

# Yapay Sinir Ağları ve bilişsel haritalar kullanılarak işsizlik oranı öngörü çalışması

**Faika Çağla KARAALİ\***, Füsün ÜLENGİN

*İTÜ Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Programı, 34367, Maçka, İstanbul*

## Özet

Öngörü modellemesi, makro politikaların oluşturulmasında önemli bir karar destek aracı olarak görülmektedir. Bilgisayar teknolojisindeki ilerlemeler sayesinde yapay zeka sistemlerinin karar destek araçları olarak kullanımları da gün geçtikçe artmaktadır. Yapay zeka tekniklerinden Yapay Sinir Ağları yöntemi, öngörü çalışmalarında kullanılabilir ümit veren bir yöntem olarak araştırmacılar tarafından ilgi görmektedir. Bu çalışmada Bilişsel Haritalar yöntemi ile Yapay Sinir Ağları yöntemleri kullanılarak bir öngörü modeli kurulması çalışması gerçekleştirilmiştir. Çalışmada öngörü veri seti olarak Türkiye’de işsizlik oranları verisi kullanılmıştır. İşsizlik problemi, dünya devletleri için olduğu kadar Türkiye için de en önemli sorunlar arasında yer almaktadır. İşsizliği etkileyen faktörlerin belirlenmesi ve bu faktörler kullanılarak işsizlik tahminleri yapılması, işsizlik sorununa çözüm için hazırlanacak politikaların geliştirilmesinde karar destek bilgisi oluşturulmasına yardımcı olacaktır. Çalışmanın birinci aşamasında bilişsel haritalar yöntemi kullanılarak daha önce Türkiye ile ilgili makroekonomik çalışmaları bulunan beş akademisyenin görüşü alınıp Türkiye’de işsizliği etkileyen faktörler belirlenmiştir. Uzmanlar tarafından belirlenen on bir faktör, çalışmanın ikinci aşamasında çok katmanlı Yapay Sinir Ağı kullanılarak oluşturulan çok değişkenli bir öngörü modeline girdi olarak kullanılmıştır. Çalışmada 1988 ve 2004 yılları arasında dört dönemlik veriler kullanılmıştır. En iyi öngörü modeli, oluşturulan 24 değişik model arasından seçilmiştir. Çalışma sonunda en iyi tahmin modellerine mevsimsellikten arındırılmış veri seti ile ulaşıldığı görülmüştür. Çalışmada aynı zamanda çıktı katmanında kullanılan doğrusal ve doğrusal olmayan aktivasyon fonksiyonlarının, ağ performansına belirgin bir etkisi olmadığı, mevsimsel arındırma ve (0.1;0.9) ölçek aralığı kullanılmasının ise ağ öngörü performansını olumlu etkilediği görülmüştür.

**Anahtar Kelimeler:** Bilişsel haritalar, Yapay Sinir Ağları, işsizlik.

\*Yazışmaların yapılacağı yazar: Faika Çağla KARAALİ. ckaraali@gmail.com; Tel: (212) 314 33 76  
Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Programında tamamlanmış olan "Use of Artificial Neural Networks and Cognitive Mapping Methodology in Predicting Unemployment Rates and Employment Index Level " adlı doktora tezinden hazırlanmıştır. Makale metni 26.12.2006 tarihinde dergiye ulaşmış, 08.03.2007 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 01.02.2009 tarihine kadar dergiye gönderilmelidir.

## Predicting unemployment rates with the use of cognitive mapping methodology and Artificial Neural Networks

### Extended abstract

Forecasting is accepted as an important tool in the development and application of macro policies. Considering the fact that accurate forecasts help decision makers take better decisions, forecasting studies have started to take growing interest of researchers. By the developments in the computer specifications, artificial intelligence techniques have gained more attention as decision support tools. Among the artificial intelligence techniques, artificial neural networks (ANNs) are seen as promising techniques especially in forecasting applications. In this study, cognitive mapping methodology which is used in capturing the cause-effect relationships in complex causal systems and facilitate understand the interconnections within the elements of the systems by gathering expert knowledge is used in the identification of the factors that affect unemployment in Turkey and ANNs methodology are integrated in order define a prediction model framework. The framework is applied to unemployment rate data sets in Turkey in order to understand the important factors that affect unemployment and to forecast unemployment rate in Turkey. Understanding the factors that affect unemployment and developing forecasting models by the use of these factors can help the decision makers as a decision support mechanism in defining policies to overcome unemployment problem.

In the first phase of the study Cognitive Mapping methodology is used in the identification of the factors that affect unemployment in Turkey by taking the views of five different experts who have made research on macroeconomic problems of Turkey. The eleven variables identified by the experts are used in the second phase of the study as the input data set in developing a multi-variate forecasting model by using ANNs. The research period covers 1988 and 2004. Quarterly data is used in the analysis. To find the best network to forecast the output variables, a design of experiment is made and two different output activation functions; (linear function and nonlinear tangent sigmoid function), two different scaling ranges (-0.9; 0.9 and 0.1; 0.9), seasonal and deseasonalized data is used in the study. Additionally, three different input data struc-

tures are used in the study. In the first data structure, all variables identified by the experts are used in the analysis. In the second structure, unemployment rate data in one past period is added to the 11 input variables. In the third input structure, all input variables and unemployment rate are used in their lagged values as the inputs to the network. Therefore a total of 24 different models are tested. The networks are trained using MATLAB software, TRAINGDX training algorithm. To train each network, different numbers of hidden units are used and almost 85 % of the data set is used as the training set. Each run is replicated ten times with different initial weights in order to avoid getting stuck in local minima. Since the data set was not large enough to use a validation set, training is stopped at epoch 1000. The results of the study show that the best network found uses the level values in deseasonalized data sets; a tangent sigmoid function as the output activation function and a scaling range of (0.1;0.9). The structure of the input set is the second structure which includes all the 11 variables identified by the expert and the one past period value of the dependent variable itself. The results show that the specified best neural network model is able to perform satisfactorily within the test set. The test MSE is found to be 0.0015 where the training MSE is 0.0029.

Furthermore in the study, the effects of the different activation functions and different scaling ranges and deseasonalization on network prediction performance are tested. The results showed that models using a scaling range of (0.1;0.9) give significantly better average MSE results compared to the models using a scaling range of (-0.9;0.9). For the output activation functions, the test results reveal the mean performances of the models using tangent sigmoid function are not different from each other statistically. The test results also indicate that deseasonalization significantly improves network performance in unemployment rate data. Finally during the analysis it is observed that the networks tend to get over trained as the number of the hidden units increase; this result is in accordance with the findings in previous research on neural networks. The results of the study indicate that ANNs may be considered as promising tools in macroeconomic forecasting studies.

**Keywords:** Cognitive maps, artificial neural networks, unemployment.


## Giriş

İşsizlik problemi günümüzde ülkelerin yaşadığı en büyük problemlerden bir tanesidir. İşsizlik artışı kişisel ve toplumsal geliri düşürür; gelir dağılımında eşitsizliği ve yoksulluğu artırır. Ekonomik problemlerin yanısıra, işsizlik, sosyopsikolojik problemlere de yol açar. İşsiz kişinin kişisel kapasitesini ve yeteneklerini kullanamaması sebebi ile bu yetenekleri ve kapasitesi zaman içerisinde azalma gösterir ve işsiz kişi toplumdan dışlanır. Yüksek işsizlik seviyesinin bu gibi sonuçları gözönünde bulundurulduğunda, işsizliği anlamının ve işsizlik artışına karşı politikalar geliştirmenin ülkeler için ne derece önemli olduğu anlaşılmaktadır. Makro politikaların uygulanması ve oluşturulmasında kullanılan önemli bir teknik, tahmin çalışmasıdır. Doğru tahminler sayesinde karar verici mercilerin daha başarılı kararları alabileceği gerçeği tahmin çalışmalarına olan ilgiyi de arttırmaktadır. Bilgisayar kullanımının ve bilgisayar özelliklerinin gittikçe artmasının da etkisi ile tahmin modellemesi çalışmalarında yapay zeka sistemlerinden gittikçe daha fazla yararlanılmaya başlanmıştır. Yapay zeka çalışmalarının amacı, insanın düşünce yapısını anlayan ve bu yapıyı taklit edip uygulayabilecek sistemleri geliştirmektir. Yapay zeka teknikleri içerisinde tahmin çalışmalarında kullanım alanı bulan bir yöntem de Yapay Sinir Ağları (YSA) yöntemidir. Bu çalışmada YSA yöntemi kullanılarak Türkiye için işsizlik oranı tahmini yapılmıştır. Tahmin modelinin girdisini oluşturan işsizliği nedensel olarak etkileyen faktörlerin belirlenmesi aşamasında ise Bilişsel Haritalar (BH) tekniğinden faydalanılmıştır. BH tekniği, karmaşık sistemlerin modellenmesi ve karmaşık sistemlerin bileşenleri arasındaki neden-sonuç ilişkilerinin tanımlanmasında kullanılan bir yöntemdir. BH tekniği kullanılarak Türkiye’de işsizlik problemi üzerinde çalışmaları bulunan farklı uzmanların görüşleri birleştirilmiş ve işsizliği etkileyen temel faktörler ve bu faktörler arasındaki ilişkiler ortaya çıkartılmıştır. Ortaya çıkartılan bu faktörler çalışmanın ikinci aşamasında YSA ile tahmin çalışmasında girdi olarak kullanılmıştır.

## Türkiye’de işsizlik problemine bakış

Türkiye, diğer pek çok ülkede olduğu gibi yüksek işsizlik problemi ile karşı karşıya bulunan bir ülkedir. İşsizlik oranları, yüksek büyüme

oranlarına karşı düşüş göstermemekte ve özellikle de şehirlerde ve üniversite mezunu gençlerde yüksek seviyelere ulaşmaktadır. İşsizlik oranı 2005 yılı itibariyle ortalama yüzde 10.3 olarak gerçekleşirken, kentlerde işsizlik oranı yüzde 13.3 (Şekil 1), kırsal kesimde ise işsizlik oranı bir önceki yıla göre yüzde 9.6 artarak, yüzde 6.5 olarak gerçekleşmiştir. Türkiye’deki genel işsizlik oranı, gelişmiş ekonomiler ve AB’deki yüzde 6.7 işsizlik oranına göre çok yüksek kalmaktadır (ILO, 2006). 2005’te 15-24 yaş grubundaki genç nüfus arasındaki işsizlik oranı ise yüzde 19.3 olmuştur. 2004’te yüzde 14.7 tahmin edilen Türkiye’deki tarım dışı işsizlik oranı 2005 yılında yüzde 13.6 hesaplanmıştır. Kırsal kesimdeki işsizlik oranındaki düşük rakamlar, kırsal kesimdeki tarımsal faaliyetlerden kaynaklanmaktadır. Türkiye, nüfus olarak da hızla büyüme gösteren bir ülkedir. Kırsal kesimden kentsel bölgelere olan göç ise kentsel bölgelerde yaşayan kesimin 2000 yılı itibariyle tüm nüfusun yüzde 60’ını oluşturmasına sebep olmaktadır. Hızlı göç ve kentsel bölgelerdeki nüfus artışı ileriki yıllarda tarım sektöründeki işsizlik oranlarındaki azalmanın da etkisi ile daha yüksek işsizlik oranlarına sebep olacaktır.



Şekil 1. Yıllara göre Türkiye’de işsizlik oranları (Kaynak: www.tuik.gov.tr, Kasım 2006)

Geçmişte baktığımızda 1993 ve 1996 yılları arasında Türkiye’nin işsizlik oranlarında bir düşüş olduğu görülmüştür. Gürsel ve Ulusoy, (1999), bu düşüşün yaratılan iş miktarındaki artışa bağlı

olduğunu ve ancak, bu düşüşün kalıcı olmayacağı, Türkiye'nin ileriki yıllarda tarımsal istihdamdan endüstriyel istihdama geçmesi, erken emeklilik sistemi ve ekonomik büyümedeki yavaşlama sebebi ile yüksek işsizlik oranları ile karşı karşıya kalacağını belirtmişlerdir. Nitekim 1996 yılı sonrası işsizlik oranlarında artış gözlemlenmektedir. Levent ve diğerleri (2002), işsizlikteki bu artışın Gürsel ve Ulusoy (1999)'un da belirttiği gibi sürpriz olmadığını ve 1990'ların ikinci yarısında büyümenin düzensiz bir yapı gösterdiğini, bu durumun da özellikle imalat sektöründe istihdamı önemli şekilde etkilediğini ve özellikle de kentsel kesimde işsizlik oranlarını arttırdığını belirtmiştir. 1999 ve 2001 yıllarında yaşanan ekonomik krizlerin de etkisi ile Türkiye'de işsizlik artmış ve 2002 yılında yüzde 10.3'e ulaşmıştır. Daha sonraki yıllarda da aynı seviyelerde kalmaya devam etmiştir. Bulutay, (1995), yatırımın ve sermaye birikiminin Türkiye'de istihdam, işsizlik ve ücretler üzerinde etkili olduğunu ve Batı ülkelerinden farklı olarak sorunun işsizlik ödemelerinin uzunluğu ve yüksekliği, ücretlerin yüksekliği değil, yaratılan işlerin yetersizliği ve Türkiye'de kalıcı büyümenin sağlanamaması olduğunu belirtmiştir.

### **Bilişsel haritalar**

Bu çalışmada Bilişsel Haritalar (BH) yöntemi, Türkiye'de işsizliği etkileyen değişkenleri belirlemek için kullanılmıştır. BH yöntemi, karmaşık sistemlerin modellenmesi ve karmaşık sistemlerin bileşenleri arasındaki neden-sonuç ilişkilerinin tanımlanmasında kullanılan bir yöntemdir. Stratejik karar verme konusunda kişilerin görüşlerini haritalar yardımı ile göstermekte de popüler olarak kullanılan bilişsel haritalar yöntemi, (Hodgkinson vd., 2004); aynı zamanda şekilsel olarak modellenen problem ya da sistem içerisindeki elemanların birbiri ile ilişkisinin yönünü ve bu elemanlardan bir tanesindeki değişimin diğer elemanları hangi yönde etkileyeceğini de göstermektedir. BH'nin bir yaklaşımı da Axelrod'un "kararın yapısı" teorisidir (Axelrod, 1976). Axelrod, bilişsel haritaları, öncelikle politik karar verme alanında döküman ve röportajları incelemede kullanmıştır. Axelrod, BH sayesinde çerçevesi belirli olan bir problem içerisindeki kavramları ve bu kavramlar arasındaki se-

bep sonuç ilişkilerini şekilsel olarak göstermeyi amaçlamıştır. Böylece BH, uzman görüşlerinin, yazılı dökümanların ve röportajlardan çıkartılan bilgilerin birleştirilip şekilsel olarak gösterilmesi sayesinde karmaşık bir konunun yapısının analizi ve anlaşılması için güvenilir bir yol olarak kullanılan bir yöntem haline gelmiştir. Bir bilişsel harita iki temel üyeden oluşur: kavram ve nedensel ilişkiler. Kavramlar, haritadaki değişkenleri, nedensel ilişkiler ise değişkenler arasındaki ilişkileri gösterir (Axelrod, 1976). Haritada kavramlar düğümlerle, kavramlar arası nedensel ilişkiler ise işaretli ve yönlü oklarla gösterilir. Kavramlar arasındaki nedensel ilişkilerin gösterilmesine göre, BH, basit bilişsel harita, ağırlıklandırılmış bilişsel harita ve bulanık bilişsel harita isimlerini alır. Bilişsel Haritalar, özellikle karmaşık sistemlerin modellenmesinde uygun bir yöntemdir. Karmaşık sistemlerin modellenmesinde bir uzmanın bilişsel haritasından faydalanmak yerine birçok uzmanın bilişsel haritasından bir arada yararlanmak daha doğru bir yoldur ve daha güvenilir sonuçlar verir (Eden, 2003). BH çıkartıldıklarında önemli bir karar destek sistemi olarak kullanılırlar. Bilişsel Haritaların kullanılabileceği dört temel problem çeşidi vardır (Axelrod, 1976): Karar verme problemi, tahmin problemi, açıklama, tanımlama problemi ve strateji problemi. BH üç yöntemle oluşturulabilir: anket yöntemi (Roberts, 1976), döküman kodlama yöntemi (Wrightson, 1976) ve röportaj yöntemi. Döküman kodlama yöntemi ile BH çıkartılırken bir yazı, söyleşi ya da demeçler cümle cümle ya da kelime kelime kodlanarak çıkartılır (Axelrod, 1976).

BH oluşturmada kullanılan ikinci yöntem olan anket yönteminde, konusunda geniş bilgi sahibi olan uzmanlar seçilerek uzman görüşleri alınarak harita oluşturulur. Uzman kişilerden, incelenmek istenen problemi belirleyen kavramları listelemeleri istenir. Bu aşamada uzman kişiler problem ile ilgili olduğunu düşündükleri kavramlardan oluşan birer liste hazırlarlar. Bu kavramlar ilgili sistemi ya da problemi kısıtlayan, etkileyen, nedensel ilişki içerisinde olan ya da sistem ya da problem tarafından etkilenen kavramlar olabilir. Eğer uzmanların oluşturdukları liste uzun ise yine anket ve görüşmeler sayesinde bu liste kısaltılabilir. Oluşturulan liste ikinci

adımında ikili olarak düzenlenip uzmanlara geri gönderilir ve kendilerinden ikili karşılaştırma yaparak bu kavramların birbirlerine olan etkilerini değerlendirmeleri istenir. Eğer değişkenler arasında bir ilişki yok ise uzmanlar bu ilişkiyi “0” değeri ile gösterir. Eğer pozitif bir ilişki var ise “+”, negatif bir ilişki var ise de “-” olarak bu ilişkiyi belirtirler. Kavramlar arası ilişkilerin yönleri ve nitelikleri belirlendikten sonra uzmanların görüşleri birleştirilerek toplu bir bilişsel harita oluşturulur. BH çıkartılmasında kullanılan üçüncü yöntem ise ucu açık röportaj yöntemidir. Bu yöntem, yukarıda anlatılan anket ve döküman kodlama yöntemlerinin bir birleşimi yöntem olarak adlandırılabilir (Axelrod, 1976).

Bilişsel Haritalar kompleks yapılardır, çünkü kendi aralarında ilişkiye sahip ve geri bildirim yapısına sahip pek çok değişkenden oluşurlar. Bilişsel Haritaların analizi güçtür ancak matris matematiği bilişsel haritaların analizinde basit bir araç olarak karşımıza çıkar (Özesmi ve Özesmi, 2004). Bilişsel harita matris şekline dönüştürülebilir ve ilişkiler matris üzerinde gösterilebilir. İlişkilerin ve değişkenlerin gösterildiği bu matrise komşuluk matrisi adı verilir. Komşuluk matrisi A, nXn boyutunda bir matristir. Bu matristeki n, bilişsel haritadaki kavram sayısını gösterir. A, matrisinde kavramlar arası ilişkiler (vij) ile gösterilir. vij =1 ise, i kavramı ile j kavramı arasında pozitif bir ilişki bulunmaktadır; -1 ise i ile j arasındaki ilişki negatif, 0 ise de kavramlar ilişkisizdir. Matrisin köşegen elemanları “0” değerindedir. Komşuluk matrisinin birkaç yararlı özelliği vardır: Matrisin i. satırındaki elemanların mutlak değer toplamı; i'nin çıkış derecesini (çd) verir ki bu da “i” kavramından dolaysız bir şekilde etkilenen kavram sayısını belirtir. Benzer şekilde i. Sütundaki elemanların mutlak toplamı, “i”nin giriş derecesi (gd) verir. Giriş derecesi “i” kavramını direkt bir şekilde etkileyen kavramların sayısını belirtir. “i” kavramına ait olan çd ve gd'lerin toplamı ise bilişsel merkezilik derecesinin ölçümünü sağlayan i'nin toplam derecesini (td) verir (Nozicka vd., 1976). Matematiksel olarak bu ilişkiler, “i” incelenen satır ve sütundaki ilgili eleman ve “j” de toplam değişken sayısı olmak üzere,

$$gd(i) = \sum_{j=1}^n v_{ij} \quad (1)$$

$$\çd(i) = \sum_{j=1}^n v_{ji} \quad (2)$$

$$td(i) = gd(i) + \çd(i) \quad (3)$$

şeklinde yazılabilir.

Özesmi ve Özesmi (2004), giriş derecesi, çıkış derecesi ve toplam derecenin bilişsel haritalar için önemli birer göstere olduğunu belirtmişlerdir. Bir değişkenin bilişsel haritaya olan katkısı onun merkeziliğinin ölçülmesi ile belirlenebilir. Alıcı değişkenler (pozitif girdi değerine ve 0 çıktı değerine sahip değişkenler) haritada karmaşıklığın göstergesidir; benzer şekilde çok sayıda verici değişken bulunması (pozitif çıktı değerine ve 0 girdi değerine sahip değişkenler) bilişsel haritanın yatay olduğunu gösterir. Bu da nedensel ilişkilerin yeterince düzgün oluşturulmadığını gösterir. Bu çalışmada Bilişsel Haritalar, anket yöntemi ve yüzyüze görüşmeler yapılarak uzman görüşleri yardımı ile oluşturulmuş ve harita sayesinde işsizliği etkileyen ve işsizlikten etkilenen faktörler belirlenmiştir.

### Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel, 2003). YSA'nın temelinde yatan fikir, insan beyninin akıllamaz veri işleme yeteneğidir. İnsan beyninde nöron adı verilen yüksek sayıda hücre bulunmaktadır. Bu nöronlar, birbiri ile bağlanmış haldedir ve bu bağlantılar sayesinde nöronlar arasında sinyal akışı gerçekleşmektedir. Gelen sinyallerin toplamı belirli bir eşik değerini aştığında diğer sinir hücrelerine sinyal gönderilmektedir. Sinir hücreleri arasındaki bu yapı matematiksel olarak YSA ile tanımlanabilmektedir. Haykin (1999), çalışan sinir hücreleri ile matematiksel sinir hücreleri arasındaki ilişkiyi detaylı olarak anlatmaktadır. YSA, günümüzde bilgi sınıflama ve bilgi yorumlamanın da içinde bulunduğu pek çok değişik problemlerle

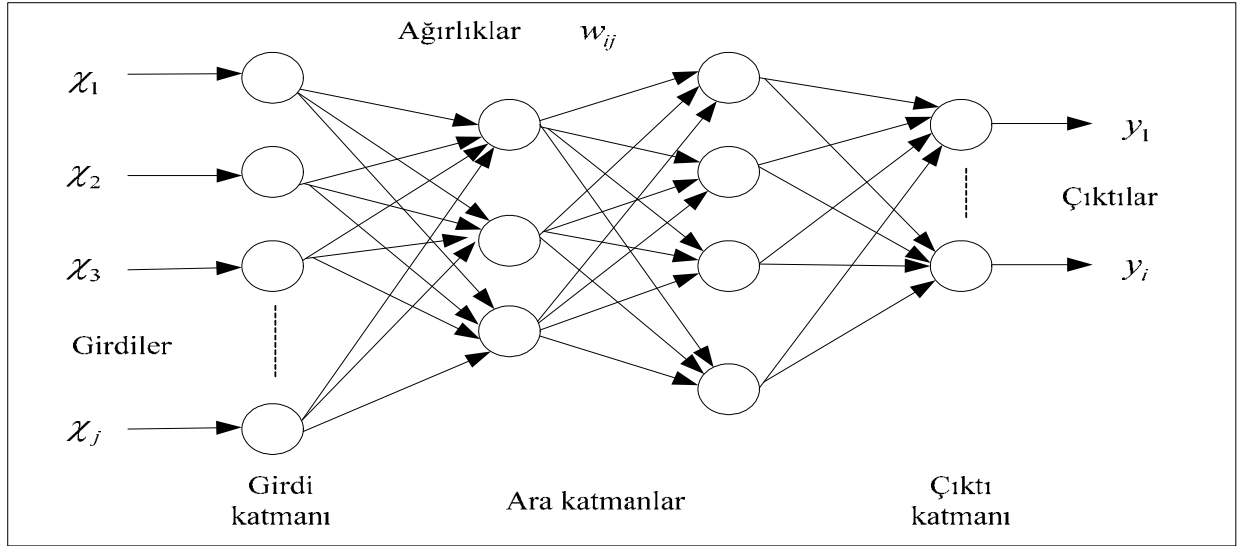
rin çözümünde kullanılmaktadır (Elmas, 2003). YSA, sınıflandırma, olasılıksal fonksiyon kestirimi, örüntü eşleştirme, örüntü tanıma, optimizasyon, doğrusal olmayan sistem modelleme, zaman serisi analizi, tahmin ve sinyal işleme gibi farklı alanlarda başarı ile kullanılmışlardır. YSA'nın temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer karar vermeye çalışırlar (Öztemel, 2003).

### YSA yapısı

İnsan beynindeki bir nöronu temsil eden bir ; düğüm, yapay sinir ağının temel elemanıdır. Ağa dışsal bilgi taşıyan düğümler girdi düğümü olarak adlandırılır. Bu düğümlere giren bir ok yoktur. Çıktı düğümleri ise ağın çıktısını oluşturmaktadır. Çıktı ya da girdi düğümü olmayan düğümler ise, gizli düğüm olarak adlandırılır. Ağırlıklar, bir düğüme gelen bilginin önemini ve düğüme olan etkisini gösterir. Toplama işlevi, bir hücreye gelen net girdiyi hesaplar. Toplama işlevinde en yaygın olarak kullanılan hesaplama, ağırlıklı toplamı bulmaktır. Ancak bu basit hesaplama yönteminin yanı sıra, en küçük (min), en büyük (max), çoğunluk gibi daha karmaşık bir formül de kullanılabilir. Toplama işlevinin sonucunda bulunan değere düğümün eşik değeri de eklenerek düğümün net girdisi hesaplanmış olur. Aktivasyon işlevi, düğüme gelen net girdiyi işleyerek bu girdiye karşılık düğümün üreteceği çıktıyı belirler. Aktivasyon işlevinde kullanılan fonksiyona aktivasyon fonksiyonu adı verilir. Aktivasyon fonksiyonunun türevi alınabilir bir fonksiyon olması tercih edilir. Günümüzde kullanılan pek çok modelde sigmoid fonksiyon tercih edilmiştir (Zhang vd., 1998). Düğümün çıktısı, aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer dış dünyaya, bir başka düğüme ya da düğümün kendisine girdi olarak gönderilebilir. Yapay sinir düğümleri, bir araya gelerek yapay sinir ağlarını oluştururlar. Öğrenilmesi istenilen hedef değerlerine yakınsamaları için, ağırlıkların nasıl bir yöntem ile değiştirileceği öğrenme algoritması tarafından belirlenir. YSA yapıları genel olarak iki çeşide ayrılır: ileri beslemeli ağlar ve geri beslemeli ağlar. İleri beslemeli ağlarda, düğümler ara katmanlara ayrılır ve iletiler, bir katmandaki düğümlerden, bir sonraki katman-

daki düğümlere doğru yapılırlar. Aynı katmandaki düğümler arası bağlantı bulunmaz. Bu tür ağların en popüler olanı, Çok Katmanlı Perseptron (ÇKP)'lerdir. Geri beslemeli ağlarda ise, iletiler hem ileri hem de geri yönlü olabilir ve düğümlerin çıktı değerleri kendi girdi düğümlerini veya önceki katmanları geri-besleyebilirler. Böylece, bir çıktı değeri sinyali, hem o anki girdileri hem de önceki girdileri dinamik bir şekilde yansıtabilir (Haykin, 1999). ÇKP'lerde ağ içerisindeki düğümler, katmanlar halinde yerleştirilir. Genelde düğümler üç katman halinde bulunurlar: Girdi katmanı, ara katmanlar ve çıktı katmanı. Girdi katmanındaki düğümler dış dünyadan gelen bilgileri ara katmanlara transfer ederler. Girdi katmanındaki her bir girdi düğümü ara katmanlarda bulunan her düğüme bağlıdır. Ara katmanlarda, girdi katmanından gelen bilgiler işlenir ve çıktı katmanına gönderilir. Bir ağ içerisinde birden fazla ara katman bulunabilir. Ara katmanlardaki her bir düğüm bir sonraki katmandaki tüm düğümlere bağlıdır. Çıktı katmanında, ara katmandan gelen bilgiler işlenerek ağın ürettiği çıktılar dış dünyaya gönderilir. ÇKP'lere bir örnek Şekil 2'de gösterilmiştir. ÇKP'ler, özellikle de bir ara katmana sahip ÇKP'ler, literatürde en yaygın olarak kullanılan ağ türüdür. Bu yaygınlığın sebebi çok katmanlı perseptronların "Evrensel Fonksiyon Yakınsayıcı Yöntem" olarak tanımlanmalarıdır (Zhang vd. 2003).

ÇKP'ler, öğretmenli öğrenme stratejisine göre çalışırlar. Eğitim sırasında ağa, hem girdiler hem de bu girdilere karşılık gelen çıktı değerleri gösterilir. Ağın görevi bu girdiye karşılık gelen çıktı değerini öğrenmektir. ÇKP'lerin öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Genelleştirilmiş Delta Kuralı iki safhadan oluşur. 1. safhaya, ileri doğru hesaplama safhası adı verilir ve bu safhada ağa gösterilen örnek seti için ağın çıktısı hesaplanır. 2. safhaya geriye doğru hesaplama safhası adı verilir; bu safhada ise ağın ağırlıkları güncellenir. İleri doğru hesaplama safhası ağa eğitim setindeki bir örneğin gösterilmesi ile başlar. Ağın ağırlıkları ilk değerlerini alır ve ara katmandaki düğümlere giren net girdi hesaplanarak ara katmanın çıktısı aşağıdaki formüle göre hesaplanır.



Şekil 2. Çok katmanlı perseptron

$$v_j^\mu = f\left(\sum_k w_{jk}^1 * x_k^\mu\right) \quad (4)$$

Çıktı düğümünün çıktısı ise benzer formül kullanılarak 2 numaralı formüle göre hesaplanır.

$$y_i^\mu = f\left(\sum_j w_{ij}^2 * v_j^\mu\right) = f\left(\sum_j w_{ij}^2 * f\left(\sum_k w_{jk}^1 * x_k^\mu\right)\right) \quad (5)$$

Bu formüllerde; “f” aktivasyon fonksiyonunu, “yi” i. çıktıyı, “xk” k. girdiyi, “vj” ara katman

düğümlelerini, “w1jk” girdi katmanı ile ara katman arasındaki ağırlıkları, “w2ij” ara katman ile çıktı katmanı arasındaki ağırlıkları ve “μ” ise ağa gösterilen eğitim setinin numarasını göstermektedir. Ağ gösterilen eğitim setinin toplam örnek sayısı p dir. 1. safha ağın çıktı değerlerinin hesaplanması ile tamamlanır.

Eğitimin 2. safhasında ise ağın mevcut çıktı değeri eğitim seti örneğinin gerçek çıktısı ile karşılaştırılır ve ağın ağırlıkları eğitim seti örneğinin gerçek çıktısı ile ağın bulduğu çıktı değeri arasındaki hatayı en aza indireyecek şekilde uyarlanır. Çıktı katmanı için oluşan toplam hata genelde hata karelerinin ortalaması (MSE) formülü ile bulunur. Çıktı katmanında hesaplanan hata ağa geri doğru dağıtılır ve ağırlıklar güncellenir. Ağırlıkların güncellenmesi aşamasında gradient descent algoritması kullanılır. Hesaplama sonu-

cunda ara katman ile çıktı katmanı arasındaki ağırlıklar, t+1 anında,

$$w_{ij}^2(t+1) = w_{ij}^2(t) + \Delta w_{ij}^2 \quad (6)$$

formülüne göre hesaplanır. Bu formülde ağırlıkların değişim miktarı  $\Delta w_{ij}^2$  ise,

$$\Delta w_{ij}^2(t+1) = -\eta \sum_\mu \delta_i^\mu * v_j^\mu + \alpha \Delta w_{ij}^2(t) \quad (7)$$

numaralı formül kullanılarak hesaplanır. 7 numaralı formülde,  $\delta_i^\mu$ , i numaralı çıktının hatasını göstermektedir ve

$$\delta_i^\mu = (o_i^\mu - y_i^\mu) * f'\left(\sum_j w_{ij}^2 * v_j^\mu\right) \quad (8)$$

formülüne göre hesaplanır. Bu formülde  $f'()$  aktivasyon fonksiyonunun türevini,  $o_i^\mu$  ise i numaralı çıktının  $\mu$  numaralı eğitim seti için gerçek çıktı değerini gösterir. Ara katman ile girdi katmanı arasında ağırlık güncellenmesi formülü ise, t+1 anı için

$$w_{jk}^1(t+1) = w_{jk}^1(t) + \Delta w_{jk}^1 \quad (9)$$

formülü ile hesaplanır. Bu formülde ağırlıkların değişim miktarı,

$$\Delta w_{jk}^1(t+1) = \eta \sum_{\mu} \delta_j^{\mu} * x_k^{\mu} + \alpha \Delta w_{jk}^1(t) \quad (10)$$

hata terimi ise,

$$\delta_j^{\mu} = f'(\sum_j w_{jk}^1 * x_k^{\mu}) * \sum_{\mu} w_{ij}^2 * \delta_i^{\mu} \quad (11)$$

formülleri ile hesaplanır (Haykin, 1999). 7 ve 10 numaralı ağırlık değişim miktarlarında kullanılan  $\eta$  ve  $\alpha$  katsayıları sırası ile öğrenme oranı ve momentumu gösterir. Öğrenme oranı ağırlıklardaki değişimin miktarını belirler ve genelde (0;1) aralığında bir değer alır. Düşük öğrenme oranları öğrenme sürecini yavaşlatırken yüksek öğrenme oranları ağırlık uzayında salımlara yol açabilir ve ağ öğrenme sırasında yerel bir optimum noktaya takılabilir. Öğrenme sürecini iyileştirmek ve yerel bir optimum noktaya takılmayı engellemek için öğrenme aşamasında momentum katsayısı kullanılır. Momentum katsayısı da öğrenme oranına benzer şekilde (0;1) arası bir değer alır.

### Bilişsel haritalar ile işsizlik analizi

Türkiye’de işsizlik ile ilgili faktörlerin belirlenmesi için Türkiye’de farklı üniversitelerde makro ekonomik problemler üzerine çalışmaları bulunan beş farklı araştırmacının görüşleri alınmıştır. Araştırmacılardan Türkiye’de işsizliğin temel sebebi olduğuna inandıkları faktörleri listelemeleri istenmiş ve sonuçta 34 adet değişken listelenmiştir. Çalışmanın ikinci aşamasında bu değişkenler uzmanlara geri verilip değişkenleri işsizliğe olan önemlerine göre sıralandırmaları istenmiştir. Bu çalışma sonucunda belirlenen 34 değişkenin iki tanesi, işsizlik ödemelerinin süresi ve işsizlik ödemelerinin miktarı değişkenleri, işsizlik ödemesi Türkiye’de kısa bir süredir uygulandığından ve ödeme miktarı oldukça düşük olduğundan listeden çıkartılmış; ayrıca satınalma gücü değişkeni işsizliğin bir sebebi değil sonucu olması ve belirlenen 34 değişken içerisinden yerli talep ile de temsil edilebileceği; kayıtdışı sektör değişkeni ise kayıtsız istihdam değişkeni ile temsil edilebileceği için değişken listesinden uzman görüşlerine dayanılarak çıkartılmıştır.

Çalışmanın üçüncü aşamasında değişkenler listelenmiş ve uzmanlara yeniden gönderilmiştir. Uzmanlardan bu değişkenleri ikili gruplar halinde değerlendirmeleri istenmiştir. Bu değerlendirme aşamasında kullanacakları değerlendirme ölçeği -1, 0, 1 olarak belirlenmiştir. Ölçekte -1 değeri değerlendirilen değişken çiftinde birinci değişkenin ikinci değişkeni negatif olarak etkilediğini; 1 değeri, iki değişken arasında pozitif bir ilişki olduğunu; 0 değeri ise iki değişkenin birbirini etkilemediği anlamını taşımaktadır. İkili değişken değerlendirilmelerinden oluşan ilişki matrisleri uzmanlardan toplanmış ve toplu bilişsel haritayı oluşturmak üzere birleştirilmişlerdir. Toplu bilişsel harita oluşturulması aşamasında Axelrod (1976), tarafından tanımlanan şekilde uzmanların en az %60’ı tarafından benimsenmiş ilişki değeri göz önüne alınmıştır. Oluşturulan toplu bilişsel harita Decision Explorer programında analiz edilmiştir. Bilişsel haritanın merkezilik (centrality) ve etki alanı (domain) analizi çalışmaları sonucunda GSMH, kişi başına milli gelir, reel ücretler ve özel sektör yatırımları en merkezi dört değişken olarak belirlenmiştir. Bu değişkenler literatürde işsizlik çalışmalarında sıkça kullanılan değişkenlerdir. Decision Explorer programı ile yapılan döngü analizleri sonucunda sistemin pek çok döngüye sahip olduğu ortaya çıkmıştır. Sistemde bulunan çok sayıda döngü, sistemin muhtemel dinamik ve karmaşık yapısına bir işaretir (Eden vd., 1992). Dinamik ve karmaşık bu yapı aynı zamanda sistemin doğrusal olmayan yapısına işaret etmektedir. Bu karmaşık yapıdaki sistemde işsizlik oranını tahmin ederken doğrusal bir tahminleme modeli kullanmak yerine girdi çıktı arasındaki ilişkilerin açık şekilde bilinmediği kompleks doğrusal olmayan modellerin tahmin edilmesinde başarı ile kullanılan yapay sinir ağları metodolojisi kullanılmıştır.

### YSA tahmin modeli

İşsizlik oranı tahmini çalışmasında bilişsel haritalar yöntemi ile belirlenen işsizliği etkileyen faktörlerden çalışma dönemi boyunca verisine ulaşılabilen faktörler tahmin modelinin girdi değişkenleri olarak ele alınmıştır. Bu faktörler aşağıda özetlenmiştir.



- GSMH % değişimi
- imalat sektöründe kapasite kullanım oranı
- reel efektif kur
- enflasyon
- reel faiz oranı
- imalat sektöründe reel ücret endeksi
- toplam ithalat
- toplam ihracat
- imalat sektöründe verimlilik endeksi
- özel yatırımlar/GSYİH
- kamu yatırımları /GSYİH

Çalışma 1988'in 3. çeyreği ve 2004'ün 4. çeyreği, dönemlerini kapsayacak şekilde gerçekleştirilmiştir. Türkiye İstatistik Kurumu 1988 ve 1999 yılları arasında işsizlik oranlarını yılda iki kez Nisan ve Ekim aylarında ölçtüğü ve ardından ölçüm periyodu yılda 4 döneme çıkartıldığı için 1988 –1999 yılları arasındaki işsizlik oranları enterpolasyon yöntemi ile 4 dönemlik değerler haline getirilmiştir. Kapasite kullanım oranları, reel ücret ve verimlilik seviyesi değerleri imalat sektörü için bulunabilmiş; çalışmada bu verilerin diğer sektörler için de benzer olacağı varsayılmıştır. Literatürde, veriyi mevsimsellikten arındırmanın yapay sinir ağları çalışmalarında daha iyi sonuçlar verebileceği konusunda tartışmalar bulunmaktadır. Franses ve Draisma (1997); Sharda ve Patil (1992), yapay sinir ağlarının mevsimsel etkileri fark edebileceği ve mevsimsel etkiler ile baş edebileceğini belirtirken Nelson ve diğerleri (1994), mevsimsellikten arındırılmış veri seti ile eğitilmiş sinir ağlarının, mevsimsel veri seti ile eğitilmişlere göre belirgin şekilde daha iyi tahmin sonuçlarına ulaştığını belirtmişlerdir. Yakın dönemde Zhang ve Qi (2005), tarafından yapılan bir araştırmada trendden arındırmanın ya da mevsimsellikten arındırmanın univariate modellerde çok daha düşük tahmin hatası elde edilmesini sağladığı gösterilmiştir. Bu çalışmada işsizlik oranı değişkeni mevsimsel bir değişken olduğu için (Zhang ve Qi, 2005), hem mevsimsel özellikler içeren orijinal veri seti hem de mevsimsellikten arındırılmış veri seti ile çalışılmıştır. Verinin normalize edilmesinin yapay sinir ağı performansını iyileştireceği literatürde gösterilmiştir (Masters, 1993). Yapay sinir ağları literatürde

kullanılan ölçek sınırları çoğunlukla (-1;1) arasındadır. Bu çalışmada ölçek sınırları (-0.9;0.9) ve (0.1;0.9) olacak şekilde ayrı modellerde incelenmiştir. Ölçeklemede kullanılan formül aşağıdaki gibidir:

$$\hat{x} = \hat{x}_{\min} + \frac{x - x_{\min}}{x_{\max} - x_{\min}} (\hat{x}_{\max} - \hat{x}_{\min}) \quad (12)$$

$\hat{x}_{\min}$  ve  $\hat{x}_{\max}$ , sırası ile kullanılan ölçeğin en küçük ve en büyük değerlerini;  $x_{\min}$  ve  $x_{\max}$ , ölçeklemenin uygulandığı orijinal veri setinin en küçük ve en büyük değerlerini;  $x$ , ölçeklenecek veriyi ve  $\hat{x}$ ,  $x$ 'in ölçeklenmiş değerini göstermektedir.

Yapay sinir ağı yapısı olarak, genel yakınsayıcı olarak kabul edilmiş iki katmanlı perseptron kullanılmıştır. Literatürde gizli hücre sayısını belirlemek konusunda kesin bir bilgi olmadığı için gizli hücre sayısı literatürde kullanılan farklı formüllere dayanılarak (Zhang vd., 1998 ve Masters, 1993), 2'den başlatılıp 25'e kadar artırılarak kullanılmıştır. İşsizlik oranını en iyi tahmin eden modeli bulmak için bir deney tasarımı yapılmış, iki farklı aktivasyon fonksiyonu, iki farklı ölçek, üç farklı girdi tipi ve mevsimsellik etkisi çalışmada kullanılmıştır. Bu farklı modeller Tablo 1'de özetlenmiştir. Model 1 tüm değişkenleri mevcut dönemdeki değerleri ile modelde kullanmaktadır, veri setine mevsimsel bir düzeltme yapılmamıştır, çıktı katmanında aktivasyon fonksiyonu olarak doğrusal purelin fonksiyonu kullanılmış ve veri seti (-0.9;0.9) aralığında ölçeklendirilmiştir. Model 1 ile 4 arasında bilişsel haritalar kullanılarak bulunan tüm girdiler mevcut dönemki değerleri ile analizde kullanılmıştır. Model 5 ile 8 arasında tüm girdilere bir de işsizlik oranının bir dönem önceki değeri eklenmiştir. Model 9 ile 13 arasında girdilere bir lag analizi yapılmış ve bu analizin sonuçları yapay sinir ağına girdi olarak kullanılmıştır. Lag analizi yapılmasının sebebi makroekonomik değişkenlerin birbirlerini zaman içerisinde etkilemeleridir. Ağın performansını ölçmekte kullanılan kriter hata karelerinin ortalaması (MSE) kriteridir. Bu kriterin formülü aşağıdaki gibidir:


$$MSE = \frac{1}{mN} \sum_{\mu=1}^N \sum_{i=1}^m (o_i^{\mu} - y_i^{\mu})^2 \quad (13)$$

Formülde m, çıktı katmanındaki nöron sayısını, N, eğitim örnekleri sayısını göstermektedir. Gizli katmanda tanjant sigmoid aktivasyon fonksiyonu kullanılmıştır. Zhang ve diğerleri (1998), hedef değişkenleri sürekli değişkenler olan tahmin problemlerinde çıktı katmanında aktivasyon fonksiyonu olarak doğrusal fonksiyon kullanmanın uygun olacağını belirtmişlerdir ancak çıktı katmanında kullanılan doğrusal aktivasyon fonksiyonları trende sahip zaman serilerini modellemekte yetersiz kaldıkları için çalışmada çıktı katmanında hem doğrusal hem de doğrusal olmayan (tanjant sigmoid) fonksiyonlar kullanılarak en iyi performansı veren ağ bulunmaya çalışılmıştır. Veri setinin yaklaşık % 15'i test seti olarak ayrılmış geri kalan veri eğitimde kullanılmıştır. Eğitimler MATLAB v. 6.5 programında, öğrenme oranını ve momentum katsayısını ayarlayabilen TRAINGD algoritması ile gerçekleştirilmiştir. Epok sayısı 1000 olarak alınmıştır. Eğitimlerde yerel minimumda takılma problemini engelleyebilmek için her bir ağ, 10 kez farklı başlangıç girdi ağırlıkları kullanılarak yeniden eğitilmiştir.

Çalışma sonucunda bulunan en iyi model, Model 20 olarak bulunmuştur (Tablo 1). Model 20'de girdi değişkenleri bilişsel haritalarla belirlenen tüm değişkenlerin ilgili periyoddaki değeri ve mevsimsel düzeltilmiş işsizlik değerinin bir önceki döneme ait değeri kullanılmış, veriler (0.1;0.9) arası ölçeklendirilmiş ve modelin çıktı fonksiyonu olarak doğrusal olmayan tanjant sigmoid fonksiyon kullanılmıştır. Modelin çıktısı ise incelenen dönemdeki mevsimsel düzeltilmiş işsizlik değeridir. Modelin eğitim seti MSE'si 0.0029; test setindeki MSE ise 0.0015 olarak bulunmuştur. Tahmin sonuçları ölçekten arındırıldığında gerçek değerleri ortalaması 8.34 olan veri setinde MSE, 0.39 olarak bulunmuş, ilgili modelin tatmin edici bir sonuç verdiği görülmüştür. Şekil 3'te test seti için tahmin sonuçları ve gerçek değerler gösterilmiştir.

Mevsimsel düzeltilmiş veri seti ile analizin, mevsimsel veri seti ile analize göre daha başarılı

sonuçlar verdiği görülmüştür. Mevsimsel düzeltmenin yapılmadığı veri setinde ağır eğitim setini ezberlemeye yatkın olduğu gözlemlenmiştir örneğin, Tablo 1-Model 1. Modellerin performansları iki aktivasyon fonksiyonu için karşılaştırılmış ve 0.05 anlamlılık düzeyi için doğrusal olmayan aktivasyon fonksiyonu ile elde edilen MSE değerlerinin doğrusal aktivasyon fonksiyonu ile elde edilen MSE'lere göre daha düşük olduğu; benzer şekilde (-0.9;0.9) ölçek aralığı ile (0.1;0.9) ölçek aralığı kullanılarak elde edilen sonuçlar karşılaştırılmış ve 0.05 anlamlılık düzeyi için (0.1;0.9) ölçeği ile elde edilen MSE değerlerinin (-0.9;0.9) ile elde edilen MSE değerlerine göre daha düşük olduğu bulunmuştur.



Şekil 3. Test seti için mevsimsel düzeltilmiş işsizlik oranı gerçek değerleri ve tahmin sonuçları

## Sonuçlar

Elde edilen sonuçlar aşağıdaki gibi özetlenebilir:

- Bilişsel haritalar kullanılarak işsizliği etkileyen değişkenler uzman görüşleri alınarak belirlenmiş ve bu değişkenler kullanılarak yapay sinir ağları ile bir tahmin çalışması yapılmıştır. Bulunan modelin tahmin performansı tatmin edici bulunmuştur.
- Mevsimsel özellikler taşıyan işsizlik değişkeninin mevsimsel düzeltme ile yapılan tahmin analizi sonuçlarının mevsimsel düzeltme yapılmadan gerçekleştirilen tahmin sonuçlarına göre daha başarılı olduğu gözlemlenmiştir.

Tablo 1. Yapay sinir ağı modelleri özellikleri ve eğitim-test sonuçları

Model	Veri tipi	Girdi	Ölçek	Aktivasyon fonksiyonu	Eğitim MSE	Test MSE
1	Orijinal veri	Tum	-0.9;0.9	Purelin	0.0026	0.0202
2	Orijinal veri	Tum	-0.9;0.9	Tansig	0.0040	0.0436
3	Orijinal veri	Tum	0.1; 0.9	Purelin	0.0038	0.0097
4	Orijinal veri	Tum	0.1; 0.9	Tansig	0.0029	0.0086
5	Orijinal veri	Tum + (*)	-0.9;0.9	Purelin	0.0020	0.0232
6	Orijinal veri	Tum + (*)	-0.9;0.9	Tansig	0.0023	0.0298
7	Orijinal veri	Tum + (*)	0.1; 0.9	Purelin	0.0086	0.0158
8	Orijinal veri	Tum + (*)	0.1; 0.9	Tansig	0.0110	0.0225
9	Orijinal veri	Lag	-0.9;0.9	Purelin	0.0037	0.0334
10	Orijinal veri	Lag	-0.9;0.9	Tansig	0.0024	0.0248
11	Orijinal veri	Lag	0.1; 0.9	Purelin	0.0051	0.0043
12	Orijinal veri	Lag	0.1; 0.9	Tansig	0.0056	0.0067
13	Mevsimsel düzeltilmiş	Tum	-0.9;0.9	Purelin	0.0048	0.0271
14	Mevsimsel düzeltilmiş	Tum	-0.9;0.9	Tansig	0.0052	0.0200
15	Mevsimsel düzeltilmiş	Tum	0.1; 0.9	Purelin	0.0039	0.0043
16	Mevsimsel düzeltilmiş	Tum	0.1; 0.9	Tansig	0.0034	0.0056
17	Mevsimsel düzeltilmiş	Tum + (*)	-0.9;0.9	Purelin	0.0064	0.0071
18	Mevsimsel düzeltilmiş	Tum + (*)	-0.9;0.9	Tansig	0.0101	0.0061
19	Mevsimsel düzeltilmiş	Tum + (*)	0.1; 0.9	Purelin	0.0035	0.0022
20	Mevsimsel düzeltilmiş	Tum + (*)	0.1; 0.9	Tansig	0.0029	0.0015
21	Mevsimsel düzeltilmiş	Lag	-0.9;0.9	Purelin	0.0049	0.0088
22	Mevsimsel düzeltilmiş	Lag	-0.9;0.9	Tansig	0.0041	0.0093
23	Mevsimsel düzeltilmiş	Lag	0.1; 0.9	Purelin	0.0034	0.0014
24	Mevsimsel düzeltilmiş	Lag	0.1; 0.9	Tansig	0.0032	0.0024

(\*) Analiz edilen dönemden bir dönem önceki işsizlik oranı

- Çıktı katmanında doğrusal olmayan tanjant sigmoid fonksiyonunun ağ performansına olan etkisinin doğrusal fonksiyonun ağ performansına olan etkisinden istatistiksel olarak farklı olmadığı gözlemlenmiştir.
- Çalışılan veri setinde (0.1;0.9) ölçeğinde sınırlandırılmış veri setinin (-0.9;0.9) ölçeğinde sınırlandırılmış veri setine göre daha iyi sonuçlar verdiği belirlenmiştir.
- Modelin eğitim seti MSE'si 0.0029; test setindeki MSE ise 0.0015 olarak bulunmuştur. Tahmin sonuçları ölçekten arındırıldığında gerçek değerleri ortalaması 8.34 olan veri setinde MSE, 0.39 olarak bulunmuş, ilgili modelin tatmin edici bir sonuç verdiği görülmüştür.

## Teşekkür

Bilgi Üniversitesi'nden Prof. Dr. Nurhan Yentürk'e, İstanbul Teknik Üniversitesi'nden Doç. Dr. Özlem Onaran ve Prof. Dr. Burç Ülengin'e, Galatasaray Üniversitesi'nden Doç. Haluk Levent'e çalışmaya olan katkılarından ötürü teşekkür ederiz.

## Kaynaklar

- Axelrod, R., (1976). *Structure of Decision: The Cognitive Maps of Political Elites*, Princeton: Princeton University Press, New Jersey.
- Banxia Software Limited, (2002), Decision Explorer User's Guide version 3.2, University of Strathclyde, Scotland.
- Bulutay, T., (1995). *Employment, unemployment and wages in Turkey*, International Labour Office, Ankara.
- Eden, C., (2003). Analyzing cognitive maps to help structure issues or problems, *European Journal of Operational Research*, **159**, 3, 673-686.
- Eden, C., ve Ackermann, F., (1998). *Making strategy: The journey of strategic management*, Sage, London.
- Eden, C., Ackermann, F. ve Cropper, S., (1992). The analysis of cause maps, *Journal of Management Studies*, **29**, 3, 309-323.
- Elmas Ç., (2003). *Yapay Sinir Ağları*, Seçkin Yayınevi, Ankara.
- Franses, P.H., ve Draisma, G., (1997). Recognizing changing seasonal patterns using artificial neural networks, *Journal of Econometrics*, **81**, 273-280.
- Gürsel, S. ve Ulusoy, V., (1999). *Türkiye'de İşsizlik ve İstihdam*, Yapı Kredi Yayınları, İstanbul.

- Haykin, S., (1999). *Neural Networks, A Comprehensive Foundation*, Prentice Hall, New Jersey.
- Hodgkinson, G.P., Maule, A.J. ve Bown, N.C., (2004). Causal cognitive mapping in the organizational strategy field: A comparison of alternative elicitation procedures. *Organizational Research Methods*, **7**, 1, 3-26.
- ILO, (2006). *Global employment trends*, International Labour Office, Geneva.
- Levent, H., Gürsel, S., Taştı, E., Yörükoğlu, A., Erçevik, A.S., ve Tercan, P., (2002). *Türkiye`de işgücü piyasası ve işsizlik*, TÜSİAD, TÜSİAD-T/2002/12-354, İstanbul.
- Masters, T., (1993). *Practical neural network recipes in C++*, Academic Press, Inc., London.
- Nelson, M., Hill, T., Remus, B., ve O'Connor, M., (1994). Can neural networks be applied to time series forecasting learn seasonal patterns: an empirical investigation. *Proceedings of the 27 Annual Hawaii International Conference on System Sciences*, 649-655, USA.
- Nozicka, G.J., Bonham, G.M., ve Shapiro, M.J., (1976). *Simulation Techniques* In Axelrod, R. eds, *Structure of Decision: The Cognitive Maps of Political Elites*, 349-359, Princeton: Princeton University Pres, New Jersey.
- OECD, (1996). *OECD Economic surveys, 1995-1996 Turkey*, Paris.
- Özesmi, U. ve Özesmi S., (2004). Ecological models based on people's knowledge: a multi-step fuzzy cognitive mapping approach, *Ecological Modelling*, **176**,1-2, 43-64.
- Öztemel, E., (2003), *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.
- Roberts, F.S., (1976). *The questionnaire method* In: Axelrod, R., eds, *Structure of Decision: The Cognitive Maps of Political Elites*, 333-342, Princeton: Princeton University Pres, New Jersey.
- Sharda, R., ve Patil R., (1992). Connectionist approach to time series prediction: an empirical test, *Journal of Intelligent Manufacturing*, **3**, 317-323.
- Wrightson, M.T., (1976). *The documentary coding method* In: Axelrod, R., (Ed.), *Structure of decision: The cognitive maps of political elites*, 291-332, Princeton University Press, New Jersey.
- Zhang G. P., Patuwo B. E., ve Hu, M. Y., (1998). Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, **14**, 35-62.
- Zhang G. P., (2003). Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, **50**, 159-175.
- Zhang G. P., ve Qi M., (2005). Neural network forecasting for seasonal and trend time series, *European Journal of Operational Research*, **160**, 501-514.
- 
- Türkiye İstatistik Kurumu, (2006). Hane Halkı İşgücü Anketi Veri Tabanı. <http://www.tuik.gov.tr>, (Kasım, 2006)