

## TÜRKİYE’DE ENFLASYONUN İLERİ VE GERİ BESLEMELİ YAPAY SİNİR AĞLARININ MELEZ YAKLAŞIMI İLE ÖNGÖRÜSÜ

### *FORECASTING OF TURKEY INFLATION WITH HYBRID OF FEED FORWARD AND RECURRENT ARTIFICIAL NEURAL NETWORKS*

**N. Alp ERİLLİ\***, **Erol EĞRİOĞLU\***, **Ufuk YOLCU\***,  
**Ç. Hakan ALADAĞ\*\***, **V. Rezan USLU\***

\* *Ondokuz Mayıs Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü*

\*\* *Hacettepe Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü*

**ÖZET:** Enflasyon öngörülerinin elde edilmesi önemli bir ekonomik problemdir. Öngörülerin doğru bir şekilde elde edilmesi daha doğru kararlara neden olacaktır. Enflasyon öngörüsü için literatürde çeşitli zaman serileri teknikleri kullanılmıştır. Son yıllarda zaman serisi öngörü probleminde esnek modelleme yeteneği nedeniyle, Yapay Sinir Ağları (YSA) tercih edilmektedir. Yapay sinir ağları doğrusal veya eğrisel belirli bir model kalıbı, durağanlık ve normal dağılım gibi ön koşullara ihtiyaç duymadığından herhangi bir zaman serisine kolaylıkla uygulanabilmektedir. Bu çalışmada Tüketici Fiyat Endeksi (TUFE) için ileri ve geri beslemeli yapay sinir ağları yaklaşımı kullanılarak öngörüler elde edilmiştir. Çözümlemede kullanılan YSA modellerinin öngörülerinin girdi olarak kullanıldığı, YSA’ya dayalı yeni bir melez yaklaşım önerilmiştir.

**Anahtar Kelimeler:** Öngörü ; İleri Beslemeli Yapay Sinir Ağları ; Geri Beslemeli Yapay Sinir Ağları

**JEL Sınıflaması:** C22

**Abstract:** *Obtaining the inflation prediction is an important problem. Having this prediction accurately will lead to more accurate decisions. Various time series techniques have been used in the literature for inflation prediction. Recently, Artificial Neural Network (ANN) is being preferred in the time series prediction problem due to its flexible modeling capacity. Artificial neural network can be applied easily to any time series since it does not require prior conditions such as a linear or curved specific model pattern, stationary and normal distribution. In this study, the predictions have been obtained using the feed forward and recurrent artificial neural network for the Consumer Price Index (CPI). A new combined forecast has been proposed based on ANN in which the ANN model predictions employed in analysis were used as data.*

**Keywords:** *Forecasting ; Feed Forward Neural Networks ; Recurrent Neural Networks*

**JEL Classification:** C22

### 1. Giriş

Enflasyon, fiyatların genel seviyesindeki artış olarak tanımlanmaktadır (Samuelson ve Nordhaus, 1992:587). Türkiye İstatistik Kurumu’nun yaptığı bir başka tanım da enflasyon, fiyatlar genel düzeyinin etkili bir şekilde devamlı yükselmesi nedeniyle paranın sürekli olarak değer kaybetmesi, bunun sonucu olarak da tüketicilerin satın alma gücünü yitirmesidir. Burada sadece belirli mal ve hizmetlerin değil, fiyatlar

genel seviyesinin yükselmesi ve bu yükselişin süreklilik arz etmesi gerekmektedir. Yüksek enflasyon paranın alım gücünü azaltır ve aynı zamanda fiyat değişimlerini anlamayı zorlaştırır.

Enflasyonun nedenlerini iki ana başlık altında toplayabiliriz. Bunlardan birincisi talep enflasyonudur. Talep enflasyonu; genellikle para arzının artmasının tüketimi artırması sonucu ortaya çıkar. Ekonomideki toplam arzın toplam talebi karşılayamaması sonucu fiyatlar yükselir. Mal ve hizmet talebindeki artış, faktör talebinde bir artışa neden olacak ve bunların fiyatları da artacaktır. Böylece ekonomi tam istihdamdayken, hem mal ve hizmet piyasasında hem de üretim faktörleri piyasasındaki toplam talep artışı enflasyona neden olmaktadır.

Enflasyonu sadece talep değil, aynı zamanda arz da etkiler. Üretimde kullanılan faktörlerin maliyetlerinin artması sonucunda fiyatların artışa geçmesi enflasyonu yaratır. Bu da maliyet enflasyonu olarak tanımlanmaktadır. Maliyet artışları; ücretlerin yükselmesi, hammadde fiyatlarının artması, ithalatın pahalılaşması, tarımsal ürünlerin fiyatlarının yükselmesi ve aşırı istihdam nedeniyle emeğin verimliliğinde yaşanacak düşüşler sonucu ortaya çıkabilir.

Yüksek enflasyon oranları gelişmekte olan ülke ekonomileri için süreklilik arz eden önemli bir makroekonomik problem olmuştur. Bu şekilde yüksek enflasyon oranlarının uzun bir zaman diliminde süreklilik kazanması, söz konusu ülkeler için ekonomik daralma, verimlilik kaybı gibi mali etkileri büyük olacaktır. Böylece enflasyonla mücadele sürecinde bekleyişlerin uygun bir biçimde yönlendirilmesi önemli faktörlerden biri haline gelmiştir (Karahan, 2005). Bu bekleyişlerden biri de enflasyon hedeflemesidir.

Enflasyon hedeflemesi son yıllarda önemi daha da artan önemli bir iktisadi kavram olmaya başlamıştır. Enflasyon-ekonomik büyüme ilişkisinin pozitif yönlü olduğuna ilişkin görüş özellikle II. Dünya Savaşı’ndan sonra kabul görmüş bir gerçektir. Ekonomik büyüme, bir ülkedeki refahı ve gelişmişlik düzeyini de önemli şekilde artırır. Enflasyon hedeflemesi ile para politikalarının daha net bir şekilde uygulanmasına çalışılmaktadır. Üretim ve büyüme dengesini ayarlamak, bölgesel ve sektörel sorunlara çözüm bulmak gibi öncelikli hedeflere istenen sonuçlarda ulaşılabilmesi için enflasyon engelinin bilinçli bir şekilde aşılması gerekmektedir. Literatürde birçok enflasyon tahmin fonksiyonları ve yöntemleri konularında çalışmalar bulunmaktadır. Bütün bunların hepsinde amaç; önemli bir sorun olarak görülen enflasyonun bir sonraki adımını tahmin etmek ve gereken önlemleri önceden almaktır.

Yapay sinir ağları, diğer zaman serisi modelleri gibi ön koşullar gerektirmemesi, belirli bir model kalıbının olmaması nedeniyle, son yıllarda öngörü problemlerini çözmek için bir çok çalışmada kullanılmıştır. Yapay sinir ağları ile öngörü elde etmenin tarihçesi oldukça eskidir. Hu (1964) de meteoroloji verilerinin tahmini için adaptif doğrusal yapay sinir ağı kullanmıştır. Rumelhart vd. (1986)’da önerilen çok tabakalı ileri beslemeli yapay sinir ağı (çok katmanlı algılayıcı veya geri yayımlı sinir ağı) modelinin XOR problemi gibi doğrusal olmayan problemleri de çözebilmesinin ardından, literatürde doğrusal olmayan zaman serileri öngörüsü için YSA kullanımı yaygınlaşmıştır. İleri beslemeli yapay sinir ağları ile farklı alanlarda ortaya çıkan doğrusal olmayan zaman serileri çözümlenmiştir. Özellikle güneş lekesi (sunspot) ve Kanada vaşağı (Canadian lynx) zaman serileri ileri beslemeli yapay

sinir ağları ile zaman serisi çözümlemesi için temel ölçüt (benchmark) olmuştur. Bu zaman serilerinin doğrusal olmayan yapılar içerdiği bilinmektedir. İleri beslemeli yapay sinir ağları ile bir çok finansal zaman serisi başarıyla öngörülmüştür. Trippi ve Turban (1993), Refenes (1995)'de iflas öngörüsü, Weigend vd. (1992), Wu (1995)'de döviz kuru tahmini, White (1988)'de borsa verilerinin öngörülmesi için ileri beslemeli yapay sinir ağını kullanmıştır. Stock ve Watson (1998), Chen vd. (2001) ve Nakamura (2005) çalışmalarında enflasyon oranı ileri beslemeli yapay sinir ağları ile çözümlenmiştir. Bu çalışmalarda YSA'nın bazı doğrusal zaman serisi modellerinden daha başarılı öngörüler verdiği gösterilmiştir.

Doğrusal olmayan zaman serilerinin modellenmesinde kullanılan bir diğer yaklaşım ise doğrusal zaman serisi modelleri ile YSA yaklaşımlarının birlikte kullanıldığı melez yaklaşımlardır. İlk melez yaklaşım Zhang (2003)'de önerilen ARIMA (Otoregresif bütünleşik hareketli ortalama) model ve ileri beslemeli YSA'nın melezlendiği yaklaşımdır. Eğrioğlu vd. (2009)'da Elman yapay sinir ağı ile ARIMA modelinin melezlendiği bir yaklaşım önerilmiştir. Her iki çalışmada da ARIMA modelleri ve YSA'nın tek başına kullanılması yerine, melez yaklaşımın kullanılmasının yararlılığı kanada vaşağı zaman serisi kullanılarak gösterilmiştir.

YSA'nın en önemli dezavantajı birçok bileşene sahip olması ve bu bileşenlerin belirlenmesinde kesin sonuçlara sahip olunamamasıdır. YSA ile öngörü üzerine yapılan çalışmalar Zhang vd. (1998) de özetlenmiştir ve yapay sinir ağının bileşenlerinin öngörü problemi için literatürde nasıl belirlendiği derlenmiştir. Literatürdeki çalışmalarda öngörü problemi için YSA kullanımında bileşen belirlemeleri probleme özel ve deneme yanılma yöntemi ile yapılmıştır. Egiroglu vd. (2008)'de yapay sinir ağları ile zaman serisi öngörüsünde mimari belirlenme problemi önerilen bir kriter ile çözümlenmiştir. Aladag vd. (2009) çalışmasında ise mimari belirleme problemi optimal bir kriter ile çözümlenmiştir.

Öngörü probleminde kullanılan bir diğer önemli yaklaşım, çeşitli modellerin öngörülerinin kombinasyonlarının elde edilmesidir. Öngörülerin kombinasyonu fikri ilk olarak Bates and Granger (1969) da ortaya atılmıştır. Daha sonra Granger (1984), Newbold (1974) ve Winlkler ve Makridakis (1983) çalışmalarında ikiden fazla model için öngörü kombinasyonları yapılmıştır. Wong vd. (2007) de dört farklı zaman serisi modelinin kombinasyonu için üç ayrı öngörü kombinasyonu tekniğini karşılaştırmıştır.

Bu çalışmada 4 farklı YSA modelinden elde edilen sonuçlar yine 4 farklı sinir ağı modeli içinde kombine edilmiştir. Önerilen yeni kombinasyon yöntemi Şubat 2003-Haziran 2008 tüketici fiyat endeksi zaman serisine uygulanmıştır. Önerilen yaklaşımın avantajları aşağıdaki gibi sıralanabilir:

- Hem ileri beslemeli, hem de geri beslemeli yapay sinir ağlarının avantajlarına sahiptir.
- Diğer öngörü kombinasyonu tekniklerinden farklı olarak, kombinasyon fonksiyonu, kombinasyon parametrelerine göre doğrusal değildir.


Çalışmanın ikinci bölümünde yapay sinir ağları tanıtılmıştır. Üçüncü bölümde yapay sinir ağları ile öngörü elde etme yöntemi verilmiştir. Dördüncü bölümde önerilen yeni melez yaklaşımın algoritması verilmiştir. Beşinci bölümde önerilen

yaklaşım Türkiye Şubat 2003-Haziran 2008 tüketici fiyat endeksi zaman serisine uygulanmıştır. Altıncı bölümde ise elde edilen sonuçlar tartışılmıştır.

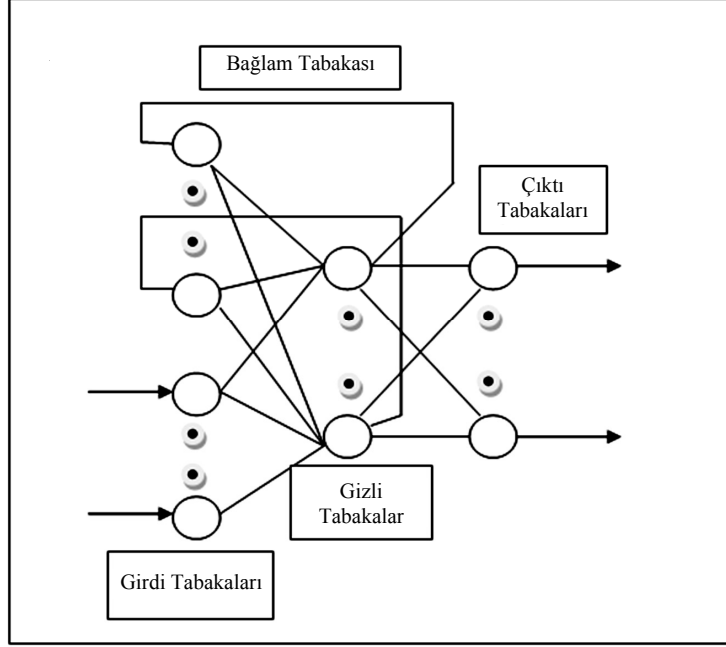
## 2. Yapay Sinir Ağları

Yapay sinir ağlarının önemli iki türü ileri beslemeli ve geri beslemeli Elman türü YSA’dır. Zaman serisi öngörü probleminde ileri beslemeli yapay sinir ağlarının kullanıldığı birçok çalışma literatürde yer almaktadır. Literatürdeki çalışmaların bir derlemesi Zhang vd. (1998) de detaylı bir şekilde verilmiştir. Genel olarak çok tabakalı ileri beslemeli bir YSA, girdi tabakası, gizli tabaka ve çıktı tabakası olmak üzere 3 kısımdan oluşmaktadır. Tabakalar nöron adı verilen düğümlerden oluşmaktadır ve bu birimlerin sayısının belirlenmesi önemli bir sorundur. Yapay sinir ağlarının bileşenleri genel olarak aşağıda verilmiştir.

*Mimari Yapı:* En basit hali ile çok tabakalı ileri beslemeli bir YSA mimari yapısı Şekil 1’de verilmiştir. Şekilde de görüldüğü gibi çok tabakalı ileri beslemeli bir YSA mimarisi üç kısımdan oluşur. Bunlar girdi tabakası, gizli tabaka (ya da tabakalar) ve çıktı tabakasıdır. Tabakalar, nöron (düğüm) adı verilen birimlerden oluşmaktadır. Yapay sinir ağlarında nöronlar birbirlerine ağırlıklar ile bağlıdır. İleri beslemeli ağlarda bu bağlantılar tek yönlü ve ileri doğrudur. Aynı tabakanın birimleri arasında bağlantı yoktur. Geri beslemeli sinir ağlarının zaman serisi öngörü problemi için kullanılan önemli bir çeşidi Elman (1990) da verilen Elman ağı olarak isimlendirilen geri beslemeli YSA’dır ve mimari yapısı Şekil 2’de gösterildiği gibidir. Elman YSA’da, ileri beslemeli YSA’dan farklı olarak bağlam (context) tabakası yer almaktadır. Bu tabaka gizli tabaka çıktılarına ağırlıklandırarak tekrar gizli tabakaya girdi olarak vermektedir.



Şekil 1. Çok Tabakalı İleri Beslemeli YSA



**Şekil 2. Elman YSA**

*Öğrenme Algoritması:* Yapay sinir ağlarında ağırlıkların belirlenmesinde kullanılan birçok öğrenme algoritması vardır. En yaygın kullanılan öğrenme algoritmalarından biri Geri Yayılım algoritmasıdır. Geri yayılım algoritması eldeki veri ile ağıın çıktısı arasındaki farka dayalı olarak ağırlıkların güncellenmesini gerçekleştirir. Geri yayılım algoritmasında kullanılan öğrenme parametresi optimal sonuca yeterli derecede yaklaşılmada önemli rol oynar. Öğrenme parametresi sabit olarak alınabileceği gibi, algoritma içinde dinamik olarak da güncellenebilir.

*Aktivasyon Fonksiyonu:* Aktivasyon fonksiyonu girdi ve çıktı birimleri arasındaki eğrisel eşleşmeyi sağlar. Aktivasyon fonksiyonunun doğru seçilmesi, ağıın performansını önemli derecede etkiler. Aktivasyon fonksiyonu genelde lojistik, tanjant hiperbolik ya da doğrusal olarak seçilebilir. Bu aktivasyon fonksiyonları aşağıda verilmiştir.

Doğrusal aktivasyon fonksiyonu:

$$f(net) = net \quad (2.1)$$

Lojistik aktivasyon fonksiyonu:  $\lambda$  eğim parametresini göstermek üzere lojistik aktivasyon fonksiyonu:

$$f(net) = \frac{1}{1 + \exp(-\lambda \cdot net)} \quad (2.2)$$

Tanjant hiperbolik aktivasyon fonksiyonu:

$$f(net) = \frac{\exp(net) - \exp(-net)}{\exp(net) + \exp(-net)} \quad (2.3)$$

Yapay sinir ağları hakkında daha detaylı bilgi Cichocki ve Unbehauen (1993), Zurada (1992) ve Günay vd. (2007)’den bakılabilir.

### 3. Yapay Sinir Ağları İle Öngörü Algoritması

Yapay sinir ağları sınıflama, örüntü tanıma gibi bir çok alanda kullanılmakla birlikte, son yıllarda zaman serisi analizi için de yoğun bir şekilde kullanılmaktadır. Yapay sinir ağları yöntemiyle zaman serilerinde öngörü elde etmeyi aşağıda verildiği gibi 7 adımda özetlemek mümkündür.

#### Adım 1: Verinin ön işlenmesi

İlk olarak verilerin  $[0,1]$  aralığına dönüştürülmesi gerçekleştirilir.  $x_i$ , girdi (gözlem) değerlerini göstermek üzere lojistik aktivasyon fonksiyonu kullanılacaksa, girdi değerleri

$$x'_i = \frac{x_i - \text{Min}(x_i)}{\text{Maks}(x_i) - \text{Min}(x_i)} \quad (3.1)$$

şeklinde  $[0,1]$  aralığına dönüştürülür.

#### Adım 2: Veri organizasyonu

Eğitim ve test kümelerinin büyüklüğünün veri kümesinin yüzde kaç olacağına karar verilir. Genelde verinin %10 veya %20’si, test kümesi olarak kullanılmaktadır.

#### Adım 3: Modelleme

Girdi sayısı, gizli tabaka sayısı, gizli tabakadaki birim sayısı ve çıktı tabakasındaki birim sayısı, bu birimlerde kullanılacak aktivasyon fonksiyonu, öğrenme algoritması ve bu algoritmanın parametreleri ve performans ölçütü belirlenerek, kullanılacak YSA modeli kurulur.

#### Adım 4: Girdi değerlerinin oluşturulması

YSA’nın girdi değerleri gecikmeli zaman serileridir.  $X_t$ , zaman serisi için girdi değerleri oluşturulurken, girdi tabakasındaki birim sayısı  $m$  ile gösterilsin,  $m$  tane gecikmeli zaman serisi  $X_{t-1}, X_{t-2}, \dots, X_{t-m}$ , şeklinde oluşturulur.

#### Adım 5: En iyi ağırlık değerlerinin hesaplanması

Eğitim kümesi üzerinden, seçilen öğrenme algoritması ile en iyi ağırlık değerleri bulunur. Elde edilen en iyi ağırlık değerleri kullanılarak, kurulan YSA modelinin çıktı değerleri hesaplanır.

#### Adım 6: Performans ölçütünün hesaplanması

YSA’nın test kümesi tahminleri elde edilir. Adım 5’te elde edilen çıktı değerlerine ve bu adımda elde edilen değerlere, Adım 1’de uygulanan dönüşümün tersi uygulanır. Bu dönüşüm sonucu elde edilen değerler sırasıyla, eğitim kümesinin tahminlerini ve test kümesinin tahminlerini oluşturur. Test kümesinin tahminleri ile test kümesindeki verilerin arasındaki farka dayalı olarak, seçilen performans ölçütü hesaplanır. Literatürde en yaygın kullanılan performans ölçütlerinden biri aşağıda formülü verilen Hata Kareler Ortalaması Karekök (HKOK) değeridir.

$$HKOK = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3.2)$$

#### Adım 7: Öngörü

Son olarak, Adım 5'te bulunan en iyi ağırlık değerleri kullanılarak, test kümesinden sonraki zamanlar için, yani gelecek için öngörü değerleri, yine iteratif öngörü ya da doğrudan öngörü yöntemlerinden biri kullanılarak elde edilir.

#### 4. Yeni Bir Melez Yaklaşım

Bir çok gerçek hayat zaman serisinde Zaman serilerinin öngörülmesinde, hem ileri beslemeli yapay sinir ağları hem de geri beslemeli yapay sinir ağları başarılı sonuçlar vermektedir (Zhang vd., 1998). Yapay sinir ağları ile öngörü elde etmede en önemli problem yapay sinir ağları bileşenlerinin belirlenmesindedir. Mimari yapı, aktivasyon fonksiyonu gibi bileşenlerinin seçiminde birçok seçenek vardır. Örneğin,

- İleri beslemeli mi? Geri beslemeli sinir ağı mimarisi mi?
- Gizli tabaka birim sayısı kaç olmalı?
- Girdi birimlerinin sayısı kaç olmalı?
- Hangi aktivasyon fonksiyonu kullanılmalı?

Tüm bu seçeneklere göre birçok seçenek model ile karşılaşılmaktadır. Bu modellerin öngörü performansları HKOK değeri farklı olmasına rağmen, her bir seçenekte modelin öngörüsünün veri içinde iyi olduğu veya kötü olduğu kısımlar vardır. Ayrıca bazı modellerin öngöruları daha doğru dönme noktalarına sahip iken, bazıları küçük hata büyüklüğüne sahip olabilmektedir. Bu nedenle çeşitli modellerden elde edilen öngörülerin yeni bir YSA'dan da kombine edilmesi yararlı olacağı düşünülmektedir. Bu çalışmada aşağıdaki YSA modellerinde elde edilen en iyi mimarilerin öngöruları başka YSA modelleri kullanılarak kombine edilmiştir. Öngörülerin yapay sinir ağları içinde kombine edilmesi diğer kombinasyon yöntemlerine göre avantajlıdır. YSA ile öngörülerin doğrusal değil eğrisel bir kombinasyonu söz konusudur. Kombinasyonda kullanılacak ağırlıklar, YSA'nın eğitilmesi ile otomatik olarak elde edilmektedir. Öngöruları kombine edilen YSA modelleri:


**Model 1-** Gizli tabaka düğümlerinde lojistik, çıktı tabakasında doğrusal aktivasyon fonksiyonunun kullanıldığı Elman YSA,

**Model 2-** Tüm tabakaların düğümlerinde lojistik aktivasyon fonksiyonunun kullanıldığı Elman YSA,

**Model 3-** Gizli tabaka düğümlerinde lojistik, çıktı tabakasında doğrusal aktivasyon fonksiyonunun kullanıldığı ileri beslemeli YSA,

**Model 4-** Tüm tabakaların düğümlerinde lojistik aktivasyon fonksiyonunun kullanıldığı ileri beslemeli YSA,

şeklinde. Dört modelden elde edilen öngörüler, yeni bir sinir ağında kombine edilmektedir. Yeni sinir ağının girdi ve çıktıları Şekil 3'de görüldüğü gibi olmaktadır.



**Şekil 3. Melez Yaklaşımın Şematik Gösterimi**

Bu melez yaklaşımın performansı, girdi olarak verilen dört modelin öngörü performansına bağlı olacaktır. Önerilen melez yaklaşımın algoritması aşağıdaki gibi özetlenebilir.

**Algoritma:**

**Adım 1.** Model 1,2,3 ve 4 için üçüncü bölümde verilen 7 adımlı algoritma gizli tabaka birim sayısı ve girdi birimlerinin sayısı için elde edilecek çeşitli kombinasyonlar ile uygulanır.

**Adım 2.** Model 1,2,3 ve 4 için en iyi girdi sayısı ve gizli tabaka birim sayısını veren mimariler ve bu mimarilere ait öngörüler belirlenir.

**Adım 3.** Model 1,2,3 ve 4 için önceki adımda elde edilen öngörüler YSA'nın girdisi ve gerçek değerler hedefi olacak şekilde aşağıdaki YSA modelleri çeşitli gizli tabaka birim sayıları için uygulanır.

**Melez YSA Modeli 1** - Gizli tabaka düğümlerinde lojistik, çıktı tabakasında doğrusal aktivasyon fonksiyonunun kullanıldığı Elman YSA.

**Melez YSA Modeli 2** - Tüm tabakaların düğümlerinde lojistik aktivasyon fonksiyonunun kullanıldığı Elman YSA

**Melez YSA Modeli 3** - Gizli tabaka düğümlerinde lojistik, çıktı tabakasında doğrusal aktivasyon fonksiyonunun kullanıldığı ileri beslemeli YSA


**Melez YSA Modeli 4** - Tüm tabakaların düğümlerinde lojistik aktivasyon fonksiyonunun kullanıldığı ileri beslemeli YSA

**Adım 4.** Melez YSA model 1,2,3 ve 4 için en iyi gizli tabaka birim sayısına karşılık gelen 4 melez YSA model mimarisi içinde en küçük HKOK değerini veren modelin öngörülleri melez yaklaşımın öngörülleri olarak alınır.

## 5. Uygulama

Önerilen melez yaklaşım Şubat 2003 – Haziran 2008 dönemlerine ait Türkiye aylık Tüketici Fiyat Endeksi (TUFİ) zaman serisine uygulanmıştır. TUFİ zaman serisinin grafiği aşağıda verilmiştir. Uygulama da TUFİ zaman serisinin son 12 değeri (Temmuz 2007- Haziran 2008, toplam verinin %18) test için diğer kısmı ( 52 veri, toplam verinin %82'si) ise eğitim için kullanılmıştır. Uygulamada “MATLAB NEURAL NETWORK TOOLBOX” kullanılmıştır.





Şekil 4. 2003 Şubat – 2008 Haziran Dönemlerine Ait Aylık Tüketici Fiyat Endeksi

Melez yaklaşımın uygulaması aşağıda adımlar ile verilmiştir:

**Adım 1.** Model 1,2,3 ve 4 için üçüncü bölümde verilen 7 adımlı algoritma, gizli tabakadaki nöron (birim) sayısının 1 ile 12 ve girdi tabakasındaki nöronların sayısının 1 ile 12 arasında değiştiği 144 durumda (her bir model için) uygulanmıştır. Uygulama sonucunda test kümeleri (Temmuz 2007- Haziran 2008 TÜFE değerleri) için elde edilen minimum HKOK değerleri Tablo 1 de verilmiştir. Tablolarda mimari yapı olarak verilen değerlerde; ilk değerimiz girdi tabaka nöron sayısını, ikinci değerimiz gizli tabaka nöron sayısını, son değer ise çıktı tabaka nöron sayısını göstermektedir. (8-1-1) örneğinde; girdi tabaka sayısı 8 iken gizli tabakası ve çıktı tabakası sayısı 1 olacaktır.


Tablo 1. 4 Modelden Test Kümesi için Hesaplanan Minimum HKOK Değerleri

	Model 1	Model 2	Model 3	Model 4
<b>Mimari Yapı</b>	8-1-1	8-1-1	7-2-1	9-1-1
<b>HKOK EĞİTİM</b>	0,3531	0,3507	0,3445	0,353
<b>HKOK TEST</b>	0,5756	0,5808	0,5726	0,5888


Tablo 2. Gerçek Değerler ve Modellerin en iyi Mimarieleri için Elde Edilen Öngörüler

Dönem	Gerçek Değerler	Model 1 (8-1-1)	Model 2 (8-1-1)	Model 3 (7-2-1)	Model 4 (9-1-1)
Tem.07	-0,73	0,3858	0,3640	0,3731	0,3858
Ağu.07	0,02	0,3858	0,3640	0,3726	0,3858
Eyl.07	1,03	1,4000	1,3575	1,2059	0,4626
Eki.07	1,81	1,4000	1,3575	1,2059	1,4060
Kas.07	1,95	1,4000	1,3575	1,5395	1,4060
Ara.07	0,22	0,3858	0,3640	0,3731	0,4277
Oca.08	0,80	0,3858	0,3640	0,3731	0,3858
Şub.08	1,29	0,3858	0,3640	0,3731	0,3858
Mar.08	0,96	0,3858	0,3640	0,3731	0,3858
Nis.08	1,68	1,4000	1,3575	1,5395	1,4060
May.08	1,40	1,4000	1,3575	1,2059	1,4060
Haz.08	-0,36	0,3858	0,3640	0,3731	0,3858
<b>HKOK TEST</b>		0,5756	0,5808	0,5726	0,5888


Tablo 2 incelendiğinde Model 3 ile en iyi sonucun elde edilebildiği görülmektedir. Tablo 2 de verilen modellerin öngörülerinin gerçek değerlerle birlikte grafiği Şekil 5, 6, 7 ve 8’te verilmiştir.




Şekil 5. Model 1’den Elde Edilen Öngörülerin Gerçek Değerlerle Birlikte Grafiği



Şekil 6. Model 2’den Elde Edilen Öngörülerin Gerçek Değerlerle Birlikte Grafiği



Şekil 7. Model 3’den Elde Edilen Öngörülerin Gerçek Değerlerle Birlikte Grafiği



**Şekil 8. Model 4'den Elde Edilen Öngörülerin Gerçek Değerlerle Birlikte Grafiği**

**Adım 2.** Model 1,2,3 ve 4 için en iyi girdi sayısı ve gizli tabaka birim sayısını veren mimariler ve bu mimarilere ait öngörüler aşağıda Tablo 3 de verilmiştir. Model 1 için en iyi mimari girdi sayısının 8, gizli tabaka nöron sayısının 1 ve çıktı tabakasında bir nöronun bulunduğu 8-1-1 mimarisidir. Benzer şekilde Model 2 için en iyi mimari 8-1-1, Model 3 için 7-2-1, Model 4 için 9-1-1 mimarisidir.

**Adım 3.** Model 1,2,3 ve 4 için önceki adımda elde edilen öngörüler YSA'nın girdisi ve gerçek değerler hedefi olacak şekilde aşağıdaki melez YSA modelleri gizli tabaka nöron sayısının 1 ile 12 arasında değiştirilmesi ile oluşan 12 şer durum için uygulanır. Uygulamadan elde edilen sonuçlar aşağıdaki tabloda özetlenmiştir.

**Tablo 3. Melez YSA Modelleri için Elde Edilen HKOK Değerleri**


Gizli Tabaka Birim Sayısı	Melez YSA Model 1	Melez YSA Model 2	Melez YSA Model 3	Melez YSA Model 4
1	0,6401	0,7234	0,6215	0,6442
2	0,5721	0,6930	0,5763	0,6078
3	0,5715	0,6472	0,5864	0,6490
4	0,5693	3,4578	0,5703	1,6368
5	0,6727	4,5969	0,5733	1,6368
6	0,5675	11,2489	0,5643	1,6368
7	0,6197	9,1607	0,6031	1,0135
8	0,5659	1,7763	0,5683	0,7002
9	0,6575	3,5903	0,5819	1,6368
10	0,5667	12,8154	0,5648	0,9503
11	0,8295	4,6102	0,6289	2,1041
12	0,6941	10,4375	0,6173	1,5203
<b>Minimum HKOK</b>	0,5659	0,6472	0,5643	0,6078

**Adım 4.** Tablo 3 de görüldüğü gibi en iyi melez YSA modeli, gizli tabaka birim sayısının 6 olduğu durumda Melez YSA Model 3 dür. Bu modelin öngörülerini aşağıda Tablo 4 de verilmiştir.

**Tablo 4. Gerçek Değerler ve Melez YSA Model 3 için Elde Edilen Öngörüler**

Dönem	Gerçek	Model 5	Dönem	Gerçek	Model 5
Tem.07	-0,73	0,3604	Oca.08	0,80	0,3604
Ağu.07	0,02	0,3602	Şub.08	1,29	0,3604
Eyl.07	1,03	0,8568	Mar.08	0,96	0,3604
Eki.07	1,81	1,2937	Nis.08	1,68	1,5025
Kas.07	1,95	1,5025	May.08	1,40	1,2937
Ara.07	0,22	0,3387	Haz.08	-0,36	0,3604

Gerçek değerler ile Melez YSA Model 3’den elde edilen öngörülerin grafiği Şekil 9’da verilmiştir.



**Şekil 9. Gerçek Değerler ve Melez YSA Model 3 için Elde Edilen Öngörülerin Grafiği**

## 6. Sonuçlar ve Tartışma

Literatürde, öngörü probleminde kombine yaklaşımların daima daha iyi öngörü sonuçları vereceği fikri hâkimdir (Wong vd. 2007). Çeşitli doğrusal veya eğrisel zaman serisi modellerinden elde edilen öngörüler farklı öngörü kombinasyonu metotları ile kombine edilebilir. Modellerin bir YSA ile kombine edilmesi hem uygulama açısından kolaylık sağlamakta hem de başarılı sonuçlar verebilmektedir. YSA ile kombinasyonda öngörülerin eğrisel bir kombinasyonu gerçekleştirilmekte ve kombinasyondaki ağırlıklar YSA’nın eğitimi esnasında otomatik olarak belirlenmektedir. Bu çalışmada ileri ve geri beslemeli yapay sinir ağlarının öngörü sonuçlarının yine yapay sinir ağları kullanılarak, kombine edildiği yeni bir melez yaklaşım önerilmiştir. Önerilen melez yaklaşım Türkiye TÜFE zaman serisine uygulanarak önerilen yaklaşımın HKOK değerini düşürdüğü gözlemlenmiştir. Standart YSA yaklaşımından elde edilen en küçük HKOK değeri 7-2-1 mimarisine sahip Model 3’den 0,5726 olarak bulunmaktadır. Gizli tabaka birim sayısının 6 olduğu Melez YSA Model 3 için ise HKOK değeri 0,5643 olarak elde edilmektedir.

Yaptığımız bu çalışmada özellikle 3 ayın enflasyon rakamları ile modelin tahmin değerleri arasında farklılıklar çıkmıştır. Bunlar Temmuz 2007, Şubat 2008 ve Haziran 2008 değerleridir. Temmuz 2007 için en iyi model tahmin değeri 0,3604 iken gerçek enflasyon değeri -0,73 gerçekleşmiştir. Bu farkın oluşmasında en önemli etken olarak 22 Temmuz yerel seçimlerini gösterebiliriz. Seçimin Türkiye ekonomisine maliyeti yaklaşık olarak 70 Milyon YTL olduğu tahmin edilmiştir. Bu

kadar büyük bir miktarın ekonomiye etkisi düşüş olarak gerçekleştiği söylenebilir. Şubat 2008 döneminde modelin tahmin değeri 0,3604 iken gerçekleşen enflasyon değeri 1,29 olmuştur. Enflasyon rakamlarının beklenenden fazla çıkmasının en önemli etkeni olarak, gıda grubundaki artış gösterilebilir. Gıda ve enerji fiyatlarındaki yükseliş sadece ülkemizde değil tüm dünyada da enflasyon rakamlarını yükseltici yönde etki yapmıştır (Karaca, 2008). Haziran 2008 döneminde ise modelin tahmin değeri 0,3604 iken gerçekleşen enflasyon değeri -0,36 olmuştur. Birçok sebepten dolayı beklentilerden daha düşük çıkmıştır. Mayıs ayından itibaren gerçekleşen petrol fiyat yükselmelerinin devam etmesi, elektrik ve doğal gaz zamları enflasyonu artırıcı etki yapmış; haziran ayı ile birlikte yaz ayları durgunluk dönemine girilmiş ve enflasyonda bir azalma görüldüğü söylenebilir.

Fiyat istikrarını sağlamak ve sürdürmek ekonomik ve sosyal gelişmeyi sağlayan temel faktörlerden biridir. Fiyat istikrarı bireylere ve firmalara tüketim, tasarruf ve yatırım kararlarında ve uzun vadeli planlar yapmalarında dikkate almaya gerek duymadıkları ölçüde düşük bir enflasyon oranını ifade eder. Yüksek enflasyon, bireylerin satın alma gücünü azaltarak geçim sıkıntısına ve yaşam kalitesinin düşmesine yol açmaktadır. Yüksek enflasyonun yarattığı belirsizlik, bireylerin karar alma sürecinde olumsuz hava yaratmaktadır. Enflasyon oranı, fiyat istikrarını sağlamak için politika uygulayıcılara yol göstermektedir (TÜİK, 2008:2-3) Enflasyon oranını tahmin etme çalışmaları ile politika uygulayıcılara yeni alternatif çözüm önerileri sunulabilir. Yine de hangi tahmin yöntemi kullanılırsa kullanılsın, enflasyon öngörüsünde tam bir başarı sağlanması oldukça zor gözükmektedir. Burada yapılması gereken her çalışmada karşılaşılan hataları ve zorlukları en aza indirmek olmalıdır.

## Referanslar

- ALADAĞ, C.H., EĞRİOĞLU, E., GÜNAY, S., BAŞARAN, M.A., (2009). Improving weighted information criterion by using optimization. *Journal of Computational and Applied Mathematics*, (Submitted manuscript).
- BATES, J.M., GRANGER, C.W.J. (1969). The combination of forecast, *Operational Research Quarterly*, 20 (4), 451-468.ss.
- CHEN, X., RACINE, J., SWANSON, N. (2001). Semiparametric ARX neural network models with an application to forecasting inflation,. *IEEE Transaction on Neural Networks*, 12, 674-683.ss.
- CICHOCKI, A., UNBEHAUEN, R. (1993). *Neural networks for optimization and signal processing*. New York: John Willey & Sons.
- EĞRİOĞLU, E., ALADAĞ, Ç.H., GÜNAY, S. (2008). A new model selection strategy in artificial neural network. *Applied Mathematics and Computation*, 195, 591-597.ss.
- EĞRİOĞLU, E., ALADAĞ, Ç.H., KADILAR, C. (2009). Forecasting nonlinear time series with a hybrid methodology. *Applied Mathematic Letters*, 22, 1467-1470.ss.
- ELMAN, J.L. (1990). Finding structure in time. *Cognitive Science*, 14:179-211.ss.
- GRANGER, C.W.J., RAMANATHAN, R. (1984). Improved methods of combined forecasts. *Journal of Forecasting*, 3, 197-204.ss.
- GÜNAY, S., EĞRİOĞLU, E., ALADAĞ, Ç.H. (2007). *Tek değişkenli zaman serileri analizine giriş*. Ankara: Hacettepe Üniversitesi Yayınları.

- HU, M.J.C. (1964). *Application of the adaline systems to weather forecasting, Master thesis*. Technical Report 6775-1, Stanford Electronic Laboratories, Stanford, C.A.
- KARACA, O. (2008). Enflasyon gelişmeleri üzerine, ekonomi üzerine yazılar, [Erişim Adresi]: <<http://www.orhankaraca.blogspot.com>>,[Erişim Tarihi: 5 Kasım 2009].
- KARAHAN, Ö. (2005). Türkiye’de örtük enflasyon hedeflemesi programının uygulanmasına ilişkin oluşan riskler ve bu risklerin yönetim politikaları. *Elektronik Sosyal Bilimler Dergisi*, ISSN:1304-0278, C:4, S.14, ss.34-47.ss.
- KAYGUSUZ, M. (2006). Enflasyon hedeflemesi ve Türkiye’de uygulanabilirliği, [Erişim Adresi]: < <http://www.ceterisparibus.net/arsiv.htm>>. [Erişim Tarihi: 5 Kasım 2009].
- NAKAMURA, E. (2005). Inflation forecasting using a neural network, *Economic Letters*, 86,373-378.ss.
- NEWBOLD, P., GRANGER, C.W.J. (1974). Experience with forecasting time series and combination of forecasts. *Journal of the Royal Statistical Society A*, 137 (2), 131-165.ss.
- REFENES, A.N. (1995). *Neural networks in the capital markets*. Chichester: John Wiley.
- RUMELHART, D.E., HINTON, G.E., WILLIAMS, R.J. (1986). Learning representations by backpropagating errors, *Nature*, 323 (6188), 533-536.ss.
- SAMUELSON, P.A., NORDHAUS, W.D.(1992). *Economics*. McGraw-Hill: Int. Editions.
- STOCK, J.H., WATSON, M.W. (1998). *A comparison of linear and nonlinear univariate models for forecasting macroeconomic time series*. NBER Working Paper 6607.
- TRIPPI, H., TURBAN, E. (1993). *Neural networks in finance and investment: using artificial intelligence to improve real-world performance*. Chicago: Probus
- TUİK (2008). *Fiyat endeksleri ve enflasyon: Sorularla Resmi İstatistik Dizisi-3*. Ankara:Türkiye İstatistik Kurumu Yayınları.
- WEIGEND, A.S., HUBERMAN, B.A., RUMELHART, D.E. (1992). *Predicting sunspots and exchange rates with connectionist networks*. In: Casdagli,M., Eubank S. (Eds.) *Nonlinear Modelling and Forecasting*. Addison Wesley: Redwood City, CA.
- WHITE, H. (1988). Economic prediction using neural networks: The case of IBM daily stock returns. *Proceedings of the IEEE International Conference on Neural Networks 2*, 451-458.ss.
- WINKLER, R.L., MARKIDAKIS, S. (1983). The combination of forecasts. *Journal of the Royal Statistical Society A*, 146 (2), 150-157.ss.
- WONG, K.K.F., SONG, H., WITT, S.F., WU, D.C. (2007). Tourism forecasting: To combine or not to combine?. *Tourism Management*, 28, 1068-1078.ss.
- WU, B. (1995). Model-free forecasting for nonlinear time series (With application to exchange rates). *Computational Statistics and Data Analysis*, 19, 433-459.ss.
- ZHANG, G., PATUWO, B.E., HU, Y.M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.ss.
- ZHANG, G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.ss.
- ZURADA, J.M. (1992). *Introduction of artificial neural systems*. St. Paul: West Publishing.