

VERİ ODAKLI HATA TEŞHİS SİSTEMİ GELİŞTİRİLMESİ

Metin YILMAZ^{1*}, Ahmet YAZICI², Eyüp ÇINAR³

¹TEI – TUSAŞ Motor Sanayii A.Ş., TEI Eskişehir Yerleşkesi, Bilişim Teknolojileri Bölümü, Eskişehir

ORCID No: <http://orcid.org/0000-0001-9478-4114>

²Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir

ORCID No: <http://orcid.org/0000-0001-5589-2032>

³Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir

ORCID No: <http://orcid.org/0000-0003-3189-7247>

Anahtar Kelimeler	Öz
CNC Anomali Tespiti Verimlilik Prognostik Filo Tabanlı Durum İzleme	<i>Bu çalışmada, Veri Odaklı Hata Teşhis Sistemi Geliştirilmesi konusunda, üretimdeki CNC tezgâhları ve rulmanları hedefleyen bir uygulamanın detayları, uygulama çıktıları, analizleri ve sonuçları paylaşılmıştır. Üretim ve bilgisayar teknolojilerinin birleşimi ile verimliliği üst düzeye çıkarmak, yapay zekâ yaklaşımları ile insan hatalarını en aza indirmek ve makine öğrenmesi ile oluşabilecek hataları önceden tahmin edebilmek konusunda yapılmış bir çalışmadan ortaya çıkan analizler sunulmuştur. Önerilen ve uygulanan yöntem ışığında aynı özellikte makinelerin izlenmesini sağlamak amacıyla filo tabanlı bir izleme sisteminin kurulması hedeflenmiştir. Yapılan çalışma sonucunda; motor ve rulman arızaları için prognostik yaklaşımları test etmek amacıyla rulman arızalarını içeren deneyler olmak üzere dört farklı veri seti üzerinde önerilen yöntemin testleri yapılmış ve anomali puanları gösterilmiştir.</i>

DEVELOPMENT OF DATA-DRIVEN FAULT DIAGNOSIS SYSTEM

Keywords	Abstract
CNC Anomaly Detection Productivity Prognostic Fleet-based condition monitoring	<i>In this study, a literature review on Development of a Data-Oriented Fault Diagnosis System is presented and details of an application on a use-case is proposed with analysis and results. With an aim on utilizing the application with CNC machines and rolling bearings, an intelligent fleet-based monitoring system application is implemented. The implemented method ensures a fleet-based monitoring system is capable of monitoring machines with same type of data and features in a manufacturing environment. The methodology is tested on four rolling bearing offline datasets. The corresponding anomaly scores of each component is calculated and presented.</i>

Araştırma Makalesi	Research Article
Başvuru Tarihi : 30.07.2020	Submission Date : 30.07.2020
Kabul Tarihi : 04.11.2020	Accepted Date : 04.11.2020

1. Giriş

Günümüzde CNC tezgâhları üretimin her alanında kullanılarak kolaylık sağlamaktadır. Bir parça belirli standartlarda insan hatasını en aza indirerek üretilmek istenirse, CNC tezgâhları bir numaralı tercih olmaktadır. Tezgâhların çalışması hem enerji ve diğer kaynaklar hem de iş gücü açısından oldukça maliyetli araçlardır. Bu durumda tezgâhların kullanımında verimlilik gündeme gelmektedir. Bir tezgâh ne kadar verimli kullanılırsa üretime o kadar fazla katkısı olmaktadır ve daha düşük maliyetle daha fazla üretim yapabilmektedir. Bunun yanında, çizelgeleme fabrikalar için ciddi sorun teşkil etmektedir. Hangi makineye ne

kadar iş verilebilir, bir makinenin iş yoğunluğuna göre farklı makinelere iş verme üretim planlama açısından önem arz etmektedir (Yılmaz ve Gürel, 2019).

Üretim planlama işlemlerine çözüm üretmek amacıyla, tezgâhtan alınan veriler ile birçok analiz yapmak mümkündür. Bu verilerle gerçek zamanlı arıza alarmları ve ekranlama yapılabilmektedir. Geçmişe yönelik veri analizi ile vardiyalar arasında çalışma farkları ile personel takibi yapılabilir. Günlük, aylık bazlı çalışma analizleri yapılabilir. Makine kendi kapasitesinin ne kadarını kullanmış (OEE - Overall Equipment Effectiveness) olduğunun cevabı verilebilir. Ayrıca, üretim planlamaya göre ne kadar üretim yapılacağı, ne


* Sorumlu yazar; e-posta : metin.yilmaz@tei.com.tr

kadar üretildi? Uzun süre çalışmayan cihazların arızalı parçası var mı? gibi soruların yanıtı verilebilir. Planlı plansız duruş analizi, kapalı durum analizi ile cihazın neden çalışmadığı gibi durumlar da tespit edilebilir (Yılmaz ve Gürel, 2019).

Üretim planlamanın önemli bir problemi de plansız bakımların getirdiği maliyettir. İş aksamalarını önlemek adına önceden planlanabilen bir bakım yöntemi işletmeler açısından oldukça değerli olabilir. Bu bağlamda etkili olabilecek yenilikçi yöntemler; önleyici bakım ve olası anomali durumlarının önceden tespitini içerebilir. Günümüzde oldukça popüler olan Makine öğrenmesi yöntemleri ile önleyici bakım ve anomali tespiti yapılabilir. Örneğin, titreşim, sıcaklık, amper bilgileri ile bir CNC tezgahında hangi ucun ne zaman bozulacağını tahmini yapılabilir. Yüzeyin pürüzlü olma durumu gelen veriler ile tahmin edilebilir. Geçmiş verilere bakılarak ileride bu cihazla ne kadar parça üretilebileceği analizi yapılabilir. Tezgâhtan sensör veri değerlerini alarak üzerinde takılı ucun ne kadar aşındığını, bu aşınmanın parça üzerinde etkileri tespit edilebilir (Yılmaz ve Gürel, 2019).

Rulmanlar başta elektrik makineleri olmak üzere CNC makineleri de dahil pek çok döner makinede yaygın olarak kullanılmaktadır. Bu derece önemli bir parçada meydana gelebilecek arızalar, üretim ve hatta insan kayıplarına neden olacak ölümcül makine arızalarına bile sebep olabilir. Bu sebeple rulman parçalarındaki olası arızaların erken teşhisi çok önemlidir. Rulmanlarda genel olarak dış ve iç bilezik makaralar veya kafes içindeki kusurlardan arıza meydana gelmektedir. Böyle kusurlar rulmanın içinde dönen silindir arızalı yüzeyden her geçtiğinde darbe sebebiyle titreşime ve sese neden olur. Farklı arızalar için farklı titreşim ve frekans etkileri olabilmektedir.

Kestirimci bakım yöntemleri ile arıza tespiti yapılabilmektedir. Bu yöntemlerden prognostik; sistemin gerçek durumu, bu durumun iz düşümü ve arızadan önce kalan sürenin tahmini olarak vurgulanmıştır. Daha sonra ISO 13381-1 standardı ile yeniden tanımlanmıştır. Bu tanıma göre; "prognostik başarısızlıktan önceki çalışma süresinin tahmini ve gelecekteki var olma veya birkaç arıza modunun ortaya çıkma riskidir." Prognostik standardı ile prognostiğin ana hatları belirlenir ve prognostiği gerçekleştirmek için ihtiyaç duyulan veriler tanımlanır. Alt ve üst çalışma limitleri için kalibrasyon durumu da yine bu standart ile belirlenebilir. Standartın tanımladığı şekilde prognostik adımları Şekil 1'de gösterilmiştir.



Şekil 1. ISO 13381-1'e göre Prognostic Adımları
(Kozlov, Al-jonid, Kozlov ve Antar, 2017)

Günümüzde kullanılan arıza teşhis sistemlerin çoğu tek bir makine üzerinde analiz yapmaktadır. Bu analiz için geçmişe ait büyük veri setlerine ihtiyaç duyulmaktadır. Bunun için de ya benzer özellikte makinelerin uzun süre çalıştırılarak veri elde edilmesi ya da daha önceden kaydedilmiş veri setlerine ihtiyaç vardır. Uygulamada bu işlemler maliyetli olabilmektedir. Ancak benzer özellikte çalışan makinelerden oluşan bir filo varsa, bu filoya ait filo tabanlı bir izleme sistemi kurulabilir. Aynı özellikteki makinelerin farklı çalışma durumları bir arıza göstergesi olabilmektedir. Bunun tespiti için kurulan bir filo tabanlı sistem ile arızalar tespit edilebilir.

Aynı türde birden fazla makine içeren sistemlerde makinelerin birlerine göre durumları karşılaştırılarak bir arıza tespit yöntemi geliştirilebilir. Bu durumda tek bir makine analizi için gerek duyulabilecek büyük boyutta veri setlerine ihtiyaç yoktur. Makine çiftleri karşılaştırılarak, tüm makine filosunu kümelemek ve karşılaştırmalı olarak anomali tespiti yapmak mümkündür. Yapılan tüm aşamalar görselleştirilerek arıza tespitine en uygun yöntem gözlemlenebilir. Bu karşılaştırma yöntemleri için yapay zekâ ve makine öğrenmesi teknikleri kullanılabilir. Bu makalede sunulan yaklaşım makineler arası çevrim içi karşılaştırmaları hedeflemektedir. Filo içerisinde diğerlerinden farklı değerler gösteren makine arıza gösterebilmektedir. Farklı özelliklerin karşılaştırılması ile etkili bir analiz yöntemi geliştirilebilir. Örneğin bir ekipmanda anamoli tespiti için titreşim, sıcaklık, akım, gerilim, x-y-z yükleri ve nem karşılaştırılmada kullanılabilecek makine verileri arasında gösterilebilir (Hendrickx ve diğ., 2019).

2. Bilimsel Yazın Taraması

Anomali durumları sistemlerin olması gerektiği gibi çalışmadığında arızaya yol açtığı koşulları belirtmektedir. Bu durumlar iş gücünün aksamasına ve kayıplar yaşanmasına sebep olmaktadır. Bu sebeple erken bir arıza tespiti üretim planlaması adına önemli bir konu haline gelebilmektedir. Bu bölümde akıllı hata tespitine yönelik yöntemlerden prognostik yaklaşımlardan ve bu yöntemlerden biri olan filo tabanlı yönetim için yapılan ilgili bilimsel çalışmalara değinilmektedir.

2.1. Prognostik (Belirti)

Endüstri 4.0' da ön plana çıkan kestirimci bakım yöntemleri için veri madenciliği yaklaşımı ile arıza teşhisi ve belirtileri için üretimde makine merkezlerinde, ölçeklenebilir ve etkili bir sistem yaklaşımı gereksinimi duyulmaktadır. Endüstri 4.0'da kullanılan yaklaşımlardan; makineden makineye iletişim (machine-to-machine communication), radyo frekans kimliği (radio frequency identification, RFID)

teknolojisi, siber fiziksel sistemler (cyber-physical systems, CPS), nesnelerin interneti (the Internet of Things, IoT), sistemlerin interneti (the Internet of services, IoS), bulut bilişim (cloud computing), hesaplamalı zekâ (computational intelligence, CI), veri madenciliği (Data Mining, DM), ve karar/destek sistemleri (decision-making/supporting systems) alanlarındaki yöntem ve uygulamalarla birlikte kullanabilen ve tüm üretimi takip etmeyi hedefleyen bir akıllı sistem kurulabilir (Li, Wang ve Wang, 2017).

Cosme ve ark. (2017), çalışmalarında arıza prognostiği için gürültü ölçümlerinde, parçacık filtrelerinin etkili bir yöntem olduğunu göstermiştir. Ölçüm için alınan parçacıklardan, yeterli miktarda olamaması sebebiyle örnek yoksunluğu ile karşılaşmıştır. Bu örnek yoksunluğunu aşmak karşılaşılan ciddi sorunlardan biridir. Bu sorunu aşmak için, durum uzayından örneklenen rastgele bağımsız değişkenler üreten, diferansiyel denklem tabanlı, parçacık filtresi (Particle Filter based on Differential Evolution, PF-DE, called IPF), ardışık gelişim filtresi (sequential evolutionary filter, SEF) yaklaşımları ile PRONOSTIA (Rulman arızası belirtisine yönelik tezgâh testi) platformundan çalışma koşulları altında rulmanların daha hızlı bozulması, bir CNC makinesi üzerinde gerçekleştirilebilir (Cosme, D'Angelo, Caminhas, Yin ve Palhares, 2017).

Takım tezgâhlarında arıza durumları oluşması bu durumların kayıt altına alınması gibi durumlar söz konusu olduğunda gerçek hayatta yeterli veriye ulaşmakta problem yaşanabilmektedir. Tezgâh performansını değerlendirmek için, gerekli veri setini oluşturmak için yeniden yapılandırılabilir prognostik bir yaklaşım tasarlanabilir. Liao ve Lee (2009), sundukları çalışmalarındaki bir tasarımda The Watchdog Agent Toolbox'ı ile takım tezgâhlarının performansını değerlendirmek ve tahmin etmek için kolay ve etkili bir şekilde kullanılabilen hem donanım hem de yazılımın bir entegrasyonu olan yeniden yapılandırılabilir bir prognostik platformu (RPP) örneğini göstermektedir (Liao ve Lee, 2009).

Kalan yararlı ömür (Remaining Useful Lifetime, RUL) pek çok makine için önemli bir değerdir. Rulman elemanları yataklarında da böyle bir RUL değeri çıkarımı ve yaklaşan arıza tahmini rulmanın gelecekteki kullanımı ile ilgili fikir verebilmektedir. Ahmad ve ark. (2017), Sağlık göstergesi eğilimini öğrenmek için regresyona dayalı bir yaklaşım, tahmine başlama zamanını (Time to Start Prediction, TSP) belirlemek için gradyan bazlı bir yöntem önermektedir. TSP verilerinin analizinin doğru yapılması rulman bozulmalarının ilk aşamalarında, ciddi bir bozulma olmadığında, daha doğru bir RUL tahmini yapmaya katkı sağlar (Ahmad, Khan ve Kim, 2017).

Prognostik yöntemlerle arıza tespiti endüstride kullanılan bazı ekipmanlar için hayati önem taşımaktadır. Bu ekipmanların biri de yüksek hızlı shaft

yataklarında rüzgâr türbini aktarma organları arıza tespitidir. Saidi ve ark. (2017), çalışmalarında rüzgâr türbini jeneratörünün HSSB (high-speed shaft bearing) için bir destek vektörü regresyon (support vector regression) - SVR modeli eğitilmiştir. SK(spectral kurtosis) türevi ile ham titreşim sinyalinden yatak karakteristik sinyali çıkarılmıştır. HSSB'nin bozulma şiddeti değerlendirilmesi için sağlık indeksleri çıkarılmıştır. SK kaynaklı özelliklerin yatak kusurları hakkında erken bir uyarı sağladığı görülmüştür (Saidi, Ali, Bechhofer ve Benbouzid, 2017).

Arıza tespiti için; üretimde benzer işi yapan benzer özellikte bir cihaz filosu varsa, burada prognostik yöntemlerden biri olan bir filo yönetimi kurulabilir. Bir sonraki bölümde filo yönetimi ile ilgili yapılan literatür çalışmaları anlatılmaktadır.

2.2. Filo Yönetimi

Makinelerin filo tabanlı durum izlemesi için bir anomali tespit sistemi kurulabilir. Bu yapının temel avantajları; İlk olarak, çevrimiçi filo tabanlı karşılaştırmalar nedeniyle geçmişe ait bir veri kümesine ihtiyaç duymamaktadır. İkincisi, kullanıcı tanımlı karşılaştırma önlemleriyle alan uzmanlığının dahil edilmesini sağlar. Son olarak, çoğu yapay zekâ tekniklerinin aksine, uygulama çıktıları kolay yorumlanabilir ve ilgili alan uzmanının, uygulamanın yaptığı tahminleri doğrulamasına olanak tanır (Hendrickx ve diğ., 2019).

Filo yönteminde makine karşılaştırma ve kümelemede çeşitli matematiksel benzerlik metriklerine başvurulabilmektedir. Bunlardan bazıları; Öklid mesafesi, Kare öklid mesafesi, Maximum Benzerlik Metriği, Manhattan mesafesi, Jaccard benzerliği, Kosinüs benzerliği, Pearson benzerliği, Overlap benzerliği olarak tanımlanabilir.

Yaklaşık en yakın komşular algoritması, Jaccard Benzerliği, Kosinüs Benzerliği, Öklid Uzaklığı veya Pearson Benzerliği temel alınarak, sağlanan benzerlik algoritmasına dayanan bir nesne kümesi için k -En Yakın Komşular Grafiği oluşturur. Benzerlik algoritmaları makine çiftleri arasındaki ilgili özellikleri karşılaştırarak, makinelerin benzerlik oranlarını bulmayı sağlar. Böylece ortak özellik gösteren makineler tespit edilebilir.

Filo tabanlı sistemlerde, bulunan benzerlikten yola çıkılarak, birbiri ile ortak özellik gösteren makineler aynı grupta toplanır. Bir grupta ne kadar çok eleman varsa, o grubun sağlıklı olma ihtimali o denli yüksektir. Bu gruplama işlemi kümeleme algoritmaları sayesinde gerçekleştirilir. Kümeleme algoritmaları yöntemlerinden centroid tabanlı kümelemede, veriler hiyerarşik olmayan kümeler halinde düzenlenir. En yaygın kullanılan centroid tabanlı kümeleme algoritması K -Means'dir. Centroid tabanlı algoritmalar etkilidir, ancak başlangıç koşullarına ve aykırı değerlere

duyarlıdır. Geometrik merkez şeklinde kümeler dağılım halinde gösterilir. Merkezin her bir bölümünde bulunan elemanlar o kümeye aittir.

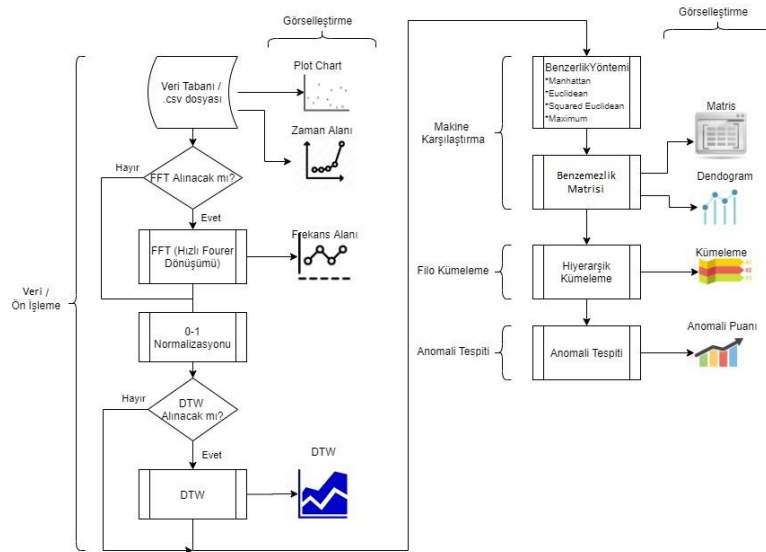
Yoğunluk tabanlı kümelemede ise; örnek yoğunluğuna göre gruplanan kümeler, keyfi şekillerde dağılırlar. Bu algoritmalar, değişen yoğunluklara ve yüksek boyutlara sahip verilerde güçlük çekmekte ve kümelere aykırı değer atanmamaktadır.

Dağıtım tabanlı kümeleme yönteminde noktaların Gauss gibi dağılımlardan oluştuğu varsayılır. Dağıtım tabanlı kümelemede bir nokta, dağıtımın merkezinden uzaklaştıkça, o dağılıma ait olma olasılığı azalmaktadır. Dağılımlarda iç içe gösterilen bantlar olasılıktaki düşüşü gösterir. Bu algoritma ancak veriler dağıtım türü biliniyorsa kullanılabilir.

Hiyerarşik kümeleme, hiyerarşik verilerden oluşan yapılarda kullanışlıdır. Bu algoritma bir küme ağacı oluşturur. Küme ağacı ne kadar seviyeye kadar alt kümeye ineceği seçilebilir. Küme sayısı belirlemek zorunlu değildir.

Filo halinde gelen veriler zaman ekseninde aynı hizada olmadığı durumlarda bazı ön işleme yöntemleri kullanılabilir. Dinamik Zaman Yamulması (Dynamic Time Warping - DTW), zaman serisi analizinde, zaman serisini temsil eden bir diziyi hizalayan başarılı bir algoritmadır. Amaç, minimum toplam mesafeye sahip X ve Y dizilerini zaman ekseninde hizalamaktır. X ve Y arasındaki benzerlik daha sonra Eşitlik 1'deki şekilde ifade edilir. Burada L benzerlik için tanımlanan dizinin uzunluğunu, $c(x,y)$ 'de maliyet fonksiyonunu tanımlar (Hendrickx ve diğ., 2019):

$$s(x, y) = \min \sqrt{\sum_{i=1}^L c(x_{p_{i,0}}, y_{p_{i,1}})^2} \quad (1)$$



Şekil 2. Uygulama Akış Diyagramı

Literatür incelendiğinde filo yönetimi ile ilgili çok fazla çalışmaya rastlanmamıştır. Bu alanda filo yönetimi ile veri odaklı bir hata tespit sisteminin uygulamasını göstererek literatüre katkı sağlanması hedeflenmektedir. Aynı zamanda sunulan çalışmanın bir diğer katkısı da makine ve rulman arızalarını içeren farklı veri setlerine uygulanarak sonuçların gösterilmesidir.

3. Yöntem

Bu çalışmada önerilen veri odaklı hata teşhis yöntemi, benzer özellikte makinelerden oluşan bir sisteme uyarlanmak üzere tasarlanmıştır. Bu yöntem; CNC makinesine entegre edilen servis uygulaması sayesinde, network üzerinden çevrim içi olarak anlık veri toplanmasına uygun bir yaklaşımdır. Sistemdeki tüm makinelerin anlık olarak izlenmesi ve olası anomali durumlarının grafiksel olarak gösterilmesine ihtiyaç vardır. Bu ihtiyaçların karşılanabilmesi için filo tabanlı izleme sistemi önerilmektedir.

Önerilen sistemin Şekil 2'de uygulama akış diyagramı görülmektedir. Uygulama; veri ön işleme ve makine çiftlerinin karşılaştırılması, filo kümeleme ve anomali tespiti bloklarından oluşmaktadır. İlk blokta sisteme anlık ya da geçmişe yönelik veriler gelmektedir. Bu veriler çeşitli ön işlemlere tabi tutularak, makine karşılaştırmasında kullanılmıştır. Makine karşılaştırma işleminde ise karşılaştırma algoritmaları ile makine çiftleri karşılaştırılarak, filo kümeleme bölümündeki kümeleme algoritmalarına aktarılmıştır. Filo kümeleme yapılan sonraki blokta da benzerlik algoritmaları ile aynı özellikteki makineler aynı kümeye alınmıştır. Son blokta da oluşan küme için, makine dağılımlarının ters orantısı aracılığı ile anomali puanları hesaplanmıştır. Anomali puanı hesaplanırken; diğer kümelerdeki eleman sayısının toplam eleman sayısına oranı ile bulunur.

Bu yöntemde her bir bloktaki veriler görselleştirilerek alan uzmanlığına gerek kalmadan arıza gözlemlenebilir ve uyarılar oluşturulabilir. Sonraki bölümlerde bu bloklardaki işlemler detaylı bir şekilde incelenmiştir.

3.1. Makine Karşılaştırma

Bu bölümde veri ön işlemeden sonra makine çiftlerini karşılaştırmakta yararlanılacak benzerlik algoritmaları açıklanacaktır. Makine karşılaştırmak için Bölüm 2.2'de sunulan benzerlik mesafe ölçü metriği belirlenip kullanılabilir. Makine çiftlerinin X ve Y eksenlerinde nasıl karşılaştırılacağına karar vermek ilk adımdır. Karşılaştırmak için ilk olarak makineden alınan veriler sinyalin türüne göre zaman sinyal alanında işlenebilir veya frekans alanına dönüşümü sağlanabilir. Titreşim verileri gibi yüksek frekanslarda harmonikler içeren zaman serisine ait sensör verilerini mesafe tabanlı karşılaştırmak, zaman alanında güçlükler ve istenmeyen sonuçlar doğuracağından, frekans alanında spektral benzerlik karşılaştırmasının yapılması daha sağlıklıdır. Sonrasında makineler bu sinyal alanlarında karşılaştırılır. Elde edilen veriler sıralı çiftler halinde 1 den n e kadar tek tek karşılaştırılır ve filodaki tüm makinelerin birbirleri ile benzemezlik (dissimilarity) matrisi oluşturulur. İki makine arasındaki benzemezlik oranı 0 ile 1 arasında bir değer almaktadır. Benzemezlik oranı sıfıra ne kadar yakınsa iki makine o kadar benzerdir denilir. Aynı makinelerin benzemezlik değeri sıfırı göstermektedir.

Makineden ilgili veriler anlık ölçümleri yakalayan sensörler ya da makine istemcilerine bağlı olarak çalışan MT Connect standardı ile toplanabilir (Yılmaz ve Gürel, 2019). Alınan ham verileri kaynağına göre başka bir sinyal alanına dönüştürmek, veriler üzerinde işlem ve çeşitli analizler yapmak için avantajlar sağlayabilir. Zaman alanındaki bir sinyali frekans alanına dönüştürmek için Hızlı Fourier Dönüşümü (Fast Fourier Transform - FFT) kullanılabilir.

Her makine, ardışık olarak elde edilen FFT dizileri ile temsil edilir. Uygulamada, veriler frekans ölçeğine dönüştürülür ve her makinenin benzer bir değer aralığına sahip olması için FFT verisi min / maks ölçekleme kullanılarak normalleştirilir. Sinyalin kaynağına göre ilgilenilmeyen yüksek frekanslar ve harmonikleri düşük frekanstaki alçak geçiren filtre ile kaldırılabilir.

Titreşim gibi yüksek frekanslarda değişim gösterebilecek özellikleri barındıran verilerde zaman uyumsuzluğu etkisini azaltmak için DTW (Eşitlik (10)) ve frekans alanı dönüşümü tercih edilebilir. Toplanan verilerin hızı değişkenlik gösterdiğinde DTW, spektrumları en uygun şekilde hizalayacaktır. Bu durumda veri, boyutları ve bölme sayısındaki sıklıkları eşit olan zaman serileri olarak kabul edilebilir.

Verileri karşılaştırmak için seçilen benzerlik veya farklılık ölçütlerine göre benzerlik oranları bulunabilir. Elde edilen veriler arasındaki benzerliği bulmak için, Bölüm 2.2'de bahsedilen metriklerden Öklid Mesafesi, Kare Öklid Mesafesi, Manhattan ve Maksimum Benzerlik yöntemleri uygulanmıştır.

Makine karşılaştırma sonucunda oluşan çıktılar ile filo kümeleme yapılabilir. Bir sonraki bölümde filo kümeleme ile ilgili bu çalışmada seçilen ve uygulanan yöntemler anlatılmaktadır.

3.2. Filo Kümeleme

Benzer davranan makineleri gruplamak için kümeleme algoritmaları kullanılır. Filo kümeleme, makineleri ikiye bölünebilir olarak, seçilen iki eksen (X, Y) karşılaştırmak için bir kümeleme algoritması kullanır ve benzer şekilde davranan makineleri aynı küme içinde tanımlar.

Kümeleme için benzerlik bloğundan elden edilen benzemezlik matrisi kullanılır. Bir küme içerisinde ne kadar çok üye varsa, doğruluğu o kadar yüksektir.

Bu çalışmada kümeleme algoritmasında kullanılan yöntem hiyerarşik kümeleme yöntemidir. Centroid tabanlı algoritmalar Hiyerarşik kümeleme yöntemine göre daha etkili olabilir ancak başlangıç koşullarına ve anlık değişimlere duyarlı olabilmektedir. Yoğunluk tabanlı kümeleme, değişen yoğunluklara ve yüksek boyutlara sahip verilerle güçlük çekmektedir. Dağıtım tabanlı kümeleme ise, ancak verilerin dağıtım türü biliniyorsa kullanılabilir. Diğer taraftan hiyerarşik kümelemede küme sayısını önceden belirlemeye gerek yoktur. Tüm bu durumlar göz önünde bulundurulduğunda, kümeleme algoritması için hiyerarşik kümeleme seçilmiştir.

3.3. Anomali Tespiti

Sistemdeki makinelere anomali puanı atamak için oluşturulan kümeler kullanılır. Benzer davranışa sahip makinelerin aynı kümede olması beklenir ve bir kümedeki makine sayısının büyüklüğü, sağlıklı davranış gösterme olasılığı ile doğru orantılıdır. Makinenin anomali puanını bulmak için; kendi kümesinde olmayan makinelerin toplam makinelere oranı hesaplanır. Bu sebeple arıza ihtimali yüksek makinelerin anomali puanı bire yakındır. Bir ile sıfır arasındaki bu puan; her makineyi sağlıklı veya arızalı olarak sınıflandırmada kullanılır. Ayrıca filonun büyüklüğü ve hatalı makinelerin beklenen oranı hakkında bilgi verir.

3.4. Görselleştirme

Her bloğun sonuçlarını görselleştirmek, makinenin sağlık koşulları ve uygulamanın tahminleri hakkında fikir verebilir. Bu görselleştirmeler açısından, benzemezlik matrisi, dendogram grafiği, plot chart ve kümeleme grafiği güçlü araçlardır.

Bu çalışmada detaylı olarak bahsedilen blokları özetlemek için uygulanan methodun sözde kodu aşağıda verilmiştir.

```
FiloTabanlıYonetimAnomaliTespiti ()
    ZamanAlanıSinyali ()
    DataÖnİşlemeFFT ()
    FFTSinyali ()
    DTWUygula ()
    DTWSinyali ()
    BenzemezlikBul (SeçilenYöntem)
    BenzemezlikMatrisiOluştur ()
    DendogramOluştur ()
    KümelemeOluştur ()
    AnomaliPuanıTanımla ()
```

Bu çalışmada araştırma ve yayın etiğine uyulmuştur.

4. Bulgular

Uygulama bloklar halinde tasarlanmıştır. Her bir bloğun çıktısı grafikleştirilerek görsel dinamiklik sağlanmıştır. Bu sistem; C# ile MVC uygulaması ile hazırlanmıştır. Sistem geçmişe yönelik veri setleriyle beslenecek şekilde hazırlanmış ancak uyarılama yapılarak anlık veri ile çalışacak hale getirilebilir. Sistemde kullanılan formül ve algoritmalar tüm veri setlerine uygulanarak her blok için çıktı oluşturacak duruma getirilmiştir. Bloklar birbirini besler niteliktedir. Grafik gösterimleri için D3.js (Data Driven Document) kullanılmıştır (Data-Driven Documents, 2020). Grafik beslemeleri için de JSON ve CSV dosyaları oluşturulmuştur. Sistem dört ayrı veri setindeki titreşim, basınç düşüşü, aşırı basınç, basınç sızıntısı ve sıcaklık parametreleri için ayrı ayrı çalıştırılmış ve her bloktaki çalışmalar gözlemlenmiştir.

Uygulama içerisinde çok katmanlı bir yapı oluşturulmuştur. Service katmanında verilerle ilgili işlemler, dosya analizleri ve grafik için dosya oluşturma, algoritma türetme ve formül uyarılama, benzerlik, karşılaştırma, anomali puanı oluşturma gibi fonksiyonlar tanımlanmıştır. Controller katmanında ise service katmanında yazılan kodlar çağırılarak sistemin web üzerinden çalıştırılması sağlanmıştır. Son olarak view katmanında verileri oluşturulan grafiklerin D3.js ile görselleştirilmesi sağlanmıştır. Bu grafiklerden anlık olarak tüm sistemin takibi yapılabilmektedir.

Uygulama PHM 2009, PHM2012, PHM2018 ve IMS veri setlerine uygulanmış ve anomali sonuçları alınmıştır. Bu çalışmada PHM2012 ve IMS veri setleri için alınan sonuçlar açıklanmıştır.

4.1. PHM 2012 Data Challenge Veri Seti ile Elde Edilen Sonuçlar


Bu veri seti; Pronostia Platformundan, motor ve rulman arızaları için prognostik yaklaşımları test etmek amacıyla toplanmış bir veri setidir. Bu setteki 17 rulman için titreşim ve sıcaklık sensörlerinden alınan veriler önerilen sisteme uygulanmıştır. Veri setindeki her bir

rulman, bir makine filosu içerisinde farklı makinelerden gelen bir makine bileşeni olarak da düşünülebilir. Veri seti için rulman isimlendirmeleri Bearing ile başlatılıp çalışma koşuluna göre numaralandırılmıştır, örn. Bearing_1_4 gibi.

Titreşim verileri için 17 rulman verisinden 14'ünün birbirine yakın zamanlardaki kısımları alınmıştır. B_1_4, B_3_3, ve B_2_7 rulmanlarından ise daha sonraki zamanlarda veri parçaları alınmıştır. Her bir rulmandan 40 milisaniye aralıklarda 2.500 veri alınmıştır.


4.1.1. Titreşim Değerleri için Makine Karşılaştırma

Uygulamaya aktarılan titreşim verileri ile sonuçlar alınmış ve grafiksel olarak gösterilmiştir. Şekil 3'te bir rulman için, ham titreşim verilerinin zaman alanı üzerinde, tepe değerleri ve verinin zamana göre akışı gösterilmiştir.




Şekil 3. Zaman Alanı Sinyali (X: Zaman ve Y: Titreşim Eksenleridir)

Şekil 4'te zaman alanındaki titreşim sinyaline FFT uygulanarak frekans alanına çevrilmiş ve 0-1 min/max normalizasyonu sağlanmıştır. Kesim frekansı 300 Hz olarak belirlenmiş ve bunun üzerindeki sinyaller atılmıştır.



Şekil 4. FFT Frekans Alanı Sinyali (X: Frekans ve Y: Titreşim Eksenleridir)

FFT den üretilen frekans alanındaki verilere DTW işlemi uygulanarak, Şekil 5'deki sonuçlar alınmıştır.




Şekil 5. DTW İşlemi Sonucu

DTW sinyali üzerinden rulman çiftleri çeşitli yöntemlerle (öklid, kare öklid, menhattan, maximum) aralarındaki mesafe hesaplanarak Tablo1'deki benzemezlik matrisi sonuçları elde edilmiştir.

Benzerlik algoritmalarında benzerlik oranı yaklaşık 0.5 olduğu varsayılmaktadır. Burada da 0.5 altındaki değerler işaretlenerek benzer makine çiftleri gösterilmiştir. Tablo 1'de oluşturulan benzemezlik matrisi için Öklid Mesafesi kullanılmıştır. Diğer kullanılan metrikler (kare öklid, menhattan, maximum) için de yakın değerler alındığı gözlemlenmiştir. İkili üye çiftleri arasındaki benzemezlik oranları küçük farklılıklar gösterse de benzer ya da farklı olan üyeler değişmemiştir.

Rulmanların nokta grafiği makinelerin titreşim verilerinin ham değerleri ile oluşturulur. Her bir rulman için gelen tüm değerlerin ortalaması alınarak Şekil

6'daki gibi gösterilmektedir. Rulmanların durumlarına göre grafik üzerinde yerleri belirlenmiş ve oluşan filoda farklılık gösteren rulmanlar farklı bölgelerde konumlanmıştır. İşlemler sonucunda benzemezlik oranları farklı olduğu tespit edilen üç rulmanın (B_1_4, B_3_3 ve B_2_7) bu grafikte farklı bölgelerde olduğu görülmektedir. Ancak ham veriler üzerinde işlem yapıldığından, anlık değişimler gibi sebeplerden dolayı sonuçlar güvenilir olmayabilir. Bu grafik sadece karşılaştırma maksatlı verilmiştir.



Şekil 6. Nokta Grafiği


Rulmanların dendogram grafiği, benzemezliği düşük olandan yüksek olana doğru çizdirilir. Bu işlem için benzemezlik matrisinden faydalanılır. Benzemezlik oranı en düşük olandan en yüksek olana doğru ikiyeşerli gruplar belirlenir. Rulman grubundaki bir rulman grafiğe daha önce eklenmişse, gruptaki diğer rulman bu

Tablo 1
Benzemezlik Matrisi

	1_3	1_4	1_5	1_6	1_7	2_3	2_4	2_5	2_6	2_7	3_3	1_1	1_2	2_1	2_2	3_1	3_2
1_3	0	0.516	0.28	0.307	0.298	0.268	0.258	0.264	0.268	0.657	0.974	0.321	0.329	0.258	0.265	0.288	0.274
1_4	0.516	0	0.514	0.509	0.513	0.519	0.521	0.518	0.517	0.645	0.517	0.506	0.506	0.528	0.517	0.515	0.516
1_5	0.28	0.514	0	0.298	0.295	0.274	0.26	0.266	0.262	0.658	0.972	0.323	0.313	0.265	0.263	0.286	0.275
1_6	0.307	0.509	0.298	0	0.316	0.303	0.294	0.298	0.294	0.655	0.955	0.337	0.333	0.296	0.29	0.313	0.302
1_7	0.298	0.513	0.295	0.316	0	0.287	0.283	0.289	0.282	0.657	0.961	0.333	0.334	0.287	0.281	0.305	0.292
2_3	0.268	0.519	0.274	0.303	0.287	0	0.245	0.251	0.255	0.659	0.99	0.317	0.318	0.237	0.258	0.275	0.263
2_4	0.258	0.521	0.26	0.294	0.283	0.245	0	0.239	0.242	0.661	0.999	0.316	0.313	0.221	0.236	0.268	0.252
2_5	0.264	0.518	0.266	0.298	0.289	0.251	0.239	0	0.249	0.66	0.99	0.311	0.315	0.238	0.249	0.276	0.255
2_6	0.268	0.517	0.262	0.294	0.282	0.255	0.242	0.249	0	0.66	0.983	0.315	0.309	0.24	0.244	0.278	0.26
2_7	0.657	0.645	0.658	0.655	0.657	0.659	0.661	0.66	0.66	0	0.646	0.653	0.653	0.664	0.66	0.657	0.659
3_3	0.974	0.517	0.972	0.955	0.961	0.99	0.999	0.99	0.983	0.646	0	0.943	0.947	0.507	0.987	0.979	0.982
1_1	0.321	0.506	0.323	0.337	0.333	0.317	0.316	0.311	0.315	0.653	0.943	0	0.345	0.329	0.315	0.323	0.315
1_2	0.329	0.506	0.313	0.333	0.334	0.318	0.313	0.315	0.309	0.653	0.947	0.345	0	0.332	0.312	0.331	0.321
2_1	0.258	0.528	0.265	0.296	0.287	0.237	0.221	0.238	0.24	0.664	0.507	0.329	0.332	0	0.229	0.273	0.253
2_2	0.265	0.517	0.263	0.29	0.281	0.258	0.236	0.249	0.244	0.66	0.987	0.315	0.312	0.229	0	0.276	0.255
3_1	0.288	0.515	0.286	0.313	0.305	0.275	0.268	0.276	0.278	0.657	0.979	0.323	0.331	0.273	0.276	0	0.275
3_2	0.274	0.516	0.275	0.302	0.292	0.263	0.252	0.255	0.26	0.659	0.982	0.315	0.321	0.253	0.255	0.275	0

rulman çiftine yeni bir değer olarak eklenir. Örneğin Şekil 7'de B_2_1 ve B_2_4 rulman çifti oluşturulmuştur ve B_2_2 rulmanı da bu çifte yeni bir benzerlik olarak eklenmiştir. Sonrasında gelen B_2_3 rulmanı da önceki çiftlerle benzerlik gösterdiğinden, önceki benzerliklere eklenmiştir. Bu döngü tüm rulmanlar sisteme dâhil olana kadar devam etmektedir.

Oluşturulan JSON dosyasından beslenecek şekilde D3.js yardımı ile Şekil 7'deki dendogram grafiği çizdirilir.



Şekil 7. Dendogram Grafiği

4.1.2. Filo Kümeleme ve Anomali Tespiti

Benzemezlik matrisi kullanılarak hiyerarşik kümeleme ile kümeler oluşturulmuş ve her kümedeki rulmanların anomali puanı bulunmuştur. Tablo 2'de bu kümeler ve anomali puanları görülmektedir. Tüm görsel grafikler ve kümeleme sonuçlarında görüleceği üzere; B_1_4, B_3_3 ve B_2_7 rulmanları diğerlerinden farklılık göstermektedir. Veriler incelendiğinde de bu üç rulmandaki titreşim değerleri diğer rulman gruplarına göre farklılık göstermektedir. Dolayısıyla kümelemede farklı bir grupta yer almıştır. Genel olarak rulmanlarda aşınmadan dolayı iç yüzükte yıpranma, bilyelerin esnemesi nedeniyle dönme problemleri, yorulma sebebiyle pullanma gibi arıza oluşabilmekte ve bunlar titreşim verisi değerlerine yansiyabilmektedir. Böyle durumlarda aynı çalışma şartlarında hareket ettiği varsayılan bu rulman parçaları anomali durumu gösterdiğinden arızalı kabul edilebilir.

Aynı veri setinin sıcaklık verileri için de anomali tespiti çalışması denenmiş ve başarılı sonuçlar alınmıştır.

Tablo 2
Kümeleme ve Anomali Puanı

Bearing	Cluster	Anomaly Point
B_2_4, B_2_1, B_2_2, B_2_3, B_2_5, B_2_6, B_3_2, B_1_3, B_1_5, B_3_1, B_1_7, B_1_6, B_1_2, B_1_1	0	0.17
B_1_4	1	0.94
B_3_3	2	0.94
B_2_7	3	0.94

4.2. IMS Bearing Veri Seti ile Elde Edilen Sonuçlar

Bu çalışma içinde kullanılan bir diğer veri seti olan IMS Rulman deneyleri veri seti Cincinnati Üniversitesi Akıllı Bakım Sistemleri Merkezi (IMS) tarafından sağlanmıştır. dört rulman için 20 KHz örnekleme hızında setler oluşturulmuştur. Veriler Bearing olarak adlandırılmış ve yerleştiği yere göre isimlendirilip B_1_4 gibi

kısaltmalarla ifade edilmiştir. Dört rulman için aynı çalışma koşullarından; B_1_4, B_1_5 ve B_1_6 aynı zaman aralığında, B_1_7 ise farklı zaman aralığında olmak üzere 2.500 örnek alınarak uygulamaya girdi olarak sağlanmıştır.

4.2.1. Titreşim Değerleri İçin Makine Karşılaştırma

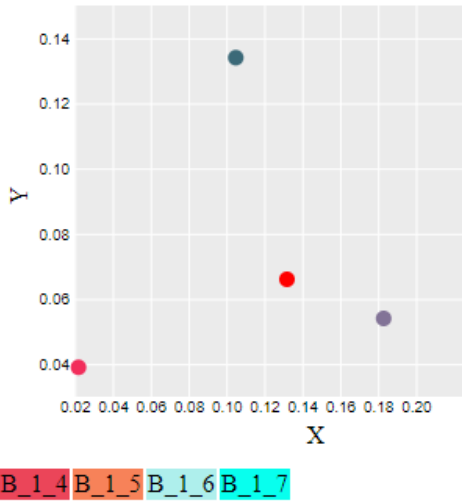
Titreşim değerleri uygulamaya aktarılmış ve uygulama anomali sonuçları için çalıştırılmıştır. Yüksek frekanslarda değişim gösterebilecek özellikleri bulunan titreşim verisine FFT uygulanarak 0-1 normalizasyonu yapılmış ve 300 Hz üzeri atılmıştır. Bu FFT den üretilen frekans alanındaki değerlere DTW uygulanmıştır. Daha sonra DTW alınmış değerler üzerinden öklid, kare öklid, manhattan ve maximum benzerlikleri uygulanarak benzemezlik matrisi oluşturulmuştur. Bu matris Tablo 3'te gösterilmiştir. Burada da benzer şekilde Tablo 3'de oluşturulan benzemezlik matrisi için Öklid Mesafesi kullanılmıştır. Diğer kullanılan metrikler için de yakın değerler alındığı gözlemlenmiştir. İkili üye çiftleri arasındaki benzemezlik oranları küçük farklılıklar gösterse de benzer ya da farklı olan üyeler değişmemiştir.

Bu benzemezlik matrisinden de dendogram grafiği üretilerek hiyerarşik olarak gösterilebilir.

Tablo 3
Benzemezlik Matrisi

	B_1_4	B_1_5	B_1_6	B_1_7
B_1_4	0	0.3835	0.4152	0.5697
B_1_5	0.3835	0	0.4182	0.554
B_1_6	0.4152	0.4182	0	0.5884
B_1_7	0.5697	0.554	0.5884	0

IMS veri setindeki ham veriler üzerinde ortalama alınarak gösterilen Şekil 8'deki nokta grafiğinde; B_1_6 ve B_1_5 yan yana gösterilse de B_1_4 daha uzak bir bölgede görülmektedir. B_1_7 uygulamada hesaplandığı gibi uzak bir bölgededir. Buradaki farka yine anlık değişimler gibi etkenler neden olmuştur.



Şekil 8. Nokta Grafiği

4.2.2. Titreşim Filo Kümeleme ve Anomali Tespiti

Tablo 4'teki grafikte görüldüğü gibi B_1_7, B_1_5 ve B1_6 rulmanları ve B_1_7 rulmanı bağımsız birer kümedir. Buradan yola çıkarak anomali puanı yüksek olan B_1_7 rulmanı arızalıdır denilebilir. Bu sonuçlara göre, olası rulman arıza durumlarında farklı değerler üreten rulmanların farklı bir kümeleme grubunda olduğu gözlemlenebilir.

Tablo 4

Kümeleme ve Anomali Puanı

Bearing	B_1_4	B_1_5	B_1_6	B_1_7
Cluster	0	0	0	1
Anomaly Point	0.25	0.25	0.25	0.75

5. Tartışma

Filo izleme tabanlı denetim sistemlerinde, geleneksel izleme yaklaşımlarına göre sağladığı avantajlar şunlardır: Öncelikli olarak anlık makine durum izlemesi imkânı sağlar bu sebeple makine durumundaki sapmayı algılayabildiğinden, tüm olası makine hatalarını daha önceden sisteme öğretmeye ihtiyaç yoktur. Böylece veri odaklı bir uygulama için daha az veriye ihtiyaç duyar. Filo izleme yaklaşımlarında makinelerin gerçek sağlık durumları bilgisini içeren yüksek boyutlu geçmiş veri setlerine ihtiyaç duymaz. Bir diğer avantajı ise makinelerin çalıştığı ve üretimin devam ettiği koşullarda analiz yapılabilmesidir. Anlık karşılaştırmalar daha önceden rastlanmamış ya da gözden kaçan koşullarda bile herhangi bir makinedeki sapma durumlarını tespit edebilir. Ayrıca grafiksel görselleştirmeler sistemin okunabilirliğini üst düzeye çıkardığından alan bilgisi uzmanlığı olmadan da arıza

tahminlerine olanak tanır.

Filo tabanlı yaklaşımlarda genel olarak izlenen filo üyelerinin birbirleriyle karşılaştırılması için yeterli sayıda üyeye sahip olduğu ve başlangıç koşulları olarak sağlıklı olduğu varsayımı yapılır. Önerilen algoritmanın başarılı bir şekilde kümeleme ve karşılaştırma yapabilmesi için yeterli miktarda elemana sahip olması, az sayıdaki üyesi olan filolar için bir problem teşkil edebilir. Makinelerin ilerleyen ömür süresi boyunca normal (sağlıklı) durumdan sapmaları beklenir. Mevcut olan sapmanın diğer küme elemanlarına göre farklılık göstermesinin derecelendirilmesi az sayıdaki makine üyelerinin olduğu durumlarda yanlış alarmlara sebebiyet verebilir.

Sisteme ilave uyarı yapıları ile hata durumlarında ilgili kişiler bilgilendirilebilir. Arıza olasılığı olan makineler önceden tespit edilerek olası bozulmaların önüne geçilebilir, böylece üretim planlaması daha verimli hale getirilebilir. Acil durum yedek parça ihtiyacını en aza indirilebilir ve üzerinde işlem yapılan parçalarla ilgili sıkıntıları olmadan önlenir.

6. Sonuçlar

Bu çalışmada filo tabanlı bir hata tespit sistemi geliştirilmiştir. Geliştirilen bu sistemde; filodaki bütün makinelerden veriler alınarak birbirleriyle karşılaştırılır ve bu karşılaştırmaya göre makineler kümelendirir. Filo üyelerinin geneli sağlam varsayıldığından büyük olan kümelerde anomali puanı düşüktür. Bazı üyeler kendi içinde küçük bir küme oluştursa da diğerlerinden farklı bölgelerde, farklı kümelerde ve yüksek anomali puanlarında olduğu durumlarda hata olma ihtimali yüksektir.

Uygulama üç blok halinde tasarlanmıştır: Makinelerin karşılaştırılması, filo kümelendirilmesi ve anomali tespiti. Verilerden elde edilen sonuçlar incelenmek istendiğinde, her bir blokta oluşturulan grafikler yol gösterecektir. Sıcaklık ve titreşim değerleri için ayrı ayrı işlem yapılarak farklı anomali sonuçlarına ulaşılmıştır. Veri setinin içeriği de benzer durumu söylemektedir.

Çalışma benzer özellikte, benzer koşullarda, benzer işi yapan makinelerin olduğu filolarda uygulanabilir. Arıza durumları için uyarılar oluşturulabilir. Makine müdahalesine izin verilen durumlarda makineler durdurulabilir. Farklı yapay zekâ algoritmalarına veri kaynağı sağlayarak hibrit bir kestirimci bakım geliştirilebilir.

Teşekkür

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TUBİTAK) 118C252 nolu projesi tarafından desteklenmiştir.

Araştırmacıların Katkısı

Bu araştırmada; Metin Yılmaz bilimsel yayın araştırması, yöntem belirlenmesi, makalenin oluşturulması, uygulanması, sonuçların analiz edilmesi ve makale sonuçlarının hazırlanması; Ahmet Yazıcı, bilimsel yayın araştırması, yöntem belirlenmesi, makalenin oluşturulması, uygulanması, sonuçların analiz edilmesi ve makale sonuçlarının hazırlanması; Eyüp Çınar, bilimsel yayın araştırması, yöntem belirlenmesi, makalenin oluşturulması, uygulanması, sonuçların analiz edilmesi ve makale sonuçlarının hazırlanması konularında katkı sağlamışlardır.

Çıkar Çatışması

Yazarlar tarafından herhangi bir çıkar çatışması beyan edilmemiştir.

Kaynaklar

- Ahmad, W., Khan, S.A. & Kim, J. (2017). A hybrid prognostics technique for rolling element bearings using adaptive predictive model. *IEEE Transactions on Industrial Electronics*. doi: <http://dx.doi.org/10.1109/TIE.2017.2733487>
- Chan, Y.S. & Tou Ng.H. (2008). MAXSIM: A maximum similarity metric for machine translation evaluation. *Department of Computer Science National University of Singapore Law Link, Singapore 117590*
- Cosme, L.B., D'Angelo, M.F.S.V., Caminhas, W. M., Yin, S. & Palhares, R.M. (2017). A novel fault prognostic approach based on particle filters and differential evolution. *Springer Science+Business Media, LLC* 2017. doi: <http://dx.doi.org/10.1007/s10489-017-1013-1>
- Data-Driven Documents, (2020). JavaScript library for manipulating documents based on data. Erişim Adresi: <https://d3js.org>
- Hendrickx, K., Meert, W., Mollet, Y., Gyselinck, J., Cornelis, B., Gryllias, K. & Davis, J. (2019). A general anomaly detection framework for fleet-based condition monitoring of machines. *Mechanical Systems and Signal Processing*, 139, (2020), 106585. doi: <http://dx.doi.org/10.1016/j.ymsp.2019.106585>
- Jammu, N.S. & Kankar, P.K. (2011). A review on prognosis of rolling element bearings, *International Journal of Engineering Science and Technology (IJEST)*
- Kozlov, A.M., Al-jonid, Kh.M., Kozlov, A.A. & Antar Sh.D. (2017). Product quality management based on CNC machine fault prognostics and diagnosis. *IOP Conf. Series: Materials Science and Engineering*, 327 (2018), 022067. doi: <http://dx.doi.org/10.1088/1757-899X/327/2/022067>

- Li, Z., Wang, Y. & Wang, K. (2017). Intelligent predictive maintenance for fault diagnosis and prognosis in machine centers: Industry 4.0 scenario. *Shanghai University and Springer-Verlag GmbH Germany*, part of Springer Nature 2017. doi: <http://dx.doi.org/10.1007/s40436-017-0203-8>
- Liao, L. & Lee, J. (2009). Design of a reconfigurable prognostics platform for machine tools. *Expert Systems with Applications*, 37, (2010), 240–252. doi: <http://dx.doi.org/10.1016/j.eswa.2009.05.004>
- Lüthe, M. (2020). Calculate similarity — the most relevant metrics in a nutshell. Erişim Adresi: <https://towardsdatascience.com/calculate-similarity-the-most-relevant-metrics-in-a-nutshell-9a43564f533e>
- Saidi, L., Ali, J.B., Bechhoefer, E. & Benbouzid, M. (2017). Wind turbine high-speed shaft bearings health prognosis through a spectral Kurtosis-derived indices and SVR. *Applied Acoustics*, 120, (2017), 1–8. doi: <http://dx.doi.org/10.1016/j.apacoust.2017.01.005>
- Yılmaz, M. ve Gürel, U. (2019). CNC tezgâhlarından MT Connect verileri ile duruş ve çalışma analizi. *ISAS 2019 3rd International Symposium on Innovative Approaches in Scientific Studies. SETSCI Conference Proceedings*, 4(1), 21-25, 2019