

## Makine Öğrenmesi Algoritmaları ile Detay Üretim Alanları İçin İş Merkezi Kırılımında Üretim Süresi Tahminleme

Tuğçe Yüce\*<sup>1</sup>, Mehmet Kabak<sup>2</sup>

\*<sup>1,2</sup> Gazi Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği, ANKARA

(Alınış / Received: 22.03.2021, Kabul / Accepted: 25.04.2021, Online Yayınlanma / Published Online: 28.04.2021)

### Anahtar Kelimeler

Üretim,  
Üretim Süresi Tahminleme,  
Destek Vektör Regresyonu,  
Gradyan Artırma Makinesi,  
Yapay Sinir Ağı

**Öz:** Günümüz rekabet koşullarında, kısıtlı kaynakları verimli bir şekilde kullanabilmek, geleceğe dönük yatırımları belirleyebilmek için üretim süresi tahmini yapmak rekabet avantajı sağlamak isteyen firmalar için çok önemlidir. Fakat üretim süresi denildiğinde akla gelen zaman etüdü gibi geleneksel yöntemler ürün ve proses çeşitliliğinin çok fazla olduğu tesislerde büyük bir iş yükü gerektirerek zaman ve maliyet kaybına yol açmaktadır. Bu noktada makine öğrenmesi algoritmaları ile üretim süresi tahminleme zaman ve maliyet açısından büyük avantaj sağlamaktadır. Bu çalışmada bir üretim tesisine ait detay üretim alanlarında 4 farklı prosese ait toplam 8 iş merkezine üretim süresi tahminleme için makine öğrenmesi algoritmalarından yapay sinir ağı, destek vektör regresyonu ve gradyan artırma algoritmaları uygulanmış ve her iş merkezi için en iyi sonucu veren algoritma belirlenmiştir. Elde edilen sonuçlara göre, yapay sinir ağı ortalamada %56,02 başarı gösterirken destek vektör regresyonu %84,08, gradyan artırma makinesi ise %85,31 oranında başarı göstermiştir.

## Production Time Estimation In Task Center Refraction For Detail Production Areas With Machine Learning Algorithms

### Keywords

Artificial Neural Network,  
Gradient Boosting Machine,  
Production,  
Production Time Estimation,  
Support Vector Regression

**Abstract:** In today's competitive conditions, estimating production time in order to use limited resources efficiently and to determine future investments is very important for companies that want to gain competitive advantage. However, traditional methods such as time study, require a large workload in facilities with a large product and process variety, resulting in loss of time and cost. At this point, production time estimation with machine learning algorithms provide great advantages in terms of time and cost. In this study, machine learning algorithms, artificial neural network, support vector regression and gradient boosting algorithms were applied to a total of 8 task centers belonging to 4 different processes in the detail production areas of a production facility. The algorithm that gives the best result for each work center was determined. According to the results, artificial neural networks have achieved 56,02% on average, while support vector regression has been 84,08%, and the gradient boosting machine has achieved 85,31%.

\*İlgili Yazar: tyuce93@gmail.com

## 1. Giriş

Üretim süresi veya temin süresi, bir ürünün üretilmesi için gerekli olan hammadde siparişinden ürünün paketlenmesine kadar geçen süre olarak ifade edilebilir. Üretim süresinin doğru belirlenmesi günümüz rekabet koşullarında hem kaynakların etkin kullanılması açısından hem de müşteriye doğru teslim süresi verebilmek açısından üretim ve yönetim kademeleri için önem taşıyan bir konudur. Üretim planlarının hazırlanması, kısa ve uzun vadeli tahminlerin yapılması, ücretlendirme, maliyet kontrolü konuları başta olmak üzere işletme içinde yürütülen tüm faaliyetlerde üretim süresi dikkate alınmadan yapılacak işlerin tutarlı ve yararlı olması mümkün değildir. Teslimat süresini kısa vermek müşteri kazanmayı sağlar ancak genellikle gecikmeyi de beraberinde getirir. Teslimat süresi uzun tutulduğunda ise teslimatın tamamlanması kolay olur fakat bu sefer de müşteri daha kısa teslimat süresi veren firmayı tercih edebilir [1]. Üretim proses sürelerinin doğru tahmin edilememesi ve bu doğrultuda gerçekleştirilen iş planlaması, işletmelerin teslimat tarihinden erken ya da geç olarak işi tamamlamasına, bu sebeple makinelerin boşa kalması ya da teslimatları yetiştirememesi gibi problemleri beraberinde getirmektedir. Bu iki sonuçta da işletmede maddi zarar ortaya çıkabilmektedir [2].

Üretim kaynaklarının etkin kullanılması için gerekli olan çizelgeleme kısa ve orta vadede, kapasite analizleri ise uzun vadede üretim durumunun somut ve matematiksel olarak ortaya konulmasında kullanılan araçlardır. Bu açıdan üretim süresi; çizelgeleme ve kapasite analizleri için temel parametre olmaktadır. Üretim süresi doğruluğuna önem veren ve düzenli olarak güncel tutan şirketler, müşteri termini konularında daha az gecikmeler ile rakiplerinin önüne geçmekte ve tezgah/ekipman ihtiyaçlarını kapasitesel olarak daha düzenli takip edebilmektedirler.

Üretim süresi belirlemede doğrudan hesaplama yöntemleri olarak bilinen zaman etüdü ve iş örnekleme metodları daha kesin sonuçlar vermesine rağmen ürün çeşitliliğinin ve iş merkezlerinin çok fazla olduğu tesislerde büyük bir iş yükü gerektirerek zaman ve maliyet kaybına yol açmaktadır. Dolaysız ölçüm yöntemi olan saptanmış hareket zamanları metodu ise doğrudan ölçüm yöntemlerine göre daha az analiz gerektirmesine rağmen yine üretim çeşitliliğinin çok fazla olduğu üretim tesislerinde büyük iş yükü gerektirdiğinden zaman ve maliyet açısından beklenen kolaylığı sağlayamamaktadır. Bu noktada makine öğrenmesi algoritmaları ile üretim süresi tahminleme zaman ve maliyet açısından büyük avantaj sağlamaktadır.

2000 yılı öncesinde üretim süresi tahminleme çalışmalarında istatistiksel analizler ön plana çıkmaktadır. İstatistiksel analizler sonucunda, istatistiksel modellerin sürecin özelliklerine göre güncellenmesi gerektiği [3] ve doğrusal modellerle sınırlı kaldığı [4] gözlenmiştir.

Makine öğrenmesinin ilk adımları 1950'lerde atılmıştır fakat "Yapay zeka kış uykusu" olarak da adlandırılan dönemde başta donanımsal kısıtlamalar ve diğer problemler sebebi ile bu alandaki çalışmalar durma noktasına gelmiştir. Duraklama dönemi sonrası 2000'lerin başında tekrar gözde olmasıyla beraber üretim süresi tahminleme çalışmaları makine öğrenmesi alanlarında yoğunlaşmıştır [5].

2003 yılında Janakiram ve arkadaşları döngü süresi tahminleme için veri madenciliği yaklaşımı üzerinde çalışarak, veri madenciliğinin istatistiksel verileri hızla yeniden analiz etme yeteneği ve gerektiğinde güncellenebilir olması açısından avantajlı bir yaklaşım olduğunu belirtmişlerdir [6]. Yine 2006 yılında yaptıkları çalışmada kümeleme, en yakın komşu ve regresyon ağacı metodları üzerinde veri madenciliği uygulamaları yaparak sonuçların performanslarını değerlendirmiş ve çalıştıkları veriler üzerinde regresyon ağacının daha başarılı tahminler yaptığını gözlemlemişlerdir [7].

2007 yılında Alenezi ve arkadaşları çok kaynaklı, çok ürünlü sistemlerde gerçek zamanlı akış süresi tahminlemek için makine öğrenmesi algoritmalarından destek vektör regresyonu üzerine yoğunlaşmışlardır. Çalışma sonucunda elde edilen hata oranını klasik zaman serisi modelleri ve yapay sinir ağlarından elde edilen sonuçlar ile karşılaştırarak destek vektör regresyonunun daha az hata oranına sahip olduğunu gözlemlemişlerdir [8]. Destek vektör algoritması ile üretim süresi tahminlemesi yapılan bir diğer çalışma ise Lim ve arkadaşları tarafından 2019 yılında gerçekleştirilmiştir. Çalışmalarında, bir ürünün üretim süresini, üretim ve iş emri verilerini kullanarak destek vektör makine algoritması ile tahminlemeyi amaçlamışlardır. Algoritmanın performansı, rastgele orman ve yapay sinir ağı algoritmaları ile karşılaştırılmıştır ve destek vektör makinesi algoritmasının yeterli sonucu verdiği görülmüştür. Model, %84,62 oranında doğru üretim süresi tahminlerken, fazla mesai tahminlemesini %65'in üzerinde doğrulukla tamamladığı görülmüştür [9].

Meidan ve arkadaşları, 2009 yılında bir yarı iletken üretim tesisinde, döngü süresinin temel faktörlerini tanımlamak ve değerini tahmin etmek için veriye dayalı bir metodoloji üzerine çalışma yapmışlardır. Simüle edilmiş bir fabrikadan bir veri kümesi elde ederek Bayes sınıflandırıcısı uygulamışlardır. Çalışma sonucunda

%72,6 'lık tahmin doğruluğu elde edilmiştir. Sinir ağları ve C5.0 karar ağacı algoritmaları ile de benzer sonuçları elde etmişlerdir [10]. 2011 yılında ise çalışmalarına yeni bir yaklaşım getirmişlerdir. Yeni yaklaşımlarında, önce koşullu karşılıklı bilgi maksimizasyonunu kullanarak en etkili faktörleri belirlemişler ve daha sonra üretim süresi tahmini için seçici Naif Bayes sınıflandırıcısını uygulamışlardır. Çalışma sonucunda üretim süresi tahmini yaklaşık %40 artarken, faktörlerin listesi 182'den 20'ye kadar daralmıştır [11].

Bilekdemir 2010 yılında veri madenciliği yaklaşım metodlarından karar ağacı C4.5 ile sınıflandırma tekniği kullanarak üretim süresi tahminlemeye çalışmıştır, çalışma sonucunda karar ağaçları ile sürekli tipteki değişkenlerin tahmini yapılamamasından dolayı çalışmanın yapay sinir ağları ile geliştirilebileceğini belirtmiştir [1]. 2011 yılında Altın, çok katmanlı yapay sinir ağlarını kullanarak bir döküm ve hammadde işleme üretim tesisinde standart zaman tahminlemesi için 3 model üzerinden çalışmasını yapmıştır; ileri yayımlı öğrenme, dinamik geri yayımlı öğrenme ve moment geri yayımlı öğrenme. Çalışma sonucunda dinamik geri yayımlı öğrenme ve moment geri yayımlı öğrenme modelleri ile başarılı sonuçlar elde etmiştir [2]. Kurnaz ise 2019 yılında yapay sinir ağı modeli oluşturarak kablo takımı üretimi yapan bir firmada ihale için öngörülen üretim sürelerinin tahmin edilebilmesi üzerine çalışmıştır. Akabinde modelin tahmin gücünü ölçebilmek adına sonuçlar, çoklu regresyon modeli ile elde edilen sonuçlar ile karşılaştırılmıştır. Çalışma sonucunda yapay sinir ağları modelinin daha iyi sonuç getirdiğini görülmüştür [12].

Zhang ve arkadaşları 2015 yılında otoyol seyahat süresini analiz etmek için gradyan artırıcı regresyon ağacı yöntemi uygulamışlardır. Uygulanan yöntem başka bir popüler topluluk yöntemi ve bir tezgâh işareti modeli ile karşılaştırılmıştır. Çalışma sonuçları, Gradyan artırma modelinin otoyol seyahat süresi tahmininde önemli avantajlara sahip olduğunu göstermiştir [13]. 2020 yılında Kuo ve arkadaşları hastane acil servislerinde bekleme sürelerini tahminleme amacıyla çoklu doğrusal regresyon, destek vektör makineleri, rassal orman ve gradyan artırma algoritmalarını kullanmışlardır. Doğrusal regresyon modelini baz alarak diğer model sonuçları ile karşılaştırmışlardır. Sonuç olarak kullanılan dört modelde de hata kareleri ortalamasının doğrusal regresyon modeline göre %17-%22 arasında daha iyi sonuç verdiği görülmüştür [14].

Makine öğrenmesi algoritmaları yalnızca süre tahminleme problemlerinde değil farklı sektörlerde farklı tahminleme konularında da ön plana çıkmaktadır. Bunlara örnek verecek olursak; 2014 yılında Var ve arkadaşları, İstanbul'a ait bir bölgenin elektrik puant yükünü yapay sinir ağları yöntemi kullanarak tahmin etmişlerdir [15]. Kartal, 2015 yılında kalp ameliyatı sırasında ya da kalp ameliyatı geçirdikten kısa bir süre sonra hastaya ait hayati riski sınıflandırmaya dayalı makine öğrenmesi teknikleri ile belirleme üzerine çalışmıştır [16]. 2016 yılında Sarı, yapay sinir ağları yöntemi kullanarak traktör firmalarına satılan motor yataklarının yıllık satışlarını tahminlemeyi ve satışları etkileyen faktörleri belirlemeyi amaçlamıştır [17]. Aynı yıl İmamoğlu ve arkadaşları yapmış oldukları çalışmada destek vektör regresyon ve ikiz destek vektör regresyon metotları ile tedarikçilerin kredi endeksini tahmin etmeye çalışmışlardır [18]. 2017 yılında Yang ve arkadaşları, gradyan artırıcı karar ağaçları ile otoyoldaki döngü dedektörleri tarafından toplanan trafik hacmi verilerine dayanarak kısa vadeli trafik tahmini üzerine çalışmışlardır [19]. Sözen ve arkadaşları 2018 yılında yapmış oldukları çalışmada, yapay sinir ağları ve derin öğrenme algoritmalarını farklı nanokompozitlerin çekme testleri sırasında oluşan deformasyonunu tahmin etmek için kullanmışlardır [20].

Bu çalışmada ise, tahminleme üzerine yapılan çalışmalarda yüksek performans gösteren yapay sinir ağları, destek vektör regresyonu ve gradyan artırma algoritmaları üretim süresi tahminlemek üzere kullanılmıştır. Bu çalışmanın özgün yanı üretim süresi veri setinin oldukça büyük olması ve veri seti oluşturulurken parçaların toplam süresi değil, proses bazlı sürelerinin tahmin edilmesi üzerine modellerin kurulmasıdır. Proses bazlı üretim süresi tahminlenmesindeki asıl amaç, farklı proseslerin gerekliliklerini kendi içinde ayrıştırılabilmektir. Teslim süresi bazlı modellerde proses farklılıklarının oluşturabileceği kısıtlar göz ardı ediliyor olacağından, proses bazlı üretim süresi tahminlemede daha gerçekçi ve net tahmin modellerin kurulması öngörülmektedir.

Çalışmanın bundan sonraki bölümleri şu şekilde düzenlenmiştir; Bölüm 2'de çalışmada kullanılan yapay sinir ağları, destek vektör regresyonu ve gradyan artırma teknikleri açıklanmıştır. Modellerin değerlendirilmesi için gereken performans ölçütleri ve veri setine ait özelliklerin belirlenmesi adımları yine bu bölüm içerisinde ele alınmıştır. Bölüm 3 ile uygulama adımları ve sonuçlar paylaşılmış olup Bölüm 4 sonuçların değerlendirilmesi ve elde edilen modellerin geliştirilebileceği alanların tartışmasına ayrılmıştır.

## 2. Materyal ve Metot

Üretim süresi tahminleme modeli oluşturulurken savunma ve havacılık sektöründe faaliyet gösteren bir firmaya ait veriler kullanılmıştır. 4 temel proses olarak talaşlı imalat, sac metal, kalite ve kompozit imalat seçilmiştir. Bu seçilen temel proseslerin her biri için 2'şer iş merkezi üzerinden geçmişe dönük 5 yıllık veri seti kullanılmıştır. Talaşlı imalat iş merkezleri olarak 5 eksen işleme kabiliyetli CNC tezgâhlar, sac metal iş merkezleri olarak sac metal

gerdirme tezgâhlar, kalite iş merkezleri olarak ultrasonik muayene tezgâhları, kompozit imalat olarak hassas frezeleme ile 5 eksenli frezeleme ve su jeti iş merkezleri seçilmiştir. İş merkezleri belirlenirken, uzman görüşlerine ve üretim sürecinde iş yükü dağılımının yüksek olmasına dikkat edilmiştir.

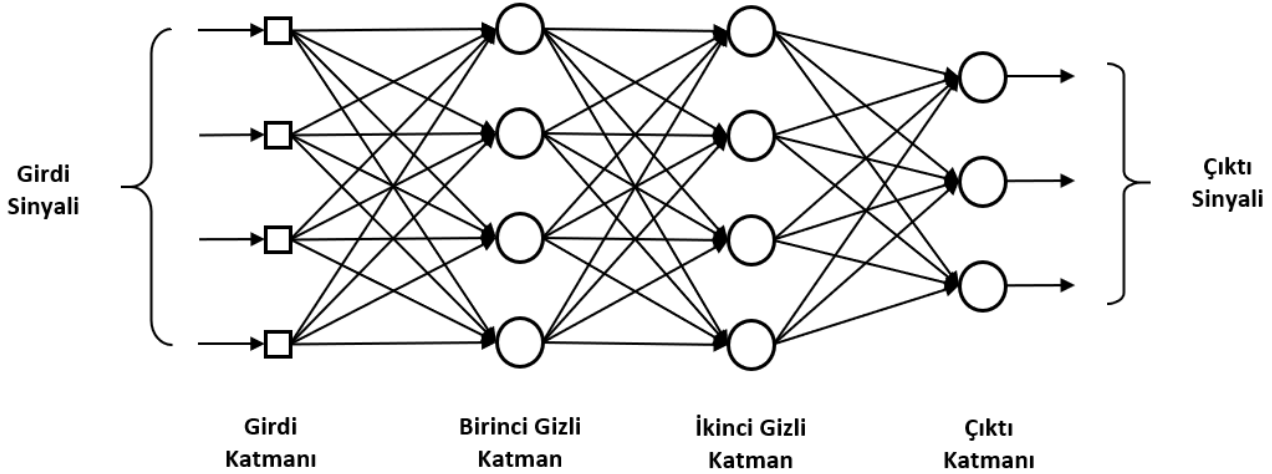
Gradyan artırma, yapay sinir ağları ve destek vektör regresyon algoritmaları kullanılarak, bu algoritmaların farklı kombinasyonları ile toplam 24 adet üretim süresi tahmin modeli oluşturulmuştur. Bölümün devamında gradyan artırma, yapay sinir ağı ve destek vektör regresyonu algoritmaları kısaca açıklanmıştır.

## 2.1. Yapay sinir ağları

Yapay sinir ağları (YSA), insan beyninin çalışma mekanizmasını taklit ederek beynin öğrenme, hatırlama, genelleme yapma yolu ile yeni bilgiler türetebilme gibi temel işlevlerini gerçekleştirmek üzere geliştirilen mantıksal yazılımlardır. Yapay sinir ağları, özellikle arka planda olan veri ilişkisi bilinmediği durumlarda modelleme için güçlü bir araçtır. YSA tıpkı insan gibi öğrenir. Bir yapay sinir ağı öğrenme süreci boyunca örüntü tanıma veya veri sınıflandırması gibi belirli bir uygulama için yapılandırılmıştır. Biyolojik sistemlerde öğrenme, nöronlar arasında var olan sinaptik bağlantılar üzerinde ayarlamalar içerir. YSA için de aynı geçerlidir [21].

Genel olarak YSA ile tahmin, sınıflandırma, veri ilişkilendirme, veri kavramlaştırma ve veri filtreleme fonksiyonlarını gerçekleştirmek mümkündür. Bir problemin çözümü için uygulanacak olan yapay sinir ağı modeli öncelikle problemin türüne bağlıdır. Ancak tahminlemeye yönelik en yaygın kullanılan yapay sinir ağı modeli çok katmanlı algılayıcıdır [22].

Çok katmanlı algılayıcılar; Rumelhart ve arkadaşları tarafından geliştirilmiştir. Geri yayılım algoritması kullanılan çok katmanlı algılayıcıların öğrenme kuralı, en küçük kareler yöntemine dayalı delta öğrenme kuralının geliştirilmiş halidir. Bu nedenle öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denmektedir. Delta kuralına göre bir nöronun istenilen çıktı değeri ile gerçek çıktı değeri arasındaki farkı azaltmak için ağırlıkların sürekli olarak ayarlanması ve geliştirilmesi gerekmektedir [23]. Bu kurala göre öğrenme sırasındaki bağlantı ağırlıkları sürekli değiştirilerek, ağırlıklar için optimum değer bulunur. Bu ağ yapısında “Öğretmenli Öğrenme” yöntemi kullanılır. Bu yöntemde hedef çıktı değerleriyle ilişkilendirilen her bir vektör, ağı öğrenmesi için ağı sunulur. Ağırlıklar, belirtilen öğrenme kuralına göre düzeltilir [24]. Şekil 1’de örnek bir tane çok katmanlı algılayıcı gösterilmiştir.




Şekil 1. Örnek Çok Katmanlı Algılayıcı [25]

Yapay sinir ağlarında bulunan girdi katmanı, ara katmana dış dünyadan gelen girdileri gönderir. Girdi katmanında bilgi işleme olmaz. Bilgiler olduğu gibi bir sonraki katmana gider. Birden fazla girdi olabilir. Her proses elemanının sadece bir tane girdisi ve bir tane çıktısı vardır. Gizli katmanlar, bir sonraki katmana girdi katmanından gelen bilgileri işleyerek gönderir. Çok katmanlı algılayıcılarda birden fazla ara katman ve her katmanda birden fazla proses elemanı olabilir. Çıktı katmanı ise dış dünyaya ara katmandan gelen bilgileri işleyerek ağı girdi katmanından verilen girdilere karşılık ağı ürettiği çıktıları gönderir. Bir çıktı katmanında birden fazla proses elemanı olabilir [21].

## 2.2. Destek vektör regresyonu


Destek Vektör Makineleri, Vapnik tarafından geliştirilen bir öğrenme yöntemi olup regresyon ve sınıflandırma problemleri için kullanılmaktadır [26]. Bu yöntem diğer geleneksel öğrenme yöntemleriyle karşılaştırıldığında doğrusal olmayan problemleri çözmedeki performansı ile öne çıkmaktadır. Destek vektör makineleri genellikle sınıflandırma problemleri için kullanılmakta olup, regresyon için uyarlaması Smola ve arkadaşları tarafından destek vektör regresyonu adı ile ileri sürülmüştür [27]. Destek vektör regresyonunda verilerin lineer olarak ayrılabilir yapıda olması veya lineer olarak ayrılamayan yapıda olması olarak iki durum ile karşılaşılr.

Lineer ayrılabilir durumu; eğitim için kullanılacak N elemandan oluşan verinin  $\theta = \{x_i, y_i\}$ ,  $i = 1, 2, \dots, N$  olduğu varsayılırsa, burada  $y_i \in \{-1, 1\}$  etiket değerleri ve  $x_i \in R^d$  özellikler vektörüdür. Bu iki değerli verilerin direkt olarak bir aşırı düzlem ile ayrılabilirdiği durumlar lineer ayrılabilir durumu olarak değerlendirilmektedir. Bu aşırı düzlem ayırıcı aşırı düzlem adı verilir (Şekil 2). Destek vektör makinelerinde aşırı düzlemin iki örnek gurubuna da eş uzaklıkta olması amaçlanmaktadır. [28].



Şekil 2. Lineer Ayrılabilen Veriler [29]

Lineer ayrılamama durumu; lineer ayrılabilir durumda veriler iki sınıfa doğrusal bir düzlem ile ayrılabilir fakat pratikte bu durum her zaman geçerli olmayabilir (Şekil 3). Yani doğrusal bir düzlem ile veriler birbirinden ayrılamaz [28].



Şekil 3. Lineer Ayrılamayan Veriler [29]

Doğrusal olmayan sınıflandırıcılar, verilerin doğrusal olarak ayrılamadığı durumlarda doğrusal sınıflandırıcı yerine kullanılabilir. Bu durumda Doğrusal Olmayan Özellik Uzayı;  $x_i \in R^n$  gözlem vektörünü daha yüksek dereceden bir uzayda  $z$  vektörüne dönüştürerek, bu yeni uzayda doğrusal sınıflandırıcıları elde etmek söz konusu olabilir. Bu  $z$  vektörünün yer aldığı özellik uzayı  $F$  ile gösterilirse,  $\emptyset$  ifadesi  $R^n \rightarrow R^F$  eşlemesini yapmak üzere  $z = \emptyset(x)$  biçiminde (Eş. 1) ifade edilebilir [30].

$$x \in R^n \rightarrow z(x) = [a_1, \emptyset_1(x), \dots, a_n, \emptyset_n(x)]^T \in R^F \quad (1)$$

Doğrusal olmayan ayrılabilirlik durumu düşünüldüğünde, eğitim örnekleri orijinal giriş uzayında doğrusal olarak ayrılamazlar. Bu gibi durumlarda destek vektör regresyonu, kolayca sınıflandırma yapabileceği yüksek boyutlu nitelik uzayına dönüşüm yapmak için doğrusal olmayan haritalama fonksiyonunu kullanır. Böylece çekirdek fonksiyonları ile bütün değerlerin tekrar hesaplanarak bulunması yerine, doğrudan çekirdek fonksiyonunda değerlerin yerine koyularak nitelik uzayındaki değerlerin bulunması sağlanır. Bu sayede, son derece yüksek boyutlu bir nitelik uzayı ile uğraşma olasılığı kalmaz. Çekirdek fonksiyonlarının diğer bir avantajı da eğitime aşamasında

bir eğitim örneği için fonksiyon kurulup değerler bulduktan sonra artık kalıp değerlerin hazır olmasından dolayı diğer örneklerin çok daha kolay hesaplanmasıdır [29]. Destek vektör regresyonunda yaygın olarak kullanılan dört çekirdek fonksiyonu vardır. Bunlar; doğrusal, polinomial, sigmoid ve radyal tabanlı fonksiyonlardır. Destek vektör regresyonu ile ilgili daha ayrıntılı bilgi literatürde yer almaktadır [26].

### 2.3. Gradyan artırma makinesi

Gradyan artırma algoritmaları ilk olarak makine öğrenimi topluluğu tarafından sınıflandırma problemleri için tanıtılmıştır [31-33]. Temel yaklaşım, gelişmiş tahmin doğruluğuna sahip "güçlü bir öğrenen" elde etmek için "zayıf öğrenenler" adı verilen birkaç basit modeli yinelemeli olarak birleştirmektir. Friedman, artırma algoritmasını kayıp fonksiyonları kavramlarına bağlayarak artırmaya ilişkin istatistiksel bir bakış açısı getirmiştir [34]. Gradyan artırma yöntemi, kayıp fonksiyonunu en aza indiren ek bir model bulmayı amaçlayan sayısal bir optimizasyon algoritması olarak görülebilir. Böylelikle, gradyan artırma algoritması yinelemeli olarak her adımda kayıp işlevini en iyi azaltan yeni bir karar ağacı yani "zayıf öğrenen" ekler. Daha kesin olarak, regresyonda algoritma modeli bir tahminle başlar, bu genellikle kayıp fonksiyonunu en üst düzeyde azaltan bir karar ağacıdır (regresyon için ortalama hata karesidir), ardından her adımda yeni bir karar ağacı mevcut artığa takılır ve artığı güncellemek için önceki modele eklenir. Algoritma, kullanıcı tarafından sağlanan maksimum yineleme sayısına ulaşılan kadar yinelemeye devam eder. Bu süreç, sözde aşamalı olarak adlandırılır. Her yeni adımda, önceki adımlarda modele eklenen karar ağaçları değiştirilmez. Karar ağaçlarının kalıntılara uydurulmasıyla model, iyi performans göstermediği bölgelerde iyileştirilir.

Her yinelemeli adımda eklenen karar ağacı, öğrenme hızı olarak adlandırılan küçülme parametresi  $\alpha$  kullanılarak küçültülürse, gradyan artırma algoritması daha iyi sonuçlara ulaşır. Gradyan artırma bağlamında küçülme prosedürünün arkasındaki fikir, daha yüksek sayıda küçük adımın, daha az sayıda büyük adımdan daha yüksek bir doğruluk sağlamasıdır. Öğrenme parametresi  $\alpha$ , 0 ile 1 arasında bir değer alabilir ve ne kadar küçük olursa, model o kadar doğru olur. Bununla birlikte, daha güçlü bir küçülme (daha küçük  $\alpha$ ) seçmek, yakınsama elde etmek için daha yüksek sayıda yineleme anlamına gelir, çünkü  $\alpha$ 'nın değeri yineleme sayısı ile ters orantılıdır.

Gradyan artırma algoritmasının kestirimsel doğruluğunu artırmanın bir başka yolu ise uyum sürecine randomizasyon eklemektir [35]. Her yinelemeli adımda, tam eğitim veri kümesini kullanmak yerine, karar ağacına uyması için rastgele seçilen (genellikle değiştirilmeden) bir alt örnek kullanılır. Gözlem sayısı yeterince büyük olduğunda, her yinelemede kullanılan verilerin varsayılan oranı genellikle 0,5'e eşittir; bu, her yinelemede veri kümesinin yüzde 50'sinin kullanıldığı anlamına gelir. Gradyan artırma modelin doğruluğu iyileştirmenin yanı sıra, alt örnekleme, algoritmanın hesaplama maliyetini alt örnekleme faktörüne eşdeğer bir faktör kadar azaltmanın yararlı etkisine sahiptir.

### 2.4. Model performans değerlendirme ölçütleri

Yapılan tahminlerin başarısını ölçmek için başarı tahmin oranı, determinasyon katsayısı ( $R^2$ ), hata kareleri ortalaması (Mean Squared Error – MSE), ortalama mutlak hata (Mean Absolute Error –MAE), ortalama mutlak yüzde hata (Mean Absolute Percentage Error – MAPE) yöntemleri kullanılmıştır. Yöntemlere ait denklemler aşağıda verilmiştir.

$$R^2 = 1 - \frac{\sum(Y_i - Y_i^*)^2}{\sum(Y_i - Y_{ave})^2} \quad (2)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - Y_i^*)^2 \quad (3)$$

$$MAE = \frac{\sum_{i=1}^n |Y_i - Y_i^*|}{n} \quad (4)$$

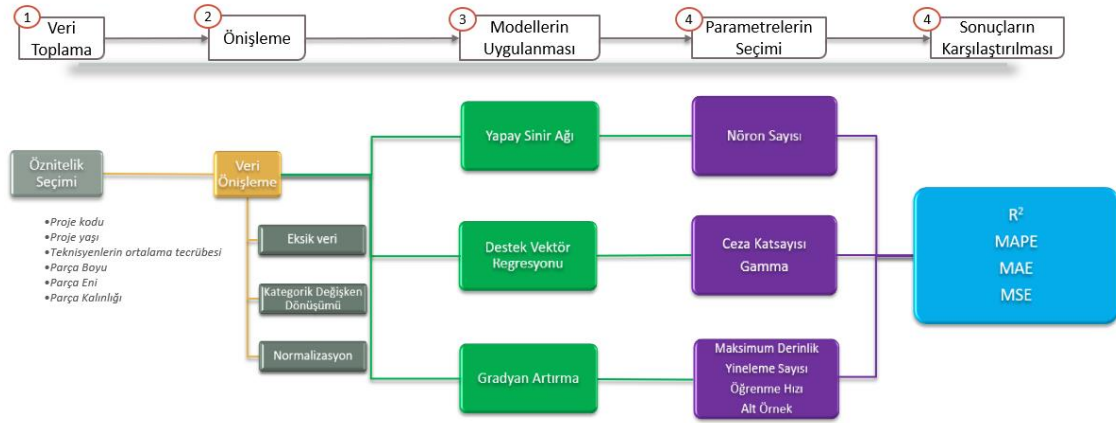
$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_i - Y_i^*}{Y_i} \right|}{n} * 100 \quad (5)$$

Burada  $Y_i$  gözlem değeri,  $Y_i^*$  tahmin edilen değeri,  $Y_{ave}$  gözlem değerlerinin ortalamasını temsil etmektedir.

Yukarıda belirtilen yöntemler arasından üretim süresi tahmin modellerinden başarılı olanı seçmek için MAPE değerleri dikkate alınmıştır. MAPE değeri %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır [36].

## 2.5. Modelde kullanılan veri setinin ve özniteliklerin belirlenmesi

Çalışmada, belirlenen merkezlerinin son 5 yıla ait verileri SQL server ile veri tabanından çekilmiştir. Elde edilen veriler üzerinde uygulanan adımlar öncelikli olarak akış şemasında özetlenmiş olup, bölümün devamında detaylandırılmıştır (Şekil 4).



Şekil 4. Akış Şeması

Öznitelik seçimi için üretim tesisinde montaj üretim alanları, detay üretim alanlarına göre daha düzenli ve tahmin edilebilir bir çalışma ortamına sahiptir. Bu nedenle montaj üretim alanından seçilen iş merkezleri üzerinden literatür ve uzman görüşü ile aday nitelikler belirlenmiştir [1]. Belirlenen aday nitelikler;

- Ship ( projeye ait üretilen kaçınıcı parça olduğu bilgisi)
- Proje yılı
- Proje % bitiş
- Parça üzerinde çalışan teknisyen sayısı
- Teknisyenlerin ortalama tecrübesi

Belirlenen her bir aday parametre ile üretim süreleri arasında korelasyon analizi yapılarak (Tablo 1) üretim süresine etkisi olan parametrelerin belirlenmesi hedeflenmiştir.

Tablo 1. Üretim Süresinin Aday Parametreler ile Korelasyonu

İş Merkezi	Ship	Proje Yılı	Proje % Bitiş	Teknisyen Sayısı	Teknisyenlerin Ortalama Tecrübesi
RD1	-0,51	-0,52	-0,52	0,28	-0,66
RD2	-0,66	-0,67	-0,67	0,12	-0,66

Yapılan analiz sonucunda belirlenen öznitelikler:

- Ship

- Proje yılı
- Proje % Bitiş
- Teknisyenlerin ortalama tecrübesi

Ship, Proje Yılı ve Proje % Bitiş parametreleri birbirleriyle doğrusal ilişkili olduğundan bu 3 parametreden Proje Yılı ile ilerlenmesine karar verilmiştir.

Montaj alanlarına ait veriler ile elde edilen parametrelere ek olarak uzman görüşü yönlendirmesi ile detay üretim alanlarına ait tahminleme çalışmasına aşağıdaki parametreler dahil edilmiştir.

- Proje Kodu
- Parça boyu
- Parça eni
- Parça kalınlığı

### 3. Bulgular

Belirlenen öznitelikler için Şekil 4'te yer alan akış şemasında da belirtildiği gibi veri ön işleme, uygulama, hiperparametrelerin seçimi ve sonuçların karşılaştırılması aşamaları gerçekleştirilmiştir.

#### 3.1. Veri ön işleme

Özniteliklerin belirlenmesinin ardından üretim veri tabanından elde edilen veriler veri ön işleme adımıyla değerlendirilmiştir. Eksik gelen veriler ve aykırı değerler ayıklanmıştır. Veri setinde bulunan kategorik değişkenler ikili (binary) olarak temsil edecek şekilde düzenlenmiştir. Öznitelikler arasındaki ölçek farklılıklarının model tahmin performansını düşürmemesi ve katsayıları yanlış yorumlamaması adına normalleştirme işlemi yapılmıştır. Normalleştirme tekniği olarak Min-Max yöntemi ile tüm veriler [0.1-0.9] arasına indirgenmiştir. Bu işlem nümerik değişken olan girdi değerleri için yapılmıştır. 1-0 olarak dönüştürülen kategorik değişkenler ve çıktı değişkenlerinde değişiklik yapılmamıştır. Veri ön işleme öncesi ve sonrası örnek veri seti Tablo 2 ve Tablo 3'te paylaşılmıştır.

**Tablo 2.** Veri Ön işleme Öncesi Veri Seti Örneği

Proje	Parça No	Proje Yılı	Tecrübe	En	Kalınlık	Boy	Toplam Saat
A1	X1	3,93	2,58	241,30	1,14	444,50	20,50
A1	X1	4,04	2,87	241,30	1,14	444,50	15,50
A1	X1	4,07	1,68	241,30	1,14	444,50	17,75
A1	X1	4,08	0,08	241,30	1,14	444,50	25,00
A1	X1	4,29	2,68	241,30	1,14	444,50	13,00

**Tablo 3.** Veri Ön işleme Sonrası Veri Seti Örneği

Parça No	Proje Yılı	Tecrübe	En	Kalınlık	Boy	Toplam Saat	Proje_A1	Proje_A2	Proje_A3
X1	0,10	0,34	0,90	0,10	0,66	20,50	1	0	0
X1	0,11	0,36	0,90	0,10	0,66	15,50	1	0	0
X1	0,11	0,25	0,90	0,10	0,66	17,75	1	0	0
X1	0,11	0,10	0,90	0,10	0,66	25,00	1	0	0
X1	0,12	0,34	0,90	0,10	0,66	13,00	1	0	0



### 3.2. Modellerin Kurulması Ve Hiperparametrelerin Belirlenmesi

Çalışmada, makine öğrenmesi algoritmalarının kurulmasında Python programından yararlanılmıştır. Bütün iş merkezlerine ait veri setlerinin %75'i eğitim, %25'i test verisi olarak ayrılmıştır. Yapay Sinir ağları, destek vektör regresyonu ve gradyan artırma modelleri her iş merkezi için uygulanmıştır.

Yapay sinir ağlarında modelin performansı esas olarak nöron sayısından etkilenmektedir. Kurulan yapay sinir ağı modellerinde gizli katman sayısı bir olarak alınmıştır. Gizli katmandaki nöron sayısını belirlemek için literatürde net bir kural yoktur. Yapay sinir ağının genelleme yeteneğini artırabilmek adına bir katmanda kullanılacak nöron sayısının mümkün mertebe az olması gerekir [12]. Bu nedenle gizli nöron sayısını belirlemede en çok kullanılan geometrik piramit kuralı kullanılmıştır. Geometrik piramit kuralında, girdi katmanından çıktı katmanına doğru nöron sayısı azalmalı, gizli nöron sayısı girdi nöron sayısının iki katını geçmemelidir. Aynı zamanda bu sayı girdi ve çıktı nöron sayısının çarpımının karekökünden daha az bir değere sahip olmamalıdır [12]. Buna göre en iyi sonucu veren gizli nöron sayısının araştırılması için ağ arama (grid search) algoritması kullanılmıştır. Grid arama algoritmasında, her bir iş merkezi için geometrik kural sonucu belirlenen 3 ile 12 arası gizli nöron sayıları denenmiştir ve bu gizli nöron sayıları içerisinde hata oranı en düşük olan gizli nöron sayısı belirlenmiştir. Her bir iş merkezi için belirlenen nöron sayıları aşağıda Tablo 4'te belirtilmiştir.

**Tablo 4.** YSA Modelleri için Optimum Nöron Sayıları

Üretim Grubu	İş Merkezi	Yapay Sinir Ağı Nöron Sayısı
Sac Metal	Gerdimli Şekil Verme Presi 1	12
	Gerdimli Şekil Verme Presi 2	12
Talaşlı İmalat	5 Eksenli İşleme Tezgahı 1	12
	5 Eksenli İşleme Tezgahı 2	11
Kompozit	Hassas Frezeleme Tezgahı	12
	5 Eksenli Frezeleme ve Su Jeti	12
Kalite	Ultrasonik Kontrol Tezgahı 1	12
	Ultrasonik Kontrol Tezgahı	12

Destek vektör regresyonu modelinin performansı esas olarak C ve  $\gamma$  hiperparametrelerinden etkilenir [37, 38]. Modeldeki C katsayısı, Lagrange çarpanının alabileceği üst sınır değerini gösteren ceza parametresini ifade etmektedir [39].  $\gamma$ , modelde ne kadar eğrilik istendiğini belirleyen parametredir.  $\gamma$  değerinin artması, modelin eğriliğinin artması anlamına gelmektedir [40].

Bu çalışmada verilerin doğrusal olmamasından kaynaklı doğrusal olmayan regresyon modelleri için kullanılan radyal tabanlı fonksiyon (RBF)'u kernel fonksiyonu olarak kullanılmıştır. C ve  $\gamma$ 'nin belirlenmesi için literatürde net bir kural yoktur. En iyi sonucu veren C ve  $\gamma$ 'nin araştırılması için ağ arama (grid search) algoritması kullanılmıştır. Grid arama algoritmasında, her bir iş merkezi için (C,  $\gamma$ ) çiftleri denenmiştir ve bu çiftler içerisinde hata oranı en düşük olan çift seçilmiştir. C ve  $\gamma$  ile ilgili bir ağ araması 10-kat çapraz doğrulama kullanılarak eğitim setinde uygulanmıştır. Ağ araması C ve  $\gamma$  (C = 2, 2<sup>2</sup>, 2<sup>4</sup>, 2<sup>5</sup>;  $\gamma$  = 2, 2<sup>2</sup>, 2<sup>4</sup>, 2<sup>5</sup>)'nin üssel sonuçlarının değerlendirilmesi ile gerçekleştirilmiştir. Bu çalışmada her bir iş merkezi için belirlenen optimum hiperparametreler aşağıda Tablo 5'te belirtilmiştir.

**Tablo 5.** DVR Modelleri için Optimum C ve Gamma Değerleri

Üretim Grubu	İş Merkezi	Destek Vektör Reg.	
		C	$\gamma$
Sac Metal	Gerdimli Şekil Verme Presi 1	32	32
	Gerdimli Şekil Verme Presi 2	32	32
Talaşlı İmalat	5 Eksenli İşleme Tezgahı 1	32	2
	5 Eksenli İşleme Tezgahı 2	32	2
Kompozit	Hassas Frezeleme Tezgahı	32	16
	5 Eksenli Frezeleme ve Su Jeti	32	32
Kalite	Ultrasonik Kontrol Tezgahı 1	32	32
	Ultrasonik Kontrol Tezgahı	32	32

Gradyan artırma modelinde modelin performansını etkileyen dört hiperparametre vardır:

D: Modelin maksimum etkileşim sırasını da kontrol eden karar ağaçlarının derinliği  
 K: Karar ağaçlarının sayısına da karşılık gelen yineleme sayısı  
 $\alpha$ : Genellikle 0 ile 1 arasında küçük bir pozitif değer olan öğrenme hızı,  
 H: Her yinelemeli adımda kullanılan veri oranı

Diğer iki algoritmada olduğu gibi gradyan artırma algoritmasında da hiperparametrelerin belirlenmesinde net bir kural yoktur. Bu nedenle en iyi sonucu veren D, K,  $\alpha$  ve H değerlerinin belirlenmesi için ağ arama (grid search) algoritması kullanılmıştır. Gradyan artırma algoritması için, D, K,  $\alpha$  ve H ile ilgili bir ağ araması 10-kat çapraz doğrulama kullanılarak eğitim setinde uygulanmıştır. Ağ araması D =2,4,8; K = 100,500,1000;  $\alpha$ =0.01,0.1,0.2,0.5; H= 0.5,0.75,1'nin sonuçlarının değerlendirilmesi ile gerçekleştirilmiştir. Bu çalışmada her bir iş merkezi için belirlenen optimum hiperparametreler aşağıda Tablo 6'da belirtilmiştir.

**Tablo 6.** Gradyan Artırma Modelleri için Optimum D, K,  $\alpha$  ve H Değerleri

Üretim Grubu	İş Merkezi	Gradyan Artırma			
		D	K	$\alpha$	H
Sac Metal	Gerdimli Şekil Verme Presi 1	8	1000	0,01	0.5
	Gerdimli Şekil Verme Presi 2	2	1000	0,2	0.75
Talaşlı İmalat	5 Eksenli İşleme Tezgahı 1	2	1000	0,1	1
	5 Eksenli İşleme Tezgahı 2	4	1000	0,01	0.75
Kompozit	Hassas Frezeleme Tezgahı	8	500	0,01	0.5
	5 Eksenli Frezeleme ve Su Jeti	8	1000	0,01	0.75
Kalite	Ultrasonik Kontrol Tezgahı 1	4	500	0,01	0.5
	Ultrasonik Kontrol Tezgahı	4	500	0,1	0.5

Her bir model için optimal hiperparametre değerlerinin belirlenmesinden sonra modeller eğitilip tahmin yapması sağlanmış ve yaptığı tahmin değerleri gerçek değerler ile karşılaştırılmıştır. Modelin tahmin başarısı  $R^2$ , MSE (hata kareleri toplamı), MAE (Hatanın mutlak ortalaması) ve MAPE (Ortalama Mutlak Yüzde Hata) değerleri ile ölçülmüştür. Sonuçların özetlendiği tablo (Tablo 7) paylaşılmıştır.

**Tablo 7.** Model Tahmin Başarıları

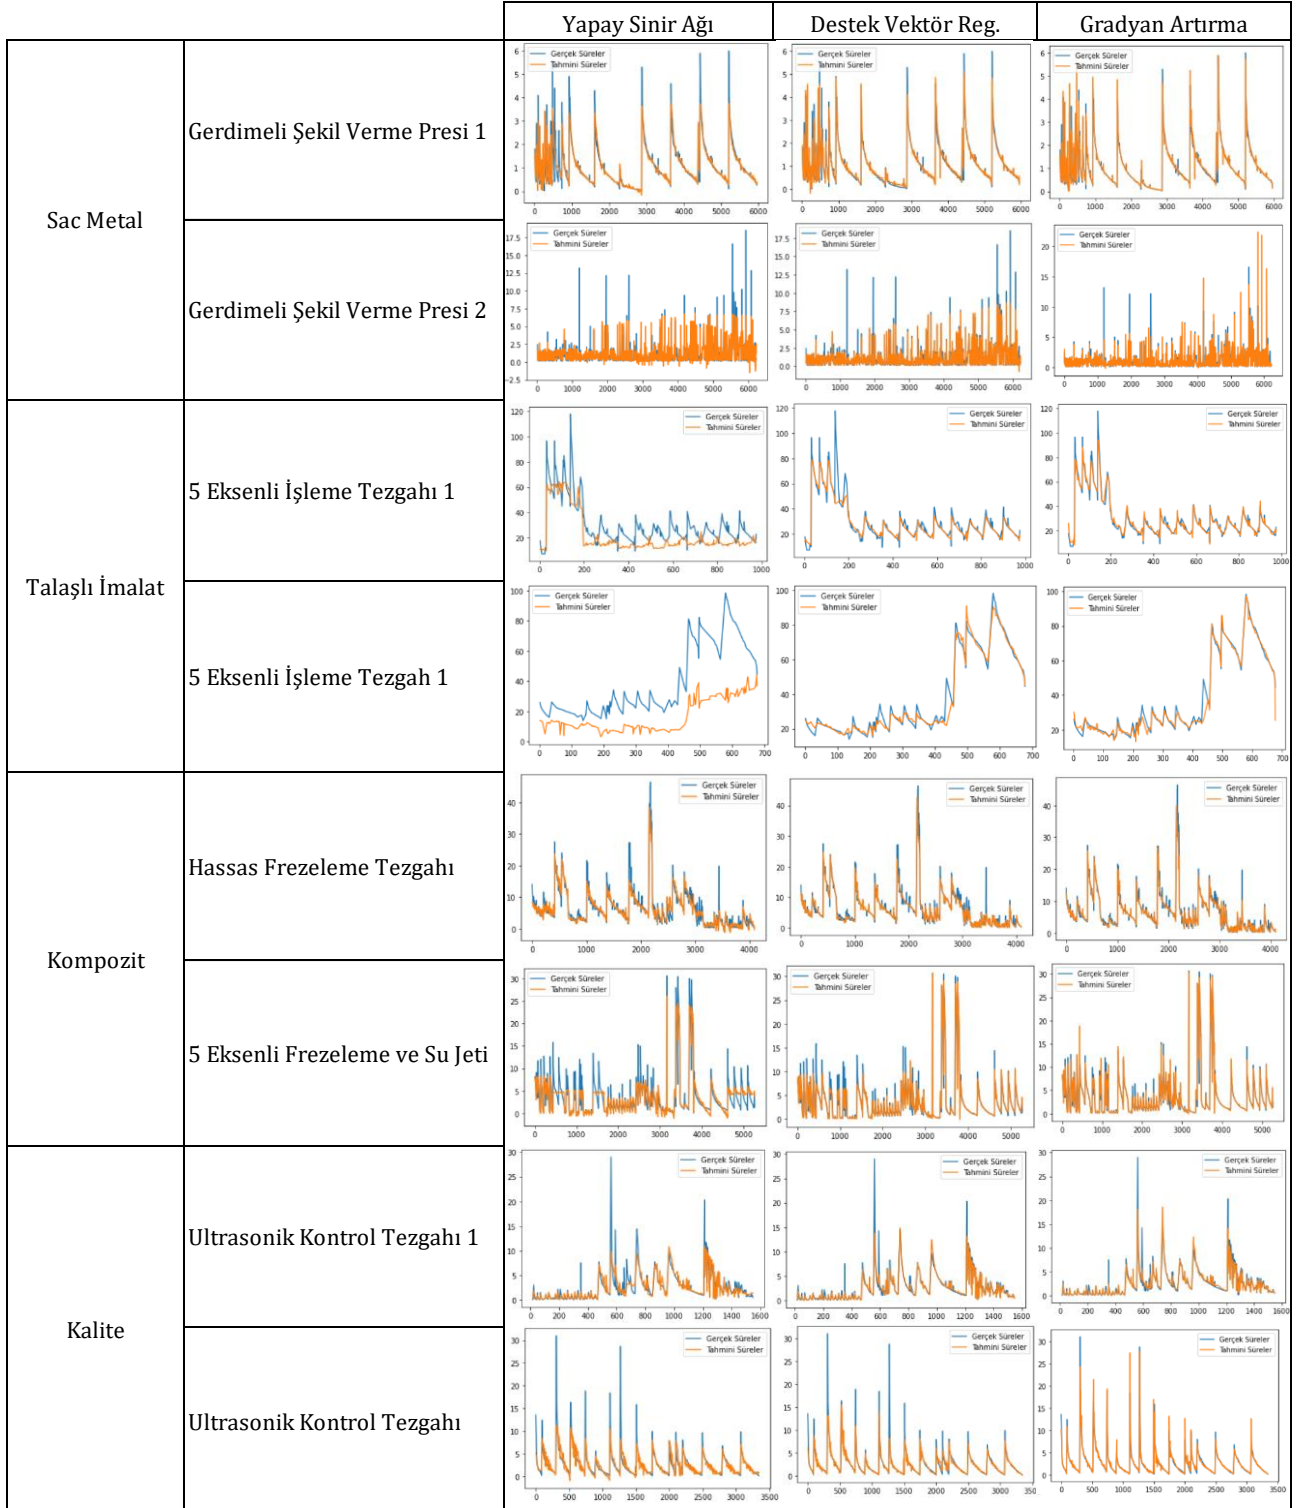
Üretim Grubu	İş Merkezi	Yapay Sinir Ağı				Destek Vektör Reg.				Gradyan Artırma			
		$R^2$	MSE	MAE	MAPE %	$R^2$	MSE	MAE	MAPE %	$R^2$	MSE	MAE	MAPE %
Sac Metal	Gerdimli Şekil Verme Presi 1	0,86	0,33	0,16	26,33	0,93	0,23	0,11	20,21	0,96	0,16	0,06	6,94
	Gerdimli Şekil Verme Presi 2	0,68	0,92	0,38	53,34	0,79	0,74	0,20	21,84	0,86	0,60	0,21	32,42
Talaşlı İmalat	5 Eksenli İşleme Tezgahı 1	0,46	13,15	10,07	33,29	0,84	7,03	2,81	9,23	0,96	3,48	2,03	7,32
	5 Eksenli İşleme Tezgahı 2	-0,24	25,70	20,81	55,43	0,98	3,52	2,18	6,74	0,98	3,15	1,77	6,01
Kompozit	Hassas Frezeleme Tezgahı	0,91	1,80	1,15	35,55	0,95	1,29	0,60	14,75	0,96	1,21	0,56	15,11
	5 Eksenli Frezeleme ve Su Jeti	0,83	1,86	1,18	65,53	0,94	1,09	0,45	16,27	0,98	0,69	0,30	11,07
Kalite	Ultrasonik Kontrol Tezgahı 1	0,75	1,53	0,72	36,67	0,86	1,16	0,44	21,89	0,89	1,01	0,45	23,26
	Ultrasonik Kontrol Tezgahı 2	0,69	1,77	0,81	45,68	0,79	1,49	0,47	16,40	0,91	0,95	0,34	15,42

#### 4. Tartışma ve Sonuç

Modellerin tahmin başarıları karşılaştırıldığında; gerdimli şekil verme presi 1'de en düşük hata oranı %6,94 ile gradyan artırma modelinde görülmüştür. En düşük ikinci hata oranı %20,21 ile Destek Vektör Regresyonu modelindedir. Gerdimli şekil verme presi 2'de ise en düşük hata oranı %21,84 ile destek vektör regresyonu modelinde olup, en düşük ikinci hata oranı % 32,42 ile gradyan artırma modelinde görülmüştür. Talaşlı imalat prosesi için seçilen iki iş merkezinde de en düşük hata oranları % 7,32 ve % 6,01 ile gradyan artırma modellerinde görülmüştür. En yakın hata oranları ise %9,23 ve %6,74 ile destek vektör regresyonu modellerindedir. Kompozit iş merkezlerinden hassas frezeleme tezgahında en düşük hata oranı %14,75 ile destek vektör regresyonu

modelinde olup ikinci sırada % 15,11 hata oranı ile gradyan artırma modeli gelmektedir. 5 eksenli frezeleme ve su jeti tezgahında ise en düşük hata oranı %11,07 ile gradyan artırma modelinde görülmüştür. %16,40 hata oranı ile destek vektör regresyonu ikinci gelmektedir. Kalite iş merkezlerinden ultrasonik kontrol tezgahı 1 için en düşük hata oranı %21,89 ile destek vektör regresyonundadır. En düşük ikinci hata oranı ise %23,26 ile gradyan artırma modelinde görülmektedir. Ultrasonik kontrol tezgahı 2'de en düşük hata oranı %15,42 ile gradyan artırma modelinde görülmüştür. %16,40 hata oranı ile destek vektör regresyonu takip etmektedir.

Yapay sinir ağı modellerinin hata oranları bütün iş merkezlerinde en yüksek hata oranını vermiştir. Hata oranı (MAPE) %10'un altında olan modelleri "çok iyi", %10 ile %20 arasında olan modelleri "iyi", %20 ile %50 arasında olan modelleri "kabul edilebilir" ve %50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır [28]. Her bir model için gerçek süreler ile tahmini sürelerin karşılaştırıldığı grafikler Şekil 5'te verilmiştir.



Şekil 5. Gerçek Süreler ve Tahmini Süreler Karşılaştırma Özet

Çalışmada sistemden çekilen işçilik saatlerinin teknisyenler tarafından doğru girildiği ve bekleme sürelerini içermediği varsayılmaktadır. Elde edilen sonuçlara göre hata oranı %20 ve altında olan modeller başarılı olarak kabul edilerek iş merkezine ait üretim süresi tahmin modeli olarak kullanılabilir. Firma, özellikle yeni iş paketleri için gereken iş yükü ve iş gücü değerlerine ulaşmak için üretim süresi tahmin modelini kullanarak gerekli hesaplamaları yapabilecektir. Üretim süresi tahmin hatalarından kaynaklı maliyet analizinde olan sapmaların önüne geçebilecektir. Aynı zamanda, yine üretim süresi tahmin hatalarından kaynaklı, müşteriye iletilen terminlerdeki gecikmelerin önüne geçerek müşteri memnuniyetinde artış sağlayabilecektir. Orta ve uzun vadeli kapasite planlarını daha doğru analiz ederek yatırım öngörülerini daha doğru yapabilecektir ve yanlış yatırım kararları ile oluşabilecek maliyet kayıplarının önüne geçebilecektir. Ek olarak firma bu model sayesinde vardiya ve fazla mesai planlarını daha doğru yapabilecek böylelikle iş gücünün daha verimli bir şekilde kullanılmasını sağlayabilecektir.

Günümüz rekabet koşullarında, taleplere doğru ve hızlı şekilde cevap verebilmek müşteri memnuniyeti açısından çok önemlidir. Kısıtlı kaynakları verimli bir şekilde kullanabilmek, geleceğe dönük yatırımları belirleyebilmek için üretim süresi tahmini yapmak rekabet avantajı sağlamak isteyen firmalar için çok önemlidir. Üretim süresi denildiğinde ilk olarak akla zaman etüdü gelmektedir. Fakat ürün çeşitliliğinin ve iş merkezlerinin çok fazla olduğu tesislerde parça başına zaman etüdü yapmak büyük bir iş yükü gerektirerek zaman ve maliyet kaybına yol açmaktadır. Bu kaybın önüne geçerek üretim süresi tahminlemek istendiğinde, makine öğrenmesi algoritmaları ön plana çıkmaktadır.

Bu uygulamada makine öğrenmesi algoritmalarından yapay sinir ağları, destek vektör regresyonu ve gradyan artırma modellerini kullanarak üretim süresi tahminlenmiştir. Bu amaçla üretim ortamından elde edilen veriler ile üretim tesisine ait 4 temel proses seçilmiştir. Bu prosesler; talaşlı imalat, sac metal, kalite ve kompozit imalat olarak belirlenmiştir. Seçilen temel proseslerin her biri için 2'şer iş merkezi üzerinden geçmişe dönük 5 yıllık veri seti kullanılmıştır. Toplam 8 iş merkezine yapay sinir ağları, destek vektör regresyonu ve gradyan artırma algoritmaları kullanılarak, bu algoritmaların farklı kombinasyonları ile toplam 24 adet üretim süresi tahmin modeli oluşturulmuştur. Modellerin başarıları performans metriklerinden MAPE değeri ile belirlenmiştir. Performans metrikleri ile model başarıları incelendiği zaman; 8 iş merkezinden 5'i için en iyi tahmin sonuçları gradyan artırma modeline ait olup, 3 iş merkezine ait en iyi sonuçlar destek vektör regresyonuna aittir. Yapay sinir ağları modellerine ait hata oranlarının her iş merkezinde oldukça yüksek olduğu görülmüştür.

Genel olarak gradyan artırma ve destek vektör regresyonu modellerinin üretim süresi tahminlemede başarılı sonuçlar verdiği görülmüştür. Ancak uygulama bölümünde de bahsedildiği gibi optimal hiperparametrelerin seçimi aşamasında, aday değerlerin belirlenmesi üzerine literatürde net kurallar yoktur. Bu nedenle aday hiperparametre sayısını artırmanın, modellerin çalışma süresi açısından olumsuz etkilemesine rağmen tahmin performansı açısından daha etkili sonuçlar vereceği değerlendirilmektedir. Sonuç olarak gelecek çalışmalarda girdi çeşitliliğinin ve optimum hiperparametrelerin belirlenmesi için gereken aday hiperparametrelerin artırılması ile daha başarılı sonuçlar elde edilebileceği öngörülmektedir. Ek olarak gelecek çalışmalarda karşılaştırılacak makine öğrenmesi algoritmalarının çeşitliliği artırılarak çalışmaların zenginleştirilebileceği ve elde edilen üretim tahmin modelleri üzerine karar destek sistemi kurularak çalışmanın geliştirilebileceği öngörülmektedir.

## Kaynakça

- [1] Bilekdemir, G. 2010. Veri madenciliği tekniklerini kullanarak üretim süresi tahmini ve bir uygulama. Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 89s, İzmir.
- [2] Altın, S. Ş. 2011. Benzer süreçlerde üretilen ürünler için yapay zeka ile zaman tahmini. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 48s, Ankara.
- [3] Enns, S. T. 1995. A dynamic forecasting model for job shop flowtime prediction and tardiness control. International Journal of Production Research, 33(5), 1295-1312.
- [4] Raddon, A., Grigsby, B. 1997. Throughput time forecasting model. IEEE/SEMI Conference and Workshop on Advanced Semiconductor Manufacturing, 10-12 September, USA, 430-433.
- [5] Şeker, A., Diri, B., Balık, H. H. 2017. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme. Gazi Mühendislik Bilimleri Dergisi, 3(3), 47-64.

- [6] Janakiram, M., Backus, P., Movafagh, S., Runger, G. 2003. Data mining for cycle time prediction. IEEE Trans. CAS. II, INFORMS Annual Conference, 19-22 October, Atlanta.
- [7] Janakiram, M., Mowzoon, S. 2006. Factory Cycle-Time Prediction With Data-Mining Approach. IEEE Transactions on Semiconductor Manufacturing, 19(2), 252-258
- [8] Alenezi, A., Moses, S. A., Trafalis, T. B. 2007. Real-time prediction of order flowtimes using support vector regression. Computers & Operations Research, 35(11), 3489-3503.
- [9] Lim, Z., Yusof, U., Shamsudin, H. 2019. Manufacturing Lead Time Classification Using Support Vector Machine. ss 268-278. 6th International Visual Informatics Conference, 19-21 November, Malaysia, 268-278.
- [10] Meidan, Y., Lerner B., Hassoun M., Rabinowitz G. 2009. Data Mining for Cycle Time Key Factor Identification and Prediction in Semiconductor Manufacturing. IFAC Proceedings Volumes, 42(4), 217-222.
- [11] Meidan, Y., Lerner B., Hassoun M., Rabinowitz G. 2011. Cycle-Time Key Factor Identification and Prediction in Semiconductor Manufacturing Using Machine Learning and Data Mining. IEEE Transactions on Semiconductor Manufacturing, 24(2), 237-248.
- [12] Kurnaz, G. 2019. Kablo takımı üretim süresinin ve kusurlu ürün oluşumuna yönelik risk faktörlerinin makine öğrenmesi algoritmaları ile belirlenmesi. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 220s, Samsun.
- [13] Zhang Y., Haghani A. 2015. A Gradient Boosting Method to Improve Travel Time Prediction. Transportation Research Part C: Emerging Technologies, 58(2), 308-324.
- [14] Kuo, Y., Chan, N., Leung, J., Meng, H., So, A., Tsoi, K., Graham. C. 2020. An Integrated Approach of Machine Learning and Systems Thinking for Waiting Time Prediction in an Emergency Department. International Journal of Medical Informatics, 139, 104-143.
- [15] Var, T., Türkay, B. E. 2014. Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini. Eleco 2014 Elektrik - Elektronik - Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu, 27-29 Kasım, Bursa, 34-37.
- [16] Kartal, E. 2015. Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri Ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 133s, İstanbul.
- [17] Sarı, M. 2016. Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 101s.
- [18] İmamoğlu, S., İnce H. 2016. Destek Vektör Regresyon ve İkiz Destek Vektör Regresyon Yöntemi ile Tedarikçi Seçimi. Doğu Üniversitesi Dergisi, 2(2), 241-253.
- [19] Yang, S., Wu, J., Du, Y., He, Y., Chen, X. 2017. Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. Journal of Sensors. 10, 1-15.
- [20] Bardak, E. S., Aydemir, D., Bardak, S. 2018. Yapay Sinir Ağları ve Derin Öğrenme Algoritmaları Kullanarak Nanokompozitlerde Deformasyonun Tahmin Edilmesi. Bartın Orman Fakültesi Dergisi, 20(2), 223-231.
- [21] Öztemel, E. 2003. Yapay sinir ağları. PapatyaYayincilik, İstanbul, 44s.
- [22] Smith, K. A. and Gupta, J. N. D. 2000. Neural Networks in Business: Techniques And Applications For The Operations Researcher. Computers & Operations Research, 27(11), no. 11, 1023-1044.
- [23] Kartalopoulos, S. V., Kartakopoulos, S. V. 1997. Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications. Wiley-IEEE Press, New York. 232s.
- [24] Hamid, S. A., Iqbal, Z. 2004. Using Neural Networks For Forecasting Volatility Of S&P 500 Index Futures Prices. Journal of Business Research, 57(10), 1116-1125.

- [25] Haykin, S. 1999. Neural Networks: A Comprehensive Foundation. Prentice- Hall, Ontario, 837s.
- [26] Vapnik V. 2000. The Nature of Statistical Learning Theory. Springer, New York, 314s.
- [27] Schölkopf, B., Smola A.J. 2002. Learning with Kernels. MIT Press, Cambridge, 626 s.
- [28] Yakut, E., Elmas, B., Yavuz, S. 2014. Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 19(1) 139-157.
- [29] Acı, M., Avcı, M., Acı, Ç. 2017. Destek Vektör Regresyonu Yöntemiyle Karbon Nanotüp Benzetim Süresinin Kısaltılması. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 32(3), 901-907.
- [30] Yakut, E. 2012. Veri madenciliği tekniklerinden c5.0 algoritması ve destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması:imalat sektöründe bir uygulama. Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, 217s, Erzurum.
- [31] Schapire, R. E. 1989. The strength of weak learnability. 30th Annual Symposium on Foundations of Computer Science, 30 Oct.-1 November, United States, 28-33.
- [32] Freund, Y. 1995. Boosting a Weak Learning Algorithm by Majority. Information and Computation, 121(2), 256-285.
- [33] Freund, Y., Schapire, R. E. 1996. Experiments with a new boosting algorithm. Thirteenth International Conference on International Conference on Machine Learning, 3-6 July , Italy, 148-156.
- [34] Friedman, J. 2000. Greedy Function Approximation: A Gradient Boosting Machine. The Annals of Statistics, 29(5), 11-28.
- [35] Friedman, J. 2002. Stochastic Gradient Boosting. Computational statistics & data analysis, 38(4), 367-378.
- [36] Lewis, C. D. 1982. Industrial and Business Forecasting Methods : A Practical Guide to Exponential Smoothing and Curve Fitting. Butterworth Scientific, London. 143s.
- [37] Cherkassky, V., Ma, Y. 2004. Practical Selection of SVM Parameters and Noise Estimation for SVM Regression. Neural Networks : The Official Journal Of The International Neural Network Society, 17(1), 113-26.
- [38] Lu, C. J., Lee, T. S., Chiu, C. C. 2009. Financial Time Series Forecasting Using Independent Component Analysis And Support Vector Regression. Decision support systems, 47(2), 115-125.
- [39] Katagiri, S., Abe, S. 2006. Incremental Training Of Support Vector Machines Using Hyperspheres. Pattern Recognition Letters, 27(13), 1495-1507.
- [40] Kumar, A. M. 2018. C and Gamma in SVM. <https://medium.com/@myselfaman12345> (Erişim Tarihi: 24.02.2021).