

KESTİRİMCİ BAKIM PLANLAMA İÇİN MAKİNE ÖĞRENMESİ TEMELLİ BİR KARAR DESTEK SİSTEMİ VE BİR UYGULAMA

Banu SOYLU¹, Hatice YİĞİTER², Venüs SARIKAYA³, Zinnet SANDIKÇI⁴, Asena UTKU⁵

ÖZET

Amaç: Üretim sistemlerinde meydana gelen arızaları önlemek için Endüstri 4.0 altyapısını kullanan kestirimci bakım planlama işletmelerin gündemine girmiştir. Bu çalışmada, bir sistemde meydana gelen arızaların ve üretim duruşlarının en küçüklenmesi için nesnelerin interneti (IoT) ve makine öğrenmesi tabanlı bakım karar destek sistemi oluşturulmuş ve bir makine üzerinde pilot çalışma yapılmıştır.

Yöntem: Bu çalışmada, sistemin sürekli izlenebilirliğini sağlamak için sıcaklık, nem ve ses sensörleri kullanılmıştır. Bu sensörlerle alınan veriler IoT kullanılarak veri tabanına bir ağ aracılığı ile aktarılmıştır. Aktarılan bu verilerden sistemin durumunu (“arıza olabilir”, “sağlam”) tahmin etmek için makine öğrenmesi teknikleri (Destek Vektör Makinesi ve Karar Ağacı) kullanılmıştır.

Bulgular: Geliştirilen karar destek sistemi, bakım kararı verebilmektedir. Böylece pilot çalışma yapılan makinede gerçekleşmiş olan 1419 dk. beklenmeyen duruşların en küçüklenmesi sağlanacaktır.

Özgünlük: Yenilikçi bir yön olarak; sisteme giren ürün sırasının da arızaya etkisinin olabileceği sıralı örüntü madenciliği yöntemleriyle incelenmiştir. IoT, makine öğrenmesi, kestirimci bakım, sıralı örüntü madenciliği ve dinamik çizelgelemenin entegrasyonunu içeren bir bakım karar destek sistemi oluşturulmuştur.

Anahtar Kelimeler: Nesnelerin İnterneti (IoT), Makine Öğrenmesi Teknikleri, Kestirimci Bakım, Sıralı Örüntü Madenciliği, Dinamik Çizelgeleme.

JEL Kodları: C38, M11, O32.

A MACHINE LEARNING-BASED DECISION SUPPORT SYSTEM FOR PREDICTIVE MAINTENANCE PLANNING AND AN APPLICATION

ABSTRACT

Purpose: In order to prevent breakdowns in production systems, predictive maintenance planning using Industry 4.0 infrastructure has been the focus of companies. In this study, a predictive maintenance decision support system integrated with internet-of-things (IoT) was developed and a pilot study was carried out on a machine to minimize the breakdowns and production downtime.

Methodology: Temperature, humidity, and sound sensors have been used in order to provide continuous monitoring of the system. The data obtained with these sensors is transferred to a database via a network using IoT. In order to predict the system state (“breakdown may occur”, “good”) from this data, the machine learning techniques (Support Vector Machine and Decision Tree) are used.

Findings: The proposed decision support system is able to make self-maintenance decision. Thus, it would be possible to minimize 1419 min. downtime of the machine that the pilot study was performed on.

Originality: The effect of production sequence on system breakdowns has been investigated with sequential pattern mining algorithms. A maintenance decision support system including the integration of IoT, machine learning, predictive maintenance, sequential pattern mining and dynamic scheduling has been developed.

Keywords: Internet-of-Things (IoT), Machine Learning Techniques, Predictive Maintenance, Sequential Pattern Mining, Dynamic Scheduling.

JEL Codes: C38, M11, O32.

¹ Prof. Dr., Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye, bsoylu@erciyes.edu.tr, ORCID: 0000-0003-4164-7583 (Sorumlu Yazar-Corresponding Author).

² Endüstri Müh., Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye, haticeyigiterr@gmail.com, ORCID: 0000-0002-9269-0111.

³ Endüstri Müh., Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye, venus.sarikayaa@gmail.com, ORCID: 0000-0002-0429-948X.

⁴ Endüstri Müh., Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye, san.zinnet@gmail.com, ORCID: 0000-0003-0968-5010.

⁵ Endüstri Müh., Erciyes Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, Kayseri, Türkiye, asenautku32@gmail.com ORCID: 0000-0001-6793-1369.

1. GİRİŞ

Dördüncü sanayi devrimi ile birlikte üretimde hızlı bir dijitalleşme başlamış, böylece makinelerin uzaktan kontrolünü ve sürekli çalışmasını sağlamak da sistemin sürdürülebilirliği açısından önem kazanmıştır. Dolayısıyla, sensörler, IoT (nesnelerin interneti), siber-fiziksel sistem, kestirimci bakım, büyük veri vb. kavramlar işletmelerin gündemine girmiştir (Pamuk ve Soysal, 2018). Çalışan bir makineden sensörler yardımıyla sürekli veri elde etmek ve bu verinin belirli sınırlar içinde olup olmadığını anlık olarak takip etmek mümkündür. Makinelerin online olarak sürekli takip edilebilmesi, IoT ve dijital teknolojilerdeki gelişmeler ile popülerlik kazanmıştır (Çakır ve diğerleri, 2021).

Kestirimci bakım stratejisi, bir sistem bozulmadan önce onun mevcut durumunu analiz ederek bakıma ihtiyacı olup olmadığını belirler. Dolayısıyla sistem parametrelerinin (sıcaklık, basınç, titreşim, ses, voltaj vb.) sürekli takip edilmesi gerekmektedir. Bu takipler için kullanılacak olan sensörlerin/cihazların veri toplaması, toplanan verinin IoT kanallarıyla depolanması ve depolanan büyük verinin de analiz edilmesi önemli ve zahmetlidir. Verilerin analizi sonucunda, arızalar meydana gelmeden önce kestirilip gerekli bakım planı hazırlanarak sistem güvenilirliği artırılır (Karaduman, 2020). Bu sebeple kestirimci bakım günümüzde diğer bakım stratejilerine göre en etkili ve doğru bakım planını oluşturduğu için oldukça önem kazanmıştır (Carvalho ve diğerleri, 2019). Kestirimci bakım sayesinde sistemde meydana gelecek uzun süreli aksamalar, yedek parça maliyetleri, üretim çizelgesindeki değişiklikler, termin sürelerindeki gecikmeler vb. pek çok problem önlenmektedir (Carvalho ve diğerleri, 2019; Köksal ve Uzun, 2016).

Endüstri 4.0 ile hayatımıza giren kestirimci bakımı uygulamak için IoT ve makine öğrenme teknikleri kullanılmaktadır (Zonta ve diğerleri, 2020). Yeni nesil üretim süreçlerinde veri transferinin sağlanması için nesnelerin internetinin kullanımı üretimdeki verimliliğin artmasına sebep olmuştur (Lu, 2017). Makine öğrenme teknikleri, büyük verileri analiz ederek faydalı bilgi üretme avantajı sayesinde işletmelere karar verme süreçlerinde yardımcı olur ve küresel pazarda rekabet gücünü artırır (Wamba ve diğerleri, 2020). Ayrıca bu analizler sayesinde dinamik endüstriyel ortamlara ait verilerin içerisindeki bilinmeyen/anlamlandırılmayan ilişkilerin çözülmesi de mümkün olur (Wuest ve diğerleri, 2016). Literatürde sensör verilerini makine öğrenmesi teknikleri ile analiz eden pek çok çalışma mevcuttur (Çınar ve diğerleri, 2020; Dalzochio ve diğerleri, 2020; Lei ve diğerleri, 2020; Carvalho ve diğerleri, 2019). Ancak bu çalışmalarda sensörler dışında üretim sisteminden gelen veriler genellikle analizlerde kullanılmamaktadır. Dolayısıyla sensör verileri ile birlikte üretim planlama, kalite kontrol, tedarik zinciri verileri de dikkate alınarak sistem verimliliği artırılabilir. Literatürde bu entegrasyon konusunda boşluk bulunmaktadır.

Bakım faaliyetlerinin etkilediği en önemli unsurlar arasında planlama faaliyetleri yer almaktadır. Üretimin bir aşamasında gerçekleşecek olan arıza hem üretim planını hem de dağıtım planını geciktirebilir. Statik bir üretim çizelgesi bakım faaliyetini dikkate almakta zorlanabilir. Ancak dinamik çizelgeler daha proaktifler ve beklenmedik arızaları absorbe etmekte daha yeteneklidirler. Dinamik çizelgeleme, düzensiz ürün gelişleri, sipariş iptali, işlem sürelerindeki farklılık, makine arızaları, teslim tarihindeki değişkenlik vb. tahmin edilemeyen durumlara en kısa sürede tepki vermeyi, üretim çizelgesini optimize etmeyi ve tutarlı bir bakım planının oluşturulmasını sağlar (Fang ve Xi, 1997; Baykasoğlu ve diğerleri, 2020).

Bu çalışmada, yatak üretiminin son aşaması olan paketleme makinesinden elde edilen geçmiş arıza ve bakım verileri, geçmiş üretim planları ve sensörlerden elde edilen anlık veriler kullanılarak bir bakım karar destek sistemi geliştirilmiştir. İlk olarak arızalar kaynağına göre gruplandırılmıştır. Elde edilen gruplar bakım uygulama metoduna göre "elektrik" ve "mekanik" olarak iki sınıfa ayrılmıştır. Her iki sınıfın da bakım yapma teknikleri farklı olduğu için Weibull analizi ile periyodik bakım süreleri belirlenmiştir. Periyodik bakımın yeterli olmayacağı, yaşanacak bir duruşun hem üretim planını hem de dağıtım planını geciktireceği için kestirimci bakım tekniklerinin kullanılmasına karar verilmiştir. Sensörlerden elde edilen veriler, makine öğrenme tekniklerine girdi olarak verilmiş ve makinenin bakıma ihtiyacı olup olmadığı kestirilmiştir. Çalışmanın iki yenilikçi yönü bulunmaktadır. Bunlar;

- Makineye gelen ürün sırasının arızaya olan etkisi araştırılmıştır. Bu amaçla, sıralı örüntü madenciliği teknikleri kullanılarak arıza oluşturabilecek örüntüler keşfedilmiş ve üretim planında bu örüntülerin kullanılmaması önerilmiştir. Literatür araştırmamıza göre, bu konu daha önce literatürde ele alınmamıştır.
- Bütünleşik bir karar destek sistemi oluşturulmuştur ve bu sistemin bileşenleri şunlardır: Sistem durumunun makine öğrenme teknikleri ile tahminlenmesi, ürün sıralamasının arızaya olan etkisinin sıralı örüntü madenciliği ile keşfedilmesi ve üretim planlama departmanına bu örüntüler hakkında bilgi verilmesi, kestirilen bakım faaliyetinin üretime olan etkisini azaltmak için dinamik çizelgeleme stratejinin uygulanmasıdır.

Bölüm 2'de literatür özeti sunulmuştur. Bölüm 3'te problem tanımı yapılmıştır. Bölüm 4'te kullanılan yöntemler ve yapılan analizler açıklanmıştır. Bölüm 5'te bulgular verilmiştir. Bölüm 6'da ise bütün sonuçlar özetlenmiştir.

2. LİTERATÜR ARAŞTIRMASI

İşletmelerin sistemlerini verimli kullanmasında makinelerin bakım politikaları önemli rol oynamaktadır. Bakım faaliyetlerinin sistematik olarak yürütülmesi, üretim veya hizmet sektörü fark etmeksizin, işletmelerde oluşacak kayıpların azaltılması, sistemdeki aksamaların giderilmesi, performansın artırılması açısından önem arz etmektedir (Çolak ve diğerleri, 2017).

Bakım stratejileri, düzeltici (plansız), önleyici (planlı) ve kestirimci bakım olarak üçe ayrılmaktadır (Susto ve diğerleri, 2012; Susto ve diğerleri, 2015; Carvalho ve diğerleri, 2019).

- **Düzeltilici bakım**, anlık arızalar meydana geldiğinde yapılmaktadır. Bu bakım stratejisi ile uzun duruş süreleri ve yüksek bakım maliyetleri olduğu literatürde bilinmektedir.
- **Önleyici bakım**, sistemde meydana gelmesi muhtemel arızaları önlemek için periyodik olarak tekrarlanan ve belirli bir zamana çizelgelenmiş bakımdır. Bu politika ile optimum bakım periyodu tespit edilebilir. Weibull analizi, bu periyodu tahmin etmek için sıklıkla kullanılan yöntemlerden birisidir. Weibull dağılımı, arızalar arasındaki ortalama sürenin tahmin edilmesinde ve deney/gözlem yoluyla elde edilmiş geniş veri yelpazesine uyum sağlama avantajlarından dolayı tercih edilir. Weibull parametrelerinin güvenilir olarak tahmin edilmesi sistemin daha doğru değerlendirilmesini sağlar (Liu ve diğerleri, 2019).
- **Kestirimci bakım** stratejisi, istatistiksel yöntemlerin ve makine öğrenme tekniklerinin kullanılmasıyla arızaların önceden tespit edilmesini sağlar. Bu stratejinin amacı, duruşları ve bakım maliyetini en küçükmek, ekipman verimliliğini ise artırmaktır. Li ve He (2015) iki çeşit kestirimci bakım uygulamasının popüler olduğunu belirtmişlerdir. Birincisi, makinenin durumunu tahmin eden sınıflandırma (classification) yaklaşımları, ikincisi ise bir sonraki arızaya kalan süreyi (remaining useful lifetime, RUL) tahmin eden, regresyon yaklaşımlarıdır.

2.1. Kestirimci Bakımda Makine Öğrenme Teknikleri

Kestirimci bakım için yapılan çalışmalarda kullanılan makine öğrenme teknikleri, %33 oranında Rastal Orman (RF), %27 oranında Yapay Sinir Ağları (YSA), %25 oranında Destek Vektör Makineleri (SVM), %13 oranında k-ortalamlar algoritmaları olarak yer almaktadır (Carvalho ve diğerleri, 2019). Literatürde, kestirimci bakımda makine öğrenme tekniklerinin kullanımını araştıran pek çok inceleme makalesi mevcuttur. Doğan ve Birant (2021) makine öğrenmesi ve veri madenciliği yöntemlerinin üretimde kullanımına yönelik bir inceleme makalesi sunmuşlardır. Carvalho ve diğerleri (2019), Çınar ve diğerleri (2020), Dalzochio ve diğerleri (2020), Lei ve diğerleri (2020) kestirimci bakım planlamasında makine öğrenme teknikleri kullanımına yönelik sistematik inceleme makaleleri yayınlamışlardır. Kang ve diğerleri (2020) üretim hatlarında makine öğrenmesi yöntemlerini kullanan çalışmalarını incelemişlerdir. Çakır ve diğerleri (2021) Endüstri 4.0 uyumlu, makine öğrenme teknikleri kullanarak bir motor şaftının durumunu takip eden bir sistem geliştirmişlerdir. Titreşim, ses, dönme hızı, sıcaklık gibi nitelikleri takip eden sistem %95-99 oranında doğru durum tespiti yapmaktadır. Dos Santos ve diğerleri (2017) endüksiyon motorlarında stator sargısı kısa devre arızalarını tespit edilebilmek için RF kullanarak sistemin durumunu "kısa devre var" veya "yok" olarak tahminlemişlerdir. Li ve diğerleri (2014) çalışmasında demiryolu ağındaki hizmet kesintilerini önleyebilmek ve demiryolu ağının hızını arttırabilmek için SVM yöntemi ile mantıksal kurallar üretmek alarm ve arıza tahmini yapmışlardır. Böylelikle her biri birkaç bin ile birkaç milyon dolar arasında maliyete yol açabilen günlük 20'den fazla hizmet kesintisinin önüne geçmişlerdir. Kulkarni ve diğerleri (2018) çalışmasında buzdolabı ve soğuk depolama sistemlerindeki problemlerin önceden tespit edilebilmesi için soğutma ve işlem sinyallerinin trendine bakarak RF yöntemi ile anormal durumları tespit etmişlerdir. Uhlmann ve diğerleri (2018) seçici lazer eritme tezgahlarının önceden arıza tespitini yapmak için sıcaklık, oksijen yüzdesi ve basınç olmak üzere 3 farklı sensör verisi kullanarak k-means yöntemiyle verileri bir normal ve üç arızalı kümeye ayırmışlardır.

Yukarıda verilen literatür araştırmasından da anlaşıldığı üzere kestirimci bakım için sensörlerden elde edilen verilerin makine öğrenme ve yapay zekâ teknikleri ile analizi literatürde oldukça yaygın olarak çalışılmaktadır. Ancak yeni gündeme gelen bir diğer husus ise üretim, bakım ve arıza log kayıtlarının incelenerek kestirimci bakıma bilgi sağlanmasıdır. Zhai ve diğerleri (2021) çalışmasında sensörlerden elde edilen durum bilgisi ve üretim çizelgesindeki işlere bakılarak makinenin ilk arızaya ne kadar zamanı kaldığını tahmin etmektedir. Lim ve diğerleri (2017) bir üretim sürecinde meydana gelen rastgele olayların sıralamasını örüntü madenciliği yöntemleri ile analiz ederek bir üretim partisinin hatalı ürün içerip içermediğini tahmin etmişlerdir. Dangut ve diğerleri (2021) uçaklardaki hata mesajları log kayıtlarını örüntü madenciliği yöntemleri ile analiz etmiş ve önemli sorunlara sebep olan mesaj sıralarını

keşfetmişlerdir. Rezig ve diğerleri (2018) çalışmasında sıralı bakım faaliyetlerini incelemiş ve bazı bakım faaliyetlerinin yapılmasının başka bakım faaliyetlerini de gerektirdiğini keşfetmiştir. Arena ve diğerleri (2022) kestirimci bakım planlama için karar ağaçlarını kullanan bir karar destek sistemi geliştirmişlerdir. Hata türleri ve etkileri analizi sonuçlarına göre kestirimci bakım politikasının mı yoksa düzeltici bakım politikasının mı daha az maliyetli olduğuna karar verilmektedir.

2.2. Dinamik Çizelgeleme

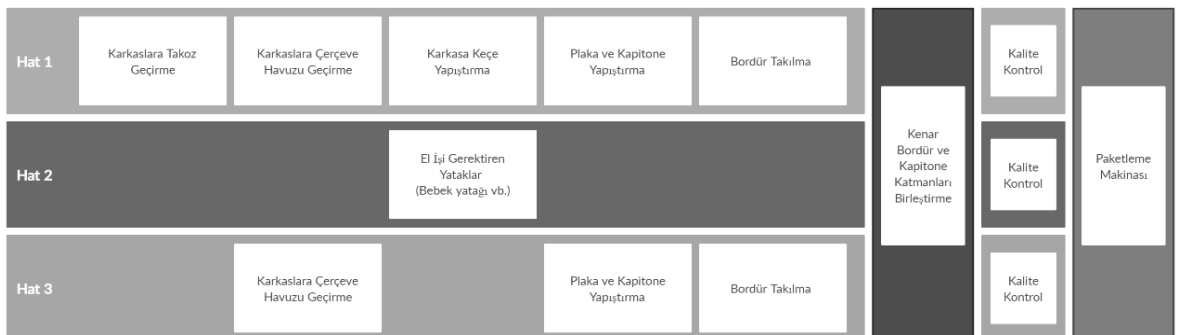
Gerçek-zamanlı olayların durumu da düşünülerek yapılan çizelgelemeye dinamik çizelgeleme denilmektedir (Ouelhadj ve Petrovic, 2009). Bu olaylar, kaynak temelli (Örneğin; makine bozulmaları, hammadde yokluğu, kalitesiz hammadde, operatör yokluğu vb.) ve iş temelli (teslim tarihi değişen siparişler, aniden gelen önemli siparişler, sipariş iptalleri vb.) olabilir (Cowling ve Johansson, 2002; Vieira ve diğerleri, 2003). Dinamik çizelgeleme, tümüyle reaktif çizelgeleme, kestirimci-reaktif çizelgeleme ve gürbüz-önleyici çizelgeleme olmak üzere üç şekilde yapılmaktadır. Tümüyle reaktif çizelgelemede sabit bir sistem yoktur ve kararlar gerçek-zamanlı alınır. Bu durumda bilinen klasik öncelik kuralları kullanılmaktadır. Ancak bütün kriterlerde iyi sonuç veren bir kural olmadığı da literatürde bilinmektedir. Kestirimci-reaktif çizelgelemede gerçek-zamanlı olaya göre mevcut çizelge güncellenir. Gürbüz-önleyici çizelgelemede ise performans ölçütleri tahmin edilerek çizelge oluşturulur ancak bu performans ölçütlerinin tahmininde zorluklar mevcuttur (Ouelhadj ve Petrovic, 2009).

Genellikle makinelerin her zaman kullanılabilir durumda olduğu varsayılarak çizelge hazırlanır ama üretimde özellikle dar boğazı oluşturan makinede meydana gelen arızalanmalar sonucunda oluşan aksamalar çizelgede çok sık değişime sebep olabilmektedir. Literatürde bu gibi durumlarda çizelgeye esneklik sağlamak için dinamik yeniden çizelgeleme yöntemleri kullanılmaktadır. Genellikle mevcut çizelgenin onarılması veya baştan yapılması olmak üzere iki strateji uygulanmaktadır (Cowling ve Johansson, 2002). Sabuncuoğlu ve Bayız (2000) çalışmasında atölye tipi üretim sisteminde yeniden çizelgeleme sıklığını, “mevcut çizelgeyi koru” ve “sürekli çizelge” arasında çeşitli sayıda periyotlarda yapmak üzere bir yöntem önermişlerdir. Baykasoğlu ve diğerleri (2020) çalışmasında, çizelgede bozulmaya neden olan beş sebep; “makine bozulmaları”, “teslim tarihinde değişimler”, “sipariş iptalleri”, “acil siparişler” ve “periyodik yeniden çizelgeleme” olarak belirtilmiştir. Periyodik yeniden çizelgeleme yaklaşımı, toplam işlem süresi, gecikme, kararsızlık vb. kriterler açısından daha iyi sonuç vermiştir. Pan ve diğerleri (2012) çalışmasında, tek makine çizelgeleme problemi için kestirimci bakım operasyonunu da dikkate alan bir yaklaşım önermişlerdir. İşlerin sırası ve bakım operasyonu birlikte çizelgenmektedir. Amaç en fazla gecikmeyi en küçükmektir.

Zhang ve diğerleri (2019), Endüstri 4.0 şartlarında atölye çizelgeleme çalışmaları literatürünü incelemişler ve dinamik çizelgeleme yöntemlerinin akıllı fabrikalar ve akıllı bakımda etkin olarak kullanıldığını belirtmişlerdir. En çok kullanılan çizelge onarım yaklaşımları, sağdan-kaydırma sezgiseli, eşleştirme sezgiseli ve kısmi çizelge onarım sezgiselidir. Mehta ve Uzsoy (1999) ve O'Donovan ve diğerleri (1999) çalışmasında çizelgeye boş zaman eklemek için sağdan-kaydırma sezgiselini kullanmışlardır. Aktürk ve Görgülü (1999) eşleştirme sezgiselinin çizelge kalitesi, işlem zamanı ve çizelge durağanlığı açısından etkili olduğunu göstermişlerdir.


3. PROBLEM TANIMI

Ele alınan üretim sisteminde akış tipi üretim ile siparişe göre yatak üretimi yapılmaktadır. Şekil 1'de üç paralel yatak üretim hattı ve her hattın aşamaları verilmiştir. Bu hatların her birinde farklı tipte yatak üretilmektedir. Hat 1'de 7 aşama sonucunda yatak ortaya çıkmaktadır. Hat 2'de el işçiliği yapılmaktadır. Hat 3'de ise 5 tane aşama sonucunda yatak ortaya çıkmaktadır. Ancak yatağın boyutlarına göre üretim aşamalarında üretim süreleri değişkenlik gösterebilmektedir.



Şekil 1. Üretim akış sistemi

Çalışmanın yapıldığı sistemde mevcut olan makineler, uzmanlar tarafından profesyonel bakım için kritiklik durumlarına göre sınıflandırılmıştır. Bu sınıflandırma sonucunda, AA (çok yüksek) önem seviyesine sahip makinelerden biri olan paketleme makinesi çalışmada ele alınmıştır. Paketleme makinesi, üç ayrı hattan gelen yatakların paketleme işlemini tek başına yapmaktadır (Şekil 2). Bu yataklar çeşitli büyüklüklerde ve ağırlıklarda olabilmektedir. Bu makineye ürünlerin gelişi sıklığı yüksektir ve işlemin çevrim süresi düşüktür. Dolayısıyla herhangi bir arıza meydana geldiğinde kısa süre içerisinde paketleme makinesi girişinde yığılma olmakta ve bu da üç üretim hattında üretimin durmasına sebep olmaktadır. Aynı zamanda paketleme makinesi üretim hattının en sonunda yer aldığından dolayı oluşabilecek bir arıza sonucunda dağıtım planı da aksamaktadır. Bu makinenin alternatifi ve işlemin fason olarak yaptırılması mümkün olmadığından akıllı bakım stratejilerinin uygulanması fabrika için oldukça önem arz etmektedir.




Şekil 2. Paketleme makinesi üretim akışı örnek görseli

Paketleme makinesinde 2017-2021 yılları arasında meydana gelen toplam 141 adet arıza kaydına ulaşılmıştır. Arızaların çoğunun (72 adet) 2017'de meydana geldiği ve bu arızalardan bazılarının kök neden analizleri yapılarak ortadan kaldırıldığı tespit edilmiştir. Dolayısıyla 2017 kayıtları analizlere dahil edilmemiştir.

Makinenin alt-sistemlerinde oluşan arızalanmalar rastgele olduğu için bu alt-sistemlerin ömürleri ve dolayısıyla düzeltici/plansız bakımlar da rassal özellik gösterir. Makine elemanlarının arızalanma davranışları incelenirken genellikle Weibull, Log-normal, Normal ve Gamma dağılımları kullanılmaktadır (Eroğlu, 1998). Bakım periyodunu tahmin edebilmek için arızalar arasındaki ortalama süre verisi alınmış, verilerin bağımsız ve özdeş dağılıma sahip olduğu kabul edilmiştir.


Şekil 3'te son 3 yılda meydana gelen arızaların (69 adet) nedenlerine göre Pareto analizi verilmiştir. Bu arızaların sebep olduğu en önemli maliyet, sistemin durma maliyetidir. Şekilde duruş süreleri (toplam 1419dk.) arıza nedenlerine göre verilmiştir. Dolayısıyla, akıllı bakım stratejileri ile öncelikli olarak bu duruş maliyetinin azaltılması hedeflenmektedir. Geçmiş bakım kayıtlarındaki bakım talebi, yapılan işin açıklaması, arızanın nedeni ve çözümü incelenerek arızalar; *bıçak*, *elektrik*, *rezistans*, *sensör*, *zincir*, *silindir*, *mekanik* olmak üzere 7 temel sınıfa ayrılmıştır. Pareto analizine göre *bıçak*, *elektrik* ve *rezistans* arızaları önlenemediği takdirde toplam duruşların %63,8'i ortadan kalkacaktır. Bakım yapma şekline göre bu 7 arıza, *mekanik bakım* ve *elektrik bakım* olarak iki temel gruba ayrılmaktadır. Şekil 3'de koyu renkli grup elektrik bakım ile giderilebilecek arızaları, açık renkli grup ise mekanik bakım ile giderilebilecek arızaları göstermektedir.



Şekil 3. Arıza nedenlerine göre Pareto grafiği ve duruş süreleri

Önleyici bakım stratejisine göre, mekanik bakım periyodu ve elektrik bakım periyodu Weibull analizi yapılarak belirlenmiştir. Elektrik kaynaklı arızalar duruşların önemli bir kısmını ihtiva ettiğinden her elektrik arızası için Weibull analizi yapılmış ve sonuçlar Ekler bölümünde yer alan Şekil A1-A4'te verilmiştir. Buna göre Weibull dağılımının Anderson Darling istatistik testi daha iyi sonuç verdiği için ortalama bakım periyodunun bıçak, elektrik, sensör ve rezistans için ortalama 90 gün olduğu belirlenmiştir. Dolayısıyla ortalama 90 günde bir elektrik bakımının yapılması makul olacaktır. Mekanik kaynaklı arızalar (zincir, silindir ve mekanik) ise sayıları az olduğu için birleştirilmiş ve Weibull analizi yapılmıştır. Sonuçlar Şekil A5'te verilmiştir. Buna göre ortalama 70 günde bir mekanik bakımın yapılması makuldür. Ancak bu önleyici bakım faaliyeti giriş bölümünde açıklanan sebeplerden dolayı yeterli olmayacağı için kestirimci bakım faaliyetleri ile desteklenmelidir.

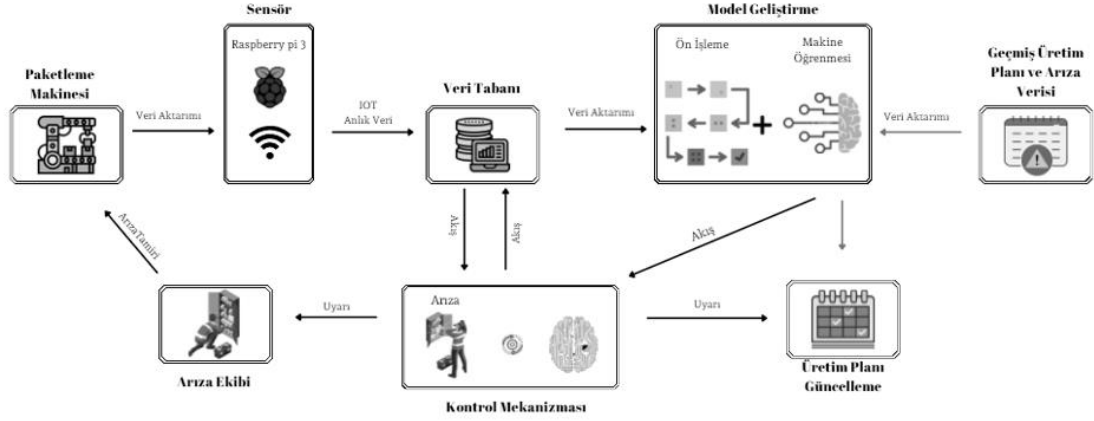
Makinelere ait sıcaklık, titreşim, yağ kalitesi, gürültü, basınç, güç, açılmal hız, akım gibi ölçütler kablolu/kablosuz veri aktarma özelliğine sahip sensörler yardımıyla toplanıp IoT ile veri tabanına aktarılabilir (Koçer, 2017). Bu çalışmada, paketlenme makinesinin IoT ile takip edilecek bölümü literatür incelemesi ve uzman görüşü alınarak belirlenmiştir. Buna göre motor redüktörü alt-sistemine sıcaklık, nem ve ses sensörleri yerleştirilmiş (Şekil 4) ve IoT yardımıyla 2 saniyelik periyotlarla veri toplanmıştır.



Şekil 4. Sensörlerin yerleştirildiği konum

4. YÖNTEM

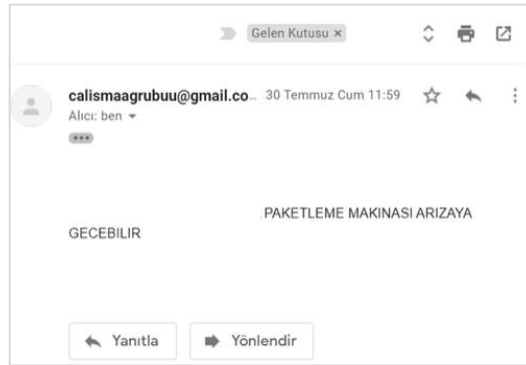
Çalışmada geliştirilen bakım karar destek sistemi temel olarak, geçmiş/anlık verilerin toplanması, sistemin durumunun tahminlemesi, sonucun karar destek sisteminde değerlendirilmesi ve bakım ekibine sonucun bildirilmesi olmak üzere dört temel aşamadan oluşmaktadır. Endüstri 4.0 uyumlu bu kestirimci bakım sisteminin şematik gösterimi Şekil 5'de verilmiştir. Sistemin bu şekilde tasarlanmasının en önemli sebebi, anlık verinin dijital teknolojiler ile toplanması, üretim planlama ve geçmiş arıza verileri ile birleştirilerek analiz edilebilmesidir.



Şekil 5. Paketleme makinesi için Endüstri 4.0 uyumlu, düşük maliyetli bir bakım karar destek sisteminin şematik diyagramı

Şekil 5'e göre ilk olarak paketleme makinesinin "geçmiş üretim planı" ve "geçmiş arıza verisi" Model Geliştirme bölümüne aktarılmaktadır. Burada sıralı örüntü madenciliği yöntemleri kullanılarak analiz edilmekte ve arızaya etkisi olan sakıncalı örüntüler belirlenmektedir. Tespit edilen sakıncalı örüntüler üretim planlama departmanına iletilmektedir. Sakıncalı örüntülerin güncellenmesi işlemi belirli periyotlarda (örneğin 6-12 aylık) yapılabilir. Sürekli olarak bir güncelleme yapılmamasının sebebi; arıza oluşmadığında yeni bir örüntü oluşmayacaktır.

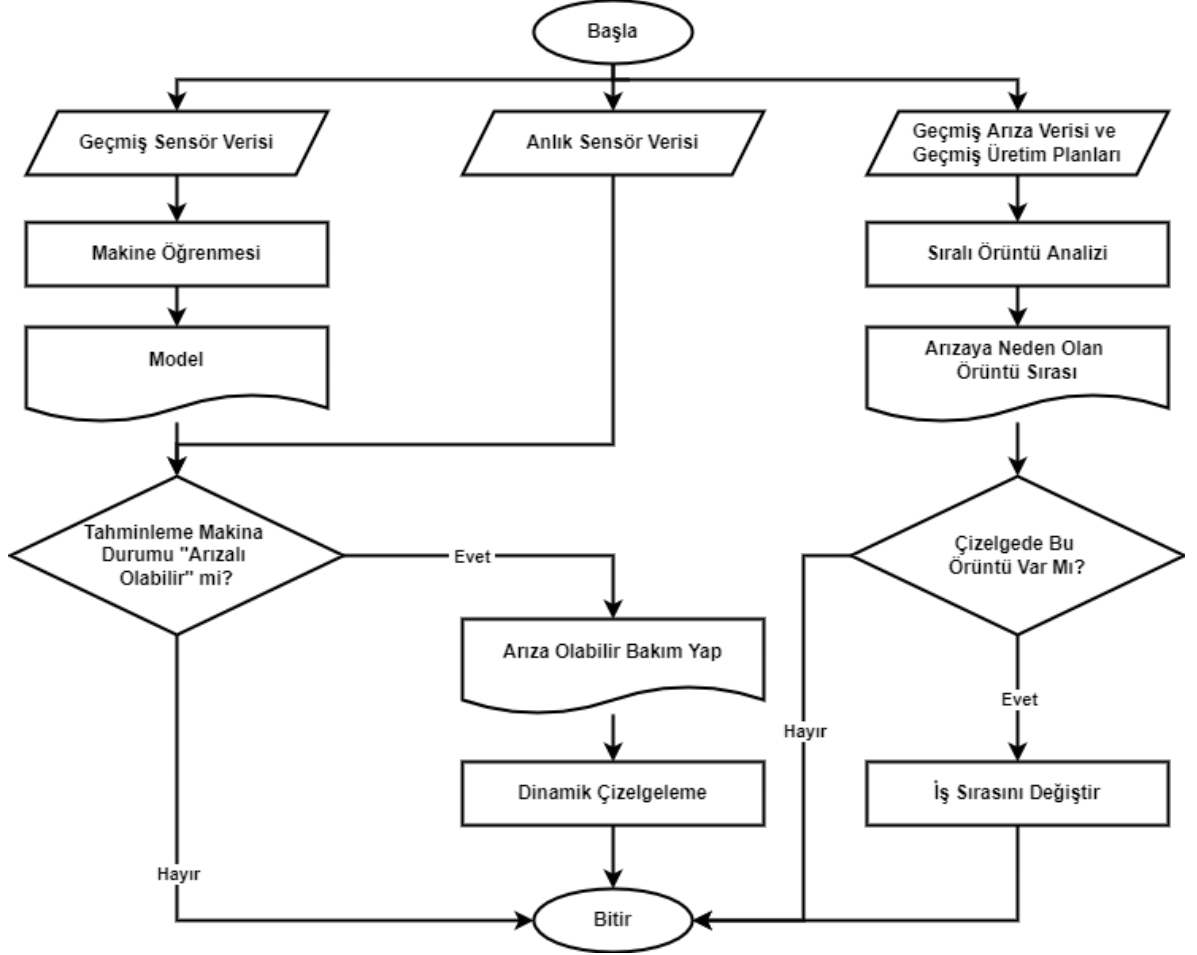
Paketleme makinesinin motor redüktörüne yerleştirilen sensörlerden alınan anlık sistem verileri de IoT aracılığı ile veri tabanına aktarılmaktadır. Veri tabanından eğitim amaçlı alınan verilere sınıflandırma algoritması uygulanmıştır. Ön işleme yapılmış veri, makine öğrenme algoritmasına girdi olarak verilmiş ve model oluşmuştur. Oluşan modele göre artık her 2sn.'de bir gelen veriye bakılarak makinenin durumu tahmin edilmektedir. Makine durumu "arıza olabilir" olarak tahmin edilirse bakım ekibi ve planlama departmanına e-posta gönderilmektedir (Şekil 6).



Şekil 6. Bakım karar destek sisteminden gönderilen otomatik uyarı e-posta örneği

Şekil 7'de ise yukarıda anlatılan bu sistemin akış şeması sunulmuştur. Bu şemanın temel girdileri "geçmiş sensör verileri", "anlık sensör verileri" ve "geçmiş arıza bakım verisi ve geçmiş üretim planları"dır. Geçmiş sensör verileri ön işleme yapılarak, daha sonraki bölümlerde detayları açıklanacak olan makine öğrenmesi (destek vektör makineleri (SVM) ve karar ağacı (DT)) algoritmalarının eğitimi (model oluşturması) için kullanılmaktadır. Elde edilen model ve anlık sensör verileri kullanılarak sistemin durumu tahmin edilmektedir. Eğer sistem durumu "arıza olabilir" olarak tahmin edilirse acil bakım planı oluşturulmakta ve üretim çizelgesine yerleştirilmektedir. Bunun için dinamik çizelgeleme yaklaşımı

kullanılmaktadır. Bir diğer önemli konu ise Paketleme makinesinde arızaya sebep olabilecek bir ürün sırası örüntüsünün tespit edilmesidir. Bu amaçla geçmiş arıza verisi ve geçmiş üretim planları birleştirilerek sıralı örüntü madenciliği (SPADE) algoritmasına girdi olarak verilmektedir. Elde edilen sakıncalı örüntüler üretim planlama bölümüne bildirilmektedir ve onların proaktif olarak bu örüntüler oluşmayacak şekilde planlama yapması sağlanmaktadır.



Şekil 7. Bakım karar destek sistemi akış şeması

4.1. Sıralı Örüntü Madenciliği

Veri madenciliğinin alt konularından birisi olan sıralı örüntü madenciliği (sequential pattern mining), veri yığınları içerisinde düzenli bir biçimde birbirlerini takip eden ilginç bağlantıları keşfetmekte kullanılır. Sıralı örüntü madenciliğinin gerçek hayatta, market sepet analizi, metin madenciliği, doğal afet analizi, web sitesindeki gezinme loglarının analizi, DNA ve protein sarmallarının analizi gibi birçok alanda uygulamaları mevcuttur (Fournier-Vier ve diğerleri, 2017).

Çalışmada incelediğimiz makineye giren ürünler, üretim planına/çizelgesine bağlı olarak belirli bir sıraya göre geldikleri için sıralı örüntüler oluşturmaktadır. Örneğin; sisteme bir saat içerisinde, önce 1. tipte, belirli bir zaman sonra 5. tipte ve daha sonra 3. tipte bir ürün girmesi ({1}, {5}, {3}) sıralı örüntüsünü oluşturur. Bu örüntü bir arızaya sebep olmuş olabilir. Bu çalışmanın bir ayağı bu örüntüyü keşfetmek ve planlama bölümünün bu örüntü konusunda dikkatli olunması gerektiği hakkında bilgilendirmektir. Bu örüntüleri keşfedebilmek için arızanın meydana geldiği andan (olay zamanı) önceki 1, 2 ve 4 saatlik zaman dilimlerini ele alarak ve bu zaman dilimlerini de 15, 30 ve 60 dakikalık periyotlara bölerek analiz edilmiştir. Ek olarak, arızadan önce sisteme giren son 30 ürünü alarak da incelemeler yapılmıştır.

Paketleme makinesine giriş yapan ürün ve giriş saatlerinden oluşan (2020 yılı ilk 6 ayına ait üretim planı ve 50 duruş kaydı) verimiz içerisinden yukarıda bahsettiğimiz zaman dilimleri ve son 30 ürünü içeren kısımlar çekilmiştir. Çekilen bu verilere önışleme yapıp sıralı veri tabanlarına dönüştürülmüştür. Tablo 1, bir sıralı veri tabanı örneğini göstermektedir. Örneğin; 1 numaralı duruş için son 1 saatlik verinin ilk 15 dakikalık periyodunda 38 ve sonra 32 nolu ürünler paketlenmiştir. İkinci 15 dakikalık periyotta ise sırasıyla 19, 43 ve 19 nolu ürünler paketlenmiştir. Dördüncü periyodun sonunda 22 nolu ürün

paketlendikten sonra duruş meydana gelmiştir. 3 numaralı duruş verisinde ise bazı periyotlarda üretim yoktur. Bu çalışmada, duruşlar öncesinde sıklıkla gözlenen ürün sıraları tespit edilerek bu örüntüler konusunda üretim planlama bölümü bilgilendirilmiş ve ürün sıralamasının değiştirilmesi sağlanmıştır.

Tablo 1. Sıralı veri tabanı örneği


Duruş No	Son bir saatte paketlenen ürünler
1	[(38 32) (19 43 19) (38 38) (22 22 22)]
2	[(53 53) (53 53 32) (53 32) 53]
3	[22 (58 53 58)]
4	[(53 58) (58 48 58 53 58)]

Sıralı örüntü madenciliğinde PrefixSpan (Pei ve diğerleri, 2004), SPADE (Zaki, 2001), GSP (Srikant ve Agrawal, 1996), CloSpan (Yan ve diğerleri, 2003) gibi algoritmalar kullanılmaktadır. Python programlama dili ve SPMF kütüphanesi kullanılarak bu algoritmaların uygulanması mümkündür. Bu çalışmada belirtilen algoritmalar ile veri üzerinde denemeler yapılmıştır. SPADE algoritması daha fazla ve farklı örüntüler keşfedebildiği için tercih edilmiştir.

4.2. Devre Kurulumu ve Veri Toplanması

Pilot çalışmanın yapıldığı paketleme makinesinin hangi bileşenleri üzerinde kestirimci bakım uygulanacağına ve ne tip sensörler kullanılması gerektiğine literatür incelemesi (Zonta ve diğerleri, 2020) ve uzman görüşü yardımıyla karar verilmiştir.

Raspberry Pi 3 Model B; düşük maliyetli, küçük boyutlu, üçüncü nesil tek kartlı bir bilgisayardır. Verinin iletimi, toplanması, işlenmesi ve bağlantı çeşitliliği sunmak için kullanılır (Sezer ve diğerleri, 2018). Günümüzde kullanılan bilgisayarlara kıyasla daha az enerji harcaması ve paketleme makinesi üzerine yerleştirilmesi ergonomik olduğu için tercih edilmiştir. Raspberry Pi 3 Model B için tercih edilen eklenti kartı (Grove Base Hat) üzerine seeed grove ses sensörü ve seeed grove sıcaklık ve nem sensörleri yerleştirilerek veri toplama işlemi yapılmıştır. Bu sensörlere erişim sağlamak ve sensörlerin konfigürasyonunu gerçekleştirmek için Python programlama dili kullanılmıştır.



Şekil 8. Devre şeması

IoT, uzaktan alınan sensör verilerinin doğru izlenmesini ve gerçek zamanlı olarak toplanmasını sağlar. Sensörlerden gelen sıcaklık, nem ve ses anlık verilerini toplamak için IP adresi üzerinden Raspberry Pi ile bilgisayar arasında hızlı ve kolay bağlantı sağlanmaktadır. Bilgisayar ve Raspberry Pi sürekli iletişim kurarak SQL (Yapılandırılmış Sorgu Dili) veri tabanına verilerin IoT ile aktarımı ve depolanma işlemi sağlanmıştır.

4.3. Makine Öğrenmesi Tekniklerinin Uygulanması

Paketleme makinesinin motor redüktöründen 1 Haziran itibarıyla toplanan sensör verileri SQL'de başarılı bir şekilde depolanmaya başlanmıştır. Veri tabanında toplam 106430 adet kayıt mevcuttur. Toplanan veri setinden örnek Tablo 2'de verilmiştir. Son verinin alındığı tarihe kadar makinede herhangi

bir arıza oluşmamıştır. Weibull analizi sonuçlarına göre ilk arızayı yakalayabilmek için 90 günlük veriye ihtiyaç olduğu düşünülmektedir ancak veritabanında 20 günlük veri mevcuttur. Bu sebeple analizlerin yapılabilmesi için makine durumu hakkında tahminde bulunarak ilerlenmiştir. Bunun için sıcaklık, ses ve nem seviyelerinin maksimum ve minimum seviyeleri gözlemlenmiş ve uç noktalar “arıza olabilir” olarak varsayılmıştır. Bu şekilde 94 adet “arıza olabilir” durumu tespit edilmiş ve makine öğrenmesi modelinin oluşturulması için girdi olarak kullanılmıştır. Tablo 2’de sıcaklık, nem ve ses sütunları öznitelik iken makine durumu sınıf niteliğidir.

Tablo 2. Sensörlerden elde edilen veri örnekleri

Sıcaklık	Nem	Ses	Tarih/Saat	Makine Durumu
27	32	999	01.06.2021 15:46	Arıza Olabilir
22	28	988	03.06.2021 11:11	Sağlam
24	46	471	01.06.2021 08:18	Sağlam
22	34	999	02.06.2021 20:00	Arıza Olabilir
24	45	534	01.06.2021 09:26	Sağlam
24	26	999	09.06.2021 15:13	Arıza Olabilir
27	19	500	21.06.2021 18:06	Sağlam
24	22	614	14.06.2021 13:56	Sağlam
21	46	999	01.06.2021 20:28	Arıza Olabilir
23	23	238	02.06.2021 09:36	Arıza Olabilir

Sınıflandırma problemlerinde sıklıkla kullanılan DT (Breiman ve diğerleri, 1984; Quinlan, 1993) ve SVM (Boser ve diğerleri 1992; Cortes ve Vapnik, 1995) makine öğrenmesi teknikleri, binary (“arızalı olabilir”, “sağlam” sınıfları) sınıflandırmada ve sayısal niteliklerde başarılı olduğundan dolayı tercih edilmiştir. DT, tek (kök) bir düğümden başlanarak her dalında özniteliklere göre karar kuralları içermektedir ve bu kararlara göre oluşan yapraklarda bir sonuç (sınıf etiketi) vermeyi hedefler. Bir örnek, öznitelik değerlerine göre hangi düğüme ulaşıyorsa o düğümün etiketini almaktadır (sınıf tahmini yapılmaktadır). SVM ise sınıflandırmayı doğrusal ya da doğrusal olmayan bir fonksiyon yardımıyla yerine getirir ve veriyi birbirinden ayırmak için en uygun fonksiyonun tahmin edilmesi esasına dayanır. Bu fonksiyon aynı zamanda her sınıfın destek noktaları arasında da maksimum marjini sağlayan fonksiyondur. İki sınıflı sınıflandırma problemleri için oldukça başarılıdır. Farklı kernel fonksiyonları ile çalıştırmak da mümkündür.

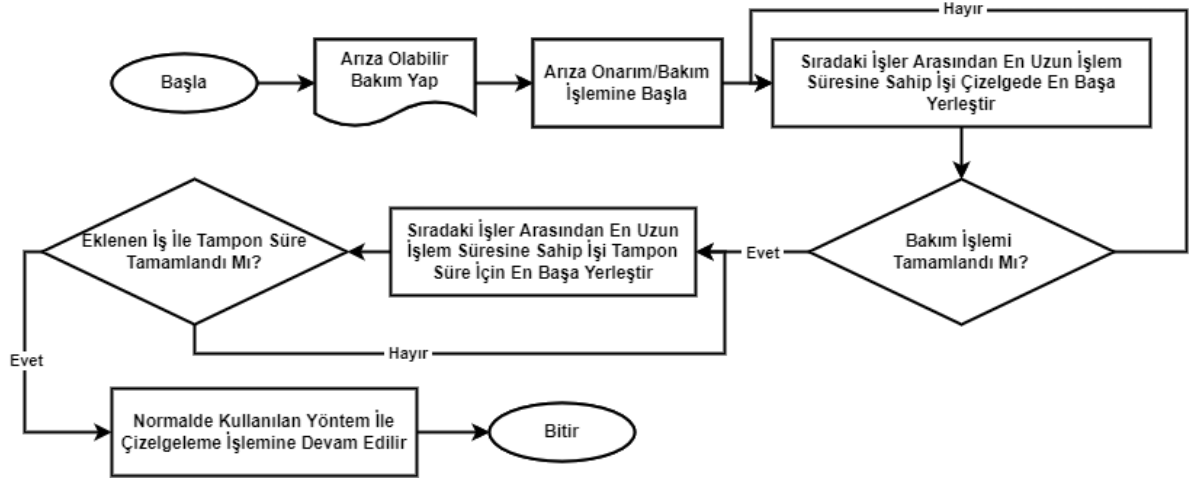
Python programlama dili ve scikit-learn kütüphanesi kullanılarak bu algoritmaların uygulanması yapılmıştır.

4.4. Dinamik Çizelgeleme İçin Önerilen Yaklaşım

Üretim çizelgesi hazırlanırken makinenin beklenmedik bir duruş yaşayabileceği genelde gözardı edilmektedir. Fakat uygulamada; beklenmedik makine arızaları, ani bakım kararları gibi belirsizliklerden dolayı üretim çizelgesinde aksamalar meydana gelebilmektedir. Bu aksamalardan dolayı oluşacak üretim duruşlarını en küçükleme için *dinamik yeniden çizelgeleme* yöntemleri kullanılmaktadır.

Bu çalışmada amacımız, önceki bölümlerde anlatılan prosedüre göre tahminlenen bakım faaliyetinin gerçekleştirilmesi için dinamik çizelgeleme metodolojisiyle entegre bir yaklaşım önermektir. Bunun için mevcut talepleri karşılamaya devam edecek şekilde “çizelgede boşluklar açılması” ve/veya “iş sıralamasını değiştiren” bir yaklaşım sunulmaktadır.

Şekil 9’da önerilen dinamik çizelgeleme prosedürünün akış şeması verilmiştir. Temel olarak arıza olan makine yeniden çalışana kadar önceki makinelerin yavaşlaması ama durmaması sağlanmaktadır. Bu amaçla çizelge, en uzun işlem süresine sahip iş öncelikli olacak şekilde güncellenmektedir. Böylece en uzun işlem süresine sahip iş ve/veya işlerin önceki makinelerde işlem gördükleri süre zarfında duruş olan makinede arıza onarım işlemi gerçekleştirilecektir. Bu çizelge arızalı makine tekrar hizmete girene kadar ve bir tampon süre geçene kadar yapılacaktır. Tampon süre boyunca da önceki makinelerde uzun işlem süresine sahip işleri yapmaya devam edilmesinin sebebi, arızalı makine açılınca yığılmaların oluşmasını yavaşlatmaktır. Eğer arızalı makine açılır açılmaz normal çizelgeleme prosedürüne geçilirse arızalı makine önünde yığılma fazla olacaktır. Dolayısıyla tampon süre, arızalı makinenin işleri toparlaması için imkân sağlar.




Şekil 9. Dinamik yeniden çizelgeleme akış şeması

İki makineden oluşan bir sistemi örnek olarak ele alırsak; sistemde yapılacak işlemler ve bu işlemlerin ilgili makinelerdeki işlem süreleri Tablo 3'te verilmiştir. M2 arızanın olduğu paketleme makinesini ve M1'de paketleme makinesi öncesindeki üretim hattında bulunan seri makineler topluluğunu göstermek üzere iki grubu ifade etmektedir. Mevcut durumda statik çizelgeleme yaklaşımı kullanılmaktadır. Yani çizelge arıza olabileceği düşünülmeden normal şartlarda hazırlanmıştır ve Gantt şeması Şekil 10'da verilmiştir. Kum saati (⌚) makine boş beklemelerini, ünlem işareti (⚠) ise arızaları göstermektedir.


Tablo 3. Çizelgeleme örneği için işlem süreleri (dk.)

İş	Önceki Makine Topluluğu (M1)	Paketleme Makinesi (M2)
1	13	3
2	2	5
3	1	3
4	4	6
5	7	7




Şekil 10. Normal durum Gantt şeması

Şekil 11'de görüldüğü üzere paketleme makinesinde (M2) 3. dakikada bir arıza meydana gelmiştir ve bu arızanın onarımı 10 dk. sürmüştür. Arıza meydana geldiği anda M2 üzerindeki işler yarım kalmış ancak arızadan sonra çizelgeye kaldığı yerden devam edilmiştir. Arıza süresince M1 üretim hattı da üzerindeki işi bitirip boş beklemiştir.



Şekil 11. Arızalı durum Gantt şeması

Şekil 12'de bakımı da dikkate alarak önerilen dinamik yaklaşıma göre yeniden hazırlanan çizelge verilmiştir. Arızanın başladığı andan itibaren geçici bir süreliğine M1 makinesindeki en uzun işlem süresine sahip iş ve/veya işler başa yerleştirilmiştir. Buna göre mevcut işler arasından en uzun süreye sahip olan 1 numaralı iş seçilerek çizelge güncellenmiştir. En uzun işin çalışılmaya başlaması ile M2'ye ürün akışı yavaşlamıştır. Böylece M2 önünde ürün birikmesi sonucu M1'in durması önlenmiştir ve 13. zaman biriminde arıza giderilmiştir. Ancak bir tampon süre kadar (arıza öncesi işler, 2 ve 3 nolu iş, M2 makinesinde tamamlanana kadar) daha çizelgeye uzun süreli iş, örneğin 5 numaralı iş, seçilerek çalışılmaya devam edilmiştir. 5 numaralı iş de tamamlandıktan sonra, yani 23. zaman biriminden sonra, normal çizelgeleme prosedürüne dönülmektedir.

**Şekil 12. Dinamik olarak yeniden hazırlanan çizelge Gantt şeması**

Tablo 4'de mevcut durumda uygulanan statik çizelge ve önerilen dinamik çizelge örnek üzerinde karşılaştırılmıştır. Arızalı durumda dinamik çizelgeleme uygulandığında makinelerin boş beklemesi azalmıştır. Özellikle M1 makine topluluğunda işler daha önce (27.dk) tamamlanmıştır. Bu da M1'in sonundaki yığılmanın çabuk bertaraf edileceğinin ve bu sebeple M1'in duruş yaşamayacağını göstergesidir. Ayrıca son makinede son iş 2 dakika daha kısa sürede tamamlanmıştır.

Tablo 4. Üç farklı durumun karşılaştırılması

	Statik Çizelge		Dinamik Çizelge
	Normal Durum	Arızalı Durum	Arızalı Durum
Boş Süre (M1)	0	9	0
Boş Süre (M2)	6	3	1
Bekleyen ürünler (Beklediği zaman)	2-4-5 (1+2+1)	2-4-5 (13+14+4)	2-1-4-5 (13+5+1+4)
M1'de son işin tamamlanma zamanı	27	36	27
M2'de son işin tamamlanma zamanı	30	39	37
Makespan	max{27,30}= 30	max{36,39}= 39	max{27,37}= 37

5. BULGULAR

Paketleme makinesinden elde edilen arıza verileri, geçmiş üretim planlama verisi ve sensörlerden gelen veriler kullanılarak önceki bölümlerde açıklanan sıralı örüntü madenciliği ve makine öğrenme teknikleri ile sınıflandırma uygulamaları gerçekleştirilmiştir ve sonuçlar analiz edilmiştir.

5.1. Sıralı Örüntü Madenciliği Algoritma Sonuçları

Paketleme makinesine giriş yapan ürün ve giriş saatlerinden oluşan (2020 yılı ilk 6 ayı ve 50 duruş olan) veriden yukarıda bahsedilen zaman dilimleri ve son 30 ürünü içeren kısımlar çekilmiştir. Python programlama dili ve SPMF kütüphanesi kullanılarak, PrefixSpan, SPADE, GSP, CloSpan algoritmaları %70 destek eşliğinde çalıştırılmıştır.

Sonuçlar incelendiğinde GSP ve CloSpan algoritmaları ikili ürün kombinasyonlarını içeren sıralı örüntü bulamamıştır. PrefixSpan algoritması ise ['53 53 53'] ve ['53 53 53 53'] gibi aynı ürünün aynı periyot (itemset) içerisindeki farklı kombinasyonlarını da içeren birçok örüntü bulmuştur. Fakat bu istediğimiz bir sonuç değildir. SPADE algoritması, duruştan önceki zaman periyotlarında ikili ürün kombinasyonlarını içeren örüntüler bulmuştur. Bu nedenle SPADE algoritması tercih edilmiştir. SPADE algoritmasının sonuçları Tablo 5'te verilmiştir. Tablo 5'e göre duruştan hemen önceki 4 saat içinde yer alan 1'er saatlik periyotlar analiz edildiğinde örneğin; (kalın işaretli örüntülerde) 53 ve 58 nolu ürünlerin birlikte 50 duruşun 39'unda aynı periyotta görüldüğü, bir diğer örüntü de ise 58 nolu ürünün bir periyotta,

53 nolu ürünün ise daha sonraki periyotta 50 duruşun 35'inde gözlemlendiği görülmektedir. Bu örüntüler duruş için bir risk oluşturmaktadır.

Tablo 5. SPADE algoritması tarafından bulunan örüntüler

Son 4 saat 1 saatlik periyotlar		Son 2 saat 30 dk.lık periyotlar		Son 1 saat 15 dk.lık periyotlar		Son 30 ürün	
Örüntü	Destek	Örüntü	Destek	Örüntü	Destek	Örüntü	Destek
['19']	40	['19']	37	['53']	40	['53']	45
['22']	41	['32']	38	['53', '53']	37		
['32']	43	['53']	45				
['38']	35	['53', '53']	40				
['48']	41						
['53']	47						
['58']	42						
['53 58']	39						
['58', '53']	35						
['53', '53']	40						
['48 53']	38						
['32 53']	38						
['32', '53']	35						
['53', '32']	37						
['19 53']	38						

5.2. Makine Öğrenmesi Algoritmaları ile Arıza Tahmini Sonuçları

DT ve SVM algoritmaları Python scikit-learn kütüphanesi ile çalıştırılmıştır. SVM çalıştırılırken Sigmoid fonksiyonu kullanılmıştır. Örneklem sınıflarındaki gözlem sayıları dengesizdir. Ancak özellik sayımız az olduğu için bu algoritmaların performansını etkilememektedir. Dengeyi kurmak için Tablo 6'da farklı örneklem sayıları ile denemeler de yapılmıştır.

Veri seti %75'i eğitim %25'i test verisi olarak ayrılmıştır ve aynı zamanda aşırı öğrenmeyi önlemek ve örnekleme sorunlarını ortadan kaldırmak için 5-katlı çapraz doğrulama (5-CV) tekniği uygulanmıştır.

Tablo 6 sonuçlarına göre DT algoritması hem 5-katlı çapraz doğrulama hem de eğitim verisi %75 oranında bölündüğünde çok yüksek doğruluk oranları vermiştir. Hata matrisinden de anlaşılacağı üzere hata 0'a yakındır. Ancak SVM algoritmasının performansı o kadar da iyi değildir. 5 katlı çapraz doğrulama yüzdesi yüksek olsa da hata matrisine baktığımızda "arıza olabilir" tahminlerinin tamamen yanlış olduğu görülmektedir. Özellikle veri dengesizliği fazla olan denemelerde (ilk üç deneme) bu hata örtülmektedir. Ancak hata matrisi böyle bir hatanın olduğunu ortaya çıkarmaktadır. Buna göre DT sonuçlarını kullanmak daha makuldür.

Tablo 6. DT ve SVM doğruluk sonuçları

Sınıfların örneklem sayısı		Doğruluk Sonucu			
		DT		SVM	
Arıza olabilir	Sağlam	5-CV	Hata matrisi (Test %25)	5-CV	Hata matrisi (Test %25)
94	106336	0.999	$\begin{bmatrix} 26590 & 0 \\ 0 & 18 \end{bmatrix}$	0.999	$\begin{bmatrix} 26588 & 2 \\ 18 & 0 \end{bmatrix}$
94	50000	0.999	$\begin{bmatrix} 12505 & 0 \\ 0 & 19 \end{bmatrix}$	0.997	$\begin{bmatrix} 12501 & 4 \\ 14 & 5 \end{bmatrix}$
94	10000	0.999	$\begin{bmatrix} 2500 & 0 \\ 0 & 24 \end{bmatrix}$	0.99	$\begin{bmatrix} 2500 & 0 \\ 24 & 0 \end{bmatrix}$
94	1000	0.997	$\begin{bmatrix} 251 & 0 \\ 0 & 23 \end{bmatrix}$	0.920	$\begin{bmatrix} 251 & 0 \\ 21 & 2 \end{bmatrix}$
94	100	0.99	$\begin{bmatrix} 28 & 0 \\ 0 & 21 \end{bmatrix}$	0.351	$\begin{bmatrix} 12 & 16 \\ 15 & 6 \end{bmatrix}$

6. SONUÇ ve DEĞERLENDİRME

Bu çalışmada sıralı örüntü madenciliği ve makine öğrenme algoritmaları kullanılarak bakım onarım planlaması için bir karar destek sistemi oluşturulmuştur. Sıralı örüntü madenciliğinde bazı ürün sıralarının arızaya etki edebileceği gösterilmiştir. Sınıflandırma ile sensörlerden alınan veriler sayesinde makinenin durumu "sağlam" veya "arızalı olabilir" olarak tahmin edilmiştir. Algoritmaların performanslarının iyi olduğu gösterilmiştir. Karar destek sistemi makinenin durumunu "arıza olabilir" olarak tahmin ederse sistemden

bir e-posta gitmektedir. Ancak bu bakım kararı statik çizelgelemede üretimi durduracağı için dinamik çizelgeleme kullanılarak sistemin yavaşta olsa çalışması sağlanmıştır. Mevcut duruma göre daha iyi performansı olan bir çizelge elde edilmiştir.

Oluşturulan bakım karar destek sistemi bütünleşik bir sistemdir. Fabrikadaki tüm makineler bu sistemle hızlı ve düşük maliyetli olarak takip edilebilir. Bu sistem sayesinde arızaların meydana gelmeden önce kestirilip makinenin bakıma alınması, beklenmedik duruşların engellenmesi, üretim çizelgesinde meydana gelebilecek beklenmedik gecikmelerin azaltılması ve dolayısıyla üretim kayıplarının azaltılması mümkün olacaktır. Pilot çalışmadan elde edilen verilere göre karar destek sistemi ile toplam 69 adet arıza ve 1419dk. plansız duruş süresinin ortadan kalkması amaçlanmaktadır. Böylece süreç verimliliği artacaktır.

Çalışmanın en önemli kısıtı paketleme makinesinin sadece motor redüktörü alt sisteminin sensörler ile takip edilmesidir. Gelecek çalışmalar için makinenin diğer alt sistemlerinin de sensörlerle takip edilmesi hedeflenmektedir. Hangi alt sistemin arızalanacağını kestirilmesiyle firma sadece gerekli olan yedek parçaların stoğunu tutarak yedek parça stok maliyetini azaltabilir. Ayrıca makineye titreşim, akım ölçer vb. sensörlerin yerleştirilmesi ve daha hassas sensörler kullanılması ile makine öğrenme tekniklerinin daha isabetli tahminler yapması mümkün olacaktır.

Teşekkür


Bu çalışma TÜBİTAK 2209-B Üniversite Öğrencileri Sanayiye Yönelik Araştırma Projeleri Desteği Programı tarafından 2020/1 döneminde desteklenmiştir.

KAYNAKÇA

- Aktürk, M.S. ve Görgülü, E. (1999). "Match-up Scheduling under a Machine Breakdown", *European Journal of Operational Research*, 112(1), 81-97.
- Arena, S., Florian, E., Zennaro, I., Orrù, P.F. ve Sgarbossa, F. (2022). "A Novel Decision Support System for Managing Predictive Maintenance Strategies Based on Machine Learning Approaches", *Safety Science*, 146, 105529.
- Baykasoğlu, A., Madenoğlu, F.S., ve Hamzadayı, A. (2020). "Greedy Randomized Adaptive Search for Dynamic Flexible Job-Shop Scheduling", *Journal of Manufacturing Systems*, 56, 425-451.
- Boser, B.E., Guyon, I.M. ve Vapnik, V.N. (1992). "A Training Algorithm for Optimal Margin Classifiers", *Proceedings of the 5th Annual Workshop on Computational Learning Theory*, 144-152.
- Breiman, L., Friedman, J.H., Olshen, R.A., ve Stone, C.J. (1984). "Classification and Regression Trees", Wadsworth ve Brooks, Cole Statistics/Probability Series.
- Carvalho, T.P., Soares, F.A., Vita, R., Francisco, R.D.P., Basto, J.P. ve Alcalá, S.G. (2019). "A Systematic Literature Review of Machine Learning Methods Applied to Predictive Maintenance", *Computers & Industrial Engineering*, 137, 106024.
- Cortes, C. ve Vapnik, V. (1995). "Support-Vector Networks", *Machine Learning*, 20(3), 273-297.
- Cowling, P. ve Johansson, M. (2002). "Using Real Time Information for Effective Dynamic Scheduling", *European Journal of Operational Research*, 139(2), 230-244.
- Çakır, M., Güvenç, M.A. ve Mıstıkoğlu, S. (2021). "The Experimental Application of Popular Machine Learning Algorithms on Predictive Maintenance and the Design of IoT Based Condition Monitoring System", *Computers & Industrial Engineering*, 151, 106948.
- Çınar, Z.M., Nuhu, A.A., Zeeshan, Q., Korhan, O., Asmael, M. ve Safaei, B. (2020). "Machine Learning in Predictive Maintenance Towards Sustainable Smart Manufacturing in Industry 4.0". *Sustainability*, 12(19), 8211.
- Çolak, M., Çetin, T. ve Atılğan, A. (2017). "Mobilya Endüstrisinde Tamir Bakımın Önemi ve Bir Uygulama", *Akademia Mühendislik ve Fen Bilimleri Dergisi*, 2(3), 60-70.
- Dalzochio, J., Kunst, R., Pignaton, E., Binotto, A., Sanyal, S., Favilla, J. ve Barbosa, J. (2020). "Machine Learning and Reasoning for Predictive Maintenance in Industry 4.0: Current Status and Challenges", *Computers in Industry*, 123, 103298.
- Dangut, M.D., Skaf, Z. ve Jennions, I.K. (2021). "An Integrated Machine Learning Model for Aircraft Components Rare Failure Prognostics with Log-Based Dataset", *ISA Transactions*, 113, 127-139.
- Doğan, A. ve Birant, D. (2021). "Machine Learning and Data Mining in Manufacturing", *Expert Systems with Applications*, 166, 114060.
- Dos Santos, T., Ferreira, F.J., Pires, J.M. ve Damásio, C. (2017). "Stator Winding Short-Circuit Fault Diagnosis in Induction Motors Using Random Forest", *2017 IEEE International Electric Machines and Drives Conference (IEMDC)*, 1-8.
- Eroğlu, A. (1998). "Planlı Bakım Sistemleri İçin Bazı Stokastik Yenileme Modelleri", *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 13(2), 173-184.
- Fang, J. ve Xi, Y. (1997). "A Rolling Horizon Job Shop Rescheduling Strategy in the Dynamic Environment", *The International Journal of Advanced Manufacturing Technology*, 13(3), 227-232.
- Fournier-Viger, P., Lin, J.C.W., Kiran, R.U., Koh, Y.S. ve Thomas, R. (2017). "A Survey of Sequential Pattern Mining", *Data Science and Pattern Recognition*, 1(1), 54-77.
- Kang, Z., Catal, C. ve Tekinerdogan, B. (2020). "Machine Learning Applications in Production Lines: A Systematic Literature Review", *Computers & Industrial Engineering*, 149, 106773.
- Karaduman, G. (2020). "Raylı Sistemlerde Bilgisayarlı Görme ve Nesnelerin İnterneti Kullanılarak Kestirimci Bakım Yöntemlerinin Geliştirilmesi", Doktora Tezi, Fırat Üniversitesi Fen Bilimleri Enstitüsü, Elazığ.
- Koçer, M. (2017). "CNC Kesim Makinesi İçin Mükemmel Olmayan Önleyici Bakım Politikasının Geliştirilmesi ve En İyilenmesi", Yüksek Lisans Tezi, TOBB ETÜ Fen Bilimleri Enstitüsü, Ankara.
- Köksal, M. ve Uzun, A. (2016). "Bakım Planlaması", Seçkin Yayıncılık, Ankara.
- Kulkarni, K., Devi, U., Sirighee, A., Hazra, J. ve Rao, P. (2018). "Predictive Maintenance for Supermarket Refrigeration Systems Using Only Case Temperature Data", *2018 Annual American Control Conference (ACC)*, 4640-4645.
- Lei, Y., Yang, B., Jiang, X., Jia, F., Li, N. ve Nandi, A.K. (2020). "Applications of Machine Learning to Machine Fault Diagnosis: A Review and Roadmap", *Mechanical Systems and Signal Processing*, 138, 106587.


- Li, Z., ve He, Q. (2015). "Prediction of Railcar Remaining Useful Life by Multiple Data Source Fusion", *IEEE Transactions on Intelligent Transportation Systems*, 16(4), 2226-2235.
- Lim, H.W., Kim, Y. ve Kim, M.K. (2017). "Failure Prediction Using Sequential Pattern Mining in the Wire Bonding Process", *IEEE Transactions on Semiconductor Manufacturing*, 30(3), 285-292.
- Liu, Q., Dong, M., Chen, F.F., Lv, W. ve Ye, C. (2019). "Single-Machine-Based Joint Optimization of Predictive Maintenance Planning and Production Scheduling", *Robotics and Computer-Integrated Manufacturing*, 55, 173-182.
- Lu, Y. (2017). "Industry 4.0: A Survey on Technologies, Applications and Open Research Issues", *Journal of Industrial Information Integration*, 6, 1-10.
- Mehta, S.V. ve Uzsoy, R. (1999). "Predictable Scheduling of a Single Machine Subject to Breakdowns", *International Journal of Computer Integrated Manufacturing*, 12(1), 15-38.
- O'donovan, R., Uzsoy, R. ve McKay, K.N. (1999). "Predictable Scheduling of a Single Machine with Breakdowns and Sensitive Jobs", *International Journal of Production Research*, 37(18), 4217-4233.
- Ouelhadj, D. ve Petrovic, S. (2009). "A Survey of Dynamic Scheduling in Manufacturing Systems", *Journal of Scheduling*, 12(4), 417-431.
- Pamuk, N.S. ve Soysal, M. (2018). "Yeni Sanayi Devrimi Endüstri 4.0 Üzerine Bir İnceleme", *Verimlilik Dergisi*, 1, 41-66.
- Pan, E., Liao, W. ve Xi, L. (2012). "A Joint Model of Production Scheduling and Predictive Maintenance for Minimizing Job Tardiness", *The International Journal of Advanced Manufacturing Technology*, 60(9-12), 1049-1061.
- Pei, J., Han, J., Mortazavi-Asl, B., Wang, J., Pinto, H., Chen, Q., Dayal, U. ve Hsu, M.C. (2004). "Mining Sequential Patterns by Pattern-Growth: The Prefixspan Approach", *IEEE Transactions on Knowledge and Data Engineering*, 16(11), 1424-1440.
- Quinlan, J.R. (1993). "C4.5: Programs for Machine Learning", Morgan-Kaufmann, San Francisco.
- Rezig, S., Achour, Z. ve Rezig, N. (2019). "Using Data Mining Methods for Predicting Sequential Maintenance Activities". *Applied Sciences*, 8(11), 2184.
- Sabuncuoğlu, I. ve Bayız, M. (2000). "Analysis of Reactive Scheduling Problems in a Job Shop Environment", *European Journal of Operational Research*, 126(3), 567-586.
- Sezer, E., Romero, D., Guedea, F., Macchi, M. ve Emmanouilidis, C. (2018). "An Industry 4.0-Enabled Low Cost Predictive Maintenance Approach for SMEs", *2018 IEEE International Conference on Engineering, Technology and Innovation (ICE/ITMC)*, 1-8.
- Srikant, R. ve Agrawal, R. (1996). "Mining Sequential Patterns: Generalizations and Performance Improvements", *International Conference on Extending Database Technology*, Springer, Berlin, Heidelberg, 1-17.
- Susto, G.A. Beghi, A. ve De Luca, C. A. (2012). "Predictive Maintenance System for Epitaxy Processes Based on Filtering and Prediction Techniques", *Transactions on Semiconductor Manufacturing*, 25, 638-649.
- Susto, G.A., Schirru, A., Pampuri, S., McLoone, S. ve Beghi, A. (2015). "Machine Learning for Predictive Maintenance: A Multiple Classifier Approach", *IEEE Transactions on Industrial Informatics*, 11, 812-820.
- Uhlmann, E., Pontes, R. P., Geisert, C. ve Hohwieler, E. (2018). "Cluster Identification of Sensor Data for Predictive Maintenance in a Selective Laser Melting Machine Tool", *Procedia Manufacturing*, 24, 60-65.
- Vieira, G.E., Herrmann, J.W. ve Lin, E. (2003). "Rescheduling Manufacturing Systems: A Framework of Strategies, Policies, and Methods", *Journal of Scheduling*, 6(1), 39-62.
- Wuest, T., Weimer, D., Irgens, C. ve Thoben, K.D. (2016). "Machine Learning in Manufacturing: Advantages, Challenges, and Applications", *Production ve Manufacturing Research*, 4(1), 23-45.
- Yan, X., Han, J. ve Afshar, R. (2003). "Clospan: Mining: Closed Sequential Patterns in Large Datasets", *Proceedings of the 2003 SIAM International Conference on Data Mining*, 166-177.
- Zaki, M.J. (2001). "SPADE: An Efficient Algorithm for Mining Frequent Sequences", *Machine Learning*, 42(1), 31-60.
- Zhai, S., Gehring, B. ve Reinhart, G. (2021). "Enabling Predictive Maintenance Integrated Production Scheduling by Operation-Specific Health Prognostics with Generative Deep Learning", *Journal of Manufacturing Systems*, 61, 830-855.
- Zhang, J., Ding, G., Zou, Y., Qin, S. ve Fu, J. (2019). "Review of Job Shop Scheduling Research and Its New Perspectives under Industry 4.0", *Journal of Intelligent Manufacturing*, 30(4), 1809-1830.
- Zonta, T., Da Costa, C.A., Da Rosa Righi, R., De Lima, M.J., Da Trindade, E.S. ve Li, G.P. (2020). "Predictive Maintenance in the Industry 4.0: A Systematic Literature Review", *Computers ve Industrial Engineering*, 106889.

EKLER




Distribution	Mean	Standard Error	95% Normal CI Lower	95% Normal CI Upper
Weibull	64,5883	18,2996	37,0668	112,544
Lognormal	78,5763	35,5807	32,3485	190,867
Exponential	64,9375	16,2344	39,7828	105,998
Normal	64,9375	19,9940	25,7499	104,125

Şekil A1. Elektrik kaynaklı arızalar - bıçak verisi - Weibull analizi sonuçları



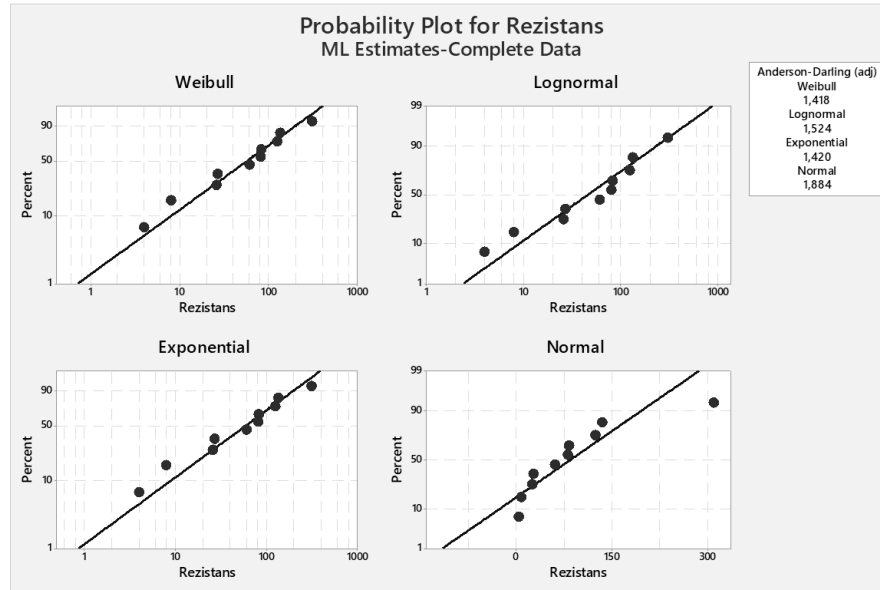
Distribution	Mean	Standard Error	95% Normal CI Lower	95% Normal CI Upper
Weibull	93,138	37,7183	42,1126	205,987
Lognormal	107,521	67,0751	31,6579	365,175
Exponential	94,091	28,3695	52,1076	169,900
Normal	94,091	36,4443	22,6613	165,520

Şekil A2. Elektrik kaynaklı arızalar - elektrik verisi - Weibull analizi sonuçları



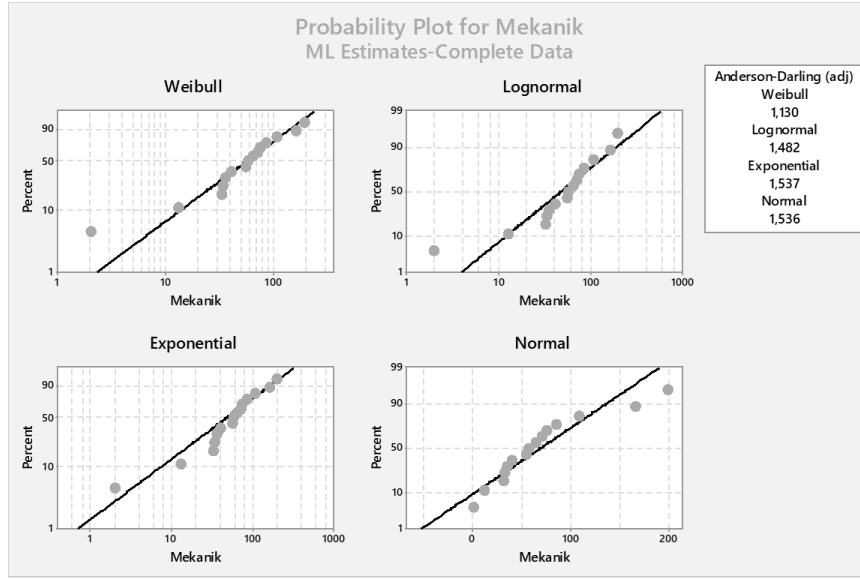
Distribution	Mean	Standard Error	95% Normal CI Lower	95% Normal CI Upper
Weibull	97,134	44,659	39,4477	239,18
Lognormal	212,325	232,618	24,7998	1817,84
Exponential	94,250	33,322	47,1342	188,46
Normal	94,250	30,714	34,0521	154,45

Şekil A3. Elektrik kaynaklı arızalar - sensör verisi - Weibull analizi sonuçları



Distribution	Mean	Standard Error	95% Normal CI Lower	95% Normal CI Upper
Weibull	86,100	28,2328	45,2781	163,726
Lognormal	104,721	56,6848	36,2480	302,541
Exponential	86,100	27,2272	46,3265	160,021
Normal	86,100	27,4034	32,3902	139,810

Şekil A4. Elektrik kaynaklı arızalar - rezistans verisi - Weibull analizi sonuçları



Distribution	Mean	Standard Error	95% Normal CI	
			Lower	Upper
Weibull	69,4639	13,7563	47,1185	102,406
Lognormal	84,9669	29,5540	42,9711	168,005
Exponential	69,7333	18,0051	42,0398	115,670
Normal	69,7333	13,4285	43,4140	96,053

Şekil A5. Mekanik kaynaklı arızalar için Weibull analizi sonuçları