

Tüketicilerin Özel Günlerde Satın Alma Davranışlarının Rastgele Orman Yöntemiyle İncelenmesi

Mert Ersen¹

Melik Masarifoğlu²

Kemal Cem Söylemez³

Özet

Bu çalışma, özel günlerin perakende satışlar üzerindeki etkisini analiz ederek, firmaların stok ve üretim planlamalarında karşılaştıkları belirsizlikleri azaltmak amacıyla makine öğrenmesi temelli bir satış tahmin modeli geliştirmeyi amaçlamaktadır. Özellikle Yılbaşı, Kara Cuma ve Noel gibi dönemlerde yaşanan ani talep artışları, doğru tahmin modelleri kullanılmadığında işletmeler için operasyonel riskler doğurabilmektedir. Bu kapsamda, Amazon'un OLED televizyon satış verileri kullanılarak Rastgele Orman algoritmasıyla bir tahmin modeli oluşturulmuş ve bu modelin özel günlerdeki satış davranışlarını anlamada nasıl kullanılabileceği gösterilmiştir. Çalışmanın bulguları, makine öğrenmesi tabanlı modellerin satış tahmin süreçlerinde etkin bir şekilde kullanılabileceğini ortaya koymakta ve işletmelerin veri temelli karar alma süreçlerine katkı sunmaktadır.

- 1 Dr. Bağımsız Araştırmacı, mert_9034@hotmail.com, ORCID ID: <https://orcid.org/0000-0001-5643-4690>
- 2 Dr. Bağımsız Araştırmacı, memasarif@hotmail.com, ORCID ID: <https://orcid.org/0000-0001-8910-0486>
- 3 Dr. Bağımsız Araştırmacı, kemalcemsoylemez@gmail.com, ORCID ID: <https://orcid.org/0000-0003-1607-7208>

1. Giriş

Satış promosyonu, bir üreticinin tüketicileri belirli bir markayı satın almaya yönlendirmek ve satış ekibini daha agresif bir şekilde satış yapmaya teşvik etmek amacıyla sunduğu her türlü teşvik olarak tanımlanabilir (Yemez & Sağır, 2021). Bu promosyonlar, tüketicileri alım yapmaya motive etmek için pazarlama stratejilerinin önemli bir parçasını oluşturur ve bir ürünün gelirene önemli ölçüde katkı sağlayabilir (Shimp, 2003). Bu bağlamda, tüketiciler, daha az harcama yapma veya akıllı bir alışveriş yapan birey olma duygusunu yaşamak amacıyla promosyonlu fiyatlara olumlu tepki verirler (Lennon vd., 2011).

Tüketicilerin ilgisini çekmek ve reklamı yapılan ürünlere yönlendirmek amacıyla, “Süper Fırsat”, “Özel Gün İndirimi”, “Büyük Tasarruf” gibi promosyon ifadeleri sıklıkla kullanılmaktadır. Bu tür ifadeler, aynı zamanda tüketicilerin teklife ilişkin algılarını şekillendirmeye yönelik de etkili bir araçtır. Pazarlamacılar, tüketicilerin satın alma davranışlarını artırmak için genellikle kısa süreli ve aralıklı kampanyalar düzenlerler. Bu tür teklifler, genellikle yıl boyunca sürekli olarak sunulmaz ve belirli özel günlerde (anneler günü, babalar günü, yılbaşı, sevgililer günü, bayramlar vb.) daha yoğun olarak karşımıza çıkar. Bu strateji, yeni müşteri kazanımını artırırken, mevcut müşterilerin de daha fazla alışveriş yapmalarına yol açar (Karaca vd., 2018).

Promosyonlar hem fiyatları düşürerek hem de duygusal etkiler yoluyla tüketicilerin ürün satın alırken elde edeceği ekonomik faydayı ciddi şekilde değiştirebilir (Raghubir vd., 2004). Promosyon teklifleri hem parasal hem de parasal olmayan kazançlar ve kayıplar içerebilir. Örneğin, indirimli bir ürün almak maddi bir kazanç sağlarken, tüketici daha az para harcarsa da, o ürünü bulmak ve almak için harcanan zaman ve gösterilen çaba maddi olmayan bir kayıp oluşturur (Fogel ve Thornton, 2008). Ayrıca, promosyonlar, bilinçli alışveriş yapan tüketicilerde olumlu duygular uyandırırken, uygun olmayan zamanlarda alışveriş yapmak gibi maddi olmayan kayıplara da yol açabilir. Bu tür “iki ucu keskin” etkiler, özellikle Black Friday gibi etkinliklerde daha belirgindir. Örneğin, sabahın erken saatlerinde alışveriş yapmak ya da stokların tükenmesi nedeniyle promosyonlu ürünleri bulamamak sinir bozucu olabilir (Lennon vd., 2011). Bu yüzden, indirim peşinde koşan tüketiciler çoğu zaman beklediklerinden fazla çaba harcar ve sonunda kazandıkları paradan çok, yitirdikleri zaman ve enerjinin etkisini hisseder. Özellikle uzun kuyruklar, tıklım tıklım mağazalar ya da çevrim içi platformlarda yaşanan yoğunluk, promosyonun cazibesini gölgede bırakabilir.

Tüketici davranışının altında yatan nedenlerin anlaşılması, işletmeler için son derece önemli olup, bu konuda çeşitli modeller geliştirilmiştir. Farklı disiplinler, tüketicilerin bir ürün ya da hizmet satın alma kararı verirken hangi faktörlerin etkili olduğunu açıklamaya çalışmışlardır. Örneğin, iktisat alanına göre tüketiciler, satın alma kararlarında faydalarını maksimize etmeyi hedefler. Ancak bu açıklama, psikoloji, sosyoloji ve antropoloji gibi disiplinler tarafından genellikle kabul edilmez. Çünkü bu disiplinler, bireyin deneyimleri, motivasyonları, algıları, kişilik özellikleri, sosyal grupları, aile yapısı ve inançları gibi faktörlerin göz ardı edildiğini belirtir. Oysa, tüketicinin karar verme sürecinde bu özelliklerin ve aidiyetlerinin de önemli bir rolü vardır (Mucuk, 1998). Pazarlama ve satış faaliyetleri de bu nedenle yalnızca ekonomik gerekçelere değil, tüketicinin davranışsal ve psikolojik özelliklerine de odaklanmak zorundadır (Uraz, 1978). Bu çerçevede pazarlama disiplini, tüketici kararlarını açıklamak için “kara kutu” kavramını kullanır. Çünkü satın alma süreci, birçok faktörün etkileşimiyle şekillenen karmaşık bir yapıya sahiptir ve bu sürecin tam olarak nasıl işlediği hâlâ net olarak bilinmemektedir. Kara kutu, bu bilinmezliği ve öngörülemezliği temsil eder (Böge, 1994).

Tüketici davranışı, yalnızca yukarıda belirtilen faktörlerle şekillenmez. İşletmelerin pazarlama faaliyetleri ve çabaları da bu davranış üzerinde önemli bir etkiye sahiptir. Özellikle özel gün ve haftaların tüketim üzerindeki etkileri, bu açıdan ele alınmalıdır. Tüketici davranışları, genellikle “kara kutu” olarak kabul edilse de, bu davranışların arkasında insanın zihinsel, duygusal ve fiziksel tepkileri ile ihtiyaçları yatar. Pazarlama faaliyetleri, bu yönleri uyandırarak tüketicilerin satın alma davranışını tetiklemeyi hedefler. Özel günler yaklaştıkça artan yoğun ve çoğu zaman agresif reklam kampanyalarının, en rasyonel tüketicileri bile etkilediği görülmektedir. Bu sayede işletmeler, söz konusu günleri adeta toplumsal bir tüketim çılgınlığına dönüştürebilmektedir. Tüketici davranışlarında duyguların ne denli güçlü bir rol oynadığının fark edilmesi, pazarlama stratejilerinin de bu duygular üzerine yoğunlaşmasına yol açmıştır. Sevgi, özlem, hatırlanma gibi temalar üzerinden verilen mesajlar aracılığıyla daha fazla tüketim teşvik edilmekte, böylece tüketim kültürünün yaygınlaşması ve bireylerin zamanla birer “tüketim toplumu” üyesine dönüşmesi kolaylaştırılmaktadır (Bayuk, 2009).

Günümüzde üretim süreçlerinin dijitalleşmesiyle birlikte tüketim davranışları da önemli ölçüde değişmiş, özellikle çevrim içi alışverişin yaygınlaşması tüketim hacmini ciddi oranda artırmıştır. Tüketicilerin yalnızca tek bir tıklamayla alışveriş yapabilmesi, bu artışın başlıca nedenlerinden biridir. Bu hızlı tüketim ortamında, satışların doğru biçimde tahmin edilmesi ve bu tahminlere dayalı olarak stok yönetimi ile üretim planlamasının yapılması

büyük önem taşımaktadır. Sağlıklı tahminler olmaksızın, işletmelerin gelir-gider dengesini öngörmeleri neredeyse imkânsızdır. Üretim planlama, satın alma, satış ve pazarlama gibi birçok departman, kararlarını bu öngörüler doğrultusunda şekillendirir (Nacar ve Erdebilli, 2021). Uzun veya kısa vadeli satış tahminlerinin doğru yapılmaması, müşteri memnuniyetsizliğine, para kaybına, hammadde eksikliğine ve benzeri sorunlara yol açabilir. Ayrıca, stratejik planlama sürecinde tahmin eksikliği, işletmenin hedef ve politikalarını belirlemesini engeller. Bu durum sadece işletmenin kendisini değil, aynı zamanda tedarik zincirinde yer alan üreticiler, perakendeciler, tedarikçiler ve nihai tüketiciler dâhil tüm paydaşları olumsuz etkileyebilir. Olası tahmin hataları zincirleme biçimde tüm süreci sekteye uğratabilirken, doğru yapılan tahminler yalnızca işletme kârlılığını artırmakla kalmaz, aynı zamanda tüm tedarik zincirinde verimlilik sağlar. Böylelikle işletmeler sektördeki rekabetçiliğini korurken, tedarik zincirindeki diğer paydaşlar için de sürdürülebilir bir kârlılık ortamı yaratılmış olur (Nacar ve Erdebilli, 2021; Yücesan, 2018).

Bununla birlikte, kapasite planlaması, işletmeler için kritik bir kavramdır çünkü işletmeler yalnızca sahip oldukları kapasiteye göre üretim yapabilirler. Bu nedenle, kârlı olabilmek için satışlarını da bu kapasiteye uygun şekilde yönetmek zorundadır. İşletmelerin sahip oldukları kapasiteyi en verimli şekilde kullanmaları gerekir ve bu da doğru bir kapasite yönetimiyle mümkündür. Kapasite planlaması, işletmelerin belirli bir zaman diliminde kullanacakları kapasiteyi belirlemek için yapılır. Bu planlamanın hatalı yapılması, işletmeleri fazla veya yetersiz kapasite sorunuyla karşı karşıya bırakabilir. Böyle bir durumda, işletmenin verimliliği ve karlılığı beklenen seviyeye ulaşamayacaktır. Kapasite planlaması yapılırken, mevcut kapasitenin yanı sıra, işletmenin tahmin edilen satış miktarları da dikkate alınmalı ve planlama bu verilere göre yapılmalıdır. Bu nedenle, güvenilir satış tahminleri, işletmelere pek çok açıdan fayda sağlar. Güvenilir satış tahminleri, yalnızca kapasite planlamasını değil; iş stratejisinin oluşturulmasını, maliyetlerin azaltılmasını ve kârın artırılmasını da doğrudan etkiler. Dolayısıyla satış tahminleri, işletmenin büyümesi ve rekabetçi bir pozisyon elde etmesi açısından karar alma süreçlerinde temel bir parametre olarak öne çıkar (Chen vd., 2010).

Uygulamada, birçok işletme satış tahminini doğrudan yapma yoluna gitmektedir. Ancak, bu yaklaşım yerine satış tahminlerinin; pazar potansiyeli ve işletmenin satış potansiyeline dair önceden yapılacak değerlendirmelere dayandırılması daha sağlıklı sonuçlar verecektir. Pazarlama planlaması işletmenin planlama işlevinin önemli bir aşamasını oluşturmakla birlikte

işletmenin genel stratejisi diğer departmanların faaliyetleri ile uyum içinde olmak zorundadır (Eroğlu, 1996).

Satış tahmini yapmak, tüketici davranışlarının belirsizliği ve özelleştirilmiş ürünlere artan ilgi nedeniyle oldukça zorlaşmıştır. Günümüzde, herhangi bir yöntem kullanılmadan büyük ölçekli satış tahminleri yapmak işletmeler açısından neredeyse imkânsızdır. Geleneksel yöntemler, büyük veri kümeleriyle başa çıkmakta yetersiz kalmakta; esneklikten uzak olmaları ve özel durumları göz ardı etmeleri sebebiyle doğru tahminler üretmekte zorlanmaktadır. Bu noktada, gittikçe yaygınlaşan yapay zekâ teknolojileri bu zorlukların çözümünde kullanılmaya başlamıştır (Acı ve Doğanşoy, 2022; Erol ve İnkaya, 2024). Yapay zekanın yalnızca robotik ya da telekomünikasyon gibi alanlarda kullanıldığına dair yaygın bir önyargı bulunsun da bu anlayış giderek değişmekte ve yapay zekâ, veriyle ilgili tüm alanlarda yaygınlaşmaktadır. Bu dönüşümün önemli bir parçası da makine öğrenmesidir (Nacar ve Erdebili, 2021). Makine öğrenmesi, pek çok mühendislik problemine hızlı ve etkili çözümler sunma potansiyeline sahiptir. Henüz gelişmekte olan bir alan olması nedeniyle literatürde çeşitli varsayımlar yer almaktadır. Bununla birlikte, birçok işletme veri biliminin sunduğu avantajların, geleneksel yöntemlerden daha hızlı ve isabetli olduğunu henüz fark etmiş değildir. Bu çalışma, söz konusu farkındalığın artmasına katkı sağlayarak işletmelere yol gösterici olmayı amaçlamaktadır.

Bu çalışmada Rastgele Orman yöntemini kullanılarak satış tahmini için model oluşturulmuş ve tahmin yöntemlerinde makine öğrenmesi algoritmalarının kullanılmasının gerekliliği üzerinde durulmuştur.

Çalışmanın ikinci ve üçüncü bölümünde sırasıyla makine öğrenmesi ve satış tahmini konuları ile ilgili literatür araştırması yapılmıştır. Dördüncü bölümde metod kısmında rasgele orman yöntemi anlatılmış ardından beşinci bölümde Amazon'daki OLED televizyon satış verileri örnek bir satış tahmini çalışması gerçekleştirilmiştir. Son bölümde ise tartışma ve sonuç bölümüne yer verilmiştir. Çalışmada özellikle özel günlerde yetersiz stok nedeniyle işletmelerin uğradıkları zararın gösterilmesi amaçlanmıştır. Makine öğrenmesi yöntemleriyle doğru satış tahminlerinin yapılmasının işletmeler için çok önemli olduğu gösterilmeye çalışılmıştır.

2. Makine Öğrenmesi

Dijitalleşen dünyada; nesnelerin interneti (IoT), bulut bilişim, büyük veri (Big Data), siber güvenlik, yapay zekâ ve makine öğrenmesi gibi kavramlar giderek daha fazla önem kazanmaktadır. Özellikle büyük veri kavramı, günümüz bilgi yönetimi açısından belirleyici bir rol oynamaktadır. Geçmişte

veriler fiziksel ortamda, defterler aracılığıyla kaydedilirken; günümüzde veri miktarının katlanarak artması, bu yöntemi sürdürülemez hâle getirmiştir. Verinin bu denli hızlı çoğalması, büyük veri yığınları içinden anlamlı ve doğru bilgilere ulaşmayı oldukça karmaşık bir süreç hâline getirmiştir. Bu noktada devreye giren veri madenciliği, büyük veri setleri içerisindeki örüntüleri, eğilimleri ve anlamlı ilişkileri ortaya çıkarmayı amaçlar. Bu sayede, veri yığınları sadece depolanan bir içerik olmaktan çıkıp, stratejik kararlar için kullanılabilir bilgiye dönüşür (Savaş vd., 2012).

Veriden anlamlı bilgi çıkarılması, yalnızca mevcut durumu analiz etmeye değil, aynı zamanda gelecekteki olaylara dair öngörülerde bulunmaya da olanak tanır. Bu öngörü süreci, özellikle karar alma süreçlerinde büyük önem taşır. İnsanlar, yaşam deneyimleri ve eğitimleri doğrultusunda tahminlerde bulunabilir; ancak karar verirken duygusal etkenlerin devreye girmesi, rasyonel seçimler yapmayı zorlaştırabilir (Tosunoğlu vd., 2021). Ayrıca, veri miktarının fazla olduğu durumlarda bazı önemli ayrıntıların gözden kaçması olasıdır ve bu da yanlış kararlarla sonuçlanabilir. Buna karşın, eğitilmiş makineler tüm verileri hızlı bir şekilde analiz edip, çok kısa bir sürede mantıklı kararlar alabilir. Makine öğrenmesinde, insan düşünme biçimini ve karar alma yeteneğini doğru bir şekilde modellemek oldukça önemlidir (İnik ve Ülker, 2017). Bu bağlamda makine öğrenmesi, insan zekâsını taklit etmeye yönelik hesaplama algoritmalarının bir dalı olarak tanımlanmakta; aynı zamanda veriye dayalı problemlerin uygun algoritmalar aracılığıyla modellenmesini ifade etmektedir (El-Naqa ve Murphy, 2015; Atalay ve Çelik, 2017). Bununla birlikte, büyük veri; çeşitlilik, hız ve hacim açısından önemli zorluklar doğurur (Suthaharan, 2014). Makine öğrenmesi algoritmaları, bu büyük ve karmaşık veri yığınlarını doğru şekilde sınıflandırarak söz konusu zorlukların üstesinden gelmede etkili çözümler sunmaktadır (Ersen vd., 2022; Keskin, 2025).

Makine öğrenmesi ilk kez 1959 yılında, Arthur Samuel tarafından bir dama oyununu analiz etmek amacıyla kullanılmıştır. Samuel, makine öğrenmesini bilgisayarlara açıkça programlanmaksızın öğrenme yetisi kazandıran bir araştırma alanı olarak tanımlamıştır (Samuel, 1959).

1970'li yıllarda, Japonya'da bu alanda yapılan araştırmaların ardından ilk insansı robot olan Wabot-1 geliştirilmiştir (İnal, 2021). 1980'li yıllarda ise istatistiksel yöntemler ve veri madenciliğindeki ilerlemeler, makine öğrenmesinin teorik temellerini güçlendirmiş; bu dönemde uzman sistemler ve karar destek sistemleri gibi yapay zekâ uygulamaları yaygınlık kazanmaya başlamıştır (Foote, 2021).

1980'lerden itibaren hızla gelişen makine öğrenmesi, 1990'lı yıllarda veriye dayalı yöntemlere odaklanmaya başlamıştır. Bu dönemin en dikkat çekici gelişmelerinden biri, IBM tarafından geliştirilen 'Deep Blue' adlı satranç programının, 1997 yılında Dünya Satranç Şampiyonu Garry Kasparov'u yenerek kamuoyunun büyük ilgisini çekmesidir (Campbell vd., 2002).

1990'lar ve 2000'ler, makine öğrenmesinin hızla geliştiği ve uygulama alanlarının genişlediği dönemler olmuştur. Bu yıllarda büyük veri kavramının ortaya çıkması, veri erişimini önemli ölçüde artırmış; bu da makine öğrenmesi algoritmalarının daha verimli çalışmasına olanak tanımıştır (Foote, 2021). Aynı dönemde destek vektör makineleri, rastgele ormanlar ve derin öğrenme gibi birçok önemli yöntem geliştirilmiş, alandaki ilerlemeye ivme kazandırmıştır.

2010'lu yıllarda ise işlem gücünü artıran donanımların yaygınlaşması, veri akışının daha da hızlanması ve derin öğrenme modellerinin evrilmesiyle birlikte makine öğrenmesinde büyük bir sıçrama yaşanmıştır. Özellikle derin öğrenme ve sinir ağı tabanlı yaklaşımlar, görüntü tanıma, doğal dil işleme ve metin analizi gibi alanlarda çarpıcı başarılar elde etmiştir. Bu gelişmeler, endüstriden sağlığa, otomasyondan eğitime kadar pek çok sektörde köklü değişimlere yol açmıştır (Koch, 2022).

Makine öğrenmesi, temelde olasılık, istatistik ve optimizasyon gibi matematiksel disiplinlere dayanır. Bu süreçte, geçmiş verilere dayalı olarak bir model oluşturulur ve bu model aracılığıyla geleceğe yönelik tahminler yapılması hedeflenir. Bu özellik, makine öğrenmesini diğer yazılım mühendisliği yöntemlerinden ayıran önemli bir farktır. Geleneksel yöntemlerde, yazılım geliştiricilerinin veri setlerini manuel olarak inceleyip belirli kurallar ve kalıplar oluşturması beklenir. Ancak bu yaklaşım, genellikle geliştiricinin önyargılarına dayanır ve gerçekçi olmayan sonuçlar doğurabilir (Grigorev, 2020).

Makine öğrenmesi, giderek daha geniş bir alanda uygulanmakta ve bu yayılımın önümüzdeki yıllarda da artarak devam etmesi beklenmektedir. Bu eğilimin birçok nedeni vardır. İlk olarak, sembolik makine öğrenmesi, hesaplamalı öğrenme teorisi, sinir ağları, istatistik ve örüntü tanıma gibi farklı araştırma alanlarında çalışan topluluklar zamanla birbirlerini keşfetmiş ve aralarında iş birlikleri gelişmeye başlamıştır. Bu disiplinler arası etkileşim, makine öğrenmesinin gelişimini hızlandırmıştır. İkinci olarak, makine öğrenmesi yöntemleri yalnızca konuşma tanıma, yüz tanıma, el yazısı tanıma ve tıbbi tanı gibi geleneksel problemlere değil; aynı zamanda bilgi keşfi, doğal dil işleme, robot kontrolü ve birleşik optimizasyon gibi daha yeni

ve karmaşık problem alanlarına da başarıyla uygulanmaktadır (Dietterich, 1997)

Makine öğrenmesinin temel türleri, gözetimli ve gözetimsiz öğrenme olarak ikiye ayrılır. Gözetimli öğrenme, daha önce belirlenmiş doğru sınıflandırmalara dayalı olarak, veri kaynağından örneklerin eğitilmesini sağlar. Gözetimsiz öğrenme ise, etiketlenmemiş verilerdeki gizli desenleri tespit etmek için kendi kendini organize eden sinir ağlarını kullanmayı öğrenir. Gözetimsizlik, çözümü değerlendirecek bir hata sinyali olmadan bilgi öğrenme ve organizasyonu yapabilme yeteneğini ifade eder (Sathya ve Abraham, 2013). Gözetimli öğrenme ise, sınıflandırma ve regresyon olmak üzere iki alt türe ayrılır. Veri setine bağlı olarak farklı algoritmaların kullanılması mümkündür (Nacar ve Erdebilli, 2021).

3. Satış Tahmininde Makine Öğrenmesi Uygulamaları

Satış tahminleri, tedarik zincirindeki önemli araştırma konularından biridir (Ingle vd., 2021). Bu alanda kullanılan yöntemler istatistiksel yöntemler ve yapay zekâ yöntemleri olmak üzere iki başlıkta incelenebilir (Ingle vd., 2021). İstatistiksel yöntemler arasında doğrusal regresyon, hareketli ortalama, ağırlıklı ortalama, üstel düzeltme ve ARIMA gibi teknikler bulunmaktadır (Ingle vd., 2021; Acı ve Doğanşoy, 2022; Erol ve İnkaya, 2024). Yapay zekâ yöntemleri ise, makine öğrenmesi ve derin öğrenme olmak üzere iki ana gruba ayrılabilir. Makine öğrenmesi yöntemleri, k-en yakın komşuluk, destek vektör makineleri, karar ağaçları ve yapay sinir ağları gibi teknikleri içerirken; derin öğrenme yöntemleri arasında çok katmanlı derin sinir ağları (DNN), evrimsel sinir ağları (CNN), tekrarlayan sinir ağları (RNN) ve uzun kısa süreli bellek ağları (LSTM) yer almaktadır (Ingle vd., 2021; Acı ve Doğanşoy, 2022; Erol ve İnkaya, 2024).

Bir araştırmaya başlamadan önce, önceki çalışmaların gözden geçirilmesi büyük önem taşımaktadır. Bu, yapılacak olan çalışmanın mevcut literatüre uygun olmasını ve daha önceki araştırmalarla tutarlı bir şekilde desteklenmesini sağlar. Satış tahminlerine yönelik yapılan literatür taramaları, veri madenciliği tekniklerinin sıkça kullanıldığını ortaya koymaktadır. Çünkü talep tahmini, satış tahminiyle doğrudan ilişkili bir kavramdır ve bu nedenle araştırmalarda “talep tahmini” ve “satış tahmini” kavramları genellikle birbirinin yerine kullanılmıştır.

Carlson ve Umble (1980), Amerika’da beş farklı otomobil segmentinde (standart ve lüks otomobiller) beş yıllık talep tahminlerini regresyon analizi kullanarak yapmışlardır. Çalışmada, bağımsız değişkenler olarak; benzin fiyatları, benzin kıtlığının piyasa üzerindeki etkisi, taşıt fiyatları, tüketici gelir

düzeyleri ve sektördeki işçi grevleri gibi faktörler incelenmiştir (Carlson ve Umble, 1980).

Gavcar vd. (1999), Türkiye’deki kâğıt ve karton talebini tahmin etmek amacıyla bir çalışma yapmışlardır. Çalışmada, kâğıt ürünleri, ithalat ve ihracat hacimleri, eşya fiyat endeksi, gayrisafi milli hasıla ve nüfus gibi değişkenler analizde kullanılmıştır. Talep tahmini, çoklu regresyon analiziyle yapılmış ve modeldeki değişkenler arasındaki ilişkiler korelasyon analizi ile incelenmiştir. Sonuç olarak, 21. yüzyılda talep edilecek kâğıt miktarına yönelik bir tahmin yapılmıştır (Gavcar vd., 1999).

Aksel (2000), İstanbul ve Türkiye genelinde uzun dönem elektrik talep tahmini yapmıştır. 2001, 2003 ve 2005 yıllarına ait yük enerji tüketim değerlerini tahmin etmek için çok değişkenli regresyon analizi ve geriye yayılım algoritmasına sahip, iki gizli katmanlı yapay sinir ağı yöntemlerini kullanmıştır. Çalışmada kullanılan değişkenler; nüfus, kişi başına düşen gayri safi milli hâsıla, gelişim hızı, sanayi üretim endeksi, petrol varil fiyatı ve elektrik enerjisi birim satış fiyatı olmuştur. Elde edilen tahminler, çok değişkenli regresyon analizi ve geriye yayılım algoritmasının sonuçları, ağırlıklı ortalama yöntemiyle tek bir sonuca dönüştürülmüştür (Aksel, 2000).

Efendigil vd. (2009), beyaz eşya tedarik zinciri için talep tahmini yapmışlardır. 24 aylık veri, her perakendeciden anket yoluyla toplanmış ve bu veriler 79 eğitim ve 17 test verisi olarak ikiye ayrılmıştır. Çalışmada kullanılan değişkenler; ürün fiyatı, ürün kalitesi ve promosyonlar olmuştur. Tahmin yöntemi olarak Bulanık Mantık ve Yapay Sinir Ağları kullanılmıştır. Çalışmanın sonucunda, Bulanık Mantık uygulamasında test edilen Gauss üyelik fonksiyonunun daha etkili bir çözüm sunduğu gözlemlenmiştir (Efendigil vd., 2009).

Demirel (2009), elektrik enerjisi talep tahmini üzerine bir tez çalışması yapmıştır. Çalışmasında kullanılan değişkenler; Gayri Safi Milli Hâsıla, üretilen enerji, tüketilen enerji, nüfus ve kurulu güç verileri olmuştur. Tahmin edilen sonuçlar, ilgili kurumun öngörü değerleriyle karşılaştırılmıştır (Demirel, 2009).

Yücesoy (2011), kâğıt talebi tahmini üzerine bir çalışma yapmıştır. Bu çalışmada Yapay Sinir Ağları (YSA) ve Çoklu Doğrusal Regresyon modelleri kullanılmıştır. Çalışmada yer alan değişkenler; üretim miktarı, ithalat hacmi, kâğıt basım sanayi toptan fiyat endeksi, GSYH, nüfus verileri ve okuryazarlık oranıdır. Tahmin sonuçları incelendiğinde, YSA modeli %98,89 başarı oranı ile öne çıkarken, regresyon modelinin başarı oranı ise %61,89 olarak belirlenmiştir (Yücesoy, 2011).

Demirbaş (2011), kombi satış adetlerini tahmin etmeyi amaçlayan bir çalışma yapmıştır. Çalışmanın hedefi, talep tahmini yaparak müşteri kaybı riskini azaltmaktır. Tahminler, zaman serisi analizi yöntemiyle gerçekleştirilmiştir ve 2008-2010 yılları arasındaki satış verileri kullanılmıştır. Araştırma sonuçlarına göre, en başarılı tahminlerin en küçük kareler tahmincileri tarafından yapıldığı bulunmuştur (Demirbaş, 2011).

Karahan (2011), talep tahmini yapmak amacıyla Yapay Sinir Ağları (YSA) kullanmıştır. Modelde, bir gizli katmanlı, ileri beslemeli ve geri yayılım gösteren bir sinir ağı yapılandırılmıştır. Çalışmada 2004-2010 yılları arasındaki veriler kullanılmıştır. Oluşturulan modelde beş girdi değişkeni ve bir çıktı değişkeni bulunmaktadır. Çıktı değişkeni, kuru kayısı talebini tahmin etmektedir. Bağımsız değişkenler arasında geçmiş talep verileri, tarih, döviz kuru, aylık ortalama fiyat, pazar sayısı ve mevsimsel etkiler yer almıştır. Ağın eğitimi için momentum ve öğrenme katsayısı 0,1 olarak belirlenmiştir. Yapılan tahminlerin doğruluğu %86 olarak bulunmuş ve gerçek verilerle tahmin edilen değerler arasındaki farkın oldukça düşük olduğu gözlemlenmiştir. Çalışmanın amacı, tahmin edilen verilere dayanarak firmanın üretim planlamasını önceden yapabilmesidir (Karahan, 2011).

Hicham ve Bouhorma (2012), ambalaj satışlarını tahmin etmek amacıyla bir çalışma yapmıştır. Çalışmada kullanılan değişkenler; imalat tüketici endeksi, rekabet endeksi ve geçmiş satış verileridir. Tahminler, Delphi yöntemi ve Yapay Sinir Ağları (YSA) ile gerçekleştirilmiştir. Sonuçlar, MAPE ve RMSE oranlarıyla değerlendirilmiş ve Delphi yönteminin YSA yöntemine kıyasla daha başarılı sonuçlar verdiği sonucuna varılmıştır (Hicham ve Bouhorma, 2012).

Karaatlı vd. (2012), otomobil satış tahmini yapmak için Yapay Sinir Ağları (YSA) yöntemini kullanmışlardır. Veri seti, Ocak 2007 ile Haziran 2011 arasındaki aylık verilere dayanmaktadır. Çalışmada kullanılan değişkenler; gayri safi yurt içi hasıla (GSYH), reel kesim güven endeksi (RKGE), yatırım harcamaları (YH), tüketim harcamaları (TH), tüketici güven endeksi (TGE), döviz kuru gibi bağımsız değişkenler ile satılan toplam otomobil sayısı bağımlı değişken olarak alınmıştır. Modelin tahminleri Yapay Sinir Ağları ile yapılmış ve MAPE değeri kullanılarak doğruluk analizi gerçekleştirilmiştir. Gerçek ve tahmin edilen değerler karşılaştırıldığında, yapılan tahminlerin başarılı olduğu sonucuna ulaşılmıştır (Karaatlı vd., 2012).

Azadeh vd. (2013), demir çelik sektöründe talep tahmini yapmışlardır. Çalışmada kullanılan değişkenler; milli gelir, büyüme oranı, enflasyon ve çelik üretim verileri olmuştur. Tahminler, Bulanık Mantık ve Yapay Sinir Ağları (YSA) yöntemleriyle gerçekleştirilmiştir. Araştırmacılar, önerdikleri

mükemmeliyet modelinin esnek olduğunu ve bu modelin hem küçük hem de büyük ölçekli şirketlerde uygulanabileceğini vurgulamışlardır (Azadeh vd., 2013).

Koochakpour ve Tarokh (2016) tarafından yapılan bir çalışmada, bir işletmenin satış tahminleri yapılmıştır. Bu tahmin için kullanılan değişkenler arasında milli gelir, döviz kuru, enflasyon ve geçmiş satış verileri yer almaktadır. Çalışmada, tahmin yöntemleri olarak Bulanık Mantık ve Yapay Sinir Ağları kullanılmıştır. Araştırmanın bulgularına göre, Bulanık Mantık modelleri, Yapay Sinir Ağlarına göre daha başarılı sonuçlar elde etmiştir (Koochakpour ve Tarokh, 2016).

Yılmaz (2018) tarafından gerçekleştirilen bir çalışmada, aylık konut satışları tahmin edilmiştir. Çalışmada, Yapay Sinir Ağları (YSA) ve regresyon yöntemleri kullanılmıştır. Veri seti, 2013-2017 yılları arasında aylık olarak toplanmıştır. Tahmin için; konut fiyatları, kredi durumu, nüfus sayısı, GSYİH, işsizlik oranı ve ailedeki kişi sayısı gibi değişkenler değerlendirilmiştir. Yapılan analiz sonucunda, tahmin edilen veriler 2017 yılındaki gerçek verilerle karşılaştırılmış ve YSA modelinin gerçek verilere daha yakın tahminler sağladığı gözlemlenmiştir (Yılmaz, 2018).

Rincon-Patino vd. (2018), avokado satışlarını inceleyen bir çalışma gerçekleştirmiştir. Hava koşullarının etkisi göz önünde bulundurularak yapılan bu çalışmada, tarım sektörüne ait veriler makine öğrenimi yöntemleriyle analiz edilmiştir. Çalışmada, Doğrusal Regresyon, Yapay Sinir Ağları'ndaki çok katmanlı algılayıcı (MLP), Destek Vektör Makineleri ve Çok Değişkenli Regresyon modelleri kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde, Destek Vektör Makineleri ve Çok Değişkenli Regresyon modellerinin daha başarılı tahminler sunduğu tespit edilmiştir (Rincon-Patino vd., 2018).

Ecemiş (2018), paslanmaz çelik satışlarını tahmin etmek amacıyla bir çalışma yapmıştır. Bu çalışmada, hammadde fiyatları, USD/TRY kuru, ÜFE ve sanayi üretim endeksi gibi değişkenler kullanılmıştır. Tahmin modelleri olarak Yapay Sinir Ağları ve Destek Vektör Makineleri (SVM) test edilmiştir. Elde edilen sonuçlar, MAPE, MAE ve RMSE gibi hata oranlarına göre karşılaştırılmıştır. Yapay Sinir Ağları yöntemi, makine sektörü dışında kalan tüm sektörlerde Destek Vektör Makineleri'ne kıyasla daha başarılı sonuçlar elde etmiştir (Ecemiş, 2018).

Kılıç vd. (2018), yemekhane talebini yapay zekâ teknikleriyle tahmin etmeye yönelik bir çalışma yapmıştır. Bu çalışmanın amacı, yemek üretiminin, talebi karşılayacak şekilde doğru miktarda yapılmasını sağlamaktır.

Üniversitelerde talep miktarı zaman zaman değişkenlik göstermektedir, bu yüzden doğru bir talep tahmini yaparak bu durumu çözmeyi hedeflemiştir. Kullanılan değişkenler arasında; tüketici türleri, yemekhaneden yararlanan öğrenci ve personel sayıları yer almıştır. Çalışmada, Yapay Sinir Ağı, Destek Vektör Makineleri ve Lincer Regresyon teknikleri kullanılmıştır. Sonuçlar değerlendirildiğinde, Destek Vektör Makineleri'nin bu analizde daha başarılı tahminler sunduğu belirlenmiştir (Kılıç vd., 2018).

Pavlyshenko (2019), çalışmasında Rossmann mağazalarının satış taleplerini incelemiştir. Araştırma, R programı ve Jupyter Notebook kullanılarak yapılmıştır. Çalışmada, Yapay Sinir Ağları, Rastgele Orman Algoritması ve Ağaç tabanlı modeller gibi çeşitli modeller kullanılmıştır. Yapılan analizler sonucunda, satış tahminlerinde regresyon modellerinin zaman serisi modellerine kıyasla daha doğru sonuçlar verdiği tespit edilmiştir (Pavlyshenko, 2019).

Türk ve Kıanı (2019), beyaz eşya sektöründe satış tahminleri yapmışlardır. Çalışmalarında beyaz eşya satış miktarı (SM) bağımlı değişken olarak kullanılırken, tüketici güven endeksi (TGE), reel kesim güven endeksi (RKGE), gayri safi yurt içi hasıla (GSYH), sanayi üretim endeksi (SÜE), tüketim harcamaları (TH), hane halkı maddi durum beklentisi (HMDB), ekonomi güven endeksi (EGE) ve evlenme istatistikleri bağımsız değişkenler olarak yer almıştır. Tahmin için Yapay Sinir Ağları (YSA) ve regresyon yöntemleri kullanılmıştır. Sonuçlar, YSA modellerinin regresyon analizlerine kıyasla daha başarılı olduğunu göstermiştir. Ayrıca, tahmin edilen değerler ile gerçek veriler karşılaştırıldığında, elde edilen sonuçların gerçek verilere oldukça yakın olduğu gözlemlenmiştir (Türk ve Kıanı, 2019).

Catal vd. (2019), satış tahminleri üzerine bir araştırma yapmıştır. Araştırmada, klasik zaman serisi yöntemleri ile makine öğrenmesi algoritmalarının karşılaştırılması yapılmıştır. Kullanılan yöntemler arasında Bayes, Yapay Sinir Ağları ve Karar Ağacı Yöntemleri yer almaktadır. Tahmin güvenilirlikleri, ortalama kare hata ve kök ortalama kare hata sonuçlarıyla değerlendirilmiştir. Başlangıçta, karar ağacı regresyon modeli en düşük hatayı verirken, tahmin sürecinin sonunda arttırılmış karar ağacının en düşük hatayı sağladığı gözlemlenmiştir. Bu bulgular ışığında, çalışmada regresyon modellerinin klasik zaman serisi yöntemlerinden daha iyi tahminler sunduğu sonucuna varılmıştır (Catal vd., 2019).

Weng vd. (2019), tedarik zinciri için satış tahminleri yapmak amacıyla Light Gradient Boosting Machine (LightGBM) ve Long Short-Term Memory (LSTM) yöntemlerini birleştiren bir model önermişlerdir. Çalışmalarında, Kaggle platformunda yer alan Corporación Favorita Market

Sale ve Rossman mağaza satışları ile Jollychic E-ticaret platformundaki tedarik zinciri veri setleri kullanılmıştır. Modelin başarısı için değişken seçim sürecinin büyük bir öneme sahip olduğu vurgulanmıştır. Veri setini analiz etmek için, veri görselleştirme tekniklerinden biri olan dağılım grafiği tercih edilmiştir. Değişken mühendisliği aşamasında, verilerin satış verisi olup olmadığına göre eksik veriler 0 veya -1 ile tamamlanmış, alakasız değişkenler ise veri setinden çıkarılmıştır. Ayrıca, verilerde herhangi bir anomali olup olmadığı da incelenmiştir. Modelin doğruluğunu değerlendirmek için Normalleştirilmiş Ağırlıklı Kök Ortalama Kare Logaritmik Hata (NWRMSLE) metriği kullanılmıştır. Çalışmada, Ridge, Destek Vektör Makineleri, Rastgele Orman, XGBoost, LightGBM ve LSTM yöntemleri ile birleşik modelin doğruluğu karşılaştırılmıştır. Sonuçlar, önerilen birleşik modelin üç farklı veri seti üzerinde başarılı bir şekilde çalıştığını ortaya koymuştur (Weng vd., 2019).

Helmini vd. (2019), çalışmalarında ARIMA gibi istatistiksel tahmin modellerinin genellikle yaygın olarak kullanıldığını, ancak doğrusal olmayan problemleri analiz etmekte yetersiz kaldığını belirtmişlerdir. Bu nedenle, doğruluğu diğer yöntemlere göre daha yüksek olan makine öğrenmesi tekniklerinin kullanılması gerektiğini vurgulamışlardır. Bu amaçla, yazarlar özgün bir Long Short-Term Memory (LSTM) modeli geliştirmiş ve bu modele hiperparametre optimizasyonu uygulamışlardır. Geliştirilen LSTM modeli, XGBoost ve Rastgele Orman modelleriyle karşılaştırılmıştır. Modeli test etmek için Kaggle platformundaki Rossmann mağaza satış veri seti kullanılmıştır. Değerlendirme için RMSE ve MAE hata fonksiyonları kullanılmıştır. Çalışmada, geliştirilen LSTM modelinin doğruluğunun, diğer makine öğrenimi yöntemlerine göre çok daha üstün olduğu sonucuna varılmıştır (Helmini vd., 2019).

Poyraz (2020), eczaneler için ilaç talep tahmini yapmıştır. Çalışmada, makine öğrenmesi yöntemleri kullanılarak gelecekteki yılların satış miktarları tahmin edilmiştir, böylece etkili bir stok yönetimi sağlanması hedeflenmiştir. Kullanılan makine öğrenme algoritmaları arasında Linear Regresyon, Gaussian Process, M5Rules, Yapay Sinir Ağları'nın çok katmanlı algılayıcı modeli, SMOreg, M5P ve Random FOREST yer almıştır. Veri seti, 2015-2019 yılları arasındaki haftalık verilerden oluşmaktadır. Sonuçlar, MAPE değeriyle karşılaştırılmış ve M5Rules algoritması en düşük hata oranına sahip olarak belirlenmiştir. Ayrıca, Gaussian Processes algoritması ise üç hafta boyunca en iyi sonuçları elde eden algoritma olmuştur (Poyraz, 2020).

Verstraete vd. (2020), taktiksel satış tahmini yapmak için Lasso yöntemini kullanarak bir çalışma gerçekleştirmiştir. Çalışmada, tedarik zincirinin tüm

unsurları için taktiksel satış tahmininin önemli olduğu vurgulanmıştır. Yazarlar, geleneksel satış tahmin yöntemlerinin bazı makroekonomik faktörlere uyum sağlamakta yetersiz kaldığını belirtmişlerdir. Makroekonomik değişiklikler öngörülemediği için, genellikle uzman görüşleri veya çalışanların yaptığı varsayımlar kullanılır, ancak bu tür yaklaşımlar hem pahalıdır hem de analitik açıdan doğrulanabilir değildir. Bu yüzden, makroekonomik değişiklikleri tahmin etmek amacıyla Lasso yöntemi tercih edilmiştir. Çalışmada kullanılan veri seti, otomotiv sektöründeki bir firmadan alınan 62 aylık verilerden oluşmaktadır. Modelin hata oranı, ortalama mutlak yüzde hata kullanılarak hesaplanmıştır. Uzun vadeli tahmin çalışması sonucunda, klasik tahmin yöntemlerine göre hata oranının %54,5 azaldığı gözlemlenmiştir (Verstraete vd., 2020).

Antipov ve Pokryshevskaya (2020), Gradient Boosting Machine (GBM), Rastgele Orman ve ElasticNet yöntemlerini karşılaştırarak, satış tahminlerinde kullanılabilecek genel bir yaklaşım geliştirmişlerdir. Çalışmada, yorumlanabilir makine öğrenmesi teknikleri kullanılarak, eyleme geçirilebilir tahminler elde edilmiştir. Veri seti, 156 haftalık bir dönemi kapsamakta olup, bir perakende analitik şirketi tarafından temin edilmiştir (Antipov ve Pokryshevskaya, 2020).

Tozak (2021), bir tekstil firmasının satış verilerini tahmin etmek amacıyla veri madenciliği programlarını kullanmıştır. Veriler, yaklaşık dört yıl boyunca aylık olarak toplanmıştır ve karar ağacı algoritması ile tahmin edilmiştir. Çalışmada yer alan değişkenler arasında; müşteri sayısı, üretim yeri, fabrika, yıl, ay, sevk adedi ve birim fiyat bulunmaktadır. Elde edilen tahminler sonucunda, firmanın yıllık üretim kapasitesinin ne kadar olması gerektiği belirlenmiş ve bu doğrultuda üretici için doğru bir planlama yapma hedeflenmiştir (Tozak, 2021).

Nacar ve Erdebili (2021), uçtan uca bir makine öğrenmesi proje sürecini ele almış ve bir makine öğrenmesi projesinin aşamaları ile veriye yaklaşım yöntemini tanıtmışlardır. Uygulama kısmında, doğrusal regresyon, Ridge, Lasso, Elastic Net, K-en yakın komşu ve Rastgele Orman gibi makine öğrenmesi algoritmaları kullanılarak gerçek bir veri seti üzerinde satış tahmin modeli geliştirilmiştir. Bu modelde, en düşük hata oranını veren algoritma olarak Rastgele Orman belirlenmiştir (Nacar ve Erdebili, 2021).

Demirer-Polat (2022) çalışmasında, beyaz eşya sektöründe faaliyet gösteren bir firmanın aylık bazda toplanan verileri incelenmiştir. Bağımlı değişken olarak sevk verileri kullanılırken, bağımsız değişkenler arasında reel kesim güven endeksi, gayri safi yurtiçi hasıla, sanayi üretim endeksi, evlenme oranı, tüketici güven endeksi ve ekonomi güven endeksi yer almaktadır.

Çalışmanın amacı, veri madenciliği teknikleri olan yapay sinir ağları, destek vektör makineleri ve çoklu doğrusal regresyon yöntemlerini kullanarak satış tahminleri yapmaktır. Ayrıca, yapılan tahminler birbirleriyle karşılaştırılarak aralarındaki farklılıklar incelenmiş ve satış süreçlerini optimize ederek maksimum kâr sağlamak ve zaman kaybını en aza indirmek hedeflenmiştir. Veriler, Weka programı aracılığıyla test edilmiş ve satış tahminleri üç farklı yöntemle ayrı ayrı değerlendirilerek sonuçlar karşılaştırılmıştır (Demirer-Polat, 2022).

Acı ve Doğanşoy (2022), yerel bir süpermarketin 2019-2020 yıllarına ait iki yıllık e-ticaret verilerini (web sitesi ve mobil uygulama) ve ürün satışını etkileyen faktörleri (tatil günleri, TÜFE değeri ve işsizlik oranı) göz önünde bulundurarak, belirli ürün kategorileri için talep tahminleri yapmışlardır. En doğru talep tahmin modelini elde etmek amacıyla, altı farklı yapay zeka algoritmasından (Derin Öğrenme, Yapay Sinir Ağları, Gauss Süreç Regresyonu, Regresyon Ağacı, Destek Vektör Regresyonu ve Topluluk Öğrenme) oluşan yirmi dört farklı yöntem kullanılmıştır. Tahmin sonuçları, korelasyon katsayısı (R), Kök Ortalama Kare Hata (KOKH) ve Ortalama Mutlak Hata (OMH) gibi kriterlerle değerlendirilmiştir. En yüksek başarı, Long Short-Term Memory (LSTM) kullanılarak elde edilmiştir (KOKH=0,0353; OMH=0,0164; R=0,9742). Bu bulgular, doğru ürün tedarikinin sağlanmasında, satış kampanyalarında ve pazarlama stratejilerinde kullanılarak e-perakende satışlarının verimliliğini artırabilir (Acı ve Doğanşoy, 2022).

Peköz ve İnkaya (2023), COVID-19 pandemisi sırasında bir üçüncü parti lojistik firmasındaki talep tahminini doğru bir şekilde yapmak amacıyla bir çalışma gerçekleştirmişlerdir. Çalışmada, firma tarafından Haziran 2020 ile Aralık 2020 arasında kaydedilen sevkiyat verileri incelenmiş ve tahmin problemi tek değişkenli bir zaman serisi problemi olarak ele alınmıştır. Araştırma kapsamında, derin öğrenme temelli bir talep tahmini modeli önerilmiştir. Bu modelde, evrişimli sinir ağı (CNN) ve uzun kısa dönem hafıza (LSTM) ağı birleştirilerek hibrit bir model oluşturulmuştur. CNN, özniteliklerin çıkarılmasını sağlarken, LSTM ağı uzun dönemli bağımlılıkların yakalanmasına olanak tanımaktadır. Bu model, hibrit CNN-LSTM olarak adlandırılmaktadır. Önerilen modelin tahmin başarısı, klasik tahmin yöntemleri ve diğer makine öğrenmesi ile derin öğrenme teknikleriyle karşılaştırılmış ve değerlendirilmiştir. Tüm yöntemlerin parametre değerleri deneysel olarak belirlenmiştir. Deneysel bulgulara göre, hibrit CNN-LSTM modelinin tahmin performansı diğer yöntemlerden daha yüksek olmuştur. Bu yaklaşım, lojistik talebinin doğru bir şekilde tahmin edilmesine olanak

tanılarak, işgücü ve kaynak planlaması süreçlerinde önemli bir katkı sağlamaktadır (Peköz ve İnkaya, 2023).

Erol ve İnkaya (2024), satış tahmini problemini çözmek için çeşitli derin öğrenme yöntemlerinin performanslarını karşılaştırmışlardır. Çalışmada, derin sinir ağı (DNN), derin otokodlayıcı (Deep AE), evrişimli sinir ağı (CNN), tekrarlayan sinir ağı (RNN), uzun kısa süreli bellek ağı (LSTM), çift yönlü LSTM (Bi-LSTM), kapılı tekrarlayan birim (GRU), CNN-LSTM ve evrişimli LSTM (ConvLSTM) gibi farklı yöntemler kullanılmıştır. Deneysel çalışmalar, çeşitli sektörlerden alınan satış verileri üzerinde gerçekleştirilmiş ve hiperparametre optimizasyonu yapılmıştır. Elde edilen sonuçlar, tahmin doğruluğu ve eğitim süreleri açısından karşılaştırılmış ve istatistiksel anlamlılık analizi yapılmıştır. Çalışmanın bulguları, LSTM ve GRU modellerinin yüksek tahmin doğruluğu sağladığını, CNN modelinin ise eğitim sürelerini önemli ölçüde kısalttığını göstermiştir (Erol ve İnkaya, 2024).

Ürün satışını veya talebini belirleyen faktörler temelinde yapılan çalışmalar incelenmiştir. Yapılan çalışmalarda kullanılan, satışlara etki eden ekonomik faktörler olarak genellikle, ülke milli geliri, sanayi üretim endeksi, ekonomi güven endeksi, enflasyon, döviz kuru, sektörün üretimleri, ürün fiyatları ve geçmiş satış verileri olduğu görülebilir.

4. Yöntem

Bu çalışmada OLED tv satışlarındaki sipariş miktarlarının tahmini güçlü makine öğrenmesi yöntemlerinden Rastgele Orman yöntemi ile gerçekleştirilmiştir.

4.1. Rastgele Orman Yöntemi

Rastgele orman (RF), bir topluluk öğrenme algoritması olarak tanımlanabilir (Breiman, 2001). Bu algoritmada, her karar ağacı düğümünde en uygun bölme, tüm elemanlar arasından rastgele seçilen bir alt küme üzerinden belirlenir. Düğümler arasındaki en iyi bölmenin sağlanabilmesi için ise Gini indeksi kullanılır. N sınıf içeren bir veri seti için Gini indeksi, Eşitlik 1'de gösterildiği gibi hesaplanır.

$$Gini(t) = 1 - \sum_j [p(j|t)]^2 \quad (1)$$

Formülasyondaki j ve t sırasıyla sınıfı ve düğümü temsil etmektedir. Ayrıca $p(j|t)$, t düğümündeki j sınıfının göreceli olasılığını ifade etmektedir. Gini indeksi, aynı zamanda değişkenlerin homojenliği hakkında önemli bilgiler sunar. Gini indeksinin sıfıra yakın olması, verinin daha homojen olduğunu

gösterirken, yüksek bir değer ise verinin heterojenliğe eğilimli olduğunu ifade eder (Ekmekcioğlu vd., 2020).


RF algoritması, örneklem büyüklüğü ve ağaç sayısı gibi hiperparametreler içerir. Kullanıcı, karar ormanını N adet ağaçla kurar ve böylece her sınıflandırma işleminde veri seti N farklı karar ağacından geçirilir. Ayrıca, eğitim ve test setlerinin belirlenmesi RF yöntemi için kritik bir aşamadır (Yu ve Abdel-Aty, 2014). Bir RF modelinin ortalama hata oranı hesaplanır ve hata oranı en düşük olan ağaç, en yüksek ağırlıkla değerlendirilir. Hata oranı en yüksek olan ağaca ise en düşük ağırlık verilir. Genel olarak, her ağacın bir oyu bulunduğu için, nihai tahmin ve en uygun sınıflandırıcıyı belirlemek amacıyla majority voting yapılır (Koyuncu ve Ekmekcioğlu, 2024).

5. Uygulama

Bu çalışma ile dünyanın en büyük e-ticaret ve perakende şirketlerinden biri olan Amazon'un tv satışları tahmin edilmeye çalışılmış ve bu tahminler ışığında üretim için gerekli stok maliyetlerinin planlanması hedeflenmiştir. Firmaların kar etme amacı ile maliyetlerini minimum da tutmaları gerekmektedir. Çalışmadaki tüm veri seti 29.03.2020 ile 30.01.2022 tarihleri arasındaki haftalık OLED tv satışlarından oluşmaktadır. Bu tarihler arasında satışların zirve yaptığı bazı özel günler ise Tablo 1'de verilmiştir.

Tablo 1. Bazı Özel Günler


Tarih	Olay
11.10.2020	Amazon Prime Günü
15.11.2020	Kara Cuma
13.12.2020	Noel
20.06.2021	Amazon Prime Günü
21.11.2021	Kara Cuma
25.12.2021	Noel



Şekil 1. 29.03.2020 ile 30.01.2022 tarihleri arasındaki OLED TV sipariş edilen miktarlar ve tahminler

Şekil 1’de Tablo 1’de verilen bazı önemli günlerde OLED TV satışlarında sipariş edilen miktarlarda zirve yaptığı görülmektedir. Bu nedenle firmaların doğru stok miktarlarını ellerinde bulundurarak sipariş edilen miktarları karşılamaları oldukça önemlidir.

Bunun gerçekleşebilmesi için ise iyi bir planlama ve bir sonraki yılı yüksek oranda tahmin ederek yol izlemek önemlidir. Şekil 2’de OLED TV satış tahmini için oluşturulan tahmin modeli verilmiştir.



Şekil 2. Tahmin Modeli (OLED TV satışları)

Çalışmada 14.11.2021 ile 30.01.2022 tarihleri arasında 12 haftalık OLED tv satışları için sipariş edilen miktarlar kullanılmıştır. Bu tarihler arasında kara cuma ve Noel haftaları olması nedeniyle özellikle seçilmiştir. Gelecek 12 hafta için ise 06.02.2022 ile 24.04.2022 arasında satışlar tahmin

edilmeye çalışılmıştır. Şekil 3’de Amazon OLED tv satışlarında kullanılan veri setinin tahmin zamanı verilmiştir.



Şekil 3. OLED TV satış verileri için tahmin zamanı

Çalışmada Rastgele Orman yöntemi ile elde edilmiş olan 12 haftalık tahmin sonuçları Tablo 2’de verilmiştir.

Tablo 2. OLED TV satış tahminleri

Sipariş Tarihi	Sipariş Edilen Miktar	Tahminler Toplamı	Ortalama Mutlak Yüzde Hata (MAPE) (Rastgele Orman Modeli)	Temel Tahminler Toplamı	Ortalama Mutlak Yüzde Hata (MAPE) Temel Model
14.11.2021	381	179	53%	69	82%
21.11.2021	649	512	21%	50	92
28.11.2021	83	293	253%	77	7
05.12.2021	14	101	621%	138	886
12.12.2021	53	90	70%	91	72
19.12.2021	36	82	128%	143	297
26.12.2021	392	391	0%	210	46
02.01.2022	299	203	32%	381	27
09.01.2022	55	98	78%	381	593
16.01.2022	39	90	131%	83	113
23.01.2022	28	122	336%	14	50
30.01.2022	12	99	725%	53	342
Toplam	2041	2260	11%	1690	17%

Modellerin öngörü doğruluğunun (tahmin performansının) ölçümünde kullanılan istatistikler; en küçük değere sahip hata kareler ortalaması (MSE),

ortalama hata (ME), hata kareler ortalamasının karakökü (RMSE), hatanın mutlak ortalaması (MAE), ortalama yüzde hata (MPE) ve ortalama mutlak yüzde hata (MAPE) şeklindedir. Ancak hangi istatistiğin kullanılması gerektiği konusunda belirli bazı kriterler takip edilmektedir.

Eğer hata değerleri birbirine yakın büyüklüklerdeyse, MSE istatistiği kullanılabilir. Ancak tahmin sonuçlarından biri ya da birkaçı, ortalamadan önemli ölçüde sapma gösteriyorsa, MSE uygun bir ölçüt olmayabilir. Çünkü MSE, hataları karesini alarak değerlendirdiği için büyük sapmalara aşırı duyarlıdır ve bu da sonuçları olduğundan daha yüksek gösterebilir. Bu tür durumlarda, daha dengeli sonuçlar sunan MAE tercih edilebilir. Öte yandan, bir modelin yansız (biasız) olup olmadığını değerlendirmek gerekirse, tahminlerin sistematik olarak gerçek değerlerin altında ya da üstünde kalıp kalmadığına bakılır. Bu tür analizlerde MPE kullanılır. Ayrıca, tahmin yöntemlerinin kullandığı değerlerin birimlerinde farklılık varsa örneğin biri ham verilerle, diğeri logaritmik dönüşüm yapılmış verilerle çalışıyorsa karşılaştırma için MAPE gibi oransal ölçütlere başvurulması daha uygundur (Yılmaz ve Çilengiroğlu, 2022).

MAPE istatistiği, farklı birimlere sahip tahmin modelleri arasında karşılaştırma yaparken ortaya çıkabilecek olumsuzlukları ortadan kaldırma avantajı sağlar. Öngörü hatalarını yüzde cinsinden ifade etmesi, MAPE'yi diğer istatistiksel ölçütlerden ayıran ve tek başına anlam taşıyan önemli bir özelliğidir. Bu yönüyle, MAPE birçok durumda tercih edilen bir performans göstergesi olarak öne çıkar. Değerlendirme açısından bakıldığında, MAPE değeri %10'un altında olan modeller "yüksek doğruluk" düzeyine sahip olarak kabul edilirken, %10 ile %20 arasında kalan modeller ise genellikle "doğru tahmin yapan" modeller şeklinde sınıflandırılır (Yılmaz ve Çilengiroğlu, 2022). MAPE değeri Eşitlik 2'de verildiği hesaplanmaktadır.

$$MAPE = \frac{\sum_{t=1}^n \frac{|u_t|}{Y_t}}{n} * 100 \quad (2)$$

Tablo 2'de hesaplanan MAPE değeri %11 değeriyle %10-%20 değerleri arasında kaldığı için doğru tahmin edilen model olarak öngörülmektedir.

Çalışmada henüz verisi elde edilmemiş olan 06.02.2022 tarihleri ile 24.04.2024 tarihleri arasındaki Rastgele Orman yöntemiyle elde edilen 12 haftalık OLED TV sipariş miktarlarını tahmin sonuçları ise Tablo 3'de verilmiştir.

Tablo 3: Gelecek 12 Haftalık Satış Tahminleri

Sipariş Tarihi	Tahminler Toplamı
06.02.2022	64
13.02.2022	61
20.02.2022	65
27.02.2022	68
06.03.2022	64
13.03.2022	64
20.03.2022	130
27.03.2022	129
03.04.2022	115
10.04.2022	115
17.04.2022	120
24.04.2022	130

Çalışmada son olarak model kullanılarak Rastgele Orman metodunu kullanarak ne kadar hasılat farkı elde edeceklerine ilişkin Tablo 4’de özet bir tahmin değerleri tablosu hazırlanmıştır.

Tablo 4. Özet Tahmin Değerleri

	Sipariş Edilen Miktar	Model Tahmin Miktarı	Göz atma sayısı	Stok Dışı Görünümler	Ürün Detay Sayfası (PDP)	Kayıp Miktar	Ortalama Satış Fiyatı
14.11.2021-30.01.2022	2041	2260	605.706	119.143	0,34%	405	€ 1091

Tablo 4’de 119.143 tane stok dışı görünüm olduğu görülmüştür. Bu değeri 0,34 PDP değeri ile çarptığımızda kayıp miktar değerini elde ederiz.

$$\text{Model kullanılmadan kayıp miktar} = 119.143 * 0,0034 = 405$$

$$\text{Model kullanılarak kayıp miktar} = 2041 + 405 - 2260 = 186$$

$$\text{Gelir Farkı} = (405 - 186) * € 1091 = € 238.929$$

Tablo 4’deki değerleri hesaplayarak Rastgele Orman modeli yöntemini kullanarak Gelir farkı değerini elde ettiğimizde € 238.929 daha fazla hasılat elde edeceğimizi görmekteyiz. Bu nedenle firmalar ellerindeki stok miktarlarını planlarken zaman serileri ve makine öğrenmesi gibi yöntemleri kullanmalarının kendileri için oldukça önemli olduğu görülmektedir. Bununla birlikte tahminleme yaptığımız 14.11.2021 ile 30.01.2022 tarihleri arasında 21.11.2021 tarihinin kara cuma ve 25.12.2021 tarihinin ise noel haftası olduğu görülmektedir. Bu tarihlerden Tablo 2’de kara cuma

gününde 649 adet OLED tv siparişi verildiği ve modelin 512 adet tahminde bulunduğu görülmektedir. Diğer yandan Noel haftaları olan 26.12.2021 tarihinde 392 adet OLED tv siparişi verildiği modelin ise 391 adet olarak tahminde bulunduğu ve 02.01.2022 tarihinde ise 299 adet sipariş verildiği ve modelin 203 adet OLED tv siparişi tahmin ettiği gözlemlenmiştir. Özellikle bunun gibi özel günlerde siparişlerin zirve yapması nedeniyle doğru bir modelleme tahmini ile toplamda firmaların ellerindeki stok miktarlarını doğru ayarlayarak daha çok hasılat edebilecekleri görülmektedir.

6. Tartışma ve Sonuç

Son yıllarda giderek daha fazla önem kazanan ve “yılın özel günleri” olarak adlandırılan Yılbaşı, Sevgililer Günü, Anneler Günü, Ramazan ve Kurban Bayramları ile Kara Cuma gibi dönemler, taşıdıkları kültürel ve dini anlamların ötesinde, tüketici davranışlarını önemli ölçüde etkilemektedir. Bu özel günlerde, işletmelerin yürüttüğü kampanya ve pazarlama stratejileri sayesinde talepte belirgin artışlar, hatta zaman zaman talep patlamaları yaşanabilmektedir. Özellikle perakende ve e-ticaret sektörlerinde bu dönemsel hareketlilik, satış hacimlerinin ciddi şekilde yükselmesine katkı sağlamaktadır. Bu bağlamda, talep tahmini işletmeler açısından yalnızca operasyonel değil, aynı zamanda stratejik bir gereklilik hâline gelmiştir. Pazardaki konumunu korumak, rekabet avantajı elde etmek ve sürdürülebilir büyümeyi sağlamak isteyen firmalar için doğru talep öngörülleri, üretim süreçlerinin temelini oluşturur. Etkili bir üretim planlaması, hammadde, yarı mamul, insan kaynağı, makine-teçhizat ve finansman gibi unsurların zamanında ve doğru şekilde belirlenmesini sağlar. Aynı zamanda, talep doğrultusunda üretimin yapılması, gereksiz stok birikimini önleyerek kaynakların daha verimli kullanılmasına olanak tanır. Özetle, isabetli tahminlerle üretim, satış ve stok yönetimi arasında sağlıklı bir denge kurulabilir.

Bu çalışmanın temel amacı, işletmelerin üretim planlaması süreçlerinde stratejik bir bakış açısı geliştirmelerine katkı sağlamaktır. Bu doğrultuda geliştirilen tahmin modeli, firmaların insan kaynağı, ekipman ve diğer üretim kaynaklarını önceden planlamalarına yardımcı olmakta; elde edilen çıktılar, üreticiler, araştırmacılar ve pazarlama profesyonelleri için karar destek mekanizması işlevi görmektedir. Satış miktarlarının önceden öngörülebilmesi, firmalara hammadde maliyetlerini optimize etme, üretimi daha düşük maliyetle gerçekleştirme ve stok yönetimini etkinleştirme gibi önemli avantajlar sunar. Ayrıca, doğru tahmin sonuçlarıyla üretim kapasitesinin artırılma potansiyeli değerlendirilebilir, bu da yeni müşteri segmentlerine ulaşma ve satış hacmini genişletme imkânı yaratır. Türkiye’de

giderek yaygınlaşan lisanslı depoculuk uygulamaları açısından da bu tür tahminlerin yönlendirici etkisi olabilir.

Tüm bu kazanımlar neticesinde firmalar, minimum maliyetle maksimum kâr elde etmeye yönelik stratejiler geliştirerek sürdürülebilirliklerini artırabilirler. Çalışma bulguları, doğru modelleme teknikleri kullanıldığında kârlılığın önemli ölçüde artırılacağını göstermektedir. Nitekim üretim planlamasının etkin bir şekilde gerçekleştirilebilmesi, büyük ölçüde güvenilir talep tahminlerine bağlıdır. Günümüzde, doğru öngörüler işletmelerin mevcut kaynaklarını daha etkin ve sürdürülebilir biçimde kullanmaları açısından kritik bir rol oynamaktadır. Özellikle son yıllarda artan ekonomik belirsizlikler, üretim planlamasının stratejik değerini daha da artırmıştır. Tüm bu kazanımların sonucunda, firmalar minimum maliyetle maksimum kâr elde etmeye yönelik stratejiler geliştirerek sürdürülebilirliklerini artırabilir. Çalışmada elde edilen bulgular, doğru modelleme teknikleri kullanıldığında kârlılığın önemli ölçüde artırılacağını ortaya koymaktadır. Bu doğrultuda, işletmeler geleneksel tahmin yöntemlerinin ötesine geçerek, daha isabetli sonuçlar sunabilen analitik ve sayısal yöntemlere yönelmektedir. Bu yöntemler arasında öne çıkan makine öğrenmesi temelli analizler, talep tahmini sürecinde yaygın olarak kullanılmaya başlanmıştır.

Bu çalışmanın uygulama bölümünde, makine öğrenmesi yöntemlerinden biri olan Rastgele Orman (Random Forest) algoritması kullanılarak bir satış tahmini gerçekleştirilmiştir. Elde edilen model, yalnızca belirli bir sektöre değil, farklı sektörlerdeki firmalara da uygulanabilecek niteliktedir. Ayrıca, diğer makine öğrenmesi algoritmalarının entegrasyonu ile modelin kapsamı daha da genişletilebilir. Bu bağlamda, yalnızca sınırlı uygulama alanlarına sahip olduğu düşünülen makine öğrenmesi yöntemlerinin, gerçek dünya problemlerine başarıyla uyarlanabileceği gösterilmiştir.

Gelecekte yapılacak çalışmaların, bu tür tahmin modellerini farklı sektörlerde test ederek çok daha geniş bir uygulama alanına yaymaları ve endüstrinin ihtiyaç duyduğu öngörü modeli çalışmalarına katkı sunmaları beklenmektedir.

Kaynakça

- Acı, M., & Doğanşoy, G. A. (2022). Demand forecasting for e-retail sector using machine learning and deep learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(3), 1325-1339.
- Aksel, F. (2000). *Regresyon Analizi ve Yapay Sinir Ağı Yöntemleri ile Uzun Dönem Yük Tahmini*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Antipov, E. A., & Pokryshevskaya, E. B. (2020). Interpretable machine learning for demand modeling with high-dimensional data using Gradient Boosting Machines and Shapley values. *Journal of Revenue and Pricing Management*, 19(5), 355–364.
- Atalay, M., & Çelik, E. (2017). Büyük Veri Analizinde Yapay Zeka Ve Makine Öğrenmesi Uygulamaları. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 9(22), 155-172.
- Azadeh, A., Neshat, N., Mardan, E., & Saberi, M. (2013). Optimization of steel demand forecasting with complex and uncertain economic inputs by an integrated neural network–fuzzy mathematical programming approach. *The International Journal of Advanced Manufacturing Technology*, 65, 833-841.
- Bayuk, M. N. (2009). Özel Gün ve Haftaların Tüketim Üzerindeki Etkileri. *Kamu İş Dergisi*, 11(1), 185-197.
- Böge, E. (1994). *Tüketici Davranışı ve Karar Verme*. Ankara: Gazi Yayınları.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32.
- Campbell, M., Hoane, A. J. & Hsu, F. (2002). Deep blue, *Artificial Intelligence*, 134, 57–83.
- Carlson, R. L., & Umble, M. M. (1980). Statistical Demand Functions for Automobiles and Their Use for Forecasting in an Energy Crisis. *The Journal of Business*, 53(2), 193–204.
- Catal, C., Ece, K., Arslan, B., Akbulut, A. (2019). Benchmarking of Regression Algorithms and Time Series Analysis Techniques for Sales Forecasting. *Balkan Journal of Electrical and Computer Engineering*, 7(1), 20-26.
- Chen, C. Y., Lee, W. I., Kuo, H. M., Chen, C. W., & Chen, K. H. (2010). The study of a forecasting sales model for fresh food. *Expert Systems with Applications*, 37(12), 7696-7702.
- Demirbaş, F. P. (2011). *Kombi Üretiminde Talep Tahmin Yöntemlerinin Uygulanması*. Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Demirel, Ö. (2009). *ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini*. Yüksek Lisans Tezi, Marmara Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Demirer-Polat, E. (2022). *Beyaz Eşya Sektöründe Satış Tahmini: Bir Veri Madencilği Uygulaması*, Yüksek Lisans Tezi, Uludağ Üniversitesi, Sosyal Bilimler Enstitüsü, Bursa.
- Dietterich, T. G. (1997). Machine-Learning Research. *AI Magazine*, 18(4), 97-136.
- Ecemiş, O. (2018). Model ağaç yöntemiyle satış tahmini: Paslanmaz çelik sektöründe bir uygulama. *Akademik Sosyal Araştırmalar Dergisi*, 6(84), 336-350.
- Efendigil, T., Önüt, S., & Kahraman, C. (2009). A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis. *Expert Systems with Applications*, 36(3), 6697-6707.
- Ekmekcioğlu, M., Başakın, E. E., & Özger, M. (2020). Tree-based nonlinear ensemble technique to predict energy dissipation in stepped spillways. *European Journal of Environmental and Civil Engineering*, 26(8), 3547-3565.
- El-Naqa, I., & Murphy, M. J. (2015). What is machine learning?. In: *Machine Learning in Radiation Oncology* (pp. 3-11). Springer, Cham.
- Eroğlu, A. H. (1996). Pazarlama Planlaması Sürecinde Satış Tahminleri Ve Çoklu Regresyon Ve Korelasyon Analizinin Etkinliği. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 1(1), 99-116.
- Erol, B., & İnkaya, T. (2024). Satış Tahmini için Derin Öğrenme Yöntemlerinin Karşılaştırılması. *Uludağ Üniversitesi Mühendislik Fakültesi Dergisi*, 29(2), 535-554.
- Ersen, M., Büyüklü, A. H., & Taşabat, S. E. (2022). Data Mining as a Method for Comparison of Traffic Accidents in Şişli District of Istanbul. *Journal of Contemporary Urban Affairs*, 6(2), 113- 141
- Fogel, S. O., & Thornton, C. G. (2008). What a hassle! consumer perceptions of costs associated with sales promotions, *Journal of Promotion Management*, 14, 31-44.
- Foot, K. D. (2021). A Brief History of Machine Learning. Available online: <https://www.dataversity.net/a-brief-history-of-machine-learning/> (accessed on: 15.09.2024).
- Gavcar, E., Şen, S., & AYTEKİN, A. (1999). Türkiye’de Kullanılan Kağıt-Karton Türlerinin Talep Tahminlerinin Belirlenmesi. *Turkish Journal of Agriculture and Forestry*, 23(2), 203 - 211.
- Grigorev, A. (2020). *Machine Learning Bookcamp MEAP V06* (A. Books (ed.)). Copyright 2020 Manning Publications. Available online: <https://www.manning.com/books/machine-learning-bookcamp> (accessed on: 17.09.2024).

- Helmini, S., Jihan, N., Jayasinghe, M., & Perera, S. (2019). Sales forecasting using multivariate long short term memory network models. *PeerJ PrePrints*, 7, c27712v1.
- Hicham, A. & Bouhorma, M. (2012). Hybrid intelligent system for sale forecasting using delphi and adaptive fuzzy back-propagation neural networks. *(IJACSA) International Journal of Advanced Computer Science and Applications*, 3(11), 122-130.
- Ingle, C., Bakliwal, D., Jain, J., Singh, P., Kale, P., & Chhajed, V. (2021) Demand forecasting: Literature review on various methodologies, *In 2021 12th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, 1-7.
- İnal, G. (2021). *Yapay zekâ, veri madenciliği ve büyük veri kavramlarına karşı okul yöneticilerinin algılarının belirlenmesi*. Yayınlanmamış Yüksek Lisans Tezi, Akdeniz Üniversitesi, Eğitim Bilimleri Enstitüsü, Antalya.
- İnik, Ö. & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- Karaatlı, M., Helvacioğlu, Ö. C., Ömürbek, N., Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karaca, Ş., Özbakır U., M. & Yemez, İ. (2018). Özel Gün İndirimlerinin Tüketicilerin Satın Alma Davranışları Üzerindeki Etkisinin İncelenmesi. *İğdır Üniversitesi Sosyal Bilimler Dergisi*, 16, 413-436.
- Karahan, M. (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*, Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.
- Keskin, A. (2025). Predicting and Reducing Patient Waiting Times in Dental Clinics Using Machine Learning: A Case Study from Türkiye. *Black Sea Journal of Engineering and Science*, 8(1), 243-248.
- Kılıç, F., Akkaya, M. R., & Memili, N. (2018). Yemekhane için Yapay Zeka Teknikleri Kullanımı ile Günlük Talep Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 13, 65-71.
- Koch, R. (2022). History of Machine Learning—A Journey through the Timeline. Available online: <https://www.clickworker.com/customer-blog/history-of-machine-learning/> (accessed on: 15.09.2024).
- Koochakpour, K. & Tarokh, M. J. (2016). Sales budget forecasting and revision by adaptive network fuzzy base inference system and optimization methods. *Journal of Computer & Robotics*, 9(1), 25-38.
- Koyuncu, Z., & Ekmekcioğlu, Ö. (2024). İstanbul İçin CBS Tabanlı Makine Öğrenmesi İle Sel Duyarlılık Haritasının Oluşturulması. *Doğal Afetler Ve Çevre Dergisi*, 10(1), 1-15.

- Lennon, S. J., Johnson, K. K. P., & Lee, J. (2011). A perfect storm for consumer misbehavior: Shopping on Black Friday. *Clothing & Textiles Research Journal*, 29(2), 119–134. <https://doi.org/10.1177/0887302X11401907>
- Mucuk, İ. (1998). Pazarlama İlkeleri ve Örnek Olaylar. 9. Basım, İstanbul: Türkmen Kitabevi.
- Nacar, E. N., & Erdebilli, B. (2021). Makine Öğrenmesi Algoritmaları ile Satış Tahmini. *Endüstri Mühendisliği*, 32(2), 307-320.
- Pavlyshenko, B. M. (2019). Machine-Learning Models for Sales Time Series Forecasting. *Data*, 4(1), 1–11.
- Peköz, A. Z., & İnkaya, T. (2023). Derin öğrenme ile talep tahmini: Bir üçüncü parti lojistik firması için COVID-19 döneminde vaka analizi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(4), 331-339.
- Poyraz, İ. (2020). *Makine Öğrenmesi Algoritmaları ile Eczaneler için İlaç Talep Tahmini*, Yüksek Lisans Tezi, İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, İstanbul.
- Raghubir, P., Inman, J. J., ve Grande, H. (2004). The three faces of consumer promotions. *California Management Review*, 46, 23-42.
- Rincon-Patino, J., Lasso, E., & Corrales, J. C. (2018). Estimating Avocado Sales Using Machine Learning Algorithms and Weather Data. *Sustainability*, 10(10), 3498.
- Samuel, A. L. (1959). Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, 3(3), 210–229.
- Sathya, R., & Abraham, A. (2013). Comparison of supervised and unsupervised learning algorithms for pattern classification. *International Journal of Advanced Research in Artificial Intelligence*, 2(2), 34–38.
- Savaş, S., Topaloğlu, N., & Yılmaz, M. (2012). Veri madenciliği ve Türkiye’deki uygulama örnekleri. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 21, 1-23.
- Shimp, T.A. (2003). *Advertising, promotion, and supplemental aspects of integrated marketing communications*, 6th ed., United States of America: Thomson SouthWestern, Boston, MA.
- Suthaharan, S. (2014). Big data classification: Problems and challenges in network intrusion prediction with machine learning. *ACM SIGMETRICS Performance Evaluation Review*, 41(4), 70-73.
- Tosunoğlu, E., Yılmaz, R., Özeren, E., Sağlam, Z. (2021). Eğitimde Makine Öğrenmesi: Araştırmalardaki Güncel Eğilimler Üzerine İnceleme. *Abmet Keleşoğlu Eğitim Fakültesi Dergisi*, 3(2), 178-199.
- Tozak, E. Y. (2021). *Veri Madenciliği Programları Kullanılarak Bir Tekstil Firmasının Satış Verilerinin Değerlendirilmesi*, Yüksek Lisans Tezi, Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Karabük.

- Türk, E., & Kıran, F. (2019). Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlama Örneği. *İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1), 30-37.
- Uraz, Ç. (1978). Temel pazarlama bilgileri. Ankara: Kalite Matbaası.
- Verstraete, G., Aghezzaf, E. H., & Desmet, B. (2020). A leading macroeconomic indicators' based framework to automatically generate tactical sales forecasts. *Computers and Industrial Engineering*, 139, 106169.
- Weng, T., Liu, W., & Xiao, J. (2019). Supply chain sales forecasting based on lightGBM and LSTM combination model. *Industrial Management and Data Systems*, 120(2), 265–279.
- Yemcz, İ., & Sağır, S. (2021). İndirim Kampanyalarının Tüketicilerin Satın Alma Davranışı Üzerindeki Etkisi: Black Friday Örneği. *Avrasya Sosyal Ve Ekonomi Araştırmaları Dergisi*, 8(2), 308-331.
- Yılmaz, H. (2018). *Antalya ili Konut Satışının Çoklu Doğrusal Regresyon ve Yapay Sinir Ağları ile Tahmini*, Yüksek Lisans Tezi, Akdeniz Üniversitesi, Sosyal Bilimler Enstitüsü, Antalya.
- Yılmaz, M. B., & Çilengiroğlu, Ö. V. (2022). Talep Tahminleme Değişkenlerinin Üssel Düzeltme Yöntemi ile Belirlenmesi. *Euroasia Journal of Mathematics, Engineering, Natural & Medical Sciences*, 9(22), 92–103.
- Yu, R., & Abdel-Aty, M. (2014). Analyzing crash injury severity for a mountainous freeway incorporating real-time traffic and weather data. *Safety Science*, 63, 50–56.
- Yücesan, M. (2018). YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. *İşletme Araştırmaları Dergisi*, 10(1), 689–706.
- Yücesoy, M. (2011). *Temizlik Kağıtları Sektöründe Yapay Sinir Ağları ile Talep Tahmini*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.