

Tedarik Zinciri Yönetiminde Makine Öğrenmesi Uygulamaları

Ersin Şener¹

Pakize Yiğit²

Emrah Önder³

Özet

Tedarik zinciri verilerinden mevcut kalıpları keşfetmek her işletmede bir dönüm noktası olabilir. Yönetici müdahalesi veya analize rehberlik edecek taksonomiler olmadan Makine Öğrenimi (ML) algoritmaları ile tedarik zinciri verilerindeki yeni modeller günlük olarak bulunabilir. Algoritmalar kısıt tabanlı modelleme kullanarak verileri yinelemeli olarak sorgular ve en yüksek tahmin doğruluğuna sahip çözümü önerir. Özünde, Yapay Zeka (AI) ve makine öğrenimi algoritmaları, işletmelere envanter, tedarikçi kalitesi, potansiyel talep, tedarikten ödemeye, sipariştten nakde, üretim planlaması, lojistik yönetimi ve daha fazlasını etkileyen Tedarik Zinciri Yönetimi (TZY) faktörlerini yönetme konusunda içgörüler sağlamaktadır. Üretilen yeni bilgi ve içgörüler, TZY’de verimli karar alma süreçleri ve işletmeler için karlı yatırım önerileri sunar.

Tüm bu faydalar işletmeleri hızla geliştirerek isabetli kararlar alınmasını, öngörülebilirliği ve yüksek yatırım ve kârlılık getirisini beraberinde getirebilir. Ticaretin doğası, yatırımın kârlılıkla geri dönüşüne bağlıdır. Bu açıdan bakıldığında bu bölüm, TZY’deki güncel ML uygulamaları hakkında bilgi sahibi olmak ve mevcut literatürü takip etmek isteyen okuyucular için bir çözüm sunmaktadır.

- 1 Dr. Öğr. Üyesi, Kırklareli Üniversitesi Fen Edebiyat Fakültesi Matematik Bölümü Uygulamalı Matematik Anabilim Dalı, ersinsener@klu.edu.tr, ORCID: 0000-0002-5934-3652
- 2 Doç. Dr., İstanbul Medipol Üniversitesi Tıp Fakültesi Temel Tıp Bilimleri Bölümü Biyoistatistik ve Tıp Bilişimi Anabilim Dalı, pyigit@medipol.edu.tr, ORCID: 0000-0002-5919-1986
- 3 Prof. Dr., İstanbul Üniversitesi İşletme Fakültesi İşletme Bölümü Sayısal Yöntemler Anabilim Dalı, emrah@istanbul.edu.tr, ORCID: 0000-0002-0554-1290

1. Giriş

Ürünlerin sadece bir tık uzakta olduğu bir dünyada, Tedarik Zinciri Yönetimi (TZY) yöneticilere en son teknolojileri kullanarak verimli kararlar alma yetkisi verir. Bu küreselleşmiş pazar, doğal olarak alıcıları daha uygun fiyatlı seçenekler aramaya, daha hızlı tedarik ve hizmet ile güvenilir servis sonrası ağları talep etmeye yönlendirmektedir. Şirketler küresel pazarda rekabet edebilmek için doğru kararları hızlı ve verimli bir şekilde almalıdırlar. Tedarik zinciri yönetimlerini otomatikleştirmek, şirketlerin küresel oyuncularla rekabet edebilmelerini sağlar. TZY, günümüz iş operasyonlarının önemli bir bileşenidir ve ana tedarikçilerden son kullanıcılara kadar çeşitli tedarik zinciri faaliyetlerini sorunsuz bir şekilde entegre etmeyi sağlar (Lambert vd., 1998). TZY'nin temel amacı, müşteri değerini en üst düzeye çıkaran ve sürdürülebilir rekabet avantajı sağlayan yüksek kaliteli hizmetler, ürünler ve bilgiler sağlamaktır. Etkili TZY stratejileri, kuruluşlara operasyonel verimliliğini optimize etmeyi, maliyetlerini düşürmeyi ve müşteri memnuniyetini artırma gibi olanaklar sunmaktadır. Bu nedenle, TZY, giderek daha karmaşık ve dinamik hale gelen bir pazar ortamında rekabetçi kalmaya çalışan çeşitli sektörlerdeki işletmeler için kilit bir odak alanı olarak ortaya çıkmıştır (Deveci, 2023; Tirkolace vd., 2021; Wenzel vd., 2019; Younis vd., 2021).

TZY beş temel alanı kapsar: hammadde seçimi ve tedarigi, üretim, dağıtım (son kullanıcıya), satış ve hizmet. Müşterinin geri bildirimi, tedarik zinciri sürecinin sürekli olarak iyileştirilmesi için çok önemlidir. Müşteri geri bildirimleri, mevcut ürünlerin yeni versiyonlarının tasarlanmasına ve hizmet ağı üzerindeki iş yükünün potansiyel olarak en aza indirilmesine yol açabilir. Bu açıdan üretim, satış, geri bildirim ve yeniden üretim süreci bir zinciri temsil eder ve dolayısıyla TZY kavramını oluşturur. TZY, her bir süreçte kaydedilen verilerin analiz edilmesiyle mümkündür. Bununla birlikte, son yıllarda üretilen verilerin hacminin büyüklüğü, işletmelerin anlamlı içgörüler elde etmesini giderek zorlaştırmaktadır. TZY'de büyük veriyi yönetmek ve analiz etmek önemli zorluklar doğurmaktadır. Bu sorunu çözmek için birçok şirket, geleneksel matematiksel ve istatistiksel yöntemler kullanmak yerine yazılım endüstrisinde kendine yer bulan Makine öğrenimini (ML), tercih etmektedir.

ML kullanımı, büyük miktarda veriyi işleme kapasitesi nedeniyle TZY'deki araştırmacıların ilgisini çekmiştir. Geleneksel yaklaşımlar, büyük ölçekte yapılandırılmamış verileri ve doğrusal olmayan problemleri etkili bir şekilde analiz edememektedir. Ancak ML teknikleri bu zorlukları çözebilmekte ve tedarik zinciri performansını etkileyen faktörleri tahmin


edebilmektedir. ML, TZY’de büyük verileri analiz etmek isteyen işletmeler için paha biçilmez bir araçtır (Tirkolace vd., 2021).

Etkili Tedarik Zinciri Yönetimi, modern iş dünyasında rekabet avantajı elde etmek için çok önemlidir. En son teknoloji ve gelişmiş veri analitiği sayesinde işletmeler, iş süreçlerini kolaylaştırmak ve karar verme yeteneklerini geliştirmek için yeni fırsatlar yakalayabilir. Bu bölüm, şirketler için TZY’de ML yöntemlerinin potansiyel uygulama alanlarını ve gelecekteki bilimsel keşifler için potansiyel araştırma alanlarını belirlemeye yardımcı olmayı amaçlamaktadır. Aşağıdaki bölümde, TZY’deki çeşitli makine öğrenmesi uygulamalarına ilişkin bir literatür taraması sunulmuştur. İş operasyonlarının optimize edilmesindeki önemi de tartışılmaktadır. İkinci bölüm, veri analitiği ve makine öğreniminin büyüleyici dünyasını incelemektedir. Bu bölümde özellikle TZY’de en çok kullanılan ML algoritmalarından bazıları özetlenmiştir. Üçüncü bölümde, okuyuculara bu algoritmaların endüstriyel elektrik tüketimine ilişkin bir veri setine aydınlatıcı bir uygulaması sunulmaktadır. Bu veri seti, Endüstri 4.0’da teknolojinin artan rolü için ilgi çekici bir vaka çalışması sunmaktadır. Bölüm, çeşitli ML algoritmalarının performansının anlaşılır bir şekilde karşılaştırılması ve TZY’ye katkılarının yorumlanmasıyla sona ermektedir. Son olarak, bu heyecan verici alanda makine öğrenmesinin gelecekteki uygulamaları için öneriler sunulmuştur.

1.1. Literatür Taraması

Günümüz iş dünyasında şirketler, hammadde tedarikinden nihai ürünlerin müşterilere dağıtımına kadar tedarik zincirleri boyunca büyük miktarda veri üretmektedir. İşletmelerin müşteri memnuniyeti ve yüksek kâr elde edebilmeleri için bu verilerden değerli içgörüler elde etmeleri çok önemlidir. Endüstri 4.0’da işletmeler için temel zorluk veri toplamak değil, bu bilgilerden değerli içgörüler elde etmek ve bunları etkili bir şekilde uygulamaktır. Endüstri 4.0’ın sunduğu teknolojik gelişmeler, TZY ortamını hızla dönüştürmektedir (Şahin, 2023).

TZY süreçlerinin görsel bir haritası Şekil 1.1’de sunulmuştur. Şekilde üretim süreçleri soldan sağa doğru gösterilmiş ve gelen bilgilerle üretimde kaliteyi artırmak için sağdan sola doğru bir zincir oluşturulmuştur.



Şekil 1.1 Tedarik Zinciri Yönetim Süreci (Supply Chain Diagram | Supply Chain Flowcharts | Creately, 2021)

Geçtiğimiz birkaç yıl içinde makine öğrenmesi, teknolojik gelişmeler ve bilgi işlem gücü sayesinde giderek daha popüler hale geldi. Tedarik zinciri yönetiminde ML ve AI kullanan birçok çalışma bulunmaktadır. Bunlardan ML kullanan bazıları aşağıda ele alınmıştır.

Talep tahmini yönetimi her işletmenin önemli bir unsurudur. Gelecekteki talebi doğru bir şekilde tahmin etmek, kuruluşların envanterlerini optimize etmelerine, tedarik zincirlerini yönetmelerine ve üretim programlarını planlamalarına yardımcı olabilir. Etkili talep yönetimi, işletmelerin arz ve talebi dengelemesine, stoksuzlukları en aza indirmesine ve tedarik sürelerini azaltmasına yardımcı olabilir. ML, TZY’de talep tahmin süreçlerini iyileştirmek için kullanılmıştır (İfraz vd., 2023). Geçmiş satış verileri, mevsimsel değişimler ve pazar eğilimleri analiz edilerek daha doğru talep tahminleri yapılabilir. Bu, envanter yönetimini optimize etmek ve stok seviyelerini en aza indirmek için önemli bir avantaj sağlamıştır.

Talep tahminine yönelik bir ML uygulamasında, Kanada Dökümhanelerinden alınan SCM verileri ve siparişleri simüle edilerek farklı tahmin teknikleri denenmiştir. Çalışma, boğa güreşi etkisi (*bullwhip effect*) olarak da bilinen çarpık talebi tahmin etmek için naif (*naïve*) kestirim, trend analizi, hareketli ortalamalar, doğrusal regresyon, tekrarlayan sinir ağları (*recurrent neural networks-RNN*) ve destek vektör makineleri gibi yöntemlerin etkinliğini karşılaştırmıştır. Sonuçlar, RNN ve destek vektör makinesi tekniklerinin regresyon yaklaşımıyla karşılaştırılabilir sonuçlar sunduğunu göstermektedir (Carbonneau vd., 2008).

Tedarik Zinciri Risk Yönetimi (TZRY) işletmeler için çok önemli bir sorundur. Aksaklıkları önceden tahmin etmek ve önlemek için AI destekli

ML yöntemlerinin kullanılması kapsamlı bir şekilde araştırılmıştır. Bununla birlikte, genellikle tahminlerin anlaşılabilirliği göz ardı edilerek tahmin doğruluğu üzerinde yoğunlaşmıştır (Ye vd., 2015; Zage vd., 2013). Bu durumu ele almak için hem tahmin doğruluğunu hem de anlaşılabilirliği dengeleyen veri odaklı bir yapay zekâ çerçevesi önerilmiştir. Bu yaklaşım, sevkiyat gecikmelerini tahmin etmek için gerçek tedarik zinciri verileri üzerinde test edilmiştir. Sonuçlar, doğruluk yerine anlaşılabilirliğe öncelik vermenin bazı tavizler vermeyi gerektirebileceğini ortaya koymaktadır (Baryannis vd., 2019).

Tedarik zinciri yönetiminde makine öğrenmesi uygulamaları beş temel alana dayanmaktadır: hammadde seçimi ve tedarigi, üretim, dağıtım (tüketiciye teslimat dahil), satış ve hizmet. Bu beş ana alanda makine öğrenmesini kullanan birçok çalışma bulunmaktadır. Bunlardan bazıları aşağıdaki gibi özetlenebilir. TZY’de tedarikçi değerlendirme ve seçim problemleri oldukça önemlidir. Tedarikçiler, perakendeci için nitelikli ve uygun olan doğru ürün veya hizmetin uygun miktarını doğru zamanda ve yerde teslim edebilir. Bu alanda veri bulmak genellikle zordur, bu nedenle küçük örneklem boyutları ve eksik veri gibi sorunlar yaygındır (Ni vd., 2020a). ML algoritmaları bu tür verilerle başa çıkmada başarılıdır. Örneğin, Lee ve arkadaşları (Lee vd., 2022) tedarik seçimi için takviyeli öğrenmeyi kullanmıştır. Endüstri 4.0’ın devreye girmesiyle birlikte ML teknikleri, veri kullanılabilirliği, yüksek işlem gücü ve geniş depolama kapasitesi nedeniyle üretim planlama ve kontrolünü ele almak için cazip bir yol haline gelmiştir (Usuga Cadavid vd., 2020).

Üretim planlaması için bulanık mantık ve karar ağaçları gerçek hayat uygulamalarında tatmin edici sonuçlar elde etmiştir (González Rodríguez vd., 2020). Ayrıca Garre ve diğerleri (Garre vd., 2020) makine öğrenmesi yöntemlerinin gıda endüstrisindeki üretim anormalliklerini geleneksel modellere göre daha iyi tespit edebildiğini göstermiştir. Tsolaki (Tsolaki vd., 2023) yük taşımacılığı, SC ve lojistik alanlarını kullanarak tüm makine öğrenmesi ve hibrit yöntemleri gözden geçirmiştir. Tüm makine öğrenmesi ve hibrit yöntemlerin bu alanda bilgi keşfini, planlamayı ve karar vermeyi desteklediğini belirtmişlerdir.

Talep ve satış tahmini çok değişkenli doğrusal olmayan ilişkilere sahiptir, bu nedenle ML tabanlı yöntemler geleneksel yöntemlerden daha iyi performans göstermiştir. Feizabadi (Feizabadi, 2022) talep tahmini için ARIMAX ve YSA modellerini karşılaştırmıştır ve YSA tahmin doğruluğu ARIMAX’tan daha yüksek bulunmuştur. Punia ve Shankar (Punia & Shankar, 2022) talep tahmini için hem geleneksel (ARIMA, ARIMAX), hem ML (RF,

ANN, LSTM) hem de hibrit ML modellerini kullanmış ve ML ve hibrit ML modellerinin geleneksel modellerden daha iyi performans ölçütlerine sahip olduğunu bulmuştur. Satış sonrası hizmetlerini iyileştirmek ve daha verimli TZY sağlamak için müşteri geri bildirimlerine ihtiyaç duyulmaktadır. Anketler, görüşmeler ve pazar araştırmaları yaygın olarak kullanılmaktadır, ancak bu yöntemlerin daha fazla sayıda örnekleme ulaşması gerekmektedir. Sosyal medya verileri, müşterilerin gerçek görüşlerine erişebilmek için son zamanlarda bu alanda kullanılmaya başlanmıştır. ML algoritmalarını Nesnelerin İnterneti (IoT) ile entegre etmek, büyük verileri işlemek için kullanılmıştır (Ni vd., 2020b). Khatua ve diğerleri (Khatua vd., 2021) de AI ile sosyal medya analizinin ürün performansı, marka itibarı, müşteri segmentasyonu, talep tahmini ve hizmet değerlendirmesi gibi belirli TZY alanlarının verimliliğini artırdığını belirtmiştir.

Endüstri 4.0'ın ortaya çıkmasıyla birlikte dijitalleşme (IoT), blok zinciri, büyük veri, bulut bilişim ve robotik gibi kavramlar da geliştirilmiştir. İşletmeler son zamanlarda TZY faaliyetlerini geliştirmek için bu yeni teknolojileri uygulamaya çalışmaktadır. Bu nedenle, büyük miktarda etkileşimli veriyi hızlı ve akıllı bir şekilde yorumlamak için büyük veri, AI ve ML yöntemlerini kullanılmıştır (Nagar vd., 2021; Tirkolace vd., 2021). Örneğin, araştırmacılar ML yöntemlerini kullanarak TZY'deki IoT ve standart uygulamalar arasındaki farkı araştırmışlardır (Li vd., 2022; Rizwan vd., 2022). Yazarlar, TZY'deki IoT uygulamalarının standart olanlardan daha iyi çalıştığını; standart olanlara kıyasla verimliliği ve kârı artırdığını bulmuşlardır. Öte yandan Cadavid ve arkadaşları (Usuga Cadavid vd., 2020), Endüstri 4.0 döneminde üretim, planlama ve kontrol problemleri için ML uygulamalarını incelemiştir. Üretim sistemindeki değişiklikleri hesaba katmak için makine öğrenmesi modelini güncelleme zorluğu ve veri toplamak için IoT teknolojilerini kullanmanın karmaşıklığı nedeniyle araştırmanın alanla ilgili bilgileri güncellemek için yetersiz olduğunu bildirmişlerdir.

TZY, kavramı ilk kez kullanıldığı 1980'li yıllardan bu yana yöneylem araştırmasında önemli bir konu olmuştur (Oliver & Webber, 1982; Pourhejazy & Kwon, 2016). Optimizasyon modelleri bu alanda en yaygın kullanılan yöneylem araştırması araçlarıdır (Barbosa-Póvoa vd., 2018). Bulanık teori ve esnek hesaplama, TZY optimizasyon problemlerini çözmek için çoğunlukla makine öğrenmesi yöntemlerini kullanmaktadır (Ni vd., 2020a). Abbasi ve arkadaşları (Abbasi vd., 2020) kan tedarik zinciri yönetimi optimizasyon problemini YSA, CART, K-NN ve RF kullanarak çözmüştür. Lin ve arkadaşları (Lin vd., 2022), performans optimizasyon problemini çözmek için yenilikçi bir makine öğrenmesi yöntemi kullanmıştır.

Tedarik Zinciri Yönetimi'nde makine öğrenmesini uygulamanın en önemli avantajlarından biri, işletmelerin verilerinden değerli çıkarımlar yapmalarına olanak sağlamasıdır. İkinci olarak, yöneticilere gerçek zamanlı içgörüler sağlayarak potansiyel riskleri en aza indirmesi sayılabilir. Son olarak da kapsamlı verilerin verimli bir şekilde analiz edilmesini sağlayarak tedarik zinciri hakkında tutarlı ve doğru bilgiler sağlamasıdır.

2. Veri Analitiği ve Türleri

Endüstri 4.0 dönemi, makinelerden ve internete bağlı ağ sensörlerinden gelen bol miktarda veri ile karakterize edilmektedir. Veri analitiği ve makine öğrenmesi, bu verileri anlamlandırmak ve makine zekasına ulaşmak için gerekli hale gelmiştir. Bu güçlü araçlar, izleme görevlerinden kritik karar alma süreçlerine kadar sürecin her yönüne nüfuz ederek geleneksel operasyonlarda ve TZY'de devrim yaratmıştır. Analitik sistemler, operasyonel verimliliği artıran, hataları ve kusurları en aza indiren, maliyetleri düşüren, kaliteyi geliştiren ve üretkenliği artıran sürdürülebilir karar verme süreçleri geliştirmek için bu verileri işleyerek entegre edilebilmektedir. Veri, akıllı ve sürdürülebilir üretim ve tedarik zinciri operasyonlarında girdi aynı zamanda da çıktıdır. Karar verme için hayati bir girdiyi ve gerçek zamanlı geri bildirim için temel bir çıktıyı temsil eder. Nihai hedefler geliri en üst düzeye çıkarmak ve maliyetleri en aza indirmekken, veri analitiği bu verileri bu hedeflere ulaşmaya yardımcı olabilecek anlamlı içgörülere dönüştürmek için hayati önem taşır.

Makine öğrenmesi yöntemleri uygulanarak çeşitli veri analizi aşamaları gerçekleştirilebilir. Bu aşamalar tahmine dayalı, tanısal, kuralcı ve açıklayıcı analitikleri içermektedir. Tahmine dayalı analitikler, potansiyel üretim çıktısını ve makinelerin kalan ömrünü tahmin etmek için istatistiksel modeller kullanır. Teşhis analitiği ise hem makine hem de ürünlerdeki arızaları tespit eder ve raporlar. Kural koyucu analitik, üretimi optimize etmek ve belirli eylemlerin etkisini belirlemek için öneriler sunar. Tanımlayıcı analitik, üretim sürecini ve ortamını çevreleyen koşulları incelemekte ve tanımlamaktadır (Kotsiopoulos vd., 2021).

2.1. Makine Öğrenmesi

Sayısal veriler ya da sayılarla ifade edilebilen gözlemler içeren her problemin bir çözüme ihtiyacı vardır. Günümüz koşullarında bu problemlerin klasik yöntemlerle manuel olarak çözülmesi mümkün olmadığından bilgisayarlar bu rolü üstlenmektedir. Bilgisayarların karmaşık problemlere algoritmalarla çözüm sunduğu bilinmektedir. Algoritmalar bilgisayarların çözüm elde etmesini ve konu hakkında bilgi edinmesini sağlar. ML, karmaşık sayısal

değerlere sahip problemleri makine diline çevirerek algoritmalar aracılığıyla çözümler.

Basit bir ifadeyle makine öğrenmesi, verilerden öğrenmek için bilgisayar sistemlerini kullanan bir teknolojidir. Bu teknolojinin temel amacı, TZY’de veri analizi, tahmin ve karar verme süreçlerini optimize etmektir. Makine öğrenmesinin temel ilkelerine aşina olmak, bu teknolojinin pratikte uygulanmasını sağlamak için çok önemlidir. ML, büyük miktarda veriyi analiz ederek kalıpları ve ilişkileri tanımlayabilmektedir. Bu yetenek, tedarikçi performansının değerlendirilmesi, talep tahminlerinin güncellenmesi ve envanter yönetiminin optimize edilmesi gibi TZY’nin birçok alanında kullanılabilir. Doğru ve güvenilir veri toplama süreçleri, ML uygulamalarının başarılı olmasını sağlamaktadır.

ML’in sınıflandırma, regresyon, kümeleme ve hibrit görevler dahil olmak üzere birçok kullanım alanı bulunmaktadır. Sınıflandırma, girdilerin önceden belirlenmiş sınıflara atanmasını içerirken, regresyon çeşitli özelliklere dayalı bir çıktı tahmin etmektedir. Temel fark, regresyonun sürekli bir çıktı değeri üretmesi, sınıflandırmanın ise ayrık bir çıktı değeri sunmasıdır. Kümeleme ise bir grup nesnenin daha küçük, benzer gruplara bölünmesini içermektedir. Hibrit görevler, her kategoriye sürekli değer biçiminde kategorik değerler atamak gibi sınıflandırma, regresyon veya kümelemeyi bir araya getirmektedir (Jo, 2021).

2.1.1. Makine Öğrenmesi Türleri

Sıklıkla kullanılan dört makine öğrenimi yöntemi vardır: denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme.

2.1.1.1. Gözetimli Öğrenme

Denetimli öğrenme girdi-çıkı verilerinden tahmin yapar. Bir öğretmenden öğrenildiğini varsayar. Modelin başarısı, eğitim aşamasında oluşturulan modelin yeni test verilerindeki çıktıyı ne kadar iyi tahmin ettiği ile ölçülür. Karar Ağaçları (DT), Naïve Bayes (NB), Destek Vektör Makinesi (DVM), k-en yakın komşu (KNN) ve denetimli yapay sinir ağları (ANN), TZY çalışmalarında sıklıkla kullanılan algoritmalarıdır (Tirkolae vd., 2021).

2.1.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme “öğretmensiz öğrenme” olarak da adlandırılmaktadır. Öğrenme sürecinde sadece girdi verileri vardır, çıktı verileri yoktur. Öğrenme yöntemi, çıktı verisi olmadan verinin karakteristik yapısını bulmayı

amaçlamaktadır. Denetimli öğrenmenin aksine, bu öğrenme yaklaşımlarında kesin bir başarı ölçütü yoktur. Ancak araştırmacılar en az farklılık gösteren ya da en çok benzeyen örüntüleri belirlemeye çalışmaktadır. K-ortalamlar kümeleme (k-means clustering), temel bileşen analizi (PCA) ve denetimsiz sinir ağı yöntemleri bu alanda önde gelen algoritmalar (Tirkolace vd., 2021).

2.1.1.3. Yarı Gözetimli Öğrenme

Denetimli öğrenme sadece verilerin etiketlenmesini gerektirir ki bu da uygulamalarda her zaman mümkün değildir. Yarı denetimli yöntemler, denetimli ve denetimsiz öğrenmeyi birleştirerek bu sorunu çözmektedir (Sammur & Webb, 2017). Kendi kendine eğitim ve transdüktif SVM yöntemleri, TZY uygulamalarında yaygın olarak kullanılmaktadır (Tirkolace vd., 2021).

2.1.1.4. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme, zaman içinde ödülü en üst düzeye çıkaracak şekilde nasıl hareket edileceğini bularak karmaşık sistemler için uyarlanabilir bir kontrolör olarak çalışabilir. Denetleyicinin (takviyeli öğrenme ajanı olarak da adlandırılır) amacı, uzun vadeli hedefleri en üst düzeye çıkarmak için dinamik sistemin yaşayabileceği her durumda en uygun kontrol eylemlerini öğrenmektir (Boute vd., 2022; Rolf vd., 2023). Klasik Q öğrenme yöntemleri, TZY problemlerinde en çok kullanılan algoritmalar (Rolf vd., 2023).

2.1.2. Makine Öğrenmesi Algoritmaları

Bu bölümde literatürde en çok kullanılan denetimli ve denetimsiz öğrenme algoritmaları özetlenmiştir. Regresyon, lojistik regresyon (LR), KNN, NB, DT, rastgele orman (RF), SVM, denetimli ANN ve Xgboost denetimli öğrenme algoritmalarıdır. K-means, hiyerarşik kümeleme, gürültülü uygulamaların yoğunluk tabanlı uzamsal kümelenmesi (DBSCAN), PCA ve birliktelik kuralları ise denetimsiz öğrenme algoritmalarıdır.

1. **Regresyon** : Regresyon modellerinin iki türü vardır: doğrusal ve doğrusal olmayan. Doğrusal bir fonksiyona uyan girdi değişkenlerini kullanarak bir çıktı değişkenini modellemek mümkündür; bu süreç doğrusal regresyon olarak bilinir ve hesaplanması oldukça basittir. Bir model doğrusal olmayan bir fonksiyona uyduğunda doğrusal olmayan regresyon gerçekleştirmek zordur (Haykin, 2009).

2. **Lojistik regresyon (LR):** LR, sınıflandırma problemleri için kullanılır ve doğrusal regresyon tekniğini uyarlar (Hastie vd., 2008). Modelde cevap değişkeni kategoriktir ve sonuç için bir değer tahmin etmek yerine cevap değişkenlerinin kategorileri için olasılığı tahmin etmeye çalışır (Kantardzic, 2020). Girdi veri setleri hem nicel hem de kategorik olabilir.
3. **K-En Yakın Komşuluk (KNN):** KNN, regresyon ve sınıflandırma problemleri için kullanılır. Algoritma, yakınlıkta bulunan kümelenmiş veri setlerini bularak sınıflandırma ve regresyon problemlerini çözmeyi amaçlar. Bu nedenle eğitim seti K adet en yakın örneğe bölünür. Doğrusal ve doğrusal olmayan problemleri kullanan etkili ve uygulaması kolay bir algoritmadır, ancak performansı kullanıcının uygun K'yı seçmesine bağlıdır (Shyam vd., 2023).
4. **Naive Bayes (NB):** NB, Bayes teoremine dayanan sağlam bir sınıflandırma algoritmasıdır. Eğitim verilerinden sınıf üyelerinin olasılığı ve her bağımsız gösterge göz önüne alındığında sınıf üyeleri için koşullu olasılık olmak üzere iki tür olasılık hesaplanabilir. Her bir girdi göstergesinin bağımsız olduğunu varsaydığı için "naive" olarak adlandırılır. Hayati bir varsayım olmasına ve gerçek veriler için pratik olmamasına rağmen, yöntem çeşitli zorlu konularda inanılmaz derecede iyi sonuç vermektedir (Shobha ve Rangaswamy, 2018).
5. **Karar ağacı (DT):** DT'ler regresyon ve sınıflandırma kullanan etkili parametrik olmayan algoritmalarıdır. Test fonksiyonlarına sahip karar düğümlerini kullanan bir dizi özyinelemeli bölünmenin yerel bölgeyi tanımladığı hiyerarşik bir modeldir. Tipik olarak, arama uzayının belirli bir alanında bir çözüm bulmak için karar ağacı öğrenme sistemleri tarafından yukarıdan aşağıya bir yaklaşım kullanılır. Bu, basit bir ağacın bulunmasını sağlar; ancak bu en basit ağaç olmayabilir. Bir karar ağacındaki düğümler, nitelikleri test etmek için kullanılır (Kantardzic, 2020).
6. **Rastgele Orman (RF):** RF, regresyon ve sınıflandırma görevleri için topluluk karar ağacı tabanlı bir algoritmadır. Çok sayıda karar ağacından oluşur ve sonuçları oluşturmak için tahminlerini toplar. Eğitim sürecinde, birçok karar ağacı hem verilerin hem de özelliklerin rastgele seçimleri üzerinde eğitilir. Ormanda, her ağaç belirli bir girdi için bir tahmin üretir ve nihai tahmin, tüm ağaçların bireysel tahminlerinin ortalama (regresyonda) veya oylama (sınıflandırmada) yoluyla toplanmasıyla belirlenir. Aşırı uyumu azaltarak daha doğru bir tahmin elde edilmesini sağlar (Shyam vd., 2023).

7. **Destek Vektör Makinesi (SVM):** SVM, regresyon ve sınıflandırma problemleri için güvenilir ve iyi bilinen bir tekniktir. Marjı optimize ederken veri noktalarını farklı sınıflara verimli bir şekilde bölen bir hiper düzlem (yüksek boyutlu bir uzayda bir çizgi veya düzlem) bulmak SVM'lerin arkasındaki ana fikirdir. Hiper düzleme en yakın veri noktaları destek vektörleri olarak adlandırılır ve hiper düzlemin konumlandırılması üzerinde en önemli etkiye sahiptirler (Shyam vd., 2023).
8. **Yapay Sinir Ağları (ANN):** ANN'ler, beyin ve sinir sisteminin nasıl çalıştığını tahmin etmek için en etkili yöntemler arasındadır. Bu algoritmalar parametrik değildir ve derin öğrenme metodolojisi ile tüm makine öğrenimi yöntemlerini (denetimli, denetimsiz, yarı denetimli ve takviyeli öğrenme yöntemleri) kullanabilir. Sonuç olarak, gerçek dünya senaryolarında doğru tahminler üretebilir.
9. **Aşırı Gradyan Güçlendirme (Xgbost):** XGBoost, hem sınıflandırma hem de regresyon görevleri için karar ağaçlarının ilkelerini kullanan bir topluluk yöntemidir. Birkaç karar ağacını eğitmek için gradyan artırma metodolojisini kullanır. Random Forest, eğitim setinden rastgele alt kümeler seçerek karar ağaçları oluştururken, XGBoost daha önce oluşturulmuş ağaçların performansını göz önünde bulundurarak karar ağaçlarını sırayla oluşturur.
10. **K-Means:** K-Means algoritması, basitliği ve gücü nedeniyle popüler denetimsiz algoritmalarından biridir. Bir çeşit bölümlendirme kümeleme tekniğidir. Algoritma, her grubun merkezini (ortalamasını) kullanarak verileri kullanıcı tarafından belirtildiği gibi K kümeye ayırır. Daha sonra belirli koşullar sağlanana kadar gözlemleri kümelere yinelenmeli olarak atar. Kriterlerin birincil amacı, farklı kümeler arasındaki uzamsal ayrımı en üst düzeye çıkarırken bir küme içindeki gözlemler arasındaki uzamsal ayrımı azaltmaktır. Uzaklık hesaplamasında genellikle Öklid uzaklığı kullanılır (Hair, 2019).
11. **Hiyerarşik Kümeleme:** Hiyerarşik kümeleme, sabit k kümesi olmayan başka bir uygulanabilir ve pratik algoritmadır; grup sayısı iterasyonlarla değişir. Yukarıdan aşağıya bir yaklaşım kullanarak kümeleri dendrogramlarla görselleştirir. Başlangıçta, her örnek aynı kümenin bir parçasıdır; iterasyonlardan sonra, her örnek kendi kümesine aittir.
12. **DBSCAN:** Bölümlendirme ve hiyerarşik yaklaşımlar küresel şekle sahip kümeleri bulmayı amaçlar. Oval ve "S-şekilli" kümeler gibi keyfi


şekilli grupları bulmakta zorlanırlar. Kümelerdeki aykırı değerleri bulmada iyi değillerdir, bu nedenle yoğunluk tabanlı yöntemler kullanılır. DBSCAN çekirdek nesneleri (nesnenin yakınındaki birkaç nesne tarafından hesaplanan bir nesnenin yoğunluğunun durumu) tanımlamıştır; bunlar yoğun komşulukları olan nesnelerdir (Han vd., 2012).

13. Temel Bileşenler Analizi (PCA): PCA öncelikle boyut azaltma için kullanılır. Verileri temsil etmek için en uygun k adet n boyutlu ortogonal vektör bulur ($k < n$). Orijinal verilerin önemli ölçüde daha küçük bir uzaya yansıtılması nedeniyle boyutluluk azaltılır. PCA, sıralı ve sırasız göstergeler için idealdir ve seyrek ve çarpık verileri çözebilir (Han vd., 2012).

14. Birliktelik Kuralları: Birliktelik kuralları, denetimsiz öğrenme sistemlerini kullanarak yerel örüntüleri bulmayı amaçlar. En popüler ve önemli makine öğrenimi tekniklerinden biridir çünkü verideki kullanıcının önceden bilemeyeceği “altın bilgileri” dikkate alır. En çok kullanılan birliktelik kuralları teknikleri pazar sepeti ve apriori algoritmalarıdır (Kantardzic, 2020).

3. Tedarik Zinciri Yönetiminde Makine Öğrenmesi (Vaka Çalışması)

Çalışma, tedarik zinciri yönetiminde makine öğrenmesinin uygulanmasını ele almaktadır. Endüstri 4.0 bağlamında tedarikten üretime, üretimden pazarlamaya, son kullanıcılara teslimata ve satış sonrası hizmete kadar bir bilgi döngüsü oluşturan tedarik zincirindeki bu süreçlerin otomasyonunu vurgulamaktadır. Endüstrinin hızlı gelişimi, artan elektrik tüketimi ile kanıtlanmaktadır. Bu noktadan hareketle, Türkiye’de son dört yılda sektörde faturalandırılan elektrik tüketim verileri EPİAŞ web sitesinden derlenmiştir. Analiz, tüketim verileri kullanılarak Ocak 2019’dan başlayıp Ekim 2023’ten sona eren 58 aylık bir dönemi kapsamaktadır. Veriler, Şekil 3.1’de gösterildiği gibi MWh cinsinden aylık elektrik tüketimini göstermektedir.



Şekil 3.1 Sanayi Elektrik Tüketimi (MWh)

Genellikle aylık olarak artan elektrik tüketimi, destek vektör regresyonu (SVR), doğrusal regresyon (LR), ikinci dereceden polinom regresyonu (QuPR), kübik polinom regresyonu (CPR) ve kuartik polinom regresyonu (QPR) yöntemleri kullanılarak tahmin edilmiştir. Tablo 3.1 tahmin edilen ve gerçek değerleri göstermektedir.

Tablo 3.1 Sanayide Öngörülen ve Gerçekleşen Elektrik Tüketim Değerleri (MWh)

Ay	SVR	LR	QuPR	CPR	QPR	Gerçek Değer
Ocak, 19	3.9046E+06	2.6812E+06	1.8949E+06	1.6910E+06	1.9361E+06	2.0080E+06
Şubat, 19	3.9046E+06	2.7141E+06	2.0106E+06	1.8496E+06	2.0087E+06	1.9109E+06
Mart, 19	3.9046E+06	2.7470E+06	2.1233E+06	2.0015E+06	2.0883E+06	2.1107E+06
...	...	...	...	...	...	...
Ağustos, 23	3.9046E+06	4.4918E+06	3.8681E+06	3.9899E+06	4.0768E+06	4.2996E+06
Eylül, 23	3.9046E+06	4.5247E+06	3.8212E+06	3.9821E+06	4.1412E+06	4.1674E+06
Ekim, 23	3.9046E+06	4.5576E+06	3.7713E+06	3.9752E+06	4.2202E+06	4.2364E+06

Makine öğrenmesi yöntemlerinin tahmin performansını gözlemlemek için MAPE değerleri hesaplanmış ve Tablo 3.2’de verilmiştir. Gözlemler sonucunda, QPR yönteminin sektördeki aylık elektrik tüketimini tahmin etmede diğer makine öğrenimi yöntemlerinden daha iyi performans gösterdiği görülmüştür. Tedarik zinciri yönetiminde QPR yönteminin kullanılması, sektördeki aylık elektrik tüketimi için yüksek doğrulukta tahminler yapılmasını sağlayabilir.

Tablo 3.2 MAPE değerleri

SVR	LR	QuPR	CPR	QPR
19.73%	12.39%	6.32%	5.96%	5.53%

Bu durumda makine öğrenmesi çoklu yöntemlerle uygulandığında başarılı tahminler vermiştir. Modelin daha başarılı sonuçlar verebilmesi için sanayi sektörünün ilgili dönem verilerinden daha kapsamlı bir veri seti ile daha yüksek performanslı sonuçlar elde edilmesi kaçınılmazdır. Bu bağlamda tedarik zincirinin ilk aşaması olan satın alma sürecinin makine öğrenmesi yöntemleri ile tahmin edilebileceğine ve modellenilebileceğine örnek teşkil etmektedir.

4. Sonuçlar

Teknolojik gelişmelerin mevcut tedarik zinciri yönetimine yepyeni bir bakış sunacağı alandaki çalışmaların artarak devam etmesinde de bu çalışmanın hazırlık sürecinde görülmüştür. Gerek AI gerekse ML yöntemleri işletmelerin yönetim asistanlığını üstleneceği öngörülmektedir. Bu bağlamda, tedarik zinciri yönetiminin çok boyutlu ele alınmasını ve bu süreçte de işletmelerin sektördeki pozisyon hedefleri doğrultusunda bu araçları kullanması kaçınılmazdır. Alanda inceleme yapmayı planlayan araştırmacılar için Tedarik Zinciri Yönetiminde Makine Öğrenmesi uygulamalarının daha kapsamlı bir okuması için [web arşivini](#) incilmesi tavsiye olunur.

Kaynakça

- Abbasi, B., Babaci, T., Hosseinifard, Z., Smith-Miles, K., & Dehghani, M. (2020). Predicting solutions of large-scale optimization problems via machine learning: A case study in blood supply chain management. *Computers & Operations Research*, 119, 104941. <https://doi.org/10.1016/j.cor.2020.104941>
- Barbosa-Póvoa, A. P., Da Silva, C., & Carvalho, A. (2018). Opportunities and challenges in sustainable supply chain: An operations research perspective. *European Journal of Operational Research*, 268(2), 399-431. <https://doi.org/10.1016/j.ejor.2017.10.036>
- Baryannis, G., Dani, S., & Antoniou, G. (2019). Predicting supply chain risks using machine learning: The trade-off between performance and interpretability. *Future Generation Computer Systems*, 101, 993-1004. <https://doi.org/10.1016/j.future.2019.07.059>
- Boute, R. N., Gijbrecchts, J., Van Jaarsveld, W., & Vanvuchelen, N. (2022). Deep reinforcement learning for inventory control: A roadmap. *European Journal of Operational Research*, 298(2), 401-412. <https://doi.org/10.1016/j.ejor.2021.07.016>
- Carbonneau, R., Laframboise, K., & Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140-1154. <https://doi.org/10.1016/j.ejor.2006.12.004>
- Deveci, T. P., Muhammet (Ed.). (2023). *Smart and Sustainable Operations and Supply Chain Management in Industry 4.0*. CRC Press. <https://doi.org/10.1201/9781003180302>
- Feizabadi, J. (2022). Machine learning demand forecasting and supply chain performance. *International Journal of Logistics Research and Applications*, 25(2), 119-142. <https://doi.org/10.1080/13675567.2020.1803246>
- Garre, A., Ruiz, M. C., & Hontoria, E. (2020). Application of Machine Learning to support production planning of a food industry in the context of waste generation under uncertainty. *Operations Research Perspectives*, 7, 100147. <https://doi.org/10.1016/j.orp.2020.100147>
- González Rodríguez, G., Gonzalez-Cava, J. M., & Méndez Pérez, J. A. (2020). An intelligent decision support system for production planning based on machine learning. *Journal of Intelligent Manufacturing*, 31(5), 1257-1273. <https://doi.org/10.1007/s10845-019-01510-y>
- Hair, J. F. (2019). *Multivariate Data Analysis*.
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques* (3. bs). Morgan Kaufmann is an imprint of Elsevier.
- Hastie, T., Robert, T., & Friedman, J. (2008). *The Elements of Statistical Learning* (Second). Springer US.

- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed). Prentice Hall.
- İfraz, M., Aktepe, A., Ersöz, S., & Çetinyokuş, T. (2023). Demand forecasting of spare parts with regression and machine learning methods: Application in a bus fleet. *Journal of Engineering Research*, 11(2), 100057. <https://doi.org/10.1016/j.jer.2023.100057>
- Jo, T. (2021). *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*. Springer International Publishing. <https://doi.org/10.1007/978-3-030-65900-4>
- Kantardzic, M. (2020). *Data Mining: Concepts, Models, Methods, and Algorithms* (3. bs). Wiley.
- Khatua, A., Khatua, A., Chi, X., & Cambria, E. (2021). Artificial Intelligence, Social Media and Supply Chain Management: The Way Forward. *Electronics*, 10(19), 2348. <https://doi.org/10.3390/electronics10192348>
- Kotsiopoulos, T., Sarigiannidis, P., Ioannidis, D., & Tzovaras, D. (2021). Machine Learning and Deep Learning in smart manufacturing: The Smart Grid paradigm. *Computer Science Review*, 40, 100341. <https://doi.org/10.1016/j.cosrev.2020.100341>
- Lambert, D. M., Cooper, M. C., & Pagh, J. D. (1998). Supply Chain Management: Implementation Issues and Research Opportunities. *The International Journal of Logistics Management*, 9(2), 1-20. <https://doi.org/10.1108/09574099810805807>
- Lee, C.-Y., Chou, B.-J., & Huang, C.-F. (2022). Data science and reinforcement learning for price forecasting and raw material procurement in petrochemical industry. *Advanced Engineering Informatics*, 51, 101443. <https://doi.org/10.1016/j.aci.2021.101443>
- Li, J., Zhang, R., Jin, Y., & Zhang, H. (2022). Optimal Path of Internet of Things Service in Supply Chain Management Based on Machine Learning Algorithms. *Computational Intelligence and Neuroscience*, 2022, 1-11. <https://doi.org/10.1155/2022/4844993>
- Lin, H., Lin, J., & Wang, F. (2022). An innovative machine learning model for supply chain management. *Journal of Innovation & Knowledge*, 7(4), 100276. <https://doi.org/10.1016/j.jik.2022.100276>
- Nagar, D., Raghav, S., Bhardwaj, A., Kumar, R., Lata Singh, P., & Sindhwani, R. (2021). Machine learning: Best way to sustain the supply chain in the era of industry 4.0. *Materials Today: Proceedings*, 47, 3676-3682. <https://doi.org/10.1016/j.matpr.2021.01.267>
- Ni, D., Xiao, Z., & Lim, M. K. (2020a). A systematic review of the research trends of machine learning in supply chain management. *International Journal of Machine Learning and Cybernetics*, 11(7), 1463-1482. <https://doi.org/10.1007/s13042-019-01050-0>

- Ni, D., Xiao, Z., & Lim, M. K. (2020b). A systematic review of the research trends of machine learning in supply chain management. *International Journal of Machine Learning and Cybernetics*, 11(7), 1463-1482. <https://doi.org/10.1007/s13042-019-01050-0>
- Oliver, R. K., & Webber, M. D. (1982). *Supply chain management: Logistics catches up with strategy*.
- Pourhejazy, P., & Kwon, O. (2016). The New Generation of Operations Research Methods in Supply Chain Optimization: A Review. *Sustainability*, 8(10), 1033. <https://doi.org/10.3390/su8101033>
- Punia, S., & Shankar, S. (2022). Predictive analytics for demand forecasting: A deep learning-based decision support system. *Knowledge-Based Systems*, 258, 109956. <https://doi.org/10.1016/j.knosys.2022.109956>
- Rizwan, A., Karras, D. A., Kumar, J., Sánchez-Chero, M., Mogollón Taboada, M. M., & Altamirano, G. C. (2022). An Internet of Things (IoT) Based Block Chain Technology to Enhance the Quality of Supply Chain Management (SCM). *Mathematical Problems in Engineering*, 2022, 1-12. <https://doi.org/10.1155/2022/9679050>
- Rolf, B., Jackson, I., Müller, M., Lang, S., Reggelin, T., & Ivanov, D. (2023). A review on reinforcement learning algorithms and applications in supply chain management. *International Journal of Production Research*, 61(20), 7151-7179. <https://doi.org/10.1080/00207543.2022.2140221>
- Sammut, C., & Webb, G. I. (Ed.). (2017). *Encyclopedia of Machine Learning and Data Mining*. Springer US. <https://doi.org/10.1007/978-1-4899-7687-1>
- Shobha, G., & Rangaswamy, S. (2018). Chapter 8—Machine Learning. *İçinde Handbook of Statistics* (C. 38, ss. 197-228).
- Shyam, K. P., Ramya, V., Nadiya, S., Parashar, A., & Gideon, D. A. (2023). Systems biology approaches to unveiling the expression of phospholipases in various types of cancer—Transcriptomics and protein-protein interaction networks. *İçinde Phospholipases in Physiology and Pathology* (ss. 271-307). Elsevier. <https://doi.org/10.1016/B978-0-443-15177-4.00016-9>
- Supply Chain Diagram | Supply Chain Flowcharts | Creately*. (2021, Kasım 3). <https://creately.com/usage/supply-chain-management-tools-examples/>
- Şahin, M. (2023). Machine Learning and Data Analytics. *İçinde Smart and Sustainable Operations and Supply Chain Management in Industry 4.0*. CRC Press. 10.1201/9781003180302-15
- Tirkolaei, E. B., Sadeghi, S., Mooseloo, F. M., Vandchali, H. R., & Acini, S. (2021). Application of Machine Learning in Supply Chain Management: A Comprehensive Overview of the Main Areas. *Mathematical Problems in Engineering*, 2021, 1-14. <https://doi.org/10.1155/2021/1476043>
- Tsolaki, K., Vafeiadis, T., Nizamis, A., Ioannidis, D., & Tzovaras, D. (2023). Utilizing machine learning on freight transportation and logistics appli-

- cations: A review. *ICT Express*, 9(3), 284-295. <https://doi.org/10.1016/j.icte.2022.02.001>
- Usuga Cadavid, J. P., Lamouri, S., Grabot, B., Pellerin, R., & Fortin, A. (2020). Machine learning applied in production planning and control: A state-of-the-art in the era of industry 4.0. *Journal of Intelligent Manufacturing*, 31(6), 1531-1558. <https://doi.org/10.1007/s10845-019-01531-7>
- Wenzel, H., Smit, D., & Sardesai, S. (2019). *A literature review on machine learning in supply chain management*. <https://doi.org/10.15480/882.2478>
- Ye, S., Xiao, Z., & Zhu, G. (2015). Identification of supply chain disruptions with economic performance of firms using multi-category support vector machines. *International Journal of Production Research*, 53(10), 3086-3103. <https://doi.org/10.1080/00207543.2014.974838>
- Younis, H., Sundarakani, B., & Alsharairi, M. (2021). Applications of artificial intelligence and machine learning within supply chains: systematic review and future research directions. *Journal of Modelling in Management*, 17(3), 916-940. <https://doi.org/10.1108/JM2-12-2020-0322>
- Zage, D., Glass, K., & Colbaugh, R. (2013). Improving supply chain security using big data. *2013 IEEE International Conference on Intelligence and Security Informatics*, 254-259. <https://doi.org/10.1109/ISI.2013.6578830>