

# Talaşlı İmalat Sektöründe Zaman Serileri Kullanarak Üretim Etkililiğinin Tahmini

*Araştırma Makalesi/Research Article*

Bahadır AKTAŞ<sup>1</sup>, Can AYDIN<sup>2</sup>

<sup>1</sup>Yönetim Bilişim Sistemleri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Sakarya Üniversitesi, Sakarya, Türkiye.

<sup>2</sup>Yönetim Bilişim Sistemleri Bölümü, İktisadi ve İdari Bilimler Fakültesi, Dokuz Eylül Üniversitesi, İzmir, Türkiye.

[bahadiraktas91@gmail.com](mailto:bahadiraktas91@gmail.com), [can.aydin@deu.edu.tr](mailto:can.aydin@deu.edu.tr)

(Geliş/Received:24.01.2018; Kabul/Accepted:24.10.2018)

DOI: 10.17671/gazibtd.383339

**Özet**— Günümüzde imalat sektöründe bulunan şirketlerin, üretim performansını, miktarını ve diğer değişkenleri tahmin edebilmesi rekabet ortamında rakiplerine ciddi bir avantaj sağlamalarına sebep olmaktadır. Üretim miktarlarının tahmin edilmesi tesisin gelecekteki giderlerini, üretim tezgâhlarındaki hata oranlarını ve karşılaşılabilecek krizlerin önceden tespit edilmesini sağlayarak verimlilik (etkililik) artışı sağlanmasına olanak tanımaktadır. Bu kapsamda talaşlı imalat sektöründe üretim performansının zaman serisi analizi kullanılarak yüksek doğrulukla ve hızlı bir şekilde tahmin edilmesi amaçlanmaktadır. Bunun için AR ve ARIMA metotları karşılaştırılarak uygun model seçimi gerçekleştirilmiştir. Seçilen model kullanılarak gerçeğe yakın tahmin değerlerine ulaşılmıştır. Modellenmiş üretim performansı değerinin üretim miktarı, üretim tonajı, üretilen parça başı ağırlık, kalıp revizyon süresi ve bakım arıza süresi değerlerinin her biri ile polinom regresyon yöntemi ile analizi yapılarak model oluşturulmuş ve performans tahmin değerinden yola çıkarak bu değerlerin her birisi için ileriye dönük tahmin edilmiştir. Bu modelin test MSE (Ortalama Karesel Hata), RMSE (Ortalama Karesel Hatanın Karekökü) ve MAPE (Ortalama Mutlak Hata yüzdesi) değerleri hesaplanmıştır. Elde edilen tahmini performans değerinden belirli ortalama hata payları ile tezgâhlarda üretilen adet sayısı, tonaj miktarı, bakım-arıza süresi, kalıp revizyon süresi, adet başı tonaj oranı gibi diğer verilerle ilgili tahminlerin yapılması sağlanmıştır.

**Anahtar Kelimeler**— zaman serisi tahmini, ARIMA, karar destek sistemleri, endüstri 4.0

## Prediction of Production Efficiency with Using Times Series on Machining Sector

**Abstract**— Nowadays, companies in the manufacturing sector are able to have the edge on the competition by being able to predict production performance, the amount produced and other variables. Estimating the production quantities allows companies to pre-determine the future costs of the plant, the error rates on the production lines, and the crises to be encountered, thereby enabling the productivity(effectiveness) increase. In this context, it is aimed to estimate the production performance in the machining industry with high accuracy and speed by using time series analysis. Therefore, AR and ARIMA methods were compared and the appropriate model was selected. Forecasts have been made by using the selected model with a small margin of error. The modeled production performance value is analyzed and modeled by using the polynomial regression method with each of the values of production amount, production tonnage, produced weight per piece, mold revision time and maintenance - breakdown time and predicted for each of these values based on prediction value of production performance. MSE (mean square error) and RMSE (square root of mean square error) values of this model were calculated. Estimates of other data such as the number of pieces produced, the production tonnage, the number of maintenance-breakdown time, mold revision time, and the weight per piece ratio were made possible from the estimated production performance values obtained.

**Keywords**— time series forecasting, ARIMA, decision support system, industry 4.0

## 1. GİRİŞ (INTRODUCTION)

Fabrikalarda Endüstri 4.0 süreçlerine geçiş için atılması gereken adımlar kapsamında performans artışı sağlanması için; iş süreçlerinde esneklik sağlanması, bilgi teknolojilerinin (BT) entegre edilmesi, iş süreçleri dijitalleştirilmesi hedeflenmektedir [1]. Bununla beraber bilgi teknolojileri kullanarak üretimde verimliliğin ve performansın artırılması pek çok işletmenin öncelikli konusu olmuş ve verimlilik ile kazanç artışı sağlamak önem kazanmıştır. Endüstri 4.0 ile artık sistemler düşük bilgisayar ya da insan zekâsı yerine makine öğrenmesi, otonom sistemler kullanılmaktadır. Fabrikalar bu hedefleri yakalayabilmek için üretim verilerini elde etme, verileri öğrenme ve buna göre sistemleri kontrol etme kabiliyetine sahip makine öğrenmesi algoritmaları kullanmayı amaçlamaktadır. Üretim süreçlerinde üretilen verilerin insan eliyle değerlendirilmesi çok uzun zaman almaktadır. Bu sürecin yavaş ilerlemesi yöneticinin hızlı karar alamamasına sebep olmaktadır. Makine öğrenmesi ile geliştirilen sistemler detaylı veri analizleri ile birçok bilgiyi bir araya getirip tahminler yaparak bu bilgileri belirli yöntemlerle problemlerin çözümünde kullanılmaktadır. Böylece makinelerin kullandığı sistemler yeni problemlerle karşılaştıklarında geçmiş verilerin ışığında çözümü kendiliğinden ortaya koyabilmektedir. Bu kapsamda üretim bandında bilgi teknolojileri kullanılması daha çok veri üretilmesi ve bu verilerin analiz edilerek üretim süreçlerinde daha etkin karar verilmesini sağlamaktadır. Üretimin takip edilip iyileştirilmesi, karar verme süreçlerine katkı sağlanması ve verimliliğin artırılması için bilgi teknolojileri (BT) kullanılmaya başlanması gibi konularda son yıllarda yapılan birçok çalışma bulunmaktadır ([2],[3],[4],[5]). Bu kapsamda zaman serisi analizi yöntemleri kullanılarak tahminleme yapılan birçok çalışma bulunmasına rağmen üretim miktarlarının tahmin edilmesine ve bu tahminlerin şirketin karar alma aşamasında kullanılıp verimliliğin artırılmasına yönelik bir çalışma bulunmamaktadır. Bu kapsamda zaman serileri analizi kullanarak üretim performansının tahmin edilmesi ve bu tahmin edilen değerlerin üretim miktarı (adedi), üretim tonajı, kalıp revizyon süresi, ortalama parça birim ağırlığı ve bakım arıza duruşları süresi değerleriyle polinom regresyon yöntemi uygulanması sonucu tüm bu değerlerin tahminlenmesi sağlanıp ve bu sayede üretim performansını ve verimliliğin artırılması amaçlanmaktadır. Çalışma kapsamında araştırma sorusu olarak talaşlı imalat sektöründe zaman serileri analizi kullanılarak üretim miktarlarının tahmin edilip edilemeyeceği araştırılmıştır. Üretim miktarlarının tahmin edilmesi için şirketin belirli bir döneme ait üretim ve performans verileri kullanılacaktır. Çalışmanın özgünlüğü; tahmin edilen performans verilerinden şirketin tezgâhlarda üretilen adet sayısı, tonaj miktarı, bakım-arıza süresi, kalıp revizyon süresi, adet başı tonaj oranı tahmin edilebilmesidir. Makine öğrenmesi alanında çalışan araştırmacılar; üretim miktarlarının tahmin edilmesinde doğru ve verimli tahminler geliştirmek sistemin uygun şekilde modellenmesi gerektiğine vurgu yapmaktadır. Ardından uygun istatistik yöntemler kullanılarak geleceğe yönelik tahminlemeler yapılmaktadır. Zaman serileri

analizi, belirli zaman aralıklarında gözlenen bir olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı amaçlayan bir metottur [6]. Literatür incelendiğinde zaman serileri analiz yöntemlerinde AR (Auto Regressive), MA (Moving Average), ARMA, ARIMA yöntemleri hisse senedi fiyatlarının tahmin edilmesi amacıyla kullanılmıştır [7]. Bunun yanında işletme alanında da yaygın olarak kullanılmaktadır. Zaman serileri analizi ile yapılan tahminler, üretim tesisinin geleceğe yönelik üretim planlama çalışmaları açısından kritik bir öneme sahiptir. Bu çalışma kapsamında talaşlı imalat sektöründe üretim miktarlarının zaman serisi analizi kullanılarak yüksek doğrulukla ve hızlı bir şekilde tahmin edilmesini sağlamaktadır. Çalışma da 1 Aralık 2016 ile 31 Mart 2017 tarihleri arasındaki üretim tezgâhının verileri zaman serisi analizi kullanılarak analiz edilmiştir. Zaman serilerinin yapısal analiz tabanlı AR ve ARIMA yöntemleri kullanılmıştır. İki farklı yöntem veri setine ayrı ayrı uygulanarak karşılaştırılmıştır. En uygun yöntem ARIMA olarak seçilmiş ve üretim tezgâhının performans verileri tahminlemesi yapılmıştır. Elde edilen bir günlük tahmini performans verisini aynı günün; üretim adedi, tonaj, tonaj/adet, üretim hazırlık verileri, bakım arıza gibi üretim ile ilgili diğer verilerin tahminlemesi için kullanılmıştır. Elde edilen sonuçlar incelendiğinde %9.5'e varan doğrulukla bu veriler tahmin edilmiş ve şirketin bir sonraki gün için alması gereken kararları önceden verebilmesini sağlamıştır. Böylece üretim tesisinin bir gün öncesinden hangi makine de ne zaman arıza oluşacak, tahmini stok verisi ve makinelerin kritik duruşlarının kaç dakika olacağı tespit edilmiştir.

## 2. TEORİK ÇERÇEVE VE HİPOTEZ (THEORETICAL FRAMEWORK AND HYPOTHESIS)

Üretim sektöründe üretim verilerinin analizinde bilgi teknolojilerinin yeteri kadar etkin kullanılmamasından dolayı; yoğun evrak işleri, toplanamayan veya geriden takip eden performans verileri, takip edilemeyen üretim istasyonu performansı gibi problemleri de beraberinde getirmektedir. Tahminleme yöntemlerinden yararlanamayan işletmeler performans hesaplanmasında, dolayısıyla yapılan ve yapılacak işlerin gidişatı ile ilgili alınacak kararların alınmasında sıkıntılar yaşamaktadır ve işletmenin verimliliği düşmektedir. Bu çalışma ile zaman serileri analizi kullanılarak üretim miktarlarının tahmin edilmesi ve bu sayede üretim sürecinde karar vermeyi hızlandırmak ve kolaylaştırmak amaçlanmaktadır. Geriden takip edilen ve tahmin edilmeyen verileri geçmişte bırakıp, geçmiş üretim verilerinden ileriye dönük kestirimler yaparak ve karar vericiler için rapor üretimiyle beraber şirketin verimliliğini artırma hedeflenmektedir. Bu kapsamda zaman serisi analizine yönelik çeşitli çalışmalar bulunmaktadır. ARIMA metodu kullanılan bir çalışma da Türkiye'deki elektrik, ithalat, ihracat, GSYİH, GSMH gibi sosyo-ekonomik zamansal veriler üzerinde tahminleme yapılmıştır [8]. Sağlık kurumlarında zaman serileri analizi ve elektrik tüketimi tahminini ARIMA modeli ile gerçekleştirmiştir. Çalışma da en uygun modelin

bulunması ve aynı zamanda en uygun tahmin periyodunun da bulunması hedeflenmiştir [9]. Türkiye'nin toplam petrol talebi ve ulaştırma sektörü petrol talebinin ARIMA ile modellenmesi sağlanmış ve tahminleme gerçekleştirilmiştir. Yapılan tahminler gelecekteki petrol talebini önceden kestirerek belirlemek hem tüketimi azaltması hedeflenmekte hem de daha uygun fiyata petrol alınması sağlanacaktır [10]. Bunun yanında yine ARIMA (1,0,0) modelleri kullanarak enflasyon tahminlemesi gerçekleştirilmiştir [11]. Bir diğer çalışmada Türkiye'de hava ulaşım talebinin ARIMA modelleri ile tahmin edilmesi sağlanmıştır. Çalışmanın sonucunda 1991-2008 yılları arasındaki yolcu sayılarından 2009 yılı için aylık yolcu sayıları tahmin edilmiştir [12]. Yine ARIMA modeli ile aylık elektrik talebinin mevsimsel model ile orta dönem öngörüsü yapılmıştır [13]. ARIMA ve panel regresyon tekniklerinden yararlanarak çevre bilimi ilgili ekonomi açısından sürdürülebilirliğin gelecekteki tahminleri ortaya konulmuştur [14]. Bunun yanında Hindistan hızlı tüketim malları sektöründe zaman serisi tabanlı tahmin analizi gerçekleştirilmiştir. Çalışma da AR, MA, ARIMA, PACF (Partial Auto Correlation Function) ve ACF (Auto Correlation Function) yöntemleri karşılaştırılmıştır [15]. Kaynar 2009 yılında aylık ve günlük döviz kurları üzerinden zaman serisi analizinde yapay sinir ağları ve ARIMA modellerini karşılaştırmıştır [6]. Yapay sinir ağlarının bu veri seti için daha başarılı bir yöntem olduğu belirlenmiştir. Bir başka çalışma da petrol kuyularının üretimini analiz ve tahmin etmek için ARIMA modelini kullanmıştır. ARIMA modelinin sonuçlarını geçerliliğini test etmek için DCA (Decline Curve Analysis) kullanmıştır. Çalışma da ARIMA (1,1,0) modeli en iyi sonucu vermiştir [16]. Petrol sektöründen farklı olarak süt üretimi tahmini gerçekleştirmek için ARIMA modelini kullanmıştır. ARIMA (1,0,3) ve (0,1,0) modelleri en uygun model olarak ortaya çıkmaktadır [17]. Babai ve Syntetos (2013) yılında iki aşamalı tedarik zincirinde talep tahminlemesi ve envanter performansı için ARIMA (0,1,1) modeli üzerine teorik ve ampirik bir çalışma gerçekleştirmiştir. Bu çalışmada, ARIMA (0,1,1) talep sürecine bakan bir perakendeci ve bir üretici tarafından oluşturulmuş bir tedarik zinciri düşünülmektedir. Tahmin doğruluğu ve envanter performansı arasındaki ilişki, perakendeci ile üretici arasında tahmini bilgi paylaşımının potansiyel yararları üzerine bir incelemeyle birlikte analiz edilmektedir [18]. Çalışma da ARIMA (4,1,4) (2,1,1) (2,2,3) modelleri en uygun model olarak çıkmıştır. Buna göre ARIMA modeli için kısa süreli tahminler daha iyi sonuç vermektedir. Cadenas vd. (2016) yılında rüzgar hızını tahminleme için ARIMA ve yapay sinir ağlarını NARX modellerini karşılaştırma üzerine bir çalışma gerçekleştirmiştir. NARX modeli çok değişkenli ARIMA ise tek değişkenli model olarak kullanılmıştır. Çalışma da iki farklı bölgenin verilerini karşılaştırmak suretiyle yapay sinir ağları modeli olan NARX'ın daha iyi sonuç verdiği ortaya çıkmıştır [19]. Babu ve Reddy (2014) yılında doğrusal bir model olan ARIMA ve doğrusal olmayan yapay sinir ağları ANN modellerini bir arada kullanarak hibrid bir model olan ARIMA-ANN kullanarak daha doğru tahminleme yapmak üzerine bir çalışma gerçekleştirmiştir [20]. Awal ve Siddique 2011 yılında Bangladesh pirinç üretimini ARIMA modelini kullanarak tahminleme üzerine

bir çalışma gerçekleştirmişlerdir [21]. ARIMA ve optimizasyon tekniği olan PSO (Particle Swarm Optimization) modellerini kullanarak yüksek miktarda eski veri kullanmadan daha iyi tahmin yapabilen bir model geliştirilmiştir [22]. Bir diğer çalışma da Hırvat endüstriyel üretim verilerinin ARIMA modeli kullanarak kısa ve uzun vadeli tahminleri karşılaştırılmıştır. Çalışmanın sonucunda ARIMA modelinin tahminleme yeteneğinin yüksek olduğu ve kısa vadeli tahminleme yapmak hususunda başarılı olduğu tespit edilmiştir [23]. 2007 yılında yapılan bir başka çalışma da tek değişkenli ve çok değişkenli ARIMA modelleri kullanarak balık üretiminin tahminlenmesi ve modellenmesi gerçekleştirilmiştir. Yapılan tahminlemeler balık üretim yönetiminde verimlilik artışı olduğu tespit edilmiştir [24]. Zaman serisi analizi yöntemi ile tahminleme yapılmasına yönelik literatür incelendiğinde üretim süreçlerinde verimlilik ve performans artışı sağladığı görülmektedir. Bu kapsamda hipotez olarak talaşlı imalat sektöründe üretim performansının zaman serisi analizi kullanılarak tahminlenmesi üretim süreçlerinde etkililiğini artırdığı belirlenmiştir.

H1: Talaşlı imalat sektöründe üretim performansının zaman serisi analizi kullanılarak tahminlenmesi, üretim süreçlerinde etkililiğini artırır.

Performans ölçümünde günlük vardiya başına hedeflenen üretim miktarı ile gerçekleşen üretim miktarının oranları karşılaştırılmıştır. Performans ölçütlerinden üretim etkililiği kullanılmıştır. Etkililik kavramının seçilmesinin sebebi, bu performans ölçütünün örgütün istenilen sonuçlara ulaşma düzeyi ve derecesini ifade etmesidir [25]. Yükü ve Atağan (2009) tarafından belirtilen üretim etkililiği aşağıdaki formüldeki gibi ifade edilmektedir [26].

$$\text{Üretim Etkililiği} = \frac{\text{Gerçekleşen üretim}}{\text{Hedeflenen üretim}}$$

Bu çalışma kapsamında anlık üretim takibi ve analizi sonucu elde edilen veriler kullanıldığından dolayı formül anlık üretim etkililiğini ölçülebilecek şekilde düzenlenmiştir.

$$\text{Anlık Üretim Etkililiği} = 100 \times \frac{\text{Gerçekte üretilen miktar (Anlık)}}{\text{Üretilmesi hedeflenen miktar} \times \frac{\text{Geçen Süre}}{\text{İş emri toplam süre}}}$$

Araştırma, İzmir - Kemalpaşa organize sanayi bölgesinde bulunan bir şirkette uygulanmıştır. Şirket 1998 yılında 5500 m2 alana kurulmuş ve yıllık 8000 ton dövme kapasitesine sahiptir. Şirkette 15'i beyaz yakalı olmak üzere 100 kişi çalışmaktadır. Talaşlı imalat, dövme gibi işlemlerini bünyesinde gerçekleştiren ve hem yurt içi hem Almanya, Macaristan, Fransa, Avusturya, İsveç gibi ülkelerde yurt dışı müşterileri bulunan Talaşlı imalat firmasıdır. Araştırma kapsamında hazırlanan üretim takip sistemleri 2 adet dövme makinesinin üretim verileri kullanılacaktır. Bu dövme makinesinin ürettiği ürünler ticari araçlar, iş makineleri, tarım makinelerinde kullanılan metal parçalar, shaft kardan ve çeşitli dişlilerdir.

### 3. YÖNTEM (METHOD)

Çalışma kapsamında ilk olarak üretim etkililiği verilerinin tahminlenmesi için yöntem seçimi

gerçekleştirilmiştir. Bunun için AR ve ARIMA yöntemleri mevcut veri seti üzerinde uygulanıp model geliştirilmiş ve daha iyi sonuç veren model seçimi gerçekleştirilmiştir. AR ve ARIMA yöntemleriyle zaman serisi analizi yapılacak veri setinin istatistiki açıdan uygun olup olmadığını görmek adına Ljung-Box uygunluk testi yapılmıştır ([27],[28]). Uygunluk testi sonuçlarında Ki-kare 4.3845, anlamlılık değeri p-değeri 0.03627 olarak hesaplanmıştır ve anlamlı ve zaman serisi analizlerinde kullanılabilir bir sonuç ortaya konulmuştur.

Ljung-Box Uygunluk Formülasyonu [28]:

$$Q = n(n+2) \sum_{k=1}^{\infty} \frac{p_k^2}{n-k}$$

Ardından seçilen model ile tahminleme yapılarak bir sonraki günün performans verisi hesaplanmıştır. Hesaplanan bu veri ile tezgâhlarda üretilen adet sayısı, tonaj miktarı, bakım-arıza süresi, kalıp revizyon süresi, adet başı tonaj oranı verileri polinom regresyon yöntemi ile ortalama hata payları hesaplanarak her biri için tahmini değerler hesaplanmıştır.

### 3.1 AR ve ARIMA Modeli (AR and ARIMA Model)

Literatür incelendiğinde zaman serisi tahminleme çalışmaları yapılırken genellikle AR ve ARIMA yöntemleri kullanılmıştır. Bu çalışma kapsamında da yine bu iki model karşılaştırılması yapılarak hangisinin bu veri seti için en uygun model olduğu belirlenmiştir. AR (Auto Regressive) model, bir modelin çıktısını, bir önceki değere bakarak lineer olarak, stokastik fark denklemi olarak verir. Bir AR modelinde, bağımlı değişken geçmişteki değerinin bir fonksiyonudur [15]. Bu durum aşağıdaki gibi bir denklemle ifade edilmektedir.

$$Y_t = c + a_1 Y_{t-1} + a_2 Y_{t-2} + \dots + a_p Y_{t-p} + u_t$$

$Y_t$ : t anındaki sonuç değişkeni

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$  = Sırasıyla  $t-1, t-2, \dots, t-p$  gecikmeli anlarındaki sonuç değişkenleri

$a_1, a_2, \dots, a_p$ : Model parametreleri

$u_t$ : t anındaki hata terimi

MA model ise basit hareketli ortalama modelini ifade etmektedir. MA modeli aşağıdaki gibi bir denklemle ifade edilmektedir.

$$Y_t = \mu + u_t + m_1 u_{t-1} + m_2 u_{t-2} + \dots + m_q u_{t-q}$$

$Y_t$ : t anındaki sonuç değişkeni

$\mu$ : Seri ortalaması

$m_1, m_2, \dots, m_q$ : Model Parametreleri

$u_t, u_{t-1}, u_{t-2}, \dots, u_{t-q}$ : Hata terimleri

AR ve MA modelleri bir araya gelerek daha karmaşık stokastik yapılara sahip olan ARIMA yöntemlerini meydana getirirler. ARIMA (Autoregressive Integrated

Moving Average) p, d, q olmak üzere 3 adet parametre kullanılmaktadır ve bu parametreler arasından uygun olanı seçilip modelin içerisinde kullanılır. ARIMA modeli için belirlenecek olan p, d, q parametreleri:

p: Otoregresif terim sayısı

d: Sezonsal olmayan farklılıkların sayısı


q: Tahmin denklemindeki gecikmeli tahmin hataları sayısı şeklinde tanımlanır.

### 3.2. Veri (Data)

Çalışma kapsamında üretim verilerinin elde edilmesi için üretim tezgâhlarına sayaç sensörleri yerleştirilerek sürekli veri alınmış ve veritabanına kaydedilmiştir. Veriler 1 Aralık 2016 ile 31 Mart 2017 tarihleri arasındaki belirlenen tezgâhlardan elde edilmiştir. Elde edilen sayaç verileri kullanılan performans ölçütlerinden üretim etkinliği formülü ile hesaplanarak üretim performans verilerine dönüştürülmüştür. Bu tarihler arasında günlük elde edilen verilerden 67 adet performans verisi bulunmaktadır.

### 3.3. AR ve ARIMA Modellerinin karşılaştırılması (Comparison of AR and ARIMA Models)

AR ve ARIMA modellerinin ne kadar sağlıklı, kullanılabilir olduğunu ve doğruluğunu test etmek için veri setindeki son 7 veri validasyon veri seti olarak ayrılmıştır. Yani 60 adet verinin ile AR ve ARIMA analizi ve tahminlemesi yapılmış elde edilen veriler 60. veriden itibaren validasyon için ayrılan 7 günlük veri setiyle karşılaştırılmıştır (Şekil 1). Bu karşılaştırmalar sonunda elde edilen MSE/RMSE verileri karşılaştırılmış ve daha uygun olan yöntem seçilmiştir.



Şekil 1. Dövme tezgâhının günlük ortalama performansı (Daily performance average of forging machine)

İlk olarak veri setine AR modeli uygulanmıştır. Tüm veri setinden ilk 60 adedi veri seti, son 7 adedi ise geçerlilik veri seti olarak belirlenmiştir. Veri hazırlanıp analize hazır hale getirildikten sonra hangi AR tahminleme modelinin en uygun olacağına karar verebilmek için test analizleri gerçekleştirilmiştir. Bu aşama da AR modelinin fark veri setine kaç adım geriden takip edeceğine karar verilmiştir. Bunun için veri setinin %66'sı kullanılarak gecikme AR(1) ile gecikme AR(9) arasındaki tüm modeller denenmiş ve her bir modelin test MSE (Ortalama Karesel Hata) ve

RMSE (Ortalama Karesel Hatanın Karekökü) değerleri hesaplanmıştır (Tablo 1).

Ortalama Mutlak Hata Formülü ([29],[30]):

$$MSE = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_t)^2$$


Kök Ortalama Mutlak Hata Formülü ([29],[30]):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}$$

Tablo 1. AR Modellerinin hata paylarının karşılaştırılması  
(Comparison of MSE and RMSE of AR model )

AR Model	Test MSE	Test RMSE
AR(1)	680.318	26.083
AR(2)	516.825	22.734
AR(3)	515.122	22.696
AR(4)	497.081	22.295
AR(5)	506.350	22.502
AR(6)	730.289	27.024
AR(7)	847.292	29.108
AR(8)	874.892	29.579
AR(9)	765.312	27.664
En iyi Sonuç: AR(4)	497.081	22.295

Sonuç olarak AR modelleri arasında en az hata payını veren AR(4) modeli seçilmiştir. Gözlemlenen veri ile tahminlenen verinin karşılaştırılması Şekil 2'de gösterilmiştir.



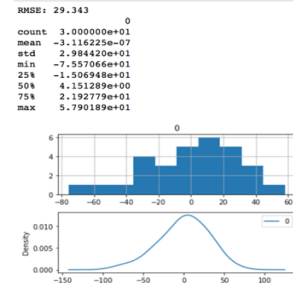
Şekil 2. Gözlemlenen veri ile tahminlenen verinin karşılaştırılması  
(Comparison of expected and predicted data)

Seçilen model veri setine uygulanarak tahminleme çalışmaları gerçekleştirilmiştir. Daha sonra 7 günlük geçerlilik setine karşılık gelen 7 günlük tahminleme verisi elde edilir (Tablo 2).

Tablo 2. AR(4) 7 günlük beklenen ve tahmin değerleri  
(AR(4) 7 days expected and predicted data)


Tahminlenen	Beklenen
109.402	117.222
121.675	155.382
159.675	89.270
93.675	94.257
98.675	107.580
112.675	152.64
157.675	135.113

AR modelinin sonuçları ortaya konduktan sonra aynı veri setine ARIMA modeli uygulanmıştır. Yine aynı veri seti 60 ve 7 adet olmak üzere ayrılmıştır. ARIMA modelinde p, d, q, olmak üzere 3 adet parametre kullanılmaktadır. Her bir parametre kombinasyonu için model değerlendirilecek ve bu %50 örneklemeyle yapılan analiz sonucunda her bir kombinasyonun MSE/RMSE değerleri hesaplanacaktır. En uygun parametre seçimi için grid search algoritması kullanılarak en düşük RMSE değerine sahip olan ARIMA (p, d, q) parametre kombinasyonu kullanılacaktır. Elde edilen sonuçlara göre RMSE:30.816 ile en iyi ARIMA (0,0,3) kombinasyonu çalışma kapsamında kullanılmak üzere seçilmiştir (Tablo 3). En uygun ARIMA modeli seçildikten sonra yapılacak olan bir diğer aşama ise veri setindeki artık tahmin hata payının hesaplanmasıdır. İdeal olarak artık hata payı Gauss dağılımının ortalamasının 0 olması beklenmektedir. Veri setimizi kullanarak elde ettiğimiz istatistikler doğrultusunda 0 olmasını beklediğimiz ortalama artık hata payı 9.415342'dir ve bu hata payı hata yoğunluk grafiğinde sağa kayma eğilimine neden olmaktadır. Çalışmanın geri kalanında yapılan tüm tahminlemeler bu hata payı göz önünde bulundurularak yapılmıştır. Her yapılan tahminlemeye hata payında elde edilen eğilim eklenerek kaydedilmiştir. Hata paylarının belirlenmesinde sonra eğilimli (biased) ARIMA modeli gerçekleştirilmiştir. Eğilimli ARIMA modeli ele alındıktan sonra veri setinin %50'si ile ARIMA(0,0,3) modelindeki RMSE'nin 30.816'dan 29.343'e düştüğü görülmüştür (Şekil 3). Böylelikle hata payı yoğunluğu grafiğinin merkez noktası 0'a oldukça yaklaşmıştır. Bu iyileştirme ile beraber 1.473'lük RMSE iyileştirmesini kullanmak için çalışma da eğilimli tahminleme modeli ile devam edilecektir.



Şekil 3. ARIMA (0,0,3) RMSE değerleri ve dağılımı  
(ARIMA (0,0,3) RMSE values and distribution)

Elde edilen ARIMA (0,0,3) modeli kullanılarak ileriye dönük 7 günlük tahminleme gerçekleştirilmiş ve 7 günlük validasyon seti ile karşılaştırılmıştır (Şekil 4). Gözlemlenen verilerin değerleri Tablo 4'te gösterilmiştir.




Şekil 4. ARIMA Modelinin tahmin ile geçerlilik verisi karşılaştırması  
(Comparison of ARIMA prediction and valid value)



Tablo 4. ARIMA(0,0,3) 7 günlük beklenen ve tahmin değerleri  
(ARIMA(0,0,3) 7 days expected and predicted values)

Tahminlenen	Beklenen
109.402	117.222
121.675	155.382
159.675	89.270
93.675	94.257
98.675	107.580
112.675	152.64
157.675	135.113

Son olarak AR ve ARIMA modellerinin sonuçları karşılaştırılmıştır. AR ve ARIMA veri setlerinden elde edilen modellerle yapılan 7 günlük 1 set tahminlemelerin 7 günlük validasyon setleriyle karşılaştırılmaları sonucunda elde edilen RMSE değerleri ve validasyon verisinin AR ve ARIMA tahminlemeleri ile karşılaştırılması şekil de görülmektedir. Sonuç olarak ARIMA yöntemi daha düşük RMSE hata payının daha düşük olduğu görülmüştür. Bu sebeple çalışma kapsamında tahminleme için ARIMA (0,0,3) modelinin seçimine karar verilmiştir.



Şekil 5. Mevcut veri, AR ve ARIMA modellerinin RMSE karşılaştırılması  
(Valid Data, AR and ARIMA models RMSE comparison)

Elimizdeki veri setini tahminleme için en uygun ARIMA modeli olan ARIMA(0,0,3) modelinde karar kılınmasının ardından elimizdeki verilerin tamamı kullanılarak bir model oluşturulup ileriye dönük bir tahminleme yapılacaktır. Analiz aşamasında validasyon seti olarak ayrılan 7 günlük veri bu sefer ayrılmamış, ARIMA(0,0,3) modelinin oluşturulmasında bu 7 günlük üretim verisi de veri setine eklenmiştir. Son olarak elde edilen MSE ve RMSE değerleri şu şekildedir.

Tablo 5. ARIMA(0,0,3) tüm veri modellemesi hata değerleri  
(ARIMA(0,0,3) all data models RMSE values)

ARIMA Model	Test MSE	Test RMSE
<b>Best:</b> <b>ARIMA(0,0,3)</b>	895.533	29.925

Beklendiği gibi validasyonlu modelde MSE değeri olarak 949.636 elde edilmişken, yeni modelde bu değer 895.533'e düşmüştür. Aynı şekilde RMSE değeri de 30.816'dan

29.925'e düşmüştür (Tablo 5). Bu da analizin daha çok veriyle tekrarlanması durumunda hata miktarını gösteren RMSE değerinin giderek azalacağını bir göstergesidir. ARIMA modeli bias değeri olan 5.793843 hesaba katılıp ARIMA(0, 0, 3) tekrardan modellenip hesaplandığında en iyi RMSE değeri 29.359 olarak iyileştirilmiştir. Bu model ile yapılan tahminleme sonucunda elde edilen performans değeri 105.391'dir. Bu tahmin değerinin doğruluğu, 7 günlük validasyon seti kullanılarak ARIMA (0,0,3) modeli ile yapılan çalışma sonucunda elde edilen (Şekil 5) tahminler ile aynı doğrulukta olduğu test edilmiştir. ARIMA modeli ile elde edilen yüzdelik performans tahmin değeri ve işletme içerisinde günlük üretilen adet, üretilen ürünün tonajı, ürünlerin adet başı tonajı, kalıp revizyon kritik duruş süreleri, bakım arıza sürelerinin her biri tek tek en uygun polinom uydurma yöntemi kullanılarak polinom bir denkleme dönüştürülmüştür. Polinom regresyon yöntemi ile iki değişkenin oluşturduğu dağılıma en yakın polinom denklemi oluşturularak veri dağılımı analiz edilmiştir. En iyi sonucu elde etmek için tüm denklemler 1. dereceden veri setinin maksimum değeri olan 67. dereceye kadar hesaplanmıştır. Elde edilen denklemler ile orijinal değerler karşılaştırılır ve RMSE ve Ortalama hata değerleri hesaplanıp grafik haline getirilmiştir.

Bu iki değer değişimini daha net görmek adına bu iki değer yüzdesel değişim oranları da hesaplanıp grafik haline getirilmiştir. Buna ek olarak en iyi ve en kötü RMSE değerleri ve MAPE değerleri hesaplanmış ve kaçınıcı derece denklem ile elde edildikleri belirtilmiştir.

Ortalama Mutlak Hata Formülü [31]:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left( \frac{|A_t - F_t|}{A_t} \right)$$

```

Start
x,y = getExcelData(ExcelDocument)
fittingRange = lenght(x)
for degree = 1 to fittingRange increase by 1 do:
  c = polyFitting(x,y,degree)
  for a = 0 to lenght(x) increase by 1 do:
    result = calculateEquationForDegree(c)
    resultList.Append(result)
  difference= calculateDifferenceToLastValue
  diffList.Append(difference)
  rmse = calculateRmse(y,resultList)
  avgError = calculateAverageError(y,resultList)
  perDegreeRmse.append(rmse)
  perDegreeAvgError.append(avgError)
plotGraphs()
End

```

Şekil 6. Polinom Regresyon Hesaplanması Algoritması  
(Algorithm of Polynomial Regression Calculation)

#### 4. DEĞERLENDİRME (EVALUATION)

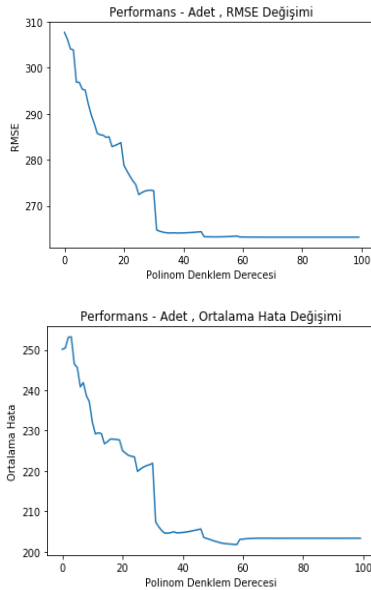
##### 4.1. Performans Değeri – Üretim Adeti (Performance Value – Production Amount)

67 adet performans ve üretilen adet verisi ile yapılan analizler sonucunda, elde edilen denklemlerin geçerlilik

hesaplamaları sonucu elde edilen MAPE değeri %17.7'ye, RMSE değeri ise %21'e kadar düşmüştür. RMSE ve ortalama hata payındaki en büyük değişim 30. derecede denklemde yaşanmıştır. Bu değişim hem RMSE ve ortalama hata değişimi grafiklerinden, hem de bu iki kriter için hesaplanan değişim oranı grafiklerinden görülebilmektedir. Bu noktadan itibaren yavaş bir şekilde de olsa bir iyileştirme devam etmektedir. En iyi sonuç ise beklenildiği gibi 67. dereceden denklemde elde edilmiştir. Yapılan analizlerde bu noktadan sonra elde edilen hata kriterlerinin iyileşmediğini, aksine kötüye gittiğini göstermektedir ve bu durum Şekil 7'deki grafiklerde görülmektedir.

Tablo 6. Performans Değeri ile Üretim Adedi arasındaki RMSE ve Ortalama Hata Oranları  
(RMSE and average error ratio between production amount with performance value )

Ortalama Performans	Ortalama Adet	Veri Adedi
106.65	1243.13	67
En Büyük Yüzdellik RMSE	En Küçük Yüzdellik RMSE	İyileştirme
%25	%21	%16
307.6 adet	263.1 adet	44.5 adet
1. Dereceden denklem	67. Dereceden denklem	
En Büyük Ortalama Hata	En Küçük Ortalama Hata	İyileştirme
253.2 adet	201.7 adet	51.5 adet
3. Dereceden denklem	58. Dereceden denklem	%20
MAPE		%17.7



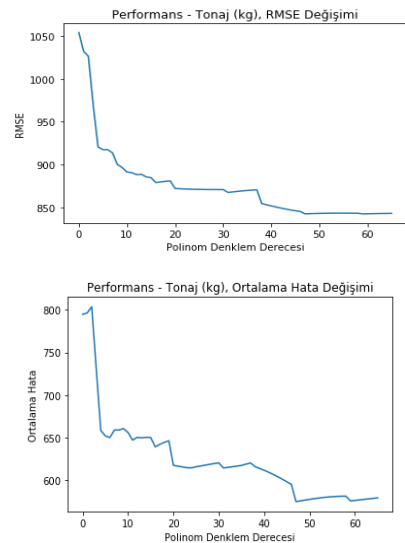
Şekil 7. Performans Değeri ile Üretim Adedi RMSE ve Ortalama Hata Değişim Grafiği  
(Average error and RMSE between performance value and production amount graphics)

#### 4.2. Performans Değeri – Tonaj (Performance Value - Tonnage)

Yapılan analizlerde RMSE yüzdelik oranının %17'den %14'e kadar düştüğü gözlemlenmiştir. 59. derecede elde edilen %14'lük RMSE oranı 1. Dereceden denklemde elde edilmiş olan RMSE hata payına göre %17,6'lık bir iyileştirme gerçekleşmiştir. Ortalama hata payları incelendiğinde ise 2. dereceden denklemde 803 ortalama hata saptanmışken 47. dereceden denklemde ortalama hata payı 573'e kadar düşmüştür. RMSE grafiği 37. dereceden ve 47. dereceden denklemlerde gözle görülür bir değişim gösterirken, ortalama hata grafiği 47. dereceden denklemde kayda değer bir değişim yaşamıştır. Bu noktadan sonra denklemler daha da karmaşıklaşsa da büyük bir avantaj elde edilememiştir. %9.53'e kadar inen MAPE diğer kriterlerle karşılaştırıldığında en olumlu sonucu vermiştir.

Tablo 7. Performans Değeri ile Üretim Tonaj değeri RMSE ve Ortalama Hata Oranları  
(Performance value with production tonnage value RMSE and average error ratio)

Ortalama Performans	Ortalama Tonaj	Veri Adedi
106.65	6217.75	67
En Büyük Yüzdellik RMSE	En Küçük Yüzdellik RMSE	İyileştirme
%17	%14	%17,6
1053 kg	842 kg	211 kg
1. Dereceden Denklem	59. Dereceden Denklem	
En Büyük Yüzdellik Ortalama Hata	En Küçük Yüzdellik Ortalama Hata	İyileştirme
803 kg	574 kg	229 kg
2. Dereceden Denklem	47. Dereceden Denklem	%30,8
MAPE		%9,53



Şekil 8. Performans Değeri ile Üretim Tonaj değeri RMSE ve Ortalama Hata Değişim Grafiği  
(Performance Value with Production Tonnage value RMSE and Error Value Interval Graph)

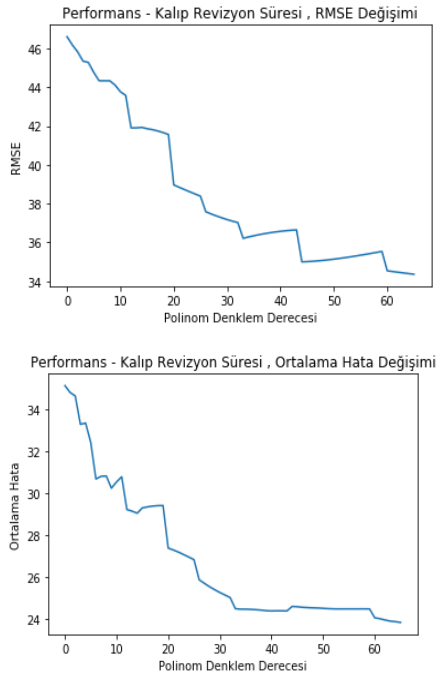
#### 4.3. Performans - Kalıp Revizyon (Tashih) (Performance – Mold Revision)

46 adet veri ile yapılan analizde RMSE yüzdelik oranı %42'ye kadar, ortalama hata da 73.8 dakika'ya kadar düşürülebilmektedir. Veri miktarının çok az olmamasına rağmen hata oranlarının bu şekilde yüksek kalması bu veri seti ile performans etkinliği arasında bir ilişki kurmayı ve ileriye dönük tutarlı tahminleme yapmayı mümkün kılmamıştır.

Tablo 8. Performans Değeri ile Kalıp Revizyon verisi RMSE ve Ortalama Hata Oranları

(Performance value with mold revision RMSE and average error ratio)

Ortalama Performans	Ortalama Kalıp Revizyon	Data Adedi
106.65	227.86	66
En Büyük Yüzdellik RMSE	En Küçük Yüzdellik RMSE	İyileştirme
%51	%42	%17.6
116.3 dk.	96.3 dk.	20 dk.
1. Dereceden denklem	65. Dereceden Denklem	
En Büyük Ortalama Hata	En Küçük Ortalama Hata	İyileştirme
95.7 dk.	73.8 dk.	11.3 dk.
1. Dereceden denklem	65. Dereceden denklem	%32
MAPE		%48,5



Şekil 9. Performans Değeri ile Kalıp Revizyon verisi RMSE ve Ortalama Hata Değişim Grafiği  
(Performance value with mold revision RMSE and Average Error Change)

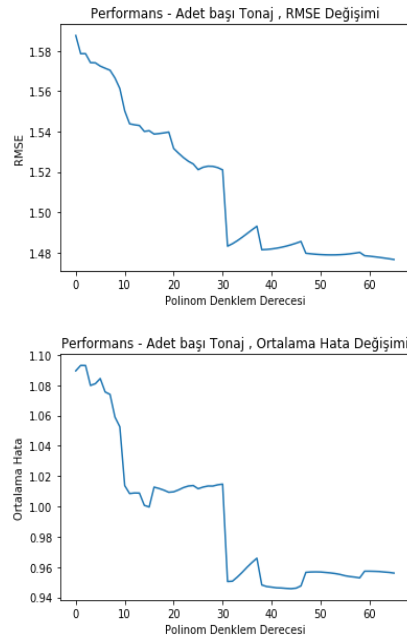
#### 4.4. Performans - Adet Başlı Tonaj (Performance – Weight per Piece)

67 Adet performans ve üretilen adet başlı tonaj verisi ile yapılan analizler sonucunda, elde edilen denklemlerin geçerlilik hesaplamaları sonucu elde edilen ortalama hata değerleri 1.09 kg'dan 0.94 kg'a, RMSE değeri ise %30'dan %28'e kadar düşmüştür. RMSE ve ortalama hata kriterlerindeki en büyük değişimler 30. dereceden denklemde yaşanmıştır. Bu noktadan itibaren yavaş bir şekilde de olsa bir iyileştirme devam etmektedir. En iyi sonuç ise RMSE'de 67. dereceden denklemden, ortalama Hata hesabında ise 46. Dereceden denklemde elde edilmiştir.

Tablo 9. Performans Değeri ile Adet Başlı Tonaj miktarı RMSE ve Ortalama Hata Oranları

(Performance Value and Quantity per ton RMSE values)

Ortalama Performans	Ortalama Adet	Data Adedi
106.65	5,28	67
En Büyük Yüzdellik RMSE	En Küçük Yüzdellik RMSE	İyileştirme
%30	%28	%6,7
1,58 kg	1,47 kg	0,11 kg
1. Dereceden denklem	65. Dereceden Denklem	
En Büyük Ortalama Hata	En Küçük Ortalama Hata	İyileştirme
1,09 kg	0,94 kg	0,15 kg
2. Dereceden Denklem	46. Dereceden Denklem	%14,3
Kalıp Revizyon Süresi Tahmini		53.90 (+/- 23.8) dk.
MAPE		% 18



Şekil 10. Performans Değeri ile Adet Başlı Tonaj miktarı RMSE ve Ortalama Hata Değişim Grafiği  
(Performance Value with Tonnage per amount RMSE and Average Error Change)



## 5. TARTIŞMA ve SONUÇ (DISCUSSION AND RESULT)

Talaşlı imalat sektöründe dövme makinelerinden elde edilen günlük tezgâh performans verileri zaman serileri analiz yöntemlerinden ARIMA (0,0,3) ile tahminleme gerçekleştirilmiştir. Elde edilen bu tahmini performans verisinden tezgâhlarda üretilen adet sayısı (%17.7), tonaj miktarı (%9.5), bakım-arıza süresi, kalıp revizyon süresi (%48), adet başı tonaj oranı (%18) hata oranlarında tahmin edilmiştir. Bu sonuçlar ile makine öğrenmesi yöntemi ile yüksek doğruluk oranında yine aynı tezgâhın tonaj miktarının, üretilen adet sayısının ve adet başı tonaj oranının tahmin edilebileceğini göstermektedir. Bunun yanında orta doğrulukta kalıp revizyon süresi tespit edileceği görülmektedir. Yetersiz veri sebebiyle bakım-arıza süresinin tahmin edilemediği fakat yeterli veri elde edilmesi durumunda bu verinin de tahmin edilebileceği görülmektedir. Geçmiş verilerden ertesi günün verilerinin tahmin edilmesi üretim tesisi için hayati öneme sahiptir. Örneğin bir tezgâhın ertesi gün kaç adet malzeme üreteceğini hatta kalıp revizyon süresinin önceden bilinmesi tesis müdürünün daha etkin karar almasını sağlamaktadır. Kalıp revizyon işlemi üretimin durdurulması anlamına gelmekte olup tesis içerisinde etkililiği azaltan bir durumdur. Ertesi günkü kalıp revizyon süresi önceden bilinmesi tesis yönetiminin bu durum için önceden önlem alması anlamına gelmektedir. Böylece tezgâhın kalıplarının hangilerinin olacağı bir gün önceden belirlenmiş olup ona göre tedarik edilmesi sağlanmıştır. Çalışmanın daha fazla veri ile gerçekleştirilmesi hem verinin doğruluğunun hata payını azaltabilir hem de bir günlük tahmin yapmak yerine yedi günlük tahminler yapılabilmesini sağlamaktadır. Tahminleme sırasında 7 günlük validasyon setinin model veri setine eklenmesiyle RMSE’de gerçekleşen 0.891’lik iyileşme (RMSE değeri 30.816’dan 29.925’e düşmüştür) (Tablo 5) bu yaklaşımın doğruluğunu ortaya koymaktadır. Bunu yanında yine tahmini performans verileri ile şirketin cirosu, maliyet, stok, çalışanların mesai ücreti ve saati gibi verilerin tahmin edilebilmektedir. Böylece yöneticilerin şirketin kısa ve orta vadeli olarak daha etkin karar verilmesini sağlayacak sonuçlar çıkarılabilmektedir.

## KAYNAKLAR (REFERENCES)

- [1] G. Schuh, T. Potente, C. Potente-Wesch, A. Weber, P. Prote, “Collaboration Mechanisms to Increase Productivity in the Context of Industrie 4.0”, *Procedia CIRP*, 19, 51-56, 2014.
- [2] B. H. Kang, T. H. Kim, G.Y. Kong, “A novel method for long-term time series analysis of significant wave height”, **16th Techno-Ocean Conference (Techno-Ocean)**, Kobe, Japonya, 6-8 Ekim 2016.
- [3] L. Luo, L. Luo, X.L. Zhang, “Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models”, *Bmc Health Services Research*, 17(469), 2017.
- [4] K. G. Boroojeni, M. H. Amini, S. Bahrami, S. S. Iyengar, Al. Sarwat, O. Karabasoglu, “A novel multi-time-scale modeling for electric power demand forecasting: From short-term to medium-term horizon”, *Electric Power Systems Research*, (142), 58-73, 2017.
- [5] H. Hassani, A. Webster, E. S. Silva, S. Heravi, “Forecasting US Tourist arrivals using optimal Singular Spectrum Analysis”, *Tourism Management*, 46, 322-335, 2015.
- [6] O. Kaynar, S. Taştan, “Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması”, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172, 2009.
- [7] G. Atsalakis, K.P. Valavanis, “Surveying Stock Market Forecasting Techniques – Part – I: Conventional Methods”, **Computation Optimization in Economics and Finance Research Compendium**, New York, ABD, 49-104, 2010.
- [8] H. Yeşilyayla, **X-12 ARIMA metoduyla sosyo-ekonomik verilerin analizi**, Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, 2013.
- [9] H. Kaur, S. Ahuja, “Time Series Analysis and Prediction of Electricity Consumption of Health Care Institution Using ARIMA Model”, **Proceedings of Sixth International Conference on Soft Computing for Problem Solving. Advances in Intelligent Systems and Computing**, (547) Springer, Singapore, 2017.
- [10] A. O. Solak, “Türkiye’nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin ARIMA Modeli ile Tahmin Edilmesi”, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 2013
- [11] O. Meçik, M. Karabacak, “ARIMA Modelleri İle Enflasyon Tahminlemesi: Türkiye Uygulaması”, *SÜ İİBF Sosyal ve Ekonomik Araştırmalar Dergisi*. 16(11), 2013.
- [12] A. Tortum, O. Gözcü, M. Y. Çodur, “Türkiye’de Hava Ulaşım Talebinin Arima Modelleri ile Tahmin Edilmesi”, *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 4(2), 39-54, 2014.
- [13] G. Altınay, “Aylık elektrik talebinin mevsimsel model ile orta dönem öngörüsü”, *Enerji, Piyasa ve Düzenleme*. 1(1), 1-23, 2010.
- [14] A. Z. Gürler, B. Ayyıldız, E. Gürel, H. G. Doğan, “Ekolojik Ekonomi Perspektifinden Sürdürülebilirliğin ARIMA Yaklaşımı ile Projeksiyonu ‘Bric Ülkeleri Ve Türkiye’”, **12. Tarım Ekonomisi Kongresi**, Isparta, Türkiye, 25-27 Mayıs 2016.
- [15] J. Sen, T. D. Chaudhuri, “A Predictive Analysis of the Indian FMCG Sector Using Time Series Decomposition-Based Approach”, *Journal of Economics Library*, 4(2), 2017.
- [16] O. Olofinu, A. Sulaimon, “Application of Time Series Analysis to Predict Reservoir Production Performance”, **Society of Petroleum Engineers Nigeria Annual International Conference and Exhibition**, Lagos, Nigeria, 5-7 August 2014.
- [17] L. Sanchez, G. Cabanas, Y. Abad, V. Torres, “Use Of ARIMA Models For Predicting Milk Production. Case Study in Ubpcc ‘Maniabo’”, Las Tunas”, *Cuban Journal of Agricultural Science*, 48(3), 2014
- [18] M. Z. Babai, A. A. Syntetos, “Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand: Theory and empirical analysis”, *International Journal of Production Economics*, 143(2), 463-471, 2013.
- [19] E. Cadenas, W. Rivera, R. Campos-Amezcuca, C. Heard, “Wind Speed Prediction Using a Univariate ARIMA Model and a Multivariate NARX Model”, *Energies*, 9(2), 2016.
- [20] C. N. Babu, B. E. Reddy, “A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data”, *Applied Soft Computing*, 23, 27-38, 2014.
- [21] M. A. Awal, M. A. B. Siddique, “Rice Production In Bangladesh Employing By Arima Model”, *Bangladesh Journal of Agricultural Research*, 36(1), 51-62, 2011.
- [22] S. Asadi, A. Tavakoli, S.R. Hejazi, “A new hybrid for improvement of auto-regressive integrated moving average models applying particle swarm optimization”, *Expert Systems with Applications*, 39(5), 5332-5337, 2012.
- [23] D. Tomić, S. Stjepanović, “Forecasting Capacity of ARIMA Models; A Study on Croatian Industrial Production and its Sub-sectors”, *Zagreb International Review of Economics & Business*, 20(1), 2017.
- [24] V. E. Tsitsika, C. D. Maravelias, J. Haralabous, “Modelling and forecasting pelagic fish production using univariate and multivariate ARIMA models”, *Fisheries Science*, 73, 979-988, 2007

- [25] T. C. Horngren, G. Foster, M. S. Datar, **Cost Accounting A Managerial Emphasis, Tenth Edition**, Prentice Hall International Inc., Londra, İngiltere, 2000.
- [26] S. Yükçü, G. Atağan, “Etkinlik, Etkililik Ve Verimlilik Kavramlarının Yarattığı Karışıklık”, *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(4), 2009.
- [27] G. E. P. Box, D. A. Pierce, “Distribution of Residual Autocorrelations in Autoregressive-Integrated Moving Average Time Series Models”, *Journal of the American Statistical Association*, 65(332), 1509-1526, 1970.
- [28] G. M. Ljung, G. E. P. Box, “On a measure of Lack of Fit in Time Series Models”, *Biometrika*, 65(2), 297-303, 1978.
- [29] M. H. Calp, “İşletmeler için Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi”, *Politeknik Dergisi*, 2019. DOI: 10.2339/politeknik.444380. (Basımda)
- [30] A. H. Gandomi, D. A. Roke, “Assessment of Artificial Neural Network and Genetic Programming as Predictive Tools”, *Advances in Engineering Software*, 88, 63-72, 2015.
- [31] A. Myttenaere, B. Golden, B. L. Grand, F. Rossi, “Mean Absolute Percentage Error for Regression Models”, *Neurocomputing*, 192, 38-48, 2016.