

Duygu analizi ve yapay sinir ağı kullanılarak envanter rotalama problemi için talep tahmini

Demand forecasting for inventory routing problem using artificial neural network and sentiment analysis

Ashlı BORU İPEK^{1,a}, Ayşe Tuğba DOSDOĞRU^{*1,b}, Rızvan EROL^{2c}

¹ Adana Alparslan Türkeş Bilim ve Teknoloji Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 01250, Adana

² Çukurova Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 01330, Adana

• Geliş tarihi / Received: 20.02.2020 • Düzeltilecek geliş tarihi / Received in revised form: 25.11.2020 • Kabul tarihi / Accepted: 02.12.2020

Öz

Sosyal medya kullanıcılarının sayısı her geçen gün katlanarak artmaktadır. Bu gelişme, tedarik zincirinde iş zekasının ilerletilmesinde önemli fırsatlar sunduğu için araştırmacıları ve yöneticileri sosyal medya ve müşteri duygularını analiz etmeye teşvik etmektedir. Ancak, tedarik zinciri üyeleri günümüz iş dünyasında genel duyguları anlamakta zorlanmaktadır. Bu nedenle, tedarik zincirine değerli bilgiler sağlamak için çeşitli yöntemler kullanılmaktadır. Bu çalışmada, SentiStrength tek bir ürün ile ilgili müşteri yorumlarını analiz etmek için kullanılmaktadır. Daha sonra, SentiStrength'in çıktısı ve ürün talepleri, müşteri taleplerini tahmin etmek için Yapay Sinir Ağına beslenmiştir. Ardından, tahmin edilen müşteri talepleri kullanılarak envanter rotalama problemini çözmek için Baskılanamayan Sıralamalı Genetik Algoritma II (NSGA-II) tabanlı simülasyon optimizasyonu kullanılmıştır. Çalışmanın sonuçları, duygu analizi içeren melez metodolojinin kullanımının envanter rotalama problemini başarılı bir şekilde analiz edebileceğini göstermiştir.

Anahtar kelimeler: Duygu analizi, Envanter rotalama problemi, Simülasyon optimizasyonu

Abstract

Social media users have been growing exponentially in recent years. This growth has evoked researchers and manager to analyze the social media and customer sentiment because it offers significant opportunities to advance business intelligence in supply chain. However, supply chain members are struggling in understanding the general sentiments in today's business world. Therefore, various methods are used to provide valuable insights in supply chain. In this paper, SentiStrength is used to analyze customer reviews related to one type of product. The output of SentiStrength and demands of the product are then fed into Artificial Neural Network to forecast the customer demands. After, nondominated sorting genetic algorithm II (NSGA-II) based simulation optimization is employed to solve the inventory routing problem using forecasted customer demands. The results of the study demonstrated that the use of hybrid methodology containing sentiment analysis can successfully analyze the inventory routing problem.

Keywords: Sentiment analysis, Inventory routing problem, Simulation optimization

*^b Ayşe Tuğba DOSDOĞRU; adosdogru@atu.edu.tr, Tel: (0322) 455-0000, orcid.org/0000-0002-1548-5237

^a orcid.org/0000-0001-6403-5307

^c orcid.org/0000-0001-6914-5062


1. Giriş

Günümüzde sosyal ağlar aracılığıyla birçok bilgi paylaşımı yapılmaktadır. İnsanlar fikirlerini ve duygularını sosyal medya siteleri, forumlar ve bloglar aracılığıyla paylaşabilmektedir. Özellikle çevrimiçi sosyal medya web siteleri temel bilgilerin üretimini, iletimini ve tüketimini sağlamaktadır. Tüketiciler ve üreticiler arasında bağlantı sağlamak için sosyal medya başarıyla kullanılmaktadır. Sosyal medya binlerce kişiye anket yapılmadan önemli bulgulara ulaşmayı mümkün kılmaktadır. Örneğin, Twitter milyonlarca insanı ağ üzerinden birbirine bağlamaktadır. Sosyal medya, işletmeler için ürünle ilgili geri bildirim ve ürünün daha iyi nasıl geliştirilebileceği konusunda fikir sahibi olmaları için harika bir fırsat sunmaktadır. Ayrıca işletmelerin müşterileriyle doğrudan etkileşime girmeleri için yeni fırsatlar sağlamaktadır (Gaikar ve Marakarkandy, 2015).

Özellikle ürün yorumları, işletmelerin pazar araştırması için kullandığı anahtar kaynaklardan biridir. İşletmeler, ürün yorumlarını yakından izleyerek pazar hakkında bilgi edinebilirler. Diğer yandan, hacimli ve dinamik yapısı nedeniyle tüketici tarafından sağlanan çevrimiçi yorumların analizi zor olabilir. Ürün yorumlarının çoğu, yalnızca ürün ile ilgili görüşlerin sayısal derecelendirmelerini değil, aynı zamanda metinsel içeriği de içermektedir (Schneider ve Gupta, 2016). Bu nedenle, bu verilerden anlamlı bilgileri elle çıkarmak zordur. Ayrıca, işletmelerin ürünler hakkındaki fikirlerini özetlemesi ve analiz etmesi de zorlu bir süreçtir. İnternet ortamı çok fazla bilgi içermektedir, ancak fazla bilgi, doğru bilgiye ulaşmayı karmaşık ve zor hale getirebilmektedir. Örneğin, sosyal medya kullanıcısının restoran gibi bir yer hakkındaki yüzlerce yorumu okuması ve yorumlaması zahmetli bir süreçtir. Bu nedenle, duygu analizi kullanılmadığında insanların duygu ve düşüncelerini değerlendirmek uzun zaman alabilir.

Duygu analizi, verilerin analiz sürecidir ve çevrimiçi alışveriş verilerini başarıyla analiz etmek için kullanılabilir. Çevrimiçi alışveriş siteleri çok fazla ürün yorumu içermektedir. Bir ürünü satın almadan önce, müşteriler o ürünle ilgili yorumları okuyarak karar verebilmektedirler. Diğer insanların görüşleri, bir tür doğal dil işleme görevi olan duygu analizi ile kolayca analiz edilebilmektedir. Duygu analizi, insanların belirli bir konu hakkındaki görüşlerini sınıflara ayırmaktadır (Rani ve Singh, 2017). Duygu analizinde, metin polaritesi genellikle pozitif, negatif ve nötr olmak üzere üç sınıfa ayrılmaktadır.

Günümüzde tedarik zinciri yönetimi, rekabet avantajlarını korumak ve müşteri taleplerini karşılamak için birçok firma tarafından uygulanmaktadır. Tedarik zinciri yönetimi, tedarik zincirindeki tüm süreçleri içermektedir. Dağıtım süreci de bu süreçlerden biridir. Dağıtım süreci, ulaştırma ve envanter yönetiminden doğrudan etkilenmektedir. Ancak, ulaşım ve envanter yönetimi modelleme yaklaşımlarında genellikle bağımsız olarak ele alınmaktadır. Bu nedenle, karşılıklı etkileri genellikle ihmal edilmektedir. Envanter yönetimi ve ulaştırma arasındaki ilişkiyi analiz etmek için, bu iki faaliyet aynı anda düşünülebilir. Bu da literatürde ERP olarak ele alınmaktadır. Bu problemde amaç, envanter yönetimi ve araç rotalamasının toplam maliyetini en aza indirmektir. Problem karmaşıklığı, envanter yönetimi ve rotalamanın aynı anda değerlendirilmesi ile ilgilidir (Popović vd., 2012). Bu çalışmada, Envanter Rotalama Problemi (ERP)'ne yeni bir metodoloji önermek amacıyla duygu analizi kullanılmıştır. Tasarlanan metodoloji iki aşamadan oluşmaktadır. Aşama I'de müşteri yorumlarının skorunu hesaplamak için SentiStrength kullanılmıştır. Daha sonra, SentiStrength çıktısı ve gerçek müşteri talepleri Yapay Sinir Ağı (YSA) ile entegre edilmiştir. Aşama II'de ERP'yi çözmek için YSA çıktısı (yani, tahmin edilen müşteri talepleri), NSGA-II tabanlı simülasyon optimizasyonu (SO)'na beslenmiştir. Önerilen metodolojinin genel yapısı Şekil 1'de verilmiştir.



Şekil 1. Önerilen metodolojinin genel yapısı

2. Önceki çalışmalar

Ürünlerin gelecekteki satış performansı, müşteri değerlendirmelerinden elde edilen duygulardan ve değerlendirmelerin kalitesinden önemli ölçüde etkilenmektedir (Balaji, 2015). Bu nedenle, müşteri değerlendirmeleri, satışlar üzerinde kritik bir etkiye sahip olabileceğinden tahminleme modelleriyle entegre edilebilir. Örneğin, Yu vd. (2012) çalışmalarında satış tahmini için duygu analizi içeren bir metot tasarlamışlardır. Ayrıca, yorumların duygu analizi için olasılıksal model kullanılmıştır. Film sektöründen gerçek bir örnek kullanılarak yorumlar arasındaki ilişki araştırılmıştır. Sonuçlar, önerilen yöntemin otoregresif modeline kıyasla daha iyi tahmin performansı verdiğini göstermiştir.

Gaikar ve Marakarkandy (2015) çalışmalarında ürünün satın alınmasını etkileyen faktörleri belirlemişlerdir. Çalışmada, API kullanılarak Twitter'dan film hakkında tweet'ler toplanmıştır. Pozitif ve negatif tweet'leri belirlemek için duygu analizi aracı kullanılmıştır. Jadav ve Vaghela (2016) optimize edilmiş Destek Vektör Makinesi'ni (DVM) kullanmışlardır. Önerilen modelin performansını karşılaştırmak için Naïve Bayes ve DVM kullanılmıştır. Çalışmada, yapılandırılmamış film yorumları önce yapılandırılmış forma dönüştürülmüş ve daha sonra önerilen yöntemler için girdi olarak kullanılan skor hesaplanmıştır. Dey vd. (2016) çalışmalarında Naïve Bayes ve k-en yakın komşu dahil olmak üzere iki denetimli makine öğrenme algoritması kullanmışlardır. Çalışmada önerilen algoritmalar, film yorumları ve otel yorumları için kullanılmıştır. Ahn ve Spangler (2014) sosyal medya tabanlı özellikleri dikkate alarak satış tahminlerinin performansını analiz etmişlerdir. Aylık otomobil satışlarını modellemek için otoregresif entegre hareketli ortalama kullanılmıştır. Schneider ve Gupta (2016) satış tahmin modelindeki boyutu azaltmak için rastgele projeksiyon modeli kullanmışlardır. Ayrıca, önerilen modelin sonuçlarını karşılaştırmak için DVM kullanılmıştır. Fan vd. (2017) çalışmalarında Bass ve Norton modelini ürün satış tahminleri için çıkarılan duygu endeksi ile birleştirmişlerdir. Çevrimiçi yorumları sınıflandırmak için Naive Bayes, DVM ve k-en yakın komşu kullanılmıştır. Önerilen modelin performansını değerlendirmek için otomotiv endüstrisinden veriler kullanılmıştır. Lau vd. (2018), paralel yön odaklı duygu analizi içeren büyük veri analizi metodolojisi tasarlamışlardır. Buna ek olarak, duygu temelli satış tahminlerinde paralel evrimsel aşırı öğrenme makinesi kullanmışlardır.

Pai ve Liu (2018) aylık toplam araç satışlarını tahmin etmek için hem zaman serisi modellerini hem de çok değişkenli regresyon modellerini kullanmışlardır. Satışları tahmin etmek için iki kategori kullanılmıştır. Birinci kategoride, veri kümesi olarak geçmiş aylık toplam araç satışları kullanılmış, ikinci kategoride ise tweetlerin duygu skorları ve iki borsa değeri yer almıştır. Çalışmada satışları tahmin etmek için mevsimsellikten arındırma yöntemleri de uygulanmıştır. Kumar vd. (2016) çalışmalarında Naïve Bayes, Lojistik Regresyon ve SentiWordNet algoritması ile yorumları olumlu ve olumsuz olarak sınıflandırmışlardır. Çalışmada yorumlar, Amazon web sitesinden alınmıştır.

Duygu analizi uygulamaları, birçok alanda kullanılmaktadır. Örneğin, Deniz ve Kızıloz (2017) çalışmalarında Türkçe belgelerin yazar, tür ve cinsiyet açısından metin sınıflandırmasını ele almışlardır. Gezici ve Yanikoğlu (2018), film değerlendirmelerinin Türkçe sınıflandırılmasında farklı özelliklerin etkinliğini araştırmışlardır. Ozturk vd. (2017) çalışmalarında öğrencilerin sosyal medyada Anadolu Üniversitesi'ne yönelik düşüncelerini anlamak için Twitter kullanmışlardır. Çalışmada, toplanan tweet'ler pozitif, negatif ve nötr olmak üzere üç duygu sınıfında sınıflandırılmıştır. Swain ve Cao (2019) çalışmalarında tedarik zinciri üyeleri tarafından üretilen sosyal medya içeriğinin tedarik zinciri performansı üzerindeki etkisini analiz etmişlerdir. Duygu analizi, önerilen hipotezleri test etmek için Naive Bayes aracılığıyla uygulanmıştır. Çalışmanın sonuçları, sosyal medya içeriğinin tedarik zincirinde bilgi paylaşımı ve işbirliği için faydalı olabileceğini göstermiştir. Çalışmamızın ana katkıları şu şekilde özetlenebilir: (i) Müşteri yorumlarının duygu skorunu hesaplamak için SentiStrength uygulanması; (ii) Müşteri talebini tahmin etmek için YSA'nın duygu skoru ile birlikte uygulanması; (iii) Talep tahminlerinin kullanıldığı ERP'yi çözmek için NSGA-II tabanlı SO'nun uygulanmasıdır.

3. Materyal ve yöntem

Bu çalışmada Amazon web sitesinde yer alan elektronik ile ilgili müşteri yorumları, yapılandırılmamış ürün bilgileri olarak kullanılmıştır. SentiStrength, İngilizce metinden duygu skorunu belirlemek için kullanılmıştır. SentiStrength, kısa, resmi olmayan İngilizce metinde duygu skorunu bulmak için ek dil bilgisi ve kuralları kullanan sözlük tabanlı bir sınıflandırıcıdır (Thelwall vd., 2012). SentiStrength, pozitif ve negatif duygu skorunu

aynı anda belirlemektedir. SentiStrength çıktısı her metin için iki tamsayı içerir. Birinci tamsayı, duygu skoru +2 ile +5 arasında olan pozitif duygu, diğeri ise duygu skoru -2 ile -5 arasında değişen negatif duyguyu belirtmektedir (Theilwall vd., 2012). Nötr kelimeleri belirtmek için ± 1 kullanılmaktadır.

SentiStrength metni kelimelere böler ve duygu skorunu belirlemek için her kelime kontrol edilir. Cümlelerin genel skoru, en yüksek pozitif ve negatif puan dikkate alınarak belirlenir. Müşteri yorumlarında birden fazla cümle bulunduğunda, her cümle için maksimum puan alınır. Örnek müşteri yorumunun değerlendirilmesi Tablo 1'de

verilmektedir. Bu metinde, maksimum pozitif (pz) skor 3 ve maksimum negatif (ng) skor -1'dir.

Çalışmamızda, büyük verilerin hacmini ve çeşitliliğini sağlamak amacıyla Amazon web sitesinin elektronik kategorisinde yer alan tüm müşteri yorumları filtrelenmiş ve daha sonra bir yıl boyunca müşteri yorumları veri kümesi olarak saklanmıştır. Müşteri yorumlarına ek olarak, Chen vd. (2012)'nin çalışmalarında kullandıkları müşteri talep verileri kullanılmıştır. Kullanılan veri seti, satıcı tarafından tutulan müşteri ile ilgili 11 farklı değişkeni içeren verileri içermektedir. Bu değişkenler, 2010 ve 2011 yıllarında gerçekleşen tüm işlemleri içermektedir.

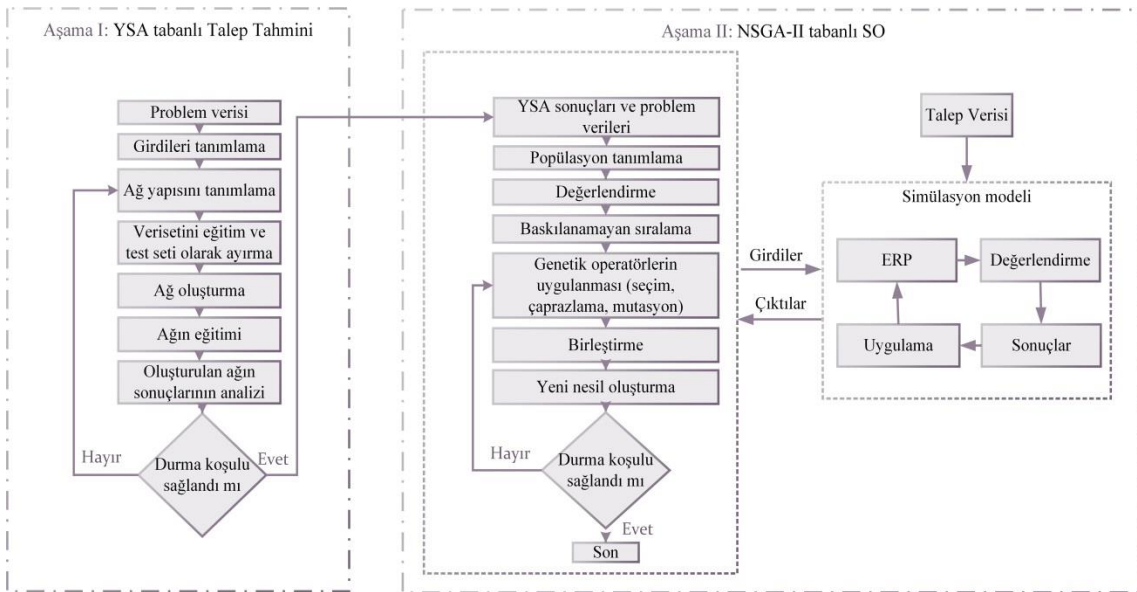
Tablo 1. Örnek müşteri yorumunun değerlendirilmesi

Müşteri Yorumu	Pz Ng	Cümlelerin değerlendirilmesi
What can I say, it's a Nikon lens cap. Good quality as expected. I love these caps with the spring action releases.	3 -1	<ul style="list-style-type: none"> ❖ What can I say, it's a Nikon [proper noun] lens cap. [sentence: 1,-1] ❖ Good[3] quality as expected. [sentence: 3,-1] ❖ I love[3] these caps with the spring a [sentence: 3,-1]

Ele alınan tedarik zincirinde müşteri talebini tahmin etmek için YSA kullanılmıştır. YSA modelinde veri kümesi, eğitim seti (% 80) ve test seti (% 20) olarak ayrılmıştır. Yorumlardan elde edilen duygu skorlarına ve talep değerlerine YSA öncesi ön işleme işlemi olarak normalleştirme uygulanmıştır. Denklem (1) kullanılarak veri kümesi [0, 1] aralığında normalleştirilmiştir.

$$y = \frac{x - minimum}{maksimum - minimum} \quad (1)$$

Burada x , gözlemlenen değerler kümesini, minimum ve maksimum sırasıyla gözlemlenen değerler kümesindeki minimum ve maksimum değerleri belirtmektedir.



Şekil 2. Tasarlanan yöntem

Tasarlanan YSA üç katmandan oluşmaktadır. İlk katman giriş katmanıdır. İkinci katman 20 gizli nöron içeren gizli katmandır. Son katman çıktı katmanıdır. YSA parametreleri deneme yanılma

yöntemiyle belirlenmiştir. Bu çalışmada, amaç fonksiyonu olarak ortalama karesel hata (MSE) seçilmiştir. Optimizasyon metodu için "adam" seçilmiştir. Aktivasyon fonksiyonu olarak

doğrultulmuş doğrusal birim (ReLU) kullanılmıştır. Tahmin edilen müşteri talepleri kullanılarak, tedarik zincirindeki ERP'yi çözmek için SO yöntemi oluşturulmuştur (Şekil 2).

Bu çalışmada, tedarik zinciri beş müşteri ve beş Dağıtım Merkezi (DM) içermektedir. Her müşteri talebi farklı DM tarafından karşılanmaktadır. Her bir DM'nin envanter kontrolü periyodik gözden geçirme (s, S) politikası dikkate alınarak yapılmaktadır. Envanter belli periyotlarla (R, inceleme periyodu) kontrol edilmektedir. Çalışmamızda R sabit ve 5 gün olduğu varsayılmıştır. Eğer stok miktarı yeniden sipariş noktasında (s) ya da altında ise belli miktarda sipariş verilerek stok miktarı maksimum sipariş miktarı seviyesine (S) ulaştırılmaktadır. Eğer stok

seviyesi yeniden sipariş noktasının üzerinde ise sipariş verilmemektedir. SO modeli üç ay boyunca çalıştırılmıştır.

Çalışmamızda, toplam tedarik zinciri maliyeti (TTZM) ve DM'lerinin servis seviyelerinin ortalaması dikkate alınarak araç için rota belirlenmektedir. Araç, tedarikçiye geri dönerken en kısa yolu kullanmaktadır. Çalışmamızda kapasite sınırı olmayan tek araç kullanılmış ve bu aracın hızının düzgün (80, 90) metre/saat dağıldığı varsayılmıştır. Her bir inceleme periyodunda her bir DM en fazla bir kez ziyaret edilmektedir. Yenileme siparişine bağlı olarak her DM'ye teslim edilen miktar değişiklik göstermektedir. Rotalama maliyeti Denklem (2) kullanılarak hesaplanmaktadır.

$$V(s, S) = \tau + \sum_{d=1}^{\text{toplama teslimat sayısı}} \gamma_d + \sum_{i \in S\{d\}} (\vartheta_i + \alpha \text{Dist}_{ij}) \quad (2)$$

τ , aracın maliyetidir. γ_d ise dağıtımın başlaması için gerekli olan sabit maliyettir. ϑ_i , her müşteride duraklamasının sabit maliyetidir. Birim mesafedeki ulaşım maliyeti ise α 'dır. Her dağıtım merkezinden Tedarikçiye olan uzaklık Dist_{ij} ile ifade edilmektedir. Son olarak $S\{d\}$, mevcut dağıtım merkezlerini ifade etmektedir.

TTZM, rotalama maliyeti ($V(s, S)$) ve envanter maliyetini $EM(s, S)$ içermektedir (Denklem (3)).

$$\text{TTZM} = EM(s, S) + V(s, S) \quad (3)$$

$$EM(s, S) = \sum_{n=1}^{\text{Toplam Periyot}} \left\{ \sum_{i=1}^n (h_i X_{in}^+ + I\{X_{in} \leq s\} (k_i X_{in}^- + p_i P_i + c_i + O_i)) \right\} \quad (4)$$

Denklem (4)'te i DM sayısını, n ise periyot sayısını ifade etmektedir. Çalışmamızda elde bulundurma maliyeti ($h_i X_{in}^+$) periyot boyunca elimizde bulunan envanter miktarı ile doğru orantılıdır. Elde bulundurmama maliyeti ($k_i X_{in}^-$) ise periyot boyunca karşılanamayan müşteri sipariş miktarı ile doğru orantılıdır. İşlem maliyeti ($p_i P_i$) işlem süresi ile orantılıdır. Kullanım başına düşen sipariş maliyeti (c_i) ise zamana bağlı olmaksızın dağıtım merkezleri kullanıldığında ele alınan bir maliyettir. Sipariş işleme maliyeti (O_i) sipariş işleme süresine ve kullanım maliyetine göre ele alınmaktadır. TTZM parametrelerinin değerleri [Boru vd. \(2019\)](#) çalışmasında mevcuttur.

Yoğun rekabet koşullarında, marjinal kâr son yıllarda oldukça azalmıştır ve bu nedenle şirketlerin yönetim zorluklarının üstesinden gelebilmesi için toplam maliyeti düşürmesi gerekmektedir. ERP'de ortaya çıkan maliyetler, tedarik zincirinde hangi envanter rotalama modelinin kullanılacağına karar verilmesi aşamasında önemli bir rol oynamaktadır. Son yıllarda, çok amaçlı yöntemler tedarik zinciri optimizasyonunda daha yaygın hale gelmiştir. Bu

yöntemler arasında NSGA-II, simülasyon tabanlı optimizasyon için en yaygın kullanılan algoritmadır ([Avcı ve Selim, 2017](#)). NSGA-II, hızlı baskılanamayan sıralama prosedürü, seçkinci (elitist) koruyan yaklaşım ve parametresiz (parameter-free) paylaşım operatörü kullanarak diğer çok amaçlı genetik algoritma tabanlı yöntemlerden daha iyi performans göstermektedir ([Deb et al., 2002](#)). Bu nedenle, çalışmamızda optimizasyon yöntemi olarak SO modelinde kullanılmak için NSGA-II seçilmiştir. SO yönteminde, NSGA-II kullanılarak ortalama servis seviyesi en üst düzeye çıkarılırken toplam tedarik zinciri maliyeti en aza indirilmektedir. NSGA-II tabanlı SO modelinde iterasyon sayısı 20 olarak ele alınmıştır. Tasarlanan SO metodolojisinde, yeniden sipariş noktası, maksimum sipariş miktarı seviyesi ve başlangıç stoğu NSGA-II tarafından belirlenmektedir. NSGA-II, $O(MN^2)$ hesaplama karmaşıklığı ile hızlı baskılanamayan sıralama yaklaşımı sunmaktadır ([Sarkar ve Modak, 2005](#)). NSGA-II'de popülasyon, problem aralığı ve kısıtlamalar dikkate alınarak tanımlanır. Baskılanamayan sıralama yaklaşımı uygulanır. Yiğilme uzaklığı değeri hesaplanır. Bireylere

genetik operatörler uygulanır. Bu işlemler, belirlenen sayıda nesil oluşturuluncaya kadar devam eder. NSGA-II ile ilgili detaylı bilgiler [Deb et al. \(2002\)](#) ve [Yusoff vd. \(2011\)](#) çalışmalarında

mevcuttur. Ayrıca, NSGA-II'nin uygulama prosedürü sözde kod ([Konak vd., 2006](#)) ile Şekil 3'te özetlenmektedir.


-
- Adım 1:** Boyutu N olan ebeveyn popülasyonunu (PP_0) rassal oluştur. t ise 0 olarak ayarlanır.
- Adım 2:** Boyutu N olan yavru popülasyonu (QP_0) oluşturmak için PP_0 'a mutasyon ve çaprazlama uygulanır.
- Adım 3:** Durma kriteri karşılandığında PP_t 'ye dönülür. t , nesil numarasını göstermektedir.
- Adım 4:** PP_t ve QP_t içeren birleştirilmiş popülasyon CP_t olarak atanır.
- Adım 5:** Hızlı baskılanamayan sıralama algoritması aracılığıyla CP_t 'de baskılanamayan cepheler ($NDF_1, NDF_2, \dots, NDF_k$) tanımlanır.
- Adım 6:** Her $i = 1, \dots, k$ için aşağıdaki adımlar uygulanır.
- Adım 6.1:** NDF_i 'deki her çözüm için yığılma uzaklığı hesaplanır.
- Adım 6.2:** PP_{t+1} oluşturulur.
- Adım 7:** PP_{t+1} 'den ebeveynleri seçmek için yığılma uzaklığına dayalı seçim uygulanır. Boyutu N olan yavru popülasyonu QP_{t+1} oluşturmak için PP_{t+1} 'e mutasyon ve çaprazlama uygulanır.
- Adım 8:** $t, t + 1$ olarak ayarlanır ve Adım 3'e geri dönülür.
-

Şekil 3. NSGA-II'nin sözde kodu ([Konak vd., 2006](#))

4. Bulgular ve tartışma

İşletmelerin giderek karmaşıklaşan endüstriyel ortamlarda müşterilerin artan beklentilerini karşılamaları gerekmektedir. Veriler, tedarik zinciri sisteminin hammaddesidir ve veri kalitesi bir işletmenin durumunu belirler. İşletmeler, karar vermek için doğru verileri kullanmaya dikkat etmelidir. Bu noktada, çeşitli şekillerde üretilen ve toplanan veriler işletmeler için oldukça önemlidir. Büyük veriler, tedarik zincirinin analizinde önemli katkılar sunmaktadırlar. Birçok araştırmacı, tedarik zinciri yönetiminde büyük veri ve uygulama fırsatlarını analiz etmeye, perspektif oluşturmaya ve geliştirmeye çalışmaktadır. Bununla birlikte, büyük verileri analiz etmek oldukça zordur. Bu çalışmada, her müşteri yorumu için duygu

skorunun elde edilmesinde SentiStrength kullanılmıştır. Büyük verideki hacim ve çeşitliliği sağlamak için Amazon'daki elektronik ile ilgili müşteri yorumları kullanılmıştır. Her ne kadar nihai sonucu hesaplamak için farklı formlar mevcut olsa da, bu çalışmada ölçek çıktı formu kullanılmıştır. Bu formda sonuç, olumlu ve olumsuz duyguların toplamı olarak verilmiştir. Böylece, pozitif duygu ve negatif duygu skorları toplanmış ve nihai puan belirlenmiştir. Daha sonra, her gün için ortalama duygu skoru hesaplanmıştır. Yorumlar ile birlikte, tedarik zincirindeki müşteri talebini tahmin etmek için geçmiş müşteri talep verileri YSA'ya beslenmiştir. YSA'yı oluşturmak için tf.keras kullanılmıştır. YSA'nın yapısı Şekil 4'te verilmiştir.



Şekil 4. YSA'nın yapısı

Test setinin MSE değeri, her müşteri için Tablo 2'de verilmiştir. MSE değeri Denklem (5)'teki gibi hesaplanmıştır:

$$MSE = \frac{1}{n} \sum_{i=1}^n (e_i)^2 \quad (5)$$

Burada, $e_i = f_i - a_i$ şeklinde hesaplanmakta olup f_i tahmin edilen talebi, a_i ise gerçek talebi belirtmektedir.

YSA çıktısı, ERP'yi çözmek için NSGA-II tabanlı SO'ya beslenir. NSGA-II, seçilen karar değişkenlerine yeni değerler atamak için geliştirilmiştir. Her döngüde, simülasyon çıktısı NSGA-II'ye geri beslenir. Daha sonra bir kez daha NSGA-II, tasarlanan modelin performansını artırmak için daha iyi karar değişkenleri bulmaya çalışır. NSGA-II kullanılarak her bir DM için

yeniden sipariş noktası, maksimum sipariş miktarı seviyesi ve başlangıç stoku belirlenir (Tablo 3). Tasarlanan NSGA-II'de popülasyon büyüklüğü 20, çaprazlama olasılığı 0.8 ve mutasyon olasılığı 0.05'tir. NSGA-II, C# (Visual Studio Community 2017) kullanılarak kodlanmıştır. Simülasyon modeli Simio (Sürüm: 7.121.12363) kullanılarak geliştirilmiştir.

Tablo 2. Her müşteri için MSE değeri

Müşteri	MSE
Müşteri 1	0.01
Müşteri 2	0.05
Müşteri 3	0.11
Müşteri 4	0.05
Müşteri 5	0.03

Tablo 3. Her bir tedarik zinciri üyesi için envanter kontrol parametrelerinin belirlenen optimal değerleri

Tedarik Zinciri Üyesi	Başlangıç Stoku	Yeniden Sipariş Noktası	Maksimum Sipariş Miktarı Seviyesi
DM1	603	403	1425
DM2	658	371	1340
DM3	1230	480	730
DM4	1230	480	699
DM5	1230	498	1164

Tablo 4. Tedarik zinciri üyeleri için maliyet bileşeni analizi

		Elde bulundurma maliyeti	Kullanım başına düşen sipariş maliyeti	Elde bulundurmama maliyeti	Sipariş işleme maliyeti	İşlem maliyeti
DM1	Maliyet (\$)	5545	1283	0	1684	564
	Yüzde değeri (%)	61	14	0	19	6
DM2	Maliyet \$	4818	1510	0	2058	953
	Yüzde değeri (%)	52	16	0	22	10
DM3	Maliyet \$	7937	364	0	495	0
	Yüzde değeri (%)	90	4	0	6	0
DM4	Maliyet \$	5062	976	0	1303	309
	Yüzde değeri (%)	66	13	0	17	4
DM5	Maliyet \$	6381	917	0	1220	430
	Yüzde değeri (%)	71	10	0	14	5

Tasarlanan yöntemde, toplam rotalama maliyeti 90010,83'tür. Ayrıca, diğer maliyet bileşenlerine ait sonuçlar da Tablo 4'te verilmektedir. Her tedarik zinciri üyesi için maliyet (\$) ve yüzde değeri (%) tabloda verilmiştir. Genel olarak, maliyet bileşeninin en yüksek payı elde bulundurma maliyeti, maliyet bileşeninin en küçük payı ise elde bulundurmama maliyetidir. Her bir tedarik zinciri üyesi için miktar tabanlı ve sipariş tabanlı analiz yapabilmek amacıyla tamamen

karşılanmış sipariş miktarı (TKSM) ve tamamen karşılanmış sipariş sayısı (TKSS) hesaplanmıştır. Örneğin, Tablo 5'te DM1 için TKSM, üç ay boyunca toplam karşılanan müşteri sipariş miktarını belirten 2487 birimdir. Ayrıca, DM1 için TKSS, üç ay boyunca toplam karşılanan müşteri siparişi sayısını gösteren 17 sipariştir. Tüm müşteri talepleri tasarlanan yöntemle karşılansa da, karşılanan sipariş miktarı tedarik zinciri üyesine göre değişmektedir (Tablo 5).

Tablo 5. Miktar tabanlı analiz ve sipariş tabanlı analiz

Tedarik zinciri üyesi	TKSS	TKSM
DM1	17	2487
DM2	20	3284
DM3	5	816
DM4	13	1894
DM5	12	2224

5. Sonuçlar

Duygu analizi, işletmelerin tedarik zincirini geliştirmek için geri bildirim almalarını sağlayabilir. Ayrıca, işletmelerin müşteri yorumları yoluyla doğrudan müşterilerle etkileşim kurmaları için önemli fırsatlar sunmaktadır. Müşteri yorumları, hizmetler ve ürünler hakkında birçok bilgi içermektedir. Olumlu yorumlar diğer müşterilerin satın alma istekliliğini etkileyebilir. Diğer yandan, olumsuz yorumların müşteriler üzerinde olumsuz bir etkisi olabilir. Bu çalışmada, ERP'yi çözmek için duygu analizi ve SO içeren yeni bir metodoloji tasarlanmıştır. Tasarlanan metodoloji, işletmelerin tedarik zincirini geliştirmeleri için yeni fırsatlar sunmaktadır. Duygu analizi ve SO'nun entegrasyonu ERP'nin çözümüne yardımcı olur. Bu tür yöntemler, müşteri taleplerini etkili bir şekilde tahmin etmek için kullanılabilir. Müşteri yorumlarının kullanımı tedarik zinciri performansının artırılmasına da katkıda bulunmaktadır. Maliyet bileşeni analizine göre, tedarik zinciri üyeleri için elde bulundurmama maliyeti gözlenmemiştir. Günümüz dünyasında işletmelerin müşteri memnuniyetini artırabilmesi için elde bulundurmama durumunu ele almaları gerekmektedir. Bu çalışmanın sonuçları, tasarlanan metodoloji ile elde bulundurmama maliyetinin azaltılabileceğini göstermiştir. Gelecekteki çalışmalarda, duygu skorunu belirlemek için literatürde sıklıkla kullanılan DVM gibi makine öğrenmesi yöntemi kullanılabilir. Ayrıca, optimize edilmiş YSA kullanılarak sistemin performansı artırılabilir.

Teşekkürler

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) 2211-C Yurt İçi Öncelikli Alanlar Doktora Burs Programı kapsamında desteklenmiştir.

Kaynaklar

Ahn, H.-I. and Spangler, W. S. (2014). Sales prediction with social media analysis. *2014 Annual Service*

Research and Innovation Institute Global Conference (ss. 213–222). <https://doi.org/10.1109/SRII.2014.37>

- Avcı, M. G. and Selim, H. (2017). A multi-objective, simulation-based optimization framework for supply chains with premium freights. *Expert Systems with Applications*, 67, 95–106. <https://doi.org/10.1016/j.eswa.2016.09.034>
- Balaji, S. M. E. (2015). Predicting sentiment analysis from online reviews. *International Research Journal of Engineering and Technology*, 2(9), 528–531.
- Boru, A., Dosdoğru, A. T., Göçken, M. and Erol, R. (2019). A novel hybrid artificial intelligence based methodology for the inventory routing problem. *Symmetry*, 11, 717. <https://doi.org/10.3390/sym11050717>
- Chen, D., Sain S. L. and Guo, K. (2012). Data mining for the online retail industry: A case study of RFM model-based customer segmentation using data mining. *Journal of Database Marketing & Customer Strategy Management*, 19, 197–208. <https://doi.org/10.1057/dbm.2012.17>
- Deb, K., Pratap, A., Agarwal, S. and Meyarivan, T. (2002). A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2), 182–197. <https://doi.org/10.1109/4235.996017>
- Deniz, A. and Kiziloğ, H. E. (2017). Effects of various preprocessing techniques to Turkish text categorization using n-gram features. *2017 International Conference on Computer Science and Engineering* (ss. 655–660). <https://doi.org/10.1109/UBMK.2017.8093491>
- Dey, L., Chakraborty, S., Biswas, A., Bose, B. and Tiwari, S. (2016). Sentiment analysis of review datasets using Naive Bayes and K-NN classifier. *International Journal of Information Engineering and Electronic Business*, 4, 54–62. <https://doi.org/10.5815/ijieeb.2016.04.07>
- Fan, Z.-P. Che, Y.-J. and Chen, Z.-Y. (2017). Product sales forecasting using online reviews and historical sales data: A method combining the Bass model and sentiment analysis. *Journal of Business Research*, 74, 90–100. <https://doi.org/10.1016/j.jbusres.2017.01.010>
- Gaikar, D. and Marakarkandy, B. (2015). Product sales prediction based on sentiment analysis using twitter data. *International Journal of Computer Science and Information Technologies*, 6(3), 2303–2313.
- Gezici, G. and Yanıkoglu B. (2018). Sentiment analysis in Turkish. *Turkish Natural Language*

Processing. Theory and Applications of Natural Language Processing (ss. 255–271). Springer.

- Jadav, B. M. and Vaghela, V. B. (2016). Sentiment analysis using support vector machine based on feature selection and semantic analysis. *International Journal of Computer Applications*, 146(13), 26–30.
- Konak, A., Coit, D. W. and Smith, A. E. (2006). Multi-objective optimization using genetic algorithms: A tutorial. *Reliability Engineering & System Safety*, 91(9), 992–1007. <https://doi.org/10.1016/j.res.2005.11.018>
- Kumar, K. L. S., Desai, J. and Majumdar, J. (2016). Opinion mining and sentiment analysis on online customer review. *2016 IEEE International Conference on Computational Intelligence and Computing Research* (ss. 1–4). Chennai <https://doi.org/10.1109/ICCIC.2016.7919584>
- Lau, R. Y. K., Zhang, W. and Xu, W. (2018). Parallel aspect-oriented sentiment analysis for sales forecasting with big data. *Production and Operations Management*, 27(10), 1775–1794. <https://doi.org/10.1111/poms.12737>
- Ozturk, Z. K., Cicek, Z. İ. E. and Ergül, Z. (2017). Sentiment Analysis: an application to Anadolu University, *Acta Physica Polonica A*, 132(3), 753–755. <https://doi.org/10.12693/APhysPolA.132.753>
- Pai, P.-F. and Liu, C.-H. (2018). Predicting vehicle sales by sentiment analysis of Twitter data and stock market values. *IEEE Access*, 6, 57655–57662. <https://doi.org/10.1109/ACCESS.2018.2873730>
- Popović, D., Vidović, M. and Radivojević, G. (2012). Variable neighborhood search heuristic for the inventory routing problem in fuel delivery. *Expert Systems with Applications*, 39(18), 13390–13398. <https://doi.org/10.1016/j.eswa.2012.05.064>
- Rani, S. and Singh, J. (2017). Sentiment analysis of tweets using support vector machine. *International Journal of Computer Science and Mobile Applications*, 5(10), 83–91.
- Sarkar, D. and Modak, J. M. (2005). Pareto-optimal solutions for multi-objective optimization of fed-batch bioreactors using nondominated sorting genetic algorithm. *Chemical Engineering Science*, 60, 481–492. <https://doi.org/10.1016/j.ces.2004.07.130>
- Schneider, M. J. and Gupta, S. (2016). Forecasting sales of new and existing products using consumer reviews: A random projections approach. *International Journal of Forecasting*, 32(2), 243–256. <https://doi.org/10.1016/j.ijforecast.2015.08.005>
- Swain, A. K. and Cao, R. Q. (2019). Using sentiment analysis to improve supply chain intelligence. *Information Systems Frontiers*, 21(2), 469–484. <https://doi.org/10.1007/s10796-017-9762-2>
- Thelwall, M., Buckley, K. and Paltoglou, G. (2012). Sentiment strength detection for the social Web. *Journal of the American Society for Information Science and Technology*, 63(1), 163–173. <https://doi.org/10.1002/asi.21662>
- Yu, X., Liu, Y., Huang, J. X. and An, A. (2012). Mining online reviews for predicting sales performance: A case study in the movie domain. *IEEE Transactions on Knowledge and Data Engineering*, 24(4), 720–734. <https://doi.org/10.1109/TKDE.2010.269>
- Yusoff, Y., Ngadiman, M. S. and Syntetos, A. M. (2011). Overview of NSGA-II for optimizing machining process parameters. *Procedia Engineering*, 15, 3978–3983. <https://doi.org/10.1016/j.proeng.2011.08.745>