

KESTİRİMCİ BAKIMDA MAKİNE ÖĞRENMESİ: LİTERATÜR ARAŞTIRMASI

Damla Rana DÜNDAR^{1*}, İnci SARIÇİÇEK², Eyüp ÇINAR³, Ahmet YAZICI⁴

¹ Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Endüstri Mühendisliği, Eskişehir, ORCID No : <http://orcid.org/0000-0002-9286-2817>

² Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Endüstri Mühendisliği, Eskişehir, ORCID No : <http://orcid.org/0000-0002-3528-7342>

³ Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği, Eskişehir, ORCID No : <http://orcid.org/0000-0003-3189-7247>

⁴ Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği, Eskişehir, ORCID No : <http://orcid.org/0000-0001-5589-2032>

Anahtar Kelimeler	Öz
Kestirimci Bakım Makine Öğrenmesi Derin Öğrenme	Endüstriyel sistemlerdeki makine arızalarını önleyerek üretimde oluşabilecek kesintilerden kaçınmak ve ilgili maliyetleri azaltmak etkin bir bakım yönetimi ile mümkündür. Etkin bakım yönetimi önleyici, düzeltici ve kestirimci bakım stratejilerinin yönetilmesi faaliyetlerini içermektedir. Sensör ve bilgisayar teknolojisindeki son gelişmelerle kestirimci bakım çalışmaları işletmeler için önem kazanmıştır. Veriye Dayalı makine öğrenimi algoritmalarının yardımıyla güçlendirilen kestirimci bakım sistemleri, yeni üretim sistemlerinin bir parçası olarak geliştirilir. Bu çalışma, makine öğrenmesi algoritmalarına dayalı kestirimci bakım ile ilgili literatürün bir incelemesidir. Çalışmalar kullanılan makine öğrenmesi algoritmaları ve çalışmaların gerçekleştirildiği endüstri/ekipman kapsamında analiz edilmiştir. Literatürde kestirimci bakımda makine öğrenmesi algoritmalarını kullanan çalışmaları derleyen ve analiz eden çok az çalışma olup bu çalışma ilgili konuda çalışacak araştırmacılara yol gösterecektir.

MACHINE LEARNING IN PREDICTIVE MAINTENANCE: LITERATURE RESEARCH

Keywords	Abstract
Predictive Maintenance Machine Learning Deep Learning	By preventing machine failures in industrial systems, avoiding interruptions that may occur in production is possible with an effective maintenance management. Effective maintenance management includes the activities of managing preventive, corrective and predictive maintenance sites. With the latest developments facilitated by sensor and computer technologies, predictive maintenance studies have gained importance for businesses. Empowered with the help of data-driven machine learning algorithms, predictive maintenance systems are developed as a part of new manufacturing systems. This study is a review of the literature on predictive maintenance based on machine learning algorithms. The studies are analyzed within the scope of employed machine learning algorithms and related industry/equipment where the studies are carried out. There are very few work in the literature that compile and analyze studies using machine learning algorithms in predictive maintenance, so this study will guide researchers who will work on the relevant subject.
Derleme Makalesi	Review Article
Başvuru Tarihi : 31.12.2020	Submission Date : 31.12.2020
Kabul Tarihi : 13.06.2021	Accepted Date : 13.06.2021

* Sorumlu yazar; e-posta : ranadamla1513@gmail.com



Bu eser, Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>) hükümlerine göre açık erişimli bir makaledir.

This is an open access article under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>).

1. Giriş

Teknolojinin gelişmesi ile birlikte işletmelerde üretim, bakım, kalite gibi alanlarda verimlilik artışı hedeflenmiştir. Üretimdeki arıza nedeni ile oluşabilecek etkin olmayan süreler, üretilen ürünlerin kusurlu olması gibi unsurlar verimliliği önemli ölçüde etkilemektedir. İlgili unsurlar, doğru zamanda belirlenmiş ve uygulanmış bakım stratejisi ile ortadan kaldırılabilmektedir. Literatürde genel olarak önleyici (preventive), kestirimci (predictive) ve düzeltici (corrective) bakım olarak üç genel bakım stratejisinden bahsedilmektedir.

Son yıllarda, arızaların tespit edilmesi, sistem durumunun izlenmesi konuları yeni bir trend haline gelmiş ve kestirimci bakım konusunda akademik çalışmalar hızla artış göstermiştir. Kestirimci bakım, sistem içerisinde oluşabilecek arızaları önlemek amacıyla bakımın hangi anda yapılabileceğini tahmin etmeye odaklanır. Arızalar, kusurlu ürünler, etkin olmayan süreler gibi israfları önlemede önemli rol oynamaktadır. Bu çalışma, literatürdeki kestirimci bakımda makine öğrenmesi algoritmalarını içeren çalışmaları incelemektedir. Literatürde bu konuda terimlerin Türkçe karşılıkları ile verildiği ve başlıca tüm çalışmaların değerlendirildiği bir çalışma olmaması sebebiyle yapılan literatür araştırmasının bu konuda çalışacak araştırmacılara ışık tutması beklenmektedir.

Araştırmada "Web of Knowledge" ve "ScienceDirect" veritabanlarından anahtar kelime olarak "Predictive Maintenance" ve "Machine Learning veya Deep Learning" kelimeleri ile tarama yapılmıştır. Toplam 45 dergiye ait 83 makale incelenmiştir. Tarama sonuçlarına göre sadece makaleler derlemeye alınmış, konferans bildirileri analize katılmamıştır.

Makine öğrenmesi algoritmalarına ilişkin incelenen çalışmalarda Rassal Orman, Karar Ağacı, Yapay Sinir Ağları, Destek Vektör Makinesi, k-NN (k-Nearest Neighbors), Doğrusal Regresyon, Derin Öğrenme Algoritmalarının kullanıldığı görülmektedir. Çalışmanın izleyen kısımlarında, bakım planlamasının önemine değinilerek, üçüncü bölümde bakım yaklaşımları ve dördüncü bölümde kestirimci bakımda makine öğrenmesi algoritmalarını içeren çalışmalar verilmiştir. Beşinci bölümde literatürdeki incelenen çalışmalar, kullanılan algoritmalara ve yıllara göre gerçekleştirilen çalışma sayıları açısından değerlendirilmiştir.

2. İşletmelerde Bakım Stratejisi

Literatürde bakım politikaları olarak da adlandırılan bakım stratejileri, işletmelerdeki varlıkların, ömür sürelerince sağlık durumlarındaki devamlılığın sağlanması ve faaliyet fonksiyonlarının yerine getirilmesi için gereken parça değişimi, yenileme ve onarım gibi bakım faaliyetlerini içermektedir. Birçok araştırmacı tarafından bakım stratejileri farklı

şekillerde adlandırılmış ve sınıflandırılmıştır. Bakım stratejileri genel olarak şu şekilde sınıflandırılır (Susto, Member, Beghi ve Luca, 2012; Susto, Schirru, Pampuri, McLoone ve Beghi, 2015):

Düzeltilici Bakım (R2F-Run-to-Failure (R2F), Corrective Maintenance, Breakdown Maintenance): Literatürde arıza giderici ve acil bakım olarak da belirtilen düzeltici bakım, arıza meydana geldikten sonra ihtiyaç duyulduğunda gerçekleştirilen bir bakım stratejisidir. Oluşan arızaları gidermek için düzeltici bakım gerçekleştirilmelidir (Yu, Zhu, Chang ve Wang, 2019). Düzeltici bakımda, diğer bakım stratejilerindeki gibi bakım planlamasının yapılmasına gerek yoktur. Arıza oluşmadan önce tespit etmek için ekstra işlem yapılmaz ancak beklenmeden bir şekilde oluşan arıza sisteme büyük zararlar verebilir ve üretim programında gecikmeye neden olabilir.

Düzeltilici bakım, diğer bakım stratejilerine göre daha basit bir bakım faaliyetidir. Sadece arıza meydana geldiğinde maliyete neden olmaktadır. Bu stratejide bozulan parça yenisi ile değiştirilerek veya onarılarak arızadan sonra sistemin çalışır konuma dönmesi sağlanmaktadır. Onarım ile ekipman/sistem yenisi kadar iyi olmayabilir. Onarım maliyeti, parça değişim maliyetinden düşüktür. Ancak onarım faaliyeti, ekipman bileşenlerinin çalışma performansını etkileyerek bozulmalara neden olabilmektedir. Bu durumda bozulan parçanın onarımı ve yeni parça ile değiştirilmesi arasında bir karar verilmesi gerekmektedir. Karar vericiler maliyet ve işlevsellik konularına dikkat ederek ilgili kararı vermektedirler.

Önleyici Bakım (PvM- Preventive Maintenance): Süreç içerisinde arıza oluşmadan önce belirlenen bir zaman çizelgesine göre gerçekleştirilen bakım tekniğidir. Ekipmanların ömrünü uzatan planlı bir bakımdır. Planlanmış zaman aralığında, rutin olarak yapılmaktadır. Koruyucu bakım, planlı bakım, programlı bakım olarak da adlandırılır. Bir makinede arıza beklenmeksizin, önceden saptanmış süreler sonunda makine bakıma alınır. Önleyici bakımın amacı, arızaları maliyete yol açmadan önce tespit edip gidermektir. Önleyici bakım, ayarlama, yağlama, onarım, değişim gibi faaliyetleri içermektedir. Parçalar çalışır durumda olsa bile değiştirilebilmektedir (Köksal, 2017).

Önleyici bakımda, ekipman düzenli olarak kontrol edildiğinden dolayı bozulma riski daha azdır ve ekipman ömrü uzayacaktır. Periyodik olarak yapılacak bakım zamanları belirlidir. Ekipman için eniyi koşullar sağlanmadığında, daha fazla enerji harcanacaktır. Bakımı yapılan ekipmanlarda enerji tasarrufu sağlanacaktır. Düzenli kontroller ile herhangi bir arıza anında ne yapılması gerektiği bilinmektedir. Parçaların ömür süresi bitmeden yenisi ile değiştirilmesinden kaynaklı fazla maliyetler ortaya çıkmaktadır. Bu durum ilgili stratejinin zayıf yönü olarak belirtilebilir. Bu bakım stratejisinde arıza sıklığı karar verilmesi gereken önemli

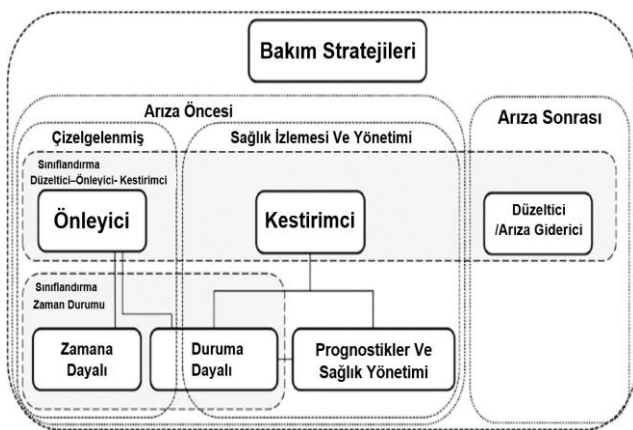
unsurlardan biridir. Diğer bakım stratejilerine göre daha fazla işgücü gerektirmektedir.

Kestirimci Bakım (PdM-Predictive Maintenance): Arıza meydana gelmeden önce bakım eylemlerinin ne zaman gerekli olduğunu ölçmeye odaklanmaktadır. Durum izlemesi ve arıza tespiti ile ilgilenmektedir. Arıza tespiti için (makine öğrenmesi algoritmaları, istatistiksel teknikler vb.) tahminleme araçları kullanılmaktadır. Ekipmanın geçmiş koşullarını izleme verilerini temel alarak, ekipmanın sağlık durumunu yansıtan özellikler, durum tahmini ve arıza teşhisi için veriye dayalı modeli oluşturmak üzere çıkarılabilmektedir (Luo, Hu, Ye, Zhang ve Wei, 2020).

Kestirimci bakım, diğer bakım stratejilerine göre daha uzun çalışma ömrü sağlamaktadır ve önleyici bakım faaliyetlerine izin vermektedir. Arızalar ile meydana gelebilecek parça/işçilik maliyetini azaltmaktadır ancak arıza teşhisi için kullanılacak ekipman yatırımını ve personel eğitimi maliyetini arttırmaktadır.

Geleneksel sınıflandırmaların yanı sıra, Şekil 1, başlangıçta iki kategori arasında stratejileri tetikleyen bakım eylemlerine göre bir sınıflandırma göstermektedir (Montero Jimenez, Schwartz, Vingerhoeds, Grabot ve Salaün, 2020).

Bakım stratejilerinden önleyici ve kestirimci bakım arıza öncesinde planlanan bakım faaliyetlerini içerirken, düzeltici bakım arızanın oluşumundan sonra gerçekleştirilen bakım faaliyetlerini içermektedir. Arızadan önce bakım eylemlerini belirlenmiş bir çizelgeye göre gerçekleştiren önleyici bakım stratejisi ile bakım eylemlerinin ne zaman yapılacağına karar verebilmek için sağlık izlemeyi kullanan kestirimci bakım stratejisi arasında ortak alt bölümler mevcuttur.



Şekil 1. Bakım Stratejileri (Montero Jimenez ve diğ., 2020)

Zamana veya kullanıma dayalı önleyici bakım (time or use based preventive maintenance) ve duruma dayalı önleyici bakım (condition based preventive

maintenance) olmak üzere iki temel strateji izlenmektedir (Montero Jimenez ve diğ., 2020). Duruma dayalı önleyici bakım, ekipmanın bilinen durumuna göre gerçekleştirilir. Ekipmanın durumuna ilişkin değerler, ekipmanın durumundan etkilenen temel ekipman parametreleri izlenerek belirlenir. Önleyici bakım stratejisi aynı zamanda kestirimci bakım olarak da adlandırılmaktadır. Rutin olarak yağlama, temizlik, parça değiştirme gibi aşınma ve bozulmayı önleyici faaliyetleri içermektedir.

Strateji olarak kestirimci bakım, düzeltici ve önleyici bakımın tamamlayıcısıdır. Kestirimci bakım, sensörlerden verilerin toplanması, sistem/ekipman durumunun izlenmesi ve verilerin işlenmesine dayanır. Bu da ekipmanın Kalan Yararlı Ömrünün (RUL - Remaining Useful Life) tahmin edilmesi, oluşabilecek arızaların tahmini, ekipmanın gelecekteki durumu hakkında bilgi sağlamaktadır. Tahminlerin yapılabilmesi için geçmişte toplanan veriler ile eğitilmiş tahmin teknikleri kullanılmaktadır. Tahmin tekniklerinden makine öğrenmesi algoritmalarının bulut tabanlı çözümler ile daha etkili çözümler sağladığı literatürde belirtilmiştir.

Kestirimci bakımın Durum Tabanlı Bakım (CBM-Condition-Based Maintenance) ve Prognostikler ve Sağlık Yönetimi (PHM-Prognostics Health Management) olmak üzere iki uzantısı bulunmaktadır. CBM geleneksel olarak zamana dayalı bakımın (time-based maintenance) karşılığı olarak belirtilmektedir (Montero Jimenez ve diğ., 2020).

Literatürde kullanılan kestirimci bakım ile ilgili bazı terimler ve anlamları Tablo 1'de verilmiştir (Tablo 1).

Tablo 1

Kısaltmalar ve Terminoloji

Kısaltma	Tanımlama
ML	Makine Öğrenmesi (Machine Learning)
PdM	Kestirimci Bakım (Predictive Maintenance)
R2F	Run-to-Failure (Düzeltilici Bakım)
PvM	Önleyici Bakım (Preventive Maintenance)
CBM	Durum Tabanlı Bakım (Condition-Based Maintenance)
PHM	Prognostikler ve Sağlık Yönetimi (Prognostics Health Management)
RUL	Kalan Faydalı Ömür (Remaining Useful Life)
CM	Durum İzleme (Condition Monitoring)
AI	Yapay Zekâ (Artificial Intelligence)
LR	Lojistik Regresyon (Logistics Regression)
DT	Karar Ağacı (Decision Tree)
NN	Sinir Ağları (Neural Networks)
SVM	Destek Vektör Makinesi (Support Vector Machine)
RF	Rassal Orman (Random Forest)
DL	Derin Öğrenme (Deep Learning)
RB	Kural Tabanlı (Rule Based)
RL	Temsili Öğrenme (Representation Learning)
PCA	Temel Bileşen Analizi (Principal Component Analysis)
DBM	Derin Boltzmann Makinesi (Deep Boltzmann Machine)
DBN	Derin İnanç Ağı (Deep Belief Network)
SAE	Yığınlı Otomatik Kodlayıcı (Stacked Autoencoder)
DAE	Derin Otomatik Kodlayıcı (Deep Autoencoder)

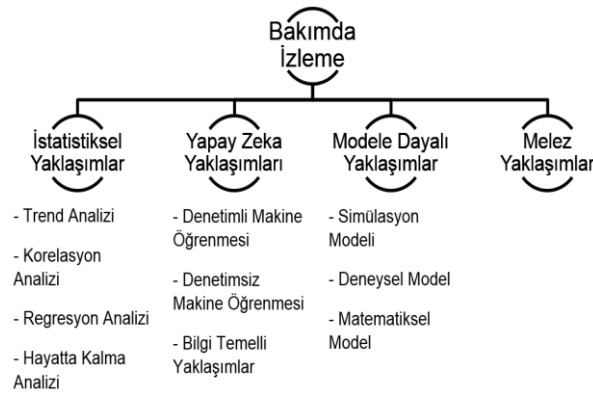
CAE	Sözleşmeli Otomatik Kodlayıcı (Contractive Auto-encoder)
VAE	Varyasyonel Otomatik Kodlayıcı (Variational Autoencoder)
RNN	Tekrarlayan Sinir Ağı (Recurrent Neural Network)
CNN	Evrişimli Sinir Ağı (Convolutional Neural Network)
DNN	Derin Sinir Ağı (Deep Neural Network)
k-NN	k- En yakın Komşu (k- Nearest Neighbor)
FNN	İleri Beslemeli Sinir Ağı (Feed-forward Neural Network)
LDA	Doğrusal Diskriminant Analiz (Linear Discriminant Analysis)
RBM	Kısıtlanmış Boltzmann Makinesi (Restricted Boltzmann Machine)
EDAE	Toplu Derin Otomatik Kodlayıcılar (Ensemble Deep Auto-encoders)
DTL	Derin Transfer Öğrenimi (Deep Transfer Learning)
DLNN	Derin Öğrenen Sinir Ağı (Deep Learning Neural Network)
LSTM	Uzun-kısa Süreli Hafıza (Long Short-term Memory)
CA	Küme Analizi (Cluster Analysis)

3. Bakım Yaklaşımlarına Genel Bakış

Jardine, Lin ve Banjevic (2006) bakımda kullanılan yaklaşımları üç ana sınıfta toplamıştır:

- İstatistiksel yaklaşımlar,
- Yapay zekâ yaklaşımları
- Model tabanlı yaklaşımlar

Wakiru, Pintelon, Muchiri ve Chemweno (2019), bakım yaklaşımları ile ilgili çalışmalara melez yaklaşımları da dâhil etmişlerdir (Şekil 2).



Şekil 2. Bakım Yaklaşımları (Wakiru ve diğ., 2019)

3.1. İstatistiksel Yaklaşımlar


Trend Analizi (Trend Analysis): Sistem durumunun değerlendirilmesi için ilgili parametreler belirlenir. Bir zaman serisi içerisindeki veriler dağılımda genel bir eğilim gösteriyorsa uygun artış – azalışları gösterecek trend doğrusu belirlenmeye çalışılır. Trend doğrusu En Küçük Kareler Yöntemi ile çizilebilmektedir. En Küçük Kareler Yöntemi, her tek denklemin sonuçlarında yapılan hataların karelerinin toplamının en aza indirildiği yaklaşımdır. Eldeki verilerin genel eğilimini temsil eden tek bir eğri türetilir.

Korelasyon Analizi (Correlation Analysis): Tek değişkenli trend analizinden farklı olarak, korelasyon katsayısını kullanarak iki farklı değişken arasındaki ilişkinin

gücünü göstermektedir (Thapliyal ve Thakre, 2017). Başka bir deyişle, olayların nasıl ilişkili olduğunun bir ölçüsüdür. Korelasyon katsayısına göre ilişkilendirme yapılmaktadır.


Literatürde, arıza teşhisi ve bakım konularında korelasyon analizini kullanan çalışmalar mevcuttur. Benítez ve diğ. (2018), beton yapıların dayanıklılığı ile ilgili olarak, karbonatlaşma kaynaklı CO₂ gibi iklimsel parametrelerle doğrudan ilişkili olan korozyonu önemli ve maliyetli bir bozunma kaynağı olarak belirtmiştir. Bu nedenle, çalışmalarında gerçek bozunma verileri ile beton yapılar için sayısal bir karbonatlaşma modeli arasındaki korelasyonun bir analizini sağlamayı ve korozyona maruz kalan beton yapıların hizmet ömrünün tahmini için uygulanabilecek en doğru matematiksel modeli seçmeyi amaçlamıştır.

Şekil 3, yerinde test sonuçları ile 20 MPa karakteristik dayanıma sahip beton yapı için karbonasyon eğrileri arasındaki bir korelasyon analizini göstermektedir. RCP 4.5 (en iyi durum) ve RCP 8.5 (en kötü durum) iklim senaryoları ve iklim değişikliğini dikkate almayan kontrol senaryosu için betonarme yapılarda beklenen bozunma gösterilmektedir.



Şekil 3. Belirli Beton Yapılar İçin Analiz (Benítez ve diğ., 2018)

Regresyon Analizi (Regression Analysis): İki veya daha fazla değişken arasındaki ilişkiyi göstermek için kullanılmaktadır. En az bir bağımsız değişken (X) ve bir veya birden fazla bağımlı değişken (Y) belirlenerek analiz yapılır (Şekil 4).

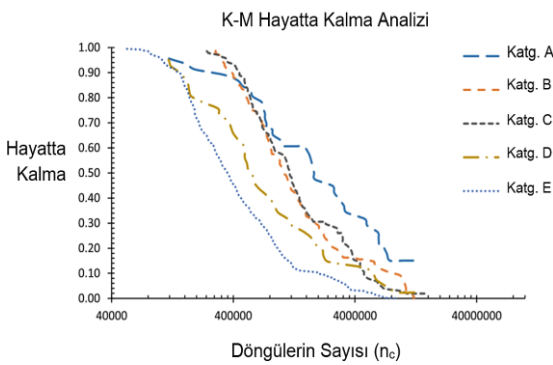


Şekil 4. Regresyon Grafiği

Bağımlı değişkeni etkileyen değişkenler bağımsız değişken olarak modele katılmaktadır. Bağımlı değişken, ilgili bağımsız değişkenlerin etkileri doğrultusunda değer almaktadır. Eğer tek bir değişkene göre analiz yapılıyorsa "tek değişkenli regresyon", birden fazla değişken söz konusu ise çok değişkenli regresyon olarak adlandırılmaktadır.

Hayatta Kalma Analizi (Survival Analysis): Mekanik sistemlerde arızanın gerçekleşmesine kadar beklenen sürenin analizidir. Ekipmanın Kalan Faydalı Ömür (RUL) tahmininde kullanılan araçtır. Rassal bir değişken olan RUL, varlığın mevcut yaşına, çalışma ortamına ve gözlemlenen durum izleme (CM-condition monitoring) veya sağlık bilgilerine bağlıdır. Bakım faaliyetlerinin planlanması, süreç içerisinde yedek parça temini, operasyonel performans gibi unsurlar üzerinde etkili olduğu için bir varlığın Kalan Faydalı Ömrünü varlık kullanımdayken değerlendirmek kritik derecede önemlidir (Si, Wang, Hu ve Zhou, 2011).

Literatürde Nabizadeh ve Tabatabai (2020), çelik köprüler için yorulma test verilerini kullanarak parametrik hayatta kalma analizleri gerçekleştirmiştir (Şekil 5).

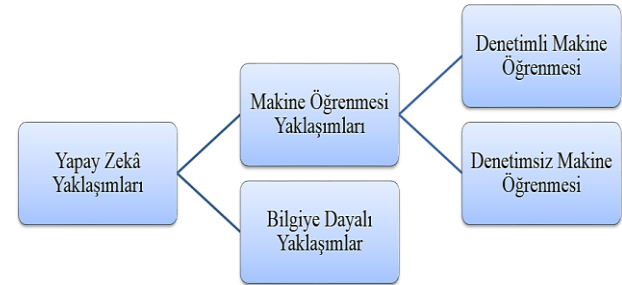


Şekil 5. Kategorilere Göre Hayatta Kalma Verileri (Nabizadeh ve Tabatabai, 2020)

Yorulma verileri A' dan E' ye kadar sınıflandırılmıştır. Belirlenen sınıflar ile Kaplan-Meier(K-M) hayatta kalma grafiği gösterilmiştir. E kategorisi verilerinin seyrek olmasından dolayı K-M grafiğinde gösterilmemiştir. Hayatta kalma analizinin yorulma direncine önerilen uygulamasında, uygulanan gerilim (n_c) döngülerinin sayısı hayali (ve negatif olmayan) bir "zaman" parametresi olarak değerlendirilmiştir.

3.2. Yapay Zekâ Yaklaşımları

Yapay zekâ, tanıma, problem çözme vb. faaliyetlerde insan gibi çalışan ve tepki veren akıllı makinelerin yaratılmasına yönelik bilgisayar bilimi yaklaşımıdır (Wakiru, Pintelon, Chemweno ve Muchiri, 2017). Yapay zekâ yaklaşımları (Şekil 6) son yıllarda PdM çalışmalarında giderek daha fazla uygulanmaktadır.



Şekil 6. Yapay Zekâ Yaklaşımları (Wakiru, Pintelon, Muchiri ve Chemweno (2019))

Yapay zekâ yaklaşımları, makine öğrenmesi yaklaşımları ve bilgi tabanlı yaklaşımlar olarak iki sınıfa ayrılmıştır. Makine öğrenmesi yaklaşımları, literatürde birçok kestirimci bakım çalışmasında kullanılmıştır.

3.2.1. Makine Öğrenmesi Yaklaşımları

Gelişen teknoloji ile birlikte belirli nesnelere veya kavramlar yeterli doğrulukla tanımlanamadığı için, bunlar örneklerle makinelerle aktarılmaktadır. Bu durumun gerçekleşmesi için kullanılan bilgisayarın örnekleri bilgiye dönüştürebilmesi gerekmektedir. Bu durumda makine öğrenmesi algoritmaları devreye girmektedir. Makine öğrenmesi, yapay zekâ (AI-Artificial Intelligence) yaklaşımlarının bir alt grubudur. Makine öğrenmesi yaklaşımları denetimli ve denetimsiz makine öğrenmesi olmak üzere iki grupta toplanır.


Denetimli makine öğrenmesi teknikleri

Makine öğrenmesinde çoğunlukla denetimli makine öğrenmesi teknikleri kullanılmaktadır. Bir modelin etiketli bir veri kümesi ile eğitildiği öğrenim türüdür. Giriş ve çıkış parametreleri modelde yer almaktadır. Öğrenme, ilgili giriş parametreleri için verilen çıktılar temelinde gerçekleşmektedir. Algoritma, eğitim verileri üzerinde yinelemeli olarak tahminler yapmaktadır.

Algoritma kabul edilebilir bir performans seviyesine ulaştığında ise öğrenme sona ermektedir.

Lojistik Regresyon (LR - Logistics Regression), verileri analiz etmek ve bir ikili değişken ile bir veya daha fazla nominal, sıralı veya oran düzeyinde bağımsız değişken arasındaki ilişkiyi açıklamak için kullanılan kestirimci bir analizdir (Wakiru ve diğ., 2017). Lojistik regresyon ve sıradan lineer regresyon, birçok farklı olasılık dağılımını kapsayan genelleştirilmiş lineer modeller (GLM- Generalized Linear Models) adı verilen daha büyük bir teknik sınıfına girmektedir. Etkili bir lojistik regresyon modeli, tahmin edicilerin her biri ile ilgili başarı oranının nasıl denetlendiğinin incelenmesini gerektirir.

Doğrusal regresyon gibi, lojistik regresyon modeli de her model terimi için eğim parametrelerine ek olarak bir kesişme noktasına sahiptir (Şekil 7).



Şekil 7. Lojistik Regresyon Eğrisi (Borucka ve Grzelak, 2019)

Lojistik regresyon, olayın log olasılıklarını doğrusal bir fonksiyon olarak modellemektedir. İncelenen sürecin değerlendirilmesi, bir olayın meydana gelme olasılıklarının hesaplanmasıdır. Lojistik regresyon modelinin tahmini parametresindeki işaret, analiz edilen oranların referans seviyesine göre daha büyük (artı) veya daha küçük (eksi) olup olmadığını göstermektedir.

Karar Ağaçları (DT-Decision Tree), bir sonuç veya olayla ilgili olası kararların sonuçlarını modellemektedir. Modellenen sonuca uygun olarak ağaç tabanlı bir grafik gösterimi ile sonuçlar yorumlanır. Ağaç tabanlı gösterimde, ağaçtaki her dalda (veya düğümde) tanımlanan bir dizi test temelinde bir veri kümesi yinelemeli olarak daha alt bölümlere ayrılarak gruplandırılmaktadır.

Karar ağacı, tüm verileri içeren bir kök düğümünden, düğümlerden (bölünmeler) ve terminal düğümlerden (yapraklar) oluşmaktadır. Bir karar ağacındaki her düğüm, yalnızca bir ana düğüme ve birden fazla alt düğüme sahiptir. Bir veri seti ağaç şemasına göre belirlenmiş bölümlere ayrılarak sınıflandırılır. Gözlemin düştüğü yaprak düğümüne göre her gözleme bir sınıf etiketi atanır. Karar ağaçlarının, eksik verilere izin

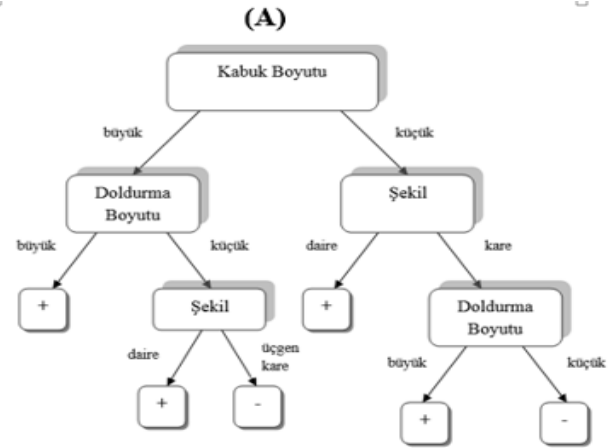
vermesi ve kolayca yorumlanabilmesi üstün yönleri arasında sayılabilir.

Tablo 2

Üç sembolik özellik ile tanımlanan sekiz eğitim verisi ve belirli bir sınıfın pozitif ve negatif etiketlere göre sınıflandırılmasını içeren bir örnek (Kubat, 2017).

Örnek	Kabuk Boyutu	Şekil	Doldurma Boyutu	Sınıf
e1	Büyük	Daire	Küçük	Pozitif
e2	Küçük	Daire	Küçük	Pozitif
e3	Büyük	Kare	Küçük	Pozitif
e4	Büyük	Üçgen	Küçük	Negatif
e5	Büyük	Kare	Büyük	Pozitif
e6	Küçük	Kare	Küçük	Negatif
e7	Küçük	Kare	Büyük	Pozitif
e8	Büyük	Daire	Büyük	Pozitif

Şekil 8, Tablo 2'deki verilere göre oluşturulmuş karar ağaçlarından birini göstermektedir.




Şekil 8. Örnek Bir Karar Ağacı (Kubat, 2017)

Dâhili düğümler öznelik değeri testlerini temsil eder. Kenarlar çeşitli test sonuçları durumunda nasıl ilerleneceğini gösterir ve yapraklar sınıf etiketlerini içermektedir. Sınıflandırılacak bir örnek ilk olarak en üst düğüm olan kökte öngörülen teste tabi tutulur. Bu testin sonucu daha sonra örneğin hangi kenar boyunca gönderileceğine karar verir ve işlem bir yaprak düğüme ulaşılan kadar devam eder. Ulaşma gerçekleştiğinde, örnek bu yaprakla ilişkili sınıfla etiketlenir.

Yapay Sinir Ağları (ANN-Artificial Neural Networks), insan sinir sisteminden esinlenerek oluşturulmuş modellerdir. Yapay sinir hücreleri dışarıdan gelen bilgileri bir toplama fonksiyonu ile toplar ve aktivasyon fonksiyonundan geçirerek çıktıyı üretilir.

bağlantılarının üzerinden diğer hücrelere gönderir. Kullanılan fonksiyonlar çeşitlilik gösterebilmektedir. Yapay sinir ağlarını birbirlerine bağlayan bağlantıların değerlerine ağırlık değerleri denir. Şekil 9' da girdi katmanı, gizli katman ve çıktı katmanından oluşan bir yapay sinir ağı yapısı gösterilmiştir (Şekil 9).




Şekil 9. Örnek Yapay Sinir Ağı (Barkana, Sarıççek ve Yıldırım, 2017)

Bilgiler, girdi sinyalleri olarak ağ yapısında girdi katmanından iletilir. Ara katmanlarda işlenir ve sonrasında çıktı katmanına gönderilir. Bilgi işleme; ağa gelen bilgilerin fonksiyonlarda ağırlık bilgilerinin kullanılması ile çıktıya dönüştürülme işlemidir. Yapay sinir ağlarında, eğitim aşamasından sonra istenen sınıflandırmayı yapacak ağırlık değerleri bulunmaktadır. Ağın eğitimi sırasında veri setindeki örnekler için doğru çıktılar üretecek ağırlık değerleri bulunmaya çalışılır. Eğitim aşamasından sonra test setindeki örnekler ağa gösterilir. Ağın hiç tanımadığı veri seti üzerinde yaptığı sınıflandırma ya da tahminlerin doğruluğu gösterilir.

Yapay sinir ağları geçmiş verilere dayandığından karar vermek için uzman bilgisi gerektirmez; veriler arasında ilişkileri öğrenen ağlar ile tutarlı tahminler yapılabilir. Bununla birlikte, kuralları ve teorileri reddeden sonuçlara ulaşabilir ve eğitimi zaman alıcı olabilir. ANN "kara kutu" yöntemlerindedir ve ANN modelinin neden ilgili çıktı tahminine ulaştığını kolayca anlamak zordur. Ayrıca bir ANN' nin doğru bir şekilde öğrenmesi için çok büyük bir veri kümesine ihtiyaç vardır (Carvalho, Soares, Vita, Francisco, Basto ve Alcalá, 2019).

Destek Vektör Makinesi (SVM-Support Vector Machine), istatistiksel öğrenmeye dayanan diğer yaklaşımlara oranla yeni bir hesaplamalı yöntemdir. Yeni gözlemleri yanıt değişkenlerine göre sınıflandıran doğrusal bir sınıflandırıcıdır. SVM, yüksek doğruluğu nedeniyle sınıflandırma ve regresyon görevlerini yerine getirmek için yaygın olarak kullanılan ve bilinen ML yöntemidir (Sexton, Brundage, Hoffman ve Morris, 2017; Chang ve Lin, 2011). Bu teknik, maksimum marjı olan ayırıcı bir hiper düzlem arar (Şekil 10).



Şekil 10. Destek Vektör Makinesi Yöntemi (Kubat, 2017)

SVM'ler başlangıçta, olasılıklı olmayan ikili sınıflandırıcılar olmasına rağmen şimdi çok sınıflı problemlerde de kullanılmaktadır. Çok sınıflı problemler, öğeleri üç veya daha fazla sınıfa ayırmak gibi zorluğu içeren problemlerdir. Bu durumda, SVM, verileri ideal olarak n sınıfa bölen n boyutlu hiper düzlemler oluşturmaktadır (Carvalho ve diğ., 2019).

PdM uygulamalarında, SVM'lerin bazı dezavantajları, bir SVM modeli için "iyi" bir çekirdek işlevi seçmenin zorluğu, bir SVM modelinin eğitim süresinin örnek sayısı arttıkça artması ve son SVM modelinin anlaşılması ve yorumlanmasının kolay olmamasıdır.

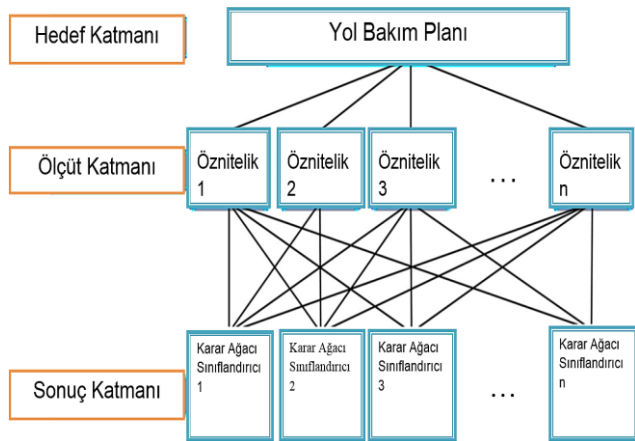
Rassal Orman (RF-Random Forest), ilk olarak Leo (2001) tarafından önerilmiştir. Yaklaşımın eğitim aşamasında birden çok rassal karar ağacı içeren bir "orman" (topluluk) oluşturulur. Bu toplulukları büyütme için, topluluktaki her ağacın büyümesini yöneten rassal vektörler oluşturulur. Yöntem, sınıflandırma doğruluğu açısından güvenilir olmasına rağmen yöntemin sonuçlarının yorumlanması zordur.

Biau ve Scornet'e (2016) göre, değişken sayısının örnek sayısından (gözlemler) fazla olduğu zaman RF'ler iyi performans göstermiştir. RF, hem sınıflandırma hem de regresyon görevleri için denetimli bir öğrenme algoritmasıdır.

Literatürde Han, Ma, Xu, Chen ve Huang (2020) bakım kararlarının doğruluğunu ve verimliliğini artırmak, yetersiz insan deneyiminin neden olduğu karar hatasını ortadan kaldırmak için karar verme yöntemi olarak rassal orman algoritmasını kullanmıştır (Şekil 11).

Analitik Hiyerarşi Prosesi (AHP) kullanan bir RF modeli oluşturulmuştur. AHP, hedef, ölçüt, sonuç katmanı olmak üzere üç katmana bölünmüştür. Ölçüt katmanı, seçilen bakım göstergeleridir ve sonuç katmanı, oluşturulan karar ağacı alt sınıflandırıcısıdır.

Derin öğrenme (DL-Deep Learning), birden çok katmandan oluşan, eldeki veri seti ile sonuçları tahmin etmeye çalışan öğrenme yöntemidir. Derin öğrenme makine öğrenmesinin, makine öğrenmesi ise yapay zekânın alt grubu olarak değerlendirilir.



Şekil 11. Rassal Orman Tekniğinin Analitik Hiyerarşi Sürec Modeli (Han ve diğ., 2020)

Derin öğrenme kavramı 1980'lerden itibaren iki olay ile daha popüler hale gelmeye başlamıştır (Deng, 2014).

•Düşük maliyet ve yüksek hesaplama yeteneği, DL algoritmaları daha kolay ve hızlı bir şekilde uygulamaya ve eğitmeye yardımcı olur.

•2006 yılına kadar DL algoritmaları ile iyi sonuçlar elde edilememiştir. 2006 yılında Hinton, Osindero ve Teh (2006), derin yapıdaki ağları eğitmek için ağgözlü katman bazlı eğitim yöntemini önermiştir. Bu da derin yapılar ile makine öğrenmesi çalışmalarında büyük bir adım olmuştur.

DL algoritmalarından CNN, SAE, DBN, DBM, RNN ve DNN algoritmaları literatürde birçok alanda uygulanmıştır. Şekil 12' de ML ve DL algoritmalarının akışı verilmektedir. ML algoritmaları (SVM, ANN, k-NN vb.) büyük miktarda veri toplamayı gerektirir. Kestirimci bakımda öznitelik çıkarımı veya sinyal analizi için birçok etkili ve kullanışlı yöntem sunulmuş, araştırılmış ve uygulanmıştır. Bu yöntemler; zaman domeni, frekans domeni ve zaman-frekans domeni'dir. Zaman domeni yönteminin özü, bir dalga formunun analizidir (Jahnke, 2015). Frekans domeni analizinde sinyal, frekansın dağılımını ortaya çıkarabilen ve sinyalin gürültüsünü elverişli bir şekilde filtreleyebilen belirli bir dönüşüm yoluyla frekansa göre analiz edilir (Öztanır, 2018).

Kestirimci bakım uygulamalarında hem ML hem de DL algoritmaları kullanılmaktadır. Makine öğrenmesi algoritmalarında büyük miktarda veri gereklidir ve öznitelikler zaman, frekans, zaman-frekans alanlarından çıkartılır. Derin öğrenme algoritması, bu karmaşık süreci önlemektedir. Derin öğrenmenin, makine öğrenmesi algoritmalarından farkı; girdilerden direkt tahmin çıktılarını sağlamasıdır.



Şekil 12. ML ve DL Süreci (Zhang, Yang ve Wang, 2019)

Kural Tabanlı (RB-Rule Based) Makine Öğrenmesi, bir sistemde elde edilen bilgiyi temsil eden bir dizi ilişkisel kural kullanır.

Temsili Öğrenme (RL- Representation Learning), benzersiz bir şekilde bir görüntüden veya öğeden çıktıya veya kendi kendine haritalamada kullanılabilir.

k-En Yakın Komşu (k-NN, k- Nearest Neighbor), uygulaması kolay yöntemlerden biridir. KNN; gürültülü eğitim verilerine karşı dirençli olmasına karşın, uzaklık hesabı yaparken bütün durumları sakladığından, büyük veri setleri için fazla bellek alanına gereksinim duyması bir dezavantajı olarak söylenebilir.

Denetimsiz makine öğrenmesi teknikleri

Denetimsiz makine öğrenmesi tekniklerinde, etiketli yanıtlar olmadan yalnızca girdi verileri içeren veri kümelerinden sonuçlar elde edilir. Temel bileşen analizi ve küme analizi denetimsiz makine öğrenmesi tekniklerindedir.

Temel Bileşen Analizi (PCA-Principal Component Analysis), verilerde benzerlikler ve farklılıklar ortaya çıkaracak şekilde modellenen yeni temel bileşenler üretir. Veri büyüklüklerinde boyut indirgemede ve değişkenler arasında ilişki olduğunda kullanılmaktadır. Temel Bileşen Analizi' nin amaçları şu şekilde belirtilmektedir (Özonur, Kılıç, Akdur ve Bayrak, 2019):

•Birbirleri ile ilişkili olan değişkenlerden, ilişkisiz yeni değişkenler üretmek.

•Değişken sayısını azaltarak boyut indirgemek.

•Zaman, maliyet ve güncelliği koruma noktasında avantaj sağlamak.

•Analizde, karşılıklı bağımlılık yapısı gösteren, n adet değişken; doğrusal, dikey ve birbirinden bağımsız olma özelliklerini taşıyan n tane yeni değişkene dönüştürülmektedir.

Kümeleme Analizi (CA-Cluster Analysis), birkaç gözlem (öznitelikler) arasındaki benzerliklere göre yapılan kümelemedir. Verileri grup/küme içerisinde toplayarak benzer özelliklere sahip nesnelere birarada toplanmasını sağlamaktadır.

3.2.2. Bilgi Tabanlı Yaklaşımlar

Bilgi tabanlı sistemler, önceki olaylardan bakımla ilgili yönleri çıkarmak için gözlenen durumların ve kuralların bilgisinin sembolik temsilini kullanarak bir tür akıllı davranış sergiler (Sikorska, Hodkiewicz ve Ma, 2011).

3.3. Model Tabanlı Yaklaşımlar

Sistem davranışı ve sistem içerisindeki ilişkilerin problem çözmek amacıyla modellemek için fiziksel ve matematiksel modelleri kullanan yaklaşımlardır. Oluşturulan modeller, simülasyon modelleri, deneysel modeller ve matematiksel modeller olarak üç kategoriye ayrılmaktadır.

Simülasyon modelleri: Belirli değişkenlerin ve yapılan değişikliklerin sistemi nasıl etkilediğini anlamak ve tahminlemede kullanılan modellerdir.

Deneysel modeller: Benzer oluşturulan çalışma ortamında, konusunda uzman kişiler tarafından geliştirilen prototipler kullanılarak oluşturulan modellerdir.

Matematiksel modeller: Sistem sinyallerinden çıkarılan zaman ve frekans alanı verilerini kullanan matematiksel modellerdir.

3.4. Melez Yaklaşımlar

Melez yaklaşımlar, iki veya daha fazla yaklaşımın bir kombinasyonunun kullanıldığı çeşitli çalışmalarda uygulanmıştır:

- İstatistiksel + Yapay zekâ
- İstatistiksel + Model tabanlı
- Model tabanlı + Yapay zekâ
- Model tabanlı + Yapay zekâ + İstatistik

4. Kestirimci Bakımda Makine Öğrenmesi Kullanan Çalışmalar

Endüstriyel ortamlarda makine sağlığı izleme ve arıza tespiti, ML için en önemli uygulama alanlarından. Makine ekipmanının vazgeçilmez bir parçası olan rulman sağlığı sadece ekipman değil tüm sistemi etkilemektedir. Oluşacak ani bir arıza büyük maliyetlere neden olabilmektedir. Durum izlemesi ve arıza tespiti genel olarak dört adımdan oluşmaktadır: veri toplama, öznitelik çıkarma, öznitelik seçimi ve öznitelik sınıflandırmasıdır (Huang, 1996).

• Veri toplama: Ekipman sağlık durumu ile ilgili sensörlerden veri toplanmasıdır. Bunlar titreşim, gürültü, emisyon vb. verilerdir.

• Öznitelik çıkarma: Orijinal sinyaller makine durumu hakkındaki bilgileri ileten istatistiksel parametrelerle

eşlenir. Sinyal öznitelikleri, zaman domeni, frekans domeni ve zaman - frekans domeninden çıkarılabilir.

• Öznitelik seçimi: Büyük bir veri seti içeren öznitelik kümesi, hesaplama süresini arttırmaktadır ve çözümü zorlaştırmaktadır. Bu veri kümesi içerisinde seçim ile hesaplama yapmak süreyi azaltmaktadır. Seçimde kullanılan en yaygın tekniklerden biri Temel Bileşen Analizi (PCA) dır (Malhi ve Gao, 2004).

• Öznitelikler sınıflandırıldıktan sonra arıza tespiti için ML Algoritmaları (ANN, SVM gibi) uygulanmaktadır.

PdM için, birkaç sensörden veri alınır ve bu nedenle veriler, çok değişkenli zaman serisi verileri olarak adlandırılır. Bazı uygulamalarda, analiz için binlerce sensörden veri toplanır. Sensör verilerine bir ML algoritması uygulanmadan önce, doğru formatta veya yapıda olduğundan emin olmak önemlidir. Buna ön işleme denir. Ön işleme, gürültüden arındırma ve boyutluluk azaltma gibi adımları içerebilir. Gürültü azaltma, sinyal-gürültü oranını iyileştirmek için bir sinyalden gelen gürültünün giderilmesi anlamına gelir. Boyut azaltma, bilgi kaybını en aza indirirken verilerdeki bağımsız değişkenlerin sayısını azaltmayı ifade eder. ML ve DL, ön işlemede de yardımcı olabilir (Namuduri, 2020).

Akıllı sensörler, giderek karmaşıklaşan sistemlerin karar alma ve yönetimini desteklemek için verimli ve etkili bir şekilde analiz edilmesi gereken, sürekli artan miktarda veri elde etmeyi mümkün kılar (Pench, Vrchota ve Bednár, 2021). Toplanan veri türüne bağlı olarak otomatikleştirilmiş hata tespiti ve teşhisi için makine öğrenimi algoritmaları uygulanabilir. Ancak, endüstride uygulamak için uygun ML tekniklerini, veri türünü, veri boyutunu ve ekipmanı seçmek çok zordur. Uygun olmayan PdM tekniği seçimi, veri kümesi ve veri boyutu, zaman kaybına ve uygulanabilir olmayan bakım planlamasına neden olabilir (Çınar, 2020).

Literatürde incelenen makine öğrenmesi algoritmalarını kullanan kestirimci bakım çalışmaları Tablo 3'te verilmiştir. 2005' ten günümüze kadar yapılan çalışma sayıları hızla artmış ve kestirimci bakım konusunda durumun izlenmesi, arızanın önceden tespit ve teşhisi, konuları bir trend haline gelmiştir.

Tablo 3 incelendiğinde en çok kullanılan tekniklerin LR, ANN ve SVM olduğu görülmektedir. 2005 yılında Yan ve Lee'nin asansör kapı sistemi bozulması konusunda LR kullandığı çalışması araştırmacılara yol göstermiştir. Pdm çalışmalarında rulman arızası ML algoritmaları ile en çok çalışılan konulardandır. Araştırmacılar rulman arızasının teşhisi ve RUL tahmini için LR, ANN ve SVM tekniklerini yaygın olarak kullanmıştır. 2020 yılında yapılan çalışmaların birden fazla ML tekniği içermesi göze çarpmaktadır. Endüstri/ekipman açısından da son yıllardaki çalışmalar farklılık göstermektedir.

Tablo 3

PdM'de Makine Öğrenmesi Algoritmalarını Kullanan Çalışmalar

Algoritma	Yazarlar	Endüstri / Ekipman	Amaç
Lojistik Regresyon (LR)	Yan ve Lee (2005)	Asansör Kapı Sistemi	Bozulma Değerlendirmesi (Degradation Assessment)
	Caesarendra, Widodo ve Yang (2010)	Rulman	Arıza Bozulma Tahmini (Estimate Failure Degradation)
	Pandya, Upadhyay ve Harsha (2014)	Rulman	Hata Bozulma Tahmini (Fault Degradation Estimate)
	Phillips, Cripps, Lau ve Hodkiewicz. (2015)	Maden Komyonlarındaki Motorlar	Arıza Teşhisi (Fault Diagnosis)
	Li, Wang, Zhao, Zhang ve Zhou (2014)	Kesici Aletler	Güvenirlilik Değerlendirmesi
	Costello, West ve McArthur (2017)	Gaz Sirkulasyon Üniteleri	Sağlık Durumu Değerlendirmesi ve RUL Tahmini
	Wu, Sari, Lin ve Chang (2017)	Mikro Delme İşlemi	Arıza Tespiti
	Ahmad, Khan, Islam ve Kim (2018)	Rulman	RUL Tahmini
	Yu (2018)	Kesici Aletler	RUL Tahmini
Karar Ağaçları (DT)	Krishnakumari, Elayaperumal, Saravanan, ve Arvindan (2017)	Düz Dişli	Arıza Teşhisi (Fault Diagnosis)
	Li, Chen, Hu, Wang, Guo, Liu, Li, Huang, Lv ve Li (2018)	Değişken Soğutucu Akış Sistemi	Arıza Teşhisi
	Santos, Maudes ve Bustillo (2018)	Dişli Kutusu	Arıza Teşhisi
	Allah Bukhsh, Saeed, Stipanovic ve Doree (2019)	Demiryolu Makasları	Performans Değerlendirmesi ve Bakım Kararı
Yapay Sinir Ağları (ANN)	Mahamad, Saon ve Hiyama (2010)	Dönen Rulman	RUL Tahmini
	Chen ve Chen (2011)	Döner Makine	Arıza Teşhisi
	Prieto, Cirrincione, Espinosa, Ortega ve Henao (2013)	Rulman	Arıza Teşhisi
	Ben Ali, Fnaiech, Saidi, Chebel-Morello ve Fnaiech. (2015)	Rulman	Arıza Teşhisi
	Ahmed, El Sayed, Gadsden, Tjong ve Habibi (2015)	Benzinli Motor	Arıza Tespiti
	Ben Ali, Chebel-Morello, Saidi, Malinowski ve Fnaiech (2015)	Rulman	RUL Tahmini
	Lei, Jia, Lin, Xing ve Ding (2016)	Rulman	Arıza Teşhisi
	Shin, Jun ve Kim (2018)	Park Yönlendirme Sistemi	Performans Değerlendirmesi
Scalabrini Sampaio, Vallim Filho, Santos da Silva ve Augusto da Silva (2019)	Motor (Sentetik Veri)	Motor Arıza Süresi Tahmini	

PdM'de Makine Öğrenmesi Algoritmalarını Kullanan Çalışmalar (devamı)

Algoritma	Yazarlar	Endüstri / Ekipman	Amaç
Destek Vektör Makinesi (SVM)	Saimurugan, Ramachandran, Sugumaran ve Sakthivel (2011)	Rulman	Arıza Teşhisi (Fault Diagnosis)
	Li ve diğ. (2014)	Demiryolu Sistemi	Hizmet Kesintilerini Önlemek
	Soualhi, Medjaher ve Zerhouni (2015)	Rulman	Arıza Teşhisi ve RUL Tahmini
	Li ve diğ. (2015)	Dişli Kutusu	Arıza Teşhisi
	Yang, Liu, Li, Li ve Ma (2015)	Dişli Kutusu	Arıza Teşhisi
	Zhang, Liang, Zhou ve Zang (2015)	Rulman	Arıza Tespiti
	García Nieto, García-Gonzalo, Sánchez Lasheras ve de Cos Juez (2015)	Uçak Motoru	RUL Tahmini
	Shafi, Safi, Shahid, Ziauddin ve Saleem (2018)	Araç Altsistemleri	Arıza Tahmini (Fault Prediction)
	Baptista ve diğ. (2018)	Uçak Motoru Valfleri	Arıza Tahmini
	Shamayleh, Awad ve Farhat (2020)	Tıbbi Ekipman	Arıza Teşhisi
Rassal Orman (RF)	Kusiak ve Verma (2011)	Rüzgâr Türbinleri	Erken Bozulma Tahmini ve Bakım Kararı
	Prytz, Nowaczyk, Rögnvaldsson ve Byttner (2015)	Kamyon ve otobüslerdeki hava kompresörleri	Bakım Kararı
	Shrivastava, Mahalingamve Dutta (2017)	Biyoreaktör	Arıza Tespiti (Fault Detection)
	Su ve Huang (2018)	Hard-disk Sürücüsü	Arıza Tespiti
	Janssens, Loccufer ve Van Hoecke (2019)	Dönen Makine	Arıza Tespiti
DT ve RF	Hsu, Wang, Lin, Chen ve Hsu (2020)	Rüzgâr Türbinleri	Arıza Teşhisi ve Bakım Kararı
ANN ve SVM	Falamarzi, Moridpour, Nazem ve Cheraghi (2019)	Tramvay Ağı	Ölçü Bozulması Tahmini (Gauge Degradation Prediction)
	Chen, Liu, Zhang ve Wang (2020)	Mekanik Bileşenler	Bileşen Gelecek Durumlarının Tahmini
SVM ve k-NN	Susto ve diğ. (2015)	Yarı İletkenler (Tungsten Filament)	Kesinti Süresini Azaltmak
SVM ve LR	Gohel, Upadhyay, Lagos, Cooper ve Sanzetenea (2020)	Nükleer Enerji Santrali	Nükleer Yapıda Meydana Gelebilecek Olayların Tahmini
DT, RF ve LR	Kaparathi ve Bumblauskas (2020)	Backblaze Veri Merkezi	Performans Değerlendirmesi
SVM, k-NN ve RNN	Hoffmann ve diğ. (2020)	Anahtarlama Cihazları	Durum İzlemesi
NN, Ağırlıklı NN ve RF	Fernandes ve diğ. (2020)	HVAC sisteminin kazan ve ısı pompası	Arıza Tespit ve Teşhisi
FNN ve SVM	You, Gao ve Katayama (2015)	Lazer Kaynak	Süreç İzleme ve Arıza Teşhisi
LDA, SVM ve RF	Lasisi ve Attoh-Okine (2018)	Demiryolu (mil)	Arıza Tahmini

Çalışmalarda makine öğrenmesi algoritmalarından RF, DT, ANN / NN, SVM, LR, k-NN ve DL algoritmalarının kullanıldığı görülmüştür. Makine öğrenmesi algoritmalarından derin öğrenme algoritmaları ayrı bir tabloda ayrıntılı olarak verilmektedir (Tablo 4). İncelenen çalışmalarda yoğun olarak rulmanlar ve dişli kutuları ekipmanının bulunduğu endüstri ortamında arıza teşhis ve tespiti için makine öğrenmesi

algoritmalarının uygulandığı görülmektedir. Diğer yıllara oranla son üç yılda daha fazla sayıda kestirimci bakımda makine öğrenmesi algoritması çalışmaları literatüre kazandırılmıştır.

Tablo 4

Derin Öğrenme Algoritmalarını İçeren Kestirimci Bakım Çalışmaları

	Algoritma	Yazarlar	Endüstri / Ekipman	Amaç
Derin Öğrenme	RBM	Liao, Jin ve Pavel (2016)	Rulman	RUL Tahmini
	DNN	Jia, Lei, Lin, Zhou ve Lu (2016)	Rulman ve Dişli Kutusu	Arıza Teşhisi (Fault Diagnosis)
	DNN	Hu, Tang, Gong, Wei ve Wang (2017)	Yüksek Hızlı Tren Sistemi	Arıza Teşhisi
	DNN	Wang, Zhang, Long, Xu ve Liu (2017)	Rüzgâr Türbini	Oluşacak Arızaları Belirleme
	DNN	Zhang, Peng, Wu, Yao ve Guan (2017)	Rulman	Arıza Teşhisi
	DAE	Shao, Jiang, Zhao ve Wang (2017)	Dişli Kutusu ve Rulman	Arıza Teşhisi
	DAE ve CAE	Shao, Jiang, Wang ve Zhao (2017)	Pervane ve Rulman	Arıza Teşhisi
	SDAE	Lu, Wang, Qin ve Ma (2017)	Rulman	Arıza Teşhisi
	DBN ve Seyrek Otomatik Kodlayıcı	Chen ve Li (2017)	Rulman	Arıza Teşhisi
	LSTM, CNN	Wu, Guo, Lin, Yu ve Ji (2018)	Siber-Fiziksel Sistemler (CPS-Cyber-Physical Systems)	Arıza Teşhisi
	LSTM ve RNN	Zhang, Liu, Su, Han ve Li (2018)	Elektrik Santrali	Tahmin Performansının İyileştirilmesi
	SAE, BP Sinir Ağı	Luo, Wang, Liu, Li ve Peng (2018)	Otomobil endüstrisi CNC Makine	Erken Arıza Tespiti
	DNN ve CNN, DL	Janssens, Van De Walle, Loccufier, Van Hoecke (2018)	Dönen Makine	Arıza Tespiti ve Yağ Seviyesi Tahmini
	EDAE	Shao, Jiang, Lin ve Li (2018)	Rulman	Arıza Teşhisi
	DNN ve DTL	Xu, Sun, Liu ve Zheng (2019)	Artan Otonom ve Karmaşık Üretim Sistemi	Arıza Teşhisi
	LSTM-OR: Derin LSTM Ağları ve Sıralı Regresyon	Tv, Diksha, Malhotra, Vig, ve Shroff (2019)	C-MAPSS Uçak Turbofan Motoru	RUL Tahmini
	LSTM ve RNN dayalı Yöntem	Zhang, Zhang ve Li (2019)	Rulman	RUL Tahmini
	CNN ve SVM	Yeh, Lin, Lin, Yu ve Chen (2019)	Elektrik endüstrisi / Rüzgâr Türbinleri	Uzun Döngü Bakım Zamanının Tahmini
	LSTM ve RBM	Nguyen ve Medjaher (2019)	Turbo Fan Motor	RUL Tahmini
	CNN (Regresyona dayalı)	Ibarra-Zarate, Alonso-Valerdi, Chuya-Sumba, Velarde-Valdez ve Siller (2019)	Inconel işleme Makinesi	Pürüzlülük Tahmini
	Derin CNN	Lee, Hwang, Choi ve Choi (2019)	Demiryolu Sistemi	Geometri Bozulma Tahmini
	Bayes Filtreleme (Bayesian Filtering)	Ruiz-Sarmiento ve diğ. (2020)	Paslanmaz Çelik Endüstrisi	Bozulma Tahmini
	Bayes Optimizasyonu ve Uyarlamalı Toplu Normalleştirme ve Derin CNN	Li ve He (2020)	Turbo Fan Motor	RUL Tahmini
	DNN	Chen, Liu, Zhang ve Wang (2020)	Otomobil Montaj Hatta	Silindir Güvenirliği
	CNN ve Uzun - LSTM	Zhang, Zhang, Shao, Niu ve Yang (2020)	Rulman	RUL Tahmini
	LSTM, DNN, Tek Boyutlu Evrişimli Sinir Ağı (CNN1D)	Rengasamy, Jafari, Rothwell, Chen ve Figueredo (2020)	Ağır Kamyonların Hava Basıncı Sistemi	RUL Tahmini ve Hata Tespiti (Fault Detection)
	RF ve CNN	Louis ve diğ. (2020)	Nükleer reaktörler ve Türbin Motorları	Kalan Faydalı Dayanım (RUS Remaining Useful Strength) Tahmini
	Cox Orantılı Tehlike Derin Öğrenme (CoxPHDL) ve LSTM	Chen ve diğ. (2020)	Otomobil Motoru	Arıza Tahmini
	DLNN	Lin ve Liu (2020)	Rüzgâr Türbini	Rüzgâr Enerjisi Tahmini
	NPBGRU: Gürültülü CNN (NCNN) ve Gürültülü Çift yönlü GRU (NBGRU)	Al-Dulaimi, Asif ve Mohammadi (2020)	Simülasyon Motoru	RUL Tahmini
	Varlık Gömülü Derin Sinir Ağları	Bukhsh, Stipanovic, Saeed ve Doree (2020)	Köprü Bakımı	Risk Seviyesi ve Bakım Kararı
	Melez Derin Sinir Ağı (DNN) : LSTM ve Klasik Sinir Ağı	Xia, Zheng, Imran ve Shoaib (2020)	Makine	RUL Tahmini
	Evrişimli LSTM Sinir Ağı Otomatik Kodlayıcıları (ConvLSTM)	Essien ve Giannetti (2020)	Makine	Makine Hızı Tahmini
	İki Evrişimli Katmandan Oluşan LSTM	Aydemir ve Paynabar (2020)	Bir Sistem	Bozulan Görüntü Akışını Kullanarak Arıza Yapma Süresi Tahmini
DNN	Utah ve Jung (2020)	Solenoid çalışan valfler (Solenoid operated valves)	Arıza ve RUL Tahmini	
LSTM ve RNN	Wang, Bu ve He (2020)	Demiryolu Sistemi	Bakım Kararı	

Çeşitli endüstriyel alan/ekipman için yapılan çalışmalarda genel olarak arızanın önceden teşhis ve tespiti ve bakım kararının verilmesi amacı ile makine öğrenmesi algoritmaları kullanılmıştır.

Tablo 4'te derin öğrenme algoritmalarını kullanan kestirimci bakım çalışmaları verilmiştir. (Liao ve diğ., 2016) ve (Jia ve diğ., 2016) çalışmaları PdM'de derin öğrenme kullanan ilk önemli çalışmalardır. Wang ve diğ. (2017) DNN ile rüzgâr türbininde arızaları belirlemeye odaklanırken, Yeh ve diğ. (2019), CNN ve SVM kullanarak bakım zamanı tahmini yapmıştır.

Literatürde rulman arızasının teşhisi ve rulman RUL tahminine ilişkin birçok çalışma yapıldığı görülmektedir. Araştırmacılar birçok DL algoritmasını kullanarak rulman için için RUL tahmini ve arıza teşhisi yapmıştır.


Çalışma sayısında 2020 yılında büyük bir artış görülmektedir. Çeşitli ağ yapıları birçok çalışmada arıza teşhisi ve RUL tahmini yapmak amacı ile kullanılmıştır. Motor ve rulman ekipmanı için deneysel çalışmalar diğer ekipmanlara oranla daha fazla gerçekleştirilmiştir.

PdM çalışmalarında yaşanan önemli problemler veri ile ilişkilidir. ML/DL algoritmaları çok miktarda veriye ihtiyaç duyar. Öncelikle hata kaynağının tespit edilmesi önemlidir. Hangi türde verilerin toplanacağı, nasıl toplanacağı cevap verilmesi gereken sorulardandır. Ayrıca ilgili verilerin eksik olması, kalibre edilmeyen cihazlardan kaynaklanan hatalı ölçüm vb. sebeplerle yanlış veriler içermesi, gürültü içermesi PdM'de karşılaşılan önemli güçlüklerdendir. Endüstri 4.0'ın temel teknolojileri arasında IoT, bulut bilişim ve yüksek hacimli veri analizi bulunur. İlgili teknolojiler ile anlık verilerin elde edilmesi ve büyük veri analitiği PdM çalışmalarında önemli bir ilerlemeye sebep olacaktır. Bu kapsamda son yıllarda PdM çalışmalarında artış olduğu gözlenmektedir.

5. İncelenen Çalışmaların Değerlendirilmesi

Çalışmalar, kullanılan makine öğrenmesi algoritmaları (derin öğrenme algoritmaları), çalışmaların gerçekleştirildiği endüstri/ekipman, çalışmaların gerçekleştirildiği yıllar açısından analiz edilmiştir.

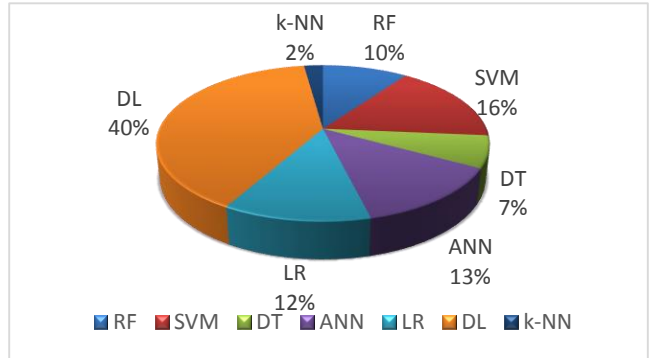
Kestirimci bakımda makine öğrenmesi algoritmaları ile ilgili incelenmiş olan makale çalışmalarının 2005 yılından günümüze büyük bir hızla artış gösterdiği görülmektedir (Şekil 13).



Şekil 13. İncelenen Çalışmaların Yıllara Göre Dağılımı

Çalışmalar son dört yılda diğer yıllara göre daha fazla artış göstermiştir. 2020 yılında en fazla çalışma sayısına ulaşmıştır.


İncelenen çalışmalarda makine öğrenmesi tekniklerinden DL, k-NN, RF, SVM, DT, ANN ve LR Algoritmalarının kullanıldığı görülmektedir (Şekil 14).



Şekil 14. İncelenen Çalışmalarda Kullanılan Makine Öğrenmesi Algoritmaları

Uygulamalarda makine öğrenmesi algoritmalarından derin öğrenme algoritmalarının %40 oranında daha fazla tercih edildiği görülmektedir. Derin öğrenmeden sonra en çok kullanılmış olan algoritma destek vektör makinesidir. Kullanılan diğer algoritmalar kullanım oranına göre ANN %13, LR %12, RF %10, DT %7, k-NN %2'dir.

Konu ile ilgili makalelerin en çok IEEE Transactions on Industrial Informatics dergisinde yayınlandığı görülmektedir (Şekil 15). İkinci sırada ise "Mechanical Systems and Signal Processing" ve "Sensors" gelmektedir.



Şekil 15. İncelenen Makalelerin Yayınlanmış Olduğu Dergiler

Dergilerden ilk beş derginin diğer dergilere oranla ilgili konuda daha fazla yayın içerdiği görülmektedir. Diğer dergilerde yayın sayılarının birbirine eşit veya yakın olduğu söylenebilir.

Bu çalışmada, araştırma ve yayın etiğine uyulmuştur.

6. Sonuçlar

Modern üretim sistemlerinin kullanılması, sistemi eniyi çalışma durumunda tutabilmek için iyi bir mühendislik yaklaşımının benimsenmesini, uygun ve doğru zamanda bakım stratejilerinin uygulanmasını gerektirmektedir. Bakım stratejilerinden biri olan kestirimci bakım, makinelerden (sensörlerden) verilerin toplanması ve değerlendirilmesi ile bakımın ne zaman yapılacağına dair kesin bir sonuca ulaşmaya odaklanmaktadır. Amaç, makine arızası oluşmadan müdahalede bulunularak makinelerin yüksek performansta çalışmasını sağlamaktır.

Literatürde makine öğrenmesi algoritmalarını içeren kestirimci bakım çalışmalarındaki hesaplamalı deneylerin yoğun olarak rulman, motor, rüzgâr türbinleri ekipmanları ile gerçekleştirildiği görülmüştür. Bu ekipmanların durumlarının izlenmesi, performanslarının değerlendirilmesi, RUL tahmini, arıza teşhis ve tespiti konularına odaklanılmaktadır. Arıza teşhis ve tespiti özel modeller ve teknikler kullanılarak gerçekleştirilmektedir. Çalışmalarda makine öğrenmesi tekniklerinden LR, RF, k-NN, SVM, ANN, DL algoritmaları kullanılmıştır. Makine öğrenmesi içeren kestirimci bakım çalışmalarında ilk yıllardan günümüze büyük oranda artış olduğu gözlenmiştir. Son yıllarda makine öğrenmesi algoritmalarından derin öğrenme algoritmasına olan yönelim fazladır. Araştırmadaki 2020 yılında yapılmış çalışmalarda % 68 oranında derin öğrenme algoritmaları kullanılırken, %32 oranında makine öğrenmesi algoritması kullanılmıştır. Derin öğrenme algoritmalarının avantajı, makine öğrenme algoritmalarındaki büyük veri ihtiyacı, öznetelik çıkarma gibi karmaşıklığı engellemesidir. Ham veriler ile çıktı arasına derin ara katmanlar eklenerek direkt tahmin sonucu sağlanmaktadır.

Endüstri 4.0 ile birlikte dijital fabrika kavramı ortaya çıkmış, bu kapsamda fabrika içerisindeki makine/ ekipmanların izlenmesi mümkün hale gelmiştir. Makinelerden veri toplama konusundaki gelişmeler büyük miktarda verinin kolaylıkla depolanabilmesi kestirimci bakım çalışmalarında önemli bir katkı sağlamıştır. Dolayısıyla literatür incelendiğinde makine öğrenmesi ile kestirimci bakım çalışmalarının son yıllarda büyük bir artış gösterdiği aşikardır. Bundan sonraki çalışmaların derin öğrenme algoritmaları başta olmak üzere işletmelerin bakım planlamasında sadece akademik çalışmalarda kalmayacağı sanayide önemli ölçüde kullanılacağı düşünülmektedir. Endüstri 4.0 çalışmaları işletmeleri bu yönde ilerlemeye teşvik edecektir.

Kestirimci bakım konusunda çalışacak araştırmacıların bundan sonraki aşamada yapay zekâ ağırlıklı tasarlayacakları bakım modellerine büyük veri, bulut, IOT (Internet of Things) gibi kavramları dahil ederek literatüre katkı sağlamaları mümkün olacaktır.

Ayrıca araştırmacılar, verilerin miktarını ve kalitesini iyileştirmek için algılama teknikleri geliştirebilir ve yeni ML/DL algoritmaları kullanmanın yanı sıra önerilen PdM stratejisini farklı algoritmalarla karşılaştıran çalışmalar yapabilir. Bir PdM uygulamasında birden fazla ML/DL yönteminin birlikte karar vereceği sistemler tasarlanabilir. Toplu öğrenme öneren çalışmalar geliştirmek, daha sağlam ve doğru tahminlere yol açabilir. Siber fiziksel sistemler için PdM çalışmalarında kullanılacak ve karşılaştırılacak veri setleri oluşturulabilir.

Teşekkür

Bu yayın TÜBİTAK 2232 Uluslararası Lider Araştırmacılar Programından (Proje No 118C252) yararlanılarak oluşturulmuştur. Ancak yaygın ile ilgili tüm sorumluluk yayının sahibine aittir. TÜBİTAK'tan alınan maddi destek, yayının içeriğinin bilimsel anlamda TÜBİTAK tarafından onaylandığı anlamına gelmez.

Araştırmacıların Katkısı

Bu araştırmada; Damla Rana DÜNDAR, bilimsel yayın araştırması ve makalenin yazım aşamasında, İnci SARIÇİÇEK, bakım planlaması konusundaki kavramlar, stratejiler ve makalenin yazım aşamasında, Eyüp ÇINAR ve Ahmet YAZICI, makine öğrenmesi konusundaki kavramlar, yöntemler ve bilimsel yayın araştırması aşamasında katkı sağlamışlardır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- Ahmad, W., Khan, S. A., Islam, M. M. M. ve Kim, J.-M. (2018). A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*, 64, 67-76. Doi: <https://doi.org/10.1016/j.ress.2018.02.003>
- Ahmed, R., El Sayed, M., Gadsden, S. A., Tjong, J. ve Habibi, S. (2015). Automotive internal-combustion-engine fault detection and classification using artificial neural network techniques. *IEEE Transactions on Vehicular Technology*, 64(1), 21-33. Doi: <https://doi.org/10.1109/TVT.2014.2317736>
- Al-Dulaimi, A., Asif, A. ve Mohammadi, A. (2020). Noisy parallel hybrid model of NBGRU and NCNN architectures for remaining useful life estimation. *Quality Engineering*, 32(3), 371-387. Doi: <https://doi.org/10.1080/08982112.2020.1754427>

- Allah Bukhsh, Z., Saeed, A., Stipanovic, I. ve Doree, A. G. (2019). Predictive maintenance using tree-based classification techniques: A case of railway switches. *Transportation Research Part C: Emerging Technologies*, 101, 35–54. Doi: <https://doi.org/10.1016/j.trc.2019.02.001>
- Aydemir, G. ve Paynabar, K. (2019). Image-based Prognostics Using Deep Learning Approach. *IEEE Transactions on Industrial Informatics*, 1–1. Doi: <https://doi.org/10.1109/TII.2019.2956220>
- Baptista, M., Sankararaman, S., de Medeiros, I. P., Nascimento, C., Prendinger, H. ve Henriques, E. M. P. (2018). Forecasting fault events for predictive maintenance using data-driven techniques and ARMA modeling. *Computers & Industrial Engineering*, 115, 41–53. Doi: <https://doi.org/10.1016/j.cie.2017.10.033>
- Barkana, B. D., Sariçiçek, İ. ve Yıldırım, B. (2017). Performance analysis of descriptive statistical features in retinal vessel segmentation via fuzzy logic, ANN, SVM, and classifier fusion. *Knowledge-Based Systems*, 118, 165–176. Doi: <https://doi.org/10.1016/j.knosys.2016.11.022>
- Ben Ali, J., Chebel-Morello, B., Saidi, L., Malinowski, S. ve Fnaiech, F. (2015). Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*, 56-57, 150–172. Doi: <https://doi.org/10.1016/j.ymssp.2014.10.014>
- Ben Ali, J., Fnaiech, N., Saidi, L., Chebel-Morello, B. ve Fnaiech, F. (2015). Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*, 89, 16–27. Doi: <https://doi.org/10.1016/j.apacoust.2014.08.016>
- Benítez, P., Rodrigues, F., Talukdar, S., Gavilán, S., Varum, H. ve Spacone, E. (2018). Analysis of correlation between real degradation data and a carbonation model for concrete structures. *Cement and Concrete Composites*. Doi: <https://doi.org/10.1016/j.cemconcomp.2018.09.019>
- Biau, G. ve Scornet, E. (2016). A random forest guided tour. *TEST: An Official Journal of the Spanish Society of Statistics and Operations Research*, 25, 197–227.
- Borucka, A. ve Grzelak, M. (2019). Application of Logistic Regression for Production Machinery Efficiency Evaluation. *Applied Sciences*, 9(22), 4770. Doi: <https://doi.org/10.3390/app9224770>
- Bukhsh, Z. A., Stipanovic, I., Saeed, A. ve Doree, A. G. (2020). Maintenance intervention predictions using entity-embedding neural networks, *Automation in Construction*, 116, 2020. Doi: <https://doi.org/10.1016/j.autcon.2020.103202>
- Caesarendra, W., Widodo, A. ve Yang, B. S. (2010). Application of relevance vector machine and logistic regression for machine degradation assessment, *Mechanical Systems and Signal Processing*, 24(4), 1161–1171. Doi: <https://doi.org/10.1016/j.ymssp.2009.10.011>
- Carvalho, T. P., Soares, F. A., Vita, R., Francisco, R. D. P., Basto, J. P., ve Alcalá, S. G. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024. Doi: <https://doi.org/10.1016/j.cie.2019.106024>
- Chang, C.- C. ve Lin, C.- J. (2011). LIBSVM: A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(27), 1-27.
- Chen, B., Liu, Y., Zhang, C. ve Wang, Z. (2020). Time Series Data for Equipment Reliability Analysis With Deep Learning. *IEEE Access*, 8, 105484–105493. Doi: <https://doi.org/10.1109/ACCESS.2020.3000006>
- Chen, C., Liu, Y., Wang, S., Sun, X., Di Cairano-Gilfedder, C., Titmus, S. ve Syntetos, A. A. (2020). Predictive maintenance using cox proportional hazard deep learning. *Advanced Engineering Informatics*, 44, 101054. Doi: <https://doi.org/10.1016/j.aei.2020.101054>
- Chen, C.- S. ve Chen, J.- S. (2011). Rotor fault diagnosis system based on sGA-based individual neural networks. *Expert Systems with Applications*, 38(9), 10822–10830. Doi: <https://doi.org/10.1016/j.eswa.2011.02.074>
- Chen, Z. ve Li, W. (2017). Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder and Deep Belief Network. *IEEE Transactions on Instrumentation and Measurement*, 66(7), 1693–1702. Doi: <https://doi.org/10.1109/tim.2017.2669947>
- Cheng, J.C.P., Chen, W., Chen, K. ve Wang, Q. (2020). Data-driven predictive maintenance planning framework for MEP components based on BIM and IoT using machine learning algorithms. *Automation in Construction*, 2020, 112, 103087. Doi: <https://doi.org/10.1016/j.autcon.2020.103087>
- Cinar, Z.M. Nuhu, A.A., Zeeshan, Q., Korhan, O., Asmael, M. ve Safaei, B. (2020). Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0, *Sustainability*, 12(19), 8211. doi: <https://doi.org/10.3390/su12198211>.
- Costello, J. J. A., West, G. M. ve McArthur, S. D. J. (2017). Machine Learning Model for Event-Based Prognostics in Gas Circulator Condition Monitoring. *IEEE Transactions on Reliability*, 66(4), 1048–1057. <https://doi.org/10.1109/tr.2017.2727489>

- Deng, L. (2014). A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Trans. Sig. Inf. Process*, 3 (2014). Doi: <https://doi.org/10.1017/ATSIP.2014.4>
- Essien, A. E. ve Giannetti, C. (2020). A Deep Learning model for Smart Manufacturing using Convolutional LSTM Neural Network Autoencoders. *IEEE Transactions on Industrial Informatics*, 16(9), 1–1 Doi: <https://doi.org/10.1109/tii.2020.2967556>
- Falamarzi, A., Moridpour, S., Nazem, M. ve Cheraghi, S. (2019). Prediction of tram track gauge deviation using artificial neural network and support vector regression. *Australian Journal of Civil Engineering*, 17(1), 63–71. Doi: <https://doi.org/10.1080/14488353.2019.1616357>
- Fernandes, S., Antunes, M., Santiago, A. R., Barraca, J. P., Gomes, D. ve Aguiar, R. L. (2020). Forecasting Appliances Failures: A Machine-Learning Approach to Predictive Maintenance. *Information*, 11(4), 208. Doi: <https://doi.org/10.3390/info11040208>
- García Nieto, P. J., García-Gonzalo, E., Sánchez Lasheras, F. ve de Cos Juez, F. J. (2015). Hybrid PSO–SVM-based method for forecasting of the remaining useful life for aircraft engines and evaluation of its reliability. *Reliability Engineering & System Safety*, 138, 219. Doi: <https://doi.org/10.1016/j.res.2015.02.001>
- Gohel, H.A., Upadhyay, H., Lagos, L., Cooper, K. Ve Sanzetenea, A. (2020). Predictive Maintenance Architecture Development for Nuclear Infrastructure using Machine Learning. *Nuclear Engineering and Technology*, 52(2020), 1436–1442. Doi: <https://doi.org/10.1016/j.net.2019.12.029>
- Han, C., Ma, T., Xu, G., Chen, S. ve Huang, R. (2020). Intelligent decision model of road maintenance based on improved weight random forest algorithm. *International Journal of Pavement Engineering*, 1–13. Doi: <https://doi.org/10.1080/10298436.2020.1784418>
- Hinton, G. E., Osindero, S. ve Teh, Y.- W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18 (7) (2006) 1527–1554.
- Hoffmann, M.W., Wildermuth, S., Gitzel, R., Boyacı, A., Gebhardt, J., Kaul, H., Amihai, I., Forg, B., Suriyah, M., Leibfried, T., Stich, V., Hicking, J., Bremer, M., Kaminski, L., Beverungen, D., zur Heiden, P. ve Tornede, T. (2020). Integration of novel sensors and machine learning for predictive maintenance in medium voltage switchgear to enable the energy and mobility revolutions. *Sensors*, 20(7), 2099. Doi: <https://doi.org/10.3390/s20072099>
- Hu, H., Tang, B., Gong, X., Wei, W. ve Wang, H. (2017). Intelligent fault diagnosis of the high-speed train with big data based on deep neural networks. *IEEE Transactions on Industrial Informatics*, 13(4), 2106–2116. Doi: <https://doi.org/10.1109/TII.2017.2683528>
- Hsu, J.- Y., Wang, Y.- F., Lin, K.- C., Chen, M.- Y. ve Hsu, J. H.- Y. (2020). Wind Turbine Fault Diagnosis and Predictive Maintenance through Statistical Process Control and Machine Learning. *IEEE Access*, 8, 23427 – 23439. Doi: <https://doi.org/10.1109/ACCESS.2020.2968615>
- Huang, D.-S. (1996). *Systematic Theory of Neural Networks for Pattern Recognition*, Publishing House of Electronic Industry of China, Beijing, 201.
- Ibarra-Zarate, D., Alonso-Valerdi, L. M., Chuya-Sumba, J., Velarde-Valdez, S. ve Siller, H. R. (2019). Prediction of Inconel 718 roughness with acoustic emission using convolutional neural network based regression. *The International Journal of Advanced Manufacturing Technology*, 105, 1609–1621.
- Jahnke, P., (2015). *Machine Learning Approaches for Failure Type Detection and Predictive Maintenance (yüksek lisans tezi)*, Technische Universität Darmstadt, Almanya.
- Jardine, A. K., Lin, D. ve Banjevic, D. (2006). A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical systems and signal processing*, 20(7), 1483-1510. Doi: <https://doi.org/10.1016/j.ymsp.2005.09.012>
- Janssens, O., Loccufier, M. ve Van Hoecke, S. (2019). Thermal imaging and vibration based multi-sensor fault detection for rotating machinery. *IEEE Transactions on Industrial Informatics*, 15(1), 434–444. Doi: <https://doi.org/10.1109/TII.2018.2873175>
- Janssens, O., Van De Walle, R., Loccufier, M., Van Hoecke, S. (2018). Deep Learning for Infrared Thermal Image Based Machine Health Monitoring. *IEEE/ASME Transactions on Mechatronics*, 2018, 23, 151–159. Doi: <https://doi.org/10.1109/TMECH.2017.2722479>
- Jia, F., Lei, Y., Lin, J., Zhou, X. ve Lu, N. (2016). Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical Systems and Signal Processing*, 72-73, 303–315. Doi: <https://doi.org/10.1016/j.ymsp.2015.10.025>
- Kaparthi, S., Bumblauskas, D. (2020). Designing predictive maintenance systems using decision tree-based machine learning techniques. *International Journal of Quality & Reliability Management*, 37(4), 659–686.
- Köksal, M. (2017). *Bakım Planlaması*. Ankara: Seçkin Yayıncılık.

- Krishnakumari, A., Elayaperumal, A., Saravanan, M. ve Arvindan, C. (2017). Fault diagnostics of spur gear using decision tree and fuzzy classifier. *The International Journal of Advanced Manufacturing Technology*, 89(9-12), 3487–3494.
- Kubat, M. (2017). *An Introduction to Machine Learning*. Second edition. Springer-Verlag. New York, NY, USA.
- Kusiak, A. ve Verma, A., 2011, Prediction of Status Patterns of Wind Turbines: A Data-Mining Approach. *Journal of Solar Energy Engineering*, 133(1), 011008. Doi: <https://doi.org/10.1115/1.4003188>
- Lasisi, A. ve Attoh-Okine, N. (2018). Principal components analysis and track quality index: A machine learning approach. *Transportation Research Part C: Emerging Technologies*, 91, 230–248. Doi: <https://doi.org/10.1016/j.trc.2018.04.001>
- Lei, Y., Jia, F., Lin, J., Xing, S. ve Ding, S. X. (2016). An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on Industrial Electronics*, 63(5), 3137–3147. Doi: <https://doi.org/10.1109/TIE.2016.2519325>
- Leo, B. (2001). Random forests. *Machine Learning*, 45, 5–32. Doi: <https://doi.org/10.1023/A:1010933404324>
- Lee, J. S., Hwang, S. H., Choi, I. Y. ve Choi, Y. (2019). Estimation of crack width based on shape-sensitive kernels and semantic segmentation. *Structural Control and Health Monitoring*, 37(4). Doi: <https://doi.org/10.1002/stc.2504>
- Li, C., Sanchez, R.-V., Zurita, G., Cerrada, M., Cabrera, D. Ve Vásquez, R. E. (2015). Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis. *Neurocomputing: An International Journal*, 168, 119–127. Doi: <https://doi.org/10.1016/j.neucom.2015.06.008>
- Li, G., Chen, H., Hu, Y., Wang, J., Guo, Y., Liu, J., Li, H., Huang, R., Lv, H. ve Li, J. (2018). An improved decision tree-based fault diagnosis method for practical variable refrigerant flow system using virtual sensor-based fault indicators. *Applied Thermal Engineering*, 129, 1292–1303. Doi: <https://doi.org/10.1016/j.applthermaleng.2017.10.013>
- Li, J. ve He, D. (2020). A Bayesian Optimization AdaBN-DCNN Method With Self-Optimized Structure and Hyperparameters for Domain Adaptation Remaining Useful Life Prediction. *IEEE Access*, 8, 41482–41501.
- Li, H., Parikh, D., He, Q., Qian, B., Li, Z., Fang, D. ve Hampapur, A. (2014). Improving rail network velocity: A machine learning approach to predictive maintenance. *Transportation Research Part C: Emerging Technologies*, 45, 17–26. Doi: <https://doi.org/10.1016/j.trc.2014.04.013>
- Li, H., Wang, Y., Zhao, P., Zhang, X. ve Zhou, P. (2014). Cutting tool operational reliability prediction based on acoustic emission and logistic regression model. *Journal of Intelligent Manufacturing*, 26(5), 923–931.
- Liao, L., Jin, W. ve Pavel, R. (2016). Enhanced Restricted Boltzmann Machine With Prognosability Regularization for Prognostics and Health Assessment. *IEEE Transactions on Industrial Electronics*, 63(11), 7076–7083. Doi: <https://doi.org/10.1109/tie.2016.2586442>
- Lin, Z. ve Liu, X. (2020). Wind power forecasting of an offshore wind turbine based on high-frequency SCADA data and deep learning neural network. *Energy*, 117693. Doi: <https://doi.org/10.1016/j.energy.2020.117693>
- Louis, S.-Y. M., Nasiri, A., Bao, J., Cui, Y., Zhao, Y., Jin, J., Huang, X. ve Hu, J. (2020). Remaining Useful Strength (RUS) Prediction of SiCf-SiCm Composite Materials Using Deep Learning and Acoustic Emission. *Applied Sciences*, 10(8), 2680. Doi: <https://doi.org/10.3390/app10082680>
- Lu, C., Wang, Z.-Y., Qin, W.-L. ve Ma, J. (2017). Fault diagnosis of rotary machinery components using a stacked denoising autoencoder-based health state identification. *Signal Processing*, 130, 377–388. Doi: <https://doi.org/10.1016/j.sigpro.2016.07.028>
- Luo, W., Hu, T., Ye, Y., Zhang, C. ve Wei, Y. (2020). A hybrid predictive maintenance approach for CNC machine tool driven by Digital Twin. *Robotics and Computer-Integrated Manufacturing*, 65, 101974. Doi: <https://doi.org/10.1016/j.rcim.2020.101974>
- Luo, B., Wang, H., Liu, H., Li, B. ve Peng, F. (2018). Early Fault Detection of Machine Tools Based on Deep Learning and Dynamic Identification. *IEEE Transactions on Industrial Electronics*, 66(1).
- Mahamad, A. K., Saon, S. ve Hiyama, T. (2010). Predicting remaining useful life of rotating machinery based artificial neural network. *Computers & Mathematics with Applications*, 60(4), 1078–1087. Doi: <https://doi.org/10.1016/j.camwa.2010.03.065>
- Malhi, A. ve Gao, R.X. (2004). PCA-based feature selection scheme for machine defect classification. *IEEE Transactions on Instrumentation and Measurement*, 53 (6) (2004) 1517–1525. Doi: <https://doi.org/10.1109/TIM.2004.834070>
- Montero Jimenez, J. J., Schwartz, S., Vingerhoeds, R., Grabot, B. ve Salaün, M. (2020). Towards multi-model approaches to predictive maintenance: A systematic literature survey on diagnostics and prognostics. *Journal of Manufacturing Systems*, 56, 539–557. Doi: <https://doi.org/10.1016/j.jmsy.2020.07.008>

- Nabizadeh, A. ve Tabatabai, H. (2020). Development of nonlinear probabilistic S-N curves using survival analysis techniques with application to steel bridges. *International Journal of Fatigue*, 105892. Doi: <https://doi.org/10.1016/j.ijfatigue.2020.105892>
- Namuduri, S. (2020). Review-Deep Learning Methods for Sensor Based Predictive Maintenance and Future Perspectives for Electrochemical Sensors, *Journal of the Electrochemical Society*, Volume: 167 Issue: 3, doi: <https://doi.org/10.1149/1945-7111/ab67a8>
- Nguyen, K.T.P. ve Medjaher, K. (2019). A new dynamic predictive maintenance framework using deep learning for failure prognostics, *Reliability Engineering & System Safety*, 188, 2019, 251-262.
- Özonur, D., Kılıç, D., Akdur, H. ve Bayrak, H. (2019). Temel Bileşenler Analizi ve Yanıt Yüzey Yöntemi Kullanılarak Gıda Sektöründe Çoklu Yanıtların Optimizasyonu. *Erzincan Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 12 (2019), 734-744. Doi: <https://doi.org/10.18185/erzifbed.485762>
- Öztaşır, O. (2018). Makine Öğrenmesi Kullanılarak Kestirimci Bakım (Yüksek Lisans Tezi). Elektrik ve Elektronik Anabilim Dalı, Hacettepe Üniversitesi, Danışman: Prof. Dr. Ali Ziya Alkar.
- Pandya, D. H., Upadhyay, S. H. ve Harsha, S. P. (2014). Fault diagnosis of rolling element bearing by using multinomial logistic regression and wavelet packet transform. *Soft Computing*, 18 (2) 255–266, 2014.
- Pench, M., Vrchota, J. ve Bednár, J. (2021). Predictive Maintenance and Intelligent Sensors in Smart Factory: Review, *Sensors*, 21, Doi:<https://doi.org/10.3390/s21041470>
- Phillips, J., Cripps, E., Lau, J. W. ve Hodkiewicz, M. R. (2015). Classifying machinery condition using oil samples and binary logistic regression. *Mechanical Systems and Signal Processing*, 60-61, 316–325.
- Prieto, M. D., Cirrincione, G., Espinosa, A. G., Ortega J. A. ve Henao, H. (2013). Bearing fault detection by a novel condition-monitoring scheme based on statistical-time features and neural networks. *IEEE Transactions on Industrial Electronics*, 60(8), 3398–3407.
- Prytz, R., Nowaczyk, S., Rögnvaldsson, T. ve Byttner, S. (2015). Predicting the need for vehicle compressor repairs using maintenance records and logged vehicle data. *Engineering Applications of Artificial Intelligence*, 41, 139–150. Doi: <https://doi.org/10.1016/j.engappai.2015.02.009>
- Rengasamy, D., Jafari, M., Rothwell, B., Chen, X. ve Figueredo, G. P. (2020). Deep Learning with Dynamically Weighted Loss Function for Sensor-Based Prognostics and Health Management. *Sensors*, 20(3), 723.
- Doi: <https://doi.org/10.3390/s20030723>
- Ruiz-Sarmiento, J.- R., Monroy, J., Moreno, F.- A., Galindo, C., Bonelo, J.- M. ve Gonzalez-Jimenez, J. (2020). A predictive model for the maintenance of industrial machinery in the context of industry 4.0. *Engineering Applications of Artificial Intelligence*, 87, 103289. Doi: <https://doi.org/10.1016/j.engappai.2019.103289>
- Saimurugan, M., Ramachandran, K. I., Sugumaran, V. ve Sakthivel, N. R. (2011). Multi component fault diagnosis of rotational mechanical system based on decision tree and support vector machine. *Expert Systems with Applications*, 38(4), 3819–3826. Doi: <https://doi.org/10.1016/j.eswa.2010.09.042>
- Santos, P., Maudes, J. ve Bustillo, A. (2018). Identifying maximum imbalance in datasets for fault diagnosis of gearboxes. *Journal of Intelligent Manufacturing*, 29(2), 333–351.
- Scalabrini Sampaio, G., Vallim Filho, A. R. de A., Santos da Silva, L. ve Augusto da Silva, L. (2019). Prediction of Motor Failure Time Using An Artificial Neural Network. *Sensors*, 19(19), 4342. Doi: <https://doi.org/10.3390/s19194342>
- Sexton, T., Brundage, M. P., Hoffman, M. ve Morris, K. C. (2017). Hybrid datafication of maintenance logs from AI-assisted human tags. *IEEE International Conference on Big Data* (ss. 1769–1777).
- Shafi, U., Safi, A., Shahid, A. R., Ziauddin, S. ve Saleem, M. Q. (2018). Vehicle Remote Health Monitoring and Prognostic Maintenance System. *Journal of Advanced Transportation*, 2018, 1–10. Doi: <https://doi.org/10.1155/2018/8061514>.
- Shamayleh, A., Awad, M. ve Farhat, J. (2020). IoT Based Predictive Maintenance Management of Medical Equipment. *Journal of Medical Systems*, 44.
- Shao, H., Jiang, H., Wang, F. ve Zhao, H. (2017). An enhancement deep feature fusion method for rotating machinery fault diagnosis. *Knowledge-Based Systems*, 119, 200–220. Doi: <https://doi.org/10.1016/j.knosys.2016.12.012>
- Shao, H., Jiang, H., Lin, Y. ve Li, X. (2018). A novel method for intelligent fault diagnosis of rolling bearings using ensemble deep auto-encoders. *Mechanical Systems and Signal Processing*, 102, 278–297. Doi: <https://doi.org/10.1016/j.ymssp.2017.09.026>
- Shao, H., Jiang, H., Zhao, H. ve Wang, F. (2017). A novel deep autoencoder feature learning method for rotating machinery fault diagnosis. *Mechanical Systems and Signal Processing*, 95, 187–204. Doi: <https://doi.org/10.1016/j.ymssp.2017.03.034>
- Shin, J.-H., Jun, H.-B. ve Kim, J.-G. (2018). Dynamic control of intelligent parking guidance using neural network predictive control. *Computers & Industrial*

- Engineering*, 120, 15–30. Doi: <https://doi.org/10.1016/j.cie.2018.04.023>
- Shrivastava, R., Mahalingam, H. ve Dutta, N. N. (2017). Application and evaluation of random forest classifier technique for fault detection in bioreactor operation. *Chemical Engineering Communications*, 204(5), 591–598.
- Si, X.- S., Wang, W., Hu, C.-H. ve Zhou, D.- H. (2011). Remaining useful life estimation – A review on the statistical data driven approaches. *European Journal of Operational Research*, 213(1), 1-14. Doi: <https://doi.org/10.1016/j.ejor.2010.11.018>
- Sikorska, J.Z., Hodkiewicz, M. ve Ma, L. (2011). Prognostic modelling options for remaining useful life estimation by industry. *Mechanical Systems and Signal Processing*, 25, 1803–1836. Doi: <https://doi.org/10.1016/j.ymsp.2010.11.018>
- Soualhi, A., Medjaher, K. ve Zerhouni, N. (2015). Bearing health monitoring based on Hilbert–Huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*, 64(1), 52–62. Doi: <https://doi.org/10.1109/TIM.2014.2330494>
- Su, C. J. ve Huang, S. F. (2018). Real-time big data analytics for hard disk drive predictive maintenance. *Computers and Electrical Engineering*, 71, 93–101.
- Susto, G. A., Member, S., Beghi, A. ve Luca, C. D. (2012). A predictive maintenance system for epitaxy processes based on filtering and prediction techniques. *IEEE Transactions on Semiconductor Manufacturing*, 25(4), 638–649. Doi: <https://doi.org/10.1109/TSM.2012.2209131>
- Susto, G. A., Schirru, A., Pampuri, S., McLoone, S. ve Beghi, A. (2015). Machine Learning for Predictive Maintenance: A Multiple Classifier Approach. *IEEE Transactions on Industrial Informatics*, 11(3), 812–820. Doi: <https://doi.org/10.1109/tii.2014.2349359>
- Thapliyal, P. ve Thakre, G. D. (2017). Correlation Study of Physicochemical, Rheological, and Tribological Parameters of Engine Oils. *Advances in Tribology*, 2017, 1–12. Doi: <https://doi.org/10.1155/2017/1257607>
- Tv, V., Diksha, Malhotra, P., Vig, L. ve Shroff, G. (2019). Data-driven Prognostics with Predictive Uncertainty Estimation using Ensemble of Deep Ordinal Regression Models. Erişim adresi: <https://www.researchgate.net/publication/331986412>
- Utah, M. N. ve Jung, J. C. (2020). Fault state detection and remaining useful life prediction in AC powered solenoid operated valves based on traditional machine learning and deep neural networks. *Nuclear Engineering and Technology*. Doi: <https://doi.org/10.1016/j.net.2020.02.001>
- Wakiru, J., Pintelon, L., Chemweno, P. ve Muchiri, P. (2017). A lubricant condition monitoring approach for maintenance decision support – A data exploratory case study. *Maintenance Forum*, (2017) 69–82.
- Wakiru, J. M., Pintelon, L., Muchiri, P. N. ve Chemweno, P. K. (2019). A review on lubricant condition monitoring information analysis for maintenance decision support. *Mechanical systems and signal processing*, 118, 108-132.
- Wang, Q., Bu, S. ve He, Z. (2020). Achieving Predictive and Proactive Maintenance for High-Speed Railway Power Equipment with LSTM-RNN. *IEEE Transactions on Industrial Informatics*, 1–1. Doi: <https://doi.org/10.1109/tii.2020.2966033>
- Wang, L., Zhang, Z., Long, H., Xu, J. ve Liu, R. (2017). Wind Turbine Gearbox Failure Identification With Deep Neural Networks. *IEEE Transactions on Industrial Informatics*, 13(3), 1360–1368. Doi: <https://doi.org/10.1109/tii.2016.2607179>
- Wu, Z., Guo, Y., Lin, W., Yu, S. ve Ji, Y. (2018). A Weighted Deep Representation Learning Model for Imbalanced Fault Diagnosis in Cyber-Physical Systems. *Sensors*, 18(4), 1096. Doi: <https://doi.org/10.3390/s18041096>
- Wu, T.-L., Sari, D. Y., Lin, B.-T. ve Chang, C.-W. (2017). Monitoring of punch failure in micro-piercing process based on vibratory signal and logistic regression. *The International Journal of Advanced Manufacturing Technology*, 93, 5–8, 2447–2458.
- Xia, M., Zheng, X., Imran, M. ve Shoaib, M. (2020). Data-driven prognosis method using hybrid deep recurrent neural network. *Applied Soft Computing*, 106351. Doi: <https://doi.org/10.1016/j.asoc.2020.106351>
- Xu, Y., Sun, Y., Liu, X. ve Zheng, Y. (2019). A Digital-Twin-Assisted Fault Diagnosis using Deep Transfer Learning. *IEEE Access*, 7, 19990-19999. Doi: <https://doi.org/10.1109/access.2018.2890566>
- Yan, J. ve Lee, J. (2005). Degradation Assessment and Fault Modes Classification Using Logistic Regression. *Journal of Manufacturing Science and Engineering*, 127(4), 912. Doi: <https://doi.org/10.1115/1.1962019>
- Yang, D., Liu, Y., Li, S., Li, X. ve Ma, L. (2015). Gear fault diagnosis based on support vector machine optimized by artificial bee colony algorithm. *Mechanism and Machine Theory*, 90, 219–229. Doi: <https://doi.org/10.1016/j.mechmachtheory.2015.03.013>
- Yeh, C.- H., Lin, M.- H., Lin, C.- H., Yu, C.- E. ve Chen, M. - J. (2019). Machine Learning for Long Cycle Maintenance Prediction of Wind Turbine. *Sensors*,

- 19(7), 1671. Doi: <https://doi.org/10.3390/s19071671>
- You, D., Gao, X. ve Katayama, S. (2015). WPD-PCA-based laser welding process monitoring and defects diagnosis by using FNN and SVM. *IEEE Transactions on Industrial Electronics*, 62(1), 628–636. Doi: <https://doi.org/10.1109/TIE.2014.2319216>
- Yu, J. (2018). Tool condition prognostics using logistic regression with penalization and manifold regularization. *Applied Soft Computing*, 64, 454–467. <https://doi.org/10.1016/j.asoc.2017.12.042>
- Yu, T., Zhu, C., Chang, Q. ve Wang, J. (2019). Imperfect corrective maintenance scheduling for energy efficient manufacturing systems through online task allocation method. *Journal of Manufacturing Systems*, 53, 282–290. Doi: <https://doi.org/10.1016/j.jmsy.2019.11.002>
- Zhang, X., Liang, Y., Zhou, J. ve Zang, Y. (2015). A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM. *Measurement*, 69, 164–179. Doi: <https://doi.org/10.1016/j.measurement.2015.03.017>
- Zhang, S., Liu, C., Su, S., Han, Y. ve Li, X. (2018). A feature extraction method for predictive maintenance with time-lagged correlation-based curve-registration model. *International Journal of Network Management*, 28(5). Doi: <https://doi.org/10.1002/nem.2025>
- Zhang, R., Peng, Z., Wu, L., Yao, B. ve Guan, Y. (2017). Fault Diagnosis from Raw Sensor Data Using Deep Neural Networks Considering Temporal Coherence. *Sensors*, 17(3), 549. Doi: <https://doi.org/10.3390/s17030549>
- Zhang, W., Yang, D. ve Wang, H. (2019). Data-Driven Methods for Predictive Maintenance of Industrial Equipment: A Survey. *IEEE Systems Journal*, 13(3), 2213–2227. Doi: <https://doi.org/10.1109/jsyst.2019.2905565>
- Zhang, B., Zhang, S. ve Li, W. (2019). Bearing performance degradation assessment using long short-term memory recurrent network. *Computers in Industry*, 106, 14–29. Doi: <https://doi.org/10.1016/j.compind.2018.12.016>
- Zhang, H., Zhang, Q., Shao, S., Niu, T. ve Yang, X. (2020). Attention-based LSTM network for rotatory machine remaining useful life prediction. *IEEE Access*, 8, 132188–132199. Doi: <https://doi.org/10.1109/access.2020.3010066>