



POLİTEKNİK DERGİSİ

JOURNAL of POLYTECHNIC

ISSN: 1302-0900 (PRINT), ISSN: 2147-9429 (ONLINE)

URL: <http://dergipark.org.tr/politeknik>



Makine öğrenmesi ile kestirimci bakım ve yedek parça yönetimi

Predictive maintenance with machine learning and spare parts management

Yazar(lar) (Author(s)): Olcay Özge Ersöz¹, Metin İfraz², Semra Tebrizcik³, Ali Fırat İnal⁴, Ömer Can Eskicioğlu⁵, Adnan Aktepe⁶, Ahmet Kurşad Türker⁷, Necaattin Barışçı⁸, Tahsin Çetinyokuş⁹, Süleyman Ersöz¹⁰

ORCID¹: 0000-0001-9429-3614
ORCID²: 0000-0001-7161-223X
ORCID³: 0000-0002-2984-7403
ORCID⁴: 0000-0001-7747-0746
ORCID⁵: 0000-0001-5644-2957
ORCID⁶: 0000-0002-3340-244X
ORCID⁷: 0000-0001-6686-9241
ORCID⁸: 0000-0002-8762-5091
ORCID⁹: 0000-0002-9963-5174
ORCID¹⁰: 0000-0002-7534-6837

To cite to this article: Ersöz O. Ö., İfraz M., Tebrizcik S., İnal A. F., Eskicioğlu Ö. C., Aktepe A., Türker A. K., Barışçı N., Çetinyokuş T. ve Ersöz S., “Makine öğrenmesi ile kestirimci bakım ve yedek parça yönetimi”, *Journal of Polytechnic*, *(*) : *, (*).

Bu makaleye şu şekilde atıfta bulunabilirsiniz: Ersöz O. Ö., İfraz M., Tebrizcik S., İnal A. F., Eskicioğlu Ö. C., Aktepe A., Türker A. K., Barışçı N., Çetinyokuş T. ve Ersöz S., “Makine öğrenmesi ile kestirimci bakım ve yedek parça yönetimi”, *Politeknik Dergisi*, *(*) : *, (*).

Erişim linki (To link to this article): <http://dergipark.org.tr/politeknik/archive>

DOI: 10.2339/politeknik.1355228

Makine Öğrenmesi ile Kestirimci Bakım ve Yedek Parça Yönetimi

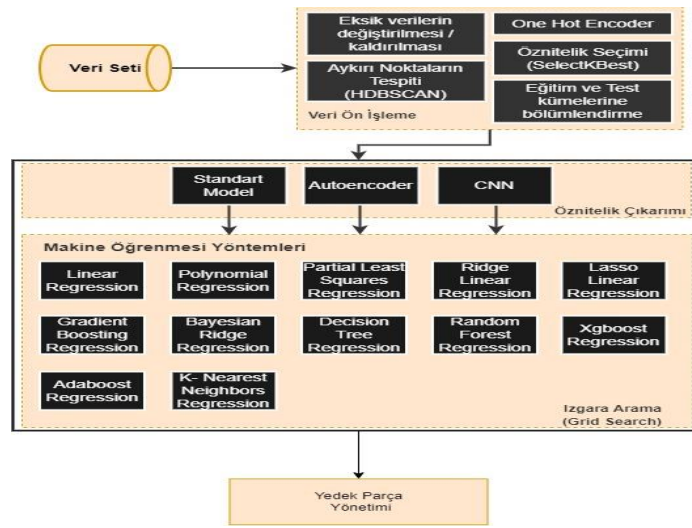
Predictive Maintenance with Machine Learning and Spare Parts Management

Önemli noktalar (Highlights)

- ❖ Makine öğrenmesi ile kestirimci bakım / Predictive maintenance with machine learning
- ❖ Yedek parça yönetimi / Spare parts management
- ❖ Ortak kestirimci bakım ve envanter yönetimi / Joint predictive maintenance and inventory management

Grafik Özet (Graphical Abstract)

Bu çalışmada, arıza verileri ile makine öğrenmesi ve derin öğrenme algoritmaları kullanılarak kestirimci bakım ve yedek parça envanter yönetimi çalışması yürütülmüştür. / In this study, predictive maintenance and spare parts inventory management study was carried out by using machine learning and deep learning algorithms using fault data.



Şekil. Çalışmanın metodolojisi / Figure. The methodology of the study

Amaç (Aim)

Bu çalışma da envanter yönetimi ile kestirimci bakım planlarını entegre eden dinamik bir model tasarlanması amaçlanmıştır. / In this study, it is aimed to design a dynamic model that integrates inventory management and predictive maintenance plans.

Tasarım ve Yöntem (Design & Methodology)

Çalışma da çeşitli makine öğrenmesi ve derin öğrenme algoritmaları kullanılmış ve sonuçları karşılaştırılmıştır. / Various machine learning and deep learning algorithms were used in the study and the results were compared.

Özgünlük (Originality)

Çalışma kestirimci bakım ve yedek parça yönetiminin birlikte ele alınması bakımından literatüre katkı sağlayacaktır. / The study will contribute to the literature in terms of considering predictive maintenance and spare parts management together.

Bulgular (Findings)

Makine öğrenmesi algoritmaları kullanılarak %95 R2 değeri ile yüksek tahmin başarısı gerçekleştirilmiştir. Stok maliyetlerinde ise %2,11 düşüş görülmüştür. / High prediction success was achieved with 95% R2 value with machine learning algorithms. Inventory costs, on the other hand, decreased by 2.11%.

Sonuç (Conclusion)

Kestirimci bakım ve yedek parça yönetiminin ortak yönetilmesinin işletmelere maliyet azalışı gibi çeşitli faydalar sağladığı gözlenmiştir. / It has been observed that joint management of predictive maintenance and spare parts management provides various benefits to businesses such as cost reduction.

Etik Standartların Beyanı (Declaration of Ethical Standards)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler. / The author(s) of this article declare that the materials and methods used in this study do not require ethical committee permission and/or legal-special permission.

Makine Öğrenmesi ile Kestirimci Bakım ve Yedek Parça Yönetimi

Araştırma Makalesi / Research Article

Olca Özge Ersöz^{1*}, Metin İfraz², Semra Tebrizci³, Ali Fırat İnal³, Ömer Can Eskicioğlu⁴, Adnan Aktepe³, Ahmet Kürşad Türker³, Necaattin Barışçır⁵, Tahsin Çetinyokuş², Süleyman Ersöz³

¹ Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK), Ankara, Türkiye

² Gazi Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Ankara, Türkiye.

³ Kırıkkale Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Endüstri Mühendisliği Bölümü, Kırıkkale, Türkiye.

⁴ Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Teknoloji Fakültesi, Yazılım Mühendisliği Bölümü, Burdur, Türkiye.

⁵ Gazi Üniversitesi, Teknoloji Fakültesi, Bilgisayar Mühendisliği Bölümü, Ankara, Türkiye

(Geliş/Received : 04.09.2023 ; Kabul/Accepted : 21.09.2023; Erken Görünüm/Early View : 17.02.2025)

ÖZ

İşletmelerin müşterilerine sundukları hizmetlerin aksamaması için araç, makine vb. kaynaklarını verimli ve etkin kullanması gerekmektedir. İşletme kaynaklarının daima hazır ve çalışır olması için bakım süreci kritik önemdedir. Ayrıca, bakım ve onarım işlemleri için ihtiyaç duyulan yedek parça ile sarf malzemeleri işletme giderlerinde önemli bir pay oluşturmaktadır. Bu nedenle bakım departmanlarında başarılı bir bakım ve envanter yönetimi işletmelere birçok boyuttan kazanç sağlamaktadır. Bu çalışma da bir otobüs filosunda envanter yönetimi ile kestirimci bakım planlarını entegre eden dinamik bir model önerilmiştir. İşletmeye ait veriler üzerinde makine öğrenmesi ve derin öğrenme algoritmaları ile ortalama arıza kilometre tahminleri yapılmıştır. Makine öğrenmesi algoritmaları kullanılarak %95 R2 değeri ile yüksek tahmin başarıları sağlanmış ve kestirimci bakım çalışmasından elde edilen bakım planlarına göre envanter yönetim çalışması yürütülmüştür. Önerilen envanter yönetimi modeli ile yılda ihtiyaç duyulacak yedek parça miktarları, emniyet stokları, yeniden sipariş noktaları ve sipariş miktarları belirlenmiştir. Gerçekleştirilen çalışma, en önemli on adet yedek parça için test edilmiş ve stok maliyetlerinde %2.11 düşüş sağlanmıştır.

Anahtar Kelimeler: Kestirimci Bakım, Envanter Yönetimi, Yapay Zeka, Makine Öğrenmesi, Derin Öğrenme.

Predictive Maintenance with Machine Learning and Spare Parts Management

ABSTRACT

Businesses need to use their resources, such as vehicles, machinery, etc., efficiently and effectively not to interrupt their customers' services. Maintenance is critical for business resources to be always ready and operational. In addition, spare parts and consumables used in maintenance-repair processes have a significant share in operating expenses. For this reason, successful maintenance and inventory management in maintenance departments provides benefits to businesses in many dimensions. This study proposes a dynamic model integrating inventory management and predictive maintenance plans in a bus fleet. Machine learning and deep learning algorithms were used to predict the average mileage of breakdowns on the company's data. By using machine learning algorithms, high prediction success was achieved with 95% R2 value, and the inventory management study was carried out according to the maintenance plans obtained from the predictive maintenance study. With the proposed inventory management model, the amount of spare parts needed per year, safety stocks, reorder points and order quantities were determined. The study was tested for the ten most critical spare parts and achieved a 2.11% reduction in inventory costs.

Keywords: Predictive Maintenance, Inventory Management, Artificial Intelligence, Machine Learning, Deep Learning.

1. GİRİŞ (INTRODUCTION)

İşletmelerde planlı bakım onarım süreçleri periyodik (koruyucu), önleyici (proaktif) ve kestirimci (uyarıcı) olmak üzere üç grup altında değerlendirilmektedir. Periyodik bakım, makine ve ekipmanların kullanım ömrünün arttırılması ve plansız duruşların yani arıza duruşların azaltılması hedefi ile belli periyotlarda gerçekleştirilen bakım-onarım süreçlerini ifade etmektedir. Günlük, haftalık, aylık, yıllık olarak gerçekleştirilebilen periyodik bakım planları makine veya ekipmanın türüne bağlı olarak değişiklikler göstermektedir. Periyodik bakım süreçleri bakım planına

bağlı olarak takip edilen süreçlerdir ve bu alanda çok fazla optimizasyon çalışması yürütülememektedir. Önleyici bakım, arıza oluşmadan önce önlem almayı hedefleyen ve bu doğrultuda gerçekleştirilen proaktif yaklaşımları kapsar. Önleyici bakım, arızanın engellenmesi için AR-GE faaliyetleri ile makine ve teçhizatlara yönelik arıza önleme faaliyetlerinin belirlenmesi ve gerçekleştirilmesini kapsar. Kestirimci bakım, potansiyel görülen arızalar için arıza gerçekleşmeden farklı tahmin metotları kullanılarak bakımın planlanması ve gerçekleştirilmesi sürecini ifade eder. Kestirimci bakımın amacı makine ve ekipmanın

*Sorumlu Yazar (Corresponding Author)
e-posta : oo.ersoz@gmail.com

çalışma durumunu izleyerek, arızasının ne zaman ortaya çıkabileceğini tahmin ederek sıfır arıza üretimi öncülünde arıza süresini ve bakım maliyetini azaltmaktır [1]. Kestirimci bakım süreçleri uyarıcı süreçler olup farklı tahmin metotları ile yürütüldüğü için tahminin doğruluğuna bağlı olarak bakım maliyetini en aza indirmek ve sıfır hatalı hizmete ulaşmak için optimize edilmesi gereken bir süreçtir.

Kestirimci bakım teknolojik ilerlemelerle birlikte farklı parametreleri kullanarak gerçekleştirilen bir bakım yöntemidir. Bu yöntem, titreşim analizi, yağ analizi, termal görüntüleme gibi çeşitli teknikleri içerir ve günümüzde bilgisayar destekli olarak en gelişmiş planlı bakım yaklaşımıdır. Bu yaklaşım, makinelerden periyodik olarak alınan fiziksel parametre ölçümlerinin zaman içindeki değişimlerini izleyerek, makine sağlığı hakkında gelecekteki durum hakkında tahminlerde bulunmayı içerir [2]. Kestirimci bakım ile sistemdeki ekipmanların çalışma durumları izlenir, ekipmanların ne zaman arıza yapacağı tahmin edilir. Elde edilen tahmin değerleri ile arıza öncesinde (arıza yapacağı tarihe olabildiğince yakın) müdahaleler gerçekleştirilerek sıfır arıza ile üretim/hizmet sürdürülmeye çalışılır. Böylece arıza kaynaklı kayıpların ve bakım maliyetlerinin azaltılması sağlanmış olur ve ekipmandan da maksimum sürede faydalanılmış olur.

Bu çalışma; bakım onarım süreçlerinin optimizasyonu için kestirimci bakım süreçlerinin yapay zeka algoritmaları ile bakım periyotları tahminleri üretmeyi ve elde edilen tahmin sonuçlarına bağlı olarak envanter yönetimi yapmayı hedeflemektedir.

Envanter yönetimi, tüketici talebini ve gelir hedeflerini karşılamak için stokta doğru miktarda mal tutarken fazla envanteri engellemeye çalışarak talep ve arzı dengeleyen bir tedarik zinciri yöntemidir. İşletmeler, talep miktarında, tedarik süresinde, hammadde fiyatlarında veya üretim maliyetlerindeki belirsizliklere ek olarak tedarik sürelerindeki değişkenlik, ölçek ekonomisinin avantajlarından yararlanma, talep dalgalanmaları ve üretimde/tedarikte karşılaşılabilecek sorunlar vb. sebeplerle stok tutarlar. Stokların bu avantajlarına rağmen, stok kaleminin maliyeti, stokta tutma, sipariş verme ve teslim süreci ile ilgili maliyetler ve stok eksikliğine bağlı maliyetler gibi çeşitli maliyet unsurları bulunmaktadır. Şirketlerin fazla stok tutma tercihi, envantere yatırılan paranın maliyetini arttıracak, işletmenin esnekliğini azaltacak, değer zincirinde israfa sebep olacaktır. Buna karşın az stok tutma tercihi, sipariş/üretim emri sayısını dolayısıyla sipariş verme/hazırlık süreçlerinin artmasına sebep olacaktır. Ayrıca az stok tercihi, talebin ve tedarik/üretim süresinin belirsiz olduğu şirketlerde müşteri taleplerinin karşılanamamasına neden olabilecektir. Doğru bir envanter yönetimi, bu çelişkili amaçların dengelenmesini sağlamalıdır [3].

Bakım/Onarım yapan işletmelerin yönetmesi gereken binlerce kalem stok vardır.

İşlerin zamanında teslim edilebilmesi ve müşteri taleplerini karşılanabilmesi için bu malzemelerin belirli bir kısmının envantere tutulması gerekmektedir. Ancak, envantere tutulan miktarın gereğinden fazla olması ek maliyetlere yol açabilir. Bu nedenle, müşteri memnuniyetsizliğine yol açmayacak bir miktarın envantere bulundurulmasıyla birlikte, maliyetlerin işletmelerin ekonomik dengesini sarsacak seviyelere ulaşmamasını sağlayacak bir envanter modeli geliştirilmesi önemlidir [4].

Bakım ve envanter yönetimi birbiriyle ilişkili iki süreçtir, ancak literatürde genellikle ayrı ayrı incelenir. Bu süreçlerin ortak yönetimi, toplam bakım ve envanter maliyetini azaltmaktadır [5]. Envanter yönetiminin işletmelerdeki kritik önemi ve yüksek doğruluk ile kestirimci bakım tahminlerinin yapılması işletmeler için önemli bir maliyeti minimize edecektir.

Bu kapsamda gerçekleştirilen çalışmada bir otobüs filosunun (2017-2021) motor arıza verileri incelenmiş ve araçların hangi motor arızasını ortalama kaç km'de bir vereceği tespit edilmeye çalışılmıştır. Bu kapsamda makine öğrenmesi ve derin öğrenme modelleri kullanılarak kestirimci bakım tahminleri gerçekleştirilmiş ve modellere ait sonuçlar kıyaslanmıştır. Elde edilen en yüksek tahmin modeli olan KNN algoritması ile araçlara ait ortalama motor arıza değerleri tespit edilmiş ve elde edilen tahmin değerlerine bağlı olarak bir stok yönetim modeli tasarlanmıştır.

Tasarlanan model ile maliyet minimizasyonuna ek olarak toplu taşıma araçlarında beklenmedik ya da öngörülemeyen kritik arızalar sebebi ile meydana gelebilecek olası büyük kazalar, buna bağlı olarak oluşabilecek can ve mal kayıplarının önlenmesi hedeflenmektedir. Ayrıca toplu taşıma süreçlerinde yaşanan arızalar nedeniyle yaşanabilecek aksaklıklar da müşteri memnuniyeti algısını zedeleyen faktörlerin azaltılması da sağlanacaktır. Yapılan çalışmayla; büyük veri setleri kullanılarak bakım periyotlarının tahminleri yüksek doğrulukla gerçekleştirilmesi, bakım onarım maliyetlerini optimizasyonu ve maliyet minimizasyonu sağlanacaktır. Ayrıca araçların servis planlarının kesintiye uğramaması hizmet kalitesinin artırılmasını sağlayacak istenmeyen ve plansız duruşların önlenerek hizmetin verimli bir şekilde sürdürülebilmesi sağlanabilecektir. Çalışmanın sektörel katkılarına ek olarak bakım onarım süreçlerinde son beş yıldır uygulanmaya başlanan makine öğrenmesi ve derin öğrenme algoritmalarının envanter yönetimi ile bir arada kullanılması da literatüre yeni bakış açısı kazandıracaktır.

Çalışmanın geri kalanı şu şekilde düzenlenmiştir. Bölüm 2'de kestirimci bakım ve yedek parça yönetimini ele alan çalışmalara ilişkin bir literatür taraması sunulmaktadır. Bölüm 3'te uygulamada kullanılacak yöntemler açıklanmaktadır. Bölüm 4'te gerçek bir uygulama ve sonuçları sunulmaktadır. Bölüm 5'te sonuçlar raporlanmakta ve ileride yapılacak çalışmalar tartışılmaktadır.

2. LİTERATÜR TARAMASI (LITERATURE REVIEW)

Yapay zekâ, teknikleri kestirimci bakım çalışmalarında 2000'li yıllardan itibaren kullanılmaya başlanmıştır. Bu alanda yapılan çalışmalarda genellikle derin öğrenme yaklaşımlarından LSTM (Long Short-Term Memory), destek vektör makinaları, yapay sinir ağları vb. tekniklerin kullanıldığı görülmektedir. Keleşoğlu (2015) [6] yılında Konik Dişlilerde Yapay Sinir Ağı (YSA)Yöntemiyle Arıza Teşhisi isimli yüksek lisans tezinde bir deney seti kurulmuş ve belli bir yük altında, ideal yağ seviyesinde belli bir süre sistem çalıştırılarak konik dişliler üzerinde hangi tür arızaların meydana geldiği incelenmiştir. Çalışmada oluşturulan deney seti üzerinde ses ve titreşim verileri girdi olarak kullanılarak dişlilerde meydana gelecek arıza teşhisi geri yayımlı yapay sinir ağları kullanılarak tespit edilmeye çalışılmıştır. Tez çalışması sonucunda, ses verileriyle yapılan sınıflandırma sonuçları ile titreşim verileriyle elde edilen sonuçların performans açısından benzer olduğu gözlemlenmiştir. Sınıflandırma işlemi sonucunda elde edilen eğitim ve test verilerinin yüksek korelasyon değerleri göstermesi, titreşim ve ses verilerinden elde edilen özelliklerin YSA yönteminin döner makinelerde meydana gelen konik dişli arızalarını erken teşhis etme konusunda başarılı bir şekilde kullanılabilceğini işaret etmektedir.

Öztañır (2018) [7] yılında yayınladığı Makine Öğrenmesi Kullanılarak Kestirimci Bakım isimli yüksek lisans tezinde; NASA prognostik veri deposundan (açık veri) alınan Turbofan Jet Motorlarına ait veriler üzerinde LSTM, Regresyon, K-Means, Destek Vektör Makinası ve LSTM Sınıflandırma metotları kullanılmış ve ürün ile ilgili kalan faydalı ömür hesaplanarak sonuçları kıyaslanmıştır. Yurtsever (2020) [8] yılında Makine Öğrenmesi ve Derin Öğrenme Yöntemleri ile Titreşim Analizi Tabanlı Arıza Teşhis ve Kestirimci Bakım Sistem Tasarımı isimli çalışmasında Case Western Reserve Üniversitesine ait rulman veri merkezinden alınmış rulman titreşim verileri kullanılmıştır. Softmax (Ham Veri), K-Means, Destek Vektör Makinaları, Karar Ağaçları, Naif Bayes, Softmax (İstatistikî Analiz Verileri) algoritmaları kullanarak arıza teşhisi yapılmıştır. Elde edilen sonuçlara bağlı olarak daha sonrasında CNC tezgahlarda da aynı algoritmalar kullanılarak algoritmalar arasında veri kıyaslaması yapılmıştır. Igbal vd. (2019) [9] tarafından gerçekleştirilen çalışmada, yüksek hacimli üretim verilerini işleyebilen, hata tespiti ve izolasyonu için derin öğrenmeye dayalı bir yaklaşım sunmaktadır. Önerilen yöntem, çok farklı öznelikte zamansal üretim verilerini yüksek doğrulukla modelleme yeteneğine sahiptir. Sonuç olarak yöntem, erken arıza tespiti, arıza kaynaklarındaki sık değişikliklere kolay uyum ve yeni arıza türlerinin otomatik tanımlanması ile karakterize edilir. Çalışmada önerilen algoritma, minimum insan süreç denetimi gereksinimi ile hata tespiti yapmaya ve buna bağlı olarak önlem almaya imkan sağlamaktadır.

Chen vd. (2019) [10] yılında DNN, BR (Bayesian Regression), K-Means algoritmaları kullanılarak filo yönetiminde arızalar arası süre tahmin edilmeye çalışılmıştır. Tahmin gerçekleştirilirken nümerik, nominal ve coğrafi bilgi sistemi üzerindeki veriler kullanılmaktadır. Tasarlanan model geçmiş dönem bakım verileri ve coğrafi bilgi sisteminden alınan yağış, sıcaklık, buzlanma bilgileri ile eğitilerek tahminler gerçekleştirilmiştir. Chen vd. (2020) [11] yılında yapmış oldukları çalışmalarında bakım-onarım süreçlerinde LSTM, DCNN, RNN, FCNN ve SVM (Support Vector Machine) ile Cox orantılı regresyon analizini kullanarak bir tahmin modeli ortaya koymuşlardır. Yapılan çalışmada bir filo şirketine ait gerçekleştirilmiş nümerik ve nominal veriler kullanılmış ve araç arıza sıklığı belirlenmiştir. Villalobos vd. (2020) [12] yılında gerçekleştirdikleri çalışmada ise fabrikalardaki operatörleri makinelerin çalışmasını engelleyebilecek veya üretim sürecini durdurabilecek durumlar hakkında uyarı yeni bir alarm sistemi tanıtılmaktadır. Sistem, LSTM ve RNN tabanlı gerçekleştirilen çalışmada sensörlerin ölçümüne bağlı olarak arıza tahminleri yapılmış ve ardından, tahmin edilen ölçümlerin bir alarmı tetikleyip tetiklemeyeceğini belirlenmiştir. Çalışmada tasarlanan sistem ile, akıllı üretim senaryolarını uygun kılan bazı özellikler desteklenmektedir.

İncelenen literatürler derin öğrenme algoritmalarının bakım onarım süreçlerinde etkin ve faydalı modeller olduğunu ortaya koymaktadır. Ayrıca yine yapılan literatür araştırmasına bağlı olarak bakım onarım faaliyetlerinde derin öğrenme algoritmalarının son 5-6 yılda popülerliğini artırdığı görülmektedir. Bu durum çalışmanın özgünlüğü açısından da büyük önem teşkil etmektedir. Bakım alanında kestirimci bakım ile ilgili çalışmalar artan bir trend gösterdiği gibi bakım ve envanter yönetimi alanında da birçok çalışma bulunmaktadır.

Zhang vd. (2022) [13] bakım ve yedek parça envanterinin ortak optimizasyonu için yürüttükleri çalışmada durum bazlı bakım ve stok yönetimi için ortak bir optimizasyon modeli geliştirilmiştir. Çalışma kapsamında beklenen maliyet oranına göre bakım yapılıp yapılmayacağına karar verilmektedir. Çalışma sonucunda stok seviyesinin, yeniden sipariş noktasının ve uygulanacak bakım politikalarının ekipmanların güvenilirliğine ciddi etki ettiği görülmüştür. Zhang vd. (2021) [14] çalışmalarında optimal yedek parça değişim aralığı ile envanter sayısını belirlemeyi amaçlamıştır. Bu kapsamda önleyici bakım ile envanter yönetiminin ortak ele alındığı bir çalışma yürütülmüştür. Portal-Garcia vd. (2021) [15] arıza yoğunluğunu azaltmaya odaklanan mükemmel ve kusurlu bir önleyici bakım ve yedek parça envanter yönetim modeli geliştirmişlerdir.

Zhu vd. (2020) [16] çalışmalarında tren ve uçak endüstrisinde bulunan iki şirketin bakım departmanına ait veriler kullanılarak ön talep bilgisi tabanlı talep tahmin modeli kullanılıp envanter optimizasyonu için bir yaklaşım önerilmiştir. Liu vd. (2020) [17] bir araştırma laboratuvarı tesisinde üretilen pompalara ait rastgele

arıza sürelerinin hesaplanmasıyla, rastgele arızaların sayısına bağlı olarak önerilen matematiksel model ile optimum tampon stok ve bakım aralığının elde edilmesi amaçlanmıştır. Yöntem olarak parçacık sürü optimizasyonu kullanılmıştır. Al-Momani vd. (2020) [18] çalışmalarında askeri uçaklar gibi karmaşık bir mühendislik sisteminin bakımı için bir envanter yönetim sisteminin nasıl geliştirilebileceğini açıklanmıştır. Önerilen sistem ile operasyonel durumu ve hazırlık seviyesini mümkün olan en az maliyetle geliştirmek için uçak filosunun servis verilebilirliğini, güvenilirliğini ve hazır olma durumunu iyileştireceği öne sürülmüştür. Önerilen sistem, tedarik zinciri yönetimini iyileştiren yüksek kaliteli raporlar ve stokları minimuma indiren bakım, tedarik zinciri ve lojistik bilgilerinin harmanlanmasına yardımcı olan süreçler sağlamıştır.

Boström ve Lundell (2020) [19] çalışmasında Analitik Hiyerarşi Süreci (AHP) ile yedek parçaları sınıflandırmıştır. Sınıflandırılan parçalar için talep tahmini yapılmıştır. Daha sonra lineer model ile dağıtım optimizasyonu yapılmıştır. Yuvaraj vd. (2020) [20] çalışmalarında Tkinter ve SQLite platformunu kullanarak özelleştirilmiş bir envanter yönetim sistemine doğru aşamalı olarak bir yol oluşturan bir envanter yönetimi uygulaması yapmışlardır. Sistem, İlişkisel Veritabanı Yönetim Sistemi ile arayüzlenen etkili Grafik Kullanıcı Arayüzü için Tkinter ve SQLite entegrasyonunu kullanır. Bu özelleştirilmiş uygulama ile stok miktarı güncellenebilir ve fatura geçmiş yedeklenebilir. Giriş özelliği sayesinde ürünün kim tarafından çekildiği, ne zaman çekildiği gibi dışa dönük bilgiler veri tabanında otomatik olarak saklanmaktadır. Envanter yönetim sisteminin bu dijitalleştirilmesi, esnekliği, güvenilirliği, akıllı depolamayı, kaynak kullanımını, ürün konumuna kolay erişimi ve depo yönetimini arttırmaktadır.

Bilir ve Erbaş (2019) [21] havayolu firmasının bakım organizasyonu için son iki yılda ait verilere dayalı olarak ABC ve XYZ sınıflandırması çalışması yürütmüşlerdir. A sınıfına dahil olan malzemeler için atölye deneyimleri ve geçmiş yıl malzeme kullanım istatistiklerine dayanarak malzeme planlaması yapılmıştır. Bu planlama sonucunda her bir malzeme için yeniden sipariş noktaları ve sipariş miktarları hesaplanmıştır. Ayrıca, firmanın mevcut yıllık bakım çalışmaları ve parça değişim istatistikleri kullanılarak hangi parçaların ne kadar ihtiyaç duyulacağı belirlenmiş ve her bir parça için yeniden sipariş miktarları belirlenmiştir. Bu çalışmanın sonucuna göre, firma acil sipariş verme gereksinimini azaltabilir ve envanter düzeylerinde önemli bir azalma sağlanabilir. Auweraera ve Boute (2019) [22] yedek parçaların talebini tahmin eden bir yöntem önererek, bu tahmin sonuçları ile bir temel stok politikası kullanıp stokların yönetilmesini sağlamak hedeflemişlerdir. Yöntem olarak Syntetos-Boylan ve Basit Üstel düzeltme kullanılmıştır. Önerilen yaklaşımın daha düşük stoklarla daha yüksek hizmet seviyelerine ulaşmada iyileştirme potansiyelinin büyük olduğu belirtilmiştir. Frenk vd. (2019) [23] çalışmalarında servis parçalarının ömür sonu

envanter sorununun ele almışlardır. Keivanpour ve Kadi (2019) [24] dört farklı yedek parça yönetim modelini karşılaştırmışlardır.

Yapılan literatür taraması sonucunda kestirimci bakım ve envanter yönetiminin birlikte ele alınmasının işletmelere birçok yarar sağladığı görülmüştür.

3. YÖNTEM (METHOD)

Bu bölümde kestirimci bakım tahmin yöntemleri ve envanter yönetimi çalışmalarında kullanılan yöntemler açıklanacaktır.

3.1. Makine Öğrenmesi ve Derin Öğrenme Algoritmaları (Machine Learning and Deep Learning Algorithms)

Literatürde makine öğrenmesi ve derin öğrenme ile ilgili birçok tanım bulunmaktadır. Bunlardan bazıları aşağıda sunulmuştur.

“Makine öğrenmesi, soruna ilişkin oluşturulmuş veri kümesindeki sıralı örüntüleri tespit ederek, en akıllıca kararı vermek amacı ile istatistiksel bilgi, mantık ve algoritmik hesaplamayı bütünleşik kullanabilen çözümlenmesi amaç edinilen konuda tasarlanarak eğitilebilen tanımlanmış algoritmaya göre karar vererek soruna ilişkin çözümü çıktı olarak sunan yöntemdir [25].”

“Makine öğrenmesi denetimli, denetimsiz ve yarı denetimli makine öğrenmesi biçimindedir. Denetimli öğrenme sınıflandırma yöntemi ve regresyon yöntemi olarak ikiye ayrılır. Regresyon analiz yöntemi, istenilen en az iki veya daha fazla değişken arasındaki ilişkilerin incelenmesini sağlayan güçlü bir istatistiksel yöntemdir [26]. Bir regresyon gerçekleştirme süreci, hangi faktörlerin en önemli olduğunu, hangi faktörlerin göz ardı edilebileceğini ve bu faktörlerin birbirlerini nasıl etkilediğini güvenle belirlenmesini sağlar [27].”

“Yapay zekânın öğrenme biçimlerinden biri olan makine öğrenmesi, daha sonraları insan beyninde yer alan nöronlara benzer bir şekilde tanımlanarak oluşturulmuş derin öğrenme yapay sinir ağlarının oluşmasına dönüşerek, bugün tanımlanmış bir önsezi ile hareket eden otonom sistemlerin oluşmasını sağlamıştır [28]. Bu teknolojik öğrenme biçimi günümüzde en çok kullanılan sistemleri tanımlamaktadır [29].”

Derin öğrenme algoritmaları da yapay sinir ağı modellerinin geliştirilmesiyle elde edilen yapılardır. Derin öğrenme, bilgisayarların deneyimlerden öğrenmesini ve dünyayı kavramlar hiyerarşisi açısından anlamasını sağlayan makine öğrenmesi olarak tanımlanır [30]. Derin öğrenme algoritmaları farklı mimari altyapılarla farklı sorunlara çözüm üretir. Her problem türü her derin öğrenme mimarisiyle istenilen düzeyde sonuç üretecek şekilde çalışmaz, bu nedenle problem türüne cevap verebilecek mimariler yapılacak işe göre farklılık gösterir.

Literatürde sıklıkla kullanılan derin öğrenme mimarileri LSTM (Uzun Kısa Süreli Bellek), RNN (Yinelemeli Sinir Ağı), CNN (Evrişimli Sinir Ağı), DCNN (Derin

Evrişimli Sinir Ağı) ve FCNN (Tam Evrişimli Sinir Ağı) modelleridir.

Bu çalışmada Linear Regresyon, Random Forest Regresyon, Decision Tree Regresyon, Bayesian Ridge Regresyon, Adaboost Regresyon, KNN Regresyon, Lasso Linear Regresyon, Xgboost Regresyon gibi birçok makine öğrenmesi algoritmaları denenmiş, en iyi sonuç üreten iki algoritma olan Random Forest regresyon ve KNN regresyon modelleri kullanılarak bakım tahminleri gerçekleştirilmiştir. Random Forest regresyon ve KNN regresyon algoritmalarına ek olarak derin öğrenme mimarilerinden CNN modeli ile bütünlük bir yapı oluşturulmuştur. Random Forest regresyon-CNN ve KNN regresyon-CNN modelleri ile tahminler yapılmış ve elde edilen sonuçlar kıyaslanarak en düşük hata ile bakım tahminleri gerçekleştirilmiştir. Gerçekleştirilen tahminlerde performans ölçütü olarak Ortalama Kare Hatası (MSE), Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE), R2 değerleri incelenmiştir.

3.2. Envanter Sınıflandırması ve Yönetimi (Inventory Classification and Management)

Günümüzde işletmelerde binlerce envanter kalemi olabilmektedir. Büyük miktarlardaki envanter kalemleri üzerinde etkili bir kontrole sahip olmak için geleneksel yaklaşım, envanteri farklı sınıflara ayırmaktır. Daha sonra oluşturulan bu farklı sınıflara farklı envanter kontrol politikaları uygulanmaktadır. Özellikle çok çeşitli malzeme gruplarını bünyesinde bulunduran işletmeler için, malzemelerin sınıflandırılması büyük bir önem taşır.

ABC stok sınıflandırma yöntemi, ürünleri değer oranlarına göre değerlendirip sınıflandırarak stok yönetiminde kullanılan bir yaklaşımdır. Bu yöntem, işletmelerin envanterlerindeki ürünleri önem düzeylerine göre gruplamalarına olanak tanır ve bu nedenle stok yönetimi alanında tercih edilmektedir. Bu sınıflandırma sayesinde işletmeler, stoklarının yönetimini daha etkili bir şekilde yapabilir ve kaynaklarını daha verimli bir şekilde kullanabilirler. ABC analizi, Pareto ilkesine dayalı olarak geliştirilmiş yaygın olarak kullanılan bir stok sınıflandırma algoritmasıdır [31]. Bu sınıflandırma sistemi, stok kalemlerinin hem parasal değerini hem de sayılarını dikkate alır. ABC analizinde yapılan sınıflandırmada stoklar 3 sınıfa ayrılmaktadır. Bunlardan A sınıfı stok kalemleri, genellikle toplam stok miktarının %15-20'sini ve toplam stok değerinin %75-80'ini oluştururken, B sınıfı stok kalemleri, toplam stok miktarının %30-40'ını ve toplam stok değerinin %10-15'ini temsil eder. C sınıfı stok kalemleri ise, toplam stok miktarının %40-50'sini ve toplam değerinin %5-10'unu oluşturur.

ABC stok sınıflandırma yönteminde stok kalemlerinin parasal değeri ile sayıları kriter alınarak sınıflandırma yapılmakta olup literatürde farklı kriterleri bir arada kullanarak geliştirilmiş yöntemler de yer almaktadır. Bu çalışmada Aktepe vd. (2018) [32] tarafından geliştirilen FNS algoritması, depo yönetimi için kullanılan bir dizi

kriteri etkili bir şekilde sınıflandırmayı hedeflemektedir. Bu geliştirilen algoritma, her bir stok kalemini FNS algoritmasında tanımlanan gruplara atamayı amaçlar. "F" grubu depo için işlevsel olarak kabul edilebilecek stok kalemlerini içerir. FNS algoritması tarafından geliştirilen bu yöntem, konfigürasyon yönetimini ele alır ve stokları hem değerlerine hem de önem derecelerine göre sınıflandırır.

Ekonomik sipariş miktarı modeli, talep ve tedarik süresinin sabit olduğunu varsayar. Stok seviyesi belirli bir düzeye düştüğünde, yeniden ekonomik sipariş miktarı kadar sipariş verilir ve sipariş verilen bu seviyeye "yeniden sipariş noktası" denir. Ancak gerçek dünyada talep ve tedarik süresi değişebilir. Bu nedenle, stokun hiçbir zaman sifira düşmemesi için bir emniyet stoku belirlenir. Bu emniyet stoku, beklenmeyen talep artışları veya tedarik gecikmeleri gibi değişkenliklere karşı koruma sağlar. Bu durumda emniyet stoku Eşitlik 1'de gösterildiği gibi hesaplanır.

$$\text{Emniyet Stoğu} = Z \sqrt{(\sigma_D)^2 L + D^2 (\sigma_L)^2} \quad (1)$$

Eşitlik 1'de ifade edilen değişkenler;

Z: İstenilen servis derecesi için normal dağılım tablosundan okunan değer

σ_D : Ortalama talebin standart sapması

L: Ortalama tedarik süresi

D: Ortalama talep

σ_L : Ortalama tedarik süresinin standart sapmasıdır.

Emniyet stoku hesaplanırken belirlenmesi gereken değişkenlerden biri hizmet düzeyidir. Hizmet düzeyi, bir tedarik sürecinde stokun sifira düşme olasılığını ifade eder. Örneğin, eğer hizmet düzeyi %99 olarak belirlenirse, bu demek olur ki, talebin %99 olasılıkla stoktan karşılanması ama %1 olasılıkla talebin karşılanamaması beklenir. Hizmet düzeyi seçildikten sonra, normal dağılım tablosundan ilgili hizmet düzeyine karşılık gelen "Z" değeri okunmalıdır. Eşitlik 1'den emniyet stoku hesaplandıktan sonra Eşitlik 2 yardımıyla yeniden sipariş noktası belirlenir.

$$\text{Yeniden Sipariş Noktası} = D * L + \text{Emniyet Stoğu} \quad (2)$$

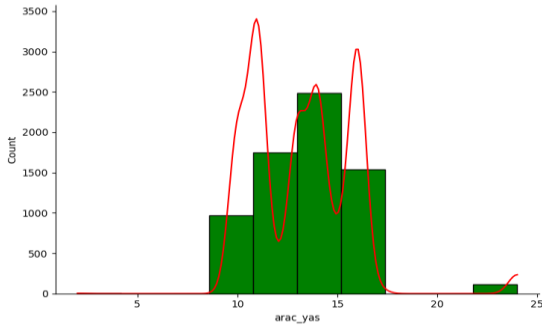
4. MODELİN UYGULANMASI (APPLICATION OF THE MODEL)

Çalışma toplu taşıma araçlarının kestirimci bakım onarım tahminlerinin gerçekleştirilmesi ve buna bağlı olarak stok yönetim stratejilerinin oluşturulmasını kapsamaktadır. Bu doğrultuda, bir otobüs filosuna ait 2017-2021 yıllarına ait bakım onarım verileri kullanılarak derin öğrenme metotları ile tahminler yapılması ilk hedeftir. Bu hedef kapsamında işletmeye ait veriler detaylı olarak incelenmiş ve sistem analizi süreçleri yürütülmüştür. Belirlenen amaç doğrultusunda sistem analizi ile elde edilen bilgiler çerçevesinde Araç Kimlik Bilgisi, Marka, Sorun Kodu, Araç Yaşı, Araç Tipi, Şanzıman Tipi, Yakıt Cinsi olmak üzere altı adet girdi ve araçlara ait Ortalama Arıza Kilometre değerinin çıktısı olarak belirlendiği bir

model kurgusu oluşturulmuştur. Belirlenen girdi ve çıktılar doğrultusunda işletmeden alınan ham veri düzenlenerek derin öğrenme ve makine öğrenmesi süreçlerinin ilk adımı olan normalizasyon ve standardizasyon süreçlerine tabi tutulmuş eksik ve hatalı verilerin modelin başarısını düşürmemesi için düzenlemeler gerçekleştirilmiştir.


Kestirimci bakım tahminlerinin gerçekleştirileceği veri setinin karakteristik özellikleri incelendiğinde;

Girdi veri setinde araç yaş ortalaması 13 olup veriler 10-17 yaş aralığında normal dağılım göstermektedir. Araç yaş dağılım grafiği Şekil 1’ de gösterilmiştir.




Şekil 1. Araç Yaş Dağılımı Grafiği / Figure 1. Vehicle Age Distribution Graph

Filoda üç farklı markaya ait toplamda sekiz model araç mevcut olup araç dağılımları Şekil 2’de gösterilmiştir. Araç filosunda MAN marka araçlar filonun %72 sini oluştururken kalan kısmı Mercedes ve Karsan marka araçlar oluşturmaktadır.



Şekil 2. Araç Filosu Marka Dağılımı / Figure 2. Vehicle Fleet Brand Distribution

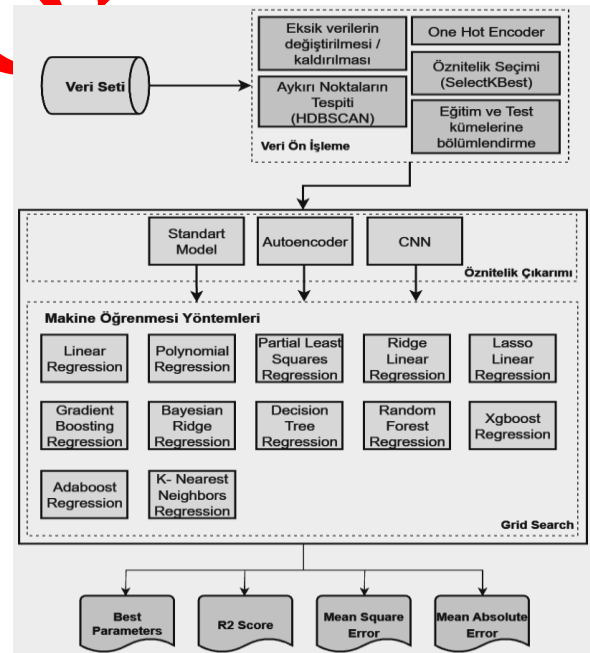
Veri setinde toplam on üç farklı arıza türü mevcuttur ve arıza sayılarına ait grafik Şekil 3’de gösterilmiştir. Grafik incelendiğinde Motor-2, Motor-5 ve Motor-13 arızalarının yoğunluğu dikkat çekmektedir.



Şekil 3. Arıza Türlerine Göre Dağılım / Figure 3. Distribution by Fault Types

Çalışmanın ilk aşamasında makine öğrenmesi algoritmaları kullanılarak regresyon tahminleri gerçekleştirilmiştir. Veri ön işleme aşamasında eksik verilerin değiştirilmesi/kaldırılması, HDBSCAN algoritmasını kullanarak aykırı noktaların tespiti, one hot encoder ile kategorik verilerin sayısallaştırılması, SelectKBest yöntemi kullanarak öznelik seçimi ve eğitim/test olarak veri setimizin bölümlendirilmesi bu aşamada yapılmaktadır. Uygulanan veri ön işleme aşamasından sonra regresyon modellerimize üç farklı senaryoda veriler sunulmaktadır. Ön işleme aşamasından sonra elde edilen veriler herhangi bir öznelik çıkarımı işlemi olmadan, doğrudan regresyon algoritmalarına verilmektedir. Diğer senaryolarımızda ise Evrişimli Sinir Ağları ve AutoEncoder ağı ile öznelik çıkarımı yapıp modele o şekilde verilmektedir.

Çalışmamızda on iki farklı regresyon modeli için ızgara-arama yöntemi kullanılarak hiperparametre optimizasyonu yapılmış olup minimum hata oranı elde edilen parametreler belirlenmiştir. Bu doğrultuda Linear Regresyon, Polinom Regresyon, Ridge Linear Regresyon, Lasso Linear Regresyon, KNN Regresyon, Karar Ağacı Regresyon, Rastgele Orman Regresyon, Xgboost Regresyon, Adaboost Regresyon, Partial Least Square Regresyon, Bayesian Ridge Regresyon ve Gradient Boosting Regresyon modelleri üzerine çalışılmıştır. Çalışmamızın akış diyagramı Şekil 4’te gösterildiği gibidir.



Şekil 4. Akış Diyagramı / Figure 4. Flow Diagram

Herhangi bir öznelik çıkarımı yapılmadan elde edilen sonuçlara göre en düşük hata oranına ve yüksek tahmin başarısına sahip model KNN ve Rastgele Orman Regresyon olarak belirlenmiştir. Bahsedilen tüm regresyon modellerinde elde edilen sonuçlar Tablo1 de verilmektedir.

Tablo 1. Veri Setine Uygulanan Regresyon Modelleri / **Table 1.** Regression Models Applied to the Data Set

Algoritma	MSE	MAE	R2 Skoru	Parametreler
Lineer Regresyon	63624675.4	6607.55	0.077	copy_X : True fit_intercept: False
Polinom Regresyon	63624675.4	6607.55	0.077	linearregression_fit_in tercept: True linearregression_norm alize: False polynomialfeatures_d egree: 1
Ridge Lineer Regresyon	63669698.22	6625.7	0.077	alpha: 10 fit_intercept: True normalize: False solver: cholesky
Lasso Lineer Regresyon	63623060.98	6607.86	0.077	alpha: 0.1
KNN	3756977.41	285.75	0.956	n_neighbors: 11 weights: distance
Karar Ağacı Regresyon	66603559.21	6770.87	0.052	max_depth: 5 max_features: auto max_leaf_nodes: None min_samples_leaf: 1 min_weight_fraction_le af: 0.1 splitter: best
Rastgele Orman Regresyon	6674148.35	456.21	0.903	bootstrap: False max_features: sqrt min_samples_split: 2 n_estimators: 30
Xgboost Regresyon	36159936.85	4731.52	0.414	colsample_bytree: 0.4 gamma: 0.0 learning_rate: 0.15 max_depth: 8 min_child_weight: 1
Adaboost Regresyon	64066052.75	6708.02	0.071	learning_rate: 0.1 n_estimators: 500 random_state: 1
Partial Least Square Regresyon	63730739.51	6629.66	0.076	max_iter: 100 n_components: 3 scale: True
Bayesian Ridge Regresyon	63686133.18	6630.12	0.052	alpha_init: 1.4 lambda_init: 1e-09
Gradient Boosting Regresyon	57576524.1	7587.91	0.18	max_depth: 3 min_samples_leaf: 2 min_weight_fraction_le af: 0.1 max_features: auto max_leaf_nodes: 10

K- En Yakın Komşu (KNN) Regresyon algoritması n_neighbors: 11 ve weights: distance parametreleri Tablo 1'de gösterildiği gibi en düşük hata oranına sahiptir. Rastgele Orman Regresyon algoritması ise bootstrap: False, max_features: sqrt, min_samples_split: 2 ve n_estimators: 30 parametreleri ile düşük hata oranına sahiptir. Diğer algoritmalar bu problemi çözmekte başarısız olduğu görülmektedir. Veri setimizde bulunan araçların yaptığı toplam kilometre yaklaşık olarak 166.575.375 olarak hesaplanmıştır. Alınan sonuçlar kapsamındaki hata oranları toplama bakılarak kabul edilebilir durumda olduğu gözlemlenmiştir. İşletmeye ait veriler kullanılarak en iyi tahmin sonucunu makine öğrenmesi modellerinden KNN regresyon modeli

gerçekleştirmiş olup modele ait R2 değeri 0,95 olarak elde edilmiştir.

Çalışma kapsamında Evrişimli Sinir Ağları ve AutoEncoder ile öz nitelik çıkarımı yapılarak regresyon modelleri tekrar eğitilmiştir. Tablo 2'de görüldüğü üzere öz nitelik çıkarımı ile modelin performansının düştüğü gözlemlenmiştir.

Tablo 2. Makine Öğrenmesi Modelleri ile Hibrit Modellerin Sonuçları / **Table 2.** Results of Machine Learning Models and Hybrid Models

Modeller	En İyi Sonuç Veren Algoritma	En İyi Parametreler	MSE	MAE	R2 Skor
Standart Model	K- En Yakın Komşu Algoritması	n_neighbors : 11 weights : distance	3756977.41	285.75	0.95
AutoEncoder + Regresyon Modeli	K- En Yakın Komşu Algoritması	n_neighbors : 11 weights : distance	5826647.89	482.22	0.91
Evrişimli Sinir Ağları + Regresyon Modeli	K- En Yakın Komşu Algoritması	n_neighbors : 11 weights : distance	9313683.41	655.64	0.87

Çalışılan hibrit tahmin modellerinde CNN-KNN, CNN-Random Forest regresyon modelleri birlikte kullanılmış ve modele ait sonuç değerleri Tablo 3'te gösterilmektedir.

Tablo 3. Derin Öğrenme ve Makine Öğrenmesi Modelleri ile Tahmin Sonuçları / **Table 3.** Prediction Results with Deep Learning and Machine Learning Models

Algoritma	CNN – KNN Regresyon	CNN – Random Forest Regresyon
Ortalama Kare Hatası (MSE)	9.313.683,41	11.172.560,95
Kök Ortalama Kare Hatası (RMSE)	3.051,83	3.342,54
Ortalama Mutlak Hata (MAE)	655,64	723,56
R2 Skoru	0,87	0,84
En İyi Parametre Değerleri	n_neighbors: 11 weights: distance	bootstrap: False max_features: auto min_samples_split: 2 n_estimators: 10

Kullanılan derin öğrenme ve makine öğrenmesi modellerine ait sonuçlar incelendiğinde CNN ve KNN modelinin hibrit olarak kullanıldığı tahmine ait R2 değeri 0,87 olarak belirlenmiştir. Değerlendirmeler sonucunda veri setine uygun olarak en iyi tahmin modelinin KNN regresyon modeli olduğu görülmektedir. Bu doğrultuda stok yönetimi modeli için KNN regresyon modeli ile eğitimi tamamlanan ağda, 600 yeni veri ile tahmin yapılmış ve elde edilen sonuçlar ile envanter yönetimi modeline geçiş yapılmıştır.

Çalışmanın ikinci kısmında envanter yönetimi ile kestirimci bakım planlarını entegre eden dinamik bir model önerilmektedir. Geçmiş yıllara ait parça değişim oranı ile kestirimci bakım planından faydalanarak envanterlerin yönetilmesi hedeflenmiştir. Kestirimci

bakımdan elde edilen ortalama arıza kilometreleri ve işletmeden elde edilen araçların yılda yaptığı kilometre bilgileri kullanılarak envanter planlaması yapılacak yıl için arıza sayıları hesaplanmıştır. Önerilen envanter yönetimi modeli ile planlanan yılda ihtiyaç duyulacak yedek parça miktarları, emniyet stokları, yeniden sipariş noktaları ve sipariş miktarları belirlenmiştir. Bu bilgiler elde edildikten sonra modelin başarısını test etmek için modelin önerdiği ve işletmede mevcut kullanılan yeniden sipariş noktaları karşılaştırılarak fark maliyet analizleri yürütülmüştür.

Çalışma, envanter sınıflandırmasında en önemli sınıf olarak belirlenen “F” sınıfına ait yedek parçalar için yürütülmüştür (Aktepe vd., 2018). Kestirimci bakım paketinde elde edilen veriler ile de “F” sınıfına ait yedek parçaların kullanılacağı arıza sayıları belirlenerek girdi olarak alınmıştır. FNS analizinde “F” sınıfı olarak belirlenen on adet yedek parça için arıza bakım sırasında değişim oranı ve değişkenliği, geçmiş üç yıldaki arıza bakımlar incelenerek belirlenmiştir. Belirlenen yedek parçaların hangi arızada kullanıldığı ve ilgili arızada kaç adet kullanıldığı belirlenmiştir. Belirlenen yedek parçaların kullanıldığı arıza bakımların son üç yılda kaç adet ve hangi tarihlerde olduğu bakım onarım yönetim sisteminden elde edilmiştir. Gerçekleşen arıza sayıları kullanılarak elde edilen beklenen toplam yedek parça kullanım miktarları ile fiili olarak kullanılan toplam yedek parça miktarı oranlanarak belirlenen parçalar için değişim oranları hesaplanmıştır. Değişim oranlarının aylık bazda çok sapma göstereceği düşünülerek yıllık bazda hesaplanmıştır. Değişim oranı bilgileri, emniyet stoku, yeniden sipariş noktası ve yıllık ihtiyaç hesaplanırken kullanılacaktır. Parçaların üç yıllık değişim oranları Tablo 4’te gösterildiği gibidir.

Tablo 4. Parça Değişim Oranları / **Table 4.** Part Change Rates

Sıra No	Parça No	Arıza başına kullanım adedi	2018 yılında kaç adet kullanıldığı	2018 yılında parçanın kullanılacağı arıza sayısı	2018 yılında beklenen kullanım adedi	2018 yılı Değişim Oranı (%)	2019 yılında kaç adet kullanıldığı	2019 yılında parçanın kullanılacağı arıza sayısı	2019 yılında beklenen kullanım adedi	2019 yılı Değişim Oranı (%)	2020 yılında kaç adet kullanıldığı	2020 yılında parçanın kullanılacağı arıza sayısı	2020 yılında beklenen kullanım adedi	2020 yılı Değişim Oranı (%)
1	150.13.03.07.06.06.25	4	48	549	2196	22,2	1043	588	2352	44,3	600	400	1600	37,5
2	150.13.03.07.06.06.26	4	517	540	1098	47,1	1031	588	1176	87,7	350	400	800	43,8
3	150.13.03.07.06.34.83	1	202	1041	1041	19,4	184	698	698	26,4	125	950	950	13,2
4	150.13.03.07.06.34.65	10	1036	1041	10410	25,5	2532	698	6980	36,3	2000	950	9500	21,1
5	150.13.03.07.06.35.01.17	5	130	549	2745	4,7	171	588	2940	5,8	180	400	2000	9,0
6	150.13.03.07.06.34.70	1	17	1041	1041	1,6	35	698	698	5,0	55	950	950	5,8
7	150.13.03.07.06.22.69	10	18	1041	10410	0,2	1564	698	6980	22,4	500	950	9500	5,3
8	150.13.03.07.06.34.63	2	27	337	674	4,0	137	263	526	26,0	120	425	850	14,1
9	150.13.03.07.06.10.29	1	141	1041	1041	13,5	111	698	698	15,9	100	950	950	10,5
10	150.13.03.07.06.01.55	1	110	337	337	32,6	20	217	217	9,2	60	800	800	7,5

Parçaların üç yıllık değişim oranlarının gösterildiği Tablo 4’te ikinci sütunda parça numarası bulunmaktadır. Üçüncü sütunda ilgili parçanın bir arızada kaç adet kullanıldığı yer almaktadır. Dördüncü sütunda, belirtilen yılda parçadan toplam kaç adet kullanıldığı bulunur.

Beşinci sütunda belirtilen yılda ilgili parçanın kullanılacağı arızaların toplam sayısını ifade eder. Altıncı sütunda arıza başı adet ile parçanın kullanılacağı toplam arıza sayısı sütunu çarpılarak, tüm parçaların yenilenmesi durumunda beklenen toplam kullanım adedi hesaplanır. Böylece toplam kullanılan miktar, beklenen toplam kullanım miktarına bölünerek her yıl için değişim oranı hesaplanmıştır.

Tablo 4’te birinci sıradaki “150.13.03.07.06.06.25” numaralı parça kullanılacağı arızalarda dört adet tüketileceği arıza başı adet sütununda yer almaktadır. 2018 yılında parçadan toplam 487 tane kullanılmıştır. Bu zaman periyodunda parçanın kullanılacağı 549 adet arıza meydana gelmiştir. Arıza başı adet sütunu ile 2018 yılı parçanın kullanılacağı arıza sayısı sütünü çarpılarak, 2018 yılı beklenen toplam kullanım adedi bulunmuştur. Eğer tüm arızalarda yenisi kullanılacak olsaydı 2196 adet parça kullanılması gerekirdi. Toplam kullanılan miktar, beklenen toplam kullanım miktarına oranlandığında 2018 yılı değişim oranı yüzde olarak bulunur. İlgili parça için 2018 yılı değişim oranı %22,2’dir. Bu orandan anlaşıldığı üzere her arızada bu parça değiştirilmemiştir. Aynı hesaplamalar bu parçaların diğer iki yılı için yapılarak değişim oranları hesaplanmıştır.

Bir sonraki adımda, değişim oranlarının ortalaması ve standart sapmaları bulunmuştur. Bu bilgiler emniyet stoku, yeniden sipariş noktası ve yıllık ihtiyaç hesaplanırken kullanılmaktadır. Parça bazında değişim oranları ve standart sapmaları Tablo 5’te gösterilmiştir.

Tablo 5. Değişim Oranları Ortalaması ve Standart Sapması / **Table 5.** Average of Change Rates and Standard Deviation

Sıra No	Parça No	2018 yılı değişim oranı (%)	2019 yılı değişim oranı (%)	2020 yılı değişim oranı (%)	2018-2020 arası ortalama değişim oranı (%)	Standart sapma (%)
1	150.13.03.07.06.06.25	22,2	44,3	37,5	34,7	11,4
2	150.13.03.07.06.06.26	47,1	87,7	43,8	59,5	24,5
3	150.13.03.07.06.34.83	19,4	26,4	13,2	19,6	6,6
4	150.13.03.07.06.34.65	25,5	36,3	21,1	27,6	7,8
5	150.13.03.07.06.35.01.17	4,7	5,8	9,0	6,5	2,2
6	150.13.03.07.06.34.70	1,6	5,0	5,8	4,1	2,2
7	150.13.03.07.06.22.69	0,2	22,4	5,3	9,3	11,6
8	150.13.03.07.06.34.63	4,0	26,0	14,1	14,7	11,0
9	150.13.03.07.06.10.29	13,5	15,9	10,5	13,3	2,7
10	150.13.03.07.06.01.55	32,6	9,2	7,5	16,5	14,0

Değişim oranlarının ortalamalarının gösterildiği Tablo 5’te birinci sıradaki “150.13.03.07.06.06.25” numaralı parçanın değişim oranları yıllara göre değişkenlik göstermektedir. Parçanın 2018 yılı değişim oranı %22,2 iken, 2019 yılı değişim oranı %44,3 ve 2020 yılı değişim oranı %37,5’dur. Bu durumda ortalama değişim oranı %34,7 ve standart sapma %11,4 olarak hesaplanmıştır.

Emniyet stoku ve yeniden sipariş noktası hesaplanırken eşitlik 1'den yararlanılmıştır. Emniyet stoku hesaplanırken aşağıdaki Eşitlik 1'de belirtilen değişkenler belirlenmiştir. "F" sınıfına giren yedek parçaların istenilen servis düzeyi %95 olarak belirlenmiştir. Ortalama talep, 2021 yılı kestirimci bakım planından faydalanılarak hesaplanmıştır. 2021 yılına ait kestirimci bakım planı ile hangi arızadan kaç adet olacağı bilgisi elde edilerek kullanılmıştır. Arıza sayıları kestirimci bakımdan gelen km bilgileri ve araçların gerçekleştirdikleri yıllık ortalama kilometre verileri kullanılarak hesaplanmıştır. Ortalama talebin standart sapması değeri için Tablo 5'teki değişim oranlarının standart sapmaları kullanılmaktadır. Tedarik sürelerindeki sapmalar ihmal edilebilir düzeyde olduğu varsayıldığı için, emniyet stoku hesaplanırken sadece parça değişim oranlarındaki sapmalar göz önünde bulundurulacaktır. Tedarik süreleri 12 aylık periyot için gerçekleştirilmiştir. Örneğin; tedarik süresi 3 ay olan bir parçanın tedarik süresi 0,25 olarak alınmıştır. Yeniden Sipariş Noktası Eşitlik 2 kullanılarak hesaplanmıştır.

Yedek parçalar için hesaplanan emniyet stokları ve yeniden sipariş noktaları Tablo 6'da gösterilmiştir. İkinci sütunda parça numarası bulunmaktadır. Üçüncü sütunda bir parçadan arıza olması durumunda kaç adet kullanılacağı belirtilmiştir. Dördüncü sütun planlaması yapılan yılda parçanın değişebileceği arızaların tahmini sayısını ifade eder. Beşinci sütun geçmiş yılların verisi ile hesaplanan ortalama değişim oranını ifade etmektedir. Belirtilen üç sütunun çarpımı ile "2021 Kullanım" olarak gösterilen altıncı sütun hesaplanmıştır. Hesaplanan değer dörde bölünerek periyotta ki ortalama kullanım miktarı bulunmuştur. 2021 Kullanım değerlerinin dörde bölünmesinin nedeni işletmenin "F" sınıftaki parçalar için üçer aylık periyotlarla planlama yapmasıdır.

İlgili parçalar için tedarik süreleri 12 aylık bazda hesaplanarak dokuzuncu sütunda gösterilmiştir. Örneğin; birinci sıradaki parçanın tedarik süresi 4 ay olup 12 ay baz alındığında tedarik süresi 0,333 (4/12)'dür. Periyottaki ortalama kullanım ve tedarik süreleri çarpılarak ve emniyet stoku ile toplanarak yeniden sipariş noktaları tüm parçalar için bulunmuştur. Parça miktarları tamsayı değerler olması gerektiği için yeniden sipariş noktaları bir üst tamsayıya yuvarlanmıştır. Tablo 6'da birinci sıradaki "150.13.03.07.06.06.25" numaralı parçasının, arıza olduğunda dört adet kullanılacağını ifade etmektedir. 2021 yılında bu parçanın kullanılacağı arıza sayısı 408 olarak tahmin edilmiştir. Değişim oranı parça için son üç yıllık verilerden faydalanılarak %34,7 olarak hesaplanmıştır. Üç sayı çarpıldığında 2021 yılında 566 adet kullanılacağı bulunmuştur. Periyot başına ortalama kullanım, 2021 yılı kullanım dörde bölünerek 141 adet olarak bulunmuştur.

İlgili parça için tedarik süresi dört ay olup 12 ay bazlı yazıldığında 0,333 değeri elde edilir. Emniyet stoku, ortalama talebin standart sapması, Z değeri 1,645 ve tedarik süresi 0,333'nin karekökünün çarpımı ile bulunmuştur.

Tablo 6. Emniyet Stoku ve Yeniden Sipariş Noktaları / **Table 6.** Safety Stock and Reorder Points

Sıra No	Parça No	Arıza başına kullanım adedi	2021 yılında parçanın kullanılacağı tahmini arıza	Değişim Oranı (%)	2021 Kullanım	Periyottaki ortalama kullanım	Ortalama talebin standart sapması (%)	Tedarik Süresi (Z, AY)	Z (%95 güven seviyesi)	Emniyet Stoku	Yeniden Sipariş Noktası
1	150.13.03.07.06.06.25	4	408	34,7	566	141	11,4	0,333	1,645	11,00	59
2	150.13.03.07.06.06.26	2	410	59,5	488	122	24,5	0,333	1,645	24,00	65
3	150.13.03.07.06.34.83	1	643	19,6	126	32	6,6	0,333	1,645	7,00	18
4	150.13.03.07.06.34.65	10	646	27,6	1784	446	7,8	0,333	1,645	8,00	157
5	150.13.03.07.06.35.01.17	5	426	6,5	139	35	2,2	0,667	1,645	3,00	27
6	150.13.03.07.06.34.70	1	668	4,1	26	7	2,2	0,667	1,645	2,00	4
7	150.13.03.07.06.22.69	10	644	9,3	598	149	11,6	0,667	1,645	16,00	116
8	150.13.03.07.06.34.63	2	448	19,4	102	26	11,0	0,167	1,645	8,00	13
9	150.13.03.07.06.10.29	1	637	13,3	88	22	2,7	0,333	1,645	3,00	11
10	150.13.03.07.06.01.55	1	361	16,5	63	16	14,0	0,167	1,645	10,00	13

Periyottaki ortalama kullanım ile tedarik süresi çarpılıp bulunan miktara emniyet stoku dahil edildiğinde ve elde edilen değer bir üst tamsayıya yuvarlanarak birinci parça için yeniden sipariş noktası 59 olarak bulunmuştur. Yani ilgili parçanın depodaki seviyesi 59'a indiğinde yeniden sipariş yapılması gerekmektedir.

2021 yılı için tahmini bakım planı ve geçmiş üç yılın verileri temel alınarak parçaların ne kadar bakıma ihtiyaç duyacağını önceden tahmin edebilir. 2021 yılında meydana gelecek arıza sayısı, bir parçanın arıza başına kullanım adedi ve değişim oranları verisi bulunmaktadır. Bu verilerden faydalanılarak ilgili parçalardan 2021 yılında ne kadar kullanılacağı Tablo 6'da hesaplanmıştır. Bu kullanım miktarlarına emniyet stoku da ilave edildiğinde 2021 yılı ihtiyaç miktarı belirlenir. Ayrıca, tüm parçalar için sipariş miktarları hesaplanmıştır. Yedek parçaların emniyet stokları, sipariş miktarı ve 2021 yılı ihtiyaç duyulacak miktarlar hesaplanarak Tablo 7'de gösterilmiştir.

Ekonomik sipariş miktarı modelinde, parçaların elde bulundurma maliyeti ile sipariş verme maliyetlerinin eşit olduğu yer optimum sipariş sayısı olarak kabul edilir. Ancak, çalışma yapılan sektörde sipariş maliyetleri, elde bulundurma maliyetlerine göre göreceli olarak düşüktür. Çünkü parçaları tedarik eden işletmelerin sayısı sınırlıdır ve işletmenin olduğu bölgeye düzenli kargo operasyonları yapılmaktadır. İşletmeye ekonomik sipariş miktarı modeli uygulanırsa, düşük miktarlarda sık sık sipariş verilmesi gerekecektir, bu durum yıllık sipariş sayısını artırırken iş takibini de zorlaştıracaktır. Ayrıca, parçaların tedarik edildiği işletmelerin sayısının az olması, parça siparişlerinin birleştirilerek toplu halde verilmesine imkan tanır. (Bilir ve Erbaş, 2019). Bu sebeplerden dolayı yılda yapılan sipariş sayısı ortalama dört olarak varsayılmıştır. Böylece 2021 ihtiyacı için dört

kez sipariş edileceği düşünülerek parçalar için sipariş miktarları hesaplanmıştır.

Tablo 7. 2021 Yılı Parçalara Göre İhtiyaç Miktarları / **Table 7.** Required Quantities by Parts for the Year 2021

Sıra No	Parça No	Arıza başına kullanımı adedi	2021 yılında parçanın kullanılacağı tahmini arıza sayısı	Değişim Oranı (%)	2021 Kullanım	Periyottaki ortalama kullanımı	Sipariş Miktarı	Emniyet Stoku	2021 İhtiyaç
1	150.13.03.07.06.06.25	4	408	34,7	566	141,5	142	11,00	577
2	150.13.03.07.06.06.26	2	410	59,5	488	122,0	122	24,00	512
3	150.13.03.07.06.34.83	1	643	19,6	126	31,6	32	7,00	134
4	150.13.03.07.06.34.65	10	646	27,6	1784	446,0	446	8,00	1792
5	150.13.03.07.06.35.01.17	5	426	6,5	139	34,7	35	3,00	142
6	150.13.03.07.06.34.70	1	668	4,1	28	6,9	7	2,00	30
7	150.13.03.07.06.22.69	10	644	9,3	598	149,4	150	16,00	614
8	150.13.03.07.06.34.63	2	348	14,7	102	25,6	26	8,00	111
9	150.13.03.07.06.10.29	1	697	13,3	85	21,2	22	3,00	88
10	150.13.03.07.06.01.55	1	382	16,5	63	15,7	16	10,00	73

Parça ihtiyaç miktarlarının gösterildiği Tablo 7’de birinci sıradaki “150.13.03.07.06.06.25” numaralı parçadan, arıza başına dört adet kullanıldığı ifade edilmiştir. 2021 yılında bu parçanın kullanılabilmesi tahmini arıza sayısı 408’dir. Değişim oranı parça için %34,7 olarak bulunmuştur. 2021 yılında 566 adet kullanılacağı hesaplanmıştır. Periyot başına ortalama kullanım 2021 kullanım dörde bölünerek 141,5 olarak hesaplanmıştır. Böylece sipariş miktarı 141,5 değeri bir üst tamsayıya yuvarlanarak 142 adet olarak belirlenmiştir. İlgili parçanın envanterdeki seviyesi Tablo 6’da görüldüğü gibi yeniden sipariş noktası olan 59 adetini altına düşüğünde otomatik olarak 142 adetlik sipariş açılmaktadır. 2021 yılı ihtiyacı belirlenirken, 2021 yılı kullanım sayısı ve emniyet stoku toplanarak bir üst tamsayıya yuvarlanmıştır. Parça için 2021 ihtiyacı 577 olarak bulunmuştur.

Çalışma yapılan bakım onarım işletmesinde geçmiş istatistikler ve tecrübeler baz alınarak yeniden sipariş noktaları ve sipariş miktarları tanımlanmıştır. Tablo 8’de tanımlı ve hesaplanan yeniden sipariş noktaları karşılaştırılmış ve farklar tabloda gösterilmiştir. Yapılan karşılaştırmaya göre, on adet parçadan yedi tanesinde hesaplanana göre daha yüksek bir yeniden sipariş noktası belirlendiği tespit edilmiştir. Yani, yedi parçada fazladan stok tutulduğu gözlenmiştir. Üç parçada hesaplanan yeniden sipariş noktası tanımlı sipariş noktasından fazladır. Tüm parçalar için 2021 ihtiyaç sayısı ve birim maliyetleri çarpılarak parçaların yıllık maliyetleri hesaplanmıştır. Ayrıca, sipariş edilen parçaların depoda olmaması nedeniyle bakımı yapılan araçların planlanan zamana yetiştirilmesi için sipariş hızlandırma maliyetleri bulunmaktadır. Çalışmada tüm parçalara %6’lık hızlandırma maliyeti uygulanmıştır.

Tablo 8’de fark maliyetlerini hesaplamak için tanımlı yeniden sipariş noktası, birim maliyet ve hızlandırma maliyeti ile çarpılarak, bu rakam hesaplanan yeniden sipariş noktası ile birim maliyetin çarpımından çıkarılmıştır. Eğer çıkan sonuç negatifse kazançta

olduğumuz ilgili parça için stok maliyetlerinde düşüş olduğunu göstermektedir. Çıkan sonuç pozitifse zararda olduğumuz stok maliyetlerinde artış olduğunu göstermektedir.

Tablo 8. Yeniden Sipariş Noktalarının Karşılaştırılması ve Fark Analizleri / **Table 8.** Comparison of Reorder Points and Difference Analyses

Sıra No	Parça No	Yeniden Sipariş Noktası (Hesaplanan)	Yeniden Sipariş Noktası (Tanımlı)	Fark (Adet)	Birim Maliyet (TL)	Hızlandırma Maliyeti (% 6)	Fark Maliyeti (TL)
1	150.13.03.07.06.06.25	59	100	-41	900	1,06	-42300
2	150.13.03.07.06.06.26	65	75	-10	500	1,06	-13485
3	150.13.03.07.06.34.83	18	30	-12	1900	1,06	-26220
4	150.13.03.07.06.34.65	157	150	7	450	1,06	-900
5	150.13.03.07.06.35.01.17	27	30	-3	1700	1,06	-5280
6	150.13.03.07.06.34.70	4	5	-1	1200	1,06	-1560
7	150.13.03.07.06.22.69	116	100	16	2150	1,06	21500
8	150.13.03.07.06.34.63	1	2	-1	800	1,06	-6560
9	150.13.03.07.06.10.29	11	10	1	470	1,06	188
10	150.13.03.07.06.01.55	13	20	-7	500	1,06	-4100

Kazanç/Zarar tablosu olarak da ifade edebileceğimiz Tablo 8’de görüldüğü üzere birinci sıradaki parça için hesaplanan yeniden sipariş noktası 59 iken tanımlı yeniden sipariş noktası ise 100’dür. Tanımlı yeniden sipariş noktası, hesaplanan yeniden sipariş noktasından “41” adet fazladır. Yukarıda belirtilen hesaplamalar yapılarak fark maliyeti -42.300 TL olarak bulunmuştur. Sonucun negatif çıkması bu parça için stok maliyetlerinde düşüş olduğu kazançta olduğumuz anlamına gelmektedir. Yedinci sıradaki parçada farklı bir durum söz konusudur. İlgili parça için hesaplanan yeniden sipariş noktası 116 iken tanımlı yeniden sipariş noktası ise 100’dür. Yani fark adeti 16’dır. İlgili hesaplamalar yapılarak fark maliyeti +21.500 TL olarak hesaplanmıştır. Sonucun pozitif çıkması, hesaplanan yeniden sipariş noktasının ilgili parça için stok maliyetlerinde artışa yol açtığını zararda olduğumuzu ifade etmektedir. Bazı durumlarda tanımlı yeniden sipariş noktası daha düşük olmasına rağmen negatif fark maliyeti görülmemektedir. Bunun sebebi şu anki durumda %6’lık hızlandırılma maliyetinin tüm parçalara uygulanmış olmasıdır.

Emniyet stoku ve yeniden sipariş noktaları hesaplamaları yapılırken hizmet düzeyi %95 olarak alınmıştır. Şu anki durumda işletmede herhangi bir hizmet seviyesi bulunmamaktadır. Bu durum, bazı parçalar için fazladan stok tutulmasına, bazı parçalar için de elde bulundurmamaya neden olmaktadır. Elde bulundurmama durumu hızlandırılmış sipariş maliyetlerine yol açmaktadır. Çıkan sonuca göre toplam fark maliyeti -78.717 TL’dir. Yani bu durumda yıllık 78.717 TL’lik stok maliyeti düşüşü olmuştur. Stok yönetimi yapılan parçaların hesaplanan yeniden sipariş noktası ve emniyet stoku bilgileri sayesinde sağlanan düşüş ile toplam maliyet oranlandığında %2,11’lik bir stok maliyet azalması görülmüştür.

5. SONUÇ (CONCLUSION)

Kestirimci bakım, potansiyel görülen arızalar için arıza gerçekleşmeden farklı tahmin metotları kullanılarak bakımın planlanması ve gerçekleştirilmesi süreci olarak tanımlanır. Kestirimci bakımın amacı makine ve ekipmanın çalışma durumunu izleyerek, arızasının ne zaman ortaya çıkabileceğini tahmin ederek arıza süresini ve bakım maliyetini azaltmaktır. Kestirimci bakım süreçleri uyarıcı süreçler olup farklı tahmin metotları ile yürütüldüğü için tahminin doğruluğuna bağlı olarak bakım maliyetini en aza indirmek ve sıfır hatalı hizmete ulaşmak için optimize edilmesi gereken bir süreçtir.

Envanter yönetimi, tüketici talebini karşılamak için doğru miktar ve zamanda stok bulundurarak talep ve arzı dengelemeye çalışan bir tedarik zinciri yöntemidir. Bakım/Onarım işletmelerinin yönetmesi gereken binlerce kalem stok vardır. İşlerin zamanında teslim edilmesi ve müşteri ihtiyaçlarının karşılanması için bu malzemelerin belirli bir kısmının envantere tutulması gerekir. Ancak envantere tutulan miktarın ihtiyaçtan fazla veya eksik olması istenmez. Ayrıca bakım ve envanter maliyetlerinin işletme giderleri içindeki payının yüksek olması nedeniyle toplam bakım ve envanter maliyetinin düşürülmesi işletmeler için kritik önem teşkil etmektedir.

Çalışmamızda envanter yönetimi ile kestirimci bakım planlarını entegre eden dinamik bir model önerilmiştir. Kestirimci bakım aşamasında makine öğrenmesi ve derin öğrenme yöntemlerinden yararlanılmıştır. Araçların arızalanacağı ortalama kilometreyi doğru tahminde bulunarak envanter ve stok yönetiminin sağlanması hedeflenmiştir. CNN+Regresyon ve AutoEncoder+Regresyon modelleriyle sonuçlar elde edilmiş ve klasik modeller ile karşılaştırma yapılmıştır. Yapılan karşılaştırma kapsamında öznelite çıkarımı yapılmadan doğrudan modele verilen verilerin regresyon yöntemleri tarafından daha az hata oranı ve yüksek tahmin skoru elde ettiği gözlemlenmiştir. Çalışmamızdaki en yüksek tahmin başarımlarını K-En Yakın Komşu algoritması ve Rastgele Orman algoritması kullanarak elde edilmiştir.

Yedek parça yönetimi aşamasında ise geçmiş yılların parça değişim oranı ile kestirimci bakım planından faydalanarak envanterlerin yönetilmesi hedeflenmiştir. Önerilen envanter yönetimi modeli ile planlanan yılda ihtiyaç duyulacak yedek parça miktarları, emniyet stokları, yeniden sipariş noktaları ve sipariş miktarları belirlenmiştir. Bu bilgiler elde edildikten sonra modelin başarısını test etmek için modelin önerdiği ve işletmede mevcut kullanılan yeniden sipariş noktaları karşılaştırılarak fark maliyet analizleri yürütülmüştür. Gerçekleştirilen çalışma kapsamında "F" sınıfına giren on adet yedek parça için test edilmiş ve stok maliyetlerinde %2,11 düşüş sağlanmıştır.

Yapılan kapsamlı analizler ışığında envanter yönetiminin makine öğrenmesi, derin öğrenme ve hibrit modeller ile başarılı tahminler yapıldığı, yapay zeka teknolojilerinin bu alana uygulanabildiği ve ileriki çalışmalar için daha

kompleks modeller üreterek başarılı öngörüler verebileceği sonucuna varılmıştır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı çerçevesinde desteklenmiştir [Proje numarası: MAG-221M438].

Proje iş birliği yaparak çalışmamıza katkı ve veri sağlayan Ankara EGO Genel Müdürlüğüne ve Araç Bakım Onarım Daire Başkanlığına teşekkür ederiz.

ETİK STANDARTLARIN BEYANI (DECLARATION OF ETHICAL STANDARDS)

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI (AUTHORS' CONTRIBUTIONS)

Olca Özgü Ersöz: Deneyle ilgili yapılmış ve sonuçlarını analiz etmiştir.

Metin İfraz: Deneyle ilgili yapılmış ve sonuçlarını analiz etmiştir.

Semra Tebrizcik: Makalenin yazım işlemini gerçekleştirmiştir.

Ali Fırat İnal: Makalenin yazım işlemini gerçekleştirmiştir.

Ömer Can Eskicioğlu: Deneyle ilgili yapılmış ve sonuçlarını analiz etmiştir.

Adnan Aktepe: Deneysel sonuçları kontrol etmiştir.

Ahmet Kürşad Türker: Modelin geliştirilmesine katkı sağlamıştır.

Necaattin Barışçı: Modelin geliştirilmesine katkı sağlamıştır.

Tahsin Çetinyokuş: Modelin geliştirilmesine katkı sağlamıştır.

Süleyman Ersöz: Modelin geliştirilmesine katkı sağlamıştır.

ÇIKAR ÇATIŞMASI (CONFLICT OF INTEREST)

Bu çalışmada herhangi bir çıkar çatışması yoktur.

KAYNAKLAR (REFERENCES)

- [1] Ötleş, S., "Endüstri İçin Kestirimci Bakım", *International Journal of 3D Printing Technologies and Digital Industry*, 3(1): 56-66, (2019).
- [2] Karahan, M.F., "Titreşim analizi ile makinelerde arıza teşhisi", Yüksek Lisans Tezi, *Celal Bayar Üniversitesi, Fen Bilimleri Enstitüsü*, (2005).
- [3] Yaz, G., "Bir firmanın gelecek dönem talep tahmini ve stok yönetimi planlaması", *İstanbul Rumeli Üniversitesi*, (2021).

- [4] Bilir, C. and Erbaş, M.A., “Joint Maintenance and Inventory Optimization: An Application in An Airline Company”, *Business and Management Studies: An International Journal*, 7(2): 814, (2019).
- [5] Moharana, U.C. and Sarmah, S.P., “Joint replenishment of associated spare parts using clustering approach”, *International Journal of Advanced Manufacturing Technology*, 94(5–8): 2535–2549, (2018).
- [6] Keleşoğlu, C., “Konik dişlilerde Yapay Sinir Ağı yöntemiyle arıza teşhisi”, Yüksek Lisans Tezi, *Marmara Üniversitesi, Fen Bilimleri Enstitüsü*, (2015).
- [7] Öztanır, O., “Makine Öğrenmesi Kullanılarak Kestirimci Bakım”, Yüksek Lisans Tezi, *Hacettepe Üniversitesi, Institute of Science*, (2018).
- [8] Yurtsever, M., “Makine Öğrenmesi ve Derin Öğrenme Yöntemleri İle Titreşim Analizi Tabanlı Arıza Teşhis ve Kestirimci Bakım Sistem Tasarımı”, Ph.D. Thesis, *Ege University*, Izmir, Turkey, (2020).
- [9] Iqbal, R., et al., “Fault Detection and Isolation in Industrial Processes Using Deep Learning Approaches”, *IEEE Transactions on Industrial Informatics*, 15(5): 3077–3084, (2019).
- [10] Chen, C., et al., “Automobile Maintenance Prediction Using Deep Learning With GIS Data”, *Procedia CIRP*, 81: 447–452, (2019).
- [11] Chen, C., Liu, Y., Wang, S., Sun, X., Di Cairano-Gilfedder, C., Titmus, S. and Syntetos, A.A., “Predictive Maintenance Using Cox Proportional Hazard Deep Learning”, *Advances in Engineering Informatics*, 44: 101054, (2020).
- [12] Villalobos, K., Johan, S., Arantza, I., “A Flexible Alarm Prediction System For Smart Manufacturing Scenarios Following A Forecaster–Analyzer Approach”, *Journal of Intelligent Manufacturing*, 1–22, (2020).
- [13] Zhang, J., Zhao, X., Song, Y., & Qiu, Q., “Joint optimization of condition-based maintenance and spares inventory for a series–parallel system with two failure modes”, *Computers & Industrial Engineering*, 168: 108094, (2022).
- [14] Zhang, J.X., Du, D.B., Si, X.S., Hu, C.H. and Zhang, H.W., “Joint optimization of preventive maintenance and inventory management for standby systems with hybrid-deteriorating spare parts”, *Reliability Engineering & System Safety*, 214: 107686, (2021).
- [15] Portal-Garcia, M., Vera-Cabello, R., Quiroz, J., Marcelo, G., and Alvarez, J.C., “Integrated Model of Maintenance Management and Inventory System in a Fleet of Trucks”, *10th International Conference on Industrial Technology and Management (ICITM)*, 172–176, IEEE, (2021).
- [16] Zhu, S., van Jaarsveld, W. and Dekker, R., “Spare parts inventory control based on maintenance planning”, *Reliability Engineering & System Safety*, 193: 106600, (2020).
- [17] Liu, Q., Dong, M., Chen, F.F., Liu, W., and Ye, C., “Multi-objective imperfect maintenance optimization for production system with an intermediate buffer”, *Journal of Manufacturing Systems*, 56: 452–462, (2020).
- [18] Al-Momani, H., Al Meanazel, O.T., Kwaldeh, E., Alaween, A., Khasaleh, A., and Qamar, A., “The efficiency of using a tailored inventory management system in the military aviation industry”, *Heliyon*, 6(7): e04424, (2020).
- [19] Boström, E. and Lundell, J., “Availability vs. Cost Efficiency: A Case Study Taking on an Integrated Approach to Spare Part Distribution in the High-Tech Industry”, (2020).
- [20] Yuvaraj, K., Oorappan, G.M., Megavarthini, K.K., Pravin, M.C., Adharsh, R., and Kumaran, M.A., “Design and Development of an Application for Database Maintenance in Inventory Management System Using Tkinter and Sqlite Platform”, *IOP Conference Series: Materials Science and Engineering*, 995(1): 012012, (2020).
- [21] Bilir, C. and Erbaş, M.A., “Bir bakım onarım organizasyonunda entegre stok yönetimi ve bakım planlaması–hava yolu firması uygulaması”, *Business and Management Studies: An International Journal*, (2019).
- [22] Van der Auweraer, S. and Boute, R., “Forecasting spare part demand using service maintenance information”, *International Journal of Production Economics*, 213: 138–149, (2019).
- [23] Frenk, J.B.G., Javadi, S., Pourakbar, M., and Sezer, S.O., “An exact static solution approach for the service parts end-of-life inventory problem”, *European Journal of Operational Research*, 272(2): 496–504, (2019).
- [24] Keivanpour, S. and Kadi, D.A., “The effect of ‘Internet of Things’ on aircraft spare parts inventory management”, *IFAC-PapersOnLine*, 52(13): 2343–2347, (2019).
- [25] Bishop, C.M., “Pattern Recognition and Machine Learning”, *Springer*, (2006).
- [26] Şerifoğlu, M.A., “Atıksu Arıtma Tesislerinde Biyolojik Oksijen İhtiyacının (BOİ5) Kaba Kümeleme ve Makine Öğrenmesi Hibrit Yaklaşımı ile Tahmini”, Yüksek Lisans Tezi, *Sakarya Üniversitesi*, (2021).
- [27] Selvi, E., “Kentsel Atıksu Arıtma Tesisi biyolojik oksijen ihtiyacının (BOİ5) makina öğrenmesi yöntemleri ile tahmin edilmesi”, Yüksek Lisans Tezi, *Sakarya Üniversitesi*, (2019).
- [28] Feng, C., Li, T., Zhu, Z., & Chana, D., “A deep learning-based framework for conducting stealthy attacks in industrial control systems”, *arXiv preprint arXiv:1709.06397*, (2017).
- [29] Pratt, L.Y., “Experiments on the transfer of knowledge between neural networks”, In S. Hanson, G. Drastal, and R. Rivest, editors, *Computational Learning Theory and Natural Learning Systems, Constraints and Prospects*, volume 1, chapter 19, *MIT Press*, (1994).
- [30] Barış, C., Kwang, G.K., “Deep Learning”, Ph.D., Biomedical Engineering Branch, Division of Precision Medicine and Cancer Informatics, *National Cancer Center*, Goyang, Korea, (2016).
- [31] Dursun, E. and Gürgen, E., “Konteyner Terminal Stok Yönetiminde ABC Analizi ve Bulanık Sınıflandırma”, *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 17(46): 563–583, (2020).
- [32] Aktepe, A., Ersöz, S., Türker, A.K., Barışçı, N., Dalgıç, A., “An Inventory Classification Approach Combining Expert Systems, Clustering and Fuzzy Logic with the ABC Method and An Application”, *South African Journal of Industrial Engineering*, 29(1): 49–62, (2018).