



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 29.08.2025
Kabul Tarihi : 11.12.2025

Received Date : 29.08.2025
Accepted Date : 11.12.2025

ENTEGRASYON MİMARİSİ KULLANAN TEDARİK ZİNCİRİNİN MAKİNE ÖĞRENMESİ İLE DESTEKLENMESİ

ENHANCING SUPPLY CHAIN WITH INTEGRATION ARCHITECTURE AND MACHINE LEARNING

*Fatih SOYGAZI*¹ (ORCID: 0000-0001-8426-2283)

*Haktan AKDAĞ*² (ORCID: 0009-0003-2151-7228)

Kevser ÖZTÜRK^{3*} (ORCID: 0009-0006-4888-066X)

¹ Aydın Adnan Menderes Üniversitesi, Bilgisayar Mühendisliği Bölümü, Aydın, Türkiye

² Aydın Adnan Menderes Üniversitesi, Aydın, Türkiye

³ Gebze Teknik Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Fatih SOYGAZI, fatih.soygazi@adu.edu.tr

ÖZET

Tedarik zincirinde dijitalleşme, çağımızın zorunluluğu haline gelmiştir. Bir tedarik zinciri takip sistemi geliştirilirken, siparişin verilmesi, mevcut stok durumunun tespiti, stok seviyelerindeki hammadde veya yarı mamül malzemelerin alım ya da tüketim süreçlerinin izlenmesi için sürekli olarak malzemelerin veri giriş ve çıkışlarını analiz eden otonom, entegre ve akıllı sistemlerin geliştirilmesine ihtiyaç vardır. Bu doğrultuda çalışma kapsamında, farklı paydaşlarda bulunan ERP (Enterprise Resource Planning - Kurumsal Kaynak Planlaması) sistemlerindeki verinin ortaklaşa kullanılabilmesi için bir mimari önerilmiş ve bu entegrasyon mimarisinden elde edilen veriden yararlanılarak hammadde miktarının tahminlenebilmesi üzerinde durulmuştur. Örnek senaryoda, yüzde fazla ekmek satış noktası olan bir fırın tarafından kullanılan un miktarının tespitine dair çalışmalar gerçekleştirilmiştir. Bu çalışmalar, makine öğrenmesi yöntemleri ile regresyon analizi üzerine yürütülmüştür. Önerilen çalışmadaki hedef, un stoğunun an itibarıyla yeterli olup olmadığının tespitidir. Bu noktada, regresyon modeli kullanımıyla elde edilen un miktarından yararlanarak sonraki gün stokta olacak un miktarının belirli bir hata payı ile tespit edilmesi hedeflenmektedir. Yapılan çalışmada, geleneksel makine öğrenmesi ve derin öğrenme yöntemleri kullanılmıştır. Elde edilen sonuçlar, XAI (Explainable Artificial Intelligence - Açıklanabilir Yapay Zekâ) yöntemleri kullanılarak yorumlanmıştır. Tüm bu süreç sonucunda R^2 0,90 ve MAE (Mean Absolute Error - Ortalama Mutlak Hatası) değeri 39,25 olarak en iyi sonucu LightGBM algoritması vermiştir.

Anahtar Kelimeler: Tedarik zinciri, makine öğrenmesi, entegrasyon, regresyon

ABSTRACT

Digitalization has become a necessity of our era within the supply chain. When developing a supply chain tracking system, there is a need to create an autonomous system to analyze the data inputs and outputs of materials that require continuous monitoring, such as order placement, determination of current stock status, and procurement or consumption processes of raw materials or semi-finished goods at stock levels. In this context, the focus has been on the possibility of using ERP systems among different stakeholders for shared data usage and forecasting based on this data. In the use case scenario, studies have been conducted on determining the amount of flour used by a bakery with over a hundred bread sales points. These studies were conducted using machine learning method is regression. The goal of proposed study was to determine whether the flour stock is sufficient at the moment. Here, the aim is to predict the amount of flour that will be in stock the next day with a certain margin of error, using the available flour quantity with the use of regression models. In this study, traditional machine learning and deep learning methods were used. The results obtained were interpreted using XAI (Explainable Artificial Intelligence) methods. As a result of this entire process, the LightGBM algorithm yielded the best result with an R^2 value of 0.90 and a MAE (Mean Absolute Error) value of 39.25.

Keywords: Supply chain, machine learning, integration, regression

GİRİŞ

ERP sistemleri, ülkemizde ve dünyada ticari faaliyet yürüten kurum ve kuruluşların satın alma, üretim, muhasebe, finans, nakit akışı ve satış gibi temel operasyonlarını planlayıp yönettiği; kayıt tutma ve raporlama işlevleriyle mevcut iş süreçlerini takip edebildiği sistemlerdir. Bazı ERP sistemleri, yalnızca muhasebe süreçleri için kullanılırken bazıları üretim ve tedarik zinciri yönetimi de dâhil olmak üzere işletmenin uçtan uca yönetimini sağlayan kurumsal bilgi sistemleri olarak kullanılmaktadır.

Önceki nesil sistemlerde, tüm tedarik zinciri (Mentzer vd., 2001) süreçlerini tecrübeli depo, muhasebe ve finans uzmanları yönetmekteydi. Endüstri 4.0 devrimi ile beraber (Hazen vd., 2014; Davis, 1993) bu sistemler süreçleri ve raporlamaları kolaylaştırdığı için otomasyona bağlanmıştır (Ghobakhloo, 2020). Endüstri 4.0 ile otomasyon ve süreçleri otomatikleştiren yazılımların geliştirilmesi ile birlikte sahadan veri toplanarak bazı çıkarımlar yapılabilmektedir. Örneğin bir muhasebe programında ilk bakışta sadece fatura keserek muhasebe uzmanlarının işini kolaylaştırmak amaçlanmışken, daha sonra toplanan fatura verilerinden finansal analizler yapılmaya başlanmıştır. Aynı şekilde fabrikalardaki otomasyona bağlı üretim planlama cihazlarından toplanan verilerle üretim verimliliği hesaplanarak daha optimal üretim planlama yapılabilmesi sağlanmıştır. Kayıt altına alınan verilerin analiz edilmesi, matematiksel formüller dışında daha teknik kavramlar olan makine öğrenmesi süreçlerinin de dahil edilmesiyle (Rai vd., 2021) birlikte mevcut olanın analizinden ziyade, olacakların tespitine ve tahminlenmesine odaklanılmıştır. Bu amaç doğrultusunda makine öğrenmesinin tedarik zincirinde kullanımı, tedarik zincirini otomatikleştirmeye, karar vermeyi iyileştirmeye ve riskleri azaltmaya önemli ölçüde yardımcı olmaktadır (Rodríguez vd., 2024).

Önceki nesil sistemlerde, uç sistemler birbirinden farklı olduğu için herhangi bir entegrasyon sistemi olsa bile süreçler manuel yürütülmekteydi. Verinin başka bir sisteme aktarılması kişilerin sorumluluğunda olduğundan, sürecin aksaması veya sistemsel sorunların oluşması durumunda tüm iş akışı sekteye uğramaktaydı. Bu sebeple önerilen çalışmada, verinin akışına göre yorum yapabilecek yetenekte bir sistem tasarlanması hedeflenmiştir. Böylece oluşabilecek olumsuz durumlarda, aksamalar minimize edilebilecektir. Teknik olarak tüm paydaşların makineler üzerinden birbiriyle tam entegre şekilde çalışabilmesi sağlandıktan sonra, nihai olarak elde edilen veriyi analiz edecek bir makine öğrenmesi yöntemi tasarlanmıştır.

Bahsi geçen süreçlerdeki problemlerin çözülmesi amacıyla çalışma kapsamında aşağıdaki katkılara odaklanılmıştır: 1-) Her paydaşın kendi sistemlerinde bulunan veriler aslında birbiri ile ilişkili olmasına rağmen, veri tiplerinin ve sistemlerin heterojen olmasından dolayı çoğu sistemde veri bütünlüğü sağlanamamaktadır (Xu vd., 2005). Bir entegrasyon mimarisi geliştirilerek tedarikçi, aracı ve müşteriler arasındaki tedarik zincirinde bulunan verinin bütünlüğü sağlanmıştır. Böylece çalışmada, veri bütünlüğünü sağlamak amacı ile mikroservis tabanlı bir uygulama önerilmiş ve geliştirilmiştir (Cebeci & Korçak, 2020).

2-) Makine öğrenmesi ile tedarik zincirindeki entegrasyon (Groenewald vd., 2024; Aamer vd., 2020; Ni vd., 2020) aşamasında elde edilen veriler, örnek bir senaryo olarak üretiminde un kullanılan ürünler için un miktarının gelecekteki talebinin tahmin edilmesi amacıyla regresyon analizine tabi tutulmuştur. Bu senaryoda, farklı ERP sistemlerinden toplanan stok hareketleri, satış kayıtları ve üretim verileri birleştirilerek un tüketim miktarının zaman içerisindeki değişimi modellenmiştir. Böylece, kritik stok seviyelerine ulaşmadan önce gerekli tedarik planlamasının yapılabilmesi hedeflenmiştir.

3-) Regresyon analizinin ardından, açıklanabilir yapay zeka (XAI) yöntemlerinden LIME kullanılarak modelin tahminlerine en çok katkı sağlayan değişkenler belirlenmiştir. Bu değişkenlerin tahmin üzerindeki pozitif ve negatif etkileri değerlendirilmiş ve tedarik zinciri yönetiminde operasyonel karar destek süreçlerinde nasıl kullanılabileceğine dair çıkarımlar yapılmıştır.

LİTERATÜR TARAMASI

Tedarik zinciri yönetiminde (Min vd., 2019; Özdemir, 2004) alım işlemleri, veri girişi çıkışı takibi gibi işlemlerin otonomlaşması ve bu süreçlerin dijitalleşmesi günümüzde oldukça önem arz etmektedir. Bu sayede gereksiz maliyetin önüne geçerek ve kaynakları efektif kullanarak işletmelerin verimliliğinin artması hedeflenmektedir. Bu literatür taraması, tedarik zinciri yönetim süreçlerinin dijitalleşmesi ve makine öğrenmesi tekniklerinin kullanımıyla ilgili çalışmaları incelemeyi amaçlamaktadır.

Tedarik zinciri entegrasyonu, işletmelerin ağları (Lee vd., 1997) arasında yani üreticileriyle, tedarikçileriyle, distribütörleriyle ve müşterileriyle daha yakın işbirliği yaparak verimlilik ve esneklik sağlamayı amaçlar.

Tiwari (Tiwari, 2021), Endüstri 4.0'ın SCI (Supply Chain Integration - Tedarik Zinciri Entegrasyonu), tedarik zinciri ve organizasyon üzerindeki performans artırımında önemli bir rol oynadığını belirtmiştir. Bu çalışma, tedarik zinciri süreçleriyle çeşitli entegrasyon düzeylerini anlamak için kapsamlı bir literatür taraması sunmaktadır.

Khanuja ve Jain (Khanuja & Jain, 2019), organizasyonların tedarik zinciri performansını artırmak için iç entegrasyon, müşteri entegrasyonu ve tedarikçi entegrasyonunun önemini vurgulamaktadır. Bilgi paylaşımı, süreç koordinasyonu ve stratejik iş birliklerin tedarik zinciri entegrasyonu sonuçlarını nasıl artırdığını açıklamaktadır.

Makine öğrenmesi ve yapay zeka tekniklerinin tedarik zinciri yönetiminde kullanımı, işletmeler için karar destek sistemleri sunar ve işletmelerin tahminleme yeteneklerini geliştirir. Aamer vd. (2020), talep tahmininde makine öğrenmesi uygulamalarının tedarik zincirindeki zorlukların üstesinden gelmede çeşitli şekillerde yardımcı olabileceğini vurgulamaktadır. Bu uygulamaların, geliştirilmiş tahmin doğruluğu, azaltılmış hesaplama maliyetleri, daha iyi envanter yönetimi, kamçı etkisinin (bullwhip effect) azaltılması, gelişmiş tedarik zinciri verimliliği ve değişen pazar koşullarına uyarlanma esnekliği gibi faydaları olduğu belirtilmiştir. Makale, bu yaklaşımların kuruluşlara değerli içgörüler sunarak bilinçli kararlar almalarını sağladığını, tedarik zinciri operasyonlarını optimize etmelerine ve rekabet güçlerini artırmalarına katkıda bulunduğunu öne sürmektedir. Carbonneau vd. (2008), tedarik zinciri talep tahmininde ileri makine öğrenmesi tekniklerinin uygulanabilirliğini inceleyerek, bullwhip etkisinde talebin tahmin edilmesine odaklanmaktadır. Bu çalışma, sinir ağları (neural networks), tekrarlayan sinir ağları (recurrent neural networks – RNNs) ve destek vektör makineleri (Support Vector Machine - SVM) de dahil olmak üzere ileri makine öğrenmesi tekniklerinin kullanılabilirliğini incelerken, bu yöntemleri naif tahmin (naive forecasting), trend, hareketli ortalama ve lineer regresyon gibi daha geleneksel yöntemlerle karşılaştırmaktadır. İki farklı veri seti üzerinde yapılan deneyler sonucunda, tekrarlayan sinir ağları ve destek vektör makinelerinin en iyi performansı gösterdiği ancak tahmin doğruluğunun, lineer regresyon modelinden istatistiksel olarak anlamlı derecede daha iyi olmadığı bulgusuna ulaşılmıştır.

Tedarik zinciri entegrasyonu ve makine öğrenmesi, işletmelerin süreçlerini optimize etmek ve operasyonel verimliliği artırmak için birleştirilerek kullanılmaktadır. Böylece sürdürülebilirlik ve dirençli üretim için ortam hazırlanmaktadır. Groenewald vd. (2024), tedarik zincirinde oluşan belirsizlik, aksaklık gibi pek çok durumdan etkilenebilecek ve verimsizleşmeye yatkın tedarik zincirindeki süreçlerin yapay zeka ile çözülebileceğini ortaya koyan bir çalışma yürütmüşlerdir. Tedarik zincirindeki planlama, kaynak kullanımı, üretim, lojistik ve dağıtım süreçlerini yapay zeka çözümleri ile incelemektedir. Yapay zeka, tedarik zincirinde bir dizi fayda sağlayabilir. Örneğin, büyük veri kümelerini analiz ederek desenleri tanımlayabilir, talebi doğru tahmin edebilir, envanter seviyelerini optimize edebilir ve üretim süreçlerini akıllıca yönetebilir. Yapay zeka, tedarik zincirindeki riskleri tanımlamak, değerlendirmek ve azaltmak için kullanılabilir. Örneğin, tedarikçi başarısızlıklarını önceden tahmin edebilir, talep dalgalanmalarını öngörebilir ve jeopolitik belirsizliklere karşı önlemler alabilir. Tedarik zincirindeki talep tahminlerini geliştirebilir, lojistik planlamayı optimize edebilir ve üretim süreçlerini daha verimli hale getirebilir. Bu da stok yönetimini iyileştirir ve müşteri memnuniyetini artırır. Bu faydalar, yapay zekanın tedarik zinciri yönetimindeki önemini ve potansiyelini vurgular. Fakat çalışma detaylı yapay zeka çalışma alanlarına yer vermemiş ve testler yapmamıştır. Bu bağlamda, önerdiğimiz çalışma, söz konusu potansiyellerin pratikteki etkilerini ortaya koymak amacıyla uygulanmıştır.

Toorajipour vd. (2021), sürü zekasının karmaşık problemleri çözmek için etkili bir teknik olarak kullanılabilirliğinden bahsetmektedir. Sürü zekası; fiyatlandırma sistemleri, ürün yelpazesinin optimizasyonu, envanter yenileme, tedarik zinciri ağ mimarisi optimizasyonu ve tedarik zinciri maliyetlerinin azaltılması gibi alanlarda, tedarik zinciri yönetimi çalışmalarında kullanılabilir. SVM ise veri sınıflandırması ve karmaşık veri setlerinde ince desenleri çözme konularında etkili olabilir. Tedarik zinciri yönetiminde SVM; talep tahmini, zaman serisi sınıflandırması, tedarikçi seçimi ve tedarik zinciri ağlarının tasarımı gibi çeşitli amaçlarla kullanılabilir.

Elufioye vd. (2024), tarımsal tedarik zincirlerinde talep tahmini ve arzın optimize edilmesi amacıyla makine öğrenmesi ve derin öğrenme tabanlı yapay zekâ teknolojilerinin kullanımını incelemiştir. Çalışmada bu teknolojilerin, tedarik zinciri doğruluğunu ve verimliliğini artırma, maliyetleri azaltma, karar alma süreçlerini iyileştirme, uyarlanabilirliği ve sürdürülebilirliği güçlendirme potansiyeli tartışılmaktadır. Ayrıca yazarlar; veri kalitesi, bağlantı altyapısı, maliyet ve kullanıcıların sistemi benimsemesi gibi başlıca zorlukları tanımlayarak, bu engellerin aşılması ve tarımda yapay zekânın potansiyelinden tam olarak yararlanılmasına yönelik çeşitli öneriler sunmuştur.

Aljohani (Aljohani, 2023), tahmine dayalı analitiği ve makine öğrenmesini tedarik zinciri risk yönetimine entegre ederek kuruluşların reaktif risk yönetiminden proaktif ve öngörülü stratejilere nasıl geçiş yapabileceklerini anlatmaktadır. Önerilen çerçevenin değerlendirilmesiyle tahmine dayalı analitiğin entegrasyonu incelenmiştir. Çalışma, çerçevenin tedarik zinciri çevikliğini ve dayanıklılığını test etmek için gerçek dünya ve simülasyon ortamlarında kullanılmıştır. One-Class SVM algoritması kullanılarak 8.000 kayıt ile model eğitilmiş, 2.000 kayıt üzerinde test edilmiştir. Tahmine dayalı analiz sonuçları, modelin %89,5 doğruluk (accuracy), %82,1 kesinlik (precision), %74,3 duyarlılık (recall) ve %77,9 F1 skoru (F1-değeri) değerleri elde ettiğini göstermektedir. Erken uyarı sistemi testlerinde ise %81,9 precision, %80,6 recall ve %81,2 F1-değeri değerlerine ulaşılmıştır. Bu metrikler, modelin yüksek doğrulukla anomali tespiti yapabildiğini, yanlış pozitif (false positive) oranının düşük tutulduğunu ve risk yönetiminde etkin şekilde kullanılabileceğini ortaya koymaktadır. Ayrıca sistemin talep tahmini bulgularına göre, optimizasyon sonrası MAPE değeri %15'ten %8'e düşmüş ve %46,7 hata oranı düşüşü ile stok yönetiminde anlamlı iyileşmeler sağlandığını göstermektedir.

Prajapati (Prajapati, 2024), ilaç endüstrisinde tedarik zinciri optimizasyonunu araştırmak için veri analitiğinin entegrasyonunun kapsamını incelemiştir. Çalışmada veri analitiği yöntemlerinin ilaç sektöründeki tedarik zinciri operasyonlarını nasıl iyileştirebileceğini ve potansiyel faydalarını ortaya koymayı hedeflemektedir. Makalenin katkılarında, talep tahmini, envanter optimizasyonu, üretim çizelgeleme ve lojistik optimizasyonu gibi süreçler üzerinde yapılan deneylerle farklı yapay zeka ve veri analitiği tekniklerinin performansı değerlendirilmiştir. Örneğin, talep tahmini probleminde Rassal Orman (Random Forest) regresyon modeli, Doğrusal Regresyon (Linear Regression) modeline kıyasla daha iyi performans göstermiştir (RMSE: 80,20; MAE: 60,75; R²: 0,90; MAPE: %6,50). R² için 0,90 değeri, modelin talep değişkenliğini %90 oranında açıklayabildiğini göstermekte; bu da yüksek bir uyum düzeyine işaret etmektedir. MAPE'nin %6,50 olması ise tahminlerin ortalama %6,5 sapma ile gerçek değerlere çok yakın olduğunu ortaya koymaktadır. Ayrıca makalede, veri kümelerindeki benzerlikleri belirlemek ve envanter optimizasyonuna temel oluşturmak amacıyla K-Means Clustering yöntemi kullanılmıştır. Ardından, talep tahmininde doğrusal olmayan ilişkileri modelleyebilme yeteneği nedeniyle Deep Learning Neural Networks tercih edilmiş ve MAPE, MAE, RMSE metriklerinin değerleri düşerken ve R² değeri yükselmiş ve doğruluğu artmıştır. Bahsi geçen tüm çalışmaların sunmuş olduğu faydalar Tablo 1'de karşılaştırılmıştır.

Tablo 1. Tedarik Zincirinde Gelişen Süreçlerin Karşılaştırması

Katkılar	Sistemler	Tedarik Zinciri Entegrasyonu	Entegre Tedarik Zincirinde Makine Öğrenmesi Kullanımı
Tedarikçi ilişkilerinin güçlendirilmesi	✓	(Basana, Suprpto, Andreani, & Tarigan, 2022; Khanuja & Jain, 2019; Frohlich & Westbrook, 2001)	✓
Veri bütünlüğünün sağlanması	✓	(Basana vd., 2022)	✓
Karar verme süreçlerinin iyileştirilmesi	x		✓ (Prajapati, 2024)
Talep tahmini doğruluğunun artışı	x		✓ (Aamer vd., 2020; Carbonneau vd., 2008)
Maliyetlerin azaltılması	✓		✓ (Prajapati, 2024; Toorajipour vd., 2021; Carbonneau vd., 2008)
Esneklik ve adaptasyon kabiliyetinin artması	✓	(Droge, Vickery, & Jacobs, 2012)	✓
Verimlilik artışı	✓	(Basana vd., 2022; Tiwari, 2021; Khanuja & Jain, 2019)	✓ (Aamer vd., 2020)
Hizmet performansı	x		✓ (Carbonneau vd., 2008)
Olası risklerin azaltılması	x		✓ (Groenewald vd., 2024; Prajapati, 2024; Aljohani, 2023)

Çalışmamız, literatürde bulunan çalışmalara ek olarak tedarik zincirindeki her bir paydaşın kendi sistemlerinde bulunan veri tiplerinin ve sistemlerinin heterojenliğinden kaynaklanan veri bütünlüğü eksikliklerini ele alıp bu eksiklikleri giderme üzerinde durmaktadır. Ayrıca, makine öğrenmesi kullanılarak tedarik zinciri entegrasyonunun kritik noktaları üzerinde tahminler yapılmıştır. Böylece tedarik zinciri yönetimi alanında veri bütünlüğü ve entegrasyon konularında yeni bir bakış açısı sunulmuştur.

TEDARİK ZİNCİRİ YÖNETİMİ

Tedarik zinciri yönetiminde (Mohamed, 2024) tahmine dayalı analitik uygulamaları (Oyewole vd., 2024) arasından her ağ için stok seviyesini öngörme oldukça önemlidir. Stok seviyesi ne kadar iyi yönetilirse talep yönetimi ve bunun sonucunda üretim de o kadar tutarlı olacaktır (Acar & Yılmaz, 2013; Doğar, 2006). Önerilen çalışmada da tedarik zincirindeki heterojen verilerin bütünlüğü sağlanarak ve tedarik zinciri makine öğrenmesi ile entegre edilerek stok seviyesini doğruya en yakın şekilde tahminleme hedeflenmektedir. Bu hedef doğrultusunda, tedarik zincirini etkileyen faktörler ve bu faktörleri gözönüne alarak çözülecek problemler detaylandırılmıştır.

Sistemdeki Problemler

Tedarik süreci yönetimine dair geliştirilen uygulamaların sürekli kullanılabilirliği için sektörlerin beklentisine göre iyileştirilmeye devam etmesi gerekmektedir (Karakoç vd., 2020). Tek bir ERP sistemi o sektörün bir paydaştaki problemlerine çözüm üretmek için modül geliştirilmesine olanak sağlamaktadır. Ancak farklı paydaşların arasındaki veri aktarımı ve stok takibi gibi konuların çözülebilmesi için entegrasyon sistemlerinin çalışması gerekmektedir. Entegrasyon sistemleri olmadığı takdirde birbirinden bağımsız veri tutan paydaşlar arasında sağlıklı bir bilgi paylaşımı gerçekleşmeyebilir (Koçoğlu vd., 2011; Bagchi vd., 2005). Bilgi paylaşımı mümkün olmadıkça paydaşların üretim veya talep konusundaki tahminleme yapması da zorlaşmaktadır.

Entegrasyon sistemleri (Power, 2005), günümüzde rekabetin ve piyasadaki ürün çeşitliliğinin artmasıyla birlikte önem kazanmıştır. Distribütörler ve bayiler, farklı markaların ürünlerini kendi portföylerine ekleyerek müşterilere daha geniş bir seçenek sunmaktadırlar. Ancak, bu durumda dağıtıcılar farklı marka ve ürünleri aynı satış sistemleri üzerinden yönetmekte zorlanmaktadırlar. Özellikle distribütörlerin farklı ürünler için farklı satış sistemleri kullanmaları, verimliliği azaltmakta ve süreçlerin sağlıklı bir şekilde yürütülmesini engellemektedir. Bunun sebebi, bir bölgeye hitap eden bir distribütörün rakip marka ürünlerini de satıyor olması, o bölgedeki fiyat belirleyiciliği ile ilgili rol oynayabileceğine işaretler. Entegrasyon sistemleri bu tür problemleri çözmek için geliştirilmektedir ve bu sistemlerin tedarik zinciri üzerindeki olumlu etkileri aşikardır (Yu vd., 2013). Özellikle entegrasyon sistemlerinin ilerlemesiyle, farklı satış sistemleri ve ERP sistemleri arasında veri akışını sağlayacak yöntemler geliştirilmektedir (Davenport & Brooks, 2004). Bu entegrasyon sistemleri, distribütörlerin ve bayilerin satış ve ERP sistemlerini beslemekte ve verimli bir işleyiş sağlamaktadır.

Entegrasyon çalışmalarını yapabilmek ve verileri sağlıklı bir biçimde taşıyabilmek için hedef ve kaynak sistemlere ait veri yapılarını veya web service/web API (Application Programming Interface - Uygulama Programlama Arabirimi) dokümanlarındaki bilgilere hakim olmak gerekmektedir. Bu nedenle, yalnızca teknik yazılım bilgisine sahip ekiplerin yanı sıra, süreç, muhasebe, satış yönetimi ve veri yapılarına hakim teknik ekiplerin de olması gereklidir. Entegrasyonu sağlamak kadar önemli başka bir husus ise aktarılan verilerin doğruluğunu sağlamak için veri uzmanlarıyla verilerin analiz edilerek hedef ile kaynak sistemlerden çekilen verilerin birbirleriyle tutarlılığını kontrol edilmesidir.

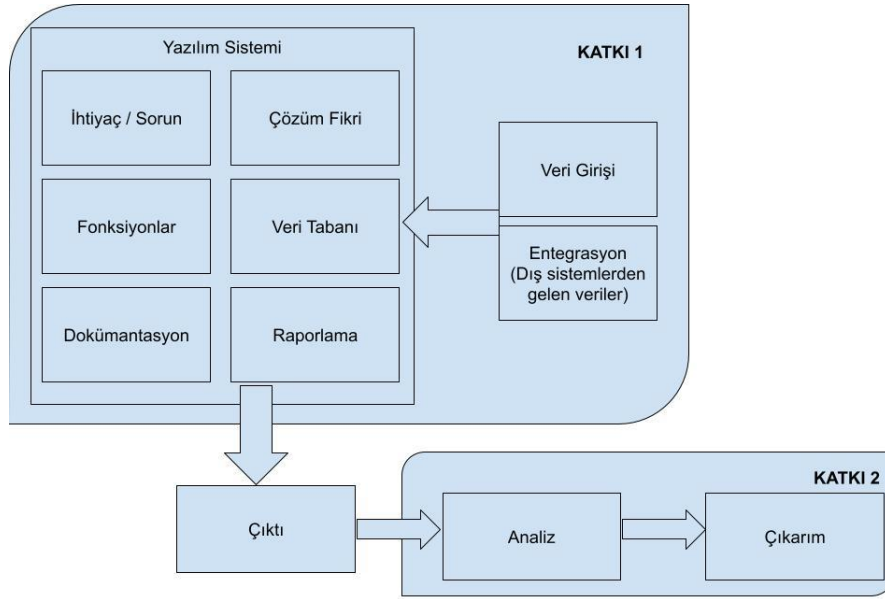
Tutarlılık denetiminin sistematik ve tekrarlanabilir olması için, entegrasyona konu veri setleri ile kaynak ve hedef sistemlerden periyodik olarak alınan raporlar, denetim kayıtları (audit log'lar) kullanılarak karşılaştırılmaktadır. Her aktarım sonrasında, ilgili döneme ait satış ve stok verileri her iki sistemden de elde edilmekte; ürün, miktar ve tutar gibi alanlar standart bir şablona dönüştürülerek eşleşme sağlanmaktadır. Bu yaklaşım, entegrasyon sonrasında ortaya çıkabilecek veri bütünlüğü sapmalarının nicel olarak izlenmesine imkân vermektedir. Bu bütünlük yapı, talep tahmini ve karar destek sistemlerine aktarılan veri kümelerinin de aynı veri bütünlüğü düzeyini korumasını sağlayarak, modelleme ve analiz sonuçlarının güvenilirliğini artırmaktadır.

Bu çerçevede entegrasyon süreci, veri girişini otomatikleştiren ve hatasızlaştıran bir süreçtir. Şekil 1'de görüldüğü üzere, Giriş bölümünde ifade edilen birinci katkı (entegrasyon mimarisi geliştirilmesi) ve ikinci katkı doğrultusunda (makine öğrenmesi ile veri analizi) elde edilen veriler üzerinden analiz ve çıkarım yapılır.

TEDARİK ZİNCİRİNDEKİ ENTEGRASYON MİMARİSİ

Bu çalışmada, tedarik zincirindeki veri entegrasyonu sağlanarak makine öğrenmesi yardımı ile tahminleme ve regresyon uygulamaları geliştirilmiştir. İlk olarak, her bir paydaşın kendi sistemlerinde bulunan ve birbirleriyle ilişkili olan Şekil 2'deki verilerin entegrasyonu için bir mimari tasarlanmıştır. Farklı veri tipleri ve heterojen sistemler nedeniyle birçok sistemde veri bütünlüğü bulunmamaktadır. Bu sorunu çözmek amacıyla tedarikçi, aracı ve müşteriler arasındaki veriler mikroservis tabanlı bir uygulama ile bütünlüştürülmüştür. Geliştirilen bu entegrasyon

mimarisi, veri bütünlüğünü sağlamak için önemli bir adım olup, tedarik zinciri boyunca verinin tutarlı ve uyumlu olmasını sağlamaktadır.



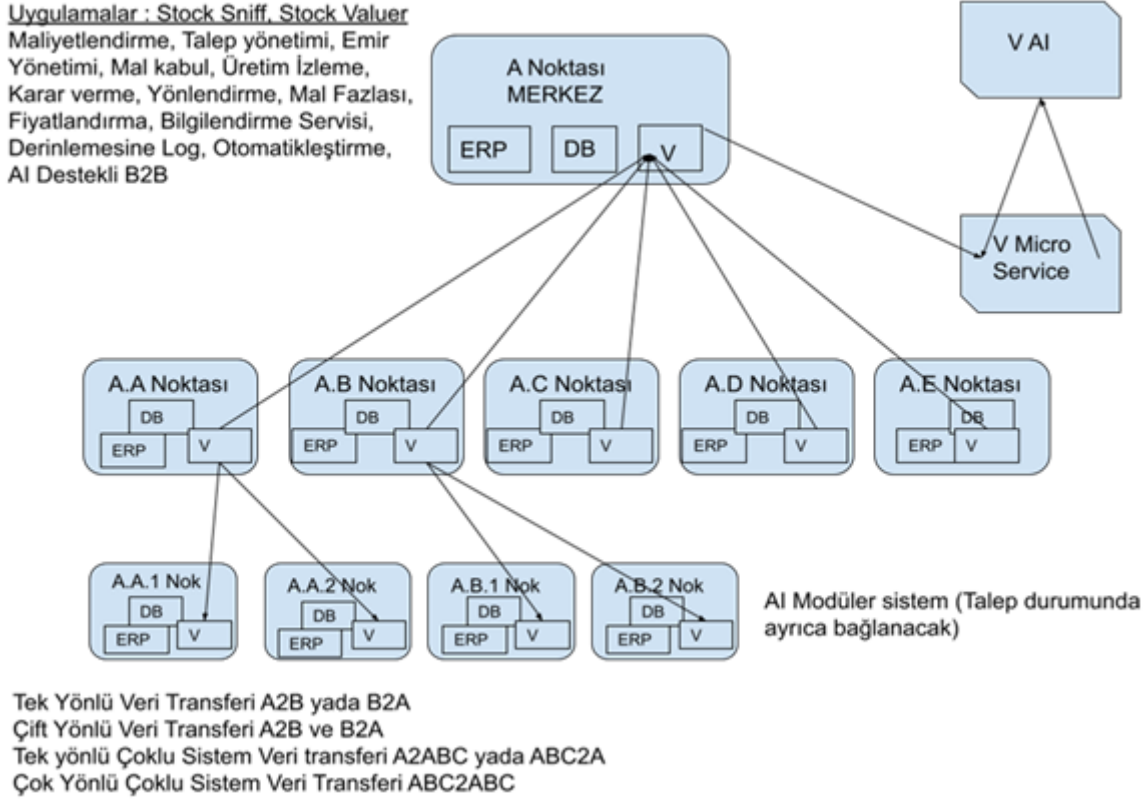
Şekil 1. Entegrasyon Sürecinde Veri Girişi ve İşlenmesi

İkinci olarak, “Tedarik Zincirinde Makine Öğrenmesi” başlığında anlatılan makine öğrenmesi yöntemleri kullanılarak tedarik zincirindeki entegrasyon sürecinde önemli olan noktaların sınıflandırılması ve regresyon analizi yapılmıştır. Bu analizler, tedarik zincirindeki verilerin etkin bir şekilde işlenmesi ve analiz edilmesini mümkün kılmıştır. “Sistemdeki Problemler” başlığında anlatılan stok seviyesi tahminleme ve bu tahminleme ile ihtiyaç doğrultusunda sipariş alınması sağlanmıştır. Kritik stok seviyesi tahminleme yapılarak her paydaşın çalıştığı sistem içerisindeki veriler sipariş planlama için elde edilebilmiştir.

Tedarik Zincirinde Entegrasyon

Veri ortaklaştırma süreçleri, ilgili ticari sistemlerde bulunan veri tabanlarındaki veri yapılarına bağlı dinamik bir altyapı oluşturmayı gerektirmektedir. Ticari sistemdeki tüm noktalarda kullanılan veri tabanları farklı veri kolonları içerebilir, ancak bu veri kolonları aynı veriyi temsil etmektedir. Bu farklılıklar dil veya farklı kelime kullanımı değişimlerinden kaynaklanmaktadır. Örnek olarak, ekmek verisi için un ve powder farklı veri çıkışlarını temsil etmekle beraber aslında aynı kavramı göstermektedir. Çalışmada önerilen sistemin amacı, makineyi ürün konusunda tutarlı hale getirmektir. Şekil 2’de, farklı ticari sistemlerin birden fazla noktasının olduğu ve ilgili ticari sistemlerden çekilecek olan verilerin veri yapılarının ortaklaştırılması gerekliliği vurgulanmaktadır.

V (veri çekme uygulaması) olarak gösterilen mimari (kurum içi adıyla Void Entegrator), heterojen ERP (Kurumsal Kaynak Planlaması) ve operasyonel veri tabanlarından (Database - DB) veri çekimi, doğrulaması, standart şemaya dönüştürme ve hedef sistemlere (raporlama vb.) güvenilir aktarım için tasarlanmış mikroservis tabanlı bir ara katmandır. Şekil 2’de kullanılan “tek yönlü” (A2B ya da B2A) ve “çift yönlü” (A2B ve B2A) ibareleri veri akışının yönünü belirtir. Tek yönlü entegrasyonda, veri (bir veya daha fazla iş bilgisi) kaynak sistemden hedef sisteme iletilmekte; çift yönlü entegrasyonda ise iki sistem arasında karşılıklı/eşzamanlı veri alışverişi gerçekleşmektedir. Çok kaynaktan tek hedefe (ABC2A) olan modellerde, birden fazla kaynaktan toplanan veriler birleştirilip anlamlandırılarak tek bir hedef sisteme aktarılır; tek kaynaktan çok hedefe (A2ABC) olan modellerde ise tek bir kaynaktan üretilen ortak verilerin devamlı ve kesintisiz bir şekilde uç sistemlere aktarılması söz konusudur. Çok kaynaklı ve çok hedefli (ABC2ABC) veri entegrasyonunda, her sistem kendi başına bağımsız olarak çalışabilmektedir ve uygulamalar arasında devamlı veri transferi gerçekleşmektedir. Tüm bu yaklaşımlar, sahadaki entegrasyon senaryolarının sade ama işlevsel bir sınıflandırmasıdır (Akdağ & Kocakoç, 2023).



Şekil 2. Ticari Sistemlerden Çekilecek Veriler

V katmanı; doğrudan veritabanı okumayı, mevcut servis/API kullanımlarını, dosya-temelli aktarımı ve raporlama arayüzlerinden çekimi destekleyen çoklu yöntemlerle çalışmaktadır ve bu yöntemler Şekil 3'te numaralandırılarak özetlenmiştir. Bu çoklu yöntemlerin koordinasyonu ve veri bütünlüğünün korunması V'nin merkezi bileşeni olan V Mikro Service (Void Entegrator Central) tarafından yürütülmektedir: farklı noktalardan gelen akışlar ilişkisel bir havuzda birleştirilmekte, şema/metadata yönetimi yapılmakta, kimliklendirme-versiyonlama ve ayrıntılı loglama sağlanmaktadır. V AI ise V üzerinde çalışan analitik/yorumlayıcı katmandır; tahminleme ve anomali tespiti gibi makine öğrenmesi iş yükleri için özellik çıkarımı ve kural tabanlı değerlendirmeleri gerçekleştirmekte ve raporlama ile diğer uygulamalara veri servis etmektedir.

Bu çerçevede, Şekil 3'te numaralanan veri çekme yöntemlerinin, Şekil 2'deki mimari üzerindeki giriş/çıkış akışlarına karşılığı aşağıda adım adım açıklanmıştır. Şekil 3'teki 1, 2, 3, 6 numaralı oklar, Şekil 1'deki girdiler ile ifade edilirken; 10, 11, 12, 14 numaralı oklar da çıktılarını temsil etmektedir.

Geliştirilen entegrasyon mimarisinin (Void Entegrator) tüm süreçleri aşağıda ifade edilmiştir:

- 1 numara: ERP Sistemi içindeki veritabanındaki verilerin kendi içindeki algoritma kapsamında geliştirilmiş, REST veya web servisi ile veri aktarımının yönüdür.
- 2 numara: Void Entegrator Data Reader direkt olarak veritabanından veri çekilebildiğini gösterir.
- 3 numara: ERP Sistemleri Veri tabanından direkt olarak bir raporlama servisi ile Excel, XML veya CSV çıktısı üretebilir.
- 4 numara: Void Entegrator sistemi herhangi bir sistem üzerindeki web service veya web API servislerine bağlanarak veri çekebilir.
- 5 numara: Void Entegrator sistemi önceden programlanmış veri şablonlarına ait XML, CSV veya Excel çıktılarından veri okuyabilir.
- 6 numara: Bazı ERP sistemlerinde COM DLL veya SDK Uygulamaları sayesinde veri okunabilir.
- 7 numara: COM DLL/SDK sistemlerinden veri okumak için ilgili DLL'lerin Void Entegrator uygulamasına referans gösterilmesi ile veriler okunabilir.

8 numara: Void Entegrator sistemi, ERP sistemlerinin web service veya API dokümantasyonlarına uygun kurallar ile veri yazabilir.

9 numara: Void Entegrator sistemi, ERP sistemlerinin içeriye veri alma formatındaki Excel, XML, CSV veya metin formatlarında dışarıya veri çıkartabilir.

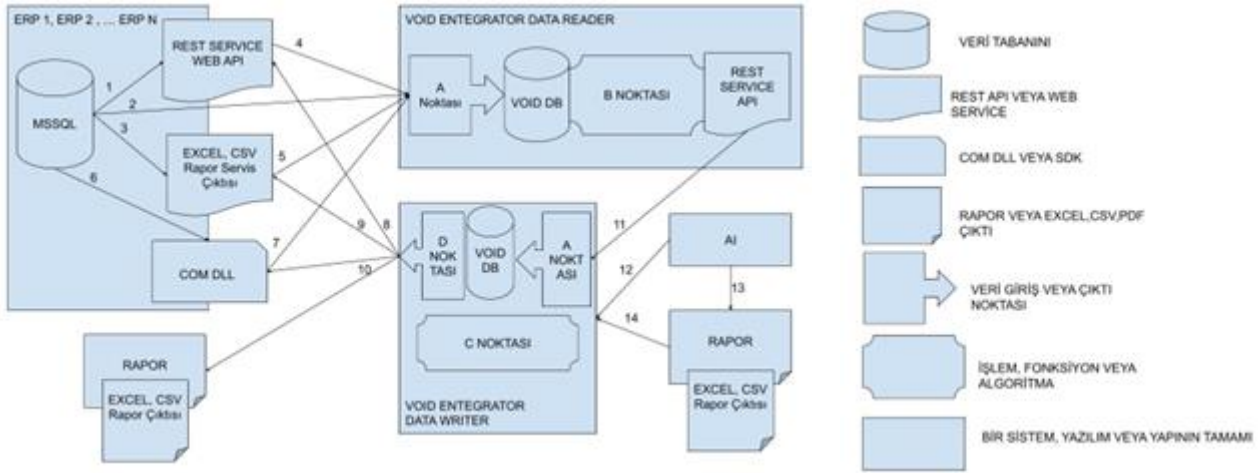
10 numara: Void Entegrator sistemi dışarıya raporlama servisi formatında rapor çıktısı sağlayabilir.

11 numara: Void Entegrator sistemi başka bir Void Entegrator sisteminden veri çekebilir.

12 numara: Void Entegrator sistemi makine öğrenmesi kapsamındaki çıktı verileri okuyabilir.

13 numara: Makine öğrenmesi dışarıya rapor çıktısı sağlayabilir.

14 numara: Makine öğrenmesi sonucunda dışarıya çıktı olarak verilen veri formatlarından veri okunabilir.



Şekil 3. Void Entegrator Veri Çekme Yöntemleri

Geliştirilen entegrasyon mimarisindeki modülleri ifade eden noktalar aşağıda ifade edilmiştir:

A Noktası: Void Entegrator'ün veri ortaklaştırma methodlarının uygulandığı bölümdür. Veri ortaklaştırma ticari sistemlerin veri tiplerinin ve sınıflarının ayrıştırıldığı alandır. Veriler ortaklaştırıldıktan sonra ticari sistemler içinden rapor veya belge kontrolü yapılarak doğru ortaklaştırma yapıp yapılmadığı kontrol edilir.

B Noktası: Veriler Void Entegrator ile ortaklaştırıldıktan sonra oluşturulan ilişkisel veri tabanı içine kaydedildiği, hesaplamaların ve dönüşümlerin yapıldığı, anlamlı analizlerin yapılabileceği veri setlerine dönüştürüldüğü bölümdür.

C Noktası: Dönüştürülen ve ortaklaştırılan verilerin hedef sisteme aktarılmadan önceki veri tiplerinin dönüştürüldüğü ve hesaplamalarının yapıldığı farklı bir operasyon bölümüdür.

D Noktası: Hedef sisteme gönderilmeden önce hedef sistemin, servis veya veritabanlarına uygun veri formatlarına dönüşümünün yapıldığı yani hedef sistem için verinin ortaklaştırıldığı bölümdür.

Sistemsal açıdan veri entegrasyonunu sağlayabilmek için veri çekmek veya verinin yazılacağı tablo ve tablo bağlantılarını bilmek gerekmektedir. Eğer bir COM (Component Object Model - Bileşen Nesne Modeli) objesi veya bir web service (WCF - Windows Communication Foundation - Windows İletişim Kuruluşu) mevcutsa entegrasyon sürecinde veri bütünlüğünü bozma riski söz konusu objeye veya servise aittir. Bu sebepten, entegrasyon süreçlerini hızlandırmak için DLL (Dynamic Link Library - Dinamik Bağlantı Kütüphanesi) ve servislerin algoritmalarına ait dokümanlar detaylı bir biçimde incelendikten sonra yazılım geliştirmeleri yapılır.

Yazılım geliştirme süreçlerinde hata ve kayıt yönetimlerini de detaylı loglamalar sağlamaktadır. Sağlanan log kayıtları, geliştirilen bilgilendirme servisleri ile entegrasyon paydaşlarına iletilir. Bu iletişimler, e-posta, SMS vb. varsayılan iletişim araçları ile yapılacağından dolayı, entegrasyon süreçlerini geliştirmek için söz konusu ekstra araçları da geliştirmek gerekmektedir.

Örneğin, veri tabanında hazırlanacak olan sorgulara göre veriler ortaklaştırılır. Veri yapılarını, ilişkisel bağlantıları

ve tablo içindeki tip enumlarını (Şekil 4) biliyor olmak gerekir. Buradaki söz konusu detayları bilmek için dahi sistem içinde ters mühendislik yapmak gerekebilir. Genellikle SQL Server Profiler (SQL Sunucu Profil Oluşturucu) aracından faydalanılarak kayıt tabloları ve tablolar arasındaki ilişki bağlantıları öğrenilerek veri setlerini oluşturacak SQL sorguları hazırlanmıştır.

Başka bir yöntemle, sistem içindeki veriler raporlanabilmek için raporlama servisleriyle son kullanıcıya veri çıktısı sunabilir, eğer veri tabanı bağlantısı yok ise dışarıya servis aracılığıyla çıkartılan veriler Excel, CSV (Comma Separated Values - Virgülle Ayrılmış Değerler), XML (Extensible Markup Language - Genişletilebilir İşaretleme Dili) ve JSON (JavaScript Object Notation - JavaScript Nesne Notasyonu) veri formatlarında dosyaya atılır. Veri okuyucular ilgili dosyaları belirli periyotlarla okuyarak veriler ortaklaştırılabilir. Burada dışarıya çıkartılan veri formatları ve tipleri entegrasyon programcısı tarafından önceden programlanmalıdır.

Özetle ifade etmek gerekirse, birçok sistem dış sistemlerle konuşabilmek, veri girişi ve çıkışı sırasında entegrasyon altyapısını gelişmiş kılabilmek için web service / API veya COM objeler ile veri transferi araçlarına sahiptir. Genel veri girişi kalıplarındaki işlemleri ve içerideki genel veri kalıplarını ilgili servis aracılığı ile dışarıya sunarlar. Entegrasyon geliştiricileri, ilgili servislerden dönen veri tiplerini dönüştürerek veya ham halde çekerek gerekli programlama faaliyetlerini yürütürler.

Söz konusu yöntemlerin kullanılma alanları tedarik zinciri yönetiminde genellikle veri toplama projelerinde gerçekleşmektedir. Birçok dağıtım ağı olan merkezi bir gıda fabrikasının bayilerine dağıttığı ürünlerin bayilerine ait ERP sistemlerindeki satış ve stok verilerinin toplanması, ortaklaştırılıp raporlanabilir bir biçimde verinin analiz edilmesini kolaylaştıracaktır. Herhangi bir ERP sisteminden veri çekebilmek ve veri yazabilmek için teknik alt yapıya göre programlama yapılır. Veri yapılarının ERP sistemlerde kullanılabilmesi için verilerin standartlaştırılması gerekmektedir, böylece dijital dönüşüm süreçleri hız kazanacaktır.

Satış sistemleri, ticari yazılımlar veya ERP sistemleri baz alındığında veri hareketinin sürekli olduğu tablolarda Şekil 4'üne benzer biçimde veri sınıflandırmaları yapılır (Kundur & Kandepu, 2023; Botta-Genoulaz & Millet, 2005). Entegrasyon sürecinde de bu veri standartlaştırmasının mutlaka belirlenmesi gerekmektedir. Her bir çalışma alanına özgü veri yapısı standartlaştırılarak entegrasyon süreci tüm entegrasyon ağında ortaklaşa kullanılmalıdır.

Ham verinin anlamlı hale dönüştürülmesi, işlenmemiş veriyi seçerken Şekil 4'teki gibi tablolardaki veri yapılarının tespit edilmesi ve programlanması çok önemlidir (Lamer vd., 2022). Girdinin ve çıktının analizi, söz konusu tanımlara bağlı olduğundan, üretim planlama aşamalarında da bu tanımlamalar ilk noktadan son noktaya kadar belli bir standartta devam eder.

	Id	EnumId	DetailCode	DetailName
1	1	1		Alış Faturası
2	2	1		Satış Faturası
3	3	1		Depo Giriş
4	4	1		Depo Çıkış
5	5	1		Alış İrsaliyesi
6	6	1		Satış İrsaliyesi
7	7	1		Depolar Arası Transfer
8	8	1		Satış Fişi
9	9	1		Satış Adisyonu
10	10	1		Devir
11	11	1		Üretim
12	12	1		Zayi

Şekil 4. Veri Tipi Sınıflandırması

Mevcut ERP sistemlerinde söz konusu veri yapılarına göre raporlamalar ve muhasebeleştirme kayıtları yapılmaktadır. Çıktıların doğrulanması, bu veri yapılarıyla bağlantılıdır; zira halihazırda bu enum tipleri, programcıların ana sistemi programlamasına olanak tanır. Buradaki doğrulama her ticari sistemdeki enum tiplerinin veri çekilirken doğru bağlanıp bağlanmadığını ifade etmektedir. Örneğin, bir sistemde satış işlemi için kullanılan enum değeri 1 iken, başka bir sistemde aynı işlemi ifade eden enum değeri 3 olabilir. Bu durumda, entegrasyon süreçlerinde verilerin doğru bir şekilde eşleştirilmesi için ters mühendislik yöntemleri kullanılarak enum tipleri

anlamlandırılır ve standart hale getirilir. Böylece, farklı sistemlerden gelen verilerin tutarlı ve uyumlu bir şekilde ERP sistemine entegre edilmesi sağlanır. Ters mühendislik ile yapılan bu süreç, veri doğruluğunu artırır ve sistemler arası entegrasyonun etkinliğini maksimize eder.

Bu çalışmada odaklanılan düşünceye göre, üretim planlamaya makine öğrenmesinin dahil edilmesi (Usuga Cadavid vd., 2020) için öncelikli olarak üretilecek ürünün planlanması aşamalarından (Sayer & Ülker, 2014) biri olan reçetenin, yani malzeme bağlantılarının önceden belirlenmiş olması ve hatta makineye öğretilecek olan algoritma için reçete tanımlarına uygun veri yapısının ortaya çıkıp çıkmadığının analiz edilmesi gerekmektedir. Veri yapısı bozuk olan bir ERP sisteminden sağlıklı veri alınamazsa analiz de sağlıklı yapılamayacaktır. Formülü hatalı olan bir problemin çözümü sağlanamayacağı gibi, belirlenen formüle uygun veri olup olmadığının kontrolü, makine öğrenmesine gönderilecek olan verinin ilk şartıdır.

Tedarik Zincirinde Makine Öğrenmesi

“Tedarik Zincirinde Entegrasyon” bölümünde anlatılan standartlaştırılmış ticari sisteme uygun çeşitli yapay zeka yöntemleri uygulanabilir. Bu yöntemlerden çalışma kapsamında, kritik stok seviyesi tespit edilerek stok takibi yapılması ele alınmıştır.

Şekil 5, çalışmada izlenen uçtan uca veri hazırlama ve modelleme iş akışını özetlemektedir. İlk olarak, “İş Anlama/Veri Toplama” adımı kapsamında, Tablo 2’de belirtildiği üzere, yüzden fazla ekmek satış noktası olan bir fırının sipariş miktarı, ürün kodu ve stok/ürün hareket tipi gibi verileri toplanmıştır. Ardından, bileşen yapısını görünür kılmak ve hammadde–yarı mamul–mamul ilişkilerini açıkça tanımlamak için ekmek mamulündeki ham madde bileşenlerini içeren diyagram, Şekil 6 ile sunulmuştur. Bu şema, veri modelinde stok tüketim akışını ve hedef değişken olan un tüketiminin, ekmek mamulünde kullanılan hammadde bileşenleri içindeki konumunu netleştirerek, gelecek çalışmalarda yapılacak analizlerin kapsamının belirlenmesine katkı sağlamıştır. “Veriyi Anlama” aşamasında, Şekil 7’de gösterildiği gibi hedef değişkenin veri dağılımı incelenmiş, eksik değer kontrolü, aykırı değer analizi yapılmıştır. Talep dinamiklerini yakalayabilmek amacıyla Şekil 8’de gösterilen takvimsel öznitelikler (gün/hafta/ay/çeyrek) ve gecikmeli (lag) değişkenler gibi öznitelik mühendisliği adımları gerçekleştirilmiştir. Şekil 9’da, yapılan öznitelik mühendisliği sonrası, veri özelliklerinin son hali ile korelasyon incelemesi yapıp değişkenler arası ilişkiler incelenmiştir. Veri ön işleme adımında, modellerin öğrenmesini başarılı kılmak için eksik verilerin işlenmesi, nümerik olmayan verilerin kodlanması ve veri tipi dönüşümleri uygulanmıştır. Bu hazırlıkların ardından, makine öğrenmesi için modellerin geliştirilmesi aşamasına geçilmiş ve regresyon modelleri R^2 , MAE ve MSE ile değerlendirilerek en iyi modeli elde etmek için çalışılmıştır. Böylece stok takibinde, sahada kullanılabilecek en başarılı yöntemle ulaşma hedeflenmiştir.

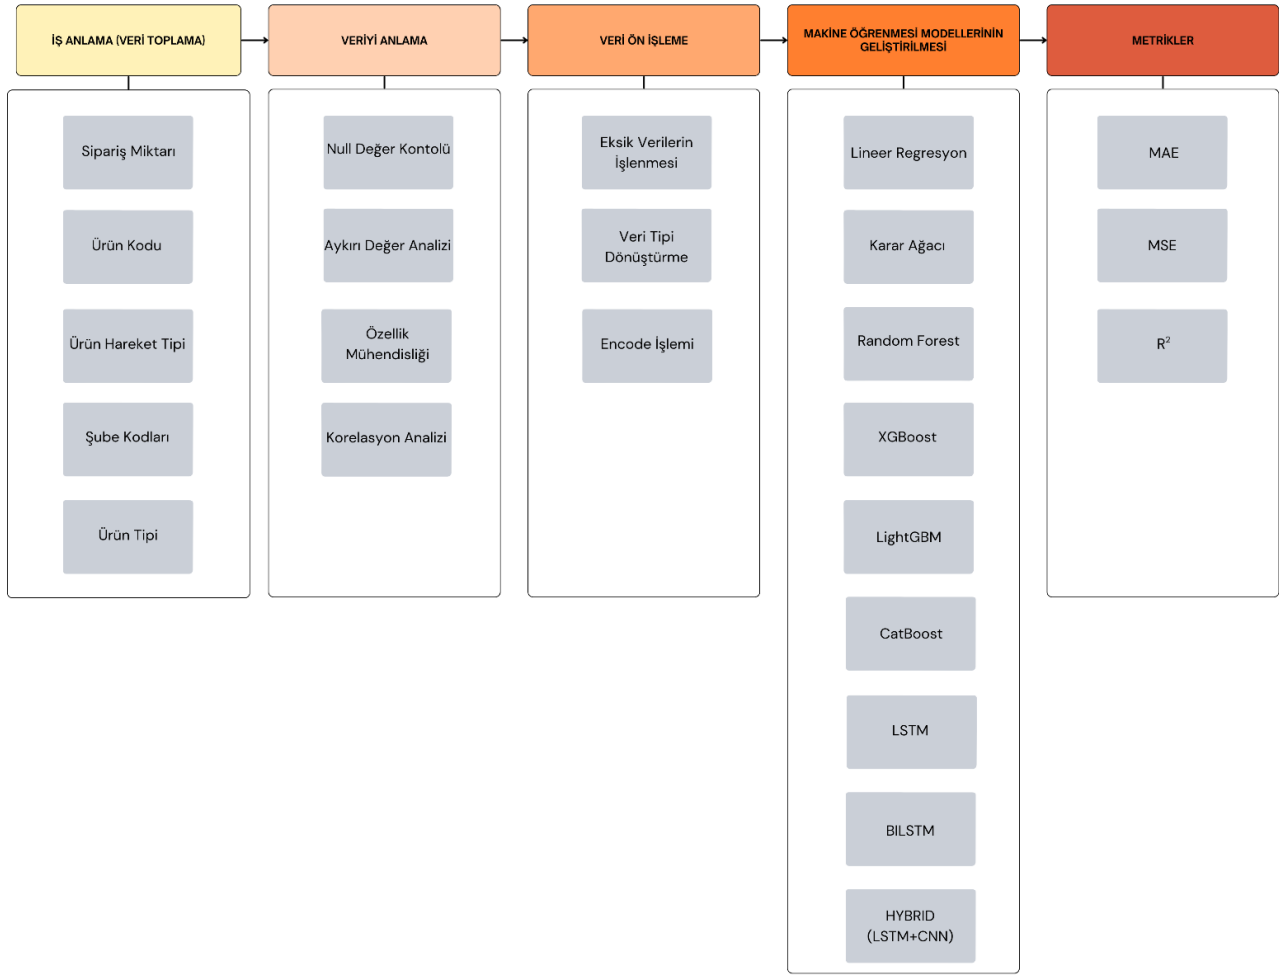
Stok hareketlerinin (giriş ve çıkışlarının) analiz edilebilmesi için geçmişe ait tüm stok bilgisi makine öğrenmesi algoritmaları ile bir model oluşturup ele alınmakta, sonrasında tahmin edilmek istenen zaman için modelin çıktıları üzerinden yorumlama yapılabilmektedir. Bu yöntem farklı ticari sistemlerdeki standartlaştırılmış verilere stok takibi amacıyla uygulanabilir. Böylece, Şekil 2’de ve Şekil 3’te çeşitli yapay zeka çözümleri (AI olarak ifade edilen kısım) mikroservis olarak sunulup, talep eden ticari sistemler tarafından çalıştırılabilecektir. Örnek olarak, Şekil 3’teki mikroservisler aracılığıyla hem tahminleme hem de raporlama yardımıyla geçmişe dair veri akışı takibi yapılabilir.

Veri akışı sağlıklı bir şekilde takip edildiğinde, makine öğrenmesinin katkısı konusunda yaptığımız çalışma sonucunda, verinin normal olmayan alımı veya tüketimi gözlemlenmiştir. Öne sürülen husus, normal dışı alımların veya fazladan kullanımın fark edilerek üreticiye veya tüketicilere akıllı bildirimler gönderme altyapısının oluşturulmasıdır. Sonuç olarak, mevcut durumun analiz edilerek gözlem sonuçlarının ağdaki tüm noktalara sunulması gerekmektedir.

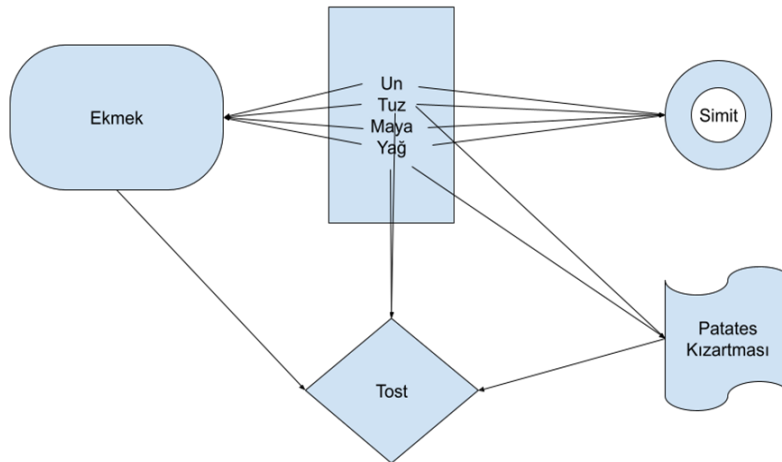
Örnek bir reçete üzerinden gitmek gerekirse, ekmek mamulünü üreten bir üretim tesisinde, ekmek için kullanılan ham, yarı veya yan mamullerin tespiti yapılmalıdır. Bu tespitin yanı sıra, ham, yarı veya yan mamullerin kullanıldığı diğer malzemelerinin de tespiti yapılmalıdır.

Şekil 6’da, bir ekmek mamulünün malzemelerini ve o malzemelerin diğer hangi mamüllerde kullanıldığının şeması bulunmaktadır. Bir ürüne ait üretim planlaması yapılırken ilgili ürünün reçetelerindeki malzemelerin de kullanıldığı diğer mamüller mercek altına alınmalıdır. Bu konu sektör bağımsız veya işletmenin diğer faaliyet alanlarından bağımsız bir biçimde ele alındığından dolayı, üretim planlama çalışmalarında ERP sistemleri içinde her bir mamulün tükettiği stoklara göre üretim planlama yapılmaktadır. Her mamül, kendi tanımlı hammadde bileşenlerini tüketirken, ilgili stoğun envanterde ne miktarda olduğu ile ilgilenmez (ayrıca bir stok planlama mekanizması işletilmiyorsa).

Dolayısıyla, özellikle ekmek üretimi yapan bir fırının ana hammaddesi olan un stoğunun analizi tedarik zinciri yönetimi açısından kritiktir. Aynı un diğer mamüller için de hammadde niteliği taşırsa da ana faaliyet ürününün ana hammaddesini analiz etmek için önerilen çalışma yapılmıştır.




Şekil 5. Veri Hazırlama ve Modelleme İş Akışı



Şekil 6. Ekmek Mamulünde Kullanılan Hammadde Bileşenleri

Şekil 7'deki örnekleme göre 480. günde normal dışı bir alım olduğu tespiti yapılması, yapılan tespit veri hatasından kaynaklanıp kaynaklanmadığının sağlanmasının yapılması ile çıktı gözlenir.



Şekil 7. Örneklem Veri Dağılımı

Şekil 7'deki çıktıya göre veride 480. günde çok fazla alış olmaktadır. Bunun sebebi ise 480. günde (25 Nisan 2022) un zammının ertelendiği haberi olabilir.

Toplanan verinin çıktısı, başka bir sistemin girdisine dönüşebilecek potansiyelde olduğundan dolayı, geliştirilecek mikroservisler aracılığıyla ağ üzerindeki ilgili bir nokta bilgilendirilebilir.

Örnek senaryoya göre, yüzden fazla ekmek satış noktası olan bir fırının stoğunda bulunan un miktarının artış ve azalışına uygun biçimde hangi zaman dilimlerinde un alınması gerektiğine dair tahminleme yapılması üzerinde durulmuştur. Bu problem, regresyon yöntemi ile ele alınmıştır. Kullanılan veri seti özellikleri Tablo 2'de sunulmuştur.

Tablo 2. Veri Seti Özellikleri

Branch Id	Depo, bölge, şube	Kod alanı, string veya float
Date_	Belge Tarihi	Tarih alanı
StockId	Hareket eden Stok İndex Numarası	Stok Bilgisi
Type	Giriş/Çıkış	1 ise giriş, -1 ise çıkış
Quantity	Miktar	KG birimi
MovementType	Giriş /Çıkış Hareket Tipi	Hangi hareket tipi olduğu bilgisidir.
FicheNoText	Giriş / Çıkış Belge / Hareket Numarası	Fatura veya sistem içindeki belge numarasıdır.
StockLink	Stok Bağlantı Numarası	Eğer bir üretime istinaden oluşan bir hareket ise stok kartı bağlantı numarasıdır.

Veri modellerine hakim ETL (Extract, Transform, Load) geliştiricileri ile oluşturulan veri modelleri, önceden programlanmış araçlar vasıtasıyla merkeze toplanır. Merkeze toplanan veriler makine öğrenmesi süreçlerinden geçirilerek bir çıktı oluşturulur.

Uç sistemlerdeki veriler toplandıktan sonra ve Şekil 4'teki yöntemler uygulandıktan sonra Tablo 2'deki gibi ortaklaştırılır. Ortaklaşan veriler artık yorumlanmaya açık hale getirilir ve yorumlayıcıya yollanır. Neticede bize ilgili ürünün giriş mi yoksa çıkış mı olduğu ve hangi hareket ile bu işlemin olduğu bilgisi gerektiğinden en sade haline dönüştürülerek makine öğrenmesi uygulamaya hazır hale getirilir.

Makine Öğrenmesi ile Hammaddede (Un) Tüketim Tahmini ve Modellerin İyileştirilmesi

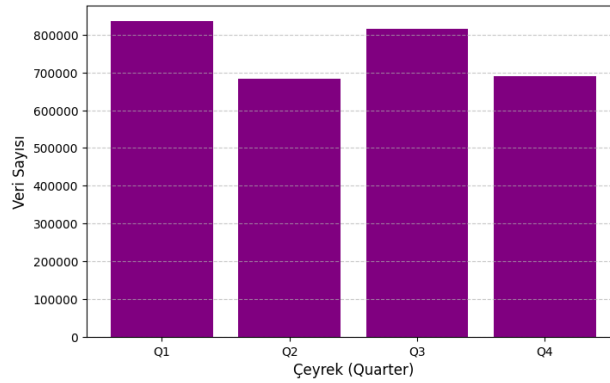
Bu bölümde, artırılmış veri seti ile bu veri seti üzerinde yapılmış feature engineering (öznitelik mühendisliği) adımlarından bahsedilmiştir. Yeni veri seti ile denenecek klasik makine öğrenmesi algoritmalarının çeşitliliği artırılmış, ek olarak zaman bağımlı öğrenmede iyi sonuçlar verdiği bilinen LSTM (Uzun-Kısa Süreli Bellek Ağı) ve BiLSTM (Çift Yönlü Uzun-Kısa Süreli Bellek Ağı) derin öğrenme algoritması da kullanılmıştır.

Özellikle LSTM gibi zaman bağımlı modellerin öğrenme kapasitesini artırmak amacıyla zaman serisi temelli ek özellikler veri kümesine dahil edilmiştir. Bu özellikler; gecikmeli (lag) değerler, hafta içi/hafta sonu ayrımı ve mevsimsellik (seasonality) göstergeleridir.

Gecikmeli değerler (lag features), çalışmada kullanılan veri setine, 1 gün, 1 hafta, 1 ay ve 1 yıl öncesine ait değerler ek özellikler olarak dahil edilmiştir. Bu yaklaşım ile özellikle hem geçmişe hem geleceğe dönük tahmin yapabilen BiLSTM gibi modellerin daha isabetli sonuçlar üretmesi hedeflenmiştir.

Hafta içi ve hafta sonu ayrımı yapılmıştır. Veri seti içerisinde hafta içi toplam gözlem sayısı 2.441.772, hafta sonu gözlem sayısı ise 582.550 olarak belirlenmiştir. Bu ayrım, tüketim alışkanlıklarındaki farklılıkların modellenmesine katkı sağlaması amacıyla yapılmıştır.

Mevsimsellik özelliği (seasonality – quarter) ile özellikle un tüketiminin aylara göre değişebileceği ve bahar-yaz dönemlerinde artan etkinlikler ve açılışlarla birlikte talebin yükseldiği varsayımına dayanarak, yılın 12 ayı dört çeyreğe (quarter) bölünmüş ve veriler bu doğrultuda etiketlenmiştir. Çeyrek bazlı veri dağılımı Şekil 8’de sunulmaktadır.




Şekil 8. Çeyrek Bazlı Veri Sayısı

Yapılan tüm ön işleme ve öznitelik mühendisliği işlemlerine ek olarak, başlangıçta yalnızca 2021–2022 yıllarına ait veriler kullanılırken; çalışma kapsamı, 2019, 2020, 2023 ve 2024 yıllarına ait verilerin de dahil edilmesiyle genişletilmiştir. Böylelikle, başlangıçta yalnızca 4.335 gözlemden oluşan veri seti, 3.510.658 gözleme ulaşmıştır. Tüm veriler, gerekli ön işleme adımlarından geçirildikten sonra modelleme sürecine tekrar dahil edilmiştir. Öznitelik mühendisliği ve veri ön işleme adımlarının sonucu olarak elde edilen yeni veri seti Tablo 3’de sunulmuştur.

Tablo 3. Yeni Veri Seti Özellikleri

Feature (Özellik)	Anlamı
ID	Her satıra özel, benzersiz işlem ID’si.
BranchId	İşlemin gerçekleştiği şubenin kimliği.
Date	İşlemin gerçekleştiği tarih.
StokKod	ERP sistemine ait stok kodu (örn. H.20.0115).
StockId	Stok kaleminin kimliği.
InOutType	Ürünün depoya giriş (+1) ya da çıkış (-1) olduğunu gösterir.
Quantity	Ürün (un) miktarını ifade eder. Önerilen çalışmadaki hedef değerdir.
MovementType	İşlem türü (örn. satış, üretim, imha)
id	İşlem numarası ya da hareket kimliği (diğer ID’den farklıdır).
ErpName	Ürün ismi (örn.ekmek, ayvalık tost vb.).
Type	Ürün tipi (hammadde, mamul ya da kullanım)
SeviyeBaglanti	Üretim sürecindeki seviyesi (örn. nihai ürün (0), yarı mamul (1), ham madde (2))
ErpName_Encoded	ErpName özelliğinin encode edilmiş hali.
StokKod_Encoded	StokKod özelliğinin encode edilmiş hali.
Quantity_Lag_1	Önceki günkü un tüketim miktarı.
Quantity_Lag_7	Bir hafta önceki un tüketim miktarı.
Quantity_Lag_30	Bir ay önceki un tüketim miktarı.
Quantity_Lag_365	Bir yıl önceki un tüketim miktarı.
IsWeekend	İşlemin haftaya denk gelip gelmediğini gösterir (1: evet, 0: hayır).
Quarter	İşlemin yılın hangi çeyreğinde yapıldığını gösterir (1-4).

Gerçekleştirilen işlemlerin etkisini ve değişkenler arası ilişkileri daha somut bir şekilde değerlendirebilmek amacıyla, Şekil 9’da değişkenler arası korelasyon matrisi sunulmuştur.



Şekil 9. Korelasyon Matrisi Grafiği

Bu süreçte, kapsamlı bir öznelik çıkarımı (feature extraction) gerçekleştirilmiş olup, veri setindeki kullanımının sonucu olumlu etkilemeyeceği kararlaştırılan öznelikler veri setinden elenmiştir ve nihai öznelikler makine öğrenmesi modellerinde kullanılmıştır. Örneğin, Quantity_Lag_1, Quantity_Lag_7, Quantity_Lag_30, Quantity_Lag_365, IsWeekend ve Quarter gibi zamansal özneliklerin detayları Şekil 16'daki LIME grafiğinde sunulmuştur.

Model çeşitliliğini artırmak ve farklı algoritmaların problem üzerindeki etkisini karşılaştırmak amacıyla Doğrusal Regresyon, Decision Tree (Karar Ağacı), Gradient Boosting ve Rassal Orman gibi alt modeller değerlendirilmiştir. En yüksek R^2 (determinasyon katsayısı) ve en düşük MAE değerini veren modeller temel alınarak değerlendirmeler yapılmıştır.

R^2 skor, bir regresyon modelinin tahmin ettiği değerlerin gerçek değerleri ne kadar açıkladığını gösterir ve 0 ile 1 arasında değer alır. Yüksek R^2 değeri, yani değerlerin 1'e yakın olması, modelin veri varyansını çok iyi açıkladığını göstermektedir. Yapılan çalışmada, R^2 skorun her modelde yüksek değere sahip olması modelleri başarılı gibi gösterse de %99 oran aşırı öğrenme (overfitting) ihtimalini beraberinde getirmektedir. Bu sebeple R^2 , çıkarım yapmak için tek başına yeterli olmayıp MAE ve MSE değerleri de alınmıştır. MAE, tahmin edilen değerlerle gerçek değerler arasındaki mutlak farkların ortalamasıdır. MSE ise bir regresyon modelinin tahminleri ile gerçek değerleri arasındaki ortalama kare farkını ölçer. Düşük MAE ve MSE değerleri modelin tahminlerinin gerçek değere daha yakın olduğunu göstermektedir.

Bu aşamada hata ölçütü olarak MSE yerine MAE kullanılmıştır. MSE, hataların karesini aldığı için büyük hata değerlerini daha fazla öne çıkarmaktadır. Çalışmamızdaki veri yapısında az sayıda yüksek hatalı örneğin optimizasyon sürecine aşırı etki etmesini istemediğimiz için, hataları doğrusal olarak cezalandıran MAE metriği daha uygun bulunmuştur. Bu özellik bazı durumlarda avantaj sağlarken, önerilen çalışmada olduğu gibi stok tahmini gibi operasyonel karar verme süreçlerinde hataların büyüklüğünden çok ortalama sapmanın önemi vardır. Örneğin, 5

kg'lık bir sapma ile 20 kg'lık bir sapma, MSE açısından sırasıyla 25 ve 400 puanlık bir etki yaratır. Ancak stok yönetiminde bu fark doğrusal olarak değerlendirilir, yani her kg eşit derecede önemlidir.

Bu nedenle MAE daha işletme dostu ve yorumlaması daha kolay bir hata metriği olarak tercih edilmiştir. Örneğin, "ortalama 5 kg hata ile tahmin yapılıyor" ifadesi, sahada kullanılabilirliği olan, doğrudan anlamlı bir çıktıdır. Model eğitimi sırasında overfitting (aşırı öğrenme) ve underfitting (yetersiz öğrenme) problemlerini önlemek amacıyla, her model hem tam veri seti (3.024.322 gözlem) hem de bu veri setinden rastgele seçilen 100.000 gözlemden oluşan daha küçük bir alt veri seti ile eğitilmiştir. Bu sayede modellerin genelleme yeteneklerinin test edilmesi amaçlanmıştır.

Tablo 4'te, ana veri seti (3.510.658 gözlem) ile eğitilen makine öğrenmesi modellerine ait değerlendirme ölçütleri üzerinden elde edilen model performans çıktıları sunulmuştur.

Tablo 4. Tüm Veri Seti İle Eğitilen Model Sonuçları

Model	R ²	MAE
XGBoost	0,8920	58,42
Light GBM	0,9086	39,25
CatBoost	0,5738	103,89
Random Forest	0,8360	103,59
Decision Tree	0,8691	52,87

Tablo 5'te, ana veri setinden rastgele seçilen 100.000 örnekten oluşan alt veri seti ile eğitilen modellerin değerlendirme ölçütlerine dayalı performans çıktıları karşılaştırılmıştır.

Tablo 5. Rastgele 100 Bin Veri ile Eğitilen Model Sonuçları

Model	R ²	MAE
XGBoost	0,8788	37,16
LightGBM	0,8209	43,92
CatBoost	0,8512	40,90
Random Forest	0,8864	31,16
Decision Tree	0,8698	34,12

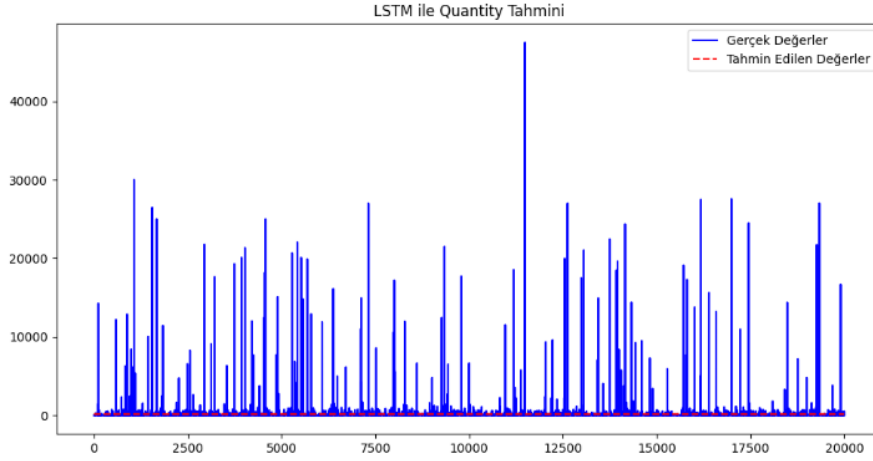
Model sonuçlarına bakıldığında, tüm veri seti ile eğitilen modeller içinden Tablo 4'te sunulduğu üzere en iyi sonuç veren 0,001 öğrenme oranı (learning rate) ve 500 iterasyon (n_estimators) ile LightGBM; Tablo 5'te ise rastgele 100 bin veri ile eğitilen modeller içinden ise en iyi sonuç veren 100 iterasyon ile Rastal Orman modeli olmuştur. Bu değerlendirme, yüksek R² ve düşük MAE değerlerinin birlikte dikkate alındığı karşılaştırma sonucunda yapılmıştır. Her iki model için kullanılan hiperparametre kombinasyonları, Grid Search (ızgara arama) algoritması yardımıyla sistematik olarak taranarak belirlenmiştir.

Makine öğrenmesi modelleri belirli ölçekte başarılı sonuçlar üretmiş olsa da, kullanılan veri setinin hem büyüklüğü (3.024.322 gözlem) hem de zaman serisi yapısına sahip olması, daha karmaşık yapısal ilişkilerin modellenmesini gerekli kılmaktadır. Özellikle büyük veri, daha yüksek örüntü yoğunluğu ve ardışık bağımlılıklar içerebileceğinden, bu tür veri yapılarında öğrenme kapasitesi daha yüksek modellere ihtiyaç duyulmaktadır.

Bu nedenle, yalnızca karar ağaçları veya boosting algoritmalarıyla sınırlı kalınmayarak, zaman boyutunu dikkate alabilen derin öğrenme tabanlı modellere geçilmiştir. Bu kapsamda, zaman serisi içeren problemlerde başarılı sonuçlar verdiği bilinen LSTM ve BiLSTM modelleri değerlendirilmiştir. Söz konusu modeller hem tüm veri setiyle hem de rastgele seçilen 100 bin veri ile ayrı ayrı eğitilmiştir.

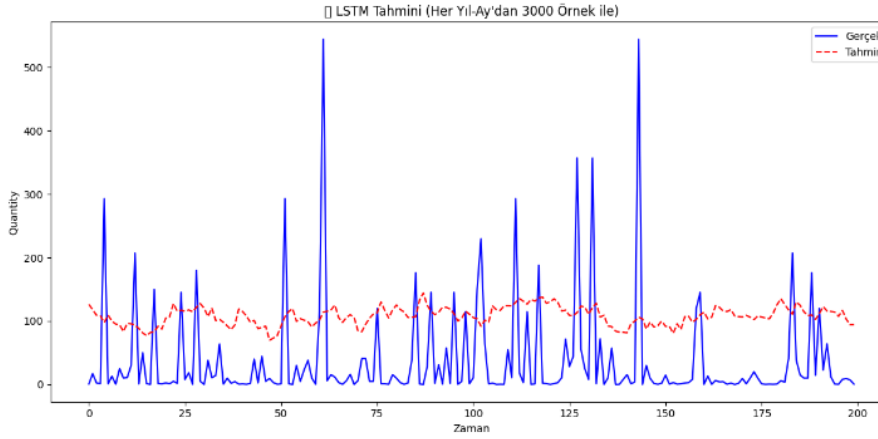
Fakat çıktılarda, modeller tüm veri seti eğitiminde 100 bin veriye göre daha düşük performans sergilemiştir. Ayrıca rastgele 100 bin veri ile eğitilen modeller birbirine yakın grafikler çizmiştir. Bu sebepten sadece LSTM üzerinden modeli anlama yoluna gidilmiştir. LSTM zaman bazlı performans sergilediği için tüm veri setinde ardışık zaman aralığı içeren veriler olmama ihtimaline karşı rastgele 100 bin veri ile değil her aydan yeterli veri varsa 3000 veri

olarak eğitilmiştir. Rastgele seçilen 100 bin örnekten oluşan alt veri seti ile eğitilen LSTM modelinin tahmin ettiği değerler ile gerçek değerlerin karşılaştırılması Şekil 10'da gösterilmiştir.



Şekil 10. LSTM Gerçek ve Tahmin Değerleri (100.000 Örnek)

Her aydan 3000 veri olarak eğitilen LSTM modelinin tahmin ettiği değerler ile gerçek değerlerin karşılaştırılması Şekil 11'de gösterilmiştir.



Şekil 11. LSTM Gerçek ve Tahmin Değerleri


Şekil 10 ve 11 incelendiğinde, model çıktılarının yeterli öğrenmeyi gerçekleştirmediği ve dolayısıyla underfitting durumunun söz konusu olduğu gözlemlenmektedir. Bu durumun olası nedenlerinden biri, LSTM gibi derin öğrenme modellerinin zaman serilerinde ardışık bağımlılıkları (temporal dependency) öğrenme yetisine sahip olmalarına rağmen, önerilen çalışmada kullanılan veri setinde bu tür bir zaman bağımlılığının yeterince belirgin olmamasıdır. Bu nedenle, LSTM tabanlı modellerin potansiyelinden tam olarak yararlanılmadığı düşünülmektedir. Bu öngörü için öncelikle her yıla ait toplam veri sayısı bastırılarak veri dağılımı gözlemlenmiştir ve Tablo 6'da verilmiştir.

Tablo 6. Yıllara Göre Veri Dağılımı

Yıl	Veri Sayısı
2019	1417482
2020	545821
2021	294574
2022	270296
2023	247573
2024	248576


Tablo 6'da görüldüğü üzere yıllara göre veri dağılımı orantısızdır. Bu durumun zaman serisi modellerinin eğitimi üzerinde etkili olabileceği düşünülerek, veri dağılımı ay bazında detaylı biçimde incelenmiştir. Yılın her ayına ait günlük veri mevcudiyeti kontrol edilmiş ve her ay için veri bulunduğu doğrulanmıştır. Fakat her ayın her günü düzenli veri olmadığı Şekil 12'deki ısı haritasında tespit edilmiştir. Örneğin bazı ayların 31 yerine 28 veya 29 gün veri

içermesi durumu söz konusudur. Bu durum, zaman serilerindeki ardışıklığın kırılmasına ve modellerin öğrenme performansının düşmesine neden olabilir.



Şekil 12. Yıl-Ay Bazında Gün Sayısı Isı Haritası

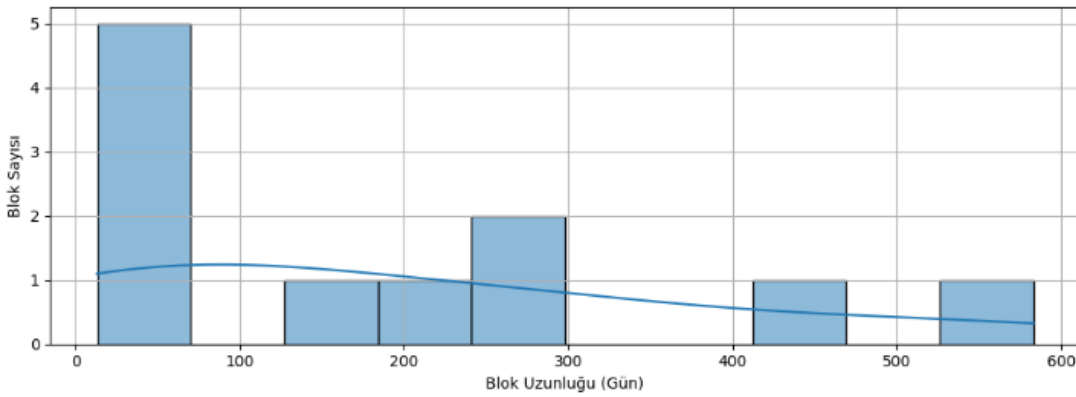
Şekil 13'te her ay için veri bulunan gün oranı (completeness ratio) hesaplanmış ve zamansal bütünlük düzeyi oransal olarak ortaya konmuştur ve en düşük oran 0,90 olarak gözlemlenmiştir.



Şekil 13. Aylık Veri Sürekliliği Grafiği

Bu oran büyük modellerin eğitilmesinde sorun değil gibi görünse de LSTM ve BiLSTM gibi zaman ardışıklığının önemli olduğu modellerde sorun oluşturabilir. Bu sebeple, ardışık veri uzunluğu istatistiği için kesintisiz blok sayısı ve uzunluğu analiz edilmiştir.

Yürütülen analiz sonucunda veri setinin toplamda 11 adet kesintisiz ardışık zaman bloğundan oluştuğu belirlenmiştir. Şekil 14, blok uzunluklarını belirli aralıklarla gruplamakta ve her aralıkta kaç blok olduğunu göstermektedir.



Şekil 14. Ardışık Veri Bloklarının Gün Bazında Süre Dağılımı

Şekil 14'e göre, ortalama blok uzunluğu 198 gün olup, maksimum blok uzunluğu 583 güne kadar çıkmaktadır. Ancak minimum 13 günlük kısa bloklar da mevcuttur. Bu dengesizlik, LSTM gibi modellerin ardışık bağımlılığı öğrenme

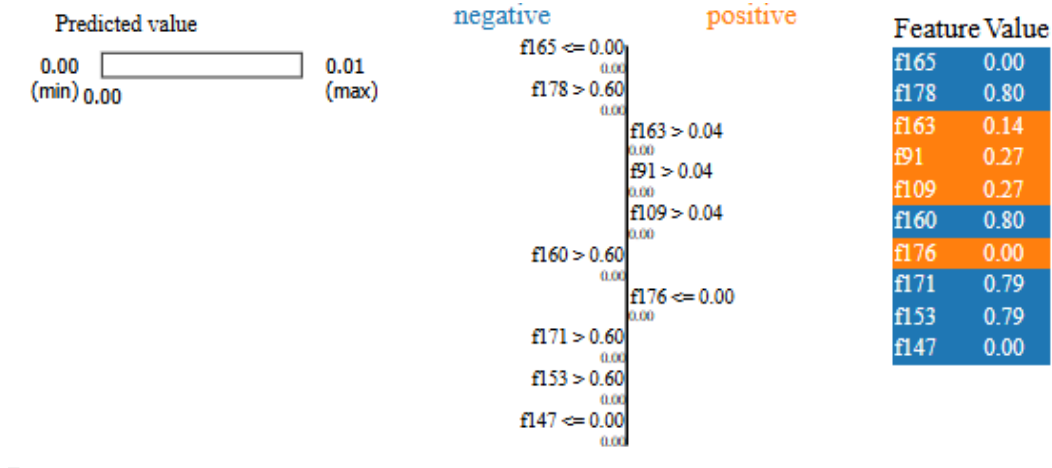
yeteneğini olumsuz etkileyerek model performansını düşürebilmektedir. Bu nedenle, gelecek çalışmalar için model eğitiminde yalnızca belirli uzunluğun üzerindeki blokların kullanılması önerilebilir.

LIME ile Sonuçların Yorumlanması

Açıklanabilirlik, modelin iç işleyişini ve karar mekanizmasını genel hatlarıyla açıklamayı hedefleyen daha geniş bir çerçeveyi ifade ederken, yorumlanabilirlik daha özel olarak belirli bir tahminin hangi özneliklerden ve ne yönde etkilendiğinin insan tarafından doğrudan takip edilebilir olmasını ifade etmektedir. Bu doğrultuda, önerilen çalışmada hangi özelliğin ne kadar etkilediğini anlayabilmek için yorumlanabilirlik yönteminden yararlanılmıştır. Bu kapsamda, modelin tahmininde etkili olan girdileri değerlendirebilmek amacıyla LIME (Local Interpretable Model-Agnostic Explanations) yöntemi kullanılmıştır. Böylece, tedarik ve üretim planlaması gibi iş kararlarını doğrudan etkileyen tahmin modellerinin çıktılarının yorumlanabilir olması sağlanmıştır.

LIME yöntemi, veri noktaları için modelin verdiği tahminin hangi özelliklerden ne derece etkilendiğini açıklar. Böylece modelin karar mekanizması hakkında sezgisel bir anlayış elde edilir. Şekil 15'te yer alan her aydan 3000 veri ile eğitilen LSTM modelinin LIME grafiği, modelin seçilen bir örnek veri için tahminine hangi özelliklerin ne yönde (pozitif ya da negatif) katkı sunduğunu göstermektedir.

Şekil 15'teki LIME görselinde; sol taraftaki özellikler model tahminini düşürmüştür; sağ taraftaki özellikler model tahminini yükseltmiştir. Özelliklerin veri sütularındaki karşılığı Tablo 7'de sunulmuştur.



Şekil 15. LSTM Modelinin LIME Grafiği

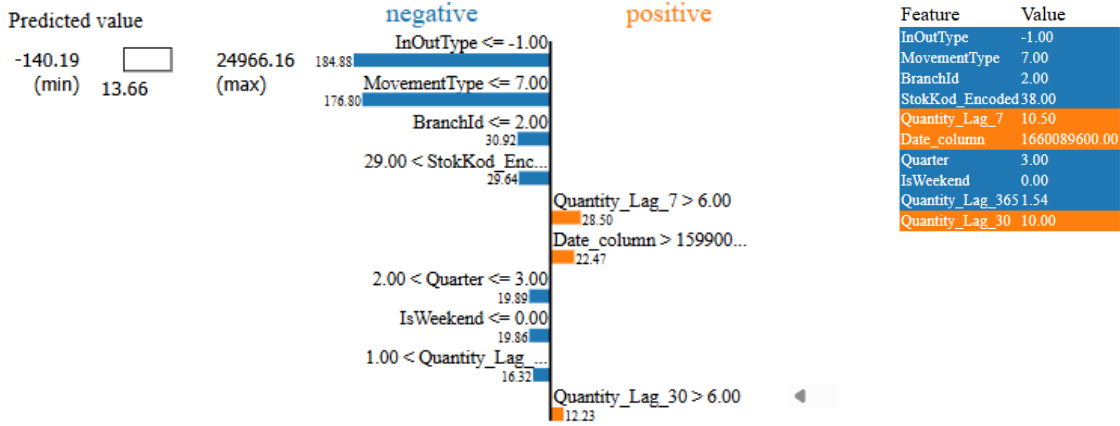
Tablo 8 için verilen zaman adımları LSTM modelinin seq_length parametresinin 10 olarak ayarlanması sonucu tahminleme yapmıştır. Yani, model her bir tahmin için 10 ardışık zaman adımındaki veriyi kullanmaktadır. Örneğin t0 ile t9 arasındaki 10 günlük veriye bakarak, bir sonraki tahmini yapmaktadır.

Tablo 7. LIME Analizine Göre Pozitif Etki Eden Özellikler

f No	Orjinal Feature İsmi	Anlamı
f178	year_t9	9. zaman adımındaki yıl bilgisi
f91	BranchId_t5	5. zaman adımındaki şube ID
f109	BranchId_t6	6. zaman adımındaki şube ID
f160	year_t8	8. zaman adımındaki yıl bilgisi
f171	Date_column_t9	9. zaman adımındaki tarih
f153	Date_column_t8	8. zaman adımındaki tarih

LSTM modeli, zaman içindeki ardışık bağımlılıkları kullanarak tahmin yapmaya çalışsa da, LIME analizi göstermektedir ki çoğu veri noktası için tahmini etkileyen özellikler zayıf kalmaktadır. Bu da modelin yüksek varyanslı veride ortalamaya sapanan bir tahmin stratejisi izlediğini, dolayısıyla karmaşık örüntüleri yeterince öğrenemediğini göstermektedir.

Buna karşın, en başarılı sonucu veren LightGBM modeline ait Şekil 16'daki LIME grafiği incelendiğinde, özellik artırma işlemlerinin model öğrenmesine katkı sağladığı görülmektedir. Örneğin, Quantity_Lag_7 (7 gün önceki veri) ve Quantity_Lag_30 (30 gün önceki veri) özelliklerinin model öğrenmesinde pozitif etki oluşturmuştur.



Şekil 16. LightGBM Modelinin LIME Grafiği

Makine öğrenmesi yöntemleri ile derin öğrenme modellerinden elde edilen sonuçlar karşılaştırıldığında, ilgili problem yapısının doğrusal (lineer) ilişkiler barındırdığı ve bu nedenle geleneksel makine öğrenmesi algoritmalarının yeterli performans gösterdiği görülmektedir. Bu bağlamda, derin öğrenme yöntemlerinin sunduğu karmaşık mimarilere ihtiyaç duyulmadığı ve daha basit modellerin daha etkin sonuçlar üretebildiği anlaşılmaktadır.

TARTIŞMA

Bu çalışmada önerilen entegrasyon mimarisinin literatürde yaygın olarak kullanılan geleneksel entegrasyon yaklaşımlarından ne şekilde ayrıştığını göstermek amacıyla Tablo 8'de özetleyici bir karşılaştırma sunulmuştur. Tablo 8'deki sonuçlar, önerilen mimarinin özellikle yüksek hacimli satış ve üretim verilerinin dinamik sorgular ve API'ler üzerinden standart bir veri şemasına dökülerek çekildiği koşullarda belirgin üstünlük sağladığını göstermektedir. Mikroservis tabanlı çözümde veri tipleri ve alanlar önceden tanımlandığı için veri tipi dönüşüm hataları ve kullanıcı müdahalesinden kaynaklanan tutarsızlıklar en aza inmektedir; mükerrer kayıt kontrolleri ve entegrasyon akışının izlenmesi de otomatikleştirilebilmektedir. Buna karşılık, mikroservis tabanlı bir entegrasyonun bulunmadığı durumda veri aktarımı çoğunlukla Excel, CSV veya benzeri dosya çıktıları üzerinden manuel olarak yapılmakta, bu da veri bütünlüğü, sürdürülebilirlik ve makine öğrenmesi modellerini besleyecek yüksek hacimli veri setlerine zamanında erişim açısından önemli sınırlılıklar doğurmaktadır.

Bu yönüyle Tablo 8, Giriş bölümünde belirtilen birinci katkıyı (entegrasyon mimarisinin geliştirilmesi ve veri bütünlüğünün artırılması) somutlaştırmakta; aynı zamanda çalışmanın ikinci katkısı olan talep tahmini modellerinin, düzenli ve tutarlı veri akışına sahip bir mimari üzerinde çalıştığında neden daha yüksek performans gösterdiğini de gerekçelendirmektedir.

SONUÇLAR

Silo sistemlerde barınan heterojen verileri analiz etmesi zor olduğu için veri kalitesizliği, veri yetersizliği ve verinin doğruluğundan sapma gibi problemlerle karşılaşılabilir. Önerilen çalışmada, heterojen verilerin standartlaştırılması ile birlikte makine öğrenmesi algoritmalarını birleştiren bir entegrasyon mimarisi sunulmuştur. Bu entegrasyon mimarisinden elde edilen veri üzerinde öznitelik mühendisliği yapılmıştır. İyileştirilen verilerde, geleneksel makine öğrenmesi ve derin öğrenme yöntemleri denenmiştir. Model çıktıları açıklanabilir yapay zeka ile yorumlanmıştır. Tüm bu çıktıların karşılaştırılması sonucu, tüm veri seti ile eğitilen modeller içinden en iyi sonuç R^2 değeri 0,90 ve MAE değeri 39,25 ile LightGBM modeline ait olmuştur.

Tablo 8. Void Entegratör ile Geleneksel Rapor/Dosya Tabanlı Entegrasyonun Karşılaştırılması

Uygulama Fonksiyonları	Önerilen Mimari (Void Entegratör, mikroservis, mevcut)	Geleneksel Yaklaşım (mikroservis yok)
ERP sistemlerinden hammadde, mamul ve ticari mal tanımlarının çekilerek ana verinin oluşturulması	Bu tür uygulamalar, sistemlerin veritabanlarına doğrudan bağlanarak ürün ve ürün tanımına ilişkin alanlardan dinamik sorgularla veri çekebilir. Veri çekme sürecinde kaynak sistemdeki veritabanı yapısı ve veri tipleri önceden bilindiği için veri tipi dönüşüm hataları en aza inmektedir.	Veri setleri sistemlerde var olan sabit raporlar veya dinamik raporlarla dışarıya atılır. Dışarıya çıkartılan veri tipleri bilinmez, verileri içeriye alacak sistem mevcut veri tiplerine göre hazırlanır fakat veri tabanından çıkabilecek öncekiyle uyumlu olmayan bir veri tipi olması durumunda dönüşüm hataları oluşur.
ERP sistemlerinden tanımlı hammadde bileşenleri, reçete vb. çıktıların çekilmesi	Veritabanlarından veya API'ler üzerinden çekilen veriler, hiyerarşik yapıları farklı olsa bile oluşturulan sorgular aracılığıyla tekil ve standart veri çıktı tipi oluşturulur. Bu sayede ERP sistemi farketmeksizin uygulama, ek bir yazılım geliştirmesi gerektirmeden veri alma işlemini yapabilir.	Her sistemin kendi içinde uyguladığı rapor ve çıktı tipi farklıdır. Yazılım tipi aynı olsa dahi raporlama tipleri, raporların içindeki hücre tipleri farklılık gösterebilir. Excel veya metin dosyası gibi biçimlerde tutulan dosyalar, son kullanıcılar tarafından bozulmaya veya değiştirilmeye müsaittir. Bu durum, veri yapısının bozulması ve yeniden kodlama gereksinimi ortaya çıkarır; sürekli veri alışverişini sürdürülebilir olmaktan uzaklaştırır.
Satış ve üretim kayıt çıktılarının çekilmesi	Özellikle büyük veri setlerinin oluşturulduğu bölümdür. Sürekli veri akışı ve mevcut verinin analiz edilebilir hale gelmesi için burada büyük veriyi en hızlı ve asenkron bir biçimde çekebilmek, veri çekilirken uygulamanın çalıştığı sistemdeki kaynakların verimli kullanılması, proje verimliliği açısından kritik öneme sahiptir. Mikroservis tabanlı yapı, söz konusu veriyi performans kaybı oluşturmadan almaya imkân tanır.	Verilerin sağlıklı işlenebilmesi ve makine öğrenmesini besleyebilecek nitelikte bir veri çokluğunu karşılayabilmek için standart veri seti yöntemleri çok ağır ve hantal kalmaktadır. Bir yıllık üretim veya satış verisinin Excel veya farklı bir formatta dışarıya aktarılması, hem ERP sistem kaynaklarının gereksiz yere tüketilmesine hem fazladan depolama alanı kullanımına hem de söz konusu verilerin tekrar içeriye alınırken aynı sunucu kaynaklarının gereksiz tüketilmesine neden olmaktadır.
Entegrasyon akışının sürdürülebilir olması	Mükerrer kayıt kontrolleri söz konusu uygulamalarla otomatik bir biçimde yapılır. Aynı verinin tekrar tekrar işlenmesi engellenir; yeni	Veri aktarımları geleneksel yöntemlerle yürütüldüğünde, aynı verilerin farklı dosya sürümleriyle mükerrer bir biçimde üretilmesi ve

	veri geldikçe tetiklenen mekanizmalar sayesinde sistem kaynakları harcanmadan ve insan gücüne ihtiyaç duyulmadan entegrasyon akışı sürdürülebilir bir biçimde çalışır.	işlenmesi sık karşılaşılan bir durumdur. Bu süreç, sistemlerden dışarıya veri çıkaran raporlama uzmanları üzerinde ek iş yükü oluşturur ve sürekli insan müdahalesi gerektirir.
Kullanılan yöntemler	Veri, doğrudan veritabanından veya XML ve JSON formatlarını kullanan web servisleri/API'ler üzerinden çekilmektedir. Parametreler sistem tarafından verildiği için çıktılar bir kaynaktan diğerine doğrudan akmakta, kullanıcı müdahalesine ihtiyaç duyulmamaktadır.	Veri aktarımı çoğunlukla DBF, Excel, CSV, XML veya JSON formatında oluşturulan dosyalar üzerinden yürütülmektedir. Parametrelerin kullanıcı tarafından belirlendiği bu yapıda, veriler önce kaynaktan dışarıya, ardından hedef sisteme doğru iki aşamalı bir akış izlemekte ve her aşamada kullanıcı kaynaklı hata riski ortaya çıkmaktadır.
Mikroservis uyumluluk	mimarisiyle ERP sistemlerinde sürekli bir veri akışı mevcuttur. Mikroservis mimariler ile gelen her veri asenkron bir biçimde okunup kaynaktan hedefe taşınabilir. Taşınan veri standartlaştırılırken veri bütünlüğü de korunmuş olur.	Asenkron veri çekmek mümkün değildir. Bu sebeple, yoğun veri aktarımı sırasında mevcut sistem üzerinde kilitlenme (deadlock) türü performans sorunları ortaya çıkabilir. Ayrıca, veri bütünlüğünü korumak için sistem kaynağı tüketen ek algoritmalar geliştirilmesi gerekir.

Hammadde miktarının tahminleme çalışmaları bağlamında, ağlar arası bilgi paylaşımı ve stok tahmininin iyileştirilmesi ile sipariş planlama ve satın alma süreçleri de dolaylı olarak geliştirilmiştir. Dolayısıyla, tedarik zincirinde entegrasyon ve yapay öğrenme ihtiyacı doğrultusunda önerilen çalışmada bu ihtiyaca dair çözümler üretilmiştir.

Bu çalışma kapsamında geliştirilen stok takip tahminlemeleri ve verilerin bütünleştirilmesi tedarik zinciri yönetiminde önemli bir kolaylık sunmaktadır. Ancak, bu çalışmanın sınırları dahilinde ele alınmayan ve gelecekte araştırılabilecek çeşitli alanlar bulunmaktadır. Çalışma kapsamında geliştirilebilecek araştırmalar şunlardır: Bu makalenin sınırlılıklarından biri, kapsamlı bir uç değer (outlier) analizi yapılmamış olmasıdır. Veri setindeki uç gözlemlerin sistematik olarak incelenmesi ve farklı uç değer tespit yöntemlerinin (örneğin Grubbs testi vb.) karşılaştırılması, gelecekteki çalışmalarda ele alınacaktır.

Stok takip tahminlemeleri sonucunda entegre edilmiş sistemler arasındaki stok yönetimi için planlama yapılabilir.

Sunulan çalışmada yapılan tahminleme sonuçları sayesinde, stok yönetimi ve sipariş planlama birleştirilerek tam otomatik bir altyapı geliştirilebilir. Bu altyapı, üretken yapay zeka etmenlerinin otonom çalışması ve tahminlemelerden elde edilen bilgiler doğrultusunda sistemin herhangi bir insan etkisine maruz kalmadan, gerçek zamanlı verilere dayanarak optimal kararlar alabilir ve böylece tedarik zincirinde süreç otomasyonu sağlanabilir. Bu durum, manuel işlemlerden kaynaklanan hataları minimize edecek ve karar süreçlerini hızlandırarak operasyonel verimliliği artıracaktır. Böylece tedarik zincirinin iyileştirilmesine olanak tanıyacaktır. SAP'nin Supply Chain

Advisor'ı (Condon, 2024) gibi tamamen otonom karar destek sistemleri, tedarik zinciri yönetiminde yenilikçi bir yaklaşım sunmaktadır. Benzer bir yaklaşımla, çalışmamızın sonuçları üzerinde inşa edilecek gelecekteki sistemler de tam otomatik karar verme süreçlerine sahip olabilir.

Bu öneriler, tedarik zinciri yönetiminde makine öğrenmesi ve entegre sistemlerin kullanımının daha da geliştirilmesine ve optimize edilmesine yönelik önemli adımlar olarak görülmektedir. Gelecekteki çalışmalar, bu alanlarda gerçekleştirilecek yenilikler ve iyileştirmeler ile tedarik zinciri yönetiminin etkinliğini ve verimliliğini daha da artıracaktır (Islam vd., 2024).

TEŞEKKÜR

Bu çalışma, KOSGEB'in Ar-Ge, Ür-Ge ve İnovasyon Destek Programı kapsamında (Başvuru No: 872787) desteklenmiştir. Bu araştırmanın gerçekleştirilmesine olanak sağlayan finansal destekleri için KOSGEB'e teşekkür ederiz.

Yapay Zeka Katkı Beyanı

Bu makale tamamen herhangi bir yapay zeka aracının yardımı olmadan yazılmış, düzenlenmiş, analiz edilmiş ve hazırlanmıştır. Metin, veri analizi ve şekiller dahil tüm içeriğin yalnızca yazarlar tarafından oluşturulduğunu beyan ederim.

KAYNAKLAR

- Aamer, A., Eka Yani, L., & Alan Priyatna, Im. (2020). Data analytics in the supply chain management: Review of machine learning applications in demand forecasting. *Operations and Supply Chain Management: An International Journal*, 14(1), 1-13. <http://doi.org/10.31387/oscm0440281>
- Acar, S. G., & Yılmaz, M. (2013). Matbaa İşletmeleri İçin Bir Malzeme İhtiyaç Planlama Yazılımı Geliştirme ve Uygulanması. *Bilişim Teknolojileri Dergisi*, 6(1), 23-32.
- Akdağ, H., & Kocakoç, İ. D. (2023). TOPLAM KALİTE YÖNETİMİ, KAIZEN VE ENTEGRASYON SÜREÇLERİNİN BÜTÜNLEŞİK ANALİZİ. *Nazilli İktisadi ve İdari Bilimler Fakültesi Dergisi*, 4(2), 119-132. <https://doi.org/10.59113/niibfd.1391223>
- Aljohani, A. (2023). Predictive analytics and machine learning for real-time supply chain risk mitigation and agility. *Sustainability*, 15(20), 15088. <https://doi.org/10.3390/su152015088>
- Bagchi, P. K., Chun Ha, B., Skjoett-Larsen, T., & Boege Soerensen, L. (2005). Supply chain integration: A European survey. *The international journal of logistics management*, 16(2), 275-294. <https://doi.org/10.1108/09574090510634557>
- Basana, S., Suprpto, W., Andreani, F., & Tarigan, Z. (2022). The impact of supply chain practice on green hotel performance through internal, upstream, and downstream integration. *Uncertain Supply Chain Management*, 10(1).
- Botta-Genoulaz, V., & Millet, P.-A. (2005). A classification for better use of ERP systems. *Computers in industry*, 56(6), 573-587. <https://doi.org/10.1016/j.compind.2005.02.007>
- 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>
- Cebeci, K., & Korçak, Ö. (2020). Design of an enterprise level architecture based on microservices. *Bilişim Teknolojileri Dergisi*, 13(4), 357-371. <https://doi.org/10.17671/gazibtd.558392>
- Chen, H.-C., Lu, M.-J., Liu, C.-C., & Tsai, C.-H. (2012). A study of the performance improvement of bill of material document sign flow system. *International Journal of Academic Research in Accounting, Finance and Management Sciences*, 2(1), 65-79.
- Condon, S. (2024). *GenAI: Agentic Workflows with the Supply Chain Advisor*. SAP Community. Geliş tarihi gönderen <https://community.sap.com/t5/technology-blogs-by-sap/genai-agentic-workflows-with-the-supply-chain-advisor/ba-p/13700531>

- Davenport, T. H., & Brooks, J. D. (2004). Enterprise systems and the supply chain. *Journal of Enterprise Information Management*, 17(1), 8-19. <https://doi.org/10.1108/09576050410510917>
- Davis, T. (1993). Effective supply chain management. *Sloan management review*, 34, 35-35.
- Doğar, A. (2006). *Tedarik Zinciri Nde Stok Yönetimi*. Geliş tarihi gönderen <https://polen.itu.edu.tr/bitstreams/71d3843e-d65d-470d-a63f-4362c41f9100/download>
- Droge, C., Vickery, S. K., & Jacobs, M. A. (2012). Does supply chain integration mediate the relationships between product/process strategy and service performance? An empirical study. *International Journal of Production Economics*, 137(2), 250-262. <https://doi.org/10.1016/j.ijpe.2012.02.005>
- Elufioye, O. A., Ike, C. U., Odeyemi, O., Usman, F. O., & Mhlongo, N. Z. (2024). Ai-Driven predictive analytics in agricultural supply chains: A review: assessing the benefits and challenges of ai in forecasting demand and optimizing supply in agriculture. *Computer Science & IT Research Journal*, 5(2), 473-497.
- Frohlich, M. T., & Westbrook, R. (2001). Arcs of integration: An international study of supply chain strategies. *Journal of operations management*, 19(2), 185-200. [https://doi.org/10.1016/S0272-6963\(00\)00055-3](https://doi.org/10.1016/S0272-6963(00)00055-3)
- Ghobakhloo, M. (2020). Industry 4.0, digitization, and opportunities for sustainability. *Journal of cleaner production*, 252, 119869. <https://doi.org/10.1016/j.jclepro.2019.119869>
- Groenewald, C. A., Garg, A., & Yerasuri, S. S. (2024). Smart supply chain management optimization and risk mitigation with artificial intelligence. *Naturalista campano*, 28(1), 261-270.
- Hazen, B. T., Boone, C. A., Ezell, J. D., & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. *International Journal of Production Economics*, 154, 72-80. <https://doi.org/10.1016/j.ijpe.2014.04.018>
- Islam, S., Amin, S. H., & Wardley, L. J. (2024). A supplier selection & order allocation planning framework by integrating deep learning, principal component analysis, and optimization techniques. *Expert Systems with Applications*, 235, 121121. <https://doi.org/10.1016/j.eswa.2023.121121>
- Karakoç, N., Eren, T., & Özcan, E. (2020). Sürdürülebilir Tedarik Zinciri Yönetimi için Endüstri 4.0'daki Zorlukların Değerlendirilmesi. *Endüstri Mühendisliği*, 31(2), 215-233. <https://doi.org/10.46465/endustrimuhendisligi.694613>
- Khanuja, A., & Jain, R. K. (2019). Supply chain integration: A review of enablers, dimensions and performance. *Benchmarking: An International Journal*, 27(1), 264-301. <https://doi.org/10.1108/bij-07-2018-0217>
- Koçoğlu, İ., İmamoğlu, S. Z., İnce, H., & Keskin, H. (2011). The effect of supply chain integration on information sharing: Enhancing the supply chain performance. *Procedia-social and behavioral sciences*, 24, 1630-1649. <https://doi.org/10.1016/j.sbspro.2011.09.016>
- Kunduru, A. R., & Kandepu, R. (2023). Data archival methodology in enterprise resource planning applications (Oracle ERP, Peoplesoft). *Journal of Advances in Mathematics and Computer Science*, 38(9), 115-127.
- Lamer, A., Fruchart, M., Paris, N., Popoff, B., Payen, A., Balcaen, T., ... Doutreligne, M. (2022). Standardized description of the feature extraction process to transform raw data into meaningful information for enhancing data reuse: Consensus study. *JMIR Medical Informatics*, 10(10), e38936. <https://doi.org/10.2196/38936>
- Lee, H. L., Padmanabhan, V., & Whang, S. (1997). The Bullwhip Effect in Supply Chains. *Sloan Management Review*, 38(3), 93-102.
- Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., & Zacharia, Z. G. (2001). DEFINING SUPPLY CHAIN MANAGEMENT. *Journal of Business Logistics*, 22(2), 1-25. <https://doi.org/10.1002/j.2158-1592.2001.tb00001.x>
- Min, S., Zacharia, Z. G., & Smith, C. D. (2019). Defining Supply Chain Management: In the Past, Present, and Future. *Journal of Business Logistics*, 40(1), 44-55. <https://doi.org/10.1111/jbl.12201>
- Mohamed, A. E. (2024). *Inventory Management*. Geliş tarihi gönderen <https://www.intechopen.com/online-first/88430>
- Ni, D., Xiao, Z., & Lim, M. K. (2020). 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>

- Oyewole, A. T., Okoye, C. C., Ofodile, O. C., & Ejairu, E. (2024). Reviewing predictive analytics in supply chain management: Applications and benefits. *World Journal of Advanced Research and Reviews*, 21(3), 568-574. <https://doi.org/10.30574/wjarr.2024.21.3.0673>
- Özdemir, A. İ. (2004). Tedarik zinciri yönetiminin gelişimi, süreçleri ve yararları. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (23). Geliş tarihi gönderen <https://dergipark.org.tr/en/pub/erciyesiibd/issue/5880/77809>
- Power, D. (2005). Supply chain management integration and implementation: A literature review. *Supply chain management: an International journal*, 10(4), 252-263. <https://doi.org/10.1108/13598540510612721>
- Prajapati, M. (2024). We are integrating Artificial Intelligence and Data Analytics for Supply Chain Optimization in the Pharmaceutical Industry. *J. Electrical Systems*, 20(3s), 682-690.
- Rai, R., Tiwari, M. K., Ivanov, D., & Dolgui, A. (2021). Machine learning in manufacturing and industry 4.0 applications. *International Journal of Production Research*, 59(16), 4773-4778. <https://doi.org/10.1080/00207543.2021.1956675>
- Rodríguez, E. Y. A., Rodríguez, E. C. A., D, A. F., Silva, A., Rizol, P. M. S. R., D, R., ... Marins, F. A. S. (2024). Analysis of machine learning integration into supply chain management. *International Journal of Logistics Systems and Management*, 47(3), 327-355. <https://doi.org/10.1504/ijlsm.2024.136856>
- Sayer, S., & Ülker, A. (2014). ÜRÜN YAŞAM DÖNGÜSÜ YÖNETİMİ. *Engineer & the Machinery Magazine*, (657). Geliş tarihi gönderen <https://search.ebscohost.com/login.aspx?direct=true&profile=ehost&scope=site&authtype=crawler&jrnl=13003402&AN=101072025&h=I8GAYfXMY%2Fpb%2BIEFz6G7i%2FyDBNwisNyBtWQOXBzCNPIMNTx0BETJaBTGEpQvzt4z%2BoQrb7DC2xJNT7bpLYpGLA%3D%3D&crl=c>
- Tiwari, S. (2021). Supply chain integration and Industry 4.0: A systematic literature review. *Benchmarking: An International Journal*, 28(3), 990-1030. <https://doi.org/10.1108/BIJ-08-2020-0428>
- Toorajipour, R., Sohrabpour, V., Nazarpour, A., Oghazi, P., & Fischl, M. (2021). Artificial intelligence in supply chain management: A systematic literature review. *Journal of Business Research*, 122, 502-517. <https://doi.org/10.1016/j.jbusres.2020.09.009>
- 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>
- Xu, Q., He, F., & Qiu, R. G. (2005). Heterogeneous information integration for supply chain systems. *2005 IEEE International Conference on Systems, Man and Cybernetics*, 1, 97-102. IEEE. Geliş tarihi gönderen https://ieeexplore.ieee.org/abstract/document/1571128/?casa_token=RzXzXZchGqgAAAAA:og5MkaX1r-sN6a3PR_GuUPHn_v7qewtL8JRTfFppYdT4oCOjjJKtDEB8U9hD28T0SjkKp2I <https://doi.org/10.1109/ICSMC.2005.1571128>
- Yu, W., Jacobs, M. A., Salisbury, W. D., & Enns, H. (2013). The effects of supply chain integration on customer satisfaction and financial performance: An organizational learning perspective. *International Journal of Production Economics*, 146(1), 346-358. <https://doi.org/10.1016/j.ijpe.2013.07.023>