

YAPAY SİNİR AĞINA DAYALI YÜKSEK
DERECELİ BULANIK ZAMAN SERİSİ
ÖNGÖRÜ MODELİ

UFUK YOLCU

YÜKSEK LİSANS TEZİ
İSTATİSTİK ANABİLİM DALI

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY SİNİR AĞINA DAYALI
YÜKSEK DERECELİ BULANIK ZAMAN SERİSİ
ÖNGÖRÜ MODELİ

UFUK YOLCU

YÜKSEK LİSANS TEZİ
İSTATİSTİK ANABİLİM DALI

AKADEMİK DANIŞMAN
Yrd. Doç. Dr. Vedide Rezan USLU

SAMSUN – 2008

T.C.

ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bu çalışma jürimiz tarafından 03/09/2008 tarihinde yapılan sınav ile İstatistik Anabilim Dalı'nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Başkan: Prof. Dr. H. Alper GÜZEL

Üye: Yrd. Doç. Dr. V. Rezan USLU (danışman)

Üye: Yrd. Doç. Dr. Erol EĞRİOĞLU

ONAY:

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

.../.../2008

Prof. Dr. Hasan GÜMÜŞ
Fen Bilimleri Enstitüsü Müdürü

YAPAY SİNİR AĞINA DAYALI YÜKSEK DERECELİ BULANIK ZAMAN SERİSİ ÖNGÖRÜ MODELİ

ÖZET

Bulanık zaman serisi analizi yöntemleri geleneksel yöntemlere göre birçok avantajı olan etkili yöntemlerdir. Bulanık zaman serisi analizi yöntemlerinin klasik yöntemlerdeki kısıtlamalara sahip olmaması, son yıllarda bu yöntemlere olan ilgiyi arttırmaktadır. Zaman serisi gözlemleri bir önceki dönemde gözlemlenmiş veriye bağlı olabileceği gibi genellikle daha önceki dönemlerde gözlemlenmiş verilere de bağlıdır. Bu nedenle, yüksek dereceli bulanık zaman serisi yaklaşımları, birinci dereceden bulanık zaman serisi yaklaşımlarına göre daha iyi öngörü sonuçları verecektir. Bunun yanında yüksek dereceli bulanık zaman serisi yaklaşımlarında bulanık ilişki belirlenmesi, birinci dereceden yaklaşımlara göre, oldukça zor ve karmaşıktır. Bu çalışmada, bulanık ilişkilerin ileri beslemeli yapay sinir ağları ile belirlendiği, yüksek dereceli bulanık zaman öngörü modeli önerilmiştir. Önerilen yeni yaklaşımın uygulaması, literatürde sıkça kullanılan Alabama Üniversitesi kayıt verisine ve Türkiye Tüketici Fiyat Endeksi verisine uygulanarak literatürdeki diğer yöntemler ile karşılaştırılmıştır. Sonuçta, önerilen yeni yöntemin bulanık ilişki belirlemedeki karmaşıklığı ortadan kaldırdığı gibi, diğer yöntemlere göre daha iyi öngörü sonuçları verdiği de görülmüştür.

Anahtar Sözcükler: Kesikli bulanık küme, yüksek dereceli bulanık zaman serisi, bulanık mantık ilişki, yapay sinir ağları, öngörü.

HIGH ORDER FUZZY TIME SERIES FORECASTING MODEL BASED ON ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Fuzzy time series procedures have many advantages comparing to the conventional time series methods. Since fuzzy time series procedures do not require assumptions which are essential for the conventional techniques they are getting popular. As a current observation of time series can be dependent of the observation measured just one period before itself, it may depend on the several lagged observations. Because of this dependency high-order fuzzy time series approaches can give more reliable forecasting results than first-order fuzzy time series methods. However the determination of fuzzy relationships by using high-order fuzzy time series procedures is very difficult since it requires evaluating many complicated fuzzy relationship tables. In this study a high-order fuzzy time series method is proposed in which fuzzy relationships are determining by using feed-forward artificial neural networks. The proposed approach has been applied to the data on enrollments at the University of Alabama which is well-known and used in many other researches in literature, as well as the data of Consumer Price Index of Turkey. The empirical results are compared to the results from the conventional methods. It has been concluded that as the proposed method prevents to evaluate massive fuzzy relation tables it provides better results in terms of forecasting accuracy.

Key Words: Discrete fuzzy set, high order fuzzy time series, fuzzy logic relation, artificial neural network, forecast.

TEŞEKKÜR

Bu bölümün gerçek anlamını bulabilmesi için, öncelikle, şu an bu satırları yazabilmemdeki en temel vesile olan ve hiçbir an desteğini, yardımını ve en önemlisi güvenini benden esirgemeyen sevgili hocam Yrd. Doç. Dr. V. Rezan USLU'ya ve elbette ki, bu çalışmanın oluşumunda temel aldığım, en az benim kadar emeği olan ve bildiklerini bildiklerim yapmak için inanılmaz cömert davranan hocam Yrd. Doç. Dr. Erol EĞRİOĞLU'na sonsuz minnetlerimi sunmalıyım.

Ayrıca, bu uzun ve yorucu süreçte bana yoldaşlık eden Arş. Gör. Necati Alp ERİLLİ'ye, ve bölümümüz tüm hocalarına teşekkürlerimi bir borç bilirim.

Ve nihayet bugünlere gelmemde en büyük emeği olan, benden, en zor anlarımda desteğini ve en ihtiyacım olan sevgi ve hoşgörülerini esirgemeyen sevgili anne ve babama en içten dileklerimle teşekkürlerimi sunarım.

İÇİNDEKİLER

1.	GİRİŞ	1
2.	GENEL BİLGİLER	3
2.1.	Zaman Serileri ve Temel Kavramları	3
2.1.1.	Zaman Serisi Çözümleme Araçları	3
2.1.1.1.	Otokorelasyon Fonksiyonu (A.C.F.)	3
2.1.1.2.	Kısmi Otokorelasyon Fonksiyonu (P.A.C.F.)	5
2.1.2.	Bazı Olasılıksal Süreçler	7
2.1.2.1.	Ak Gürültü Süreci	8
2.1.2.2.	Otoregresif Süreçler	8
2.1.2.3.	Hareketli Ortalamalar Süreci	9
2.1.2.4.	Otoregresif Hareketli Ortalamalar Karma Süreci	10
2.2.	Bulanık Mantık	11
2.2.1.	Bulanık Küme Kuramı	13
2.2.1.1.	Bulanık Küme	15
2.2.1.2.	Bulanık Sayı	15
2.2.1.3.	Alfa Kesmeleri	18
2.2.1.4.	Eşitsizlikler	19
2.2.1.5.	Kesikli Bulanık Kümeler	20
2.2.1.6.	Bulanık Aritmetiğe Giriş	20
2.2.1.7.	Bulanık Aritmetik	23
2.2.1.8.	Bulanık Fonksiyonlar	23
2.3.	Yapay Sinir Ağları (YSA)	25
2.3.1.	Mimari Yapı	26
2.3.2.	Aktivasyon Fonksiyonu	29
2.3.3.	Öğrenme Algoritması	31
2.3.3.1.	Geri Yayılım Öğrenme Algoritması	32
2.3.3.2.	Levenberg-Marquardt Öğrenme Algoritması	35
3.	MATERYAL VE YÖNTEM	38
3.1.	Bulanık Zaman Serileri	38
3.1.1.	Chen'in Yüksek Dereceli Bulanık Zaman Serisi Yöntemi	40
3.1.2.	Y.S.A.'na Dayalı Yüksek Dereceli Bulanık Zaman Serisi Yöntemi	43

4.	BULGULAR VE TARTIŞMA	47
4.1.	Alabama Üniversitesi Kayıt Verisi Çözümlemesi	47
4.2.	Aylık Bazdaki TÜFE Verisi Çözümlemesi	53
4.3.	Yıllık Bazdaki TÜFE Verisi Çözümlemesi	59
5.	SONUÇ VE ÖNERİLER	66
6.	KAYNAKLAR	68
7.	EKLER	72
8.	ÖZGEÇMİŞ	85

SİMGE VE KISALTMALAR LİSTESİ

(a, b)	Açık aralık
α	Alpha
$E(Y)$	Beklenen değer Y
β	Beta
$>$	Büyük
$\geq$	Büyük ve eşit
δ	Delta
Δ	Delta
$\notin$	Elemanı değildir
$\in$	Elemanıdır
$=$	Eşit
η	Etta
γ	Gamma
MA	Hareketli ortalamalar modeli
H.K.O.K.	Hata kareler ortalaması karekökü
$\approx$	Hemen hemen eşit, yaklaşık
$\Rightarrow$	İse
$[a, b]$	Kapalı aralık
∂	Kısmi (türev)
P.A.C.F.	Kısmi otokorelasyon fonksiyonu
$\cos$	Kosinüs fonksiyonu
$Kov(X, Y)$	Kovaryans (X ile Y arasındaki)
$<$	Küçük
$\leq$	Küçük ve eşit
λ	Lambda
$\max$	Maksimum
$\min$	Minimum
μ	Mu
Ω	Omega
A.C.F.	Otokorelasyon fonksiyonu

ARIMA	Otoregresif bütünleşik hareketli ortalamalar modeli
ARMA	Otoregresif hareketli ortalamalar karma modeli
AR	Otoregresif model
ϕ	Phi
$\Re^+$	Pozitif reel sayılar
$\Re$	Reel sayılar
ρ	Rho
$^{\circ}\text{C}$	Santigrat derece
σ	Sigma
$\sin$	Sinüs fonksiyonu
$\sup$	Supremum (en küçük üst sınır)
/	Şart
θ	Theta
T.C.M.B.	Türkiye Cumhuriyeti Merkez Bankası
$\sum$	Toplam
TÜFE	Türkiye tüketici fiyat endeksi
$\exp$	Üstel
$V(Y)$	Varyans Y
YSA	Yapay sinir ağı

ŞEKİLLER LİSTESİ

Şekil 2.1.	Klasik küme için sıcaklık örneği	13
Şekil 2.2.	Bulanık küme için sıcaklık örneği	14
Şekil 2.3.	Bulanık kümelerde örtüşüm	15
Şekil 2.4.	Üçgensel bulanık sayı	16
Şekil 2.5.	Yamuk bulanık sayı	16
Şekil 2.6.	Üçgensel biçimli bulanık sayı	17
Şekil 2.7.	McCulloch-Pitts nöron modeli	27
Şekil 2.8.	Genel yapay nöron modeli	28
Şekil 2.9.	Çok tabakalı ileri beslemeli yapay sinir ağı mimarisi	29
Şekil 2.10.	Geri yayılım öğrenme algoritması için örnek yapay sinir ağı	33
Şekil 3.1.	İleri beslemeli yapay sinir ağı mimarisi	45
Şekil 4.1.	1971-1992 yılları Alabama Üniversitesi kayıt verisi	48
Şekil 4.2.	Şubat 2003 ve Şubat 2008 aylık bazda TÜFE verisi	54
Şekil 4.3.	Mart 2007 ve Şubat 2008 aylık bazda TÜFE ve öngörüler	59
Şekil 4.4.	Mart 2007 ve Şubat 2008 yıllık bazda TÜFE ve öngörüler	65

TABLOLAR LİSTESİ

Tablo 2.1.	Aktivasyon fonksiyonu tipine göre nöron çıktı değeri	30
Tablo 3.1.	İkinci dereceden bulanık zaman serisi öngörü modeli için örnek	46
Tablo 4.1.	Kayıt verisine ait reel ve bulanık değerler	49
Tablo 4.2.	Kayıt verisine ait bulanık öngörüler	50
Tablo 4.3.	Kayıt verisine ait durulaştırılmış öngörüler	51
Tablo 4.4.	Önerilen yöntemin kayıt verisi için H.K.O.K. değerleri	52
Tablo 4.5.	Önerilen ve Literatürdeki diğer yöntemlerin en iyi sonuçları	53
Tablo 4.6.	Aylık TÜFE verisine ait reel ve bulanık değerler	56
Tablo 4.7.	Aylık TÜFE verisine ait bulanık ve duru öngörüler	57
Tablo 4.8.	Aylık TÜFE verisi için yöntemlerin en iyi sonuçları	58
Tablo 4.9.	Yıllık TÜFE verisine ait reel ve bulanık değerler	61
Tablo 4.10.	Yıllık TÜFE verisine ait bulanık ve duru öngörüler	63
Tablo 4.11.	Yıllık TÜFE verisine ait T.C.M.B. beklenti anketi öngörülleri	64
Tablo 4.12.	Yıllık TÜFE için anket sonuçları ve yöntemlerin en iyi sonuçları	64

1. GİRİŞ

Bulanık zaman serisi analizi yöntemleri model varsayımı ve gözlem sayısı kısıtları içermeyen etkili yöntemlerdir. Son yıllarda bulanık zaman serisi yöntemlerine, bu tür kısıtlamalara sahip olmaması ve öngörü doğruluğu nedeniyle ilgi artmaktadır.

İlk olarak Zadeh (1965) tarafından verilen bulanık küme teorisi birçok uygulama alanına sahiptir. Bulanık zaman serisi kavramı ise ilk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya atılmıştır. Tüm bu çalışmalar Zadeh (1973, 1975) tarafından verilen tanımlamalara dayanmaktadır. Song ve Chissom (1993a, 1993b, 1994) bulanık zaman serisinin tahmin edilmesi için matris işlemlerine dayalı bir yöntem önermiştir ve bu yöntem üç aşamadan oluşmaktadır. Birinci aşama gözlemlerin bulanıklaştırılması, ikinci aşama bulanık ilişkilerin belirlenmesi ve üçüncü aşama ise durulaştırma aşmasıdır. Literatürde bulanık zaman serilerinde bu üç aşamanın da iyileştirilmesi için çeşitli çalışmalar yapılmıştır. Bulanık ilişkinin belirlenmesi aşamasında, Chen (1996), Song ve Chissom (1993a, 1993b) tarafından önerilen yöntemdeki matris hesaplama işlemleri yerine bulanık ilişki tablosundan yararlanarak daha kolay hesaplama yapabilen bir yöntem önermiştir. Huarng ve Yu (2006), bulanık ilişkinin belirlenmesinde, basit bir ileri beslemeli yapay sinir ağı (feed-forward artificial neural network) kullanımı önermiştir. Huarng ve Yu (2006) tarafından önerilen bu yöntemde birinci dereceden bulanık zaman serisi yaklaşımı ele alındığından, kullanılan ileri beslemeli yapay sinir ağı modeli bir girdi, iki gizli tabaka birimi ve tek çıktı biriminden oluşmaktadır. Literatürdeki tüm bu yöntemlerin hepsinde birinci derece bulanık zaman serisi modeli ile ilgilenilmiştir. Birinci dereceden bulanık zaman serisi yaklaşımının sadece birinci dereceden otoregresif (AR(1)) yapılı zaman serileri için uygulanması gerekir. Ancak gerçek hayatta karşılaşılan zaman serilerinin sadece AR(1) yapısında olması düşünülemez. Birçok zaman serisi AR(2), AR(3) gibi yüksek dereceli ilişkiler ile öngörülebilir. Chen (2002) AR(1) yapılı verilerin çözümlenmesi için yüksek dereceli bulanık zaman serisi yaklaşımı önermiştir. Chen (2002)'nin önerdiği bu yöntemde yüksek dereceli modellerde tüm gecikmeli bulanık değişkenler bulunmaktadır. Yani 4. dereceden bir zaman serisinin çözümlenmesinde $F(t)$ bulanık zaman serisi iken, $F(t-1)$, $F(t-2)$, $F(t-3)$, $F(t-4)$ bulanık gecikmeli değişkenleri modelde yer almaktadır. Dolayısıyla Chen (2002)'nin çalışmasında tanımlanan yüksek dereceli bulanık zaman serisi modeli AR(p), $p>1$ yapılı zaman serilerini de modelleyebilir.

Bunun yanında yüksek dereceli bulanık zaman serisi yaklaşımında derece arttıkça, bulanık ilişkinin belirlenmesinde, Chen (2002) tarafından verilen yöntemin uygulanması da oldukça zorlaşmaktadır. Yüksek dereceli modelin çözümlenmesinde bulanık ilişkiler, yapay sinir ağı ile belirlenir ise Chen (2002)'nin önerdiği yöntemdeki işlem yoğunluğundan kurtulmak mümkündür.

Bu çalışmada yüksek dereceli bulanık zaman serisi modelini çözümleyen, bulanık ilişkinin belirlenmesinde ileri beslemeli yapay sinir ağının kullanıldığı, yeni bir yöntem önerilmiştir. Yapay sinir ağına dayalı bu yaklaşım, ilk olarak literatürde sıkça kullanılan Alabama Üniversitesi 1971-1992 yıllarına ait kayıt verisine ve daha sonra da 2003 Şubat ve 2008 Şubat ayları arasında hesaplanan Türkiye Tüketici Fiyat Endeksi zaman serisine uygulanarak sonuçlar elde edilmiş ve diğer yöntemlerle karşılaştırılmasıyla birlikte, yıllık bazda hesaplanan sonuçlar ayrıca Türkiye Cumhuriyeti Merkez Bankası (T.C.M.B.) tarafından her yılın belirli dönemlerinde yayınlanan, enflasyon beklentisi anketi sonuçları ile de karşılaştırılarak önerilen yaklaşımın üstün olduğu görülmüştür.

Çalışmanın ikinci bölümünde genel bilgiler ana başlığı altında sırasıyla, zaman serileri ile ilgili temel tanım ve kavramlar, bulanık mantık yaklaşımı ve genel kavramları ayrıca yapay sinir ağları ve bileşenleri, üçüncü bölümde ise materyal ve yöntem ana başlığı altında, bulanık zaman serileri ve çözümleme yöntemleri ile birlikte önerilen yöntem tanıtılmıştır. Çalışmanın dördüncü bölümünde bulgular ve tartışma ana başlığı altında, önerilen yönteme ait üç uygulama verilmiş ve son olarak beşinci bölümde ise elde edilen sonuçlar sonuç ve öneriler ana başlığı altında değerlendirilmiş, ortaya konabilecek yeni çalışmalarda üzerinde durulması gereken konulara kısaca değinilmiştir.

2. GENEL BİLGİLER

2.1. Zaman Serileri ve Temel Kavramları

İlgilenilen zamana bağlı bir olayın, gözlem ya da deney sonucunda aldığı değerlerden oluşan veri topluluğuna zaman serisi adı verilir. İlgilenilen Z değişkeninin belirli bir t anında almış olduğu değer Z_t ile gösterildiğinde, Z_t 'lerin oluşturduğu $\{Z_t, t \in T\}$ kümesi bir olasılıksal süreçtir (Chatfield, 1989). Yani zaman serisi genellikle, zamanın deterministik bir fonksiyonu değildir. Zaman serileri çözümlenirken, serilere olasılıksal süreç olarak bakılması, tanımlanması ve olasılıksal modeller kullanılması gerekir (Box ve Jenkins, 1970).

Zaman içinde sürekli olarak kaydedilebilen verilere sahip serilere sürekli, yalnızca belirli aralıklarla elde edilebilen verilere sahip serilere kesikli zaman serileri denir. Elektrik sinyalleri, ses titreşimleri gibi mühendislik alanlarına ait veriler sürekli, faiz oranı, satış hacmi, enflasyon oranı gibi iktisadi veriler de kesikli zaman serileri için örnek olarak verilebilir (Kadılar, 2005).

Zaman serisi terimleri, trend, mevsimsel dalgalanmalar, konjonktürel dalgalanmalar ve rassal dalgalanmalar olmak üzere dört etkenin etkisi altında oluşurlar. Zaman serilerinde, iç bağımlılık olarak da isimlendirilebilen, gözlem değerlerinin birbirine bağlı olması özelliği nedeniyle, zaman serisinin geçmiş dönem gözlem değerleri arasındaki ilişki belirlenerek, ileriye dönük öngörude bulunulur.

2.1.1. Zaman Serisi Çözümleme Araçları

2.1.1.1. Otokorelasyon Fonksiyonu (A.C.F.)

Otokorelasyon fonksiyonu, serinin durağanlığının, durağan değilse buna sebep olan etmenlerin belirlenmesinde, otoregresif bütünleşik hareketli ortalama modellerini (ARIMA) tanımlama ve uygunluk sınavasında kullanılır. Bir zaman serisinde Z_t ve Z_{t+k} k gecikmeli iki değer arasındaki ilişkinin standartlaştırılmış ölçümü otokorelasyon katsayısı ve bu katsayıların k gecikmeye bağlı olarak ifadesine de otokorelasyon fonksiyonu adı verilir (Cryer, 1986).

$\rho_Z(k)$ ile gösterilen kitle otokorelasyon fonksiyonu,

$$\rho_Z(k) = \frac{E[(Z_t - \mu_Z)(Z_{t+k} - \mu_Z)]}{E[(Z_t - \mu_Z)^2]} \quad , \quad k = 0, \pm 1, \pm 2, \dots \quad (2.1)$$

şeklinde tanımlanır. (2.1) eşitliğindeki pay kısmı otokovaryans fonksiyonu olarak bilinir ve $\gamma_Z(k)$ ile, payda kısmı ise Z_t zaman serisinin varyansı olarak bilinir ve σ_Z^2 ile gösterilir. Bu durumda otokorelasyon fonksiyonu,

$$\rho_Z(k) = \frac{\gamma_Z(k)}{\gamma_Z(0)} = \frac{\gamma_Z(k)}{\sigma_Z^2} \quad , \quad k = 0, \pm 1, \pm 2, \dots \quad (2.2)$$

şeklinde de ifade edilebilir.

Örneklem zaman serisine dayanarak, $\gamma_Z(k)$ 'nın tahmini $c_Z(k)$ ve $\rho_Z(k)$ 'nın tahmini de $r_Z(k)$ ile gösterilir. Otokorelasyon fonksiyonu, gecikmenin simetrik bir fonksiyonu olması nedeniyle, $\rho_Z(k) = \rho_Z(-k)$ olacağından, pozitif gecikmeler için,

$$c_Z(k) = \frac{1}{n-k} \sum_{t=1}^{n-k} (Z_t - \bar{Z})(Z_{t+k} - \bar{Z}) \quad , \quad k = 0, 1, 2, \dots, n \quad (2.3)$$

$$r_Z(k) = \frac{c_Z(k)}{c_Z(0)} \quad , \quad k = 0, 1, 2, \dots, n \quad (2.4)$$

olarak verilebilir. k. gecikme için hesaplanan r_k otokorelasyon katsayısının varyansı Barlett (1955)'de aşağıdaki gibi elde edilmiştir.

$$V(r_k) = \frac{1}{n} \sum_{v=-\infty}^{\infty} (r_v^2 + r_{v+k}^2 r_{v-k}^2 - 4r_k r_v r_{v-k} + 2r_v^2 r_k^2) \quad (2.5)$$

(2.5)'deki formülün yaklaşık ve daha kolay bir formu aşağıdaki gibidir.

$$V(r_k) = \frac{1}{n} \left[1 + 2 \sum_{i=1}^k r_i^2 \right] \quad (2.6)$$

İncelenen zaman serisinin içerdği bileşenlerin belirlenmesi ve bu bileşenlerin, rassal bileşenden ayırt edilebilmesi için, ortalaması sıfır ve standart hatası yaklaşık olarak $1/\sqrt{n}$ olan, otokorelasyon katsayılarının örnekleme dağılımından yararlanılır (Box ve Jenkins, 1976). Eğer zaman serisi yalnızca rassal bileşeni içeriyor ise, tüm otokorelasyonları sıfır olacağından $V(r_k) = 1/n$ olacağı açıktır ve zaman serisinin otokorelasyon katsayıları $\pm z_\alpha/\sqrt{n}$ aralığında kalıyorsa serinin rassal olduğu sonucuna varılır. Bununla birlikte bu sınırların dışında kalan otokorelasyonların sıfırdan farklı ve anlamlı olduğu, modellemede göz ardı edilemeyeceği ve ARMA modelin derecesini belirlemede kullanılacağı bilinmektedir. Zaman serisinin olasılıksal yapısının belirlenmesinde anlamlı otokorelasyonların ve serinin rassal bileşen dışındaki bileşenlerinin ortaya çıkarılması önemlidir. Aynı yöntemle modelin yeterliliği de araştırılabilir.

2.1.1.2. Kısmi Otokorelasyon Fonksiyonu (P.A.C.F.)

Zamana bağlı bir değişkenin şimdiki değeri Z_t 'nin, diğer gecikmelere etkisi sabit kalmak üzere, önceki Z_{t-k} değerleriyle ilişkisini veren ölçüm, k gecikmesi için kısmi otokorelasyon adını alır ve ϕ_{kk} ile ifade edilir (Markidakis ve Wheelwright, 1978). Kısmi otokorelasyon katsayısı, regresyon çözümlemesinde, diğer değişkenler sabit iken, yani bu değişkenlerin etkilerinin olmadığı varsayıldığında, iki değişken arasındaki ilişkinin miktarını veren kısmi korelasyon katsayısına benzer.

Zaman serisi çözümlemesinde, seriye uygun AR modelinin derecesi, çok sayıda gecikme için anlamlı otokorelasyon katsayısı olacağından otokorelasyon fonksiyonuna göre belirlenemez. Bunun yanında p 'inci dereceden bir AR modeli için, kısmi otokorelasyon fonksiyonunda p tane sıfırdan istatistiksel olarak farklı kısmi otokorelasyon katsayısı vardır ve diğer gecikmelerde kısmi otokorelasyon katsayıları sıfırdan farklı değildir. Örneğin, bir zaman serisinde kısmi otokorelasyon fonksiyonuna bakıldığında; yalnızca birinci gecikmede sıfırdan farklı kısmi otokorelasyon katsayısı var ve diğer gecikmeler için katsayıların sıfırdan farklılıkları anlamlı değilse, ilgili seri için belirlenecek model AR(1) olacaktır.

Genel olarak, k 'inci dereceden AR sürecinde j 'inci katsayı ϕ_{kj} ve son katsayı da ϕ_{kk} ile ifade edilir. ϕ_{kk} 'ların oluşturduğu denklemler kümesi, Yule-Walker denklemler sistemi şeklinde aşağıdaki gibi yazılarak, çözümlenebilir (Box ve Jenkins, 1970);

$$\rho_j = \phi_{k1} \rho_{j-1} + \dots + \phi_{k(k-1)} \rho_{j-k+1} + \phi_{kk} \rho_{j-k}, \quad j = 1, 2, \dots, k \quad (2.7)$$

Bu denklem sistemi daha açık bir ifadeyle aşağıdaki gibi yazılabilir;

$$\begin{aligned} \rho_1 &= \phi_{k1} \rho_0 + \phi_{k2} \rho_1 + \dots + \phi_{kk} \rho_{k-1} \\ \rho_2 &= \phi_{k1} \rho_1 + \phi_{k2} \rho_2 + \dots + \phi_{kk} \rho_{k-2} \\ &\dots \quad \dots \quad \dots \quad \dots \quad \dots \\ \rho_k &= \phi_{k1} \rho_{k-1} + \phi_{k2} \rho_{k-2} + \dots + \phi_{kk} \rho_k \end{aligned} \quad (2.8)$$

Uygulamada, Yule-Walker denklem sisteminde ρ 'ların yerine, r örneklem otokorelasyon katsayıları kullanılarak çözümleme yapılır ve k gecikmeleri için ϕ_{kk} tahminleri olan, $\hat{\phi}_{kk}$ örneklem kısmi otokorelasyon katsayıları elde edilir (Cryer, 1986).

Bir AR(p) modeli için, tahmin edilmiş kısmi otokorelasyonlar p 'inci gecikmeden sonra, ortalaması sıfır, varyansı $1/n$ olan bir normal dağılıma sahiptir ve belirlenen bir anlam düzeyinde, $\pm z_\alpha / \sqrt{n}$ sınırları içinde kalır (Quenouille, 1949).

Aşağıdaki iteratif yöntem, kısmi otokorelasyonların hesaplanabilmesi için verilebilir.

$$\begin{aligned} N_1(j) &= D_1(j) = \rho_j \\ N_k(j) &= N_{k-1}(j+1) - D_{k-1}(j) \cdot \hat{\phi}_{k-1,k-1} \\ D_k(j) &= D_{k-1}(j) - N_{k-1}(j+1) \cdot \hat{\phi}_{k-1,k-1} \\ \hat{\phi}_{kk} &= \frac{N_k(1)}{D_k(0)} \end{aligned}, \quad \begin{aligned} j &= 0, 1, 2, \dots \\ k &= 2, 3, \dots \end{aligned} \quad (2.9)$$

(2.9) formüllerinden kısmi otokorelasyon katsayı tahmini,

r_k : k gecikmeli otokorelasyon katsayısı,

$\hat{\phi}_{kk}$: j 'inci gecikmeli serinin etkisi yok edildiğinde k gecikmeli kısmi otokorelasyon katsayı tahmini

olmak üzere;

$$\hat{\phi}_{kk} = \frac{r_k - \sum_{j=1}^{k-1} (\hat{\phi}_{k-1,j})(r_{k-j})}{1 - \sum_{j=1}^{k-1} (\hat{\phi}_{k-1,j})(r_j)} , \quad \hat{\phi}_{kj} = \hat{\phi}_{k-1,j} - (\hat{\phi}_{kk})(\hat{\phi}_{k-1,k-j}) \quad (2.10)$$

ifadesi ile hesaplanabilir (Kadılar, 2005).

2.1.2. Bazı Olasılıksal Süreçler

Yaklaşık 30 yılı aşkın bir süredir literatürde, ele alınan zaman serileri için en doğru tahmin yapılabilmesi amacıyla en uygun modelin bulunmasına çalışılmaktadır. Otoresif hareketli ortalamalar karma süreci (ARMA) yöntemi olarak da bilinen ve George E.P.Box ve Gwilym M. Jenkins tarafından 1976 yılında ortaya atılmış Box-Jenkins yöntemi bu çalışmalardan biridir. Bu yöntem temelde, ororegresif süreçler (AR), hareketli ortalamalar süreçleri (MA) ve bu iki sürecin kombinasyonu ile oluşan ARMA süreçlerine dayanmaktadır. Günümüze kadar birçok bilimsel çalışmada kullanılmış olan bu etkili yöntem, ele alınan zaman serisinin durağanlığı ve tersinirliği varsayımını öngörmektedir.

Box-Jenkins yöntemi aşağıda belirtilmiş dört ana aşamadan oluşmaktadır.

- Model bulma aşaması
- Parametre tahmini aşaması
- Artık analizi aşaması
- Gelecekle ilgili tahmin yapma aşaması

Şimdi, bu yöntemin öngördüğü zaman serilerinde durağanlığı ve yine yöntemin temelini oluşturan AR, MA ve ARMA süreçleri ile ilgili bazı temel bilgileri ele alalım.

2.1.2.1. Ak Gürültü Süreci

Karşılıklı bağımsız ve aynı dağılımlı Z_t raslantı değişkenlerinin dizisinden oluşan olasılıksal sürece ak gürültü süreci denir. Durağan bir olasılıksal süreç olan ak gürültü süreci aşağıdaki özelliklere sahiptir.

- i. $E(Z_t) = \mu_z$, $\mu_z \in \Re$
- ii. $V(Z_t) = \sigma_z^2$, $\sigma_z^2 \in \Re^+$
- iii. $\gamma(k) = 0$, $(k \neq 0)$

2.1.2.2. Otoregresif Süreçler

Z_t , durağan ve a_t hata terimleri bir ak gürültü süreci olmak koşulu ile p 'inci dereceden bir otoregresif süreç, bir başka ifade ile AR(p) modeli, açık bir formda;

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t \quad (2.11)$$

şeklinde ifade edilebilir. Aynı zamanda $B^k Z_t = Z_{t-k}$ ile tanımlanan geri öteleme operatörü kullanılarak (2.11) eşitliği kapalı bir formda,

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t = a_t \quad (2.12)$$

şeklinde düzenlenebilir.

Genel olarak uygulamada birinci ve ikinci dereceden otoregresif süreçlerin kullanımı yaygındır. Birinci dereceden otoregresif süreç, Markov süreci, ikinci dereceden otoregresif süreç ise, Yule süreci olarak adlandırılır.

p 'inci dereceden bir otoregresif süreç olan AR(p) modelinin karakteristikleri elde edilmek istenir ise modelin otokorelasyon fonksiyonu;

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \quad , \quad k > 0 \quad (2.13)$$

Bunun yanında $\gamma(0) = \sigma_z^2$ ve $\gamma(k) = \gamma(-k)$ özellikleri kullanılarak, sürecin varyansı;

$$\sigma_z^2 = \frac{\sigma_a^2}{1 - \phi_1 \rho_1 - \phi_2 \rho_2 - \dots - \phi_p \rho_p} \quad (2.14)$$

olarak elde edilir.

2.1.2.3. Hareketli Ortalamalar Süreci

a_t hata terimleri bir akgürültü süreci olmak koşulu ile q . dereceden bir hareketli ortalamalar süreci, bir başka ifade ile MA(q) modeli, açık bir formda;

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.15)$$

şeklinde ifade edilebilir. Aynı zamanda, geri öteleme operatörü kullanılarak (2.15) eşitliği kapalı bir formda,

$$\begin{aligned} Z_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \\ &= \theta(B) a_t \end{aligned} \quad (2.16)$$

şeklinde düzenlenebilir.

q . dereceden bir hareketli ortalamalar sürecinin otokorelasyon fonksiyonu;

$$\rho_k = \begin{cases} \frac{-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2} & , k = 1, 2, \dots, q \\ 0 & , k > q \end{cases} \quad (2.17)$$

olarak bulunur.

Bunun yanında $E(Z_t) = 0$ ve $Kov(Z_t, Z_{t-k}) = E(Z_t, Z_{t-k})$ olduğundan,

$$\gamma(k) = \begin{cases} (-\theta_k + \theta_1 \theta_{k+1} + \theta_2 \theta_{k+2} + \dots + \theta_{q-k} \theta_q) \sigma_a^2 & , k = 1, 2, \dots, q \\ 0 & , k > q \end{cases} \quad (2.18)$$

ifadesi elde edilir.

Sürecin varyansı ise, $k=0$ olduğu durumda;

$$\gamma(0) = (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2) \sigma_a^2 \quad (2.19)$$

olacaktır.

2.1.2.4. Otoregresif Hareketli Ortalamalar Karma Süreci

a_t hata terimleri bir akgürültü süreci olmak koşulu ile (p,q) 'uncu dereceden bir hareketli ortalamalar süreci, bir başka ifade ile ARMA (p,q) modeli, açık bir formda;

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.20)$$

şeklinde ifade edilebilir. Aynı zamanda, geri öteleme operatörü kullanılarak (2.20) eşitliği kapalı bir formda,

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) Z_t &= (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) a_t \\ \phi(B) Z_t &= \theta(B) a_t \end{aligned} \quad (2.21)$$

şeklinde düzenlenebilir.

ARMA (p,q) modelinin karakteristikleri elde edilmek istenir ise; modelin açık formu olarak verilen (2.20) eşitliğinin her iki tarafı öncelikle Z_{t-k} ile çarpılıp, oluşan denklemin beklenen değeri alındığında,

$$\gamma(k) = \phi_1 \gamma_{k-1} + \dots + \phi_p \gamma_{k-p} + \gamma_{za}(k) - \theta_1 \gamma_{za}(k-1) - \dots - \theta_q \gamma_{za}(k-q) \quad (2.22)$$

sonucu bulunur. Burada $\gamma_{za}(k)$, Z ve a arasındaki çapraz kovaryans fonksiyonu,

$\gamma_{za}(k) = E[Z_{t-k} a_t]$ şeklinde ifade edilir ve

$$\gamma_{za}(k) = \begin{cases} = 0 & , k > 0 \\ \neq 0 & , k \leq 0 \end{cases} \quad (2.23)$$

olur. Aynı zamanda $k \geq q + 1$ olduğu durumda,

$$\gamma(k) = \phi_1 \gamma_{k-1} + \phi_2 \gamma_{k-2} + \dots + \phi_p \gamma_{k-p} \quad (2.24)$$

ve böylece otokorelasyon fonksiyonu,

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \quad (2.25)$$

şeklinde bulunur.

ARMA(p, q) modelinin varyansı ise, $k = 0$ olduğu durumda,

$$\gamma_0 = \phi_1 \gamma_1 + \dots + \phi_p \gamma_p + \sigma_a^2 - \theta_1 \gamma_{za}(-1) - \dots - \theta_q \gamma_{za}(-q) \quad (2.26)$$

olarak elde edilir.

2.2. Bulanık Mantık

Bilgisayarlar çok karmaşık sayısal işlemleri anında çözümleyebilmesine karşın, idrak etme ve deneyimlerle kazanılmış bilgileri kullanabilme noktasında oldukça yetersizdir. Bunun yanında, insan beyni dünyanın en karmaşık makinesi olarak kabul edilebilir ve sayısal bir işlemi ancak birkaç dakikada yapabilirken, idrak etmeye yönelik olayları çok kısa bir sürede yapabilir. İnsanı ya da insan beynini üstün kılan temel özellik, sinirsel algılayıcılar vasıtası ile kazanılmış ve görelî olarak sınıflandırılmış bilgileri kullanmasıdır. Acaba bir bilgisayar yardımı ile böyle bir zekâ üretmek mümkün olabilir mi? Bu amaçla geliştirilen, Uzman Sistemler (US), Bulanık Mantık (BM), Genetik Algoritma (GA) ve Yapay Sinir Ağları (YSA) gibi yapay zekâ alt dalları özellikle son yıllarda, geniş bir araştırma ve uygulama alanı bulmaktadırlar (Elmas, 2003).

Bulanık mantık, bulanık küme teorisine dayanan bir matematiksel disiplin olup, insan mantığında olduğu gibi, uzun-kısa, sıcak-soğuk, hızlı-yavaş, siyah-beyaz gibi keskin değerler yerine, çok uzun-uzun-orta-kısa-çok kısa, sıcak-ılık-az soğuk-soğuk-çok soğuk vb. gibi ara değerlere göre çalışmaktadır. Belirtilen bu ara değer terimleri sözel terimler olup bulanık değişkenler olarak isimlendirilir. Bulanık mantık için, gerçek

dünyada her an değişen durumlarda değişik sonuçlar ortaya çıkabileceğinden, matematiğin gerçek dünyaya uygulanması denilebilir.

Bulanık mantık yaklaşımı, makinelere, insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsözlerinden yararlanarak çalışabilme yeteneği verir. Bu yeteneği kazandırırken de sayısal ifadeler yerine sembolik ifadeler kullanır ki bu sembolik ifadelerin makinelere aktarılması matematiksel bir temele dayanır. Bu matematiksel temel, bulanık mantık kümeler kuramı ve buna dayanan bulanık mantıktır.

Bulanık mantık yaklaşımı ilk olarak 1956 yılında Amerika Birleşik Devletlerinde düzenlenen bir konferansta duyurulmasına karşın, ilk önemli çalışma, Lotfi A. Zadeh tarafından 1965 yılında yayımlanan ve bulanık mantık ve bulanık küme kuramını ortaya koyan makaledir. Zadeh (1965), insan düşüncesinin büyük çoğunluğunun bulanık olduğu, kesin olmadığı, sıfır ve birle temsil edilen boolean mantığın bu düşünce işlemini yeterli şekilde ifade etmediğini belirtmiştir. Bulanık mantık, klasik mantığın aksine, iki seviyeli değil, çok seviyeli işlemleri kullanmaktadır.

Zadeh (1965), bulanık mantığın temel özelliklerini şu şekilde ifade etmiştir;


- i. Bulanık mantıkta, kesin değerlere dayanan düşünme yerine, yaklaşık düşünme kullanılır.
- ii. Bulanık mantıkta her şey $[0,1]$ aralığında belirli bir derece ile gösterilir.
- iii. Bulanık mantıkta bilgi büyük, küçük, çok az gibi dilsel ifadeler şeklindedir.
- iv. Bulanık mantık çıkarım işlemi dilsel ifadeler arasında tanımlanan kurallar ile yapılır.
- v. Her mantıksal sistem bulanık olarak ifade edilebilir.
- vi. Bulanık mantık matematiksel modeli çok zor elde edilen sistemler için çok uygundur.

Bulanık mantık uygulaması ilk olarak, 1974 yılında Mamdani tarafından, bir buhar makinesinin bulanık denetiminin gerçekleştirilmesi ile olmuştur. Bu çalışmayı takiben, dünyanın çeşitli yerlerindeki birçok firma birçok başarılı uygulama

gerçekleştirmiştir. Bulanık mantık uygulamaları, son senelerde özellikle Japonya, Amerika ve Almanya’da ticari ve endüstri alanlarında oldukça yaygın ve başarıyla gerçekleştirilmekte ve gelecekte de bu uygulamaların hızla gelişeceği ve yaygınlaşacağı öngörülmektedir. Bulanık kuramının uygulamalarının ürünleri de Japonya’da 1990 yılında tüketicilerin hizmetine sunulmaya başlanmıştır. Örneğin, bulanık denetimli çamaşır makinesi, çamaşırın cinsine, miktarına, kirliliğine göre en etkili yıkama ve su kullanım programını seçebilmektedir. Benzer uygulamalar arabalarda yakıt püskürtme ve ateşlemede, elektrik süpürgesi, televizyon ve müzik kümeleri gibi aygıtlarda da kullanılabilmektedir (Elmas 2003).

2.2.1. Bulanık Küme Kuramı

Klasik küme kuramında bir eleman o kümenin ya elemanıdır ya da değildir, kısmi üyelik söz konusu olamaz. Nesnenin üyelik değeri 1 ise kümenin tam elemanı, 0 ise elemanı değildir yani klasik kümelerde elemanların üyelikleri $\{0,1\}$ değerlerini alır. Bulanık mantık, insanların günlük yaşantısında nesnelere verdiği üyelik değerlerini, dolayısıyla insan davranışlarını taklit eder. Örneğin elini sıcak suya sokan bir kimse suyun ısısını tam olarak bilemez ve fakat sıcak, az sıcak, soğuk, çok soğuk gibi dilsel belirteçler kullanır (Elmas 2003).




Şekil 2.1. Klasik küme için sıcaklık örneği

Klasik kümelere örnek olarak, Şekil 2.1. incelendiğinde, sıcaklığın 20 °C'nin altında olmasının soğuk, üstünde olmasının ise sıcak olarak nitelendirildiği görülür. Bu

durumda $19,5^{\circ}\text{C}$ sıcak değildir. Doğal olarak bu mantığın esnekliği söz konusu değildir. Oysaki gerçek yaşamda ise, sınırlar bu kadar keskin çizgilerle nitelendirilemezler.


Klasik kümelerdeki bu keskin durumun aksine, bulanık kümelerde elemanların üyelik dereceleri $[0,1]$ aralığında sonsuz sayıda değerler alabilir. Keskin kümelerdeki soğuk-sıcak, hızlı-yavaş, aydınlık-karanlık gibi ikili değişkenler, bulanık mantıkta biraz soğuk, biraz sıcak, biraz aydınlık gibi esnek betimleyicilerle esnetilerek gerçek yaşam şartlarına benzetilirler.

Bulanık kümelere örnek olarak, Şekil 2.2. incelendiğinde, $10-40^{\circ}\text{C}$ arasındaki değerler, sıcak kümesine üye olmalarına karşın, $20-40^{\circ}\text{C}$ arasındaki sıcaklık değerleri, 1 üyelik değerine sahipken, $10-20^{\circ}\text{C}$ arasındaki sıcaklık değerleri 0 ile 1 arasında değişen üyelik derecelerine sahip olacaktır. Yani, örneğin 11°C az sıcak, 15°C ise biraz sıcak olarak değerlendirilebilir.



Şekil 2.2. Bulanık küme için sıcaklık örneği

20°C 'yi oda sıcaklığı kabul ederek soğuk bulanık kümesi oluşturulmak istendiğinde elde edilen Şekil 2.3. incelenir ise, $10-20^{\circ}\text{C}$ arasındaki değerlerin değişen üyelik dereceleriyle hem sıcak hem de soğuk bulanık kümesine ait oldukları ve dolayısıyla 15°C değerinin de 0,5 üyelik derecesi ile sıcak hem de soğuk bulanık kümesine ait olduğu görülür. Şekilde taralı olarak gösterilen alan ilgili bulanık kümelerin kesişim bölgesidir ve bulanık kümelerin örtüşümü olarak isimlendirilir.



Şekil 2.3. Bulanık kümelerde örtüşüm

Bulanık kümeler kuramını gerektiğinde anlayabilmek için, bulanık kümeler, bulanık sayılar, genişleme prensibi, alfa (α) kesme, aralık aritmetiği, bulanık fonksiyonlar gibi, bulanık kümeler kuramına temel oluşturacak, kavramlar tanımlanmalıdır.


2.2.1.1. Bulanık Küme

Ω herhangi bir küme ve $\bar{A}$, Ω ’nın bulanık alt kümesi olmak üzere, $\forall x \in \Omega$ için Ω kümesini $[0,1]$ aralığına eşleştiren, $\bar{A}$ ’nın bir üyelik fonksiyonu $\bar{A}(x)$ ile gösterilsin. Eğer $\bar{A}(x_0) = 1$ ise x_0 , $\bar{A}$ bulanık alt kümesine aittir, $\bar{A}(x_1) = 0$ ise x_1 , $\bar{A}$ bulanık alt kümesine ait değildir. Eğer $\bar{A}(x_2) = 0.6$ ise x_2 ’nin $\bar{A}$ bulanık alt kümesine üyelik değeri 0.6’dır. $\bar{A}$ ’nın bir üyelik fonksiyonu, $\bar{A}(x)$, daima 1 veya 0 değerleri alıyor ise $\bar{A}$, Ω kümesinin bir bulanık olmayan (crisp) altkümesidir. Bulanık kümelerin hemen hepsinde bulanık sayılar kullanılır (Buckley, 2006).

2.2.1.2. Bulanık Sayı


Bulanık sayının genel bir tanımı Buckley ve Elsami (2002), Klir ve Yuan (1995) tarafından yapılan çalışmalarda bulunabilir. Ancak bu çalışmada, bulanık sayılardan,

daha çok üçgensel ve yamuk bulanık sayılar ile ilgili bilgilerin verilmesi yeterli görülmüştür.



Şekil 2.4. Üçgensel bulanık sayı

Bir $\bar{N}$ üçgensel bulanık sayısı, $a < b < c$ olmak üzere, üç sayı tarafından tanımlanır. Burada a , üçgensel bulanık sayının sol ucunu, c , sağ ucunu ve b ise orta noktasını göstermektedir. $[a, c]$ aralığı üçgenin temelini (tabanını), $x = b$ ise tepe noktasını oluşturur. Üçgensel bulanık sayı bu parametrelere bağlı olarak, $\bar{N} = (a/b/c)$ şeklinde gösterilir. Herhangi bir üçgensel bulanık sayı, $\bar{N} = (1.2/2/2.4)$, Şekil 2.4.'de gösterilmiştir ve şekilden de görülebileceği gibi $\bar{N}(2) = 1$ ve $\bar{N}(1.6) = 0.5$ olacaktır.




Şekil 2.5. Yamuk bulanık sayı

Bir $\bar{M}$ yamuk bulanık sayısı ise, $a < b < c < d$ olmak üzere dört sayı tarafından tanımlanır. Burada, $[a, d]$ aralığı yamuğun temelini (tabanını) ve $[b, c]$ aralığı ise merkezini (tavanını) oluşturur. Yamuk bulanık sayı bu parametrelere bağlı olarak, $\bar{M} = (a/b, c/d)$ şeklinde gösterilir. Herhangi bir yamuk bulanık sayı, $\bar{M} = (1.2/2, 2.4/2.7)$, Şekil 2.5.'de gösterilmiştir.

Bu iki tür bulanık sayıdan başka, üçgensel bulanık sayıya benzer bir başka bulanık sayı türü, üçgensel biçimli bulanık sayıdır. Bir $\bar{P}$ üçgensel biçimli bulanık sayısı parametrelere bağlı olarak, $\bar{P} \approx (a/b/c)$ şeklinde ifade edilir. $[a, c]$ aralığı üçgenin temelini (tabanını), $x = b$ ise tepe noktasını yani üyelik değerinin 1 olduğu noktayı oluşturur. Bir $\bar{P} \approx (a/b/c)$ bulanık sayısının üçgensel biçimli olması için,

- i. $[a, b]$ aralığında monoton artan ve sürekli
- ii. $[b, c]$ aralığında monoton azalan ve sürekli

olması yeterlidir. Herhangi bir üçgensel biçimli bulanık sayı, $\bar{P} \approx (1.2/2/2.4)$, Şekil 2.6.'da gösterilmiş ve şekilden de görülebileceği gibi $[1.2, 2]$ ve $[2, 2.4]$ aralıkları doğru olmayan eğriler ile birleştirilmiştir. Verilen örnek üçgensel biçimli bulanık sayıda, $[1.2, 2.4]$ aralığı üçgenin temelini (tabanını), $x = 2$ ise tepe noktasını yani üyelik değerinin 1 olduğu merkez noktayı oluşturur.



Şekil 2.6. Üçgensel biçimli bulanık sayı

Üçgensel biçimli bulanık sayıya benzer şekilde yamuk biçimli bulanık sayı da tanımlanabilir.

2.2.1.3. Alfa Kesmeleri

Alfa kesmeleri bulanık sayının üyelik değeri sabit tutulduğunda elde edilen alt aralıklara verilen isimdir. Herhangi bir Ω kümesinin bulanık bir alt kümesi $\bar{A}$ ise, $\bar{A}$ için α – kesme, $\bar{A}[\alpha]$ şeklinde yazılır ve

$$\bar{A}[\alpha] = \{x \in \Omega / \bar{A}(x) \geq \alpha\} \quad , 0 < \alpha \leq 1 \quad (2.27)$$

olarak tanımlıdır. $\alpha = 0$ – kesme veya $\bar{A}[0]$ farklı tanımlanmalıdır. Herhangi bir $\bar{A}$ bulanık kümesi için, $\bar{A}[0]$, $\bar{A}$ bulanık kümesinin temeli (base) olarak isimlendirilir ve bazı çalışmalarda bu temel değer (a, c) açık aralığı ile de ifade edilebilmesine karşın bu çalışmada $[a, c]$ kapalı aralığı ile ifade edilecektir. $\alpha = 0$ – kesme $\bar{N} = (1.2/2/2.4)$ şeklinde verilen bir üçgensel bulanık sayı için, $\bar{N}[0] = [1.2, 2.4]$, $\bar{M} = (1.2/2, 2.4/2.7)$ olarak verilen bir yamuk bulanık sayı için, $\bar{M}[0] = [1.2, 2.7]$ ve $\bar{P} \approx (1.2/2/2.4)$ olarak verilen bir üçgensel biçimli bulanık sayı için de, $\bar{P}[0] = [1.2, 2.4]$, (2.27) ifadesinden elde edilebilmektedir.

Üyelik değerleri 1 olan elemanların meydana getirdiği küme, bir bulanık sayının merkezini (core) oluşturur. $\bar{N} = (a/b/c)$ ve $\bar{N} \approx (a/b/c)$ şeklinde ifade edilen üçgensel ve üçgensel biçimli bulanık sayılar için merkez, tek bir b noktasıdır. Bunun yanında $\bar{M} = (a/b, c/d)$ ve $\bar{M} \approx (a/b, c/d)$ şeklinde ifade edilen yamuk ve yamuk biçimli bulanık sayılar için ise merkez, $[b, c]$ kapalı aralığı olacaktır.

Herhangi bir $\bar{Q}$ bulanık sayısı için $0 \leq \alpha < 1$ olmak üzere, $\bar{Q}[\alpha]$ kapalı ve sınırlı bir aralıktır ve aşağıdaki gibi gösterilir,

$$\bar{Q}[\alpha] = [q_1(\alpha), q_2(\alpha)] \quad (2.28)$$

Burada, $q_1(\alpha)$ alfanın artan, $q_2(\alpha)$ ise alfanın azalan fonksiyonu ve dolayısı ile $q_1(1) \leq q_2(1)$ olmalıdır. Eğer $\bar{Q}$ üçgensel biçimli veya yamuk biçimli bulanık sayı ise,

- i. $q_1(\alpha); [0,1]$ aralığında alfanın sürekli, monoton artan bir fonksiyonudur.
- ii. $q_2(\alpha); [0,1]$ aralığında alfanın sürekli, monoton azalan bir fonksiyonudur.
- iii. Üçgensel biçimli bulanık sayı için; $q_1(1) = q_2(1)$ ve yamuk biçimli bulanık sayı için; $q_1(1) < q_2(1)$

olacaktır.

Şekil 2.4'de verilen $\bar{N} = (1.2/2/2.4)$ üçgensel bulanık sayısı için $\bar{N}[\alpha] = [n_1(\alpha), n_2(\alpha)]$ şeklinde ifade edilen alfa kesmesinde $n_1(\alpha) = 1.2 + 0.8\alpha$ ve $n_2(\alpha) = 2.4 - 0.4\alpha$, $0 \leq \alpha \leq 1$ olarak elde edilir. Benzer şekilde, Şekil 2.5'de verilen $\bar{M} = (1.2/2, 2.4/2.7)$ yamuk bulanık sayısı için $\bar{M}[\alpha] = [m_1(\alpha), m_2(\alpha)]$ şeklinde ifade edilen alfa kesmesinde $m_1(\alpha) = 1.2 + 0.8\alpha$ ve $m_2(\alpha) = 2.7 - 0.3\alpha$, $0 \leq \alpha \leq 1$ olarak elde edilir. Bu denklemler tüm alfa kesmeleri için tanımlıdır.

2.2.1.4. Eşitsizlikler

$\bar{N} = (a/b/c)$ herhangi bir üçgensel bulanık sayı ve δ herhangi bir reel sayı olmak üzere, $a \geq \delta \Rightarrow \bar{N} \geq \delta$ ve $a > \delta \Rightarrow \bar{N} > \delta$ ifadeleri yazılabileceği gibi $c \leq \delta \Rightarrow \bar{N} \leq \delta$ ve $c < \delta \Rightarrow \bar{N} < \delta$ ifadeleri de yazılabilir.

$\bar{A}$ ve $\bar{B}$, Ω kümesinin iki bulanık alt kümesi olsun. Eğer $\bar{A} \leq \bar{B}$ ise Ω kümesindeki tüm x elemanları için $\bar{A}(x) \leq \bar{B}(x)$ olacaktır ve $\bar{A}$, $\bar{B}$ bulanık kümesinin bir alt bulanık kümesidir.

2.2.1.5. Kesikli Bulanık Kümeler

$\bar{A}$, Ω kümesinin bulanık alt kümesi olsun. Eğer $\bar{A}(x)$, Ω kümesindeki x değerlerinin sonlu sayısında sıfırdan farklı ise $\bar{A}$ bulanık kümesi kesikli bulanık küme olarak isimlendirilir. Varsayalım ki $\bar{A}(x)$, yalnızca x_1, x_2, x_3, x_4 de sıfır değildir. Bu durumda bulanık küme aşağıdaki gibi ifade edilebilir,

$$\bar{A} = \left\{ \frac{\mu_1}{x_1}, \frac{\mu_2}{x_2}, \frac{\mu_3}{x_3}, \frac{\mu_4}{x_4} \right\} \quad (2.29)$$

Burada $i = 1, 2, 3, 4$ olmak üzere, μ_i , üyelik değerini göstermektedir ve üyelik fonksiyonu,

$$\bar{A}(x_i) = \begin{cases} \mu_i, & i = 1, 2, 3, 4 \\ 0, & a.h. \end{cases} \quad (2.30)$$

şeklinde gösterilebilir.

2.2.1.6. Bulanık Aritmetiğe Giriş

$\bar{A}$ ve $\bar{B}$ gibi iki bulanık sayı mevcut olduğunda bunlar arasında toplama, çıkarma, çarpma ve bölme gibi işlemlere ihtiyaç duyulabilir. $\bar{A} + \bar{B}$, $\bar{A} - \bar{B}$ ve bunun gibi hesaplamaları yapmanın iki yöntemi vardır,

Bu yöntemlerden ilki genişleme prensibidir ve şu şekilde ifade edilebilir,

$\bar{A}$ ve $\bar{B}$ gibi iki bulanık sayı olsun. $\bar{A} + \bar{B} = \bar{C}$ olduğunda $\bar{C}$ için üyelik fonksiyonu;

$$\bar{C}(z) = \sup_{x,y} \{ \min(\bar{A}(x), \bar{B}(y)) / x + y = z \} \quad (2.31)$$

şeklinde ifade edilirken, eğer $\bar{C} = \bar{A} - \bar{B}$ ise $\bar{C}$ için üyelik fonksiyonu;

$$\bar{C}(z) = \sup_{x,y} \{ \min(\bar{A}(x), \bar{B}(y)) / x - y = z \} \quad (2.32)$$

şeklinde ifade edilir. Eğer $\bar{C} = \bar{A} \cdot \bar{B}$ ise $\bar{C}$ için üyelik fonksiyonu;

$$\bar{C}(z) = \sup_{x,y} \{ \min(\bar{A}(x), \bar{B}(y)) / x \cdot y = z \} \quad (2.33)$$

şeklinde ifade edilirken, eğer $\bar{C} = \bar{A} / \bar{B}$ ise $\bar{C}$ için üyelik fonksiyonu;

$$\bar{C}(z) = \sup_{x,y} \{ \min(\bar{A}(x), \bar{B}(y)) / x / y = z \} \quad (2.34)$$

olarak ifade edilir ve bu durumda da $\bar{C}$ bir bulanık sayı olacaktır. $\bar{A}$ ve $\bar{B}$ üçgensel (ya da yamuk) bulanık sayılar olduğunda $\bar{A} + \bar{B}$, $\bar{A} - \bar{B}$ de üçgensel (ya da yamuk) bulanık sayılar olmasına karşın çarpma ve bölme işlemlerinde durum böyle değildir. $\bar{A} \cdot \bar{B}$ ve $\bar{A} / \bar{B}$ ise üçgensel (ya da yamuk) biçimli bulanık sayı olacaktır. Burada $\sup$ ifadesi en küçük üst sınırı göstermektedir. Ω reel sayıların bir kümesi olduğunda eğer Ω en büyük üyeye sahip ise, $\sup(\Omega) = \max(\Omega)$ olmaktadır. Örneğin; $\Omega = [0,1]$ olduğunda $\sup(\Omega) = 1$ ve ancak $\Omega = [0,1]$ olduğunda ise $\sup(\Omega) = \max(\Omega) = 1$ olarak elde edilir.

Yukarıda verilen genişleme prensibine dayanan denklemler ile hesaplama yapmak zor olabileceğinden, genişleme prensibine denk bir yaklaşım olarak alfa kesmesi ve aralık aritmetiği kullanılabilir.

Bu çalışmada aralık aritmetiğine yalnızca kısa bir giriş yapılacaktır. Bu konu ile ilgili daha fazla bilgi Moore (1979) ve Neumaier (1990) tarafından yapılan çalışmalardan edinilebilir. $[a_1, b_1]$ ve $[a_2, b_2]$ iki kapalı, sınırlı, gerçel sayıların aralığı olsun. $*$ işareti çarpma, bölme, toplama veya çıkarmayı gösterdiğinde, ilgili işlemler $[a_1, b_1] * [a_2, b_2] = [\alpha, \beta]$ şeklinde gösterilir ve burada;

$$[\alpha, \beta] = \{ a * b / a_1 \leq a \leq b_1, a_2 \leq b \leq b_2 \} \quad (2.35)$$

$*$ işareti bölme işlemini temsil ettiğinde, $[a_2, b_2]$ aralığının sıfırı kapsamadığı varsayımı altında (2.35) eşitliği daha basit bir şekilde,

$$[a_1, b_1] + [a_2, b_2] = [a_1 + a_2, b_1 + b_2] \quad (2.36)$$

$$[a_1, b_1] - [a_2, b_2] = [a_1 - b_2, b_1 - a_2] \quad (2.37)$$

$$[a_1, b_1] / [a_2, b_2] = [a_1, b_1] \left[\frac{1}{b_2}, \frac{1}{a_2} \right] \quad (2.38)$$

ve

$$[a_1, b_1] \cdot [a_2, b_2] = [\alpha, \beta] \quad (2.39)$$

eşitliklerine dönüşür. Burada,

$$\alpha = \min\{a_1 a_2, a_1 b_2, b_1 a_2, b_1 b_2\} \quad (2.40)$$

ve

$$\beta = \max\{a_1 a_2, a_1 b_2, b_1 a_2, b_1 b_2\} \quad (2.41)$$

şeklindedir.

Eğer $a_1 > 0$ ve $b_2 < 0$ veya $b_1 > 0$ ve $b_2 < 0$ ya da bunun gibi bilgiler biliniyor ise çarpma ve bölme işlemleri daha kolay ifade edilebilirler. Örneğin $a_1 \geq 0$ ve $a_2 \geq 0$ olduğunda,

$$[a_1, b_1] \cdot [a_2, b_2] = [a_1 a_2, b_1 b_2] \quad (2.42)$$

$b_1 < 0$ ancak $a_2 \geq 0$ olduğunda ise,

$$[a_1, b_1] \cdot [a_2, b_2] = [a_1 b_2, a_2 b_1] \quad (2.43)$$

bunun yanında $b_1 < 0$ ancak $b_2 < 0$ olduğunda,

$$[a_1, b_1] \cdot [a_2, b_2] = [b_1 b_2, a_1 a_2] \quad (2.44)$$

$a_1 \geq 0$ ancak $b_2 < 0$ olduğunda ise,

$$[a_1, b_1] \cdot [a_2, b_2] = [a_2 b_1, b_2 a_1] \quad (2.45)$$

olacaktır.

2.2.1.7 Bulanık Aritmetik

$\bar{A}$ ve $\bar{B}$ iki bulanık sayı olsun. Alfa kesmelerinin kapalı, sınırlı aralıklar olduğunu biliyoruz. Bu bulanık sayılar için alfa kesmeleri $\bar{A}[\alpha] = [a_1(\alpha), a_2(\alpha)]$, $\bar{B}[\alpha] = [b_1(\alpha), b_2(\alpha)]$ şeklindedir. Eğer $\bar{C} = \bar{A} + \bar{B}$ ise,

$$\bar{C}[\alpha] = \bar{A}[\alpha] + \bar{B}[\alpha] \quad (2.46)$$

$\bar{C} = \bar{A} - \bar{B}$ ise,

$$\bar{C}[\alpha] = \bar{A}[\alpha] - \bar{B}[\alpha] \quad (2.47)$$

eşitlikleri $[0,1]$ aralığındaki her α için yazılabilir. Bunun yanında $\bar{C} = \bar{A} \cdot \bar{B}$ ise,

$$\bar{C}[\alpha] = \bar{A}[\alpha] \cdot \bar{B}[\alpha] \quad (2.48)$$

ayrıca her α için $\bar{B}[\alpha]$ değerlerinin sıfırdan farklı olması koşulu ile $\bar{C} = \bar{A} / \bar{B}$,

$$\bar{C}[\alpha] = \bar{A}[\alpha] / \bar{B}[\alpha] \quad (2.49)$$

şeklinde ifade edilir. Bu yöntem bulanık aritmetiğin genişleme prensibi ile eşdeğer bir yöntemdir.

2.2.1.8. Bulanık Fonksiyonlar

Bir bağımsız değişkenli fonksiyon $H(\bar{X}) = \bar{Z}$ şeklinde tanımlansın. Genellikle $\bar{X}$ üçgensel (ya da yamuk) bir bulanık sayı ise, $\bar{Z}$ de üçgensel (ya da yamuk) biçimli bulanık sayı olarak elde edilir. Bulanık fonksiyon kavramı iki şekilde ortaya atılabilir. Birincisi, genişleme prensibine dayalı olarak şu şekilde verilebilir,

Herhangi bir $h : [a, b] \rightarrow \mathfrak{R}$, $H(\bar{X}) = \bar{Z}$ için aşağıdaki gibi genişletilebilir.

$$\bar{Z}(z) = \sup_x \{ \bar{X}(x) / h(x) = z, a \leq x \leq b \} \quad (2.50)$$

bu denklem $[a, b]$ aralığında herhangi bir üçgensel (ya da yamuk) bulanık sayı, $\bar{X}$, için $\bar{Z}$ 'nin üyelik fonksiyonunu tanımlar. Eğer h sürekli ise, $\bar{Z}$ 'nin α -kesmesi, $\bar{Z}[\alpha] = [z_1(\alpha), z_2(\alpha)]$ ve $0 \leq \alpha \leq 1$ olmak üzere,

$$z_1(\alpha) = \min\{h(x) / x \in \bar{X}[\alpha]\} \quad (2.51)$$

$$z_2(\alpha) = \max\{h(x) / x \in \bar{X}[\alpha]\} \quad (2.52)$$

şeklinde elde edilebilir.

İki bağımsız değişken söz konusu olduğunda, $[a_1, b_1]$ aralığındaki x ve $[a_2, b_2]$ aralığındaki y değerleri için $z = h(x, y)$ olsun. Bu durumda $H(\bar{X}, \bar{Y}) = \bar{Z}$ için h genişlemesi,

$$\bar{Z}(z) = \sup_{x,y} \{\min(\bar{X}(x), \bar{Y}(y)) / h(x, y) = z\} \quad (2.53)$$

şeklinde olacaktır. Burada $\bar{X}$ ve $\bar{Y}$, $[a_1, b_1]$ ve $[a_2, b_2]$ aralıklarındaki birer üçgensel (ya da yamuk) bulanık sayıdır. Eğer h sürekli ise, $\bar{Z}$ 'nin α -kesmesi, $\bar{Z}[\alpha] = [z_1(\alpha), z_2(\alpha)]$ ve $0 \leq \alpha \leq 1$ olmak üzere,

$$z_1(\alpha) = \min\{h(x, y) / x \in \bar{X}[\alpha], y \in \bar{Y}[\alpha]\} \quad (2.54)$$

$$z_2(\alpha) = \max\{h(x, y) / x \in \bar{X}[\alpha], y \in \bar{Y}[\alpha]\} \quad (2.55)$$

olarak elde edilir.

Bulanık fonksiyon kavramı ikinci olarak alfa kesmeler ve aralık aritmetiğine dayalı olarak şu şekilde verilebilir,

$h: [a, b] \rightarrow \mathfrak{R}$ şeklinde bir fonksiyon tanımlanmış olsun. $\bar{X}$, $[a, b]$ aralığına ait olmak üzere $H(\bar{X}) = \bar{Z}$ için genişleme, $h(\bar{X}[\alpha]) = \bar{Z}[\alpha]$ ($0 \leq \alpha \leq 1$), aralık aritmetiği vasıtasıyla hesaplanabilir. $\bar{X}[\alpha]$ aralığı fonksiyona verilerek $\bar{Z}[\alpha]$ aralığı elde edilir ve burada, bu aralık üzerinde h genişlemesini tanımlayabilmek için aritmetik operasyonları

uygulamaya ihtiyaç duyulur. $\bar{Z}$ değerini elde edebilmek için bu alfa kesmeleri koyulur. Daha fazla bağımsız değişken için genişleme, benzer şekilde olacaktır. Örneğin,

$$\bar{Z} = H(\bar{X}) = \frac{\bar{A}\bar{X} + \bar{B}}{\bar{C}\bar{X} + \bar{D}} \quad (2.56)$$

ile ifade edilen bulanık fonksiyonu dikkate alalım. $\bar{X}$, $[0,10]$ aralığında üçgensel bulanık sayı ve ayrıca $\bar{A}, \bar{B}, \bar{C}, \bar{D}$ üçgensel bulanık sayılar olmak üzere, $\bar{C} \geq 0$, $\bar{D} > 0$ ve $\bar{C}\bar{X} + \bar{D} > 0$ olduğunda genişleme,

$$h(x_1, x_2, x_3, x_4, x) = \frac{x_1 x + x_2}{x_3 x + x_4} \quad (2.57)$$

ile ifade edilir. Burada, x_1 yerine $\bar{A}[\alpha]$, x_2 yerine $\bar{B}[\alpha]$, x_3 yerine $\bar{C}[\alpha]$, x_4 yerine $\bar{D}[\alpha]$ ve x yerine $\bar{X}[\alpha]$ aralıklarını kullanarak aralık aritmetiği yoluyla $\bar{Z}$ için $\bar{Z}[\alpha]$ hesaplanır.

2.3. Yapay Sinir Ağları (YSA)

Yakın geçmişte bulanık zaman serilerinin analizinde ilişki belirleme ve bunun gibi belirli aşamalarında, diğer yöntemlere seçenек olarak yapay sinir ağları yöntemi de kullanılmaya başlanmıştır. Huarng ve Yu (2006, 2008) çalışmalarında bulanık zaman serilerinde bulanık ilişkilerin belirlenmesinde ileri beslemeli yapay sinir ağı kullanmışlardır. Yapay sinir ağları ile bulanık ilişki belirlenmesi, özellikle yüksek dereceli modellerde kolaylık sağlar ve bulanık mantık ilişki ve grup ilişki tablolarının oluşturulmasındaki karmaşıklığı ortadan kaldırdığı gibi öngörülerini de iyileştirir.

Diğer analiz yöntemlerine göre daha iyi sonuçlar elde edildiğinden, yapay sinir ağlarına olan ilgi giderek artmıştır. Bu bölümde, yapay sinir ağlarının bileşenleri ve öngörü probleminde yapay sinir ağlarının kullanımı ile ilgili temel bilgiler verilecektir.

Yapay sinir ağlarını, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalar olarak

tanımlanabilir (Öztemel, 2003). Yapay sinir ağları, biyolojik sinir ağlarını taklit eden sentetik ağlar olarak da tanımlanabilir. Günümüzde, yapay sinir ağları, kullanım kolaylığı ve ürettiği iyi sonuçlardan dolayı, matematik, istatistik, fizik, mühendislik ve bilgisayar bilimleri uygulama alanlarında başarıyla kullanılmaktadır.

Mühendislerin, matematikçilerin, istatistikçilerin ve fizikçilerin yeni fikirler elde etmek için biyolojik bilimlere olan ilgisi uzun bir geçmişe sahiptir. Yapay sinir ağlarının oluşturulmasında da biyolojik sinir ağlarından esinlenilmiş olmasına karşın, hala biyolojik sinir sistemleri ile yapay sinir ağları arasında hem mimarileri hem de yetenekleri yönünden büyük farklılıklar bulunmaktadır. Hiçbir model insan beyninin performansının aynısını taklit etmede başarılı olamamıştır. Bu nedenle, geliştirilen farklı çeşitlerdeki yapay sinir ağı konfigürasyonunda insan beyni sadece bir mecaz olarak kalmıştır.

Yapay sinir ağları genel olarak, biyolojik sinir ağlarından esinlenerek oluşturulmuş matematiksel algoritmalar şeklinde tanımlanabilir. Matematiksel bir algoritma olarak tanımlanan yapay sinir ağları, örneklerden öğrenebilen ve öğrendiğini genelleştirebilen algoritmadır. Ağ gösterimi, matematiksel algoritmanın grafiksel ifadesidir. (Günay ve ark., 2007).

Yapay sinir ağlarının işleyişini yönlendiren bileşenler, mimari yapı, aktivasyon fonksiyonu ve öğrenme algoritması olmak üzere üç ana başlık altında toplanabilir.


2.3.1. Mimari Yapı

Yapay sinir ağları, birbirlerine bağlı, yapay nöronlardan (düğümler, birimler) oluşurlar. Yapay sinir ağı mimarisinin temel birimi olan her bir nöron için, nörona gelen girdi değeri ve bu nöronun diğer nöron veya nöronlara ilettiği bir çıktı değeri vardır. Nörona gelen girdi değeri tek bir nörona gelen çıktı değeri olabileceği gibi birden fazla nörona gelen çıktı değerlerinin toplamı da olabilir. Nöronun aldığı bu girdi değeri bir fonksiyon yardımıyla çıktı değerine dönüştürülür ve diğer nöron ya da nöronlara girdi değeri olarak iletilir. Bir nöronun çıktı değerinin diğer bir nörona girdi değeri olarak iletilmesi işlemine sinyal akışı adı verilir.

İlk olarak, 1943 yılında McCulloch ve Pitts tarafından tanımı yapılan bir yapay nöron modeli Şekil 2.7.'de görülmektedir. x_i girdileri ($i=1,2,\dots,n$), k anındaki girdi değerinin yokluğuna ya da varlığına bağlı olarak sırasıyla 0 ya da 1 değerini alırlar. Nöronun çıktı değeri o ile gösterilmiştir. Bu model için $k+1$ anında elde edilecek çıktı değeri,


$$o^{k+1} = \begin{cases} 1, & \text{eğer } \sum_{i=1}^n w_i x_i^k \geq T \\ 0, & \text{eğer } \sum_{i=1}^n w_i x_i^k < T \end{cases} \quad (2.58)$$

eşitliği ile elde edilir. Burada, diğer nöronların çıktısı olan her bir x_i girdi değeri, karşılık gelen w_i ağırlıyyla ($w_i = \pm 1, i = 1, 2, \dots, n$) çarpılarak toplanır ve elde edilen değer eğer T gibi bir eşik değerinden büyükse, nöronun $k+1$ anındaki o^{k+1} çıktısı 1 değerini alır, diğer durumda nöronun çıktı değeri 0 olacaktır.



Şekil 2.7. McCulloch-Pitts nöron modeli

Tanımlanacak yapay nöron modelinde ise, ağdaki tüm nöronların işlemlerinin eş zamanlı olduğu varsayılır. Çıktı değerleri $[0,1]$ aralığında değerler alabilecektir. Ağırlıklar model içinde düzeltilir ve sinyal akışı dışında ağın nöronları arasında hiçbir etkileşim olmaz. Bu özellikleri taşıyan genel yapay nöron modeli Şekil 2.8. de gösterilmiştir (t üst indisi devrikliği gösterir).



Şekil 2.8. Genel yapay nöron modeli

Şekilden de anlaşılacağı gibi her yapay nöron, girdi bağlantılarına sahiptir ve tek çıktıya sahip bir işlem biriminden oluşur. Nöronun çıktı sinyal akışı gibi, x_i nöron girdilerinin sinyal akışı da tek yönlü olarak düşünülür. Tüm sinyal akışlarının ileri yönlü olduğu ağ, ileri beslemeli yapay sinir ağı olarak isimlendirilir. Nöron çıktı değeri,

$$o = f(w^t x) \quad (2.59a)$$

ya da

$$o = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2.59b)$$

şeklinde ifade edilir. w , ağırlık vektörü,

$$w = [w_1 \quad w_2 \quad \dots \quad w_n]^t \quad (2.60)$$


ifadesi ile tanımlanabilirken x girdi vektörü ise,

$$x = [x_1 \quad x_2 \quad \dots \quad x_n]^t \quad (2.61)$$

ile gösterilir.

Çok tabakalı yapay sinir ağı mimarileri, tek girdi ve çıktı tabakası içerirken, birden çok gizli tabaka içerebilirler. Mimari yapının belirlenmesi, tabakalardaki nöron

sayılarının belirlenmesi anlamına gelir. Şekil 2.9.'da çok tabakalı ileri beslemeli bir yapay sinir ağı mimarisi görülmektedir.



Şekil 2.9. Çok tabakalı ileri beslemeli yapay sinir ağı mimarisi

Şekilden de anlaşılacağı üzere, nöronlar birbirlerine ağırlıklarla bağlıdır, aynı tabakanın nöronları arasında bağlantı yoktur, bağlantılar tek yönlü ve ileri doğrudur. Şekilde çıktı tabakasında yalnızca bir nöron varken, isteğe göre birden çok nöron da kullanılabilir. Burada w_{ij} , girdi tabakasındaki i nöronu ile gizli tabakadaki j nöronu arasındaki ağırlığı ve w_{jk} , gizli tabakadaki j nöronu ile çıktı tabakasındaki k nöronu arasındaki ağırlığı gösterir. Şekilde çıktı tabakasında, yalnızca bir nöron olduğu için, k indisi bu tek nöronu göstermektedir. Benzer şekilde oluşturulabilecek bir başka mimaride ise girdi tabakasındaki nöronlar ile çıktı tabakasındaki nöron (ya da nöronlar) arasında doğrudan bağlantı da kurulabilir.

2.3.2. Aktivasyon Fonksiyonu

Nöron çıktı değerinin hesaplanmasında kullanılan $f(\mathbf{w}^t, \mathbf{x})$ fonksiyonu, aktivasyon fonksiyonu olarak adlandırılır. Aktivasyon fonksiyonunun doğru seçilmesi ağı performansı önemli derecede etkileyen faktörlerden biridir. Ağırlık ve girdi vektörünün skaler çarpımı olarak verilen ifade, *net* aktivasyon değeri olarak adlandırılır.

$$net = \mathbf{w}^t \mathbf{x} \quad (2.62)$$

Bu durumda aktivasyon fonksiyonunun tanım kümesi nöron modelinin net aktivasyon değerlerinin kümesi olacaktır. Yapay sinir ağlarının farklı türleri için farklı aktivasyon fonksiyonları kullanılır. Bunun yanında aynı ağın içinde bile, nöronlarda, farklı aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonu genel olarak tek kutuplu, çift kutuplu ya da doğrusal olarak seçilebilir. Tek kutuplu $f(net)$ aktivasyon fonksiyonu için, $net \in \mathcal{R}$ ya da $f(net) \in (0,1)$ yazılabileceği gibi çift kutuplu $f(net)$ aktivasyon fonksiyonu için ise $net \in \mathcal{R}$ ve $f(net) \in (-1, 1)$ olacaktır. Bununla birlikte, aktivasyon fonksiyonu kesikli ya da sürekli olabilir. Seçilecek aktivasyon fonksiyonuna göre elde edilecek nöron çıktı değerleri Tablo 2.1.'de verilmiştir. Tabloda, o , nöronun çıktı değerini göstermektedir.

Tablo 2.1. Aktivasyon fonksiyonu tipine göre nöron çıktı değeri

Aktivasyon fonksiyonu tipi		Nöron çıktı değeri
Tek kutuplu	Sürekli	$o \in (0,1)$
	Kesikli	$o \in \{0,1\}$
Çift kutuplu	Sürekli	$o \in (-1,1)$
	Kesikli	$o \in \{-1,1\}$

Sıklıkla kullanılan aktivasyon fonksiyonları ise aşağıdaki gibi verilebilir.

- Doğrusal aktivasyon fonksiyonu:

$$f(net) = net \quad (2.63)$$

- Adımsal aktivasyon fonksiyonu:

$$f(net) = \begin{cases} 0, & net > 0 \\ 1, & net < 0 \end{cases} \quad (2.64a)$$

ya da

$$f(net) = \begin{cases} -1, & net > 0 \\ 1, & net < 0 \end{cases} \quad (2.64b)$$

- λ eğim parametresini göstermek üzere Lojistik aktivasyon fonksiyonu:

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} \quad (2.65a)$$

ya da

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} - 1 \quad (2.65b)$$

- Radyal Temelli aktivasyon fonksiyonu:

$$f(net) = \exp(-\lambda net^2) \quad (2.66)$$

- Tanjant hiperbolik aktivasyon fonksiyonu:

$$f(net) = \frac{(\exp(net) - \exp(-net))}{(\exp(net) + \exp(-net))} \quad (2.67)$$

- Sinüs, Kosinüs aktivasyon fonksiyonu:

$$f(net) = \sin(net) \quad (2.68a)$$

$$f(net) = \cos(net) \quad (2.68b)$$

2.3.3. Öğrenme Algoritması

Yapay sinir ağlarının beklide en önemli özelliği, bir bilgi kaynağından (veriden) öğrenebilme yeteneğidir. Öğrenme işlemi, ağırlıkların en iyi değerinin bulunması işlemidir ve bu işlem yapay sinir ağının eğitimi olarak isimlendirilir. Yapay sinir ağlarında öğrenme işlemi, önceden belirlenmiş bir ölçüte göre adım adım ağırlıkların en iyi değerine ulaşılmaya çalışılan, öğrenme algoritması adı verilen algoritmanın kullanılmasıyla gerçekleştirilir.

Yapay sinir ağında en iyi ağırlıkların bulunması bir optimizasyon problemi olarak düşünülebilir. Bununla birlikte yapay sinir ağlarının eğitiminde kullanılan yöntemler arasında, genetik algoritmalar, tavlama benzetimi ve tabu arama algoritması gibi sezgisel algoritmalar da bulunmaktadır.


Öğrenme algoritmaları, *öğrenme kuralı* adı verilen değişik kurallara göre işler. En çok bilinen ve kullanılan iki öğrenme kuralı, *denetimli* (supervised) ve *denetimsiz* (unsupervised) öğrenme kuralıdır. Denetimli öğrenmede, elde edilecek her bir çıktı değerinin, önceden bilinen bir hedef değeri vardır. Buna göre, öğrenme algoritmasının her bir adımında, yapay sinir ağının çıktı değeri ve karşılık gelen hedef değeri arasındaki hata azaltılarak ağırlık değerleri güncellenir. Bir başka sözle, denetimli öğrenmede amaç, yapay sinir ağının çıktı değeriyle, bu değerlerin hedef değeri arasındaki farkı minimum yapacak ağırlık değerlerini bulmaktır. Denetimsiz öğrenmede ise çıktı değerlerine karşılık gelen hedef değerleri yoktur. Girdi değerleri arasındaki benzerliklere göre, bu değerler kümelendirilir. Denetimsiz öğrenmede amaç, yapay sinir ağı çıktısının, girdi verisindeki istatistiksel düzeni en iyi şekilde yakalamasını sağlayacak ağırlıkların belirlenmesidir.

2.3.3.1. Geri Yayılım Öğrenme Algoritması

Geri yayılım (backpropagation) öğrenme algoritması genelleştirilmiş delta kuralı olarak da bilinir. İlk olarak Werbos (1974) tarafından ortaya konmuş ve Parker (1982) tarafından yeniden gündeme taşınmıştır. Rumelhart ve ark. (1986) da bu konuda çalışmışlar ve Le Chun (1988) yaptığı çalışmada çok benzer bir algoritma sunmuştur.

Bu bölümde, ileri beslemeli çok tabakalı yapay sinir ağları için geri yayılım öğrenme algoritması tanıtılacaktır. İleri beslemeli çok tabakalı bir yapay sinir ağı, verilen girdi ve elde edilen çıktı değerleri arasında, seçilen aktivasyon fonksiyonunun sağladığı eğrisel eşleşmeyi gerçekleştirir. İleri beslemeli çok tabakalı bir yapay sinir ağında öğrenme, hedef çıktı ve elde edilen çıktı değerleri arasındaki farkı makul bir seviyede tutacak ağırlıkları belirlemeyi içerir. Geri yayılım algoritması, uygun bir şekilde oluşturulmuş hata fonksiyonunun (maliyet fonksiyonu veya enerji fonksiyonu) kısıtsız optimizasyon problemi olarak da düşünülebilir.

Şekil 2.10. ile verilen örnek bir yapay sinir ağı için geri yayılım öğrenme algoritmasının algoritması beş temel adımda incelenebilir.



Şekil 2.10. Geri yayılım öğrenme algoritması için örnek yapay sinir ağı

Adım 1. Ağırlıkların başlangıç değerlerinin seçilmesi

Ağırlıkların başlangıç değerlerinin belirlenmesinde çeşitli yöntemler kullanılabilir, ancak Smith ve Gupta (2002) başlangıç değerlerinin,

$$-\frac{0.5}{v} \leq w_{ji}^{[s]} \leq \frac{0.5}{v} \quad (2.69)$$

aralığından rastgele seçilmesini önermişlerdir. Burada v , s tabakasındaki nöron sayısını gösterir.

Adım 2. Nöronların çıktı değerinin hesaplanması.

Gizli tabakalardaki nöronlar için:

$$o_j^{[s]} = \sum_{i=1}^{n_{s-1}} f_i^{[s-1]}(o_i^{[s-1]}) \cdot w_{ij}^{[s]} \quad (2.70)$$

Çıktı tabakasındaki nöronlar için:

$$o_j^{[s]} = \sum_{i=1}^{n_{s-1}} f_i^{[s-1]}(o_i^{[s-1]}) \cdot w_{ij}^{[s]} \quad (2.71)$$

Adım 3. Tüm tabakalar için hata sinyallerinin hesaplanması.

Çıktı tabakasındaki nöronlar için:

$$\delta_j^{[s]} = e_j \cdot f_j'^{[s]}(net_j^{[s]}) = (y_j - d_j) \cdot \frac{\partial f_j^{[s]}}{\partial net_j^{[s]}} \quad (2.72)$$

Gizli tabakalardaki nöronlar için:

$$\delta_j^{[s]} = \frac{\partial f_j^{[s]}}{\partial net_j^{[s]}} \cdot \sum_{i=1}^{n_{s+1}} \delta_i^{[s+1]} \cdot w_{ji}^{[s+1]} \quad (2.73)$$

Adım 4. Ağırlıkların güncellenmesi.

Çıktı tabakasındaki ağırlıklar için değişim miktarı:

$$\Delta w_{ij}^{[s]} = c \cdot \delta_j^{[s]} \cdot o_i^{[s-1]} \quad (2.74)$$

Gizli tabakalardaki ağırlıklar için değişim miktarı:

$$\Delta w_{ij}^{[s]} = c \cdot \delta_j^{[s]} \cdot o_i^{[s-1]} \quad (2.75)$$

Tüm ağırlıkların güncellenmesi:

$$w_{ji}^{[s]}(k+1) = w_{ji}^{[s]}(k) + \Delta w_{ji}^{[s]}(k) \quad (2.76)$$

şeklindedir. Burada c parametresi, geri yayılım algoritmasının *öğrenme oranını* göstermektedir. Geri yayılım algoritmasında, öğrenme oranının doğru olarak seçilmesi, optimal sonuca yaklaşımda çok önemlidir. Öğrenme oranı, sabit bir değer alınabileceği gibi, algoritmanın işleyişine göre dinamik olarak da güncellenebilir.

Adım 5. Algoritmanın durdurulması.

Bir sonraki öğrenme örneğine ilişkin girdi değerleri alınır ve 2. *Adım*'a geri dönülür. w_{ji} ağırlıkları belli bir değere yakınsayıncaya kadar algoritma sürdürülür.

2.3.3.2. Levenberg – Marquardt Öğrenme Algoritması

İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması Gradyen Azalması algoritmasıdır. Bu algoritmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pek çok problem için çok yavaş kalmaktadır.

Bu algoritmadan daha hızlı, daha yüksek performanslı algoritmalar da vardır. Bunlardan bazıları, standart sayısal optimizasyon yöntemlerini kullanan, eşlenik gradyen öğrenme algoritması, Newton öğrenme algoritmaları ve Levenberg – Marquardt öğrenme algoritmasıdır.

Öğrenme algoritmaları, kendisinden önce geliştirilen algoritmalara alternatif olarak ortaya çıkmıştır ve önceki algoritmaların iyi yönlerini geliştirip, kötü yönlerini azaltmaya yönelmiştir. Levenberg – Marquardt algoritması da, Newton ve Gradyen Azalması algoritmalarının en iyi özelliklerinden oluşur ve kısıtlamalarını ortadan kaldırır (Bolat ve Kalenderli, 2003).

Eşlenik gradyen öğrenme algoritmasına alternatif olarak sunulan Newton yöntemlerinde, temel adım, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinden oluşan, Hessian matrisini elde etmektir. Hessian matrisi, ağırlık uzayının farklı doğrultularındaki gradyen değişimini gösterir.

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (2.77)$$

burada H , Hessian matrisi, E , performans fonksiyonu, w , ağın sinaptik ağırlığıdır. Performans fonksiyonu, duruma göre toplam ani hata veya ortalama karesel hata olarak alınabilir. Bu çalışmada, ileri beslemeli ağların çoğunda olduğu gibi, performans fonksiyonu olarak, ortalama karesel hata kullanılmıştır.

$$E(n) = E_{ort}(n) \sum_{n=1}^N \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (2.78)$$

burada N , eğitim kümesindeki toplam örüntü sayısını, e_j , hata işaretini, C , ağın çıkış katmanındaki bütün nöronları içeren kümeyi göstermektedir. d_j hedef değer, y_j ağın çıktısı olmak üzere hata,

$$e_j(n) = d_j(n) - y_j(n) \quad (2.79)$$

ifadesi ile elde edilebilir. Hessian matrisi hesaplandıktan sonra, tersi bulunarak ağırlıklar yenilenebilir. Ancak Hessian matrisi çok karmaşık ve ileri beslemeli bir yapay sinir ağı için hesaplanması zor bir matristir. Newton yöntemlerinin içinde, ikinci dereceden türevlerin hesaplanmadan işlem yapılan bir sınıf vardır. Bu sınıftaki yöntemler, Quasi –Newton yöntemleri olarak adlandırılırlar. Quasi – Newton yöntemleri, algoritmanın her iterasyonunda, Hessian matrisinin yaklaşık bir şeklini kullanır.

Levenberg – Marquardt algoritması da Quasi – Newton yöntemleri gibi, Hessian matrisinin yaklaşık değerini kullanır. Levenberg – Marquardt algoritması için Hessian matrisinin yaklaşık değeri,

$$H(n) = J^T(n)J(n) + \mu I \quad (2.80)$$

şeklinde ifade edilir. Burada, μ Marquardt parametresi, I birim matrisi gösterirken, hataların ağırlıklara göre birinci türevlerinden oluşan J , Jakobien matrisi olarak isimlendirilir ve

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (2.81)$$

ifadesi ile bulunabilir. Bu ifade, e , ağ hata vektörüdür. Jakobien matrisi, Hessian matrisine göre daha kolay hesaplanabilir olduğundan uygulamada tercih edilir. Ağın gradyeni ise,

$$g(n) = J^T(n)e(n) \quad (2.82)$$

şeklinde hesaplanır ve sonuç olarak ağırlıklar,

$$w(n+1) = w(n) - [H(n)]^{-1} g(n) \quad (2.83)$$

ifadesine göre değiştirilerek güncellenir.

Marquardt parametresi, μ , skaler bir sayıdır. Eğer μ sıfırsa, bu yöntem yaklaşık Hessian matrisini kullanan Newton algoritması; eğer μ büyük bir sayı ise, küçük adımlı gradyen azalması yöntemi haline gelir. Newton yöntemleri, en küçük hata yakınlarında daha hızlı ve kesindir. Her başarılı adımdan sonra, yani performans fonksiyonunun azalmasında μ azaltılır ve sadece deneme niteliğindeki bir adım performans fonksiyonunu yükseltecekse μ artırılır. Bu yöntemle, algoritmanın her iterasyonunda, performans fonksiyonu daima azaltılır.

Genel olarak Levenberg – Marquardt algoritması yavaş yakınsama probleminden etkilenmez. Burada hedef, performans fonksiyonun en küçük yapacak ağırlık değerini bulmaktır (Ngia, 2000, Oğuz, 2001).

3. MATERYAL VE YÖNTEM

3.1. Bulanık Zaman Serileri

Bulanık zaman serisi analizi yöntemleri, son zamanlarda, doğrusal ya da eğrisel model özelliği taşıyan, gözlem sayısını koşul olarak almaksızın az ya da çok sayıda gözlem içeren tüm verilere kolaylıkla uygulanabilmesi nedeniyle literatürde sıklıkla tercih edilmektedir.

İlk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya atılan bulanık zaman serisi kavramı Zadeh (1965, 1973, 1975) tarafından verilen bulanık küme teorisine dayanmaktadır. Bulanık zaman serisi analizi yöntemleri genel olarak, gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve durulaştırma olmak üzere üç aşamadan oluşmaktadır. Huarng ve Yu (2005 ve 2006), Huarng (2001a), Yu (2005a) ve Huarng ve Yu (2004) çalışmalarında bulanık zaman serisi yöntemlerinde bulanıklaştırma aşamasının geliştirilmesi ile ilgilenilmiştir. Bulanık ilişkinin belirlenmesi aşamasında ise Song ve Chissom (1993a, 1993b) tarafından önerilen ve matris hesaplama işlemlerine dayanan yöntemin yerine Chen (1996), bulanık ilişki tablolarını kullanan, daha kolay ve etkin bir yöntem önermiştir. Bunun yanında, Huarng ve Yu (2006) ise basit bir ileri beslemeli yapay sinir ağı kullanılarak bulanık ilişkilerin belirlendiği başka bir birinci dereceden bulanık zaman serisi yaklaşımı önermiştir.

Bunun dışında Sullivan ve Woodal (1994), Song ve ark. (1995), Song ve Leland (1996), Hwang ve ark. (1998), Chen(2000), Chen ve Hwang (2000), Huarng (2001b), Huanrg ve Yu (2005) ve Yu (2005b) tarafından bu konudaki diğer önemli çalışmalar ortaya koyulmuştur. Bu yöntemlerin hepsinde birinci derece bulanık zaman serisi modeli ile ilgilenilmiştir. Chen (2002) ise yüksek dereceli bulanık zaman serisi yaklaşımı önermiştir. Chen (2002) tarafından önerilen bu yaklaşımda modelde tüm gecikmeli bulanık değişkenlerin bulunması nedeniyle derece arttıkça bulanık ilişkinin belirlenmesi ve dolayısıyla yöntemin uygulanması oldukça zorlaşmaktadır. Yüksek dereceli modelin çözümlenmesinde bulanık ilişkiler, yapay sinir ağı ile belirlenir ise Chen (2002) tarafından önerilen bu yöntemdeki işlem yoğunluğundan kurtulmak mümkündür.

Bulanık zaman serisi yaklaşımları bazı temel kavram ve tanımlara bağlıdır. Bu tanım ve kavramlar aşağıda özetlenmiştir.

$U = \{u_1, u_2, \dots, u_b\}$, evrensel küme ve evrensel kümenin belirlenen bir sabit aralık uzunluğuna göre parçalanması ile elde edilen u_i 'ler alt aralıklar olmak üzere bulanık kümeler,

$$A_i = f_{A_i}(u_1)/u_1 + f_{A_i}(u_2)/u_2 + \dots + f_{A_i}(u_b)/u_b \quad (3.1)$$

şeklinde tanımlanır. Burada, f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonunu gösterir ve $f_{A_i}: U \rightarrow [0,1]$ olacaktır. Bunun yanında $f_{A_i}(u_a)$ ise u_a alt aralığının A_i bulanık kümesine ait olmasının üyelik derecesidir ve $1 \leq a \leq b$ olmak üzere $f_{A_i}(u_a) \in [0,1]$ olacaktır.

Tanım 1. $Y(t)$, ($t = \dots, 0, 1, 2, \dots$) reel değerli zaman serisi olsun. Zaman serisine uygun evrensel küme tanımı ve alt aralıkların tespit edilmesinden sonra bunlara bağlı olarak elde edilen A_i bulanık kümelerinden oluşan yeni zaman serisi, $F(t)$ bulanık zaman serisi olarak adlandırılır.

$F(t)$ bulanık zaman serisi hakkında, Tanım 1. gereğince, şunlar söylenebilir,

- i. $F(t)$ zamanın bir fonksiyonudur.
- ii. $F(t)$ bulanık kümeler tarafından temsil edilen dilsel değerlere sahip, dilsel değişkenler olarak ifade edilebilir.

Tanım 2. “*” herhangi bir operatörü göstermek üzere, eğer $F(t)$ bulanık zaman serisi yalnızca bir gecikmeli $F(t-1)$ bulanık zaman serisinden etkilenmekte ise, $F(t)$ ile $F(t-1)$ bulanık zaman serisi arasındaki bulanık ilişki,

$$F(t) = F(t-1) * R(t, t-1) \quad (3.2)$$

şeklinde ifade edilir ve birinci dereceden bulanık zaman serisi öngörü modeli olarak adlandırılır. Bu ilişki Song ve Chissom (1993a) tarafından aşağıdaki gibi tanımlanmıştır,

$$F(t-1) \rightarrow F(t) \quad (3.3)$$

Sonuç olarak $F(t-1) = A_i$ ve $F(t) = A_j$ olduğunda $F(t)$ ile $F(t-1)$ bulanık zaman serisi arasındaki bulanık ilişki,

$$A_i \rightarrow A_j \quad (3.4)$$

olacaktır, ki burada A_i , bulanık ilişkinin sol yanı, A_j ise bulanık ilişkinin sağ yanı olarak isimlendirilir.

Tanım 3. Eğer $F(t)$ bulanık zaman serisi, gecikmeli $F(t-1), F(t-2), \dots, F(t-n)$ bulanık zaman serilerinden etkilenmekte ise, $F(t)$ bulanık zaman serisi ile $F(t-1), F(t-2), \dots, F(t-n)$ bulanık zaman serileri arasındaki bulanık ilişki,

$$F(t-n), \dots, F(t-2), F(t-1) \rightarrow F(t) \quad (3.5)$$

ifadesi ile verilebilir ve n'nci dereceden bulanık zaman serisi öngörü modeli olarak adlandırılır.

3.1.1. Chen' nin Yüksek Dereceli Bulanık Zaman Serisi Yöntemi

Chen, 2002 yılında yaptığı çalışmada öngörü elde etmede yüksek dereceli bulanık zaman serisi yaklaşımını önermiştir. Chen (2002) tarafından verilen bu yöntemde yüksek dereceli modellerde tüm gecikmeli bulanık değişkenler bulunmaktadır. Yani 4. dereceden bir zaman serisinin çözümlenmesinde, $F(t)$ bulanık zaman serisi iken, $F(t-1), F(t-2), F(t-3), F(t-4)$ bulanık gecikmeli değişkenleri modelde yer almaktadır. Birinci dereceden bulanık zaman serisi öngörü modellerine göre daha iyi sonuçlar veren, bu yüksek dereceli bulanık zaman serisi yönteminin algoritması aşağıdaki adımlardan oluşur (Chen 2002).

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük ve en büyük değerleri sırasıyla $D_{\min}$ ve $D_{\max}$, ayrıca keyfi iki sayı D_1 ve D_2 olmak üzere evrensel küme,

$$U = [D_{\min} - D_1, D_{\max} + D_2] \quad (3.6)$$

şeklinde ve sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$U = \{u_1, u_2, \dots, u_b\} \quad (3.7)$$

olacak şekilde tanımlanır.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Üyelik dereceleri,

$$a_{jk} = \begin{cases} 1 & , k = j \\ 0.5 & , k = j-1, j+1 \\ 0 & , o.w. \end{cases} \quad , \quad j = 1, 2, \dots, b \quad (3.8)$$

olmak üzere, bulanık kümeler aşağıdaki gibi tanımlanır.

$$A_j = a_{j1} / u_1 + a_{j2} / u_2 + \dots + a_{jb} / u_b \quad , \quad j = 1, 2, \dots, b \quad (3.9)$$

Adım 3. Gözlemler bulanıklaştırılır.

Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır.

Adım 4. Bulanık mantık ilişki ve grup ilişki tablosu oluşturulur.

Bulanık mantık ilişki ve grup ilişki tablosu oluşturulmasını kavrayabilmek için birkaç örnekle açıklamaya çalışalım. Örneğin, birinci dereceden bulanık mantık ilişkiler,

$$A_i \rightarrow A_j \quad , \quad A_i \rightarrow A_i \quad , \quad A_i \rightarrow A_k$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_i \rightarrow A_j, A_i, A_k$$

olarak elde edilir. Benzer şekilde genel bir ifade ile n'nci dereceden bulanık mantık ilişkiler,

$$\begin{aligned} A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{j1} \\ A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{j2} \\ \vdots &\vdots \\ A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{jp} \end{aligned}$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp}$$

olarak elde edilir. Bulanık mantık ilişki ve grup ilişki tabloları, elde edilen bu bulanık mantık ilişki ve grup ilişkilerden oluşur.

Adım 5. Bulanık öngörüler elde edilir.

n'nci dereceden bulanık zaman serisi öngörü modeli için bulanık öngörüler elde edilirken üç durum söz konusudur.

Durum 1. n'nci dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_j \quad (3.10)$$

ilişkisi mevcut ise bulanık öngörü, A_j olacaktır.

Durum 2. n'nci dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp} \quad (3.11)$$

ilişkisi mevcut ise bulanık öngörüde belirsizlik söz konusudur ve bulanık öngörünün elde edilebilmesi için belirsizlik giderilene kadar incelenen derecenin bir üst derecesine bakılarak $m > n$ olmak üzere,

$$A_{im}, A_{i(m-1)}, \dots, A_{i1} \rightarrow A_j \quad (3.12)$$

ilişkisini veren m aranır ve bu durumda bulanık öngörü, yine A_j olacaktır.

Durum 3. n'nci dereceden bulanık mantık grup ilişki tablosunda,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow Boş \quad (3.13)$$

ilişkisi mevcut ise reel öngörü, $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ bulanık kümelerine bağlı olarak, $u_{in}, u_{i(n-1)}, \dots, u_{i1}$ aralıklarının orta noktaları, $m_{in}, m_{i(n-1)}, \dots, m_{i1}$ olmak üzere,

$$\frac{1 \times m_{in} + 2 \times m_{i(n-1)} + \dots + n \times m_{i1}}{1 + 2 + \dots + n} \quad (3.14)$$

ifadesi ile elde edilir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Öngörülerin elde edilmesinde karşılaşılan Durum 1. ve Durum 2. için bulanık öngörü A_j olarak elde edilmişken, durulaştırılmış öngörü, A_j bulanık kümesinde en yüksek üyelik değerine sahip olan u_j aralığının orta noktası olacaktır. Durum 3. için ise reel öngörünün, $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ bulanık kümelerine bağlı olarak nasıl elde edildiği daha önce belirtilmişti.

3.1.2. Y.S.A.'na Dayalı Yüksek Dereceli Bulanık Zaman Serisi Yöntemi

Chen (2002) tarafından tanımlanan yüksek dereceli bulanık zaman serisi modeli AR(p), $p > 1$ yapılı zaman serilerini de modelleyebilir. Bunun yanında, yüksek dereceli bulanık zaman serisi yaklaşımında derece arttıkça, bulanık ilişkinin belirlenmesinde, Chen (2002) tarafından önerilen yöntemin uygulanması da oldukça zorlaşmaktadır. Yüksek dereceli modelin çözümlenmesinde bulanık ilişkiler, yapay sinir ağı ile belirlenir ise Chen (2002) tarafından önerilen yöntemde bulanık mantık ilişki ve grup ilişki tablolarının oluşturulmasındaki karmaşıklıktan ve işlem yoğunluğundan kurtulmak, bunun yanında daha iyi öngörüler elde etmek mümkündür. Bu çalışmada bu dezavantajları olmayan, yapay sinir ağlarına dayalı yeni bir yöntem önerilmiştir. Önerilen yöntemin algoritması aşağıdaki adımlardan oluşur.

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük ve en büyük değerleri sırasıyla $D_{\min}$ ve $D_{\max}$, ayrıca keyfi iki sayı D_1 ve D_2 olmak üzere evrensel küme,

$$U = [D_{\min} - D_1, D_{\max} + D_2] \quad (3.15)$$

şeklinde ve sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$U = \{u_1, u_2, \dots, u_b\} \quad (3.16)$$

olacak şekilde tanımlanır.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Üyelik dereceleri,

$$a_{jk} = \begin{cases} 1 & , k = j \\ 0.5 & , k = j-1, j+1 \\ 0 & , o.w. \end{cases} \quad , \quad j = 1, 2, \dots, b \quad (3.17)$$

olmak üzere, bulanık kümeler aşağıdaki gibi tanımlanır.

$$A_j = a_{j1} / u_1 + a_{j2} / u_2 + \dots + a_{jb} / u_b \quad , \quad j = 1, 2, \dots, b \quad (3.18)$$

Adım 3. Gözlemler bulanıklaştırılır.


Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır.

Adım 4. Bulanık mantık ilişkileri ileri beslemeli yapay sinir ağı kullanılarak oluşturulur.

- Sinir ağının girdileri gecikmeli değişkenlerden, çıktıları öngörülerden ve hedef değerleri ise gerçek verinin bulanık değerlerinden oluşur.
- Sinir ağı verilen girdi ve çıktılara göre eğitilir.
- Girdi nöronlarının sayısı modelin derecesi olacaktır.

- Gizli tabaka birim sayısına deneme yanılma yöntemi ile karar verilir.
- Çıktı birimlerindeki nöron sayısının ise bir olacağı açıktır.

Bu özellikleri taşıyan ileri beslemeli yapay sinir ağı mimarisi Şekil 3.1.'de verilmiştir.



Şekil 3.1. İleri beslemeli yapay sinir ağı mimarisi

Bulanık mantık ilişkilerin, ileri beslemeli yapay sinir ağı kullanılarak oluşturulması ve ağın girdi, çıktı ve hedef değerlerini daha iyi kavrayabilmek için elimizde 6 gözlemden oluşan herhangi bir $F(t)$ bulanık zaman serisi olduğunu ve ikinci gecikme için ileri beslemeli yapay sinir ağı ile bulanık ilişki belirlenmesinin istendiğini düşünelim. Bu durumda,

- İlk olarak $F(t-1)$ ve $F(t-2)$ gecikmeli bulanık zaman serileri oluşturulur.
- Ağın girdi tabakası 2 ve çıktı tabakası 1 nörondan oluşacaktır.
- Girdiler, gecikmeli değişkenler olup, gecikmeli bulanık zaman serisinin sınıf numaralarından ve hedef değerler, bulanık zaman serisinin kendi sınıf numaralarından oluşur.

Bu özellikleri taşıyan, ikinci dereceden bulanık zaman serisi öngörü modeli için bulanık ilişkilerin ileri beslemeli yapay sinir ağı ile belirlendiği, ağın girdi, çıktı ve hedef değerlerini Tablo 3.1.'de görebiliriz.

Tablo 3.1. İkinci dereceden bulanık zaman serisi öngörü modeli için örnek

Gözlem No	$F(t-2)$	$F(t-1)$	$F(t)$	Girdi - 1	Girdi - 2	Hedef
1	---	---	A_6	---	---	---
2	---	A_6	A_2	---	---	---
3	A_6	A_2	A_3	6	2	3
4	A_2	A_3	A_7	2	3	7
5	A_3	A_7	A_4	3	7	4
6	A_7	A_4	A_2	7	4	2

Adım 5. Bulanık öngörüler elde edilir.

n 'nci dereceden bulanık zaman serisi öngörü modeli için bulanık öngörüler elde edilirken yalnızca tek durum söz konusudur. n 'nci dereceden bulanık ilişkisi,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow YSA \rightarrow A_j \quad (3.19)$$

olarak elde edildiğinde bulanık öngörü A_j olacaktır. Burada $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ yapay sinir ağının girdilerini, A_j ise çıktısını temsil etmektedir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Bulanık öngörü A_j olarak elde edildiğinde, durulaştırılmış öngörü, A_j bulanık kümesinde en yüksek üyelik değerine sahip olan u_j aralığının orta noktası olacaktır.

4. BULGULAR VE TARTIŞMA

Önerilen yeni yöntemin uygulaması, sırasıyla, literatürde sıkça kullanılan 1971-1992 yıllarına ait Alabama Üniversitesi kayıt verisine (enrollment data) ve Şubat 2003 - Şubat 2008 dönemleri arasında hesaplanan aylık bazda Türkiye Tüketici Fiyat Endeksi (TÜFE) ve yine aynı zaman serisi kullanılarak Şubat 2004 ve Şubat 2008 dönemleri arasında her bir ay için hesaplanan yıllık bazda Türkiye Tüketici Fiyat Endeksi zaman serisine uygulanmıştır.


Enflasyon öngörülerinin elde edilmesi önemli bir ekonomik problemdir. Öngörülerin daha doğru elde edilmesi daha doğru ekonomik politikalar doğuracaktır. T.C.M.B. her yılın belirli dönemlerinde, enflasyon beklentisi anketi sonuçlarının yer aldığı, enflasyon raporları yayınlamaktadır. Tüketici fiyat endeksi zaman serisi belirtilen dönemlerde, hem literatürde yer alan bazı bulanık zaman serisi yaklaşımları, hem de bu çalışmada önerdiğimiz yöntem ile aylık ve yıllık bazda ayrı ayrı tahmin edilerek sonuçlar öngörü doğruluğu açısından karşılaştırılmış ve bunun yanında, yıllık bazda elde edilen öngörüler aynı zamanda T.C.M.B. enflasyon beklentisi anketi sonuçları ile de karşılaştırılmıştır.

Çözümleme aşamasında MATLAB programlama dilinde yazılmış programlar kullanılmış olup, örnek iki programın açık kodları Ek 3. ve Ek 4.' de verilmiştir.

4.1. Alabama Üniversitesi Kayıt Verisi Çözümlemesi

Önerilen yöntem ilk olarak literatürde sıkça kullanılan ve grafiği Şekil 4.1.'de verilen, 1971-1992 yıllarına ait Alabama Üniversitesi kayıt verisine (enrollment data) uygulanmıştır.

Bu veri için birinci, ikinci, üçüncü ve dördüncü dereceden bulanık zaman serisi modelleri ile uygulama yapılmıştır. Uygulamada u_i aralık uzunlukları Huarng (2001a)'ın çalışmasında olduğu gibi 200, 300, 400, 500, 600, 700, 800, 900 ve 1000 olarak belirlenmiştir. Algoritmanın 4. adımında kullanılan ileri beslemeli yapay sinir ağı mimarisinde gizli tabaka birim sayısı, ağıın genelleştirme yeteneğini kaybetmemesi için 1-4 arasında sınırlandırılmıştır.



Şekil 4.1. 1971-1992 yılları Alabama Üniversitesi kayıt verisi

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük değerinin 13055 ve en büyük değerinin 19337 olması sebebiyle sırasıyla $D_{\min} = 13055$ ve $D_{\max} = 19337$, ayrıca keyfi iki sayı $D_1 = 55$ ve $D_2 = 663$ olmak üzere evrensel küme,

$$U = [13000, 20000]$$

ve bununla birlikte aralık uzunluğu verideki artışı kapsayacak şekilde 1000 olarak seçildiğinde, sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$u_1 = [13000, 14000], \quad u_2 = [14000, 15000], \quad u_3 = [15000, 16000],$$

$$u_4 = [16000, 17000], \quad u_5 = [17000, 18000], \quad u_6 = [18000, 19000],$$

$$u_7 = [19000, 20000]$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu 200, 300, 400, 500, 600, 700, 800 ve 900 olarak alındığında da u_i alt aralıkları benzer şekilde elde edilir.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Adım 1.'de belirlenen evrensel küme ve aralık uzunluğunun sabit 1000 olduğu durumda belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri

$$\begin{aligned}
A_1 &= 1/u_1 + 0.5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 \\
A_2 &= 0.5/u_1 + 1/u_2 + 0.5/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 \\
A_3 &= 0/u_1 + 0.5/u_2 + 1/u_3 + 0.5/u_4 + 0/u_5 + 0/u_6 + 0/u_7 \\
A_4 &= 0/u_1 + 0/u_2 + 0.5/u_3 + 1/u_4 + 0.5/u_5 + 0/u_6 + 0/u_7 \\
A_5 &= 0/u_1 + 0/u_2 + 0/u_3 + 0.5/u_4 + 1/u_5 + 0.5/u_6 + 0/u_7 \\
A_6 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0.5/u_6 + 1/u_7
\end{aligned}$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu 200, 300, 400, 500, 600, 700, 800 ve 900 olarak alındığında da A_j bulanık kümeleri benzer şekilde elde edilir.

Adım 3. Gözlemler bulanıklaştırılır.

Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır. Tablo 4.1.'de gözlemlere ait reel ve aralık uzunluğunun sabit 1000 olduğu durum için bulanıklaştırılmış değerler verilmiştir. Bunun yanında, diğer tüm aralık uzunlukları için de bulanık değerler benzer şekilde elde edilir.

Tablo 4.1. Kayıt verisine ait reel ve bulanık değerler

Yıl	Değer	Bulanık Değer	Yıl	Değer	Bulanık Değer
1971	13055	A_1	1982	15433	A_3
1972	13563	A_1	1983	15497	A_3
1973	13867	A_1	1984	15145	A_3
1974	14696	A_2	1985	15163	A_3
1975	15640	A_3	1986	15984	A_3
1976	15311	A_3	1987	16859	A_4
1977	15603	A_3	1988	18150	A_6
1978	15861	A_3	1989	18970	A_6
1979	16807	A_4	1990	19328	A_7
1980	16919	A_4	1991	19337	A_7
1981	16388	A_4	1992	18876	A_6

Adım 4. Bulanık mantık ilişkileri ileri beslemeli yapay sinir ağı kullanılarak oluşturulur.

Çözümlemede kullanılan yapay sinir ağı bileşenlerini aşağıdaki özellikleri taşımaktadır.

- Mimari Yapı: Tüm mümkün aralık uzunlukları için, girdi tabakasındaki birim sayısının her bir derece için sırasıyla 1, 2, 3 ve 4, gizli tabakadaki birim sayısının ise her bir durum için 1-4 arasında değiştiği ve çıktı tabakasındaki tek birimin kullanıldığı toplam 16 farklı mimari ile çözümleme yapılmıştır.
- Öğrenme Algoritması: Öğrenme parametresinin her bir iterasyonda güncellendiği Levenberg – Marquardt algoritması en iyi ağırlıkların elde edilmesinde kullanılmıştır.
- Aktivasyon Fonksiyonu: Tüm birimlerde eğrisel aktivasyon fonksiyonlarından olan ve eğim parametresi $\gamma = 1$ olmak üzere, aşağıdaki eşitlik ile ifade edilen Lojistik aktivasyon fonksiyonu kullanılmıştır.

$$f(x) = (1 + \exp(-\gamma x))^{-1} \quad (4.1)$$

Adım 5. Bulanık öngörüler elde edilir.

Aralık uzunluğunun sabit 1000 olduğu durum için ileri beslemeli yapay sinir ağı kullanılarak, ikinci dereceden bulanık zaman serisi öngörü modeli için oluşturulan bulanık mantık ilişkilerinden yararlanılarak elde edilen bulanık öngörüler Tablo 4.2.'de verilmiştir.

Tablo 4.2. Kayıt verisine ait bulanık öngörüler

Yıl	Bulanık Değer	Bulanık Öngörü	Yıl	Bulanık Değer	Bulanık Öngörü
1971	A1	---	1982	A3	A4
1972	A1	---	1983	A3	A3
1973	A1	A2	1984	A3	A3
1974	A2	A2	1985	A3	A3
1975	A3	A3	1986	A3	A3
1976	A3	A3	1987	A4	A3
1977	A3	A3	1988	A6	A5
1978	A3	A3	1989	A6	A6
1979	A4	A3	1990	A7	A7
1980	A4	A5	1991	A7	A7
1981	A4	A4	1992	A6	A7

Bunun yanında aralık uzunluğu olarak 200, 300, 400, 500, 600, 700, 800 ve 900 alındığında da ikinci dereceden bulanık zaman serisi öngörü modeli için bulanık öngörüler ve ayrıca tüm aralık uzunluklarında birinci, üçüncü ve dördüncü dereceden bulanık zaman serisi öngörü modelleri için bulanık öngörüler benzer şekilde elde edilir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Aralık uzunluğunun sabit 1000 olduğu durumda, ikinci dereceden bulanık zaman serisi öngörü modeli için elde edilen bulanık öngörüler dikkate alınarak yapılan durulaştırma işlemi sonucunda ulaşılan durulaştırılmış öngörüler Tablo 4.3.'de verilmiştir. Ayrıca diğer tüm aralık uzunlukları ve dereceler için de durulaştırılmış öngörüler benzer şekilde elde edilir.

Tablo 4.3. Kayıt verisine ait durulaştırılmış öngörüler

Yıl	Bulanık Öngörü	Duru Öngörü	Yıl	Bulanık Öngörü	Duru Öngörü
1971	---	---	1982	A4	16500
1972	---	---	1983	A3	15500
1973	A2	14500	1984	A3	15500
1974	A2	14500	1985	A3	15500
1975	A3	15500	1986	A3	15500
1976	A3	15500	1987	A3	15500
1977	A3	15500	1988	A5	17500
1978	A3	15500	1989	A6	18500
1979	A3	15500	1990	A7	19500
1980	A5	17500	1991	A7	19500
1981	A4	16500	1992	A7	19500

Önerilen yöntemin algoritmasını oluşturan 6 adım, tüm mümkün durumlar için uygulandı ve elde edilen durulaştırılmış öngörüler ($\hat{y}_i$) ile verinin gerçek değerleri (y_i) kullanılarak, tüm bu durumlar için hata kareler ortalanması karekökü (H.K.O.K.),

$$H.K.O.K. = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (4.2)$$

formülü ile hesaplandı. Tüm mümkün durumlar için hesaplanan H.K.O.K. sonuçları Tablo 4.4.'de verilmiştir.

Tablo 4.4. Önerilen yöntemin kayıt verisi için H.K.O.K. değerleri

Aralık Uzunluğu	Gizli Tabaka Birim Sayısı	H.K.O.K. Değeri			
		Birinci Derece	İkinci Derece	Üçüncü Derece	Dördüncü Derece
200	1	537.27	444.31	874.39	1083.94
300	1	578.91	521.16	519.56	1089.57
400	1	551.67	482.18	511.84	1085.94
500	1	614.04	557.62	492.26	1135.43
600	1	636.10	630.53	507.34	989.55
700	1	527.76	361.67	724.60	1550.24
800	1	683.79	639.82	713.81	1069.31
900	1	641.49	463.77	617.16	1160.89
1000	1	758.06	680.36	648.26	1069.63
200	2	3398.23	412.91	3319.91	1105.73
300	2	3529.50	433.44	3453.59	1205.40
400	2	3311.60	394.83	3231.58	1081.66
500	2	3354.82	455.35	3275.66	1096.06
600	2	3398.23	482.94	3319.91	1090.27
700	2	3706.73	379.61	3633.81	1166.89
800	2	3140.72	553.83	3057.09	1099.11
900	2	3796.20	439.87	3724.68	1141.39
1000	2	3573.58	600.99	3498.44	970.91
200	3	420.17	3237.23	607.47	1180.21
300	3	474.27	3368.58	608.81	1183.40
400	3	431.08	3150.59	609.44	1085.94
500	3	466.28	432.08	677.77	1078.46
600	3	542.63	502.90	554.62	1650.48
700	3	468.33	347.85	697.30	1223.51
800	3	616.40	553.83	602.00	1064.86
900	3	629.89	512.01	775.03	1134.09
1000	3	728.59	600.99	496.96	1436.85
200	4	419.49	259.99	629.96	1148.32
300	4	488.63	277.96	621.03	1136.00
400	4	444.05	288.19	621.38	967.33
500	4	464.75	410.78	643.92	1127.22
600	4	556.56	424.42	622.39	3410.87
700	4	466.19	294.57	697.30	1183.08
800	4	626.81	553.83	647.23	3139.86
900	4	554.09	476.60	688.69	1134.09
1000	4	723.02	636.47	496.96	3594.10


Tüm mümkün durumlar için hesaplanan H.K.O.K. sonuçlarının verildiği Tablo 4.4. incelendiğinde genel olarak ikinci dereceden bulanık zaman serisi öngörü modelinden elde edilen sonuçların diğer dereceden modellere göre daha iyi sonuçlar verdiği görülmektedir. Önerilen yöntemin en iyi sonucu ile birlikte literatürde uygulanan diğer yöntemlere ait en iyi sonuçlar Tablo 4.5.'de verilmektedir. Bu tablo incelendiğinde ise literatürde uygulanan diğer yöntemler arasında en iyi sonucun Chen (2002) tarafından önerilen yöntemde, üçüncü dereceden bulanık zaman serisi öngörü modeli için H.K.O.K. değeri, 294.44 ile elde edildiği görülürken, bu çalışmada önerilen yöntemde ise en iyi sonuca, ikinci dereceden bulanık zaman serisi öngörü modelinde, bulanık ilişkinin 2-4-1 mimarisi ile belirlendiği ve aralık uzunluğunun 200 olduğu durumda, 259.99 H.K.O.K. değeri ile ulaşılmıştır.

Tablo 4.5. Önerilen ve Literatürdeki diğer yöntemlerin en iyi sonuçları

Yöntem	Derece	H.K.O.K.
Song ve Chissom (1993a)	1	642.26
Song ve Chissom (1994)	1	880.73
Sullivan ve Woodall (1994)	1	621.33
Chen (1996)	1	638.36
Hwang, Chen, ve Lee (1998)	5	528.13
Chen (2002)	3	294.44
Önerilen Yöntem	2	<u>259.99</u>

4.2. Aylık Bazdaki TÜFE Verisi Çözümlemesi

Önerilen yeni yöntem, ikinci olarak, grafiği Şekil 4.2.'de verilen, Şubat 2003 ve Şubat 2008 dönemleri arasında hesaplanan aylık bazda Türkiye Tüketici Fiyat Endeksi (TÜFE) zaman serisine uygulanmıştır.



Şekil 4.2. Şubat 2003 ve Şubat 2008 aylık bazda TÜFE verisi

Uygulamada ilgilenilen zaman serisine ait aylık bazda bulunan veri kümesinden ilk 49 veri eğitim kümesi ve son 12 veri de önerilen yöntem sonuçlarının literatürdeki diğer yöntem sonuçları ile karşılaştırılabilmesi için test kümesi olarak alınmıştır. Bu zaman serisi için birinci dereceden başlayarak on ikinci dereceye kadar olan bulanık zaman serisi modelleri ile uygulama yapılmıştır. Uygulamada u_i aralık uzunlukları, verinin artışı göz önünde bulundurularak 0.10 ile 0.50 arasında her bir aşamada 0.05 artırılarak belirlenmiştir. Algoritmanın 4. adımında kullanılan ileri beslemeli yapay sinir ağı mimarisinde gizli tabaka birim sayısı, ağın genelleştirme yeteneğini kaybetmemesi için 1-6 arasında sınırlandırılmıştır.

Aylık bazda bulunan zaman serisinin çözümlemesi şu şekilde özetlenebilir.

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük değerinin -0.73 ve en büyük değerinin 2.25 olması sebebiyle sırasıyla $D_{\min} = -0.73$ ve $D_{\max} = 2.25$, ayrıca keyfi iki sayı $D_1 = 0.27$ ve $D_2 = 0.75$ olmak üzere evrensel küme,

$$U = [-1.00, 3.00]$$

ve bununla birlikte aralık uzunluğu verideki artışı kapsayacak şekilde 0.50 olarak seçildiğinde, sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$\begin{aligned}
u_1 &= [-1.00, -0.50], & u_2 &= [-0.50, 0.00], & u_3 &= [0.00, 0.50], \\
u_4 &= [0.50, 1.00], & u_5 &= [1.00, 1.50], & u_6 &= [1.50, 2.00], \\
u_7 &= [2.00, 2.50] & u_8 &= [2.50, 3.00]
\end{aligned}$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu olarak, 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 alındığında da u_i alt aralıkları benzer şekilde elde edilir.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Adım 1.'de belirlenen evrensel küme ve aralık uzunluğunun sabit 0.50 olduğu durumda belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri

$$\begin{aligned}
A_1 &= 1/u_1 + 0.5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 \\
A_2 &= 0.5/u_1 + 1/u_2 + 0.5/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 \\
A_3 &= 0/u_1 + 0.5/u_2 + 1/u_3 + 0.5/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 \\
A_4 &= 0/u_1 + 0/u_2 + 0.5/u_3 + 1/u_4 + 0.5/u_5 + 0/u_6 + 0/u_7 + 0/u_8 \\
A_5 &= 0/u_1 + 0/u_2 + 0/u_3 + 0.5/u_4 + 1/u_5 + 0.5/u_6 + 0/u_7 + 0/u_8 \\
A_6 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0.5/u_5 + 1/u_6 + 0.5/u_7 + 0/u_8 \\
A_7 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0.5/u_6 + 1/u_7 + 0.5/u_8 \\
A_8 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0.5/u_7 + 1/u_8
\end{aligned}$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu olarak 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 alındığında da A_j bulanık kümeleri benzer şekilde elde edilir.

Adım 3. Gözlemler bulanıklaştırılır.

Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır. Tablo 4.6.'da gözlemlere ait reel ve aralık uzunluğunun sabit 0.50 olduğu durum için bulanıklaştırılmış değerler verilmiştir. Bunun yanında, diğer tüm aralık uzunlukları için de bulanık değerler benzer şekilde elde edilir.

Tablo 4.6. Aylık TÜFE verisine ait reel ve bulanık değerler

Dönem	Değer	Bulanık Değer	Dönem	Değer	Bulanık Değer
Şubat 03	1.54	A6	Mart 05	0.26	A3
Mart 03	1.96	A6	Nisan 05	0.71	A4
Nisan 03	0.99	A4	Mayıs 05	0.92	A4
Mayıs 03	0.96	A4	Haziran 05	0.10	A3
Haziran 03	0.08	A3	Temmuz 05	-0.57	A1
Temmuz 03	-0.19	A2	Ağustos 05	0.85	A4
Ağustos 03	0.16	A3	Eylül 05	1.02	A5
Eylül 03	1.35	A5	Ekim 05	1.79	A6
Ekim 03	0.93	A4	Kasım 05	1.40	A5
Kasım 03	1.27	A5	Aralık 05	0.42	A3
Aralık 03	0.42	A3	Ocak 06	0.75	A4
Ocak 04	0.66	A4	Şubat 06	0.22	A3
Şubat 04	0.52	A4	Mart 06	0.27	A3
Mart 04	0.96	A4	Nisan 06	1.34	A5
Nisan 04	0.50	A4	Mayıs 06	1.88	A6
Mayıs 04	0.43	A3	Haziran 06	0.34	A3
Haziran 04	-0.13	A2	Temmuz 06	0.85	A4
Temmuz 04	0.48	A3	Ağustos 06	-0.44	A2
Ağustos 04	0.76	A4	Eylül 06	1.29	A5
Eylül 04	0.95	A4	Ekim 06	1.27	A5
Ekim 04	2.25	A7	Kasım 06	1.29	A5
Kasım 04	1.31	A5	Aralık 06	0.23	A3
Aralık 04	0.32	A3	Ocak 07	1.00	A5
Ocak 05	0.55	A4	Şubat 07	0.43	A3
Şubat 05	0.02	A3			

Adım 4. Bulanık mantık ilişkileri ileri beslemeli yapay sinir ağı kullanılarak oluşturulur.

Çözümlemede kullanılan yapay sinir ağı bileşenlerini aşağıdaki özellikleri taşımaktadır.

- Mimari Yapı: Tüm mümkün aralık uzunlukları için, girdi tabakasındaki birim sayısının her bir derece için sırasıyla 1-12, gizli tabakadaki birim sayısının ise her bir durum için 1-6 arasında değiştiği ve çıktı tabakasinda tek birimin kullanıldığı toplam 72 farklı mimari ile çözümleme yapılmıştır.
- Öğrenme Algoritması: Öğrenme parametresinin her bir iterasyonda güncellendiği Levenberg – Marquardt algoritması en iyi ağırlıkların elde edilmesinde kullanılmıştır.

- Aktivasyon Fonksiyonu: Tüm birimlerde eğrisel aktivasyon fonksiyonlarından olan ve eğim parametresi $\gamma = 1$ olmak üzere, aşağıdaki eşitlik ile ifade edilen Lojistik aktivasyon fonksiyonu kullanılmıştır.

$$f(x) = (1 + \exp(-\gamma x))^{-1} \quad (4.3)$$

Adım 5. Bulanık öngörüler elde edilir.

Aralık uzunluğunun sabit 0.50 olduğu durum için ileri beslemeli yapay sinir ağı kullanılarak, beşinci dereceden bulanık zaman serisi öngörü modeli için oluşturulan bulanık mantık ilişkilerinden yararlanılarak elde edilen ve test kümesine ait bulanık öngörüler Tablo 4.7.'de verilmiştir. Bunun yanında aralık uzunluğu 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 olarak alındığında da beşinci ve diğer tüm derecelerde bulanık zaman serisi öngörü modeli için test kümesine ait bulanık öngörüler benzer şekilde elde edilir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Aralık uzunluğunun sabit 0.50 olduğu durumda, beşinci dereceden bulanık zaman serisi öngörü modeli için elde edilen bulanık öngörüler ile birlikte, durulaştırma işlemi sonucunda ulaşılan durulaştırılmış öngörüler Tablo 4.7.'de verilmiştir. Ayrıca diğer tüm aralık uzunlukları ve dereceler için de durulaştırılmış öngörüler benzer şekilde elde edilir.

Tablo 4.7. Aylık TÜFE verisine ait bulanık ve duru öngörüler

Dönem	Duru Öngörü	Bulanık Öngörü	Dönem	Duru Öngörü	Bulanık Öngörü
Mart 07	0.25	A3	Eylül 07	1.25	A5
Nisan 07	1.25	A5	Ekim 07	2.25	A7
Mayıs 07	0.25	A3	Kasım 07	2.25	A7
Haziran 07	0.25	A3	Aralık 07	0.25	A3
Temmuz 07	0.25	A3	Ocak 08	0.25	A3
Ağustos 07	0.25	A3	Şubat 08	0.25	A3

Önerilen yöntemin algoritmasını oluşturan 6 adım, aylık bazdaki TÜFE verisine tüm mümkün durumlar için uygulandı ve elde edilen durulaştırılmış öngörüler ($\hat{y}_t$) ile verinin gerçek değerleri (y_t) kullanılarak, tüm bu durumlar için hata kareler ortalanması karekökü (H.K.O.K.),

$$H.K.O.K. = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (4.4)$$


formülü ile hesaplandı. Tüm mümkün durumlar için hesaplanan H.K.O.K. sonuçları EK 1’de mevcut olan tablolarda verilmiştir.

Tüm mümkün durumlar için hesaplanan H.K.O.K. sonuçlarının verildiği tablolardan da görülebileceği gibi, Chen (2002) tarafından önerilen yöntemde en iyi sonuç, on ikinci dereceden bulanık zaman serisi öngörü modeli için aralık uzunluğunun 0.50 olduğu durumda, 0.81903 H.K.O.K. değeri ile elde edilmiş olup, Huarng ve Yu (2006) tarafından önerilen yöntemde ise en iyi sonuç, aralık uzunluğunun 0.15 ve gizli tabaka birim sayısının altı olduğu durumda, 0.66194 H.K.O.K. değeri ile elde edilmiştir. Bu çalışmada önerilen yöntemde ise en iyi sonuca, beşinci dereceden bulanık zaman serisi öngörü modeli için aralık uzunluğunun 0.50 ve girdi tabakası birim sayısının beş, gizli tabaka birim sayısının iki olduğu, yani bulanık ilişkinin 5-2-1 mimarisi ile belirlendiği durumda, 0.53878 H.K.O.K. değeri ile elde edilmiştir. Her üç yöntemin en iyi sonuçlarını içeren Tablo 4.8. aşağıda verilmiştir.

Tablo 4.8. Aylık TÜFE verisi için yöntemlerin en iyi sonuçları

Yöntem	Derece	Aralık Uzunluğu	Gizli Tabaka Birim Sayısı	H.K.O.K.
Chen (2002)	12	0.50	-	0.81903
Huarng ve Yu (2006)	1	0.15	6	0.66194
Önerilen Yöntem	5	0.50	2	0.53878

Bu sonuçlar göz önüne alındığında bu çalışmada önerilen Y.S.A.’na dayalı yüksek dereceli bulanık zaman serisi yöntemin literatürdeki diğer yöntemlere göre daha iyi sonuçlar verdiği önerilen ve alternatif yöntemlerin öngörülerinin, zaman serisi gerçek değerleri ile birlikte çizilen ve Şekil 4.3.’de verilen grafikten de görülmektedir.



Şekil 4.3. Mart 2007 ve Şubat 2008 aylık bazda TÜFE ve Öngörüler

4.3. Yıllık Bazdaki TÜFE Verisi Çözümlemesi

Önerilen yeni yöntem, son olarak Şubat 2004 ve Şubat 2008 dönemleri arasında her bir ay için hesaplanan yıllık bazda Türkiye Tüketici Fiyat Endeksi (TÜFE) zaman serisine uygulanmıştır. Öncelikle aylık olarak gözlenmiş veri yıllık veriye dönüştürülmüştür. Tablo 4.9. yıllık bazda elde edilen zaman serisini içermektedir.

Aynı zamanda yıllık bazda bulunan veri kümesinden ilk 37 veri eğitim kümesi ve son 12 veri de önerilen yöntem sonuçlarının literatürdeki diğer yöntem ve enflasyon beklentisi anketi sonuçları ile karşılaştırılabilmesi için test kümesi olarak alınmıştır. Bu zaman serisi için birinci dereceden başlayarak on ikinci dereceye kadar olan bulanık zaman serisi modelleri ile uygulama yapılmıştır. Uygulamada u_i aralık uzunlukları, verinin artışı göz önünde bulundurularak 0.10 ile 0.50 arasında her bir aşamada 0.05 arttırılarak belirlenmiştir. Algoritmanın 4. adımında kullanılan ileri beslemeli yapay sinir ağı mimarisinde gizli tabaka birim sayısı, ağın genelleştirme yeteneğini kaybetmemesi için 1-6 arasında sınırlandırılmıştır.

Yıllık bazda bulunan zaman serisinin çözümlemesi şu şekilde özetlenebilir.

Adım 1. Evrensel küme ve alt aralıklar tanımlanır.

Veri setinin en küçük değerinin 6.91 ve en büyük değerinin 11.70 olması sebebiyle sırasıyla $D_{\min} = 6.91$ ve $D_{\max} = 11.70$, ayrıca keyfi iki sayı $D_1 = 0.91$ ve $D_2 = 0.30$ olmak üzere evrensel küme,

$$U = [6.00, 12.00]$$

ve bununla birlikte aralık uzunluğu verideki artışı kapsayacak şekilde 0.50 olarak seçildiğinde, sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$\begin{aligned} u_1 &= [6.00, 6.50], & u_2 &= [6.50, 7.00], & u_3 &= [7.00, 7.50], \\ u_4 &= [7.50, 8.00], & u_5 &= [8.00, 8.50], & u_6 &= [8.50, 9.00], \\ u_7 &= [9.00, 9.50], & u_8 &= [9.50, 10.00], & u_9 &= [10.00, 10.50], \\ u_{10} &= [10.50, 11.00], & u_{11} &= [11.00, 11.50], & u_{12} &= [11.50, 12.00], \end{aligned}$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 olarak alındığında da u_i alt aralıkları benzer şekilde elde edilir.

Adım 2. Evrensel küme ve belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri tanımlanır.

Adım 1.'de belirlenen evrensel küme ve aralık uzunluğunun sabit 0.50 olduğu durumda belirlenen alt aralıklara bağlı olarak A_j bulanık kümeleri

$$\begin{aligned} A_1 &= 1/u_1 + 0.5/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\ A_2 &= 0.5/u_1 + 1/u_2 + 0.5/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\ A_3 &= 0/u_1 + 0.5/u_2 + 1/u_3 + 0.5/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\ A_4 &= 0/u_1 + 0/u_2 + 0.5/u_3 + 1/u_4 + 0.5/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\ A_5 &= 0/u_1 + 0/u_2 + 0/u_3 + 0.5/u_4 + 1/u_5 + 0.5/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\ A_6 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0.5/u_5 + 1/u_6 + 0.5/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \end{aligned}$$

$$\begin{aligned}
A_7 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0.5/u_6 + 1/u_7 + 0.5/u_8 + 0/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\
A_8 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0.5/u_7 + 1/u_8 + 0.5/u_9 + 0/u_{10} + 0/u_{11} + 0/u_{12} \\
A_9 &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0.5/u_8 + 1/u_9 + 0.5/u_{10} + 0/u_{11} + 0/u_{12} \\
A_{10} &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0.5/u_9 + 1/u_{10} + 0.5/u_{11} + 0/u_{12} \\
A_{11} &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0.5/u_{10} + 1/u_{11} + 0.5/u_{12} \\
A_{12} &= 0/u_1 + 0/u_2 + 0/u_3 + 0/u_4 + 0/u_5 + 0/u_6 + 0/u_7 + 0/u_8 + 0/u_9 + 0/u_{10} + 0.5/u_{11} + 1/u_{12}
\end{aligned}$$

şeklinde elde edilir. Bunun yanında aralık uzunluğu olarak 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 alındığında da A_j bulanık kümeleri benzer şekilde elde edilir.

Adım 3. Gözlemler bulanıklaştırılır.

Her bir veri bulunduğu aralığın en büyük üyelik değerine sahip olduğu bulanık küme ile eşleştirilerek zaman serisi bulanıklaştırılır. Tablo 4.9.'de gözlemlere ait reel ve aralık uzunluğunun sabit 0.50 olduğu durum için bulanıklaştırılmış değerler verilmiştir. Bunun yanında, diğer tüm aralık uzunlukları için de bulanık değerler benzer şekilde elde edilir.

Tablo 4.9. Yıllık TÜFE verisine ait reel ve bulanık değerler

Dönem	Değer	Bulanık Değer	Dönem	Değer	Bulanık Değer
Şubat 04	9.48	A7	Eylül 05	7.99	A4
Mart 04	8.40	A5	Ekim 05	7.50	A4
Nisan 04	7.88	A4	Kasım 05	7.60	A4
Mayıs 04	7.31	A3	Aralık 05	7.71	A4
Haziran 04	7.09	A3	Ocak 06	7.92	A4
Temmuz 04	7.81	A4	Şubat 06	8.14	A5
Ağustos 04	8.45	A5	Mart 06	8.15	A5
Eylül 04	8.02	A5	Nisan 06	8.82	A6
Ekim 04	9.44	A7	Mayıs 06	9.86	A8
Kasım 04	9.48	A7	Haziran 06	10.12	A9
Aralık 04	9.37	A7	Temmuz 06	11.70	A12
Ocak 05	9.25	A7	Ağustos 06	10.27	A9
Şubat 05	8.71	A6	Eylül 06	10.56	A10
Mart 05	7.95	A4	Ekim 06	10.00	A9
Nisan 05	8.18	A5	Kasım 06	9.88	A8
Mayıs 05	8.71	A6	Aralık 06	9.67	A8
Haziran 05	8.96	A6	Ocak 07	9.94	A8
Temmuz 05	7.82	A4	Şubat 07	10.17	A9
Ağustos 05	7.92	A4			

Adım 4. Bulanık mantık ilişkileri ileri beslemeli yapay sinir ağı kullanılarak oluşturulur.

Çözümlemede kullanılan yapay sinir ağı bileşenlerini aşağıdaki özellikleri taşımaktadır.

- Mimari Yapı: Tüm mümkün aralık uzunlukları için, girdi tabakasındaki birim sayısının her bir derece için sırasıyla 1-12, gizli tabakadaki birim sayısının ise her bir durum için 1-6 arasında değiştiği ve çıktı tabakasında tek birimin kullanıldığı toplam 72 farklı mimari ile çözümleme yapılmıştır.
- Öğrenme Algoritması: Öğrenme parametresinin her bir iterasyonda güncellendiği Levenberg – Marquardt algoritması en iyi ağırlıkların elde edilmesinde kullanılmıştır.
- Aktivasyon Fonksiyonu: Tüm birimlerde eğrisel aktivasyon fonksiyonlarından olan ve eğim parametresi $\gamma = 1$ olmak üzere, aşağıdaki eşitlik ile ifade edilen Lojistik aktivasyon fonksiyonu kullanılmıştır.

$$f(x) = (1 + \exp(-\gamma x))^{-1} \quad (4.5)$$

Adım 5. Bulanık öngörüler elde edilir.

Aralık uzunluğunun sabit 0.50 olduğu durum için ileri beslemeli yapay sinir ağı kullanılarak, üçüncü dereceden bulanık zaman serisi öngörü modeli için oluşturulan bulanık mantık ilişkilerinden yararlanılarak elde edilen ve test kümesine ait bulanık öngörüler Tablo 4.10.'de verilmiştir. Bunun yanında aralık uzunluğu 0.10, 0.15, 0.20, 0.25, 0.30, 0.35, 0.40 ve 0.45 olarak alındığında da üçüncü ve diğer tüm derecelerde bulanık zaman serisi öngörü modeli için test kümesine ait bulanık öngörüler benzer şekilde elde edilir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Aralık uzunluğunun sabit 0.50 olduğu durumda, üçüncü dereceden bulanık zaman serisi öngörü modeli için elde edilen bulanık öngörüler ile birlikte, durulaştırma işlemi sonucunda ulaşılan durulaştırılmış öngörüler Tablo 4.10.'da verilmiştir. Ayrıca diğer tüm aralık uzunlukları ve dereceler için de durulaştırılmış öngörüler benzer şekilde elde edilir.

Tablo 4.10. Yıllık TÜFE verisine ait bulanık ve duru öngörüler

Dönem	Duru Öngörü	Bulanık Öngörü	Dönem	Duru Öngörü	Bulanık Öngörü
Mart 07	11.25	A11	Eylül 07	7.25	A3
Nisan 07	10.75	A10	Ekim 07	7.25	A3
Mayıs 07	10.25	A9	Kasım 07	7.75	A4
Haziran 07	8.25	A5	Aralık 07	8.75	A6
Temmuz 07	6.25	A1	Ocak 08	8.75	A6
Ağustos 07	7.25	A3	Şubat 08	8.75	A6

Önerilen yöntemin algoritmasını oluşturan 6 adım, yıllık bazdaki TÜFE verisine tüm mümkün durumlar için uygulandı ve elde edilen durulaştırılmış öngörüler ($\hat{y}_i$) ile verinin gerçek değerleri (y_i) kullanılarak, tüm bu durumlar için hata kareler ortalanması karekökü (H.K.O.K.),

$$H.K.O.K. = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}} \quad (4.6)$$

formülü ile hesaplandı. Tüm mümkün durumlar için hesaplanan H.K.O.K. sonuçları EK 2’de mevcut olan tablolarda verilmiştir.

Tüm mümkün durumlar için hesaplanan H.K.O.K sonuçların verildiği tablolardan da görülebileceği gibi, Chen (2002) tarafından önerilen yöntemde en iyi sonuç, ikinci dereceden bulanık zaman serisi öngörü modeli için aralık uzunluğunun 0.40 olduğu durumda, 0.75745 H.K.O.K. değeri ile elde edilmiş olup, Huarng ve Yu (2006) tarafından önerilen yöntemde ise en iyi sonuç, aralık uzunluğunun 0.30 ve gizli tabaka birim sayısının dört olduğu durumda, 0.60270 H.K.O.K. değeri ile elde edilmiştir.

Bununla birlikte, T.C.M.B. tarafından her yılın belirli dönemlerinde yayınlanan, Tablo 4.11’ de verilen, 2007 yılı ikinci dönemine ait enflasyon beklentisi anketi sonuçlarının yer aldığı, enflasyon raporlarında ise H.K.O.K. değerleri, birinci anket sonucunda 2.69045 ve ikinci anket sonucunda 2.62527 olarak elde edilmiştir (T.C.M.B., 2007).

Tablo 4.11. Yıllık TÜFE verisine ait T.C.M.B. beklenti anketi öngörülleri


Dönem	T.C. Merkez Bankası Beklenti Anketi 1 Öngörülleri	T.C. Merkez Bankası Beklenti Anketi 2 Öngörülleri	Dönem	T.C. Merkez Bankası Beklenti Anketi 1 Öngörülleri	T.C. Merkez Bankası Beklenti Anketi 2 Öngörülleri
Mart 07	5.46	5.44	Eylül 07	7.62	7.54
Nisan 07	5.41	5.47	Ekim 07	7.38	7.31
Mayıs 07	5.57	5.83	Kasım 07	7.13	7.16
Haziran 07	6.66	7.48	Aralık 07	7.23	7.11
Temmuz 07	7.89	8.07	Ocak 08	6.84	6.84
Ağustos 07	7.98	7.94	Şubat 08	6.77	6.75

Bu çalışmada önerilen yöntemde ise en iyi sonuca, üçüncü dereceden bulanık zaman serisi öngörü modeli için aralık uzunluğunun 0.50 ve bunun yanında girdi ve gizli tabaka birim sayısının üç olduğu yani bulanık ilişkinin 3-3-1 mimarisi ile belirlendiği durumda, 0.49640 H.K.O.K. değeri ile elde edilmiştir. Her üç yöntemin en iyi sonuçlarını içeren Tablo 4.12. aşağıda verilmiştir.

Tablo 4.12. Yıllık TÜFE için anket sonuçları ve yöntemlerin en iyi sonuçları

Yöntem	Derece	Aralık Uzunluğu	Gizli Tabaka Birim Sayısı	H.K.O.K.
Enflasyon Beklenti Anketi (1)	-	-	-	2.69045
Enflasyon Beklenti Anketi (2)	-	-	-	2.62527
Chen (2002)	2	0.40	-	0.75745
Huarng ve Yu (2006)	1	0.30	4	0.60270
Önerilen Yöntem	3	0.50	3	0.49640

Bu sonuçlar göz önüne alındığında bu çalışmada önerilen Y.S.A.'na dayalı yüksek dereceli bulanık zaman serisi yöntemin literatürdeki diğer yöntemlere göre daha iyi sonuçlar verdiği, önerilen ve alternatif yöntemlerin öngörülerinin zaman serisi gerçek değerleri ile birlikte çizilen ve Şekil 4.4.'de verilen grafikten de görülmektedir.



Şekil 4.4. Mart 2007 ve Şubat 2008 yıllık bazda TÜFE ve öngörüler

5. SONUÇ VE ÖNERİLER

Bulanık zaman serisi analizi yöntemleri klasik zaman serisi analizi yöntemlerindeki model varsayımları ve gözlem sayısı gibi kısıtlamalara gerek duymaması ve geleneksel yöntemlere göre daha iyi öngörü performansına sahip olması nedeniyle son yıllarda literatürde sıkça kullanılmaya başlanmıştır.

Bulanık zaman serisi kavramı ilk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya atılmıştır. Song ve Chissom (1993a, 1993b, 1994) bu çalışmalarında bulanık zaman serisinin tahmin edilmesi için matris işlemlerine dayalı bir yöntem önermiştir. Önerilen bu yöntem üç aşamadan oluşmaktadır. Birinci aşama gözlemlerin bulanıklaştırılması, ikinci aşama bulanık ilişkilerin belirlenmesi ve üçüncü aşama ise durulaştırma aşmasıdır. Literatürde bulanık zaman serilerinde bu üç aşamanın da iyileştirilmesi için çeşitli çalışmalar yapılmıştır. Huarng ve Yu (2006) birinci dereceden bulanık zaman serisi öngörü modeli için bulanık ilişkinin belirlenmesinde, basit bir ileri beslemeli yapay sinir ağı kullanımını önermiştir. Huarng ve Yu (2006) önerdikleri bu yöntemde ilişki belirlemede 1-2-1 sinir ağı mimarisi kullanmışlardır. Gizli tabakadaki birim sayısı, yapay sinir ağının genelleştirme yeteneğini kaybetmemesi için, iki olarak alınmış olunmasına rağmen, gizli tabaka birim sayısının 3 ve 4 alınması da genelleştirme yeteneğini kaybettirmeyecektir. Chen (2002) ise yüksek dereceli bulanık zaman serisi yaklaşımı önermiştir. Chen (2002) tarafından önerilen bu yaklaşımda, modelde tüm gecikmeli bulanık değişkenlerin bulunması ve bulanık ilişki tablolarına dayalı işlem yapılması nedeniyle derece arttıkça bulanık ilişkinin belirlenmesi ve dolayısıyla yöntemin uygulanması oldukça zorlaşmaktadır. Yüksek dereceli modelin çözülmesinde bulanık ilişkiler, yapay sinir ağı ile belirlenir ise bu yöntemdeki işlem yoğunluğundan kurtulmak mümkündür.

Bu çalışmada yüksek dereceli bulanık zaman serisi modelini çözümleyen, bulanık ilişkinin belirlenmesinde ileri beslemeli yapay sinir ağının kullanıldığı, yeni bir yöntem önerilmiştir. Yapay sinir ağına dayalı bu yaklaşım, ilk olarak literatürde sıkça kullanılan Alabama Üniversitesi 1971-1992 yıllarına ait kayıt verisine ve daha sonra da Şubat 2003 - Şubat 2008 dönemleri arasında hesaplanan aylık bazda Türkiye Tüketici Fiyat Endeksi (TÜFE) ve yine aynı zaman serisi kullanılarak Şubat 2004 ve Şubat 2008 dönemleri arasında her bir ay için hesaplanan yıllık bazda Türkiye Tüketici Fiyat

Endeksi zaman serisine uygulanarak sonuçlar elde edilmiş ve diğer yöntemlerle karşılaştırılmasıyla birlikte, yıllık bazda hesaplanan sonuçlar ayrıca T.C. Merkez Bankası tarafından her yılın belirli dönemlerinde yayınlanan, enflasyon beklentisi anketi sonuçları ile de karşılaştırılarak önerilen yaklaşımın üstün olduğu görülmüştür.

Tüm bu sonuçlar göz önüne alındığında, bu çalışmada önerilen, yüksek dereceli bulanık zaman serisi modelini çözümleyen, bulanık ilişkinin belirlenmesinde ileri beslemeli yapay sinir ağının kullanıldığı yöntemin, bulanık ilişki ve grup ilişki tablolarının oluşturulmasındaki karmaşıklığı ortadan kaldırdığı gibi öngörülerini de iyileştirdiği görülmektedir.

Bunun yanında, yöntemin uygulanmasında önemli aşamalardan biri olan, ileri beslemeli yapay sinir ağları ile ilişki belirlenmesi aşamasında, ağın mimari yapısının öngörülere olan etkisi göz önünde bulundurularak, mimari yapının belirlenmesi konusunda belirli kıstaslar ortaya koyabilecek yeni çalışmalar oluşturulabilir. Ayrıca ağın girdilerinin belirlenmesi de, üzerinde durulması ve gelecek çalışmalara konu edilmesi gerekli olan önemli bir meseledir.

6. KAYNAKLAR

- Bartlett, M.S., 1955. *Stochastic Processes*. Cambridge University Press, Cambridge.
- Bolat, S., Kalenderli, Ö., 2003. Levenberg-Marquardt Algoritması Kullanılan Yapay Sinir Ağı İle Elektrot Biçim Optimizasyonu. "International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003"
- Box, G. E. P., Jenkins, G. M., 1976. *Time Series Analysis: forecasting and control*. Holden Day, 575s, San Francisco.
- Buckley, J. J., 2006. *Fuzzy Probability and Statistics*. Springer-Verlag, 270s, Berlin.
- Buckley, J. J., Elsami, E., 2002. *Introduction to Fuzzy Logic and Fuzzy Sets*. Physica-Verlag, Berlin.
- Chatfield, C., 1989. *The analysis of time series: an introduction*. Chapman, London.
- Chen, S. M., 1996. Forecasting enrollments based on fuzzy time-series. *Fuzzy Sets and Systems*, 81, 311-319.
- Chen, S. M., 2000. Usin High-Order Fuzzy Time Serises for Handling Forecasting Problems. *Proceedings of the 11th National Conference on Information Management*, 2000, Kaohsiung.
- Chen, S. M., 1996. Forecasting enrollments based on fuzzy time-series. *Fuzzy Sets and Systems*, 81, 311-319.
- Chen, S.M., 2002. Forecasting enrollments based on high order fuzzy time series. *Cybernetics and Systems*, 33, 1-16.
- Chen, S. M., Hwang, J. R., 2000. Temperature prediction using fuzzy time series. *IEEE Transaction on Systems, Man and Cybernetics, Part B*, 30 (2), 263-275.
- Cryer, J. D., 1986. *Time Series Analysis*. Dyxbury Press, Boston.
- Elmas, Ç., 2003. *Bulanık Mantık Denetleyiciler*. Seçkin Yayıncılık, 230s, Ankara.

- Günay, S., Eğrioğlu, E., Aladağ, Ç.H., 2007. *Tek Değişkenli Zaman Serileri Analizine Giriş*. Hacettepe Üniversitesi Yayınları, 230s, Ankara.
- Huarng, K., 2001a. Effective length of intervals to improve forecasting in fuzzy time-series. *Fuzzy Sets and Systems*, 123, 387-394.
- Huarng, K., 2001b. Heuristic models of fuzzy time series for forecasting. *Fuzzy Sets and Systems*, 123 (3), 369-386.
- Huarng, K., Yu, H.-K., 2004. A dynamic approach to adjusting lengths of intervals in fuzzy time series forecasting. *Intelligent Data Analysis*, 8(1), 3-27.
- Huarng, K., Yu, H.-K., 2005. A type 2 fuzzy time series model for stock index forecasting. *Physica A*, 353, 445-462.
- Huarng, K., Yu, H.-K., 2006. The application of neural networks to forecast fuzzy time series. *Physica A*, 363, 481-491.
- Huarng, K., Yu, H.-K., 2008. A bivariate fuzzy time series model to forecast TAIEX. *Expert Systems with Applications*, 34, 2945-2952.
- Hwang, J. R., Chen, S. M., Lee, C. H., 1998. Handling forecasting problems using fuzzy time series. *Fuzzy Sets and Systems*, 100, 217-228.
- Kadılar, C., 2005. *SPSS Uygulamalı Zaman Serileri Analizine Giriş*. Bizim Büro Basımevi, 299s, Ankara.
- Klir, G., Yuan, B., 1995. *Fuzzy Set and Fuzzy Logic: Theory and Applications*. Prentice Hall, Upper Saddle River, N.J.
- Le Chun, Y., 1988. A theoretical framework for backpropagation, in *proc. Connectionist Model Summer School*, June 17-26, Touretzky, D., Hinton, G., and Sejnowski, T. (Eds.), Morgan Kaufmann, pp. 21-28.
- Markidakis, S., Wheelwright, S.C., 1978. *Interactive forecasting: univariate and multivariate methods*. 2nd Edition, Holden-Day, 650s, New York.

- Moore, R.E., 1979. *Methods and Applications of Interval Analysis*. SIAM Studies in Applied Mathematics, Philadelphia.
- Neumaier, A., 1990. *Interval Methods for Systems of Equations*. Cambridge University Press, Cambridge, U.K.
- Ngia, S. H., 2000. Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm. *IEEE Trans. on Signal Process.*, 48, 1915-1927.
- Oğuz, M., 2001. Yalıtkan Maddelerde Elektriksel Delinme Dayanımının Yapay Sinir Ağları İle Belirlenmesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Papatya Yayıncılık, 238s, İstanbul.
- Parker, D.B., 1982. Learning-Logic, Invention Report. Office of Technology Licensing Stanford University. S81-64, File 1, Stanford.
- Quenouille, M.H., 1949. Approximate tests of correlation in time series. *Jour. Royal Stat. Soc.*, B11, 68.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning Representations by Backpropagating Errors. *Nature*, 323 (6188), 533-536.
- Smith, K.A., Gupta, J.N.D., 2002. *Neural networks in business: techniques and applications*. Idea Group, 272s, Hershey.
- Song, Q., Chissom, B.S., 1993a. Fuzzy time series and its models. *Fuzzy Sets and Systems*, 54, 269-277.
- Song, Q., Chissom, B.S., 1993b. Forecasting enrollments with fuzzy time series- Part I. *Fuzzy Sets and Systems*, 54, 1-10.
- Song, Q., Chissom, B.S., 1994. Forecasting enrollments with fuzzy time series- Part II. *Fuzzy Sets and Systems*, 62 1-8.

- Song, Q., Leland, R.P., Chissom, B.S., 1995. A new fuzzy time-series model of fuzzy number observations. *Fuzzy Sets and Systems*, 73(3), 341-348.
- Song, Q., Leland, R.P., 1996. Adaptive learning defuzzification techniques and applications. *Fuzzy Sets and Systems*, 81(3), 321-329.
- Sullivan, J., Woodall, W. H., 1994. A comparison of fuzzy forecasting and Markov modeling. *Fuzzy Sets and Systems*, 64(3), 279 - 293.
- T.C.M.B., 2007. <http://www.tcmb.gov.tr/research/parapol/enf-nisan2007.pdf> Enflasyon Raporu 2007-II, Sayfa: 26.
- Werbos, P.J., 1974. Beyond Regression: New tools for Prediction and Analysis in the Behavioral Sciences. Ph. D. Thesis, Harvard University, Cambridge.
- Yu, H. K., 2005a. A refined fuzzy time series model for forecasting. *Physica A*, 346, 657-681.
- Yu, H. K., 2005b. Weighted fuzzy time series models for TAIEX forecasting, *Physica A*, 349, 609-624.
- Zadeh L.A., 1965. Fuzzy Sets, *Inform and Control*, 8,338-353.
- Zadeh L.A., 1973. Outline of a new approach to the analysis of complex systems and decisions processes, *IEEE Trans. Systems Man Cybernet.*, 3, 28-44.
- Zadeh L.A., 1975. The concept of a linguistic variable and its application to approximate reasoning, Parts 1-3, *Inform. Sci.* 8, 199-249; 8, 301-357; 9, 43-80.

7. EKLER

Ek 1. Aylık TÜFE Verisi İçin Elde Edilen H.K.O.K. Değerleri

Ek Tablo 1.1. Birinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu
(Huarng ve Yu (2006))

		Huarng ve Yu (2006)					
		Gizli Tabaka Birim Sayısı					
ARALIK UZUNLUĞU	LA	m=1	m=2	m=3	m=4	m=5	m=6
	0.10	0.71980	1.70498	0.94311	0.85953	0.84771	1.10828
	0.15	0.72812	1.68275	0.78464	0.78225	0.73953	0.66194
	0.20	0.70707	1.74965	0.94231	0.86330	0.87728	0.87728
	0.25	0.73773	1.81718	0.74699	0.77840	0.71856	0.74307
	0.30	0.77122	1.61657	0.74819	0.80795	0.95120	0.83324
	0.35	0.77567	1.77210	0.94793	0.94885	0.95315	0.77265
	0.40	0.68917	1.83982	1.07251	0.83683	1.08241	0.93823
	0.45	0.68019	1.81718	0.72191	0.72191	0.72191	0.72191
	0.50	0.76667	1.70498	0.76667	0.77585	0.76667	0.76667

Ek Tablo 1.2. İkinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.77886	0.71632	0.81932	0.95452	1.00984	1.70498	0.83660
	0.15	0.77840	0.67075	0.82274	0.83196	1.68275	1.68275	0.99003
	0.20	0.72843	0.70424	0.65647	0.98283	1.07080	1.74965	0.95407
	0.25	0.78054	0.80317	0.89284	1.00295	0.96505	0.68196	0.96294
	0.30	0.80423	0.72338	1.67430	0.91038	0.81442	1.61657	0.99270
	0.35	0.77378	0.71460	0.79241	1.15639	0.79498	1.47871	1.01003
	0.40	0.77090	0.74316	0.83204	1.05243	1.07033	1.83982	1.07802
	0.45	0.75839	0.74794	0.68294	0.62021	0.88100	0.81142	1.01566
	0.50	0.79285	0.77585	0.77585	1.13076	1.00679	1.70498	1.13263

Ek Tablo 1.3. Üçüncü Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		m=1	m=2	m=3	m=4	m=5	m=6	
ARALIK UZUNLUĞU	LA	m=1	m=2	m=3	m=4	m=5	m=6	
	0.10	0.70056	1.70498	0.73140	1.13627	1.20158	1.04902	0.89471
	0.15	0.70136	1.68275	0.71548	0.63573	1.01571	0.82714	1.02706
	0.20	0.70163	1.74965	0.92373	0.85982	1.01355	1.03213	0.99770
	0.25	0.71332	1.81718	0.88886	0.70981	1.06462	1.18536	0.86659
	0.30	0.65862	1.61657	0.70872	0.84308	0.98096	0.95801	1.04849
	0.35	0.70474	1.77210	0.82769	0.89116	1.24739	1.18603	1.03715
	0.40	0.67697	1.83982	0.89309	1.08702	1.21557	1.42371	1.02734
	0.45	0.65548	1.81718	0.64452	0.79367	1.12912	1.06907	0.98042
0.50	0.67227	1.70498	1.00097	0.91667	1.11405	1.12633	1.06165	

Ek Tablo 1.4. Dördüncü Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.58931	0.89700	0.87870	1.70498	1.70498	1.17209	0.90370
	0.15	0.70136	0.83016	0.67890	0.58814	1.68275	1.05944	0.90719
	0.20	0.64520	0.88503	0.78291	1.74965	1.74965	0.94408	0.88783
	0.25	0.64135	0.85566	0.70035	1.81718	1.81718	1.91444	0.87392
	0.30	0.66655	0.85574	0.89263	1.61657	1.61657	0.66127	0.91803
	0.35	0.70474	0.92394	1.77210	1.77210	0.76773	1.77210	0.93796
	0.40	0.71434	0.89905	1.83982	1.83982	1.39246	0.86156	0.89391
	0.45	0.60738	0.71303	0.83780	1.81718	1.81718	1.22929	0.88593
	0.50	0.64053	0.66417	0.57034	1.70498	1.70498	1.16345	0.87068

Ek Tablo 1.5. Beşinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.70175	0.67721	1.04528	1.25191	0.82792	1.68388	0.88789
	0.15	0.71197	0.71844	0.85391	0.83316	1.45582	1.41710	0.88963
	0.20	0.65494	0.89886	0.65571	0.79159	1.05449	1.58901	0.87538
	0.25	0.60662	0.66464	0.81756	1.37085	0.97515	1.16372	0.85849
	0.30	0.74517	0.75019	0.68358	0.75052	1.49425	1.37251	0.89875
	0.35	0.70017	0.84926	0.78054	1.16318	1.35606	1.79759	0.91565
	0.40	0.81585	0.60024	0.98130	0.70872	1.14001	1.15106	0.87861
	0.45	0.72087	0.77695	0.67687	1.08647	1.08647	1.26862	0.87482
	0.50	0.64053	0.53878	0.74517	0.80433	0.76122	1.06276	0.85517

Ek Tablo 1.6. Altıncı Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.67153	0.78525	1.01413	1.02638	1.01790	1.20504	0.86690
	0.15	0.86323	0.84626	0.68148	0.88553	1.14549	1.51671	0.86878
	0.20	0.57904	0.60933	0.72407	0.88371	1.15309	1.59560	0.85672
	0.25	0.60662	0.89284	0.90027	1.21195	1.61235	1.27544	0.83984
	0.30	0.79516	0.59185	1.07461	1.39096	1.35804	1.47928	0.87486
	0.35	0.70845	0.70598	1.28970	1.17441	1.24552	1.57646	0.89020
	0.40	0.76307	0.62686	0.93752	0.78589	1.58270	1.17372	0.85922
	0.45	0.69976	0.68568	0.88989	1.28420	1.35745	1.37528	0.85655
0.50	0.62606	0.74741	0.89225	0.95844	1.02321	1.26930	0.83652	

Ek Tablo 1.7. Yedinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.55252	0.88409	0.84850	1.68699	0.89738	1.67490	0.85229
	0.15	0.56028	0.68294	0.77599	1.58860	1.36562	1.24946	0.85528
	0.20	0.69782	0.60933	0.77821	1.26463	1.40355	1.26687	0.84358
	0.25	0.60041	0.81756	0.85102	1.41306	0.81450	1.07842	0.82843
	0.30	0.64481	0.97636	1.16803	0.59311	1.52177	1.31483	0.85946
	0.35	0.70017	0.90318	0.69179	0.91058	1.62475	1.77210	0.87213
	0.40	0.65799	0.71154	1.30369	1.11667	0.86619	0.83123	0.84607
	0.45	0.58409	0.79414	0.83556	1.26892	1.14068	1.81718	0.84406
	0.50	0.67227	0.59885	0.58548	0.82226	0.87146	0.68334	0.82647

Ek Tablo 1.8. Sekizinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.68028	0.64855	0.70056	1.43583	1.70498	1.35122	0.84902
	0.15	0.71074	0.65948	1.06485	1.24375	1.68275	1.81216	0.85320
	0.20	0.60604	0.75407	1.14497	1.36380	1.74965	1.52642	0.84189
	0.25	0.65453	0.73688	0.88675	1.52236	1.81718	1.19464	0.82843
	0.30	0.57557	0.67289	0.59564	0.63819	1.61657	1.32845	0.85620
	0.35	0.59818	0.79754	0.91026	1.36933	1.77210	1.23092	0.86620
	0.40	0.71434	0.77435	1.83982	1.17372	1.83982	1.32374	0.84379
	0.45	0.66795	0.68019	0.95886	1.33263	1.81718	1.02903	0.84246
	0.50	0.57760	0.76395	0.74852	1.14504	0.77532	1.15229	0.82762

Ek Tablo 1.9. Dokuzuncu Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.60960	0.87566	1.47104	1.59686	1.53111	1.41967	0.84904
	0.15	0.65108	0.70651	1.40700	1.67277	1.03617	1.09300	0.85419
	0.20	0.59885	0.83184	1.61729	1.20677	0.94953	1.54476	0.84286
	0.25	0.65038	1.00502	0.83820	1.13030	1.45333	1.28650	0.83172
	0.30	0.97636	1.18355	1.05037	1.31179	1.40028	1.18101	0.85618
	0.35	0.72915	0.96983	0.89442	0.95894	1.24177	1.53332	0.86428
	0.40	0.83563	0.92066	1.04417	1.31261	1.58649	1.45176	0.84373
	0.45	0.62623	0.77647	1.31535	1.08024	1.18043	1.08232	0.84495
	0.50	0.64053	0.73617	0.98883	1.52871	1.00554	1.06589	0.83061

Ek Tablo 1.10. Onuncu Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	m=6
ARALIK UZUNLUĞU	0.10	0.71224	0.71527	1.77711	1.48187	1.38803	1.58302	0.84630
	0.15	0.87072	1.06825	1.27442	1.33282	1.30582	1.19579	0.85219
	0.20	0.57180	0.85496	1.43025	1.05717	1.14497	1.35841	0.84083
	0.25	0.67552	0.77276	1.23224	0.97322	1.13929	1.44715	0.83201
	0.30	0.57209	0.58162	1.09260	1.15943	1.61657	1.41184	0.85298
	0.35	0.69850	1.47693	1.48284	1.22307	1.54110	1.30789	0.86064
	0.40	0.68820	1.15857	1.70067	1.13238	1.83982	1.12796	0.84035
	0.45	0.76773	0.59301	1.30591	1.13310	1.05708	1.08612	0.84559
	0.50	0.80743	0.84820	1.21906	1.08295	1.17450	1.37032	0.82979

Ek Tablo 1.11. Onbirinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.57543	0.71189	1.70498	0.88343	1.19253	0.69626	0.84001
	0.15	0.82895	0.86395	1.68275	1.22980	1.12023	0.96910	0.84604
	0.20	0.69758	1.04289	1.74965	1.31274	1.50564	1.09603	0.83499
	0.25	0.88675	0.82920	1.81718	1.58129	1.04924	1.25933	0.82830
	0.30	0.56858	0.83862	1.61657	0.97508	1.05512	1.54103	0.84590
	0.35	0.66294	1.39173	1.77210	1.56327	0.93959	1.19655	0.85330
	0.40	0.58846	1.35829	1.83982	1.35362	1.26318	1.67141	0.83385
	0.45	0.90245	0.97476	1.81718	1.27717	1.27599	1.53237	0.84179
	0.50	0.58405	1.14468	1.70498	1.20116	0.83782	1.41637	0.82564

Ek Tablo 1.12. Onikinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Soncu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.73708	1.22866	1.16874	1.22002	1.47895	1.15663	0.83178
	0.15	0.71844	0.71844	1.21095	1.10200	1.12235	1.01484	0.83753
	0.20	0.63452	1.06581	0.92265	1.97711	1.25961	1.62017	0.82704
	0.25	0.61209	0.72892	1.46447	1.58090	1.15311	1.71940	0.82158
	0.30	0.63030	1.01355	1.41148	0.79861	0.89710	1.36062	0.83733
	0.35	0.76277	0.97762	1.37337	1.31855	1.92408	1.54526	0.84401
	0.40	0.91812	1.04353	1.12322	1.09344	1.38719	1.70693	0.82607
	0.45	0.63809	0.97630	1.37310	1.51934	1.14462	1.28973	0.83437
0.50	0.61260	0.94089	1.46439	1.19036	1.27552	1.14140	0.81903	

Ek 2. Yıllık TÜFE Verisi İçin Elde Edilen H.K.O.K. Değerleri

Ek Tablo 2.1. Birinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu
(Huarng ve Yu (2006))

		Huarng ve Yu (2006)					
		Gizli Tabaka Birim Sayısı					
ARALIK UZUNLUĞU	LA	m=1	m=2	m=3	m=4	m=5	m=6
	0.10	0.75172	3.41817	0.71233	0.70799	1.43936	1.43936
	0.15	0.71929	3.44153	0.98495	0.68328	1.45065	2.14310
	0.20	0.77325	3.37154	0.70799	0.94388	1.46136	0.96432
	0.25	0.76346	3.30176	0.70737	0.62346	1.39745	1.91952
	0.30	0.71397	3.51173	0.69264	0.60270	0.65973	0.60477
	0.35	0.79112	3.44153	0.71248	0.66505	0.79527	0.79527
	0.40	0.73320	3.46491	0.70065	1.42861	0.94882	1.11934
	0.45	0.77193	3.30176	0.70596	0.63492	0.63492	0.63492
	0.50	0.82447	3.41817	0.71280	0.71280	0.61285	0.75150

Ek Tablo 2.2. İkinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
ARALIK UZUNLUĞU	LA	m=1	m=2	m=3	m=4	m=5	m=6	
	0.10	0.73320	0.75592	0.73320	1.74597	0.97652	3.41817	0.90933
	0.15	0.72431	0.75357	1.56289	0.72569	1.82992	3.44153	0.90372
	0.20	0.71151	0.81440	1.72170	1.86635	1.85389	3.37154	0.78057
	0.25	0.70146	0.78286	0.71528	1.08319	0.98275	0.99915	0.83616
	0.30	0.66839	0.73161	0.66839	1.59930	1.68530	1.62458	0.84513
	0.35	0.73147	0.72666	0.96766	0.73147	0.90312	0.81876	0.78407
	0.40	0.68720	0.66301	1.50806	0.90494	1.73000	3.22701	0.75745
	0.45	0.73357	0.72120	0.73357	0.74322	0.97462	3.30176	0.83683
0.50	0.71746	0.68356	1.66025	0.63947	0.63947	3.41817	0.77348	

Ek Tablo 2.3. Üçüncü Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.69348	3.41817	0.95180	1.41242	1.74330	1.62078	1.01811
	0.15	0.67814	3.44153	0.98228	1.49579	1.98006	1.35624	1.01203
	0.20	0.71827	3.37154	1.63358	1.69123	0.83242	1.50574	1.03260
	0.25	0.68523	3.30176	1.08319	0.94910	1.27784	1.19057	0.99764
	0.30	0.71116	3.51173	0.95013	0.93742	2.36860	1.53452	0.99463
	0.35	0.75578	3.44153	0.87823	0.77371	0.81017	1.74837	1.02128
	0.40	0.72543	3.46491	0.50818	1.73462	1.98299	1.04829	1.04895
	0.45	0.73357	3.30176	0.98799	1.56329	1.09047	1.30322	1.01826
0.50	0.71746	3.41817	0.49640	1.01312	1.75231	2.13848	1.03095	

Ek Tablo 2.4. Dördüncü Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.71804	1.61645	1.35342	3.41817	3.41817	3.41817	1.11229
	0.15	0.68383	1.62984	1.57238	3.44153	1.46659	3.44153	1.10698
	0.20	0.71920	1.58354	1.39556	3.37154	3.37154	3.37154	1.12400
	0.25	0.69339	1.56763	0.97914	3.30176	3.30176	3.30176	1.09235
	0.30	0.71116	0.83741	0.98805	3.51173	1.78375	3.51173	1.09166
	0.35	0.77934	0.76346	0.71534	3.44153	1.46141	3.44153	1.11304
	0.40	0.69779	0.87192	0.61934	3.46491	3.46491	3.46491	1.16715
	0.45	0.73357	2.07711	1.56257	3.30176	3.30176	3.30176	1.11127
0.50	0.69384	0.94194	1.20128	3.41817	3.41817	3.41817	1.14683	

Ek Tablo 2.5. Beşinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	1.26079	0.90595	1.47233	1.81239	2.39797	2.32194	1.18333
	0.15	3.44153	0.82923	1.56137	1.72217	1.55953	3.24683	1.17895
	0.20	0.71292	0.85220	1.49496	2.00929	0.96519	1.54464	1.19253
	0.25	0.67974	0.90598	1.33852	1.23253	2.00405	2.00727	1.16237
	0.30	0.94194	1.10465	0.88783	1.06946	2.62874	1.53842	1.16497
	0.35	0.77484	0.79012	2.03657	2.34230	2.41489	1.38770	1.18179
	0.40	1.30087	0.96346	1.30624	1.89936	2.06452	1.41524	1.24064
	0.45	0.82500	0.91795	1.34094	1.18475	1.61752	3.41531	1.18536
0.50	0.82497	0.84641	1.34434	1.89884	2.05987	1.98886	1.22323	

Ek Tablo 2.6. Altıncı Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.75812	0.96112	1.43402	3.41817	2.15934	1.85775	1.23297
	0.15	0.75606	1.64229	1.22071	1.58284	2.05216	2.07723	1.22936
	0.20	0.91081	1.76302	1.69172	2.02112	2.84053	1.97760	1.24031
	0.25	1.22609	1.64695	1.07740	1.76575	1.48855	2.72029	1.21065
	0.30	0.77055	1.72199	1.53566	3.51173	1.71937	1.18438	1.21665
	0.35	1.03917	0.78716	2.11897	2.26030	2.52680	1.89195	1.22997
	0.40	0.74044	0.86809	1.09860	1.62734	2.62759	1.37074	1.23908
	0.45	0.73714	1.03362	1.08806	2.16012	2.64308	1.15850	1.23572
	0.50	0.77174	1.70213	2.04648	2.11812	2.13965	2.79534	1.23071

Ek Tablo 2.7. Yedinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.75592	3.41817	1.62155	1.61160	2.10929	1.83255	1.26860
	0.15	0.75589	3.44153	1.53603	1.80614	2.14828	3.44153	1.26509
	0.20	0.77001	1.40377	1.75402	1.74028	2.83271	2.20581	1.27506
	0.25	0.71790	3.30176	1.71390	1.90470	1.78721	1.64948	1.24501
	0.30	0.77734	3.51173	1.68990	1.85047	1.74721	1.82462	1.25307
	0.35	0.78196	1.86790	1.74637	1.79723	1.90240	1.65742	1.26457
	0.40	0.74044	1.05052	1.51490	1.78033	1.66280	1.71957	1.27473
	0.45	0.73357	1.98384	1.83456	1.67425	2.71088	2.46650	1.27131
	0.50	0.67001	1.26448	2.03975	1.41619	1.72788	2.26453	1.26382

Ek Tablo 2.8. Sekizinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.77444	1.01485	1.01485	1.49429	3.24139	2.50917	1.29231
	0.15	0.79867	0.65869	1.32273	1.85165	3.31841	2.73777	1.28861
	0.20	0.76979	1.00793	1.46944	2.38933	1.91770	1.78155	1.29816
	0.25	0.75523	1.43975	2.22326	1.41376	2.86770	2.13930	1.26778
	0.30	0.90291	1.15877	1.21891	1.77038	1.84845	2.88752	1.27708
	0.35	0.88221	1.24243	2.47690	1.91417	3.29307	3.07543	1.28856
	0.40	0.72451	1.08670	1.41053	1.87339	1.88173	2.63583	1.29870
	0.45	0.74069	0.77918	3.30176	1.95087	1.67582	2.42309	1.29549
	0.50	0.90953	1.83682	2.38077	2.05461	1.89092	2.45606	1.28551

Ek Tablo 2.9. Dokuzuncu Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	0.72646	1.17972	2.04542	1.60034	1.31400	2.62019	1.31203
	0.15	0.71981	1.94451	1.87120	1.79858	1.47712	1.77013	1.30800
	0.20	0.71292	0.71292	1.92352	1.56245	1.70555	2.91340	1.31768
	0.25	0.72655	0.95914	2.04409	1.57638	1.86770	1.99436	1.28742
	0.30	0.86444	2.05311	2.16096	1.53011	1.37976	1.79492	1.29750
	0.35	0.70837	1.95801	2.05723	1.96796	1.34609	1.95517	1.30912
	0.40	0.83999	0.89270	3.28840	1.38501	2.17154	1.15596	1.31894
	0.45	0.75870	1.55945	2.32209	1.28379	1.35236	2.67145	1.31493
0.50	0.77766	1.22089	1.89664	1.68144	1.43866	2.38095	1.30429	

Ek Tablo 2.10. Onuncu Dereceden Bulanık Zaman Serisi Öngörü Modeli Soncu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		m=1	m=2	m=3	m=4	m=5	m=6	
ARALIK UZUNLUĞU	LA	m=1	m=2	m=3	m=4	m=5	m=6	
	0.10	0.71978	2.21278	1.75236	1.11411	1.44612	2.59501	1.33334
	0.15	1.08045	1.62600	2.40315	1.26021	0.89478	1.80489	1.32913
	0.20	0.74872	2.21907	2.24676	1.51940	1.79060	1.37680	1.33885
	0.25	0.74496	1.89351	2.84780	2.71998	1.37385	2.40303	1.30908
	0.30	1.10962	1.67190	1.42259	2.13898	1.95659	2.25205	1.31997
	0.35	0.70837	0.80981	2.76459	1.53613	1.94980	1.95577	1.33180
	0.40	0.68038	2.14855	2.45742	2.57337	2.10735	1.52236	1.34118
	0.45	0.81171	1.21166	1.56281	1.51900	1.46931	2.08504	1.33609
0.50	0.77766	2.45131	1.42411	2.89866	1.69625	1.56543	1.32565	

Ek Tablo 2.11. Onbirinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	1.05242	2.99468	0.97626	1.29708	3.41817	2.97101	1.35751
	0.15	1.30350	1.42281	3.44153	1.81235	3.44153	2.09389	1.35320
	0.20	1.71170	2.14210	3.37154	1.88589	3.37154	3.13144	1.36274
	0.25	1.54622	2.80891	3.30176	1.11428	3.30176	2.70616	1.33378
	0.30	1.36647	1.30528	1.28792	0.87479	3.51173	0.87621	1.34522
	0.35	1.99168	1.73917	0.92640	1.12774	3.44153	2.69146	1.35730
	0.40	0.72175	1.91126	1.70301	0.96207	3.46491	2.59286	1.36595
	0.45	1.08045	1.47872	3.30176	1.80177	3.30176	2.58121	1.36014
	0.50	1.03710	2.81465	2.77949	1.44184	3.41817	1.93557	1.35055

Ek Tablo 2.12. Onikinci Dereceden Bulanık Zaman Serisi Öngörü Modeli Sonucu

		ÖNERİLEN YÖNTEM						CEHN (2002)
		Gizli Tabaka Birim Sayısı						
		LA	m=1	m=2	m=3	m=4	m=5	
ARALIK UZUNLUĞU	0.10	1.14175	1.20737	1.45639	1.16665	1.93557	2.84808	1.38608
	0.15	1.13143	1.12233	1.70540	1.90463	1.53334	3.08871	1.38179
	0.20	1.12187	1.38308	1.44519	1.47702	0.86694	1.94865	1.39098
	0.25	1.03981	0.71207	1.49567	2.75325	1.73492	1.51477	1.36289
	0.30	1.10420	2.70134	2.36151	3.09277	0.99762	1.10238	1.37491
	0.35	0.75346	1.64789	2.58127	0.94077	1.56342	3.30950	1.38711
	0.40	0.78629	1.18726	1.69850	1.24321	2.13235	1.83746	1.39491
	0.45	0.69687	0.70543	1.32434	2.57131	1.66707	1.41576	1.38848
0.50	1.10480	2.40498	2.37464	1.26349	2.04913	2.54160	1.37989	

**Ek 3. Üçüncü Dereceden Bulanık Zaman Serisi Öngörü Modeli İçin Örnek
MATLAB Programı**

Program Girdi ve Parametreleri

x: Zaman serisi
m: Gizli tabaka birim sayısı
salt: Evrensel küme alt sınırı
ss: Bulanık küme sayısı
la: Evrensel küme alt aralık uzunluğu
ntest: Test kümesi genişliği

```
function output=fuzzytg3tli(x,m,salt,ss,la,ntest)
rand('seed',4.9276984E7);
n=size(x,1)-ntest;
for i=1:ss
    ualt(i)=salt+(i-1)*la;
    uust(i)=salt+i*la;
    mb(i)=(ualt(i)+uust(i))/2;
end
for i=1:n+ntest
    for j=1:ss
        if ((x(i)<=uust(j))&(x(i)>=ualt(j)))
            fs(i)=j;
        end
    end
end
zd1=(fs-min(fs))/(max(fs)-min(fs));
Gegt=[zd1(1:(n-3));zd1(2:(n-2));zd1(3:(n-1))];
yegt=zd1(4:n)';
net=newff(minmax(Gegt'),[m,1],{'tansig','tansig'},'trainlm');
net.trainParam.show=500;
net.trainParam.epochs=500;
net.trainParam.goal=1e-8;
[net,tr]=train(net,Gegt',yegt');
ycegt=sim(net,Gegt');
yc=round(ycegt*(max(fs)-min(fs))+min(fs));
```

```

for i=1:(n-3)
    if yc(i)<=0
        yc(i)=1;
    end
end

for i=1:(n-3)
    ong(i)=mb(yc(i));
end
for i=1:(n-3)
    hatakare(i)=(x(i+2)-ong(i))^2;
end
for j=1:ntest
    Gegt=[zd1(n+j-3);zd1(n+j-2);zd1(n+j-1)]';
    ycegt2(j)=sim(net,Gegt');
end
yc2=round(ycegt2*(max(fs)-min(fs))+min(fs));
for i=1:(ntest)
    if yc2(i)<=0
        yc2(i)=1;
    end
end
for i=1:ntest
    ong2(i)=mb(yc2(i));
end
for i=1:ntest
    hatakare2(i)=(x(i+n)-ong2(i))^2;
end
MSE=(sum(hatakare)/(n-3))
RMSE=(sum(hatakare)/(n-3))^0.5
MSEtest=(sum(hatakare2)/(ntest))
RMSEtest=(sum(hatakare2)/(ntest))^0.5
output=[RMSEtest];

```

**Ek 4. Beşinci Dereceden Bulanık Zaman Serisi Öngörü Modeli İçin Örnek
MATLAB Programı**

Program Girdi ve Parametreleri

x: Zaman serisi
m: Gizli tabaka birim sayısı
salt: Evrensel küme alt sınırı
ss: Bulanık küme sayısı
la: Evrensel küme alt aralık uzunluğu
ntest: Test kümesi genişliği

```
function output=fuzzytg5tli(x,m,salt,ss,la,ntest)
rand('seed',4.9276984E7);
n=size(x,1)-ntest;
for i=1:ss
    ualt(i)=salt+(i-1)*la;
    uust(i)=salt+i*la;
    mb(i)=(ualt(i)+uust(i))/2;
end
for i=1:n+ntest
    for j=1:ss
        if ((x(i)<=uust(j))&(x(i)>=ualt(j)))
            fs(i)=j;
        end
    end
end
zdl=(fs-min(fs))/(max(fs)-min(fs));
Gegt=[zdl(1:(n-5));zdl(2:(n-4));zdl(3:(n-3));zdl(4:(n-2));zdl(5:(n-1))];
yegt=zdl(6:n)';
net=newff(minmax(Gegt'),[m,1],{'tansig','tansig'},'trainlm');
net.trainParam.show=500;
net.trainParam.epochs=500;
net.trainParam.goal=1e-8;
[net,tr]=train(net,Gegt',yegt');
ycegt=sim(net,Gegt');
yc=round(ycegt*(max(fs)-min(fs))+min(fs));
```

```

for i=1:(n-5)
    if yc(i)<=0
        yc(i)=1;
    end
end
for i=1:(n-5)
    ong(i)=mb(yc(i));
end
for i=1:(n-5)
    hatakare(i)=(x(i+2)-ong(i))^2;
end
for j=1:ntest
    Gegt=[zd1(n+j-5);zd1(n+j-4);zd1(n+j-3);zd1(n+j-2);zd1(n+j-1)];
    ycegt2(j)=sim(net,Gegt');
end
yc2=round(ycegt2*(max(fs)-min(fs))+min(fs));
for i=1:(ntest)
    if yc2(i)<=0
        yc2(i)=1;
    end
end
for i=1:ntest
    ong2(i)=mb(yc2(i));
end
for i=1:ntest
    hatakare2(i)=(x(i+n)-ong2(i))^2;
end
MSE=(sum(hatakare)/(n-5))
RMSE=(sum(hatakare)/(n-5))^0.5
MSEtest=(sum(hatakare2)/(ntest))
RMSEtest=(sum(hatakare2)/(ntest))^0.5
output=[RMSEtest];

```

8. ÖZGEÇMİŞ

1977 yılında Gaziantep'te doğdum. İlk ve orta öğrenimimi İstanbul'da tamamladım. 1999 yılında kaydolduğum Ondokuz Mayıs Üniversitesi Fen Edebiyat Fakültesi İstatistik Bölümünden 2003 yılında bölüm 3.'sü olarak mezun oldum. 2006 yılında Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalında Yüksek Lisans öğrenimime başladım ve 2007 yılında yine Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalında Araştırma Görevlisi olarak başladığım görevime devam etmekteyim.