

TÜRKİYE’NİN GSYİH TAHMİNİ İÇİN YAPAY SİNİR AĞLARI MODEL PERFORMANSLARININ KARŞILAŞTIRILMASI*

Hasan SÖYLER** ve Oktay KIZILKAYA***

Özet

Bir ülkenin gelecek yıllara ait makroekonomik değişkenlerinin tahminleri, karar vericiler için ekonomi politikaların oluşturulmasında önemli bir role sahiptir. Bu çalışmada; son yıllarda tahmin modellemesinde sıklıkla kullanılan yapay sinir ağları modeli yardımı ile ekonomik büyüme değişkeni GSYİH'nın tahmini yapılması amaçlanmıştır. Ekonomik büyüme için; Çok Katmanlı Algılayıcı (ÇKA), Radyal Tabanlı Fonksiyon Ağları (RTFA) ve geri dönüşümlü Elman Ağı kullanılarak kendi gecikmeli değerlerine göre tahminler elde edilmiştir. Kullanılan YSA mimarilerinin tahmin performansları incelendiğinde 4 girdi katmana sahip RTFA modelinin en yüksek doğruluğu sağladığı görülmüş ve bu model yardımıyla 2013Q4:2014Q4 dönemleri için ekonomik büyüme oranı tahminleri üretilmiştir. Elde edilen sonuçlar yapay sinir ağlarının ekonomik büyüme tahmininde kullanılabilecek başarılı bir yöntem olduğunu göstermiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Zaman Serisi, Ekonomik Büyüme

Artificial Neural Networks Models Performance Comparisons For Turkey's GDP Forecasting

Abstract

Estimates of economic growth for the coming years in a country has an important role in determining business plans for business entities and fiscal policies formulation for governments. In this study, It was intended to estimate the GDP of economic growth variable with the help of artificial neural networks models which have often been used in estimation modelling recently. For the economic growth estimation were obtained according with its own delayed values by using Multiple Layer Perception (MLP), Radial Basis Function Networks (RBFN) and Recurring Elman Networks. When the estimation performances of the used artificial neural network structures were analyzed, it was seen that RBFN model having 4 input layers got the highest accuracy and through this model estimates of economic growth were produced for 2013Q4 and 2014Q4 periods. The obtained results showed that artificial neural networks were a successful method to be used in the estimates of economic growth.

Key Words: Artificial Neural Networks, Time Series, Economic Growth

* Bu makale, 22-25 Mayıs 2014 tarihleri arasında Süleyman Demirel Üniversitesi tarafından düzenlenen 15. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu'nda sözlü bildiri olarak sunulan "Türkiye'de Ekonomik Büyümenin Yapay Sinir Ağları Modelleri ile Tahmini" adlı çalışmanın genişletilmiş halidir.

**Yrd. Doç. Dr., İnönü Üniversitesi İİBF, Ekonometri Bölümü, Malatya, hasan.soyler@inonu.edu.tr


***Araş Gör., Hakkari Üniversitesi, İİBF, Maliye Bölümü, Hakkari, o.kizilkaya.4@gmail.com

GİRİŞ

Çok sayıda finansal ve ekonomik karar, ekonomik büyüme beklentilerine bağlıdır. Enflasyon oranı, gayri safi yurt içi hâsıla (GSYİH), işsizlik oranı gibi birçok ekonomik gösterge ekonominin ne kadar iyi olduğunun ve gelecekte ne kadar iyi olacağını göstermektedir (Huang vd., 2007:127). Ekonomik büyüme, bir ülkede üretilen mal ve hizmetlerin artmasına neden olan ekonomideki faaliyetlerin geliştirilmesi olarak tanımlanabilir (Sukirno, 2008:9). Bir ülkenin ekonomisini değerlendirmek için kullanılan ölçütler milli gelir ya da GSYİH'dır. GSYİH bir dönemde, bir ülkede üretime devam eden kendi vatandaşları ve yabancı ülke vatandaşları tarafından sahip olunan üretim faktörleri dâhil üretilen tüm nihai mal ve hizmetlerin piyasa değeridir (Liliana ve Napitupulu, 2012:410-411). Bir ülkede yaşayan bireylerin refah düzeyleri ülkenin üretim kapasitesine ve üretim kapasitesinin zaman içerisindeki artışına, yani ülkenin ekonomik büyüme oranına bağlıdır. Ekonomi politikası analizlerinde ve öngörü modellerinde ekonomik aktivite ve gelir düzeyinin ölçütü olarak genelde GSYİH değişkeni kullanılır (Kaplan ve Tekeli, 2008:83).

Türkiye, küresel ekonomik krizden en hızlı çıkan ülkelerdendir. 2003-2013 döneminde Türkiye ekonomisi yıllık ortalama %5 oranında büyümüştür. Tablo 1'de Türkiye'nin 2003-2013 dönemi yıllık büyüme oranları verilmiştir.

Tablo 1. Türkiye'nin Yıllık Büyüme Oranları



Kaynak: TÜİK, 2013

Zaman serisi analizleri, geçmişte ortaya çıkan verileri kullanarak, gelecekteki değerler hakkında tahminler ve politikalar oluşturma teknikleridir. Zaman serisi analizinde birçok yöntem mevcuttur ve her yöntemin kendine göre avantajı ve dezavantajı vardır. Yapay sinir ağları, zaman serisi problemlerinde yeni nesil bir yöntem olarak kullanılmaktadır. Özellikle veri içinde örüntü tanımlama

özellikleri sayesinde zaman serileri için kısa dönemli tahminler oluşturmada başarılı uygulamaları vardır (Kubat, 2013:669). YSA ile zaman serisi tahmininde, girdiler veri serisinin geçmiş gözlemlerinden oluşurken, çıktı gelecekteki tahmin değeridir. Yani tahmin edilmek istenen dönem değeri çıktı nöronunda, geçmiş gözlem değerleri ise girdi nöronlarında temsil edilmektedir (Hamzaçebi, 2011:96). Zaman t ile ifade edilirse, çıktı değeri y_t ve geçmiş gözlem değerlerinden oluşan girdi değerleri $(y_{t-1}, y_{t-2}, y_{t-3}, \dots)$ olmak üzere $y_t = f(y_{t-1}, y_{t-2}, y_{t-3}, \dots)$ fonksiyonunun tahmin edilmesi ile zaman serisi tahminleri elde edilebilir.

YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir önbilgiye ihtiyaç duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir. Bu sebeple YSA, tahmin aracı olarak diğer yöntemlere göre daha genel ve esnek (Zhang vd., 1998:36). YSA, güçlü bir modelleme tekniği olarak finansal ve ekonomik tahminlerde yaygın olarak kullanılır. YSA ile veri seti içinde yatan fonksiyonel ilişkileri algılama ve örüntü tanıma, sınıflandırma, değerlendirme, modelleme, tahmin ve kontrol gibi işlevler gerçekleştirebilir (Huang vd., 2007:115).

Box-Jenkins yöntemi de tek değişkenli zaman serileri analizinde sıklıkla kullanılan bir yöntemdir. Bu yöntem $AR(p)$ (otoregresif), $MA(q)$ (hareketli ortalama), $ARMA(p,q)$ (otoregresif hareketli ortalama) ve $ARIMA(p,d,q)$ (bütünleşik otoregresif hareketli ortalama) modelleri arasından en uygun modeli seçerek tahmin yapmak amacıyla kullanılır.

Literatürde konu ile ilgili yapılan çalışmalardan Tkacz (2001), 1968Q1-1999Q2 dönemi için üç aylık verileri kullanarak Kanada'da GSYİH büyümesi için yaptığı çalışmada $ARIMA$ modelleri, Lineer modeller ve YSA modellerini karşılaştırmış ve YSA'nın özellikle uzun dönem tahminlerinde daha iyi sonuçlar verdiğini sonucuna ulaşmıştır (Tkacz, 2001:57-69).

Junoh (2004) çalışmasında, Malezya ekonomisinin GSYİH tahmini için YSA ve ekonometrik yaklaşımları karşılaştırmış ve YSA'nın daha iyi sonuç verdiği sonucuna ulaşmıştır (Junoh, 2004:39-50). Benzer şekilde Düzgün (2008), Türkiye'de 1987Q1:2007Q3 dönemleri için GSYİH tahmininde ve modellemesinde YSA ve $ARIMA$ modellerini kullanmıştır. Elde edilen sonuçlara göre GSYİH tahmininde $ARIMA$ modeli ile, YSA modelinden daha başarılı sonuçlar elde edilmiştir (Düzgün, 2008:165-176).

Liliana ve Napitupulu (2012), Endonezya için GSYİH tahmininde YSA yöntemini kullanmışlardır. Yazarlar makroekonomik göstergelerin tahmininde YSA modeli ile elde edilen tahminlerin, hükümet tarafından yayınlanan tahminlere göre daha iyi olduğu sonucuna varmışlardır (Liliana ve Napitupulu, 2012:410-415). Mirbagheri (2010), İran için GSYİH büyüme tahmininde Bulanık Mantık ve Sinirsel Bulanık Mantık yöntemleri kullanarak tahmin sonuçlarını karşılaştırmıştır.

Yazar sonuç olarak Sinirsel Bulanık Mantık yöntemi ile daha iyi sonuçlar elde etmiştir (Mirbagheri, 2010:925-929).

Bir ülkenin gelecek yıla ait ekonomik büyüme tahminleri, ticari kuruluşlar için iş planlarının belirlenmesinde ve hükümetler için mali politikaların oluşturulmasında önemli role sahiptir. Ekonomik büyüme tahmini için literatürde çeşitli zaman serileri teknikleri kullanılmıştır. Bu çalışmada, diğer zaman serisi teknikleri gibi ön koşullar gerektirmemesi ve belirli bir model kalıbının olmaması nedeniyle tahmin problemlerinde sıklıkla tercih edilen Yapay Sinir Ağları modelleri kullanılmıştır. Literatürde ekonomik veriler kullanılarak YSA ile yapılan çalışmalarda ağırlıklı olarak ÇKA modeli kullanılmıştır. Bu çalışmada ise ÇKA modeline ek olarak RTFA ve Elman Ağı modelleri kullanılarak bu modellerin ekonomik büyüme oranı tahmin performansı incelenmiştir. Ayrıca, yapay sinir ağı tekniğinin tahmin başarısını karşılaştırabilmek amacıyla ekonometride yaygın olarak kullanılan yöntemlerden olan Box-Jenkins yöntemi kullanılmış ve elde edilen sonuçlar tahmin performansı başarı ölçütleri çerçevesinde karşılaştırılmıştır.

I. YAPAY SİNİR AĞLARI

YSA, temelde bağlantılı işlem elemanlarının bir problemi çözmek için beraberce çalışması temeline dayanan, girdi ve çıktı arasındaki örüntüyü bulmak için insan beynini taklit etmeye çalışan bir tekniktir. Yapay sinir ağları, biyolojik sinir ağları ile ortak özelliklere sahip bir bilgi işleme sistemidir. Sinir ağı, nöron adı verilen çok sayıda basit işlem elemanının bir araya gelmesi ile oluşur. Her nöron, diğer nöronlarla ağırlıklandırılmış bağlantılar aracılığıyla bağlanmıştır (Fausett, 1994:3) YSA'nın; iş tahmini, kredi puanlama, tahvil değerlendirme, iş başarısızlığı tahmini, tıp, örüntü tanıma ve görüntü işleme gibi doğrusal olmayan fonksiyon formdaki parametrik olmayan verilerde etkin bir araç olduğu kanıtlanmıştır (Liliana ve Napitupulu, 2012:410).


YSA'nın geleneksel istatistik tekniklere göre en önemli avantajları daha az varsayıma sahip olması ve aktivasyon fonksiyonlarının seçimine bağlı olarak doğrusal olmayan ilişkileri modelleyebilmesidir. Olayları öğrenerek benzer olaylar karşısında mantıklı kararlar verebilirler. YSA eğitildikten sonra, veriler eksik bilgi içerse dahi, çıktı üretebilirler. Bilgiler ağıın tamamında saklanır ve yapay sinir hücrelerinin bazılarının işlevini yitirmesi, bilginin kaybolmasına neden olmaz. Bununla beraber YSA'nın avantajlarının yanında bazı dezavantajları da vardır. YSA'da kullanıcıya bağlı olarak değiştirilebilir parametre çok fazladır ve uygun ağ yapısının belirlenmesinde belli bir kural yoktur. Aktivasyon fonksiyonunun türü, gizli katman sayısı ve bu katmanlarda bulunacak nöron sayılarının belirlenmesi deneme yanılma yolu ile belirlenmektedir. Ağıın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belirli bir kural da yoktur. Ağıın hatasının belirli bir değerin altına inmesi eğitimin tamamlandığı anlamına gelmektedir.

Ayrıca ağın davranışları açıklanamamaktadır ve bu durum ağa olan güveni azaltmaktadır.

A. ÇOK KATMANLI ALGILAYICI

Günümüzde en çok bilinen ve yaygın biçimde kullanılan yapay sinir ağı Çok Katmanlı Algılayıcı (ÇKA) yöntemidir. Genel amaçlı, esnek ve çoklu katmanlar halinde organize edilmiş nöronlardan oluşan ve birçok fonksiyonu tahmin etme özelliğine sahip doğrusal olmayan modellerdir. ÇKA eğitiminde birçok öğrenme algoritmasının kullanılabilir olmasından dolayı yaygın olarak kullanılan bir yöntemdir. ÇKA, girdi katmanı, bir veya birden fazla gizli katman ve çıktı katmanından oluşan ileri beslemeli sinir ağıdır. Bir katmandaki her nöron, bir sonraki katmanın bütün nöronları ile bağlantılıdır ve girdi katmanından çıktı katmanına doğru ileri yönlü bir iletişim mevcuttur. Eğitim sırasında ağa, hem girdiler hem de bu girdilere karşılık gelen çıktı değerleri gösterildiği için öğretmenli öğrenme stratejisine göre çalışırlar. ÇKA'nın öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş hali olan Genelleştirilmiş Delta Kuralı (Backpropagation)'dır. Genelleştirilmiş Delta Kuralı iki aşamadan oluşur. 1. aşamada, ileri doğru hesaplama vardır ve ağa gösterilen örnek seti için ağın çıktısı hesaplanır. 2. aşamada ise geriye doğru hesaplama vardır ve bu aşamada ise ağın bağlantı ağırlıkları güncellenir. Kullanılan öğrenme algoritmasına göre, ağın çıktısı ile beklenen çıktı arasındaki hata geriye doğru yayılarak hata minimuma düşüncüye kadar ağın ağırlıkları güncellenmektedir. Şekil 1' de 2 gizli katmana sahip bir ÇKA modeli görülmektedir.

Şekil 1. İki Gizli Katmana Sahip ÇKA



B. RADYAL TABANLI FONKSİYON AĞLARI

Radyal Tabanlı Fonksiyon Ağları (RTFA), biyolojik sinir hücrelerinde görülen etki-tepki davranışlarından esinlenilerek geliştirilmiştir. Çok boyutlu uzayda eğri uydurma yaklaşımı olan RTFA, ÇKA'nın aktivasyon fonksiyonu

olarak radyal temel işlevini kullanan özel bir halidir. RTFA, radyal tabanlı fonksiyon kullanımı sebebiyle ÇKA'dan daha hızlı eğitilirler (Zhang vd., 2013:4) Bir RTFA'nın çalışma ilkesi, girdi gizli katmanda uygun genişlik ve merkez değerlerine sahip radyal tabanlı fonksiyonları belirleyerek, çıktı katmanında bu fonksiyonların ürettiği çıktıların uygun ağırlık değerleriyle doğrusal birleşimlerini oluşturup girdi-çıkıtı arasındaki ilişkiyi belirleme süreci olarak açıklanabilir (Kaynar vd., 2010:565). Girdi katmanı, gizli katman ve çıktı katmanı olmak üzere toplam üç katmandan oluşmaktadır. Ağın girdi katmanı doğrudan gizli katmana bağlanmıştır ve bundan dolayı sadece gizli katman ile çıktı katmanı arasında ağırlıklar mevcuttur. Radyal tabanlı fonksiyon ağı tek gizli katman bulundurur ve gizli katman nöronlarında aktivasyon fonksiyonu olarak radyal tabanlı fonksiyonlar kullanılır. En yaygın olarak kullanılan radyal tabanlı fonksiyon Gauss fonksiyonudur. Gauss temelli fonksiyonlar ile bir RTFA'nın çıktısı Denklem 1 yardımıyla hesaplanabilmektedir.

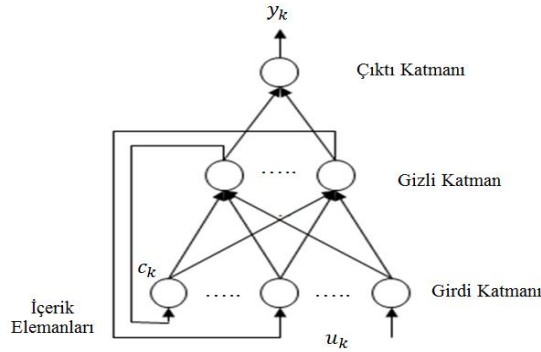
$$y_i = \sum_{i=1}^h W_i \exp\left(-\frac{1}{2\sigma^2} \|x_p - c_i\|\right) \quad (1)$$

Bu denklemde, x_p ağın p . girdi örneğidir. p radyal taban fonksiyon sayısı, c_i temel fonksiyon merkezi, σ temel fonksiyonların yayılımı, W_i ise gizli ve çıktı katmanları arasındaki bağlantı ağırlıklarıdır. RTFA'da c_i temel fonksiyon merkezi ve σ temel fonksiyonların yayılımı ve W_i gizli ve çıktı katmanları arasındaki bağlantı ağırlıkları olmak üzere ana parametrelerin ağın eğitim algoritmasında tahmin edilmesi gerekmektedir (Zhang vd., 2013:5).

C. ÖZYİNELEMELİ ELMAN AĞI

Daha önce anlatılan ÇKA ve RTFA modellerinde gelen bilgiler girişten çıkışa doğru ileri beslemeli olarak iletiliyordu. Elman Ağı ise çıkışların, giriş birimlerine veya önceki gizli katmanlara geri beslendiği bir ağ yapısıdır. Ağa gelen bilgiler, hem ileri hem de geri yönde aktarılır. Elman ağı, çok katmanlı algılayıcı ağının öğrenme kuralı olan genelleştirilmiş delta öğrenme kuralına göre öğrenmektedir. Elman ağının; girdi elemanları, gizli katman elemanları, çıktı elemanları ve içerik (context) elemanları olmak üzere 4 çeşit elemanı vardır. Elman Ağında, ÇKA'dan farklı olarak içerik tabakası yer almaktadır. Elman Ağı'nın mimari yapısı Şekil 2'de gösterilmiştir.

Şekil 2. Elman Ağı'nın Yapısı



Elman Ağı'nın girdi elemanları dış dünyadan bilgileri alır ve gizli katmanlara iletirler. Çıktı elemanları ise ağıın çıktısını dış dünyaya iletirler. Çıktı ünitelerinin bilgi işleme fonksiyonları doğrusaldır. Gizli katman elemanları ise hem doğrusal hem de doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları gizli katman elemanlarının önceki aktivite değerlerini hatırlamak için kullanılmaktadır. Bu elemanlar bir önceki iterasyondaki aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşırlar (Öztemel, 2003:166)

II. UYGULAMA VE BULGULAR

Bu çalışmada 1988Q1 – 2013Q3 dönemlerine ait Türkiye için ekonomik büyüme (GSYİH) verileri kullanılmıştır. Veriler, Dünya Bankası web sayfasından temin edilmiştir.

Box-Jenkins yönteminde uygun modeli seçebilmek için öncelikle serinin durağan olup olmadığı araştırılmalıdır. Ekonomik büyüme serisinin birim kök içerip içermediğini belirlemek amacıyla AugmentedDickey Fuller (ADF) birim kök testi kullanılmıştır. Elde edilen test değerleri Tablo 2'de sunulmuştur.

Tablo 2. ADF Birim Kök Testi Sonuçları

Değişken	Test İstatistikleri	Kritik Değer			Olasılık
	ADF	(%1)	(%5)	(%10)	
gsyih	-3.793[4]	-3.498	-2.891	-2.582	0.004

Tablo 2'den izlenebileceği gibi ADF test istatistiği sonuçlarına göre, analizde kullanılan gsyh (ekonomik büyüme) serisinin düzey değerinde birim kök içermediği yani serinin durağan olduğu sonucuna ulaşılmıştır. Sonraki aşamada serinin kolegramına bakılarak serinin AR(p), MA(q) veya ARMA(p,q) süreçlerinden hangisine uyduğuna karar verilmelidir. Serinin düzey değerinde kolegram görüntüsü incelendiğinde, otokorelasyon fonksiyonu üstel olarak azalırken kısmi otokorelasyon fonksiyonu 5. gecikme noktasından sonra kesintiye uğrayarak sıfırlanmaktadır. Kurulan AR(5) modelinin kolegram örüntüsü

incelendiğinde otokorelasyon sorununun olmadığı ve istatistiki olarak anlamlı olduğu sonucuna ulaşılmıştır Bundan dolayı AR (5) sürecine sahip modelin seçilmesine karar verilmiştir.

YSA için GSYİH zaman serisinin ilk 92 değeri (1988Q1-2010Q4) eğitim, son 11 değeri (2011Q1- 2013Q3) ise test için kullanılmıştır. Kullanılan YSA modellerinde aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır. Sigmoid aktivasyon fonksiyonu yalnızca (0,1) aralığında değerler üretebildiği için girdi setleri (0,1) aralığında normalleştirilmiştir. Öğrenme işlemi bittikten sonra, normalleştirilen veriler ters işlem ile orijinal haline dönüştürülmüştür.

Çalışmada üç farklı YSA yapısı (ÇKA, RTFA, Elman Ağı) kullanılarak hangi yöntemin daha az hata ile tahminde bulunduğu belirlenmesi ve Box-Jenkins yöntemi ile karşılaştırılması amaçlanmıştır. Test işlemi sonucunda bulunan tahmin değerleri, gerçek değerlerle karşılaştırılmış, Ortalama Mutlak Yüzde Hata (MAPE) ve Hata Kareleri Ortalaması (MSE) dikkate alınarak modellerin tahmin performansları karşılaştırılmıştır. Serinin t zamandaki değerinin geçmiş kaç gözlem değerinden etkilendiğini belirlemek için girdi nöron sayısı 1'den 8'e kadar değiştirilmiştir.

Kurulan ÇKA modelleri etkin yakınsama tekniğinden dolayı Levenberg-Marquardt öğrenme algoritması ile eğitilmiştir. Modellerde tek gizli katman kullanılmış ve gizli katmanda farklı nöron sayıları denenerek en düşük MAPE değerini veren ağ yapısı 4-4-1 olarak bulunmuştur. ÇKA'nın en düşük hata değerine sahip tahmin performansları Tablo 3'de verilmiştir.

Kurulan Elman Ağı modelleri, ÇKA modellerinde olduğu gibi Levenberg-Marquardt öğrenme algoritması ile eğitilmiştir. Modellerde tek gizli katman kullanılmış ve gizli katmanda farklı nöron sayıları denenerek en düşük MAPE değerini veren ağ yapısı 5-10-1 olarak bulunmuştur. Elman Ağı'nın en düşük hata değerine sahip tahmin performansları Tablo 4'de verilmiştir.

Tablo 3.ÇKA için en düşük MAPE değerine sahip ağ yapıları

Girdi Katmanındaki Nöron Sayısı	Gizli Katmandaki Nöron Sayısı	MAPE
2	4	33,13
2	5	36,62
3	6	37,73
4	4	27,08
4	8	32,05
5	10	32,51
5	11	33,09
6	6	32,31
6	12	28,64
8	16	29,48

Tablo 4.Elman Ağı için en düşük MAPE değerine sahip ağ yapıları

Girdi Katmanındaki Nöron Sayısı	Gizli Katmandaki Nöron Sayısı	MAPE
3	6	30,92
3	7	28,33
4	4	32,78
4	8	28,33
4	9	28,31
5	5	26,45
5	10	21,99
5	11	26,86
6	6	25,46
8	16	30,60

RTFA için ağı eğitimi modellerine ait yayılma parametreleri(0.1- 2.0) arasındaki değerler 0.1 artırılarak, deneme yanılma yoluyla belirlenmiştir. Gizli katmandaki nöron sayıları ise veri sayısına eşitlenerek her bir örnek veri seti aynı zamanda merkez vektör olarak kullanılmıştır.Kurulan RTFA modellerinde girdi katman nöron sayısının 4 olduğu model en iyi mimariye sahiptir. RTFA için en düşük hata değerine sahip tahmin performansları Tablo 5’de verilmiştir.

Tablo 5.RTFA İçin En Düşük MAPE Değerine Sahip Ağ Yapıları

Girdi Katmanındaki Nöron Sayısı	2	3	4	5	8
MAPE	33,18	34,88	21,35	38,98	34,81

Her bir ağ yapısı için en iyi performansı veren modellerin ve AR(5) ile bulunan sonuçların karşılaştırılmaları için MAPE ve MSE kriterlerinden faydalanılmış ve sonuçlar Tablo 6’da verilmiştir.

Tablo 6.Modellerin Karşılaştırılması

Model	Girdi Katmanındaki Nöron Sayısı	MAPE	MSE
ÇKA	4	27,08	8,0217
RTFA	4	21,35	4,6312
Elman Ağı	5	21,99	7,6923
AR(5)	-	33,17	7,0118

Tablo 6’da görüldüğü gibi, ekonomik büyümenin tahmini amacıyla denenen yapay sinir ağı modelleri içerisinde en başarılı tahmin performansı sergileyen yöntem, 4 girdi nöron sayısına sahip RTFA modelidir.İlgili modele ait hata değerlerini temsil eden MAPE ve MSE değerleri sırasıyla % 21,35 ve 4,63 bulunmuş ve bu değerlerin kullanılan modeller içerisinde en düşük hata düzeyine sahip olduğu görülmüştür.Tablo 6’da dikkat çeken bir diğer nokta ise;MAPE değerleri dikkate alındığı zamanAR modelinin, YSA modellerine göre, en kötü tahmin performansını sergilediği belirtilebilir.Analizde kullanılan modellerin

tahmin değerleri ve gerçek değerleri Tablo 7’de sunulmuş, ayrıca Şekil 3’te verilmiştir.


Tablo 7 incelendiğinde, Türkiye Ekonomisi için “güçlü ekonomiye geçiş programının” uygulanmaya başlandığı 2001 yılından itibaren çeyrek dönemler göz önüne alındığı zaman, 2011Q1 döneminde en büyük büyüme rakamlarından biri kaydedilmiştir. İlgili çeyrek dönemde büyüme rakamının büyük olmasında; 2008 ekonomik krizinden sonra ekonomiyi canlandırma adına Keynesyen makroekonomik politikaların uygulanması (vergi indirimleri, kamu harcamalarının artırılması vb.) ve baz etkisi önemli rol oynamıştır. 2011Q1 döneminde ekonomik büyümenin gerçekleşen değeri 12,4 iken tahmin değerleri; ÇKA için 3,9, RTFA için 5,7 ve Elman Ağı için 3,5 bulunmuştur. 2011Q1 örneğinde görüldüğü gibi en iyi tahmin sonucu RTFA modelinde gerçekleşmiştir. Bu dönemdeki gerçek değer ve tahmin değerleri arasındaki dikkate değer fark Şekil 3’de açıkça görülmektedir.

Tablo 7. Modellerin Tahmin Değerleri

Tarih	Gerçek Değer	ÇKA	RTFA	Elman Ağı	AR(5)
2011Q1	12,4236	3,9927	5,7877	3,5975	4,1490
2011Q2	9,3034	6,5130	9,2622	8,2307	10,0180
2011Q3	8,7447	6,9949	8,5527	9,0283	9,9269
2011Q4	5,2617	5,2187	7,2103	6,0736	5,4574
2012Q1	3,1298	2,1424	3,9168	2,6918	2,4572
2012Q2	2,7835	1,6450	1,9082	2,3461	3,4944
2012Q3	1,5358	1,4769	1,3642	1,5109	2,3872
2012Q4	1,4009	2,2066	1,7359	1,9214	3,1518
2013Q1	2,9671	2,9430	2,5433	2,1054	3,0098
2013Q2	4,5267	4,4172	3,5180	2,6774	3,6439
2013Q3	4,3501	6,1871	4,9421	4,4492	5,4396

2011 ve 2012 yılları bir bütün olarak incelendiğinde; büyüme rakamlarında istikrarlı bir azalma kaydedilmiş ve bu rakamlar tahmin edilen modellerde de teyit edilmiştir. 2013 yılında ise tahmin edilen modellerde büyüme rakamları gerçek değerlere paralel olarak artış göstermiştir. Yine tahmin modelleri içerisinde gerçek değerler ile en tutarlı modelin RTFA modeli olduğu görülmüştür. Modellerin tutarlılığının testi için seçilen 2011Q1-2013Q3 dönemi tahmin modellerinde sonuçların gerçek değerlere paralel olması, tahmin sonuçlarının güvenilirliği hakkında olumlu fikir verdiği ifade edilebilir.

Şekil 3. Gerçek ve Tahmin Değerleri Grafiği



Tablo 8’de ise en iyi sonucu veren 4 girdi nöron sayısına sahip RTFA kullanılarak, 2013Q4-2014Q4 dönemleri için bulunan ekonomik büyüme oranı tahminleri verilmiştir.

Tablo 8.2013Q4-2014Q4 Dönemleri Tahmin Değerleri

Tarih	2013Q4	2014Q1	2014Q2	2014Q3	2014Q4
Tahmin Değerleri	5,13	3,63	4,26	3,34	4,74

Tablo 8 incelendiğinde 2013 yılının son çeyreği için ekonomik büyüme oranı 5,13 olarak tahmin edilmiştir. Yine tablodan Türkiye’nin 2014 yılı ekonomik büyüme oranı 3,99 olarak tahmin edilmiştir.

SONUÇ

Yapılan çalışmada, ekonomik büyüme oranlarının tahmininde ÇKA, RTFA ve Elman Ağı olmak üzere üç farklı YSA modeli ve Box-Jenkins yöntemi ile elde edilen otoregresif model kullanılmış, hangi modelin daha başarılı olduğu araştırılmıştır. Çalışmada kullanılan YSA modellerinin, Box-Jenkins yöntemi ile elde edilen otoregresif modele göre öğrenme, herhangi bir ön bilgiye ve varsayıma ihtiyaç duymadan doğrusal olmayan ilişkileri başarı ile modelleyebilme gibi avantajları vardır. Bununla beraber YSA ile kurulacak ağın yapısının belirlenmesinde ve parametrelerin seçiminde belirli bir kuralın olmaması,

değiştirilebilir parametre sayısının çok fazla olması ve ağıın davranışlarının açıklanamaması gibi dezavantajları da bulunmaktadır. Örneğin, Otoregresif model parametreleri Box-Jenkins yöntemiyle belirlenirken, YSA modellerinde ki girdi birim sayısı deneme yanılma yoluyla belirlenmiştir. Kullanılan YSA modellerinde girdi nöron sayısı ÇKA ve RTFA için 5, Elman Ağı için 4 olarak, Box-Jenkins ile elde edilen AR modelinin p parametresi ise 4 olarak elde edilmiştir. Tang ve Fishwick (1993:381), çalışmalarında YSA ile yapılan tek değişkenli zaman serisi modeli için girdi birim sayısının Box-Jenkins modelindeki AR parametresi p'nin derecesine eşit alınması gerektiğini ifade etmektedir. Bu çalışmada elde edilen sonuçlara göre kurulan modellerdeki girdi birim sayısı 4 ve 5 olarak elde edilmiş ve AR parametresine oldukça yakın değerler bulunmuş olup bu sonuç, Tang ve Fishwick'in görüşünü desteklemektedir.

Yöntemlerin tahmin performansları incelendiğinde 4 girdi katmana sahip RTFA ile yapılan ekonomik büyüme tahminlerinin, hem ÇKA ve Elman ağı yapıları ile elde edilen tahminlerden hem de Box-Jenkins yöntemi ile elde edilen otoregresif modelin tahminlerinden daha başarılı olduğu sonucuna ulaşılmıştır. Bu model yardımıyla 2013Q4: 2014Q4 dönemleri için ekonomik büyüme oranı tahminleri üretilmiştir. En başarılı performansla sahip RTFA ile 2013 yılının son çeyreğinde Türkiye'nin ekonomik büyüme oranı 5,13 olarak, 2014 yılı için ise 3,99 olarak tahmin edilmiştir. Literatürde konu ile ilgili yapılan çalışmalarda genellikle ÇKA yapısının tercih edildiği görülmektedir. Bu çalışmada literatürden farklı olarak RTFA ve Elman Ağı olmak üzere 2 farklı ağ yapısı daha kullanılmıştır. Literatürde yaygın olarak kullanılan ÇKA'nın aksine RTFA modelinin daha iyi sonuçlar verdiği bulgusuna ulaşılmıştır. Çalışmanın, Türkiye'nin ekonomik büyüme oranını ÇKA, RTFA ve Elman Ağı gibi üç farklı YSA yapısı ile modelleyen ve ileriye yönelik tahminler üreten sınırlı sayıdaki çalışmadan bir tanesi olduğu söylenebilir.

Sonuç olarak, zaman serilerinin tahmininde uygun ağ yapısı belirlenerek kurulan yapay sinir ağları diğer istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabilir. Ekonomik büyüme değişkeni makroekonomideki birçok değişkenle yakın ilişkide olduğu için, ekonomik büyüme oranının başarılı bir şekilde tahmininin yapılması diğer makroekonomik değişkenlere uygulanabilirliği açısından oldukça önemlidir. Elde edilen sonuçlar yapay sinir ağlarının ekonomik büyüme tahmininde kullanılabilecek başarılı bir yöntem olduğunu göstermiştir. Bulunan tahmin değerleri gelecek ekonomik politikaların belirlenmesinde oldukça önemli olduğu için, politika yapıcıların farklı çalışmalardaki tahminleri göz önünde bulundurarak makroekonomik politikalara yön vermeleri daha uygun olacaktır.

KAYNAKÇA

- DÜZGÜN, Recep (2008), “A Comparison of Artificial Neural Networks and ARIMA Models Success in GDP Forecast”, Marmara Üniversitesi İ. İ. B. F. Dergisi, Cilt.XXV, Sayı. 2, 2008, s. 165-176.
- ERİLLİ, N. Alp; Erol EĞRİOĞLU; Ufuk YOLCU; Ç.Hakan ALADAĞ ve V.Rezan USLU (2010), “Türkiye’de Enflasyonun İleri ve Geri Beslemeli Yapay Sinir Ağlarının Melez Yaklaşımı İle Öngörüsü”, Doğu Üniversitesi Dergisi, 11(1):42-55.
- FAUSETT, Laurene (1994), Fundamentals of Neural Networks: Architecture, Algoritma and Applications, New Jersey: Printice Hall.
- HAMZAÇEBİ, Coşkun (2011), Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Bursa: Ekin Yayıncılık.
- HUANG, Wei; Kin K. LAI; Yoshiteru NAKAMORI; Shouyang WANG and Lean YU (2007), “Neural Networks in Finance and Economics Forecasting”, International Journal of Information Technology and Decision Making, Vol. 6, No.1, 113-140.
- JUNOH, Mohd Z. H. M. (2004), ”Predicting GDP Growth in Malaysia Using Knowledge – Based Economy Indicators: A Comparison Between Neural Network and Econometric Approach”, Sunway College Journal, Vol. 1, 39-50.
- KAPLAN, Muhittin ve Recep TEKELİ (2008), Ekonomide Bekleyişler ve Tahmin: Yapay Sinir Ağları Uygulamaları, Konya: Tablet Yayınları.
- KAYNAR, Oğuz; Serkan TAŞTAN ve Ferhan DEMİRKOPARAN (2010), “Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini”, Ege Akademik Bakış / Ege Academic Review, 10 (2): 561-575.
- KUBAT, Cemalettin (2013), Elinizin Altındaki Matematik Laboratuvarı: Matlab: Yapay Zekâ ve Mühendislik Uygulamaları, İstanbul: Pusula Yayıncılık.
- LILIANA ve Togar A. NAPITUPULU (2012), “Artificial Neural Network Application in Gross Domestic Product Forecasting an Indonesia Case”, Journal of Theoretical and Applied Information Technology, Vol. 45, No. 2, pp. 410-415.
- MIRBAGHERI, Mirnaser (2010), “Fuzzy Logic and Neural Network Fuzzy Forecasting of Iran GDP Growth”, African Journal of Business Management, Vol.4, No.6, 925-929.
- SUKIRNO, Sadono (2008), Makroekonomi: Teori Pengantar, 1st ed., PT Raja Grafindo Persada, Jakarta.

- TANG, Zaiyong ve Paul A. FISHWICK (1993), “Feedforward Neural Nets As Models For Time Series Forecasting”, ORSA Journal on Computing, 5(4), ss.374–385.
- TKACZ, Greg (2001), “Neural Network Forecasting of Canadian GDP Growth”, International Journal of Forecasting, 17, 57-69.
- TÜİK, İnternet Adresi: www.tuik.gov.tr , Erişim tarihi: 20.09.2013
- ÖZTEMEL, Ercan (2003), Yapay Sinir Ağları, İstanbul: Papatya Yayıncılık.
- ZHANG, Guoqiang; B. Eddy PATUWO ve Michael Y. HU (1998), “Forecasting with Artificial Neural Networks: The State of the Art”, International Journal of Forecasting, 14, ss.35-6.
- ZHANG, Xingyu; Yuanyuan LIU; Min YANG; Tao ZHANG; A. Alistair YOUNG ve Xiaosong LI (2013), “Comparative Study of Four Time Series Methods in Forecasting Typhoid Fever Incidence in China”, PloS ONE, 8(5): e63116, 1-11.