

GIDA BİLİMİNDE YAPAY ZEKÂ UYGULAMALARI: MAKİNE ÖĞRENMESİ TABANLI YAKLAŞIMLAR VE GÜNCEL EĞİLİMLER

Raciye MERAL^{1*}

Van Yüzüncü Yıl üniversitesi Mühendislik Fakültesi Gıda Mühendisliği Bölümü, Van-Türkiye

Öz

Bu çalışmada, yapay zekâ ve makine öğrenmesi tekniklerinin gıda bilimi ve teknolojisi alanındaki güncel ve potansiyel uygulamaları kapsamlı bir şekilde ele alınmıştır. Çalışmanın başlangıcında, makine öğrenmesine dair temel kavramlar, öğrenme türleri (denetimli, denetimsiz ve pekiştirmeli öğrenme) ve bu alanlarda yaygın olarak kullanılan geleneksel algoritmalar (karar ağaçları, destek vektör makineleri, yapay sinir ağları, k-en yakın komşu vb.) ayrıntılı şekilde açıklanmıştır. Devamında, doğal dil işleme (NLP), görüntü işleme ve nesnelerin interneti (IoT) tabanlı sistemler gibi yapay zekânın alt bileşenlerinin gıda bilimi alanında nasıl kullanıldığına dair örnek uygulamalara yer verilmiştir. Bu kapsamda; etiketleme, içerik analizi, sosyal medya duygu analizi, ürün tanımlama, bozulma tespiti ve gıda güvenliği izleme sistemleri gibi pek çok uygulama senaryosu incelenmiştir.

Literatür incelemesine dayalı olarak, yapay zekâ tabanlı yöntemlerin kalite kontrol süreçlerinde, raf ömrü tahmininde, duyu analizlerde, tüketici eğilimlerinin belirlenmesinde ve mikrobiyal/kimyasal bozulmaların erken tespitinde etkili biçimde kullanıldığı ortaya konmuştur. Ayrıca, bu teknolojilerin veri temelli karar destek sistemlerinin gelişimine katkı sağladığı vurgulanmıştır. Sonuç olarak, veri çeşitliliği, açıklanabilirlik ve model güvenilirliği gibi bazı sınırlılıklar bulunsada, yapay zekânın gıda sistemlerine entegrasyonu, bu alanın geleceğinde daha akıllı, sürdürülebilir, izlenebilir ve tüketici odaklı çözümlerin önünü açacak önemli bir dönüşüm süreci olarak değerlendirilmiştir.

Anahtar kelimeler: Yapay zekâ, Makine öğrenmesi, Derin öğrenme, Gıda bilimi

ARTIFICIAL INTELLIGENCE AND MACHINE LEARNING IN FOOD SCIENCE: CONCEPTUAL FOUNDATIONS AND APPLICATION AREAS

Extended Abstract

This study provides a comprehensive overview of the current and potential applications of artificial intelligence (AI) and machine learning (ML) techniques in the field of food science and technology. It begins with an explanation of key concepts related to machine learning, including learning types (supervised, unsupervised, and reinforcement learning) and commonly used traditional algorithms such as decision trees, support vector machines, artificial neural networks, and k-nearest neighbors. The study then explores how various subfields of AI—particularly natural language processing (NLP), image processing, and Internet of Things (IoT)-based monitoring systems—are applied in food science. Representative applications are presented in areas such as product labeling, content analysis, sentiment analysis on social media, product recognition, spoilage detection, and food safety monitoring systems.

A literature-based review demonstrates that AI-powered methods are effectively used in critical tasks including quality control, shelf life prediction, sensory evaluation, consumer preference analysis, and early detection of

***Sorumlu Yazar (Corresponding Author):** Raciye MERAL

Van Yüzüncü Yıl üniversitesi Mühendislik Fakültesi Gıda Mühendisliği Bölümü, VAN
raciyemeral@yyu.edu.tr

Geliş (Received) : 27.05.2025

Kabul (Accepted) : 21.06.2025

Basım (Published) : 31.07.2025

microbial or chemical spoilage. Moreover, these technologies contribute to the development of data-driven decision support systems that can enhance operational efficiency across the food supply chain.

Despite certain limitations such as data heterogeneity, lack of interpretability, and model reliability, the integration of AI into food systems is assessed as a transformative process. It is expected to pave the way for smarter, more sustainable, traceable, and consumer-oriented food systems in the near future.

Key words: Artificial intelligence, machine learning, deep learning, food science

1. Giriş

İnsanlığın başlangıcından bu yana, yaşamı ve yaşama yeteneğini sürdürmenin ilk yolu gıda tüketmek olmuştur (Esmaily vd., 2024). Gıda bilimi, gıdaların üretimi, işlenmesi, korunması ve dağıtım süreçlerine bilimsel temellerle yaklaşan, çok disiplinli uygulamalı bir bilim dalıdır. Bu alan; kimya, fizik, biyokimya, mühendislik, biyoloji, mikrobiyoloji, moleküler biyoloji, istatistik, beslenme ve sağlık bilimleri gibi pek çok disiplini bünyesinde barındıran, gıda maddelerinin yapısının anlaşılması, bu maddelerin güvenli, besleyici ve işlevsel ürünlere dönüştürülmesi yoluyla ürünlerin tüketiciye ulaştırılmasına yönelik kapsamlı bir yaklaşım sunmaktadır. Gıda bilimciler, bu alanın bilimsel temellerini oluşturan uzmanlar olarak; gıda maddelerinin fiziksel, kimyasal ve mikrobiyolojik özelliklerini araştırmakta, elde ettikleri bulguları güvenli, sürdürülebilir ve yenilikçi gıda ürünlerinin tasarımında kullanılmaktadırlar (Alav vd., 2024; Ceylan vd., 2023; Esmaily vd., 2024; Meral vd., 2024, 2025; Smithers, 2016).

Bu bilimsel temellerin üzerine inşa edilen gıda üretim sistemleri, günümüzde yalnızca beslenme amacıyla değil; aynı zamanda küresel ölçekte artan nüfus, iklim değişikliği, sağlık sorunları ve tüketici beklentileri doğrultusunda şekillenmektedir. Bu nedenle küresel gıda endüstrisi, teknolojik gelişmeler, dijitalleşme ve hassasiyet, güvenlik ve sürdürülebilirlik için artan talepler doğrultusunda dönüşümsel bir değişim süreci geçirmektedir (Ceylan vd., 2021, 2022; Kutlu vd., 2024; Meral, Ekin, vd., 2022; Meral, Kose, vd., 2022; Meral ve Kamberoğlu, 2012; Okumuş vd., 2021). Gıda sistemleri giderek daha karmaşık ve çok boyutlu bir hâl almakta, bu da geleneksel analitik ve karar verme araçlarının; hammadde tedarikinden tüketici tercihlerine kadar tedarik zinciri boyunca üretilen büyük ölçekli, heterojen ve doğrusal olmayan verileri işlemekte yetersiz kalmasına neden olmaktadır. Bu bağlamda, yapay zeka (YZ), gıda biliminde ortaya çıkan çok yönlü sorunları ele almak üzere güçlü ve etkili bir araç olarak öne çıkmaktadır.

YZ algoritmaları—özellikle makine öğrenmesi, derin öğrenme ve doğal dil işleme (NLP) tabanlı yaklaşımlar—büyük ve karmaşık veri kümelerini işleyebilme, gizli kalıpları ortaya çıkarabilme, üretim koşullarını optimize etme ve tüketici davranışlarını öngörebilme gibi önemli avantajlar sunmaktadır. Klasik istatistiksel yöntemlerden farklı olarak, YZ sistemleri verilerden öğrenme ve zaman içinde kendini geliştirme kapasitesine sahiptir; bu da onları dinamik, doğrusal olmayan ve değişken yapıya sahip gıda sistemleri için son derece değerli kılmaktadır. Son yıllarda yapılan araştırmalar, kalite kontrol, süreç optimizasyonu, duyu analizi, gıda güvenliği ve kontaminasyon tespiti, raf ömrü tahmini ve tedarik zinciri yönetimi gibi gıda biliminin çeşitli alt disiplinlerinde YZ uygulamalarının hızla arttığını ortaya koymaktadır. Ayrıca, gıda endüstrisinde metaverse teknolojisinin de ortaya çıkışı, üretim, eğitim, pazarlama ve tüketici etkileşimi alanlarında yeni bir boyut kazandırmaktadır. Sanal gerçeklik (VR) ve artırılmış gerçeklik (AR) tabanlı sistemler aracılığıyla oluşturulan dijital ikizler, gıda üretim süreçlerinin uzaktan izlenmesini, simülasyonlarını ve dijital eğitim platformlarını mümkün kılmakta; bu da insan-makine etkileşimini yeniden tanımlamaktadır (Avcı vd., 2021; Kına, 2023; Kına ve Biçek, 2023a; Kına ve İnan, 2023; Koca, 2024a; Koca ve Avcı, 2024).

Tüm bu gelişmeler, gıda mühendisliği ve ürün geliştirme süreçlerinde veri odaklı, öğrenen ve akıllı karar destek sistemlerine dayanan yeni bir paradigma değişimini yansıtmaktadır. Bu dönüşüm, yalnızca teknolojik bir evrim değil, aynı zamanda sürdürülebilir, güvenli ve kişiselleştirilmiş gıda sistemlerinin inşasında geleceğe yönelik stratejik bir yönelimi temsil etmektedir. Kullanım potansiyelinin artmasına rağmen, yapay zekanın gıda bilimine entegrasyonu hala erken aşamalarındadır. Gıda bilimi ve teknolojisi alanı, karmaşık biyolojik sistemlerle, çok değişkenli proseslerle ve büyük hacimli veri kümeleriyle çalışmayı gerektiren dinamik bir yapıya sahiptir. Gıda ürünlerinin bileşiminden kaynaklanan doğal değişkenlik, işleme koşullarındaki hassas parametreler, raf ömrü tahmini, kalite kontrol, gıda güvenliği, tüketici duyu değerlendirmeleri ve tedarik zinciri yönetimi gibi süreçlerde geleneksel analiz yöntemleri zaman zaman yetersiz kalabilmekte, zaman ve kaynak açısından maliyetli

olabilmektedir. Bu nedenle, büyük ve heterojen veri setlerinin hızlı, doğru ve otomatik biçimde analiz edilmesine olanak tanıyan yapay zekâ temelli yaklaşımlar, gıda biliminin giderek artan sayıda alt alanında önemli bir ihtiyaç hâline gelmiştir. Yapay zekâ, veri madenciliği, örüntü tanıma ve tahmine dayalı modelleme yetenekleriyle hem üretim süreçlerinin optimizasyonunu hem de tüketici odaklı ürün geliştirme stratejilerini daha bilimsel ve veriye dayalı bir temele oturatarak, gıda sistemlerinin daha sürdürülebilir, izlenebilir ve yenilikçi hâle gelmesine katkı sunmaktadır (Miyazawa vd., 2022; Zatsu vd., 2024). Bu doğrultuda, bu çalışmada yapay zekâ ve özellikle makine öğrenmesi temelli yaklaşımların gıda bilimi ve teknolojisindeki uygulama alanları ele alınacak; bu yöntemlerin kuramsal temelleri, sınıflandırılması ve gıda odaklı örnek uygulamalar bağlamında bir değerlendirmesi sunulacaktır.

2. Yapay Zekâ (YZ) ve Makine Öğrenmesi (MÖ): Kavramsal Çerçeve


Yapay zekâ (YZ), insan zekâsına özgü bilişsel işlevlerin (algılama, akıl yürütme, öğrenme ve karar verme) makineler tarafından gerçekleştirilmesini amaçlayan multidisipliner bir araştırma alanıdır. Önceleri bilim kurgu yazarlarının ve sinema filmi yapımcılarının hayal gücünde yaratılan fütüristik toplumlara atfedilen YZ artık modern yüksek teknoloji toplumlarımızda günlük yaşamın bir gerçeği olmuştur (Asnicar vd., 2024). Özellikle yapay zekânın en yaygın alt disiplinlerinden biri olan makine öğrenmesi, insan müdahalesine gerek kalmadan verilerden öğrenen ve bu öğrenme süreci sonucunda tahminlerde ya da sınıflamalarda bulunabilen algoritmalar yoluyla, çok boyutlu ve kompleks verilerin analizinde başarılar ortaya koymaktadır (Goralski ve Tan, 2020).

Makine öğrenmesi, bilgisayar bilimlerinin bir alt alanı olup Arthur Samuel'in 1959 yılında tanımladığı şekliyle, *"bilgisayarlara açıkça programlanmadan öğrenme yetisi kazandırma"* disiplinidir. Yapay zekâ kapsamında desen tanıma ve hesaplamalı öğrenme teorisi çalışmalarıyla evrimleşen makine öğrenmesi, veriden öğrenebilen ve tahmin yapabilen algoritmaların geliştirilmesini ve incelenmesini konu alır. Bu algoritmalar, sabit programlama talimatlarını takip etmek yerine, örnek girdilerden bir model oluşturarak veri odaklı tahminler ya da kararlar verebilir.

Bilgisayarlarla tahmin yapmayı hedefleyen hesaplamalı istatistik alanıyla yakından ilişkili olan makine öğrenmesi çoğu zaman bu alanla örtüşür. Ayrıca matematiksel optimizasyon ile de güçlü bağlara sahiptir; çünkü bu alan makine öğrenmesi için yöntemler, kuramsal altyapı ve uygulama alanları sunar. Farklı veri türlerini analiz etme kapasitesi sayesinde duygu analizi (Kına ve Biçek, 2023; Kına, 2022; Kına ve Biçek, 2023, 2024; Kına ve Özdağ, 2021), görüntü işleme (Ayata vd., 2020; Kına, 2025; Kına ve Özdağ, 2024), doğal dil işleme ve öneri sistemleri (Kına vd., 2024), nesnelerin interneti, siber güvenlik sistemleri (Avcı ve Koca, 2024; Çavdar vd., 2019) gibi birçok uygulama alanında temel bir yöntem olarak kullanılmaktadır. Bu bağlamda, makine öğrenmesi teknikleri, karmaşık veri yapılarından anlamlı bilgi çıkarılmasını sağlayarak yapay zekâ sistemlerinin çok boyutlu problem çözme süreçlerinde etkin bir şekilde görev almasına olanak tanımaktadır.

Genel olarak makine öğrenmesi cevapların bilindiği eğitim verileri verildiğinde öngörücü modeller geliştirmeyi amaçlayan denetimli makine öğrenimi (supervised learning) ve gözlemleri gruplandırmayı veya verilerin ana yapılarının basitleştirilmiş temsillerini oluşturmayı amaçlayan denetimsiz makine öğrenimi (unsupervised learning) olarak kategorize edilebilir (Asnicar vd., 2024). Ayrıca, yarı denetimli öğrenme (semi-supervised learning) ve pekiştirmeli öğrenme (reinforcement learning) gibi yaklaşımlar da bu kapsamda değerlendirilmekte olup, makine öğrenmesi genel olarak dört ana kategoriye ayrılmaktadır. Her bir öğrenme türü, veri yapısına, problem tipine ve hedeflenen çıktıya bağlı olarak farklı algoritmalarla uygulanmaktadır. Tüm makine öğrenmesi uygulamalarının yaklaşık %70'i denetimli öğrenmeye dayanırken, %10 ila %20'si denetimsiz öğrenmeye dayanmaktadır.

Bu öğrenme paradigmasının içerisinde yer alan derin öğrenme (deep learning) ise, özellikle çok katmanlı yapay sinir ağlarına dayalı mimariler aracılığıyla büyük hacimli ve karmaşık verilerin daha soyut düzeyde temsil edilmesini ve yüksek doğrulukla analiz edilmesini sağlar. Görüntü işleme, ses tanıma ve doğal dil işleme gibi çok boyutlu veri türlerinde sağladığı üstün başarılar nedeniyle derin öğrenme modelleri, son yıllarda makine öğrenmesinin ötesinde özel bir uzmanlık alanı olarak konumlanmıştır (Montesinos López vd., 2022; Ongsulee, 2017; Sharma vd., 2024). YZ, makine öğrenimi ve derin öğrenme arasındaki ilişki Şekil 1'de gösterilmektedir. Aşağıdaki alt bölümlerde, geleneksel makine öğrenimi yöntemlerine ve derin öğrenme yöntemlerine dayalı algoritmalar ve uygulamalar ayrı ayrı tanıtılacaktır.



Şekil 1. Yapay Zekâ, Makine Öğrenmesi ve Derin Öğrenme Arasındaki Hiyerarşik İlişki

3. Makine Öğrenmesi Türleri

Makine öğrenmesi, verilerden örüntüler çıkararak karar verme süreçlerini otomatikleştiren bir yapay zekâ alanıdır. Gıda biliminde kalite tahmini, sınıflandırma ve bozulma tespiti gibi çeşitli uygulamalarda kullanılmaktadır.

3.1. Denetimli Öğrenme (Supervised Learning)

Denetimli öğrenme algoritmaları, doğru çıktının bilindiği etiketli örnekler kullanılarak eğitilen makine öğrenmesi teknikleridir. Bu algoritmalar, geçmiş ve mevcut veri kümeleri arasında ilişki kurarak gelecekteki olayları tahmin etmeyi amaçlar. Öğrenme süreci, etiketli bir veri setiyle başlar ve belirli çıktıları öngörmeye yönelik bir model oluşturulmasını hedefler. Örneğin, bir gıda numunesi “U” (uygun) veya “B” (bozuk) şeklinde etiketlenmiş olabilir.

Algoritma, girdilerle birlikte bu doğru çıktıları alarak eğitilir ve tahmin ettiği sonuçları gerçek sonuçlarla karşılaştırarak hataları belirler. Bu hatalar doğrultusunda modelin parametreleri güncellenir ve modelin doğruluğu artırılır. Denetimli öğrenme kapsamında sınıflandırma, regresyon, tahmin ve gradyan artırma (gradient boosting) gibi yöntemler yer alır. Bu teknikler, etiketli verilere dayanarak örüntüleri öğrenir ve sonrasında etiketsiz veriler üzerinde tahmin gerçekleştirebilir (Muhammad vd., 2021a; Nafea vd., 2024; Ongsulee, 2017). Gıda bilimi alanında bu yaklaşım, ürün bozulmalarının erken tespiti, kalite sınıflandırması ve raf ömrü tahmini gibi uygulamalarda yaygın olarak kullanılabilir. Denetimli öğrenme iki algoritma kategorisine ayrılır: regresyon ve sınıflandırma

3.1.1. Regresyon

Regresyon, denetimli öğrenme kapsamında yer bir makine öğrenmesi yöntemidir. Genellikle bir bağımlı değişken ve bir veya birden fazla bağımsız değişken olmak üzere sürekli bir miktarı tahmin etme görevi olarak tanımlanan regresyonda amaç, giriş değişkenleri ile çıktı arasında matematiksel bir ilişki kurarak, gelecekteki gözlemler için sayısal tahminler yapabilen bir model geliştirmektir. Regresyon algoritmaları, geçmiş verilerden öğrenerek bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini istatistiksel olarak modellemeye çalışır (GeeksforGeeks, 2025; Kumar ve Bhatnagar, 2022). Makine öğrenmesinde farklı veri yapıları ve problem türlerine göre çeşitli regresyon algoritmaları kullanılır. Regresyon türleri aşağıda sunulmuştur.

Liner regresyon: Liner regresyon, en basit ve en yaygın olarak kullanılan, bilinmeyen verilerin değerini tahmin etmek için değeri bilinen verileri kullanan istatistiksel bir yöntemdir. Bağımlı ve bağımsız değişken veya değişkenler arasındaki ilişki, gözlemlenen verilere doğrusal bir denklem uydurularak modellenir. Denklemi aşağıda sunulmuştur (Kumar ve Bhatnagar, 2022; Snowflake.com, 2025).

$$Y = a + bx$$

Çoklu Doğrusal Regresyon (Multiple Linear Regression): Birden fazla bağımsız değişkenin, bağımlı değişken üzerindeki etkisini modeller.

$$y = a_1x_1 + a_2x_2 + \dots + a_nx_n + b$$

Polinom Regresyonu (Polynomial Regression): Girdiler ile çıktı arasındaki ilişki doğrusal değilse, polinom terimler eklenerek model genişletilir.

$$y = ax^2 + bx + c$$

Lasso Regresyonu (Least Absolute Shrinkage and Selection Operator): Değişken seçiminde kullanılan, L1 normu ile ceza terimi içeren bir regresyon türüdür. Bazı katsayıları sıfıra indirerek model sadeleştirir.

Ridge Regresyonu: L2 normu içeren ceza terimi kullanır. Aşırı öğrenmeyi (overfitting) önlemeye yardımcı olur.

Elastic Net Regresyonu: Lasso ve Ridge regresyonlarının birleşimidir. Hem L1 hem L2 normlarını içerir.

Loess / Local Regression: Veri noktalarının etrafında lokal ağırlıklı regresyonlar hesaplar. Özellikle küçük veri kümelerinde ve değişken dağılımlarda etkilidir.

3.1.1.1. Gıda Biliminde Regresyon Tabanlı Makine Öğrenmesi Uygulamaları

Regresyon algoritmaları, gıda ürünlerine ait sürekli değişkenlerin tahmini amacıyla yaygın biçimde kullanılabilecek denetimli öğrenme yöntemleridir. Gıda alanında regresyon kullanımına yönelik olası bir örnek, taze ürünlerde C vitamini miktarının tahmini olabilir. Bu senaryoda, ürünün depolama süresi, sıcaklığı, ışık maruziyeti ve nem oranı gibi fiziksel ve çevresel faktörler giriş değişkeni olarak modele sunulabilirken; modelin hedef çıktısı, C vitamini miktarı olacaktır. Bu sayede, yeni örnekler için ölçüm yapılmadan önce, ilgili koşullar altında beklenen vitamin düzeyi tahmin edilebilir. Benzer şekilde, kurutulmuş meyve veya sebze ürünlerinde nem içeriği, renk değişimi düzeyi gibi sürekli değerlerin öngörülmesi de regresyon modelleriyle gerçekleştirilebilir. Ayrıca, duyu analiz kapsamında tat, aroma veya dokuya ilişkin panelist değerlendirmelerinin sayısal skorları, tüketici beğenisinin nicel olarak modellenmesini sağlayabilir. Söz konusu örneklerin her biri, regresyon tabanlı denetimli öğrenme algoritmalarının gıda ürünlerinin kimyasal içerik tahmini, kalite parametrelerinin öngörülmesi ve duyu analiz değerlendirme verilerinin analizi gibi alanlarda taşıdığı uygulama potansiyelini ortaya koymaktadır.

Günümüze kadar regresyon modelleriyle ilgili çeşitli çalışmalar yapılmıştır. Bu bağlamda Naravane ve Tagkopoulos, (2023) tarafından gerçekleştirilen bir çalışmada, makine öğrenmesi teknikleri kullanılarak pişirme işlemi sonrası gıdalardaki mikro besin profillerinin tahmin edilmesi hedeflenmiştir. Modelleme sürecinde, çiğ gıdaların besin bileşimleri giriş verisi olarak kullanılmış ve her bir mikro besin için ayrı regresyon modelleri oluşturulmuştur. Bu modeller, pişirme yöntemine (örneğin, haşlama veya kuru ısıtma) göre ayrı ayrı eğitilmiştir. Model performansı, normalize edilmiş ortalama kare hata (NMSE) metriği kullanılarak değerlendirilmiş ve sonuçlar, geleneksel "retention factor" yöntemine kıyasla ortalama %31 daha düşük hata oranı elde edildiğini göstermiştir.

Osmotik dehidrasyon ve sıcak hava kurutma süreçlerini inceleyen bir çalışmada Rahman vd., (2020), alginik asit ve poligalakturonik asit bazlı yenilebilir kaplama materyalleri kullanılmış ve bu süreçlerin etkileri Yapay Sinir Ağları (ANN) modeliyle değerlendirilmiştir. Model, zaman (dakika), alginik asit yüzdesi ve poligalakturonik asit yüzdesi gibi girdi parametrelerini kullanarak nem kaybı ve katı madde alımı gibi çıktı parametrelerini tahmin etmiştir. ANN modeli, yüksek doğruluk ($R^2 = 0.999$) ve düşük hata oranı ile başarılı sonuçlar elde etmiştir. Bu çalışma, kaplama materyallerinin gıda muhafazası üzerindeki olumlu etkilerini ortaya koyarken, makine öğrenmesinin süreç tahmini ve optimizasyonundaki başarısını göstermiştir.

Benzer bir yaklaşımı Satorabi vd., (2021), kızılotesi kurutma sırasında kayısı dilimlerinin kurutma zamanı ve nem içeriği tahmini için GA-ANN ve ANFIS modellerini kullanarak uygulamıştır. GA-ANN modeli, kurutma zamanı için $r = 0.970$ ve nem içeriği için $r = 0.999$ ile yüksek doğruluk sağlamıştır. ANFIS modeli de benzer şekilde mükemmel tahmin performansı göstermiştir.

Tabassum vd., (2023) taze kesilmiş papaya üzerinde nanoemülsiyon bazlı yenilebilir kaplamaların etkilerini değerlendirmek ve renk değişimi (ΔE), kromatiklik (chroma), ton açısı (hue) gibi kalite parametrelerini tahmin etmek için Yapay Sinir Ağları (ANN) ve Destek Vektör Regresyonu (SVR) modellerini kullanmıştır. SVR modeli, ANN modeline kıyasla daha yüksek doğruluk ve daha düşük hata oranları ($R^2 > 0.99$) ile öne çıkmıştır. Bu çalışma,

makine öğrenmesi yaklaşımlarının deneysel iş yükünü azaltmada ve kalite parametrelerini yüksek doğrulukla tahmin etmede başarısını vurgulamıştır.

Cui vd., (2023) tarafından yürütülen çalışmada, buğday ununun kalite ve kullanım özellikleriyle doğrudan ilişkili olan farinograf parametrelerinin tahmini ele alınmıştır. Bu modelleme yöntemi, farinograf özelliklerinin tahmin performansını önemli ölçüde artırmış; su absorpsiyonu, hamur gelişme süresi, hamur stabilitesi ve yumuşama derecesi gibi parametrelerin tahmininde başarılı sonuçlar elde edilmiştir (Cui vd., 2023).

Raj vd., (2024) buğday ununun farinograf özelliklerini tahmin etmek amacıyla yapay sinir ağı (ANN) tabanlı bir model geliştirmiştir. Zhang vd., (2024) ise hiperspektral ve RGB sensörlerden elde edilen orijinal yansıma (OR), dalga boyu özelliği (WF) ve renk indeksi (CI) verilerini kullanarak, protein içeriği (PC) ve yaş gluten içeriği (WGC) tahmini için doğruluk modelleri oluşturmuştur.

Junior vd., (2020) organik numunelerin nitel ve nicel özelliklerini tahribatsız olarak belirlemek amacıyla NIR spektroskopisini kullanmış; Çoklu Hedef (Multi-Target, MT) tahmin yaklaşımlarının ve çeşitli makine öğrenmesi algoritmalarının performansını değerlendirmiştir. Rousu vd., (2003) tarafından gerçekleştirilen çalışmada, endüstriyel fırıncılık süreçlerinde ürün kalitesinin tahmininde sınıflandırma ve regresyon ağacı, karar listesi, sinir ağı, destek vektör makineleri, Bayes öğrenme algoritmaları ve çok değişkenli istatistiksel yöntemler gibi çeşitli yaklaşımlar karşılaştırılmıştır. Veriler, ekşi mayalı çavdar ekmeği ve Danimarka çöreği üretim süreçlerinden elde edilmiştir. Naive Bayes algoritması sınıflandırmada en başarılı yöntem olarak belirlenmiş, regresyonda ise kısmi en küçük kareler (PLS) yöntemi öne çıkmıştır.

Sen Gupta vd., (2025) Güney Asya’da yaygın olarak tüketilen urdbean türü baklagillerin fiziksel özellikleri ile un ve nişasta örneklerinin fonksiyonel parametrelerini incelediği çalışmada; ANN modeli kullanarak, özellikle pik viskozite gibi özelliklerin tahmininde R^2 değerlerinin 0.90’a yakın çıkmasıyla yüksek uyum elde edildiğini belirtmiştir. Bu sonuçlar, ANN’nin urdbean çeşitlerinin sınıflandırılması açısından etkili bir yöntem olduğunu göstermektedir. Cingöz ve Nacar, (2024) farklı un türlerinin fizikokimyasal özelliklerinden yola çıkarak alveograf parametrelerinin tahmini üzerine çalışmış; 150 un örneği üzerinden yürütülen analizde, protein, kül, düşme sayısı, yaş gluten, gluten indeksi, Zeleny ve gecikmeli sedimantasyon gibi veriler kullanılarak ANN ve çoklu regresyon analizi (MRA) karşılaştırılmıştır. ANN modeli özellikle W parametresinde en düşük hata oranı ve en yüksek doğrulukla en başarılı performansı göstermiştir.

Karunathilaka vd., (2020) FTIR ve FT-NIR spektroskopisinden elde edilen verilerle altı farklı yağ asidinin incelenmesini amaçlamış; PLS ve destek vektör makinelerine (SVM) dayalı doğrusal olmayan kalibrasyon modellerini karşılaştırmıştır. SVM modelleri, her iki veri setinde de PLS’ye göre yaklaşık 2.4 kat daha yüksek doğruluk sağlamış; bu da yağ asidi analizlerinde SVM’nin daha etkili bir yaklaşım olduğunu ortaya koymuştur.

Windarsih vd., (2024) tuna balığı yağına eklenen domuz yağı miktarının tahmini için PLS ve ortogonal PLS (OPLS) modelleri geliştirmiş ve sonuçları Irnawati vd., (2023) tarafından yapılan benzer çalışmayla karşılaştırmıştır. SVM modelleri, PLS ve OPLS’ye kıyasla daha düşük RMSE değeri sunmuş ve hedef analitlerin tahmininde üstün performans göstermiştir. Araştırmacılar, modelin daha fazla taşıyıcı örnek üzerinde test edilmesi durumunda da tekrarlanabilirliğinin yüksek olacağını ifade etmişlerdir. Chu vd., (2023) manda, keçi ve deve sütlerinin daha ucuz inek sütü veya su ile taşıyıcı edilmesini tespit etmek amacıyla orta-kızılötesi spektroskopi (MIRS) ve modern makine öğrenme tekniklerinden yararlanmıştır. SVM, yansıtma izleme regresyonu (PPR) ve Bayes düzenlemeli sinir ağları (BRNN) modelleri, PLS yöntemine göre daha yüksek doğruluk göstermiş; özellikle SVM ile oluşturulan ikili sınıflandırma modelleri, deve sütü-inek sütü ve keçi/deve sütü-su karışımlarını başarıyla ayırt etmiştir.

Scatigno ve Festa, (2022) İtalyan sızma zeytinyağlarının coğrafi köken ve kültivar çeşitliliğini analiz etmek amacıyla ATR-FTIR spektroskopisi ile makine öğrenme yöntemlerini bir araya getirmiştir. Elde edilen spektrumlar; SIMCA, SVM regresyonu (SVMR) ve Ana Bileşen Regresyonu (PCR) ile analiz edilmiş, taşıyıcı örneklerin saf örneklerden ayırt edilmesi hedeflenmiştir. Modellerin doğruluğu bu bağlamda test edilmiştir. Xu vd., (2018), sızma zeytinyağındaki taşıyıcı FTIR spektroskopisi ve çok değişkenli kalibrasyon yöntemleri ile belirlemeye çalışmıştır. Doğrusal ayırma analizi, geri yayımlı yapay sinir ağı ve en küçük kareler destek vektör makinesi (LS-SVM) yöntemleri karşılaştırılmış; LS-SVM modeli eğitim setinde %100, doğrulama setinde ise %92.5 doğruluk ile en başarılı yöntem olarak öne çıkmıştır.

3.1.2. Sınıflandırma

Makine öğrenmesinde sınıflandırma, verileri önceden tanımlanmış kategorilere ayırmayı amaçlayan bir denetimli öğrenme yöntemidir. Bu yöntem, etiketli verilerden (yani hangi girdinin hangi sınıfa ait olduğunu bildiği örneklerden) öğrenerek bir model oluşturur. Elde edilen model, yeni ve daha önce görülmemiş verilerin hangi sınıfa ait olduğunu tahmin etmek için kullanılır (IBM, 2025c).

Sınıflandırma ve regresyon, öngörüye dayalı modelleme türleri olup temel farkları tahmin edilen çıktının türüne dayanır: sınıflandırma, verileri kategorilere ayırırken; regresyon, sürekli sayısal değerleri tahmin eder. Sınıflandırma modelleri belirli sınıflara aitlik belirlerken, regresyon modelleri bağımsız değişkenlere göre sayısal çıktılar öngörür. Lojistik regresyon gibi bazı algoritmalar ise ismine rağmen sınıflandırma amacıyla kullanılarak bu iki yaklaşım arasında yöntemsel bir geçişkenlik olduğunu göstermektedir.

3.1.2.1. Gıda Biliminde Sınıflandırma Tabanlı Makine Öğrenmesi Uygulamaları

Son yıllarda, YZ ve makine öğrenmesi yöntemlerinin gıda mühendisliği alanındaki uygulamaları artış göstermiştir. Bu kapsamda Aich vd., (2018) tarafından yapılan çalışmada, farklı şarap türlerinin kalite düzeylerinin tahmini amacıyla çeşitli makine öğrenmesi algoritmaları kullanılmıştır. Çalışmada, öznelite seçimi için Principal Component Analysis (PCA) ve Recursive Feature Elimination (RFE) yöntemleri uygulanmış; elde edilen öznelite setleri üzerinde sınıflandırma algoritmalarının doğruluk performansları karşılaştırılmıştır. Bulgular, özellikle RFE yöntemiyle seçilen öznelitelerin Random Forest algoritması ile birlikte kullanıldığında en yüksek sınıflandırma başarımının elde edildiğini göstermiştir.

Shaw vd., (2020) Portekiz'e özgü "Vinho Verde" şaraplarına ait 6.497 örnek üzerinde çalışarak, şarap kalitesinin tahmini için CART, Random Forest ve KNN algoritmalarını uygulamıştır. Fizikokimyasal özelliklerin analizinde, alkol ve sülfür dioksit seviyeleri kaliteyi belirleyen en önemli etmenler olarak saptanmıştır. Yüksek alkol ve düşük yoğunluk değerleri, daha yüksek kaliteli şaraplarla ilişkilendirilmiştir. da Costa vd., (2021) Güney Amerika'daki dört ülkeye ait 83 şarap örneğini uçucu, yarı uçucu ve fenolik bileşik içerikleriyle analiz etmiş; CFS ve Rastgele Orman Öneli (RFI) yöntemleriyle öznelite seçimi yapmıştır. Seçilen 13 bileşik, SVM algoritması ile %93.97 doğrulukla sınıflandırılmış ve bu yöntemle şarapların coğrafi özgünlüğü güvenilir biçimde belirlenebilmiştir.

Ozturk vd., (2023) sürekli üretim hatlarında hareket halindeki gıda tozlarının doğru ve gerçek zamanlı sınıflandırılması için NIR spektroskopisi ile makine öğrenmesi entegrasyonunu incelemiştir. Spektral veriler autoencoder ile ön işleme tabi tutulmuş ve ardından SVM modeli uygulanmıştır. Sınıflandırma doğrulukları, statik koşullarda %99.52'den başlayarak artan taşıma hızlarında sırasıyla %97.12, %94.08 ve %91.68 olarak raporlanmıştır.

3.2. Denetimsiz Öğrenme (Unsupervised Learning)

Denetimsiz öğrenme, eğitim veri kümesinin sınıflandırılmamış veya etiketlenmemiş olduğu durumlarda kullanılan makine öğrenmesi tekniklerini kapsar. Bu yaklaşımda algoritmaya "doğru" yanıtlar sunulmaz; sistem, verilerdeki örüntüleri ve gizli yapıları kendi başına keşfetmek zorundadır. Temel amaç, verinin içindeki doğal yapıyı ortaya çıkarmak ve benzerliklere dayalı olarak anlamlı gruplamalar yapmaktır. Örneğin, benzer bileşim ve kalite özellikleri gösteren süt örnekleri segmentlere ayrılarak her gruba özel pastörizasyon, depolama ya da ambalajlama stratejileri geliştirilebilir. Ayrıca, bu segmentleri birbirinden ayıran temel özellikler (örneğin yağ oranı, protein içeriği veya mikrobiyolojik yük) analiz edilerek kalite kontrol süreçleri optimize edilebilir.

Bu kapsamda yaygın olarak kullanılan teknikler arasında k-means kümeleme, en yakın komşu eşlemesi (nearest-neighbor mapping), kendini organize eden haritalar (self-organizing maps) ve tekil değer ayrıştırması (singular value decomposition) gibi algoritmalar yer alır. Sonuç olarak, denetimsiz öğrenme algoritmaları, ölçülmüş ya da bilinen bir sonuca ihtiyaç duymadan veri yapısındaki ilişkileri keşfetmeye odaklanır ve bu yönüyle tanımlama, segmentasyon ve örüntü keşfi gibi görevlerde önemli avantajlar sunar (Muhammad vd., 2021a; Shetty vd., 2022).

3.3. Yarı Denetimli Öğrenme (Semi-supervised Learning)

Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenme yöntemleri arasında yer alan bir makine öğrenmesi yaklaşımıdır. Bu yöntemlerde model eğitimi hem etiketli hem de etiketsiz verilerle gerçekleştirilir. Genellikle, az miktarda etiketli veriyle birlikte çok daha büyük bir etiketsiz veri kümesi kullanılır; çünkü etiketsiz veri elde etmek,

etiketli veriye kıyasla daha ucuz ve kolaydır. Yarı denetimli öğrenme, denetimli öğrenmeyle benzer uygulama alanlarında kullanılabilir. Sınıflandırma, regresyon ve tahmin gibi görevlerde bu yöntem başarıyla uygulanabilir. Bu teknikler, etiketli verinin sınırlı olduğu ancak büyük miktarda etiketsiz veriye erişimin mümkün olduğu senaryolarda model doğruluğunu artırmak amacıyla tercih edilmektedir (Muhammad vd., 2021).

3.4. Pekiştirmeli Öğrenme (Reinforcement Learning)

Pekiştirmeli öğrenme, modelin bir ortamla etkileşim kurarak deneyim yoluyla öğrenmesini sağlayan bir makine öğrenmesi yaklaşımıdır. Bu yöntemde algoritma, gerçekleştirdiği her eylem sonrasında aldığı ödül veya ceza ile geri bildirim alır ve bu geri bildirimler doğrultusunda stratejisini geliştirir. Gecikmeli ödüller ve deneme-yanılma temelli arama süreçleri, pekiştirmeli öğrenmenin karakteristik özellikleri arasında yer alır. Algoritma, deneme-yanılma yoluyla hangi eylemlerin en fazla ödülü sağladığını keşfetmeye çalışır. Bu bağlamda üç temel bileşen tanımlanır:

- **Ajan (agent):** Öğrenen ya da karar verici yapı
- **Çevre (environment):** Ajanın etkileşimde bulunduğu ortam,
- **Eylemler (actions):** Ajanın gerçekleştirebileceği hareketler.

Bu yapı içerisinde amaç, ajan tarafından uzun vadede en yüksek toplam ödülü sağlayacak eylemlerin belirlenmesidir. Ajan, etkili bir strateji geliştirerek hedefe daha hızlı ve verimli bir şekilde ulaşabilir. Dolayısıyla pekiştirmeli öğrenmenin temel hedefi, ortamdaki edinilen geri bildirimler aracılığıyla en iyi eylem stratejisini öğrenmektir (Panch vd., 2018; Muhammad vd., 2021).

4. Geleneksel Makine Öğrenmesi Yöntemleri ve Derin Öğrenme Yaklaşımı

Geleneksel makine öğrenmesi, küçük örneklem kümeleri üzerinde özelliklerin elle çıkarılması yoluyla yürütülen bir öğrenme yaklaşımıdır. Bu yöntem, sınırlı sayıda örnekle çalışıldığında öğrenme sonuçlarının geçerliliği ile modelin yorumlana bilirliliği arasında denge kurmayı ve öğrenme problemlerine çözüm üretmeyi amaçlar. Geleneksel yöntemlerin önemli teorik temellerinden biri istatistiktir. Bu yaklaşımlar genellikle örüntü sınıflandırması, regresyon analizi, olasılık yoğunluğu tahmini ve benzeri analiz türlerini içerir.

4.1. Algoritmalar

4.1.1. Destek Vektör Makineleri (SVM)

Destek Vektör Makineleri (SVM), beklenen çözümün optimize edilmesinde en çok bilinen ve yaygın kullanılan makine öğrenmesi tekniklerinden biridir. Vapnik tarafından sınıflandırma ve regresyon görevleri için çekirdek tabanlı bir model olarak geliştirilmiş olan SVM'ler, denetimli öğrenmeye dayalıdır ve sınıflandırma ile regresyon analizlerinde etkili bir şekilde kullanılmaktadır.

SVM'in en dikkat çeken özellikleri arasında olağanüstü genelleme yeteneği, optimal çözüm sunma kapasitesi ve yüksek ayırt edici gücü yer almaktadır. Özellikle ikili sınıflandırma problemlerinde yaygın olarak tercih edilen SVM'ler, sınıflar arasında maksimum mesafeyi sağlayacak şekilde ayırma sınırları (marjinler) çizerek sınıflandırma hatasını en aza indirir. Ayrıca SVM, yalnızca doğrusal değil, çekirdek yöntemi (kernel trick) aracılığıyla doğrusal olmayan sınıflandırmaları da yüksek boyutlu özellik uzaylarında gerçekleştirme yeteneğine sahiptir. Bu esneklik, SVM'yi karmaşık veri yapılarıyla çalışmada da güçlü kılar. Literatürdeki pek çok çalışma, SVM'lerin birçok denetimli öğrenme algoritmasına kıyasla daha yüksek doğruluk ve genel başarı sağladığını ortaya koymuştur. Teorik altyapısının sağlamlığı ve güçlü genelleme kapasitesi sayesinde, SVM günümüzde en yaygın kullanılan sınıflandırma yöntemlerinden biri hâline gelmiştir (Abdullah ve Abdulazeez, 2021; Cervantes vd., 2020).

4.1.2. Lojistik Regresyon

Lojistik regresyon, özellikle ikili sınıflandırma problemlerinde (örneğin 0 veya 1, evet veya hayır gibi) yaygın olarak kullanılan bir makine öğrenmesi ve istatistiksel modelleme yöntemidir. Bu yöntem, belirli bir olayın gerçekleşme olasılığını tahmin etmek amacıyla kullanılır ve tahmin sonuçları genellikle dichotomous yani iki kategorili olur. Uygulamada, bir bireyin hastalığa sahip olup olmadığı ya da bir müşterinin belirli bir ürünü satın alıp almayacağı gibi karar verme süreçlerinde kullanılabilir. Modelin çıktısı doğrudan bir olasılık değeri değil,

gerçekleşme olasılığı ile gerçekleşmeme olasılığı arasındaki oranı, yani literatürde olasılık oranı (odds) olarak adlandırılan değeri temsil eder. Bu oran, daha sonra bir lojistik fonksiyon aracılığıyla 0 ile 1 arasında bir olasılık değerine dönüştürülerek yorumlanır.

Lojistik regresyon, yalnızca sınıflar arasındaki sınırları belirlemekle kalmaz; aynı zamanda bir gözlemin hangi sınıfa ait olabileceğini sınıra olan uzaklığına göre değerlendiren bir yaklaşım sunar. Bu yönüyle, yalnızca kategorik bir tahmin sunmakla kalmaz, aynı zamanda her sınıfa ait olma olasılıklarını da nicel olarak ifade eder. Bu durum, lojistik regresyonu sıradan sınıflandırma algoritmalarından ayırarak, güçlü ve ayrıntılı tahminler yapabilme potansiyeline sahip kılar. Ancak bu güçlü tahminlerin veri setinin büyüklüğüne bağlı olarak uç değerlere (0 veya 1) daha hızlı yönelmesi, bazen modelin aşırı güvenli ancak hatalı tahminler yapmasına neden olabilir.

Lojistik regresyon, matematiksel olarak doğrusal enterpolasyon mantığına dayanır ve Tahmini En Küçük Kareler (Ordinary Least Squares, OLS) regresyonuna benzer şekilde, parametre tahmini amacıyla optimize edilir. Bununla birlikte, bağımlı değişkenin sürekli değil, sınırlı ve ayrık değerler alması, lojistik regresyonu OLS regresyonundan ayıran temel farktır. Uygulamalı istatistik ve makine öğrenmesi alanlarında yaygın olarak kullanılan lojistik regresyon, özellikle ayrık veri analizi, risk tahminleme ve karar destek sistemleri gibi pek çok alanda etkili bir şekilde kullanılmaktadır (Osisanwo vd., 2017).

4.1.3. En Yakın Komşu (K-Nearest Neighbours, KNN)

En Yakın Komşu (K-NN) algoritması, veri ayrıştırma süreçlerinde en temel ve etkili algoritmalarından biri olarak kabul edilmekte olup, özellikle verilerin belirsiz olduğu durumlarda öncelikli olarak tercih edilen yöntemlerden biridir. KNN algoritması, farklı örnekler arasındaki özellik mesafesini ölçerek sınıflandırma yapar. Temel mantık şudur: özellik uzayında birbirine en yakın K örneğin büyük çoğunluğu belirli bir kategoriye aitse, sınıflandırılacak örneğin de aynı kategoriye ait olduğu varsayılır. K değeri genellikle 20'den küçük bir tamsayı olarak seçilir.

KNN algoritmasında seçilen komşular, daha önce doğru şekilde sınıflandırılmış örneklerdir. Bu yöntem, sadece en yakın komşuların kategorilerine bakarak sınıflandırma kararı verir. Örnekler arasındaki mesafe, benzerlik ölçütü olarak değerlendirilir ve genellikle Öklid veya Manhattan mesafesi kullanılarak hesaplanır. Bu mesafe ölçümleri, nesneler arasındaki karşılaştırmalarda uyumsuzlukları önlemeye yardımcı olur (Abdullah ve Abdulazeez, 2021; Bansal vd., 2022; Osisanwo vd., 2017).

4.1.4. Bayesçi Ağ (Bayesian Network)

Bayesçi ağ, belirsizlik altında nedensel çıkarım yapmaya olanak tanıyan ve Bayes teorisine dayanan bir modeldir. Matematiksel olarak, bir Bayes ağı; düğümler kümesi VVV ve yönlü kenarları ifade eden bağlantılar kümesi EEE ile tanımlanan bir yönlü çevrimsiz grafik (DAG) olarak ifade edilir (Koca vd., 2023).

4.1.5. Karar Ağacı (Decision Tree)

Karar ağacı, her iç düğümün bir niteliğe göre karar verdiği, dalların bu kararın çıktısını temsil ettiği ve yaprak düğümlerin ise sınıflandırma sonucunu gösterdiği ağaç yapısında bir sınıflandırma algoritmasıdır. Karar ağaçları, veri üzerinde açık ve yorumlanabilir bir sınıflama yapısı sunar.

Karar ağaçları örnekleri öznitelik değerlerine göre sıralayarak sınıflandıran yapılardır. Bu ağaç yapısında her bir düğüm sınıflandırılması hedeflenen bir örnekteki öznitelikleri temsil ederken; her bir dal, bu düğümün alabileceği olası değerleri gösterir. Sınıflandırma işlemi, kök düğümden başlanarak, örneğin öznitelik değerlerine göre dallara ayrılmasıyla gerçekleştirilir. Karar ağacı sınıflandırıcılarında, genellikle ağacın performansını artırmak ve aşırı öğrenmeyi (overfitting) önlemek amacıyla budama işlemi uygulanır. Bu işlem sırasında bir doğrulama veri seti kullanılarak model değerlendirilir. Budama sırasında, istenilen düğümler ağaçtan kaldırılır ve bu düğümler yerine, o düğüme yönlendirilen eğitim örnekleri arasında en sık görülen sınıf atanabilir (Bansal vd., 2022; Osisanwo vd., 2017).

4.1.6. Rastgele Ormanlar (Random Forest, RF)

Random Forest, birbirinden bağımsız çok sayıda karar ağacından oluşan bir topluluk öğrenme (ensemble) yöntemidir. Yeni bir örnek sınıflandırıldığında, her bir karar ağacı bağımsız olarak karar verir. Tüm ağaçların verdiği kararlar arasında en sık tekrar eden karar, nihai sınıflandırma sonucu olarak belirlenir (Breiman, 2001).

4.2. Derin öğrenme

Derin öğrenme (deep learning), aynı zamanda derin yapıli öğrenme, hiyerarşik öğrenme veya derin makine öğrenmesi olarak da bilinir; birden fazla gizli katman içeren yapay sinir ağıları ve bunlarla ilişkili makine öğrenmesi algoritmalarını inceleyen bir alandır.

Bu derin ağılar:

- Özellik çıkarımı ve dönüşümü için çok katmanlı doğrusal olmayan işlem birimlerinden oluşan bir yapı kullanır. Her katman, bir önceki katmanın çıktısını girdi olarak alır. Algoritmalar denetimli ya da denetimsiz olabilir ve örüntü analizi (denetimsiz) ile sınıflandırma (denetimli) gibi uygulamalarda kullanılır.
- Verilerin birden fazla düzeyde özelliklerini veya temsillerini öğrenmeye dayanır. Üst düzey özellikler, alt düzey özelliklerden türetilerek hiyerarşik bir temsil oluşturur.
- Verilerin temsili öğrenmeye dayalı daha geniş bir makine öğrenmesi alanının parçasıdır.
- Farklı soyutlama seviyelerine karşılık gelen çok katmanlı temsilleri öğrenir; bu seviyeler bir kavramlar hiyerarşisi oluşturur.

Basit bir örnekte, iki nöron kümesi olabilir: biri giriş sinyali alır, diğeri çıkış sinyali üretir. Giriş katmanı bir sinyal aldığında, bunu dönüştürerek bir sonraki katmana iletir. Derin bir ağıda, giriş ile çıkış arasında çok sayıda katman vardır (her ne kadar katmanlar teknik anlamda nöronlardan oluşmasa da işlevsel açıdan bu şekilde düşünmek öğrenme mantığını anlamak için faydalı olabilir.). Bu yapı, çok sayıda işlem katmanı kullanılarak hem doğrusal hem doğrusal olmayan dönüşümlerin gerçekleştirilmesini sağlar.

Derin öğrenme, verilerin temsillerini öğrenmeye dayalı makine öğrenmesi yöntemlerinin daha geniş bir ailesinin parçasıdır. Örneğin bir gözlem (örneğin bir görüntü), her pikselin yoğunluk değerlerinden oluşan bir vektör ya da kenarlar, belirli şekillerdeki bölgeler gibi daha soyut bir biçimde temsil edilebilir. Bazı temsiller, öğrenme görevini (örneğin yüz tanıma veya yüz ifadesi tanıma gibi) basitleştirme açısından daha uygundur.

Derin öğrenmenin en büyük vaatlerinden biri, insan eliyle tasarlanan (handcrafted) özelliklerin yerini verimli denetimsiz veya yarı denetimli özellik öğrenme algoritmalarına ve hiyerarşik özellik çıkarımı süreçlerine bırakmasıdır. Bu alandaki araştırmalar, daha iyi veri temsilleri oluşturmayı ve bu temsilleri büyük ölçekli etiketsiz verilerden öğrenebilecek modeller geliştirmeyi amaçlamaktadır. Bazı veri temsilleri, nörobilimdeki ilerlemelerden esinlenerek, sinir sistemindeki bilgi işleme ve iletişim kalıplarının yorumlanmasına dayanır. Örneğin, nöral kodlama çeşitli uyaranlar ile beyindeki ilgili nöron tepkileri arasındaki ilişkiyi tanımlamaya çalışır.

Her ne kadar derin öğrenme bazen bir moda terimi ya da sinir ağlarının yeniden markalanmış hali olarak görülse de, derin sinir ağları; özellikle nesne tanıma gibi görevlerde diğerk makine öğrenmesi algoritmalarını geride bırakma yeteneğini açıkça ortaya koymuştur. Yapay zekâ, makine öğrenmesi ve derin öğrenme temelde birer makine algısıdır.(Chollet, 2017; LeCun vd., 2015; Ongsulee, 2017).

Çeşitli derin öğrenme mimarileri vardır. Bunlar aşağıda sunulmuştur.

4.2.1. Yapay Sinir Ağları (ANN)

Yapay Sinir Ağları (Artificial Neural Networks – ANN), biyolojik sinir sistemlerinden esinlenerek geliştirilmiş, nispeten basit yapıya sahip derin öğrenme modelleridir. Tipik bir ANN yapısı üç katmandan oluşur: giriş katmanı, gizli katman(lar) ve çıkış katmanı. Giriş katmanı dış dünyadan gelen verileri alır (örneğin, görüntülerin piksel yoğunlukları gibi), gizli katmanlar bu verileri işleyerek öğrenme sürecini yürütür ve çıkış katmanı, sınıflandırma veya regresyon gibi görevlerde sonuç üretir.

ANN'ler, insan beyindeki nöronların bilgi işleme biçimini taklit eder. Biyolojik sistemlerde olduğu gibi, bu ağlarda da her bir “nöron” girişleri alır, ağırlıklı toplamalarını hesaplar ve belirli bir eşik değerine göre çıktılar üretir. Gerçek sinir sistemlerinde nöronlar, vücut sensörlerinden gelen sinyalleri alarak, dendrit ve aksonlar

aracılığıyla diğer nöronlara iletir. Beyinde yaklaşık 10^{11} nöronun paralel çalıştığı tahmin edilmektedir ve bu yapı, bilgiyi hem işleyen hem de depolayan geniş ölçekli dağıtık bir sistem olarak görev yapmaktadır. Bu benzerlikler doğrultusunda, ANN'ler çok katmanlı yapıları sayesinde karmaşık görevleri kısa sürede yüksek doğrulukla gerçekleştirebilecek kapasiteye sahiptir (Bansal vd., 2022; Montesinos López vd., 2022).

4.2.2. Konvolüsyonel Sinir Ağları (CNN – Convolutional Neural Networks)

Konvolüsyonel Sinir Ağları (CNN), özellikle görüntü işleme alanında yaygın olarak kullanılan derin öğrenme modelleridir. CNN mimarisi; konvolüsyonel katman, havuzlama (pooling) katmanı, tam bağlantılı katman ve çıkış katmanından oluşur. Konvolüsyon işlemi, giriş görüntüsü ile filtre ağırlıkları arasındaki etkileşimi hesaplayarak görüntüdeki kenar, doku ve şekil gibi özellikleri çıkarır. İlk katmanlar basit görsel öğeleri algılamak, derin katmanlar daha karmaşık yapıları tanıır. Son aşamada, tam bağlantılı katman sayesinde görüntünün ait olduğu kategori olasılıkla tahmin edilir. CNN'ler, görüntü tanıma, konuşma analizi ve medikal teşhis gibi birçok uygulamada yüksek doğrulukla çalışmaktadır (IBM, 2025a).

4.2.3. Tekrarlayan Sinir Ağları (RNN – Recurrent Neural Networks)

Tekrarlayan Sinir Ağları (RNN), bilgiyi işleme biçimi açısından klasik sinir ağlarından farklılık gösterir. Standart sinir ağları verileri yalnızca girişten çıkışa doğru aktarırken, RNN'ler her adımda çıktıyı yeniden ağı geri besleyerek geçmiş bilgileri de hesaba katar. Bu sayede, önceki adımlarda öğrenilen bilgiler bir sonraki adıma taşınır ve modelin bağlamı anlaması sağlanır. Örneğin, bir cümlede gelecek kelimeyi tahmin ederken yalnızca mevcut kelime değil, önceki kelimeler de dikkate alınmalıdır. RNN'ler bu tür sıralı yapıları "hatırlayarak" daha anlamlı ve doğru tahminler yapabilir. Bu özellikleri sayesinde, RNN'ler dil modelleme, konuşma tanıma, zaman serisi analizi, duygu analizi, doğal dil işleme (NLP), dil çevirisi ve görsel altyazı üretimi gibi çok sayıda sıralı veri içeren problemde başarıyla kullanılmaktadır.

Ayrıca RNN'ler, geçmişe dayalı zaman bağımlı verilerle çalışabildiği için yalnızca dil verisiyle sınırlı kalmaz; örneğin, geçmiş sel, gelgit ve meteorolojik verilere dayanarak gelecekteki sel seviyelerini tahmin etmek gibi uygulamalarda da etkili bir şekilde kullanılabilir. RNN'lerin bu gibi alanlarda tercih edilme nedeni, sıralı verilerdeki örüntüleri öğrenerek bağlamsal ilişkileri güçlü bir şekilde modelleyebilmesidir (Geeksforgeeks, 2025a; IBM, 2025b). Her ne kadar gıda biliminde RNN'lerin kullanımı henüz yaygınlaşmamış olsa da potansiyel uygulama alanları mevcuttur. Örneğin, sıcaklık, nem ve mikrobiyal veriler gibi zaman serisi formatındaki verilerden yararlanarak raf ömrü tahmini, ürün bozulma sürecinin modellenmesi, ya da gıda üretim hattındaki kalite değişimlerinin izlenmesi mümkün olabilir. Aynı şekilde, tüketici yorumları ve sosyal medya içerikleri üzerinden duygu eğilimlerinin zamanla nasıl değiştiğini analiz etmek de gelecekte RNN modelleriyle gerçekleştirilebilecek olası senaryolardandır.

4.2.4. Uzun Kısa Süreli Bellek (LSTM – Long Short-Term Memory)

LSTM ağı, Hochreiter ve Schmidhuber tarafından geliştirilen, klasik Tekrarlayan Sinir Ağları'nın (RNN) geliştirilmiş bir versiyonudur. LSTM'ler, sıralı verilerdeki uzun vadeli bağımlılıkları yakalayabilme yetenekleri sayesinde dil çevirisi, konuşma tanıma ve zaman serisi tahmini gibi uygulamalar için son derece uygundur. Geleneksel RNN'ler yalnızca tek bir gizli durumu zaman boyunca iletirerek çalışırken, LSTM'ler bunun ötesine geçerek uzun süreli bilgi taşıyabilen bir bellek hücresi yapısı sunar. Bu yapı, bilgilerin uzun zaman adımları boyunca kaybolmadan taşınmasını sağlar ve böylece gradyan kaybı gibi sorunların önüne geçer.

LSTM'nin temel bileşenleri olan unutma kapısı, giriş kapısı ve çıkış kapısı, hangi bilginin saklanacağına, güncelleneceğine veya aktarılacağına karar vererek öğrenme sürecini kontrol eder. Bu kapı mekanizmaları sayesinde LSTM'ler hem kısa vadeli hem de uzun vadeli bilgileri etkili şekilde işleyebilir (Geeksforgeeks, 2025b; Lindemann vd., 2021).

5. Makine Öğrenmesinin Teknik Uygulama Alanları ve Gıda Bilimindeki Yansımaları

Makine öğrenmesi, veri odaklı çözüm üretme kabiliyeti sayesinde çok sayıda bilimsel ve endüstriyel alanda kullanılmakta olup, gıda bilimi bu alanlardan biri olarak giderek daha fazla sayıda çalışmada yer almaktadır. Gıda üretim süreçlerinin izlenmesi, kalite kontrolü, ürün geliştirme, raf ömrü modelleme, duyu analizi ve tüketici davranışlarının incelenmesi gibi konular, makine öğrenmesinin uygulanabilirliğine açık yapıdadır.

Makine öğrenmesi, farklı veri türlerinin işlenmesini mümkün kılan esnek yapısıyla, birçok teknik uygulama alanında etkili bir biçimde kullanılmaktadır. Özellikle doğal dil işleme (Natural Language Processing), görüntü işleme ve bilgisayarla görü (Computer Vision), öneri sistemleri, anomali tespiti, zaman serisi modelleme ve pekiştirmeli öğrenme gibi alt alanlar, makine öğrenmesinin çeşitli veri kaynaklarını analiz etme ve yorumlama gücünü yansıtmaktadır. Bu alanlar, metinsel verilerden anlam çıkarımı, görsel örüntülerin tanınması, kişiselleştirilmiş içerik önerileri, norm dışı davranışların saptanması ve zamana bağlı değişimlerin öngörülmesi gibi çok sayıda görevi kapsamaktadır. Her biri, çok boyutlu veri yapılarıyla çalışabilme ve öngörülmesi kabiliyeti sayesinde, sadece bilişim sistemleriyle sınırlı kalmayıp; sağlık, finans, üretim, enerji ve gıda gibi farklı sektörlerde de disiplinler arası çözümler üretme potansiyeline sahiptir.

5.1. Doğal Dil İşleme (Natural Language Processing – NLP)

Dijitalleşme, araştırmacılara çağdaş olguları incelemek için zengin metin verilerini toplama konusunda benzeri görülmemiş fırsatlar sunmaktadır (Kına vd., 2024; Koca, 2024b). İnsan dilini otomatik olarak analiz etmeyi ve anlamayı amaçlayan bilgisayar destekli analitik bir teknik olan NLP, araştırmacıların külfetli hesaplama işlerinden kaçınırken metinsel veri kümelerinde bulunan faydalı içgörülerini kolayca çıkarmalarına olanak tanır (Kang vd., 2020). Metin veya sesi girdi verisi olarak kullanan NLP, sözdizimi (kelime ve cümlelerin bağlamsal düzenlemesi) ve anlambilim (anlam) dahil olmak üzere dilin çeşitli yönlerini ele alır ve insan dilini işlemek ve çıktı sağlamak için kural tabanlı yöntemler, istatistiksel, makine öğrenimi ve derin öğrenme modelleri gibi çeşitli tekniklerin bir kombinasyonunu kullanır. NLP, günlük hayatta halihazırda kullanılan geniş bir uygulama yelpazesine sahiptir (örneğin, sesle çalışan sistemler, konuşmadan metne dikte yazılımı veya kullanıcı sorularına otomatik yanıtlar üreten müşteri hizmetleri sohbet robotları) (Lareyre vd., 2023).

Temel NLP modelinin geliştirilme süreci, ardışık ve bütüncül bir yaklaşımla yapılandırılmış üç ana aşamadan oluşmaktadır. İlk olarak, veri temizleme ve tokenizasyon süreci gerçekleştirilir. Bu aşamada metinsel veriler; büyük/küçük harf dönüşümü, durak kelimelerin çıkarılması ve kelimelerin kök ya da gövde formlarına indirgenmesi yoluyla standartlaştırılır. Bu, daha tutarlı ve anlamlı bir analiz zemini oluşturmak amacıyla metnin yapısal sadeleştirilmesini sağlar. İkinci aşama olan vektörleştirme (kelime gömme), metinsel verilerin sayısal ifadelerle dönüştürülmesini kapsamaktadır. Zira bilgisayar sistemleri metni doğrudan işleyememekte; dolayısıyla her bir kelimenin veya dizgenin matematiksel vektörlerle temsil edilmesi gerekmektedir (Kına ve Biçek, 2024; Kına ve Özdağ, 2021). Son olarak, model eğitimi aşamasında genellikle derin öğrenme temelli yöntemler, özellikle de sıralı veri işleme konusunda yetkin olan Tekrarlayan Sinir Ağları (RNN) ve Uzun Kısa Süreli Bellek (LSTM) ağları kullanılmaktadır. Bu modeller, dilin doğası gereği taşıdığı zamansal ve bağlamsal ilişkileri öğrenerek daha isabetli çıktılar üretmeyi amaçlamaktadır. Bu yapı, doğal dilin istatistiksel ve anlamsal yönlerinin sistematik olarak modellenmesini mümkün kılar (Yang ve Huang, 2023). Bu yapay sinir ağı temelli modellerin gelişimiyle birlikte, metinlerdeki anlamsal örüntülerin ve duygusal eğilimlerin daha hassas biçimde analiz edilebilmesi mümkün hale gelmiştir. Bu doğrultuda, duygu analizi (sentiment analysis), doğal dil işleme uygulamaları arasında öne çıkan bir alt alan olarak dikkat çekmektedir.

Duygu analizi, bireylerin metinler aracılığıyla ifade ettikleri duygusal eğilimlerin otomatik olarak sınıflandırılmasını ve değerlendirilmesini amaçlayan bir doğal dil işleme yöntemidir. Bu yaklaşım, metinlerdeki duygusal içeriği pozitif, negatif veya nötr şeklinde kategorize ederek, metni oluşturan kişinin tutumunu, memnuniyet düzeyini ya da eleştirel yaklaşımını belirlemeye çalışır. Duygu analizi, genellikle sosyal medya paylaşımları, ürün yorumları, kullanıcı değerlendirmeleri, anket yanıtları gibi serbest metinlerden elde edilen veriler üzerinde uygulanmakta ve makine öğrenmesi ya da derin öğrenme tabanlı sınıflandırma algoritmaları kullanılarak gerçekleştirilmektedir. Bu yöntem, özellikle pazarlama, kamuoyu araştırmaları, marka yönetimi, müşteri memnuniyeti değerlendirmesi ve politika analizleri gibi alanlarda değerli içgörüler sağlamaktadır (Adak vd., 2022; Al-Tameemi vd., 2024; Birjali vd., 2021; Kına ve Biçek, 2024; Kına ve Biçek, 2023; Kına ve Özdağ, 2021). Gıda bilimi bağlamında ise tüketici yorumlarının analiz edilmesi yoluyla ürün beğenisinin ölçülmesi, yeni ürün geliştirme süreçlerinde yönlendirici bilgi elde edilmesi ve pazar stratejilerinin şekillendirilmesi gibi çok çeşitli uygulama alanlarına sahiptir.

5.1.1. Gıda Biliminde Duygu Analizi Uygulamaları

Son yıllarda duygu analizi yöntemlerinin gıda bilimi ile entegrasyonu giderek daha fazla önem kazanmaktadır. Özellikle tüketici geri bildirimlerinin, çevrimiçi ürün yorumlarının ve pazarlama içeriklerinin analiz edilmesi yoluyla; ürün algısı, tüketici memnuniyeti ve pazar tepkisi gibi unsurlar daha nesnel biçimde değerlendirilebilmektedir. Örneğin, bir gıda ürününe ilişkin sosyal medya yorumlarının duygu analizine tabi tutulması, ürünün tat, ambalaj, içerik veya sürdürülebilirlik gibi yönlerden nasıl algılandığını ortaya koymakta ve ürün geliştirme, kalite yönetimi ile tüketici eğilimlerinin öngörülmesi gibi süreçlere stratejik katkılar sağlamaktadır.

Hu vd., (2023) tarafından gerçekleştirilen çalışmada, NLP teknikleri kullanılarak gıda ürünlerine ait etiket bilgilerinden otomatik biçimde gıda kategorisi ve beslenme kalitesi skoru tahmin edilmiştir. Etiketlerdeki serbest metinler, önceden eğitilmiş Sentence-BERT modeli ile vektörleştirilmiş ve bu temsiller, çeşitli denetimli öğrenme algoritmalarıyla analiz edilmiştir. Elde edilen bulgular, NLP tabanlı yaklaşımların geleneksel yöntemlere kıyasla sınıflandırma ve regresyon görevlerinde daha yüksek doğruluk sağladığını göstermektedir. Bu sonuçlar, etiket temelli verilerin işlenmesinde NLP'nin güçlü bir araç olarak kullanılabileceğini ortaya koymaktadır.

Mostafa, (2019) sosyal medyada helal gıdaya ilişkin kullanıcı tutumlarını incelemiştir. Rastgele seçilen 3.919 tweet, 6.800 sıfat içeren uzman tanımlı bir sözlük kullanılarak duygu analizine tabi tutulmuştur. Tanımlayıcı analizler, genel olarak olumlu bir tutumun baskın olduğunu göstermiştir. Ayrıca, Partitioning Around Medoids (PAM) algoritması ile yapılan kümeleme analizinde, tüketicilerin dindarlık düzeyi, bireysel kimlik algısı, hayvan refahı ve gıda otantikliği gibi unsurlar temelinde dört farklı alt gruba ayrılabilirdiği saptanmıştır. Bu durum, helal gıda tüketicilerinin heterojen bir yapı gösterdiğini ortaya koymuştur.

Asani vd., (2021) kullanıcı yorumlarından yemek tercihlerini çıkararak bireyselleştirilmiş restoran önerileri sunan bağlam farkındalıklı bir tavsiye sistemi önermiştir. Sistem, kullanıcı yorumlarındaki isim öbeklerini WordNet ontolojisi aracılığıyla anlamlı gıda terimlerine dönüştürmekte, ardından bu terimleri semantik benzerliklerine göre kümelendirmekte ve her küme için duygu analizi gerçekleştirmektedir. Bu yolla, kullanıcının örtük tercihleri tespit edilmekte ve bu tercihler, yakın çevredeki restoran menüleriyle eşleştirilerek öneri listesi oluşturulmaktadır. Sistem, TripAdvisor verileri kullanılarak test edilmiş; %92.8 oranında kesinlikle yüksek doğrulukta öneriler sunduğu ve benzer çalışmalara kıyasla üstün performans sergilediği belirlenmiştir.

Rikters ve Kåle, (2023) Letonya'da et tüketimi ve alternatif protein kaynaklarına yönelik toplumsal tutumları sosyal medya verileri aracılığıyla analiz etmiştir. Letonca yazılmış tweet'ler, olumlu, olumsuz ve nötr kategorilere ayrılarak duygu analizine tabi tutulmuştur. Sonuçlar, et tüketimine yönelik olumlu ifadelerin zamanla azaldığını; buna karşılık nötr ve olumsuz ifadelerin arttığını göstermiştir. Ayrıca "lezzetli" ifadesinin "sağlıklı" ifadesine kıyasla daha sık geçtiği belirlenmiş; bu durum tat faktörünün, sağlık kaygısından daha belirleyici olduğunu ortaya koymuştur. Araştırmacılar, sosyal medya verilerinin gıda tüketimi ve sürdürülebilirlik gibi alanlarda toplumsal eğilimleri anlamada etkili bir araç olduğunu vurgulamıştır.

Chen ve Zhang, (2022) ise Çin'deki tüketicilerin alternatif et ürünlerine yönelik algılarını incelemiş ve sosyal medya verilerini doğal dil işleme teknikleriyle analiz etmiştir. Transfer öğrenme yaklaşımı kullanılarak, büyük veri setlerinde eğitilmiş modellerin sınırlı etiketli veriyle yüksek doğrulukla sınıflandırma yapabileceği gösterilmiştir. Analiz, tüketicilerin alternatif et ürünlerine yönelik olumlu, olumsuz ve nötr tutumlar sergilediğini ortaya koymuş; ayrıca sağlık, çevre, etik, tat ve fiyat gibi temaların tüketici algısını şekillendirmede önemli rol oynadığı belirlenmiştir. Araştırma, transfer öğrenme tabanlı yaklaşımların sosyal medya verileri üzerinden kamuoyu analizinde etkili şekilde kullanılabileceğini ve bu bağlamda gıda sektörü ile politika yapıcılara değerli çıkarımlar sunduğunu göstermiştir.

5.2. Görüntü İşleme ve Bilgisayarla Görü (Computer Vision)

Bilgisayarla görü, görsel verilerden anlamlı desenler çıkararak sınıflandırma ve tahmin işlemleri yapmaya imkân tanır. Gıda biliminde özellikle ürün yüzeyindeki kusurların tespiti, olgunluk düzeyinin belirlenmesi, renk değişimlerinin izlenmesi ve mikrobiyolojik kolonilerin otomatik sayımı gibi uygulamalarda başarıyla kullanılmaktadır. Örneğin, meyve ve sebzelerin dış görünüşüne göre kalite sınıflandırması yapılması, ekmek kabuğu renginden pişme derecesinin tahmini, et ürünlerinde dış yüzeyde oluşan renk ve leke değişimlerinin izlenmesi gibi görevler bilgisayarla görü teknikleri ile otomatik hale getirilebilir. Görüntü işleme, dijital

görüntülerin bilgisayarlar aracılığıyla analiz edilmesini, iyileştirilmesini ve anlamlı bilgiler elde edilmesini sağlayan bir teknoloji alanıdır. Bu süreç, görüntülerin sayısal olarak işlenmesini ve yorumlanmasını kapsayan bilgisayarla görme ve yapay zekâ teknikleriyle desteklenebilir.

Bilgisayarla görme, donanım, yazılım ve görüntüleme tekniklerini bir araya getiren bir bilgisayar bilimi uygulamasıdır. Bu alan genellikle iki temel aşamadan oluşur: görüntü edinme ve görüntü işleme.

5.2.1. Görüntü Edinme

Görüntü edinme, sensörlerden gelen sayısal verilerin elektronik sinyaller aracılığıyla alınmasıdır. Bu işlemde en yaygın kullanılan kamera türleri alan taramalı ve çizgi taramalı kameralardır. Alan taramalı kameralar her pozlamada tüm görüntüyü üretirken, çizgi taramalı kameralar her seferinde yalnızca bir satır pikseli tarar. Görüntü elde etme sırasında aydınlatma koşulları, ışığın yoğunluğu ve arka plan gibi etkenler modelin doğruluğunu etkileyebilir. Uygun aydınlatma, sistemin genel performansını ve güvenilirliğini artırır.

5.2.2. Görüntü İşleme

Görüntü işleme, mevcut görüntülerden yeni görüntüler üretmek amacıyla kullanılan bir tekniktir ve esas olarak ilgi bölgesinin tanımlanmasını veya karakterizasyonunun iyileştirilmesini hedefler. Bu süreç, içerik ya da anlam yorumlaması içermeyen dijital sinyal işleme olarak değerlendirilebilir. Görüntü işleme, görüntünün alınmasının ardından uygulanan işlemleri kapsar. Bu aşamada görüntüdeki gereksiz gürültü azaltılır, kalite artırılır ve modelleme için gerekli bilgiler çıkarılır. Düşük düzey işlemler, gri ton ayarlamaları, keskinlik artırma ve kenar tespiti gibi ön işlemleri içerir. Orta düzey işlemler, görüntülerin sınıflandırılması, segmentasyonu ve ilgi bölgelerinin belirlenmesiyle ilgilidir. Yüksek düzey işlemlerde ise sınıflandırıcılar veya yapay sinir ağları ile anlamlı bölgeler tespit edilir. Kenar tespiti için yaygın olarak SIFT, Harris ve Canny gibi yöntemler kullanılır (Sood ve Singh, 2021).

Makine görüşü sistemleri ve görüntü işleme algoritmalarındaki hızlı gelişmelerin yanı sıra, gıda türlerinin ve işleme yöntemlerinin çeşitlenmesi bu alanda yayımlanan literatürün önemli ölçüde artmasına neden olmuştur (Zhu vd., 2021).

5.2.2.1. Görüntü İşleme Uygulamaları

Shen vd., (2020) tarafından gerçekleştirilen çalışmada, görsel veriye dayalı olarak gıda tanıma ve buna bağlı besin değeri tahmini gerçekleştirebilen çok modlu bir sistem geliştirilmiştir. Sistem, kullanıcıların yüklediği yiyecek görüntülerini derin öğrenme algoritmaları aracılığıyla analiz etmekte ve ilgili makro-mikro besin bileşenleri ile enerji içeriklerini tahmin etmektedir. Modelleme sürecinde, önceden eğitilmiş konvolüsyonel sinir ağları (CNN) transfer öğrenme yöntemiyle yeniden yapılandırılmış ve görüntü sınıflandırması gerçekleştirilmiştir.

Görüntü verisine ek olarak, internetten elde edilen metin tabanlı besin içerikleri Word2Vec gibi sözcük gömme yöntemleriyle işlenerek, besin maddeleriyle ilişkili semantik temsiller oluşturulmuştur. Bu çok modlu yapı sayesinde, sistem yalnızca görsel analizle sınırlı kalmayıp, aynı zamanda içerik bazlı besin tahmini görevlerinde de yüksek doğruluk sağlamıştır. Uygulama, istemci-sunucu mimarisi temelinde çalışmakta; istemci tarafından gönderilen görüntüler sunucu tarafında işlenerek, kullanıcıya ilgili besin değerlerini sunmaktadır. Elde edilen sonuçlar, bu tür sistemlerin diyet takibi, kalori kontrolü ve sağlıklı beslenme alışkanlıklarının desteklenmesi açısından etkili ve uygulanabilir bir çözüm sunduğunu ortaya koymaktadır.

Mishra vd., (2022) ise, gıda alerjisi riski taşıyan bireylerin güvenliğini artırmak amacıyla derin öğrenme tabanlı bilgisayarlı görü yöntemlerine dayalı bir sistem geliştirmiştir. Çalışmada, 30 yaygın alerjen sınıfını içeren ve 6.000'den fazla etiketli görüntüden oluşan Allergen30 adlı özel bir veri kümesi oluşturulmuştur. Bu veri seti üzerinde YOLOv5 ve YOLOR gibi nesne tanıma algoritmaları uygulanmış ve her iki model de alerjen içeren gıdaların görüntü üzerinden yüksek doğrulukla tespit edilmesini sağlamıştır. Elde edilen bulgular, önerilen sistemin gıda güvenliği uygulamaları ve etiket denetimi gibi süreçlerde etkili bir karar destek aracı olarak kullanılabileceğini göstermektedir.

5.3. IoT ve Sensör Verilerine Dayalı Gıda İzleme sistemleri

Nesnelerin İnterneti (IoT), fiziksel nesnelerin sensörler ve ağ bağlantıları aracılığıyla veri toplamasını ve ilemesini sağlayan bir teknolojidir. Gıda biliminde IoT, üretimden tüketime kadar geçen süreçte gıdanın sıcaklık, nem ve gaz konsantrasyonu gibi çevresel koşullarının gerçek zamanlı izlenmesinde kullanılır. Bu sayede gıdaların bozulma riski erken tespit edilebilir, kalite kontrol süreçleri otomatikleştirilebilir ve gıda israfı azaltılabilir. IoT sistemleri, makine öğrenmesiyle birlikte kullanıldığında bozulma tahmini gibi öngörülse uygulamalar için güçlü bir altyapı sunar.

Tutul vd., (2023) tarafından gerçekleştirilen çalışmada, gıda ürünlerinin tazelik durumunu gerçek zamanlı olarak izlemeye yönelik bir sistem geliştirilmiştir. Bu sistemde, Nesnelerin İnterneti (IoT) sensörlerinden elde edilen çevresel veriler (örneğin sıcaklık, nem ve gaz konsantrasyonu) makine öğrenmesi algoritmalarıyla entegre edilmiştir. Sensörler aracılığıyla toplanan veriler, geçmiş örüntülere dayalı olarak eğitilmiş modellerle analiz edilerek gıdanın bozulma eğilimi tahmin edilmiştir. Bu sayede, hem üretim hem de tüketim süreçlerinde gıda israfının önlenmesi ve kalite kontrol uygulamalarının iyileştirilmesi hedeflenmiştir. Geliştirilen sistem, web tabanlı bir gösterge paneli ve mobil uygulama desteğiyle kullanıcıların uzaktan izleme yapabilmesine imkân tanımaktadır.

Nerker vd., (2023) tarafından yapılan çalışmada da gıda güvenliğini artırmaya yönelik olarak IoT ve makine öğrenmesi tekniklerinin entegrasyonu ele alınmıştır. Yüksek çözünürlüklü kameralar ile elde edilen gıda görüntüleri, IoT cihazları aracılığıyla bulut sistemlerine aktarılmıştır. Bu görüntüler üzerinde ilk olarak K-means kümeleme algoritması kullanılarak segmentasyon işlemi uygulanmış, ardından Ana Bileşen Analizi (PCA) ile öznelik çıkarımı gerçekleştirilmiştir. Elde edilen öznelikler, K-en Yakın Komşu (KNN) ve Naive Bayes sınıflandırıcıları ile analiz edilerek gıdanın tazelik durumu belirlenmiştir.

Hebbar, (2020) gıda ürünlerinin tazelik durumunu gerçek zamanlı olarak izleyip sınıflandırabilen bir sistem geliştirmiştir. Bu kapsamda, sıcaklık, nem ve gaz salınımı gibi çevresel parametreleri ölçebilen IoT tabanlı sensörler kullanılmış; bu sensörlerden elde edilen veriler çeşitli makine öğrenmesi algoritmalarına aktarılmıştır. Çalışmada, Karar Ağaçları, Lojistik Regresyon, Destek Vektör Makineleri (SVM) ve Yapay Sinir Ağları (ANN) gibi farklı sınıflandırma modelleri uygulanmış ve her bir modelin performansı karşılaştırılmıştır. Toplanan verilerle eğitilen modeller, gıda ürünlerinin bozulma eğilimlerini analiz ederek tazelik sınıflandırması gerçekleştirmiş ve kalan raf ömrünü tahmin etmeye çalışmıştır. En yüksek doğruluk oranı (%94) yapay sinir ağı modeli ile elde edilmiştir. Bununla birlikte, SVM modeli özellikle bozulmaya yakın ürünlerin tespitinde yüksek hassasiyet göstermiştir. Geliştirilen sistemin, gerçek zamanlı uyarı mekanizmaları sayesinde gıda israfını azaltmada etkili olduğu ve manuel kontrol ihtiyacını azaltarak veri temelli karar destek sistemi sunduğu belirtilmiştir. Elde edilen bulgular, IoT ve makine öğrenmesi temelli çözümlerin gıda güvenliği ve kalite kontrol süreçlerinde etkin bir şekilde kullanılabileceğini ortaya koymaktadır.

Benzer şekilde Alfian vd., (2020) bozulabilir gıda ürünlerinin tedarik zincirinde izlenebilirliğini artırmak amacıyla RFID teknolojisine IoT sensörleri ve makine öğrenmesi algoritmalarını entegre etmiştir. Bu sistemde, RFID etiketlerinin yönünün doğru bir şekilde sınıflandırılabilmesi için SVM, Karar Ağaçları ve Yapay Sinir Ağları gibi algoritmalar kullanılmıştır. Analizler sonucunda en yüksek doğruluk oranının ANN modeli ile elde edildiği rapor edilmiştir. Geliştirilen sistem, ürünlerin hareketlerini ve konumlarını otomatik olarak izleyerek manuel kontrol ihtiyacını azaltmış; böylece tedarik zinciri boyunca izlenebilirlik ve operasyonel verimlilik önemli ölçüde artırılmıştır. Çalışma, RFID temelli sistemlerin makine öğrenmesi ile desteklenmesi sayesinde, gıda ürünlerinin gerçek zamanlı takibi ve durum değerlendirmesinin daha güvenilir ve otomatik bir şekilde gerçekleştirilebileceğini göstermektedir.

Sonuç

YZ gıda biliminde veri yoğun süreçlerin yönetilmesini kolaylaştıran, karmaşık ilişkileri ortaya koyabilen ve öngörüye dayalı karar destek sistemleri geliştirilmesine olanak tanıyan güçlü bir araç olarak öne çıkmaktadır. Günümüzde kalite kontrol, raf ömrü tahmini, bozulma tespiti, duysal analiz, tüketici algısı değerlendirmesi ve izlenebilirlik gibi birçok alanda YZ temelli uygulamalar geliştirilmeye başlanmıştır. Görüntü işleme, doğal dil işleme ve IoT verileriyle desteklenen sistemler sayesinde, gıda ürünlerinin fiziksel ve kimyasal özellikleri yüksek doğrulukla analiz edilebilmekte; kullanıcı yorumlarından anlam çıkarımı yapılarak tüketici merkezli ürün geliştirme süreçleri iyileştirilebilmektedir.

Yapay zekânın gıda bilimindeki potansiyel uygulamaları, sadece mevcut süreçlerin dijitalleşmesiyle sınırlı kalmamakta; aynı zamanda kişiselleştirilmiş beslenme, akıllı ambalaj sistemleri, sürdürülebilir üretim planlaması

ve erken uyarı mekanizmalarının geliştirilmesi gibi yenilikçi çözümleri de kapsamaktadır. Ancak bu teknolojilerin etkin ve yaygın biçimde uygulanabilmesi için yüksek kaliteli veri setlerine erişim, model şeffaflığı, etik ilkelerin gözetilmesi ve disiplinlerarası iş birliklerinin artırılması gerekmektedir.

Sonuç olarak, yapay zekâ; geleneksel analiz yöntemlerinin sınırlarını aşarak, gıda bilimi ve teknolojisinde daha esnek, sürdürülebilir ve tüketici odaklı bir dönüşümün temelini oluşturmaktadır. Bu dönüşümün gelecekte gıda güvenliği, kaynak verimliliği ve sağlık odaklı ürün geliştirme gibi alanlarda stratejik katkılar sunması beklenmektedir.

Kaynaklar

1. Abdullah, D. M., & Abdulazeez, A. M. (2021). Machine learning applications based on SVM classification a review. *Qubahan Academic Journal*, 1(2), 81-90.
2. Adak, A., Pradhan, B., & Shukla, N. (2022). Sentiment analysis of customer reviews of food delivery services using deep learning and explainable artificial intelligence: Systematic review. *Foods*, 11(10), 1500.
3. Aich, S., Al-Absi, A. A., Hui, K. L., Lee, J. T., & Sain, M. (2018). A classification approach with different feature sets to predict the quality of different types of wine using machine learning techniques. *2018 20th International conference on advanced communication technology (ICACT)*, 139-143.
4. Alav, A., Kutlu, N., Kına, E., & Meral, R. (2024). A novel green tea extract-loaded nanofiber coating for kiwi fruit: Improved microbial stability and nutritional quality. *Food Bioscience*, 62, 105043. <https://doi.org/10.1016/j.fbio.2024.105043>
5. Alfian, G., Syafrudin, M., Farooq, U., Ma'arif, M. R., Syaekhoni, M. A., Fitriyani, N. L., Lee, J., & Rhee, J. (2020). Improving efficiency of RFID-based traceability system for perishable food by utilizing IoT sensors and machine learning model. *Food Control*, 110, 107016.
6. Al-Tameemi, I. K. S., Feizi-Derakhshi, M.-R., Pashazadeh, S., & Asadpour, M. (2024). A comprehensive review of visual-textual sentiment analysis from social media networks. *Journal of Computational Social Science*, 1-72.
7. Asani, E., Vahdat-Nejad, H., & Sadri, J. (2021). Restaurant recommender system based on sentiment analysis. *Machine Learning with Applications*, 6, 100114.
8. Asnicar, F., Thomas, A. M., Passerini, A., Waldron, L., & Segata, N. (2024). Machine learning for microbiologists. *Nature Reviews Microbiology*, 22(4), 191-205.
9. Avcı, İ., & Koca, M. (2024). Intelligent Transportation System Technologies, Challenges and Security. *Applied Sciences*, 14(11), 4646.
10. AVCI, İ., KOCA, M., & ATASOY, M. (2021). Windows Tabanlı Uygulamalarda SQL Enjeksiyon Siber Saldırı Senaryosu ve Güvenlik Önlemleri. *Avrupa Bilim ve Teknoloji Dergisi*, 28, 213-219. <https://doi.org/10.31590/ejosat.995697>
11. Ayata, F., Çavuş, H., İnan, M., Seyyarer, E., Biçek, E., & Kına, E. (2020). Dostroajan: Facial recognition based system input control agent. *AJIT-e: Academic Journal of Information Technology*, 11(40), 82-96.
12. Bansal, M., Goyal, A., & Choudhary, A. (2022). A comparative analysis of K-nearest neighbor, genetic, support vector machine, decision tree, and long short term memory algorithms in machine learning. *Decision Analytics Journal*, 3, 100071.
13. Birjali, M., Kasri, M., & Beni-Hssane, A. (2021). A comprehensive survey on sentiment analysis: Approaches, challenges and trends. *Knowledge-Based Systems*, 226, 107134.
14. Breiman, L. (2001). Random forests. *Machine learning*, 45, 5-32.
15. Cervantes, J., Garcia-Lamont, F., Rodríguez-Mazahua, L., & Lopez, A. (2020). A comprehensive survey on support vector machine classification: Applications, challenges and trends. *Neurocomputing*, 408, 189-215.
16. Ceylan, Z., Atıcı, C., Unal, K., Meral, R., Kutlu, N., Babaoğlu, A. S., & Dilek, N. M. (2023). A novel material for the microbiological, oxidative, and color stability of salmon and chicken meat samples: Nanofibers obtained from sesame oil. *Food Research International*, 170, 112952.
17. Ceylan, Z., Kutlu, N., Meral, R., Ekin, M. M., & Kose, Y. E., (2021). Protective Effect of Grape Seed Oil-Loaded Nanofibers: Limitation of Microbial Growth and Lipid Oxidation in Kashar Cheese and Fish Meat Samples. *Food Bioscience*, 42(101076), 101076. <https://doi.org/10.1016/j.fbio.2021.101076>

18. Ceylan, Z., Unal, K., Kutlu, N., Meral, R., Balci, B. A., & Doğu Baykut, E. (2022). A novel gastronomy application technique for ready-to-eat salmon meat samples: Curcumin and black seed oil nanofibers with sous vide cooking. *Journal of Food Processing and Preservation*, e16538.
19. Chen, Y., & Zhang, Z. (2022). Exploring public perceptions on alternative meat in China from social media data using transfer learning method. *Food Quality and Preference*, 98, 104530.
20. Chollet, F. (2017). *Deep Learning With Python* Manning Publications Company. Manning Publications Company.
21. Chu, C., Wang, H., Luo, X., Wen, P., Nan, L., Du, C., Fan, Y., Gao, D., Wang, D., & Yang, Z. (2023). Possible Alternatives: Identifying and Quantifying Adulteration in Buffalo, Goat, and Camel Milk Using Mid-Infrared Spectroscopy Combined with Modern Statistical Machine Learning Methods. *Foods*, 12(20), 3856.
22. Cingöz, A., & Nacar, S. (2024). Prediction of Rheological Properties of Flour From Physicochemical Properties Using Multiple Regression Techniques and Artificial Neuronal Networks. *Journal of Food Process Engineering*, 47(10), e14751.
23. Cui, C., Caporaso, N., Chen, J., & Fearn, T. (2023). Farinograph characteristics of wheat flour predicted by near infrared spectroscopy with an ensemble modelling method. *Journal of Food Engineering*, 359, 111689.
24. Çavdar, Z. Y., Avcı, İ., Koca, M., & Sertaş, A. (2019). A survey of hybrid main memory architectures. *Sakarya University Journal of Science*, 23(1), 1-15.
25. da Costa, N. L., Valentin, L. A., Castro, I. A., & Barbosa, R. M. (2021). Predictive modeling for wine authenticity using a machine learning approach. *Artificial Intelligence in Agriculture*, 5, 157-162.
26. Ekin, M. M., Kutlu, N., Meral, R., Ceylan, Z., & Cavidoglu, İ. (2021). A novel nanotechnological strategy for obtaining fat-reduced cookies in bakery industry: Revealing of sensory, physical properties, and fatty acid profile of cookies prepared with oil-based nanoemulsions. *Food Bioscience*. <https://doi.org/10.1016/j.fbio.2021.101184>
27. Esmaeily, R., Razavi, M. A., & Razavi, S. H. (2024). A step forward in food science, technology and industry using artificial intelligence. *Trends in Food Science & Technology*, 143, 104286.
28. Geeksforgeeks. (2025a). *Introduction to Recurrent Neural Networks*.
29. GeeksforGeeks. (2025). *Multioutput Regression in Machine Learning*. <https://www.geeksforgeeks.org/multioutput-regression-in-machine-learning/>
30. Geeksforgeeks. (2025b). *What is LSTM - Long Short Term Memory?*
31. Goralski, M. A., & Tan, T. K. (2020). Artificial intelligence and sustainable development. *The International Journal of Management Education*, 18(1), 100330.
32. Hebbbar, N. (2020). Freshness of food detection using IoT and machine learning. *2020 International Conference on Emerging Trends in Information Technology and Engineering (ic-ETITE)*, 1-3.
33. Hu, G., Ahmed, M., & L'Abbé, M. R. (2023). Natural language processing and machine learning approaches for food categorization and nutrition quality prediction compared with traditional methods. *The American Journal of Clinical Nutrition*, 117(3), 553-563.
34. IBM. (2025a). *What are convolutional neural networks?*
35. IBM. (2025b). *What is a recurrent neural network (RNN)?*
36. IBM. (2025c). *What is classification in machine learning?* <https://www.ibm.com/think/topics/classification-machine-learning>.
37. Irnawati, I., Windarsih, A., Indrianingsih, A. W., Apriyana, W., Ratnawati, Y. A., & Rohman, A. (2023). Rapid detection of tuna fish oil adulteration using FTIR-ATR spectroscopy and chemometrics for halal authentication. *Journal of Applied Pharmaceutical Science*, 13(4), 231-239.
38. Junior, S. B., Mastelini, S. M., Barbon, A. P. A. C., Barbin, D. F., Salvini, R., Lopes, J. F., & Ulrici, A. (2020). Multi-target prediction of wheat flour quality parameters with near infrared spectroscopy. *Information processing in agriculture*, 7(2), 342-354.
39. Kang, Y., Cai, Z., Tan, C.-W., Huang, Q., & Liu, H. (2020). Natural language processing (NLP) in management research: A literature review. *Journal of Management Analytics*, 7(2), 139-172.
40. Karunathilaka, S. R., Yakes, B. J., Choi, S. H., Brückner, L. E. A., & Mossoba, M. M. (2020). Comparison of the performance of partial least squares and support vector regressions for predicting fatty acids and fatty acid classes in marine oil dietary supplements by using vibrational spectroscopic data. *Journal of food protection*, 83(5), 881-889.

41. Kına, E. (2022). Detection of the Trends of Football Fans in Turkey by Machine Learning Algorithm Using Twitter Data. *International Journal of Scientific and Engineering Research*, 13(4).
42. Kına, E. (2023). *ALGORİTMİK OYUN KURAMI* (E. Biçek, Ed.; 1. bs). İksad Yayınevi. <https://iksadyayinevi.com/wp-content/uploads/2023/07/ALGORİTMİK-OYUN-KURAMI.pdf>
43. Kına, E., & Biçek, E. (2023a). Duygu Analizinde Denetimli Makine Öğrenme Algoritmalarının Karşılaştırılmaları,(Kahramanmaraş Depremi Örneği). *Batman Üniversitesi Yaşam Bilimleri Dergisi*, 13(1), 21-31.
44. Kına, E., & Biçek, E. (2023b). *Metaverse–Yeni Dünyaya İlk Adım* (E. Kına & E. Biçek, Ed.). İksad Yayınevi. <https://iksadyayinevi.com/wp-content/uploads/2023/06/METaverse—YENI-DUNYAYA-ILK-ADIM.pdf>
45. KINA, E., & BİÇEK, E. (2023). Tweetlerin Duygu Analizi İçin Hibrit Bir Yaklaşım. *Doğu Fen Bilimleri Dergisi*, 6(1), 57-68. <https://doi.org/10.57244/dfbd.1314901>
46. Kına, E., & Biçek, E. (2024). Machine Learning Approach for Emotion Identification and Classification in Bitcoin Sentiment Analysis TT - Bitcoin Duygu Analizinde Duygu Tanıma ve Sınıflandırma için Makine Öğrenmesi Yaklaşımı. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 29(3), 913-926. <https://doi.org/10.53433/yyufbed.1532649>
47. Kına, E., Biçek, E., İnan, M., Gümüş, O., & Alkan, A. (2024). Üniversitelerde Dijital Araç Yönetimi: Van Yüzüncü Yıl Üniversitesi Örneğiyle Web Tabanlı Araç Takip ve İzleme Sistemi. *Bartın University International Journal of Natural and Applied Sciences*, 7(2).
48. Kına, E., & İnan, M. (2023). Metaverse ve Güvenlik. İçinde İ. Avcı & M. Koca (Ed.), *BİLGİ VE BİLİŞİM SİSTEMLERİ GÜVENLİĞİ* (1. bs, ss. 187-243). ATLAS AKADEMİK BASIM YAYIN DAĞITIM .
49. Kına, E., & Özdağ, R. (2021). Complexity Matrices in Twitter Sentiment Analysis of Thoughts on Mobile Games Using Machine Learning Algorithms. *Muş Alparslan Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 2(2), 91-100.
50. Kına, E., & Özdağ, R. (2024). Multilingual Sentiment Analysis for Mobile Gaming: A Comparative Study of Machine Learning and Hybrid Deep Learning Approaches. *SETSCI-Conference Proceedings*, 21, 1-5.
51. Kına, E. (2025). TLEABLCNN: Brain and Alzheimer's Disease Detection using Attention based Explainable Deep Learning and SMOTE using Imbalanced Brain MRI. *IEEE Access*, 13, 27670-27683. <https://doi.org/10.1109/ACCESS.2025.3539550>
52. Koca, M. (2024a). Real-Time Security Risk Assessment From CCTV Using Hand Gesture Recognition. *IEEE Access*, 12, 84548-84555. <https://doi.org/10.1109/ACCESS.2024.3412930>
53. Koca, M. (2024b). Real-Time Security Risk Assessment From CCTV Using Hand Gesture Recognition. *IEEE Access*, 12, 84548-84555. <https://doi.org/10.1109/ACCESS.2024.3412930>
54. Koca, M., Avcı, İ., & Al-hayani, M. A. S. (2023). Classification of Malicious URLs Using Naive Bayes and Genetic Algorithm. *Sakarya University Journal of Computer and Information Sciences*, 6(2), 80-90.
55. Koca, M., & Avcı, İ. (2024). A Novel Hybrid Model Detection of Security Vulnerabilities in Industrial Control Systems and IoT Using GCN+LSTM. *IEEE Access*, 12, 143343-143351. <https://doi.org/10.1109/ACCESS.2024.3466391>
56. Kumar, S., & Bhatnagar, V. (2022). A review of regression models in machine learning. *Journal of Intelligent Systems and Computing*, 3(1), 40-47.
57. Kutlu, N., Alav, A., & Meral, R. (2024). A novel Nanocoating with zein, gallic acid, and flaxseed oil: Enhancing stability of chicken meatballs. *Food Bioscience*, 60, 104253.
58. Kutlu, N., & Meral, Raciye, Ekin, M.M., Erim Kose, Y., Ceylan, Z. (2021). A new application for the valorisation of pomegranate seed oil : nanoencapsulation of pomegranate seed oil into electrospun nanomats for food preservation. *International Journal of Food Science and Technology*, 1-9. <https://doi.org/10.1111/ijfs.15472>
59. Lareyre, F., Nasr, B., Chaudhuri, A., Di Lorenzo, G., Carlier, M., & Raffort, J. (2023). Comprehensive review of natural language processing (NLP) in vascular surgery. *EJVES Vascular Forum*, 60, 57-63.
60. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
61. Lindemann, B., Müller, T., Vietz, H., Jazdi, N., & Weyrich, M. (2021). A survey on long short-term memory networks for time series prediction. *Procedia Cirp*, 99, 650-655.
62. Meral, R., Alav, A., Karakas, C., Dertli, E., Yilmaz, M. T., & Ceylan, Z. (2019). Effect of electrospun nisin and curcumin loaded nanomats on the microbial quality, hardness and sensory characteristics of rainbow trout fillet. *LWT*, 113. <https://doi.org/10.1016/j.lwt.2019.108292>

63. Meral, R., Ceylan, Z., Kutlu, N., Kılıçer, A., Çağlar, A., & Tomar, O. (2022). Antimicrobial nanocoating for food industry. İçinde H. Chaudrey (Ed.), *Handbook of Microbial Nanotechnology* (ss. 225-284). Academic Press. <https://www.elsevier.com/books/handbook-of-microbial-nanotechnology/hussain/978-0-12-823426-6>
64. Meral, R., Ekin, M. M., Ceylan, Z., Alav, A., & Kına, E. (2025). A Novel Solution to Enhance the Oxidative and Physical Properties 2 of Cookies Using Maltodextrin-Based Nano-Sized Oils as a Fat 3 Substitute. *ACS Omega*, 10(22), 23111-23120.
65. Meral, R., Ekin, M. M., Kutlu, N., & Kose, Y. E. (2022). The nanoemulsions: A new design and fat-reducing strategy for the bakery industry. Their effects on some quality attributes of fat-reduced cakes. *Journal of Food Processing and Preservation*, 46(12), e17160. <https://doi.org/10.1111/jfpp.17160>
66. Meral, R., & Kamberoğlu, G. S. (2012). Tahıllardan etanol üretimi. *Journal of the Institute of Science and Technology*, 2(3), 61-68.
67. Meral, R., Kına, E., & Ceylan, Z. (2024). Low-Calorie Cookies Enhanced with Fish Oil-Based Nano-ingredients for Health-Conscious Consumers. *ACS Omega*, 9(37), 39159-39169. <https://doi.org/10.1021/acsomega.4c06050>
68. Meral, R., Kose, Y. E., Ceylan, Z., & Cavidoglu, İ. (2022). The potential use of agro-industrial by-products as sources of bioactive compounds: a nanotechnological approach. *Studies in Natural Products Chemistry*, 73, 435-466.
69. Mishra, M., Sarkar, T., Choudhury, T., Bansal, N., Smaoui, S., Rebezov, M., Shariati, M. A., & Lorenzo, J. M. (2022). Allergen30: detecting food items with possible allergens using deep learning-based computer vision. *Food Analytical Methods*, 15(11), 3045-3078.
70. Miyazawa, T., Hiratsuka, Y., Toda, M., Hatakeyama, N., Ozawa, H., Abe, C., Cheng, T.-Y., Matsushima, Y., Miyawaki, Y., & Ashida, K. (2022). Artificial intelligence in food science and nutrition: a narrative review. *Nutrition Reviews*, 80(12), 2288-2300.
71. Montesinos López, O. A., Montesinos López, A., & Crossa, J. (2022). Fundamentals of artificial neural networks and deep learning. İçinde *Multivariate statistical machine learning methods for genomic prediction* (ss. 379-425). Springer.
72. Mostafa, M. M. (2019). Clustering halal food consumers: A Twitter sentiment analysis. *International Journal of Market Research*, 61(3), 320-337.
73. Muhammad, L. J., Algehyne, E. A., Usman, S. S., Ahmad, A., Chakraborty, C., & Mohammed, I. A. (2021a). Supervised machine learning models for prediction of COVID-19 infection using epidemiology dataset. *SN computer science*, 2(1), 11.
74. Muhammad, L. J., Algehyne, E. A., Usman, S. S., Ahmad, A., Chakraborty, C., & Mohammed, I. A. (2021b). Supervised machine learning models for prediction of COVID-19 infection using epidemiology dataset. *SN computer science*, 2(1), 11.
75. Nafea, A. A., Alameri, S. A., Majeed, R. R., Khalaf, M. A., & AL-Ani, M. M. (2024). A short review on supervised machine learning and deep learning techniques in computer vision. *Babylonian Journal of Machine Learning*, 2024, 48-55.
76. Naravane, T., & Tagkopoulos, I. (2023). Machine learning models to predict micronutrient profile in food after processing. *Current Research in Food Science*, 6, 100500.
77. Nerkar, P. M., Shinde, S. S., Liyakat, K. K. S., Desai, S., & Kazi, S. S. L. (2023). Monitoring fresh fruit and food using IoT and machine learning to improve food safety and quality. *Tuijin Jishu/Journal of Propulsion Technology*, 44(3), 2927-2931.
78. Okumuş, E., Bakkalbaşı, E., Javidipour, I., Meral, R., & Ceylan, Z. (2021). A novel coating material: Ellagitannins-loaded maltodextrin and lecithin-based nanomaterials. *Food Bioscience*. <https://doi.org/10.1016/j.fbio.2021.101158>
79. Ongsulee, P. (2017). Artificial intelligence, machine learning and deep learning. *2017 15th international conference on ICT and knowledge engineering (ICT&KE)*, 1-6.
80. Osisanwo, F. Y., Akinsola, J. E. T., Awodele, O., Hinmikaiye, J. O., Olakanmi, O., & Akinjobi, J. (2017). Supervised machine learning algorithms: classification and comparison. *International Journal of Computer Trends and Technology (IJCTT)*, 48(3), 128-138.
81. Ozturk, S., Bowler, A., Rady, A., & Watson, N. J. (2023). Near-infrared spectroscopy and machine learning for classification of food powders during a continuous process. *Journal of Food Engineering*, 341, 111339.

82. Rahman, S. M. A., Nassef, A. M., Al-Dhaifallah, M., Abdelkareem, M. A., & Rezk, H. (2020). The effect of a new coating on the drying performance of fruit and vegetables products: experimental investigation and artificial neural network modeling. *Foods*, 9(3), 308.
83. Raj, A. S., Badgujar, C. M., Lollato, R., Prasad, P. V. V., & Siliveru, K. (2024). Predicting rheological properties of wheat dough from flour properties using NIR coupled with artificial neural network. *Journal of the ASABE*, 67(4), 1023-1035.
84. Rikters, M., & Kāle, M. (2023). The Future of Meat: Sentiment Analysis of Food Tweets. *Proceedings of the 11th International Workshop on Natural Language Processing for Social Media*, 38-46.
85. Rousu, J., Flander, L., Suutarinen, M., Autio, K., Kontkanen, P., & Rantanen, A. (2003). Novel computational tools in bakery process data analysis: a comparative study. *Journal of Food Engineering*, 57(1), 45-56.
86. Satorabi, M., Salehi, F., & Rasouli, M. (2021). The influence of xanthan and balangu seed gums coats on the kinetics of infrared drying of apricot slices: GA-ANN and ANFIS modeling. *International Journal of Fruit Science*, 21(1), 468-480.
87. Scatigno, C., & Festa, G. (2022). FTIR coupled with machine learning to unveil spectroscopic benchmarks in the Italian EVOO. *International Journal of Food Science & Technology*, 57(7), 4156-4162.
88. Sen Gupta, D., Sharanagat, V. S., Chakraborty, G., Kumar, J., Parihar, A. K., Yadav, T., Swaraj, Upadhyay, S., Desai, S., & Katiyar, P. K. (2025). Urdbean (Vigna mungo L. Hepper) cultivar characterization based on multiple seed and flour properties and their multi-variate analysis using artificial neural network. *Food Production, Processing and Nutrition*, 7(1), 26.
89. Sharma, N. A., Ali, A. B. M. S., & Kabir, M. A. (2024). A review of sentiment analysis: tasks, applications, and deep learning techniques. *International Journal of Data Science and Analytics*, 1-38.
90. Shaw, B., Suman, A. K., & Chakraborty, B. (2020). Wine quality analysis using machine learning. *Emerging technology in modelling and graphics: proceedings of IEM graph 2018*, 239-247.
91. Shen, Z., Shehzad, A., Chen, S., Sun, H., & Liu, J. (2020). Machine learning based approach on food recognition and nutrition estimation. *Procedia Computer Science*, 174, 448-453.
92. Shetty, S. H., Shetty, S., Singh, C., & Rao, A. (2022). Supervised machine learning: algorithms and applications. *Fundamentals and methods of machine and deep learning: algorithms, tools and applications*, 1-16.
93. Smithers, G. W. (2016). Food Science—Yesterday, Today and Tomorrow. *Reference Module in Food Science*, 1-11.
94. Snowflake.com. (2025). *Types of Regression Models in Machine Learning*. <https://www.snowflake.com/guides/types-regression-models-ml/>
95. Sood, S., & Singh, H. (2021). Computer vision and machine learning based approaches for food security: A review. *Multimedia Tools and Applications*, 80(18), 27973-27999.
96. Tabassum, N., Aftab, R. A., Yousuf, O., Ahmad, S., & Zaidi, S. (2023). Application of nanoemulsion based edible coating on fresh-cut papaya. *Journal of Food Engineering*, 355, 111579.
97. Tutul, M. J. I., Alam, M., & Wadud, M. A. H. (2023). Smart food monitoring system based on iot and machine learning. *2023 International Conference on Next-Generation Computing, IoT and Machine Learning (NCIM)*, 1-6.
98. Windarsih, A., Jatmiko, T. H., Anggraeni, A. S., & Rahmawati, L. (2024). Machine learning-assisted FT-IR spectroscopy for identification of pork oil adulteration in tuna fish oil. *Vibrational Spectroscopy*, 134, 103715.
99. Xu, Y., Hassan, M. M., Kutsanedzie, F. Y. H., Li, H. H., & Chen, Q. S. (2018). Evaluation of extra-virgin olive oil adulteration using FTIR spectroscopy combined with multivariate algorithms. *Quality Assurance and Safety of Crops & Foods*, 10(4), 411-421.
- Yang, C., & Huang, C. (2023). Natural language processing (NLP) in aviation safety: Systematic review of research and outlook into the future. *Aerospace*, 10(7), 600.
100. Zatsu, V., Shine, A. E., Tharakan, J. M., Peter, D., Ranganathan, T. V., Alotaibi, S. S., Mugabi, R., Muhsinah, A. Bin, Waseem, M., & Nayik, G. A. (2024). Revolutionizing the food industry: The transformative power of artificial intelligence-a review. *Food Chemistry: X*, 101867.
101. Zhang, S., Qi, X., Gao, M., Dai, C., Yin, G., Ma, D., Feng, W., Guo, T., & He, L. (2024). Estimation of wheat protein content and wet gluten content based on fusion of hyperspectral and RGB sensors using machine learning algorithms. *Food Chemistry*, 448, 139103.

102. Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. N. (2021). Deep learning and machine vision for food processing: A survey. *Current Research in Food Science*, 4, 233-249.