

Dijital Gastronomi Bağlamında Yapay Zekâ Destekli Menü Öneri Sistemleri

İlhan Avcu¹

Büşra Şen Avcu²

Anıl Örnek³

Özet

Dijital dönüşümün gıda ve gastronomi sektörünü derinden etkilediği günümüzde, yapay zekâ destekli menü öneri sistemleri, kişiselleştirilmiş beslenme deneyimlerinin oluşturulmasında kritik bir rol üstlenmektedir. Bu bölüm, dijital gastronomi kavramı ile yapay zekâ teknolojilerinin kesişim noktasında yer alan menü öneri sistemlerini kapsamlı bir literatür taraması perspektifiyle ele almaktadır. Çalışmada, makine öğrenmesi ve derin öğrenme yöntemlerinin gıda önerisi alanındaki uygulamaları, işbirlikçi filtreleme ve içerik tabanlı filtreleme gibi temel öneri sistemi teknikleri, hibrit yaklaşımların avantajları ve kişiselleştirilmiş beslenme sistemlerinin gelişimi sistematik olarak incelenmektedir. Literatür analizi, yapay zekâ teknolojilerinin restoran yönetiminden bireysel beslenme planlamasına kadar geniş bir yelpazede nasıl uygulandığını ortaya koymakta ve bu alandaki zorlukları, fırsatları ve gelecek araştırma yönelimlerini tartışmaktadır.

- 1 Öğr. Gör., Burdur Mehmet Akif Ersoy Üniversitesi, Turizm Fakültesi, Gastronomi ve Mutfak Sanatları Bölümü, Burdur, Türkiye, iavcu@mehmetakif.edu.tr, 0000-0003-4961-4524
- 2 Öğr. Gör., Aksaray Üniversitesi, Güzelyurt Meslek Yüksekokulu, Aksaray, Türkiye busrasen@aksaray.edu.tr , 0000-0001-7902-0394
- 3 Öğr. Gör., Burdur Mehmet Akif Ersoy Üniversitesi, Yeşilova İsmail Akın Turizm Meslek Yüksekokulu, Otel Lokanta ve İkram Hizmetleri Bölümü, Burdur, Türkiye, aornek@mehmetakif.edu.tr, 0000-0001-9401-5622

1. GİRİŞ

Dijitalleşmenin hızla ilerlediği çağımızda, gastronomi ve beslenme alanı da bu dönüşümden payını almakta, geleneksel yemek kültürü ile modern teknolojilerin entegrasyonu yeni bir paradigma olan “dijital gastronomi” kavramını ortaya çıkarmaktadır. Bu paradigma değişimi, yapay zekâ teknolojilerinin gıda sektörüne entegrasyonu ile daha da derinleşmekte ve tüketicilerin yemek seçim süreçlerini kökten değiştirmektedir. Yapay zekâ destekli menü öneri sistemleri, kullanıcıların tercihlerini, beslenme ihtiyaçlarını ve sağlık durumlarını dikkate alarak kişiselleştirilmiş öneriler sunma kapasitesiyle, modern gastronomi deneyiminin merkezine yerleşmektedir (Thakur & Sharma, 2024; Murugeah, 2024).

Günümüzde yapay zekâ sistemleri, restoran işletmelerinden mobil uygulamalara, akademik kafeteryalardan ev yemek planlamasına kadar çeşitli ortamlarda kullanılmakta olup hem kullanıcı deneyimini iyileştirmekte hem de bireylerin sağlıklı beslenme alışkanlıklarını geliştirmelerine destek olmaktadır. Özellikle bulaşıcı olmayan hastalıklar, gıda alerjileri ve özel diyet gereksinimleri olan bireyler için bu sistemlerin önemi daha da artmaktadır (Imantho vd., 2024). Yapay zekâ teknolojilerindeki gelişmeler, gıda sektöründe üretim süreçlerinden tüketici tercihinin kadar geniş bir etki alanı yaratmakta ve bu sistemler, gıda israfının önlenmesi, üretim verimliliğinin artırılması ve gıda güvenliğinin temini gibi kritik alanlarda önemli katkılar sağlamaktadır (Nicholas-Okpara vd., 2021).

Literatürde, gıda öneri sistemlerinin sistematik incelemeleri, bu alandaki araştırmaların son yıllarda önemli bir ivme kazandığını göstermektedir (Mahajan & Mahajan, 2024). Bu sistemlerin temelinde yatan öneri algoritmaları, kullanıcı davranışlarını analiz etme, benzer kullanıcıları veya ürünleri belirleme ve bu bilgileri kullanarak kişiselleştirilmiş öneriler sunma prensibine dayanmaktadır. Makine öğrenmesi ve derin öğrenme tekniklerinin gelişimiyle birlikte, bu sistemlerin doğruluğu ve etkinliği önemli ölçüde artmış, karmaşık kullanıcı tercihlerini ve bağlamsal faktörleri dikkate alabilen sofistike modeller geliştirilmiştir (Yaiprasert & Hidayanto, 2024).

Bu çalışma, dijital gastronomi çerçevesinde yapay zekâ destekli menü öneri sistemlerini kapsamlı bir literatür taraması ile ele almayı amaçlamaktadır. Araştırma, bu sistemlerin kullanılan yöntem ve tekniklerini sistematik bir biçimde değerlendirmeyi ve gelecekteki araştırma potansiyellerini tartışmayı hedeflemektedir. Çalışma, öneri sistemlerinin teorik altyapısını inceleyerek makine öğrenmesi ve derin öğrenme yaklaşımlarının uygulamalarını detaylandırmakta, farklı kullanım alanlarından örnekler sunmakta ve söz konusu alandaki zorluklar ile fırsatları ortaya koymaktadır.

KAVRAMSAL ÇERÇEVE

2. Dijital Gastronomi ve Yapay Zekâ

Dijital gastronomi, geleneksel mutfak sanatı ile dijital teknolojilerin birleşiminden doğan, yemek hazırlama, sunum ve tüketim süreçlerinin teknoloji aracılığıyla dönüştürüldüğü yeni bir alan olarak tanımlanmaktadır. Bu kavram, sadece yemek pişirme tekniklerinin dijitalleşmesini değil, aynı zamanda tüketici deneyiminin, menü tasarımının ve gıda hizmetlerinin yapay zekâ teknolojileriyle zenginleştirilmesini de kapsamaktadır. Yapay zekanın gastronomi alanındaki uygulamaları, yemek ve şarap eşleştirmelerinden üretim süreçlerine, tüketici tercihlerinden gıda güvenliğine kadar geniş bir alanda kullanılmaktadır (Thakur& Sharma, 2024). Yapay zekâ teknolojilerinin gastronomi sektöründe kullanımı, restoran işletmelerinin verimliliğini ve kişiselleştirme kapasitesini önemli ölçüde artırmaktadır. Bu teknolojiler, müşteri davranışlarını analiz etme, talep tahmininde bulunma, menü optimizasyonu yapma ve kişiselleştirilmiş öneriler sunma gibi çeşitli işlevleri yerine getirmektedir (Murugeah, 2024). Restoran yönetim sistemlerinde yapay zekanın entegrasyonu, operasyonel süreçlerin otomasyonunu sağlarken, müşteri memnuniyetini artıran yenilikçi çözümler sunmaktadır. Özellikle sesli asistan teknolojileri ve doğal dil işleme yetenekleri, kullanıcıların yemek sipariş süreçlerini hızlı ve kolay bir hale getirmektedir.

Dijital gastronomi ortamında, yapay zekâ destekli sistemler, bireylerin beslenme alışkanlıkları, sağlık profilleri ve kişisel tercihlerini göz önünde bulundurarak öneriler sunabilmektedir. Bu sistemler, insan benzeri problem çözme ve karar alma yeteneklerini taklit eden yapay zekâ teknolojilerinden faydalanmakta; makine öğrenmesi algoritmaları aracılığıyla kişisel veriler ve ‘omik’ veri setlerinden örüntüler çıkararak olasılıksal tahminler üretmektedir (Kraemer & Bedsaul, 2022; Gavin-Smith vd., 2022). Derin öğrenme, özellikle görüntü tanıma alanında, gıda görsellerini analiz etmek ve besin değerleri hakkında veriler sunmak için kullanılmakta, bu da kişiselleştirilmiş beslenme uygulamalarının geliştirilmesine olanak sağlamaktadır.

Kişiselleştirilmiş beslenme (precision nutrition) kavramı, yapay zekâ ve makine öğrenmesi teknolojilerinin gastronomi alanındaki en önemli uygulamalarından birini temsil etmektedir. Bu yaklaşım, bireylerin genetik yapıları, metabolik profilleri, bağırsak mikrobiyomları ve yaşam tarzı faktörlerini dikkate alarak özelleştirilmiş diyet önerileri sunmayı amaçlamaktadır (Tsolakidis vd., 2024). Örneğin, ZOE PREDICT çalışması, bağırsak mikrobiyomu ile insan sağlığı arasındaki güçlü ilişkiyi ortaya koymuş ve kişiselleştirilmiş tahmin algoritmalarının glisemik yanıt için 0.77 doğruluk oranına ulaştığını

göstermiştir (Kraemer & Bedsaul 2022; Gavin-Smith vd., 2022). Bu tür gelişmeler, dijital gastronomi alanında yapay zekâ teknolojilerinin potansiyelini açıkça ortaya koymaktadır.

Yapay zekâ destekli gıda sistemlerinin bir diğer önemli boyutu, gıda tanıma ve kalori ölçümü alanındaki uygulamalardır. Makine öğrenmesi tekniklerinin kullanıldığı bu sistemler, görüntü işleme ve derin öğrenme yöntemleriyle gıda maddelerini otomatik olarak tanımlayabilmekte ve besin değerlerini tahmin edebilmektedir (Gupta & Sharma, 2021). Bu teknolojiler, diyet takibi uygulamalarından restoran menü analizine kadar büyük bir etki alanına sahiptir ve kullanıcıların beslenme alışkanlıklarını daha bilinçli bir şekilde yönetmelerine yardımcı olmaktadır.

2.1. Öneri Sistemlerinin Teorik Temelleri

Öneri sistemleri, kullanıcıların ilgi alanlarına, geçmiş davranışlarına ve tercihlerine dayalı olarak kişiselleştirilmiş öneriler sunan bilgi filtreleme sistemleridir. Bu sistemler, e-ticaretten eğlence platformlarına, sosyal medyadan gastronomi uygulamalarına kadar birçok yerde kullanılmakta ve kullanıcı deneyimini önemli ölçüde iyileştirmektedir. Gıda ve gastronomi alanında öneri sistemlerinin uygulanması, kullanıcıların yemek seçim süreçlerini kolaylaştırırken, sağlıklı beslenme alışkanlıklarının geliştirilmesine de katkı sağlamaktadır (Nadeem & Sivakumar, 2023).

2.2. İşbirlikçi Filtreleme Yaklaşımları

İşbirlikçi filtreleme, öneri sistemlerinin en yaygın kullanılan tekniklerinden biridir ve benzer tercihlere sahip kullanıcıların davranışlarından yararlanarak öneriler oluşturma prensibine dayanmaktadır. Bu yaklaşım, bir kullanıcının geçmişte beğendiği veya tükettiği ürünlere benzer tercihlere sahip diğer kullanıcıların seçimlerini analiz ederek, hedef kullanıcı için uygun önerilerde bulunmaktadır. İşbirlikçi filtreleme teknikleri, temel olarak kullanıcı verilerine dayalı bellek tabanlı yaklaşımlar ile istatistiksel ve makine öğrenmesi modellerine dayalı model tabanlı yaklaşımlar olmak üzere iki ana sınıfa ayrılmaktadır (Nadeem & Sivakumar, 2023). Bellek tabanlı işbirlikçi filtreleme yöntemleri, kullanıcı-ürün etkileşim matrisini doğrudan kullanarak benzerlik hesaplamaları yapmaktadır. Pearson korelasyon benzerliği ve Log Likelihood benzerliği gibi metrikler, kullanıcılar veya ürünler arasındaki benzerlik derecesini ölçmek için yaygın olarak kullanılmaktadır (Nadeem & Sivakumar, 2023; Pérez vd., 2018). Gıda öneri sistemlerinde, bu yaklaşım, benzer beslenme alışkanlıklarına sahip kullanıcıları belirleyerek ve onların tercihlerini analiz ederek kişiselleştirilmiş menü önerileri sunmaktadır (Zioutos vd., 2023). Model tabanlı işbirlikçi filtreleme ise, kullanıcı-ürün etkileşimlerinden öğrenilen matematiksel modeller

kullanarak öneriler oluşturmaktadır. Matris çarpanlarına ayırma (matrix factorization), tekil değer ayrıştırması (Singular Value Decomposition-SVD) ve gizli semantik analiz gibi teknikler, bu kategorinin önemli örnekleridir (Nadeem & Sivakumar, 2023). Bu yöntemler, yüksek boyutlu kullanıcı-ürün matrislerini daha düşük boyutlu gizli faktör uzaylarına dönüştürerek, kullanıcı tercihlerini ve ürün özelliklerini daha etkili bir şekilde modellemektedir.

Gıda öneri sistemlerinde işbirlikçi filtrelemenin uygulanması, kullanıcıların benzer diyet tercihlerine sahip bireylerle eşleştirilmesini ve bu bilginin kişiselleştirilmiş tarif önerileri için kullanılmasını sağlamaktadır (Zioutos vd., 2023). Örneğin, bir çalışmada, işbirlikçi filtreleme ve knapsack yöntemi kullanılarak geliştirilen kişiselleştirilmiş sağlıklı gıda öneri sistemi, kullanıcılardan mükemmel düzeyde memnuniyet almış ve 4.20 ortalama memnuniyet skoru elde etmiştir (Thongsri vd., 2022).

Grafik tabanlı öneri sistemleri, işbirlikçi filtrelemenin gelişmiş bir versiyonunu temsil etmektedir. Grafik sinir ağları (Graph Neural Networks-GNN), kullanıcı-ürün etkileşim grafinin yapısını kullanarak daha etkili öneriler sunabilmektedir. GCFA (Graph Neural Networks on Collaborative Filtering Recommendation via Attention Mechanism) gibi yaklaşımlar, dikkat mekanizması kullanarak heterojen kullanıcı-ürün etkileşim güçlerini modellemekte ve grafik yapısı üzerinde gömme (embedding) yayılımı gerçekleştirmektedir (Zou vd., 2020). Bu tür gelişmiş yöntemler, geleneksel işbirlikçi filtreleme tekniklerinin sınırlamalarını aşmada önemli potansiyele sahiptir.

2.3. İçerik Tabanlı Filtreleme Yöntemleri

İçerik tabanlı filtreleme, ürünlerin özelliklerini ve kullanıcıların geçmiş tercihlerini analiz ederek öneriler sunan bir yaklaşımdır (Lops vd., 2011). Bu yöntem, kullanıcının daha önce beğendiği veya tükettiği ürünlerin özelliklerine benzer özelliklere sahip yeni ürünleri önermektedir (Ricci vd., 2015). Gıda öneri sistemlerinde, içerik tabanlı filtreleme; yemeklerin besin değerleri, malzemeleri, pişirme yöntemleri, mutfak türleri ve diğer özelliklerini kullanarak öneriler oluşturmaktadır (Arulprakash vd., 2024). İçerik tabanlı filtreleme sistemleri, ürün özelliklerini vektörler olarak temsil etmekte ve bu vektörler arasındaki benzerliği hesaplamak için kosinüs benzerliği gibi metrikler kullanmaktadır (Deniz, 2021; Aggarwal, 2016; Lops vd., 2011). Makine öğrenmesi algoritmaları, kullanıcı davranışlarını ve tercihlerini analiz ederek, hangi ürün özelliklerinin kullanıcı için daha önemli olduğunu öğrenmekte ve bu bilgiyi öneri sürecinde kullanmaktadır (Bondevik vd., 2024). Doğal dil işleme (NLP) ve konuşma tanıma teknolojileri, kullanıcı girdilerini

işlemek ve daha doğal etkileşimler sağlamak için içerik tabanlı sistemlerde kullanılmaktadır (Musto vd., 2021; Soma ve Dyapur, 2023). Gıda alanında içerik tabanlı filtrelemenin önemli bir uygulaması, malzeme tanıma ve tarif öneri sistemleridir. Örneğin, RecipeIS sistemi, ResNet-50 konvolüsyonel sinir ağı kullanarak gıda malzemelerini %96 doğrulukla tanımlamakta ve tanınan malzemelere dayalı olarak kişiselleştirilmiş tarif önerileri sunmaktadır (Rodrigues vd., 2023). Bu sistem, kullanıcıların ellerinde bulunan malzemeleri kullanarak yemek yapmalarına yardımcı olmakta ve gıda israfını azaltmaya katkı sağlamaktadır. Benzer şekilde, görüntü tanıma teknolojilerini kullanan başka bir sistem, sık kullanılan gıda setlerini madenciliği yaparak ve derin sinir ağlarıyla %80 tanıma doğruluğu elde ederek gıda önerileri sunmaktadır (Tangpong vd., 2021).

2.4. Hibrit Öneri Sistemleri

Hibrit öneri sistemleri, işbirlikçi filtreleme ve içerik tabanlı filtreleme gibi farklı öneri tekniklerini birleştirerek, her bir yaklaşımın avantajlarından yararlanmayı ve dezavantajlarını minimize etmeyi amaçlamaktadır. Literatürde, hibrit sistemlerin tek başına kullanılan yöntemlere göre daha yüksek doğruluk oranları elde ettiği ve kullanıcı deneyimini önemli ölçüde iyileştirdiği gösterilmektedir (Nadeem & Sivakumar, 2023; Sharma vd., 2023). Hibrit sistemler, farklı teknikleri birleştirmek için çeşitli stratejiler kullanmaktadır. Bunlar arasında ağırlıklı (weighted) yaklaşım, geçiş (switching) yaklaşımı, karışık (mixed) yaklaşım, özellik birleştirme (feature combination) ve özellik artırma (feature augmentation) gibi yöntemler bulunmaktadır (Nadeem & Sivakumar, 2023). Her bir strateji, farklı senaryolarda ve uygulama alanlarında değişen düzeylerde etkinlik göstermektedir.

Gıda öneri sistemlerinde hibrit yaklaşımların kullanımı, özellikle karmaşık kullanıcı tercihlerini ve çoklu kısıtlamaları dikkate almada önemli avantajlar sağlamaktadır. Örneğin, bir akademik ortamda geliştirilen gıda öneri sistemi, işbirlikçi filtreleme, içerik tabanlı ve bilgi tabanlı modelleri birleştiren hibrit bir yaklaşım kullanmış ve AdaBoost makine öğrenmesi modeliyle %73.70 doğruluk oranına ulaşmıştır (Ajami & Teimourpour, 2023). Bu sistem, üniversite öğrencilerinin enerji göstergeleri ve seçim geçmişlerine dayalı olarak menü önerileri sunmaktadır.

Başka bir çalışmada, TripAdvisor ve Foursquare verilerini kullanan hibrit bir restoran öneri sistemi geliştirilmiş ve işbirlikçi filtreleme ile içerik tabanlı filtrelemeyi birleştiren Bayesian sınıflandırıcı ve doğal dil işleme teknikleri kullanılmıştır (Pérez vd., 2018). Bu sistem, GPS konum bilgisini de filtreleme kriteri olarak kullanarak, %85'in üzerinde kesinlik ve %79'un üzerinde daha

doğru ve verimli restoran önerileri sunmuştur. Benzer şekilde, popülerlik tabanlı ve içerik tabanlı filtrelemeyi birleştiren hibrit bir ürün öneri sistemi, daha doğru, çeşitli ve kişiselleştirilmiş öneriler sunarak kullanıcı deneyimini ve müşteri memnuniyetini artırmıştır (Sharma vd., 2023).

Hibrit sistemlerin bir diğer önemli örneği, içerik tabanlı ve işbirlikçi filtreleme tekniklerini birleştiren sağlam ve doğru bir gıda öneri sistemidir (Elwin vd., 2024). Bu sistem, makine öğrenmesi algoritmalarını kullanarak kullanıcı tercihlerini ve yemek özelliklerini analiz etmekte ve deneysel sonuçlar, hibrit yöntemin etkinliğini ve doğruluğunu kanıtlamaktadır.

3. Yapay Zekâ ve Makine Öğrenmesi Yöntemleri

Yapay zekâ ve makine öğrenmesi yöntemleri, gıda öneri sistemlerinin doğruluğunu ve kişiselleştirme kapasitesini artıran temel teknolojiler arasında yer almaktadır. Kullanıcı tercihleri, beslenme alışkanlıkları ve içerik özellikleri gibi çok boyutlu verilerin analiz edilmesi, bu sistemlerin daha etkin öneriler sunmasını sağlamaktadır. Bu bağlamda, gıda öneri sistemlerinin geliştirilmesinde geleneksel makine öğrenmesi algoritmalarından derin öğrenme mimarilerine ve son yıllarda transformer tabanlı modellere kadar geniş bir yöntem yelpazesi kullanılmaktadır (Ricci vd., 2015; Aggarwal, 2016; Yaiprasert vd., 2024).

3.1. Geleneksel Makine Öğrenmesi Yaklaşımları

Geleneksel makine öğrenmesi algoritmaları, gıda öneri sistemlerinin erken dönemlerinden itibaren yaygın olarak kullanılan yöntemlerdir. Destek Vektör Makineleri (SVM), Karar Ağaçları, Rastgele Ormanlar, k-En Yakın Komşu (k-NN) ve topluluk öğrenme (ensemble learning) algoritmaları bu kapsamda öne çıkmaktadır. Özellikle SVM tabanlı modeller, yüksek boyutlu veri kümelerinde güçlü sınıflandırma performansı sunmaları nedeniyle restoran öneri sistemleri ve gıda tercihi tahmini gibi uygulamalarda tercih edilmektedir. Yelp veri seti üzerinde gerçekleştirilen çalışmalar, SVM tabanlı modellerin benzer restoranların belirlenmesi ve kullanıcı tercihlerinin tahmin edilmesinde etkili sonuçlar verdiğini göstermektedir. Ayrıca gıda turizmine yönelik öneri sistemlerinde yapılan karşılaştırmalı analizlerde SVM algoritmasının diğer yöntemlere kıyasla daha yüksek doğruluk oranları elde ettiği rapor edilmiştir (Suruthi vd., 2019). Benzer şekilde gıda görüntülerinin tanınması ve kalori tahmini üzerine gerçekleştirilen çalışmalarda Gabor filtreleri ile desteklenen SVM modellerinin %86 doğruluk oranına ulaştığı belirtilmektedir (Gupta & Sharma, 2021).

Karar ağaçları ve rastgele orman algoritmaları ise yorumlanabilir yapıları sayesinde gıda öneri sistemlerinde önemli bir yer tutmaktadır. Bu algoritmalar,

kullanıcı tercihleri ve gıda özellikleri arasındaki ilişkileri hiyerarşik karar yapıları aracılığıyla modelleyerek öneri üretmektedir (Suruthi vd., 2019). K-En Yakın Komşu algoritması ise kullanıcı veya ürün benzerliklerini belirlemek için sıklıkla kullanılan bir yöntem olup özellikle turizm ve restoran öneri sistemlerinde başarılı sonuçlar vermektedir (Muruganandam ve Manipaul, 2023). Buna ek olarak topluluk öğrenme yöntemleri, birden fazla modelin çıktısını birleştirerek daha güçlü tahmin performansı elde etmeyi amaçlamaktadır. AdaBoost ve Bagging gibi yöntemler bu bağlamda öne çıkmakta olup üniversite öğrencileri için geliştirilen bir gıda öneri sisteminde AdaBoost modelinin %73.70 doğruluk oranı ile en iyi performansı sağladığı rapor edilmiştir (Ajami & Teimourpour, 2023). Ayrıca lojistik regresyon gibi doğrusal sınıflandırıcılar da tarif üretimi ve malzeme ikamesi gibi uygulamalarda kullanılmakta ve özellikle diyabetik veya süt ürünü içermeyen tarif önerilerinde yüksek doğruluk oranları elde edilmektedir (Britto vd., 2020).

3.2. Derin Öğrenme Yaklaşımları

Derin öğrenme yöntemleri, çok katmanlı sinir ağları aracılığıyla karmaşık veri örüntülerini öğrenebilme yetenekleri sayesinde gıda öneri sistemlerinde önemli bir ilerleme sağlamıştır. Özellikle Konvolüsyonel Sinir Ağları (CNN), Tekrarlayan Sinir Ağları (RNN), Uzun Kısa Süreli Bellek (LSTM) ağları ve oto kodlayıcı mimarileri bu alanda yaygın olarak kullanılmaktadır. CNN tabanlı modeller, gıda görüntülerinin sınıflandırılması ve tanınması konusunda yüksek doğruluk oranları elde etmektedir. ResNet, VGGNet, GoogLeNet, Inception ve EfficientNet gibi yöntemler gıda görüntülerinin analizinde yaygın olarak kullanılmaktadır (Gupta & Sharma, 2021). Örneğin ResNet-50 tabanlı bir modelin 36 farklı sebze ve meyve sınıfını %96 doğruluk oranı ile tanımlayabildiği gösterilmiştir (Rodrigues vd., 2023). Benzer şekilde Food-101 veri seti üzerinde gerçekleştirilen bir çalışmada ResNet modeli %82.07 doğruluk oranı elde etmiştir (Martí, 2017).

Derin öğrenme modelleri yalnızca görüntü tanıma görevlerinde değil, aynı zamanda sağlıklı tarif önerileri ve beslenme analizi gibi uygulamalarda da kullanılmaktadır. ImageNet üzerinde ön eğitilmiş CNN modelleri kullanılarak geliştirilen bir sistemde ResNet50 tabanlı mimari ile k-En Yakın Komşu algoritmasının birleştirilmesi sonucunda %98.61 doğruluk oranı elde edilmiştir (Lico vd., 2023). Bunun yanında AI4Food-NutritionDB gibi veri tabanları, gıda görüntülerinin besin değerleri ile ilişkilendirilmesi ve öneri sistemlerinin performansının değerlendirilmesi için önemli veri kaynakları sağlamaktadır (Romero-Tapiador vd., 2022).

Oto kodlayıcı tabanlı modeller de işbirlikçi filtreleme süreçlerinde önemli bir rol oynamaktadır. Özellikle denoising oto kodlayıcı mimarileri, eksik veya gürültülü kullanıcı verilerinden anlamlı temsil öğrenerek öneri performansını artırabilmektedir. Food.com veri seti üzerinde gerçekleştirilen bir çalışmada kümeleme yöntemi ile birleştirilen denoising oto kodlayıcı modelinin 0.1927 RMSE (kök ortalama kare hata) değeri ile yüksek doğruluk sağladığı rapor edilmiştir (Al-Asadi ve Jasim, 2023).

3.3. Transformer Tabanlı Yaklaşımlar

Son yıllarda transformer yaklaşımlar de öneri sistemleri alanında önemli bir araştırma odağı haline gelmiştir. Self-attention mekanizması sayesinde kullanıcı ve ürün etkileşimleri arasındaki karmaşık ilişkileri modelleyebilen bu mimariler, büyük veri kümelerinde yüksek performans göstermektedir. Örneğin MenuAI sistemi transformer tabanlı bir model kullanarak restoran menülerindeki yemekleri sıralamakta ve kullanıcıların beslenme ihtiyaçlarına göre kişiselleştirilmiş öneriler sunmaktadır (Ju vd., 2022). Benzer şekilde FoodNet modeli dikkat mekanizması kullanarak kullanıcı tercihlerine dayalı gıda kombinasyonları önermekte ve büyük veri setlerinde geleneksel öneri yöntemlerine kıyasla daha yüksek performans elde etmektedir (Vijjali vd., 2022).

4. Gıda ve Gastronomi Alanında Uygulama Örnekleri

4.1. Restoran Menü Öneri Sistemleri

Restoran menü öneri sistemleri, müşterilerin yemek seçim süreçlerini kolaylaştırmak, kişiselleştirilmiş deneyimler sunmak ve restoranların operasyonel verimliliğini artırmak amacıyla geliştirilmektedir. Bu sistemler, kullanıcı tercihleri, geçmiş sipariş verileri, beslenme gereksinimleri ve bağlamsal faktörler gibi çok boyutlu bilgileri analiz ederek kişiselleştirilmiş öneriler sunmaktadır. Akıllı restoran öneri platformları, Yelp gibi çevrimiçi inceleme ve değerlendirme platformlarından elde edilen büyük veri setlerini kullanarak benzer restoranları veya yemekleri önerebilmektedir. Bu sistemlerde makine öğrenmesi algoritmaları, özellikle Destek Vektör Makineleri (SVM) gibi yöntemler kullanılarak kullanıcı yorumları ve restoran özellikleri üzerinden tahmin modelleri oluşturulmaktadır. Yelp veri setleri üzerinde gerçekleştirilen çalışmalar, makine öğrenmesi tabanlı modellerin restoran özelliklerini analiz ederek kullanıcıların daha bilinçli yemek seçimleri yapmasına katkı sağladığını göstermektedir (Luo & Xu, 2019; Yu vd., 2017).

Gıda turizmi alanında, yapay sinir ağları kullanılarak geliştirilen öneri sistemleri, turistlere kişiselleştirilmiş seyahat deneyimleri sunmaktadır. K-Means

kümeleme, Karar Ağaçları, PCA ve SVM gibi algoritmalar karşılaştırılmış ve SVM'nin en yüksek doğruluğu gösterdiği bulunmuştur (Suruthi vd., 2019). Bu sistemler, turistlerin farklı ülkelere seyahat ederken yerel yiyecekler ve malzemeleri hakkında bilgi sahibi olmalarına yardımcı olmakta ve özel diyet ihtiyaçlarını dikkate almaktadır (Rajabpour vd., 2018).

IoT tabanlı menü sipariş sistemleri, restoran operasyonlarını çağdaşlaştırmakta ve müşteri deneyimini iyileştirmektedir (Ingle vd., 2022). Sesli asistan teknolojileri, doğal dil işleme ve konuşma tanıma kullanarak, kullanıcıların sesli komutlarla yemek sipariş etmelerini sağlamaktadır. İçerik tabanlı filtreleme ve makine öğrenmesi algoritmaları, kullanıcı davranışlarını ve sipariş geçmişini analiz ederek kişiselleştirilmiş gıda önerileri, pişirme süresi tahminleri ve yakındaki mekanlar için öneriler sunmaktadır.

Adaptif elektronik menü sistemleri, restoranlarda kişiselleştirilmiş menü önerileri sunmak için bağlamsal işbirlikçi filtreleme yaklaşımlarını kullanmaktadır (Zitouni vd., 2020; Filho & Wörndl, 2015). Bu sistemler, kullanıcının mevcut bağlamını (zaman, konum, sosyal durum vb.) dikkate alarak daha ilgili öneriler sunmaktadır. Örneğin, bir çalışmada geliştirilen kişiselleştirilmiş menü sistemi, bağlamsal faktörleri entegre ederek kullanıcı memnuniyetini artırmıştır (Zitouni vd., 2020).

4.2. Kişiselleştirilmiş Beslenme ve Sağlık Odaklı Sistemler

Kişiselleştirilmiş beslenme sistemleri, bireylerin sağlık durumlarını, beslenme ihtiyaçlarını ve diyet kısıtlamalarını dikkate alarak özelleştirilmiş menü önerileri sunmaktadır. Bu sistemler, bulaşıcı olmayan hastalıklar, gıda alerjileri, diyabet, laktöz intoleransı ve diğer özel durumlar için kritik öneme sahiptir (Ordovás vd., 2018; Zeevi vd., 2015).

Bulaşıcı olmayan hastalık geçmişi olan yemek müşterileri için geliştirilen akıllı gıda öneri sistemi, kullanıcıların sağlık durumlarına uygun menü önerileri sunmaktadır (Imantho vd., 2024). Benzer şekilde, diyabetik ve süt ürünleri içermeyen tarifler için otomatik tarif üretimi yapan bir sistem, doğrusal sınıflandırıcılar kullanarak malzeme ikamesi gerçekleştirmekte ve diyabetik dostu tarifler için %92, süt ürünleri içermeyen tarifler için %88 doğruluk oranlarına ulaşmaktadır (Britto vd., 2020).

Akademik ortamlarda, üniversite öğrencileri için geliştirilen gıda öneri sistemleri, enerji göstergeleri ve seçim geçmişine dayalı olarak menü önerileri sunmaktadır. 2519 üniversite öğrencisi üzerinde test edilen hibrit bir sistem, işbirlikçi filtreleme, içerik tabanlı ve bilgi tabanlı modelleri birleştirmiş ve AdaBoost modeliyle %73.70 doğruluk oranına ulaşmıştır (Ajami &

Teimourpour, 2023). Bu tür sistemler, büyük veri setlerinden yararlanarak sağlıklıyla ilgili diyet önerilerinin etkinliğini göstermektedir.

Sağlıklı tarif önerileri için geliştirilen çerçeveler, kullanıcıların sağlık geçmişlerine ve tercihlerine dayalı olarak kişiselleştirilmiş tarifler sunmaktadır. SHARE gibi sistemler, işbirlikçi filtreleme kullanarak benzer diyet tercihlerine sahip kullanıcıları belirlemekte ve düşük karbonhidratlı veya vejetaryen gibi çeşitli sağlık kısıtlamalarını ve diyet planlarını ele almaktadır (Zioutos vd., 2023). Büyük gerçek dünya veri setleri üzerinde yapılan deneyler, bu sistemlerin son derece kişiselleştirilmiş ve doğru öneriler sunduğunu göstermiştir.

Pekiştirmeli öğrenme (reinforcement learning) kullanan etkileşimli gıda öneri sistemleri, gerçek zamanlı kullanıcı sağlık gereksinimlerine uyum sağlamaktadır. RecipeRL adlı sistem, çok adımlı etkileşimli gıda önerileri için pekiştirmeli öğrenme algoritmalarını kullanmaktadır (Liu vd., 2024). Kişiselleştirilmiş sağlıklı gıda öneri sistemleri, işbirlikçi filtreleme ve knapsack yöntemini birleştirerek, bireysel tercihlere göre gıda seçimi için karar verme verileri sağlamaktadır. Kullanıcılar, sistemin çalışma yeteneği, ekran tasarımı ve verimliliği konusunda mükemmel memnuniyet ifade etmiş ve ortalama 4.20 memnuniyet skoru elde edilmiştir (Thongsri vd., 2022).

4.3. Tarif Öneri ve Malzeme Tanıma Sistemleri

Tarif öneri ve malzeme tanıma sistemleri, kullanıcıların ellerinde bulunan malzemeleri kullanarak yemek yapmalarına yardımcı olmakta ve gıda israfını azaltmaya katkı sağlamaktadır. Bu sistemler, görüntü tanıma, doğal dil işleme ve öneri algoritmaları gibi çeşitli yapay zekâ tekniklerini entegre etmektedir (Salvador vd., 2019).

RecipeIS, gıda malzemelerinin tanınmasına dayalı bir tarif öneri sistemidir. ResNet-50 konvolüsyonel sinir ağı kullanılarak geliştirilen bu sistem, 36 sınıf sebze ve meyve için %96 doğrulukla görüntüleri sınıflandırmakta ve yaklaşık %4 kayıp oranıyla yüksek doğruluk göstermektedir (Rodrigues vd., 2023). Rodrigues vd., (2023) tarafından geliştirilen RecipeIS projesinde, sistem Edamam API'si ile entegre edilerek tarif önerilerinin elde edilmesi ve böylece özel bir veri tabanı oluşturma gereksiniminin ortadan kaldırılması açıklanmaktadır. Bu API kullanımı, kullanıcıların tanınan malzemelere göre tariflere ulaşmasını sağlamış ve filtreleme seçenekleriyle kişiselleştirilmiş öneriler sunmuştur.

Sık kullanılan gıda setlerinin madenciliği ve görüntü tanıma kullanılarak geliştirilen bir gıda öneri sistemi, derin sinir ağlarını kullanmaktadır (Tangpong vd., 2021). Gıda görüntülerine dayalı sağlıklı tarif önerisi için geliştirilen uçtan uca derin öğrenme sistemleri, derin sinir ağlarını k-En Yakın Komşu

algoritmasıyla birleştirmektedir. 50,718 görüntüden oluşan ve Nutri-Score değerleriyle etiketlenmiş yeni bir veri seti kullanılarak, ResNet50 ile maksimum %98.61 tahmin doğruluğu elde edilmiş ve bu, DenseNet121 (%95.12), ResNet101 (%90.51) ve EfficientNetB2 (%84.81) modellerini geride bırakmıştır (Lico vd., 2023). Yaklaşım, benzer ve daha sağlıklı tarifleri etkili bir şekilde tanımlamakta ve kişiselleştirilmiş öğün planlaması için yeni bir yöntem sunmaktadır.

Metin analitiğine dayalı mutfak tarifi önerileri, kullanıcı tercihlerini ve tarif özelliklerini analiz ederek öneriler sunmaktadır (Hong ve Lee 2018). Doğal dil işleme teknikleri, tarif açıklamalarından anlamlı bilgiler çıkarmak ve kullanıcı sorgularıyla eşleştirmek için kullanılmaktadır. Benzer şekilde, geçmiş tercihlere dayalı otomatik menü öneri sistemleri, kullanıcıların önceki seçimlerini analiz ederek gelecekteki öneriler sunmaktadır (Sanz & Agrawal, 2014).

Kullanıcı tat tercihlerini anlamak, gıda önerisi için kritik öneme sahiptir (Naresh vd., 2020). Makine öğrenmesi teknikleri, kullanıcıların tat profillerini modellemek ve bu bilgiyi öneri sürecinde kullanmak için uygulanmaktadır. Ayrıca, diyet davranışına dayalı gıda öneri sistemleri, kümeleme ve derin öğrenme tekniklerini birleştirerek, benzer diyet davranışlarına sahip kullanıcıları bulmakta ve onları öneri sürecine dahil etmektedir (Al-Asadi & Jasim, 2023).

5. SONUÇ VE ÖNERİLER

Dijital gastronomi bağlamında yapay zekâ destekli menü öneri sistemleri, gıda sektöründe devrim niteliğinde değişimlere yol açmakta ve kullanıcıların beslenme deneyimlerini kökten dönüştürmektedir. Bu bağlamda çalışma kapsamında yapılan literatür taraması, öneri sistemlerinin teorik temellerinden makine öğrenmesi ve derin öğrenme yöntemlerine, gerçek dünya uygulamalarından gelecek yönelimlere kadar geniş bir perspektif sunmaktadır. Literatür analizi, gıda öneri sistemlerini işbirlikçi filtreleme, içerik tabanlı filtreleme ve hibrit sistemler olarak üç ana teknik yaklaşım etrafında şekillendiğini göstermektedir. İşbirlikçi filtreleme, benzer kullanıcıların tercihlerinden yararlanarak etkili öneriler sunmaktadır (Nadeem& Sivakumar, 2023; Zou vd., 2020). İçerik tabanlı filtreleme, ürün özelliklerini kullanarak öneriler oluşturmakta ve yeni ürünler için avantaj sağlamakla birlikte, çeşitlilik sınırlaması yaşamaktadır (Rodrigues vd., 2023; Tangpong vd., 2021).

Hibrit sistemler, her iki yaklaşımın güçlü yönlerini birleştirerek, daha yüksek doğruluk oranları ve kullanıcı memnuniyeti elde etmektedir (Pérez vd., 2018; Teimourpour, 2023; Elwin vd., 2024). Makine öğrenmesi ve derin öğrenme teknolojilerinin gelişimi, gıda öneri sistemlerinin doğruluğunu ve etkinliğini önemli ölçüde artırmıştır. Geleneksel makine öğrenmesi algoritmaları olan SVM,

Karar Ağaçları, k-NN ve topluluk öğrenme yöntemleri, çeşitli uygulamalarda etkili sonuçlar vermektedir (Suruthi vd., 2019; Teimourpour, 2023; Britto vd., 2020). Derin öğrenme mimarileri, özellikle CNN'ler, gıda tanıma ve görüntü sınıflandırma görevlerinde olağanüstü başarı göstermekte ve %96'ya varan doğruluk oranlarına ulaşmaktadır (Rodrigues vd., 2023; Martí vd., 2017; Lico vd., 2023). Transformer tabanlı modeller, self-attention mekanizması ve paralel işleme kapasitesiyle, karmaşık kullanıcı-ürün etkileşimlerini modellemede güçlü bir araç haline gelmiştir (Ju vd., 2022; Vijjali vd., 2022).

Literatür incelendiğinde yapay zekâ destekli menü öneri sistemlerinin geniş bir yelpazede kullanıldığını göstermektedir. Restoran menü öneri sistemleri, müşteri deneyimini iyileştirmekte ve operasyonel verimliliği artırmaktadır (Suruthi vd., 2019; Ingle vd., 2022; Zitouni vd., 2020). Kişiselleştirilmiş beslenme ve sağlık odaklı sistemler, bulaşıcı olmayan hastalıklar, diyet kısıtlamaları ve özel beslenme ihtiyaçları olan bireyler için kritik destek sağlamaktadır (Imantho vd., 2024; Britto vd., 2020; Liu vd., 2024). Tarif öneri ve malzeme tanıma sistemleri, gıda israfını azaltmakta ve kullanıcıların ellerindeki malzemelerle yemek yapmalarına yardımcı olmaktadır (Rodrigues vd., 2023; Tangpong vd., 2021; Lico vd., 2023). Mevcut sistemlerin sınırlamaları ve zorlukları, gelecekteki araştırmalar için önemli fırsatlar sunmaktadır.

Sonuç olarak, dijital gastronomi ve yapay zekâ teknolojilerinin kesişimi, gıda sektöründe yenilikçi çözümler ve kişiselleştirilmiş deneyimler için muazzam bir potansiyel sunmaktadır. Yapay zekâ destekli menü öneri sistemleri, kullanıcıların beslenme alışkanlıklarını iyileştirmekte, sağlıklı yaşam tarzlarını desteklemekte ve gıda endüstrisinin verimliliğini artırmaktadır. Gelecekteki araştırmalar, mevcut zorlukları ele alarak, daha sofistike, açıklanabilir ve sürdürülebilir sistemler geliştirmelidir. Bu alandaki interdisipliner iş birlikleri, bilgisayar bilimi, beslenme bilimi, gastronomi ve sosyal bilimler arasındaki sinerjiyi güçlendirerek, dijital gastronomi paradigmasının tam potansiyelini ortaya çıkaracaktır.

Kaynakça

- Aggarwal, C. C. (2016). *Recommender systems: The textbook*. (pp. 1-28), Springer. <https://doi.org/10.1007/978-3-319-29659-3>
- Ajami, A., & Teimourpour, B. (2023). A food recommender system in academic environments based on machine learning models. *arXiv preprint arXiv:2306.16528*. <https://doi.org/10.48550/arXiv.2306.16528>
- Al-Asadi, A. A., & Jasim, M. N. (2023). Dietary behavior based food recommender system using deep learning and clustering techniques. *Wasit Journal of Computer and Mathematics Science*, 2(1), 126-135. <https://doi.org/10.31185/wjcm.126>
- Arulprakash, M., Kumar, S., & Singh, R. (2024). Food recommender system using content based filtering. *AIP Conference Proceedings*, 3075(1), 020216. <https://doi.org/10.1063/5.0217594>
- Bondevik, J. N., Bennin, K. E., Babur, Ö., & Ersch, C. (2024). A systematic review on food recommender systems. *Expert Systems with Applications*, 238, Article 122166. <https://doi.org/10.1016/j.eswa.2023.122166>
- Britto, L., Neto, A. F. S., & Pedrini, H. (2020). Geração automática de receitas culinárias para pessoas com restrições alimentares. *Revista Eletrônica de Iniciação Científica em Computação*, 18(4). <https://doi.org/10.5753/REIC.2020.1749>
- Burada: Martí, A., Giró-i-Nieto, X., & Ioannidis, A. G. (2017). Anàlisi semàntic d'imatges en xarxes socials amb tècniques de deep learning [Bachelor's thesis, Universitat Politècnica de Catalunya].
- Deniz, E. (2021). İçerik tabanlı bilimsel yayın öneri sisteminde benzerlik ölçümlerinin incelenmesi. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(1), 1-10. <https://dergipark.org.tr/tr/pub/dumf/issue/60884/838084>
- Elwin, G. R., Kiruthika, E., Paranitharan, M., & Kumar, R. K. M. (2024). Developing a robust and accurate food recommendation system using a hybrid filtering approach. *International Journal of Innovative Science and Research Technology*, 9(3). 596-602. <https://doi.org/10.38124/ijisrt/ijisrt24mar717>
- Filho, PH ve Wörndl, W. (2015). An adaptive electronic menu system for restaurants. In *Proceedings of the Conference on Recommender Systems*.
- Gavin-Smith, B., van Zutphen-Küßer, K. G., Bedsaul, J. R., & Monroy-Gomez, J. (2022). Precision nutrition for low- and middle-income countries – the why? *Sight and Life Magazine*, 36(1). <https://doi.org/10.52439/trj3376>
- Gupta, A., & Sharma, S. (2021). A review: Food recognition for dietary assessment/calorie measurement using machine learning techniques. *International Journal of Engineering Research and Technology*, 10(6). <https://doi.org/10.17577/IJERTCONV9IS08027>

- Hong, J., & Lee, H. (2018). Culinary recipe recommendation based on text analytics. *International Journal of Engineering and Technology*, 7(4.4), 324-327. <https://doi.org/10.14419/IJET.V7I4.4.19591>
- Imantho, H., Semineri, K. B., Damayanthi, E., Suyatma, N. E., Priandana, K., Ligar, B. W., & Semineri, A. U. (2024). *An intelligent food recommendation system for dine-in customers with non-communicable diseases history*. *Jurnal Keteknikan Pertanian*, 12(1), 140-152. <https://doi.org/10.19028/jtep.012.1.140-152>
- Ingle, A. S., Ade, A. N., Chandane, P. M., Bhagat, D. B., & Dolase, V. R. (2022). IoT based menu ordering system. *International Journal for Research in Applied Science and Engineering Technology*, 10(11), 1164-1168. <https://doi.org/10.22214/ijraset.2022.48164>
- Ju, X., Lo, F. P. W., Qiu, J., Shi, P., Peng, J., & Lo, B. (2022). MenuAI: Restaurant food recommendation system via a transformer-based deep learning model. *arXiv preprint arXiv:2210.08266*. <https://doi.org/10.48550/arXiv.2210.08266>
- Kraemer, K., & Bedsaul, J. R. (2022). Precision nutrition for public health. *Sight and Life Magazine*, 36(1). <https://doi.org/10.52439/lml15772>
- Lico, L., Enesi, I., & Meka, S. J. R. (2023). An end-to-end deep learning system for recommending healthy recipes based on food images. *International Journal of Advanced Computer Science and Applications*, 14(4), 401-410. <https://doi.org/10.14569/ijacsa.2023.0140401>
- Liu, L., Guan, Y., Wang, Z., Shen, R., Zheng, G., Fu, X., Yu, X., & Jiang, J. (2024). An interactive food recommendation system using reinforcement learning. *Expert Systems with Applications*, 250, 124313. <https://doi.org/10.1016/j.eswa.2024.124313>
- Lops, P., De Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In F. Ricci, L. Rokach, B. Shapira, & P. Kantor (Eds.), *Recommender systems handbook* (pp. 73-105). Springer. https://doi.org/10.1007/978-0-387-85820-3_3
- Lucas, J. (2020). Representation learning for recommender systems [Doctoral dissertation, Nanyang Technological University]. <https://doi.org/10.32657/10356/145694>
- Luo, Y., & Xu, X. (2019). Predicting the helpfulness of online restaurant reviews using different machine learning algorithms: A case study of Yelp. *Sustainability*, 11(19), 5254. <https://doi.org/10.3390/su11195254>
- Mahajan, P., & Mahajan, P. D. K. (2024). A systematic literature review of food recommender systems. *SN Computer Science*, 5(2), 237. <https://doi.org/10.1007/s42979-023-02537-y>

- Martí, A. (2017). Anàlisi semàntic d'imatges en xarxes socials amb tècniques de deep learning [Bachelor's thesis, Universitat Politècnica de Catalunya]. *Universitat Politècnica de Catalunya Repository*.
- Muruganandam, K., & Manipaul, S. (2023). A real time tourism recommender system using KNN and RBM approach. *International Journal for Research in Applied Science and Engineering Technology*, 11(5), 2527-2533. <https://doi.org/10.22214/ijraset.2023.51527>
- Murugeah, S. (2024). Enhancing efficiency and personalization in food and beverage service through AI: Future trends and challenges. *International Journal for Multidimensional Research Perspective*, 2(7), 162-168. <https://doi.org/10.61877/ijmrp.v2i7.162>
- Musto, C., Starke, A. D., Trattner, C., Rapp, A., & Giovanni, S. (2021). Exploring the effects of natural language justifications in food recommender systems. In *Proceedings of the 29th ACM Conference on User Modeling, Adaptation and Personalization* (pp. 202-213). <https://doi.org/10.1145/3450613.3456827>
- Nadeem, R., & Sivakumar, T. (2023). A systematic literature survey on recommendation system. *International Journal for Research in Applied Science and Engineering Technology*, 11(1), 828-835. <https://doi.org/10.22214/ijraset.2023.48828>
- Naresh, A., Yadav, B. P., Shaastry, M. S. S., & Bhaskar, K. (2020). Understanding user taste preferences for food recommendation. *International Journal of Engineering Research and Technology*, 9(6), 7-12. <https://doi.org/10.17577/IJERTV9IS060007>
- Nwachukwu, V. A., Ubaka, A. J., Adegboyega, M. O., Utazi, I. A., Chibudike, C. E., & Chibudike, H. O. (2021). *Advancements in food technology using artificial intelligence: Deep learning*. *Current Journal of Applied Science and Technology*, 40(18), 31-44. <https://doi.org/10.9734/CJAST/2021/V40I1831439>
- Ordovás, J. M., Ferguson, L. R., Tai, E. S., & Mathers, J. C. (2018). *Personalised nutrition and health*. *BMJ*, 361, bmj.k2173. <https://doi.org/10.1136/bmj.k2173>
- Pérez, S., Cuccuecha, M. C., Ramírez, J. F., & Crispín, J. (2018). Análisis, diseño y desarrollo de un sistema de recomendación basado en datos restauranteros de TripAdvisor y Foursquare. *Research on Computing Science*, 147(5), 185-196. <https://doi.org/10.13053/RCS-147-5-16>
- Rajabpour, E., Mohammadighavam, A., Naserasadi, A., & Estilayee, M. (2018). TFR: A tourist food recommender system based on collaborative filtering. *International Journal of Computer Applications*, 181(26), 1-6. <https://doi.org/10.5120/IJCA2018917695>
- Ricci, F., Rokach, L., & Shapira, B. (2015). *Recommender systems handbook* (2nd ed.). Springer. <https://doi.org/10.1007/978-1-4899-7637-6>

- Rodrigues, M. S., Fidalgo, F., & Oliveira, Â. (2023). RecipeIS—Recipe recommendation system based on recognition of food ingredients. *Applied Sciences*, 13(13), 7880. <https://doi.org/10.3390/app13137880>
- Romero-Tapiador, S., Tolosana, R., Morales, A., Fierrez, J., Vera-Rodriguez, R., Espinosa-Salinas, I., Freixer, G., Carrillo de Santa Pau, E., Ramírez de Molina, A., & Ortega-Garcia, J. (2022). AI4Food-NutritionDB: Food image database, nutrition taxonomy, and recognition benchmark. *arXiv preprint arXiv:2211.07440*. <https://doi.org/10.48550/arXiv.2211.07440>
- Salvador, A., Drozdal, M., Giro-i-Nieto, X., & Romero, A. (2019). Inverse cooking: Recipe generation from food images. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp. 10453-10462). <https://doi.org/10.1109/CVPR.2019.01070>
- Sanz, D. S., & Agrawal, A. (2014). Automated menu recommendation system based on past preferences. *International Journal of Advanced Computer Science and Applications*, 5(7), 78-84. <https://doi.org/10.14569/IJACSA.2014.050711>
- Sharma, S., Baishya, K., Pandey, M., & Rautaray, S. S. (2023). Hybrid product recommendation system using popularity-based and content-based filtering. In *Proceedings of the 2023 International Conference on Data Science and AI* (pp. 564-569). IEEE. <https://doi.org/10.1109/icdsaai59313.2023.10452564>
- Soma, S., & Dyapur, S. (2023). IoMT assisted monitoring and voice-based food recommendation system using deep learning model. In M. Seetha, S. K. Peddoju, V. Pendyala, & V. V. S. S. S. Chakravarthy (Eds.), *Intelligent Computing and Communication: Proceedings of the International Conference on Intelligent Computing and Communication (ICICC 2022)* (Advances in Intelligent Systems and Computing, Vol. 1447, pp. 491-501). Springer. https://doi.org/10.1007/978-981-99-1588-0_42
- Suruthi, P., Varsa Sukirthana, S., & Raguvaran, S. (2019). Recommendation of food tourism using artificial neural network – A survey. *International Journal of Advance Research, Ideas and Innovations in Technology*, 5(3), 1234-1238.
- Tangpong, T., Leanghirun, S., Hansuebsai, A., & Takano, K. (2021). A food recommender based on frequent sets of food mining using image recognition. In *Artificial intelligence in food industry*, (pp. 97-186). IntechOpen. <https://doi.org/10.5772/INTECHOPEN.97186>
- Thakur, N., & Sharma, T. (2024). Exploring the convergence of artificial intelligence in gastronomy: Enhancements in food and wine pairing, production, and consumer preferences through AI-driven technologies. *International Journal for Multidimensional Research Perspective*, 2(4), 134-142. <https://doi.org/10.61877/ijmrp.v2i4.134>
- Thongsri, N., Warintarawej, P., Chotkaew, S., & Saetang, W. (2022). Implementation of a personalized food recommendation system based on collaborative filtering and knapsack method. *Indonesian Journal of Electrical Engineering*

and Computer Science, 12(1), 630-638. <https://doi.org/10.11591/ijece.v12i1.pp630-638>

- Tsolakidis, D., Gymnopoulos, L. P., & Dimitropoulos, K. (2024). Artificial intelligence and machine learning technologies for personalized nutrition: A review. *Informatics*, 11(3), 62. <https://doi.org/10.3390/informatics11030062>
- Vijjali, R., Bhageria, D., Tamhane, A., Mithun, T. M., & Sathyanarayana, J. (2022). FoodNecNet: Simplifying online food ordering with contextual food combos. In *Proceedings of the 2022 ACM Conference on Information Technology for Social Good* (pp. 93-98). <https://doi.org/10.1145/3493700.3493728>
- Yaiprasert, C., & Hidayanto, A. N. (2024). AI-powered in the digital age: Ensemble innovation personalizes the food recommendations. *Journal of Open Innovation: Technology, Market, and Complexity*, 10(2), 100261. <https://doi.org/10.1016/j.joitmc.2024.100261>
- Yu, B., Zhou, J., Zhang, Y., & Cao, Y. (2017). *Identifying restaurant features via sentiment analysis on Yelp reviews* [Preprint]. arXiv. <https://doi.org/10.48550/arXiv.1709.08698>
- Zeevi, D., Korem, T., Zmora, N., Israeli, D., Rothschild, D., Weinberger, A., Ben-Yacov, O., Lador, D., Avnit-Sagi, T., Lotan-Pompan, M., Suez, J., Mahdi, J. A., Matot, E., Malka, G., Kosower, N., Rein, M., Zilberman-Schapira, G., Dohnalová, L., Pevsner-Fischer, M., Bikovsky, R., Halpern, Z., Elinav, E., & Segal, E. (2015). Personalized nutrition by prediction of glycemic responses. *Cell*, 163(5), 1079-1094. <https://doi.org/10.1016/j.cell.2015.11.001>
- Zioutos, K., Kondylakis, H., & Stefanidis, K. (2023). SHARE: A framework for personalized and healthy recipe recommendations. In *Proceedings of the EDBT/ICDT 2023 Joint Conference Workshops*, Ioannina, Greece.
- Zitouni, H., Bouchelik, K., Saidi, R., & Çekkai, N. (2020). Personalized menu: A new contextual collaborative recommender system. In *Proceedings of the 2020 International Conference on Advanced Aspects of Software Engineering* (pp. 111-118). <https://doi.org/10.1109/ICAASE51408.2020.9380111>
- Zou, H., Yu, G., & Zhang, Z. (2020). GCFA: Graph neural networks on collaborative filtering recommendation via attention mechanism. In *Proceedings of the 2020 IEEE International Conference on Big Data* (pp. 1901-1906). <https://doi.org/10.1109/ICBDA49040.2020.9101190>