

Derleme | Review

YAPAY ZEKANIN ALERJİK HASTALIKLARIN TANI VE TEDAVİSİNDE KULLANIMI

USE OF ARTIFICIAL INTELLIGENCE IN THE DIAGNOSIS AND TREATMENT OF ALLERGIC DISEASES

 Lütfi Kılınçkaya¹,  Öner Özdemir^{1*}

¹Sakarya Üniversitesi, Tıp Fakültesi, Çocuk İmmünolojisi ve Alerji Hastalıkları Bilim Dalı, Sakarya, Türkiye.



Öz

Yapay Zeka, toplanan verileri öğrenerek ve bunlara uyum sağlayarak karmaşık insan bilişsel yeteneklerini modellemek için gelişmiş hesaplama algoritmalarının kullanılmasıdır. Yapay Zeka' nın sağlık alanındaki çalışmaları ve uygulamaları son on yılda hızla artmıştır. Sağlık alanındaki bu gelişmelere paralel olarak alerji alanında da Yapay Zeka ve makine temelli öğrenim süreçlerinin de kullanımı artış göstermektedir. Yapay zekanın astım, alerjik rinit, gıda alerjisi gibi pediatrik alerjinin konu başlıklarında kullanım amaçları genellikle daha önce tanı konulan hastaların tekrardan değerlendirilmesi ve buna göre çeşitli algoritmalar oluşturup tanısallı yeterliliği arttırmaktır. Bununla birlikte tedavi takibi ve prognoz değerlendirmede de Yapay Zeka ve ilişkili araçların kullanımlarının artması gerektiği de çalışmalarda belirtilmiştir. Bu derlemede, Yapay Zeka' nın alerjik hastalıkların tanı ve tedavilerinde kullanım metodlarının literatür verileri ışığında anlatılması amaçlanmıştır.

Anahtar kelimeler: Yapay Zeka, alerji, teşhis, tedavi

ABSTRACT

Artificial Intelligence is the use of advanced computational algorithms to model complex human cognitive abilities by learning and adapting to collected data. The studies and applications of Artificial Intelligence in the field of health have increased rapidly in the last decade. In parallel with these developments in the field of health, the use of Artificial Intelligence and machine-based learning processes in the field of allergy is also increasing. The aim of using Artificial Intelligence in pediatric allergy topics such as asthma, allergic rhinitis, food allergy is generally to re-evaluate previously diagnosed patients and to increase diagnostic competence by creating various algorithms accordingly. However, it has also been stated in studies that the use of Artificial Intelligence and related tools should increase in treatment follow-up and prognosis evaluation. In this review, it is aimed to explain the methods of using Artificial Intelligence in the diagnosis and treatment of allergic diseases in the light of literature data.

Keywords: Artificial Intelligence, allergy, diagnosis, treatment

*Corresponding author/İletişim kurulacak yazar: Öner Özdemir; Sakarya Üniversitesi, Tıp Fakültesi, Çocuk İmmünolojisi ve Alerji Hastalıkları Bilim Dalı, Sakarya, Türkiye.

Phone/Telefon:+90 (264) 444 54 00 e-mail/e-posta:ozdemir_oner@hotmail.com

Submitted/Başvuru: 05.12.2025


Accepted/Kabul: 23.03.2026

Published Online/Online Yayın: 19.06.2026

Giriş

Yapay zeka (YZ) sağlık alanı dışında da birçok sektörde benimsenmiştir. YZ, toplanan verileri öğrenerek ve bunlara uyum sağlayarak karmaşık insan bilişsel yeteneklerini Modell Emek için gelişmiş hesaplama algoritmalarının kullanılmasıdır. YZ'nin sağlık alanındaki çalışmaları ve uygulamaları son on yılda hızla artmıştır.^{1,2}

Alerji alanında, ilk çalışmalar büyük ölçüde astım ve atopik dermatit üzerine odaklanmıştır, ancak çok az uygulama geniş çapta uygulanmıştır.^{3,4} Alerji alanında, YZ araştırması ve uygulaması, etkilenen büyük nüfusun yanı sıra sağlık hizmeti kullanımı ve kötü kontrol edilen veya şiddetli astımla ilişkili maliyetler nedeniyle en sık astıma uygulanmıştır. YZ'nin diğer alerji alanındaki tanı ve öngörü uygulamalarına olan ilgi artarken, aynı zamanda bu uygulamayı benimsemenin riskleri ve faydalarına dair çeşitli makaleler de literatürde bulunmaktadır.^{5,6} Makalemizde değerlendirilen yayınların basım yılına göre dağılımı Şekil 1'de gösterilmiştir.



Şekil 1. Makalede atıfta bulunulan çalışmaların yayın yıllarına göre dağılımı

Genel Alerji Alanında Yapay Zekânın Temel Klinik Uygulamaları

Son yıllarda, alerjik hastalıkların teşhisinde YZ'nin uygulanması, bilgisayar destekli teşhis (CSD: Computer-Supported Diagnostics) olarak bilinen alerji testlerinin yorumlanması için yenilikçi araçlar üretmiştir. CSD, uzman sistemlere (ES: Expert Systems) yani tavsiye ve öneriler sunmak için insan uzmanlar gibi hareket eden klinik rutini desteklemek için geliştirilen bilgi tabanlı sistemlere dayanmaktadır. ES'ler, klinik uygulamada insan uzmanların uygun karar verme sistemleriyle yer değiştirmesini desteklemek için kullanılan gelişmiş format araçlarıdır. Örneğin, mikroyarray teknolojisine dayalı alerji testlerinin sonuçlarını yorumlamak, özellikle klinik rutinlerinde böyle bir testle uğraşmayan klinisyenler için oldukça karmaşık olabilir. Bu nedenle, uluslararası kılavuzlardan ve uzman görüşlerinden elde edilen verilerle eğitilmiş bilgisayar destekli bir aracın mevcudiyeti, teşhis sürecini desteklemede önemli bir rol oynayabilir.

Rekombinant alerjenler kullanılarak alerji teşhisi alanındaki ilerlemeler, bileşen çözümlü teşhis (Component Resolved Diagnostic) olarak adlandırılan yöntemin geliştirilmesine yol açmıştır.⁷ CRD, hastanın immüoglobulin E (IgE)

profillerini tasvir etmeye ve spesifik IgE'nin primer duyarlılıktan mı yoksa çapraz reaktiviteden mi kaynaklandığını netleştirmeye yardımcı olabilir. Özellikle polisensitize kişilerde, kliniği ve/veya sensitizasyon paterni belirsiz olanlarda ve tedaviye yanıt vermeyen hastalarda faydalıdır.⁸ Son yıllarda, Allergenius® adlı bir ES mikroyarray teknolojisine (ImmunoCAP ISAC®) dayalı alerji testlerinin yorumlanmasını desteklemek için geliştirilmiştir. Çalışma, bu ES'yi yapay ve gerçek vakalar kullanarak doğrulamış ve raporlarını moleküler tanı konusunda deneyimli klinisyenlerin raporlarıyla karşılaştırarak Allergenius®'un ISAC® sonuçlarının anlaşılmasını iyileştirmek ve hastanın IgE profilinin kapsamlı bir yorumunu elde etmek için umut verici bir araç olabileceğini öne sürmüştür. Gerçekten de Allergenius®'un çapraz ve eş duyarlılığı ayırt edebildiği ve gerçek ve çapraz reaktif bileşenlere karşı duyarlılığı belirleyebildiği görülmüştür. Alerji uzmanları ile ES arasında 10/18 konuda mükemmel bir uyum bulunmuştur. Alerji uzmanları, Allergenius®'un tespit edemediği sorunları tanımlamamıştır.⁹

Astım Alanında Yapay Zekanın Temel Klinik Uygulamaları

Astım için YZ'nin önerilen faydaları arasında gelecekte astım gelişiminin öngörülmesi, daha doğru tanı, astım alevlenmelerinin öngörülmesi, klinisyenin astım kılavuzlarına bağlılığının değerlendirilmesi ve optimal terapötik müdahale için astım endotiplerinin sınıflandırılması yer almaktadır.¹⁰⁻¹⁸

Mayo Clinic'te yakın zamanda yapılan ve klinisyenlerin astım kılavuzlarına YZ ile uyumunu değerlendiren bir çalışma, bu kavramlardan bazılarını göstermektedir. Eğitim seti için 200 ve test seti için 100 olmak üzere 300 astım hastasının klinik notları analiz için seçilmiştir.¹⁰ Bu çalışmada, araştırmacılar klinisyen notlarındaki metinleri analiz etmek ve bunlardan veri çıkarmak için doğal dil işleme (NLP) kullanmışlardır. Bazı durumlarda metin madenciliği olarak da adlandırılan NLP, yapılandırılmamış metinlerin bilgisayar tabanlı analiz yöntemidir.³ Bu yöntem kullanılarak yapılandırılmış laboratuvar ve genomik veriler, tanı, hasta bakımı ve bilimsel araştırma için "All of Us" adında YZ odaklı bir program oluşturulmuştur.¹⁹ Bu programın esas kullanım alanı başta allerji olmak üzere tıbbın diğer alanlarını da kapsamı beklenmektedir.^{20,21}

Astım tanısı belirsiz olduğunda, ML (Machine Learning-Makine öğrenmesi) solunum semptomları olan hangi hastaların gerçekten astım olduğunu belirlemede rol oynayabilir. Tıbbi veri tabanlarından çıkarılan verilere uygulanan ML modellerinin, astımlı hastaları diğer potansiyel solunum tanılarından doğru bir şekilde ayırt ettiği gösterilmiştir ve bu modelleri güçlendirmek için benzer çalışmalar önerilmiştir.^{11,12}

Astımın optimal tedavisi için, öngörücü biyobelirteçler kullanarak astım endotiplerini daha iyi anlamak amacıyla çoklu-omik veri kümelerine ML yaklaşımları önerilmiştir.²² Astımın heterojenliği, benzer biyobelirteç profillerine rağmen aynı monoklonal ajana farklı yanıtlar sergileyen hastalarla standart biyobelirteç yaklaşımlarını bile yalanlamaktadır. Klinik özellikler veya "omik olmayan"

verilerle eşleştirilmiş yüksek boyutlu "omik" verilerin makine öğrenimi entegrasyonu, gelecekte astım tedavisinde hassasiyeti ve kişiselleştirmeyi artırma fırsatını temsil etmektedir.^{23,24} İnhalerler de dahil olmak üzere astım terapötiklerinin önemli maliyeti, belirli ilaçlara yanıt verenlerin daha hızlı ve daha hassas bir şekilde tanımlanmasıyla sağlık hizmeti maliyetlerini azaltmak için YZ için bir fırsat teşkil etmektedir. Astım teşhisi, tahmini ve sınıflandırması ile ilişkili çok sayıda karmaşık veri göz önüne alındığında, YZ gelecekte klinik uygulanabilirliği olan astım araştırmalarında daha fazla kullanılmaya başlanacaktır.

Alerjik Rinit / Alerjik Konjunktivit

Yakın zamanda, popülasyona dayalı bir doğum kohortuna katılan çocuklarda alerjenlerin alerjik hastalıklarla ilgili tahmin yeteneğini test etmek için bir ML yaklaşımı kullanılmıştır. Spesifik IgE paternlerinin klinik sonuçlarla ilgili ayırt edici kabiliyeti, mikroarray alerji testi tarafından sağlanan bilgiler ile klinik semptomlar arasındaki ilişkiyi araştırmak için karar ağaçları (çalışma popülasyonunu alerjen eşikleri ve kombinasyonlarına göre gruplandıran) ve Bayesian ağları (değişkenlerin nedensel bağımlılıklarını araştıran) gibi farklı ML modelleri aracılığıyla analiz edilmiştir. Astım, rino-konjunktivit, hırıltı ve hava yolu hiper-reaktivitesi semptomlarının aksine, ön tahmin modelleri egzama semptomları için zayıf performans göstermiştir; bu da CRD olarak da adlandırılan makine bazlı öğrenmenin egzamalı çocuklarda güvenilir bir tanı aracı olmayabileceğini düşündürmektedir; bunun nedeni, egzamanın patogeneğinde IgE aracılı mekanizmalardan ziyade bozulmuş cilt bariyeri fonksiyonunun daha önemli rolü veya yüksek tahmin kabiliyetine sahip alerjenlerin çip üzerinde zayıf mevcudiyetidir.²⁵

Fu ve ark.²⁶ yaptığı çalışmada, göz semptomları, nazal kavite muayenesi, burun akıntısı gibi 16 semptomu içeren toplam 66 bulgu ve bu bulgularla ilişkilendirilen alerjik rinit ve yedi farklı hastalık (rinosinüzit, kronik rinit, üst solunum yolu enfeksiyonu vs.) tanımlanmış ve bu tanımlanan maddeleri değerlendirmek ve aynı veri grubu üzerinde eğitmek için birden fazla model tanımlanmıştır. Bu modeller beş farklı sınıflandırma algoritmasında (Naive Bayes, destek vektör makinesi, lojistik regresyon, çok katmanlı algılayıcı, GC Forest ve XGBoost) değerlendirilmiş ve nihai olarak bulunan modelin (ARF-OOBEE: Adaptive Random Forest-out of Bag-Easy Ensemble) diğer algoritmalara göre %2'lik bir tanısız üstünlüğünün var olduğu saptanmıştır.

Her ne kadar tanısız avantajları olsa da alerjik rinit tanısının genellikle semptom skorlaması ve alerjen tespitine dayandığı bilinmektedir. Bazı olguların negatif test sonuçları olmasına rağmen aşikâr semptomlarının bulunması, nazal provokasyon testi gibi ek tanısız metotlara ihtiyaç duyulması anlamına gelmektedir. Bu testlerin algoritmada bulunmadığı YZ modellerinin de istenen tanısız yetkinliği vermediği durumları ortaya çıkarabilmektedir.

Atopik Dermatit (Çocukluk Çağı Egzaması)

Genel popülasyondaki yüksek atopik dermatit prevalansı göz önüne alındığında, talep veri tabanlarında üretilen veri miktarı, YZ yöntemleriyle analiz edilmeye uygundur. Son zamanlarda YZ; AD tanısı, şiddet tahmini ve skorlaması, omik analizi ve tedavi yanıtı tahminine uygulanmıştır. AD'de YZ daha önce gözden geçirilmiştir; ancak bu alan araştırmalarla aktif olmaya devam etmektedir.^{4,27}

Egzama, oldukça heterojen alt fenotipler/endotipler içeren karmaşık bir enflamatuvar deri hastalığıdır. Bu heterojenliği yakalamak, mevcut verilerden öğrenmek ve hastalık durumları arasında ayırım yapmak ve multi-omik ve klinik veriler arasındaki karmaşık ilişkileri tanımlamak için yeni veriler üzerinde tahminler yapmak için gelişmiş birleşik yaklaşımlar giderek daha fazla kullanılmaktadır.⁴ Bu bağlamda, Ghosh ve ark. daha önce bir destek vektör makinasının (girdileri doğrusal ve doğrusal olmayan dönüşümler kullanarak yüksek boyutlu uzaylara eşleyerek sınıflandırma yapan denetimli bir yöntem) egzamayı sağlıklı ciltten %98 tahmin doğruluğu ile başarılı bir şekilde ayırdığını göstermiştir. Yazarlar, insan mikroarray veri setlerini kullanarak, hastaları sağlıklı kontrollerden sınıflandırmak için yararlı biyobelirteçleri temsil edebilecek ve aynı zamanda terapötik tabakalandırmaya hizmet edebilecek egzama ile ilişkili 89 geni tanımlamıştır.²⁸

Okul çocuklarından oluşan bir kohortta çeşitli kemokinler ve egzama arasındaki karmaşık ilişkileri araştırmak için yenilikçi bir ML yöntemi kullanan çok yeni bir çalışma, egzama endotiplerini karakterize etmede bu tür bir yaklaşımın faydalarına ışık tutmuştur. Yazarlar, belirti ve semptomları egzama kriterlerini karşılayan çocukların, egzama teşhisi için yararlı olan CCL17, CCL22 ve CCL27 kemokin ligandlarının daha yüksek seviyelerini gösterme eğiliminde olduklarını bildirmiştir.²⁹ Genel olarak, hesaplamalı analizdeki son gelişmeler, egzama endotipleme ve sınıflandırma için bu yöntemlerin uygulanabilirliğini ve umut verici katkısını vurgulamasına rağmen, şimdiye kadar çocuklarda çok az çalışma yapılmıştır. Patofizyolojik mekanizmaların daha iyi tanımlanması ve tanı için yeni biyobelirteçlerin belirlenmesi için farklı yaklaşımların büyük ölçekli ve boylamsal kohortlarda entegre edilmesi ve doğrulanması gerekecektir.²⁴

AD tanısı, AD tanısına farklı yaklaşımları olan farklı uzmanlıklar tarafından konulabilir. Son yayınlar, cilt lezyonlarının fotoğrafik görüntülerinin, derin evrişimli sinir ağı (CNN) ve hibrit derin sinir ağları dahil olmak üzere DL (Deep Learning) algoritmaları kullanılarak analiz edilebileceğini ve böylece AD'nin diğer yaygın cilt rahatsızlıklarından doğru bir şekilde ayırt edilebileceğini göstermiştir.^{30,31} Ultrason veya dermal görüntüleme kullanan diğer görüntüleme yöntemlerinden elde edilen veriler, ilgili uzmandan bağımsız olarak tanısız doğruluğu artırmak için potansiyel yollar olarak önerilmiştir. Bazı örnekler arasında noninvaziv subelüler 3D-çözünmüş görüntüleme için multiphoton tomografi ve sedef hastalığı teşhisinde önceki başarılarına dayanarak AD teşhisi için DL ve CNN kullanan Raster-taramalı optoakustik mesoskopi görüntüleri yer almaktadır.³²⁻³⁴

YZ, AD tanısı koymanın ötesinde, AD'nin şiddetini değerlendirmede ve skorlamada da faydalıdır. SCORing Atopic Dermatitis (SCORAD), AD şiddetini ölçmek için yaygın olarak kullanılan bir klinik araçtır; ancak zaman alıcıdır ve gözlemciler arası güvenilirlik tutarsızdır.³⁵ Otomatik SCORAD, AD şiddetini doğru, hızlı ve sunucular arası değişkenlik olmadan ölçmek için CNN ile DL kullanır.³⁶ Hasta tarafından bildirilen veriler veya serum biyobelirteç ölçümleri üzerinde eğitilen ML modelleri, SCORAD ile gelecekteki AD şiddetini önceden tahmin etmek için kullanılmıştır.³⁷⁻³⁹ Araştırmacılar, hangi hastaların en yüksek risk altında olduğunu daha iyi anlamak için hangi klinik ve demografik özelliklerin şiddetli AD ile en çok ilişkili olduğunu belirlemek için ML'yi kullanmışlardır.⁴⁰ ML modelleri ve transkript, mikrobiyota, metabolomik ve maruziyet verilerini içeren daha karmaşık veri kümeleri, araştırmacıların AD patogenezi daha iyi anlamalarına yardımcı olabilir.⁴¹⁻⁴³ Örneğin, çalışmalar kirlilik maruziyetlerini AD hastalığı prevalansı ile ilişkilendirmiştir.⁴⁴ Benzer şekilde, AD alevlenmeleri orman yangınları ile ilişkilendirilmiştir.⁴⁵

Gıda Alerjileri

Gıda alerjisinin, bölgeye bağlı olarak yetişkinlerin %3-11'ini ve dünya genelinde çocukların %8'ini etkilediği bildirilmektedir.^{46,47} Gıdalarda alerjen kontaminasyonu vakası, tüketiciler üzerinde anafilaksi reaksiyonları ve ciddi vakalarda ölüm gibi yıkıcı bir etkiye sahip olabilir ve bu durumun ortaya çıkması gıda üreticilerinin yatırım getirisini olumsuz etkileyebilir. ABD'de gıda alerjilerinin tıbbi ve bakıcı fırsat maliyeti açısından yıllık ekonomik maliyetinin 19 ila 25 milyar dolar arasında olduğu tahmin edilmektedir.^{48,49} Uygun bir azaltma çabası, alerjik reaksiyonlarla ilişkili insani ve ekonomik kayıpları önemli ölçüde azaltabilir. Japonya'da altı gıdadan oluşan bir grubun (tavuk yumurtası, inek sütü, buğday, kabuklu deniz ürünleri, meyve ve karabuğday) gıda alerjisi vakalarının %75'inden fazlasından sorumlu olduğu bildirilmektedir.⁵⁰ Bununla birlikte, Avrupa ve Amerika Birleşik Devletleri'nde, sekiz gıda sınıfı, en şiddetli gıda alerjik reaksiyonlarının %90'ından fazlasını oluşturmaktadır.^{51,52} Bu sekiz gıda buğday (gluten dahil proteinler), yer fıstığı, yumurta, kabuklu deniz ürünleri, süt, ağaç yemişleri, balık ve soya fasulyesini içermektedir.⁵² Amerika Birleşik Devletleri kongresi 2021 yılında Gıda Alerjisi Güvenlik, Tedavi, Eğitim ve Araştırma (FASTER) Yasasını kabul ederek susamı alerjen listesine eklemiştir. Bu, 2023 yılının ocak ayında yürürlüğe girdi ve gıda alerjenleri listesini, gıdalara dahil edildiklerinde gıda etiketlerine dahil edilmesi gereken "büyük dokuz" haline getirmiştir.

YZ, hangi pediatrik hastaların gıda alerjisi geliştireceğini veya devam ettireceğini tahmin etmek için kullanılmıştır. DIABIMMUNE veri setinden bağırsak mikrobiyom profilleri ve gıda alerjenine özgü serum spesifik IgE kullanılarak Rusya, Finlandiya ve Estonya'da doğumdan 3 yaşına kadar olan bebeklerde süt, yumurta ve yer fıstığı alerjisini tahmin etmek için özellikle uzun kısa süreli bellek (LSTM) kullanan bir DL çerçevesi önerilmiştir. DL aracı performansı, gıda alerjenine maruz kalmaya verilen klinik yanıtlarla

karşılaştırılmış ve klinik gıda alerjisi durumunu öngörmeye 0,69 AUC ROC değerine sahip olmuştur.

Consortium of Food Allergy Researchers (CoFAR2) çalışmasından yüksek riskli bebekler değerlendirilmiştir. Araştırmacılar 293 çocukta yer fıstığına özgü ve epitopa özgü IgE ve IgG4, toplam IgE ve deri prik test sonuçlarını, demografik bilgileri ve klinik geçmişi prospektif olarak ölçmüş ve karşılaştırmıştır.⁵³ Bu veriler üzerinde eğitilen rastgele forrest ML algoritması, çeşitli yaşlarda toplanan verilerden 4 yıl sonra yer fıstığı alerjisi gelişimini iyi bir doğrulukla tahmin edebilmiştir (AUC 0,84-0,87).⁵⁴ LEAP çalışmasında, Ara h 1-3 proteinlerinin 64 sıralı epitopuna karşı spesifik IgE ve IgG4 biyobelirteçlerini içeren klinik veriler, kullanılan veri miktarına bağlı olarak %64-83 doğruluk aralığında 5 yaşında yer fıstığı alerjisini tahmin etmek için bir elastik ağ algoritmasında değerlendirilmiştir.⁵⁵

Teşhise ek olarak, oral gıda yüklemesi (OFC) toleransın ve süt oral immünoterapisine (OIT) yanıtın öngörülmesi acil bir ihtiyaçtır. Pişmiş yumurtaya karşı OFC'yi tamamlayan pediatrik hastaların retrospektif bir çalışmasından elde edilen yapılandırılmış veriler, demografik bilgiler, toplam IgE, yumurta akına karşı IgE, yumurta sarısı ve ovomukoid kullanılarak bir ML modelini eğitmek için kullanılmış ve OFC başarısını tahmin etmek için 0,83'lük bir AUC ROC göstermiştir.⁵⁶ Bir ML karar ağacı analizi (DTA) benzer şekilde tanısal OFC sonuçlarını değerlendirmiş ve ardından NPV ve PPV (negatif / pozitif prediktif value) > %96 ile OFC sonuçlarının olasılığını tahmin etmek için demografik özellikleri, klinik geçmişi, IgE ve deri prik testi sonuçlarını retrospektif olarak değerlendirmiştir.⁵⁷ Bu çalışmaların her ikisi de tek merkezde yürütülmüştür ve diğer ortamlara genellenebilirliği daha fazla çalışma gerektirmektedir.

Az sayıda çalışma YZ kullanarak OIT sonuçlarını araştırmıştır. Süt OIT toleransı için omalizumabın etkinliğini değerlendiren bir çalışmada, inek sütü alerjisi için süt OIT alan 7 ila 35 yaş arası hastalarda, süt OIT öncesi ve sonrasında sıralı süt proteini epitoplarına karşı IgE ve IgG4 ölçülmüştür. ML, sürekli yanıtsızlığı %87 doğrulukla öngören temel değişkenleri tanımlamak için kullanılmıştır.⁵⁸ Bu ön çalışmalar, gıda alerjisi olan hastalarda OIT sonuçlarının ve OFC sonuçlarının erken belirlenmesinde YZ'nin faydasını göstermektedir.

Çalışmamızda irdelenen literatürlerden, her hastalık alanından temsil edici çalışmalar, AUC (Eğri altında kalan alan), NPV (Negatif Prediktif Değer) ve PPV (Pozitif Prediktif Değer) gibi ölçülebilir performans metriği içeren toplam 10 çalışmaya ait karşılaştırmalı bir özet Tablo 1'de sunulmaktadır.

YZ'nin Benimsenmesinin Önündeki Zorluklar ve Engeller

Önyargı, Zarar ve Etik Hususlar

YZ ve makine öğrenimi yaratımının birçok seviyesinde uygunsuz bir şekilde dahil edilebilecek birçok önyargı, etik ve zarar unsuru vardır. Sağlık hizmeti sunumu sırasında zararı önlemek için adalet, şeffaflık, açıklanabilirlik ve diğer etik özelliklerin dikkate alınması gereklidir. Sağlık hizmetlerinde YZ'nin rolünü değerlendirirken sağlık eşitliği ön planda olmalıdır. Algoritmik önyargı, insan

önyargılarının bilgisayar modellerine dahil edilmesidir. Biyolojik cinsiyet, toplumsal cinsiyet, ırk ve davranışsal tahminler gibi demografik özellikler de dahil olmak üzere

veri unsurları algoritmalara dahil edildiğinde, sağlık eşitliğinin daha da kötüleşmesi riski ortaya çıkmaktadır.⁵⁹

Tablo 1. Alerji alanında kullanılan yapay zeka algoritmalarının karşılaştırmalı performans

Hastalık Alanı	YZ / ML Yöntemi	Uygulama	Performans	Veri Kaynağı	Referans
Genel Alerji	Uzman Sistem (ES)	ISAC® mikroarray sonuç yorumlaması	18 konuda 10/18 mükemmel uyum	Gerçek ve yapay klinik vakalar	Melioli ve ark. 2014
Astım	NLP (Doğal Dil İşleme)	Klinisyen kılavuz uyumunun değerlendirilmesi	300 hasta; eğitim/test seti analizi	Elektronik sağlık kayıtları	Sagheb ve ark. 2022
Astım	Makine Öğrenmesi (ML)	Astım vs KOAH ayrımı	Yüksek tanısal doğruluk	Tıbbi veri tabanları	Joumaa ve ark. 2022
Alerjik Rinit	ARF-OOBEE (Adaptif Rastgele Orman + Ensemble)	AR tanısı; 7 hastalıkla ayırıcı tanı	Diğer algoritmalara göre %2 üstünlük	66 klinik bulgu, 16 semptom	Fu ve ark. 2024
Atopik Dermatit	Destek Vektör Makinesi (SVM)	AD'yi sağlıklı ciltten ayırma	%98 tahmin doğruluğu	Mikroarray transkriptom verisi	Ghosh ve ark. 2015
Atopik Dermatit	Derin Öğrenme / CNN	Otomatik SCORAD şiddet skoru	Hızlı, gözlemciler arası tutarsızlık yok	Klinik fotoğrafik görüntüler	Medela ve ark. 2022
Gıda Alerjisi	LSTM (Derin Öğrenme)	Süt/yumurta/yer fıstığı alerjisi tahmini	AUC ROC: 0.69	Bağırsak mikrobiyom profilleri (DIABIMMUNE)	Metwally ve ark. 2019
Gıda Alerjisi	Rastgele Orman (Random Forest)	Yer fıstığı alerjisi gelişim tahmini (4 yıl)	AUC: 0.84–0.87	IgE/IgG4, deri prik testi (CoFAR2, n=293)	Suprun ve ark. 2020
Gıda Alerjisi	ML Karar Ağacı (DTA)	Oral gıda yüklemesi (OFC) sonucu tahmini	NPV ve PPV >%96	Demografik veri, IgE, deri prik testi	Machnes-Maayan ve ark. 2022
Gıda Alerjisi (OIT)	ML (Epitop-spesifik antikor profili)	Süt OIT'e sürekli yanıtızlık tahmini	%87 doğruluk	IgE ve IgG4 epitop ölçümleri (OIT öncesi/sonrası)	Suárez-Fariñas ve ark. 2019

AR: Alerjik Rinit; AD: Atopik Dermatit; AUC: Eğri Altında Kalan Alan; CNN: Evrişimli Sinir Ağı; DTA: Karar Ağacı Analizi; ES: Uzman Sistem; KOAH: Kronik Obstrüktif Akciğer Hastalığı; LSTM: Uzun Kısa Süreli Bellek; NLP: Doğal Dil İşleme; NPV: Negatif Prediktif Değer; OFC: Oral Gıda Yüklemesi; OIT: Oral İmmünoterapi; PPV: Pozitif Prediktif Değer; ROC: Alıcı İşletim Karakteristik Eğrisi; SVM: Destek Vektör Makinesi

Yapay Zekanın Uygulanması, Yönetimi ve Benimsenmesi

YZ/ML'nin uygulanmasının önünde, düzenleyici hususlar, algoritmaların açıklanabilirliği ve tekrarlanabilirliğinin yanı sıra gizlilik, veri ve yasal kısıtlamalar da dahil olmak üzere birçok engel bulunmaktadır.⁵⁹

Düzenleyici uygulamalar arasında yazılımı tıbbi cihaz (SaMD) olarak kategorize eden FDA süreçleri aracılığıyla teknolojinin onaylanması da bulunmaktadır.⁵⁹ FDA yönetmeliği, SaMD'nin hastalığı teşhis etmek, tedavi etmek, önlemek veya klinik yönetimi bilgilendirmek için tıbbi bir amaca hizmet etmesini gerektirmektedir. SaMD için bir pazar başvurusunda bulunmak için, uygulama için hasta popülasyonunun ve SaMD'nin amaçlanan kullanıcılarının net bir açıklaması sağlanmalıdır. SaMD, analitik ve klinik doğrulamaya ek olarak geçerli bir klinik ilişki göstermelidir. İyi Tıbbi Uygulamalara benzer şekilde, İyi Makine Öğrenimi Uygulamalarına (GMLP) da benzer bir çerçeve uygulanmaktadır. İnsan merkezli bir yaklaşım ve

tam ölçekli benimsemeden önce etkinliği veya gerçek dünya performansını değerlendirmek için klinik çalışmaların yürütülmesi önerilmektedir. Bazı YZ modelleri, tıpta rutin klinik uygulamalara dahil edilmek için uygulama engelleriyle karşılaşmaktadır.⁶⁰ Makine öğrenimi algoritmalarının etkinliği ve güvenliği titizlikle değerlendirilmelidir.

Sonuçlar

YZ'nin çocuk alerjisi alanındaki vaadi, teşhis doğruluğunu önemli ölçüde artırma ve kişiselleştirilmiş sağlık hizmeti sunma fırsatı verse dahi, böyle yenilikçi bir yaklaşımın rutin klinik uygulamaya dahil edilebilmesi için birkaç hususun ele alınması gerekmektedir.

Yeni hesaplama algoritmalarının ve DL'nin potansiyelinin büyük ölçekli çalışmalarda test edilmesi zorunludur. Bu bağlamda, bu araştırma alanındaki yetersizlikleri göz önüne

alındığında, nedensel çıkarımı kolaylaştıran klinik fayda ölçümlerini elde etmek için randomize klinik çalışmalara özellikle ihtiyaç duyulmaktadır.⁶¹ Ayrıca, YZ teknolojilerini araştırmadan klinik ortamlara aktarmadan önce maliyet etkinliği ve güvenlik sorunları gibi karşılanmamış ihtiyaçlar dikkate alınmalıdır. Gerçekten de hassas veri depolama ve yönetimi için güvenlik önlemlerini garanti altına almak için uygun düzenleyici süreçler gereklidir.

Adil ve kapsayıcı bir YZ tabanlı sağlık hizmetini garanti altına almak bir başka kritik konuyu temsil etmektedir. Sağlık hizmeti YZ'si, geliştirilebilir performans seviyelerine ulaşmak için nüfusu temsil eden veriler üzerinde eğitilmeli ve doğrulanmalıdır.⁶² Gerçekten de sosyal ve sağlık eşitsizlikleri, geleneksel olarak bakıma erişimi zayıf olan çocuk gruplarını dışarıda bırakabilir.

Sağlık sistemleri, araştırma topluluğu ve endüstri arasında yapılandırılmış koordinasyon, YZ'nin tüm kritik yönlerini ele almak ve akademik araştırmalardan gerçek hayata aktarılabilirliğini garanti etmek için özellikle önemli olacaktır.

Sonuç olarak, ağırlıklı olarak çoğunluk etnik gruplardan veya yüksek sosyoekonomik düzeydeki hastalardan veri toplamak, bilgisayar bu aşırı temsil edilen gruplardan kaynaklanan tanı modellerini öğreneceğinden, YZ performansını önyargılı hale getirme riski taşıyacaktır. Konuyla ilgili bir diğer husus, klinisyenleri YZ ürün ve hizmetlerini kullanma ve yorumlama konusunda sürekli eğitim yoluyla desteklemek için eğitim programlarının geliştirilmesiyle ilgilidir. Gerçekten de YZ teşhis sürecinin iyileştirilmesinde önemli bir role sahip olsa da yanıltıcı teşhis ve yanlış risk değerlendirmesinde tuzaklar içerebilir.

Etik Beyan

Çalışmamız Yapay Zeka'nın Alerjik Hastalıkların Tanı ve Tedavisinde Kullanımına dair bir derleme yazısı olduğundan çalışma kapsamında insan veya hayvan materyali kullanılmamış olup etik beyan gerektirmemektedir.

Çıkar Çatışması

Yazarların beyan edebilecekleri herhangi bir çıkar çatışması yoktur.

Finansal Destek

Yazarlar finansal destek beyan etmemişlerdir.

Yazar Katkısı

LK, ÖÖ; Fikir ve tasarım, LK, ÖÖ; Literatür taraması ve analizi, LK, ÖÖ; Makale yazımı, LK, ÖÖ; Eleştirel inceleme.

Kaynaklar

1. Rajpurkar P, Chen E, Banerjee O, Topol EJ. AI in health and medicine. *Nat Med*. 2022;28(1):31-38. doi:10.1038/s41591-021-01614-0
2. Lopez-Jimenez F, Attia Z, Arruda-Olson AM, et al. Artificial Intelligence in Cardiology: Present and Future. *Mayo Clin Proc*. 2020;95(5):1015-1039. doi:10.1016/j.mayocp.2020.01.038

3. Rider NL, Srinivasan R, Khoury P. Artificial intelligence and the hunt for immunological disorders. *Curr Opin Allergy Clin Immunol*. 2020;20(6):565-573. doi:10.1097/ACI.0000000000000691
4. Ferrante G, Licari A, Fasola S, Marseglia GL, La Grutta S. Artificial intelligence in the diagnosis of pediatric allergic diseases. *Pediatr Allergy Immunol*. 2021;32(3):405-413. doi:10.1111/pai.13419
5. Rudrapatna VA, Butte AJ. Opportunities and challenges in using real-world data for health care. *J Clin Invest*. 2020;130(2):565-574. doi:10.1172/JCI129197
6. Khoury P, Srinivasan R, Kakumanu S, et al. A Framework for Augmented Intelligence in Allergy and Immunology Practice and Research-A Work Group Report of the AAAAI Health Informatics, Technology, and Education Committee. *J Allergy Clin Immunol Pract*. 2022;10(5):1178-1188. doi:10.1016/j.jaip.2022.01.047
7. Sastre J. Molecular diagnosis in allergy. *Clin Exp Allergy*. 2010;40(10):1442-1460. doi:10.1111/j.13652222.2010.03585.x
8. Stringari G, Tripodi S, Caffarelli C, et al. The effect of component-resolved diagnosis on specific immunotherapy prescription in children with hay fever. *J Allergy Clin Immunol*. 2014;134(1):75-81. doi:10.1016/j.jaci.2014.01.042
9. Melioli G, Spenser C, Reggiardo G, et al. Allergenius, an expert system for the interpretation of allergen microarray results. *World Allergy Organ J*. 2014;7(1):15. doi:10.1186/1939-4551-7-15
10. Sagheb E, Wi CI, Yoon J, et al. Artificial Intelligence Assesses Clinicians' Adherence to Asthma Guidelines Using Electronic Health Records. *J Allergy Clin Immunol Pract*. 2022;10(4):1047-1056.e1. doi:10.1016/j.jaip.2021.11.004
11. Joumaa H, Sigogne R, Maravic M, Perray L, Bourdin A, Roche N. Artificial intelligence to differentiate asthma from COPD in medico-administrative databases. *BMC Pulm Med*. 2022;22(1):357. doi:10.1186/s12890-022-02144-2
12. Kaplan A, Cao H, FitzGerald JM, et al. Artificial Intelligence/Machine Learning in Respiratory Medicine and Potential Role in Asthma and COPD Diagnosis. *J Allergy Clin Immunol Pract*. 2021;9(6):2255-2261. doi:10.1016/j.jaip.2021.02.014
13. Hurst JH, Zhao C, Hostetler HP, Ghiasi Gorveh M, Lang JE, Goldstein BA. Environmental and clinical data utility in pediatric asthma exacerbation risk prediction models. *BMC Med Inform Decis Mak*. 2022;22(1):108. doi:10.1186/s12911-022-01847-0
14. Jiao T, Schnitzer ME, Forget A, Blais L. Identifying asthma patients at high risk of exacerbation in a routine visit: A machine learning model. *Respir Med*. 2022;198:106866. doi:10.1016/j.rmed.2022.10686615.
15. Inselman JW, Jeffery MM, Maddux JT, Lam RW, Shah ND, Rank MA, Ngufo CG. A prediction model for asthma exacerbations after stopping asthma biologics. *Ann Allergy Asthma Immunol*. 2023;130(3):305-311. doi:10.1016/j.anai.2022.11.025.
16. D'Amato M, Ambrosino P, Simioli F, et al. A machine learning approach to characterize patients with asthma exacerbation attending an acute care setting. *Eur J Intern Med*. 2022;104:66-72. doi:10.1016/j.ejim.2022.07.019
17. Lugogo NL, DePietro M, Reich M, et al. A Predictive Machine Learning Tool for Asthma Exacerbations: Results from a 12-Week, Open-Label Study Using an Electronic Multi-Dose Dry Powder Inhaler with Integrated Sensors. *J Asthma Allergy*. 2022;15:1623-1637. doi:10.2147/JAA.S377631

18. Tsang KCH, Pinnock H, Wilson AM, Salvi D, Shah SA. Predicting asthma attacks using connected mobile devices and machine learning: the AAMOS-00 observational study protocol. *BMJ Open*. 2022;12(10):e064166. doi:10.1136/bmjopen-2022-064166
19. Ramirez AH, Sulieman L, Schlueter DJ, et al. The *All of Us* Research Program: Data quality, utility, and diversity. *Patterns (N Y)*. 2022;3(8):100570. doi:10.1016/j.patter.2022.100570
20. Kurnat-Thoma E, Baranova A, Baird P, et al. Recent Advances in Systems and Network Medicine: Meeting Report from the First International Conference in Systems and Network Medicine. *Syst Med (New Rochelle)*. 2020;3(1):22-35. doi:10.1089/sysm.2020.0001
21. Z Zhang XA, Yates A, Vasilevsky N, et al. Semantic integration of clinical laboratory tests from electronic health records for deep phenotyping and biomarker discovery. *NPJ Digit Med*. 2019;2:32. doi:10.1038/s41746-019-0110-4
22. Ray A, Das J, Wenzel SE. Determining asthma endotypes and outcomes: Complementing existing clinical practice with modern machine learning. *Cell Rep Med*. 2022;3(12):100857. doi:10.1016/j.xcrm.2022.100857
23. De A, Sarda A, Gupta S, Das S. Use of Artificial Intelligence in Dermatology. *Indian J Dermatol*. 2020;65(5):352-357. doi:10.4103/ijd.IJD_418_20
24. Eyerich K, Brown SJ, Perez White BE, et al. Human and computational models of atopic dermatitis: A review and perspectives by an expert panel of the International Eczema Council. *J Allergy Clin Immunol*. 2019;143(1):36-45. doi:10.1016/j.jaci.2018.10.033
25. Prosperi MC, Belgrave D, Buchan I, Simpson A, Custovic A. Challenges in interpreting allergen microarrays in relation to clinical symptoms: a machine learning approach. *Pediatr Allergy Immunol*. 2014;25(1):71-79. doi:10.1111/pai.12139
26. Fu D, Chuanliang Z, Jingdong Y, et al. Artificial intelligence applications in allergic rhinitis diagnosis: Focus on ensemble learning. *Asia Pac Allergy*. 2024;14(2):56-62. doi:10.5415/apallergy.0000000000000126
27. Duverdier A, Custovic A, Tanaka RJ. Data-driven research on eczema: Systematic characterization of the field and recommendations for the future. *Clin Transl Allergy*. 2022;12(6):e12170. doi:10.1002/clt2.12170
28. Ghosh D, Ding L, Sivaprasad U, et al. Multiple Transcriptome Data Analysis Reveals Biologically Relevant Atopic Dermatitis Signature Genes and Pathways. *PLoS One*. 2015;10(12):e0144316. doi:10.1371/journal.pone.0144316
29. Yamamoto-Hanada K, Kawakami E, Saito-Abe M, et al. Exploratory analysis of plasma cytokine/chemokine levels in 6-year-old children from a birth cohort study. *Cytokine*. 2020 Jun;130:155051. doi: 10.1016/j.cyto.2020.155051.
30. Aggarwal SLP. Data augmentation in dermatology image recognition using machine learning. *Skin Res Technol*. 2019;25(6):815-820. doi:10.1111/srt.12726
31. Liu Y, Jain A, Eng C, et al. A deep learning system for differential diagnosis of skin diseases. *Nat Med*. 2020;26(6):900-908. doi:10.1038/s41591-020-0842-3
32. Guimarães P, Batista A, Zieger M, Kaatz M, Koenig K. Artificial Intelligence in Multiphoton Tomography: Atopic Dermatitis Diagnosis. *Sci Rep*. 2020;10(1):7968. Published 2020 May 14. doi:10.1038/s41598-020-64937-x
33. Park S, Saw SN, Li X, et al. Model learning analysis of 3D optoacoustic mesoscopy images for the classification of atopic dermatitis. *Biomed Opt Express*. 2021;12(6):3671-3683. doi:10.1364/BOE.415105
34. Aguirre J, Schwarz M, Garzorz N, Omar M, Buehler A, Eyerich K, et al. Precision assessment of label-free psoriasis biomarkers with ultra-broadband optoacoustic mesoscopy. *Nat Biomed Eng*. 2017;1(5):0068. doi:10.1038/s41551-017-0068
35. Schmitt J, Langan S, Deckert S, et al. Assessment of clinical signs of atopic dermatitis: a systematic review and recommendation. *J Allergy Clin Immunol*. 2013;132(6):1337-1347. doi:10.1016/j.jaci.2013.07.008
36. Medela A, MacCarthy T, Aguilar Robles SA, Chiesa-Estomba CM, Grimalt R. Automatic SCORing of Atopic Dermatitis Using Deep Learning: A Pilot Study. *JID Innov*. 2022;2(3):100107. doi:10.1016/j.xjidi.2022.100107
37. Hurault G, Domínguez-Hüttlinger E, Langan SM, Williams HC, Tanaka RJ. Personalized prediction of daily eczema severity scores using a mechanistic machine learning model. *Clin Exp Allergy*. 2020;50(11):1258-1266. doi:10.1111/cea.13717
38. Hurault G, Stalder JF, Mery S, et al. EczemaPred: A computational framework for personalised prediction of eczema severity dynamics. *Clin Transl Allergy*. 2022;12(3):e12140. doi:10.1002/clt2.12140
39. Holm JG, Hurault G, Agner T, et al. Immunoinflammatory Biomarkers in Serum Are Associated with Disease Severity in Atopic Dermatitis. *Dermatology*. 2021;237(4):513-520. doi:10.1159/000514503
40. Maintz L, Welchowski T, Herrmann N, et al. Machine Learning-Based Deep Phenotyping of Atopic Dermatitis: Severity-Associated Factors in Adolescent and Adult Patients. *JAMA Dermatol*. 2021;157(12):1414-1424. doi:10.1001/jamadermatol.2021.3668
41. Clayton K, Vallejo A, Sirvent S, et al. Machine learning applied to atopic dermatitis transcriptome reveals distinct therapy-dependent modification of the keratinocyte immunophenotype. *Br J Dermatol*. 2021;184(5):913-922. doi:10.1111/bjd.19431
42. Acharjee A, Gribaleva E, Bano S, Gkoutos GV. Multi-omics-based identification of atopic dermatitis target genes and their potential associations with metabolites and miRNAs. *Am J Transl Res*. 2021;13(12):13697-13709.
43. Jiang Z, Li J, Kong N, et al. Accurate diagnosis of atopic dermatitis by combining transcriptome and microbiota data with supervised machine learning. *Sci Rep*. 2022;12(1):290. doi:10.1038/s41598-021-04373-7
44. Zeldin J, Chaudhary PP, Spathies J, et al. Exposure to isocyanates predicts atopic dermatitis prevalence and disrupts therapeutic pathways in commensal bacteria. *Sci Adv*. 2023;9(1):eade8898. doi:10.1126/sciadv.ade8898
45. Fadadu RP, Grimes B, Jewell NP, et al. Association of Wildfire Air Pollution and Health Care Use for Atopic Dermatitis and Itch. *JAMA Dermatol*. 2021;157(6):658-666. doi:10.1001/jamadermatol.2021.0179
46. Gupta RS, Warren CM, Smith BM, et al. Prevalence and Severity of Food Allergies Among US Adults. *JAMA Netw Open*. 2019;2(1):e185630. doi:10.1001/jamanetworkopen.2018.5630
47. Gendel SM. Comparison of international food allergen labeling regulations. *Regul Toxicol Pharmacol*. 2012;63(2):279-285. doi:10.1016/j.yrtph.2012.04.007
48. Croote D, Quake SR. Food allergen detection by mass spectrometry: the role of systems biology. *NPJ Syst Biol Appl*. 2016;2:16022. doi:10.1038/npsba.2016.22
49. Gupta R, Holdford D, Bilaver L, Dyer A, Holl JL, Meltzer D. The economic impact of childhood food allergy in the United States [published correction appears in *JAMA Pediatr*. 2013;167(11):1083]. *JAMA Pediatr*. 2013;167(11):1083.

- 2013;167(11):1026-1031. doi:10.1001/jamapediatrics.2013.2376
50. Matsuo H, Yokooji T, Taogoshi T. Common food allergens and their IgE-binding epitopes. *Allergol Int.* 2015;64(4):332-343. doi:10.1016/j.alit.2015.06.009
 51. Sánchez J, Sánchez A. Epidemiology of food allergy in Latin America. *Allergol Immunopathol (Madr).* 2015;43(2):185-195. doi:10.1016/j.aller.2013.07.001
 52. Adedeji AA, Priyesh PV, Odugbemi AA. The Magnitude and Impact of Food Allergens and the Potential of AI-Based Non-Destructive Testing Methods in Their Detection and Quantification. *Foods.* 2024;13(7):994. doi:10.3390/foods13070994
 53. Metwally AA, Yu PS, Reiman D, Dai Y, Finn PW, Perkins DL. Utilizing longitudinal microbiome taxonomic profiles to predict food allergy via Long Short-Term Memory networks. *PLoS Comput Biol.* 2019;15(2):e1006693. doi:10.1371/journal.pcbi.1006693
 54. Suprun M, Sicherer SH, Wood RA, et al. Early epitope-specific IgE antibodies are predictive of childhood peanut allergy. *J Allergy Clin Immunol.* 2020;146(5):1080-1088. doi:10.1016/j.jaci.2020.08.005
 55. Grinek S, Suprun M, Raghunathan R, et al. Epitope-Specific IgE at 1 Year of Age Can Predict Peanut Allergy Status at 5 Years. *Int Arch Allergy Immunol.* 2023;184(3):273-278. doi:10.1159/000526364
 56. Kuniyoshi Y, Tokutake H, Takahashi N, Kamura A, Yasuda S, Tashiro M. Machine learning approach and oral food challenge with heated egg. *Pediatr Allergy Immunol.* 2021;32(4):776-778. doi:10.1111/pai.13433
 57. Machnes-Maayan D, Yahia SH, Frizinsky S, et al. A clinical pathway for the diagnosis of sesame allergy in children. *World Allergy Organ J.* 2022;15(11):100713. doi:10.1016/j.waojou.2022.100713
 58. Suárez-Fariñas M, Suprun M, Chang HL, et al. Predicting development of sustained unresponsiveness to milk oral immunotherapy using epitope-specific antibody binding profiles. *J Allergy Clin Immunol.* 2019;143(3):1038-1046. doi:10.1016/j.jaci.2018.10.028
 59. MacMath D, Chen M, Khoury P. Artificial Intelligence: Exploring the Future of Innovation in Allergy Immunology. *Curr Allergy Asthma Rep.* 2023;23(6):351-362. doi:10.1007/s11882-023-01084-z
 60. He J, Baxter SL, Xu J, Xu J, Zhou X, Zhang K. The practical implementation of artificial intelligence technologies in medicine. *Nat Med.* 2019;25(1):30-36. doi:10.1038/s41591-018-0307-0
 61. Angus DC. Randomized Clinical Trials of Artificial Intelligence. *JAMA.* 2020;323(11):1043-1045. doi:10.1001/jama.2020.1039
 62. Matheny ME, Whicher D, Thadaney Israni S. Artificial Intelligence in Health Care: A Report From the National Academy of Medicine. *JAMA.* 2020;323(6):509-510. doi:10.1001/jama.2019.21579