

Endüstriyel Makinelerin Arıza Durumlarına Göre Segmentasyonu: K-means ve Fuzzy C-means Algoritmaları ile RFM Analizi

Hikmet CANLI^{1*}  Sena VARICI¹ 

¹Istanbul Gedik Üniversitesi, Yazılım Mühendisliği, İstanbul, Türkiye

Makale Bilgisi

Araştırma Makalesi
Başvuru: 04/03/2025
Düzeltilme: 25/04/2025
Kabul: 23/06/2025

Anahtar Kelimeler

RFM Analizi
K-means
Fuzzy C-means
Kestirimci Bakım

Article Info


Research article
Received: 04/03/2025
Revision: 25/04/2025
Accepted: 23/06/2025

Keywords

RFM Analysis
K-means
Fuzzy C-means
Predictive Maintenance

Grafik Özet (Graphical/Tabular Abstract)

Bu çalışma, otomotiv sektöründe faaliyet gösteren bir üretim firmasındaki makinelerin arıza ve bakım verilerine dayalı olarak segmentasyonunu gerçekleştirmeyi amaçlamaktadır. Makine verileri üzerinde Arıza Frekansı, Toplam Arıza Süresi ve Son Arıza Zamanı parametreleri kullanılarak RFM analizi yapılmış, ardından K-means ve Fuzzy C-means algoritmaları ile kümeleme uygulanmıştır. Segmentasyon sonuçları David-Bouldin Index, Dunn Index ve Calinski-Harabasz Index gibi metriklerle değerlendirilmiş ve her üç metrikte de K-means algoritmasının daha başarılı olduğu görülmüştür. Elde edilen segmentasyon, makinelerin operasyonel sağlık durumlarını analiz etmeye, arıza eğilimlerini tahmin etmeye ve bakım süreçlerini optimize etmeye olanak tanımaktadır. Bu veri odaklı yaklaşım, operasyonel verimliliği artırmak ve bakım maliyetlerini düşürmek amacıyla etkili bir yöntem sunmaktadır.



Şekil / Figure 2: Dağılım Grafikleri (Scatter Plots)

Önemli noktalar (Highlights)

- Arıza Frekansı, Toplam Arıza Süresi ve Son Arıza Zamanı gibi parametrelerle RFM analizi yapılarak makineler segmentlere ayrılmıştır.
- K-means ve Fuzzy C-means algoritmaları kullanılarak kümeleme yapılmış, değerlendirme metriklerine göre K-means algoritması daha iyi performans göstermiştir.
- Arıza Segmentasyon sayesinde makineler için özel bakım stratejileri geliştirilebilmiş, bu da kestirimci bakımın etkinliğini ve operasyonel verimliliği artırmıştır.

Amaç (Aim): Bu çalışmanın temel amacı, üretim makinelerinin arıza ve bakım verilerini kullanarak RFM analizi ile segmentasyonunu sağlamak ve K-means ile Fuzzy C-means algoritmaları aracılığıyla en uygun kümeleme yöntemini belirleyerek bakım süreçlerini optimize etmektir.

Özgünlük (Originality): Bu çalışma, müşteri segmentasyonunda yaygın olarak kullanılan RFM analizini ilk kez üretim makinelerinin arıza verilerine uygulayarak farklı bir alanda özgün bir yaklaşım sunmaktadır. Ayrıca, farklı kümeleme algoritmalarının karşılaştırılmasıyla bakım stratejilerinin veri odaklı şekilde iyileştirilmesine yönelik somut katkılar sağlamaktadır.

Bulgular (Results): RFM analizi ile makineler arıza frekansı ve son arıza zamanına göre 9 anlamlı segmente ayrılmış, bu sayede müdahale önceliği yüksek makineler belirlenmiştir. K-means algoritması, üç farklı validasyon metriğinde de Fuzzy C-means'e kıyasla daha yüksek başarı göstermiş ve kümeler arası ayrımı daha net yapabilmektedir.

Sonuç (Conclusion): Çalışma, makine bakımında veri odaklı bir yaklaşımın arıza önceliklendirmesi ve kaynak kullanımında önemli avantajlar sağladığını göstermektedir. K-means algoritması, segmentasyon doğruluğu açısından daha etkili bulunmuş ve bakım planlamasında öncelikli tercih olarak önerilmiştir.



Endüstriyel Makinelerin Arıza Durumlarına Göre Segmentasyonu: K-means ve Fuzzy C-means Algoritmaları ile RFM Analizi

Hikmet CANLI^{1*} Sena VARICI¹

¹*İstanbul Gedik Üniversitesi, Yazılım Mühendisliği, İstanbul, Türkiye*

Makale Bilgisi

Araştırma Makalesi
Başvuru: 04/03/2025
Düzeltilme: 25/04/2025
Kabul: 23/06/2025

Anahtar Kelimeler

RFM Analizi
K-means
Fuzzy C-means
Kestirimci Bakım

Öz

Bu çalışma makinelerin segmentasyonunu, bakım ve arıza kayıtlarına dayalı olarak RFM analizi ile değerlendirdikten sonra K-means ve Fuzzy C-means kümeleme algoritmaları kullanarak değerlendirmeyi amaçlamaktadır. Her bir makinenin arıza geçmişi makinelerin bakım ve arıza verileri analiz edilerek incelenmiştir. Makinelerin segmentasyonunu değerlendirmek amacıyla Arıza Frekansı, Toplam Arıza Süresi ve Son Arıza zamanı gibi parametreler kullanılmıştır. Bu parametreler, müdahale edilmesi gereken makinelerin belirlenmesini ve makinelerin operasyonel sağlık durumlarını anlaşılmasını sağlamıştır. Makine verileri üzerinde RFM analizi uygulandıktan sonra K-means ve Fuzzy C-means algoritmaları kullanılarak kümeleme yapılmıştır. Bu çalışma, makinelerin bakım süreçlerini optimize etmek, arıza eğilimlerini daha doğru tahmin etmek, operasyonel verimliliği artırmak ve maliyetleri düşürmek için veri odaklı bir yaklaşım sunmaktadır. Çalışma sonuçları David-Bouldin Index, Dunn Index, Calinski-Harabasz Index gibi metrikler kullanılarak kıyaslanmış ve en iyi kümelemeyi yapan algoritma seçilmiştir. Sonuçlar, makinelerin segmentlere ayrılmasını ve her segment için özel bakım ve iyileştirme stratejilerinin geliştirilmesini sağlamaktadır.

Segmentation of Industrial Machines Based on Fault Conditions: RFM Analysis with K-means and Fuzzy C-means Algorithms

Article Info

Research article
Received: 04/03/2025
Revision: 25/04/2025
Accepted: 23/06/2025

Keywords

RFM Analysis
K-means
Fuzzy C-means
Predictive Maintenance

Abstract

This study aims to evaluate machine segmentation based on maintenance and failure records using RFM analysis, followed by clustering with K-means and Fuzzy C-means algorithms. The failure history of each machine was analyzed based on maintenance and failure data. Parameters such as Failure Frequency, Total Failure Time, and Last Failure Time were used to assess the segmentation of the machines. These parameters helped identify machines that require intervention and better understand their operational health status. After applying RFM analysis to the machine data, clustering was performed using K-means and Fuzzy C-means algorithms. This study presents a data-driven approach to optimize machine maintenance processes, more accurately predict failure trends, increase operational efficiency, and reduce costs. The results were compared using metrics such as the David-Bouldin Index, Dunn Index, and Calinski-Harabasz Index, and the best clustering algorithm was selected. The findings facilitate the segmentation of machines and the development of specific maintenance and improvement strategies for each segment.

1. GİRİŞ (INTRODUCTION)

Endüstri 4.0 teknolojisinde endüstriyel ekipmanlar ve bilgisayarlar birbiriyle bağlantılıdır ve insan müdahalesine gerek kalmadan karar alabilmek için iletişim halindedir [3]. Endüstriyel sistemler tarafından toplanan büyük miktardaki veri, süreçler ve olaylar hakkında önemli bilgiler sunar. Bu veriler analiz edilip işlendiğinde bakım maliyetleri ve makine arızalanma oranları düşebilir ve operasyonel verimlilik artabilir [6]. Makineler arızalandıktan sonra bakım yapmak yerine, kestirimci bakım sayesinde arızalar önceden tahmin edilip zamanında müdahale edilerek arızaların önüne geçilebilir. Kestirimci bakım, veri toplama sistemleri kullanarak makinelerin çalışmalarına dayalı verileri analiz eder ve bu veriler üzerinden tahminler yaparak bakım ihtiyaçlarını değerlendirir [17].

Bu çalışmada, otomotiv sektöründe faaliyet gösteren bir üretim firması makinelerinden toplanan arıza verileri gruplandırılmaktadır. Makineler RFM analizi, K-means ve Fuzzy C-means kümeleme teknikleri kullanılarak arıza durumlarına göre sınıflandırılmıştır. Bu süreçte makineleri segmentlere ayırmak için Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametreleri kullanılarak RFM analizi uygulanmış daha sonrasında ise K-means ve Fuzzy C-means algoritmaları kullanılarak verilerin kümeleme işlemi yapılmıştır. Son Arıza, makinelerin en son arıza verdikleri zamanı hesaplayarak elde edilirken Arıza Frekansı, makinelerin gözlem yapılan dönemde ne sıklıkla arızalandığını ifade etmektedir. Toplam Arıza Süresi ise makinelerin arıza sebebiyle ne kadar durduğunu ve üretimdeki kayıplara etkisini göstermektedir. Bu parametreler makinelerin performans durumlarını ve bakım ihtiyaçlarını anlamak için önemli bilgiler içermektedir. Uygulanan teknikler sayesinde makineler arıza durumlarına göre segmentlere ayrılmakta ve her bir segmente uygun bakım planlamaları yapılabilmektedir. K-means ve Fuzzy C-means algoritmalarını kıyaslamak amacıyla Dunn Index, David-Bouldin Index ve Calinski Harabasz Index teknikleri kullanılmıştır. Bu teknikler kümelenmiş verilerin küme içindeki durumlarını değerlendirme amacı ile kullanılır. David-Bouldin Index, küme içindeki yoğunluğu değerlendirir ve kümeleme doğruluğunu ölçer. Bu teknik, küme içindeki ortalama mesafeyi ve kümeler arasındaki mesafeyi dikkate alır. [12]. Dunn Index, iki küme merkezi arasındaki en küçük mesafeye ve aynı kümedeki iki nokta arasında en büyük mesafeye bakarak küme doğruluğunu ölçer [11]. Calinski Harabasz Index ise küme içi ve kümeler arası varyansı dikkate alarak

değerlendirme yapar [5]. Bu değerlendirme teknikleri uygulanarak kullanılan kümeleme algoritmalarının performansı değerlendirilmiştir.

Dunn Index ve Calinski Harabasz Index tekniklerinde yüksek değer daha iyi kümelemeyi ifade etmektedir. Dunn Index değerlendirmesinde K-means algoritması 0.117 puan, Fuzzy C-means algoritması 0.0015 puan almıştır. Calinski Harabasz Index değerlendirmesinde ise K-means 510.093 puan alırken Fuzzy C-means 470.043 puan almıştır. Bu durumda her iki değerlendirmede de K-means algoritması daha iyi performans göstermiştir. David-Bouldin Index tekniğinde ise düşük değer daha iyi kümelemeyi ifade etmektedir. K-means algoritması 1.053 puan, Fuzzy C-means algoritması ise 1.153 puan almıştır. Sonuçlara bakıldığında K-means algoritması daha iyi performans göstermiştir. Bu durumda K-means, kullanılan tekniklerin hepsinde daha iyi performans sergilemiş ve Fuzzy C-means algoritmasından daha iyi kümeleme yapmıştır.

RFM analizi, K-means ve Fuzzy C-means tekniklerinin tercih edilmesinde, bu yöntemlerin literatürde bulunan müşteri davranışları üzerinden müşteri segmentasyonu çalışmalarındaki başarılı sonuçlarıdır [4,7,10]. Literatürde yapılan çalışmaların amacı ortaktır. Müşteri davranışlarını RFM analizi ve diğer kümeleme tekniklerini kullanarak en iyi segmentasyonu sağlamaktır ve bu birleşimi kullanılarak müşteri segmentasyonu alanında önemli başarılar elde edilmiştir [8, 18, 13].

Bu çalışmanın ikinci bölümünde yapılan çalışmanın her adımı detaylı bir şekilde açıklanmıştır. Bulgular ve tartışma kısmında sonuçlar değerlendirilirken en sonda sonuçlara yer verilerek gelecekteki yapılacak çalışmalar için öngörü ve fikir verilmiştir.

2. MATERYAL VE METOD (MATERIALS AND METHODS)

Bu bölümde, çalışmada kullanılan veriler, yöntemler ve uygulama süreci ayrıntılı bir şekilde açıklanacaktır. Çalışmanın amacı doğrultusunda veri setinin hazırlanması, analiz yöntemleri ve kullanılan algoritmaların özellikleri hakkında bilgi verilecektir.

2.1. Veri Setinin Hazırlanması (Preparing the Data Set)

Bu çalışmada, otomotiv sektöründe faaliyet gösteren bir üretim firmasının son üç yıl içinde makinelerinde gerçekleşen arızalara ait veriler kullanılmıştır. Kullanılan veri seti çeşitli makine türlerine ait arıza durumlarının detaylı kayıtlarını

içermektedir. Veri seti 15 adet özellikten ve 43722 adet veriden oluşmaktadır. Makine Adı, Makine Kodu boş olan değerler ve tekrarlanan veriler temizlendikten sonra 43487 adet veri kalmıştır.

Kayıtlı olan aynı makineler gruplanmış ve toplamda 654 tane makine olduğu gözlemlenmiştir. Tablo 1’de kaydedilen verilerin özelliklerinin tanımlamaları yapılmıştır.

Tablo 1. Veri Seti (Dataset)

Özellikler	Tanım
Durum	Arızanın son durumu
Makine Kodu	Makinenin kodu
Makine Adı	Makine adı
Türü	Arızanın türü
BildirimTar	Arızanın bildirildiği tarih ve saat
OnarımBaslangic	Arızanın onarılmaya başlandığı tarih ve saat
OnarımBitis	Arıza onarımının bittiği tarih ve saat
Bildiren	Arızayı bildiren personel ismi
ArizayiOnaylayanBakimci	Arıza onayı veren personel ismi
TezgahiTeslimAlanPersonel	Tezgâhı teslim alan personel ismi
ArizaTanimi	Arıza tanımının yapılması
YapılanIslem	Arızanın giderilmesi için yapılan işlem
OnarımSuresi	Arızanın onarılma süresi
ArizaMudahaleSuresi	Arızaya ne kadar sürede müdahale edildiği
TezgahDurum	Tezgâhın çalışma durumu

Veri seti üzerinde tekrar eden ve eksik bilgilere sahip kayıtlar kaldırılmıştır. Arıza Tanımı parametresi operatörler tarafından girildiği için yeterli bilgiyi sağlamamaktadır. Bundan dolayı bu parametrenin kullanılmamasına karar verilmiştir. Ayrıca diğer parametreler de çalışmanın amacına hizmet etmediği için bu parametreler kullanılmamıştır. Sonuç olarak Makine Kodu, Makine Adı, Makine Türü, Bildirim Tarihi ve Onarım Bitiş tarihi özellikleri kullanılmıştır. Daha doğru sonuçlar elde edebilmek için veri seti görselleştirilmiş ve aykırı, gürültülü değerler tespit edilip bu kayıtlar temizlenmiştir.

2.2 RFM Analizi (RFM ANALYSIS)

RFM modeli yenilik, sıklık ve parasal değer parametrelerine dayanan bir analiz yöntemidir. Bu analiz müşterilerin davranışını anlamak ve segmentlere ayırmak için kullanılabilir etkili bir yöntemdir [1]. Müşterilerin satın alma geçmişleri hakkında bilgi edinilmesi için kullanılan üç parametre yenilik (R), sıklık (F) ve parasal değer (M)’dir. R parametresi son satın alma zamanından beri geçen süreyi, F parametresi bir dönem içinde yapılan satın alma sıklığını ve M parametresi bir dönem içinde harcanan parayı temsil eder [14]. Bu parametreler kullanılarak müşteri segmentasyonu gerçekleştirilir ve pazarlama stratejileri oluşturulur. Müşteriler R, F ve M değerlerine göre beşe ayrılır. En iyi değerler için beş puan, bir sonraki için dört puan verilir ve bu şekilde bir puana kadar devam

eder [16]. Daha sonrasında verilen puanlar her üç parametre için birleştirilir müşteriler segmentlere ayrılmış olur.

Bu çalışmada Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametreleri veri seti üzerinde yapılan çalışmalarla hesaplanmıştır. $R = \text{Son Arıza}$, $F = \text{Arıza Frekansı}$ ve $M = \text{Toplam Arıza Süresini}$ temsil etmektedir.

$$R = \text{Son Arıza}(\text{dk}) \\ = \frac{(\text{Şimdiki Zaman} - \text{Son Bildirilen Arıza Tarihi})}{60}$$

$$F = \text{Arıza Frekansı} = \text{Toplam Arıza Sayısı}$$

$$M = \text{Toplam Arıza Süresi}(\text{dk}) \\ = \sum_{i=1}^n \frac{(\text{Onarım Bitiş})_i - (\text{Bildirim Tarihi})_i}{60}$$

n: Her makine için toplam arıza sayısı

Onarım Bitiş: i’nci arızanın tamirinin bittiği zaman

Bildirim Tarihi: i’nci arızanın bildirildiği zaman

R, her makinenin arıza durumu bildirildikten sonra geçen süreyi dakika cinsinden temsil ederken F, belirli bir tarih aralığında kaydedilen arıza sayısına göre belirlenmiştir. M ise her makinenin arızalı kaldığı süre hesaplanarak dakika cinsinden elde

edilmiştir. F ve M değerleri yüksek olan makineler operasyonel verimlilik açısından kötü ve acil bakım gerektiren R değeri yüksek olan makinelerin çalışma performansı iyidir.

Her parametre için 1 ile 5 arasında bir skorlama yapılmıştır. 1 puan makinelerin çalışma performanslarının kötü olduğunu ve acil bakım gerektirdiklerini ifade ederken 5 puan daha dayanıklı makineleri temsil etmektedir. Her makinenin genel RFM skorunu elde etmek için bu puanlar birleştirilmiştir. 111 puan alan makineler, operasyonel verimlilik açısından zayıf performans sergilerken 555 puan alan makineler oldukça yüksek bir performans göstermektedir.

2.3 K-Means

K-means algoritmasının modern formülasyonu 1967’de geliştirilmiştir [15]. Algoritma prensipleri daha açık hale getirilmiş ve algoritmanın bugünkü halini almasına katkı sağlanmıştır. K-means kümeleme algoritmasının amacı veri setini benzer özelliklerine göre gruplayarak kümelere ayırmaktır. K-means basitliği, hızlı yakınsama ve büyük veri setlerini işleme yeteneği nedeniyle en yaygın kullanılan algoritmadır [9]. Küme sayısını belirlemek için genel bir çözüm, algoritmayı birkaç kez çalıştırmak ve bazı geçerlilik ölçütlerine göre istenen küme sayısını seçmek veya bazı anlamlı yöntemler veya ölçütlerle otomatik olarak belirlemektir [2].

K-means algoritmasının amacı, küme merkezleri ve veriler arasındaki yakınlığı belirlemek ve hata kareler oranını en az indirmektedir. Denklem 1’de matematiksel ifadesine yer verilmiştir.

$$c_i = \arg \min_{1 \leq j \leq k} \|x_i - C_j\|^2 \quad (1)$$


c_i : Veri noktası x_i ’nin ait olduğu küme

C_j : j-inci küme merkezinin konumu

K-means algoritmasının işleyiş şekli aşağıdaki gibidir:

- Küme merkezlerini belirlemek amacıyla küme sayısı yani k adet noktalar seçilir.
- Seçilen merkezler ile veri noktaları arasındaki uzaklık hesaplanarak veriler kendilerine en yakın kümeye yerleştirilir.
- Seçilen merkez noktaları her iterasyon için değişir ve bu noktalar değişmeye kadar bu adımlar tekrarlanır. K-means kümeleme algoritmasında,

Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametreleri kullanılmıştır. Bu parametrelerin kullanılması her bir makinenin arıza özelliklerine yönelik kümeler oluşturmasını sağlar. Bu kümeler benzer arıza özelliklerine sahip makineleri bir araya getirerek bakım planlaması yapılmasına yardımcı olacaktır. Küme sayısının belirlenmesinde Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametreleri temel alınmıştır. Bu işlemde uygun küme sayısını (k) belirlemek amacıyla Elbow yöntemi ve Silhouette Score yöntemi kullanılmıştır. Elbow yönteminde belirli bir aralıkta farklı k değerleri için K-means algoritması uygulanır. Her bir k değeri için inertia değeri hesaplanır. Inertia, her veri noktasının ait olduğu küme merkezine olan kare uzaklıklarının toplamıdır ve bu kümelerin iç tutarlılığını ifade eder. Elde edilen inertia değerleri grafik üzerinde gözlemlendiğinde başta hızlı bir düşüş yaşarken bir noktadan sonra bu düşüş yavaşlar. Bu nokta “dirsek noktası” olarak isimlendirilir ve en uygun küme sayısını temsil eder. Silhouette Score yöntemi her bir gözlemin ait olduğu kümeyle ne kadar iyi eşleştiğini ve diğer kümelere ne kadar net ayrıldığını ölçerek kümeleme kalitesini değerlendirir. Belirli bir aralıkta k değerleri kullanılarak algoritma çalıştırılır ve ortalama skor sonuçlanır. Bu skor, -1 ile +1 arasında bir değer alır. 1’e yakın skorlar, gözlemin diğer kümelere net bir şekilde ayrıldığını gösterir. En yüksek ortalama skoru veren k değeri veri yapısına uygun optimum küme sayısını ifade eder. Elbow Yöntemi Şekil 1’deki gibi görsel olarak bir küme sayısı önerirken Silhouette Score ise daha matematiksel bir değerlendirme sunar. Bu yöntemler sonucunda küme sayısı 4 olarak belirlenmiştir.




Şekil 1. Elbow Yöntemi (Elbow Method)

Küme sayısı belirlendikten sonra K-means algoritması kullanılarak model oluşturulmuş ve veri üzerinde tahmin işlemleri gerçekleştirilmiştir. Model kurulduktan sonra her bir makineye ait Son Arıza, Arıza Frekansı ve Toplam Arıza Süre

parametreleri kullanılarak makineler belirlenen kümelerle atanmıştır. Bu sayede her bir makinenin arıza durumlarına göre hangi kümelerde daha yoğun oldukları belirlenmiştir. Gruplanan makineler veri

görselleştirme teknikleri kullanılarak görselleştirilmiş ve bu sayede kümeler arasındaki ilişkiler daha iyi bir şekilde gözlemlenmiştir.



Şekil 2. Dağılım Grafikleri (Scatter Plots)

Şekil 2’de, K-means kümeleme sonucunda üç farklı dağılım grafiği çizilmiştir. Kullanılan parametreler arasındaki ilişki kümelerin nasıl farklılaştığını gösterir ve her küme için arıza profillerinin anlaşılmasına yardımcı olur. Bu sayede makinelerin bakım periyotları ayarlanabilir ve operasyonel verimlilik açısından avantaj sağlanmış olur.

2.4 Fuzzy C-means

Fuzzy C-means ilk kez 1965 yılında Lotfi Zadeh tarafından bir makalede tanıtılmıştır. Bulanık kümeler, her nesneye sıfır ile bir arasında değişen bir üyelik derecesi atayan ve bu derecelerin sürekli bir dağılım gösterdiği bir nesne sınıfıdır [21]. Klasik K-means algoritmasında her veri noktası yalnızca bir kümeye aitken Fuzzy C-means algoritmasında her veri noktası birden fazla kümeye ait olabilir. Bezdek ve ark. algoritmanın matematiksel temellerini açıklayarak verilerin bulanık kümelenebilirliği ve küme üyelik fonksiyonları üzerine detaylı bilgiler sunmaktadır [19]. Veriler belirlenen küme merkezlerine ne kadar yakınsa o kümeye ait üyeliği o kadar fazladır. Her iterasyondan sonra küme merkezleri ve üyelik dereceleri güncellenir [20].

Fuzzy C-Means algoritmasının amacı, minimize eden bir fonksiyon kullanarak veri noktalarına olan aitlikleri en iyi şekilde modelleyen bir kümeleme yapmaktır. Minimize fonksiyonu Denklem 2’deki gibi tanımlanır:

$$J_m(U, C) = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2 \quad (2)$$

x_i : veri noktası

c_j : j-inci kümenin merkezi

u_{ij} : x_i 'nin j-inci kümeye olan üyelik derecesi

Bu algoritmada daha önce uygulanan diğer yöntemler için belirlenen parametreler kullanılmaya devam edilmiştir. Küme sayısının belirlenmesinde Elbow Yöntemi ve Silhouette Score gibi doğrulama teknikleri kullanılmıştır. Şekil 3’de Silhouette Score sonuçları gözlemlenmektedir. Bu yöntemler aracılığıyla elde edilen sonuçlara bakılarak optimal küme sayısının 4 olduğu tespit edilmiştir. Bu sayede farklı arıza türlerine sahip makineler dört ayrı şekilde gruplanmış ve her bir kategorinin özellikleri net bir şekilde tanımlanmıştır. Elde edilen kümeler, bakım ekiplerinin makinelerin arızalarına nasıl müdahale edebileceğini belirlemelerine olanak tanır ve böylece daha verimli müdahaleler yapılabilir.

```

2 küme için Silhouette Score: 0.40495131703688975
3 küme için Silhouette Score: 0.4685874995159107
4 küme için Silhouette Score: 0.5068487696988263
5 küme için Silhouette Score: 0.3894539061744767
6 küme için Silhouette Score: 0.4282612760198679
7 küme için Silhouette Score: 0.4321386431270553
8 küme için Silhouette Score: 0.4270943542846409
9 küme için Silhouette Score: 0.42553985256174076
10 küme için Silhouette Score: 0.4007272106356272
11 küme için Silhouette Score: 0.3889659808328625
12 küme için Silhouette Score: 0.4062414045412148
13 küme için Silhouette Score: 0.40332754003288723
14 küme için Silhouette Score: 0.40972002645103095

```

Şekil 3. Silhouette Score Yöntemi(Silhouette Score Method)

Küme sayısı belirlendikten sonra Fuzzy C-means algoritması uygulanmış ve bir model oluşturulmuştur. Bu süreçte, makinelerin arıza geçmişlerini anlamak için oluşturulan Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi gibi parametreler kullanılmıştır. Bu parametreler aracılığıyla her bir makine, arıza durumlarına göre en uygun kümelerle atanmıştır. Böylece her makine,

benzer arıza özelliklerine sahip olan makinelerle aynı kümeye yerleştirilmiş ve kümeler arasında daha net bir ayırım sağlanmıştır. Makinelerin bu kümelerle nasıl yerleştirildiğini ve kümelerin içerisindeki dağılımları daha iyi gözlemleyebilmek amacıyla veri görselleştirme teknikleri kullanılmıştır. Görselleştirme araçları sayesinde, kümelerin farklı arıza türlerine göre nasıl yapılandırıldığı ve makinelerin hangi küme içinde yer aldığı daha net bir şekilde analiz edilmiştir.

3. BULGULAR ve TARTIŞMA (RESULTS and DISCUSSION)

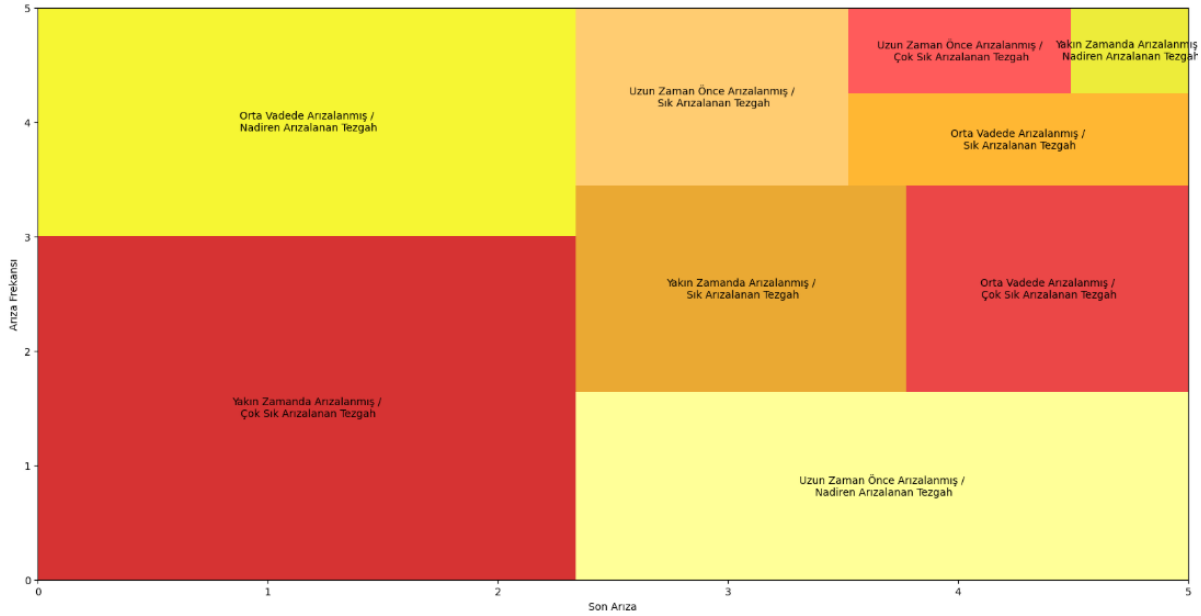
Bu bölümde yapılan analiz ve kullanılan algoritmaların sonuçları ve bu sonuçların detayları ele alınacaktır. Her bir küme için elde edilen sonuçlar makinelerin bakım ihtiyaçları ile ilişkili olarak tartışılacak ve farklı yöntemlerin kıyası yapılacaktır. Elde edilen sonuçlar görsellerle birlikte yorumlanacaktır.

3.1 RFM Analizi (RFM ANALYS)

RFM analizi bu çalışmada makinelerin arıza geçmişlerini segmentlere ayırmak amacı ile kullanılmıştır. Makineler, Son Arıza ve Arıza

Frekans parametrelerine göre analiz edilmiştir. İki parametre için de veriler beş eşit aralığa bölünmüştür. Son Arıza skorunda düşük değerler 1, yüksek değerler 5 olarak puanlanırken; Arıza Frekans skorunda düşük değerler 5, yüksek değerler 1 olarak puanlanmıştır. Bu skorlar birleştirilerek RF skoru elde edilmiştir. Toplam Arıza Süresi parametresi, bakımın yoğunluğundan, parça yetersizliğinden veya servis bekleme süresinden

dolayı net arıza süresini vermemektedir. Bu sebeple RFM segmentasyonuna dahil edilmemiştir. Bu nedenle teorik olarak $5 \times 5 = 25$ farklı skor kombinasyonu oluşması mümkünken verilerin yoğunlukları ve gerçek dağılımı dikkate alındığında 9 anlamlı kategori ortaya çıkmıştır. Sonuçlar treemap diyagramı kullanılarak görselleştirilmiştir. Treemap diyagramında verilerin büyüklüğü dikkate alınmaktadır ve konumlarının bir önemi bulunmamaktadır. Şekil 4'te renklendirme işlemi, Son Arıza zamanına göre renk tonları, Arıza Frekansı değerlerine göre ise renk doygunlukları dikkate alınarak gerçekleştirilmiştir. Analiz sonucu elde edilen segmentler, makinelerin arıza durumları hakkında bilgi vermiş ve bu bilgiler müdahale edilmesi gereken makinelerin belirlenmesinde kullanılmıştır.



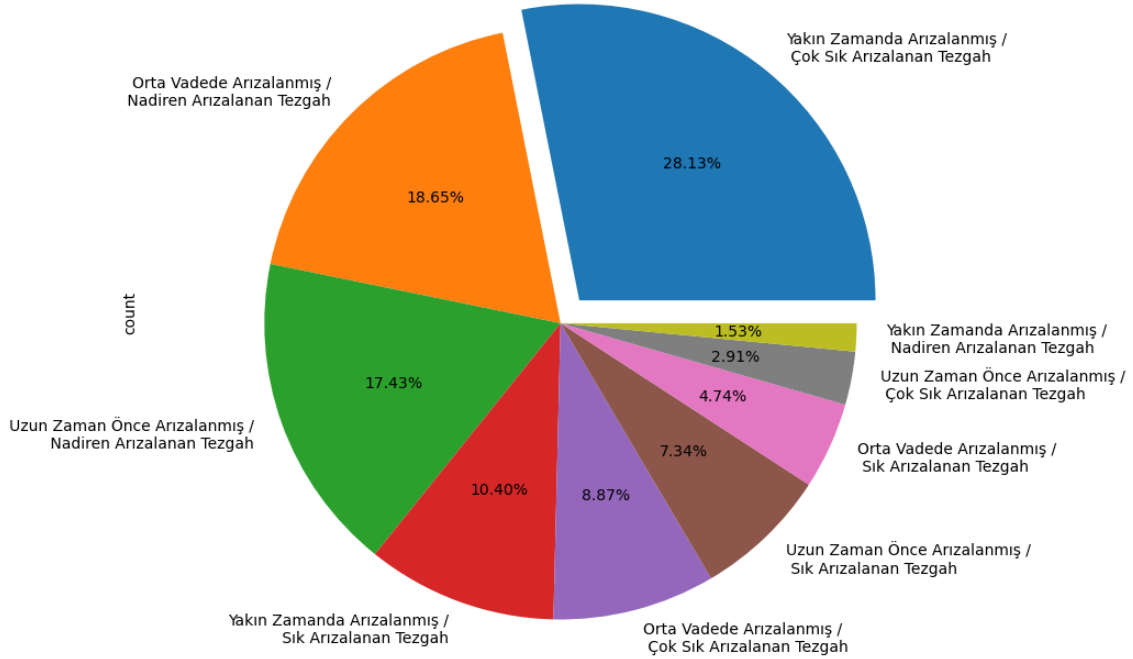
Şekil 4. RFM Analizi ile Makine Segmentasyon Yoğunluk Dağılımı (Machine Segmentation Density Distribution with RFM Analysis)

Şekil 4'te, makinelerin çok sık, sık ve nadiren şeklinde sınıflandırılması Arıza Frekans skorlarına bakılarak belirlenirken yakın zamanda arızalanmış, orta vadede arızalanmış ve nadiren arızalanmış sınıfları Son Arıza skorlarına göre belirlenmiştir. Yakın Zamanda Arızalanmış / Çok Sık Arızalanan

tezgahlar Arıza Frekansı ve Son Arıza zamanı parametrelerinde en düşük puanı almıştır. Bu makineler, sürekli arıza yaşamakta olup üretim süreçlerinde büyük verimlilik kayıplarına yol açabilir. Arıza sıklığının yüksek olması makinelerin bakıma duyduğu ihtiyacın yüksek düzeyde

olduğunu ve acil müdahale gerektirdiklerini ifade eder. Orta Vadede Arızalanmış / Sık Arızalanan Tezgâh segmentindeki makineler Arıza Frekansı ve Son Arıza zamanı parametreleri bakımından ortalama bir puan almıştır. Bu makineler için bakım planlarının güncellenmesi ve periyodik bakım sıklığının artırılması gereklidir. Ayrıca arıza nedenlerinin daha detaylı bir şekilde analiz edilmesi

ve temel sebeplerin tespit edilmesi gereklidir. Uzun Zaman Önce Arızalanmış / Nadiren Arızalanan Tezgâh segmentindeki makineler ise Arıza Frekansı ve Son Arıza zamanı parametrelerinde en yüksek skoru almıştır. Bu segmentteki makineler için periyodik bakımın yeterli olduğu ve acil müdahale gerektirmedikleri anlaşılmaktadır.




Şekil 5. Makine Segmentlerinin Dağılımı (Breakdown of Machine Segments)

Şekil 5’de makinelerin son arıza zamanları ve arıza sıklıkları baz alınarak pasta grafiği elde edilmiştir. Grafiğe bakıldığında %17.43 oranında Uzun Zaman Önce Arızalanmış / Nadiren Arızalanan Tezgâhların olduğu gözlemlenmektedir. Bu segmente ait makinelerin acil müdahale gerektirmediği ve periyodik bakımlarının yapılmasının yeterli olacağı anlaşılmaktadır. Ayrıca bu makineler operasyonel verimlilik açısından iyi bir performans sergilemektedirler. Yakın Zamanda Arızalanmış / Çok Sık Arızalanan makinelerin ise %28.13 oranında olduğu görülmektedir. Bu segment, acil müdahale edilmesi gereken makinelerin diğerlerine oranla daha fazla olduğunu gösterir. Zamanında müdahale edilmezse üretimde kayıplar oluşabilir ve firma bu durumdan olumsuz etkilenebilir.

3.2 K-means

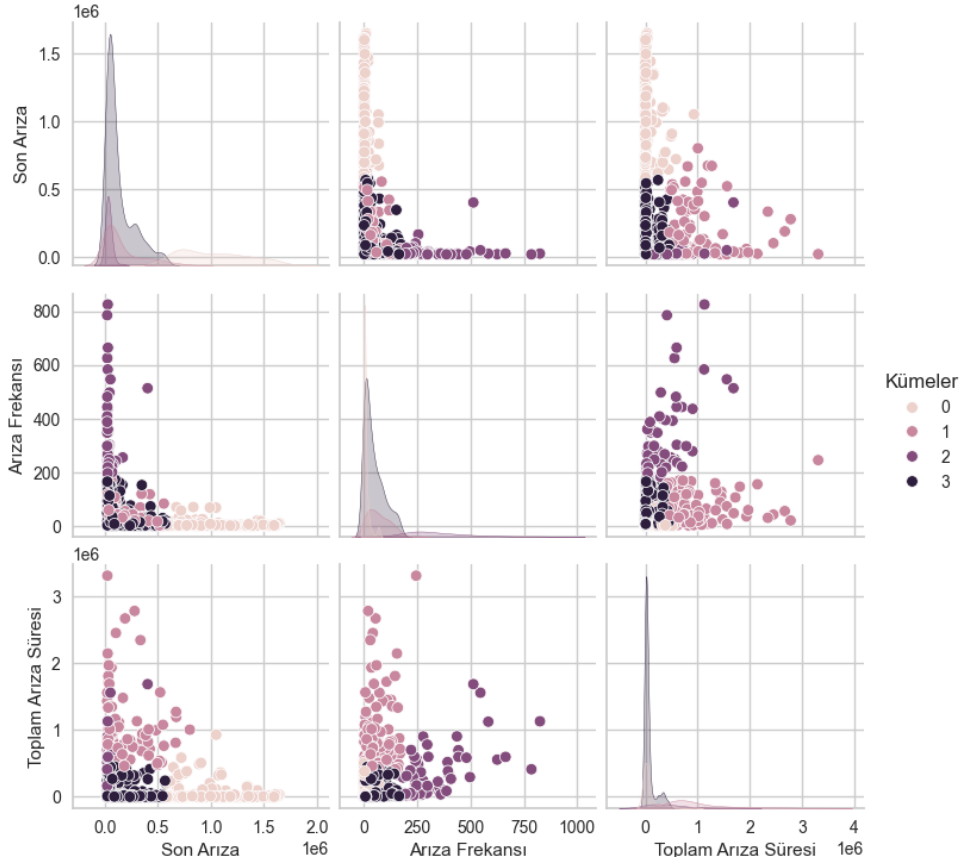
Bu çalışmada, hesaplanan Son Arıza, Arıza Frekansı ve Toplam Arıza Süre parametreleri K-means algoritması için kullanılmıştır. Merkez kümeleri belirlemek amacı ile Elbow ve Silhouette Score yöntemleri kullanılmış ve bu yöntemler sonucunda

veriler 4 kümeye ayrılmıştır. Kümelere ayrılan Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametrelerinin dağılımı Şekil 6’da gösterilmektedir.



Şekil 6. Verilerin Kümelere Dağılımı (Distribution of Data to Clusters)

Şekil 6’da verilerin kümelere dağılımına bakıldığında çoğu verinin ilk kümeye atandığı gözlemlenmektedir. Bu durum, benzer özelliklere sahip verilerin fazla olduğunu ifade ederken makinelerin belirli bir arıza durumuna sahip olduklarını temsil eder.



Şekil 7. Kümelenen Verilerin Dağılımı (Distribution of Clustered Data)

Şekil 7’de, Son Arıza, Arıza Frekansı ve Toplam Arıza Süresi parametrelerinin birbiriyle olan ilişkileri temsil edilmektedir. Küme sayısını belirlemek için Elbow ve Silhouette Score yöntemleri kullanılmış ve bu yöntemler sonucunda veriler 4 kümeye ayrılmıştır. Oluşan kümeler, küme içi ve kümeler arası benzerliklerine göre ayrılmıştır. Son arıza parametresinin çoğu değerinin düşük olduğu gözlemlenmektedir. Bu durum çoğu makinenin arızalanma tarihlerinin yakın olduğunu ifade eder ve makinelerin bakımının yapılması gerektiği sonucu çıkarılabilir. Arıza Frekans parametresi incelendiğinde sık arızalanan makinelerin azınlıkta olduğu yani birçok makinenin sık arıza vermediği anlaşılmaktadır. Son olarak Toplam Arıza Süresi parametresine bakıldığında genellikle makinelerin kısa süreli arıza verdikleri ama bazı makinelerin ise oldukça uzun süre arızada kaldıkları görülmektedir. Bu durum bazı makinelerin üretimdeki kayıplarının fazla olduğu anlaşılmaktadır.

Kümeler incelendiğinde küme 0, düşük arıza frekansı ve toplam arıza süresi, yüksek son arıza zamanına sahip olan makinelerden oluşmaktadır. Bu durum güvenilir makineleri temsil eder ve periyodik bakımlarının yapılması yeterlidir. Küme 1, orta düzeyde arızalanan makineleri temsil


etmektedir. Bu makinelerin bakım planları güncelleştirilebilir ve periyodik bakımları sıklaştırılabilir. Küme 2, son arıza süresi düşük, arıza frekansı yüksek ve toplam arıza süresi değişkenlik gösteren ama genelde yüksek makineleri temsil etmektedir. Bu durumdaki makinelere öncelik verilerek müdahale edilmesi gerekir. Küme 3 ise son arıza süresi düşük, arıza frekansı ve toplam arıza süresi yüksek olan makinelerden oluşmaktadır. Bu durumda makineler üretimde kayba neden olabilir ve acil müdahale edilmesi gerekmektedir.

Sonuç olarak bu veriler ve kümeler incelendiğinde makineler hakkında çıkarım yapılabilir. Her küme için bakım periyotları, küme içindeki makinelerin arıza profillerine göre belirlenmelidir. Örneğin, sık arızalanan makineler için kısa zamanlı bakım periyotları oluşturulurken daha az sıklıkta arızalanan makineler için periyodik bakım zamanları daha uzun olabilir. Toplam Arıza Süresi baz alındığında makinelerin arıza sürelerine göre ayrılan kümeler Şekil 7 üzerinde gözlemlenmektedir. Makinelerin arızada kaldığı zaman dilimleri dikkate alınarak bakım planlaması yapılmalıdır. Acil müdahale edilmesi gereken makineler incelenmeli ve bu makinelere yoğunlaşılmalıdır.

3.3 Fuzzy C-means

Bu kümeleme algoritmasında her bir verinin bir kümeye üye olma durumları incelenmiştir.

Makinelerin kaç kümeye ayrılacağı Elbow ve Silhouette Score yöntemleri kullanılarak belirlenmiştir. Bu yöntemler sonucunda makineler 4 kümeye ayrılmıştır.



Şekil 8. Kümelerin Dağılım Grafiği (Scatter Plot of Clusters)

Şekil 8’de, Son Arıza parametreleri kullanılarak oluşturulan ilk kümede değerler oldukça yüksek olarak gözlemlenmektedir. Bu durum makinelerin son arızalarının oldukça eski tarihlere dayandığını ve uzun süredir herhangi bir arıza yaşanmadığını gösterir. Diğer üç kümede ise son arıza değerleri daha düşük olup makinelerin yakın zamanda arızalandığını ifade etmektedir. Arıza Frekansı verileriyle oluşturulan grafikte üçüncü kümeye bakıldığında arıza frekanslarının yüksek olduğu ve makinelerin sıkça arızalandığı görülmektedir. Bu durum, makinelerin acil müdahale edilmesi gerektiğini ifade etmektedir. Diğer kümelerde arıza frekansları daha düşük olarak gözlemlenmektedir ve bu makinelerin öncelikli olmadığı anlaşılmaktadır. Toplam Arıza Süresi parametresi kullanılarak oluşturulan grafikte ikinci küme toplam arıza sürelerinin en fazla olduğu kümelemedir. Bu durum, makinelerin arızalanma sürelerinin fazla olduğunu ifade etmektedir. Sonuç olarak her bir parametre ve küme için değerlendirme bu grafikler üzerinden yapılabilir.

Kümeleme analizinde, kümeleri oluşturan temel parametreler olarak Arıza Frekansı, Son Arıza Zamanı ve Toplam Arıza Süresi dikkate alınmıştır. Bu özelliklere ek olarak, her veri noktasının ait olduğu küme bilgisini içeren etiketler kullanılarak kümelerin hem birbirlerinden ne ölçüde ayrıldığı hem de kendi içlerindeki yoğunluk derecesi analiz

edilmiştir. K-means ve Fuzzy C-means algoritmalarını kıyaslamak amacı ile David-Bouldin Index, Dunn Index ve Calinski Harabasz Index yöntemleri kullanılmıştır. Bu yöntemler sayesinde kümeler arası uzaklıklar ve küme içi yoğunluklar analiz edilerek her bir algoritmanın ne derece başarılı olduğu ölçülmüştür.

	David-Bouldin Index	Dunn Index	Calinski-Harabasz Index
K-means	1.053	0.117	510.093
Fuzzy C-means	1.153	0.0015	470.043

Tablo 2. Değerlendirme Sonuçları (Evaluation Results)

Tablo 2’ye bakıldığında David-Bouldin yönteminde K-means algoritması 1.053 puan alırken Fuzzy C-means algoritması 1.153 almıştır. Bu yöntem kümeler arası mesafeyi artırmayı ve küme içindeki verilerin birbirine yakın olmasını hedefler. Düşük bir değer, kümelemenin daha iyi olduğu anlamına gelmektedir. Bu durumda K-means algoritmasının daha iyi bir sonuç verdiği gözlemlenmektedir. Dunn Index tekniği kullanıldığında K-means 0.117 ve

Fuzzy C-means 0.0015 puan almıştır. Yüksek bir Dunn Index değeri, küme içindeki mesafelerin küçük ve kümeler arasındaki mesafenin büyük olduğunu ifade eder. Yani, yüksek değer kümelerin iyi ayrıldığı anlamına gelmektedir. Bu durumda, K-means algoritması daha iyi bir kümeleme yaptığı anlaşılmaktadır. Calinski-Harabasz Index tekniğinde K-means algoritması 510.093 puan alırken Fuzzy C-means algoritması 470.043 puan almıştır. Bu teknikte küme içindeki yoğunluğa ve kümeler arasındaki ayrıma göre değerlendirme yapılmaktadır. Yani, daha yüksek olan skor kümeler arasındaki ayrımın daha güçlü olduğu anlamına gelmektedir. Bu durumda K-means algoritması daha yüksek puan alarak daha iyi kümeleme yaptığı gözlemlenmektedir. Kullanılan üç tekniğin sonuçlarına bakıldığında K-means algoritması hepsinde daha ideal bir sonuç alarak daha iyi bir kümeleme yapmıştır. Bu durum göz önüne alındığında makineleri kümelere ayırmak için K-means algoritması kullanılabilir ve daha optimal sonuçlar elde edilebilir.

4. SONUÇ (CONCLUSION)

Bu çalışmada makineler RFM analizi ile segmentlerine ayrılmış daha sonrasında ise K-means ve Fuzzy C-means algoritmaları kullanılarak kümelere ayrılmıştır. RFM analizi sonucu elde edilen skorlar doğrultusunda makineler arıza durumlarına göre 9 farklı kategoriye ayrılmıştır ve böylece makinelerin arıza eğilimleri hızlı ve anlamlı bir şekilde sınıflandırılmıştır. K-means algoritması, makineleri belirlenen 4 küme etrafında sert bir şekilde gruplandırmıştır. Bu yöntemde makineler kesin olarak bir kümeye aittir. Fuzzy C-means algoritması ise makinelerin 4 kümeye belli bir üyelik derecesiyle ait olmasını sağlamıştır. Makineler, Son Arıza, Arıza Frekansı ve Toplam Arıza Sürelerine göre gruplandırılmıştır. Bu gruplandırma sonuçlarına bakılarak makinelerin bakım süreçleri optimize edilebilir. Bu çalışma, endüstriyel bakım süreçlerini optimize etmek için veri odaklı güçlü bir yaklaşım sunar ve makinelerin arızalarına müdahale etme ve bakım maliyetlerini azaltma konularında önemli katkılar sağlamaktadır.

RFM analizinde makineler doğrudan belirli skorlara göre kategorilere ayrılmıştır. Bu yöntem hızlı bir segmentasyon işlemi yapılmasını sağlar. K-means ve Fuzzy C-means algoritmaları ile yapılan kümeleme çalışması ise makineler arasındaki gizli benzerlikleri ve farklılıkları daha hassas bir şekilde ortaya çıkarmıştır. Bu çalışma sonucunda arıza yapma riski yüksek makineler önceden tespit edilerek planlı bakıma alınabilir. Gereksiz bakım uygulamaları önlenerek bakım ve duruş maliyetleri

düşürülür. Ayrıca düzenli ve zamanında müdahale ile makinelerin ömrü uzatılabilir.

RFM analizi, makineleri önceden belirlenen skor aralıklarına göre hızlı ve basit bir şekilde segmentlere ayırarak arıza eğilimlerini sınıflandırır. Bu sayede makinelerin arıza durumlarına göre ilk risk durumları belirlenebilir. Ancak RFM analizi, sabit eşiklerden oluştuğu için değişkenler arası karmaşık ilişki göz ardı edilebilir. Buna karşılık, K-means algoritması, makineleri veri dağılıma dayalı olarak kümelendirir ve değişkenler arası istatistiksel benzerlikleri dikkate alır. RFM analizine göre daha az kategori üretse de bu kategoriler veri yapısını daha iyi analiz eder. Sonuç olarak, RFM analizi makinelerin genel arıza eğilimlerini belirleyerek ilk tarama ve önceliklendirme için kullanılabilir. K-means algoritması ise önceliklendirilen makineler arasında derin bir analiz ve bakım stratejilerinin geliştirilmesi için kullanılabilir. Bu sayede her iki yöntem birlikte kullanılarak hem bakım kaynakları etkin bir şekilde kullanılabilir hem de arızaya bağlı üretimde kayıp en aza indirgenebilir.

Literatürde RFM analizi ve kümeleme algoritmaları müşteri segmentasyonu için kullanılmaktadır. Ancak bu çalışmada üretim sektörüne ait arıza verileri kullanılarak makine segmentasyonu için kullanılmıştır. Elde edilen segmentasyon sonucunda hangi makinelere öncelikli olarak bakım yapılması gerektiği belirlenmiş ve operasyonel verimlilik artırılmıştır. Ayrıca enerji ve maliyet tasarrufları sağlanarak daha verimli bir üretim süreci sağlanmıştır. Bu çalışma RFM analizi ve kümeleme algoritmalarının üretim sektörüne entegre edilebileceği konusunda bir bakış açısı sunmuştur.

Gelecekte, farklı algoritmaların kullanımı ve karşılaştırması, ayrıca periyodik bakım kayıtları olan daha geniş veri setleri ile yapılan testler sonuçların performansını iyileştirebilir. Veri seti genişletilirse periyodik bakım planlaması ve arıza müdahale durumları için daha iyi sonuçlar elde edilebilir.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu çalışmada kullanılan veri seti, Birinci Otomotiv firması tarafından sağlanmıştır. Kendilerine, değerli katkıları ve destekleri için teşekkür ederiz. Verilerin sağlanması, bu araştırmanın gerçekleştirilmesinde büyük bir yardımcı olmuştur ve çalışmanın başarısına önemli bir katkı sağlamıştır.

KAYNAKLAR (REFERENCES)

- [1] Shokrani A, Dhokia V, Newman ST. Environmentally conscious machining of difficult-to-machine materials with regard to cutting fluids. *International Journal of Machine Tools and Manufacture*. 2012; 57: 83–101.
- [2] Sivakumar K, Mathan Kumar P, Amarkarthik A, Jegadheeswaran S, Shanmugaprasath R. Empirical modeling of material removal rate and surface roughness of OHNS steel using Cu-TiB₂ Tool in EDM. *Materials Today: Proceedings*. 2021; 45: 2725–2729.
- [3] Matorian P, Sulaiman S, Ahmad MMHM. An experimental study for optimization of electrical discharge turning (EDT) process. *Journal Of Materials Processing Technology*. 2008; 204: 350–356.
- [4] Pant P, Bharti PS. Electrical Discharge Machining (EDM) of nickel-based nimonic alloys: A review. *Materials Today: Proceedings*. 2020; 25: 765–772.
- [5] Bishnoi P, Sahu M. Optimization of the Keyseat Design with Consideration of Effect of Stress Concentration on Different Materials. *International Journal of Engineering Research & Technology*. 2014; 3: 477–481.
- [6] Kishor HP, Raghu T. Design Analysis of A Keyless Coupling. *International Journal of Recent Research in Civil and Mechanical Engineering*. 2014; 1: 37–43.
- [7] Verma V, Sajeevan R. Multi Process Parameter Optimization of Diesinking EDM on Titanium Alloy (Ti6Al4V) Using Taguchi Approach. *Materials Today: Proceedings*. 2015; 2: 2581–2587.
- [8] Klocke F, Mohammadnejad M, Holsten M, Ehle L, Zeis M, Klink A. A Comparative Study of Polarity-related Effects in Single Discharge EDM of Titanium and Iron Alloys. *Procedia CIRP*. 2018; 68: 52–57.
- [9] Bhaumik M, Maity K. Effect of different tool materials during EDM performance of titanium grade 6 alloy. *Engineering Science and Technology, An International Journal*. 2018; 21: 507–516.
- [10] Singh NK, Singh Y, Sharma A, Prasad R. Experimental investigation of flushing approaches on EDM machinability during machining of titanium alloy. *Materials Today: Proceedings*. 2021; 38: 139–145.
- [11] Prakash J, Equbal MdI, Equbal A. Investigative study on dimensional accuracy of machined cavity formed during EDM of AISI 1035. *Materials Today: Proceedings*. 2021; 47: 3217–3220.
- [12] Kumar P, Dewangan S, Pandey C. Analysis of surface integrity and dimensional accuracy in EDM of P91 steels. *Materials Today: Proceedings*. 2020; 33: 5378–5383.
- [13] Sanchez JA, Lopez de Lacalle LN, Lamikiz A, Bravo U. Dimensional accuracy optimisation of multi-stage planetary EDM. *International Journal of Machine Tools and Manufacture*. 2002; 42: 1643–1648.
- [14] Çakıroğlu R, Günay M. Comprehensive analysis of material removal rate, tool wear and surface roughness in electrical discharge turning of L2 tool steel. *Journal Of Materials Research and Technology*. 2020; 9: 7305–7317.
- [15] Singh H, Shukla DK. Optimizing electric discharge machining parameters for tungsten-carbide utilizing thermo-mathematical modelling. *International Journal of Thermal Sciences*. 2012; 59: 161–175.
- [16] Unses E, Çoğun C. Improvement of Electric Discharge Machining (EDM) Performance of Ti-6Al-4V Alloy with Added Graphite Powder to Dielectric. *Strojniski Vestnik - Journal of Mechanical Engineering*. 2015; 61.
- [17] Azhiri RB, Bideskan AS, Javidpour F, Tekiyeh RM. Study on material removal rate, surface quality, and residual stress of AISI D2 tool steel in electrical discharge machining in presence of ultrasonic vibration effect. *The International Journal of Advanced Manufacturing Technology*. 2019; 101: 2849–2860.
- [18] Koenig W. The Flow Fields in the Working Gap with Electro Discharge Machining. *Annals Of The CIRP*. 1977; 25: 71–75.
- [19] Schumacher BM. About the Role of Debris in the Gap During Electrical Discharge Machining. *CIRP Annals*. 1990; 39: 197–199.
- [20] Obara H, Abe M, Ohsumi T. Control of Wire Breakage during Wire EDM -1st Report: Monitoring of Gap Signals According to Discharged Location. *International Journal of Electrical Machining*. 1999; 4: 53–58.
- [21] Çakıroğlu R, Günay M. Elektro Erozyonla Tornalama Yöntemiyle İşlenen Soğuk İş Takım Çeliğinin Yorulma Ömrünün Tahmini. *Politeknik Dergisi*. 2021; 24: 495–502.