

MALNÜTRİSYON DURUMUNUN SAPTANMASINDA MAKİNE ÖĞRENMESİNİN KULLANILMASI

THE USE OF MACHINE LEARNING TO ASSESS MALNUTRITION STATUS

Dilay Ermiş^{1,2}, Güleren Sabuncular³, Zehra Margot Çelik³

1.Marmara Üniversitesi, Sağlık Bilimleri Enstitüsü, Beslenme ve Diyetetik Anabilim Dalı, İstanbul, Türkiye

2.İstanbul Kent Üniversitesi, Sağlık Bilimleri Fakültesi, Beslenme ve Diyetetik Bölümü, İstanbul, Türkiye

3.Marmara Üniversitesi, Sağlık Bilimleri Fakültesi, Beslenme ve Diyetetik Bölümü, İstanbul, Türkiye

ORCID ID: DE: 0009-0003-6372-2772 GS: 0000-0001-5922-295X ZMÇ: 0000-0002-4622-9252

MAKALE BİLGİLERİ

Anahtar Kelimeler:

Algoritma,
Makine Öğrenmesi,
Malnütrisyon,
Yetersiz Beslenme,
yapay Zeka

ÖZET

Bireyin beslenme durumu, vücut kompozisyonu ve fonksiyonel durumunun bir belirleyicisidir. Yetersiz beslenme yaşam kalitesini düşürür, hasta semptomlarını, mortalite ve morbidite riskini artırır, hastanede kalış süresini ve maliyetleri olumsuz etkiler. Malnütrisyon, enerji, protein ve diğer besin öğelerinin eksikliğinin veya fazlalığının (veya dengesizliğinin) doku/ vücut formu (vücut şekli, boyutu ve bileşimi) ve işlevi ile klinik sonuçlar üzerinde ölçülebilir olumsuz etkilere neden olduğu bir beslenme durumudur. Malnütrisyonun erken tanısı için malnütrisyon tarama ve tanı araçlarının geliştirilmesi, hastaların sağlığı, refahı ve uzun vadeli komplikasyonları önlemek için gereklidir. Hastane ortamında kullanılabilecek pek çok beslenme tarama aracı bulunmasına rağmen, en iyi aracın hangisi olduğu konusunda bir fikir birliği bulunmamakta ve tarama uygulamalarına yeterince uyulmadığı için etkin beslenme tedavisine ulaşılamamaktadır. Son yıllarda, makine öğrenimi yöntemleri, klinikte karar vermeye yardımcı olmak ve tedavinin kalitesini, etkinliğini iyileştirmek için birçok tıbbi alanda yaygın olarak uygulanmaktadır. Bu derlemede Pubmed, Google Scholar, Web of Science veri tabanlarında yetersiz beslenme, malnütrisyon, makine öğrenmesi, yapay zeka anahtar kelimeleri ile tarama yapılmıştır ve makine öğrenme yöntemlerinin malnütrisyon tanısında kullanımı incelenmiştir. İncelenen çalışmalar, makine öğrenmesi algoritmalarının malnütrisyonun erken teşhisi ve risk gruplarının belirlenmesinde etkili ve güvenilir sonuçlar sunduğunu göstermektedir.

ARTICLE INFO

Keywords:

Algorithm,
Machine Learning,
Malnutrition,
Undernourishment,
Artificial intelligence

ABSTRACT

An individual's nutritional status is a determinant of body composition and functional status. Undernourishment reduces quality of life, increases patient outcomes, mortality and morbidity risk, and adversely affects length of hospitalization and costs. Malnutrition is a nutritional state in which a deficiency or excess (or imbalance) of energy, protein and other nutrients causes measurable adverse effects on tissue/body form (body shape, size and composition) and function, and clinical outcomes. The development of malnutrition screening and diagnostic tools for the early detection of malnutrition is essential for the health and well-being of patients and to prevent long-term complications. Although there are many nutritional screening tools that can be used in the hospital setting, there is no consensus on which is the best tool and effective nutritional treatment is not achieved due to poor adherence to screening practices. In recent years, machine learning methods have been widely applied in many medical fields to assist clinical decision-making and improve the quality and effectiveness of treatment. In this review, Pubmed, Google Scholar, Web of Science databases were searched with the keywords undernourishment, malnutrition, machine learning, artificial intelligence and the use of machine learning methods in the diagnosis of malnutrition was examined. The reviewed studies demonstrate that machine learning algorithms provide effective and reliable results in the early detection of malnutrition and identification of at-risk groups.

Makale Bilgisi | Article Information

Makale Türü | Article Type: Derleme | Review

Geliş Tarihi | Received: 07.03.2025

Kabul Tarihi | Accepted: 07.08.2025

Yayın Tarihi | Published: 29.08.2025

Çıkar çatışması

Yazarlar herhangi bir çıkar çatışması veya finansal destek bildirmemişlerdir.

Finansman

Bu çalışma, herhangi bir kurum ya da kuruluş tarafından finanse edilmemektedir.

Teşekkürler

-

Etik Onay

Bu çalışmada Etik Kurul Onay'ına ihtiyaç duyulmamıştır.

Sorumlu Yazar | Correspondence Author Dilay Ermiş

Address for Correspondence: Marmara Üniversitesi, Sağlık Bilimleri

Enstitüsü Beslenme ve Diyetetik Bölümü, İstanbul

Mail: dlykurtoglu25@gmail.com

Yazar Katkıları

Motivasyon / Konsept: DE, GS, ZMÇ

Çalışma Tasarımı: DE

Kontrol / Gözetim: DE, GS, ZMÇ

Veri Toplanması ve / veya İşlemesi: Bu çalışmada yapılmamıştır.

Analiz ve / veya Yorum: Bu çalışmada yapılmamıştır.

Literatür inceleme: DE

Makalenin Yazılması: DE, GS, ZMÇ

Eleştirel İnceleme: DE, GS, ZMÇ

GİRİŞ

Yeterli büyüme ve gelişmenin hayati bir unsuru olan beslenme, hastalıkların önlenmesinde, sağlığın korunmasında ve daha hızlı iyileşmenin sağlanmasında ayrılmaz bir rol oynamaktadır. Yetersiz beslenme, her yaşta insan için önemli bir halk sağlığı sorunu olmaya devam etmektedir. Proteinler, yağlar ve karbonhidratlar gibi temel makro besinlerin yanı sıra vitaminler ve mineraller gibi mikro besinlerin eksiklikleri, çeşitli fiziksel ve psikolojik bozukluklara neden olmaktadır (1). Mevcut çalışmalar, hastanede yatan hastaların yaklaşık %3-5'inde malnütrisyon tanısı konulduğunu göstermektedir, ancak tahminler bu oranın %30-60 kadar yüksek olabileceğini göstermektedir. Hastanelerde malnütrisyonu tanıma stratejilerinde yapılacak iyileştirmeler ve beslenme uzmanları ve sağlık hizmeti sağlayıcıları arasındaki iş birliği, malnütrisyonlu hastaların daha iyi tespit edilmesini sağlayabilir (2, 3). Bireyin beslenme durumu, vücut kompozisyonu ve fonksiyonel durumunun bir belirleyicisidir. Yetersiz beslenme yaşam kalitesini düşürür, hastalık semptomları, mortalite ve morbidite riskini artırır, hastanede kalış süresini ve maliyetleri olumsuz etkiler (4). Bu bağlamda, malnütrisyon açısından risk faktörlerinin taranması ve gerekiyorsa bireyin beslenme durumunun belirlenmesi hasta değerlendirmesinin bir parçası olmalıdır (5). Beslenme taraması hastaneye kabul sırasında yapılmalı ve herhangi bir risk tespit edilirse beslenme durumu değerlendirmesi yapılmalıdır. Avrupa Klinik Beslenme ve Metabolizma Derneği'ne (ESPEN) göre beslenme taramasının amacı, daha iyi veya daha kötü bir beslenme sonucu olasılığını ve beslenme tedavisinin bunu etkileyip etkilemeyeceğini tahmin etmektir (6). Beslenme durumu değerlendirmesi Amerikan Parenteral ve Enteral Nütrisyon Derneği (ASPEN) tarafından "beslenmeyle ilgili sorunları belirlemek için birlikte kullanılan kapsamlı bir yaklaşım" olarak tanımlanır (7). Beslenme değerlendirmesinin amacı, herhangi bir özel beslenme riskini veya risklerini ya da yetersiz beslenmenin varlığını saptamaktır. Beslenme değerlendirmesi, beslenme durumunun iyileştirilmesi için veya yeniden tarama için bir öneri sağlayabilir (8).

Malnütrisyon

Malnütrisyon, enerji, protein ve diğer besin öğelerinin eksikliğinin veya fazlalığının (veya dengesizliğinin) doku/vücut formu (vücut şekli, boyutu ve bileşimi) ve işlevi ile klinik sonuçlar üzerinde ölçülebilir olumsuz etkilere neden olduğu bir beslenme durumudur (9). Kelime anlamı olarak bozuk beslenme anlamına gelmektedir. Her ne kadar malnütrisyon tanımı aşırı yeme ve yetersiz beslenme durumlarının içerse de, genellikle malnütrisyon ve yetersiz beslenme kavramları birbirlerinin yerine kullanılmaktadır. Malnütrisyon, yetersiz beslenme, aşırı beslenme, spesifik besin eksiklikleri ve orantısız besin alımına bağlı dengesizliklerin bir kombinasyonu olarak tanımlanmaktadır (10, 11). Açlık, hastalık veya yaşlanmaya bağlı malnütrisyon, vücut kompozisyonunun (yağsız kütlenin azalması) ve vücut hücre kütlesinin değişmesine yol açan, fiziksel ve zihinsel işlevlerin azalmasına ve hastalıklardan kaynaklanan klinik sonuçların bozulmasına neden olan, besin alımı eksikliğinden kaynaklanan bir durumdur (12). Hastanede tüm hastaların yaklaşık %30'u yetersiz beslenmektedir. Bu hastaların büyük çoğunluğu hastaneye kabul edildiklerinde yetersiz beslenmektedir ve bu hastaların çoğunda yetersiz beslenme hastanedeyken gelişmektedir (13). ASPEN ve ESPEN malnütrisyon tanısı için bazı kriterler tanımlamıştır. Bunlar, yetersiz enerji alımı, kilo kaybı, kas kütlesinde azalma, deri altı yağ dokusu kaybı, vücut ağırlığı kaybını maskeleyen lokalize veya genel sıvı birikimi, el kavrama gücü gibi fonksiyonel durumların bozulması olarak açıklanmaktadır (10). Vücut ağırlığının sık sık ölçülmesi, beslenmenin yeterli olup olmadığını değerlendirmek için en kolay yöntemdir. İstenmeyen ciddi ağırlık kaybı, özellikle ileri yaşlarda ölüm oranı ile ilişkilendirilmiştir. Ağırlık kaybının bir ay içinde vücut ağırlığının %2'sinden, üç ay içinde %5'inden ve altı ay içinde %10'undan daha fazla olması risk faktörlerindendir (14).

Malnütrisyon değerlendirme araçları, hastalardaki spesifik beslenme eksikliklerini belirlemek için klinik ortamlarda kullanılmaktadır. Değerlendirme araçları, klinisyenlerin hastanın

durumunu daha iyi anlamasını sağlar ve hedefe yönelik tedavi stratejilerini teşvik edebilir. ASPEN, beslenme durumunun değerlendirilmesinde kullanılan standart bir klinik yaklaşımdır. Bu yaklaşım, inflamasyon ve malnütrisyon varlığını belirlemek için klinik tanının yanı sıra bireyin tıbbi ve ailesel geçmişini de dikkate alır. Ateş, hipotermi, taşikardi, ödem ve kilo alma/kayıbı gibi klinik bulgular malnütrisyonu tespit etmek için kullanılır. ASPEN kılavuzları, objektif bir doğrulama için serum albümini, C-reaktif protein, beyaz hücre sayımı, negatif nitrojen dengesinden oluşan laboratuvar parametrelerini vurgulamaktadır. Bunun yanı sıra, el kavrama dinamometresi ve fiziksel performanslar (zamanlı yürüme, sandalyede durma ve merdiven testleri gibi) dahil olmak üzere güç testleri yaşlılarda değerlendirme için kullanılmaktadır (15). ASPEN'e ek olarak, Kısa Beslenme Değerlendirme Anketi (Short Nutritional Assessment Questionnaire-SNAQ) ve Beslenme Risk Taraması (Nutrition Risk Screening - NRS) malnütrisyon hastalarının erken tespiti için hızlı ve genel araçlardır. Bu araçlar vücut ağırlığı, beden kütle indeksi, besin alımı ve yaş gibi biyometrik özellikleri dikkate alır (16, 17). Bazı hasta popülasyonları malnütrisyon değerlendirmeleri için daha özel bir yaklaşım gerektirdiğinden, bu spesifik hastalara yönelik farklı araçlar vardır. Örneğin, Mini Nütrisyonel Değerlendirme Kısa Formu (Mini-Nutritional Assessment Short Form - MNA-SF) yaşlılarda demans ve depresyonun bilişsel sorunlarını inceler (18, 19). Yoğun bakım ünitesindeki hastalar, hastalıklarının ciddiyetini göz önünde bulunduran farklı beslenme değerlendirmeleri gerektirir. Kritik Hastalarda Beslenme Riski (The Nutrition Risk in the Critically Ill - NUTRIC) ve modifiye Kritik Hastalarda Beslenme Riski (the modified Nutrition Risk in the Critically Ill - mNUTRIC), yoğun bakım ünitelerine kabul edilen hastalarda hastalığın ciddiyetini saptayan Akut Fizyoloji, Yaş, Kronik Sağlık Değerlendirmesi II (Acute Physiology, Age, Chronic Health Evaluation II - APACHEII) parametresini kullanmaktadır (20). Her iki değerlendirme aracı da hastanın yoğun bakım ünitesindeki organ fonksiyonunu takip eden Sıralı Organ Yetmezliği Değerlendirmesi (SOFA) skorunu hesaplar.

Bu spesifik araçlara ek olarak, Patient Generated-Subjective Global Assessment (PG-SGA), beslenme hesaplaması için hasta semptomlarını kullanan onkoloji hastalarına has bir değerlendirme aracı örneğidir (21).

Makine öğrenmesi

Makine öğrenimi terimi ilk olarak Alan Turing'in "Makineler düşünebilir mi?" sorusunu sormasıyla ortaya atılmıştır (22). Özetle, makine öğrenimi temel bir sorudan ortaya çıkmıştır: Bilgisayarların bizim çalışma şeklimizin ötesine geçmesi ve belirli işlemleri kendi kendilerine yapmayı öğrenebilmeleri mümkün mü? (23). Makine Öğrenimi ve Yapay Zeka makine öğrenimi temelde bilgisayar biliminin bir alt dalıdır ve 1959 yılında yapay zekada hesaplamalı öğrenme ve örüntü tanıma çalışmalarından ortaya çıkmıştır. Makine öğrenimi, yapının bir işlevi olarak verilere dayalı tahminler yapabilen algoritmalar oluşturma sistemidir. Bu tür algoritmalar, statik program yönergelerini sıkı bir şekilde takip etmekten ziyade, veri odaklı tahminler ve kararlar almak için örnek verilerden modeller oluşturarak çalışmaktadır. Yapay Zeka, insan zekasını taklit edebilen sistemler ya da makineler için kullanılan genel bir terimdir. Yapay zekanın bir alt türü olan makine öğrenimi, makineye kodlanmış hazır verilere dayalı olarak öğrenme yapan veya performansı artırma sistemleri oluşturma üzerinde odaklanır. En temel haliyle makine öğrenimi, bir makinenin (genellikle bir bilgisayarın) bir görevi yapmayı öğrenmesine yardımcı olmayı amaçlamaktadır. Son yıllarda makine öğrenimi çalışmaları, matematik ve istatistikten faydalanarak karar verme ve tahmin etme problemlerini çözmek için sıklıkla kullanılmaktadır (24).

Makine Öğrenmesi yaklaşımları; Denetimli Öğrenme, Denetimsiz Öğrenme, Pekişmeli Öğrenme, Yarı Gözetimli Öğrenme olarak ayrılmıştır. Denetimli Öğrenme (Supervised Learning) yaklaşımında, veri setinde çıktı değerleri (değişkeni) bulunur. Denetimli öğrenmede, sınıflandırma ve tahmin için bir model yaratılır ve daha sonra yeni veriler için bu model kullanılarak tahminler elde edilmektedir (25). Sosyal

medya platformunda Antalya ili için gelen yorumlar üzerinde denetimsiz öğrenme yöntemi kullanarak yapılan çalışmada elde edilen verilere göre turizm sektöründeki işletmelerin geliştirecekleri stratejiler için önemli olan bilgileri edinebilecekleri sonucu elde edilmiştir (26). Yarı Denetimli Öğrenme (Semi-Supervised Learning) yaklaşımında, veri setinde büyük çoğunlukta çıktı değişkeni bulunmayan, girdi değişkeni varken bununla birlikte az miktarda girdi ve çıktı değişkeninin de bulunmaktadır (25). Kolorektal kanser hastalığının nüks riski tahmininde yapılan ve yarı denetimli öğrenme modelini kullanan bir araştırmada elde edilen sonuçlara göre kanser hastalarının gen ekspresyonuna dayalı tahminlerde bu modelin başarılı bir şekilde kullanılabileceğini görülmüştür (27). Pekiştirmeli Öğrenme (Reinforcement Learning) yaklaşımında, davranışsal bir makine öğrenmesi kullanılır. Veri analizi sonucunda kullanıcıyı en iyi sonuçta yönlendirmektedir. Bu makine öğreniminde sistem deneme yanılma yöntemiyle öğrenir. Robotik alanında sıklıkla kullanılır (25). Mobil robotları programlama için yapılan çalışmada pekiştirmeli öğrenmenin elle kodlama yapılarak öğretilmesinden daha hızlı ve iyi sonuçlar verdiğini gözlemlenmiştir (28). Sınıflandırma, denetimli öğrenme yöntemlerinden biridir. Sınıflandırma, makine öğreniminin yaygın ve temel bir uygulamasıdır ve bilinmeyen bir veri setini bilinen bir gruba yerleştirmede kullanılır (29). Karar ağaçları, lojistik regresyon, destek vektör makineleri, rastgele orman, k-en yakın komşu algoritması makine öğreniminde sınıflandırma için en sık kullanılan algoritmalar (30-32). Sınıflandırmanın amacı, belirsiz bir veri parçasını en yüksek doğrulukla bir sınıfa atamak için kullanılabilecek bir sınıflandırıcı geliştirmektir. Makine öğreniminde kullanılan pek çok algoritma bulunmaktadır. Günümüzde makine öğrenmesi sınıflandırması yöntemleri birçok alanda yaygın olarak kullanılır hale gelmiştir. Bu alanlar içerisinde sağlık, makine öğrenmesinin başarılı ve yaygın bir şekilde kullanıldığı önemli bir alandır. Makine öğrenmesi ile yapılan sınıflandırmalar başarılı ve doğru bir şekilde elde edildikleri sürece hem sağlık çalışanları hem de hastalar için son derece faydalı olan yöntemlerdir (33).

Bu çalışma kapsamında, PubMed, Web of Science ve Google Scholar veri tabanlarında "malnütrisyon", "yetersiz beslenme", "makine öğrenmesi" ve "yapay zeka" anahtar kelimeleri kullanılarak tarama yapılmıştır. 2015–2024 yılları arasında yayımlanmış, makine öğrenmesi ile malnütrisyon ilişkisini inceleyen orijinal araştırma makaleleri değerlendirmeye alınmıştır. Editöryal yazılar, sistematik derlemeler, yalnızca teorik model önerileri içeren yayınlar ve klinik ya da istatistiksel veri içermeyen çalışmalar değerlendirme dışı bırakılmıştır. Ayrıca, model çıktısı belirsiz veya değerlendirme kriterleri eksik olan yayınlar da kapsam dışında bırakılmıştır.

Malnütrisyon saptanmasında makine öğrenmesi

Makine öğrenmesinin malnütrisyon teşhisi için kullanılması, tedavi sürecinde otomatik tarama yoluyla erken beslenme müdahalesini kolaylaştırabilir ve tedavinin maliyet olarak hasta başına sağlık giderlerini, morbidite ve mortaliteyi azaltarak fayda sağlayabilir. Bu nedenle, bu bağlamda birçok çalışma yapılmaktadır (34, 35, 36, 37). Çalışmaların özeti Tablo 1’de verilmiştir.

Çok merkezli retrospektif bir kohort çalışmasında, kayıtlı diyetisyen çalışma akışında uygulanan bir makine öğrenimi tarama aracının (MUST-Plus) yetersiz beslenen hastaları hastanede kalış süresinin erken dönemlerinde belirleme ve yetersiz beslenmenin tanı ve belgelenme oranını iyileştirme becerisi incelenmiştir. Çalışma New York’ta farklı hasta popülasyonuna hizmet veren altı hastaneden oluşan büyük bir kentsel sağlık sisteminde yürütülmüştür. Yatış ve tanı arasındaki gecikmenin MUST-Plus uygulaması ile iyileştiği görülmüştür. Araç çıktısının diyetisyenler tarafından kullanılabilirliği %90’ı aşarak kullanıcılar tarafından iyi bir şekilde kabul edildiğini göstermiştir. Uygulama öncesi ve sonrası karşılaştırıldığında, malnütrisyonun hem teşhis hem de belgelenme oranı iyileşme göstermiştir. Yatış ve tanı arasındaki gecikmenin MUST-Plus uygulaması ile iyileştiği görülmüştür (35).

Bangladeş’de yapılan bir çalışmada makine öğrenme algoritmaları kullanılarak 5 yaş altı çocukların malnütrisyon durumlarını tahmin edilmeye çalışılmıştır. Analiz amacıyla, 2014 Bangladeş Nüfus ve Sağlık Araştırması’ndan elde edilen ulusal düzeyde temsili ikincil kayıtlar kullanılmıştır. Doğrusal diskriminant analizi, k-en yakın komşular, destek vektör makineleri, rastgele orman ve lojistik regresyon gibi iyi bilinen beş makine öğrenimi algoritması, çocuklar arasında malnütrisyon durumunu doğru bir şekilde tahmin etmek için kullanılmıştır. Ayrıca, doğruluk, duyarlılık, özgüllük ve Cohen’s k istatistiği kullanılarak algoritmaların sistematik bir değerlendirmesi yapılmıştır. Çeşitli performans parametrelerine dayalı olarak, en iyi sonuçlar %68,51 doğruluk, %94,66 duyarlılık ve %69,76 özgüllük gösteren rastgele orman algoritması ile elde edilmiştir. Ayrıca, rastgele orman sınıflandırmasında (Cohen’s $k = 0.2434$) en yüksek ayırt edici yetenek ortaya çıkmıştır. Mevcut araştırma, malnütrisyonun tahmin edilmesi söz konusu olduğunda rastgele orman özellik seçimiyle birlikte rastgele orman sınıflandırmasının uygulanmasını önermiştir (36).

Başka bir çalışma, boylamsal hasta kayıtlarından malnütrisyonun öngörülebilirliğini ve öngörücü bir modelin dış genelleme kabiliyetini değerlendirmeyi amaçlamıştır. Tahmine dayalı modeller, 2015’ten 2018’e kadar olan ziyaretler dahil olmak üzere Kaliforniya, Florida ve New York için eyalet çapında acil servis ve hastane kabul veritabanları üzerinde geliştirilmiş ve doğrulanmıştır. Veri tabanlarında incelenen durumlar arasında hasta demografisi, tanı kodları ve prosedür kategorileri yer almıştır. Modeller, boylamsal yörüngeler üzerinde eğitilmiş uzun kısa süreli bellek (long short-term memory) tekrarlayan sinir ağlarını ve kesitsel hasta verileri üzerinde eğitilmiş gradyan artırma ağaç ve lojistik regresyon modellerini kapsamaktadır. Alıcı-işletim karakteristiği altındaki alan (Area under the receiver-operating characteristic - AUROC) ve kesinlik-hatırlama eğrileri (precision-recall curves - AUPRC) test setlerindeki ilk malnütrisyon tanılarının tahminini tanımlamak için kullanılmıştır. Hastalar %4,0 (New York) ile

%6,2 (Kaliforniya) arasında malnütrisyon tanısı almıştır. Boylamsal uzun kısa süreli bellek (long short-term memory) modeli malnütrisyon konusunda en doğru tahminleri üretmiştir. Araştırmadan elde edilen verilerle, derin öğrenme modellerinin, mevcut araçlardan daha iyi tahmin performansı ve daha düşük veri toplama gereksinimleri ile mevcut boylamsal hasta kayıtlarından malnütrisyonu güvenilir bir şekilde tahmin edebildiği öne sürülmüştür (34).

Besin alımını ve bunun malnütrisyonla ilişkisine odaklanarak 6 ay ile 5 yaş arasındaki çocuklar arasında besin güvencesizliğinin etkisini araştıran bir çalışmada, makine öğrenme algoritmaları kullanılmıştır ve bu etkiler arasındaki sosyodemografik ve sağlık faktörlerini araştırmak için Batı Şeria’daki 819 çocuktan elde edilen veriler analiz edilmiştir. Analiz, çocukların %18,1’inin besin güvencesizliği ile karşı karşıya olduğunu ve hane halkı eğitimi, aile geliri, yerleşim yeri, ilçe ve yaşın önemli belirleyiciler olduğunu ortaya koymuştur. Bunun yanı sıra, makine öğrenimi modelleri B1 vitaminini, K1 vitamini, A vitamini ve çinko ile birlikte tüm yetersiz beslenme türlerinin temel göstergesi olarak gözlemlemiştir. Düşük vücut ağırlığı kategorisinde kolin ve zayıf kategorisinde karbonhidratlar gibi belirli besinler, benzersiz beslenme öncelikleri olarak belirlenmiştir. Çalışmada makine öğrenimi modellerinin kullanılması, temel öngörücülerin belirlenmesine yardımcı olmakta ve besin güvencesi olmayan çocuklar arasında yetersiz beslenmeye ilişkin değerli bilgiler sağlandığı gözlemlenmiştir (37).

Laboratuvar testlerinin kullanımı, beslenme yetersizliklerini tespit etmek için hızlı ve daha etkili bir yöntem sağlayarak doktorların derinlemesine değerlendirme ve müdahale sürecine başlamasını teşvik ederek sağlık hizmeti sunumunu geliştirebilir. Bununla birlikte, bu metodolojiler genellikle daha geniş bir hasta popülasyonunu tanımlamada ve bu hastaları takip etmede yetersiz kaldığı düşünülmektedir. Yapay zeka, yetersiz beslenmeyi ele alırken bu eksikliklere yönelik ölçeklenebilir çözüm sunmaktadır. Yapay zekaya dayalı algoritmalar, denetimli

öğrenme, denetimsiz öğrenme, derin öğrenme ve bilişsel öğrenme dahil olmak üzere çeşitli modelleme stratejilerinden oluşur. Denetimli öğrenme sınıflandırma ve regresyon için kullanışlı iken, denetimsiz öğrenme verilerdeki örüntüleri tanımlamak için kullanışlı olduğu gözlemlenmiştir (38, 39).Yapay zeka dahil olmak üzere çeşitli modelleme stratejileri veya meta modelleme tabanlı duyarlılık analizi gibi istatistiksel modelleme yaklaşımları, zengin boylamsal klinik parametreleri çıkarmak ve eyleme geçirilebilir tahminlere yol açabilecek kalıpları bulmak için tasarlanabilir (40, 41).

Beslenme ve vücut kompozisyonunun izlenmesine imkan sağlayan bir mobil sağlık uygulaması tarafından toplanan verilere bağlı olarak malnütrisyon riskinin erken tespitine yönelik bir Karar Destek Sistemi sunan ve vücut kompozisyonu verileri için biyoimpedans ölçeği ile bütünleştirilen, İtalya'da bir huzurevinde yapılan çalışmada, 3 farklı süre aralığı (Mart-Eylül 2018 arasında 22 hafta, Aralık 2019-Mart 2020 arasında 17 hafta, Haziran-Ağustos 2020 arasında 13 hafta) belirlenmiş ve bunlar en sürekli ve güvenilir beslenme gözlem seansları olarak değerlendirilmiştir. Ardından, MNA derecelendirme ölçeğinin sonuçlarını baz alıp veri kümesi dengesizliği ile başa çıkabilmek için SMOTE ve maliyete duyarlı öğrenme yöntemleri uygulayarak çeşitli makine öğrenimi modellerini çalıştırılmış ve elde edilen sonuçlardan, malnütrisyon risk tahmini için en iyi performans gösteren makine öğrenimi modellerinin sırasıyla %94 ve %92 medyan doğruluk ve geri dönüş değerlerine ulaştığı görülmüştür. Sonuç olarak da bu yaklaşımın kırılğan yaşlılar için tasarlandığı, fakat aynı modelin risk grubundaki diğer kategorilerde de kullanılabileceği düşünülmektedir (42).

2660 yaşlı hastayı dahil eden çok merkezli, gözlemsel bir kohort çalışması, malnütrisyonlu yaşlı hastaların belirlenmesi ve bireyselleştirilmiş tedaviye odaklanılmasını sağlamak için makine öğrenmesi kullanılarak destekli bir tanı modeli geliştirmeyi amaçlanmıştır. Başlangıçtaki malnütrisyonu, GLIM (Global Leadership initiative on malnutrition) kriterleri kullanılarak

tanımlamışlardır. Malnütrisyon riskini belirleyebilmek için 5 makine öğrenme modeli kullanılmıştır. Sonuçlara bakıldığında, kullanılan makine öğrenimi modelleri ile GLIM kriterlerine dayalı doğru ve dinamik bir malnütrisyonlu yaşlı hasta tespit etme kapasitesi olduğu görülmüştür. Bu modelin, sağlık profesyonellerine yardımcı olacak bir karar mekanizması olarak kullanılabileceği öngörülmüştür (43).

Yapılan başka bir çalışmada, hastaneye yatırışta malnütrisyonu tespit etmek için bir makine öğrenimi modeli (MUSTPlus) kullanılmıştır. 1 Ocak 2021 - 31 Aralık 2022 tarihleri arasında hastaneye yatan yetişkin hastalardan elde edilen veriler analiz edilmiştir. MUST-Plus tahminleri diyetisyen resmi değerlendirmeleri ile karşılaştırılmıştır. Farklı hasta gruplarında, iyi kalibre edilmeyen bir modelin yanlış teşhise sebep olabileceği ve sağlık hizmetlerindeki dengesizlikleri daha da şiddetlendirebileceği varsayımında bulunulmuştur. Kalibrasyonun hem zayıf hem de orta dereceli ölçümleri hem beyaz ve siyah ırka sahip hastalar arasında, hem de erkek ve kadın hastalar arasında önemli ölçüde farklılık göstermiştir. Ayrıca kadınlarda malnütrisyonu erkeklere kıyasla fazla tespit etmiştir. Lojistik yeniden kalibrasyon, örneklemde modelin kalibrasyonunu ırk ve cinsiyete göre önemli ölçüde iyileştirmiştir. Lojistik yeniden kalibrasyon, tüm hasta gruplarında yanlış kalibrasyonu azaltmıştır. Sürekli gözlem ve zamanlı yeniden kalibrasyon modelin doğruluğunu artırabileceği düşünülmüştür (44).

Malnütrisyonun önemli faktörlerini tespit etme ve doğru bir şekilde tahmin edebilme açısından makine öğrenimi modellerinin sağladığı avantajlardan yararlanmayı hedefleyen ve 2005-2006 ve 2015-2016 yıllarına ait Hindistan Nüfus ve Sağlık Araştırması veri setlerindeki çocukların dosyaları kullanan bir çalışma yürütülmüştür.0-59 aylık çocukların beslenme durumunu değerlendirmek için, bodurluk (yaşa göre boy), zayıflık (boya göre ağırlık) ve eş zamanlı bodur zayıflık (yaşa göre boy- boya göre ağırlık) durumları incelenmiştir. Normal Makine Öğrenimi modelleri, Tabular Derin Öğrenme çer-

çeveleri, H2O (H2O.ai tarafından geliştirilen açık kaynaklı bir makine öğrenimi platformu) temel modelleri ve otomatik makine öğrenmesi (Automated Machine Learning - AutoML) modelleri olmak üzere dört tür makine öğrenimi modeli kullanılmıştır. Araştırma sonuçlarında, genel olarak otomatik makine öğrenimi algoritmalarının ve tabular derin öğrenme çerçevelerinin hız ve verimlilik bakımından diğer modellerden daha iyi performans sağladığı ve bunun gibi sınıflandırma problemlerinde önemli olan doğruluk (%96,46'ya kadar) ve AUC-ROC puanlarının (%99,95'e kadar) daha yüksek olduğu görülmüştür. Her üç antropometrik indeks için malnütrisyonun sayısız etmeninin önemini grafiksel gösteriminin ardından, çeşitli modellerin performanslarını karşılaştırarak ve en iyi performans gösteren algoritmaları belirleyerek bulgular sonuçlandırılmıştır. Bu çalışma, etkili önleme, tedavi ve hedef grupların tespiti için malnütrisyonun olası ilişkilerinin belirlenmesinde makine öğrenimini kullanma imkanlarına önemli ölçüde katkıda bulunmayı amaçlamıştır (45).

SONUÇ VE ÖNERİLER

Malnütrisyonun erken tanısı için malnütrisyon tarama ve tanı araçlarının geliştirilmesi, hastaların sağlığı, refahı ve uzun vadede komplikasyonları önlemek için gereklidir. Hastane ortamında kullanılabilecek pek çok beslenme tarama aracı bulunmasına rağmen, en iyi aracın hangisi olduğu konusunda bir fikir birliği bulunmamakta ve tarama uygulamalarına yeterince uyulmadığı için etkin beslenme tedavisine ulaşılamamaktadır. Son yıllarda, makine öğrenimi yöntemleri, klinikte karar vermeye yardımcı olmak ve tedavinin kalitesini, etkinliğini iyileştirmek için birçok tıbbi alanda yaygın olarak uygulanmaktadır. Bu alanda birçok çalışma yapılmış ve hala yapılmaya devam etmektedir. Bu çalışmalar ışığında, makine öğrenmesi kullanılarak malnütrisyonun daha hızlı ve etkili bir şekilde teşhis edilebildiği ve güvenilir bir yöntem olarak kullanılabileceği fikri ortaya çıkmıştır. Bu sayede daha hızlı bir teşhis ile hastalığın önlenmesi veya iyileşmenin hızlandırılması, uzun vadeli komplikasyonların önlenmesi sağlanabilir. Bu

da mortalite, morbidite ve maliyet olarak hasta başına sağlık giderlerini azaltarak hem bireysel hem de toplumsal yönlerden fayda sağlayabilir. Ancak bu çalışmalarda farklı örneklemeler, belirli risk grupları için belirlenmiş kesin bir yaklaşım yoktur. Bu nedenle farklı gruplara özgü ve daha geniş kapsamda yapılarak tüm toplumu kapsayabilecek yaklaşımların oluşturulması için daha fazla uygulama yöntemleri geliştirilip mevcut literatüre katkı sağlanabilir.

REFERANSLAR

1. U.S. Department of Agriculture & U.S. Department of Health and Human Services. (2020). *Dietary Guidelines for Americans, 2020–2025* (9th ed.). <https://www.dietaryguidelines.gov>
2. Corkins MR, Guenter P, DiMaria Ghalili RA et al. Malnutrition diagnoses in hospitalized patients: United States, 2010. *J Parenter Enteral Nutr.* 2014;38(2):186-95. <https://doi.org/10.1177/0148607113512154>
3. White JV, Guenter P, Jensen G et al. Consensus statement of the Academy of Nutrition and Dietetics/American Society for Parenteral and Enteral Nutrition: characteristics recommended for the identification and documentation of adult malnutrition (undernutrition). *J Acad Nutr Diet.* 2012;112(5):730-8. <https://doi.org/10.1016/j.jand.2012.03.012>
4. Correia MITD, Perman MI, Waitzberg DL. Hospital malnutrition in Latin America: A systematic review. *Clin Nutr.* 2017;36(4):958-67. <https://doi.org/10.1016/j.clnu.2016.06.025>
5. Correia MITD. Nutrition screening vs nutrition assessment: what's the difference? *Nutr Clin Pract.* 2018;33(1):62-72. <https://doi.org/10.1177/0884533617719669>
6. Kondrup J, Allison SP, Elia M et al. ESPEN guidelines for nutrition screening 2002. *Clin Nutr.* 2003;22(4):415-21. [https://doi.org/10.1016/S0261-5614\(03\)00098-0](https://doi.org/10.1016/S0261-5614(03)00098-0)
7. Robinson D, Walker R, Adams S et al. Definition of Terms, Style, and Conventions Used in ASPEN Board of Directors–Approved Documents. *ASPEN, May. 2018:1-21. ASPEN-Definition-of-Terms-Style-and-Conventions-Used-in-ASPEN-Board-of-Directors–Approved-Documents.pdf*
8. Ukleja A, Freeman KL, Gilbert K et al. Standards for nutrition support. 2010. <https://doi.org/10.1177/0884533610374200>

9. Stratton RJ, Green CJ, Elia M. Disease-related malnutrition: an evidence-based approach to treatment: Cabi; 2003. <https://doi.org/10.1079/9780851996486.0000>
10. Cederholm T, Barazzoni R, Austin P et al. ESPEN guidelines on definitions and terminology of clinical nutrition. *Clin Nutr*. 2017;36(1):49-64. <https://doi.org/10.1016/j.clnu.2016.09.004>
11. Lochs H, Allison S, Meier R et al. Introductory to the ESPEN guidelines on enteral nutrition: terminology, definitions and general topics. *Clin Nutr*. 2006;25(2):180-6. <https://doi.org/10.1016/j.clnu.2006.02.007>
12. Sobotka L, Forbes A. Basics in clinical nutrition: Galen; 2019. Erişim adresi: <https://ueaeprints.uea.ac.uk/id/eprint/72123>
13. McWhirter JP, Pennington CR. Incidence and recognition of malnutrition in hospital. *Bmj*. 1994;308(6934):945-8. <https://doi.org/10.1136/bmj.308.6934.945>
14. Karahan İ, Çifci A. Malnütrisyonun tanımı ve hastaların yönetimi. *J Med Palliat Care*. 2020;1(1):5-9. Erişim adresi: <https://dergipark.org.tr/en/pub/jompac/issue/53586/684792>
15. Jensen GL, Hsiao PY, Wheeler D. Adult nutrition assessment tutorial. *Journal of J Parenter Enteral Nutr*. 2012;36(3):267-74. <https://doi.org/10.1177/0148607112440284>
16. Bolayır B, Arik G, Yeşil Y et al. Validation of nutritional risk screening 2002 in a hospitalized adult population. *Nutr Clin Pract*. 2019;34(2):297-303. <https://doi.org/10.1002/ncp.10082>
17. Kruienga HM, Seidell J, de Vet HC et al. Development and validation of a hospital screening tool for malnutrition: the short nutritional assessment questionnaire (SNAQ®). *Clin Nutr*. 2005;24(1):75-82. <https://doi.org/10.1016/j.clnu.2004.07.015>
18. Jeong DH, Hong S-B, Lim C-M et al. Comparison of accuracy of NUTRIC and modified NUTRIC scores in predicting 28-day mortality in patients with sepsis: a single center retrospective study. *Nutrients*. 2018;10(7):911. <https://doi.org/10.3390/nu10070911>
19. Kaiser MJ, Bauer JM, Ramsch C et al. Validation of the Mini Nutritional Assessment Short-Form (MNA®-SF): A practical tool for identification of nutritional status. *J Nutr Health Aging*. 2009;13:782-8. <https://doi.org/10.1007/s12603-009-0214-7>
20. Knaus WA, Draper EA, Wagner DP et al. APACHE II: a severity of disease classification system. *Crit Care Med*. 1985;13(10):818-29. <https://doi.org/10.1097/00003246-198510000-00009>
21. Bauer J, Capra S, Ferguson M. Use of the scored Patient-Generated Subjective Global Assessment (PG-SGA) as a nutrition assessment tool in patients with cancer. *Eur J Clin Nutr*. 2002;56(8):779-85. <https://doi.org/10.1038/sj.ejcn.1601412>
22. Turing AM. *Mind*. 1950;59(236):433-60. <https://doi.org/10.1093/mind/LIX.236.433>
23. Chollet F. Deep learning with Python: Simon and Schuster; 2021. <https://doi.org/10.31211/interacoes.n42.2022.r1>
24. Nils J. Nilsson Robotics Laboratory Department of Computer Science Stanford University Stanford. *Introduction To Machine Learning*. 1998. Erişim adresi: <https://ai.stanford.edu/~nilsson/MLBOOK.pdf>
25. Zilyas D, Yılmaz A. Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*. 2023;14(3):437-47. <https://doi.org/10.24012/dumf.1322273>
26. Sökmen A. Sosyal Medya Verilerinden Metin Madenciliği Yöntemiyle Rekabet Avantajı Yaratma: Antalya Örneği. *Editors/Editörler*. 2020:84. Erişim adresi: <https://acikerisim.kastamonu.edu.tr/items/8f5fad87-22c9-4dd3-8376-26d2d7e74ba6/full>
27. Shi M, Zhang B. Semi-supervised learning improves gene expression-based prediction of cancer recurrence. *Bioinformatics*. 2011;27(21):3017-23. <https://doi.org/10.1093/bioinformatics/btr502>
28. Smart WD, Kaelbling LP. Effective reinforcement learning for mobile robots. *Proceedings 2002 IEEE International Conference on Robotics and Automation (Cat No 02CH37292)*; 2002: IEEE. <https://doi.org/10.1109/robot.2002.1014237>
29. Harrington P. *Machine Learning in Action*: Manning Publications; 2012. Erişim adresi: <https://www.manning.com/books/machine-learning-in-action>
30. Ayık YZ, Özdemir A, Yavuz U. Lise türü ve lise mezuniyet başarısının, kazanılan fakülte ile ilişkisinin veri madenciliği tekniği ile analizi. *Atatürk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(2), 441-454. Erişim adresi: <https://dergipark.org.tr/en/pub/ataunisobil/issue/2820/38029>

31. Breiman L. Random forests. *Machine learning*. 2001;45:5-32. <https://doi.org/10.1023/a:1010933404324>
32. Ulgen K. Makine Öğrenimi Bölüm-2 (k-En Yakın Komşuluk). Medium; 2017. Erişim adresi: <https://medium.com/@k.ulgen90/makine-ogrenimi-bolum-2-6d6d120a18e1>
33. Dogancay MM. Covid-19 hastaları için Makine öğrenmesi sınıflandırma yöntemleriyle hastalık Evresinin Tahmini: Dokuz Eylül Üniversitesi (Turkey); 2023. Erişim adresi: <https://avesis.deu.edu.tr/yonetilen-tez/4b18c6b5-da-b5-48ed-ad46-d2d1785fb0aa/covid-19-hastalari-icin-makine-ogrenmesi-siniflandirma-yon-temleriyle-hastalik-evresinin-tahmini>
34. Jin BT, Choi MH, Moyer MF et al. Predicting malnutrition from longitudinal patient trajectories with deep learning. *PloS one*. 2022;17(7):e0271487. <https://doi.org/10.1371/journal.pone.0271487>
35. Parchure P, Besculides M, Zhan S et al. Malnutrition risk assessment using a machine learning based screening tool: A multicentre retrospective cohort. *J Hum Nutr Diet*. 2024. <https://doi.org/10.1111/jhn.13286>
36. Talukder A, Ahammed B. Machine learning algorithms for predicting malnutrition among under-five children in Bangladesh. *Nutrition*. 2020;78:110861. <https://doi.org/10.1016/j.nut.2020.110861>
37. Qasrawi R, Sgahir S, Nemer M et al. Machine Learning Approach for Predicting the Impact of Food Insecurity on Nutrient Consumption and Malnutrition in Children Aged 6 Months to 5 Years. *Children*. 2024;11(7):810. <https://doi.org/10.3390/children11070810>
38. Deo RC. Machine learning in medicine. *Circulation*. 2015;132(20):1920-30. <https://doi.org/10.1161/CIRCULATIONAHA.115.001593>
39. Noorbakhsh-Sabet N, Zand R, Zhang Y et al. Artificial intelligence transforms the future of health care. *Am J Med*. 2019;132(7):795-801. <https://doi.org/10.1016/j.amjmed.2019.01.017>
40. Chen X, Wang W, Xie G et al. Multi-resolution sensitivity analysis of model of immune response to helicobacter pylori infection via spatio-temporal metamodeling. *Front Appl Math Stat*. 2019;5:4. <https://doi.org/10.3389/fams.2019.00004>
41. Verma M, Bassaganya-Riera J, Leber A et al. High-resolution computational modeling of immune responses in the gut. *GigaScience*. 2019;8(6):giz062. <https://doi.org/10.1093/gigascience/giz062>
42. Di Martino F, Delmastro F, Dolciotti C et al. Malnutrition risk assessment in frail older adults using m-health and machine learning. *ICC 2021-IEEE International Conference on Communications*; 2021: IEEE. <https://doi.org/10.1109/ICC42927.2021.9500471>
43. Wang X, Yang F, Zhu M et al. Development and assessment of assisted diagnosis models using machine learning for identifying elderly patients with malnutrition: cohort study. *J Med Internet Res*. 2023;25:e42435. <https://doi.org/10.2196/42435>
44. Liou L, Scott E, Parchure P et al. Assessing calibration and bias of a deployed machine learning malnutrition prediction model within a large healthcare system. *NPJ Digit Med*. 2024;7(1):149. <https://doi.org/10.1038/s41746-024-01141-5>
45. Jain S, Khanam T, Abedi AJ et al. Efficient Machine Learning for Malnutrition Prediction among under-five children in India. *2022 IEEE Delhi Section Conference (DELCON)*; 2022: IEEE. <https://doi.org/10.1109/delcon54057.2022.9753080>

Tablo 1. Malnütrisyon saptanmasında kullanılan makine öğrenme yöntemleri

Makine Öğrenme Yöntemi	Öğrenme Tipi	Sonuç	Referans
Lojistik Regresyon (Logistic Regression), Rastgele Orman (Random Forest), XGBoost	Denetimli Öğrenme (Supervised Learning)	Veriye dayalı yaklaşımlarla beslenme durumu tahmin edilmiş, XGBoost modeli %88 AUC ile en iyi performansı göstermiştir.	Jin ve ark., 2022
Gradyan Artırma (Gradient Boosting)	Denetimli Öğrenme (Supervised Learning)	MUST-Plus aracı, malnütrisyonun hastane yatışının erken evrelerinde tanılanmasını hızlandırarak tanı oranlarını ve klinik belgelenmeyi artırmada etkili bulunmuştur.	Parchure ve ark., 2024
Rastgele Orman (Random Forest), Doğrusal Ayırıcı Analiz (Linear Discriminant Analysis), En Yakın Komşular (k-Nearest Neighbors), Destek Vektör Makineleri (Support Vector Machines), Lojistik Regresyon (Logistic Regression)	Denetimli Öğrenme (Supervised Learning)	Random Forest algoritması, malnütrisyonun öngörülmesinde en yüksek duyarlılık ve doğruluğu sağlayarak en başarılı yöntem olarak öne çıkmıştır.	Talukder ve Ahammed, 2020
Rastgele Orman (Random Forest), Destek Vektör Makineleri (Support Vector Machines), Lojistik Regresyon (Logistic Regression), Gradyan Artırma (Gradient Boosting)	Denetimli Öğrenme (Supervised Learning)	Random Forest algoritması, 5 yaş altı çocuklarda malnütrisyonu yüksek doğrulukla tahmin etmiş; vitamin B1, K1, A, çinko, kolin ve karbonhidrat gibi mikrobeyinler en belirleyici etkenler olarak saptanmıştır.	Qasrawi ve ark., 2024
Destek Vektör Makineleri (Support Vector Machines), Naive Bayes, Lojistik Regresyon (Logistic Regression), K-En Yakın Komşu (k-NN)	Denetimli Öğrenme (Supervised Learning)	Çeşitli klinik senaryolarda tahmin gücünü karşılaştıran çalışmada, veriye dayalı karar destek sistemlerinin doğruluğu %85'in üzerindedir.	Deo ve ark., 2015
Destek Vektör Makineleri (Support Vector Machines), Karar Ağaçları (Decision Trees), Bayes Sınıflayıcı (Bayesian Classifier)	Denetimli Öğrenme (Supervised Learning)	Farklı algoritmaların karşılaştırıldığı çalışmada, destek vektör makineleri özellikle karmaşık medikal verilerde yüksek doğruluk göstermiştir.	Noorbakhsh-Sabet ve ark., 2019
Uzaysal-zamansal Gaussian Süreç Regresyonu (GPR), Sobol indeks analizi, kısmi sıralı korelasyon katsayısı (PRCC)	Denetimli Öğrenme benzeri parametrik metamodelleme	Geliştirilen iki aşamalı metamodelleme yaklaşımı, parametrelerin immün yanıt çıktıları üzerindeki zamana bağlı etkilerini başarıyla analiz etmiştir. En etkili girdiler tespit edildi; model biyolojik anlamlı sonuçlarla uyumuştur.	Chen ve ark., 2019

Uzaysal-zamansal Gaussi-an Süreçler (GP), Ajan tabanlı model (ABM), ODE/PDE modelleri, Sobol indeksleri, PRCC analizi	Denetimli modelleme & duyarlılık analizi	Hibrit modelleme yaklaşımı, <i>H. pylori</i> enfeksiyonuna karşı gelişen gastrointestinal bağışıklık yanıtlarını yüksek doğrulukla simüle ederek, epitelyal hücre çoğalması ile tolerojenik bağışıklık hücrelerinin enfeksiyon seyrindeki belirleyici rollerini ortaya koymuştur.	Verma ve ark., 2019
Lojistik Regresyon (LASSO), Rastgele Orman (Random Forest), AdaBoost, RUSBoost, k-En Yakın Komşu, SVM, Karar Ağaçları, SMOTE, Cost-sensitive learning	Denetimli Öğrenme (Supervised Learning)	Vücut bileşimi verisi içeren modellerle %94 doğruluk ve %92 duyarlılık elde edilmiştir. Cost-sensitive learning, veri dengesizliğiyle başa çıkmada en etkili yöntem olarak belirlenmiştir.	Di Martino ve ark., 2021
LightGBM, XGBoost, Rastgele Orman (Random Forest), Lojistik Regresyon, Naive Bayes, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı (MLP)	Denetimli Öğrenme (Supervised Learning)	Çalışma, yaşlı bireylerde malnütrisyon tanısını desteklemek için geliştirilen makine öğrenmesi modellerinin yüksek doğruluk sunduğunu, bireysel risklerin SHAP ile açıklanabildiğini ve klinik müdahaleleri yönlendirmede kullanılabileceğini göstermiştir.	Wang ve ark., 2022
Rastgele Orman (Random Forest), Kalibrasyon: Lojistik Recalibration, Recalibration-in-the-Large	Denetimli Öğrenme (Supervised Learning), kalibrasyon analizi	Model kadınlarda aşırı tahmin, erkeklerde yetersiz tahmin yaparken; ırksal gruplar arasında da kalibrasyon dengesizlikleri göstermiştir.	Liou ve ark., 2024
AutoML algoritmaları, Derin Öğrenme (TabularDL), Karar Ağaçları, Lojistik Regresyon, Rastgele Orman, SMOTE, Gain Ratio, LR + Özellik Seçimi	Denetimli Öğrenme (Supervised Learning)	AutoML ve tabular derin öğrenme modelleri, Hindistan'daki 5 yaş altı çocuklarda malnütrisyonu yüksek doğruluk (%96.5) ve AUC (%99.9) ile öngörerek, büyük ve dengesiz veri setlerinde etkili ve ölçeklenebilir çözümler sunmuştur.	Jain ve ark., 2022