



Journal of Turkish Operations Management

Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama

Gözde Nur Calayır^{1*}, Mehmet Kabak²

¹Endüstri Mühendisliği Bölümü, Gazi Üniversitesi, Ankara, Türkiye
e-mail:nurcalayr@gmail.com, ORCID No: <http://orcid.org/0000-0001-9344-701X>

²Endüstri Mühendisliği Bölümü, Gazi Üniversitesi, Ankara, Türkiye
e-mail:mkabak@gazi.edu.tr, ORCID No: <http://orcid.org/0000-0002-8576-5349>

*Sorumlu Yazar

Makale Bilgisi

Makale Geçmişi:

Geliş: 02.04.2021
Revize: 13.05.2021
Kabul: 18.05.2021

Anahtar Kelimeler:

Makine öğrenmesi,
Kestirimci bakım,
Bakım planlaması

Özet

Bakım, her üretim kuruluşunda olması gerekli bir faaliyet olarak kabul edilirken, günümüzde ise ilave olarak şirketin gelir ve giderlerini etkileyen kritik bir işletme fonksiyonu olarak tanımlanmaktadır. Makine öğrenmesi kavramı, makinelerin karşılaştıkları durumlar karşısında kendini eğiterek daha iyi kararlar verebilmesini sağlayan algoritmaların geliştirilmesi olgusudur. 1950 yıllarından itibaren bakım planlaması tahminleme çalışmasında makine öğrenmesi teknikleri kullanılmaktadır. Savunma sanayi firmasında yapılan bu çalışmada makinelerin aniden ve plansız yapılan bakımlardan kaynaklı maliyeti yüksek olan parçaların hurda olması ve sevkiyatlarda meydana gelen gecikmelerden dolayı firmanın müşterilere yüksek miktarda ceza ödemesi problemi ele alınmıştır. Bu çalışmadaki amaç gelişen bilim ve teknoloji kullanılarak, yapılacak olan bakım planlamalarını, arızaları önceden tahmin etmek, üretimde durmayı, maliyet kaybını en aza indirmek veya tamamen engelleyebilmektir. Makine Öğrenmesi tekniklerinden denetimli öğrenme tekniği savunma sanayi firmasındaki en kritik kimyasal boya makinesinde uygulanarak bakım planlaması tahmini çalışması yapılmıştır.

Analysis of machine learning techniques for maintenance and an application

Article Info

Received: 02.04.2021
Revised: 13.05.2021
Accepted: 18.05.2021

Keywords:

Machine learning,
Predictive maintenance,
Maintenance planning

While maintenance is considered as a necessary activity in every production establishment, it is defined as a critical business function that affects the income and expenses of the company today. The concept of machine learning is the phenomenon of developing algorithms that enable machines to make better decisions by educating themselves in the face of the situations they encounter. Machine learning techniques have been used in the maintenance planning estimation study since the 1950s. In this study conducted by a defense industry firm, the problem of the fact that the parts with high costs due to sudden and unplanned maintenance of the machines are scrap and the company pays a high amount of fines to customers due to delays in shipments. The purpose of this study is to predict the maintenance planning and malfunctions to be made by using developing science and technology, to minimize the cost loss and completely prevent stopping in production, in addition, the supervised learning technique, one of the Machine Learning techniques, was applied in the most critical chemical paint machine in the defense industry company, and maintenance planning was estimated.

Abstract

1. Giriş

Endüstriyel işletmelerde makinelerin arızalanması, parçaların kırılması ya da eskimesi, malzemelerin aşınması durumları söz konusudur. Son zamanlarda bu durumdan dolayı bakım planlaması uygulaması kaçınılmaz bir faaliyet olmuştur. Yapılan araştırmalara göre 1950 yıllarından itibaren bakım konusuna verilen önem gittikçe artmıştır. Değişen sanayi koşullarıyla birlikte işletmelerdeki bakım anlayışı da değişmiştir. Bakım, bir makinenin belirli zaman içerisindeki işlevleri yerine getirebilecek şekilde korunması amacıyla yapılan bir faaliyettir. İşletmelerdeki bakım hizmetleri, büyük yatırımlar yapılan makinelerin veya donanımların çalışılabilirliğini korumak, toplam arıza sayısını düşürmek ve arızalardaki maliyetlerini azaltmak için mevcuttur.

Bakım ilk ortaya düzeltici bakım olarak çıkmıştır. Düzeltici bakım arıza meydana geldikten sonra yapılan bakım faaliyetidir. Düzeltici bakım, ekipmana arızadan sonra daha büyük kayıplara yol açılmaması için uygulanmaktadır. Bu bakım türü zamanla yerini planlı bakıma bırakmıştır. Planlı bakım koruyucu bakım ve kestirimci bakım olarak üzere iki çeşittir. Kestirimci bakım ölçümler sonucu arızanın önceden tahmin edildiği, koruyucu bakım ise periyodik olarak yağlama, yenileme işleminin yapıldığı bakım türüdür. Literatür tarandığında, bu konu ile ilgili çeşit genişlikte çalışmalar yapıldığı görülmüştür. Bakım politikaları sistemdeki güvenilirliği ve sağlamlığı en düşük maliyetle sürdürmeyi amaçlar. Bakım, fonksiyonel bir ekipmanın parça değiştirme, tamir yapma, test etme gibi işlevleri yerine getirmesini ve devamlılığını sağlar. Bakım, fonksiyonel bir birimi belli bir durumda tutmayı, ona belirli işlevsel özellikler kazandırmayı amaçlayan bir politikadır (Lyonnet, 1991).

Bakım planlamasında arızanın önceden bilinmesi ve önlem alınması için tahminleme çalışması yapılabilmektedir. 1970'li yıllardan itibaren makine öğrenmesi teknikleri bu konuda kullanılmaktadır. Makine öğrenmesi ilk olarak 1959 yılında bilgisayar biliminin yapay zekâda sayısal öğrenme ve model tanıma çalışmalarından ortaya çıkmıştır. Makine öğrenmesi yöntemi geliştirilmiş verileri öğrenebilen ve bu veriler üzerinden tahmin yapabilen ve algoritmaları araştıran bir sistemdir. Makine öğrenmesi yöntemi ile daha önceden belirlenmiş verileri kullanarak onlardan yeni tahminleme çalışması yapılmaktadır ve bu teknik sanayide planlama faaliyetlerini kolaylaştıran tekniklerden biri olmuştur.

Endüstride yüksek mekanizasyon ve otomasyon, arızalar yüzünden ürünün zamanında teslim edilememesinden kaynaklı ödenen cezaların olmaması, hatalı ürün çıkışı olduğunda zamanında düzeltilmesi, sürekli gereksiz yapılan bakımlardaki masrafları azaltmak gibi temel sebeplerden dolayı bakım planlaması yapılmalıdır. Eğer bakım planlaması yapılmaz ise firma sevkiyat gecikmesinden kaynaklı prestij, yüksek miktarda para ve müşteri kaybına uğramaktadır.

Bu çalışmanın ikinci bölümünde makine öğrenmesi ve bakım planlamasının literatür taraması, üçüncü bölümde makine öğrenmesinin ve bakım planlamasının yöntemleri, dördüncü bölümde bulgular ve beşinci bölümde sonuçlar kısmı ele alınmıştır.

2. Literatür Taraması

Kestirimci bakım, ekipman parametrelerinin durumuna bağlı olarak arıza riskini azaltarak, hizmet ömrünü artırmayı amaçlar (Garcia ve Sanz-Bobi Pico, 2006). Kestirimci bakım yöntemi, tarihsel olarak nesnel olaylardan, meydana gelmektedir. Önceden alanında tecrübeli kişilerin gözlemlerine dayanarak yapılan işlemin, algılayıcılar ile yapılarak uygulanması sağlanmıştır (Hashemian ve Bean, 2011). Son yıllardaki ilerlemeler sayesinde gelişmiş algılayıcıların duyarlılığı insanlardan daha iyi olabilmektedir.

1958 yılında Rosenblatt tarafından makine öğrenmesinin temeli olan algılayıcılar yani Perceptron geliştirilmiştir. Perceptron doğrusal çok boyutlu düzlem ile ayrıştırılan sorunların çözümünde kullanılmaktadır. Makine öğrenmesindeki teknikler, psikologların hayvan ve insan teorilerini hesaplama modeliyle kesin hale getirilmiştir (Nils J. ve Nilsson, 1996). Yapay zeka türlerinden olan makine öğrenmesi, insan beyninin yapısının taklit edildiği bir modeldir. Makineye önce bilgiler öğretilir, sonrasında öğrendiği bilgiler ışığında tahmin yaptırılmaktadır (Nourmohammadzadeh ve Hartman, 2015).

Üretim ve makine öğrenmesi beraber düşünüldüğünde akla ilk gelen çalışma kestirimci bakımdır. Kestirimci bakım anlık verileri inceleyip, bu verilerde bir uyumsuzluk tespit edildiğinde arıza gerçekleşmeden bakım-onarım işleminin gerçekleşmesi mantığına dayanmaktadır. Bir işletmede üretim sistemi büyüdükçe veya üretim miktarı arttıkça bakım faaliyeti önem kazanır. Bu çalışmada kestirimci bakım ve makine öğrenmesi üzerinde durulmuştur.

Literatürde bakım planlaması alanında farklı makine öğrenmesi ve yapay zeka çalışmaları bulunmaktadır. Makine öğrenmesi yöntemlerinin bakım planlamasında uygulanmaya başlanması hayatımızı kolaylaştırmıştır. Literatür incelendiğinde traktör tamir ve bakım tahmininde geri yayılım sinir ağı (Rohani, ve diğ., 2011), rulman

hata teşhisi ve rulman bozulma değerlendirmesi bakımında destek vektör makineleri (Konar ve Chattopadhyay, 2011), makine onarım ve bakım tahmininde geri yayılım sinir ağı yönteminin kullanıldığı görülmektedir. Literatürde makine öğrenmesinin bakım planlamasında kullanıldığı bir diğer çalışma ise derin öğrenme yöntemine dayanmaktadır. Bu konuda yapılan ilk çalışma yüksek hızlı CNC freze makinelerin ürettiği veriler ile yapılan çalışmadır (Tamilselvan ve Wang, 2013). Çalışmada regresyon, destek vektör makineleri, tek katmanlı derin öğrenme yöntemleri kullanılmıştır.

Sriram ve Haghani (2003), uçak bakım planlaması ve tekrar uçuşa verme için bir model oluşturmuştur. Uçak için bakım planlaması tahmini havayolu şirketinin vermek zorunda olduğu en önemli karar problemidir. Sarac, Batta ve Rump (2006), uçak bakım planlamasında çalışmalar yapmışlardır. Günlük uçak bakım planlaması nedeniyle uçakların kalan uçuş sürelerinin dışına çıkılmadan ekipmanların kalan ömürleri çalışması yapılmıştır. Çalışmada uçağın bir sonraki bakımın gerçekleşeceği uçuş saatini maksimumda tutmak amaçlanmaktadır.

Ekici (2012), makine öğrenmesi yöntemlerinden destek vektör makinelerini kullanarak iletim hatlarındaki arıza tahmini yapan ve arıza türünü bulan bir yöntem gerçekleştirmiştir. 1950'li yıllardan itibaren arıza tahmininde makine öğrenmesi ve yapay zeka teknikleri yaygın olarak kullanılmaya başlanmıştır. Aggarwal vd. (1999) denetimli ve denetimsiz makine öğrenmesi teknikleriyle iletim hatlarındaki arıza tahmini ve arıza tipleri sınıflandırması çalışması yapmıştır. Yapılan incelemelerde lineer olmayan regresyon tekniğine sahip yapay sinir ağları yöntemleri kullanılmış olup, global hatayı en aza indirmek amaçlanmıştır.

Literatürdeki bir diğer çalışma ise, Turbofan makinesine bağlı jet motoru algılayıcılarına yapılan kestirimci bakım çalışmasıdır. Bu çalışmada regresyon, sınıflandırma ve derin öğrenme yöntemleri kullanılmıştır (Öztañır, 2018).

Literatürdeki çalışmalar genel olarak tarandığında, bakım alanındaki çalışmaların yapay zeka ile birleştirildiği, bakım planlaması, makinelerdeki arıza tahminleri, makinelerin kalan ömür tahminleri konularının ele alındığı görülmektedir. Kullanılan yöntemler çoğunlukta derin öğrenme, sınıflandırma, karar ağacı yöntemleridir.

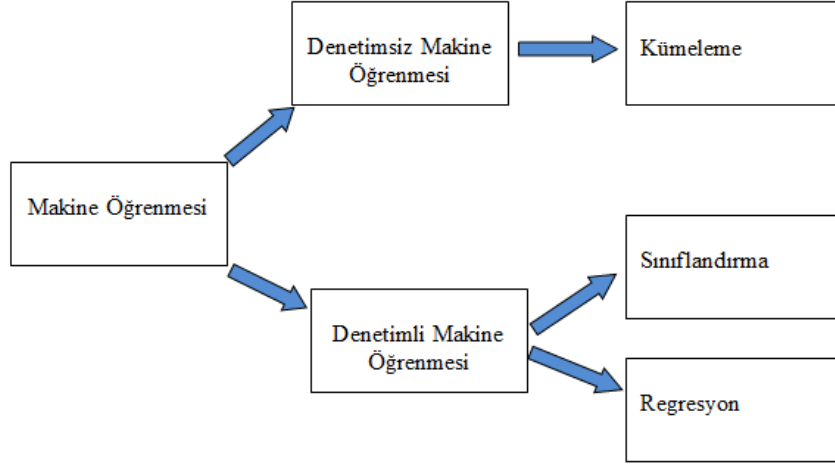
Bu çalışmayı diğerlerinden ayıran nokta ise çalışmada arızadan önce bakım tarihinin belirlenmesi, makine öğrenmesi yöntemlerinden polinomal regresyon ve destek vektör makinesi yöntemlerinin kullanılması ayrıca çalışma sonrasında karekök analizi ile en uygun yöntemin rakamsal olarak ifade edilmesidir. Bu çalışma literatüre, istasyon ya da alandaki bir makinenin daha önceki geçmiş arıza ve algılayıcı verilerinden yararlanarak makinelerdeki aniden meydana gelen duruşları azaltmak yönünde katkı sağlamaktadır.

Bu çalışma ile önerilen yöntemlerle gerçek bakım planlaması çalışmalarının başlatılması için bilimsel bir yaklaşım önerilmiş ve üretim sürekliliğine katkı sağlanmıştır. Sürekli üretim tesisi olan işletmelerde hangi makinenin veya ekipmanın ne zaman bakıma alınması gerektiği bilinmesi gerekmektedir. Bu çalışma sayesinde üretimde meydana gelen aksaklıkların ve duruşların önüne geçilmesinin sağlanması ve sevkiyatlardaki gecikmelerin azaltılması amaçlanmıştır. Çalışma gerçek verilerle yapıldığı için sonrasında başka yazılımlarla kodlama çalışması yapılarak tesis için bakım zamanı geldiğinde alarm etkisi yaratacak bir çalışma olarak katkı sunmaktadır.

3. Yöntemler

3.1 Makine öğrenmesi yöntemleri

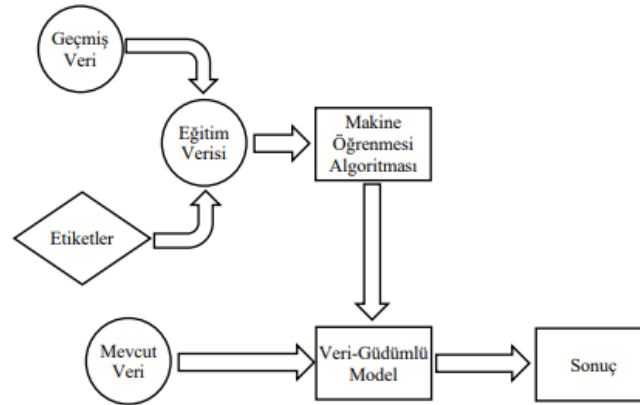
Makine öğrenmesinin tarihi, ilk öğrenen makinelerin kurulması, teori temelleri, sinir ağları olmak üzere öne çıkan üç olayla nitelendirilebilecek farklı dönemler altında gruplandırılabilir (Vapnik, 2000). Veri madenciliğinin gelişmesinde önemli rol oynayan ve sıklıkla kullanılan, makine öğrenmesi yöntemleri; denetimli öğrenme (supervised learning), denetimsiz öğrenme (unsupervised learning) ve yarı-denetimli öğrenme (semi-supervised learning) algoritmalarıdır. Şekil 1'de kategorize edilmiş makine öğrenme yöntemleri gösterilmektedir. Bu çalışmada veri girdi setine sahip olan gerçek veriler kullanılacağından denetimli makine öğrenmesi teknikleri kullanılmıştır.



Şekil 1. Makine Öğrenmesi Yöntemleri

3.1.1 Denetimli makine öğrenmesi önerilen yöntemler

Denetimli makine öğrenmesi, insan müdahalesi olmadan geçmişe dayalı verilerden öğrenebilen algoritmalarıdır. Denetimli öğrenmede bilinen bir girdi veri seti vardır. Denetimli öğrenme hem giriş hem de çıkış parametrelerine sahiptir. Girdi verilerini kullanarak bu veriler üzerinden tahminlemeler yapılmaya başlanır ve algoritma kabul edilen performansa geldiğinde öğrenme durur. Kullanılan veri seti “geçmiş veri” olarak tanımlanmaktadır. Toplanan tüm verilerde ilk olarak tamamı kullanılamayacağından veri temizleme, filtreleme işlemi gerçekleştirilir. Sonrasında veri setleri etiketlenerek makine öğretilmeye başlanır. Elde edilen veri setine eğitim verisi denir. Bu veriler makine öğrenmesi tekniği ile işlenerek, giriş ve çıkış algoritmasına dayanan model oluşturulur. Bahsi geçen iş akışı Şekil 2’de görselleştirilmiştir.



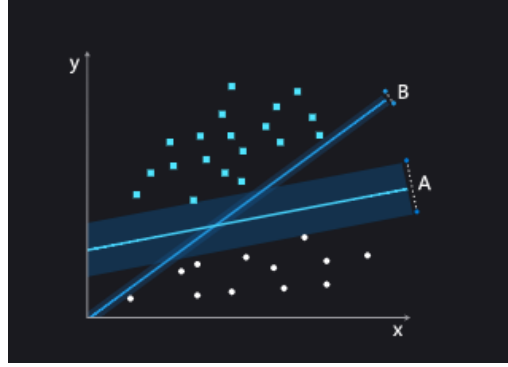
Şekil 2. Denetimli Öğrenme (Jahnke, 2015)

Arıza zamanı tespiti ve bakım planında, denetimli öğrenme en yaygın kullanılan öğrenme tekniğidir. Bu teknik geçmiş verilere dayandığı için birden fazla çalışmaya olanak sağlamaktadır, bununla gerçek dünya sistemi izlenmektedir (Jahnke, 2015).

3.1.1.1 Destek vektör makinesi

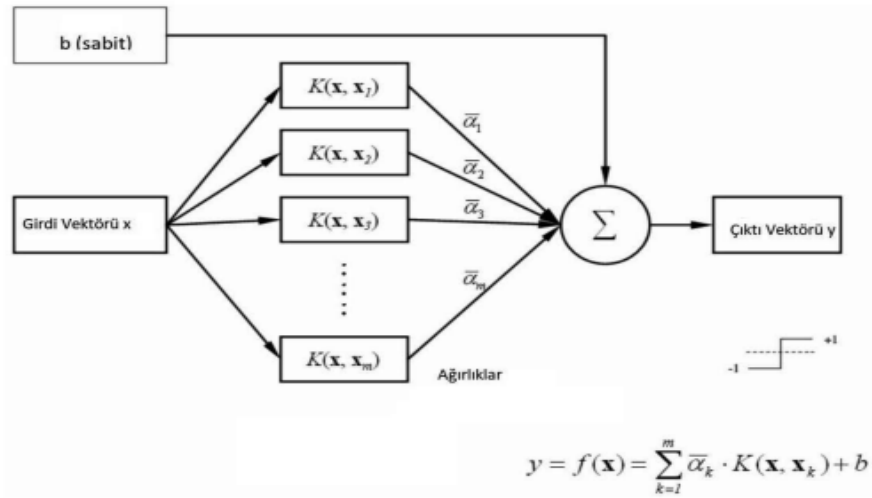
Destek Vektör Makineleri, etkin makine öğrenimi tekniklerinden biridir. Destek Vektör Makinelerinin en önemli avantajı, sınıflandırma problemini kareli optimizasyon problemine dönüştürüp çözmesidir. Böylece problemin çözümünde tahmin aşamasında işlem sayısı azalmakta ve diğer algoritmalara göre daha hızlı çözüme ulaşılmaktadır (Osowski ve diğ., 2004). Bu nedenle büyük hacimli veri setlerinde daha kullanışlı bir yöntemdir. Destek vektör makinesi optimizasyon temelli olduğundan diğer tekniklere oranla karmaşık problemlerde daha kullanışlıdır (Nitze ve diğ., 2012). Karmaşık veri setleri için en uygun yöntemdir. Bu teknik bağımsız öğrenme algoritmasıdır, çünkü veriye dayanan birleşik dağılım fonksiyonuna ihtiyaç duymadan çalışır (Soman ve diğ.,

2011). Destek vektör makinelerinin en yakın veri noktaları arasında hiper düzlem oluşturması durumu Şekil 3’de gösterilmiştir.



Şekil 3. Destek Vektör Makineleri (Vapnik, 2000)


Aşağıdaki Şekil 4’te destek vektör makinesinin ağ yapısı verilmiştir. Bu akış şemasında $K(X, X_k)$ çekirdek fonksiyonlarını, α ise ağırlıkları gösteren Lagrange çarpanını ifade etmektedir. Bu yapı ile girdilerin iç çarpımları hesaplanmaktadır (Ayhan ve Erdoğan, 2014).



Şekil 4. Destek Vektör Makinesi Ağ Yapısı (Ayhan ve Erdoğan, 2014)

3.1.1.2 Regresyon Yöntemi

Regresyon işlemi de sınıflandırma işlemi ile benzerdir. Regresyon işleminde de bir eğitim kümesi ve bu eğitim kümesinden tahminleme çalışması yapılarak oluşturulan bir model mevcuttur. İki veya daha fazla değişken arasındaki ilişkiye regresyon denir. Regresyonda kullanılan parametreler birbirinden bağımlı veya bağımsız olabilir. Amaç, parametreler arasındaki ilişki fonksiyonunu elde etmektir. Lineer regresyon bağımlı değişken ile bağımsız değişken arasındaki ilişkiyi gösteren algoritmadır (Freedman, 2009). Şekil 5’de lineer regresyon yöntemi ile değişkenler arasındaki ilişki görsel olarak ifade edilmiştir.



Şekil 5. Regresyon (Freedman, 2009)

Lineer regresyon özellikleri ve davranışları çok iyi bilme, parametre tahminleri, çok geniş ve karmaşık problemlerin kolay çözülmesi, spesifik veriler için tahminlerin büyük olasılıkla çözülmesi gibi avantajlara sahiptir. Lineer modelde doğrusal bir sınıflandırma oluşturularak çözüm yoluna gidilir. Regresyon modelinin bir diğer türü lojistik regresyondur.

Lojistik Regresyon sınıflandırma işlemi yapmaya yarayan bir regresyon yöntemidir. Bağımlı değişkenin iki farklı değer alması durumunda kullanılmaktadır (Evet / Hayır vs). Kategorik ve sayısal verilerin işlenmesinde kullanılmaktadır. Doğrusal sınıflandırma problemlerinde yaygın olarak kullanılmaktadır.

Doğrusal regresyon modelinde, y bağımlı değişkeni, x bağımsız değişkeni, β_0 kesişim noktası, β_1 doğrunun eğimini ve ε ise gerçek değerlerin sapmalarına neden olan rassal değişkeni ifade etmek kullanılır (Kutner ve diğ., 2015).

$$y = \beta_0 + \beta_1 x + \varepsilon$$

Polinomal (lojistik) regresyon ise bağımlı değişkenin sürekli çıkış değerleri yerine sınıfları tahmin edilir. Lojistik regresyonda, s , bağımsız x değişkeninin $-\infty$ ile $+\infty$ arasında değerler alabilen doğrusal işlevi olmak üzere aşağıdaki ifade kullanılır (Gök ve Atuntaş, 2017).


$$f(s) = \frac{e^s}{1 + e^s} = \frac{1}{1 + e^{-s}}$$

3.1.2 Denetimli makine öğrenmesi diğer yöntemler

3.1.2.1 Sınıflandırma yöntemi

Denetimli öğrenme yöntemlerinden en etkin kullanılan sınıflandırma tekniğidir. Sınıflandırma tekniği eğitilmiş veri setine yönelik tahminleme çalışması yapılmak amacıyla kullanılır (Sebastiani, 2002). Sınıflandırma probleminde sonuç çıktılarını ayrı ayrı tahmin edilmeye çalışılır. Makine öğrenmesi metodu tahmininde kullanılan çıktı kategorik ise sınıflandırmadır, eğer numerik ise regresyondur. Bu çalışmada regresyon yöntemi kullanılmıştır.


Sınıflandırmada problem tanımlama, veriyi anlama, veriyi hazırlama, veri ön işleme ve model kurma aşamaları Şekil 6'da mevcuttur.



Şekil 6. Sınıflandırma Şeması

3.1.2.2 Karar ağacı

Karar ağacı, ağaç tabanlı algoritmalarından biri olup karmaşık problemlerde kullanılır. Karar ağaçlarının ilk hücreleri köktür ve kök hücrelerinin altında yapraklar bulunur, bu yapraklar bize sonucu verir. Belirli bir karar için olası tüm çözümleri tanımlayan başarılı bir yöntemdir. Olası çözümlerin grafiksel gösterimidir. Gerçek hayatta uygulanan karar ağaçları yapısı çok karmaşık olmakla beraber seçenek olarak çok fazladır. Karar ağacı ile yapılan her planlamanın maliyeti ve faydası ortaya çıkmaktadır. Karar ağaçlarının genel akış şeması Şekil 7'de ifade edilmiştir.



Şekil 7. Karar Ağacı Akışı (Albayrak ve Yılmaz, 2019)

Karar ağacında her bölme işlemi ile birbirine benzeyen veriler gruplandırılır ve tümevarım yöntemi ile çözmeye çalışılmak amaçlanır.

Karar ağacında veri seti oluşturma algoritması aşağıdaki Tablo 1’de ifade edilmiştir.

Tablo 1. Karar Ağaçları Algoritması

Veri oluşturma algoritması
Girdi: T (Öğrenme Kümesi) 1. Her nitelik için bilgi kazancını hesapla 2. Bilgi kazancının en yüksek niteliğini “ayırıcı nitelik” seç 3. T’yi ayırıcı nitelik ile böl, düğüm oluştur. If(örnekler aynı sınıfta örnekleri bölecek özellik yok kalan özellik için örnek yok) { İşlemi sonlandır } else { 1. adıma geri dön }

3.1.3 Denetimsiz makine öğrenmesi

Denetimsiz öğrenmede sistem öğretilmiyor, verilerden kendisi öğreniyor. Denetimli öğrenmede olduğu gibi geçmiş veriler makineye öğretilip sonrasında gelecek tahmini yapılmıyor. Bu yöntem bakım planında kullanılan bir yöntem değildir. Verileri keşfetmek için kümelere ayırmak gerekiyorsa bu yöntem kullanılır fakat kümeleme olmayacaksa tercih edilen bir yöntem değildir. Daha karmaşık bir yöntemdir.

3.2 Bakım planlaması yöntemleri

Bakım, maliyet azaltma türleri arasında ilk sırada yer almaktadır. Bakım yapılması zorunlu bir faaliyet olduğu için firmalar için önemli bir durumdur (Tsang, 2002). Modern endüstride az kaynak ile daha fazlasını yapmak durumu ön plana çıkmıştır. Bunun nedeni bütçelerin azalması şirketlerin küçülmesidir. Böylelikle ürün değişkenlikleri artarak insanlar tarafından ekipmanlardan üst düzey performans beklenmektedir (Cassady ve diğ., 2001). Bakım, ekipman ve parça stoğunu minimize hale getirir. Bir fabrikanın makine ve tesislerinin sürekli olarak çalışır durumda olması için gerekli faaliyetlerin planlanması bakımın gerekliliğidir. Bakım sayesinde ekipmanın ömrü ve ekipmanın performansı artar, enerji tasarrufu sağlanır.

Bir işletmede yapılacak bakım, işletmenin kendi bakım ekibi tarafından yapılabileceği gibi, dışarıdan da satın alınabilir. Bakım maliyeti ve uygun ekipman yetersizliği göz önüne alındığında dışarıdan bakım hizmeti satın alınması gerçekleştirilebilir. Arıza ve kesinti plansız bakımda oldukça yüksektir, planlı bakımda ise sonradan oluşan maliyet diğerlerine göre daha azdır. Makinalardaki durumu en aza indirerek mümkün olan en yüksek düzeyde üretimi sağlamak amacıyla bakım çalışması yapılır.

Üretim maliyetlerini düşürmek, verimi ve kaliteyi artırmak, makine duruş sayısını azaltmak ve sürekli üretimi sağlamak bakım faaliyetlerinin başlıca amaçlarıdır. Bakım planı ile kapasite kullanım oranının artırılmasını sağlar ve böylece yatırımlar için harcanan sermayeden daha fazla verim elde edilmesi sağlanır. Arıza halinde makine veya tesis zincirleme olarak bütün sistemi, üretimi etkilemektedir. Bu etki yanlış malzemenin üretilmesi ya da kalitenin düşmesine sebebiyet vermektedir. Böylece müşteri taleplerinin karşılanamaması ve müşteri kayıplara meydana gelmektedir.

3.2.1 Bakım planlaması önerilen yöntem

3.2.1.1 Kestirimci (Öngörücü) bakım

Kestirimci bakım mevcut durum analizinin daha gelişmiş yaklaşımıdır. Kestirimci bakım, makine ve ekipmanların çalışma durumlarını, ölçüm ve analizlerinin sonuçlarını değerlendiren, olumsuz bir durum varsa önlem olarak gerekli planlamaların yapılmasını sağlayan bir bakım türüdür (Zhou ve diğ., 2007). Kestirimci bakımda özel aygıtlar kullanılarak gözlem ve ölçümler yapılabilmektedir. Bir makine ya da parçanın durumunu izleyerek, elde tutulan verilerden yararlanarak bakımın yapılacağı en uygun zamanı belirleyen bir faaliyettir. Böylece daha az duruş, işçilik ve maliyet kaybı olmakta, ekipmanların ömrü uzadığı için daha çok kullanılmaktadır (Baraçlı ve diğ., 2001). Bu yöntemde arızanın nedeni önceden belirleneceği için bakım yapılırken daha az zaman harcanmaktadır. Makine arızalanmadan müdahale edildiği için üretim durmadan, sevkiyatlar gecikmeden makine aktif hale gelmektedir. Üretimde süreklilik bu yöntem ile daha iyi sağlanmaktadır.

Kestirimci bakım ölçme ve kontrol, analiz değerlendirme, bakım planlama ve bakım onarım olmak üzere dört aşamadan oluşmaktadır. Bu aşamalar ile düzgün operasyon şartlarında ekipmanın arızaya doğru hareket edip etmediği teslim edilir.

Ölçme ve Kontrol: Özel aygıtlarla yapılan ölçümler ile makine veya ekipmanların ölçümleri gerçekleştirilir. Olması gereken değerler ve olan değerler karşılaştırılır.

Analiz ve Değerlendirme: Titreşim, basınç, sıcaklık, performans gibi ölçülen değerlerin analizi yapılarak son durumlar değerlendirilir. En önemli analiz edilebilecek parametreler vibrasyon, yağ analizi, ultrasonik test, kızıl ötesi sıcaklık, motor akım analizidir.

Bakım Planlama: Belirlenen arızanın giderilmesi için iş emri oluşturulur ve arıza için bakım planlama tarihi belirlenir.

Bakım-Onarım: Bakım-onarım belirlenen tarihte gerçekleştirilerek üretimin durması engellenir. Üretime ara vermeden, sevkiyatlarda gecikme olmadan müşteri memnuniyeti sağlanır.

3.2.2 Bakım planlaması diğer yöntemler

3.2.2.1 Plansız-Düzeltilici bakım

Plansız bakım, arıza olduktan sonra yapılan gecikmiş bir bakımdır. Bu bakım türü oldukça maliyetli bir hâle dönüşebilir. Hatta o anda oluşan küçük bir arıza giderilirken daha büyük arızalara ya da problemlere yol açabilecek sorunlar meydana getirebilir. Bu nedenle bu tip arızaların daha büyük arızalara ve duruşlara sebebiyet verdiği görülmektedir. Önleyici bakım yaptırılmamasından kaynaklı meydana gelen plansız arızalardır. İşletmeler tarafından bütçe ve çeşitli sebeplerden dolayı istenmeyen bir durumdur. Önleyici bakım ise ekipmanın ömrünü uzatmak, planlanmamış bakımın etkilerini azaltmak için yapılan bakımdır (Worsham, 2004).

3.2.2.2 Koruyucu bakım

Makine üreticisi imalatçı firmalar veya bakım planlama ekibi tarafından belirlenmiş periyodik zamanlarda yapılan bakımdır. Yağlama, yenileme, değiştirme işlemlerinin gerçekleştirildiği ekipmanların kontrol edildiği bakım türüdür. Düzgün bir planlama ile yapıldığında endüstride kullanılacak uygunlukta olup, üretimin sürekliliğini artıran bir yöntemdir (Kenne ve Nkeungoue, 2007)

4. Bulgular

Bu çalışma Savunma Sanayi'nde Türk Havacılık firmasında boya tesisinin bulunduğu alanda gerçekleştirilmiştir. Boyahane tesisinde gerçekleştirilen bu çalışmada otomatik boya makinesinin bakım planlama günleri için tahmin yapılmış ve belirlenmiştir. Makine özellikle önemli projelerin boyandığı su bazlı cihazdır. Bu makinede bozulma

veya arıza olduğu zaman üretim durmakta, acile düşen sevkiyat parçaları artmaktadır. Hatta üretimin duruşundan kaynaklı kimyasaldan gelen saatlik parçalar hurda olmaktadır. Bundan dolayı firma müşteri kaybı ve büyük maddi zarara uğramaktadır. Bu su bazlı makinede işleme alınan parçalar sevkiyat gününe yetişmediği takdirde parçalar için firma günlük zarar ödemektedir. Bu nedenle bu makinenin arızaya geçmeden önce son durumunun tahmin edilmesi önemlidir. Cihaz için belirli bakım zamanları önceden belirlenmelidir. Bu istasyondaki makineye gelen parçalar kimyasaldan geldiği için 18 saat süre içerisinde yüzey kaplama primer ve renk boyası işleme yapılması gerekmektedir. Aksi takdirde parçalar hurda olup firma ciddi zarara uğramaktadır, hurda olmayan parçalarda ise geç boyamadan kaynaklı boya kalkması meydana gelmektedir, dolayısıyla müşteri kaynaklı şikâyetler firmaya zarar vermektedir.

Su bazlı makinenin performans yüzdesine göre bakım zamanının tahmini yapılmalıdır, çünkü makineye giren karton sayısı ve boyama süresi performansıyla orantılıdır, makinenin performansında azalma olduğunda makinenin karton alma sayısı azalır ve toplamda boyadığı karton sayısından daha az parça alır. Aynı zamanda performansı azalan makinenin boyama süresi uzamakta ve hızı düşmektedir. Makinenin performans yüzdesine göre kalan süre sistemsel olarak yansımaktadır.


Su bazlı makinenin %100 performansla çalıştığında alacağı karton sayısı 82'dir. Ayrıca 20 kartonun altında makinenin açılması sağlanamaz, çünkü boşa giden boyanın maliyeti bir gün beklemenin maliyetinden daha fazladır. Bu cihaz 7 gün 24 saat aralıksız olarak çalışmaktadır ve sadece bozulduğunda bakım yapılmaktadır. Bakım süreleri ve türleri farklı olduğundan ne zaman yapılacağı mevcut durumda sadece anlık arızalarla belirlenmektedir. Cihazın yedek parçaları firmada bulundurulduğundan cihazın bakımı için en fazla 4 güne ihtiyaç vardır, bu nedenle 4 gün önceden arıza durumunu bildiren bir sistem olmalıdır. Amaç makine öğrenmesi teknikleri ile bakım planlaması tahmini yapmak, daha önceden belirlenen süreler ile makine öğrenmesi sonucu çıkan tahminlerin uyum yüzdesine bakmaktır. Bu çalışmada denetimli makine öğrenmesi tekniklerinden lineer regresyon, polinomal regresyon ve destek vektör makineleri yaklaşımı kullanılmıştır.

Bu yöntemlere spyder uygulamasında çalışıldıktan sonra çıkan sonuçlar kök ortalama kare hatası yöntemi ile karşılaştırılmıştır. Veri seti savunma sanayinin gizliliğinden dolayı gerçek ve yaklaşık değerlerden oluşmaktadır. 2 adet veri seti ele alınarak problem çözülmüştür. Performans ve ömür olarak nitelendirilen veri setleri, eğitim ve test veri setleri olmak üzere ayrılmıştır. 15 adet veri bulunmaktadır. Eğitim seti arıza durumuna geçene kadar olan verileri içermektedir. Makine öğrenmesi yöntemleriyle çözüm için Python yazılımı kullanılmıştır. Problem için kullanılan veri seti Tablo 2'de verilmiştir.

Tablo 2. Problem İçin Veri Seti

Performans	Arızaya kalan süre	Karton sayısı	Boyama süresi
100%	720	82	30
90%	648	75	35
80%	600	67	40
75%	528	65	45
70%	480	58	50
65%	432	55	55
60%	408	50	60
55%	384	48	65
50%	360	41	70
45%	288	38	75
40%	312	35	80
35%	240	30	85
30%	192	25	90
25%	168	23	95
20%	120	15	100

Şekil 8'de veriler X, Y dağılımı ile analiz edilerek gösterilmiştir. Karton sayısı, arızaya kalan süre ve boyama süresi arasındaki ilişki analiz edilerek gösterilmiştir.




Şekil 8. Verilerin X,Y dağılımıyla gösterimi

Çalışmada yukarıdaki değerlerden veri ön işleme yapılarak sadece gerekli kriterler belirlenmiştir. Bu nedenle performans ve makine ömrü verilerinden yararlanarak test ve eğitim setleri oluşturulmuştur. Performans verisinden x_{test} test setini ve x_{train} eğitim setini oluşturmaktadır. Veriler Şekil 8’de gösterildiği gibi 0,33 oranında eğitim ve test seti olarak bölünmüş ve rassal olarak seçilmiştir. Şekil 9’da sol taraftaki değerler makine öğrenimi için eğitim verileri, sağ taraftaki veriler ise tahminleme sonucu oluşturulan test verileridir.

x_train - DataFrame		x_test - DataFrame	
Index	performans	Index	performans
0	100	1	90
2	80	6	60
3	75	8	50
4	70	9	45
5	65	14	20
7	55		
10	40		
11	35		
12	30		
13	25		

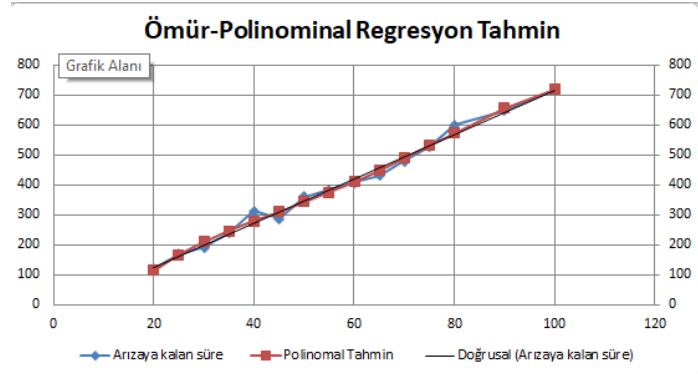
Şekil 9. Ömür eğitim ve veri seti oluşturma

Sonuç olarak lineer regresyon uygulanmış ve makine öğrenmesi ile test olarak ayrılmış 5 verinin performans açısından arızaya geçmesinin kalan süreleri tahmin edilmiştir. Gerçek yani tecrübeye dayanan sürelerle karşılaştırma yapılarak makine öğrenmesi tekniğinin başarı oranı hesaplanır. Lineer regresyon sonucu çıkan tahminlerin ve gerçek ömür değerlerinin karşılaştırılması Şekil 10’da verilmiştir. Arızaya girdiği performans verileri ve tahminleme sonucu arızaya girebileceği performans değerleri arasındaki fark gösterilmiştir.



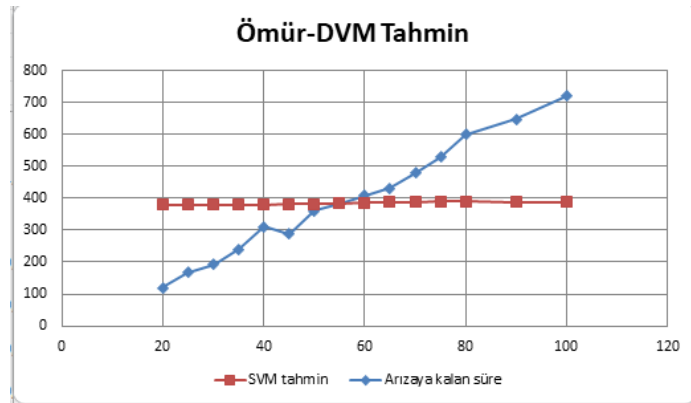
Şekil 10. Ömür ve lineer tahmin

Polinomial regresyon sonucu çıkan tahminlerin ve gerçek ömür değerlerinin karşılaştırılması Şekil 11’de verilmiştir. Yapılan hesaplamalar sonucu arızaya kalan süreye en yakın zaman polinomial ile belirlenmiştir. Planlamada herhangi bir sapma olmaması için arızaya kalan sürenin yüksek olması istenilen bir durumdur. Polinomial regresyonda arızaya kalan süre diğer tahminlemeden daha fazladır ve önlem ona göre daha önceliklidir.



Şekil 11. Ömür ve polinomial regresyon tahmin

Destek vektör makineleri sonucunda arızaya kalan süre performans açısından minimum değerler olarak gözlemlenmektedir. Normalde 480 gün sonrasında arıza veren makinenin bu tahminleme sonucunda 388 gün sonra arızaya geçeceği görülmektedir, bu durum daha önce görülmemiştir. Destek vektör makinesi sonucu çıkan tahminlerin ve gerçek ömür değerlerinin karşılaştırılması Şekil 12’de verilmiştir.



Şekil 12. Ömür ve DVM tahmin

Bu çalışma kapsamında Lineer regresyon, polinomial regresyon ve destek vektör makineleri teknikleri kullanılmıştır. Bu teknikler sonucunda arızaya kalan süre ve performans verisi hesaplanmıştır. Tablo 3’de yaklaşım için hesaplanan tahmin değerleri verilmiştir.

Tablo 3: Yaklaşımlar için Tahmini Değerler

Performans	Arızaya kalan süre	Lineer tahmin	Polinomal tahmin	DVM tahmin
100	720	644,293	719,439	387,118
90	648	648	656,688	388,378
80	600	600	574,357	389,013
75	528	528	531,401	388,844
70	480	480	489,32	388,234
65	432	405,666	449,109	387,164
60	408	408	411,316	385,702
55	384	357,941	376,045	384
50	360	286,353	342,953	382,272
45	288	288	311,253	380,745
40	312	312	279,71	379,605
35	240	240	246,645	378,962
30	192	192	209,932	378,837
25	168	168	167	379,167
20	120	119,314	114,832	379,829

Yapılan analizler sonucu kök ortalama kare hatası hesaplanmıştır, hesaplama hem excel ortamında manuel olarak hem de python yazılımında yapılmıştır. Kök ortalama kare hatası lineer sonucunda 0,9, polinomal lineer sonucunda 1,0 ve destek vektör makinesi sonucunda 0,037 olarak değerler sonuçlanmıştır. Bu değerler sonucunda tahminlemenin ne kadar doğru sonuçlar vereceği planlanmıştır. Bu değerler arızalanma süresi olarak değerlendirildiğinde üretim için en etkin olan polinomal değer olarak belirlenmiştir. Bu çalışmanın devamında SQL’de alarm l-kodu yazılarak makine öğrenmesinde hesaplanan tahmini saatlere göre ömür 209,8 saatin altına düştüğünde bilgisayarlara otomatik olarak rapor gitmesi sağlanacaktır.

5. Sonuç

Bu çalışma kapsamında, kestirimci bakım ve makine öğrenmesi perspektifi ile kök ortalama kare hesabı ve bakım takvimi planlaması çalışması gerçekleştirilmiştir. Kök ortalama kare hesabı için python spyder uygulaması kullanılmıştır. Bu şekilde, çıkan değere göre hangi yöntemin kullanılacağını gösteren rakamsal ifade belirlenmiştir. Periyodik bakım takvimi planlaması için de regresyon, destek vektör makineleri yöntemleri kullanılmış, etiketlenmiş veriler üzerinden modeller eğitilerek, performans bazlı bakım planlamasında doğrudan kullanılacak çıktıları üretmek hedeflenmiştir.

Çalışmalar savunma sanayinde otomatik boya tezgâhında yapay zeka alanında gerçekleştirilmiştir. Bu çalışma sayesinde makineler için kalan faydalı ömürler hesaplanmış, ona uygun olarak bakım tarihleri belirlenmiştir. Üretimin aksamaması, parçaların hurdaya ayrılmaması ve müşteri kaybının olmaması için çalışma yapılmıştır. İki ayrı veri setinde performanslar ayrı ayrı gözlemlenmiş, birbiri ile doğrulanarak net sonuçlar ortaya çıkmıştır. Otomatik boya tezgâhındaki algılayıcılardan alınan veriler, genel olarak sanayide kullanılmakta olan gelişmiş robotları ve üretim hatlarındaki diğer ekipmanları takip eden algılayıcılar ile aynı özelliktedir. Karşılaştırmalı sonuç tablolarındaki değerler göz önüne alınarak hangi yöntemin bakım planlamasında kullanılacağı, ne oranda kazançlar sağlayacağı analiz edilmiştir. Polinomal yöntem ile üretime ara vermeden bakım çalışmasının yapılacağı gösterilmiştir. Gelecek çalışmalarda, buradaki sonuçlar ışığında önerilen yöntemin, ‘gerçek’ bir sistemden elde edilen veriler üzerinde uygulaması yapılabilir ve üretilen sonuçlara göre bakım planlaması gerçekleştirilebilir.

Araştırmacıların Katkısı

Bu araştırmada, Gözde Nur Calayır, problemin ortaya konması, literatür taraması, makalenin oluşturulmasında, Mehmet Kabak yazım kontrolleri ve son kontrollerin yapılarak düzenlenmesinde katkı sağlamıştır.

Çıkar Çatışması

Yazar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

Aggarwal, R. K., Xuan, Q. Y., Dunn, R. W., Johns, A. T. ve Bennett, A. (1999). A novel fault classification technique for double-circuit lines based on a combined unsupervised/supervised neural network, IEEE transactions on Power Delivery, 1250-1256. Doi: <https://doi.org/10.1109/61.796214>

- Albayrak, A.S., Yılmaz, Ö. (2019). Veri madenciliği: Karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama. “*Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*.” Doi: <https://doi.org/10.31590/ejosat.843837>
- Ayhan, S., Erdoğmuş, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. “*Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*.” Erişim adresi: <http://www.itobiad.com/tr/pub/issue/54141/673015>
- Baraçlı, H., Coşkun, S., Eser, A. (2001). Toplam kalite programlarının başarılı olarak uygulanabilmesinde toplam üretken bakım tekniği, *I. Demir-Çelik Sempozyumu*, 340-341, Zonguldak. Erişim adresi: <https://www.mmo.org.tr/kitaplar/idemir-celik-sempozyumu-bildiriler-kitabi-1>
- Cassady, C.R., Pohl, E.A., Murdock W.P. (2001). Selective Maintenance Modeling for Industrial Systems, *Journal of Quality in Maintenance Engineering*, 7, 104-117. Doi: <https://doi.org/10.1108/13552510110397412>
- Ekici, S. (2012). Support Vector Machines for classification and locating faults on transmission lines, *Applied Soft Computing*, 1650-1658. Doi: <https://doi.org/10.1016/j.asoc.2012.02.011>
- Freedman, D. A. (2009). *Statistical Models*, Cambridge University Press. Doi: <https://doi.org/10.1017/CBO9781139165495>
- Garcia, M. A., Sanz-Bobi, Pico, J. (2006). SIMAP: Intelligent System for Predictive Maintenance. “*Application to the health condition monitoring of a wind turbine gearbox*”, *Comput. Ind.*, 57, 552-568. Doi: <https://doi.org/10.3390/pr9020300>
- Gök, M., Atuntaş, V. (2017). “*Regresyon Analizi*”, (Ed. Akçetin E, Çelik, U, Gök, M.) “*Rapidminer ile Veri Madenciliği*”, 85-86, Ankara. Erişim adresi: <https://dergipark.org.tr/tr/pub/gujsc/issue/31140/311082>
- Hashemian, H., Bean, W. C. (2011). “*State-of-the-art predictive maintenance techniques*,” *IEEE Trans. Instrum. Meas.*, 60, 3480-3492. Doi: <https://doi.org/10.1109/TIM.2009.2036347>
- Jahnke, P. (2015). *Machine Learning Approaches for Failure Type Detection and Predictive Maintenance*, 83. Erişim adresi: https://www.ke.tu-darmstadt.de/lehre/arbeiten/master/2015/Jahnke_Patrick.pdf
- Kenne, J.P., Nkeungoue, L.J. (2007). Simultaneous control of production, preventive and corrective maintenance rates of a failure-prone manufacturing system, *Applied Numerical Mathematics*. Doi: <https://doi.org/10.1016/j.apnum.2006.11.010>
- Konar, P., Chattopadhyay, P. (2011). “*Bearing fault detection of induction motor using wavelet and Support Vector Machines (SVMs)*,” *Appl. Soft Comput. J.*, 11, 4203-4211. Doi: <https://doi.org/10.1016/j.asoc.2011.03.014>
- Kutner, M. H., Nachtsheim, C. J., Neter, J., Li, W. (2015). “*Applied Linear Statistical Models*”, Cilt 103. McGraw-Hill Irwin, New York. Erişim adresi: <https://docplayer.biz.tr/140769174-Fen-bilimleri-dergisi-makine-ogrenmesi-yontemleri-ile-akademik-basarininin-tahmin-edilmesi.html>
- Lyonnet, P. (1991). *Maintenance Planning: Methods and Mathematics*, Chapman&Hall. Doi: <https://doi.org/10.1002/qre.4680090514>
- Nils J. Nilsson, (1996). *Introduction to Machine Learning: An Early Draft of a Proposed Textbook*, Stanford University. Erişim adresi: <https://ai.stanford.edu/~nilsson/MLBOOK.pdf>
- Nitze, I., Schulthess, U., Asche, H. (2012). Comparison of machine learning algorithms random forest, artificial neural network and support vector machine to maximum likelihood for supervised crop type classification. *Proceedings of the 4th. GEOBIA*, 35-40. Doi: <https://doi.org/10.5194/isprs-archives-XLII-3-W6-573-2019>
- Nourmohammadzadeh, A., Hartmann, S. (2015). Fault Classification of a Centrifugal Pump in Normal and Noisy Environment with Artificial Neural Network and Support Vector Machine Enhanced by a Genetic Algorithm in Theory and Practice of Natural Computing. *Lecture Notes in Computer Science*. Doi: <https://doi.org/10.1016/j.eswa.2009.06.018>
- Oowski, S., Siwekand, K., Markiewicz, T. (2004). MLP and SVM Networks – a Comparative Study *Proceedings of the 6th Nordic Signal Processing Symposium – NORSIG*. <https://doi.org/10.1109/NORSIG.2004.250120>
- Öztanır, O. (2018). “*Makine öğrenmesi kullanılarak kestirimci bakım*”, (Yüksek lisans tezi), <https://openaccess.hacettepe.edu.tr>

- Rohani, A., Abbaspour-Fard, M., Abdolahpour, S. (2011). Prediction of tractor repair and maintenance costs using Artificial Neural Network, Expert Syst. Appl., 38, 8999–9007. Doi: <https://doi.org/10.1016/j.eswa.2011.01.118>
- Sarac, A., Batta, R. ve Rump, C. M. (2006). A Branch-and-Price Approach for Operational Aircraft Maintenance Routing. European Journal of Operational Research.
- Sebastiani, F. (2002). Machine learning in automated text categorization, ACM computing surveys (CSUR), 34, 1-47. Doi: <https://doi.org/10.1145/505282.505283>
- Soman, K.P., Loganathan, R., Ajay, V. (2011). Machine learning with SVM and other kernel methods. PHI Learning. Erişim adresi: https://content.kopykitab.com/ebooks/2018/03/16708/sample/sample_16708.pdf
- Sriram, C. ve Haghani, A. (2003). An Optimization Model for Aircraft Maintenance Scheduling and Re-assignment. Transportation Research. Doi: [https://doi.org/10.1016/S0965-8564\(02\)00004-6](https://doi.org/10.1016/S0965-8564(02)00004-6)
- Tamilselvan, P., Wang, P. (2013). Failure diagnosis using deep belief learning based health state classification, Reliab. Eng. Syst. Saf., 115, 124–135. Doi: <https://doi.org/10.1016/j.res.2013.02.022>
- Tsang A.H.C. (2002). Strategic Dimensions of Maintenance Management, Journal of Quality in Maintenance Engineering, 8, 7-39. Doi: <https://doi.org/0.1108/13552510210420577>
- Vapnik, V. (2000). The Nature of Statistical Learning Theory, Second Ed., 1, New York. Doi: <http://dx.doi.org/10.1007/978-1-4757-3264-1>
- Worsham, C.W. (2004). “Önleyici bakım gerekli midir?”, Mühendis ve Makine Dergisi, 45, Sayı 538, 21-23. Erişim adresi: <https://polen.itu.edu.tr/bitstream/11527/5895/1/9192.pdf>
- Zhou, X., Xi, L., Lee, J. (2007). Reliability centered predictive maintenance scheduling for a continuously monitored system subject to degradation, Reliability Engineering & System Safety, 92, 530-534. doi: [10.1016/j.res.2006.01.06](https://doi.org/10.1016/j.res.2006.01.06)