

# Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi

*Forecasting Amount of Export Demand with Artificial Neural Networks Method: A Comparative Analysis of ARIMA and ANN*

Mehmet KARAHAN<sup>1</sup>

## ÖZET

Karar verme zorunluluğunda olan tüm işletmeler, gelecekte mevcut durumlarını muhafaza etmek ve geliştirebilmek için gelecekteki olayları tahmin etmek ve iyi bir plan çerçevesinde uygun çözümler üretmek zorundadırlar. Tahminin amacı işletmelerin gelecekte karşılaşılabilecekleri durumları önceden öngörmek, çeşitli veri ve teknikleri kullanarak önceden önlemler alınmasını sağlamaktır. Bu bağlamda yapılan çalışmada, istatistiksel talep tahmin tekniklerinden yapay sinir ağı modeli kullanılarak, Malatya ili kuru kayısı ürününe ait ihracat miktarlarının tahmini uygulaması yapılmıştır. Uygulama sonrası yapılan hata testi sonuçları, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğunu göstermiştir.

**Anahtar kelimeler:** Üretim planlaması, Talep, Tahminleme, YSA

## ABSTRACT

Decision-making is the requirement of all businesses in the future to maintain and improve the existing situation to predict future events and are required to produce appropriate solutions within the framework of a good plan. The purpose of the forecast, businesses may face situations in the future to predict before, using different data and techniques to enable measures to be taken before. In this study, using artificial neural network model from statistical techniques to forecast demand, product of dried apricots belong to Malatya exports was applied to forecast demand. According to the results of the error test, the model is reliable and consistent.

**Keywords:** Production Planning, Demand, Forecasting, ANN

## GİRİŞ

Üretim, doğada var olan maddelerin insanların gereksinimlerini karşılayacak ürünler ve hizmetler haline dönüştürülmesi işlemidir (Mucuk, 1987; Çağlar, 2007). Üretim yönetimi ise en az maliyetle, belirli kalite düzeyinde, belirli miktarda ve zamanda, üretimi en iyi biçimde gerçekleştirecek kararların alınmasıdır. Üretim yönetiminin temel amacı, bu faktörler için en uygun değerlerin bulunmasıdır (Şahin, 1978; Mucuk, 2001). Üretim yönetimi fonksiyonlarının en önemlilerinden birisi planlama fonksiyonudur. Çünkü karar sürecinde hızlı olabilmek için, örgütün sistemlere ve planlamaya ihtiyacı vardır (Muhlemann vd., 1994).

Üretim planlaması yapılırken; üretimi yapılacak malın talep durumu dikkate alınarak, tüketicilerin istediği ürün özellikleri, fiyatı, kalitesi ve miktarıyla ilgili bilgiler toplanarak bu bilgiler doğrultusunda planlamalar yapılmalıdır (Tekin, 2009). Üretime geçişten önce, elde edilen bu bilgiler ışığında hazırlık çalışmaları yapılarak, üretimle ilgili tahmini maliyetler, ürün miktarları belirlenir. Bu tahmini talepler bilmeden işletmelerin herhangi bir planlama yapması mümkün değildir. Çünkü bu planlamaya göre ham-

madde, yedek parça, yarı mamul, makine, insan gücü ve yatırım ihtiyaçları belirlenmektedir.

Tahmin, gelecekte meydana gelebilecek olayların belli bir dönem için sonuçlarının hesaplanmasıdır. Bu hesaplamalar geçmişteki olaylardan elde edilen veriler değerlendirilerek yapılır (Bağırkan, 1982). İşletmeler hedeflerine ulaşabilmek için, ancak etkili bir tahmin yaparak en uygun kâr seviyesine ulaşabilirler. Bu yüzden Bolt, (1981) tahminler, işletme kaynaklarının "regülâtörüdür" demiştir.

Günümüzde talebi etkileyen faktörlerin çoğalması, bunlar arasındaki ilişkilerin karmaşıklığı, tecrübe ve sezgiye dayanan yöntemlerin yetersiz kalması, istatistikî metotlarla talep tahmin metotlarına başvurmayı zorunlu kılmıştır (Kobu, 1994). İstatistiksel metotlar; geçmişteki talep durumlarını, talebi etkileyen faktörleri ve ekonomik göstergeler ilişkilerini analiz ederek tahmin yapılmasına imkân sağlayan, gelecekte ortaya çıkması muhtemel gelişmelerin, planlamaların önceden yapılmasını mümkün kılan metotlardır (Tenkorong, 2006).

İstatistiksel metotların kullanımı sürecinde zamanla karmaşıklaşan problem durumlarının

<sup>1</sup> Dicle Üniversitesi, İİBF İşletme Bölümü Öğretim Üyesi

çözümü için, ihtiyaçları karşılayabilecek yeni metod arayışları ve bilgisayarlar üzerinde yapılan uzun süreli çalışmalar, insan beyninin modellenmesi ve yapay zekâ modelini yaşamımıza sokmuştur. Bunu izleyen çalışmalar, yapay sinir ağları adı verilen yeni bir alanı ortaya çıkarmıştır. Yapay sinir ağlarının doğrusal olmayan karmaşık problemlerin çözümünde etkin olarak kullanılması ve oldukça güvenilir sonuçlar sunması, günümüzde bu tekniğin kullanımını yaygınlaştırmıştır.

Literatürde yapay sinir ağları ile yapılan birçok tahmin çalışması mevcuttur. İşletmelerde yapılan tahmin çalışmaları ise, öncelikle finans ve ekonomi alanlarında yapılmış ve önemli sonuçlar elde edilmiştir. Bu tutarlı sonuçların olumlu referansı sayesinde YSA ile yapılan tahmin uygulamaları yaygınlaşmaya başlanmıştır. Bu uygulamalardan çalışma konusu ile ilgili olan bazıları aşağıda özetlenmiştir.

Kirby vd. (1997) otoyol trafik yoğunluğu tahmini, Gürbüz (2008) yolcu ve yük taşımacılığına olan talebi, Tsai vd. (2009) demiryolu taşımacılığına olan talebi, Yaşar (2009) otobüs ile yolcu taşımacılığına olan talebi, Hu (2002) iç turizme olan talebi, Çuhadar vd. (2009), dış turizm talebi, Yu vd. (2008) ve Kaynar vd. (2010) ham petrol fiyat tahminini, Jones, (2008) hastanelerin ilk yardım bölümlerine olan talebi, Kellova, (2008) kısa dönemli elektrik enerjisine olan talebi, Aksoy ve Dahamsheh (2009), yağış miktarlarının tahminini, Avcı (2009) IMKB-30 endeksi içinden seçilmiş bazı hisse senetlerinin günlük getirilerinin tahminlemesini, Asilkan (2009) ikinci el otomobillerin gelecekteki fiyatlarının tahminini, yapay sinir ağları metodunun kullanarak yapmışlardır. Bütün bu çalışmaların ortak sonuçlarına göre; YSA metodunun, diğer geleneksel metotlara göre daha iyi tahminlerde bulunduğu, diğer zaman serisi yöntemleri ile karşılaştırıldığında, bazı ön koşullar gerektirmemesi ve esnek bir modelleme yapısı olması nedeniyle daha üstün olduğu (Tosunoğlu ve Benli, 2012), geliştirilen YSA modellerinin veriler arasındaki doğrusal olmayan ilişkileri dahi öğrenerek genelleme yapabildiğini ve böylelikle daha önce hiç karşılaşılmayan sorunları bile kabul edilebilir hata sınırları içinde çözebildiği ifade edilmiştir.

## 2. YAPAY SİNİR AĞLARI

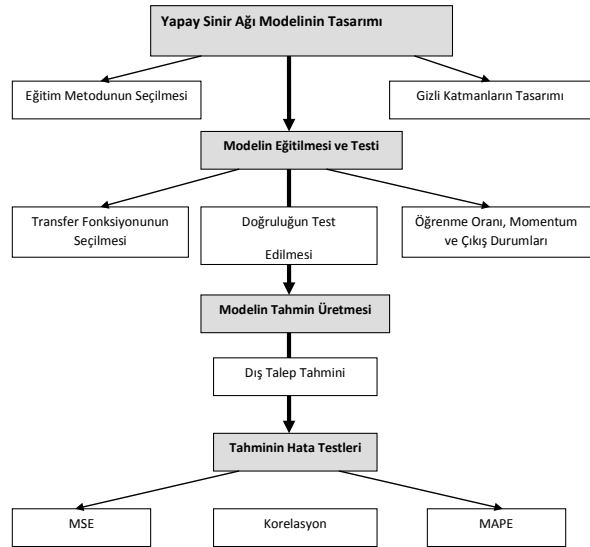
Yapay sinir ağları (YSA), insan beyninin özelliklerinden olan, öğrenme yolu ile yeni bilgiler üretebilme, çoğullama ve keşfedebilme gibi üstün yetenekleri, herhangi bir yardım almadan gerçekleştirebilen bir bilgisayar sistemidir (Öztemel, 2006). YSA, insan beyninin bilişsel öğrenme biçimine benzer bir şekilde, biyolojik nöron hücrelerini taklit eden, öğrendiklerini hafızasında saklayan, genelleme yapabilen, insani

özellikleri taklit edebilen, birlikte işleyen çok sayıda işlemci elemandan oluşan, bir bilgi işleme ve hesaplama sistemidir (Toktaş ve Aktürk, 2004; Whitby, 2005; Güngör, 2007; Çelik, 2008; Efendigil, 2008).

YSA, yöneylem araştırmasının inceleme sahalarna giren tahmin, modelleme, araç rotalama, gezgin satıcı problemi, kümeleme, sınıflandırma gibi birçok alandaki problemlerin çözümünde tercih edilen bir metottur. Önemli bir özelliği, doğrusal olmayan bir tahmin yöntemi olduğundan karmaşık verilerin modellenmesinde daha uygun sonuçlar üretebilmesidir (Ermış, 2005; Yu vd., 2008). Bu sistemlerin en önemli avantajları, öğrenme yetenekleri ve ortam değişikliklerine uyum sağlayabilme yetenekleridir (Hu, 2002). YSA, genel olarak tahminlerde, kümeleme çalışmalarında, yüksek oranlarda doğru olması istenen sınıflandırmalarda, gelecekte finansal bilgi manipülasyonuna başvuran şirketleri tahmin ederken ve sıra dışı karmaşık verilerin modellenmesinde kullanılmaktadır (Haykin, 1999; Ermış, 2005; Küçükkoçoğlu vd., 2007).

### 2.1. Yapay Sinir Ağı Modeli ile Tahmin Sürecinin Planlaması

YSA modeli ile talep tahmini sürecinde, sinir ağı modelinin tasarımı aşağıda Şekil 1'de görüldüğü gibi, aşamalı olarak gerçekleştirilmiş ve bu işlemler aşağıda şematik olarak açıklanmıştır.




Şekil 1. Yapay Sinir Ağı Modelinin Tasarım Süreci

### 2.2. Tasarlanan YSA Modelinin Tanımlanması

Bu çalışmada istatistiksel talep tahmin tekniklerinden yapay sinir ağı modeli kullanılarak, Dünya kuru kayısı üretiminde %97 paya sahip olan Türkiye'nin kuru kayısı ürününün dış talep miktarı tahmini yapılmıştır. Tasarlanan modelin; 5 girdi katmanı, 5 elemanlı

bir tek gizli katmanı ve bir çıktı katmanı vardır. Tasarlanan YSA modeli, ilgili yazında yaygın olarak kullanılan ileri beslemeli geri yayımlı bir sinir ağına sahiptir. Bu ağı tercih edilmesinin sebebi, hem doğrusal hem de doğrusal olmayan modellerdeki tahmin başarısı, kullanım kolaylığı ve yakınsama hızıdır. Yapılan bu çalışmada, YSA ile tahmin yapılırken tek dönemli iteratif metod kullanılmıştır. Model Alyuda ForecasterXL programı kullanılarak kurulmuştur. Aşağıda Şekil 2'de tasarlanan bu sinir ağının mimarisi gösterilmiştir.



Şekil 2. Tasarlanan Yapay Sinir Ağı Modelinin Mimarisi


Yukarıda Şekil 2'de mimarisi gösterilen YSA modelinin, tahmin işlemi için belirlenen ürün talep miktarını etkileyen beş değişkene ait dönemsel veriler, Ocak 2004 tarihinden Aralık 2010 sonuna kadar aylık olarak düzenlenmiştir. Modelin bağımlı değişkeni, kuru kayısı aylık ihracat miktarıdır. Bağımsız değişkenleri ise; geçmişte yapılan ihracat tarihleri, ABD dolarının aylık ortalama kur değerleri, kuru kayısı ihracat fiyatları, ihracat yapılan ülke (pazar) sayıları, mevsimsel etkilerin oluşturduğu zararların yüzdeleridir.

### 2.3. Yapay Sinir Ağının Eğitimi ve Testi

Tasarım, mimari ve programlama aşamaları gibi teknik kısımlardan sonra, sırasıyla modelin eğitimi ve testi aşamalarına geçilmiştir. Nöral sistemlerin eğitimi, uzun zaman alan ve dikkat edilmesi gereken en kritik noktalardan biridir. Bu aşamada, çalışmada ele alınan 5 seri ve 84 adet veriden rastgele seçilen 14 satırı test (%17), yine rastgele seçilen 70 satırı (%83) da eğitim seti olarak seçilmiştir. Bir başka ifadeyle, her bir serideki 84 değerden 70'er tanesi eğitim kümesine, 14'er tanesi ise test kümesine dâhil edilmiştir. Bu tür çalışmalarda, genellikle veri setinin yaklaşık % 80'ni eğitim, % 10'u geçerlilik ve son %10'luk kısmı ise test için ayrılmaktadır (Benli, 2005; Tosunoğlu ve Benli, 2012).

Ağın eğitimi için çevrimiçi geri yayılım algoritması kullanılmış, başlangıç öğrenim oranı ve momentum değerleri 0,1 olarak alınmıştır. Bu değerlerin seçimi için farklı başlangıç değerleri ile denemeler yapılmış ve sonunda bu değerlerde karar kılınmıştır. Prog-

ram her iterasyonda öğrenim oranı ve momentum değerlerini değiştirmek üzere ayarlanmıştır. Ağın başlangıç ağırlık değerleri yine program tarafından rastsal olarak atanmıştır. YSA modeli 5088 iterasyon yapılarak program tarafından eğitilmiş ve bu eğitime ilişkin sonuçlar Şekil 3'de gösterilmiştir. En iyi performansı veren ağırlık değerlerinin seçiminde, eğitim sonunda elde edilen doğrulama setinin hata değerleri kullanılmıştır. Aşağıdaki Şekil 3'de eğitim setinin 5088 iterasyon boyunca aldığı ortalama hata değerlerinin grafiği görülmektedir. Şekilde en düşük hata değerinin 1070'inci iterasyonda olduğu açıkça görülmektedir.



Şekil-3. Yapay Sinir Ağının Eğitimi

Eğitim aşamasından sonraki bir diğer önemli aşama test aşamasıdır. Test aşamasında, ilk önce eğitim aşamasında verilen değerlerin tamamı tekrar ağı sunulur. Böylelikle sinaptik ağırlıklar matrisi ve girdi değerleri ağı sunularak programın en az hata payı ile tahmin yapması amaçlanmıştır. Test aşamasında ise, algoritmanın gerçek sonuçlara yaklaşıp yaklaşmadığı denetlenir. Aşağıda Tablo 1'de eğitimi sırasında modelin yaptığı hata sonuçları gösterilmiştir.

Tablo 1. Sinir Ağı Eğitimi Hata Sonuçları

Mutlak Hata (AE)	681,77
Ortalama Hata Kareleri Toplamı (MSE)	1232907
İterasyon Sayısı	1070
Modelin Mimarisi	[5 - 5 - 1]
Modelin Öğrenme Algoritması	Online Geri Yayılımlı

Yukarıda Tablo 1'de ve Şekil 3'deki grafikte görüldüğü gibi, sinir ağı 1070'inci iterasyonda en küçük hata değerine ulaşmış (MSE=1232907) ve en iyi öğrenmeyi bu aşamada gerçekleştirmiştir. Şekil 3'deki grafikte görüldüğü gibi, 1070'inci iterasyondan sonraki tekraralarda hata oranı arttığından, bu noktada öğrenmenin tamamlandığını söylemek mümkündür. Yine bu grafikte, MSE hata değerinin en küçük olduğu noktanın 1070'inci satır olduğu açıkça görülmektedir. Hesaplanan korelasyon (ilgileşim) değerine (0,8875) göre, modelin açıklayıcılığının yüksek olduğu söylenebilir (Tekin, 2009: 242; Monks, 1996).

## 2.4. Tasarlanan YSA Modeli ile Tahmin Üretimi

Uygulamanın bu kısmında, tasarlanan YSA modelinin eğitim ve test aşamasından sonra, modelde ele alınan değişkenlerin Ocak 2004 ile Aralık 2010 dönemine ait değerleri baz alınarak, gelecekte gerçekleşmesi beklenen Ocak 2011 ile Haziran 2011 dönemine ait 6 aylık ihracat değerlerinin tahmin edilmesi aşamasına geçilmiştir. YSA modeline, tahminini yapmak istediğimiz gelecek dönemle ilgili veri girişleri yapılarak, modelden gelecek dönemle ilgili tahminler üretmesi istenmiştir. Tablo 2'de, Alyuda Forecaster XL programının belirlenen altı aylık dönem için ürettiği tahminler gösterilmiştir.

**Tablo 2:** Gelecek Altı Aylık Dönem İçin Üretilen Tahminler (Ton)

Tarih	Gerçekleşen Talep (f)	Tahmini Talep (x)
Ocak 2011	7.544	5.995
Şubat 2011	6.923	5.622
Mart 2011	7.280	5.391
Nisan 2011	5.450	5.058
Mayıs 2011	4.836	4.875
Haziran 2011	3.977	4.636

Modelin ürettiği değerler ile gerçekleşen tahmin değerlerinin karşılaştırıldığı ve aynı zamanda modelin performansını da görebileceğimiz Tablo 2'de görüldüğü gibi ilgili dönemde ürüne talep miktarı oldukça dalgalı olmasına rağmen, modelin ürettiği tahminler gerçekleşen talebe oldukça yakın olmuştur. Bu sonuçlara göre modelin tahminlerinin tutarlı olduğuna karar verilebilir. Ancak bu sonuçları test etmek için, ilgili yazında sıkça kullanılan aşağıdaki hata testleri yapılmıştır.

**Tablo 3:** Tahminin Hata Testleri Excel Çözümü

Tarih	Gerçekleşen Talep (f)	Tahmini Talep (x)	Sapma (e)	Yüzde Hata (p)	Mutlak Hata  p
Ocak 2010	6.429	6.418	-11	-0,0017	0,0017
Şubat 2010	6.597	6.177	-420	-0,0680	0,0680
Mart 2010	6.420	4.957	-1463	-0,2951	0,2951
Nisan 2010	5.935	4.828	-1107	-0,2293	0,2293
Mayıs 2010	4.401	4.378	-23	-0,0053	0,0053
Haziran 2010	3.728	3.994	266	0,0666	0,0666
Temmuz 2010	4.366	3.781	-585	-0,1547	0,1547
Ağustos 2010	8.471	8.752	281	0,0321	0,0321
Eylül 2010	9.792	9.592	-200	-0,0209	0,0209
Ekim 2010	12.332	12.752	420	0,0329	0,0329
Kasım 2010	10.354	11.767	1413	0,1201	0,1201
Aralık 2010	12.109	12.081	-28	-0,0023	0,0023

## 3. MODELİN ÜRETTİĞİ TAHMİNLERİN HATA TESTLERİ

Tahmin doğruluğunu ölçmek için kullanılacak birçok ölçüt bulunmaktadır. Bunlardan birisi olan basit hata terimi sapma  $e(t)$ , tahmin edilen değerler  $x(t)$  ile gerçekleşen değerler  $f(t)$  arasındaki fark alınarak hesaplanır ve aşağıdaki gibi formüle edilebilir (Bayır, 2006: 106).

$$e(t) = x(t) - f(t)$$

Sonra, tahminin yüzde hatasını  $p(t)$ , aşağıdaki formüldeki gibi hesaplayabiliriz.

$$p(t) = \frac{e(t)}{x(t)}$$

Daha sonra; YSA tahmin sonuçlarının tutarlılığını ölçmede yaygın olarak kullanılan hata ölçütlerinden; Ortalama Hata Kareleri (Mean Squared Error-MSE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error-MAPE) hesaplamaları Excel ortamında yapılmış ve sonuçları aşağıdaki Tablo 3'de gösterilmiştir.

$$MSE = \frac{1}{n} \sum [e(t)]^2$$

$$MAPE = \frac{1}{n} \sum |p(t)|$$

Yukarıda formülleri verilen hata hesaplamalarının Excel tablosu üzerinde yapılışı ve elde edilen sonuçlar aşağıdaki Tablo 3'de gösterilmiştir.

Aşağıda Tablo 3'te; gerçekleşen talep (f) miktarları, modelin yaptığı talep tahminleri (x), gerçekleşen ve tahmin edilen talep miktarları arasındaki sapma miktarları (e), yüzde hata (p) miktarı, mutlak hata  $|p|$  miktarları, ayrı sütunlarda gösterilmiştir.

Aşağıda Tablo 4’de model tarafından üretilen talep tahminlerine ait sapma ve güvenilirlik sonuçları bir yıllık dönem için gösterilmiştir.

**Tablo 4:** Tahminin Hata ve Güvenirlik Sonuçları

	Korelasyon	R <sup>2</sup>	MSE	MAPE
YSA	0,980	0,960	176904	0,086

Yukarıda Tablo 4’de görüldüğü gibi, YSA modelinin ürettiği tahmini talepler ile gerçekleşen talep arasındaki korelasyon 0,98 olarak hesaplanmıştır. Buna göre modelin açıklayıcılığı %98’dir. Giriş değişkenlerinin sonucu etkileme oranları ise (regresyon) değeri ise 0,96 olarak hesaplanmıştır. Hesaplanan her iki değer de oldukça iyi sonuçlar olduğu, yani modelin yaptığı tahminlerin tutarlı olduğu söylenebilir. Ayrıca sinir ağının yaptığı en küçük hata Ocak 2010 tarihinde yapılan tahminde olmuştur, bu noktada ortalama hata karesi (MSE) değeri de 176904 olarak hesaplanmıştır.

Yapılan tahminlerin doğruluğunu ölçmede yaygın olarak kullanılan bir yöntem de, Ortalama Mutlak Yüzde Hata (MAPE) istatistiğidir. Literatürde, MAPE istatistiğinin tahmin hatalarını yüzde olarak ifade etmesinden dolayı tek başına da bir anlam taşıması, uygulamada diğer yöntemlere göre daha çok kabul görmesine neden olmaktadır (Akgül, 2003). Çalışmada, MAPE değeri 0.086 olarak hesaplanmıştır. Bu sonuçlara göre, YSA modelinin yapmış olduğu tahmin değerlerinin eğitim ve test aşamalarının her ikisinde de güvenilir ve tutarlı olduğu ifade edilebilir.

#### 4. YSA VE ARIMA MODELLERİ TARAFINDAN YAPILAN TAHMİNLERİN KARŞILAŞTIRILMASI


Çalışmanın bu kısmında, YSA ve geleneksel zaman serisi metodlarından Otoregresif Bütünleşik Hareketli Ortalamalar (ARIMA) metodunun yaptığı talep tahminleri karşılaştırılarak, performansları değerlendirilmiştir. Her iki modelin 2004 ile 2010 yılları arasındaki, yedi yıllık yani 84 aylık dönem için yaptıkları tahminler esas alınarak karşılaştırmalar yapılmıştır. Aşağıda, Tablo 5’de ilgili dönem için gerçekleşen talep miktarları ve iki modele ait talep tahminleri karşılaştırmalı olarak gösterilmiştir.

**Tablo 5:** YSA ile ARIMA Modelinin Yaptığı Tahminlerin Karşılaştırılması

Tarih	Gerçekleşen	YSA	ARIMA
30.01.2010	6589	6207	8229
25.02.2010	6762	6844	4902
30.03.2010	6581	9200	8318
30.04.2010	6083	5869	7031
30.05.2010	4511	4406	5458
30.06.2010	3821	4297	4369
30.07.2010	4474	4147	5083
30.08.2010	8682	10442	8962
30.09.2010	10036	10264	9422
30.10.2010	12640	10833	11412
30.11.2010	10612	10508	10864
30.12.2010	12412	12305	11867
30.01.2011	-	10267	8082
25.02.2011	-	9910	7942
30.03.2011	-	10290	7904
30.04.2011	-	11011	7917
30.05.2011	-	10256	7886
30.06.2011	-	10249	7681

Yukarıda, Tablo 5’de 18 aylık dönem için gerçekleşen talep miktarları ile Yapay Sinir Ağı ve ARIMA modeli tarafından tahmin edilen talep miktarları görülmektedir. Görüldüğü gibi, her iki modelin ürettiği talep tahmin değerleri birbirine oldukça yakın olmasına karşın, hassasiyet ve gerçeğe yakınlık anlamında yapay sinir ağları daha yakın değerler tahminlemiştir.

Aşağıda Şekil 4’deki grafikte ise, belirlenen bu talep miktarlarının karşılaştırmaları görsel olarak yapılmıştır.



**Şekil 4:** YSA ve ARIMA Modelinin Yaptıkları Tahminlerin Karşılaştırılması

Yukarıda Şekil 4’de, gerçekleşen talep değerleri ile iki farklı modelin tahmin performanslarının karşılaştırıldığı grafik incelendiğinde; gerçekleşen talep değerleri ile yapay sinir ağları modeli tarafından yapılan tahmin değerlerinin birbirine çok yakın olduğu görülmektedir. Yine,

grafik incelendiğinde gerçekleşen talep değerleri ile ARIMA modelinin yaptığı tahminlerin, yapay sinir ağı modeline göre gerçekleşen talepten biraz daha uzakta olduğu görülmektedir. Yapılan bu görsel tespitler, aşağıda Tablo 6'daki hesaplanan değerlerle de desteklenmektedir.

**Tablo 6:** Tahmin Hatasının Doğruluk Ölçütleri Karşılaştırması

Tahmin Metodu	Korelasyon	R <sup>2</sup>	MSE	MAPE
YSA	0,8653	0,7418	880347,8	0,151
ARIMA	0,7486	0,0560	0,0476	0,233

Yukarıda, Tablo 6 ve Şekil 4'de görüldüğü gibi, YSA modeli, ARIMA modeline göre daha iyi tahmin üretmektedir. Yine, YSA modelinin açıklayıcılığı %86, ARIMA modelinin açıklayıcılığı %75 olarak hesaplandığından, YSA modelinin açıklayıcılığı daha yüksektir denilebilir. Tüm bu sonuçlara göre; YSA modelinin yapmış olduğu tahminlerin daha tutarlı ve gerçeğe yakın olduğu söylenebilir.

Ayrıca, yapılan hata testleri sonucunda YSA modelinin MAPE hata değeri 0.151, ARIMA modelinin MAPE değeri 0.233 olarak hesaplanmıştır. İlgili yazında, MAPE değerleri % 10'un altında olan tahmin modelleri "yüksek doğruluk" derecesinde, % 10 ile % 20 arasında olan modeller ise "doğru" tahmin modelleri olarak sınıflandırılmaktadır (S.F. Witt ve C. Witt, 1992). Benzer şekilde Lewis, 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 (Lewis, 1982; Çuhadar vd., 2009).

Uygulama sonucunda elde edilen değerlere göre, YSA modelinin, ARIMA modelinden daha az tahmin hatası yaptığı görülmektedir. Yukarıda Tablo 6'da görülen değerler karşılaştırmalı olarak incelendiğinde, kuru kayısı talep tahminini yapmak üzere tasarlanan yapay sinir ağı modelinin tahmin performansının, ARIMA modeline göre daha yüksek olduğuna ve yapay sinir ağı modeli tarafından yapılan tahminlerin geçerli ve güvenilir olduğuna karar verilmiştir.

## SONUÇ VE ÖNERİLER

Yapay sinir ağılar metodu, sosyal bilim alanlarında tahmin modellemesinde kullanılan en yeni yöntemlerden birisidir. Ancak Türkiye'deki çalışmalar dünya literatürüne göre çok fazla değildir. Artık ülkemizde de araştırmacıların bu metot üzerinde yoğunlaşmaları ve bu metot ile birçok konuda çözümler geliştirmeleri, ülkemiz bilimine önemli katkılar sağlayacaktır. Bunun ötesinde, daha yeni mimarilerin geliştirilmesi, bulanık mantık ve genetik algoritmalar yardımıyla yapay sinir ağılar metodunun daha da iyileştirilmesi bilim adamlarımıza ileride yepyeni ufuklar açabileceklerdir.

Çalışmada, tahmin modellemesi için yapay sinir ağıları modeli seçilmiş ve bu amaç doğrultusunda yapay sinir ağıları teorisi detaylı bir şekilde incelenmiştir. Uygulama kısmında ise, çalışma için uygun bulunan bir yapay sinir ağı modeli kullanılarak, kuru kayısı talep tahmini için bir model geliştirilmiştir. Bu modelde, tahmin çalışmalarında en çok kullanılan, doğrusal olmayan problem durumlarında başarılı sonuçlar üretebilen, yakınsama hızı yüksek olan ileri beslemeli geri yayılım ağı kullanılmıştır. Kurulan modelin kendi içinde değerlendirilmesi ve performans testleri yapılmıştır. Yapılan bu test sonuçlarına göre, modelin yaptığı tahminlerin güvenilir ve tutarlı olduğu görülmüştür. Uygulamada aşırı eğitime, hatalı mimari gibi problemlerin oluşmaması durumunda, modelinin tahmin gücünün yüksek, geleneksel ve ekonometrik modellere göre daha iyi performans sergilediği gözlenmiştir.

YSA modelleri, mevsimsel etkiler yansıtılmamış olsa bile diğer modellerden üstün performans sağlamakta, ek olarak mevsimsel etkilerin yansıtılması durumunda da performansını daha da artırmaktadır. Yapılan bu uygulamada da yapay sinir ağılarıyla tasarlanan model, geleneksel zaman serileri metodlarından ARIMA metodu ile karşılaştırılmış, elde edilen sonuçlar, ilgili yazında ve Benli (2005)'in yaptığı YSA-Lojistik regresyon modeli karşılaştırmasında da olduğu gibi YSA'nın lehine oldukça olumlu olmuştur. Çalışmadan elde edilen veriler sayesinde, Malatya ilindeki üreticiler bir sezon önceden üretim planlamalarını sağlıklı bir şekilde yapabilecek ve yapacakları yatırımlar için önceden öneriler geliştirebileceklerdir.

Çalışma sürecinde, araştırma sonuçlarının yararlılığını ve genelleştirilmesini sınırlayan bazı kısıtlayıcılar tespit edilmiştir. Bunlardan en önemlisi, tarım ürünleri üretim miktarlarının, satış fiyatı ve miktarlarının, ihracat fiyatı ve miktarlarının tek elden ve düzenli bir kayıt sisteminin olmayışından kaynaklanan sağlıklı veri elde etme zorluğudur. Araştırma sırasında bu kısıtın ülke genelinde, hatta yurt dışında dahi tarım ürünlerine has genel bir kısıt olduğu tespit edilmiştir. Çalışmanın diğer kısıtı ise, ihracatçı firmaların aralarındaki rekabet sebebiyle sattıkları ürün fiyatını, iade edilen ürün miktarı hakkında bilgi vermekten kaçınmalarıdır.

Karşılaşılan bazı sınırlılıklar ve çalışma boyunca karşılaşılan soruların zamanla giderilmesi, ilgili kayıtların daha sağlıklı ve sistematik bir şekilde tutulması, ileride yapılacak çalışmalarda daha da yararlı olabilecek, fiyat tahminlemesi, üretim miktarı tahminlemesi, her yıl satılmayıp stoklarda tutulan ürün miktarının tahminlemesi gibi konularda da yeni çalışmalar yapılabilecektir. Ayrıca, çalışmanın ileride yapılacak araştırmalara yol gösterici bir kaynak rolü oynayacağı da ümit edilmektedir.

## KAYNAKLAR

- Akgül, Işıl (2003). Zaman Serilerinin Analizi ve ARIMA Modelleri, Der Yayınları, İstanbul s. 138.
- Aksoy, Hafzullah ve Dahamsheh, Ahmad (2009). Artificial neural network models for forecasting monthly precipitation in Jordan, *Stock Environ Res Risk Assess* (2009) 23: 917-931.
- Asilkan, Özcan ve Irmak, Sezgin (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2) 2009: 375-391.
- Avcı, Emin (2009). Yapay Sinir Ağları Modelleri İle Hisse Senedi Getiri Tahminleri, Marmara Üniversitesi *İktisadi ve İdari Bilimler Fakültesi Dergisi*, 26(1) 2009: 443-461.
- Bağırkan, Ş. (1982) *İstatistiksel Analiz*, Önsöz Basım ve Yayıncılık, İstanbul
- Bayır, F. (2006) "Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama" Yayınlanmamış Yüksek Lisans Tezi, İstanbul, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Benli, Yasemin Keskin (2005). Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon ve Yapay Sinir Ağı Karşılaştırması, Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi Sayı: 16, ss. 31-46.
- Bolt, G.J. (1981) *Market and Sales Forecasting, A Total Approach*, Second Edition, London, Kogan Page Limited.
- Çağlar, T. (2007) "Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması" Yayınlanmamış Yüksek Lisans Tezi, Kırıkkale, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü.
- Çelik, B. (2008) "YSA Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama" Yayınlanmamış Yüksek Lisans Tezi, İstanbul, Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Çuhadar, Murat, Güngör, İbrahim ve Göksu, Ali (2009). Turizm Talebinin Yapay Sinir Ağları ile Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1) 2009: 99-114.
- Çuhadar, Murat; Güngör, İbrahim; Göksu, Ali (2009). Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri ile Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1): 99-114.
- Efendigil, T. (2008) "Müşteri Odaklı Sistemler için YSA ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı" Yayınlanmamış Doktora Tezi, İstanbul, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Efendigil, T., Önüt, S., ve Kahraman, C. (2009) "A decision support system for demand forecasting with artificial neural networks and neuro-fuzzy models: A comparative analysis" *Expert Systems with Applications*, 36(2009): 6697-6707.
- Ermiş, M. (2005) "Lojistik Sistemlerinin Yapay Sinir Ağları ile Modellenmesi, Gerçeklenmesi ve Kontrolü", Doktora Tezi, İstanbul, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Güneri, Nuray ve Keskin Benli, Yasemin (2012), "Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü", Ege Akademik Bakış Dergisi, Cilt: 12, Ekim 2012, Sayı 4: 541-547.
- Güngör, E. (2007). Yapay Sinir Ağları Yardımı İle Makine Arızalarının Önceden Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü.
- Gürbüz, Tolga (2008). *Yapay Sinir Ağları Yaklaşımıyla Türkiye'deki Ulaştırma Talebinin Tahmini*, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- Haykin, S. (1999). *Neural Networks: A Comprehensive Foundation*, Second Edition, New Jersey, Prentice-Hall.
- Hu, C. (2002). *Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling*, Doktora Tezi, Purdue University, MI, USA.
- Jones, Spencer S. (2008). *Measuring, Modeling, and Forecasting Demand in The Emergency Department*, Doktora Tezi, The University of Utah, USA.
- Kaynar, O., Taştan, S. ve Demirkoparan, F. (2010) "Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini", *Ege Akademik Bakış*, 10(2): 561-575.
- Kellova, Andrea (2008). *Statistical Approach to Short-Term Electricity Forecasting*, Dissertation (Doktora Tezi), Charles University, Prague.
- Kirby, Howard R., Watson, Susan M. and Dougherty, Mark S. (1997). Should we use neural networks or statistical models for short-term motorway traffic forecasting? *International Journal of Forecasting*, 13 (1997) 43-50.
- Kobu, B. (1994). *Üretim Yönetimi*, 8. Baskı, İstanbul, Avcıol Basım-Yayım.
- Küçükkoçoğlu, Güray, Benli, Yasemin Keskin ve Küçüksözen, Cemal (2007). Finansal Bilgi Manipülasyonunun Tespitinde Yapay Sinir Ağı Modelinin Kullanımı, *İMKB Dergisi*, Cilt: 9, Sayı: 36.

Lewis, Colin D. (1982). *Industrial and Business Forecasting Methods*. Butterworths Publishing: London, 1982, s. 40

Monks, J.G. (1996) *İşlemler Yönetimi Teori ve Problemler*. (Çeviren: Sevinç Üreten), Ankara, Nobel Yayın Dağıtım.

Mucuk, İ. (1987) *Modern İşletmecilik*, 3. Basım, İstanbul, Türkmen Kitabevi.

Mucuk, İ. (2001) *Temel İşletme Bilgileri*, 1. Basım, İstanbul, Türkmen Kitabevi.

Muhlemann, A., Oakland J. and Lockyer, K. (1994) *Production and Operations Management*, 6th Edition, London, Pitman Publishing.

Öztemel, E. (2006) *Yapay Sinir Ağları*, 2. Baskı, İstanbul, Papatya Yayıncılık.

Stephen F. Witt ve Christine Witt (1992). *Modeling and Forecasting Demand in Tourism*. Academic Press: London, s. 137

Şahin, M. (1978) *Üretim Yönetiminde Simülasyon Analizi ve Uygulaması*, Eskişehir, İktisadi ve Ticari İlimler Akademisi Yayınları No:194/124.

Tekin, M. (2009) *Üretim Yönetimi Cilt 1*, 6. Baskı, Konya, Günay Ofset.

Tenkorang, F.A. (2006) "Projecting World Fertilizer Demand in 2015 and 2030", Yayınlanmamış Doktora Tezi, USA, Purdue University, West Lafayette, Indiana.

Toktaş, İ. ve Aktürk, N. (2004) "Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulamaları", *Makine Teknolojileri Elektronik Dergisi*, 2004(2): 7-20.

Tosunoğlu, Nuray Güneri ve Benli, Yasemin Keskin (2012). Morgan Stanley Capital International Türkiye Endeksinin Yapay Sinir Ağları ile Öngörüsü, *Ege Akademik Bakış*, Cilt: 12, Sayı: 4, ss. 541-547.

Tsai, Tsung-Hsien; Lee, Chi-Kang and Wei, Chi-en-Hung (2009). Neural network based temporal feature models for short-term railway passenger demand forecasting, *Expert Systems with Applications*, 36(2009) 3728-3736.

Whitby, B. (2005) *Yapay Zekâ Yeni Başlayanlar İçin Kılavuz*, (Çeviren: Çiğdem Karabağlı), İstanbul, İletişim Yayınları.

Yaşar, Ahmet Bora (2009). *Kent içi Otobüs Taşımacılığında Talep Tahmini*, Yüksek Lisans Tezi, Pamukkale Üniversitesi Fen Bilimler Enstitüsü, Denizli.

Yu, Lean; Wang, Shouyang and Lai, Kin K. (2008). Forecasting crude oil price with an EMD-based neural network ensemble learning paradigm, *Energy Economics*, 30(2008): 2623-2635.