

## DİJİTAL DÖNÜŞÜM SÜREÇLERİNE UYUMLU, SERİ ÜRETİM VERİLERİNİ RAPORLAYAN VE ANALİZ EDEN SİSTEM ÖNERİSİ

**Bora Mocan<sup>a\*</sup>, Deniz Kılınç<sup>b</sup>, Sema Yıldız Yoldaş<sup>a</sup>, İrem Karaşen<sup>a</sup>, Büşra Arslan<sup>a</sup>, Çetin Özdil<sup>c</sup>**

*Ar-Ge Departmanı, AdresGezgini A.Ş., Folkart Towers: B Kule, Bayraklı - 35580 İzmir*

*Yazılım Mühendisliği, Hasan Ferdi Turgutlu Teknoloji Fakültesi, Celal Bayar Üniversitesi Turgutlu – 45400 Manisa*

*<sup>c</sup> İndas Teknoloji Ticaret A.Ş., Muradiye Mah. C.B.Ü. Kampüsü Küme Evleri No:22 Yunusemre - 45140 Manisa*

---

### ABSTRACT

Endüstriyel devrim ile birlikte otomasyona bağlı seri üretim yapan firmalar için makinelerin bakımı ve üretim devamlılığı önemli bir nokta olmakta, plansız duruşlar son derece önemli maliyet kayıplarına yol açmaktadır. Üretim hatlarında performans ölçümü, dijital dönüşüm ile üretimde devamlılık ve rekabet avantajı sağlanabilmesi açısından önem arz etmektedir. Bu çalışma kapsamında, karo parke taşı vb. seri üretim yapan firmalarda makinelerin çalışma süresi, üretim miktarı, enerji tüketimi gibi ana verilerin yanı sıra basınç, sıcaklık, ağırlık, nem, hız, mesafe gibi gerçek anlık süreç verileri okunarak performans durumlarının anlık olarak takip edilmesi ve raporlanması ile birlikte kestirimci bakım yöntemlerinden yararlanılarak performans durum değişikliklerini arıza öncesi tespit edebilecek bir sistem önerilmektedir. Bu sayede plansız duruşların önüne geçilmesi ve üretim hattı fire oranlarının azaltılması mümkün olacak, önemli maliyet avantajları sağlanmış olacaktır.

---

### KEYWORDS

Endüstride Dijital Dönüşüm;  
Kestirimci Bakım; Üretim Raporlama Sistemi, Üretim Verimliliği, Akıllı Üretim Otomasyonu

## **Bölüm I**

### **Dijital dönüşüm**

#### **1. Giriş**

Endüstriyel devrim; akıllı malzemeler, robotlar, akıllı üretim ve akıllı nesnelere ile bunlar arasındaki dijital bağlantıların ön plana çıktığı “Dijital Dönüşüm” çağına giriş olarak tanımlanmaktadır (Tao ve Zhang, 2017; Paravizo ve ark., 2018; Nagata ve Keigo, 2013). Dijital dönüşüm, mevcut küresel rekabet ortamında üretkenliği artırma arayışı, üretim süreçleri için titizlikle tanımlanmış performans ölçüm sistemlerine ihtiyaç duyulmasına neden olmuştur. Dijital çağ ile endüstriyel değişim ve gelişime uyum sağlamak amacıyla özel sektör ve işletmelerin, ileri düzey mühendislik uygulamaları, veri madenciliği, makine öğrenmesi teknikleri, akıllı üretim standartları, anlık ve doğru verilere ulaşma, bu verileri anlamlandırma/depolama, bulut ve akıllı robotlar gibi dijital teknolojik çevreye sahip olmaları gerekmektedir. Endüstriyel Devrimin ana odağı Bilgi Teknolojileri alanındaki yenilikleri kullanan akıllı nesnelere, otonom ürünler ve karar mekanizmaları süreçleridir (Syam ve Sharma, 2018; Diez-Olivan ve ark., 2019). Bulut Teknolojileri alanında yeni bir eğilim olan Bulut Bilişim, geleceğin otomasyon sistemlerini mümkün kılacak bir yapı haline gelecektir. “Cloud Manufacturing” akıllı fabrikaların hayata geçirilmesi için bir iş modeli olarak önerilmektedir. “Cloud Agile Manufacturing” olarak adlandırılan yaklaşım, minimum karmaşıklık ile maksimum otomasyon seviyelerine ulaşmayı hedeflemektedir (Givenchi ve ark., 2013). Bulut teknolojileri, veri paylaşımını çok sayıda kaynak üzerinden sağlarken verimli ve esnek bir şekilde yönetebilmektedir. Bulut tabanlı bir sistem, veri toplanması için teknolojik temeli sağlarken etkili sonuçlar veren ve isteğe bağlı olarak özelleştirilebilir bir açık hizmet platform ortamı oluşturulmasına da olanak tanımaktadır (Wang ve ark., 2017). Bulut bilişim alanındaki gelişmeler, imalat endüstrisini dinamik olarak ölçeklenebilir, talep üzerine hizmet odaklı ve yüksek dağıtılmış maliyet işletme modelini yeniden şekillendirmektedir (Wang, 2013; Venters ve Whitley, 2012). Bununla birlikte, makineler ve süreçlerde güvenilirlik, kullanılabilirlik, uyarlanabilirlik ve güvenlik gibi zorluklar da ortaya çıkmaktadır. Bu gibi zorlukların üstesinden gelmek ve maliyet avantajı sağlamak için arıza teşhisi ve bakım zamanlamasında gelişmiş doğruluk ve güvenilirlik tespiti için kestirimci bakım yöntemlerinin kullanıldığı bir sistem geliştirilmesi önerilmektedir. Bilgiyi zamanında edinme ve paylaşma ile kullanımı mümkün kılmak için sistemin bulut tabanlı olması planlanmaktadır (Liao ve Wang, 2013). Kestirimci bakımın önemi ve bu alanda literatürde yapılan çalışmalar Bölüm II’de detaylandırılmaktadır.

## **Bölüm II**

### **Kestirimci Bakım ve Yapılan Çalışmalar**

#### **2. İlişkili Çalışmalar**

Dijital dönüşüm ile başlayan gelişmeler işletmelerin sadece üretim bölümlerinde değişimlere sebep olmamış, üretimi etkileyen bütün süreçlerin daha verimli, müşterinin isteklerine daha hızlı uyarlanabilir olması gibi hedeflere diğer bölümlerin de uyum sağlamasını zorunlu kılmıştır (Fırat ve Fırat, 2017). Dijital dönüşümden önce de kullanılan, fakat günümüzde hepsinin ortak bir amaç için kullanıldığı Wifi, RFID, sensörler, POS cihazları vb. akıllı sistemler, işletmeler ile ilgili her türlü veri üretim, satın alma, lojistik, pazarlama, satış vb. bölümlerde ayrı ayrı toplanıp depolanmaktadır. Böylece bulut sistemlerde depolanan çok büyük boyutlu verilerin anlamlı bilgiye nasıl dönüştürülebileceği söz konusu haline gelmiştir (Miragliotta ve ark., 2018).

Dijital dönüşümün oluşturduğu potansiyel gelişimin, işletmelerin faaliyet alanlarına göre farklılık gösteren bakım ve iyileştirme süreçlerine uygulanmasının en önemli yollarından biri kestirimci bakım yaklaşımıdır. Kestirimci bakım kavramı, seri imalat yapan fabrikaların içerdiği üretim hattı unsurlarının belirli aralıklar ile ölçümlendiği parametrelerin zaman kırımında değişkenliklerini ve eğimlerini izleme, üretimi etkileyen makine gereklilikleri hakkında süreç için ileriye dönük bir tahminleme yöntemidir (Mobley, 2002). İşletme içerisinde her birimden gelen anlık veriler, sistemin gerçek mekanik durumu ve çalışma verimliliği hakkında bilgi vermektedir. Bu veriler, bakım yöneticisine bakım etkinliklerini zamanlamak ve gereksiz duruşları önlemek için gerçek zamanlı veri sağlamaktadır. Bu verilerin anlamlandırılması ile tesisteki tüm mekanik ekipmanın programlanmamış arızaları üretimin durmasına ya da aksamasına sebebiyet vermeden belirlenerek kestirimci bakım yöntemleri ile sorunlar erken tespit edilebilmekte, bu sayede mekanik arıza modları ciddiyetleri ile doğru orantılı bir hızda düşürülebilmektedir (Liu ve ark., 2019; Yeo ve Grant; 2018).

Dijital dönüşüme geçiş sürecinde seri üretim yapan fabrikaların üretim ihtiyaçlarını kolaylaştırma ve maliyet avantajları sağlama düşüncesi ile kestirimci bakımdan veri madenciliği ve makine öğrenmesi tekniklerine kadar birçok yöntem uygulayarak verimlilik artışına yönelik pek çok çalışma yapılmaktadır. Kestirimci bakım, veri madenciliği, makine öğrenmesi teknikleri kullanılarak dijitalleşme sürecine katkı sağlayan çalışmalardan bazıları; Yaman ve Karadayı (2014) tarafından kestirimci bakım yöntemleri kullanılarak işletme için kritik olan kızgın yağ pompa ekipmanlarının periyodik olarak titreşim ölçümlerini alıp bunların titreşim analizleri incelenmiştir. Ölçüm alınan periyotta meydana gelen durumlar göz önüne alınarak, bazı arızaların birbirini tetikleyebildiği yönünde verilere ulaşılmıştır. Bu arızaların oluşmadan kontrol altında tutulup, yerinde müdahale etmenin önemli olduğu görülmüştür (Denli, 2007). Bir diğer çalışmada, motorun (soyut) mevcut durumunu tahmin etmek için Uzun Kısa Süreli Bellek (LSTM) ağları kullanılarak tahmin işlemi

gerçekleştirilmiştir. LSTM ağlarının eğitim süreci, yüksek performanslı büyük ölçekli veri işleme motoru üzerinde gerçekleştirilmiştir. Tahmin modeline büyük miktarda veri aktığından, dağıtılmış bir kümelenme ortamı sunan “Apache Spark” kullanılmıştır. LSTM ağının çıktısı, bileşenlerin mevcut yaşam koşullarına karar vermek ve ömürlerinin bitiminden önce bileşenlere yönelik uyarıları sunmaktır (Aydın ve Guldamlasıoğlu, 2017). Üretim süreçlerinde, hızlı ve karmaşık tahmin sistemleri için kullanılan makine öğrenmesi teknikleri bakım maliyetlerini önlemeye yönelik olarak kullanılabilir güçlü tekniklerden biridir. Sculley ve ark. (2015) tarafından yapılan çalışma kapsamında makine öğrenmesi uygulama tasarımında göz önünde bulundurulması gereken risk etmenleri (veri bağımlılığı, yapılandırma konuları, dış dünyadaki değişimler gibi) anlatılmaktadır. Önerilen sistemde makine öğrenmesi adımı bu çalışmada anlatılan önemli noktalardan yararlanmayı planlamaktayız. Bir diğer çalışma ise veri madenciliğinin üretimde ürün süreçleri, kontrol ve bakım işlemleri, müşteri ilişkileri yönetimi, kalite iyileştirmesi, hata tespiti ve mühendislik dizaynı alanlarında kullanılabilirliğini ortaya koymuştur. Literatürdeki örneklerden bazıları: Gaz türbinleri pervanelerinin çeşitli denge ve titreşim değerleri karar ağaçları ile analiz edilip sinir ağlarıyla modellenerek aralarındaki ilişkiler tespit edilmiştir. Yarı iletken üretiminde randıman artışı için K-Means algoritması ve Kruskal-Wallis testi yöntemleri kullanılmıştır (Shamila ve Shanmugasundaram, 2012).

Önerilen çalışma kapsamında otomasyona dayalı seri üretim yapan firmalarda (karo, parke taşı, ağırlık beton vb.) tanımlayıcı analiz ve kestirimci bakım teknikleri kullanılarak verimliliği artırmaya yönelik üretim alanında gerçekleşen duruş ve fire oranlarını minimize edecek ve üretim hatlarından elde edilen veriyi anlamlandıran ve ilgili birimlere raporlamalar sunan yönetim/analiz platformu geliştirilmesi hedeflenmektedir. Kestirimci analiz yöntemlerinde başarı oranı, uygulanacak üretim hattında fire oranında iyileştirme, plansız duruşları en aza indirme, yapılacak prototipin haberleşebileceği cihaz marka ve protokol sayısının birden fazla olabilecek düzeyde geliştirilmesi amaçlanmaktadır.

## **Bölüm III**

### **Biz Ne Yapıyoruz?**

#### **3. Önerilen Yöntem ve Sistem**

Otomasyona dayalı seri üretim yapan firmalarda (karo, parke taşı, ağırlık beton vb.) üretimden gelen veriler büyük yer kaplamakta ve depolama sorunlarına neden olmaktadır. Bu çalışmada uygulanacak sistem sayesinde üretimden gelen tüm verilerinin bulutta tutularak yönetilebilir bir sistem kurulması amaçlanmaktadır. Mevcut sistemlerde üretimden veri toplayarak kullanıcılara bu veriler iletilmektedir. Veri toplama aşamasında yetkinlik olarak sorunlar yaşanmakta, veriler kullanıcılar tarafından anlamlandırılmamakta ve analiz edilmesinde süreç uzun olmaktadır. Verilerin anlamlandırılması ve analiz edilmesi süreçlerinde kullanılacak yöntemler 3.1. bölümde açıklanmaktadır.

### 3.1. Önerilen Yöntem

OEE (Overall Equipment Effectiveness - Toplam Ekipman Etkinliği) bir işletmedeki bütün makine ve ekipmanların verimliliğini hesaplayan bir ölçüttür. OEE, farklı üretim kayıplarını ölçen ve süreç iyileştirme alanlarını gösteren bu tür bir performans ölçüm aracı olarak tanımlanmaktadır (Muchiri ve Pintelon, 2008). Arızalar, ekipman ayarları, duruşlar, çalışma hızındaki azalmalar, ıskartalar ve yeniden işlem gibi problemler, OEE değerinin düşmesine sebep olur. Ekipman Etkinlik Oranının %100 olması, hiçbir makine duruşu olmadan, hiç hata yapmadan tam performans ile üretim yapıldığını göstermektedir. OEE hesaplamasında genel olarak 3 önemli değişkeni üzerinde durulmaktadır:

$$OEE [\%] = (KO) \times (PO) \times (KAO) \quad (1)$$

Kullanılabilirlik Oranı (KO) [%]: Ekipmana ait sebeplerden (arıza, ayarlamadan kaynaklanan duruş süresi vs.) kaynaklanan kullanılabilirlik miktarını gösterir.

$$KO = (\text{Çalışma Süresi} / \text{Toplam Süre}) \times 100 \quad (2)$$

$$\text{Çalışma Süresi} = \text{Toplam Süre} - \text{Duruş Süresi} \quad (3)$$

Performans Oranı (PO) [%]: Çalışma hızlarında tasarımıyla belirlenmiş hızlara göre düşüşleri ve birkaç saniyelik duruşları hesap eder.

$$PO = \text{Standart Çevrim Zamanı} * \text{Üretim Miktarı} / \text{Çalışma Süresi} \quad (4)$$

Kalite Oranı (KAO)[%]: Toplam işlenen parçaların ıskarta ve yeniden işlem kayıplarının yüzdesidir.

$$KAO = (\text{Üretilen Sağlam Parça Sayısı} / \text{Toplam Üretim}) \times 100 \quad (5)$$

OEE hesabını etkileyen makine duruşları makine öğrenmesi yaklaşımları ile analiz edilmektedir. Bu çalışmada, makine duruşlarının analizi ve tahmini için Karar Ağaçları, Zaman Serileri Analizi ve Sıralı Örüntü Madenciliği yöntemleri ele alınmaktadır. Kestirimci bakım tekniklerinden Karar Ağaçları ve Yapay Sinir Ağları yöntemleri ile makine öğrenmesi yaklaşımı öngörülmektedir. Yeni geliştirilen sistemde kullanılması öngörülen yöntemler aşağıdaki bölümlerde açıklanmıştır.

### 3.1.1. Makine Duruşları ve Bakım Süreci

Duruş, üretimde makinenin çıktı vermediği yani üretim yapmadığı durumdur ve takip edilmesi gereken önemli bir KPI değeridir. OEE hesabına etkileyen 6 büyük kayıp arasından 2 tanesi duruş ile ilişkilidir; ekipman arızaları ve ayar beklemleri. Üreticilerin duruş sürelerini azaltmak için aldıkları bir takım aksiyonlar/önlemler aşağıdaki gibidir:

Duruş nedenlerinin ve sürelerinin raporlanması ve  
izlenmesi Raporlama ve izleme programlarının kullanılması

Kurulum sürelerini azaltma

Hata yapmaya müsaade etmeyen çalışma düzeni kurulması

Üretim planlarının yeniden gözden geçirilmesi ve duruş raporlarına göre düzenlenmesi

Bakım süreçleri *planlı* ve *plansız* olmak üzere ikiye ayrılır. Plansız bakımlar arıza meydana geldiğinde yapılan çalışmalardır. Planlı bakımlar ise periyodik (koruyucu), önleyici ve uyarıcı (kestirimci) bakımlar olarak üçe ayrılır. Uyarıcı/kestirimci bakımlar için işletmelerdeki makine ve ekipmanlar belirli noktalardan izlemeye alınırlar (titreşim ve sıcaklık sensörleri gibi). Ölçüm sonuçlarının dağılımları incelenerek ekipmanlarda oluşması muhtemel arızalar bu yolla tespit edilebilmektedir.

### 3.1.2. Makine Duruşlarının Makine Öğrenmesi Yaklaşımları ile Analizi

Duruş analizi ve tahmini için Karar Ağaçları, Zaman Serileri Analizi ve Sıralı Örüntü Madenciliği yöntemlerin denenmesi planlanmıştır.

#### 3.1.2.1 Karar Ağaçları

Karar ağaçları, sınıflandırma ve tahmin için sıkça kullanılan veri madenciliği yaklaşımlarından biridir (Çalış ve ark., 2014). Karar ağaçları, diğer sınıflandırma yöntemleri ile karşılaştırıldığında benzer veya daha iyi doğruluk elde etmektedir. Karar ağacı tekniğini kullanarak verinin sınıflanması iki basamaklı bir işlemdir. İlk basamak öğrenme basamağıdır. Karar ağacı öğrenmesi, bir öğeye ilişkin gözlemleri, öğrenin hedef değeri hakkındaki sonuçlara eşleyen öngörücü bir model olarak kullanır (Sharma ve Kumar, 2016). Öğrenme basamağında önceden bilinen bir eğitim verisi, model oluşturmak amacıyla karar ağacı algoritması tarafından analiz edilir. Öğrenilen model karar ağacı olarak gösterilir. İkinci basamak ise sınıflama basamağıdır. Sınıflama basamağında test verisi karar ağacının doğruluğunu belirlemek amacıyla kullanılır. Eğer doğruluk kabul edilebilir oranda ise kurallar yeni verilerin sınıflandırılması amacıyla kullanılır.

Bu çalışmada üretim sırasında hangi olaylar meydana geldiğinde makinelerde duruş gerçekleştiğine dair karar vermeyi sağlayan bir model geliştirilmesinde karar ağaçları kullanılmaktadır.

### 3.1.2.2. Zaman Serileri Analizi

Zaman serisi, zaman içinde art arda alınan bir dizi gözlemdir (Box, 2016). Zaman serisi ham verilerin gün, ay, yıl gibi zaman dilimlerine göre düzenlenmesi ile oluşturulan serilerdir. Zaman serisi analizi ise değişkenlerin bir zaman aralığı üzerindeki değerlerini ve bu değerlerin farklı değişkenler için birbirleriyle karşılaştırılmasına dayanır. Zaman serileri analizinde en önemli amaç, zaman serileri kullanarak değişkenlerin gelecekteki değerlerinin ön görülmesidir. Bunu yapabilmek için serinin belli başlı özelliklerinin ortaya çıkarılması gerekmektedir. Zaman serileri, zamanın ve ona bağlı olarak değişen çeşitli olayların etkisi altında kaldıklarından dört faktörden etkilenirler. Bu faktörler; mevsimlik dalgalanmalar, konjonktürel dalgalanmalar ve düzensiz/tesadüfi hareketlerdir.

Bir zaman serisi verisinden yukarıda belirtilen bileşenlerin ayrıştırılarak her birinin etkisinin incelenmesi zaman serileri analizi olarak ifade edilmektedir. Zaman serileri tüm bu bileşenlere göre ayrıldıktan sonra, bileşenlerin toplamı şeklinde,  $Y_t = T_t + S_t + C_t + I_t$  veya çarpımı şeklinde  $Y_t = T_t \cdot S_t \cdot C_t \cdot I_t$  belli bir  $t$  döneminde  $Y$  zaman serisi ifade edilebilir.

Bu çalışmada zaman serisi analizi ile üretim hattında kullanılan makine ve ekipmana ait zamana bağlı veriler toplanarak, duruşa etkisi olanlar değerlendirilebilir ve bunlar üzerinde yukarıda belirlenen dört faktör analiz edilerek makine ve ekipmanın gelecekte ne zaman ve ne kadar süre sonra durabileceğinin tahmin edilmesinde kullanılması planlanmaktadır.

### 3.1.2.3. Sıralı Örüntü Madenciliği

Sıralı örüntü, sık sık belirli bir düzende meydana gelen bir olaylar kümesidir, aynı kümedeki tüm olayların aynı işlem sürecinde veya bir zaman aralığı içinde olması gerekmektedir. Sıralı örüntü madenciliği ise sıralı olayların oluşumları arasındaki ilişkileri bulmaya, olayların belirli bir sırada olup olmadığını bulmak için kullanılmaktadır (Zhao ve Bhowmick, 2003). Sıralı örüntü madenciliği veri tabanlarında birliktelik analizi yöntemlerine benzer analizler gerçekleştirerek en sık tekrarlanan en uzun örüntülerin bulunması veya geleceğe yönelik çıkarım yapılmasında kullanılmaktadır. Sıralı örüntü madenciliği yöntemlerinin birliktelik kuralları analizinden en önemli farkı, olayların birlikteliğinde öncelik-sonralık durumunun da dikkate alınmasıdır.

Önerilen bu çalışmada, sıralı örüntü madenciliğinin en temel algoritmalarından genelleştirilmiş sıralı model algoritması GSP (Generalized Sequential Pattern) ve eşdeğerlik sınıfları kullanarak sıralı örüntü bulma olarak adlandırılan SPADE (Sequential Pattern Discovery using Equivalence) algoritmaları kullanılması planlanmaktadır. GSP algoritması, sıralı örüntüyü keşfeden bir algoritmadır. Bu algoritma, sıralı örüntü madenciliği için Apriori (önsel) yatay veri formatını kullanırken, SPADE algoritması dikey veri formatı olarak eşlenen sıralı bir veritabanı kullanmaktadır. Böylece her öğeyi gözlem merkezi olarak görerek, ilişkili sıra ve olay tanımlayıcılarını veri setleri olarak alabilmektedir (Qalalwi, 2015). Dolayısıyla çalışma kapsamında bu temel algoritmalar kullanılarak hangi olayların

hangi sıralama ile meydana geldiğinde makinelerde duruş gerçekleşebileceğine dair çıkarım yapmayı sağlayan bir model geliştirilmesi öngörülmektedir.

### *3.1.3. Kestirimci Bakımda Makine Öğrenmesi Yaklaşımları*

Kestirimci bakım gerçekleştirimi için Karar Ağaçları ve Yapay Sinir Ağları yöntemlerin uygulanması planlanmaktadır. Kayan pencereler yaklaşımında öncelikle geçmişte gerçekleşmiş olan arızalar öncesindeki zaman serisi örüntülerinin etiketlenmesi ile bir bilgi tabanı oluşturulacaktır. Bu bilgi tabanı üzerinde Karar Ağaçları algoritmaları kullanılarak arızaların karakteristiğini tespit eden bir model geliştirilecektir. Sonrasında ise sisteme yeni giren, akan verilerden sabit genişlikli kayan pencereler halinde kesitler alınacaktır. Bu kesitler gerçek zamanlı olarak Karar Ağaçlarına verilecek ve bir sonraki veya (n) sonraki adımda makinenin arıza yapıp yapmayacağına karar verilebilecektir. Karar Ağaçlarının başarılı olamaması ihtimaline karşılık bilgi tabanındaki arıza verileri ile Yapay Sinir Ağları eğitilerek, arıza örüntülerinin sınıflandırılması sağlanabilecektir.

### *3.2. Sistem*

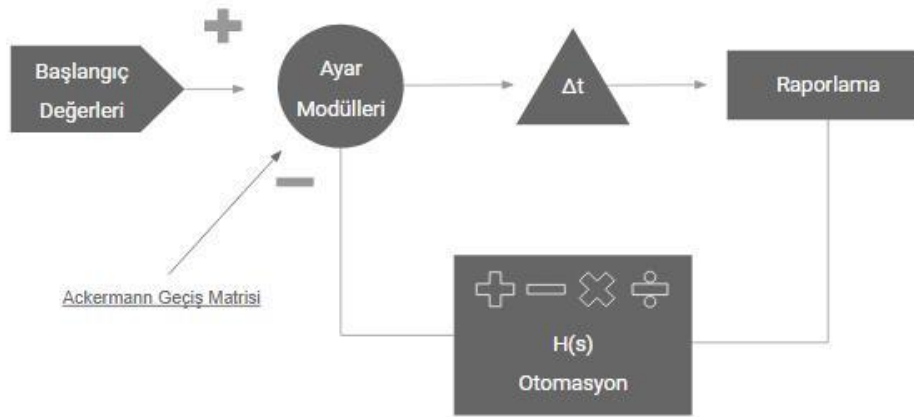
Klasik analiz yöntemleri kullanılarak yapılan veri anlamlandırmaları yanlış sonuçlar üretebilmektedir. Ayrıca, mevcut sistemler, elde edilen verilerin raporlanmasını sağlasa bile farklı markadaki PLC'lerden verilerin farklı protokollerle okunup veritabanına aktarılması firmaların en önemli sorunu haline gelmiştir. Bu durumun yanı sıra bu sistemler, üretim sürecine uygun yazılmadığı için genel raporlama formatları bulunmaktadır. Her bölüme göre esnek ve kullanışlı arayüzleri yoktur. Bu bağlamda, TEYDEB destekli başarı ile tamamlamış olduğumuz proje çıktısının da önerilen sistem kapsamında kullanılması planlanmaktadır. Proje çıktısı sistem sayesinde endüstride sıklıkla kullanılan PLC çeşitleri ve farklı protokoller ile haberleşme sağlanabilecektir. Geliştirilecek sisteminin en önemli avantajları; PLC çeşitleri ile ara yazılımlara gerek kalmadan doğrudan haberleşme sağlanarak sadece enerji, akım, motor, üretim miktarı değil, gerçek anlık süreç bilgilerini (basınç, sıcaklık, bakım süresi vb.) de toplayarak her ekibin kullanabileceği arayüzlerle esnek ve anlaşılabilir raporlama sunabilmesi olacaktır.

Bu çalışmada izlenen ekipmanlardan veri alınarak, duruş gerçekleşmeden gerekli olan bakımın sağlanması için kestirimci bakım yöntemi kullanılması öngörülmektedir. Duruş analizi ve tahmini için Karar Ağaçları, Zaman Serileri Analizi ve Sıralı Örüntü Madenciliği kullanılabilirliği öngörülmektedir. Üretim sırasında meydana gelen hangi olay veya olayların geldiğinde makinelerde duruş gerçekleştiğine dair karar vermeyi sağlayan yapının geliştirilmesinde karar ağaçları kullanılacaktır. Üretim hattında kullanılan makine ve ekipmana ait zamana bağlı elde edilen veriler sayesinde duruşa etkisi olanlar değerlendirilerek bunlar üzerinde zaman serisi analizi yöntemi kullanılarak makine ve ekipmanın gelecekte ne zaman veya ne kadar süre sonra durabileceğinin tahmin edilmesi sağlanacaktır. Makinelerin hangi durumlarda duruş veya bozulma gösterdiğini



belirlenerek ilerleyen süreçlerde aynı durumların oluşması halinde duruşların gerçekleşebileceği öngörülerek, bir bakım planlaması sağlanabilir. Sıralı Örüntü Madenciliği ile olayların sıralamasına bağlı olarak meydana gelen duruş veya bozulmaların analizi ile ilerleyen süreçte hangi ardışık olayların makinelerin duruşuna sebep olabileceği öngörülmektedir.

Sistemin çalışma prensibi Şekil 1’de gösterilmiştir.  $H(s)$  şeklindeki transfer fonksiyonu ile ifade edilen her bir modül diğer transfer fonksiyonlarından bağımsız olarak sistem parametrelerine etki etmektedir. Özyineleme prensibine göre çalışan bu sistemde, matematiksel model olarak Ackermann Geri Besleme metodu ve sistem parametrelerinin güncellenmesi için ayar modülleri oluşturulurken gelişen  $\Delta(t)$  sürede transfer fonksiyonu üzerinden raporlama sunulacaktır.




Şekil 1. Sistem blok diyagramı

Geri besleme modeli ile tespit edilen başlangıç değerlerinin  $\Delta(t)$  süre test edilip katsayılar üzerinden optimizasyon edilecek metrikler, üretim hatlarındaki fire oranları ve plansız duruşlar, işletmeler için üretim verimliliğini dolayısıyla tüm iş akışındaki verimliliği etkilemektedir. Geliştirilecek sistem ile fire oranları ve duruşlardaki kayıpların azaltılması hedeflenmektedir. İşletmelerde kullanılan üretim araçlarından üretim ile ilgili büyük veriyi toplama, depolama, esnek olmama, tek bir kaynakta toplayamama, iyileştirme ve geliştirmeye yönelik analiz edememe, dağınık halde elde fazla veri bulunması ile bu verilerden sağlanan fayda payının düşük olması, fireler ve duruşlar ile ilgili hatalara zamanında müdahale edememe ve yüksek maliyetler, gerçekleştirilmesi planlanan projenin ana problemlerini oluşturmaktadır.

Önerilen sistemle özellikle karo, parke taşı gibi yer döşemeleri ve beyaz eşya sektöründe yoğun kullanılan ağırlık betonu (denge ağırlığı) üretimi yapan otomasyona dayalı firmalarda üretim hatlarında bulunan makine, tezgah, robot vb. üretim araçlarından PLC ve sensörler kullanılarak gerçek anlık süreç bilgileri gibi çok sayıda toplanan veri ile oluşan matris yapısının bir veri tabanına

aktarılması, veri bilimi uygulamaları gerçekleştirilmesi ve verilerin tek bir kanaldan raporlanması hedeflenmektedir.



Şekil 2. Sistem blok diyagramı

Şekil 2.'de sistemin çalışma diyagramı ayrıntılı olarak belirtilmiştir. İhtiyaç duyulan tüm parametrelerin anlık olarak alınabildiği ve işlenerek ilgili değerler ile anlamlandırılmasının belirtildiği bu akış görselinde sistem unsurları da belirtilmektedir. Şekil 2'de görüldüğü gibi fabrika içerisinde çalışan tüm süreç ekiplerinden protokol bağımsız olarak gelen ve büyük veriyi oluşturan anlık değişkenler tek bir bulut sunucusu üzerinde depolanarak sistem özelinde ilgili bölümlere gönderilmektedir. Bu sayede her birim için ayrı raporlama ve değerlendirme sisteminin oluşturulmasına imkan sağlanacak ve zaman kayıpları önlenecektir. Üretim hattı, makine, tezgah, robot vb. cihazlardan elde edilen çalışma süresi, üretim miktarı, enerji tüketimi gibi ana veriler ve ürün başına sıcaklık, basınç, ağırlık, nem, hız, mesafe gibi gerçek anlık süreç verileri alınarak elde edilen büyük veriyi işleyen analiz eden, raporlayan ve yorumlayan sistemden bahsetmek mümkündür ayrıca bu sistem yapılacak optimizasyonlar ile ilgilenen bölümler için özelleştirilmiş verilerin sunulması planlanırken, amaca doğrudan hizmet eden ve aynı zamanda veri kirliliği de yaşanmamasını sağlayan bir raporlama sunulması öngörülmektedir.

## BÖLÜM IV

### 4. Sonuç ve Öneriler

Günümüzde fabrikaların üretim süreçlerinde bakım ya da duruşlar için planlanan stratejilerin uygulanması dışında bu çalışmada belirtilen çeşitli faktörlerin etkisiyle üretimin toplam etkinliğini azaltan senaryolar oluşmaktadır. Mevcut durumda kullanılan sistemler ile veri toplama, analiz etme ve raporlandırma süreçleri firmanın her bir birimi için ayrı ayrı ve firmaya özgü yöntemler ile gerçekleştirilmektedir. Bu durum özellikle büyük tesislerde zaman ve verim kaybına neden olmaktadır. Önerilen projedeki en önemli yenilik, tasarlanacak sistemin tüm süreçler için veri cinsinden bağımsız olarak tek bir platform üzerinden çözüm sunabilecek bir yapıda oluşturulabilmesidir. Bu sistem sayesinde gerçek zamanlı üretim raporları en fazla 1 dakikada alınarak, ek proje veya yazılım bilgisi gerekmeden özelleştirilebilir rapor şablonları oluşturulabilecektir. Büyük verinin anlamlandırılması sürecinde dijital dönüşüm kavramı altında makine öğrenmesi, kestirimci bakım yöntemlerinin kullanılması ve veriler arasındaki ilişkiler açısından bakıldığında ulusal anlamda teknoloji ve ürün yeniliği içermektedir. Önerilen sistem başarı ile tamamlandığında kestirimci analiz yöntemlerinde başarı oranının en az %80 olacağı, uygulanacak üretim hattında fire oranlarında en az %3, plansız duruşlarda ise en az %8 azalma sağlanacağı öngörülmektedir. Ayrıca, otomasyon kullanan tüm işletmeler için uygun altyapı sağlanarak prototipin haberleşebileceği cihaz marka ve protokol sayısı en az 5 olacaktır.

Geliştirilen yaklaşım bir pilot çalışma olarak kabul edilip, uygulanması için tek bir üretim bölümü seçilmiş olup sonrasında işletme geneline ve ilerleyen süreçlerde her işletme genelinde özelleştirilebilir bir versiyona dönüştürülmesi ve bu kapsamda bakım planlamalarında, üretim süreçlerinin iyileştirilmesinde, yalın üretim stratejisi ile ilerleyen fabrikalarda başarılı ile sonuçlanacağı öngörülmektedir.

## REFERANSLAR

- Aydin O., Guldamlasioglu S. (2017). Using LSTM networks to predict engine condition on large scale data processing framework. 2017 4th International Conference on Electrical and Electronic Engineering. 281-285.
- Box G. E. P., Time Series Analysis: Forecasting and Control. Prentice Hall: USA. 2016.
- Çalış A., Kayapınar S., Çetinyokuş T. (2014). Veri Madenciliğinde Karar Ağacı Algoritmaları İle Bilgisayar Ve İnternet Güvenliği Üzerine Bir Uygulama. Journal Of Industrial Engineering. 25; 2-19.
- Denli H. B. Kestirimci Bakım ve Uygulamalarının İyileştirilmesi. Yüksek Lisans Tezi, Mersin Üniversitesi Fen Bilimleri Enstitüsü Makine Mühendisliği Ana Bilim Dalı. Yüksek Lisans Tezi. Mersin (2007).
- Diez-Olivan A., Del Ser J., Galar D., Sierra B. (2019). Data Fusion and Machine Learning for Industrial Prognosis: Trends and Perspectives Towards Industry 4.0. Information Fusion. 50; 92-111.
- Fırat S. Ü., Fırat O. Z. (2017). Sanayi 4.0 Devrimi Üzerine Karşılaştırmalı Bir İnceleme: Kavramlar, Küresel Gelişmeler ve Türkiye. Toprak İşveren Dergisi. 114; 10-23.
- Givenchi O., Trsek H., Jasperneite J. (2013). Cloud Computing for Insudtrial Automation Systems - A Comprehensive Overview. 2013 IEEE 18th Conference on Emerging Technologies & Factory Automation. 1-4.
- Liao W., Wang Y. (2013). Data-driven Machinery Prognostics Approach using in a Predictive Maintenance Model. Journal of Computers. 8(1); 225–231.
- Liu Q., Dong M., Chen F. F., Lv W., Ye C. (2019). Single-Machine-Based Joint Optimization of Predictive Maintenance Planning and Production Scheduling. Robotics and Computer-Integrated Manufacturing. 55; 173-182.
- Miragliotta G., Sianesi A., Convertini E., Distanto R. (2018). Data Driven Management in Industry 4.0: A Method to Measure Data Productivity. IFAC-PapersOnLine, 51; 19-24.
- Mobley P. K. An Introduction to Predictive Maintenance. Butterworth-Heinemann: England; 2002.
- Muchiri P., Pintelon L. (2008). Performance Measurement Using Overall Equipment Effectiveness (OEE): Literature Review and Practical Application Discussion. International Journal of Production Research. 46(13); 3517–3535.
- Nagata F., Watanabe K. (2013) In: Controller Design for Industrial Robots and Machine Tools (Eds), Velocity-based discrete-time control system with intelligent control concepts for openarchitecture industrial robots. Woodhead Publishing: England; 2013
- Paravizo E., Chaim O. C., Braatz D., Muschard B., Rozenfeld H. (2018). Exploring Gamification to Support Manufacturing Education on Industry 4.0 as an Enabler for Innovation and Sustainability. Procedia Manufacturing. 21; 438-445.

- Sculley D., Holt G., Golovin D., Davydov E., Phillips T., Ebner D., Chaudhary V., Young M., Crespo J. F., Dennison D. (2015). Hidden Technical Debt in Machine Learning Systems. *Neural Information Processing Systems*. 2494-2502.
- Sharma H., Kumar S. (2016). A Survey on Decision Tree Algorithms of Classification in Data Mining. *International Journal of Science and Research*. 5; 2094–2097.
- Sharmila V., Shanmugasundaram M. (2012). A Survey of Data Mining Techniques for Quality Improvement in Process Industries. *International Journal of Computer Applications*. 4; 20-22.
- Syam N., Sharma A. (2018). Waiting for a Sales Renaissance in the Fourth Industrial Revolution: Machine Learning and Artificial Intelligence in Sales Research and Practice. *Industrial Marketing Management*. 69; 135-146.
- Tao F., Zhang M. (2017). Digital Twin Shop-Floor: A New Shop-Floor Paradigm Towards Smart Manufacturing. *IEEE Access*. 5; 20418-20427.
- Venters W., Whitley E. A. (2012). A Critical Review of Cloud Computing: Researching Desires and Realities. *Journal of Information Technology*. 27; 179–197.
- Wang J., Zhang L., Duan L., Gao R. X. (2017). A New Paradigm of Cloud-Based Predictive Maintenance for Intelligent Manufacturing. *Journal of Intelligent Manufacturing*. 28; 1125-1137.
- Wang L. (2013). Machine Availability Monitoring and Machining Process Planning Towards Cloud Manufacturing. *CIRP Journal of Manufacturing Science and Technology*. 6; 263-273.
- Yeo B., Grant D. (2018). Predicting Service Industry Performance using Decision Tree Analysis. *International Journal of Information Management*. 38; 288-300.
- Zhao O., Bhowmick S. S. (2003). Sequential Pattern Mining: A Survey. *Communications of The Ais*.