



Endüstriyel Tesislerde Makine Öğrenmesi ile Kestirimci Bakım ve Arıza Analizleri

Predictive Maintenance and Fault Analysis with Machine Learning in Industrial Facilities

İlyas Güvenç Pirge , İlhan Bastürk* 

Manisa Celal Bayar Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Manisa, Türkiye

Öz

Günümüzde endüstriyel tesislerde seri üretimin durmadan verimli bir şekilde devam etmesi oldukça önemlidir. Üretim hatlarında yaşanabilecek herhangi bir arıza, uzun duruşlara neden olup üretim verimliliğini olumsuz yönde etkilemektedir. Bu arızaların yaşanmasını önlemek için planlı bakım ve kestirimci bakım uygulamaları büyük bir öneme sahiptir. Geleneksel bakım yöntemlerinin yanında günümüz endüstriyel teknolojilerinin etkisi ile özellikle endüstri 4.0'ın getirdiği yeni yöntemler ile kestirimci bakım uygulamaları, bakım çalışmaları içerisinde ön plana çıkmıştır. Uyarıcı bakım olarak da bilinen bu yöntem sayesinde üretim sistemlerinde bakım gerektiren bir arıza önceden tahmin edilerek bu durum yaşanmadan ve sistemi uzun bir süre durdurmadan önüne geçilebilmektedir. Bu çalışmada, bir gıda üretim tesisinin nişasta transfer sisteminde yer alan helezon motoru ve şanzıman grubundan alınan titreşim ve sıcaklık değerleri ile ortam sıcaklık ve nem parametreleri kullanılarak makine öğrenmesi ile arıza analizleri yapılmış ve arıza kaynaklı uzun duruşların önüne geçilmeye çalışılmıştır. Denetimli öğrenme yöntemlerinden olan k-en yakın komşu (KNN), karar ağacı (DT), Naive Bayes (NB), destek vektör makineleri (SVM), rassal orman (RF) ve Extreme Gradient Boosting (XGBoost) gibi makine öğrenme algoritmaları kullanılarak sistemlerin performans verileri karşılaştırılmıştır. Çalışma kapsamında ele alınan modellerde girdi verisi olarak ortam sıcaklık ve nem, motor sıcaklık ve titreşim ile redüktör sıcaklık ve titreşim parametreleri kullanılmıştır. Modelin arıza yok, arıza kısa duruş, arıza uzun duruş yakın ve uzun duruş büyük arıza olmak üzere dört çıktısı bulunmaktadır. Verilerin analizi için Python programı kullanılmış ve çalışmanın sonucunda XGBoost ve DT algoritmalarının daha yüksek doğruluk oranı verdiği tespit edilmiştir.

Anahtar Kelimeler: Asenkron motor, denetimli öğrenme, kestirimci bakım, makine öğrenmesi, redüktör.

Abstract

Nowadays, it is very important for mass production in industrial facilities to continue efficiently without stopping. Any failure that may occur in production lines causes long stoppages and negatively affects production efficiency. To prevent these failures, planned maintenance and predictive maintenance applications are of great importance. With the new methods brought by Industry 4.0, predictive maintenance, also known as warning maintenance, have come to the forefront in maintenance works. Thanks to this method, a failure requiring maintenance in production systems can be predicted and prevented without stopping the system for a long time. In this study, failure analyzes were performed with machine learning using vibration and temperature values taken from the helical motor and transmission group in the starch transfer system of a food production facility and ambient temperature and humidity parameters, and an attempt was made to prevent long stoppages due to failures. The performance data of the systems were compared using machine learning algorithms such as k-nearest neighbor (KNN), decision tree (DT), Naive Bayes (NB), support vector machines (SVM), random forest (RF) and Extreme Gradient Boosting (XGBoost). In the models considered within the scope of the study, ambient temperature and humidity, motor temperature and vibration and reducer temperature and vibration parameters were used as input data. The model has four outputs: no fault, fault short stop, fault long stop near and long stop major fault. Python program was used for data analysis and as a result of the study, it was determined that XGBoost and DT algorithms gave higher accuracy rate.

Keywords: Asynchronous motor, supervised learning, predictive maintenance, machine learning, reducer.

*Sorumlu yazarın e-posta adresi: ilhan.basturk@cbu.edu.tr

İlyas Güvenç Pirge  orcid.org/0009-0008-3978-1883

İlhan Bastürk  orcid.org/0000-0003-1869-6010



1. Giriş

Ülkemizde üretim sektöründe, endüstriyel işletmelerin rekabetçi olabilmeleri için üretim süreçlerinde verimliliklerini arttırmaları büyük önem taşımaktadır. Verimliliğini arttırmak isteyen işletmeler, teknolojik faaliyetleri takip ederek hem üretim performanslarını arttırmak hem de bu süreç içerisinde oluşan maliyetlerini minimize etmek durumunda kalmışlardır. Bu değerlendirme, işletmeleri üretim hatlarının bakımlarını etkin ve verimli bir şekilde uygulayabilecekleri bir program oluşturmalarına yaklaştırmıştır. Aksi durum düşünüldüğünde, bakımların sürdürülebilir yapılmadığı tesislerde arıza duruşlar artacak ve buna bağlı olarak işçilik, malzeme, enerji ve zaman açısından büyük kayıplar yaşanacaktır. Bu çıkarımlar genel olarak değerlendirildiğinde seri üretimin olduğu tüm sektör ve işletmelerde etkin ve programlı bakımların yapılması önem arz etmektedir.

Bakım uygulamaları literatürde genel olarak iki başlık altında incelenmektedir. Bunlar düzeltici ve önleyici bakım olarak adlandırılmaktadır (Cortadi vd. 2020). Düzeltici bakım, bir ekipman veya sistemin iş göremez hale geldiği veya arızalandığı esnada yapılan bakım türüdür. Bu tarz bakımlar, anlık olup arızanın kök sebebini bulmak ve sorunu çözmek için yapılmaktadır. İçeriğinden de anlaşılacağı üzere düzeltici bakım, genellikle acil durumlarda anlık ve plansız bir şekilde gerçekleşmektedir. Ayrıca anlık duruşlar ve yedek parça tüketimi göz önünde bulundurulduğunda düzeltici bakımlar, işletmelere maliyet açısından bir yük oluşturmaktadır. Önleyici bakım ise, ekipman veya üretim hatlarının periyodik olarak kontrol edilip temizlenerek arızaların oluşmasını önleyen bir bakım çeşididir. Bu tür bakımlar, işletmelerin yıllık çalışma takvimi kapsamında önceden belirlenip uygulanmaktadır. Planlı yapılan bir uygulama olduğu için bu tür bakımlarda, kontrol edilecek ve aksiyon alınacak noktalar önceden tespit edilmekte ve bu aksiyonlarda kullanılabilecek olası yedek parçalar da bakım öncesi hazırlanmaktadır. Önleyici bakım yaklaşımları içerisinde değerlendirilen diğer bir konu ise kestirimci bakımdır (Köprü 2022). Kestirimci bakım (Predictive Maintenance), ekipmanların arızalarını tahmin etmek ve önlemek amacıyla elde edilen verilerin analiz edilerek çıkarımların yapıldığı bir bakım türüdür. Bu tür bakım, düzeltici ve önleyici bakımlar ile ele alınarak tamamlayıcı bir şekilde uygulanmaktadır. Bu bakımlar, özellikle iki önemli noktada işletmelere yardımcı olmaktadır. Bunlardan birisi arıza meydana gelmeden, sorun ortaya çıkmadan önce uyarı vermesi ve arıza oluşmadan tahmin edebilmesi ikincisi ise ekipmanların faydalı ömürlerinin uzaması için en uygun bakım zamanlarının belirlenmesidir (Köprü 2022).

Kestirimci bakım ekipmana ait belirli parametrelerin sürekli izlenmesi ve analiz edilmesiyle gerçekleşmektedir. Sensörlerden veya diğer veri izleme sistemlerinden elde edilen veriler kullanılarak değerlendirme yapılmaktadır. Bu analizler ile ilgili ekipmanların kalan faydalı ömrü (Remaining Useful Life-RUL) veya üretim hatlarının ileriye dönük performansları tahmin edilebilmektedir. Bu tahminleme çalışmalarında makine öğrenmesi (ML) algoritmaları sıkça kullanılmaktadır. Makine öğrenmesine dayalı kestirimci bakım modelleri işletmelerde ekipman, işçilik, zaman ve enerji gibi kayıpların maliyetlerinden kurtarabilecek önemli bir nokta olmuştur. Özellikle son dönemde hem akademide hem de endüstride kestirimci bakım büyük önem kazanmış ve farklı sektörlerle yönelik birçok çalışma yapılmaya başlanmıştır. Tuğba Köprü, yaptığı çalışmada üretim hattından aldığı dört ayrı titreşim verisi ile RPM ve akım verilerini kullanarak bir veri seti oluşturmuş ve bu veri setini istatistiksel bir program üzerinde SVM ve DT algoritmaları ile analiz etmiştir. (Köprü 2022). Özcan Armağan Ayan, yaptığı çalışmada titreşim analizi yöntemini kullanarak baca gazı fanında yaşanan balanssızlık arızası ve dış bilezik hasar tespitini yapmıştır. Bu tespitleri fanın çalışmasına ciddi bir tehlike oluşturmadan önce yaparak olası üretim kayıplarının ve ek bakım maliyetlerinin önüne geçmiştir (Ayan 2019). Kürşat Tuncer, bir seramik fabrikasında toz emme görevini yapan fan motor tahrik grubunun üzerindeki 8 farklı noktadan (motor iç yatay, motor iç dikey, motor dış yatay, motor dış dikey, fan iç yatay, fan iç dikey, fan dış yatay, fan dış dikey) titreşim verilerini ölçerek balanssızlık problemini tespit etmiştir (Tuncer 2022). Hakan Ceyhan, yaptığı çalışmada endüstriyel alanda üretim yapan bir döküm makinesi üzerinde mikser motoru sürücü arıza zamanının tahmini için kestirimci bakım uygulamasını gerçekleştirmiştir (Ceyhan 2022). Yusuf Kalemoglu, tez çalışmasında bir demir çelik tesisinin haddehanesinde bulunan bir tezgâhın, elektrik motorlarında sıcaklık ve titreşim ölçümleri ile kestirimci bakım uygulaması yapmıştır. Her motordan ön ve arka rulman sıcaklıkları, sargı sıcaklıkları, ön ve arka kapak titreşim verileri alınarak sisteme entegre etmiştir. Verilerin analizi aşamasında rulman arızası tespiti yapılmış ve onarılmıştır (Kalemoglu 2023). Erkan Sındır, bir asenkron motorun sıcaklık, titreşim ve akım değerlerini PLC yardımı ile sahadan toplamış ve veri tabanına aktararak test verilerinin oluşturulmasında kullanmıştır. Sahadan toplanan verilerin MATLAB uygulaması aracılığıyla analizi sonucunda bulanık mantık temelli çıkarım sistemi tasarlamıştır. Sisteme giriş değişkeni olarak verilen test verilerinin değerlendirilmesi sonucunda üretilen çıkış değişkeniyle sistemde çalışan asenkron motorun mo-

tor sağlığını belirlemiştir (Sındır 2022). Mehmet Şahin, bir işletmedeki torna tezgahından belli bir zaman aralığında aldığı verileri Python programlama dilini kullanarak analiz etmiştir. Bu analiz esnasında anomali tespiti yapmak için aykırı değer, seviye yükseltme ve kayması, desen değişimi ve sezonluk düzen gibi farklı metotlar kullanmıştır (Şahin 2022). Oktay Karagöz, uçak ekipmanlarının arıza sayısının tahminine yönelik olarak yapay zekâ ve makine öğrenmesi algoritmaları kullanmıştır. Bu bağlamda, arıza tahmin başarısını arttırmak için iki aşamalı model üzerinde durmuştur. İlk aşamada, etkili ve etkisiz parametrelerin belirlenmesi için özel bir seçme yöntemini, ikinci aşamada ise gürültülü ve tutarsız verilerin elemine edilmesini sağlayan K-ortalamlar algoritmasını kullanmıştır. Daha sonra bakım veri kümesindeki performansı, Yapay Sinir Ağı, Destek Vektör Regresyonu (DVR), Doğrusal Regresyon (DR) gibi makine öğrenme algoritmaları ve Genetik Algoritma (GA), Diferansiyel Evrim Algoritması (DE), Dağıtık Algoritma (DA) gibi optimizasyon algoritmaları kullanarak değerlendirmiştir (Karagöz 2024). Fırat Dişli, ampirik mod ayrışımı (AMA) ve ML yöntemlerini kullanarak kırık rotor çubuğu kaynaklı arızaların sınıflandırmasını yapmıştır. Arızalı motor veri setinden aldığı faz akımı ve titreşim sinyallerini filtreleyip etiketlendirme işlemlerini yaparak öznitelikleri oluşturmuştur. Oluşturulan öznitelikleri SVM, KNN ve DT makine öğrenmesi yöntemleriyle sınıflandırmıştır (Dişli vd. 2023). Telat Akyaz, bir endüstriyel tesiste makinelerin titreşim, sıcaklık, ortam hava kalitesi ve güç tüketimi verilerini sahadan toplayarak bir bulut uygulamasına kaydeden taşınabilir ve modüler bir sistem tasarlamıştır. Toplanan verilerin optimizasyon çalışmasında MATLAB makine öğrenmesi yöntemlerini kullanmıştır (Akyaz 2022). Ercan Kızılay, demiryolu makas motorlarının emniyetli operasyonu ve gerçek zamanlı verilere dayalı olarak kestirimci bakım faaliyetlerinin entegrasyonu ile bir kontrol sistemi geliştirmiştir. Yaptığı tasarım çalışması ile emniyet yazılımlar geliştirip test sağlamıştır. Kontrol devresinde kestirimci bakım algoritması oluşturularak verileri analiz etmiştir (Kızılay 2022). Sinem Kulluk, bir üretim hattında yer alan ana tambur motoru üzerinden sensör aracılığıyla aldığı verileri etiketleme, temizleme ve normalizasyon işlemlerinden geçirmiştir. Ekipmanın kalan faydalı ömrünün tahmin edebilmek için elde ettiği verileri DT, RF, SVM ve LR gibi makine öğrenme algoritmalarını kullanmıştır (Kulluk vd. 2024). Aykut Atapek, turbojet motorlarının titreşimlerini ölçtükten sonra bu verileri detaylı analiz ederek dört adet motor arızasının önceden tespit etmiştir (Atapek 2022). Asad Asadzade, bir çalışmasında jet motorlarının kalan faydalı ömürlerini tahmin etmek için

NASA tarafından sağlanan simülasyon veri setlerini kullanarak akış öğrenmeye dayalı ARF (Adaptive Random Forest) yöntemini uygulamıştır. Daha sonra aynı veri kümesinin kullanıldığı diğer çalışmalar ile karşılaştırmalar yapmıştır (Asadzade 2020). Osman Güler, turbo fan motorlarının kalan faydalı ömrünü tahmin etmek için lojistik regresyon (LR), KNN, SVM, DT, AdaBoost, XGBoost, NB, stokastik gradyan inişi (SGD) ve gizli Dirichlet ayrımı (LDA) makine öğrenme algoritmalarını kullanmış ve sonuçlarını karşılaştırmıştır. Yapılan çalışmalar sonucunda LDA, XGBoost ve SVM algoritmalarının en iyi performansı gösterdiğini tespit etmiştir (Güler 2024). Halil Murat Karadayı, bu çalışmada kestirimci bakım yöntemlerinden biri olan titreşim ölçümü yöntemiyle bir işletme için kritik olan pompa grubundan veriler alarak titreşim seyrini incelemiştir. Alınan ölçümlerin FFT spektrum analizini yapmıştır. Bu analiz ile ekipman arızı bir duruşa sebep olmadan önce arıza tespiti yapılabildiğini ortaya koymuştur (Karadayı 2011). V. İlhan Baykara, bir çalışmada bir sistemde çalışmakta olan bir şanzımandan aldığı titreşim ölçümlerini analiz etmiş ve şanzımanın dişli çarklarında oluşan hasarları tespit etmiştir. Bu şekilde kestirimci bakım uygulayarak şanzımanın çok daha ciddi şekilde hasar alarak plansız duruşlara sebep olmasını engellemiştir (Baykara 2009). Sadettin Orhan, rulmanlarla yataklanmış dönen makine elemanlarında titreşim analizi kullanarak kestirimci bakım uygulaması gerçekleştirmiştir. Elde ettiği titreşim verilerini frekans analizi metodu ile değerlendirerek dengesizlik, eksen kaçıklığı, mekanik gevşeklik ve rulman hasarlarını ilk oluşma anlarında belirlemeye çalışmıştır (Orhan 2002).

Bu çalışmada, gıda sektöründe yer alan bir işletmenin üretim tesisindeki ham madde transfer sisteminde bulunan helezon motorları için önceden oluşabilecek arızaların analizi yapılmıştır. Çalışma, helezonun tahrik grubuna yerleştirilen sıcaklık ve vibrasyon sensöründen ve çalışma ortamının sıcaklık ile nem değerlerini ölçen datalogger cihazından alınan veriler ile yapılmıştır. ML algoritmalarından denetimli öğrenme metotları kullanılarak Python programında modellerin arıza analiz performansları karşılaştırılmıştır.

2. Gereç ve Yöntem(ler)

Gıda üretimi yapılan endüstriyel bir firmada üretim hattında yaşanan arıza analizi için öncelikle arıza kaynaklı uzun duruşların yaşandığı noktalar belirlenmiştir. Bu tespit yapıldıktan sonra nişasta sirkülasyon sisteminde bulunan helezon motor ve şanzıman (redüktör) grubuna sıcaklık ve titreşim sensörleri ile çalışma alanının ortam sıcaklık ve nem değer-



Şekil 1. Datalogger ve sıcaklık/titreşim sensörlerinin montajı.

lerini ölçen datalogger montajı Şekil 1’de gösterildiği gibi yapılarak çalışmalara başlanmıştır. Bu çalışmada Advantech ailesine ait sıcaklık/vibrasyon sensörleri ile Testo ailesine ait datalogger kullanılmıştır. Bu cihazlara ait teknik özellikler aşağıda belirtilmiştir.

Advantech WISE-2410 vibrasyon/sıcaklık sensörünün teknik özellikleri

- Dahili anten, LoRaWan (Long Range) uzun mesafe haberleşme
- IP66 korumalı tasarım
- -20 ila 80°C çalışma sıcaklığı
- ISO10816-3 titreşim standardı ile uyumluluk

Testo 174H Datalogger teknik özellikleri

- -20 ila 70°C ölçüm aralığı
- $\pm 0,5^\circ\text{C}$ doğruluk (-20 ila 70°C)
- 0 ila 100 %rH nem ölçüm aralığı
- -20 ila 70°C çalışma sıcaklığı
- IP20 koruma sınıfı
- 16.000 ölçüm değerini kayıt altında tutabilme

Yaklaşık üç ay boyunca sahadan alınan veriler, Şekil 2’de yer alan arayüz programı aracılığıyla dijital ortama aktarılmıştır. Veri kümesinde belirtilen başlıklara ait bilgiler Çizelge 1’de görülmektedir.


Çizelge 1. Öznitelik başlıklarının tanımlamaları.

Öznitelik Başlığı	Tanımı
NID Vortex Sic [$^\circ\text{C}$]	Vorteks bölgesi çalışma ortamı sıcaklığı
NID Vortex Nem[%rH]	Vorteks bölgesi çalışma ortamı nemi
MSic	Motor gövde sıcaklığı
MVib	Motor gövde titreşim değeri
RedSic	Redüktör (şanzıman) gövde sıcaklığı
RedVib	Redüktör (şanzıman) gövde titreşim değeri


Aktarılan bu veriler, Python programında kullanılan algoritmaların tanıyabileceği formata dönüştürülerek %30’u test ve %70’i eğitim seti olarak ayrılarak performans değerlendirme çalışmaları yapılmıştır. Veri işleme aşamalarını özetleyen bir blok diyagramı Şekil 3’te görülmektedir.

2.1. Makine Öğrenmesi

Makine öğrenmesi, Şekil 4’de de görüleceği üzere yapay zekâ alanında bir alt disiplin olarak kabul edilmektedir (Ramachandran vd. 2022). Bu disiplinin temel amacı, insan müdahalesi olmadan karmaşık problemleri çözebilen otonom sistemler geliştirmektir. Bakımdan, üretime, satıştan robotığa kadar birçok alanda toplanan veriler makine öğrenmesi algoritmaları ile anlamlandırılıp yarar sağlamaya çalışılmaktadır (Köprü 2022). Yapay zekâ kapsamında makine öğrenimi, birçok alanda akıllı tahmin algoritmaları geliştirmek için güçlü bir araç olarak ortaya çıkmıştır. ML yaklaşımları, yük-



Şekil 2. Verilerin arayüz programı ile alınması.




Şekil 3. Çalışmanın blok diyagramı.

sek boyutlu ve çok değişkenli verileri işleme, kompleks ve dinamik ortamlarda veriler arasındaki ilişkileri ortaya çıkarma becerisine sahiptir (Wuest vd. 2016). Bu nedenle ML, kestirimci bakım (PdM) uygulamaları için güçlü tahmin yaklaşımları sağlar. Ancak bu uygulamaların performansı, uygun makine öğrenmesi algoritmasının seçimine bağlıdır (Carvalho vd. 2019). ML yöntemlerinin farklı alanlarda kullanılması insana olan ihtiyacı önemli ölçüde azaltmıştır. İnsandan kaynaklı verim düşüklüğü ya da hataların önüne geçilmiştir (Köprü 2022). Kullanılan bu metotlar ile büyük veri setleri analiz edilerek kısa sürede daha etkin ve daha doğru kararlar verilebilmektedir. Makine öğrenimi zamanla oluşan verileri analiz ederek gelecekte meydana gelebilecek verileri tahmin eden modeller yaratmak için çeşitli algoritmaları kapsamaktadır (Arumugam vd. 2022). Makine öğrenmesi de Şekil 4'te görüleceği gibi alt alanlarda incelenebilir. Literatürdeki özellikle denetimli, denetimsiz ve pekiştirmeli öğrenme olarak üç ana başlık altında incelenmektedir.

2.1.1 Denetimli Makine Öğrenmesi

Bu çalışmada denetimli makine öğrenmesi ile çalışılacak olması nedeniyle bu kapsamdaki yöntemler üzerine odakla-

nılacaktır. Bir sistemin bilinen bir girdi seti ile bunlara denk gelen çıktıları alıp algoritmanın daha önce hiç görmediği yeni verilere en uygun çıktıları üretmek için kullanılan bir makine öğrenmesi modelidir (Kızılkaya ve Oğuzlar 2018). Bu tarz öğrenme metodunda, tahminleme yapılabilmesi için sınıflandırma ve regresyon teknikleri kullanılmaktadır. En kritik nokta etiketli veri kümesinin kullanılmasıdır. Bu veriler, sisteme daha önce tüm özellikleri ve örüntüleri ile tanımlanmış spesifik datalardır. Algoritma; etiketlenmiş, tanımlı eğitim verileri üzerinden girdi datalarını bir çıktı verisi ile ilişkilendirmek için arka planda fonksiyonlar bulmaya çalışır. Burada amaç, algoritmanın girdi ile çıktı arasında en iyi korelasyonu sağlayarak en iyi tahmini gerçekleştirmesidir. Denetimli öğrenme, genellikle sınıflandırma ve regresyon kökenli problemlere uygulanmaktadır. Buradaki temel fark; regresyon sıcaklık, nem, yaş, titreşim gibi kendini tekrar eden sürekli değerleri tahmin etmek için kullanılırken; sınıflandırma ise doğru veya yanlış, iyi ya da kötü, uygun ya da uygun değil gibi birbirinden bağımsız ayrık değerleri tahmin etmek için kullanılmasıdır.



Şekil 4. Yapay zeka disiplinleri (Arumugam vd. 2022).

Regresyon algoritmaları, bir sistemdeki girdi verileri ile çıktı verileri arasındaki korelasyonu modelleyen istatistiksel bir yaklaşımdır. Regresyon analizinde bu korelasyonu tahmin etmek için istatistiğin birçok yöntemi kullanılmaktadır. En yaygın kullanılan regresyon yöntemleri; doğrusal regresyon, lojistik regresyon, kademeli regresyon ve sinir ağları şeklinde ifade edilebilir.

Sınıflandırma algoritmaları, bir makine öğreniminde, bir veri kümesini farklı parametrelere bağlı olarak sınıflara ayırmayı amaçlamaktadır. Endüstriyel uygulamalarda genellikle doğru/yanlış, uygun/uygun değil ya da herhangi bir ekipmanın arızalı ya da değil olarak sınıflandırılması yaygın olarak kullanılmaktadır. Sınıflandırma yöntemlerinde genellikle DT, KNN, NB, SVM ve RF algoritmaları tercih edilmektedir. Bu çalışma kapsamında da kullandığımız sınıflandırma algoritmaları aşağıda kısaca özetlenecektir.

Karar Ağaçları Algoritması

Karar ağaçları algoritması (DT), veri madenciliğinde uygulamasının ve anlaşılmasının kolay olması sebebiyle literatürde yaygın olarak kullanılan bir sınıflandırma algoritmasıdır (Güvenç vd. 2022). Hem regresyon hem de sınıflandırma problemlerini çözmek için kullanılan en popüler denetimli makine öğrenme yöntemlerinden biridir. Verileri daha küçük alt kümelerle ayıran ve girdi özelliklerine dayalı bir dizi kararı takip ederek bir tahminde bulunan ağaç tabanlı bir modeldir. Veride bulunan her bir öznitelik, sınıflandırma sonrasında ağaçta bir düğüm noktasını temsil etmektedir (Pala vd. 2019). Kök düğüm, dal ve yaprak düğümler, karar ağaçlarının temel bileşenleri olup karar verme süreci

kök düğümlerden yaprak düğümlere doğru ilerler (Dişli vd. 2023). Giriş verisinin bir gruplandırma algoritması aracılığıyla adım adım gruplara bölünmesine dayanır. Gruptaki tüm elemanlar aynı sınıf etiketine sahip olana dek gruplandırma işlemi devam eder. Literatürde en sık kullanılan DT algoritmaları ID3, C4.5, CHAID, CART algoritmalarıdır (Güvenç vd. 2022).

En Yakın Komşu Algoritması

K-en yakın komşu (KNN) algoritması, örnekleri uzayda noktalar olarak temsil edilen bir veri seti üzerinde sınıflandırma veya regresyon görevleri için kullanılan denetimli bir makine öğrenme algoritmasıdır (Yapıcı vd. 2024). Temel çalışma prensibi sınıflandırılmamış örneklerin, en yakın komşularının bulunmasına ve benzer sınıflara göre tahminlerde bulunmasına dayanmaktadır. Algoritma, mevcut tüm verileri analiz ettikten sonra yeni bir veri noktası için bu veri kümesindeki mesafe açısından kendisine en yakın K veri noktasını bularak çalışma yapar. En yakın komşuları bulmak için veri setini tek tek taramak algoritmanın performansını düşürdüğü için tembel öğrenme yöntemi olarak da adlandırılır (Güvenç vd. 2022). Bu nedenden dolayı KNN algoritması, büyük kapasiteli verilerde (big data) yavaş bir çalışma prosesine sahiptir. KNN algoritması, belirli bir sınıfa atanmamış bir veriyi önceden sınıflandırılmış verilerden herhangi birisine olan uzaklığını referans alarak atama işlemi gerçekleştirir. Sınıflandırılacak noktaya en yakın sınıf ve komşu noktaların mesafeleri Öklid uzaklığı kullanılarak hesaplanır. KNN algoritması, diğer denetimli metotlardan farklı olarak eğitim setine sahip değildir. Bu nedenle eğitim ve test verileri hemen hemen aynı kümedir. Eğitim ve test

verilerinin aynı olmasından dolayı büyük veri kümelerinin analizi ve işlenmesinde genellikle tercih edilmemektedir.

Naive Bayes Algoritması

Adını ünlü matematikçi Thomas Bayes'den alan bir sınıflandırma algoritmasıdır. NB sınıflandırması, olasılık ilkelerine göre tanımlanmış bir dizi hesaplama ile sisteme sunulan verilerin sınıfını tespit etmeyi amaçlar (Rochim vd. 2021). Algoritma, bir veri için tüm olasılıkları hesapladıktan sonra olasılık değeri en yüksek çıkan sonuca göre diğer verilerin sınıflandırma işlemini gerçekleştirir. Olasılığa dayalı bir sınıflandırma yaptığı için tembel bir öğrenme metodudur. İstatistik ve bilgisayar bilimi literatüründe, NB modelleri, Simple Bayes ve Independent Bayes dahil olmak üzere çeşitli isimler altında bilinir ve bütün bu isimler, sınıflandırıcının karar kuralında Bayes teoreminin kullanımına atıfta bulunmaktadır (Güvenç vd. 2022).

Destek Vektör Makinesi Algoritması

SVM sınıflandırıcısı, istatistiksel yöntemleri kullanan güçlü bir lineer olamayan sınıflandırıcıdır (Dişli vd. 2023). SVM algoritması, verilerin sınıflandırma problemlerini çözmek için kullanılmaktadır. Problem çözümü sürecinde bu algoritma, karar sınırı (decision boundary) olarak tanımlanan bir hiper düzlem oluşturur ve düzlemin her iki tarafındaki iki veri sınıfını ayırır. Destek vektör makinesi, destek vektörleri olarak adlandırılan uç vektörleri seçerek bunların hiper düzlemi oluşturulmasına katkıda bulunur. İki sınıfı en iyi ayıran doğrunun bölgeler arasında kaldığı alana margin denir (Kartal 2020). Margin ne kadar geniş olursa, SVM algoritması iki veri sınıfını o kadar doğru ve net ayırmaktadır. SVM algoritması, NB algoritmasına göre daha hızlı tahmin yapar ve daha yüksek skorlu doğruluk sunmaktadır. SVM algoritmasının bazı dezavantajları da bulunmaktadır. Algoritmanın eğitim süresi yüksek olduğu için büyük veri (big data) kümeleri için uygun değildir.

Rastgele Orman Algoritması

Rastgele ormanlar veya rastgele karar ormanları, eğitim zamanında çok sayıda karar ağacı oluşturarak çalışan, sınıflandırma, regresyon ve diğer görevler için bir topluluk öğrenme yöntemidir (Güvenç vd. 2022). Bu algoritma, basitliği ve kullanılabilirliği nedeniyle hem "sınıflandırma" hem de "regresyon" için en yaygın kullanılan makine öğrenimi algoritmalarından biridir (Nahzat ve Yağanoğlu 2021). RF algoritması pek çok özelliğe ve kayda sahip verilerde tahmine dayalı modeller için başarılı sonuçlar veren bir denetimli öğrenme algoritmasıdır (Hatipoğlu vd. 2024). Algoritma içerisinde kullanılan ağaç sayısı arttıkça doğruluğa yaklaşım

oranı da artmaktadır. DT ile arasındaki ana fark, RF algoritmasında kök düğümü bulma ve düğümleri ayırma işlemlerinin rastgele olmasıdır. RF algoritmasında tek bir ağaçtan ziyade birden fazla ağaç yetiştirilerek süreç yürütülmektedir. Sınıflandırma söz konusu olduğunda algoritmanın oluşturduğu ormanlardaki tüm ağaçlar içerisinde en çok oyu alan seçilmektedir. Bu özellikler, algoritmanın kararlılığını artırarak sınıflandırma ve regresyon problemlerinin çözümü için kullanılabilir.


Extreme Gradient Boosting (XGBoost) Algoritması

XGBoost, Gradient Boosting algoritmasının bazı regülasyon çalışmaları ile kararlı hale getirilmiş yüksek performanslı biçimidir. Bu algoritma, 2016 yılında Tianqi Chen ve Carlos Guestrin'in yayınladıkları makale ile ilk kez ortaya çıkmıştır. DT tabanlı bir algoritma olan XGBoost; yüksek tahmin gücü elde edebilmesi, aşırı öğrenmeye gereksinim duymaması, boş verileri dahi yönetebilmesi ve tüm bunları hızlı bir şekilde yapabilmesi ile diğer algoritmalarından ayrılmaktadır. Daha verimli hesaplama yöntemleri kullanarak eğitim sürecini hızlandıran XGBoost, paralel hesaplama yetenekleri sayesinde özellikle büyük veri setlerinde daha yüksek performanslar sergilemektedir (Yapıcı vd. 2024). Şekil 5'te karar ağacı algoritmalarının zaman içinde XGBoost algoritmasına dönüşümü görülmektedir. XGBoost'un geliştirilmesi, veri bilimciler tarafından halen devam etmektedir ve Github'ta 500'den fazla katılımcısı, 5400'den fazla kod eklemesi bulunmaktadır (Kelle ve Yüce 2022).

XGBoost, veri kümesindeki her değişkene göre kazanç skorunu en yüksek yapacak şekilde olası tüm senaryolarda karar ağaçları kurar. XGBoost, ağacı oluştururken maksimum derinlik değerini kullanır. Oluşturulan ağaç aşağı yönde aşırı ilerleme gösterirse, budama gerçekleştirilir. Aşırı öğrenmenin önüne geçilir (Kelle ve Yüce 2022). XGBoost algoritması, verideki her değeri analiz etmek yerine veriyi parçalara bölerek çalışmaktadır. Böylece parça miktarı arttırıldıkça algoritma daha küçük aralıklara bakacağı için daha iyi tahminleme skorlarına sahip olabilmektedir.

3. Bulgular ve Tartışma

Bu çalışmada altı öznelikten oluşan (ortam sıcaklık, ortam nem, redüktör sıcaklık, redüktör nem, motor sıcaklık ve motor nem) toplam 3124 data NB, DT, RF, SVM, KNN ve XGBoost gibi denetimli öğrenme algoritmaları aracılığıyla %30'u test, %70'i eğitim verisi olacak şekilde analiz edilerek arıza kestirimi konusunda performans skorları karşılaştırılmıştır. Modelin çıktısı olarak dört ayrı sınıf, Çizelge 2'deki gibi belirlenmiştir.




Şekil 5. Karar ağacı algoritmalarının XGBoost'a Evrimi (Kelle ve Yüce 2022).


Çizelge 2. Modelde kullanılan sınıf tanımlamaları.

Class 0	Arıza yok. Her şey normal.
Class 1	Kısa duruş var.
Class 2	Uzun duruş yakında.
Class 3	Uzun duruş var.


NB algoritmasında, ilk aşamada altı özneliliğin önem derecesi belirlenmiştir. Şekil 6'da görüleceği üzere redüktör vibrasyon (RedVib) ve motor vibrasyon (MVib) değerleri tahminleme konusunda ön plandadır. Şekil 7'de motor vibrasyon değerlerinin redüktör vibrasyon değerleri ile değişimine bakılarak verilerin sınıflandırılmasında iki titreşim değerinin etkisi görülmektedir.




Şekil 6. NB öznelilik önem derecesi.



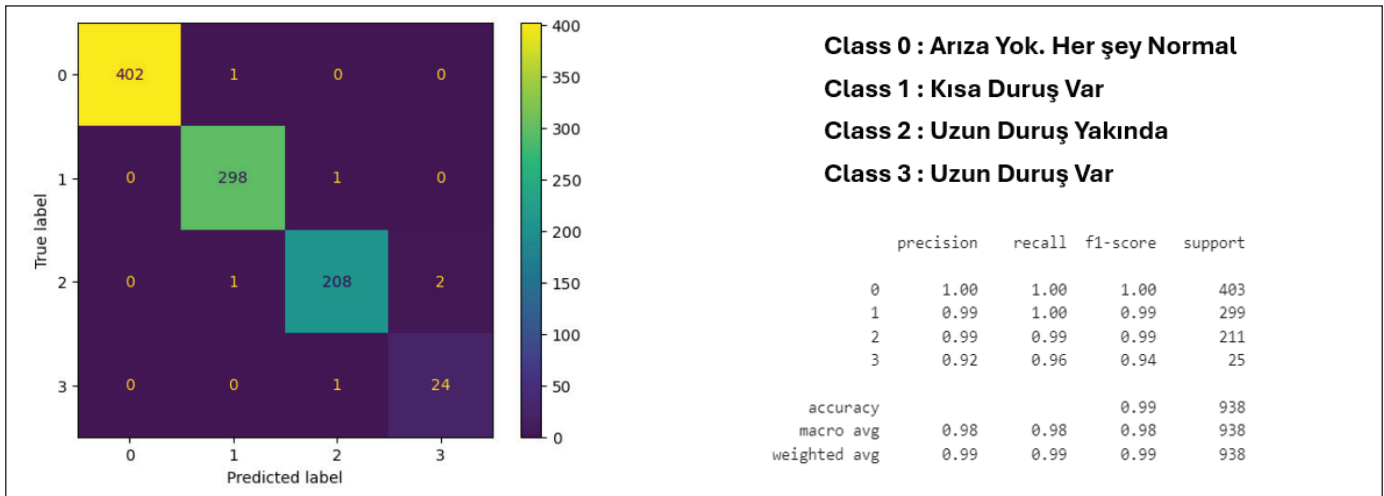
Şekil 7. Motor ve redüktör vibrasyon değişimi.



Şekil 8. Motor vibrasyon ve motor gövde sıcaklık değişimi.



Şekil 9. NB karışıklık matrisi ve değerlendirme metrikleri.




Şekil 10. DT karışıklık matrisi ve değerlendirme metrikleri.


Şekil 8'de sınıflandırma aşamasında motor gövde sıcaklık değerinin bir etkisinin olmadığı, motor vibrasyon şiddetinin arttıkça ölçülen verilerin sınıflandırmasının değiştiği görülmektedir. NB algoritmasının karışıklık matrisi ve skor metrikleri Şekil 9'da yer almaktadır.

DT algoritması ile aynı veriler analiz edildiğinde Class 0 (arıza yok) verilerini NB algoritmasına göre daha başarılı tahmin ettiği Şekil 10'da yer alan karışıklık matrisinde görülmektedir. Diğer sınıflarda NB göre yakın sonuçlar vermiştir.

RF algoritması ile yapılan çalışmada özneliliklerin önem derecesi belirlenmiştir. Yapılan analizde Şekil 11'de görüleceği üzere redüktör vibrasyon ve motor vibrasyon değerleri daha ön plana çıkmıştır.



Şekil 11. RF öznelilik önem derecesi.



Şekil 12. RF karışıklık matrisi ve değerlendirme metrikleri.

RF algoritmasının karışıklık matrisi ve verileri tahmini aşamasında gösterdiği performans çıktıları Şekil 12'de görülmektedir. RF metodu, gerçekte Class 3 sınıfına ait verileri Class 2 olarak tahminlemiştir. Bu yönden bakıldığında Class 2 ve Class 3 verilerinin ayrımını tam olarak yapamamıştır. Diğer sınıflandırmalarda başarılı bir tahmin yürütmüştür.


KNN algoritması ile ölçülen veriler analiz edildiğinde sisteme tanınan komşu sayısının doğruluk metriğine etki ettiği görülmüştür. Şekil 13'teki grafiğe bakıldığında komşu sayısı arttıkça algoritmanın doğruluk skoruna olumsuz etkilediği çıkarımı yapılabilmektedir. Literatür çalışmaları incelendiğinde ters korelasyon etkisinin farklı bir çalışmada da (Mohammedi 2019) ortaya çıktığı görülmektedir.

KNN algoritmasının karışıklık matrisi ve skorları Şekil 14'te görülmektedir. Buna göre algoritmanın Class 0-1-2 (arıza yok, kısa duruş, uzun duruş yakında) verilerinde tahmin performansının yüksek ancak önem derecesinin kritik olduğu, duruş maliyeti çıkaracak durumları ifade eden Class 3 (uzun duruş var) verilerinde düşük performans göstermiştir.

SVM algoritması ile aynı veriler %30 test verisi ve %70 eğitim verisi olacak şekilde analiz edilmiştir. Algoritmanın performans çıktıları Şekil 15'te görülmektedir.

SVM algoritmasının karışıklık matrisi incelendiğinde 0,1 ve 2 sınıflarına ait tahminleme skorunun KNN algoritması kadar başarılı olduğu Class-3 verilerinde ise daha iyi performans gösterdiği görülmüştür.

Son aşamada sahadan alınan ölçümler sonucu elde edilen veriler XGBoost algoritması ile ele alınmıştır. Öncelikle algoritmada yer alan özneliliklerin önem derecesi belirlenmiş-




Şekil 13. KNN algoritmasında komşu sayısı ve doğruluk değeri değişimi.


tir. Şekil 16'da görüleceği üzere her bir özneliliğin algoritmanın vereceği kararlar içinde etkisi bulunmaktadır.

XGBoost algoritmasının Şekil 17'de yer alan skorları incelendiğinde ele alınan tüm denetimli öğrenme yöntemleri arasında en başarılı performans gösteren algoritma olduğu görülmektedir. Özellikle uzun duruşlara neden olacak arızaları temsil eden Class-3 verilerini tahminleme konusunda DT algoritmasına göre çok daha iyi bir başarı ortaya koymuştur.


Yapılan arıza analizi çalışmasında kullanılan denetimli öğrenme algoritmalarından en başarılı sonucu Çizelge 3'te görüleceği üzere XGBoost algoritması vermiştir.



Şekil 14. KNN karışıklık matrisi ve değerlendirme metrikleri.



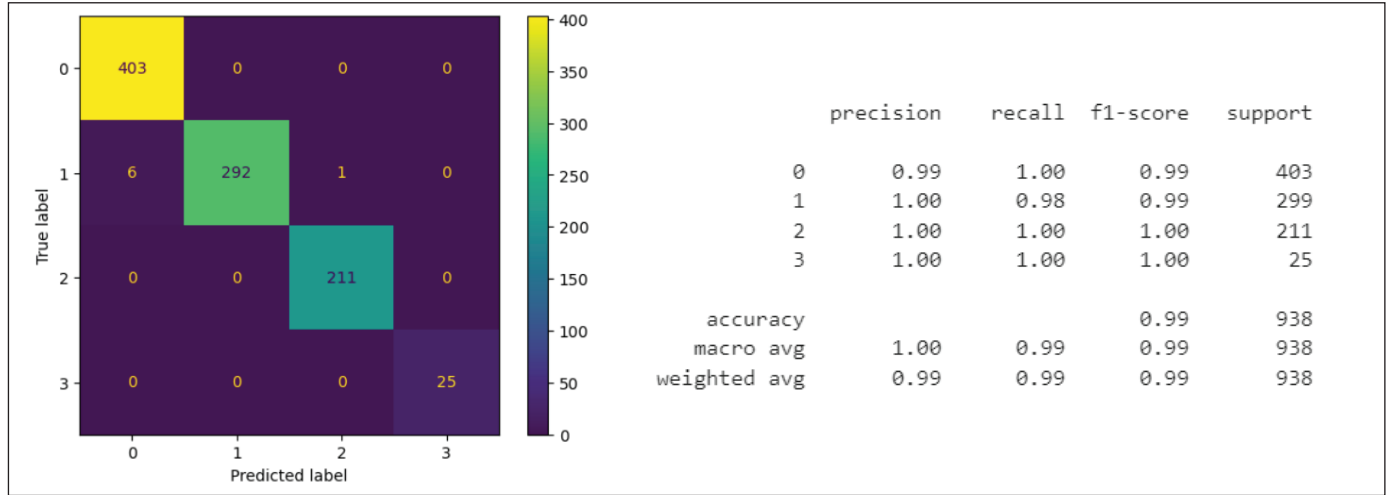
Şekil 15. SVM karışıklık matrisi ve değerlendirme metrikleri.




Şekil 16. XGBoost algoritmasında öznetelik önem derecesi.

Çizelge 3. Denetimli öğrenme algoritmalarının performans sonuçları.

Algoritma	Accuracy	Recall	Precision	F1-Score
KNN	0.95	0.95	0.95	0.94
Naive Bayes	0.97	0.97	0.97	0.97
SVM	0.97	0.97	0.97	0.97
Decision Tree	0.99	0.99	0.99	0.99
Random Forest	0.96	0.96	0.93	0.94
XGBoost	0.99	0.99	0.99	0.99




Şekil 17. XGBoost karışıklık matrisi ve değerlendirme metrikleri.



Şekil 18. Kullanılan algoritmaların performans metrikleri.

Şekil 18'de yer alan grafiğe de bakıldığında en yüksek skorun DT ve XGBoost algoritmalarına ait olduğu görülmektedir. Ancak bir alt başlık altında tekrar bu iki algoritma karşılaştırıldığında, uzun duruşlara neden olan Class-3 verilerini tahmin etme açısından XGBoost algoritması bir adım öndedir. XGBoost; DT tabanlı bir algoritma oluşu, aşırı öğrenme ihtiyacı olmaması ve veri kümesinde yer alan boş ya da anlamsız verileri dahi yönetebilmesi gibi özellikleri ile ön plana çıkmaktadır. Ayrıca her veriyi analiz etmek yerine onları parçalara bölerek çalışma mantığına sahiptir. XGBoost algoritmasının yüksek skorlar elde etmesi bu özellikleri ile yorumlanabilir. Verileri oluşturan özniteliklerin önem değerine bakmaksızın tümünü ön planda tutması da bu performansını olumlu yönde etkilemiştir.



Şekil 19. Pearson korelasyonu ile öznitelikler arası önem karşılaştırması.

Özniteliklerin kendi arasındaki önem ilişkisi Pearson korelasyonu yöntemi ile belirlenmiştir. Şekil 19'a bakıldığında motor vibrasyon (MVib) ve redüktör vibrasyon (RedVib) değerleri ile motor sıcaklık (MSic) ve redüktör sıcaklık (RedSic) değerlerinin bire yakın olduğu görülmektedir. Korelasyon değeri bire ne kadar yakın ise özniteliklerin o derece önemli olduğu, negatif veya sıfıra yakın ise önem derecesinin yok denecek kadar az olduğunu ifade etmektedir.

Bu grafikten de anlaşılabacağı gibi yapılan arıza analizi çalışmasında motor ve şanzıman grubunun yer aldığı ortam sıcaklık ve nem değerlerinin arıza tahminleme modeline etkisinin oldukça az olduğu görülmüştür. Spesifik çalışmalar dışında herhangi bir dişli veya asenkron motora ait arıza



Şekil 20. Uzun duruşa (Class 3) sebep olan dişli arızası.

analizinde ortam sıcaklık ve nem değerlerinin göz önünde bulundurulmasının sisteme herhangi bir etkisinin olmayacağı çıkarımı yapılabilir.

Şekil 20’de görüldüğü gibi dişli sıyırması sonucu gerçekleşen arızaların ortam sıcaklık ve nem değerleri ile değil, helezon sisteminin taşıdığı mekanik yükün anormal artışı ve bu durum, dişli ya da motor gövdesinde titreşim ve sıcaklığın artması olarak karşımıza çıkmaktadır.

4. Sonuç ve Öneriler

Endüstriyel işletmelerde üretim tesislerinin yüksek verimle çalışması ve sürekliliği her zaman ön planda olmuştur. Tesisin herhangi bir ekipmanında oluşabilecek bir arıza, üretim ve zaman kaybına neden olabilir. Arıza sonucu üretim, iş gücü ve zaman kayıplarının yaşanmaması için tesise ait ekipman bakımlarının planlanması gerekmektedir. Teknoloji alanındaki gelişmeler ile kestirimci ya da uyarıcı bakım olarak da bilinen bakım yöntemleri, planlı bakım uygulamalarında önemli bir yer edinmiştir. Kestirimci bakım yönteminde amaç, herhangi bir ekipman üzerinde oluşabilecek bir arızayı gerçekleşmeden önce tespit edebilmektir. Bu çalışmada belirli bir zaman aralığında ölçülen 3124 veri, bazı denetimli öğrenme yöntemleri kullanılarak incelenmiştir. Bu verilerin analizi ile üretim hattında yaşanabilecek uzun duruşların önceden tahminlemesi yapılmıştır. Tahminleme çalışmalarında denetimli öğrenme yöntemlerinden KNN, NB, SVM, DT, RF ve XGBoost metotları kullanılarak veriler ele alınmıştır. Çalışmalar esnasında algoritmalarda girdi olarak

kullanılan özniteliklerin sınıflandırma sürecindeki etki katsayısı da Pearson korelasyon yöntemi ile tespit edilmiştir. Yapılan analiz çalışmalarında XGBoost algoritmasının performans skoru diğer metotlar ile karşılaştırıldığında %99 ile daha yüksek çıkmıştır. Özellikle uzun duruşlara neden olan arıza verilerinin etiketlendiği Class 3 sınıfına ait durumların tamamını doğru tahmin etmesi ile DT algoritmasından bir adım önde olduğu görülmüştür. Helezon dişlisinin sıyırması ya da mil üzerinden çıkması kaynaklı arızaların ön görülmesi ile hem yaklaşık üç saate varan duruşların hem de üretim hattı kapasitesinin yaklaşık 2400 kg/h olduğu düşünüldüğünde 7200 kg’lık üretim kaybının önüne geçilmiştir. Veri depolama (server, Cloud vb.) üzerinde altyapı çalışmaları yapılarak TCP/IP haberleşme protokolü aracılığıyla endüstriyel işletmelerin kritik kontrol noktalarında sürekli veri takip ve izleme sistemleri oluşturulabilir. Böylece birçok yerden veriler alınarak yapılan bu izleme sistemi ile işletmenin birden fazla noktasında geniş kapsamlı ve birçok alanda uygulanabilir bir arıza analiz sistemi etkin bir hale getirilebilir.

Teşekkür: Makalenin oluşturulması sürecinde yapılan saha çalışmalarına verdikleri katkıdan dolayı Kervan Gıda San. Ve Tic. AŞ’ye teşekkür ederiz.

Yazar katkısı: İlyas Güvenç Pirge çalışma hakkında verileri toplamış ve analiz etmiştir, çalışmanın analizlerini yaparak makaleyi yazmıştır, İlhan Baştürk çalışmanın danışmanlığını yapmış ve makaleyi yazmıştır.

Etik kurul onayı: Etik kurul onayı gerekmiyor.

5. Kaynaklar

- Akyaz, T. 2022.** Bilgisayar Destekli Kestirimci Bakım Sisteminin Tasarlanması. Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Ana Bilim Dalı, İzmir, 74.
- Arumugam, K., Swathi Y., Sanchez DT., Mustafa M., Phoemchalard, C., Phasinam, K., Okoronkwo, E. 2022.** Towards Applicability of Machine Learning Techniques in Agriculture and Energy Sector. Materials Today: Proceedings, 51:2260–2263. Doi: 10.1016/j.matpr.2021.11.394
- Asadzade, A. 2020.** Predictive Maintenance For Smart Industry. Mühendislik ve Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İzmir, 51.
- Atapek, A. 2022.** Kestirimci Bakım Metotları ile Arızaların Tespit Edilmesi ve J79 Turbojet Uçak Motorlarında Kestirimci Bakım Uygulamaları. Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Bölümü, İstanbul, 127.
- Ayan, ÖA. 2019.** Döner Makine Elemanların Titreşim Analizi İle Kestirimci Bakımı. Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Edirne, 82.
- Baykara, Vİ. 2009.** Titreşim Analizi ile Şanzımanlarda Arıza Teşhisi ve Kestirimci Bakım. Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Zonguldak, 81.
- Carvalho TP., Soares, FA., Vita, R., Francisco RDP., Basto, JP., Alcala, SG. 2019.** A Systematic Literature Review of Machine Learning Methods Applied To Predictive Maintenance. Computers & Industrial Engineering, 137. Doi: 10.1016/j.cie.2019.106024
- Ceyhan, H. 2022.** Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım Uygulaması ve Modellemesi. Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Ana Bilim Dalı, İstanbul, 62.
- Cortadi, AJ., Irigoien I., Boto, F., Sierra, B., Rodriguez, G. 2020.** Predictive Maintenance on the Machining Process and Machine Tool. Applied Sciences, 10(1): 224. Doi: 10.3390/app.10010224
- Dişli, F., Gedikpınar M., Şengür A. 2023.** Kırık Rotor Çubuğu Sayısının Ampirik Mod Yaklaşımı ve Makine Öğrenmesi Yaklaşımları ile Belirlenmesi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 35(2): 783-795. Doi:10.35234/fumbd.1289156
- Güler, O. 2024.** Turbo Fan Motorlarının Kestirimci Bakımında Makine Öğrenimi Algoritmaları Performanslarının Karşılaştırılması. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 13(1): 99-106. Doi: 10.28948/ngu-muh.1266541.
- Güvenç, E., Sakal, M., Çetin, G., Özkaraca O. 2022.** Öğrencilerin Dersteki Niteliklerinin Makine Öğrenmesi Teknikleri Kullanılarak Sınıflandırılması. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 10: 1359-1371. Doi:10.29130/dubited.1017202
- Hatipoğlu, A., Güneri, Y., Yılmaz, E. 2024.** A Comparative Predictive Maintenance Application Based on Machine and Deep Learning. Journal of the Faculty of Engineering and Architecture of Gazi University, 39(2): 1037-1048. Doi: 10.17341/gazimmfd.1221105
- Kalemoğlu, Y. 2023.** Haddehanelerde Sıcaklık Ve Titreşim Ölçümü İle Kestirimci Bakım Uygulamaları. Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Karabük, 76.
- Karadayı, MH. 2011.** Titreşim Analizi İle Pompalarda Arıza Tespiti ve Kestirimci Bakım Uygulamaları. Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Balıkesir, 95.
- Karagöz, O. 2024.** Yapay Zekanın Hava Araçlarında Bakım ve Arıza Giderme Sürecindeki Etkisi. The Journal of Academic Social Science, 156: 353-371. Doi:10.29228/ASOS.77613
- Kartal, C. 2020.** Destek Vektör Makineleri ile Borsa Endekslerinin Tahmini. İnsan ve Toplum Bilimleri Araştırmaları Dergisi, 9(2): 1394-1418. Doi: 10.15869/itobiad.673015
- Kelle, AC., Yüce, H. 2022.** MQTT Trafiğinde DoS Saldırılarının Makine Öğrenmesi ile Sınıflandırılması ve Modelin SHAP ile Yorumlanması. Journal of Materials and Mechatronics: A (JournalMM), 3(1): 50-62. Doi: 10.55546/jmm.995091
- Kızılay, E. 2022.** Demiryolu Makas Motorlarının Kontrolü, Kestirimci Bakım ve Emniyet Analizi. Fen Bilimleri Enstitüsü, Elektrik Mühendisliği Ana Bilim Dalı, İstanbul, 70.
- Kızılkaya, MY., Oğuzlar A. 2018.** Bazı Denetimli Öğrenme Algoritmalarının R Programlama Dili ile Kıyaslanması. Karadeniz Uluslararası Bilimsel Dergisi, (37): 90-98. Doi: 10.17498/kdeniz.405746
- Köprü, T. 2022.** Kestirimci Bakım Zamanlarının Makine Öğrenmesi Yöntemleriyle Tahminlenmesi: Demir Çelik Sektöründe Bir Uygulama. Lisansüstü Eğitim Enstitüsü, Endüstri Mühendisliği Ana Bilim Dalı, Karabük, 80.
- Kulluk, S., Torun, H., Ay, MM., Akargöl, İ. 2024.** Kestirimci Bakımda Makine Öğrenmesi: Sayısal Bir Vaka Çalışması. Sivas II. International Conference on Scientific and Innovation Research 15-17 September.
- Mohammedi, MM. 2019.** Development of Condition Prediction Models for Sanitary Sewer Pipes. The University of Texas at Arlington.
- Nahzat, S., Yağanoğlu M. 2021.** Diabetes Prediction Using Machine Learning Classification Algorithms. European Journal of Science and Technology, (24): 53-59. Doi: 10.31590/ejosat.899716
- Orhan, S. 2002.** Rulmanlarla Yataklanmış Dinamik Sistemlerin Titreşim Analizi İle Kestirimci Bakımı. Fen Bilimleri Enstitüsü, Makine Ana Bilim Dalı, Kırıkkale, 161.

- Pala, MA., Çimen, ME., Boyraz ÖF., Yıldız, MZ., Boz, AF. 2019.** Meme Kanserin Teşhis Edilmesinde Karar Ağacı ve KNN Algoritmalarının Karşılaştırmalı Başarım Analizi. Academic Perspective Procedia, 2(3): 544-552. Doi: 10.33793/acperpro.02.03.47
- Ramachandran, KK., Mary, AAS., Hawladar, S., Asokk, D., Bhaskar, B., Pitroda, JR. 2022.** Machine Learning And Role of Artificial Intelligence in Optimizing Work Performance and Employee Behavior. Materials Today: Proceedings, 51: 2327-2331. Doi: 10.1016/j.matpr.2021.11.544
- Rochim, AF., Kusumastuti, R., Windasari, IP. 2021.** Comparison of Feature Selection for Naive Bayes Classification Method in A Case Study of The Corona Virus Lockdown. International Conference on Data Science and Its Applications, 215-220. Doi: 10.1109/ICoDSA53588.2021.9617471
- Sındır, E. 2022.** Endüstride Kullanılan Asenkron Bir Motorda Bulanık Mantık Temelli Kestirimci Bakım Uygulaması. Lisansüstü Eğitim Enstitüsü, Elektrik Elektronik Mühendisliği Ana Bilim Dalı, Hatay, 83.
- Şahin, M. 2022.** Makine İmalat Sektöründe Kullanılan Takım Uçları İçin Yapay Zeka İle Kestirimci Bakım Uygulamaları. Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Tekirdağ, 54.
- Yapıcı, İS., Arslan, RU., Er kaymaz O. 2024.** Kalp Yetmezliği Tanılı Hastaların Hayatta Kalma Tahmininde Topluluk Makine Öğrenme Yöntemlerinin Performans Analizi. Karaelmas Fen ve Mühendislik Dergisi, 14(1): 59-69. Doi: 10.7212/karaelmasfen.1429458
- Tuncer, K. 2022.** Durum Bazlı Kestirimci Bakım Yöntemlerinden Titreşim Analizi İle Fanlardaki Dengesizlik Arızasının Tespiti ve Bakımı. Eğitim Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı, Kayseri, 130.
- Wuest, T., Weimer, D., Irgens, C., Thoben, K. 2016.** Machine Learning in Manufacturing: Advantages, Challenges, and Applications. Production & Manufacturing Research, 4(1): 23-45. Doi: 10.1080/21693277.2016.1192517