

Kaotik Zaman Serilerinin Kestirimci Bakım Temelli Aktif Arızaya Dayanıklı Kontrol Sistemleri için Uygulanması

Applying Chaotic Time Series for Predictive Maintenance-based Active Fault-Tolerant Control Systems

Batuhan ATASOY¹, Senem KURŞUN²

¹Mekatronik Mühendisliği Bölümü
İstanbul Teknik Üniversitesi, İstanbul
atasoyba@itu.edu.tr

²Makina Mühendisliği Bölümü
İstanbul Teknik Üniversitesi, İstanbul
kursuns@itu.edu.tr

Özetçe

Arıza Toleranslı Kontrol, tesis işlevselliğini artırmak ve arızaya karşı riski azaltmak için geliştirilen bir dizi kontrol tekniğidir. Bu kontrol tekniği durum izleme, çevrimiçi arıza teşhisi ve otomatik durum değerlendirmesine dayanır ve ciddi arızaları önlemek için uyarlanabilir kontrol parametreleri geliştirir. Ana arıza kipleri, miller veya rulmanlar gibi döner makine elemanlarından, anlık akım değişikliklerinden kaynaklanan ani sıcaklık artışlarına kadar elektronik durumlardan veya dış durumlardan kaynaklanır. Tesisin insanlar için aşırı tehlikeli olduğu ortamlarda bakım prosedürlerinin gerçekleştirilmesinde, kestirimci bakım yöntemleri tesis elemanlarının arıza zamanını tahminlemek için yardımcı araçlar olabilir.

Bu çalışmada, kestirimci bakım yöntemlerini temel alan arızaya dayanıklı kontrol sistemleri tasarlamak için yeni bir kontrol yöntemi önerilmiştir. Algıç tabanlı zaman serisi verileri kullanılarak tesis elemanlarındaki anomalileri; kaotik zaman serisi analizleri ve yinelenbilir sinir ağları tabanlı anomali tespit algoritmalarıyla birleştirilerek yeni bir kontrolcü tasarımı önerilmiştir.

Abstract


Fault-Tolerant Control is a set of control techniques developed to enhance facility functionality and reduce the risk of faults. This control technique relies on condition monitoring, online fault diagnosis, and automatic state assessment, developing adaptable control parameters to prevent severe faults. Main failure modes come from rotary machine elements, such as shafts or bearings, electronic cases of sudden temperature rise from instantaneous current changes, or the outside cases. In environments where the facility is excessively hazardous for humans to perform maintenance procedures, predictive maintenance methods can be auxiliary tools for estimating the downtime of facility components.

In this study, a novel control methodology has been proposed to design Fault-Tolerant Control Systems considering Predictive Maintenance. Using sensor-based time series data, it is proposed to detect the anomalies in plant elements

combining with the chaotic time series analysis and recurrent neural networks-based anomaly detection algorithms.


1. Giriş

Geleneksel arıza dayanıklı kontrol sistemleri, beklenen arızaların sistemli ve sistem dışı senaryolarına göre tasarlanmaktadır [1]. Örnek bir aktif arızaya dayanıklı kontrol sistemi tasarımı Şekil 1'deki gibidir.



Şekil 1: Aktif Arızaya Dayanıklı Kontrol Sistemi Çalışma Prensibi [2]

Genel makine arızalarına örnek olarak, ötelemeli ve dönen makine elemanlarında, içsel sebepler olarak elektriksel ve elektronik arızalarda, aşırı dinamik yüklerden kaynaklanan arızalarda ve elektromanyetik bozulmalarda görülen arızaları içermektedir. Rulman gibi içsel sebepler için istatistiksel yöntemler, genellikle %99.99 güven seviyesinde tatmin edici sonuçlar verebilir. Ayrıca, bu yöntemler zaman serisi tabanlı arıza analizleri ile birleştirilerek makine elemanının arızasıyla ilgili kanıtlar sunabilir. Ancak, bu yöntemler bazen ortalama karesel hata (mse), kök ortalama karesel hata (rmse) veya ortalama mutlak hata (mae) sonuçları verebilir. Ayrıca, kaotik zaman serileri için dinamik bir sistem modeli oluşturmak çoğu zaman zordur. Bu nedenle, makine öğrenimi yöntemleri son zamanlarda düşük hata payıyla arıza türlerini ve zaman damgalarını tespit etmek için kullanılmıştır. Yapay öğrenme temelli yöntemler sayesinde, kestirimci bakım yöntemleri arıza zamanını ve arıza modunu düşük hatayla tahmin edebilir. Yaygın kullanılan yöntemlerden birisi olan zaman serileri üzerinde anomali tespiti Şekil 2'de gösterilmektedir.

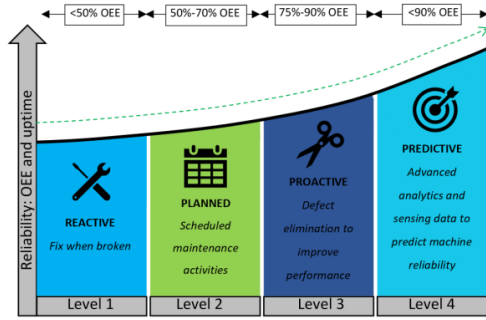


Şekil 2: Zaman Serisi Temelli Anomali Tespiti [3]

2. Problem Tanımı & Literatür Çalışmaları

2.1. Problem Tanımı

Endüstriyel kontrol sistemlerinde tesis stabilitesinin önemli bir kısmı, bakım prosedürlerine dayanmaktadır. Bu prosedürler arasında, tesis içindeki akışkan özelliklerin yenilenmesi, elektrik, elektronik veya mekanik elemanların değiştirilmesi gibi işlemler bulunmaktadır. Bakım prosedürlerinin tiplerine bağlı olarak, “Tepkisel Bakım”, “Zamanında Bakım”, “Önleyici Bakım” ve “Kestirimci Bakım” yöntemleri olmak üzere dört bakım türü yaygın bir şekilde kullanılmıştır. Bu bakım yöntemlerinin verimliliği Şekil 3’te gösterilmiştir.



Şekil 3: Endüstriyel Tesis Bakım Yöntemleri [4]

Tepkisel bakımda, hatalı makine elemanının arıza sonrası değiştirilmesine dayalı olarak işlem yapılmaktadır, bu da birçok makine duruşuna neden olur ve endüstriyel tesisler için tercih edilemez. Zamanında bakım yönteminde ise işlemler, elemanların tam zaman çizelgesine göre yapılır, ancak genellikle bakım süresini azaltmak için tercih edilmezler. Bakım aralığı ve çoklu parça değişiminin bir dengelemesi olan önleyici bakım yöntemleri yaygın bir şekilde kullanılmaktadır. Diğer yöntemlerle karşılaştırıldığında, Genel Ekipman Verimliliği (OEE) puanları %70’in üzerindedir, bu da tesise uzun süreli istikrarlı bir çalışma sağlar. Ancak, ömür boyu veya makine parçalarının basit testlerine dayandıkları için, koşullu izleme olmadan tahmini arıza zamanını tespit etmek mümkün değildir. Bu sorunu aşmak için, elde edilen verilere göre anomali tespiti veya arıza türünü sırasıyla tespit etmek için gerçek zamanlı veya çevrimdışı koşullu izleme temel alınarak ardışık makine öğrenme algoritmalarıyla çalışan Kestirimci Bakım yöntemleri kullanılmıştır. Bu yöntemler kullanıldığında, OEE puanları %90’ın üzerindedir [4].

Sistemli hatalar göz önünde bulundurulduğunda, zaman serilerinin kendisi içinde tespit edilebilecek anomaliler

barındırır ve bu anomaliler, kaotik analiz yöntemleri aracılığıyla saptanabilir. Bu tür yöntemler arasında Yinelemeli Çizimler (Recurrence Plots), Lyapunov Üstelleri (Lyapunov Exponents), Poincaré Haritaları, Kararsız Periyodik Yörüngeler (Unstable Periodic Orbits-UPO) vb. bulunmaktadır. Bu yöntemleri kullanabilmek için, bilgi teorisi temelli Ortalama Karşılıklı Bilgi (Average Mutual Information-AMI) ve grafik tabanlı Yanlış En Yakın Komşular (False Nearest Neighbours-FNN) yöntemleri, doğrusal olmayan zaman serilerinin faz uzayını oluşturmak için uygulanabilir. Ancak, hesaplama karmaşıklıkları ve bilgisayarların artan hesaplama gücünün kullanımı nedeniyle, derin öğrenme yöntemleri anomalileri tespit etmek için en kolay yol olabilir. Tekrarlayan Sinir Ağları (Recurrent Neural Networks-RNN), Uzun Kısa Dönem Bellek (Long-Short Term Memory-LSTM), Tek veya Çift Yönlü Evrişimli LSTM veya Kapılı Yinelem Birimi (Gated Recurrent Unit-GRU) gibi yöntemler, zaman serisi içindeki anomalileri ve olası zaman damgalarını tespit etmek için tatmin edici sonuçlar verir. Ancak, model düzeltmelerinin hiperparametrelere bağımlı olması nedeniyle, hiperparametre optimizasyonu büyük ölçüde gereklidir. Ayrıca, bu yöntemler literatürde tek değişkenli zaman serisi analizleri için kullanılmış olup, çoklu sensör verileri ışığında elde edilen parametre belirsizlikleri de bu kontrol sistemlerinin tasarımında dikkate alınmalıdır.

2.2. Literatür Özeti

Arızaya dayıklı kontrol sistemleri için yapılan çalışmalar, temelinde yapay zeka ve makine öğrenimi temelli yöntemleri bünyesinde barındırmaktadır. Mousavi vd., Dinamik Ağırlıklı Ateşböceği Algoritması (Dynamic Weighted Firefly Algorithm) ve Kısmi Türev Tabanlı yaklaşımları birleştirerek farklı algıç, eyleyici ve tesis arızalarını dikkate alarak rüzgar türbinlerinin kanat açılarını dengelemiş ve enerji üretimini sürdürmüşlerdir (Mousavi vd., 2022) [5]. Mazare vd., rüzgar türbinlerinin kanat açılarını dengelemek için geriadımlama (backstepping) ve kayan kipli (Sliding Mode Control-SMC) kontrol tabanlı bir aktif arızaya dayanıklı kontrol sistemi tasarlamışlardır (Mazare vd., 2021) [6]. Doğrusal durumlarla karşılaştırıldığında, rüzgar türbinleri her zaman değişken bozuculara maruz kaldığından tesis tamamen doğrusal olmayan hale gelmektedir. Hibrid doğrusal olmayan kontrol sistemleri kullanarak, rotor hızındaki belirsizlikler, sıradan Kayan Kipli Denetleyiciler (SMC) ve Bulanık Mantık Denetleyicileri (FLC) ile karşılaştırıldığında 5.23×10^{-4} düzeyine kadar azalmıştır. Miao vd., lineer PID denetleyicilerine dayalı bir aktif arızaya dayanıklı kontrol sistemi tasarlamışlardır (Miao vd., 2021) [7]. Çoklu algıç verilerini kullanmak için, tek boyutlu Evrişimsel Sinir Ağları (Convolutional Neural Networks-CNN) geliştirilmiş ve ardından elektro-hidrolik eyleyiciler üzerinde farklı algıçlar ile tek değişkenli zaman serisi analizi yapmak için LSTM tabanlı bir yöntem kullanmışlardır. Sınıflandırma tabanlı algoritmaları kullanarak, arıza teşhisi için %99.1 doğruluk sağlamışlardır. Veerasamy vd., çimento firmasının sıcaklığını kontrol etmek için Model Tabanlı Arızaya Dayanıklı Denetim (Model Predictive Fault Tolerant Control) ile Adaptif Azalan Bellekli Kalman Filtreleri (Adaptive Fading Memory Kalman Filters-AFMKF) bir araya getirmişlerdir (Veerasamy vd., 2022) [8]. AFMKF hiperparametrelerini ayarlamak için Çok Amaçlı Genetik Algoritmalar (Multi Objective Genetic

Algorithms-MOGA) kullanılmış ve çalışmaları arıza dayanımında iyileştirmeler sağlamıştır.

Kestirimci bakım yöntemleri, anomali tespiti, hata sınıflandırması ve zaman serisi tabanlı tahmin yöntemleri için koşullu izleme tabanlı analiz yöntemleridir. Diğer bakım prosedürleriyle karşılaştırıldığında tatmin edici Genel Ekipman Verimliliği (OEE) puanları verdiği için, doğruluk ve hassasiyetlerini artırmak için birçok çalışma devam etmektedir. Langeron vd., endüstriyel bir tür eyleyicinin monoton bozulmasını incelemişlerdir ve bir denetleyici ile aktör bozulması arasında bir ilişki bulmuşlardır (Langeron vd., 2015) [9]. Ancak daha iyi bir modelleme için stokastik bozulmalar elenmiş ve Doğrusal Karesel Regülatörler (LQR) temelli örnek bir çalışması gerçekleştirmiştir. Herrero ve Zorrilla, bir nesnelerin interneti (Internet of Things-IoT) tabanlı kestirimci bakım algoritması tasarlamak için farklı sensör tabanlı ölçümleri incelemişlerdir (Herrero & Zorrilla, 2022) [10]. Bunun için verileri bir Amazon Web Services (AWS) bulut platformuna aktarmış ve hatalı etiketli verilerini Destek Vektör Makineleri (SVM), K-En Yakın Komşular (KNN) ve Yapay Sinir Ağları (ANN) ile karşılaştırmışlardır. Çalışmaları %99.87 doğruluk başarıları vermiştir, ancak zaman serisi analitiği yerine, çalışmaları denetimli öğrenmeye dayanmaktadır. De Benedetti vd., Fotovoltaik (PV) hücreler için kestirimci bakım tabanlı anomali tespitini incelemişlerdir (De Benedetti vd., 2018)[11]. Anomali tespiti algoritmaları, ölçülen ve yapay sinir ağları (Artificial Neural Networks-ANN) tabanlı tahmin edilen AC Güç üretimi değerleri arasındaki hata dikkate alınarak tanımlanmıştır. Anomali tespitinde %90'ın üzerinde bir doğruluk skoru ve PV hücreleri için uygulanabilir tahminsel bakım metodolojisi tasarlamak için %2.3 doğrulama hatası elde edilmiştir. Choi vd., çok değişkenli zaman serisi anormallik tespiti analizi için otomatik kodlayıcı (AE) ve LSTM-AE tabanlı bir yöntem tasarlamışlardır (Choi vd., 2022)[12]. Çalışmaları imalat endüstrisi için uygulanmış ve algoritmaları sayesinde yanlış alarm oranlarının %0.18 ile %2.86 arasında olduğu bulunmuştur.

3. Kullanılan Yöntemler & Tartışmalar

3.1. Değer Önerisi

Bu çalışma kapsamında tespit edilen problemlerin çözümü için yenilikçi bir algoritma önerilmiştir. Buna göre, aktif arzaya dayanıklı kontrol sistemlerinde anomali tespiti yapılabilmesi amacıyla kaotik zaman serisi analizleri yapılmıştır.

Zaman serisi üzerinde yapılan kaos analizlerinde, ilk olarak serinin veri analiz süreçleri gerçekleştirilmiştir. Bu kapsamda, Deneysel Veri Analizleri (Exploratory Data Analysis-EDA) temelli veri incelemeleri yapılmaktadır. Özellikle çok değişkenli bir zaman serisi için veri kaybını sıfır ya da en düşük değerde tutacak boyut düşürme yöntemleri için, zaman serilerinde yaygın olarak kullanılan ve Bağımlı Bileşen Analizi (Dependent Component Analysis-DCA) analizleri yapılır. Elde edilen yeni zaman serisi daha sonrası kaotik analiz yöntemleri kullanılarak incelenir.

Zaman serisi içerisindeki kaosun tespit edilebilirliği amacıyla Eğilimden Arındırılmış Dalgalanma Analizi (α -DFA) yapılır. Grafik temelli olan bu yöntemde, zaman serisi her bir yinelemede eşit parçalara ayrılır ve dalgalanma log-log

grafiki üzerinde toplanır. Sonuçları çoğunlukla doğrusal olan bu grafiğin eğimi α katsayısını vermekle birlikte, bu katsayının karşılığı olan zaman serisi karakteristiği Tablo 1'deki gibidir.

Tablo 1: α -DFA analiz değerleri

α Katsayısı	İlinti Durumu
<0,5	İlinti Yok
\approx 0,5	Çok Düşük İlinti
>0,5	İlintili
\approx 1	Pembe Gürültü
>1	Durağan Olmayan
\approx 1,5	Brownian Gürültüsü

Kaotik bir karakteristiğe sahip olduğu tespit edilen veri, bir sonraki aşamada boyutsal analizler için kullanılır. Tipik bir kaotik sistemde boyutlar fraktal olarak tespit edilir ve bu değerlerin artışı sistemdeki kaosun, dolayısıyla düzensizliğin bir ölçütü olarak kabul edilmektedir. Bu sebeple bir zaman serisinden elde edilen fraktal boyutlar, yapay öğrenme temelli anomali tespit algoritmaları için bir öznelik olarak kullanılabilir.

3.2. Veriseti Çalışmaları


Çalışma kapsamında önerilen yeni algoritmanın uygulanabilirliğini test amacıyla, Kaliforniya Üniversitesi-Irvine tarafından paylaşılan CNC üretim hattı verisi (AI4I-2020) verisi kullanılmıştır. Verisetime ait bilgiler Şekil 5'te gösterilmiştir.

Dataframe Info


```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 10000 entries, 0 to 9999
Data columns (total 14 columns):
#   Column                                Non-Null Count  Dtype
---  ---                                -
0   UDI                                    10000 non-null  int64
1   Product ID                            10000 non-null  object
2   Type                                  10000 non-null  object
3   Air temperature [K]                   10000 non-null  float64
4   Process temperature [K]               10000 non-null  float64
5   Rotational speed [rpm]                10000 non-null  int64
6   Torque [Nm]                           10000 non-null  float64
7   Tool wear [min]                       10000 non-null  int64
8   Machine failure                       10000 non-null  int64
9   TWF                                    10000 non-null  int64
10  HDF                                    10000 non-null  int64
11  PWF                                    10000 non-null  int64
12  OSF                                    10000 non-null  int64
13  RNF                                    10000 non-null  int64
dtypes: float64(3), int64(9), object(2)
```

Şekil 4: Verisetime Ait Öznelik Bilgisi


Kestirimci bakım analizleri için gerekli olabilecek öznelikler Dış Ortam Sıcaklığı, Proses Sıcaklığı, Açılma Hızı, Tork ve Takım Aşınma değerleri olarak tespit edilmiştir. Veriseti ile ilgili grafikler aşağıda verilmektedir.




Şekil 5: Dış Ortam Sıcaklığı Zaman Serisi



Şekil 6: Proses Sıcaklığı Zaman Serisi




Şekil 7: Açısal Hız Zaman Serisi




Şekil 8: Tork Zaman Serisi

Veriseti üzerinde yapılan ilk analizlerde, bazı girdi özniteliklerinin periyodik, bazılarının ise kaotik bir yapıda olduğu tespit edilmiş; bu da kontrol sistemleri için önerilen algoritmanın uyarlanabilirliğini göstermiştir.



Şekil 9: Takım Aşınması Zaman Serisi

Elde edilen veriler doğrultusunda, modele içerisinde oluşabilecek çoklu doğrusallık probleminin analizi amacıyla, ilinti matrisi verileri Şekil 10'da gösterilmektedir.




Şekil 10: İlinti Matrisi Analizi


İlinti matrisi üzerinde yapılan analizlerde, Dış Ortam Sıcaklığı-Proses Sıcaklığı ve Tork-Açısal Hız arasında yüksek ilinti (0.88) tespit edilmiş ve model üzerindeki boyut düşürmesi bu ilinti değerlerine göre yapılmıştır.

Deneysel veri analizi sürecinde, çok değişkenli zaman serisinin boyut düşürme süreçlerinde Bağımlı Bileşen Analizi yöntemi kullanılmıştır. Özellikle zaman serileri için yaygın kullanılan bu yöntemde, Kümülatif Varyans Oranı dikkate alınarak boyut düşürme işlemleri yapılmış ve veriseti bir boyuta indirgenerek tek değişkenli bir zaman serisine çevrilmiştir.

Elde edilen bu seri ve seriye ait Kümülatif Varyans Oranları Şekil 11 ve Şekil 12'de gösterilmektedir.




Şekil 11: Bağımlı Bileşen Analizi Sonrası Elde Edilen Tek Değişkenli Yeni Zaman Serisi



Şekil 12: Çok Değişkenli Zaman Serisine ait Boyut-Kümülatif Varyans Oranı Grafiği

Elde edilen yeni zaman serisi, α -DFA analizi kapsamında incelenmiş, ve log-log grafiği Şekil 13'te gösterilmiştir.



Şekil 13: Yeni Zaman Serisine ait α -DFA Grafiği

Yapılan incelemelerde, grafik eğimi olan α katsayısı 0.53 olarak tespit edilmiş, bu da serinin kaotik bir karakteristiğe sahip olduğunu göstermiştir.

Analizin son aşamasında, seriye ait düzensizliğin ölçütünün tespit edilebilmesi amacıyla Hurst Üsteli ve fraktal boyut analizi yapılmıştır. Hurst üsteli ile boyut arasındaki ilişki Denklem 1'de verilmektedir.

$$D=2-H \quad (1)$$

Formüldeki D fraktal boyut değerini, H ise Hurst üstelini göstermektedir. Buna göre $1 < D < 2$ arasında kesirli değerler alan bir zaman serisi kaotik karakteristiğe sahiptir ve değer 2'ye yaklaştıkça düzensizlik artmaktadır.

Analizin son aşamasında, zaman serisine ait Hurst üsteli yaklaşık 0.003 olarak tespit edilmiş, bu da yaklaşık olarak 1.997 boyut değerine karşılık gelmektedir. Bu sebeple, görece düzensiz olduğu tespit edilen yeni zaman serisi kaotik bir karakteristiğe sahiptir ve düzensizliği sayesinde RNN temelli anomali tespit algoritmalarında kullanılabilir.

4. Sonuçlar

4.1. Sonuçlar

Bu çalışmada, arızaya dayanımlı kontrol sistemlerinin tasarımında kestirimci bakım temelli yöntemlerin kullanılmasına dönük bir tasarım yapılmıştır. Önerilen zaman serisi temelli analiz yöntemleriyle birlikte; özellikle bakım süreçlerinde insanların çalışması için tehlikeli olan bölgelerde, gelecekteki olası makine arızalarını tespit edilebilmesi ve kontrolcü parametrelerinin bu tip arıza senaryolarına karşı düzenlenebilmesi mümkün kılınmıştır.

Endüstriyel bakım süreçlerinde yaygın olarak kullanılan önleyici bakım gibi yöntemlerde arızalanan parçayla birlikte, belirli aralıklarda değiştirilmesi gereken parçaların da değiştirilmesi, toplam ekipman verimliliğini (Overall Equipment Efficiency-OEE) %80 ve üzerine taşıya da; sağlam parçanın değiştirilmesinde kaynaklı maliyet artışlarına da sebep olabilmektedir. Bu sebeple, Nesnelerin İnterneti temelli kestirimci bakım uygulamaları, parçanın olası arıza durumlarını sensör verileri ve yapay öğrenme yöntemlerini kullanarak tespit edebilmekte ve bu verimliliği %90 ve üzerine taşıyabilmektedir.

Geliştirilen yeni yaklaşım, ilk olarak CNC operasyonlarından elde edilen AI4I2020 veriseti üzerinde uygulanmıştır. Bu kapsamda ilk olarak modelin geliştirilmesi için gerekli öznitelikler toplanmış, ve çok değişkenli zaman serisi üzerinde veri analiz işlemleri yapılmıştır. Yapılan araştırmalar sonucunda, veriseti üzerinde elde edilen boyutu düşürülmüş zaman serisinde; ilk olarak α -DFA analizi uygulanmış ve α skoru yaklaşık 0.53 bulunmuştur. İkinci yapılan analizde, serinin Hurst üsteli ve takibinde fraktal boyutu yaklaşık olarak 1.99 bulunmuştur. Bu veriler ışığında, analizi yapılan çok değişkenli zaman serisinin kaotik bir karakteristiğe sahip olduğu tespit edilmiş, ve düzensizlikten doğan anomalilerin, zaman serilerindeki olası en büyük ve en küçük değerleri belirlemede yardımcı olabileceği, aynı şekilde bu değerlerin de, aktif arızaya dayanıklı kontrol sistemleri için sınır değerleri oluşturabileceği tespit edilmiştir.

4.2. İleri Çalışmalar

Zaman serisi analizleri kapsamında yapılacak gelecek çalışmalarda, kaotik analiz yöntemlerinin Tekrarlanabilir Sınır Ağları (RNN-based) temelli yöntemleri anomali tespitinde kullanılması hedeflenmektedir. Bu kapsamda fraktal boyutların bir öznitelik olarak kullanılması ve sınır ağları modellerinin bu özniteliklere göre eğitilerek arıza tahminlemesi yapması hedeflenmektedir.

Kaynakça

- [1] Blanke, M., Christian Frei, W., Kraus, F., Ron Patton, J., & Staroswiecki, M. (2000). *What is Fault-Tolerant Control?* IFAC Proceedings Volumes, 33(11), 41-52. [https://doi.org/10.1016/S1474-6670\(17\)37338-X](https://doi.org/10.1016/S1474-6670(17)37338-X)
- [2] Richter, J. H., Lunze, J., & Schlage, T. (2008). *Control reconfiguration after actuator failures by Markov parameter matching*. International Journal of Control, 81(9), 1382-1398. <https://doi.org/10.1080/00207170701813141>
- [3] Carrasco, J., López, D., Aguilera-Martos, I., García-Gil, D., Markova, I., GarcíaBarzana, M., Arias-Rodil, M., Luengo, J., & Herrera, F. (2021). *Anomaly detection in predictive maintenance: A new evaluation framework for temporal unsupervised anomaly detection algorithms*. Neurocomputing, 462, 440-452. <https://doi.org/10.1016/j.neucom.2021.07.095>
- [4] Çınar, Z. M., Abdussalam Nuhu, A., Zeeshan, Q., Korhan, O., Asmael, M., & Safaei, B. (2020). *Machine Learning in Predictive Maintenance towards Sustainable Smart Manufacturing in Industry 4.0*. Sustainability, 12(19), 8211. <https://doi.org/10.3390/su12198211>
- [5] Mousavi, Y., Bevan, G., & Kucukdemiral, I. B. (2022). *Fault-tolerant optimal pitch control of wind turbines*.

- using dynamic weighted parallel firefly algorithm*. ISA Transactions, 128, 301-317. <https://doi.org/10.1016/j.isatra.2021.10.019>
- [6] Mazare, M., Taghizadeh, M., & Ghaf-Ghanbari, P. (2021). *Fault tolerant control of wind turbines with simultaneous actuator and sensor faults using adaptive time delay control*. Renewable Energy, 174, 86-101. <https://doi.org/10.1016/j.renene.2021.04.077>
- [7] Miao, J., Wang, J., Wang, D., & Miao, Q. (2021). Experimental investigation on electro-hydraulic actuator fault diagnosis with multi-channel residuals. Measurement, 180, 109544. <https://doi.org/10.1016/j.measurement.2021.109544>
- [8] Veerasamy, G., Kannan, R., Siddharthan, R., Muralidharan, G., Sivanandam, V., & Amirtharajan, R. (2022). *Integration of genetic algorithm tuned adaptive fading memory Kalman filter with model predictive controller for active fault-tolerant control of cement kiln under sensor faults with inaccurate noise covariance*. Mathematics and Computers in Simulation, 191, 256-277. <https://doi.org/10.1016/j.matcom.2021.07.023>
- [9] Langeron, Y., Grall, A., & Barros, A. (2015). *A modeling framework for deteriorating control system and predictive maintenance of actuators*. Reliability Engineering & System Safety, 140, 22-36. <https://doi.org/10.1016/j.res.2015.03.028>
- [10] Herrero, R. D., & Zorrilla, M. (2022). *An I4.0 data intensive platform suitable for the deployment of machine learning models: A predictive maintenance service case study*. Procedia Computer Science, 200, 1014-1023. <https://doi.org/10.1016/j.procs.2022.01.300>
- [11] De Benedetti, M., Leonardi, F., Messina, F., Santoro, C., & Vasilakos, A. (2018). *Anomaly detection and predictive maintenance for photovoltaic systems*. Neurocomputing, 310, 59-68. <https://doi.org/10.1016/j.neucom.2018.05.017>
- [12] Choi, H., Kim, D., Kim, J., Kim, J., & Kang, P. (2022). Explainable anomaly detection framework for predictive maintenance in manufacturing systems. Applied Soft Computing, 125, 109147. <https://doi.org/10.1016/j.asoc.2022.109147>