

# Aile Araştırmalarında Makine Öğrenmesi: Sistemik Bir Gözden Geçirme

## Machine Learning in Family Research: A Systematic Review

 Gizem Kavalcı<sup>1</sup>,  Gözde Sayın Karakaş<sup>1</sup>

<sup>1</sup>Aydın Adnan Menderes Üniversitesi, Aydın

### ÖZ

Makine öğrenmesi, büyük veri setlerinden anlamlı örüntüler çıkarmak ve tahmine dayalı modelleme yapmak için kullanılan güçlü bir araçtır. Son yıllarda, makine öğrenmesi yöntemleri aile bilimleri, ruh sağlığı ve eğitim araştırmalarında giderek daha fazla uygulanmaktadır. Bu sistemik gözden geçirme, makine öğrenmesi yöntemlerinin aile dinamikleri, bireylerin ruh sağlığı, eğitim başarıları ve davranışsal sonuçları üzerindeki etkilerini anlamada nasıl kullanıldığını değerlendirmeyi amaçlamaktadır. Çalışmada, Web of Science, PubMed, Scopus, Science Direct, Ulakbim ve TRDizin veri tabanlarında kapsamlı bir literatür taraması yapılmış ve PICOS kriterlerine uygun 11 çalışma analiz edilmiştir. İncelenen çalışmalar, makine öğrenmesi algoritmalarının aile içi şiddet, depresyon, akademik başarı ve çocukların psikososyal gelişimi gibi konularda güçlü öngörüler sunduğunu ortaya koymaktadır. Özellikle Rasgele Orman (RF), Destek Vektör Makineleri (SVM), derin öğrenme ve doğal dil işleme (NLP) yöntemlerinin yüksek doğruluk oranlarıyla tahmin yapabildiği görülmektedir. Ancak, model şeffaflığı, etik kaygılar ve aile bağlamında uygulanabilirlik gibi konular, makine öğrenmesi modellerinin sınırlılıkları arasında yer almaktadır. Bu nedenle, gelecekteki araştırmalarda, makine öğrenmesi yaklaşımlarının daha açıklanabilir hale getirilmesi, kuramsal modellerle entegre edilmesi ve aile bilimleri alanında daha fazla ampirik araştırma ile desteklenmesi önerilmektedir. Böylece, makine öğrenmesi teknikleri aile içi dinamikleri daha iyi anlamak ve bireylerin ruh sağlığını desteklemek için daha etkin bir şekilde kullanılabilir.

**Anahtar sözcükler:** Makine öğrenmesi, aile dinamikleri, ruh sağlığı, tahmine dayalı modelleme, yapay zeka

### ABSTRACT

Machine learning is a powerful tool for extracting meaningful patterns from large datasets and performing predictive modeling. In recent years, machine learning methods have been increasingly applied in family sciences, mental health, and educational research. This systematic review aims to evaluate how machine learning methods are used to understand the impact of family dynamics on individuals' mental health, educational attainment, and behavioral outcomes. A comprehensive literature search was conducted in the Web of Science, PubMed, Scopus, Science Direct, Ulakbim, and TRDizin databases, and 11 studies meeting the PICOS criteria were analyzed. The reviewed studies indicate that machine learning algorithms provide strong predictions in areas such as domestic violence, depression, academic achievement, and children's psychosocial development. In particular, Random Forest (RF), Support Vector Machines (SVM), deep learning, and natural language processing (NLP) methods have demonstrated high accuracy in predictive tasks. However, challenges related to model transparency, ethical concerns, and applicability within the family context remain among the limitations of machine learning models. Therefore, future research should focus on enhancing the interpretability of machine learning approaches, integrating them with theoretical models, and supporting their application in family sciences with more empirical studies. By doing so, machine learning techniques can be used more effectively to understand family dynamics and support individuals' mental health.

**Keywords:** Machine learning, family dynamics, mental health, predictive modeling, artificial intelligence

## Giriş

Makine öğrenmesinin temeli, 1957 yılında psikolog Frank Rosenblatt'ın Cornell Üniversitesi'nde gerçekleştirdiği çalışmalarla ilişkilendirilmektedir. Rosenblatt, sinir sisteminin çalışma prensiplerinden ilham alarak, alfabe harflerini tanıyabilen bir makine tasarlamıştır. Bu makine, "Perceptron" olarak adlandırılmış ve hem analog hem de dijital sinyalleri kullanabilen bir yapı üzerine inşa edilmiştir. Perceptron, analog sinyalleri dijital sinyallere dönüştüren bir eşik elemanı içermekteydi ve bu özellik, modern yapay sinir ağlarının (YSA) prototipi olarak kabul edilmektedir (Fradkov 2020). Bu bağlamda, Perceptron, makine öğrenmesinin ve yapay zekânın gelişiminde önemli bir kilometre taşı olmuş ve günümüzün derin öğrenme tekniklerinin temelini atmıştır.

Birçok yöntem bir birey hakkında bilinmeyen mevcut ve gelecekteki özellikleri tahmin etmeye çalışır (Tversky ve Kahneman 1974). Sınıflandırma ve regresyon modelleme gibi istatistiksel yaklaşımlar, verilerde gözlemlenen ilişkileri kullanarak daha iyi bir sınıflama ve tahmin yapmayı amaçlar (De'ath ve Fabricius 2000). Benzer şekilde, makine öğrenmesi, verilerde gözlemlenen kalıplara dayanarak sınıflandırma ve tahmin etme araçları koleksiyonu sağlar. Son zamanlarda, makine öğrenme, geniş sağlık veri depolarının (örneğin elektronik tıbbi kayıt veritabanları) artan kullanılabilirliği ve bilgi işlem gücündeki gelişmeler nedeniyle, aile hekimliği araştırması da dahil olmak üzere sağlık araştırmalarında sınıflandırma ve tahmin görevleri için dikkat çekmiştir (Lin 2022).

Makine öğrenmesi (Mitchell 2010), sınıflandırma ve tahmin gibi görevleri gerçekleştirmek için verilerdeki ("öğrenme") kalıplarını belirlemeye yönelik otomatik süreci tanımlar. Makine öğrenme, bilgisayarların bilgiyi "akıllıca" nasıl "düşünebileceğini" veya işleyebileceğini ele alan yapay zekânın bir alt alanıdır. Bilinen regresyon tabanlı tekniklere benzer şekilde, sınıflandırma veya tahmin için sonucun belirlenmesi, sonuca ulaşmak için gerekli olan verilerin seçilmesi ve sınıflandırma veya tahmin için kullanılan değişkenlerin belirlenmesi dahil olmak üzere çeşitli kullanıcı kararları gerektirir (Black ve ark. 2023). Sınıflandırma ve tahmin etmede kullanılan makine öğrenme yaklaşımları denetimli öğrenme teknikleri (supervised learning) olarak adlandırılır (Sutton ve Barto 2018). Diğer alt alanları denetimsiz öğrenme (unsupervised learning) ve pekiştirmeli (takviyeli) öğrenmeyi (reinforcement learning) içerir (Hastie ve ark. 2009, Sutton ve Barto 2018). Denetimsiz öğrenme alanında sadece giriş verileri vardır ve çıktı verileri belirsizdir. Amaç verilerdeki gizli desenleri veya grupları bulmaktır. Örneğin; kümeleme ve boyut indirgeme. Pekiştirmeli öğrenme de ise, bir ajan çevreden aldığı ödül/cezaya göre öğrenme gerçekleştirir. Pekiştirmeli öğrenme uzun vadeli ödülü en üst düzeye çıkarmayı amaçlar. Örneğin otonom araçların güvenli sürüşleri ve çarpışmadan kaçınmaları, oyun oynayan yapay zekâlar, reklamların kullanıcıya göre yansıtılması (ödül: reklama tıklanması, ceza: reklamın görmezden gelinmesi)(Ongsulee 2018, Sutton ve Barto 2018).

Denetimli öğrenme, bilinen verilerdeki sonuçları kullanarak, gözlemlenmeyen sonuçları nasıl sınıflandıracağını ve tahmin edeceğini öğrenir. Bu genellikle bilinen sonuçlar ve tahmin edici değişkenler arasındaki ilişkileri öğrenerek yeni sonuçları sınıflaması ve tahmin etmesiyle elde edilir (Black ve ark. 2023). Diğer bir deyişle, bu aşamada girdiler ve çıktılar bellidir ve denetimli öğrenme, girdiler ile çıktılar arasındaki ilişkiyi öğrenmeyi amaçlar. Örneğin; e-posta spam filtesi ya da el yazısı tanıma (Ongsulee 2018). Denetimli öğrenme tekniklerinin diğer yaklaşımları, karar ağacı (decision tree), rastgele ormanlar (RF, random forest) (Quinlan 1986), destek vektör makineleri (SVM, Burges 1998; support vector machines), k-en yakın komşuluk (k-nearest neighbours (Patrick ve Fischer 1970), Naive Bayes sınıflandırıcısı (James ve ark. 2021), sinir ağları, lineer ve logistik regresyon (James ve ark. 2021), sinir ağları (neural networks; Bishop 1994) olarak belirtilmiştir.

Karar ağaçları, verileri öngörücü özelliklere göre homojen sonuçlara sahip iki veya daha fazla gruba tekrar tekrar böler. Veriler grup içi benzerliğin (grupların homojenliğini) en üst düzeye çıkaran değişkene maksimum bölme sayısı gibi bir durdurma kriterine ulaşana kadar devam ettirilir. Yeni bir bireyin sonucu, belirlenen bölme kurallarının değerlendirilmesi ve son gruptaki gözlenen sonucun atanmasıyla tahmin edilir.

RF, karar ağacı geliştirme sırasında dahil edilen gözlemler ve değişkenler değiştirilerek oluşturulur. Yeni sınıflandırmalar ve tahminler, her bileşen ağacından gelen tahminlerin fikir birliğine dayanır.

SVM (Burges 1998); verilerin özellik üzerinde tanımlanan özellik alanını parçalara ayıran n boyutlu bir düzlem üzerinde gruplara ayrılır. Yeni bireyler özellik alanında buldukları bölümün sonucuna atanır.

K-en yakın komşuluk (k-nearest neighbours (Patrick ve Fischer 1970); yeni veriler, sonuçları bilinen verilerle karşılaştırılır. Yeni bir bireyin sınıflandırılmış veya tahmin edilen sonucu, yeni bireye en çok benzeyen k bireyin sonuçlarına göre belirlenir.

Sinir ağları (neural networks; Bishop 1994); bilgi işlemek için birbiriyle bağlantılı düğümlerin (nodes) katmanlar halinde düzenlendiği bir sistemdir. Düğümler, dışarıdan gelen sinyalleri alır. Bu sinyaller genellikle verilerden gelir (örneğin, bir resimden gelen piksel bilgileri). Her düğüme bir ağırlık (weight) atanır. Bu ağırlıklar, gelen sinyalin ne kadar önemli olduğunu belirler. Örneğin, bir sinyalin ağırlığı yüksekse, bu sinyal daha fazla etki eder. Gelen sinyal, düğüm içinde bir matematiksel işlemden geçirilir (genelde toplam ve aktivasyon fonksiyonu kullanılır). İşlemden sonra, düğüm bir çıkış üretir. Bu çıkış, bir sonraki katmana iletilir. Gizli katmanlar, bilgiyi işleyerek daha karmaşık özellikleri öğrenir. Çıkış katmanına ulaşıldığında, sistem nihai sonucu üretir. Örneğin, bir resmin kedi mi yoksa köpek mi olduğunu belirleyebilir. Sinir ağlarının temel amacı, verilen bir görevi en iyi şekilde öğrenmek için ağırlıkları optimize etmektir. Bu, eğitim sürecinde hata miktarını azaltarak gerçekleştirilir.

Lineer ve lojistik regresyon (James ve ark. 2021); verilerde gözlemlenen ilişkilere dayanarak bir veya daha fazla değişkeni bazı sonuçlarla ilişkilendirir. Doğrusal regresyon, bazı matematiksel kriterlere göre verilere en iyi uyan çizgiyi bulur. Lojistik regresyon da benzer şekilde lojistik fonksiyonu uyguladıktan sonra verilere en iyi uyan çizgiyi bulur.

Naive Bayes sınıflandırıcısı (James ve ark. 2021), başlangıçtaki bir öncül olasılığı, veride gözlemlenen özelliklerin duruma ilişkili frekanslarına dayanarak güncelleyen basit bir olasılık temelli sınıflandırıcıdır. Bu model, tüm özelliklerin birbirinden bağımsız olduğu varsayımına dayanarak çalışır; bu nedenle "naive" olarak adlandırılır.

Denetimli makine öğrenmesi (DMÖ), tahmin edici değişkenler ile sonuçlar arasındaki ilişkileri öğrenerek sınıflandırma veya tahmin yapar ve genellikle istatistiklerle yakından ilişkilidir. Makine öğrenmesi, özellikle sağlık araştırmalarında, olası neden-sonuç ilişkilerini anlamak veya karıştırıcı değişkenleri dengelemek gibi istatistiksel analizlere destek olabilir. ML, parametrik modellerin ötesine geçerek, k-en yakın komşular gibi yöntemlerle veri yapısı hakkında varsayımında bulunmadan tahmin yapabilir. İstatistiksel ve makine öğrenmesi modelleri, sonuç ve tahmin ediciler arasındaki ilişkileri özetlemek için bir arada kullanılabilir (Black ve ark. 2023).

Makine öğrenim yapay zekanın bir alt kümesidir. Derin öğrenme de makine öğrenmesinin bir alt kümesidir. Esasen, tüm derin öğrenme makine öğrenmesidir ve tüm makine öğrenmesi yapay zekadır, ancak tüm yapay zeka makine öğrenmesi değildir (Ongsulee 2018). Derin öğrenme, yapay sinir ağlarını kullanır ve bu ağlar, insan beyninden esinlenerek tasarlanmıştır. Makine öğrenmesinin diğer algoritmalarından farkı, özellik çıkarımını otomatik yapmasıdır. Derin öğrenme, katmanlı yapısıyla büyük veri setlerindeki karmaşık ilişkileri öğrenebilir. Denetimli, denetimsiz ve pekiştirmeli öğrenme yöntemleriyle birlikte çalışabilir (Bengio ve ark. 2015).

Dijital çağda, veri kümelerinin boyutlarının hızla büyümesi ve hesaplama gücüne kolayca erişim sağlanması, makine öğrenmesinin faydalarını sosyal bilimler başta olmak üzere birçok alanda öne çıkarmaktadır. Ev ziyareti hizmetlerine ihtiyaç duyan aileleri belirleme, (Ahn ve ark. 2024); yoğun bakımda kalan bireylerin aile üyelerinin travma sonrası stres bozukluğu risk değerlendirmesi (Dupont ve ark. 2024); ergenlerin ebeveyn çatışmasına tanık olma durumlarıyla ilgili risk faktörlerinin belirlenmesi (Lopez-Larrosa ve ark. 2022) gibi pek çok konuda makine öğrenmesinden yararlanıldığı görülmüştür. Doğu Afrika'da anne, çocuk ve yeni doğan bebeklerin sağlık hizmetlerini sürekli alamama durumunun belirleyicinin makine öğrenmesi yönetimiyle incelendiği (Mlandu ve ark. 2023); çocuk refahını inceleme sistemindeki başvuruların makine öğrenmesi ile incelendiği (Schwartz ve ark. 2017) birçok çalışma farklı alanlarla sürdürülmüştür. Risk altındaki çocuklara ve ailelere yardımcı hedeflemek için doğru tahminlere ulaşmak, kişinin yaşamının seyri ile yaşamın sonucunun öngörülebilirliği, sosyal bağlamlar arasındaki öngörülemeyen farklılıkları anlama

çabaları, bilimsel keşiflerin ve sosyal politikaların geliştirilmesine olası katkısı ve çocuklar, ebeveynler ve hane halkından oluşan aile yapısının yaşam sonuçlarını ölçmek amacıyla birçok çalışma yürütülmüştür.

Ruh sağlığı alanında makine öğrenmesi, son yıllarda giderek artan bir araştırma alanı haline gelmektedir (Le Glaz ve ark. 2021, Chung ve Teo, 2022). Gözetimli makine öğrenmesi yöntemleri, tanı doğruluğunu artırmak, klinik durumların seyrini öngörmek ve riskli bireyleri erken belirlemek için çeşitli bağlamlarda test edilmiştir. Bu kapsamda doğum sonrası depresyon (Zhong ve ark. 2022), elektronik sağlık kayıtlarından elde edilen ruh sağlığı krizleri (Garriga ve ark. 2022), intihar davranışı (Kusuma ve ark. 2022), uyku ve klinik sağlık göstergelerine dayalı depresif semptomlar (Gomes ve ark. 2023), ergen ruh sağlığı (Rothenberg ve ark. 2023) ve bipolar bozuklukta ruh hali değişimleri (Sankar ve ark. 2023) gibi alanlarda umut verici sonuçlar elde edilmiştir. Ayrıca bilişsel-davranışçı terapi (Vieira ve ark. 2022), klinik depresyon tedavisi (Sajjadian ve ark. 2021) ve travma sonrası stres bozukluğuna yönelik bilişsel işleme terapisi (Nixon ve ark. 2021) gibi müdahalelerde tedaviye yanıtın öngörülmesi için de kullanılmaktadır. Bu bulgular, yapay zekâ tabanlı modellerin hem klinik karar süreçlerini destekleyebileceğini hem de kişiselleştirilmiş ruh sağlığı hizmetlerinin gelişimine katkıda bulunabileceğini göstermektedir.

Makine öğrenmesi algoritmaları, aynı anda çok sayıda değişkeni işleyebilme ve veriler arasındaki karmaşık ilişkileri ortaya çıkarabilme kapasitesiyle, geleneksel istatistiksel yöntemlerin ötesine geçmektedir (Yarkoni ve ark. 2017, Ivaskevics ve Haller 2022) Bu özellik, aile çalışmalarında özellikle önemlidir; çünkü aile yapısı ve işlevselliği, bireyler arası etkileşimlerin çok boyutlu örüntülerini içerir. Aile temelli psikososyal tedavilerin kanıt temelli araştırmalarda etkili olduğu bilinmektedir (Naar-King ve ark. 2016, Baldwin ve ark. 2023). Makine öğrenmesi, bu tür müdahalelerde hangi ailelerin hangi koşullarda daha fazla yarar göreceğini tahmin etme potansiyeline sahiptir. Böylece hem aile dinamiklerinin daha ayrıntılı anlaşılmasına hem de tedavi planlarının daha hassas biçimde uyarlanmasına katkı sağlayabilir.

Aile, bireylerin sosyal, duygusal ve davranışsal temellerinin şekillendiği bir yapı taşıdır. Modern veri analitiği yöntemleri, özellikle makine öğrenmesi, bu karmaşık dinamikleri daha önce mümkün olmayan bir derinlikle inceleme fırsatı sunmaktadır. Aile üyelerinin birbirleriyle olan etkileşimlerinden toplumsal değişimlerin aile yapısı üzerindeki etkilerine kadar geniş bir yelpazede, makine öğrenmesi sayesinde aile üzerine yapılan araştırmalar daha kapsamlı ve öngörülebilir hale gelmiştir. Bu bağlamda, makine öğrenmesi, ailelerin karşılaştığı kritik zorlukları anlamak ve çözüm önerileri geliştirmek için devrim niteliğinde bir yöntem sunmaktadır. Makine öğrenmesiyle incelenen aile ve aile üyelerinin dinamikleriyle ilgili çeşitli araştırmalar yürütülmüştür. Makine öğrenmesi, çocuk istismarı (Chouldechova ve ark. 2018), baba yokluğunun etkileri (Liu 2022), genç yaşta hamilelik (Harding ve ark. 2022) ve çift ilişki kalitesi (Joel ve ark. 2020) gibi aile ve ilişki çalışmalarında uygulanmıştır. Daha önce yapılan araştırmalar, makine öğrenmesinin geniş kapsamı ve karmaşıklığı nedeniyle tüm yönleriyle tek bir çalışmada ele alınmasının zorluklarını ortaya koymuştur. Örneğin, 160 ekibin aile yaşamını etkileyen dönüm noktalarını incelemek amacıyla geliştirdiği tahmin modellerinin başarısız olması (Salganik ve ark. 2020) ve aileyle ilgili verilerin hem sayıca hem de kategorik olarak fazlalığının modelleme sürecini zorlaştırması (Hastie ve ark. 2009) bu durumu desteklemektedir. Bu nedenle, makine öğrenmesinin metodolojik çeşitliliği ve sunduğu geniş fırsatlar dikkate alındığında, konunun tek bir çalışmada kapsamlı biçimde değerlendirilmesi mümkün görünmemektedir. Bu nedenle, bu makale, aile araştırmalarında yararlı olduğu kanıtlanmış makine öğrenmesi araştırmalarını aile bilimini ilerletmedeki yararlılığını tartışmayı ve uygulama biçimlerini bir dizi örnek analizle göstermeyi amaçlamaktadır.

Psikolojide sıklıkla açıklayıcı (explain) modellere odaklanılırken, makine öğrenmesi daha çok tahmine (predict) yönelik güçlü araçlar sunmaktadır. Bu ayrım, aile araştırmalarında da yöntemsel zorlukların anlaşılmasını kolaylaştırır (Yarkoni ve Westfall 2017). Aile çalışmalarında ölçüm hataları, boylamsal analiz zorlukları ve küçük örneklem sorunları, elde edilen bulguların güvenilirliğini ve genellenebilirliğini sınırlayan temel metodolojik güçlükler olarak görülmektedir.

Psikoloji ve aile araştırmalarında ölçüm hataları, gerek sistematik yanlışlık gerekse rastlantısal varyans kaynaklı olarak bulguların güvenilirliğini sınırlandırmaktadır. Geleneksel istatistiksel yöntemler bu hataları modele doğrudan yansıtırlarken, makine öğrenmesi algoritmaları bias-variance dengesini optimize ederek hem sistematik hatayı hem de örnekleme bağlı değişkenliği en aza indirme kapasitesine sahiptir (Yarkoni

ve Westfall 2017). Bu özellik, aile çalışmalarında daha tutarlı ve genellenebilir sonuçlar elde edilmesine katkı sağlamaktadır.

Aile dinamiklerini anlamaya yönelik araştırmalar sıklıkla boylamsal tasarımlara dayansa da, tekrarlayan ölçümler ve çok değişkenli ilişkilerin karmaşıklığı, geleneksel modellerle güvenilir biçimde çözümlenmesini güçleştirmektedir. Makine öğrenmesi yaklaşımları, özellikle çapraz doğrulama gibi yöntemler aracılığıyla modellerin yalnızca mevcut veriye değil, yeni örneklemelere de genellenebilir olmasını sağlamaktadır (Simmons ve ark. 2011, Yarkoni ve Westfall 2017). Böylece zaman içerisindeki değişimlerin daha doğru biçimde izlenmesi ve aile yapısındaki dinamik ilişkilerin daha güvenilir şekilde ortaya konulması mümkün olmaktadır.

Aile araştırmaları sıklıkla sınırlı örneklem büyüklükleriyle yürütülmektedir. Bu durum, modellerde aşırı uyum (overfitting) riskini artırmakta ve elde edilen bulguların farklı örneklemelerde tekrarlanabilirliğini azaltmaktadır (Cohen 1962, 1992, Ioannidis 2008, Yarkoni 2009). Literatürde, küçük örneklemelerden elde edilen güçlü etkilerin daha geniş veri setlerinde genellikle kaybolduğu belirtilmektedir. Makine öğrenmesi, büyük ölçekli veri setleriyle çalışmaya elverişli yapısı ve düzenleme teknikleri sayesinde bu sınırlılığı aşarak, bulguların hem içsel tutarlılığını hem de genellenebilirliğini artırmaktadır.

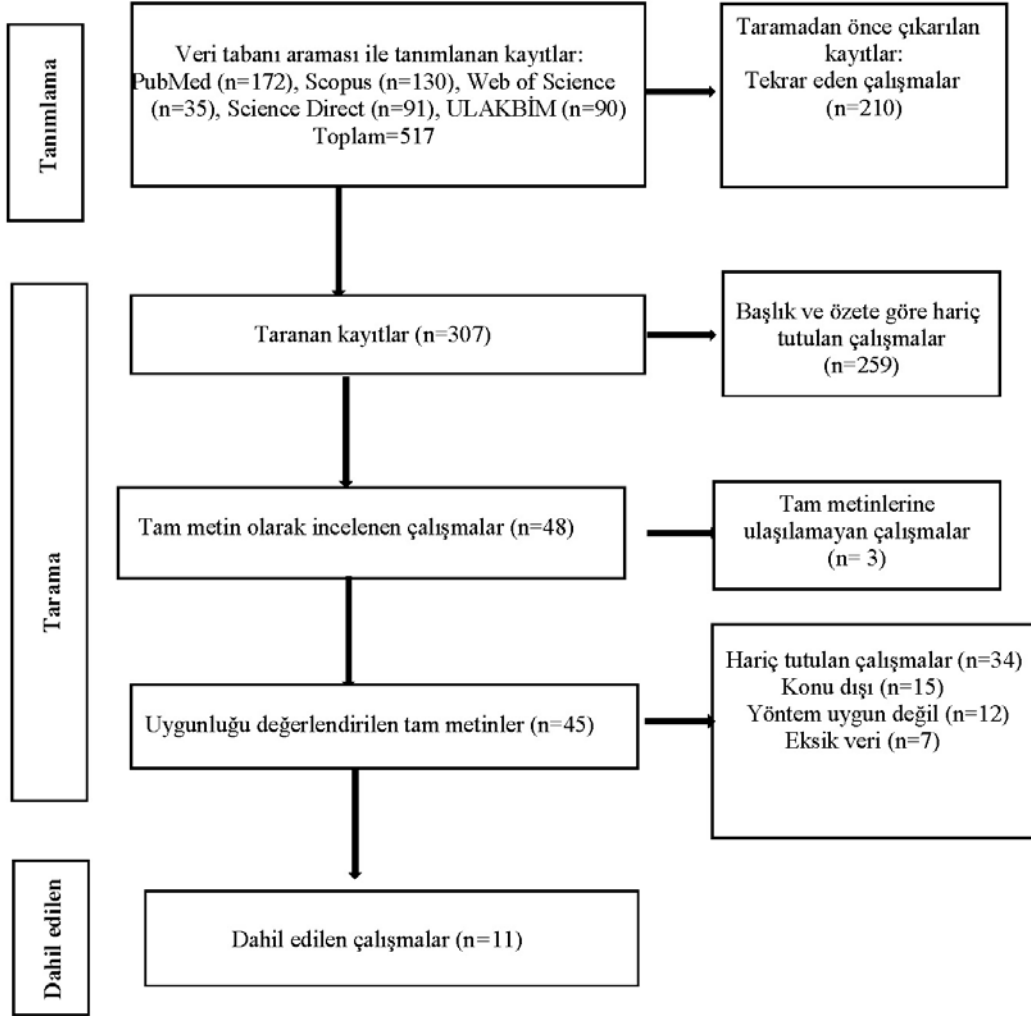
Makine öğrenmesi, matematiksel algoritmalar kullanarak bilgisayarların bağımsız bir şekilde öğrenmesini ve gelişmesini sağlayan bir teknoloji alt kümesidir. Bu yöntem, çocuklar ve aileler için önemli olan sağlık sonuçları ve tahmin faktörleri arasındaki kalıpları (örneğin, norovirüs salgınları veya çocuk istismarı riski) belirlemek amacıyla veriyle modeller oluşturmak için kullanılabilir (Salganik ve ark. 2020, Syed ve ark. 2022, Tiyyagura ve ark. 2022). Son yıllarda bu alanda ilgili çalışmalar artmasına rağmen, kanıt tabanı hakkında sınırlı bir anlayış bulunmaktadır. Makine öğrenmesi araçlarının niteliği, uygulanan yöntemler, elde edilen sonuçların birleştirilmesi ve etik kullanımı gibi önemli sorular hala yanıtızdır. Aile verilerinin toplanması ve analiz edilmesi ya da ailelere kaynak ve hizmet sunulması için makine öğrenmesini kullanan uygulamalı aile çalışmalarıyla ilgili kanıt tabanını anlamak büyük önem taşımaktadır. Bu anlayış, araştırmacılara makine öğrenmesini uygulamalı aile bilimi alanında yenilikçi ve uygulanabilir bir araç olarak değerlendirme fırsatı sunarken, aynı zamanda aile uygulayıcıları ve politika yapıcılar için makine öğrenmesi destekli karar araçlarının geliştirilmesine de katkı sağlayacaktır. Bu doğrultuda kapsam inceleme çalışması, makine öğrenmesinin ailelerin psikolojik sağlığı ve risk faktörlerini incelemek amacıyla nasıl kullanıldığını anlamak için, uygulamalı aile bilimine yönelik ampirik literatürü kapsamlı bir şekilde ele almayı hedeflemektedir.

## Yöntem

Mevcut sistematik derleme, PRISMA (Preferred Reporting Items for Systematic Reviews and Meta Analyses) kriterleri (Moher ve ark. 2015) doğrultusunda yürütülmüştür. Bu doğrultuda Web of Science (WOS), PubMed, Scopus, Science Direct, Ulakbim ve TRDizin veri tabanları çalışma konusunun güncel olması nedeniyle herhangi bir tarih kriteri olmadan taranmıştır. Literatür taraması Kasım 2024 - Ocak 2025 tarihleri arasında yürütülmüştür. Taramalarda hem İngilizce hem de Türkçe anahtar kelimeler kullanılmıştır. Kullanılan İngilizce anahtar kelimeler: ("machine learning") AND ("family" OR "parent") AND ("assessment" OR "treatment" OR "screening") AND ("families"); Türkçe karşılıkları ise: ("makine öğrenmesi") AND ("aile" OR "ebeveyn") AND ("değerlendirme" OR "müdahale" OR "tarama") AND ("aileler") şeklinde belirlenmiştir. Anahtar kelimeler Boolean operatörleri aracılığıyla birleştirilmiş ve farklı kombinasyonlarla da denenmiştir. Yapılan tarama sonucunda, PubMed (n=172), Scopus (n=130), Web of Science (n=35), Science Direct (n=91), ULAKBİM (n=90), TRDizin (n=0) veri tabanları aracılığıyla toplam 517 çalışmaya ulaşılmıştır. Tekrar eden çalışmalar (n=210) çıkarıldığında, geriye kalan 307 çalışmanın başlık ve özet bölümleri dahil etme kriterleri açısından değerlendirilmiş, 48 çalışmanın tam metnin incelenebileceği sonucuna ulaşılmıştır. PICOS ölçütleriyle tam metni incelenen 48 çalışmadan da 11 tanesinin kriterleri karşılıdığı görülerek çalışmaya dahil edilmiştir.

Başlangıçta ulaşılan 517 çalışmadan tekrar edenler çıkarıldıktan sonra 307 benzersiz kayıt elde edilmiştir. İlk aşamada başlık ve özetler değerlendirilmiş, P (Popülasyon) ve I (Müdahale) kriterlerini karşılamayan, yani aile üyelerini kapsamayan, yalnızca birey odaklı olan veya makine öğrenmesi içermeyen çalışmalar dışlanmıştır. Bu aşama sonucunda 48 çalışma tam metin incelemesine alınmıştır. Tam metin

değerlendirmesinde O (Sonuç) ve S (Araştırma Deseni) kriterleri uygulanmış; aile yapısının birey üzerindeki koruyucu ve risk faktörlerini incelemeyen, yalnızca ekonomik ya da hukuki odaklı olan, derleme veya protokol niteliğindeki raporlar ile foster family çalışmaları dışlanmıştır. C (Karşılaştırma) kriteri için herhangi bir sınırlama getirilmemiştir. Bu adımlar sonucunda 37 çalışma elenmiş ve toplamda 11 çalışma sistematik derlemeye dahil edilmiştir.



Şekil 1. PRISMA akış şeması

### Çalışmaya Dahil Etme ve Dışlama Kriterleri

Çalışmanın dahil etme kriterleri, PICO (S) (P: Population- Popülasyon, I: Intervention - Müdahale, C: Comparator - Karşılaştırma, O: Outcome - Sonuç, S: Study design - Araştırma deseni [PICO (S)]) modeli kapsamında belirlenmiştir (Tablo 1). Buna göre, (P) Aile üyelerini kapsayan, ebeveynler ya da çocukları ile yürütülen aile araştırmaları (I), aile yapısında değişimden etkilenen veya aile yapısını etkileyen makine öğrenmesi tekniği ile incelenen, (C) karşılaştırma kriteri kullanılmadan, (O) aile yapısının birey üzerindeki koruyucu ve risk faktörlerinin incelendiği, (S) makine öğrenmesi yöntemiyle karşılaştırma ve tahminler sunan çalışmalar derlemeye dahil edilmiştir. Çalışma kapsamında, aile yapısı yerine sadece bireyi hedef alan, tek bir aile üyesinin fiziksel sağlığını ele alan ve aile üyelerin bakımveren konumunda olduğu çalışmalar, aile ile ilgili genetik değişimin temel alındığı, ailenin koruyucu ve risk faktörü olarak çalışılmadığı çalışmalar hariç tutulmuştur. Dolaylı olarak psikolojik sağlığın çalışıldığı ancak sadece ekonomik ya da hukuki gelişmeleri hedef alan çalışmalar, tamamlanmamış çalışmalar (protokols), koruyucu ailelerle yapılan çalışmalar (foster family) bu çalışmaya dahil edilmemiştir. Derleme makaleler hariç tutulmuştur. Sonuç olarak, toplamda 11 makale mevcut çalışmaya dahil edilmiştir. Süreç Şekil 1'de özetlenmiştir (Şekil 1).

<b>Tablo 1. PICOS kriterleri</b>		
<b>Kriter</b>	<b>Dahil Etme</b>	<b>Dışlama</b>
P(Population–Popülasyon)	Aile üyelerini kapsayan; ebeveynler veya çocuklarla yürütülen aile araştırmaları	Sadece bireyi hedef alan; tek bir aile üyesinin yalnızca fiziksel sağlığını ele alan; bakımveren konumundaki aile üyeleriyle sınırlı çalışmalar
I (Intervention – Müdahale)	Aile yapısında değişimden etkilenen veya aile yapısını etkileyen ve makine öğrenmesi tekniği ile incelenen çalışmalar	Aile ile ilgili genetik değişim temelli olup aileyi koruyucu/risk faktörü olarak ele almayan çalışmalar
C(Comparator-Karşılaştırma)	Karşılaştırma kriteri kullanılmadan yapılan çalışmalar kabul edilmiştir.	–
O (Outcome – Sonuç)	Aile yapısının birey üzerindeki koruyucu ve risk faktörlerini inceleyen çalışmalar	Dolaylı olarak psikolojik sağlığı çalışsa da yalnızca ekonomik veya hukuki gelişmeleri hedef alan çalışmalar
S(Study Design – Araştırma Deseni)	Makine öğrenmesi yöntemiyle karşılaştırma ve tahminler sunan özgün araştırmalar	Tamamlanmamış çalışmalar (protokoller), koruyucu ailelerle (foster family) yapılan çalışmalar, derleme makaleler

## Bulgular

Sistemik gözden geçirme çalışması kapsamında dahil edilen makaleler, örneklem özellikleri, temel ölçüm araçları, araştırma deseni, müdahale özellikleri ve etkileri açısından ele alınmıştır. İlgili tablo Tablo 2’de özetlenmiştir (Tablo 2).

## Örneklem Özellikleri

Makine öğrenmesi yöntemi aracılığıyla çalışmaların incelendiği çalışmalarda örneklem özellikleri oldukça değişkendir. Örneklem sayıları 61 kişi (Zheng ve Ye 2022) ile 1.16 milyon kullanıcı verilerinin kullanıldığı (Li ve ark. 2021) çalışmalar arasında değişmektedir. Yürütülen çalışmaların %45.45’inde (Sun ve ark. 2020, Lopez-Larrosa ve ark. 2022, Zheng ve Ye 2022, Wang ve ark. 2023, Zhou ve ark. 2024) ergen katılımcılar aracılığıyla aile verileri toplanmıştır. Yürütülen çalışmaların %36.36’sında (Li ve ark. 2021, Gil ve ark. 2022, Berkel ve ark. 2023, Zhou ve ark. 2024) hem çocuk hem de birincil bakım vereni aracılığıyla veriler toplanmıştır. Çocukların verileri aracılığıyla aile değişkenlerinin çalışıldığı iki çalışma (Schwartz ve ark. 2017, Gao ve ark. 2024) sistemik gözden geçirme kapsamında dahil edilmiştir. Çalışmaların sadece iki tanesinde katılımcıların demografik bilgileri ayrıntılı olarak verilmiştir (Lopez-Larrosa ve ark. 2022; Sun ve Sayer 2024).

## Makine Öğrenme Yöntemleri

Makine öğrenmesi yöntemleri açısından değerlendirildiğinde, en çok kullanılan yöntemler arasında Doğal Dil İşleme (NLP), RF, Lojistik Regresyon ve Derin Öğrenme teknikleri öne çıkmaktadır. Berkel ve arkadaşları (2023) çalışmasında, NLP yöntemlerinden TF-IDF ve BERT modelleri kullanılmıştır. Gil ve arkadaşları (2022) çalışmasında Seyrek Lojistik Regresyon (SLR), SVM ve RF yöntemleri karşılaştırılmış ve RF modeli %86 doğruluk oranı ile en başarılı sonuçları vermiştir. Zhou ve arkadaşları (2024) çalışmasında ise Lojistik Regresyon ve Rastgele Orman algoritmaları karşılaştırılmış ve her iki yöntemin de yüksek doğruluk sağladığı belirtilmiştir. Diğer yandan, Schwartz ve arkadaşları (2017) çalışmasında yargıya yönlendirme süreçlerinde makine öğrenmesi modellerinin %93 doğruluk oranı ile başarılı olduğu görülmüştür. Çalışmalarda en çok tercih edilen makine öğrenmesi yöntemleri arasında RF öne çıkmaktadır ve en fazla kullanılan yöntemlerden biri olarak %30’lar seviyesinde bir yaygınlığa sahiptir. Bunu sırasıyla, Karar Ağaçları ve Logistic Regression takip etmektedir, her biri %20 civarında bir kullanım oranına sahiptir.

Tablo 2: İncelenen çalışmaların özellikleri

	Çalışma	Örneklem	Amaç	Araçlar	Değişkenler	Müdahale	Müdahale detayı	Sonuç	
1	(Berkel ve ark. 2023)	113 aile (130 ebeveyn, %92 kadın)	Aile temelli kontrol programlarının değerlendirmesini makine öğrenmesi ile incelemek	(TF-IDF ve BERT) COACH	Programın uygulanma kalitesi, ebeveyn katılım düzeyi, evde uygulama becerisi ve ebeveyn motivasyonu gibi çeşitli göstergeler.	Evet	Family Check-Up 4 Health programı	NLP yöntemleri (TF-IDF ve BERT) programın uygulanma kalitesini izlemek için geçerli ve etkili bulunmuştur.	NLP
2	(Gao ve ark. 2024)	141,356 çocuk	Toplumun, ailenin ve hastanenin birlikte katıldığı bir DEHB yönetim modelinin oluşturulması		Kişisel sağlık - Sosyal ve aile faktörleri ve Ebeveyn-çocuk etkileşim kalıpları	Hayır	Hayır	DEHB tanısı için bir algoritma 13 bağımsız belirleyiciye dayanarak oluşturulmuştur.	Lojistik regresyon
3	(Gil ve ark. 2022)	171 aile verisi (171 baba, anne ve üniversite öğrencisi)	Üniversite öğrencilerinde depresyon riskini tahmin etmek ve önemli aile ve bireysel faktörleri belirlemek için makine öğrenmesi geliştirmek	SPS STS CES-D BFI-10 FACES IV KMSS PBI	Aile uyumu Depresyon düzeyi Kişilik Özellikleri	Hayır	Hayır	Aile uyumu ve annenin depresyonu depresyonun öngörücüleri arasında açıklanmıştır.	-RF -SLR -SVM
4	(Li ve ark. 2021)	1,16 milyon aktif kullanıcının kamuya açık verileri	Aile içi şiddete maruz kalan bireylerin kişiliklerinde değişim olup olmadığını incelemek	Big Five Inventory	Şiddete uğrayan ve uğramayan grubun kişilik değişimleri karşılaştırılmıştır.	Hayır	Hayır	Aile içi şiddete maruz kaldıktan sonra mağdurların nevrotikliğinin arttığını ve sorumluluğun azaldığını göstermiştir.	Dilsel Sorgulama ve Kelime Sayımı
5	(Lopez-Larrosa ve ark. 2022)	251 İspanyol ergen ( $M_{yaş}=15,59,SD=1.74$ ).	Aileleriyle birlikte yaşayan ve yaşamayan aile ergenlerin çatışmasına katılımını incelemek	-CPIC -SIFS -HFBWAQ -CV -MOVQ	Aile çatışmasına katılımı tahmin eden değişkenleri incelemişlerdir.	Hayır	Hayır	Ergenlerin aile çatışmalarına katılımını %65 doğruluk oranıyla tahmin edebilmiştir.	-K-En Yakın Komşu, Naive Bayes - SVM - Karar Ağaçları (C5.0), -RF
6	(Schwartz ve ark. 2017)	78.394 Bireysel çocuk vakası	Düşük, orta ve yüksek riskli vakaların daha doğru bir şekilde tespit edilmesi	-	Çocuk Koruma servisinde yapılan yönlendirmeler	Hayır		Çocuk refahı risk değerlendirme aracının doğruluğunu ve faydasını önemli ölçüde artırdığını göstermektedir	Karar Ağacı Regresyon
7	(Sun ve Sayer 2024)	5114 ergen ( $M_{yaş}=15$ ) Ebeveynleri (N = 4548; 92.71%)	Ergenlik döneminde ölçülen aile deneyimi değişkenlerinin	-	Aile deneyimi değişkenleri ile okul başarısı yordayıcılarını keşfetmek	Hayır		Okul başarısıyla ilgili 14 aile değişkenine ulaşılmıştır.	DMÖ, RF



Tablo 2: İncelenen çalışmaların özellikleri

	Çalışma	Örneklem	Amaç	Araçlar	Değişkenler	Müdahale	Müdahale detayı	Sonuç	
		anneleri, Myaş = 41.51, SD = 6.35)	eğitim başarısı ile ilişkisini incelemek						
8	(Sun ve ark. 2020)	5114 ergen (Myaş= 15)	Ergenlik dönemi aile deneyimi faktörlerinin eğitim başarısındaki öngörücü değişkenleri incelemek	Aile değişkenleri ve üniversiteye devam etme ya da kayıt olma	Okul başarısı üzerinde etkili olan aile deneyimi değişkenlerinin tutarlılığını ölçmeyi denemişler.	Hayır	Hayır	Aile deneyimleri genç yetişkinlerin başarısını %72,33-79,10 doğrulukla tahmin etmiştir.	Düzenleştirilmiş lojistik regresyon RF
9	(Wang ve ark. 2023)	2455 öğrenci (Yaş grubu ayrımı yapılmaksızın)	Aile ve okul alanlarında depresyonun risk/koruyucu faktörlerinin birleşik etkilerini incelemek	DBF	-Aile yapısı -Ebeveyn boşanması -Ebeveyn eğitimi -Aile birliği -Aile çatışması -Okul değişkenleri	Hayır	Hayır	Aile uyumu, aile çatışması, akran desteği ve öğretmen desteğinin ergen depresyonu ile ilişkili en güçlü faktörler olarak ortaya çıktığı gösterilmiştir.	İlişki Kuralı madenciliği
10	(Zheng ve Ye 2022)	61 ergen sosyal anksiyete hastası	Ergenlerde sosyal anksiyete tedavisinde BDT'nin derin öğrenme ile etkinliğini değerlendirmek	-Sosyal anksiyete ölçeği -Duygusal düzenleme - Öz-yeterlilik ölçeği	Ergenlerin sosyal anksiyete düzeylerini ve duygusal düzenleme yeterliliklerini.	Evet	BDT	Derin öğrenme yöntemiyle tedavi ve tanı aşamasında kullanılmak üzere keşifsel bir algoritma oluşturulmuştur.	Derin Öğrenme
11	(Zhou ve ark. 2024)	7967 öğrenci ve birincil bakımveren i	Ergenlik döneminde intihar dışı kendine zarar verme için aile düzeyinde risk tahmininin doğruluğunu incelemek amaçlanmıştır.	-PHQ-9 -ISI -Family APGAR -NMHLQ	Sosyodemografik bilgiler -Aile yapısı -Ergen ve ebeveyn depresyonu -Aile işlevselliği -Algılanan damgalama	Hayır	Hayır	RF yöntemi ile aile işlevi, aile çatışması ve ebeveyn depresyonu risk faktörleri olarak açıklanmıştır.	RF Lojistik Regresyon

**BERT** = Bidirectional Encoder Representations from Transformers (Çift Yönlü Kodlayıcı Temsilleri, Transformer Tabanlı Dil Modeli), **BFI-10** = Big Five Personality Inventory (Büyük Beşli Kişilik Envanteri), **CES-D** = Center for Epidemiologic Studies Depression Scale (Epidemiyolojik Araştırmalar Merkezi Depresyon), **COACH** = Cognitive Oriented Approach to Child Health (Çocuk Sağlığına Bilişsel Odaklı Yaklaşım), **CPIC** = Children's Perception of Interparental Conflict Scale (Çocukların Ebeveynler Arası Çatışma Algısı Ölçeği), **CV** = Conflict Vignette (Çatışma İçerikli Videolar), **DBF** = Demografik Bilgi Formu, **DMÖ** = Denetimli Makine Öğrenmesi, **DSRSC** = Depression Self-Rating Scale for Children (Çocuklar İçin Depresyon Öz Değerlendirme Ölçeği), **FA** = Family APGAR (Aile İşlevselliği Ölçeği), **FACES-II** = Family Adaptation and Cohesion Evaluation Scales II – Family Version (Aile Uyumu ve Birliği Değerlendirme Ölçeği II), **FACES-IV** = Family Adaptability and Cohesion Evaluation Scale IV (Aile Uyumu ve Birliği Değerlendirme Ölçeği IV), **FES** = Family Environment Scale (Aile Çevresi Ölçeği), **HFBWAQ** = How Does My Family Behave When We Have Argument Questionnaire (Tartışma Olduğunda Ailem Nasıl Davranıyor Ölçeği), **ISI** = Insomnia Severity Index (Uykusuzluk Şiddeti Ölçeği), **KMSS** = Kansas Marital Satisfaction Scale (Kansas Evlilik Doyum Ölçeği), **MOVQ** = My Opinion About the Video Questionnaire ("Video Hakkındaki Fikrim" Ölçeği), **NLP** = Natural Language Processing (Doğal Dil İşleme), **NMHQ** = National Mental Health Literacy Questionnaire (Ulusal Ruh Sağlığı Okuryazarlığı Ölçeği), **PBI** = Parental Bonding Instrument (Ebeveyn Bağlanma Aracı), **PDD** = Perceived Discrimination and Devaluation Scale (Algılanan Ayrımcılık ve Değersizlik Ölçeği), **PHQ-9** = Patient Health Questionnaire (Hasta Sağlık Ölçeği), **RF** = Random Forest (Rastgele Orman), **SIFS** = Security in the Family System Scale (Aile Sisteminde Güvenlik Ölçeği), **SPS** = Spiritual Perspective Scale (Maneviyat Algısı Ölçeği), **STS** = Self-Transcendence Scale (Kendini Aşma Ölçeği), **SVM** = Support Vector Machine (Destek Vektör Makineleri), **SLR** = Stepwise Logistic Regression (Adımsal Lojistik Regresyon), **TF-IDF** = Term Frequency – Inverse Document Frequency (Terim Frekansı – Ters Belge Frekansı)

Ayrıca, Deep Learning yöntemleri de önemli bir yer tutmakla birlikte, kullanımı %15 civarındadır. Düzenleştirilmiş Lojistik Regresyon ve Regresyon yöntemleri ise sırasıyla daha düşük oranlarda (%10) tercih edilmiştir. Bunun yanında, daha az kullanılan ancak bazı çalışmalarda yer bulan denetimli makine öğrenme yöntemleri (Association Rule Mining ve Supervised ML) gibi yöntemler de %5'lik bir paya sahiptir.

## **Makine Öğrenme ile Aile Üyelerinin Ruh Sağlığı**

Sistemik derleme kapsamında, bireylerin ruh sağlığı üzerindeki aile değişkenlerini tahmin etmeyi amaçlayan dört çalışma bulunmaktadır (Gil ve ark. 2022, Wang ve ark. 2023, Gao ve ark. 2024, Zhou ve ark. 2024). Gao ve arkadaşları (2024); dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) deneyimleyen bireylerle bireysel, ailevi ve sosyal faktörleri tahmin etmeyi amaçladıkları çalışmada aile ile ilgili risk faktörlerini zayıf ebeveyn-çocuk etkileşimi kalıpları (ebeveynler genellikle çocuklarına karşı sabırsızlık gösterir veya sık sık sinirlenmesi), erken doğum ve ebeveyn boşanması veya ayrılmasını DEHB riskinin artışıyla ilişkilendirmiştir (Gao ve ark. 2024). Aile bağlamında DEHB'nin anlaşılmasını ve yönetimini geliştirmeyi amaçlayan sosyal ve ailevi faktörleri kapsayan bir tahmin modeli geliştirilmiştir. Gil ve arkadaşları (2022); 171 anne, baba ve üniversite öğrencisinden oluşan aile verisiyle depresyon riskinin bireysel ve ailevi değişkenlerini tahmin etmeyi amaçladıkları çalışmalarında aile uyumu ve annenin depresyon düzeyinin en güçlü öngörücü olduğunu belirtmişlerdir (Gil ve ark. 2022). Ayrıca annede depresyon, solunum yolu hastalıkları ve babada kanser bulunması üniversite öğrencilerinde depresyon riskini yordamada anlamlı üç aile faktörü olarak belirlendiği açıklanmıştır. Zhou ve arkadaşları (2024); 7967 öğrenci ve birincil bakımverenleri ile yürüttükleri çalışmada intihar dışı kendine zarar verme davranışlarını inceledikleri çalışmada bulgular, aile işlevi, aile çatışması, geride bırakılma (left-behind experience) deneyimi, bir aile üyesinin ölümü deneyimi, ailede ruhsal hastalık öyküsü, ebeveyn depresyonu, ebeveyn uykusuzluğu, ebeveynlerden veya ailedeki diğer kişilerden ruhsal sıkıntıya yönelik yardım arama davranışları ve annenin lise altı eğitim düzeyinin ergenlikteki intihar dışı kendine zarar verme davranışı için önemli ailevi öngörücü faktörler olduğunu ortaya koymuştur (Zhou ve ark. 2024). Wang ve arkadaşları (2023); ilkökul ve ortaokulda okuyan toplam 2455 ergen ile yürüttükleri çalışmada; aile uyumu, aile çatışması, akran desteği ve öğretmen desteğinin ergenlik depresyonuyla ilişkili en güçlü faktörler olarak ortaya çıktığı gösterilmiştir (Wang ve ark. 2023). Düşük aile uyumu ve yüksek aile çatışması, cinsiyet, yaş grubu ve geride kalan durumdan bağımsız olarak aile faktörleri arasında en etkili tahmin edici risk faktörleri olarak ortaya çıkarmıştır.

## **Makine Öğrenmesi ile Aile İçi Müdahale ve Destek Sistemleri**

Aile ve aile üyelerine yönelik müdahalelerin etkinliğini artırmayı amaçlayan çalışmalar (Schwartz ve ark. 2017, Zheng ve Ye 2022, Berkel ve ark. 2023); bu bağlamda ele alınmıştır. Berkel ve arkadaşları (2023); kanıt temelli ebeveynlik programlarının uygulama sürecini değerlendirmek için NLP gibi makine öğrenmesi yöntemlerini kullanmayı amaçlamışlardır. Araştırmada, Ailelerin Sağlığı için Kontrol Programı (Family Check-Up 4 Health, FCU4Health) programının değerlendirilmesi, 113 aileden elde edilen 116 İngilizce ve 81 İspanyolca deşifre üzerinde gerçekleştirilmiştir. Terim Frekansı-Ters Doküman Frekansı (TF-IDF) ve Çift Yönlü Kodlayıcı Temsillerden Dönüşümler (BERT) modelleri eğitildi ve modellerin geçerliliği, uygulayıcı değerlendirmesi için kullanılan COACH (programın uygulayıcı değerlendirme sistemi) ölçütleriyle karşılaştırılarak test edildi (Berkel ve ark., 2023). Sonuçlar, her iki modelin COACH gözlemci derecelendirmeleriyle anlamlı bir ilişki gösterdiğini ortaya koymuştur. Bu çalışmada, Ailelerin Sağlığı için Kontrol Programı (FCU4Health), makine öğrenmesi yöntemleri (TF-IDF ve BERT) kullanılarak değerlendirilmiştir. Bu yöntemlerin, uygulayıcıların kullandığı COACH ölçütleriyle karşılaştırıldığında anlamlı derecede uyumlu sonuçlar verdiği gösterilmiştir. Bulgular, makine öğrenmesi yöntemlerinin ebeveynlik programlarının değerlendirilmesinde etkili bir araç olabileceğini ve uygulayıcı değerlendirmelerine katkı sunabileceğini göstermektedir. Ancak, yöntemlerin uygulayıcı değerlendirmeleriyle tamamen eşdeğer olup olmadığına dair kesin bir yargıya varılmamıştır. Ayrıca, bu modellerin oturum içi katılım, ebeveynlik oturumlarına devam, ev uygulama yeterliliği ve değişim motivasyonu gibi alanları öngörmede başarılı olduğu görülmüştür. Zheng ve arkadaşları (2022); yürüttükleri çalışmada ergenlerde derin öğrenmeye dayalı Bilişsel Davranış Terapi (BDT) uygulamasının tanı ve tedavi süreçleri hakkında derinlemesine bir çalışma yürütmeyi amaçlamışlardır (Zheng ve Ye 2022). Bu kapsamda BDT ile ergen sosyal kaygısı arasındaki

korelasyon tahmin modeli, çok amaçlı bir evrimsel algoritmaya dayanarak oluşturulmuştur. Ergen büyümesindeki risk ve koruyucu faktörler, insanlar, aile, okul ve toplum perspektiflerinden taranmasıyla bireylerin sosyal kaygısının düzeyini azaltmakta destek olacağı belirtilmiştir. Schwartz ve arkadaşları (2017); çocuk koruma merkezindeki bireysel çocuk vakalarının; yargıya doğru yönlendirilebilmesi amacıyla, 2010-2015 yılları arasında incelenen 78.394 çocuk vakasının yönlendirme kriterleri üzerine makine öğrenmesi yöntemiyle çalışmışlardır (Schwartz ve ark. 2017). Oluşturulan modelin yargıya yönlendirilmesi gereken vakaları %93 oranında belirleyebildiği açıklanmıştır. Bir algoritma kullanılmayan durumda vakaların %40'nın yanlış yönlendirme yaptığı model ile açıklanmıştır. Çalışmanın ilgi çekici bir bulgusu olarak yönlendirme ve yargıya iletme süreçlerinin güvenilirlikleri tasarlanan model aracılığıyla keşfedilmiş ve sürecin öngörücü değişkenleri arasına eklenmiştir. Yaralanmalar, ölüm ve/veya önceki raporlar dahil olmak üzere istismar ve/veya ihmal kanıtı; araştırma süreci boyunca erişimlerinin kısıtlanması dahil olmak üzere iş birliği yapmayan bakıcı davranışı; bakıcı şiddeti ve/veya suç geçmişi; güvenli olmayan/tehlikeli konut koşulları, yiyecek eksikliği; ve evde yaşayan ilgisiz kişiler olması durumları yargıya yönlendirilen vakaların öngörücüleri olarak açıklanmıştır (Schwartz ve ark., 2017).

### **Aile İçi Şiddet Risk Analizleri ve Makine Öğrenmesi Yöntemleri**

Aile içi şiddetin ailedeki bireyler üzerindeki değişimlerini ve ilgili öngörücü faktörleri tahmin etmeyi amaçlayan iki çalışma (Li ve ark. 2021, Lopez-Larrosa ve ark. 2022) bulunmaktadır. Li ve arkadaşları (2021); yürüttükleri çalışmada weibo üzerinden 1.6 milyon katılımcının aile şiddeti ile ilgili paylaşımları üzerinden iki ayrı örneklem oluşturarak, aile içi şiddetin kişilik özellikleri üzerindeki değişimini tahmin etmeyi amaçlamışlardır (Li ve ark., 2021). Yürüttükleri çalışmada şiddete uğrayan kişilerin uğramayanlara göre uyumluluk (aggreableness), neuroticism (duygusal stabilite) ve sorumluluk (conscientiousness) alanlarında istatistiksel olarak anlamlı farklılıklar olduğu gösterilmiştir. Hayatında ilk kez aile içi şiddet deneyimleyen kişilerden oluşan ikinci örneklem grubunun ise nevrozluğunun aile içi şiddet deneyimledikten sonra arttığını ve sorumluluk (conscientiousness) alt boyutunun da azaldığını göstermiştir. Çalışma kapsamında aile içi şiddet, çocukluk çağı istismarı, aile içi şiddete tanık olmak, fiziksel şiddet ve fiziksel olmayan şiddet türleri arasında bir farklılaşma olmadığı açıklanmıştır. Lopez-Larrosa ve arkadaşları (2022); yürüttükleri çalışmada ergenlerin ailelerin yanında yaşaması ve yaşamaması durumunda aile içi çatışmaya dahil olması durumundaki öngörücüleri tahmin etmeyi amaçlamışlardır (Lopez-Larrosa ve ark. 2022). Çalışmanın ilgi çekici bir bulgusu olarak katılımcıların hipotetik videolara verdikleri tepkilerin, gerçek hayattaki çatışmalara verdikleri tepkileri yordadığı açıklanmıştır. Çalışma sonuçlarında yaş, cinsiyet veya aile tipinin, aile içi çatışmaya katılımın en önemli öngörücü değişkenleri olmadığı gösterilmiştir. Ergenlerin kırsal veya kentsel yerleşim yerlerindeki okullara giden ergenleri ifade eden sosyodemografik değişkenin, ebeveynler arasındaki çatışmaya katılımın en yüksek belirleyici değeri olduğu gösterilmiştir.

### **Aile ve Eğitim Başarısı: Makine Öğrenmesi ile İlişki Analizleri**

Bireylerin eğitim başarısı üzerindeki aile öngörücü faktörlerini keşfetmek için sürdürülen iki çalışmada (Sun ve ark. 2020; Sun ve Sayer 2024) genç yetişkinlerin eğitimini yordayan aile değişkenleri incelenmiştir. Sun ve arkadaşları (2020) yürüttükleri çalışmada, bgenç yetişkinlerin akademik başarısı üzerine etkili olan aile deneyimi değişkenlerinin yordayıcı yüklerini çalışmıştır. Bu doğrultuda aile deneyimi ile ilgili değişkenler: aile yapısı (9 değişken), sosyoekonomik özellikler (10 değişken), aile ilişkileri ve ebeveynlik (12 değişken), ebeveynlerin eğitimle ilgili katılımı (7 değişken), sosyo-kültürel özellikler (5 değişken), aile sağlık kaynakları ve davranışları (11 değişken), ebeveyn ve aile ilişki geçmişi (4 değişken) ve olumsuz aile deneyimleri (4 değişken) olarak ele alınmıştır (Sun ve ark. 2020). Üniversite kaydı ve üniversite mezuniyeti sonuçlarındaki en iyi aile öngörücüleri olarak; ailenin sosyoekonomik özellikleri, ebeveynlerin eğitim beklentilerini göstermiştir. Çalışma kapsamında elde edilen aile ile ilgili 14 öngörücü değişken; anne eğitimi (olumlu etki), aile geliri (olumlu etki), baba eğitimi (olumlu etki), veli-öğretmen birlikteliğinde olma (olumlu etki), anne eğitim beklentileri (olumlu etki), kuşaklar arası yakınlaşma (olumlu etki), ebeveyn yaşı (olumlu etki), anne mesleki prestiji (olumlu etki), ebeveyn kontrolü (olumsuz etki) ve ebeveynlerle birlikte akşam yemeği yeme (olumlu etki) olarak belirtilmiştir. Sun ve Sayer (2024); Denetlenen makine öğrenmesi (Supervised machine learning) ile beraber Ulusal Ergen Sağlığı Boylamsal çalışması verileri aracılığıyla

yürütülen 143 makaleden, eğitim başarısında öngörücü olan aile değişkenlerini keşfetmeyi amaçlamıştır. Çalışma bulgularında 14 aile değişkenini tanımlamış ve aile sosyoekonomisini en yüksek öngörücü değişken gösterirken, aile içi olumsuz deneyimlerin eğitim başarısını yordamakta en az gücü sahip değişken olarak ifade etmiştir (Sun ve Sayer 2024).

## Makine Öğrenmesi ve Aile ile İlişkili Değişkenlerin Sonuçları

Makine öğrenmesi yöntemleri ve NLP teknikleri, aile, bireysel ve sosyal faktörlerin ruh sağlığı ve eğitim üzerindeki etkilerini öngörmekte etkili bulunmuştur. Berkel ve arkadaşları (2023), TF-IDF ve BERT modellerinin COACH ölçümleriyle yüksek uyum gösterdiğini ve ebeveyn katılımı gibi önemli alanları tahmin ettiğini ortaya koymuştur. Gao ve arkadaşları (2024), dikkat eksikliği ve hiperaktivite bozukluğunu %95.9 doğrulukla tahmin eden bir nomogram geliştirmiştir. Gil ve arkadaşları (2022), depresyon riskini öngörmekte RF modelinin %86 doğruluk oranı ile en iyi performansı sergilediğini belirtmiş ve aile uyumunun depresyon riskinde önemli bir faktör olduğunu vurgulamıştır. Li ve arkadaşları (2021), aile içi şiddet mağdurlarında uyumluluk ve sorumluluk puanlarının kontrol grubuna göre %5-10 oranında daha düşük olduğunu ve duygusal dengesizlik puanlarının daha yüksek olduğunu göstermiştir. Lopez-Larrosa ve arkadaşları (2022), ergenlerin aile içi çatışmalara katılım riskini %65 doğruluk oranıyla öngörmüştür. Sun ve Sayer (2024), genç yetişkinlerin eğitim düzeyinin %29'unun ailenin sosyoekonomik durumu ile ilişkili olduğunu göstermiştir. Wang ve arkadaşları (2023), depresyonun aile ve okul faktörleriyle ilişkisini inceleyerek, aile uyumu ve akran desteğinin koruyucu faktörler, aile çatışmasının ise risk faktörü olduğunu belirtmiştir. Zheng ve Ye (2022), ergenlerde sosyal kaygıyı azaltmada bilişsel davranışçı terapinin etkili olduğunu ve tedavi sonrası kaygının anlamlı düzeyde düştüğünü ortaya koymuştur. Zhou ve arkadaşları (2024), intihar dışı kendine zarar verme davranışını %85.2 doğrulukla öngörmüş ve aile işlevselliği, ebeveyn depresyonu gibi faktörlerin önemli olduğunu ortaya koymuştur. Bu bulgular, makine öğrenmesi yöntemlerinin bireylerin psikolojik ve sosyal durumlarını anlamada yüksek doğruluk oranlarıyla öngörücü güce sahip olduğunu göstermektedir.

## Tartışma

Mevcut sistematik derleme ile makine öğrenmesi yöntemlerinin aile ve aile üyelerinin sağlığı ile refahını incelemedeki kullanımını değerlendirmeyi amaçlamıştır. Özellikle aile dinamiklerinin bireylerin ruh sağlığı, eğitim başarısı ve davranışsal sonuçlar üzerindeki etkilerini öngörmekte makine öğrenmesi tekniklerinin nasıl kullanıldığını anlamak hedeflenmiştir. Tarama sonucunda PICOS dahil etme ölçütlerine uygun olduğu belirlenen 11 çalışma örneklem özellikleri, çalışma desenleri, değerlendirme araçları, müdahale yaklaşımlarının özellikleri ve müdahalelerin etkisi yönünden incelenmiştir. Derleme sonucunda, makine öğrenmesi yöntemlerinin aile içi risk ve koruyucu faktörlerin belirlenmesinde ve müdahale programlarının etkinliğini değerlendirmede etkili bir araç olabileceği görülmektedir.

Makine öğrenmesi, bireyin aile içinde deneyimlediği risk göstergelerini ve temel öngörücü değişkenleri tanımlamada önemli bir araç olarak öne çıkmaktadır. Bu sistematik derleme kapsamında ele alınan çalışmalar, makine öğrenmesi algoritmalarının aile dinamikleri ve aile üyelerinin sonuçları arasındaki karmaşık ilişkileri analiz etme ve anlamada güçlü bir potansiyele sahip olduğunu göstermektedir (Gil ve ark. 2022, Wang ve ark. 2023, Berkel ve ark. 2023, Gao ve ark. 2024). Özellikle RF, SVM ve derin öğrenme gibi yöntemler, aile ve üyeleri düzeyindeki risk ve koruyucu faktörlerin belirlenmesi ve tahmin edilmesinde yüksek doğruluk oranları sergilemiştir Gil ve ark. 2022, Zhou ve ark. 2024, Gao ve ark. 2024). Aile sosyoekonomik durumu, genç yetişkinlerin eğitim başarısı üzerinde en güçlü öngörücü faktörlerden biri olarak öne çıkmaktadır (Sun ve ark. 2020, Sun ve Sayer 2024). Ebeveynlerin eğitim düzeyi, aile gelir düzeyi ve sosyal destek mekanizmaları gibi değişkenlerin, bireylerin akademik başarıları üzerinde doğrudan ilişkiler gösterdiği açıklanmıştır. Bunun yanında, aile içi çatışma, ebeveyn depresyonu ve düşük aile işlevselliği, ergenlerde depresyon ve intihar dışı kendine zarar verme davranışlarını artıran önemli risk faktörleri arasında gösterilmektedir (Gil ve ark. 2022, Wang ve ark. 2023, Zhou ve ark. 2024). Bu tür olumsuz ailevi deneyimler, bireylerin psikolojik dayanıklılığını zayıflatarak ruh sağlığı problemlerine zemin hazırlayabilmektedir. Bu nedenle, makine öğrenmesinin bu alanlardaki riski tespit edebilmesi önemlidir.

Öte yandan, ebeveyn katılımı ve destekleyici aile yaklaşımları, çocukların ruh sağlığı ve gelişimi üzerinde koruyucu bir etkiye sahiptir (Naar-King ve ark. 2016, Berkel ve ark. 2023). Ebeveynlerin çocuklarının psikolojik ihtiyaçlarına duyarlılık göstermesi, psikolojik destek arayışında bulunması ve olumlu aile içi etkileşimler, bireylerin olumsuz sonuçlardan korunmasını sağlamaktadır. Bu durum, aile temelli müdahalelerin önemini vurgularken, ebeveynlerin çocuklarının gelişim süreçlerine aktif katılımının teşvik edilmesi gerektiğini ortaya koymaktadır. Makine öğrenmesi algoritmaları, bu karmaşık değişkenler arasındaki ilişkileri daha iyi anlayarak risk faktörlerini erken dönemde tanımlama ve koruyucu önlemler geliştirme konusunda büyük bir potansiyel taşımaktadır. Derleme kapsamında incelenen çalışmaların çoğunda kullanılan modellerin kuramsal arka planlarına ve değişken seçimine dair açıklamaların sınırlı olduğu dikkat çekmektedir (Gil ve ark. 2022, Lopez-Larrosa ve ark. 2022, Wang ve ark. 2023, Ahn ve ark. 2024, Zhou ve ark. 2024).

İncelenen sistematik gözden geçirme çalışmaları kapsamında, örneklem özellikleri oldukça çeşitlidir. Çalışmalarda genellikle çocuklar, ergenler ve aile üyeleri (ebeveynler ve birincil bakım verenler) odak alınmıştır. Örneğin, Zheng ve Ye (2022) çalışmasında 61 ergen katılımcı yer alırken, Li ve arkadaşları (2021) çalışmasında 1.16 milyon sosyal medya kullanıcısı verileri analiz edilmiştir. Sistematik derleme kapsamında ele alınan makalelerin %45.45'inde ergen katılımcılar aracılığıyla aile verilerinin toplandığı çalışmalar (Lopez-Larrosa ve ark. 2022, Zheng ve Ye 2022, Wang ve ark. 2023, Sun ve Sayer 2024, Zhou ve ark. 2024) yer almaktadır. Çalışmaların %36.36'sında (Smith ve ark. 2018, Gil ve ark. 2022, Zhou ve ark. 2024) hem çocuklardan hem de birincil bakım verenlerden veri toplanmıştır. Çocuk verileri üzerinden aile değişkenlerinin incelendiği Gao ve arkadaşları (2024) ile Schwartz ve arkadaşları (2017) çalışmaları da dikkat çekmektedir. Çalışmaların sadece iki tanesinde katılımcıların demografik bilgileri ayrıntılı olarak verilmiştir (Lopez-Larrosa ve ark. 2022; Sun ve Sayer 2024).

Çalışmalarda veri madenciliğiyle ulaşılan dataların büyüklüğü ve katılımcı sayılarının sosyodemografik bilgilerinin çeşitliliği söz konusu olduğunda bu verilerin paylaşılmasının gücü ortadadır. Diğer alanlarla karşılaştırıldığında sosyal hizmetlerdeki ve sağlık alanındaki çalışmaların sonuçların kişilerin iyilik hali üzerindeki önemli etkisi göz önüne alındığında sonuçlara olan güvenin artırılması için geliştirilmesi gereken bir yan olarak belirtilebilir.

Çalışmalar genel olarak aile içi şiddet (Li ve ark. 2021, Lopez-Larrosa ve ark. 2022), çocukların ruh sağlığı, depresyon riski (Gil ve ark. 2022, Wang ve ark. 2023, Zhou ve ark. 2024), dikkat eksikliği ve hiperaktivite bozukluğu (DEHB) (Gao ve ark. 2024), ergenlerde sosyal kaygı (Zheng ve Ye 2022) ve eğitim başarısı (Sun ve ark. 2020, Sun ve Sayer 2024) gibi aileyle ilişkili konuları ele almıştır. Li ve arkadaşları (2021), çalışmasında aile içi şiddetin bireylerin kişilik özellikleri üzerindeki etkileri araştırılırken, Gao ve arkadaşları (2024), DEHB'nin ailevi risk faktörlerini incelemiştir. Gil ve arkadaşları (2022), çalışmasında üniversite öğrencilerinde depresyon riski ele alınmış, Sun ve Sayer (2024) çalışmasında ise genç yetişkinlerin eğitim başarısını etkileyen aile faktörleri araştırılmıştır. Bu dağılım, aile dinamiklerinin bireylerin psikolojik sağlığı ve gelişimi üzerindeki etkilerini anlamaya yönelik kapsamlı bir yaklaşımı yansıtmaktadır. Bireylerin doğalarının karmaşık olması ve birçok farklı değişkenden etkilenebileceği göz önüne alındığında; belirli bir durumda farklı değişkenler çalışabilir. Bunun yanı sıra, çalışmalarda kullanılan verilerin eski zamanlı olması (Schwartz ve ark. 2017); öngörücü değişkenlerin zaman içinde değişmiş olma ihtimali, birçok karıştırıcı değişkenin çalışmalara dahil olmasıyla beraber sonuçların güvenilirliğini riske atabilir. Bahsedilen sınırlılıklar, mevcut derlemede de ele alınan çalışmaların ve bulguların dış geçerliliği konusunda da şüphe uyandırabilir. Bu sınırlılıklar makine öğrenmesi uygulamalarının daha sağlam teorik temellere dayandırılması gerektiğini göstermektedir. Ayrıca, model şeffaflığı ve yorumlanabilirlik konularında daha fazla çalışmaya ihtiyaç vardır. Çalışmalarda kullanılan verilerin güvenilirliğine dair etik izinler bulunsa da, çok büyük ölçekli vakalar ve sosyal medya çalışmaları (Li ve ark. 2021) kapsamında makine öğrenmesi modellerinin uygulanması ve pratikteki kullanımıyla ilgili zorlukların daha fazla kaynağa ihtiyaç duyduğu görülmektedir.

Jacob Cohen'in *The Earth Is Round* (p < .05) başlıklı makalesinde (1994) ortaya koyduğu null hipotez testine (NHST) yönelik eleştiriler, yapay zeka ve makine öğrenmesi yaklaşımlarının bilimsel araştırmalardaki önemini vurgulayan önemli bir bakış açısı sunmaktadır. Cohen (1994), p-değerlerinin yanlış yorumlanması ve anlamlılık kavramının istatistiksel sonuçlara aşırı bağımlı bir şekilde değerlendirilmesinin, bilimsel ilerlemeyi sınırladığını savunmuştur. Bu bağlamda, geleneksel NHST yöntemleri, özellikle büyük veri

setleriyle çalışırken sınırlı kalmaktadır çünkü p-değeri, bir hipotezin doğruluğunu değil, gözlemlenen verilerin rastlantısal olarak ortaya çıkma olasılığını ölçmektedir. Buna karşılık, makine öğrenmesi algoritmaları veri odaklı yaklaşımıyla etkili öngörüler yapabilmekte ve model performansını çeşitli doğrulama teknikleriyle (örneğin, çapraz doğrulama, ROC eğrileri, AUC, F1 skoru) değerlendirebilmektedir. Bu yönüyle makine öğrenmesi, Cohen'in önerdiği (1994) etki büyüklüğü ve güven aralığı gibi istatistiksel yaklaşımlarla örtüşerek, sonuçların daha derinlemesine ve anlamlı analiz edilmesini sağlamaktadır.

Makine öğrenmesi yöntemleri, Cohen'in eleştirdiği NHST'nin sınırlamalarını aşarak (1994), bilimsel araştırmalarda daha güvenilir ve yorumlanabilir sonuçlar elde edilmesine katkı sağlar. Özellikle tahmine dayalı modelleme ve karmaşık veri ilişkilerinin analizinde makine öğrenmesi, p-değerlerinin ötesinde model doğruluğunu ve genellenebilirliğini temel alır. Bu durum, araştırma süreçlerinde Cohen'in (1994) vurguladığı bilimsel tekrar edilebilirlik (replikasyon) ve etki büyüklüğünün önemini destekler niteliktedir. Ayrıca makine öğrenme algoritmalarının esnek yapısı, teorik çerçeveden bağımsız olarak büyük ve çeşitli veri kümelerindeki karmaşık ilişkileri keşfetmeye olanak tanır. Dolayısıyla Cohen'in NHST eleştirileri, yapay zekâ ve makine öğrenmesi tekniklerinin bilimsel araştırmalarda daha etkili ve yenilikçi yöntemler olarak benimsenmesini haklı çıkarabilir. Bu yöntemlerin kullanımı, araştırmacıların hem teorik hem de pratik açıdan daha anlamlı ve güvenilir sonuçlara ulaşmalarını sağlayarak bilimsel alanyazına önemli katkılar sunmaktadır.

Bu derlemede elde edilen bulgular, Cohen'in NHST'ye yönelik eleştirileriyle önemli ölçüde örtüşmektedir (Cohen 1962, Cohen 1992, Cohen 1994). Derlemeye dahil edilen çalışmalar, aile dinamikleri ve bireylerin psikolojik sağlığı üzerindeki etkileri incelerken, makine öğrenmesi algoritmalarının (RF, SVM, Derin Öğrenme vb.) geleneksel yöntemlere kıyasla daha güçlü ve esnek tahmin yetenekleri sunduğunu göstermiştir (Yarkoni ve Westfall 2017, Gil ve ark. 2022, Wang ve ark. 2023, Black ve ark. 2023, Gao ve ark. 2024, Sun ve Sayer 2024, Zhou ve ark. 2024). Örneğin, Sun ve Sayer (2024) çalışmasında, genç yetişkinlerin eğitim başarısını öngörmede aile sosyoekonomik durumunun etkisi, geleneksel regresyon modelleriyle sınırlı kalırken, makine öğrenmesi modelleri (Lasso, Karar Ağaçları, RF) daha yüksek doğruluk oranlarıyla daha detaylı ve güçlü sonuçlar üretmiştir. Bu durum, Cohen'in (1994) etkili sonuçlar için sadece p-değerine odaklanılmaması gerektiği yönündeki eleştirileriyle doğrudan örtüşmektedir. Öte yandan bazı açılardan mevcut bulgular Cohen'in eleştirilerinden ayrılmaktadır. Cohen, NHST'nin yetersizliklerini vurgularken, makine öğrenmesi modellerinin sınıflandırma doğruluğuna ve performans ölçütlerine odaklanır. Derlemede yer alan bazı çalışmaların (örneğin, Gil ve ark. 2022) makine öğrenmesi algoritmalarını kullanırken teorik temelden kopuk ve yorumlanabilirlikten uzak sonuçlar sunduğu gözlemlenmiştir. Cohen'in (1994) eleştirileri doğrultusunda, yalnızca model performansına (doğruluk, AUC) odaklanmak yerine, modellerin öngörücü değişkenlerinin teorik çerçeveye nasıl ilişkilendirildiği de dikkate alınmalıdır. Bu durum, makine öğrenmesi modellerinin Cohen'in önerdiği şekilde daha güçlü ve geçerli sonuçlar üretmesi için, teorik arka planla daha iyi entegre edilmesi gerektiğini göstermektedir.

İncelenen çalışmalarda kullanılan makine öğrenmesi yöntemlerinin farklı alanlarda öne çıktığı görülmektedir (Tablo 3). Örneğin RF modelleri, çok sayıda değişkeni aynı anda ele alabilme ve risk/koruyucu faktörleri hiyerarşik olarak sıralayabilme özelliği sayesinde aile içi risk faktörlerinin öngörülmesinde yüksek doğruluk oranları sergilemiştir (Gil ve ark. 2022, Zhou ve ark. 2024). SVM ise özellikle sınıflandırma problemlerinde (örneğin ergenlerde depresyon riski olup olmaması gibi ikili çıktılarda) güçlü performans göstermiştir (Gil ve ark. 2022). Derin öğrenme algoritmaları, büyük ve karmaşık veri setlerinde (ör. sosyal medya verileri, çok boyutlu psikososyal veriler) güçlü öngörüler sağlamış, ancak yorumlanabilirlik açısından sınırlı kalmıştır (Zheng ve Ye 2022). NLP yöntemleri, aile içi iletişim, sosyal medya içerikleri veya ebeveyn-çocuk etkileşim metinleri gibi sözel verilerin analizinde özgün katkılar sunarken, veri temizliği ve dilsel bağlama duyarlılık gibi sınırlılıklarla karşılaşmıştır (Berkel ve ark. 2023). Lojistik regresyon gibi daha geleneksel yöntemler ise basitlik ve yorumlanabilirlik açısından avantajlı olmakla birlikte, çok değişkenli karmaşık ilişkileri açıklamada diğer yöntemlere kıyasla sınırlı kalmıştır (Zhou ve ark. 2024).

Bu bulgular aile bilimleri araştırmaları açısından değerlendirildiğinde, RF ve SVM gibi yöntemlerin risk ve koruyucu faktörlerin belirlenmesinde güçlü araçlar sunduğu; derin öğrenme ve NLP yaklaşımlarının ise özellikle büyük ölçekli ve metin tabanlı veri setlerinde gelecek vadettiği söylenebilir (Gil ve ark. 2022, Zheng ve Ye 2022, Berkel ve ark. 2023, Zhou ve ark. 2024). Bununla birlikte, aile bilimleri bağlamında kullanılacak

modellerin yalnızca öngörü gücü yüksek değil, aynı zamanda yorumlanabilir, etik ilkelere duyarlı ve uygulayıcılar için anlaşılır olması da önemlidir (Ivaskevics ve Haller 2022, Ahn ve ark. 2024). İleri araştırmalarda, özellikle RF ve NLP tabanlı yöntemlerin aile ilişkilerinin dinamiklerini anlamada öne çıkacağı, ancak bu modellerin şeffaflık ve açıklanabilirlik ilkeleriyle desteklenmesinin gerekliliği vurgulanmalıdır.

<b>Tablo 3. Makine öğrenme yöntemleri</b>		
<b>Yöntem</b>	<b>Kullanıldığı Çalışmalar</b>	<b>Öne Çıkan Sonuç</b>
RF	Gil ve ark. 2022, Zhou ve ark. 2024, Sun ve Sayer 2024	Risk/koruyucu faktörlerde yüksek doğruluk
SVM	Gil ve ark. 2022	İkili sınıflandırmalarda güçlü performans
Derin Öğrenme	Zheng ve Ye 2022	Karmaşık verilerde öngörü gücü yüksek, yorumlanabilirliği düşük
NLP	Berkel ve ark. 2023	Sözel veri analizi, ebeveynlik programı değerlendirilmesi
Lojistik Regresyon	Gil ve ark. 2022, Zhou ve ark. 2024	Basit, yorumlanabilir; karmaşık ilişkilerde sınırlı
Nomogram	Gao ve ark. 2024	DEHB tahmininde %95,9 doğruluk

DL = Deep Learning (Derin Öğrenme), NLP = Natural Language Processing (Doğal Dil İşleme), RF = Random Forest (Rastgele Orman), SVM = Support Vector Machine (Destek Vektör Makineleri)

İncelenen çalışmaların büyük bir kısmı makine öğrenmesi modellerinin doğruluk ve öngörü gücüne odaklanırken, modellerin şeffaflığı, yorumlanabilirliği ve etik boyutlarına sınırlı düzeyde değinildiği görülmüştür (Ivaskevics ve Haller 2022, Ahn ve ark. 2024). Özellikle aile bağlamında kullanılan verilerin niteliği, kişisel ve hassas bilgilerin gizliliği, algoritmik önyargı riski ve modellerin karar süreçlerinin açıklanabilirliği, bu alanda gelecekte daha fazla dikkate alınması gereken konular arasında yer almaktadır. Makine öğrenmesinin aile araştırmalarında uygulanabilirliği artarken, model performansının yanı sıra etik kaygılar ve şeffaflık ilkelerinin de araştırma süreçlerine entegre edilmesi, bulguların güvenilirliğini ve uygulanabilirliğini güçlendirecektir.

Sistemik derlemenin kısıtlılıkları arasında sadece İngilizce dilinde ve sayılı veri tabanında yapılan çalışmaların yer alması gösterilebilir. Araştırma sonuçlarının istatistiksel değerleri açısından dışlama kriteri belirlenmemesi bir sınırlılık olarak gösterilebilir. Bu derleme kapsamında ele alınan çalışmalarda da, araştırma kalitesine yönelik detaylı bir değerlendirme yapılmamış olması bir sınırlılık olarak görülmektedir. Bu çalışmada dahil edilen araştırmalarda olası yayın yanlılığı değerlendirilmemiştir. PRISMA kılavuzunda önerildiği üzere yayın yanlılığının incelenmesi bulguların genellenebilirliği açısından önemli görülmektedir (Page ve ark. 2021). Ancak mevcut derlemede bu analiz yapılmadığından, elde edilen sonuçların pozitif bulgulara sahip çalışmalar lehine bir yanlılık taşıyabileceği göz önünde bulundurulmalıdır. Dahil edilen çalışmaların metodolojik kalite değerlendirmesi sistematik olarak yapılmamıştır. PRISMA kontrol listesi, çalışma kalitesinin değerlendirilmesini ve kullanılan yöntemin raporlanmasını önermektedir. Bu eksiklik, derlemenin güçlü yönleri yanında dikkat edilmesi gereken bir sınırlılık oluşturmaktadır. Ayrıca, makalelerde AUC (Eğri Altındaki Alan) kriterlerinin bulunmaması ya da eksik olması, mevcut bulguların kapsamlı bir şekilde yorumlanmasını zorlaştırmaktadır. Bu durum, bu alandaki çalışmaların görece yeni olması ve metodolojik standartların henüz tam anlamıyla oturmamış olmasıyla açıklanabilir (Yarkoni ve Westfall 2017).

Çalışma kapsamında ele alınan aile araştırmalarında makine öğrenim tekniklerini kullanan araştırmalara yer verilmiştir. Bu bağlamda ele alınan çalışmaların artması psikoloji alanındaki gelişmeler adına önerilebilir. Türkiye’de de makine öğrenme tekniklerinin bulunmasına karşın aile değişkenlerinin makine öğrenme teknikleriyle çalışıldığı bir çalışmaya raslanılmamıştır. Ülkemiz bağlamında, aile dinamiklerine yönelik makine öğrenmesi çalışmalarının geliştirilebilmesi için öncelikle kültürel ve toplumsal yapıyı yansıtan kapsamlı veri setlerine ihtiyaç vardır. Bu kapsamda aile içi iletişim, ebeveynlik stilleri, sosyoekonomik durum, eğitim düzeyi, ruh sağlığı göstergeleri ve sosyal destek mekanizmalarını içeren uzunlamasına veri setleri oluşturulabilir. Özellikle aile temelli müdahalelerin sonuçlarının sistematik biçimde toplanması, makine öğrenmesi algoritmalarının risk ve koruyucu faktörleri daha doğru biçimde öngörmesine katkı

sağlayacaktır. Örneğin, ebeveyn-çocuk etkileşimlerinin doğal ortamda gözlemlenmesi ve dijital araçlar aracılığıyla kaydedilmesi, doğal dil işleme ve derin öğrenme yöntemleriyle analiz edilebilir. Ayrıca, sosyoekonomik göstergeler ile psikolojik değişkenleri birleştiren çok boyutlu veri setleri, aile refahının öngörülmesine ve politika yapıcılara yol göstermeye elverişli olabilir. Bu tür veri setlerinin geliştirilmesi, Türkiye’de aile temelli araştırmalara yeni bir metodolojik boyut kazandıracak ve uluslararası alanyazına özgün katkılar sunacaktır.

## Sonuç

Derleme sonucunda, makine öğrenmesinin aile araştırmalarında kullanılabileceği alanlar şunlar olarak öne çıkmıştır: aile içi risk ve koruyucu faktörlerin belirlenmesi, aile yapısının birey üzerindeki etkilerinin öngörülmesi ve aile temelli müdahalelerin etkinliğinin değerlendirilmesi. İncelenen çalışmalar, özellikle RF, SVM ve derin öğrenme yöntemlerinin yüksek doğruluk oranlarıyla aile dinamiklerini anlamada güçlü bir potansiyele sahip olduğunu göstermektedir. Makine öğrenmesi yöntemleri, aile üyelerinin psikolojik sağlık ve refahı ile ilgili risk göstergelerini erken dönemde tespit edebilmekte ve koruyucu faktörleri ortaya koyarak müdahale süreçlerine yön verebilmektedir. Bu bağlamda, ebeveyn katılımı, sosyoekonomik durum, aile içi çatışma ve sosyal destek mekanizmaları gibi değişkenlerin hem risk hem de koruyucu etkiye sahip olduğu belirlenmiştir. Bulgular, makine öğrenmesi algoritmalarının sosyal bilim araştırmaları ve klinik hizmetler sunan profesyoneller için giderek artan bir ilgi odağı haline geldiğini göstermektedir. Gelecekte yapılacak çalışmaların, bu yöntemleri daha sağlam kuramsal temellere dayandırması ve metodolojik standartları güçlendirmesi önem arz etmektedir. Ayrıca, Türkiye’de aile değişkenlerinin makine öğrenmesi teknikleriyle incelendiği çalışmaların yetersizliği, bu alanda yeni araştırmalar yapılmasının hem akademik hem de uygulamalı düzeyde değerli katkılar sağlayacağını ortaya koymaktadır.

## Kaynaklar

- Ahn E, Tejada Y, Yang Y (2024) Examining fairness in machine learning applied to support families: A case study of preventive services. *Fam Relat*, 74:1285-1298.
- Baldwin JR, Wang B, Karwatowska L, Schoeler T, Tsaligopoulou A, Munafò MR et al. (2023) Childhood maltreatment and mental health problems: a systematic review and meta-analysis of quasi-experimental studies. *Am J Psychiatry*, 180:117-126.
- Bengio Y, Goodfellow I, Courville A (2015) *Deep Learning*. Cambridge, MIT Press.
- Berkel C, Knox DC, Flemotomos N, Martinez VR, Atkins DC, Narayanan SS et al. (2023) A machine learning approach to improve implementation monitoring of family-based preventive interventions in primary care. *Implement Res Pract*, 4:e26334895231187906.
- Bishop CM (1994) Neural networks and their applications. *Rev Sci Instrum*, 65:1803-1832.
- Black JE, Kueper JK, Williamson TS (2023) An introduction to machine learning for classification and prediction. *Fam Pract*, 40:200-204.
- Burges CJC (1998) A tutorial on support vector machines for pattern recognition. *Data Min Knowl Discov*, 2:121-167.
- Chouldechova A, Benavides-Prado D, Fialko O, Vaithianathan R (2018) A case study of algorithm-assisted decision making in child maltreatment hotline screening decisions. In Conference on Fairness, Accountability and Transparency:134-148. Jan 2018, New York, USA. *Proceedings of Machine Learning Research*.
- Chung J, Teo J (2022) Mental health prediction using machine learning: taxonomy, applications, and challenges. *Applied Computational Intelligence and Soft Computing*, 2022:e9970363.
- Cohen J (1962) The statistical power of abnormal-social psychological research: a review. *J Abnorm Soc Psychol*, 65:145-153.
- Cohen J (1992) A power primer. *Psychol Bull*, 112:155-159.
- Cohen J (1994) The earth is round ( $p < .05$ ). *Am Psychol*, 49:997-1003.
- De’ath G, Fabricius KE (2000) Classification and regression trees: a powerful yet simple technique for ecological data analysis. *Ecology*, 81:3178-3192.
- Dupont T, Kentish-Barnes N, Pochard F, Duchesnay E, Azoulay E (2024) Prediction of post-traumatic stress disorder in family members of ICU patients: a machine learning approach. *Intensive Care Med*, 50:114-124.
- Fradkov AL (2020) Early history of machine learning. *IFAC Pap OnLine*, 53:1385-1390.
- Gao T, Yang L, Zhou J, Zhang Y, Wang L, Wang Y et al. (2024) Development and validation of a nomogram prediction model for ADHD in children based on individual, family, and social factors. *J Affect Disord*, 356:483-491.



- Garriga R, Mas J, Abraha S, Nolan J, Harrison O, Tadros G et al. (2022) Machine learning model to predict mental health crises from electronic health records. *Nat Med*, 28:1240-1248.
- Gil M, Kim SS, Min EJ (2022) Machine learning models for predicting risk of depression in Korean college students: identifying family and individual factors. *Front Public Health*, 10:1023010.
- Gomes SRBS, von Schantz M, Leocadio-Miguel M (2023) Predicting depressive symptoms in middle-aged and elderly adults using sleep data and clinical health markers: a machine learning approach. *Sleep Med*, 102:123-131.
- Harding JF, Keating B, Walzer J, Xing F, Zief S, Gao J (2022) How accurately can we predict repeat teen pregnancy based on social ecological factors? *Dev Psychol*, 58:1793.
- Hastie T, Tibshirani R, Friedman J (2009) *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. New York, Springer.
- Ivaskevics K, Haller J (2022) Risk matrix for violent radicalization: a machine learning approach. *Front Psychol*, 13:745608.
- Ioannidis JPA (2008) Why most discovered true associations are inflated. *Epidemiology*, 19:640-648.
- James G, Witten D, Hastie T, Tibshirani R (2021) *An Introduction to Statistical Learning*. New York, Springer.
- Joel S, Eastwick PW, Allison CJ, Arriaga XB, Baker ZG, Bar-Kalifa E et al. (2020) Machine learning uncovers the most robust self-report predictors of relationship quality across 43 longitudinal couples studies. *Proc Natl Acad Sci U S A*, 117:19061-19071.
- Kusuma K, Larsen M, Quiroz JC, Gillies M, Burnett A, Qian J et al. (2022) The performance of machine learning models in predicting suicidal ideation, attempts, and deaths: a meta-analysis and systematic review. *J Psychiatr Res*, 155:579-588.
- Le Glaz A, Haralambous Y, Kim-Dufor DH, Lenca P, Billot R, Ryan TC et al. (2021) Machine learning and natural language processing in mental health: systematic review. *J Med Internet Res*, 23:e15708.
- Li M, Li L, Wu F, Cao Y, Zhang H, Li X et al. (2021) Perceived family adaptability and cohesion and depressive symptoms: a comparison of adolescents and parents during COVID-19 pandemic. *J Affect Disord*, 287:255-260.
- Li S, Liu M, Zhao N, Xue J, Wang X, Jiao D et al. (2021) The impact of family violence incidents on personality changes: an examination of social media users' messages in China. *Psych J*, 10:598-613.
- Lin S (2022) A clinician's guide to artificial intelligence (AI): why and how primary care should lead the health care AI revolution. *J Am Board Fam Med*, 35:175-184.
- Liu R (2022) Leveraging machine learning methods to estimate heterogeneous effects: father absence in China as an example. *Chin Sociol Rev*, 54:223-251.
- Lopez-Larrosa S, Sánchez-Souto V, Losada DE, Parapar J, Barreiro Á, Ha AP et al. (2022) Using machine learning techniques to predict adolescents' involvement in family conflict. *Soc Sci Comput Rev*, 41:1581-1607.
- Mitchell TM (2010) Learning classifiers based on Bayes rule. *Mach Learn*, 1:1-17.
- Mlandu C, Matsena-Zingoni Z, Musenge E (2023) Predicting the drop out from the maternal, newborn and child healthcare continuum in three East African Community countries: application of machine learning models. *BMC Med Inform Decis Mak*, 23:305.
- Naar-King S, Ellis DA, Idalski Carcone A, Templin T, Jacques-Tiura AJ, Brogan Hartlieb K et al. (2016) Sequential multiple assignment randomized trial (SMART) to construct weight loss interventions for African American adolescents. *J Clin Child Adolesc Psychol*, 45:428-441.
- Nixon RDV, King MW, Smith BN, Gradus JL, Resick PA, Galovski TE et al. (2021) Predicting response to cognitive processing therapy for PTSD: a machine-learning approach. *Behav Res Ther*, 144:103920.
- Ongsulee P (2018) Artificial intelligence, machine learning and deep learning. In *Proceedings of 2017 Fifteenth International Conference on ICT and Knowledge Engineering*, 92-97. Bangkok, Thailand, Siam University.
- Page MJ, McKenzie JE, Bossuyt PM, Boutron I, Hoffmann TC, Mulrow CD et al. (2021) The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *BMJ*, 372:n71.
- Patrick EA, Fischer FP (1970) A generalized k-nearest neighbor rule. *Information and Control*, 16:128-152.
- Rothenberg WA, Bizzego A, Esposito G, Lansford JE, Al-Hassan SM, Bacchini D et al. (2023) Predicting adolescent mental health outcomes across cultures: a machine learning approach. *J Youth Adolesc*, 52:1595-1619.
- Quinlan JR (1986) Induction of decision trees. *Mach Learn*, 1:81-106
- Sajjadian M, Lam RW, Milev R, Rotzinger S, Frey BN, Soares CN et al. (2021) Machine learning in the prediction of depression treatment outcomes: a systematic review and meta-analysis. *Psychol Med*, 51:2742-2751.
- Salganik MJ, Lundberg I, Kindel AT, Ahearn CE, Al-Ghoneim K, Almaatouq A et al. (2020) Measuring the predictability of life outcomes with a scientific mass collaboration. *Proc Natl Acad Sci U S A*, 117:8398-8403.
- Sankar A, Shen X, Colic L, Goldman DA, Villa LM, Kim JA et al. (2023) Predicting depressed and elevated mood symptomatology in bipolar disorder using brain functional connectomes. *Psychol Med*, 53:6656-6665.
- Schwartz IM, York P, Nowakowski-Sims E, Ramos-Hernandez A (2017) Predictive and prescriptive analytics, machine learning and child welfare risk assessment: the Broward County experience. *Child Youth Serv Rev*, 81:309-320.

- Silver D, Huang A, Maddison C, Guez A, Sifre L, Van Den Driessche G et al. (2016) Mastering the game of Go with deep neural networks and tree search. *Nature*, 529:484-489.
- Simmons JP, Nelson LD, Simonsohn U (2011) False-positive psychology: undisclosed flexibility in data collection and analysis allows presenting anything as significant. *Psychol Sci*, 22:1359-1366.
- Smith JD, Berkel C, Rudo-Stern J, Montañó Z, St. George SM, Prado G et al. (2018) The Family Check-Up 4 Health (FCU4Health): applying implementation science frameworks to the process of adapting an evidence-based parenting program for prevention of pediatric obesity and excess weight gain in primary care. *Front Public Health*, 6:293.
- Sun X, Ram N, McHale SM (2020) Adolescent family experiences predict young adult educational attainment: a data-based cross-study synthesis with machine learning. *J Child Fam Stud*, 29:2770-2785.
- Sun X, Sayer L (2024) Supervised machine learning for exploratory analysis in family research. *J Marriage Fam*, 86:1468-1494.
- Suthaharan S (2016) *Machine Learning Models and Algorithms for Big Data Classification*. Cham, Springer.
- Sutton RS, Barto AG (2018) *Reinforcement Learning: An Introduction*. Cambridge, MIT Press.
- Syed S, Gonzalez-Izquierdo A, Allister J, Feder G, Li L, Gilbert R (2022) Identifying adverse childhood experiences with electronic health records of linked mothers and children in England: a multistage development and validation study. *Lancet Digit Health*, 4:e482-e496.
- Tiyyagura G, Asnes AG, Leventhal JM, Shapiro ED, Auerbach M, Teng W et al. (2022) Development and validation of a natural language processing tool to identify injuries in infants associated with abuse. *Acad Pediatr*, 22:981-988.
- Tversky A, Kahneman D (1974) Judgment under uncertainty: heuristics and biases. *Science*, 185:1124-1131.
- Wang C, Zhou T, Fu L, Xie D, Qi H, Huang Z et al. (2023) Risk and protective factors of depression in family and school domains for Chinese early adolescents: an association rule mining approach. *Behav Sci (Basel)*, 13:893.
- Vieira S, Liang X, Guimar R, Mechelli A (2022) Can we predict who will benefit from cognitive-behavioural therapy? A systematic review and meta-analysis of machine learning studies. *Clin Psychol Rev*, 97:102193.
- Yarkoni T (2009) Big correlations in little studies: inflated fMRI correlations reflect low statistical power—commentary on Vul et al. (2009). *Perspect Psychol Sci*, 4:294-298.
- Yarkoni T, Westfall J (2017) Choosing prediction over explanation in psychology: lessons from machine learning. *Perspect Psychol Sci*, 12:1100-1122.
- Zheng Y, Ye Y (2022) Prediction of cognitive-behavioral therapy using deep learning for the treatment of adolescent social anxiety and mental health conditions. *Sci Program*, 2022:3187403.
- Zhou SC, Zhou Z, Tang Q, Yu P, Zou H, Liu Q et al. (2024) Prediction of non-suicidal self-injury in adolescents at the family level using regression methods and machine learning. *J Affect Disord*, 352:67-75.
- Zhong M, Zhang H, Yu C, Jiang J, Duan X (2022) Application of machine learning in predicting the risk of postpartum depression: a systematic review. *J Affect Disord*, 318:364-379.

**Yazarların Katkıları:** Çalışmaya önemli bir bilimsel katkı sağlandığı ve makalenin hazırlanmasında veya gözden geçirilmesinde yardımcı olduğu tüm yazar(lar) tarafından beyan edilmiştir.

**Danışman Değerlendirmesi:** Dış bağımsız

**Etik Onay:** Bu çalışma bir derleme yazısı olduğu için etik onaya gerek yoktur.

**Çıkar Çatışması:** Çıkar çatışması bildirilmemiştir.

**Finansal Destek:** Bu çalışma için finansal destek alındığı beyan edilmemiştir.

**Authors Contributions:** The author(s) have declared that they have made a significant scientific contribution to the study and have assisted in the preparation or revision of the manuscript

**Peer-review:** Externally peer-reviewed.

**Ethical Approval:** This review study does not require ethical clearance.

**Conflict of Interest:** No conflict of interest was declared.

**Financial Disclosure:** No financial support was declared for this study.