

**DAĞILIM VE SİNİR AĞI TABANLI
BULANIK ZAMAN SERİSİ MODELLERİ**

Özer ÖZDEMİR
Doktora Tezi

İstatistik Anabilim Dalı
Eylül – 2013

**Bu tez çalışması Anadolu Üniversitesi Bilimsel Araştırma Projeleri
Komisyonu Başkanlığı tarafından desteklenmiştir. Proje No: 1110F167**

JÜRİ VE ENSTİTÜ ONAYI

Özer Özdemir'in “**Dağılım ve Sinir Ağı Tabanlı Bulanık Zaman Serisi Modelleri**” başlıklı **İstatistik** Anabilim Dalındaki, Doktora Tezi 09.09.2013 tarihinde, aşağıdaki jüri tarafından Anadolu Üniversitesi Lisansüstü Eğitim - Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca değerlendirilerek kabul edilmiştir.

	Adı Soyadı	İmza
Üye (Tez Danışmanı)	: Prof. Dr. MEMMEDAĞA MEMMEDLİ	
Üye	: Prof. Dr. EMBİYA AĞAOĞLU	
Üye	: Prof. Dr. YUSUF OYSAL	
Üye	: Prof. Dr. AYŞEN APAYDIN	
Üye	: Yard. Doç. Dr. RABİA ECE OMAV	

Anadolu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun..... tarih ve sayılı kararıyla onaylanmıştır.

Enstitü Müdürü

ÖZET

Doktora Tezi

DAĞILIM VE SİNİR AĞI TABANLI BULANIK ZAMAN SERİSİ MODELLERİ

Özer ÖZDEMİR

Anadolu Üniversitesi
Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı

Danışman : Prof. Dr. Memmedağa MEMMEDLİ
İkinci Danışman : Doç. Dr. Sevil ŞENTÜRK
2013, 113 sayfa

Bulanık zaman serisi yaklaşımları genelde bulanıklaştırma, bulanık ilişkiler belirleme ve durulaştırma olmak üzere üç aşamadan oluşur. Bu çalışmada, tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörüsü için yeni bir yaklaşım ve yeni bir yöntem önerilmiştir. İlk olarak evrensel küme parçalanmasında yapılan aralık uzunluğu belirleme aşamasında sabit bir aralık uzunluğu almak yerine daha etkili olan dağılım tabanlı uzunluk yaklaşımı kullanılmıştır. Bulanıklaştırma aşamasında yeni bir algoritma oluşturularak işlem kolaylığı sağlanmıştır. Ayrıca bu aşamada önerilen yöntemde ilk defa ağırlıklandırılmış indisler kullanılmıştır. Bulanık ilişki belirlemede bütün üyelik derecelerinin ayarlanması sağlanmıştır. Öngörü performansını geliştirmek için sadece Çok Katmanlı Algılayıcı (ÇKA) değil, ayrıca Genelleştirilmiş Regresyon Sinir Ağları (GRSA), ve Radyal Tabanlı Fonksiyon Sinir Ağı (RTFSA) gibi farklı yapay sinir ağı mimarileri de uygulanmıştır. Bu YSA mimarileri için klasik sinir ağı tabanlı bulanık zaman serisi öngörü yöntemlerinden farklı olarak tek katman ve düğüm sayısı, girdi ve çıktılarının toplamaları olması yerine en iyi sonucu verecek şekilde farklı sayıda gizli katman ve düğüm sayısı kullanılmıştır.

Önerilen yöntem ve yaklaşım, oldukça iyi bilinen ve literatürde sıklıkla kullanılan Alabama Üniversitesi kayıt verileri ve ayrıca büyük bir veri seti olarak İ.M.K.B. (BİST) ulusal 100 endeksi verileri 2006-2010 yılları için kullanılarak literatürde önerilmiş sinir ağı tabanlı veya sinir ağı tabanlı olmayan çeşitli bulanık zaman serisi öngörü yöntemleri ile karşılaştırılmıştır. Sonuçlar; önerilen yeni yöntemin, literatürde verilen diğer yöntemlerden üstün olduğunu göstermiştir.

Anahtar Kelimeler: Dağılım tabanlı uzunluk, Bulanık kümeler, Bulanık zaman serileri, Yapay sinir ağları, Sinir ağı tabanlı bulanık zaman serileri, Üyelik dereceleri

ABSTRACT

PhD Dissertation

DISTRIBUTION AND NEURAL NETWORK BASED FUZZY TIME SERIES MODELS

Özer ÖZDEMİR

**Anadolu University
Graduate School of Sciences
Department of Statistics**

**Supervisor : Prof. Dr. Memmedağa MEMMEDLİ
Co-Supervisor : Assoc. Prof. Dr. Sevil ŞENTÜRK
2013, 113 pages**

Fuzzy time series approaches generally have three steps as fuzzification, identification of fuzzy relation and defuzzification. In this study, a new approach and a new method have proposed for forecasting univariate first order neural network-based fuzzy time series (NNBFTS). Firstly, distribution based length approach has used instead of getting a constant length of interval in the step of defining length of interval in partition of universe of discourse. Convenience of operation has provided by creating a new algorithm in the step of fuzzification. Also, weighted indices have firstly used in this step of proposed method. Adjustment of all degrees of membership has provided in the step of identification of fuzzy relation. Not only Multilayer Perceptron (MLP) but also various ANNs such as Generalized Regression Neural Networks (GRNN) and Radial Basis Function Neural Networks (RBFNN) have applied for improving forecasting performance. Various hidden layer and nodes are used for getting the best result instead of being number of nodes which is the sum of inputs and outputs and one hidden layer in NNBFTS forecasting methods for these architectures of ANNs.

Proposed method and approach is compared with various NNBFTS or without NNBFTS forecasting methods proposed in the literature by using a data set of enrollment for the University of Alabama which is a well-known and mostly used in the literature and also a big data set of Istanbul Stock Exchange (ISE) national-100 index during 2006-2010 years. The results show that the new proposed method outperforms other methods proposed in the literature.

Keywords: Distribution based length, Fuzzy sets, Fuzzy time series, Artificial neural networks, Neural network based fuzzy time series, Degrees of membership

TEŞEKKÜR

Doktora çalışmam boyunca sürekli yanımda olan, bana her zaman her türlü konuda engin bilgi ve deneyimi ile desteklerini esirgemeyen, her konuda çok şey öğrendiğim ve birçok şeyi borçlu olduğum kıymetli, çok değerli hocam ve tez danışmanım **Prof. Dr. Memmedağa MEMMEDLİ**'ye en içten teşekkürlerimi sunarım.

Çalışmam boyunca bana destek olup özellikle “Bulanık Mantık” konusunda ve diğer konularda da bilgi ve deneyimlerini benimle paylaşan, tez çalışmamın oluşmasında katkısı bulunan değerli hocam ve ikinci tez danışmanım **Doç. Dr. Sevil ŞENTÜRK**'e teşekkür ederim.

Doktora tez çalışmam boyunca tez çalışmamın şekil almasında, ilerlemesinde ve oluşmasında katkıları olan yönlendiricilikleri ve özverileri ile desteklerini esirgemeyen saygıdeğer hocalarım **Prof. Dr. Embiya AĞAOĞLU** ve **Prof. Dr. Yusuf OYSAL**'a teşekkür ederim.

Doktora çalışmam boyunca benden maddi desteğini esirgemeyen, her zaman bilim insanının yanında olan **Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK)** verdiği her türlü destekten dolayı teşekkürlerimi sunarım.

Hayatımın her aşamasında bana yardımcı olan, sürekli yanımda ve desteklerini daima gösteren, sevgili **annem, babam** ve **ağabeyime** en içten teşekkürlerimi sunarım.

Doktora eğitimim süresince daima yanımda olan destek ve gülücüklerini eksik etmeyen hayat arkadaşım değerli eşim **Merve ÖZDEMİR**'e ve dünyalar tatlısı sevgili oğlum **Mert ÖZDEMİR**'e teşekkür ederim.

Özer ÖZDEMİR

Eylül 2013

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR.....	iv
İÇİNDEKİLER.....	v
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	x
1. GİRİŞ.....	1
2. BULANIK MANTIK.....	7
2.1. Bulanık Kümeler	10
2.1.1. Üyelik fonksiyonu tipleri	12
2.1.2. Bulanık kümelerle ilgili bazı kavramlar	14
2.1.3. Bulanık parçalama	16
2.2. Bulanık İlişki.....	17
2.3. Genişleme İlkesi.....	18
2.4. Bulanık Sayılar.....	20
2.4.1. Üçgen bulanık sayılar	21
2.4.2. Yamuk bulanık sayılar	22
2.4.3. LR gösterimli bulanık sayılar.....	23
2.4.4. Çan şeklinde bulanık sayılar	24
2.5. Durulaştırma Yöntemleri.....	25
2.5.1. En büyük üyelik ilkesi	25
2.5.2. Sentroid yöntemi	26

2.5.3. Ağırlıklandırılmış ortalamalar yöntemi	27
2.5.4. Ortalama en büyük üyelik yöntemi	28
2.5.5. En büyük alanın merkezi yöntemi	29
 3. YAPAY SİNİR AĞLARI	 31
3.1. YSA'nın Tanımı	32
3.2. Biyolojik Sinir Ağlarının Fizyolojik Yapısı	32
3.3. YSA'nın Temel Yapısı	35
3.4. YSA'nın Temel Elemanları	37
3.4.1. Girdiler	37
3.4.2. Ağırlıklar	37
3.4.3. Transfer (Aktivasyon) fonksiyonu	38
3.4.4. Hücrenin çıktısı	43
3.5. Bazı YSA Algoritmaları	43
3.5.1. Standart geriye yayılım algoritması	43
3.5.2. Esnek geriye yayılım algoritması	44
3.5.3. Radyal tabanlı fonksiyon algoritması	45
3.6. Bazı YSA Mimarileri	47
3.6.1. Radyal tabanlı fonksiyon sinir ağları (RTFSA)	47
3.6.2. Çok katmanlı algılayıcı (ÇKA)	48
3.6.3. Genelleştirilmiş regresyon sinir ağları (GRSA)	49
3.7. Öngörü Değerlendirme Yöntemleri	51
 4. BULANIK ZAMAN SERİLERİ	 52
4.1. Song ve Chissom Yöntemi	55
4.2. Chen Yöntemi	57

4.3. Chen'in Yüksek Dereceli Bulanık Zaman Serisi Yöntemi.....	59
4.4. Yu ve Huarng'ın Sinir Ağı Tabanlı Bulanık Zaman Serisi Yöntemi.....	63
5. GELİŞTİRİLEN ve ÖNERİLEN YÖNTEMLER	66
5.1. Sinir Ağı Tabanlı Bulanık Zaman Serilerinin Öngörüsünde Yu ve Huarng Yöntemi Üzerine Yeni bir Yaklaşım.....	66
5.2. Sinir Ağı Tabanlı Bulanık Zaman Serilerinin Öngörüsünün Geliştirilmesi için Yeni bir Yöntem.....	71
6. VERİ SETLERİ ÜZERİNDE UYGULAMALAR	77
6.1. Uluslararası Boyutta Sık Kullanılan Alabama Üniversitesi Kayıt Verisi Üzerinde Uygulama	77
6.2. Ulusal Boyutta Sık Kullanılan Geniş bir Veri Seti Olarak BİST(İMKB) Verisi Üzerinde Uygulama	88
7. SONUÇ ve ÖNERİLER	93
KAYNAKLAR	96
Ek-1 Bütün $V(t-1, t)$ 'leri bulan algoritma	105
Ek-2 Önerilen yöntemde 2. veri seti için $obs(t)$ ve $obs(t-1)$ farkları.....	107
Ek-3 Önerilen yöntemde 2. veri seti için mutlak farklar (2006 yılı için).....	109
Ek-4 Önerilen yöntemde 2. veri seti farkları için üyelik dereceleri (2006 yılı için).....	110
Ek-5 Önerilen yöntemde 2. veri seti için ağırlıklandırılmış indis değerleri (2006 yılı için).....	112

ŞEKİLLER DİZİNİ

2.1. Bulanık kümenin örnek grafik gösterimleri.....	11
2.2. Üçgen (a), Yamuk (b), Gaussian (c) ve Çan şeklinde (d) olmak üzere üyelik fonksiyonlarının gösterimi.....	13
2.3. Sigmoidal üyelik fonksiyonunun gösterimi.....	14
2.4. Konveks ve normal bulanık küme	20
2.5. Bulanık sayı	21
2.6. Üçgen Bulanık Sayı.....	22
2.7. Yamuk Bulanık Sayı	23
2.8. <i>LR</i> Bulanık Sayısı.....	24
2.9. En büyük üyelik derecesi ile durulaştırma	26
2.10. Sentroid yöntemi ile durulaştırma.....	27
2.11. Ağırlıklandırılmış ortalamalar yöntemi ile durulaştırma.....	28
2.12. Ortalama en büyük üyelik yöntemi ile durulaştırma.....	29
2.13. En büyük alan merkezi yöntemi ile durulaştırma	30
3.1. Biyolojik Sinir Hücresinin Temel Yapısı.....	33
3.2. Tipik Bir YSA Yapısı.....	36
3.3. Özdeşlik Fonksiyonu.....	39
3.4. Tek Kutuplu Eşik Fonksiyonu	40
3.5. Çift Kutuplu Eşik Fonksiyonu	40
3.6. Parçalı Doğrusal Fonksiyon.....	41
3.7. Sigmoid Fonksiyonu	42
3.8. Hiperbolik Tanjant Fonksiyonu	43
3.9. Radyal tabanlı fonksiyon sinir ağı	48
3.10. ÇKA Yapısı	49
3.11. GRSA Yapısı	51

6.1. Önerilen yöntemde 1. veri seti için birinci farkların kümülatif dağılımı	80
6.2. Önerilen yöntemde 2. veri seti için birinci farkların kümülatif dağılımı	89
6.3. Önerilen yöntemde 2. veri seti için 2006 yılına göre gerçek değerler ve öngörü değerleri	90

ÇİZELGELER DİZİNİ

3.1. Biyolojik Sınır Sistemi ile YSA Arasındaki Benzerlikler	35
5.1. Taban haritalama çizelgesi	68
6.1. Kayıt Verisi.....	78
6.2. Önerilen yöntemde 1. veri seti için $obs(t)$ ve $obs(t-1)$ farkları	79
6.3. Önerilen yöntemde 1. veri seti için mutlak farklar	80
6.4. Önerilen yöntemde 1. veri seti farkları için üyelik dereceleri	82
6.5. Önerilen yöntemde 1. veri seti için ağırlıklandırılmış indis değerleri	83
6.6. Önerilen yöntemde 1. veri seti için ikinci dereceden bulanık zaman serisi notasyon çizelgesi.....	84
6.7. Önerilen yöntem için sonuçlar	84
6.8. Önerilen yöntemde 1. veri seti için sonuçların karşılaştırılması.....	85
6.9. Önerilen yaklaşımda 1. veri seti için öngörölmüş üyelik dereceleri.....	87
6.10. Önerilen yaklaşımda ve yöntemde 1. veri seti için sonuçların karşılaştırılması.....	88
6.11. Önerilen yöntemde 2. veri seti için sonuçlar	90
6.12. 2. veri seti için YSA modellerinde HKOK değerleri	91
6.13. 2. veri seti için farklı YSA modelleri ile önerilen yaklaşımın HKOK değerleri	91
6.14. 2. veri seti için bütün yöntemlerin en iyi HKOK değerleri	92

1. GİRİŞ

Gözlemleri belirsizlikler içeren ve bulanık kümeler ile temsil edilen zaman serilerinin öngörülmesi önemli bir problemidir. Örnek olarak, günlük hava sıcaklığı alınabilir. Gün boyunca hava sıcaklığı sabit kalmadığı için her günü temsil eden kesin bir hava sıcaklığı bulunamaz. Dolayısıyla, günlük hava sıcaklığı bir bulanık küme ile temsil edilir ve belirsizlik modellenir. Bulanık küme teorisi Zadeh tarafından önerilmiştir ve birçok çalışmanın öncüsü olmuştur (Zadeh 1965).

Song ve Chissom (Song ve Chissom 1993a) tarafından ortaya atılan bulanık zaman serileri, Zadeh (1965) tarafından önerilen bulanık küme teorisine ve sonrasında yine Zadeh (Zadeh 1973; Zadeh 1975) tarafından verilen tanımlamalara dayanmaktadır. Song ve Chissom çalışmalarında, bulanık küme teorisinden yararlanarak bulanık zaman serisi tanımını yapmış ve bulanık zaman serilerinin öngörülmesi için matris işlemlerine dayalı yöntem önermiştir (Song ve Chissom 1993a; Song ve Chissom 1993b; Song ve Chissom 1994). Bu yöntem ile birlikte genel olarak bulanık zaman serisi öngörü yöntemleri üç temel aşamadan oluşmaktadır. Birinci aşama gözlemlerin bulanıklaştırılması, ikinci aşama bulanık ilişkilerin belirlenmesi ve üçüncü aşama ise durulaştırma aşamasıdır. Literatürde bulanık zaman serilerinde bu üç aşamanın da iyileştirilmesi için çeşitli çalışmalar yapılmıştır.

Öncelikle, bulanıklaştırma aşamasında evrensel küme parçalanması esnasında ihtiyaç duyulan aralık uzunluğunu belirlemeye yönelik çeşitli yöntemler geliştirilmiştir. Literatürde birçok aralık uzunluğu belirlenmesi üzerine çalışma bulunmaktadır ve bu çalışmaların aralık uzunluğuna bağlı olarak öngörü performansını arttırdıkları görülmüştür. Bu çalışmaların birçoğunda aralık uzunluğu sabit alınmaktadır, rastgele olarak Song ve Chissom (1993a, 1993b, 1994) ve Chen (1996, 2002) almıştır. Huarng (2001b) çalışmasında ortalamaya ve dağılıma dayalı iki yaklaşım önermiştir. Chen ve Chung (2006) ve Lee ve ark. (2007, 2008) çalışmalarında genetik algoritmaları kullanan yöntemler önermişlerdir. Parçacık sürü optimizasyonunu kullanan yöntemlerle Davari ve ark. (2009), Kuo ve ark. (2009, 2010), Hsu ve ark. (2010) ve Park ve ark. (2010)

çeşitli çalışmalar yapmışlardır. Huarng ve Yu (2006a) orana dayalı yaklaşımı ile ve Yolcu ve ark. (2009) oranın optimizasyonuna dayalı yaklaşımı ile değişken aralık uzunluğuna sahip çalışmalarda bulunmuşlardır. Cheng ve ark. (2008) ve Li ve ark. (2008), evrensel küme parçalanmasına gerek kalmadan bulanık C-ortalamlar yöntemini kullanan yöntemler önermişlerdir.

Bulanık ilişki belirleme aşamasında yapılan düzenlemelerle ve kullanılan yöntemlerle öngörü performansları oldukça gelişmektedir. Bu aşamada Song ve Chissom (1993a, 1993b, 1994), bulanık ilişkileri karmaşık matris operasyonları ile belirlemiştir. Chen (1996), bu aşamada nispeten daha kolay olan bulanık grup ilişki tablolarını kullanırken Huarng ve Yu (2006b), Aladağ ve ark. (2009), Eğrioğlu ve ark. (2009a, 2009b, 2009c) ve Yu ve Huarng (2008, 2010) bulanık ilişkilerin belirlenmesinde son yıllarda daha sıklıkla kullanılmaya başlayan yapay sinir ağlarını (YSA) kullanmışlardır.

Son olarak durulaştırma aşamasına gelindiğinde, literatürde 30'dan fazla durulaştırma yöntemi bulunmakla beraber, bu aşamada çoğunlukla ağırlıklandırılmış ortalamlar yöntemi tercih edilmektedir. Bunun dışında farklı olarak Jilani ve Burney (2007, 2008) ve Jilani ve ark. (2007) çeşitli yöntemler önermişlerdir.

Literatürde sıklıkla, birinci dereceden bulanık zaman serisi öngörü modelleri kullanılmaktadır. Bazen, karşılaşılan problemin sahip olduğu karmaşık ilişkilere göre, yüksek dereceli bulanık zaman serisi öngörü modelleri kullanılır. Nadir olarak mevsimsel ilişkiler nedeniyle mevsimsel bulanık zaman serisi öngörü modelleri de kullanılır. Yüksek dereceli ve mevsimsel modellerin karışımı olarak hibrit modeller de kullanılmaktadır.

Bulanık zaman serisi öngörüsü için birinci dereceden bulanık zaman serisi öngörü modelleri kullanan çalışmalar; Song ve Chissom (1993a, 1993b, 1994), Sullivan ve Woodall (1994), Chen (1996), Chen ve Hwang (2000), Huarng (2001b), Huarng ve Yu (2006a, 2006b), Cheng ve ark. (2008) ve Li ve ark. (2008), Davari ve ark. (2009), Yolcu ve ark. (2009) ve Yu ve Huarng (2008, 2010) şeklinde ifade edilebilir.

Bulanık zaman serisi öngörüsü için yüksek dereceden bulanık zaman serisi öngörü modelleri kullanan çalışmalar; Chen (2002), Huarng ve Yu (2003a), Chen

ve Chung (2006), Jilani ve ark. (2007), Jilani ve Burney (2007, 2008), Lee ve ark. (2007, 2008), Aladağ ve ark. (2009), Eğrioğlu ve ark. (2009a, 2009c, 2010) Kuo ve ark. (2009, 2010), Hsu ve ark. (2010) ve Park ve ark. (2010) olarak ifade edilebilir.

Bulanık zaman serisi öngörüsü için hibrit modeller kullanan çalışmalar, Huarng ve Yu (2003b) ve Tseng ve Tzeng (2002) ve mevsimsel modeller kullanan çalışmalar, Chang (1997), Song (1999) ve Eğrioğlu ve ark. (2009b) olarak sıralanabilir.

Bu sınıflamalar dışında kullanılan değişken sayısına göre tek değişkenli bulanık zaman serisi öngörü modelleri ve çok değişkenli bulanık zaman serisi öngörü modelleri olarak sınıflama yapılabilir. Tek değişkenli bulanık zaman serisi öngörü modelleri kullanan çalışmalar; Song ve Chissom (1993a, 1993b, 1994), Chen (1996, 2002), Chang (1997), Song (1999), Huarng (2001b), Chen ve Chung (2006), Huarng ve Yu (2006a, 2006b), Davari ve ark. (2009), Yolcu ve ark. (2009), Kuo ve ark. (2009, 2010), Aladağ ve ark. (2009) ve Yu ve Huarng (2010) çalışmalarıdır.

Çok değişkenli bulanık zaman serisi öngörü modelleri kullanan çalışmalar; Huarng (2001a), Hsu ve ark. (2003), Lee ve ark. (2006, 2007, 2008), Jilani ve ark. (2007), Jilani ve Burney (2007, 2008), Cheng ve ark. (2008), Li ve ark. (2008), Yu ve Huarng (2008), Eğrioğlu ve ark. (2009a, 2009b, 2009c), Hsu ve ark. (2010) ve Park ve ark. (2010) olarak söylenebilir. Bu bulanık zaman serisi modelleri, kayıt verileri (Huarng 2001b; Huarng ve Yu 2006) sıcaklık verileri (Lee ve ark. 2006; Lee ve Ark. 2007) ve borsa verileri (Huarng ve Yu 2004; Huarng ve Yu 2005) gibi birçok farklı veri yapısına uygulanmıştır.

Bulanık ilişki belirleme aşamasında sıklıkla bulanık mantık grup ilişki tabloları kullanılmakla beraber son çalışmalarda YSA da kullanılmaktadır. Ancak bu çalışmalarda bulanık ilişkiler belirlenirken, gözlemlerin ait olduğu kümeleri ifade eden küme numaraları ile işlemler yapılmaktadır. Fakat bir bulanık zaman serisi gözlemi, ait olduğu düşünülen bulanık küme dışında diğer kümelere de belirli üyelik değerleri ile aittir. Dolayısıyla bulanık ilişkiler belirlenirken, her bir gözlemin tüm bulanık kümelere ait olmasının üyelik değerlerinin dikkate alınması, bilgi kaybını önleyeceği gibi bulanık zaman serisinde mevcut bulanık

ilişkileri daha gerçekçi olarak ortaya koyacak ve böylece öngörü doğruluğunu arttıracaktır. Bu amaçla, Yu ve Huarng (2010), girdileri ve çıktıları gözlemlerin üyelik değerlerinden oluşan yapay sinir ağlarını bulanık ilişkilerin belirlenmesinde kullanmıştır.

Bu tez kapsamında, bulanık zaman serisi öngörüsünü geliştirmek amaçlanmıştır. Bu doğrultuda son zamanlarda sıklıkla kullanılmaya başlanan YSA, bulanık zaman serisi öngörüsü için kullanılarak sinir ağı tabanlı bulanık zaman serisi öngörüsü üzerine çalışılmıştır.

Çalışmanın giriş bölümünden sonraki bölümleri şu şekilde düzenlenmiştir.

İkinci bölümde bulanık mantık kavramı tanımlanarak genel özellikleri ifade edilmiştir. Bulanık kümeler, bulanık ilişki ve genişleme ilkesi gibi kavramlar tanımlanmıştır. Son olarak ağırlıklandırılmış ortalamalar yöntemi ile birlikte beş durulaştırma yöntemine yer verilmiştir.

Üçüncü bölümde diğer önemli konu olarak YSA ele alınmıştır. YSA'nın genel tanımı ve yapısı incelenmiştir. Yaygın olarak kullanılan ÇKA, GRSA ve RTFSA mimarileri ayrıntılarıyla açıklanmıştır.

Dördüncü bölümde, bulanık zaman serilerinin genel tanımlamaları yapılmıştır. Durulaştırma, bulanık ilişki belirleme ve durulaştırma aşamalarının yer aldığı bazı bulanık zaman serisi öngörü yöntemleri anlatılmıştır. Bu yöntemler, Song ve Chissom (1993a, 1993b, 1994) ve Chen (1996) yöntemleridir. Ayrıca, yüksek dereceli bulanık zaman serisi öngörü yöntemi olarak Chen'in yöntemi (2002) ele alınmıştır. Sinir ağı tabanlı bulanık zaman serisi öngörü yöntemlerinden Yu ve Huarng'ın yöntemi(2010) açıklanmıştır.

Beşinci bölümde, Yu ve Huarng'ın (2010) yöntemi temel alınarak tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için yeni bir yaklaşım önerilmiştir.

Bu yaklaşımda, bulanıklaştırma aşamasında, Yu ve Huarng'ın çalışmasından farklı bir şekilde, Huarng'ın (2001b) dağılım tabanlı uzunluk yaklaşımına göre aralık uzunlukları belirlenmiştir. Yu ve Huarng'ın çalışmasında aralık uzunlukları rastgele alınmakta ve öngörü performansını oldukça etkilemektedir.

Önerilen yaklaşımda, bulanıklaştırma aşamasında, yeni bir algoritma hazırlanmış ve her bir gözlemin belirlenen bulanık kümelerle ait olmasının üyelik değerleri, bu algoritma çerçevesinde oluşturulmuştur. Yu ve Huarng da ise, her bir gözlemin belirlenen bulanık kümelerle ait olmasının üyelik değerleri, aralık uzunluğu gibi keyfi olarak belirlenmektedir.

Bulanık ilişki belirleme aşamasında, ÇKA dışında GRSA ve RTFSA gibi diğer sık kullanılan YSA mimarileri de kullanılmıştır. Bu aşamada Yu ve Huarng'ın çalışmasında bir gizli katman kullanılmaktadır. Bu gizli katmandaki düğümlerin sayısı, girdi ve çıktı katmanındaki düğümlerin sayısı toplamı kadardır. Oysaki önerilen yeni yaklaşımda, gizli katman sayısı ve gizli düğümlerin sayısı, YSA'nın performansına göre en iyi sonucu elde edecek şekilde belirlenmektedir.

Beşinci bölümde, önerilen yaklaşım dışında tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için, yeni bir yöntem önerilmiştir. Bu yöntem, hem YSA kullanan bulanık zaman serisi öngörü yöntemlerine hem de bulanık zaman serisi öngörü yöntemlerine alternatif, yeni bir yöntemdir.

Bu yöntemde, bulanıklaştırma aşamasında, evrensel küme parçalamasında yapılan aralık uzunluğu belirleme işleminde, sabit bir aralık uzunluğu almak yerine daha etkili olan dağılım tabanlı uzunluk yaklaşımı kullanılmıştır. Bu aşamada, yeni yaklaşım için oluşturulan algoritma eklenmiştir. Bulanıklaştırma aşamasında ilk olarak Chen'in (Chen 2002) yönteminde ve sonraki yöntemlerde benzer şekilde, bulanık kümelerin indislerin kullanımı söz konusudur. Bu aşamada, her bir veriyi temsilen oluşturulan üyelik dereceleri kümesi yerine, Chen'in (Chen 2002) yönteminde maksimum üyelik derecesinin bulunduğu bulanık kümenin indisi kullanılmaktadır. Tez çalışmasında önerilen yöntem sayesinde, maksimum üyelik derecesi yerine, veriyi daha iyi temsil eden ve bütün üyelik derecelerinin kullanımını sağlayan, ağırlıklandırılmış ortalamalar yöntemi ele alınmıştır. Ağırlıklandırılmış ortalamalar yöntemi ile bulanık kümeler yerine, indisleri temsilen ağırlıklandırılmış indis değerleri belirlenmiş ve kullanılmıştır.

Sonuçta, bütün üyelik derecesi değerlerinin kullanımı ile ağırlıklandırılmış indislerin bulunması sonucunda, her bir gözlemin, tüm bulanık kümelerle ait

olmasının ağırlıklı olarak dikkate alınması sağlanmıştır. Dolayısıyla, bilgi kaybı önlenerek verinin daha etkili ve iyi bir şekilde temsil edilmesi sağlanmıştır.

Bu yöntemle, bulanık zaman serisinde var olan bulanık ilişkiler, daha gerçekçi olarak ortaya çıkmış ve öngörü performansı artarak daha doğru öngörüler gerçekleştirilmiştir.

Bulanık ilişkiler belirleme aşamasında, karmaşık ve uzun süren işlemler yerine, oldukça kullanışlı olan yapay sinir ağları (YSA) kullanılmıştır. Bulanık ilişki belirlemede, bütün üyelik derecelerinin ayarlanması sağlanmıştır.

Durulaştırma işleminden önce, elde edilen çıktı indislerinin üyelik derecelerine ayrılması gerçekleştirilmiştir. Bu aşama ile ilgili olarak da bir algoritma oluşturulmuştur. Durulaştırma işlemi, ağırlıklandırılmış ortalamalar yöntemi ile yapılmış, öngörü işleminin ardından performans değerlendirmesi yapılmıştır.

Altıncı bölümde, beşinci bölümde önerilen yaklaşım ve yöntem, öncelikle, uluslararası boyutta sık kullanılan Alabama Üniversitesi kayıt verisi üzerinde uygulanmıştır. Önerilen yaklaşım ve yöntem, literatürde bu veriyi kullanan çalışmalarla karşılaştırılmıştır. Ardından, önerilen yaklaşım ve yöntem, ulusal boyutta sık kullanılan geniş bir veri seti olarak İ.M.K.B. (BİST) verisi üzerinde uygulanmış ve sonuçlar karşılaştırılmıştır.

Son bölümde, altıncı bölümde elde edilen sonuçlar yorumlanmış ve çalışmanın geneli değerlendirilerek ileride yapılabilecek alternatif çalışmalar önerilmiştir.

2. BULANIK MANTIK

İnsan beyni dünyanın en karmaşık makinesi olarak kabul edilebilir. İnsan beyni sayısal bir işlemi birkaç dakikada yapabilmesine karşılık; anlamaya yönelik olayları çok kısa bir sürede yapar. Örneğin yolda giden bir şoför, yolun kayganlık derecesini, önündeki tehlikeden ne kadar uzak olduğunu, sayısal olarak değerlendiremezse dahi geçmişte kazanmış olduğu tecrübeler sayesinde aracın hızını azaltır. Çünkü o saniyelerle ölçülebilecek kadar kısa bir sürede tehlikeyi anlamış ve ona karşı koyma gibi bir tepki vermiştir. Bu noktada akla gelen ilk soru şu olmaktadır: Acaba bir bilgisayar yardımıyla böyle bir zeka üretmek mümkün olabilir mi? Bilgisayarlar çok karmaşık sayısal işlemleri anında çözümleyebilmelerine karşılık, anlama ve deneyimlerle kazanılmış bilgileri kullanabilme noktasında çok yetersizdirler. Bu olayda insanı ya da insan beynini üstün kılan temel özellik, sinirsel algılayıcılar vasıtasıyla kazanılmış ve göreceli olarak sınıflandırılmış bilgileri kullanabilmesidir. Bulanık Mantık ve Yapay Sinir Ağları gibi yapay zeka alt dalları özellikle son yıllarda geniş bir araştırma ve uygulama alanı bulmaktadır (Elmas 2003).

Bulanık mantık iki anlamda kullanılmaktadır. Dar anlamda bulanık mantık, klasik iki değerli mantığın genelleştirilmiş halidir. Geniş anlamda ise bulanık kümeleri kullanan bütün teorileri ve teknolojileri ifade eder.

Sembolik mantık kuralları ile sadece somut değil, soyut düşüncelere dayalı önermeler de yapılarak genel çıkarımların elde edilmesi mümkündür. Ancak bunu yaparken kavram ve terimlerdeki belirsizlik ve bulanıklıkların işin başında durulaştırılarak kesinlik kazandırılması gerekir. Bundan dolayı, sembolik mantık idealleştirilmiş kavram ve terimlerle önermelerden çıkarılacak ideal sonuçları içerir. Oysa gerçek dünyada bulanıklık ve belirsizlik kaçınılmazdır.

Bulanık mantığın en geçerli olduğu iki durumdan ilki, incelenen olayın çok karmaşık olması ve bununla ilgili yeterli bilginin bulunmaması durumunda kişilerin görüş ve değer yargılarına yer verilmesi, ikincisi ise insan kavrayış ve yargısına gerek duyan hallerdir. İnsan düşüncesinde sayısal olmasa bile belirsizlik, yararlı bir bilginin kaynağıdır. İşte bu tür bilgi kaynaklarının, olayların

incelenmesinde özgün bir biçimde kullanılmasına bulanık mantık ilkeleri yardımcı olacaktır.

Bir olayın bulanık mantıkla incelenmesi için öncelikle, yapılacak çıkarımların belirli tolerans sınırları içinde kalmasına önceden karar vermek gerekir. Bir sorunun çözülmesine başlamadan önce toplanabilen sayısal ve sözel veriler göz önünde bulundurularak çözüm için en uygun yöntem hakkında karar verilmelidir (Baykal ve Beyan 2004).

Bulanık kümelere dayalı olan bulanık mantık, genelde insan düşüncesine özdeş işlemlerin gerçekleşmesini sağlamakta, gerçek dünyada sık sık meydana gelen belirsiz ve kesin olmayan verileri modellemede yardımcı olmaktadır. Geleneksel mantıkta bir önerme “doğru” veya “yanlıştır”. Ancak gerçek dünyadaki olayların ne derece iyi veya yanlış olmasının belirlenmesi gerekmektedir. Örneğin 100 derecede suyun sıcaklığı “sıcak” olarak ifade edilirse 95, 80 derecelerdeki su için “sıcak değildir” ifadesi bu anlamda doğru olmadığı gibi yanlış da değildir. Bu nedenle önermelerin doğru ve yanlış değerleri arasındaki değerler kullanılarak bulanık küme teorisi ortaya atılmıştır (Nabiyev 2005).

Bulanık mantık, bulanık küme teorisine dayanan bir matematiksel disiplindir. Bulanık mantık insan mantığında olduğu gibi, Uzun-Kısa, Sıcak-Soğuk, Hızlı-Yavaş, Siyah-Beyaz yerine Çok Uzun-Uzun-Orta-Kısa-Çok Kısa, Sıcak-Ilık-Az Soğuk-Soğuk-Çok Soğuk vb. gibi ara değerlere göre çalışmaktadır.

Bulanık mantık için, matematiğin gerçek dünyaya uygulanması denilebilir. Çünkü gerçek dünyada her an değişen durumlarda değişik sonuçlar çıkabilir.

Bulanık mantık yaklaşımı, makinelere insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsezilerinden yararlanarak çalışabilme yeteneği verir. Bu yeteneği kazandırırken sayısal ifadeler yerine sembolik ifadeler kullanır. İşte bu sembolik ifadelerin makinelere aktarılması matematiksel bir temele dayanır. Bu matematiksel temel Bulanık Mantık Kümeler Kuramı ve buna dayanan Bulanık Mantıktır.

Sözel ifadelerin bilgisayara aktarılması matematiksel bir temele dayanmaktadır. Bu matematiksel temel, bulanık kümeler kuramı ve bulanık

mantık olarak adlandırılır. Bulanık mantık bilinen klasik mantık gibi $(0,1)$ olmak üzere iki seviyeli değil, $[0,1]$ aralığında çok seviyeli işlemleri ifade etmektedir.

Örneğin odadaki klimanın motoru otomatik olarak değil de, bir insan tarafından denetlendiği varsayılın; eğer oda sıcaklığı biraz arttıysa işletmen motorun hızını biraz arttıracaktır, eğer oda sıcaklığı çok düştüyse motor hızını çok azaltacaktır. Burada kullanılan “biraz” ve “çok” terimleri dilsel terimler olup “bulanık değişkenler” olarak isimlendirilirler.

Bulanık mantık ilk defa Amerika Birleşik Devletlerinde düzenlenen bir konferansta 1956 yılında duyurulmuştur. Ancak bu konudaki ilk ciddi adım 1965 yılında Lotfi A. Zadeh (Zadeh 1965) tarafından yayınlanan bir makalede bulanık mantık veya bulanık küme kuramı adı altında ortaya konulmuştur. Zadeh bu çalışmasında insan düşüncesinin büyük çoğunluğunun bulanık olduğunu, kesin (crisp) olmadığını belirtmiştir. Bu yüzden 0 ve 1 ile temsil edilen boolean mantık bu düşünce işlemini yeterli bir şekilde ifade edememektedir.

Bulanık mantığın genel özellikleri Zadeh tarafından şu şekilde ifade edilmiştir;

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

Bulanık mantık tam olarak bilinmeyen veya eksik girilen bilgilere göre işlem yapma yeteneğine sahiptir (Elmas 2003; Zadeh 1965).

Bu bölümde öncelikle bulanık küme kavramı tanımlanacak, bulanık kümelerle ilgili özel kavramlar açıklanacaktır. Özellikle önerilen yöntemlerde kullanılmak üzere bulanık ilişki ve bulanık sayı kavramları ve ilgili özellikleri ifade edilecek ve sonunda yöntemlerin durulaştırma aşamasında kullanılan yöntemle birlikte literatürdeki diğer yöntemler de ifade edilecektir.

2.1. Bulanık Kümeler

Bulanık kümeler klasik kümelere benzer şekilde iki yöntemle gösterilir. Bunlardan birincisi küme elemanlarının üyelik derecelerine göre sıralanması, diğeri de matematiksel olarak üyelik fonksiyonu tanımlamak şeklindedir.

Bulanık kümelerde klasik kümelerdeki karakteristik fonksiyon,

$$\mu_A : X \rightarrow \{0,1\}, \quad (2.1)$$

yerini üyelik fonksiyonuna bırakır. Bu da;

$$\mu_A : X \rightarrow [0,1] \quad (2.2)$$

şeklinde gösterilir. Burada $[0,1]$, 0 ve 1'i içeren ve 0 ve 1 arasındaki reel sayılardır.

Genel olarak küme üyelerini değerleri ile değişiklik gösteren eğriye **üyelik fonksiyonu** denir. Şekil 2.1'deki üyelik fonksiyonu şeklinde de görüldüğü gibi x eksenini üyeleri gösterirken, y eksenini de üyelik derecelerini gösterir. A bulanık kümesi, $\mu_A : X \rightarrow [0,1]$ A'nın üyelik fonksiyonu ve $\mu_A(x) \in [0,1]$ $x \in X$ 'nin A'daki üyelik derecesi olmak üzere;

$$A = \{(\mu_A(x), x)\} \quad (2.3)$$

olarak yazılabilir. Bu durumda X'deki bulanık küme olan A;

$$A = \{(\mu_A(x), x)\} = \{\mu_A(x) / x\} \quad (2.4)$$

$$A = \{\mu_A(x_1) / x_1 + \mu_A(x_2) / x_2 + \dots + \mu_A(x_n) / x_n\}$$

ve dolayısıyla;

$$A = \sum_{i=1}^n \mu_A(x_i) / x_i \quad (2.5)$$


olarak gösterilebilir.

Bulanık kümenin sürekli olması durumunda gösterim;

$$A = \int \mu_A(x) / x_i \quad (2.6)$$

şeklinde olacaktır.

Bölüm işareti bu notasyonda bölme işlemini değil alttaki sayıya yani küme elemanına üstteki üyelik derecesinin karşılık geldiğini göstermektedir. $\sum$ ve $\int$ işaretleri de küme elemanlarının topluluğunu ifade etmektedir (Lee 2005; Lin ve Lee 1996; Baykal ve Beyan 2004).



Şekil 2.1. Bulanık kümenin örnek grafik gösterimleri

2.1.1. Üyelik fonksiyonu tipleri

Çok sayıda üyelik fonksiyonu tipi olmakla beraber pratikte en fazla kullanılanlar üçgen, yamuk, çan eğrisi, Gaussian ve sigmoidal fonksiyonlardır.

Bir **üçgen üyelik fonksiyonu** a_1 , a_2 ve a_3 olarak üç parametre ile tanımlanır.

$$\mu_A(x; a_1, a_2, a_3) = \begin{cases} a_1 \leq x \leq a_2 \text{ ise } (x - a_1)/(a_2 - a_1) \\ a_2 \leq x \leq a_3 \text{ ise } (a_3 - x)/(a_3 - a_2) \\ x > a_3 \text{ veya } x < a_1 \text{ ise } 0 \end{cases} \quad (2.7)$$

Bir **yamuk üyelik fonksiyonu** a_1 , a_2 , a_3 ve a_4 olarak dört parametre ile tanımlanır.

$$\mu_A(x; a_1, a_2, a_3, a_4) = \begin{cases} a_1 \leq x \leq a_2 \text{ ise } (x - a_1)/(a_2 - a_1) \\ a_2 \leq x \leq a_3 \text{ ise } 1 \\ a_3 \leq x \leq a_4 \text{ ise } (a_4 - x)/(a_4 - a_3) \\ x > a_4 \text{ veya } x < a_1 \text{ ise } 0 \end{cases} \quad (2.8)$$


Gaussian üyelik fonksiyonu m ve σ parametreleri ile tanımlanır.

$$\mu_A(x; m, \sigma) = \exp \left\{ \frac{-(x - m)^2}{2\sigma^2} \right\} \quad (2.9)$$

Bu fonksiyonda m fonksiyon merkezini ve σ da genişliğini ifade eder. σ değerini değiştirerek, fonksiyonun biçimini değiştirebiliriz.

Çan şeklinde üyelik fonksiyonu a_1 , a_2 ve a_3 olarak üç parametre ile tanımlanır.

$$\mu_A(x; a_1, a_2, a_3) = \left\{ \frac{1}{1 + \left| \frac{x - a_3}{a_1} \right|^{a_2}} \right\} \quad (2.10)$$




Şekil 2.2. Üçgen (a), Yamuk (b), Gaussian (c) ve Çan şeklinde (d) olmak üzere üyelik fonksiyonlarının gösterimi

Sigmoidal üyelik fonksiyonu a_1 ve a_2 parametreleri ile tanımlanır.

$$\mu_A(x; a_1, a_2) = \left\{ \frac{1}{1 + e^{-a_1(x-a_2)}} \right\} \quad (2.11)$$

a_3 değeri tüm sigmoidal üyelik fonksiyonlarında üye olma ile olmama arasında bir kırım noktası olup $\mu(a_3)$ değeri 0.5'dir (Baykal ve Beyan 2004).



Şekil 2.3. Sigmoidal üyelik fonksiyonunun gösterimi

2.1.2. Bulanık kümelerle ilgili bazı kavramlar

Bulanık kümelerle ilgili bazı önemli kavramlar aşağıda sıralanmıştır.

- A bulanık küme olmak üzere A'nın tüm elemanlarının üyelik dereceleri 0'dan büyük küme A'nın **destek (support) kümesi** olarak ifade edilir.

$$Destek(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (2.12)$$

- Üyelik derecelerinin maksimum değeri bulanık kümenin **yüksekliği** olarak ifade edilir. Eğer bu yükseklik değeri 1 ise bu bulanık küme **normal bulanık küme** olur.
- α **kesim kümesi** A_α , üyelik dereceleri α 'dan az olmayan üyelere sahip olan kümedir. Burada α keyfi bir değerdir.

$$A_\alpha = \{x \in X \mid \mu_A(x) \geq \alpha\} \quad (2.13)$$

- Üyelik fonksiyonunun değerini açıkça gösteren α değeri $[0,1]$ aralığındadır. **Seviye kümesi** α 'lar ile sağlanır. Dolayısıyla seviye kümesi,

$$\Lambda_A = \{\alpha \mid \mu_A(x) = \alpha, \alpha \geq 0, x \in X\} \quad (2.14)$$

olarak ifade edilir.

- X evrensel kümesinin n boyutlu Öklid vektör uzayı $\Re^n$ 'de tanımlandığı varsayalım. Eğer bütün α kesim kümeleri konveks ise, bu α kesim kümeleriyle **bulanık küme konvektir**. Başka bir deyişle;

$$t = \lambda r + (1 - \lambda) s \quad r, s \in \Re^n, \quad \lambda \in [0, 1] \quad (2.15)$$

olduğunda bir

$$\mu_A(t) \geq \min[\mu_A(r), \mu_A(s)] \quad (2.16)$$

ilişkisi varsa, A bulanık kümesi konvektir.

- **Bulanık kümenin büyüklüğünü** göstermek için, bulanık kümenin niceliğini (cardinality) ölçmede üç yol vardır. Birincisi, üyelik dereceleri toplanarak büyüklük elde edilir. Bu “skalar nicelik” dir.

$$|A| = \sum_{x \in X} \mu_A(x) \quad (2.17)$$

İkincisi, X evrensel kümesi ile A bulanık kümesinin birbirine oranlanmasıdır. Bu “bağıl nicelik” dir.

$$\|A\| = \frac{|A|}{|X|} \quad (2.18)$$

Üçüncüsü, A 'nın A_α α kesim kümesi ele alınsın. A_α 'nın eleman sayısı $|A_\alpha|$ 'dır. Başka deyişle, A 'da elemanların $|A_\alpha|$ olma olasılığı

α 'dır. "Bulanık nicelik", $|A|$ 'nın üyelik değeri olarak tanımlanır ve $\alpha \in \Lambda_A$ olmak üzere;

$$\mu_{|A|}(|A_\alpha|) = \alpha \quad (2.19)$$

ile hesaplanır. A_α bir α kesim kümesi ve Λ_A bir seviye kümesidir.

- A bulanık kümesinin tamamlayıcısı (**tümleyeni**) olan $\bar{A}$ kümesi,

$$\forall x \in X, \quad \mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (2.20)$$

üyelik fonksiyonu ile tanımlanır.

- **Aralık**, $A = [a_1, a_3]$ $a_1, a_3 \in \mathfrak{R}$ olmak üzere $a_1 \leq a_3$ gibi herhangi iki sayı arasındaki tüm gerçel sayılardan oluşan $\mathfrak{R}$ 'nin tüm alt kümelerine denir. Üyelik fonksiyonlarıyla sadece bulanık sayıları ve kümeleri değil $a \in \mathfrak{R}$ olan bir a gerçel sayısını ya da bir sayı aralığını da tanımlayabiliriz. $a_1, a_3 \in \mathfrak{R}$ olmak üzere $[a_1, a_3]$ şeklindeki bir aralığın üyelik fonksiyonu,

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ 1, & a_1 \leq x \leq a_3 \\ 0, & x > a_3 \end{cases} \quad (2.21)$$

Eğer $a_1 = a_3$ ise, aralık $[a_1, a_1] = a_1$ şeklinde tek bir noktayı gösterir (Lee 2005).

2.1.3. Bulanık parçalama

Evrensel kümede (X) tanımlanan klasik A kümesinin tümleyeni $\bar{A}$ olsun.

$A \neq \emptyset$ ve $A \neq X$ koşulları X 'i iki alt kümeye ayıran bir çift $(A, \bar{A})$ ile

sonuçlanır. Aynı şekilde $A \neq \emptyset$ ve $A \neq X$ koşullarını sağlayan bulanık kümedeki bir çift $(A, \bar{A})$ bulanık parçalama olarak tanımlanır. Genel olarak X 'de m alt küme tanımlanmışsa, aşağıdaki koşullara uyan m 'li dizge $(A_1, A_2, \dots, A_m)$ bulanık parçalama olarak tanımlanır;

1. $A_i \neq \emptyset$
2. $A_i \cap A_j = \emptyset (i \neq j \text{ için})$
3. $\forall x \in X, \sum_{i=1}^m \mu_{A_i}(x) = 1$

2.2.Bulanık İlişki

A kümesinden B kümesine bir klasik ilişki R ise, her $x \in A$ ve $y \in B$ için, üyelik fonksiyonu $\mu_R(x, y)$;

$$\mu_R(x, y) = \begin{cases} (x, y) \in R \text{ ise } 1 \\ (x, y) \notin R \text{ ise } 0 \end{cases} \quad (2.22)$$

olarak tanımlanır. Bu üyelik fonksiyonu $A \times B$ 'den $\{0,1\}$ kümesine $\mu_R(x, y): A \times B \rightarrow \{0,1\}$ olarak da ifade edilebilir. R ilişkisi bir küme olarak tanımlanabilir.

Bulanık ilişki $[0,1]$ üyelik derecelerine sahip ilişkidir.

$$\begin{aligned} \mu_R(x, y): A \times B &\rightarrow [0,1] \\ R &= \{((x, y), \mu_R(x, y)) \mid \mu_R(x, y) \geq 0, x \in A, y \in B\} \end{aligned} \quad (2.23)$$

Burada $\mu_R(x, y)$ x ve y arasındaki **ilişkinin gücü** olarak yorumlanır. $\mu_R(x, y) \geq \mu_R(x', y')$ olduğunda, (x, y) (x', y') 'den daha güçlüdür.

Bulanık ikili ilişki n’li ilişkiye genişletilebilir. Eğer $X_1, X_2, \dots, X_n$ bulanık kümeleri olarak kabul edilirse,

$$R \subseteq X_1 \times X_2 \times \dots \times X_n \quad (2.24)$$

bulanık ilişkisi

$$x_1 \in X_1, x_2 \in X_2, \dots, x_n \in X_n \quad (2.25)$$

olan $x_1, x_2, \dots, x_n$ elemanlarının bir dizgisel kümesidir (Baykal ve Beyan 2004).

2.3. Genişleme İlkesi

Zadeh (1978) tarafından ortaya konulan genişletme prensibi (extension principle) bulanık küme teorisinde en önemli araçlardan biridir. Bu prensip, kesin matematiksel kavramların bulanık küme çerçevesinde genelleştirilmesini sağlar ve noktasal görüntülemeyi bulanık kümeler için görüntülemeye genişletir.

Bu ilke, U kesin kümesindeki n’li $(x_1, x_2, \dots, x_n)$ ’leri, V kesin kümesindeki bir noktaya görüntüleyen her f fonksiyonunun, U ’daki n bulanık alt kümenin V ’deki bir bulanık alt kümeye görüntülemesine genelleştiren bir araç sağlar. Böylece, bulanık olmayan elemanlar arasındaki her matematiksel ilişki, bulanık elemanlar ile ilgili olarak genişletilebilir.

$f : U \rightarrow V$ verilen bir fonksiyon ve

$$A = \mu_1 / x_1 + \mu_2 / x_2 + \dots \mu_n / x_n, \quad (2.26)$$

U ’da bir bulanık küme olmak üzere, genişletme prensibi,

$$f(A) = f(\mu_1 / x_1 + \mu_2 / x_2 + \dots \mu_n / x_n)$$

$$= \mu_1 / f(x_1) + \mu_2 / f(x_2) + \dots \mu_n / f(x_n) \quad (2.27)$$

biçiminde ifade edilir.

Bu durumda V kümesinde tanımlanan $f(A)$ bulanık kümesinin üyelik fonksiyonu şöyle ifade edilir,

$$\mu_{f(A)}(x) = \max_{\substack{x_i \in U \\ f(x_i)=y}} [\mu_{A_i}(x_i)] \quad (2.28)$$

U kesin kümesi evrenlerin bir kartezyen çarpımı

$$U = U_1 \times U_2 \times \dots \times U_n \quad (2.29)$$

olmakla, kesin f fonksiyonu U 'daki n -liyi, V 'deki bir noktaya görüntüleyen n değişkenli bir fonksiyon olsun, yani $y = f(x_1, x_2, \dots, x_n)$. Uygun olarak $A_1, A_2, \dots, A_n$ $U_1, U_2, \dots, U_n$ 'de, n sayıda bulanık kümeler olsun. Genişletme prensibi $f(x_1, x_2, \dots, x_n)$ fonksiyonunu, U 'daki n bulanık $A_1, A_2, \dots, A_n$ alt kümelere şöyle genişletir. $B = f(A)$, $f(\cdot)$ 'in $A_1, A_2, \dots, A_n$ 'de bulanık görüntüsü olmak üzere, bu bulanık küme şöyle tanımlanır:


$$B = \{(y, \mu_B(y)) \mid y = f(x_1, x_2, \dots, x_n), (x_1, x_2, \dots, x_n) \in U\}$$

$$\mu_B(y) = \sup_{\substack{(x_1, x_2, \dots, x_n) \in U \\ y = f(x_1, x_2, \dots, x_n)}} \min [\mu_{A_1}(x_1), \mu_{A_2}(x_2), \dots, \mu_{A_n}(x_n)], \quad (2.30)$$

eğer $y = f(x_1, x_2, \dots, x_n)$ şeklinde hiçbir $(x_1, x_2, \dots, x_n) \in U$ elemanı yoksa $\mu_B(y) = 0$ 'dır (Dubois ve Prade 1980; Lin ve Lee 1996).

2.4. Bulanık Sayılar

Konveks A bulanık kümesinden alınan $(x_1, \mu_A(x_1))$ ve $(x_2, \mu_A(x_2))$ noktalarını birleştirecek bir doğru çizildiğinde, bu doğru üzerindeki tüm noktaların üyelik dereceleri $\mu_A(x_1)$ ve $\mu_A(x_2)$ 'nin minimumuna eşit veya daha büyük olur (Lin ve Lee 1996). Şekil 2.4'de, verilen bir üyelik fonksiyonu ile ifade edilen bulanık kümenin konveks ve normalliği görülmektedir.



Şekil 2.4. Konveks ve normal bulanık küme


$\Re$ reel sayılar kümesinin normal ve konveks bir bulanık A kümesine bulanık sayı denir. Burada μ_A üyelik fonksiyonunun kısmi-sürekli olması istenir.

Bulanık sayı, $\Re$ gerçel sayılar kümesinde bulanık aralık olarak tanımlanan bir bulanık küme şeklinde ifade edilebilir. Bu aralığa ait sınırlar belirsiz olduğundan, aralıklar aynı zamanda bir bulanık kümedir. Bulanık aralıklar, $[a_1, a_2, a_3]$ şeklinde iki sınır noktası a_1 , a_3 ve bir tepe noktası a_2 yardımıyla gösterilirler. Bu açıklamalardan yola çıkılarak görülmektedir ki bulanık sayılara α -kesim işlemi uygulanabilir. Eğer A bulanık sayısı için α -kesim aralığını gösterirsek, tanımlanan A_α aralığı,

$$A_\alpha = [a_1^{(\alpha)}, a_3^{(\alpha)}] \quad (2.31)$$

biçiminde tanımlanır.

Tanımı gerçekleştirilen bulanık sayı ifadesi Şekil 2.5 ile gösterilmiştir (Lee 2005).



Şekil 2.5. Bulanık sayı


Böylelikle, bulanık sayı, kısmi-süreklilik üyelik fonksiyonuna sahip $\mathfrak{R}$ reel sayılar doğrusunda normal ve dışbükey (konveks) bulanık alt kümedir (Lin ve Lee 1996).

2.4.1. Üçgen bulanık sayılar

$A = (a_1, a_2, a_3)$ bir bulanık sayı olmak üzere, a_1 bulanık sayının alt sınırı, a_2 bulanık sayının merkezi ve a_3 bulanık sayının üst sınırını göstermek üzere aşağıdaki üyelik fonksiyonu ile tanımlanması durumunda üçgen bulanık sayı olarak adlandırılır.

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x - a_1}{a_2 - a_1}, & a_1 \leq x \leq a_2 \\ \frac{a_3 - x}{a_3 - a_2}, & a_2 \leq x \leq a_3 \\ 0, & x > a_3 \end{cases} \quad (2.32)$$

Eğer $a_2 - a_1 = a_3 - a_2$ ise simetrik üçgen bulanık sayı olarak adlandırılır ve üyelik fonksiyonu Şekil 2.6 ile gösterilir (Lee 2005).



Şekil 2.6. Üçgen Bulanık Sayı


Simetrik üçgen bulanık sayı sol ve sağ uç olarak iki gerçek sayı yardımıyla yazılabilir. (a_1, a_2, a_3) şeklindeki bir simetrik üçgen bulanık sayı (a_1, a_3) şeklinde de yazılabilir ve bu durumda $a_2 = \frac{a_3 + a_1}{2}$ olarak bulunur.

2.4.2. Yamuk bulanık sayılar

$A = (a_1, a_2, a_3, a_4)$ bir yamuk bulanık sayı olmak üzere, yapısında üyelik derecesi 1'e eşit olan pek çok nokta barındırır. Yamuk bulanık sayı aşağıdaki gibi bir üyelik fonksiyonu yardımı ile ifade edilir.

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x - a_1}{a_2 - a_1}, & a_1 \leq x \leq a_2 \\ 1, & a_2 \leq x \leq a_3 \\ \frac{a_4 - x}{a_4 - a_3}, & a_3 \leq x \leq a_4 \\ 0, & x > a_4 \end{cases} \quad (2.33)$$

Bir yamuk bulanık sayı $a_2 = a_3$ olması durumunda üçgen bulanık sayıya dönüşür. Yamuk bulanık sayıya ait bir üyelik fonksiyonunun gösterimi Şekil 2.7'de görülmektedir (Lee 2005).



Şekil 2.7. Yamuk Bulanık Sayı

2.4.3. *LR* gösterimli bulanık sayılar


Bulanık sayıların *LR* gösterimi, onun genelliğini sınırlamaksızın hesaplamasal etkinliğini artırmasından dolayı Dubois ve Prade (1980) tarafından önerilmiştir. Bir M bulanık sayısı için üyelik fonksiyonu $\mu_M(x)$ 'in *LR* gösterimi eşitlik (2.34) ile tanımlanır.

$$\mu_M(x) = \begin{cases} L[(m-x)/\alpha], & x < m, \alpha > 0 \\ 1, & x = m \\ R[(x-m)/\beta], & x > m, \beta > 0 \end{cases} \quad (2.34)$$

Referans fonksiyonları olarak anılan $L(x)$ ve $R(x)$ fonksiyonları, $\Re^+ \rightarrow [0,1]$ olmak üzere aşağıdaki koşulları sağlar.

- i. $L(x) = L(-x), R(x) = R(-x)$
- ii. $L(0) = 1, R(0) = 1$
- iii. L ve R $[0, \infty]$ aralığında artmayandır ($x \geq 0$ için $L(x)$ ve $R(x)$ kesin azalandır)

Denklem (2.34) ifadesinde m , M 'nin orta değeri, α ve β ise uygun olarak sol ve sağ saçılımlar (yayımlar) olarak adlandırılırlar. Saçılımlar sıfıra yaklaştığında sayı bulanıklığını kaybeder, saçılımlar arttıkça sayı daha fazla bulanıklaşır (Lin ve Lee 1996). M , LR bulanık sayısına ait üyelik fonksiyonu referans fonksiyonlarının yapısına bağlı olarak Şekil 2.8'deki gibi ifade edilebilir.



Şekil 2.8. LR Bulanık Sayısı

Sembolik olarak LR bulanık sayısını $M = (m, \alpha, \beta)_{LR}$ şeklinde yazacağız ve gerekli olmadığı durumlarda LR indisini göstermeyeceğiz. LR bulanık sayıları üzerinde bir dizi genişletilmiş aritmetik işlemler geliştirilmiştir (Dubois ve Prade 1980). Örneğin, $(m, \alpha, \beta)_{LR}$ ve $(n, \gamma, \delta)_{LR}$ sayılarının genişletilmiş toplamı $(m+n, \alpha+\gamma, \beta+\delta)_{LR}$ ve farkı $(m-n, \alpha+\gamma, \beta+\delta)_{LR}$ formülleri ile hesaplanır, $(m, \alpha, \beta)_{LR}$ sayısının toplamsal tersi ise $-(m, \alpha, \beta)_{LR} = (-m, \alpha, \beta)_{LR}$ olarak bulunur.

2.4.4. Çan şeklinde bulanık sayılar

Çan şeklinde bulanık sayı sık sık pratik uygulamalarda kullanılır ve fonksiyonu,

$$\mu_A(x) = \exp \left\{ \frac{-(x-m_A)^2}{2\delta_A^2} \right\} \quad (2.35)$$

biçiminde ifade edilir. Burada m_A fonksiyonun ortalaması, δ_A standart sapmadır (Lee 2005).

2.5. Durulaştırma Yöntemleri

Hassas konularda çalışan karar vericilerin yaklaşık değerler ile işlem yapması istenmeyen bir durumdur. Dolayısıyla, bulanık sayılar ile yapılan işlemler sonucunda elde edilen yeni bulanık kümeden bir çıkarım yapılması gereklidir. Başka bir ifadeyle, bulanık sayılarla yapılan işlemlerden sonra elde edilen bulanık çıktı kümesinin kesin bir değere dönüştürülmesi gerekmektedir. Bulanıklaştırma(fuzzification) işleminin tersi olarak adlandırılabilen bu işlemin adı durulaştırmadır(defuzzification). Durulaştırma işlemleri bulanık işlemler sonucu elde edilen bulanık kümelerin üyelik fonksiyonları aracılığıyla gerçekleştirilir (Roychowdhury ve Pedrycz 2001).


Literatürde 30'dan fazla durulaştırma yöntemi bulunmakla beraber, bulanık denetleme teorisinde en fazla kullanılan yöntemler, en büyük üyelik ilkesi, sentroid yöntemi, ağırlıklı ortalama yöntemi, ortalama en büyük üyelik ve en büyük alanın merkezi yöntemleridir. Bu beş tane durulaştırma işleminin esasları alt kesimlerde verilmiştir. Bu yöntemlerden hangisinin kullanılacağı karar vericinin ele aldığı problemin yapısına göre belirlenir (Paksoy ve ark. 2013).

2.5.1. En büyük üyelik ilkesi

En büyük üyelik ilkesi (max-membership principle) bulanık çıkarım kümesindeki en yüksek üyelik derecesine sahip öge değerini verir. Bu durulaştırma yönteminin kullanılabilmesi için tepeleri olan bir bulanık çıkarım kümesine ihtiyaç vardır. Tek bir tepe üyelik fonksiyon değeri bulunan bulanık çıkarım kümeleri için en hızlı durulaştırma yöntemlerinden biridir. En büyük üyelik ilkesi yöntemi matematiksel olarak,

$$\mu(z^*) \geq \max\{\mu(z), z \in Z\} \quad (2.36)$$

biçiminde ifade edilirken, Şekil 2.9'da da gösterilmiştir (Ross 1995).




Şekil 2.9. En büyük üyelik derecesi ile durulaştırma

2.5.2. Sentroid yöntemi

Başka bir ismi de ağırlık merkezi yöntemi olan Sentroid yöntemi (center of area method/centroid method/center of gravity method), Sugeno tarafından 1985 yılında geliştirilmiştir. Geliştirildiği zamandan günümüze kadar en yaygın olarak kullanılan durulaştırma yöntemidir. Sentroid yöntemi,

$$z^* = \frac{\int \mu(z) z dz}{\int \mu(z) dz} \quad (2.37)$$

biçiminde ifade edilirken Şekil 2.10'da da gösterilmiştir (Ross 1995; Lee 2005).



Şekil 2.10. Sentroid yöntemi ile durulaştırma

2.5.3. Ağırlıklandırılmış ortalamalar yöntemi


Ağırlıklandırılmış ortalamalar yöntemi (weighted average method/mean of maxima method) sonucunda durulaşmış kesin değer, bulanık çıkarım kümesini oluşturan her bir çıktı bulanık kümesinin sahip olduğu en büyük üyelik fonksiyonu değeri ile ilgili öge değerinin çarpılıp toplam üyelik fonksiyonu değerine oranlanması ile elde edilir. Matematiksel olarak ise,

$$z^* = \frac{\sum_i \mu_i z_i}{\sum_i \mu_i} \quad (2.38)$$

biçiminde ifade edilir. Burada μ_i , i. bulanık kümenin en büyük üyelik fonksiyonu değerini gösterirken, z_i değeri i. bulanık kümenin yatay ekseninde oluşturduğu aralığın orta değeri (mean value) dir. Şekil 2.11’de gösterilen iki bulanık kümenin ağırlıklı ortalaması (durulaştırılmış değer),

$$z^* = \frac{a(0.6) + b(0.9)}{0.6 + 0.9} \quad (2.39)$$

olarak bulunur (Lee 2005; Şen 2004).




Şekil 2.11. Ağırlıklandırılmış ortalamalar yöntemi ile durulaştırma (Ross 1995)

2.5.4. Ortalama en büyük üyelik yöntemi

En büyük üyelik ilkesi yönteminde bulanık çıkarım kümesinin tek bir tepe noktası olduğu varsayılmış ve ona göre durulaştırma işlemi yapılmıştır. Ancak bazı durumlarda durulaştırma işlemi yapılacak olan bulanık çıkarım kümesinde tek bir tepe noktası yerine Şekil 2.12’de olduğu gibi birden fazla tepe noktasının yer aldığı düz bir plato kısmı bulunabilir. Bu tarz bulanık çıkarım kümelerinde durulaştırma işlemi ortalama en büyük üyelik ilkesi yöntemine (center of maxima method) göre yapılır. Şekil 2.12’de a ve b değerleri üyelik fonksiyonu değeri 1’e eşit olan uç değerleri gösterirken, ortalama en büyük üyelik yöntemi ile durulaştırılmış değer,

$$z^* = \frac{a+b}{2} \quad (2.40)$$

işlemi ile bulunur.




Şekil 2.12. Ortalama en büyük üyelik yöntemi ile durulaştırma (Ross 1995)

2.5.5. En büyük alanın merkezi yöntemi

Çıktı bulanık kümesi en az iki adet dışbükey alt bulanık kümeyi içeriyor ise, en büyük alana sahip dışbükey bulanık kümenin ağırlık merkezi, en büyük alanın merkezi yöntemine (center of largest area) göre durulaştırılmış değer kabul edilir. Bu yöntemde en büyük alana sahip dışbükey bulanık kümenin ağırlık merkezi, ağırlık merkezi yönteminde kullanılan formülasyona göre yapılır. Şekilsel olarak Şekil 2.13'de gösterilen bu durum, matematiksel olarak,

$$z^* = \frac{\int \mu_{\bar{C}_m}(z) z dz}{\int \mu_{\bar{C}_m}(z) dz} \quad (2.41)$$

biçiminde ifade edilir. Burada $\mu_{\bar{C}_m}$ en büyük alana sahip dışbükey kümenin üyelik fonksiyonunu göstermektedir (Ross 1995; Paksoy ve ark. 2013).



Şekil 2.13. En büyük alan merkezi yöntemi ile durulaştırma (Ross 1995)

3. YAPAY SİNİR AĞLARI

Bu bölüm, çalışmanın temel konusunu oluşturan YSA teknolojisine ait temel ve teorik bilgileri kapsamaktadır. Teknolojik gelişmenin önemli boyutlara ulaştığı bugün, insanoğlunun kendisini tanımaya yönelik çalışmaları da önemli aşamalar kaydetmiştir. Yapay zekâ (artificial intelligence) kavramı ile insanın en önemli özellikleri olan düşünebilme ve öğrenebilme yetenekleri önemli araştırma konuları durumuna gelmiştir. Özellikle bilgisayar kullanımının hızla yaygınlaşması sonucunda yapay zekâ çalışmaları da bir ivme kazanmıştır.

“İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak” olarak tanımlanan yapay zekâ, aslında programlanmış bilgisayarlara düşünme yeteneği sağlama girişimidir. İnsan gibi düşünen ve davranan sistemlerin geliştirilmesine yönelik olarak 1950’li yıllardan beri süren yapay zekâ çalışmaları, bir noktada insanı taklit etmeye yönelik olduğundan mühendislik, nöroloji ve psikoloji gibi alanlara da yayılmıştır. İnsan gibi düşünebilen ve davranabilen sistemlerin geliştirilmesi için yapılan çalışmalarda geline nokta, henüz yapay zekânın tam olarak geliştirilememiş olmasıdır.

Yapay zekâ çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zekâ çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de Yapay Sinir Ağları teknolojisidir. İnsan beyninin temel işlem elemanı olan nöronu (neuron) şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir “girdi veriden öğrenme” kapasitesi sağlamaktadır ve birçok avantajlar sunmaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknoloji, günümüzde birçok alanda olduğu gibi ekonomi ve istatistik alanlarında da faydalanılmaktadır. Özellikle, “Evrensel Fonksiyon Yakınsayıcı Yöntem (Universal Function Approximators)” olarak tanınmalarından dolayı tahmin ve öngörü gibi verinin içerdiği yapının tanımlanmasını gerektiren alanlarda sıkça kullanılmaktadırlar (Yurtoğlu 2005).

Bu bölümde YSA ile ilgili genel kavramlar, YSA yapısı, YSA'nın temel elemanları, bazı YSA algoritmaları, bazı YSA mimarileri ve bazı öngörü değerlendirme yöntemleri hakkında bilgi verilmektedir.

3.1. Yapay Sinir Ağlarının Tanımı

YSA, insan beyninden esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarıdır (Elmas 2003). Bir başka deyişle insan beyninin işleyişini taklit eden sistemlerdir (Sağıroğlu ve Ark. 2003). YSA, biyolojik sinir ağlarından esinlenilerek ortaya çıkarılan ve biyolojik sinir ağlarına benzer bazı performans özellikleri içeren bir bilgi işleme sistemidir (Fausett 1994). YSA, deneyime dayalı bilgiyi depolamaya ve bu bilgileri kullanıma sunmaya yönelik doğal bir eğilim içerisinde olan yoğun paralel dağılmış bir işlemcidir (Haykin 1999). YSA, insan beyninin işleyişine benzer bir biçimde, bir girdi seti ile bir çıktı setini doğrusal olmayan bir şekilde eşleştirebilen sistemlerdir (Jain ve Martin 1998).


Literatürde YSA ya da sinir ağları olarak bahsedilen çalışmalar, başlangıçta insan beyni hesaplamalarını tanıma olarak geleneksel bilgisayarlardan tamamen farklı yollarla harekete geçirilmiştir (Haykin 1999).

YSA ile ilgili çalışmaların temel amaç olarak biyolojik sinir sistemlerinin anlaşılmasına ve matematiksel olarak modellenmesine yönelik çabaları içermesi, öncelikle YSA'nın tarihi gelişimine ve biyolojik sinir ağlarının fizyolojik yapılarının anlaşılmasını gerektirmektedir (Terence 1999). Bu nedenle izleyen bölümde, YSA'nın biyolojik sinir sistemleri ile benzerliğini ifade etmek için biyolojik sinir ağlarının fizyolojik yapısı ele alınmıştır.

3.2. Biyolojik Sinir Ağlarının Fizyolojik Yapısı

İnsan sinir sistemi çok karmaşık bir ağıdır. Beyin bu sistemin merkezi elemanıdır ve birbirlerine alt ağlarla bağlı nöronlara (sinir hücresi) sahiptir. Sinir hücreleri elektrokimyasal bir işlemle bilgi taşımak için özelleşmiş hücrelerdir. Bu sinir hücreleri değişik şekil ve büyüklükte dirler. Bazıları sadece 4 mikron (4/1000

milimetre) genişliğinde iken 100 mikron genişliğinde olanlar da vardır. Her ne kadar değişik tipteki sinir hücrelerinin şekil ve işlev açısından farklılıkları bulunsa da hepsinin ortak özelliği hücre gövdesi, dendrit, akson ve akson terminallerinden olmak üzere 4 farklı kısımdan oluşmalarıdır (Guyton ve Hall 2006). Biyolojik bir sinir hücresinin temel yapısı Şekil 3.1’de gösterilmiştir (Diamantaras ve Kung 1996; Haykin 1999).



Şekil 3.1. Biyolojik Sinir Hücresinin Temel Yapısı (Diamantaras ve Kung 1996; Haykin 1999)

Dendritler, hücre gövdesinden dışarıya doğru uzanım gösterirler ve diğer sinir hücrelerinin akson sonlanım noktalarındaki kimyasal sinyalleri almak için özelleşmişlerdir (Guyton ve Hall 2006). Diğer bir deyişle dendritler, bir hücre için girdi kanallarını oluştururlar (Anderson ve McNeill 1992). Dendritler bu sinyalleri küçük elektriksel akımlara çevirerek hücre gövdesine iletirler. Dendritlerin yüzeyleri düz değildir ve genellikle bir sinir hücresinde çok sayıda dendrit vardır. Aksonların aksine üzerlerini kaplayan sinir kılıfları (myelin) yoktur.

Hücre gövdesi çekirdeği içerir ve tüm sinir hücre proteinlerinin ve zarların üretim merkezi olma görevini üstlenir. (Guyton ve Hall 2006). Hücre gövdesi, dendritler aracılığıyla gelen sinyalleri işleyerek çıktıya dönüştürür. Hücre gövdesinin ürettiği bu çıktılar ise aksonlar aracılığıyla diğer nöronlara girdi olmak üzere gönderilir (Anderson ve McNeill 1992). Tüm sinir hücreleri akson adı

verilen çapı 1 mikrometreden 1 milimetreye varabilen uzun kollarla diğer sinir hücreleriyle etkileşime girerler. Aksonlar, aksiyon potansiyeli denen bir çeşit elektriksel akımın hücre gövdesinden akson terminaline iletimini sağlarlar. Akson yüzeyleri düzdür ve genellikle bir sinir hücresinde bir akson vardır. Aksonlar sinir hücre gövdesinden uzakta dallanırlar. Hücre gövdesinden ayrıldıktan sonra myelin denen bir kılıfla yüzeyleri kaplanır. Bu kılıf aksonun seyri boyunca 0,2-2 milimetrede bir kesintiye uğrar. Bu kesinti noktalarına Ranvier düğümü adı verilir.

Nöronal hücre gövdeleri sinyal alımı için sinapslar oluştururlar. Sinaps, iki sinir hücresi arasındaki fonksiyonel bir ünedir. Sinaps terminaline ulaşan akım, nörotransmitter adı verilen belirli kimyasalların açığa çıkmasını sağlar. Bu kimyasal maddeler postsinaptik uçtaki reseptörlere bağlanınca, postsinaptik hücrenin uyarılabilirliğinde bir değişikliğe sebep olur. Bu değişiklik uyarıcı yönde, başka bir ifadeyle sinir hücresinin bir aksiyon potansiyeli oluşturmamasını destekleyecek şekilde olabileceği gibi engelleyici yönde de olabilir. Eğer uyarıcı olaylar yeterli sayıda olursa, postsinaptik sinir hücresinde yeni bir aksiyon potansiyeli oluşur ve mesaj iletilmiş olur. Sinapslarda ileti her zaman tek yönde, presinaptik düğümden postsinaptik hücreye doğru iletilir. Sinapslar genellikle sinyalleri tek bir yönde iletirler (presnaptik hücreden postsnaptik hücreye doğru). Bir hücrenin aksonu diğer hücrelerle bu sinapslar sayesinde binlerce bağlantı yapabilir (Guyton ve Hall 2006).

YSA beyne özellikle iki özelliğiyle benzetilmektedir. Bu özelliklerden birincisi; bilginin, bir öğrenme işlemi ile ağın çevresinden elde edilmesi, ikincisi; sinaptik ağırlıklar olarak bilinen işlem elemanları (nöron) arasındaki bağlantı ağırlıkları, elde edilen bilgileri depolamak için kullanılmasıdır (Haykin 1999). Fausett'e göre ise, YSA, insanın kavrama yeteneğinin ya da sinir biyolojisinin matematiksel modellerinin genelleştirilmesi olup aşağıdaki varsayımlara dayandırılarak oluşturulmuştur (Fausett 1994):

1. Bilgi işleme, işlem elemanı (nöron) adı verilen birçok basit birimlerle gerçekleşir.

2. Sinyaller bağlantılar aracılığıyla işlem elemanları arasında geçiş yapar.

3. Her bağlantının bir ağırlığı vardır. Tipik bir sinir ağında olduğu gibi, iletilen sinyallerle çarpılır.

4. Her işlem elemanı çıktı sinyallerini belirlemek için genellikle doğrusal olmayan bir transfer fonksiyonu uygular.

Tüm bu açıklamaların çerçevesinde biyolojik sinir sisteminin yapısı ile YSA arasındaki benzerlikler Çizelge 3.1'deki gibi gösterilebilir (Elmas 2003).

Çizelge 3.1. Biyolojik Sinir Sistemi ile YSA Arasındaki Benzerlikler (Elmas 2003)

Biyolojik Sinir Ağı	YSA
Nöron	İşlem Elemanı (Düğüm) (X)
Sinaps	İşlem Elemanları Arasındaki Bağlantı Ağırlıkları (W)
Dendrit	Birleştirme Fonksiyonu (Σ)
Hücre Gövdesi	Transfer Fonksiyonu
Akson	İşlem Elemanının Çıkışı (Y)

3.3. Yapay Sinir Ağlarının Temel Yapısı


Bir YSA'nın temel yapısı, girdiler arasında bağlantı kuran işlem elemanlarından, bağlantı ağırlıklarının belirlenmesini sağlayan öğrenme algoritmalarından ve transfer fonksiyonundan oluşmaktadır. Her bir işlem elemanı, diğer işlem elemanlarıyla bağlantılı olup bir ağırlık değerine (W) sahiptir.

Ağırlıklar, işlem elemanları arasındaki bağlantıların kuvvetini gösterir ve gizli katmandaki ve çıktı katmanındaki işlem elemanlarının net girdisinin hesaplanmasında kullanılır. Her işlem elemanın bir ağırlığa ve diğer işlem elemanlarıyla bağlantıya sahip olması, bilginin tüm bu bağlantılar aracılığıyla işlem elemanları ve katmanlar arasında ağına çıkışına kadar iletilmesini ve ağına dağıtılmış bir hafızaya sahip olmasını sağlamaktadır (Fausett 1999).

Teknik olarak, bir YSA'nın en temel görevi, örnek veri setindeki yapıyı öğrenerek, istenilen görevi yerine getirecek şekilde genelleştirmeler yapmasıdır. Bunu yapabilmesi için ağı, ilgili olayın örnekleri ile eğitilerek genelleme

yapılabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir. Ağın ürettiği sonuçlar ise; ağa girilen bilgilerin kendi ağırlıkları ile çarpımlarının toplanması sonucu elde edilen net girdinin, bir transfer fonksiyonu ile işlenmesi ile çıktı katmanından alınmaktadır (Öztemel 2003).

YSA'da ilk katman girdi katmanıdır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin YSA'ya alınmasını sağlar. Diğer katman ise ağ içerisinde işlenen bilginin dışarıya iletildiği çıktı katmanıdır. Girdi ve çıktı katmanlarının arasında katman varsa bunlara gizli katman adı verilir. Bir YSA'da gizli katman olması gerekmediği gibi, birden fazla gizli katman da bulunabilir. Her katmanda birden çok işlem elemanı bulunabilir. Literatürde, hemen hemen tüm çalışmalarda girdi katmanı, girdilerin ağa girmesinde bir kapı işlevi görmesi nedeniyle niceliksel olarak katman sayısına dâhil edilmemektedir. Bundan dolayı, girdi katmanı ile birlikte üç katmandan oluşan bir YSA, iki (çok) katmanlı bir ağ olarak kabul edilmektedir. Girdi katmanı ile birlikte iki katmanlı olan bir YSA ise tek katmanlı bir ağ olarak kabul edilmektedir (MacKay 2003). Tipik bir YSA yapısı Şekil 3.2'de gösterilmiştir (Smith 2002).



Şekil 3.2. Tipik Bir YSA Yapısı (Smith, 2002)

Şekil 3.2.'de, $(x_i; i=1, \dots, n)$ girdi katmanındaki işlem elemanlarını, $(y_j; j=1, \dots, h)$ gizli katmandaki işlem elemanlarını, $(z_k; k=1, \dots, p)$ çıktı katmanındaki işlem elemanlarını göstermektedir. Ayrıca w_{ij} , i . girdi işlem elemanından j . gizli işlem elemanına olan bağlantının ağırlığını ve v_{jk} , j . gizli işlem elemanından k . çıktı işlem elemanına olan bağlantının ağırlığını göstermektedir. +1 olarak gösterilen birimler sapma “ Θ ” (bias term) değerleridir (Smith 2002).

3.4. Yapay Sinir Ağlarının Temel Elemanları

Biyolojik sinir ağlarındaki sinir hücrelerine karşılık, YSA'da da yapay sinir hücreleri vardır. Şekil 3.2 aynı zamanda bir yapay sinir hücresini de göstermektedir. Her yapay sinir hücresinin 4 temel elemanı vardır. Bu elemanlar; girdiler, ağırlıklar, transfer fonksiyonu ve hücrenin çıktısıdır.

3.4.1. Girdiler

Girdiler $(x_i; i=1, \dots, n)$ bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Yapay sinir hücresine dış dünyadan olduğu gibi başka hücrelerden veya kendisinden de bilgiler gelebilir.

3.4.2. Ağırlıklar

Ağırlıklar, bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki etkisini gösterir (Öztemel 2003). Bir işlem elemanı, genellikle eşanlı olarak birçok girdi almaktadır. Her girdi $(x_i; i=1, \dots, n)$ gizli katmandaki işlem elemanına $(y_j; j=1, \dots, h)$; bağlanırken bir bağlantı ağırlığına $(w_{ij}; i=1, \dots, n; j=1, \dots, h)$ sahip olmaktadır. Gizli katmandaki gizli işlem elemanları diğer bir gizli katmandaki gizli işlem elemanlarına ya da başka bir gizli

katman bulunmuyorsa çıktı katmanındaki işlem elemanlarına $(z_k; k = 1, \dots, p)$; bağlanırken de bir bağlantı ağırlığına $(v_{jk}; j = 1, \dots, h; k = 1, \dots, p)$ sahip olmaktadır. Girdi katmanından gizli katmana gelen girdilerin bu bağlantı ağırlıkları ile çarpılması ile gerekli değerler elde edilir (Anderson ve McNeill 1992).

3.4.3. Transfer(Aktivasyon) fonksiyonu


Transfer fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Transfer fonksiyonu olarak çıktıyı hesaplamak için değişik formüller kullanılmaktadır.

Transfer fonksiyonunda ağırlık işlem elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu diğerleri farklı fonksiyonları kullanabilirler. Bir problem için en uygun fonksiyonunun bulunması, ağırlık tasarımcısının denemeleri sonucunda belirleyebileceği bir durumdur. Uygun fonksiyonu gösteren bir formül henüz bulunmuş değildir (Öztemel 2003). En yaygın olarak kullanılan transfer fonksiyonları aşağıda verilmektedir.

Özdeşlik (identity) Fonksiyonu: Genellikle girdi değerleri için kullanılan aktivasyon fonksiyonu aşağıda ifade edilen ve Şekil 3.3’de gösterilen özdeşlik fonksiyonudur (Zilouchian 2001).

$$F(NE T) = NE T \quad (3.1)$$

Belirli bir katmandaki tüm nöronlar için aynı aktivasyon fonksiyonu kullanılabilir. Birçok durumda doğrusal olmayan aktivasyon fonksiyonları kullanılır (Fausett 1999).




Şekil 3.3. Özdeşlik Fonksiyonu (Zilouchian 2001)


Eşik Fonksiyonu: Eşik (threshold) fonksiyonun en önemli özelliği, tüm girdi değerine karşılık sadece iki çeşit çıktı üretmesidir. Eğer giriş değeri, sapma değerini “ Θ ” aşarsa çıktı olarak α , aksi takdirde β sabit değerini alır. Eşik fonksiyonun matematiksel ifadesi,

$$f(NET) = \begin{cases} \alpha & \text{eğer } NET \geq \Theta \text{ ise} \\ \beta & \text{eğer } NET \leq \Theta \text{ ise} \end{cases} \quad (3.2)$$

şeklinde olur. Bir YSA’da α , β ve Θ değerleri yapılan çalışmanın türüne göre belirlenebilir. Literatürdeki birçok çalışmada $\Theta = 0$ olmak üzere, $\alpha = 1$ ve $\beta = 0$ veya $\alpha = 1$ ve $\beta = -1$ olarak seçilmektedir (Bayramoğlu 2007). Şekil 3.4’de tek kutuplu, Şekil 3.5’de ise çift kutuplu eşik fonksiyonları gösterilmektedir (Zilouchian 2001).



Şekil 3.4. Tek Kutuplu Eşik Fonksiyonu (Zilouchian 2001)




Şekil 3.5. Çift Kutuplu Eşik Fonksiyonu (Zilouchian 2001)

Parçalı Doğrusal Fonksiyon (Piecewise Linear Function): Parçalı doğrusal (piecewise linear) fonksiyon, özdeşlik fonksiyonu ile basamak fonksiyonunun bir araya gelmesi ile oluşur. Bu fonksiyonda $\beta \leq x \leq \alpha$ aralığında doğrusal işlemci, $x > \alpha$ ve $x < \beta$ için de eşik işlemcisi özelliği göstermektedir. Parçalı doğrusal fonksiyonun matematiksel ifadesi,

$$f(NE T) = \begin{cases} \gamma & \text{eğer } NET > \alpha \\ \frac{\gamma - \delta}{\alpha - \beta} NET + \frac{\alpha\delta - \beta\gamma}{\alpha - \beta} & \text{eğer } \beta \leq NET \leq \alpha \\ \delta & \text{eğer } NET < \beta \end{cases} \quad (3.3)$$

şeklindedir. Pratik çalışmalarda γ ve δ değerleri genel olarak $\gamma = +1$ ve $\delta = 0$ veya $\delta = -1$ 'dir (Şen 2004). Şekil 3.6'da parçalı doğrusal fonksiyon gösterilmektedir (Zilouchian 2001).




Şekil 3.6. Parçalı Doğrusal Fonksiyon (Zilouchian 2001)

Sigmoid Fonksiyonu: Sigmoid fonksiyonu, doğrusal olmayan bir fonksiyondur. Sigmoid fonksiyonu; matematiksel olarak doğrusal olmayan yapısının olması, kolayca türevinin alınabilmesi, sürekli ve artan olması nedeniyle YSA yapılarının kurulmasında en çok kullanılan fonksiyondur. Bu fonksiyonun matematiksel ifadesi;

$$f(NE T) = \frac{1}{1 + e^{-\alpha NE T}}, \quad 0 \leq f(NE T) \leq 1 \quad (3.4)$$

şeklindedir. İfadedeki α , sigmoid fonksiyonunun şekil parametresidir. Bu parametre değiştirildiğinde fonksiyonun farklı şekilleri de ortaya çıkar (Zilouchian

2001). Şekil 3.7’de sigmoid fonksiyonu gösterilmektedir (Anderson ve McNeill 1992).




Şekil 3.7. Sigmoid Fonksiyonu (Anderson ve McNeill 1992)

Hiperbolik Tanjant Fonksiyon: Sigmoid fonksiyon ile birlikte hiperbolik tanjant (hyperbolic tangent) fonksiyonu da YSA’da özellikle de çok katmanlı algılayıcı (Multilayer Perceptron) yapılarında sıkça kullanılan bir fonksiyondur. Çift kutuplu (bipolar) fonksiyon olarak da bilinen hiperbolik tanjant fonksiyonu, $[-1, +1]$ aralığını kullanır. Bu yüzden giriş uzayının genişletilmesinde etkili bir fonksiyondur. Ancak bu fonksiyonun hiçbir parametresi bulunmamaktadır. Bu nedenle sigmoid fonksiyonu kadar elastik değildir. Bu fonksiyonun matematiksel ifadesi,

$$f(NET) = \frac{e^{NET} - e^{-NET}}{e^{NET} + e^{-NET}} \quad (3.5)$$

şeklindedir. Bu transfer fonksiyonunun da türevi kolayca alınabilmektedir (Bayramoğlu 2007). Şekil 3.8’de hiperbolik tanjant fonksiyonu gösterilmektedir (Anderson ve McNeill 1992).



Şekil 3.8. Hiperbolik Tanjant Fonksiyonu (Anderson ve McNeill 1992)

3.4.4. Hücresin çıktı

Transfer fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı, dış dünyaya veya başka bir hücreye gönderilir. Hücre, kendi çıktısını kendisine girdi olarak da gönderebilir. Bir işlem elemanın birden fazla girdisi olmasına rağmen sadece bir çıktısı olmaktadır. Ağ şeklinde gösterildiğinde bir işlem elemanın birden fazla çıktısı varmış gibi görülmektedir. Bu sadece gösterim amacıyladır. Aslında bir işlem elemanından çıkan tek bir çıktı değeri vardır. Aynı değer birden fazla işlem elemanına girdi olarak gitmektedir (Öztemel 2003).

3.5. Bazı Yapay Sinir Ağı Algoritmaları

Bu kesimde, yaygın olarak kullanılan standart geriye yayılım algoritması, esnek geriye yayılım algoritması ve radyal tabanlı fonksiyon algoritması hakkında bilgi verilmiştir.

3.5.1. Standart geriye yayılım algoritması

Tahmin ve sınıflandırma problemlerinde daha çok kullanılan ileri beslemeli çok katmanlı YSA modelleri (ÇKA) ele alınsın. Bu ağlarda geniş yayılmış eğitim

algoritması, esas fikri hata kareler toplamını adım adım minimize etmeye dayalı, geriye yayılım (Backpropagation (BP)) algoritmasıdır (Bishop 1995; Haykin 1999; Aslanargun ve Ark. 2007). Aslında, bu algoritma değişkenleri ağırlıklar olan hata fonksiyonuna sayısal optimizasyonda yaygın olan gradyan düşümü yönteminin uygulanmasıdır; her adımda, hata fonksiyonunun bulunulan cari noktadaki gradyan vektörü yönünde ağırlık vektörü belirli bir oranla değiştirilir ve hatanın değeri küçültülür:

$$w_{k+1} = w_k - \alpha g_k, \quad (3.6)$$

burada w_k , cari (k .) adımdaki ağırlık vektörü; g_k , hata fonksiyonunun w_k noktasında gradyan vektörü ve α öğrenme oranıdır.

Basit gradyan düşümü yönteminde yerel minimum ve yakınsama hızıyla ilgili bir sıra zorluklar meydana çıkmaktadır. Bu nedenle ağırlık değişimi formülüne momentum terimi eklenir:

$$\Delta w_{k+1} = -\alpha g_k + \mu \Delta w_k, \quad (3.7)$$

burada

$$\Delta w_k = w_k - w_{k-1} \quad (3.8)$$

ağırlık değişimi, μ momentum katsayısıdır. Momentum içeren geriye yayılım algoritmasına standart geriye yayılım (BPM) denir. Bu algorithmada α ve μ katsayılarının seçimine bağlı olarak algoritmanın kararlılık ve yakınsama hızı gibi nitelikleri değişir (Aslanargun ve Ark. 2007).

3.5.2. Esnek geriye yayılım algoritması

Çok katmanlı ağlar gizli katmanlarda sigmoid aktivasyon fonksiyonunu kullanırlar. Bu fonksiyonlara sıkıştırılmış fonksiyonlar denir, çünkü sonsuz girdi

aralığını sonlu çıktı aralığına sıkıştırırlar. Sigmoid fonksiyonları girdiler genişledikçe sifıra yaklaşma eğiliminde bulunarak karakterize edilirler. Bu da steepest descent sigmoid fonksiyonlu çok katmanlı ağ eğitilirken kullanılırsa problem yaratır; eğitim küçük olur, ağırlık ve sapmada küçük değişikliklere sebep olur.

Esnek Geriye Yayılım Algoritması (Resilient Backpropagation (RP)), eğitim algoritmasının amacı kimi türevlerin büyüklüklerinin zararlı etkilerinden arındırmaktır. Sadece türevin işareti güncellenen ağırlıkları belirlemek için kullanılır. Eğer türev sıfır ise güncellenen değerler aynı kalır. Eğer ağırlıklar birçok iterasyonda aynı doğrultuda değişmeye devam ederse, ağırlık değişiminin büyüklüğü artar (Aslanargun ve Ark. 2007).

3.5.3. Radyal tabanlı fonksiyon algoritması

Radyal Tabanlı Fonksiyon Sinir Ağı (RTFSA), regresyon ve sınıflama problemlerinde ÇKA'nın yanı sıra sıklıkla kullanılan bir ağıdır. Katmanlı YSA'nın tasarımında eğiticili geriye yayılım öğrenme algoritması bir en iyileme uygulamasıdır. Radyal tabanlı fonksiyon ağı tasarımı ise çok boyutlu uzayda eğri uydurma yaklaşımıdır ve bu nedenle RTFSA'nın eğitimi, çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemine dönüşür. RTFSA'nın genellemesi ise test verilerini interpolate etmek amacıyla, eğitim sırasında bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Radyal tabanlı fonksiyonlar, sayısal analizde çok değişkenli interpolasyon problemlerinin çözümünde kullanılmış ve YSA'nın gelişmesi ile birlikte bu fonksiyonlardan YSA tasarımında yararlanılmıştır. RTFSA, ileri beslemeli YSA yapılarına benzer şekilde girdi, ara ve çıktı katmanından oluşur ancak, girdi katmanından ara katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür (Özdemir 2007). Ara katmandan çıktı katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir.

Eğri uydurma teorisi, herhangi birçok değişkenli ve sürekli $f(x)$ fonksiyonunu yaklaştırma ya da interpolate etme problemi ile ilgilidir. İnterpolasyon problemi, $k = 1, 2, \dots, N$ için x_k veri noktası ve d_k gerçek değerler

olmak üzere $F(x_k) = d_k$ interpolasyon koşulunu sağlayan $F(\cdot)$ fonksiyonunun bulunması olarak tanımlanır. Radyal tabanlı fonksiyonlarla doğrusal $F(\cdot)$; denklem;

$$F(x) = \sum_{k=1}^N W_k \varphi_k(\|x - x_k\|). \quad (3.9)$$

şeklinde tanımlanır. Burada $\varphi(\cdot)$ doğrusal olmayan radyal tabanlı fonksiyon, $\|\cdot\|$ genellikle standart öklit uzaklığıdır. Bilinen veri noktaları, radyal tabanlı fonksiyonların merkezleri olarak söylenir. RTFSA'nın genel yapısında veri örneği kadar ara katman hücresine ve ağırlığa gerek duyulduğundan genel çözümü yakınsayan en iyi çözüm aranır. $M < N$ olmak üzere RTFSA çıkışı,

$$F^*(x) = \sum_{i=1}^M W_i \varphi_i(\|x - c_i\|). \quad (3.10)$$

Burada c_i veri noktalarından belirlenecek olan radyal tabanlı fonksiyonların merkez vektörleridir. RTFSA'da ara katman aktivasyon fonksiyonu genellikle standart öklit uzaklıklarını üstel fonksiyondan geçiren gaussian fonksiyonudur ve

$$\varphi(\|x - c_i\|) = e^{\left(\frac{1}{2\sigma^2}\|x - c_i\|^2\right)} \quad (3.11)$$

biçiminde tanımlanır.

RTFSA'da uyarlanabilecek serbest parametreler; merkez vektörleri, radyal fonksiyonların genişliği ve çıktı katman ağırlıklarıdır. Çıktı katmanı doğrusal olduğundan ağırlıklar, eğim düşme ya da doğrusal en iyileme yöntemleri ile kolayca bulunabilir. Merkezler, girişler arasından rastgele ve sabit olarak seçilebilmekle birlikte RTFSA'nın performansını iyileştirmek amacıyla merkez vektörlerinin ve genişliğin uyarlanması için çeşitli yöntemler geliştirilmiştir. Merkez vektörleri, eğim düşme yöntemine göre eğitici öğrenme algoritması ile

uyarlanarak, dik en küçük kareler yöntemi ile ya da kendiliğinden düzenlemeli yöntemle giriş örneklerinden öbekleme yapılarak belirlenebilir (Aslanargun ve Ark. 2007).

3.6. Bazı Yapay Sinir Ağı Mimarileri


Bu kesimde, Bölüm 6’da yapılan uygulamalarda ele alınan bazı YSA mimarileri hakkında kısa bilgi verilecektir. Bu YSA mimarileri radyal tabanlı fonksiyon sinir ağları (Radial Basis Function Networks), çok katmanlı algılayıcı (Multilayer Perceptron) ve genelleştirilmiş regresyon sinir ağları (Generalized regression neural network) olarak ifade edilebilir. Bu mimariler sırasıyla izleyen alt kesimlerde ifade edilmiştir.

3.6.1. Radyal tabanlı fonksiyon sinir ağları (RTFSA)

RTFSA, modelleme, yaklaşık fonksiyon belirleme, sınıflandırma amacıyla kullanılan bir ağ tipi olup ağ yapısı girdi, ara ve çıktı katmanlarından oluşur. Bu yapı Şekil 3.9’da gösterilmiştir (Moody ve Darken 1989; Renals ve Rohwer 1989). Ağın ara katmanında yer alan hücrelerin (gauss hücreleri) çıktısı ağın girdi vektörlerine bağlı olarak bir gauss fonksiyonu ile c_j ve σ_j j . hücre için sırasıyla “merkez değer” ve “bant genişliği” olmak üzere aşağıdaki şekilde verilebilir (Lee ve Choi 2001; Jang ve Sun 1993; Trenn 2008):

$$\phi_j(X) = \exp\left(-\frac{\|X - c_j\|^2}{2\sigma_j^2}\right) \quad (3.12)$$

Ağın çıktısı (y_z) ise Gauss hücrelerine ait çıktılarının ağırlık faktörleri (w_{zj}) üzerinden toplamı olarak hesaplanır:




Şekil 3.9. Radyal tabanlı fonksiyon sinir ağı

Ara katman ve çıktı katmanı arasındaki ağırlık faktörlerinin belirlenmesi ağıın eğitilmesi sonucunda belirlenir. Radyal tabanlı fonksiyon ağında eğitime genellikle denetimli ve denetimsiz olarak iki aşamada gerçekleştirilir. Denetimsiz eğitime aşamasında gauss hücrelerinin (gauss fonksiyonlarının) parametreleri (c_j ve σ) farklı teknikler yardımıyla belirlenirken; denetimli eğitime aşamasında ara katman ve çıktı katmanları arasındaki ağırlık faktörleri uygun bir eğitime algoritması yardımıyla, ileri beslemeli denetimli sinir ağlarında olduğu gibi, belirlenir (Wasserman 1993; Mori ve Awata 2007; Asma ve ark. 2012).

3.6.2. Çok katmanlı algılayıcı (ÇKA)

Tek katmanlı algılayıcıların doğrusal problemleri çözmekle sınırlı kalmaları sonucunda yapılan araştırmalar, ÇKA'ların ve onun öğrenme kuralı olan geriye yayılım algoritmasının ortaya çıkmasıyla sonuçlanmıştır (Haykin 1999; Rumelhart ve ark. 1986; Vaughn 1999). ÇKA'lar ve geriye yayılım algoritması ile doğrusal olmayan problemlerin çözümünde başarılı sonuçlar elde edilmesi,

işletme bilimi dahil birçok alanda kullanımının artmasına yol açmıştır. Şekil 3.10'daki YSA, bir ÇKA'nın yapısına sahiptir (Ozdemir ve ark. 2010).



Şekil 3.10. ÇKA yapısı

ÇKA'ların ilk katmanı girdi katmanıdır. Son katmanı ise, çıktı katmanıdır. Girdi katmanı ile çıktı katmanı arasında ise gizli işlem elemanlarının yer aldığı en az bir tane gizli katman bulunmaktadır. ÇKA'ları tek katmanlı algılayıcılardan ayıran özellik, ÇKA'larda bulunan gizli katmandır. Çünkü gizli katmanda yapılan bir dizi işlem ile ağ doğrusal olmayan bir yapıya kavuşturulabilmektedir. Gizli katman sayısı en az bir tane olmak üzere birden fazla da olabilmektedir. Gizli katmandaki her işlem elemanı, doğrusal olmayan bir transfer fonksiyonuna sahiptir ve bu fonksiyonlar aracılığıyla elde edilen sonuçlar bir sonraki işlem elemanlarına girdi sağlamaktadır. ÇKA'larda en çok kullanılan transfer fonksiyonları sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonudur (Trenn 2008; Bayramoğlu 2007; Asma ve ark. 2012).

3.6.3. Genelleştirilmiş regresyon sinir ağları (GRSA)

GRSA, RTFSA'nın özel bir durumudur. Ağ yapısı bir radyal tabanlı katman ile özel bir doğrusal katmandan oluşmaktadır. RTFSA'larda temel fikir, bir grup radyal tabanlı fonksiyonu istenen fonksiyona yaklaşacak şekilde ağırlıklandırarak toplamaktır. GRSA'larında ise RTFSA'nın merkez ve bant genişliklerinin eğitime verisinin deterministik fonksiyonları olarak belirlenir ve bu tip ağlarda eğitim için yinelemeli (iteratif) yöntemler kullanılmaz (Wasserman 1993).

Birinci katman, normal bir RTFSA gibi işler. Her nöronun ağırlıklı girişi, giriş vektörü ile bu girişin ağırlık vektörü arasındaki uzaklıktır. Her nöronun net girişi, o nöronun ağırlıklı girişi ile biasının çarpımıyla belirlenir. Her nöronun çıkışı, o nöronun net girişinin radyal tabanlı katmandan geçirilmesiyle hesaplanır.

GRSA’nda bir x_j girişi, ağdaki Gauss çekirdeklerinden birinin merkezi olarak atanır. Herhangi bir giriş vektörü x için i . radyal tabanlı biriminin çıkışı

$$\beta_i = \exp \left[-\frac{(x - x_i)^T (x - x_i)}{2\sigma^2} \right] \quad (3.13)$$

şeklinde hesaplanır. Burada σ kullanıcı tarafından belirlenen yumuşatma parametresidir. Herhangi bir x girişi için ağın çıkışı y


$$y = \sum_{i=1}^K \alpha_i y_i \quad (3.14)$$

şeklindedir. Buradaki α katsayıları aşağıda görüldüğü gibi hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^K \beta_i} \quad (3.15)$$

Eğer giriş vektörü x , herhangi bir x_i eğitim vektörüne yakın ise x_i ’ye ilişkin α_i en büyük olacak ve istenen çıkış y , x_i ’ye ilişkin y_i çıkışına yaklaşacaktır (Bolat ve ark. 2004; Asma ve ark. 2012).

Şekil 3.11’de GRSA’nın genel yapısı gösterilmiştir (Mostafa 2010).



Şekil 3.11. GRSA yapısı

3.7. Öngörü Değerlendirme Yöntemleri

Öngörü performanslarının karşılaştırılmasında, genellikle aşağıdaki ölçütler kullanılır. Yapılan karşılaştırmalar için sıklıkla kullanılan bu ölçütler aşağıdaki eşitliklerde verildiği gibidir:

$$\text{Hata Kareler Ortalaması (HKO)} = \sum (e_t)^2 / N \quad (3.16)$$

$$\text{Ortalama Mutlak Hata (OMH)} = \sum |e_t| / N \quad (3.17)$$

$$\text{Ortalama Mutlak Yüzde Hata (OMYH)} = (1/N) \sum |e_t / y_t| (100) \quad (3.18)$$

$$\text{Hata Kareler Toplamı (HKT)} = \sum (e_t)^2 \quad (3.19)$$

$$\text{Hata Kareler Ortalamasının Karekökü (HKOK)} = \sqrt{MSE} \quad (3.20)$$

Bu eşitliklerde e_t öngörü hatasını, y_t t dönemi gözlem değerini ve N hata terimleri sayısını göstermektedir (Zhang ve Ark. 1998; Erdoğan 2006; Özdemir 2008).

4. BULANIK ZAMAN SERİLERİ

Bu bölümde, bulanık zaman serileri ile ilgili tanımlamalar verilecektir. Evrensel küme

$$U = \{u_1, \dots, u_b\} \quad (4.1)$$

olsun. U 'nun elemanları aralıklardır. Bu aralıklar zaman serisinin tüm değerlerini kapsayan evrensel kümenin parçalanması ile elde edilir. U 'nun elemanlarına bağlı olarak A_i bulanık kümeleri,

$$A_i = f_{A_i}(u_1)/u_1 + \dots + f_{A_i}(u_b)/u_b \quad (4.2)$$

biçiminde tanımlanabilir. Burada f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonudur ve

$$f_{A_i} : U \rightarrow [0,1] \quad (4.3)$$

olmaktadır. $f_{A_i}(u_a)$, u_a 'nın A_i 'ye ait olmasının derecesidir (Song ve Chissom 1993a; Song ve Chissom 1993b; Song ve Chissom 1994).

$Y(t), t = \dots, 0, 1, 2, \dots$ reel değerli zaman serisi olsun. Zaman serisine uygun evrensel küme tanımı ve parçalanması yapıldıktan sonra A_i 'lerden oluşan yeni zaman serisi $F(t)$ 'ye bulanık zaman serisi adı verilir.

$F(t)$ bulanık zaman serisi hakkında yukarıdaki tanım gereğince şunlar söylenebilir,

1. $F(t)$ zamanın bir fonksiyonudur.

2. $F(t)$ bulanık kümeler tarafından temsil edilen dilsel değerlere sahip, dilsel değişkenler olarak ifade edilebilir (Song ve Chissom 1993a; Song ve Chissom 1993b; Song ve Chissom 1994).

Bulanık zaman serisinde ilişki için, $F(t)$ 'nin sadece $F(t-1)$ 'den etkilendiği düşünülürse bulanık zaman serisine birinci dereceden bulanık zaman serisi adı verilir. Birinci dereceden bulanık zaman serisi için bulanık ilişki

$$F(t) = F(t-1) * R(t, t-1) \quad (4.4)$$

şeklinde gösterilebilir. Bu ifadede * herhangi bir operatörü göstermektedir.

$$F(t-1) = A_i \quad (4.5)$$

ve

$$F(t) = A_j \quad (4.6)$$

olsun. Bu durumda bulanık mantık ilişki

$$A_i \rightarrow A_j \quad (4.7)$$

ile gösterilebilir. Buna göre birinci dereceden bulanık zaman serisi öngörü modeli

$$F(t-1) \rightarrow F(t) \quad (4.8)$$

şeklinde yazılır (Song ve Chissom 1993a; Song ve Chissom 1993b; Song ve Chissom 1994).

$F(t)$ bulanık zaman serisi iken eğer $F(t-1), F(t-2), \dots$, ve $F(t-n), F(t)$ 'ye neden oluyorsa bulanık mantık ilişki,

$$F(t-n), \dots, F(t-2), F(t-1) \rightarrow F(t). \quad (4.9)$$

olur. Bu ifadeye n. dereceden bulanık zaman serisi öngörü modeli adı verilir (Chen 2002).

F ve G iki bulanık zaman serisi olsun. $F(t-1) = A_i$, $G(t-1) = B_k$ ve $F(t) = A_j$ olsun. İki değişkenli bulanık mantık ilişki

$$A_i, B_k \rightarrow A_j \quad (4.10)$$

olarak gösterilir ve burada A_i, B_k ilişkinin sol yanı ve A_j bulanık mantık ilişkinin sağ yanı olarak isimlendirilir. Sonuç olarak birinci dereceden iki faktör (değişkenli) bulanık zaman serisi öngörü modeli,

$$F(t-1), G(t-1) \rightarrow F(t) \quad (4.11)$$

olarak gösterilir.

F ve G iki bulanık zaman serisi olsun. Eğer $F(t)$ bulanık zaman serisi $(F(t-1), G(t-1)), (F(t-2), G(t-2)), \dots, (F(t-n), G(t-n))$ gecikmeli bulanık zaman serilerinden etkileniyorsa bulanık mantık ilişki,

$$(F(t-1), G(t-1)), (F(t-2), G(t-2)), \dots, (F(t-n), G(t-n)) \rightarrow F(t) \quad (4.12)$$

şeklinde gösterilir ve iki faktör n. dereceden bulanık zaman serisi öngörü modeli olarak isimlendirilir. Burada $F(t)$ ve $G(t)$ sırasıyla ana faktör ve ikincil faktör bulanık zaman serileri olarak adlandırılır.

F ve $G_1, G_2, \dots, G_{k-1}$ k adet bulanık zaman serisi olsun. Eğer $F(t)$ bulanık zaman serisi $(F(t-1), G_1(t-1), G_2(t-1), \dots, G_{k-1}(t-1)), \dots,$

$(F(t-n), G_1(t-n), G_2(t-n), \dots, G_{k-1}(t-n))$ gecikmeli bulanık zaman serilerinden etkileniyorsa bulanık mantık ilişkisi

$$\left. \begin{array}{c} F(t-1), G_1(t-1), G_2(t-1), \dots, G_{k-1}(t-1) \\ \vdots \\ F(t-n), G_1(t-n), G_2(t-n), \dots, G_{k-1}(t-n) \end{array} \right\} \rightarrow F(t) \quad (4.13)$$

şeklinde gösterilir ve k faktör n . dereceden bulanık zaman serisi öngörü modeli olarak isimlendirilir. Burada $F(t)$ ve $G_i(t)$ sırasıyla ana faktör ve ikincil faktör bulanık zaman serileri olarak adlandırılır ($i = 1, 2, \dots, k-1$) (Jilani ve Burney 2008).

Literatürde sık kullanılan bazı bulanık zaman serisi çözüm yöntemleri aşağıda verilmiştir.

4.1. Song ve Chissom Yöntemi

Song ve Chissom (Song ve Chissom 1993b) bulanık zaman serilerinin öngörüsü için aşağıdaki adımlardan oluşan çözüm yöntemini önermişlerdir.

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,

$$U = [D_{\min} - D_1, D_{\max} + D_2] \quad (4.14)$$

şeklinde ve sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$U = \{u_1, u_2, \dots, u_b\} \quad (4.15)$$

olacak şekilde tanımlanır.

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

$$a_{jk} = \begin{cases} 1 & k = j \\ 0.5 & k = j-1, j+1, \\ 0 & d.d. \end{cases} \quad j = 1, 2, \dots, b \quad (4.16)$$

olmak üzere, bulanık kümeler,

$$A_j = a_{j1} / u_1 + a_{j2} / u_2 + \dots + a_{jb} / u_b, \quad j = 1, 2, \dots, b \quad (4.17)$$

olarak tanımlanır.

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 ilişkiler belirlenir.

Bu aşamada matris işlemlerinden yararlanılır. Bulanık ilişki $A_k \rightarrow A_l$ olduğunda bu ilişkiye karşılık gelen ilişki matrisi $R_l = A_k^T A_l$ ile elde edilir. Bu çarpım işleminde “min” operatörü kullanılır. Bulanık zaman serisi için birinci dereceden bulanık ilişkiyi ifade eden ilişki matrisi ise $R = \cup R_l$ olarak elde edilir.

Adım 5. Bulanık öngörüler elde edilir.

Bu aşamada bulanık öngörüler $\hat{F}(t)$ olmak üzere,

$$\hat{F}(t) = \max \left\{ \min \left\{ F(t-1) \circ R \right\} \right\} \quad (4.18)$$

ifadesi ile hesaplanır.

Adım 6. Durulaştırma aşaması

Bu yöntemde durulaştırma aşamasında üç farklı durum söz konusudur.

Durum 1. $\hat{F}(t) = \max \left\{ \min \left\{ F(t-1) \circ R \right\} \right\}$ ifadesi tek bir “en büyük” üyeliğe sahipse duru öngörü bu üyeliğe karşılık gelen aralığın orta noktası olacaktır.

Durum 2. $\hat{F}(t) = \max \left\{ \min \left\{ F(t-1) \circ R \right\} \right\}$ ifadesi birden fazla ve ardışık “en büyük” üyeliklere sahipse duru öngörü bu üyeliklere karşılık gelen aralıklarının orta noktalarının ortalaması olacaktır.

Durum 3. $\hat{F}(t) = \max \left\{ \min \left\{ F(t-1) \circ R \right\} \right\}$ ifadesi birden fazla ve ardışık olmayan “en büyük” üyeliklere sahipse duru öngörü tüm bu üyeliklerin standartlaştırılması ile elde edilir (Song ve Chissom 1993b).

4.2. Chen Yöntemi

Song ve Chissom tarafından önerilen yöntemlerde bulanık ilişki belirleme işlemi karmaşık matris operasyonlarına dayanmaktadır (Song ve Chissom 1993a; Song ve Chissom 1993b). Chen’in çalışmasında, bulanık ilişki belirleme, bulanık mantık grup ilişki tablolarına dayalı olarak yapılarak Song ve Chissom’un önerdiği yöntemler basitleştirilmiştir (Chen 1996). Chen’in çalışmasında önerilen yöntem birinci dereceden bulanık zaman serisi öngörü modeline dayalıdır (Chen 1996). Chen tarafından önerilen bu yöntem algoritma olarak adımlar halinde aşağıda verilmiştir.

Adım 1. Evrensel küme (U) ve alt aralıkları $(u_i, i = 1, 2, \dots, b)$ tanımlanır.

Evrensel kümenin başlangıç ve bitiş noktaları belirlenir. Bu noktalar zaman serisinin aldığı ve alabileceği mümkün değerleri kapsayacak şekilde seçilir. Daha

sonra uygun aralık uzunluğuna göre evrensel küme alt aralıklara parçalanır. Bu yöntemde aralık uzunluğunun belirlenmesi araştırmacıya bağlıdır. Belirlenecek aralık uzunluğunun alt aralık sayısı üzerinde etkili olduğu unutulmamalıdır.

$$U = [Baş., Bitiş] \quad (4.19)$$

Adım 2. Evrensel küme ve parçalanmalara bağlı olarak bulanık kümeler tanımlanır.

$$A_i = f_{A_i}(u_i)/u_i + \dots + f_{A_i}(u_b)/u_b \quad i = 1, 2, \dots, b \quad (4.20)$$

Adım 3. Gözlemler bulanıklaştırılır.

Her bir gözlemin bulunduğu alt aralık belirlenir. Belirlenen alt aralığın en yüksek üyelik değerine sahip olduğu bulanık küme belirlenir. Gözlemin bulanık değeri belirlenen bu bulanık kümedir.

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

Örneğin, bulanık mantık ilişkiler

$$A_1 \rightarrow A_2, A_1 \rightarrow A_1, A_1 \rightarrow A_3 \quad (4.21)$$

şeklinde iken, bulanık mantık grup ilişki

$$A_1 \rightarrow A_2, A_3, A_1 \quad (4.22)$$

şeklinde olmaktadır.

Adım 5. Öngörüler elde edilir.

Öngörü elde etmede birkaç durum söz konusudur. $F(t-1) = A_j$ olsun.

Durum 1: Bulanık grup ilişki tablosundan sadece $A_i \rightarrow A_j$ varsa öngörü A_j 'dir.

Durum 2: Bulanık grup ilişki tablosunda $A_i \rightarrow A_i, A_j, \dots, A_k$ ise öngörü $A_i, A_j, \dots, A_k$ 'dır.

Durum 3: Bulanık grup ilişki tablosunda $A_i \rightarrow Boş$ ise öngörü A_i 'dir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulaştırmada merkezileştirme yöntemi kullanılır. Adım 5'te belirtilen durum 1 ve 3 için bulanık öngörü A_j olduğunda durulaştırılmış öngörü, A_j bulanık kümesinde en yüksek üyelik değerine sahip olan u_j aralığının orta noktası olmaktadır. Durum 2 için ise bulanık öngörü $A_i, A_j, \dots, A_k$ olduğunda durulaştırılmış öngörü, her bir $A_i, A_j, \dots, A_k$ bulanık kümelerinin en yüksek üyelik değerine sahip olan $u_i, u_j, \dots, u_k$ aralıklarının orta noktalarının aritmetik ortalaması olarak elde edilir (Chen 1996).

4.3. Chen'in Yüksek Dereceli Bulanık Zaman Serisi Yöntemi

Chen, 2002 yılında yaptığı çalışmada öngörü elde etmede yüksek dereceli bulanık zaman serisi yaklaşımını önermiştir (Chen 2002). Chen tarafından verilen bu yöntemde yüksek dereceli modellerde tüm gecikmeli bulanık değişkenler bulunmaktadır. Başka bir ifadeyle, 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, Chen'in çalışmasında önerilen 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,

$$U = [D_{\min} - D_1, D_{\max} + D_2] \quad (4.23)$$

şeklinde ve sabit aralık uzunluğuna sahip u_i alt aralıkları,

$$U = \{u_1, u_2, \dots, u_b\} \quad (4.24)$$

olacak şekilde tanımlanır.

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

$$a_{jk} = \begin{cases} 1 & , k = j \\ 0.5 & , k = j-1, j+1 \\ 0 & , d.d. \end{cases} \quad , \quad j = 1, 2, \dots, b \quad (4.25)$$

olmak üzere, bulanık kümeler aşağıdaki gibi tanımlanır.

$$A_j = a_{j1} / u_1 + a_{j2} / u_2 + \dots + a_{jb} / u_b \quad , \quad j = 1, 2, \dots, b \quad (4.26)$$

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.

Örneğin, birinci dereceden bulanık mantık ilişkiler,

$$A_i \rightarrow A_j, \quad A_i \rightarrow A_i, \quad A_i \rightarrow A_k \quad (4.27)$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_i \rightarrow A_j, A_i, A_k \quad (4.28)$$

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

$$\begin{aligned} A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{j1} \\ A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{j2} \\ \vdots &\quad \quad \quad \vdots \\ A_{in}, A_{i(n-1)}, \dots, A_{i1} &\rightarrow A_{jp} \end{aligned} \quad (4.29)$$

şeklinde verilmişken, bulanık mantık grup ilişkisi,

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp} \quad (4.30)$$

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

$$A_{in}, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_j \quad (4.31)$$

ilişkisi mevcut ise bulanık öngörü, A_j olacaktır.

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

$$A_m, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_{j1}, A_{j2}, \dots, A_{jp} \quad (4.32)$$

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,

$$A_m, A_{i(n-1)}, \dots, A_{i1} \rightarrow A_j \quad (4.33)$$

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

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

$$A_m, A_{i(n-1)}, \dots, A_{i1} \rightarrow Boş \quad (4.34)$$

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

$$\frac{1 * m_m + 2 * m_{i(n-1)} + \dots + n * m_{i1}}{1 + 2 + \dots + n} \quad (4.35)$$

ifadesi ile elde edilir.

Adım 6. Durulaştırma işlemi uygulanır.

Durulařtırmada merkezileřtirme yntemi kullanılır. ngrlerin elde edilmesinde karřılařılan Durum 1 ve Durum 2 iin bulanık ngr A_j olarak elde edilmiřken, durulařtırılmıř ngr, A_j bulanık kmesinde en yksek yelik deęerine sahip olan u_j aralıęının orta noktası olacaktır. Durum 3 iin ise reel ngrnn, $A_{in}, A_{i(n-1)}, \dots, A_{i1}$ bulanık kmelerine baęlı olarak nasıl elde edildięi daha nce belirtilmiřtir (Chen 2002).

4.4. Yu ve Huarng'ın Sinir Aęı Tabanlı Bulanık Zaman Serisi Yntemi

Bu yntemin algoritmasının adımları ařaęıda sıralanmıřtır.

Adım 1. Fark:

Bu yntem, gzlemleri doęrudan kullanmak yerine her t ve $t-1$ anındaki ardı ardına gelen iki gzlem arasındaki farkları ngrmektedir:

$$d(t-1, t) = obs(t) - obs(t-1) \quad (4.36)$$

Adım 2. Ayarlama:

Farklar negatif hale gelebilir. Btn evrensel kmelerin pozitif olduęundan emin olmak iin farklı pozitif sabitler, farklı seriler iin bu farklara eklenir:

$$d'(t-1, t) = d(t-1, t) + const \quad (4.37)$$

Her seri iin, btn farkların minimum ve maksimumu $D_{\min}$ ve $D_{\max}$ elde edilir.

$$\begin{aligned} D_{\min} &= \min(d'(t-1, t)), \text{ her } t \text{ iin,} \\ D_{\max} &= \max(d'(t-1, t)), \text{ her } t \text{ iin,} \end{aligned} \quad (4.38)$$

Adım 3. Evrensel Kme:

U evrensel kümesi,

$$[D_{\min} - D_1, D_{\max} + D_2] \quad (4.39)$$

şeklinde tanımlanabilir. Burada D_1 ve D_2 iki belirlenmiş pozitif sayıdır. Aralık uzunluğu l olarak belirlendiğinde U eşit uzunlukta aralıklara ayrılır ve $u_1, u_2, u_3, \dots, u_k$ olarak isimlendirilir. Burada k aralıkların sayısıdır. u_i şu şekilde ifade edilir;

$$u_i = [D_{\min} - D_1 + (i-1)l, D_{\min} - D_1 + il] \quad i = 1, 2, \dots, k \quad (4.40)$$

Buna uygun orta nokta ise

$$m^i = D_{\min} - D_1 + \frac{(2i-1)l}{2} \quad i = 1, 2, \dots, k \quad (4.41)$$

Adım 4. Bulanıklaştırma:

$d'(t-1, t)$, $V(t-1, t)$ şeklinde bir üyelik dereceleri kümesine bulanıklaştırılabilir,

$$V(t-1, t) = [\mu_{t-1,t}^1, \mu_{t-1,t}^2, \dots]. \quad (4.42)$$

Adım 5. Sinir Ağı Eğitimi:

Bu yöntem, öngörü sonuçlarını geliştirmek için, bulanık ilişki kurmakta bütün üyelik derecelerini kullanır. İki ardı ardına gelen V' 'ler bir bulanık ilişkiyi oluşturmak için şu şekilde kullanılabilir:

$$V(t-1, t) \rightarrow V(t, t+1) \quad (4.43)$$

Bulanık ilişkileri oluşturmak için sonrasında geriye yayılım sinir ağları uygulanır. Sinir ağı mimarisi, bir girdi katmanı, bir gizli katman ve bir çıktı katmanı içerir. Girdi ve çıktı düğümlerinin sayısı $V(t-1, t)$ 'deki üyelik dereceleri sayısına eşittir. Gizli düğüm sayısı girdi ve çıktı düğümleri sayısı toplamı olarak ifade edilir.

Adım 6. Sinir Ağı Öngörüsü:

Sinir ağı eğitilerek $V(t-1, t)$ ile $V(t, t+1)$ 'in öngörüsü gerçekleştirilir.

Adım 7. Durulaştırma:

Ağırlıklandırılmış ortalamalar yöntemi, üyelik derecelerini durulaştırmada uygulanır:

$$fd(t-1, t) = \frac{\sum_{k=1}^{\mu_{t-1,t}^k} \mu_{t-1,t}^k m^k}{\sum_{k=1}^{\mu_{t-1,t}^k} \mu_{t-1,t}^k}, \quad (4.44)$$

Burada $fd(t-1, t)$, $t-1$ ve t arasındaki öngörölmüş farktır, $\mu_{t-1,t}^k$ öngörölmüş üyelik derecelerini ifade eder ve m^k , $\mu_{t-1,t}^k$ aralığına uygun orta noktasını gösterir.

Adım 8. Öngörü:

$t-1$ ve t arasında öngörölmüş fark elde edilince, t için öngörü;

$$fd'(t-1, t) = fd(t-1, t) - const, \quad (4.45)$$

$$forecast(t) = fd'(t-1, t) + obs_{t-1}. \quad (4.46)$$

şeklinde hesaplanabilir (Yu ve Huarng 2010).

5. GELİŞTİRİLEN ve ÖNERİLEN YÖNTEMLER

Bu bölümde ilk olarak daha önce ifade edildiği gibi sahip olduğu özelliklerden dolayı en etkili yöntemlerden Yu ve Huarng'ın (2010) sinir ağı tabanlı bulanık zaman serisi öngörü yöntemini temel alarak geliştiren **tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için yeni bir yaklaşım** önerilmiştir. Ardından ikinci olarak yine tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için hem YSA kullanan bulanık zaman serisi öngörü yöntemlerine alternatif hem de bulanık zaman serisi öngörü yöntemleri içinde iyi sonuçların elde edildiği **yeni bir sinir ağı tabanlı bulanık zaman serisi öngörü yöntemi** önerilmiştir.

5.1. Sinir Ağı Tabanlı Bulanık Zaman Serilerinin Öngörüsünde Yu ve Huarng Yöntemi Üzerine Yeni bir Yaklaşım

Bu yaklaşım, Yu ve Huarng'ın algoritmasını (Yu ve Huarng 2010) temel almakla birlikte bazı değişiklikler ve yenilemelere sahiptir ve şu şekilde özetlenebilir:

Adım 1. Fark ve Ayarlama:

Bu yöntem, gözlemleri doğrudan kullanmak yerine her t ve $t-1$ anındaki ardı ardına gelen iki gözlem arasındaki farkları öngörmektedir:

$$d(t-1, t) = obs(t) - obs(t-1) \quad (5.1)$$

Burada $obs(t)$ ve $obs(t-1)$, t ve $t-1$ anında iki ardı ardına gelen gözlemlerdir.

Farklar negatif hale gelebilir. Bütün evrensel kümelerin pozitif olduğundan emin olmak için farklı pozitif sabitler, farklı yıllar için bu farklara eklenir:

$$d'(t-1, t) = d(t-1, t) + const \quad (5.2)$$

Her yıl için, bütün farkların minimumu ve maksimumu olan $D_{\min}$ ve $D_{\max}$ elde edilir.

$$\begin{aligned} D_{\min} &= \min(d'(t-1, t)), \text{ her } t \text{ için,} \\ D_{\max} &= \max(d'(t-1, t)), \text{ her } t \text{ için,} \end{aligned} \quad (5.3)$$

Adım 2. Evrensel Küme:

U evrensel kümesi, $[D_{\min} - D_1, D_{\max} + D_2]$ şeklinde tanımlanabilir. Burada D_1 ve D_2 iki belirlenmiş pozitif sayıdır. Aralık uzunluğu l olarak belirlendiğinde U eşit uzunlukta aralıklara ayrılır ve $u_1, u_2, u_3, \dots, u_k$ olarak isimlendirilir. Burada k aralıkların sayısıdır. u_i şu şekilde ifade edilir;

$$u_i = [D_{\min} - D_1 + (i-1)l, D_{\min} - D_1 + il] \quad i = 1, 2, \dots, k \quad (5.4)$$

Buna uygun orta nokta ise

$$m^i = D_{\min} - D_1 + \frac{(2i-1)l}{2} \quad i = 1, 2, \dots, k \quad (5.5)$$

Bulanık kümelerin sözel (dilsel) değerleri tanımlanır. $A_1, A_2, A_3, \dots$ sözel değerler olsun ve bütün bulanık kümeler olası $u_1, u_2, u_3, \dots$ sözel değerleri ile etiketlensin.

Bu adımda, dağılım tabanlı uzunluk olarak ifade edilen Huarng'ın yaklaşımı (Huarng 2001b), aralık uzunluğunu belirlemek için kullanılmıştır. Çünkü Huarng çalışmasında, TAIFEX (Tayvan Borsası) ve Alabama Üniversitesi kayıtlarını öngörmek için evrensel küme parçalanmasında iki çeşit aralık yöntemi

tanımlamıştır. Huarng aralık uzunluğunun öngörü doğruluk oranını etkilediğine dikkat çekmiştir (Memmedli ve Ozdemir 2010). Huarng'ın modelinde, iki farklı aralık uzunluğu Chen'in modeline uygulanmıştır ve bu dağılım tabanlı ve ortalama tabanlı uzunlukların öngörü doğruluğunu geliştirdiği sonucuna çeşitli çalışmalarda ulaşılmıştır (Haykin 1999; Khashei ve ark. 2008; Yu 2005). Dağılım tabanlı uzunluk, verinin birinci farklarının dağılımına göre hesaplanır. Algoritması aşağıdaki gibi özetlenebilir:

Adım 1. Birinci farklar şeklinde A_{t+1} ve A_t arasındaki bütün mutlak farklar ve birinci farkların ortalaması hesaplanır.

Adım 2. Ortalamaya göre, Çizelge 5.1'e uygun olarak aralık uzunluğu için tabana karar verilir.

Çizelge 5.1. Taban haritalama çizelgesi

Aralık	Taban
0.1-1.0	0.1
1.1-10	1
11-100	10
101-1000	100

Adım 3. Birinci farkların kümülatif dağılımı grafikte çizilir. Adım 2'de kararlaştırılan taban aralık olarak kullanılır.

Adım 4. Adım 2'de kararlaştırılan tabana göre, birinci farkların en az yarısından daha küçük olan en büyük aralık, aralık uzunluğu olarak seçilir.

Adım 3. Bulanıklaştırma:

$d'(t-1, t)$, $V(t-1, t)$ şeklinde bir üyelik dereceleri kümesine bulanıklaştırılabilir,

$$V(t-1, t) = [\mu_{t-1, t}^1, \mu_{t-1, t}^2, \dots]. \quad (5.6)$$

Burada μ , 4. bölümde 4.3 denkleminde yer alan f 'e eşittir.

$const$, $D_{\min}$, $D_{\max}$, D_1 , D_2 , U ve l belirlendikten sonra k olarak ifade edilen aralık sayısı, U ve l 'ye göre bulunabilir. $A_1, A_2, A_3, \dots, A_k$ şeklinde gösterilen bulanık kümelerin sözel değerleri hesaplanabilir. Ardından, bütün $V(t-1, t)$ 'ler bulunabilir. Bütün $V(t-1, t)$ 'leri bulan algoritma Ek-1'de verilmiştir.

Adım 4. Sinir Ağı Eğitimi ve Öngörüsü:

Öngörü sonuçlarını geliştirmek için, önerilen yaklaşım bulanık ilişkileri oluşturmada bütün üyelik derecelerini kullanmaktadır. İki ardı ardına gelen V 'ler bir bulanık ilişki oluşturmada kullanılabilir:

$$V(t-1, t) \rightarrow V(t, t+1). \quad (5.7)$$

Bulanık ilişkileri oluşturmada (veya eğitim) geriye yayılım sinir ağları uygulanmaktadır. Bir girdi katmanına, bir veya daha fazla gizli katmana ve bir çıktı katmanına sahiptir. Girdi ve çıktı düğümlerinin sayısı $V(t-1, t)$ 'deki üyelik derecelerinin sayısına eşittir. Gizli düğümlerin sayısı sinir ağlarının performansına göre kararlaştırılır. $V(t-1, t)$ ile eğitilmiş sinir ağı vasıtasıyla $V(t, t+1)$ 'in öngörüsüne devam edilebilir. Eğer örnek içi (in-sample) gözlemler kullanılırsa, sonuçlar örnek içi tahmininkilere ait olur. Eğer örnek dışı (out-of-sample) gözlemler kullanılırsa, sonuçlar örnek dışı öngörününlere ait olur.

Adım 5. Durulaştırma:

Ağırlıklandırılmış ortalamalar yöntemi, üyelik derecelerini durulaştırmada uygulanır:

$$fd(t-1, t) = \frac{\sum_{k=1}^{\mu_{t-1,t}^k} \mu_{t-1,t}^k m^k}{\sum_{k=1}^{\mu_{t-1,t}^k}}, \quad (5.8)$$

Burada $fd(t-1, t)$, $t-1$ ve t arasındaki öngörölmüş farktır, $\mu_{t-1,t}^k$ öngörölmüş üyelik derecelerini ifade eder ve m^k , $\mu_{t-1,t}^k$ aralığına uygun orta noktasını gösterir.

Adım 6. Öngörü:

$t-1$ ve t arasında öngörölmüş fark elde edilince, t için öngörü,

$$fd'(t-1, t) = fd(t-1, t) - const, \quad (5.9)$$

$$forecast(t) = fd'(t-1, t) + obs_{t-1}. \quad (5.10)$$

şeklinde hesaplanabilir.

Performans değeriendirilmesi için hata kareler ortalaması (HKO) aşağıdaki gibi hesaplanır:

$$HKO = \frac{\sum_{t=k+1}^n (forecast(t) - obs(t))^2}{n-k}, \quad (5.11)$$

Burada k örnek içini içeren ve $n-k$ örnek dışını içeren gözlemler olmak üzere n adet gözlem vardır (Memmedli ve Ozdemir 2012).

5.2. Sinir Ağı Tabanlı Bulanık Zaman Serilerinin Öngörüsünün Geliştirilmesi için Yeni bir Yöntem

Bu kesimde tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için iyi sonuçların elde edildiği yeni bir sinir ağı tabanlı bulanık zaman serisi öngörü yöntemi önerilmiştir. 5.1 kesiminde ifade edilen yaklaşımdan farklı olarak ağırlıklandırılmış indis değerlerinin kullanımıyla 3 adım daha eklenmiş ve daha iyi sonuçlar elde edilmiştir.

Bu yeni yöntem şu şekilde özetlenebilir:

Adım 1. Fark ve Ayarlama:

Bu yöntem, gözlemleri doğrudan kullanmak yerine her t ve $t-1$ anındaki ardı ardına gelen iki gözlem arasındaki farkları öngörmektedir:

$$d(t-1, t) = obs(t) - obs(t-1) \quad (5.12)$$

Burada $obs(t)$ ve $obs(t-1)$, t ve $t-1$ anında iki ardı ardına gelen gözlemlerdir.

Farklar negatif hale gelebilir. Bütün evrensel kümelerin pozitif olduğundan emin olmak için farklı pozitif sabitler, farklı yıllar için bu farklara eklenir:

$$d'(t-1, t) = d(t-1, t) + const \quad (5.13)$$

Her yıl için, bütün farkların minimumu ve maksimumu olan $D_{\min}$ ve $D_{\max}$ elde edilir.

$$\begin{aligned} D_{\min} &= \min(d'(t-1, t)), \text{ her } t \text{ için,} \\ D_{\max} &= \max(d'(t-1, t)), \text{ her } t \text{ için,} \end{aligned} \quad (5.14)$$

Adım 2. Evrensel Küme:

U evrensel kümesi,

$$[D_{\min} - D_1, D_{\max} + D_2] \quad (5.15)$$

şeklinde tanımlanabilir. Burada D_1 ve D_2 iki belirlenmiş pozitif sayıdır. Aralık uzunluğunu l olarak belirlediğimizde U eşit uzunlukta aralıklara ayrılır ve $u_1, u_2, u_3, \dots, u_k$ olarak isimlendirilir. Burada k aralıkların sayısıdır. u_i şu şekilde ifade edilir;

$$u_i = [D_{\min} - D_1 + (i-1)l, D_{\min} - D_1 + il] \quad i = 1, 2, \dots, k \quad (5.16)$$

Buna uygun orta nokta ise

$$m^i = D_{\min} - D_1 + \frac{(2i-1)l}{2} \quad i = 1, 2, \dots, k \quad (5.17)$$

Bulanık kümelerin sözel değerleri tanımlanır. $A_1, A_2, A_3, \dots$ sözel değerler olsun ve bütün bulanık kümeler olası $u_1, u_2, u_3, \dots$ sözel değerleri ile etiketlensin.

Bu adımda, dağılım tabanlı uzunluk olarak ifade edilen aralık uzunluğunu belirlemekte kullanılan Huarng'ın yaklaşımını (Huarng 2001b) kullandık. Huarng çalışmasında, TAIFEX (Tayvan Borsası) ve Alabama Üniversitesi kayıtlarını öngörmek için evrensel küme parçalanmasında iki çeşit aralık yöntemi tanımlamıştır. Huarng aralık uzunluğunun öngörü doğruluk oranını etkilediğine dikkat çekmiştir. Huarng'ın modelinde, iki farklı aralık uzunluğu Chen'in modeline uygulanmıştır ve bu dağılım tabanlı ve ortalama tabanlı uzunlukların öngörü doğruluğunu geliştirdiği sonucuna çeşitli çalışmalarda ulaşılmıştır (Haykin 1999; Khashei ve ark. 2008; Yu 2005). Dağılım tabanlı uzunluk, verinin birinci farklarının dağılımına göre hesaplanır. Algoritması aşağıdaki gibi özetlenebilir:

Adım 1. Birinci farklar şeklinde A_{t+1} ve A_t arasındaki bütün mutlak farklar ve birinci farkların ortalaması hesaplanır.

Adım 2. Ortalamaya göre, Çizelge 5.1'e uygun olarak aralık uzunluğu için tabana karar verilir.

Adım 3. Birinci farkların kümülatif dağılımı grafikte çizilir. Adım 2'de kararlaştırılan taban aralık olarak kullanılır.

Adım 4. Adım 2'de kararlaştırılan tabana göre, birinci farkların en az yarısından daha küçük olan en büyük aralık, aralık uzunluğu olarak seçilir.

Adım 3. Bulanıklaştırma:

$d'(t-1, t)$, $V(t-1, t)$ şeklinde bir üyelik dereceleri kümesine bulanıklaştırılabilir,

$$V(t-1, t) = [\mu_{t-1, t}^1, \mu_{t-1, t}^2, \dots] \quad (5.18)$$

Burada μ , 1. denklemde yer alan ve önceden tanımlanmış f 'e eşittir.

$const$, $D_{\min}$, $D_{\max}$, D_1 , D_2 , U ve l 'yi belirledikten sonra k olarak ifade edilen aralık sayısı U ve l 'ye göre bulunabilir. Sonrasında, $A_1, A_2, A_3, \dots, A_k$ şeklinde gösterilen bulanık kümelerin sözel değerleri hesaplanabilir. Ardından, bütün $V(t-1, t)$ 'ler bulunabilir. Bütün $V(t-1, t)$ 'leri bulan algoritma Ek-1'de verilmiştir.

Adım 4. Ağırlıklandırılmış İndislerin Bulunması:

Bulanıklaştırma aşamasında ilk olarak Chen'in (Chen 2002) yönteminde bulanık kümelerin indislerinin kullanımı söz konusudur. Sinir ağı için girdi ve

çıktı belirlemede örneğin ikinci dereceden bulanık zaman serisi için $F(t)$ 'nin $F(t-1)$ ve $F(t-2)$ gecikmeli değişkenlerinden etkilendiği düşünüldüğünde girdilerin $F(t-1)$ ve $F(t-2)$ olacağı, çıktının ise $F(t)$ olacağı görülmektedir. Bu aşamada her bir serinin indisleri kullanılmaktadır. Bulanıklaştırma aşamasında her bir veriyi temsilen oluşturulan üyelik dereceleri kümesi yerine Chen'in (Chen 2002) yönteminde maksimum üyelik derecesinin bulunduğu bulanık kümenin indisleri kullanılmaktadır. Bu aşamada sinir ağı tabanlı bulanık zaman serilerinde herhangi bir kullanım söz konusu değildir. İlk olarak bu aşamada kullanılmak üzere maksimum üyelik derecesi yerine veriyi daha iyi temsil eden ve bütün üyelik derecelerinin kullanımı sağlayan ağırlıklandırılmış ortalamalar yöntemi yardımıyla Chen (Chen 2002) yönteminde olduğu gibi bulanık kümeler yerine indisleri temsilen ağırlıklandırılmış indis değerleri belirlenecek ve kullanılacaktır.

$$a_t = \frac{\sum_{k=1} \mu^k k}{\sum_{k=1} \mu^k}, \quad (5.19)$$

Burada a_t , t anındaki veri için elde edilen ağırlıklı indis değeri, μ^k bulanıklaştırma sonucu elde edilen üyelik derecelerini ifade eder ve k , bulanık küme sayısını gösterir.

Adım 5. Sinir Ağı Eğitimi ve Öngörüsü:

Sinir ağı için girdi ve çıktı belirlemede örneğin ikinci dereceden bulanık zaman serisi için $F(t)$, $F(t-1)$ ve $F(t-2)$ gecikmeli değişkenlerinden etkilendiğinde girdiler, $F(t-1)$ ve $F(t-2)$ serilerine ait ağırlıklandırılmış indisler olur, çıktının ise $F(t)$ serisine ait ağırlıklandırılmış indis değerleridir.

Sonrasında bu yöntem bulanık ilişkileri oluşturmada (veya eğitim) ifade edilen sinir ağı mimarisini uygulamaktadır. Gizli düğümlerin sayısı sinir ağlarının performansına göre kararlaştırılır.

Adım 6. Çıktı İndislerinin Üyelik Derecelerine Ayrılması:

Durulaştırma aşamasından önce sinir ağı eğitimi ve öngörüsü ile elde edilen ağırlıklandırılmış çıktı indis değerlerin üyelik derecelerine ayrılması gerekir. Bu aşamada aşağıdaki algoritma kullanılır:

Adım 1. Elde edilen değerler için yuvarlama işlemi yapılır. 0.5'in üstü üstteki tam sayıya, altı ise alttaki tam sayıya yuvarlanır. Çıktı oi ile, yuvarlama işlemi sonucu om ile gösterilir.

Örnek:

$oi = 3.42$ ise $om = 3$ veya $oi = 4.68$ ise $om = 5$ şeklindedir.

Adım 2. Elde edilen om değeri üyelik derecesi 1 olan bulanık kümenin numarasını verir. k bulanık küme sayısını vermek üzere ilgili bulanık kümeler ve çıktıya ait üyelik dereceleri aşağıdaki gibidir:

A_1	A_2	...	A_{om-1}	A_{om}	A_{om+1}	...	A_k
0	0	0	md	1	$1-md$	0	0

Burada md üyelik derecesi aşağıdaki formül yardımıyla bulunur.

$$md = om - oi + 0.5 \quad (5.20)$$

Adım 3. Adım1-2 her çıktı değeri için tekrarlanır ve bütün bulanık kümeler için her çıktıya ait üyelik dereceleri elde edilir.

Adım 7. Durulaştırma:

Ağırlıklandırılmış ortalamalar yöntemi, üyelik derecelerini durulaştırmada uygulanır:

$$fd(t-1, t) = \frac{\sum_{k=1}^{\mu_{t-1,t}^k} \mu_{t-1,t}^k m^k}{\sum_{k=1}^{\mu_{t-1,t}^k} \mu_{t-1,t}^k}, \quad (5.21)$$

Burada $fd(t-1, t)$, $t-1$ ve t arasındaki öngörölmüş farktır, $\mu_{t-1,t}^k$ öngörölmüş üyelik derecelerini ifade eder ve m^k , $\mu_{t-1,t}^k$ aralığına uygun orta noktasını gösterir.

Adım 8. Öngörü:

$t-1$ ve t arasında öngörölmüş fark elde edilince, t için öngörü aşağıdaki gibi hesaplanabilir:

$$fd'(t-1, t) = fd(t-1, t) - const, \quad (5.22)$$

$$forecast(t) = fd'(t-1, t) + obs_{t-1}. \quad (5.23)$$

Performans değeriendirilmesi için hata kareler ortalaması (HKO) aşağıdaki gibi hesaplanır:

$$HKO = \frac{\sum_{t=k+1}^n (forecast(t) - obs(t))^2}{n-k}, \quad (5.24)$$

Burada k örnek içini içeren ve $n-k$ örnek dışını içeren gözlemler olmak üzere n adet gözlem vardır

6. VERİ SETLERİ ÜZERİNDE UYGULAMALAR

Sinir ağı tabanlı bulanık zaman serisi modelleri, bulanık zaman serisi öngörüsünü geliştirmekte ve çeşitli problemleri çözmekte kullanılmaktadır. Bu bölümde, yapay sinir ağlarını kullanarak bulanık ilişki belirlemede bütün üyelik derecelerinin ayarlanmasıyla algoritmasıyla birlikte sinir ağı tabanlı bulanık zaman serisi öngörüsünü geliştirmek için Yu ve Huarng'ın yöntemini (Yu ve Huarng 2010) temel alan **yeni bir yaklaşım** ve **yeni bir yöntem** uygulanmıştır. Önerilen yöntem ile bütün üyelik derecelerinin ayarlanmasında ağırlıklandırılmış ortalamalar yöntemi, indisler için ilk defa bu çalışmada kullanılmıştır. Aralık uzunluğu belirlemede dağılım tabanlı uzunluk yaklaşımı kullanılmıştır. Öngörü performansını geliştirmek için çok katmanlı algılayıcı (ÇKA), radyal tabanlı fonksiyon sinir ağı (RTFSA) ve genelleştirilmiş regresyon sinir ağı (GRSA) mimarileri uygulanmıştır.

Önerilen yaklaşım ve yöntemin etkinliği için literatürde bir çok çalışmada sıklıkla kullanılan Alabama Üniversitesi kayıt verisi ile ulusal ve uluslararası boyutta geniş bir veri seti olarak İ.M.K.B. ulusal-100 endeksi verileri ele alınmıştır. Bütün uygulamalarda STATISTICA programı ve Microsoft Excel programları kullanılmıştır.

6.1. Uluslararası Boyutta Sık Kullanılan Alabama Üniversitesi Kayıt Verisi Üzerinde Uygulama

Önerilen yaklaşım ve yöntem, öncelikle Çizelge 6.1'de verilen Alabama Üniversitesi kayıt verisi ile incelenmiştir.

Çizelge 6.1. Kayıt verisi

Yıllar	Kayıt Sayısı	Yıllar	Kayıt Sayısı
1971	13055	1982	15433
1972	13563	1983	15497
1973	13867	1984	15145
1974	14696	1985	15163
1975	15460	1986	15984
1976	15311	1987	16859
1977	15603	1988	18150
1978	15861	1989	18970
1979	16807	1990	19328
1980	16919	1991	19337
1981	16388	1992	18876

Bu veri, sayı açısından az olmasına karşın aslında metodolojinin etkinliğini vurgulamakta yeterli olabilmektedir çünkü Song ve Chissom (1993a), Song ve Chissom (1993b), Song ve Chissom (1994), Chen (1996), Huarng (2001a), Huarng (2001b), Huarng ve Yu (2006), Hwang ve ark. (1998) ve Sullivan ve Woodall (1994) gibi birçok önemli çalışma bulanık zaman serisi öngörüsü için çok az gözlem kullanmıştır ve literatürde önerilmiş diğer yöntemlerle kolaylıkla sonuçları karşılaştırmak için bu zaman serisi ele alınmıştır.

Bu kesimde ele alınan veri seti için, öncelikle 5.2 kesiminde önerilen yöntem ele alınmış ve adım adım uygulanmıştır. İlk olarak, bütün farklar bulunmuştur. Bütün farkların minimumu Çizelge 6.2’de görüldüğü gibi -955 olduğundan negatiften kurtulmak için 1000 değeri sabit olarak alınmıştır.

Çizelge 6.2. Önerilen yöntemde 1. veri seti için $obs(t)$ ve $obs(t-1)$ farkları

$obs(t)$	$obs(t-1)$	$d(t-1, t)$
13055	-	-
13563	13055	508
13867	13563	304
14696	13867	829
15460	14696	764
15311	15460	-149
15603	15311	292
15861	15603	258
16807	15861	946
16919	16807	112
16388	16919	-531
15433	16388	-955
15497	15433	64
15145	15497	-352
15163	15145	18
15984	15163	821
16859	15984	875
18150	16859	1291
18970	18150	820
19328	18970	358
19337	19328	9
18876	19337	-461

Bütün farklara bu sabit eklenir. Bütün farklar için minimum ve maksimum $D_{\min} = 45(-955+1000)$, $D_{\max} = 2291(1291+1000)$ olarak belirlendikten sonra $D_1 = 45$ ve $D_2 = 9$ (Alt sınır ve üst sınıra tamamlanır) şeklinde alınır. Ardından Huarng'ın yaklaşımına göre aralık uzunluğu belirlenir. Huarng'ın yaklaşımına göre aralık uzunluğunu belirlemek için,


Adım 1. Birinci farklar şeklinde A_{i+1} ve A_i arasındaki bütün mutlak farklar ve birinci farkların ortalaması hesaplanır. Bu Çizelge 6.3'de gösterilmiştir.

Çizelge 6.3. Önerilen yöntemde 1. veri seti için mutlak farklar

A_i	Mutlak farklar (A_{i+1} ve A_i)	A_i	Mutlak farklar (A_{i+1} ve A_i)
1508	204	1064	416
1304	525	648	370
1829	65	1018	803
1764	913	1821	54
851	441	1875	416
1292	34	2291	471
1258	688	1820	462
1946	834	1358	349
1112	643	1009	470
469	424	539	
45	1019	Ort.	480.05

Adım 2. Ortalamaya göre, Çizelge 5.1'e uygun olarak aralık uzunluğu için tabana karar verilir. 480.05 ortalamaya göre aralık uzunluğu için taban 100 alınır.

Adım 3. Birinci farkların kümülatif dağılımı grafikte çizilir. Adım 2'de kararlaştırılan taban aralık olarak kullanılır. Birinci farkların kümülatif dağılımı Şekil 6.1'de gösterilmiştir.



Şekil 6.1. Önerilen yöntemde 1. veri seti için birinci farkların kümülatif dağılımı

Adım 4. Adım 2’de kararlaştırılan tabana göre, birinci farkların en az yarısından daha küçük olan en büyük aralığı aralık uzunluğu olarak seç. Dağılımdan, 400’den daha az 6 birinci fark vardır. 500 olunca bu sayı 13’e çıkmaktadır. Dolayısıyla 400, birinci farkların en az yarısından daha küçük en büyük aralıktır. Sonuçta, 400 aralık uzunluğu olarak belirlenir.

400 için, evrensel küme $U = [0, 2400]$ olarak belirlenir. U eşit aralıklara ayrılır ve bütün farklar üyelik derecelerine bulanıklaştırılır. Örneğin, birinci fark 1508, izleyen denklemdeki gibi üyelik derecesine bulanıklaştırılabilir:

$$V(1971, 1972) = (0.00 \quad 0.00 \quad 0.23 \quad 1.00 \quad 0.77 \quad 0.00) \quad (6.1)$$

Çizelge 6.4, bütün farklar için uygun üyelik derecelerini listelemektedir.

Çizelge 6.4. Önerilen yöntemde 1. veri seti farkları için üyelik dereceleri

$t-1$	$d'(t-1, t)$	A_1	A_2	A_3	A_4	A_5	A_6
1971	1508	0,00	0,00	0,23	1,00	0,77	0,00
1972	1304	0,00	0,00	0,74	1,00	0,26	0,00
1973	1829	0,00	0,00	0,00	0,43	1,00	0,57
1974	1764	0,00	0,00	0,00	0,59	1,00	0,41
1975	851	0,00	0,87	1,00	0,13	0,00	0,00
1976	1292	0,00	0,00	0,77	1,00	0,23	0,00
1977	1258	0,00	0,00	0,86	1,00	0,15	0,00
1978	1946	0,00	0,00	0,00	0,14	1,00	0,87
1979	1112	0,00	0,22	1,00	0,78	0,00	0,00
1980	469	0,83	1,00	0,17	0,00	0,00	0,00
1981	45	1,00	0,11	0,00	0,00	0,00	0,00
1982	1064	0,00	0,34	1,00	0,66	0,00	0,00
1983	648	0,38	1,00	0,62	0,00	0,00	0,00
1984	1018	0,00	0,46	1,00	0,55	0,00	0,00
1985	1821	0,00	0,00	0,00	0,45	1,00	0,55
1986	1875	0,00	0,00	0,00	0,31	1,00	0,69
1987	2291	0,00	0,00	0,00	0,00	0,27	1,00
1988	1820	0,00	0,00	0,00	0,45	1,00	0,55
1989	1358	0,00	0,00	0,61	1,00	0,40	0,00
1990	1009	0,00	0,48	1,00	0,52	0,00	0,00
1991	539	0,65	1,00	0,35	0,00	0,00	0,00

5.2 kesiminde önerilen yöntemde 3. adıma uygun olarak yapılan bulanıklaştırma işleminden sonra sınır ağı eğitimi ve öngörüsü için ağırlıklandırılmış indisler bulunur. Elde edilen üyelik dereceleri için ağırlıklandırılmış indis değerleri Çizelge 6.5’de verilmiştir.

Çizelge 6.5. Önerilen yöntemde 1. veri seti için ağırlıklandırılmış indis değerleri

$d'(t-1, t)$	a_t
1508	4,27
1304	3,76
1829	5,07
1764	4,91
851	2,63
1292	3,73
1258	3,65
1946	5,37
1112	3,28
469	1,67
45	0,61
1064	3,16
648	2,12
1018	3,05
1821	5,05
1875	5,19
2291	3,68
1820	5,05
1358	3,90
1009	3,02
539	1,85

En yüksek üyelik derecesi sahip olan bulanık kümenin indisi değil ağırlıklı olarak hesaplanan indisler, girdiler ve hedefi oluşturmaktadır. Bulanık zaman serilerinde örnek olarak ilk 10 gözlem için ikinci dereceden bulanık zaman serisi için notasyon çizelgesi Çizelge 6.6’de verilmiştir.

Alabama Üniversitesi kayıt verisi için birinci dereceden ve tek değişkenli sinir ağı tabanlı bulanık zaman serisi ele alınmıştır. Ancak indisler bazından yöneme uygun olarak daha yüksek dereceden gecikmeler dikkate alınarak işlem yapılmıştır.

Çizelge 6.6. Önerilen yöntemde 1. veri seti için ikinci dereceden bulanık zaman serisi notasyon çizelgesi

Gözlem no.	$F(t-2)$	$F(t-1)$	$F(t)$	Girdi-1	Girdi-2	Hedef
1	-	-	A_4	-	-	-
2	-	A_4	A_4	-	-	-
3	A_4	A_4	A_5	4,27	3,76	5,07
4	A_4	A_5	A_5	3,76	5,07	4,91
5	A_5	A_5	A_3	5,07	4,91	2,63
6	A_5	A_3	A_4	4,91	2,63	3,73
7	A_3	A_4	A_4	2,63	3,73	3,65
8	A_4	A_4	A_5	3,73	3,65	5,37
9	A_4	A_5	A_3	3,65	5,37	3,28
10	A_5	A_3	A_2	5,37	3,28	1,67

Sinir ağı eğitimi ve öngörüsü için Çizelge 6.6’da yer alan girdiler ve hedef dışında birinci, üçüncü, dördüncü ve beşinci dereceden sinir ağı tabanlı bulanık zaman serileri için de çıktı indisler bulunur. Bu değerler adım 6’daki gibi üyelik derecelerine ayrılır ve durulaştırma aşaması gerçekleştirilir.

Durulaştırma işleminden sonra, bütün durulaştırılmış öngörü değerleri ve HKO değerleri hesaplanır. En iyi sonuç 1-20-3-1 yapısına sahip iki gizli katmanlı ÇKA sinir ağı mimarisiyle elde edilmiştir ve HKO değeri 44049’dur. Önerilen yöntem için en iyi 3 HKO değeri hesaplanan her derece için Çizelge 6.7’de verilmiştir.

Çizelge 6.7. Önerilen yöntem için sonuçlar

HKO değerleri				
1. Derece	2. Derece	3. Derece	4. Derece	5. Derece
44049	77239	246431	204253	100048
65543	106837	247739	311361	169955
126931	117639	300939	820130	195485

Çizelge 6.8. Önerilen yöntemde 1. veri seti için sonuçların karşılaştırılması

Yöntem	HKO
Song ve Chissom(1993)	412499
Song ve Chissom(1994)	775687
Sullivan ve Woodall (1994)	386055
Chen(1996)	407507
Hwang vd. (1998)	278919
Huarng (2001)	78792 ^a
	124707 ^b
Chen (2002)	86694
Aladag vd. (2009) –Matlab	78073
Yu ve Huarng (2010)	247461
Tsaur vd. (2005)	134923
Li ve Chen (2004)	173459
Li ve Cheng (2007)	85040
Egrioglu vd.(2009)-Matlab	66661
Egrioglu vd. (2010) –Matlab	60714
Önerilen yöntem	44049

^a Ortalama tabanlı uzunluk

^b Dağılım tabanlı uzunluk

Song ve Chissom (1993a), Song ve Chissom (1994), Sullivan ve Woodall (1994), Chen (1996), Hwang ve ark. (1998), Chen (2002), Huarng (2001b), Aladağ ve ark. (2009), Yu ve Huarng (2010), Tsaur ve ark. (2005), Li ve Chen (2004), Li ve Cheng (2007), Eğrioglu ve ark. (2009) ve Eğrioglu ve ark. (2010) şeklinde literatürde önerilmiş diğer yöntemlerin HKO değerleri ve ayrıca önerilen yöntemin HKO değeri Çizelge 6.8’de karşılaştırma amacıyla verilmiştir. Önerilen yöntemle elde edilen sonuç en küçük HKO değerine sahiptir, dolayısıyla bu yöntemin Çizelge 6.8’e göre bulanık zaman serisi öngörüsü için diğer yöntemlerden üstün olduğu söylenebilir.

İkinci olarak 5.1 kesiminde tanımlanan yaklaşım adım adım uygulanmıştır. Yönteme benzer şekilde ilk üç adım uygulanır ve Çizelge 6.4 dahil olmak üzere aynı analizler yapılarak sonuçlar elde edilir. Bu aşamada aralık uzunluğu 400 için, 6 girdi ve çıktı düğümü oluşur. Girdi düğümleri, $V(t-1, t)$ üyelik dereceleri

içindir ve çıktı düğümleri $V(t, t+1)$ üyelik dereceleri içindir. Örnek olarak, $d'(1971, 1972) = 1508$ için üyelik dereceleri sinir ağının

$$V(1971, 1972) = (0.00 \quad 0.00 \quad 0.23 \quad 1.00 \quad 0.77 \quad 0.00) \quad (6.2)$$

biçiminde elde edilen girdileri haline gelir.

$d'(1972, 1973) = 1304$ için

$$V(1972, 1973) = (0.00 \quad 0.00 \quad 0.74 \quad 1.00 \quad 0.26 \quad 0.00) \quad (6.3)$$

çıktıları bulunur.

Gizli düğüm sayısı STATISTICA programı ile rassal olarak alınır ve en iyi performansa sahip gizli düğüm sayısı belirlenir. Süreci tekrarlayarak, sinir ağının eğitiminde örnek içi gözlemlerin hepsi kullanılır. STATISTICA programını kullanarak en iyi sinir ağını elde ettikten sonra, benzer şekilde, örnek dışı farklar için bütün üyelik dereceleri öngörülür. Örnek olarak,

$$V(1988, 1989) = (0.00 \quad 0.00 \quad 0.00 \quad 0.45 \quad 1.00 \quad 0.55) \quad (6.4)$$

olan girdiler şeklinde $d'(1988, 1989) = 1820$ için üyelik dereceleri kullanılır. Çıktılar,

$$V(1989, 1990) = (0.09 \quad 0.48 \quad 0.91 \quad 0.05 \quad 0.45 \quad 0.18) \quad (6.5)$$

olmak üzere bir sonraki fark için öngörölmüş üyelik dereceleridir.

Çizelge 6.9'da bütün öngörölmüş üyelik derecelerini listeler.

Çizelge 6.9. Önerilen yaklaşımda 1. veri seti için öngörölmüş üyelik dereceleri

A_1	A_2	A_3	A_4	A_5	A_6
0,08	0,15	0,39	0,19	1,00	0,58
0,09	0,48	0,91	0,05	0,45	0,18
0,09	0,53	0,67	0,08	0,05	0,05
0,09	0,46	0,55	0,22	0,06	0,05

Öngörölmüş farklar (5.10) eşitliği kullanılarak hesaplanır. Durulaştırma işleminden sonra, bütün durulaştırılmış öngörü değerleri ve HKO değeri bulunur. En iyi sonuç 6-8-6 yapısına sahip ÇKA sinir ağı mimarisiyle elde edilmiştir ve HKO değeri 69095'dir.

Elde edilen sonuç Çizelge 6.8'e eklenerek Çizelge 6.10 oluşturulur.

Çizelge 6.10 incelendiğinde, önerilen yaklaşımın temel aldığı Yu ve Huarng'ın (2010) yöntemine göre oldukça iyi sonuç verdiği görölmektedir. Literatürdeki diğer yöntemlerle karşılaştırıldığında son yıllarda yapılan çalışmalara yakın sonuca sahip olmakta ve bu da sinir ağlarının ne derece etkili olduğunu göstermektedir. Özellikle sinir ağlarının kullanıldığı çalışmaların daha iyi sonuçlar verdiği görölmekle birlikte önerilen yöntemin diğer bütün yöntemlerden çok daha iyi olduğu bu uygulama sonucu açısından söylenebilir. Önerilen yöntemde bulanık ilişkiler belirlenirken, gözlemlerin ait olduğu kümeleri ifade eden küme numaraları yerine her bir gözlemin tüm bulanık kümelere ait olmasının üyelik değerleri dikkate alınmıştır. Dolayısıyla, bilgi kaybı en aza indiği gibi bulanık zaman serisinde mevcut bulanık ilişkiler daha gerçekçi olarak ortaya konulmuş ve sonuçlar daha üstün şekilde elde edilmiştir.

Çizelge 6.10. Önerilen yaklaşımda ve yöntemde 1. veri seti için sonuçların karşılaştırılması

Yöntem	HKO
Song ve Chissom(1993)	412499
Song ve Chissom(1994)	775687
Sullivan ve Woodall (1994)	386055
Chen(1996)	407507
Hwang vd. (1998)	278919
Huang (2001)	78792 ^a
	124707 ^b
Chen (2002)	86694
Aladag vd. (2009) –Matlab	78073
Yu ve Huang (2010)	247461
Tsaur vd. (2005)	134923
Li ve Chen (2004)	173459
Li ve Cheng (2007)	85040
Egrioglu vd.(2009)-Matlab	66661
Egrioglu vd. (2010) –Matlab	60714
Önerilen yaklaşım	69095
Önerilen yöntem	44049

^a Ortalama tabanlı uzunluk


^b Dağılım tabanlı uzunluk

6.2. Ulusal Boyutta Sık Kullanılan Geniş bir Veri Seti olarak BİST(İMKB) Verisi Üzerinde Uygulama

Önerilen yaklaşım ve yöntem için ikinci olarak geniş bir veri seti olan 2006-2010 yılları arasındaki İ. M. K. B. ulusal-100 endeksi haftalık kapanış değerleri (261 gözlem) kullanılmıştır (www.tcmb.gov.tr). Veri Ocak ayından Eylül ayına kadar örnek içi (eğitim) ve Ekim ayından Aralık ayına kadar örnek dışı (Öngörü) olarak her yıl için seçilmiştir (75%:25%). Bu aşamada oluşacak büyük değerlerden kurtulmak adına HKO değeri yerine HKOK (Hata kareler ortalamasının karekökü) değeri performans kriteri olarak belirlenmiş ve bütün yıllar için elde edilen HKOK değerlerinin ortalamaları hesaplanmıştır.

Önerilen yöntem adım adım uygulanmıştır. 2006 yılı örnek olarak verilirse, ilk olarak, bütün farklar bulunmuştur. Ek-2’de görüldüğü gibi bütün farkların minimumu -4483 olduğundan negatiften kurtulmak için 4500 değeri bu yıl için sabit olarak alınmıştır. Sonrasında, bütün farklara bu sabit eklenmiştir. Bütün farklar için minimum ve maksimum $D_{\min} = 17$, $D_{\max} = 7364$ olarak belirlenmiştir. Huarng’ın yaklaşımına göre aralık uzunluğu belirlenmiştir (Huarng 2001b).

Birinci farkların kümülatif dağılımı Şekil 6.2’de gösterilmiştir.



Şekil 6.2. Önerilen yöntemde 2. veri seti için birinci farkların kümülatif dağılımı


Ek-3’de örnek olarak 2006 yılı için önerilen yöntemle uygun mutlak farklar verilmiştir. Sonuçta, 1000 aralık uzunluğu olarak belirlenmiştir. 1000 için, evrensel küme $U = [0,8000]$ şeklinde oluşmuştur. U eşit aralıklara ayrılıp bütün farklar üyelik derecelerine bulanıklaştırılmıştır. Ek-4’de örnek olarak 2006 yılı için önerilen yöntemle uygun veri seti farkları için üyelik dereceleri verilmiştir.

Bu bulanıklaştırma işleminden sonra sınır ağı eğitimi ve öngörüsü için ağırlıklandırılmış indisler bulunur. Bu aşamadan sonra en yüksek üyelik derecesi sahip olan bulanık kümenin indisi değil ağırlıklı olarak hesaplanan indisler girdiler ve hedefi oluşturmaktadır. Ek-5’de örnek olarak 2006 yılı için önerilen yöntemle uygun ağırlıklandırılmış indis değerleri verilmiştir.

Sinir ağı eğitimi ve öngörüsü birinci, ikinci, üçüncü, dördüncü ve beşinci dereceden sinir ağı tabanlı bulanık zaman serileri için çıktı indisler bulunur. Bu değerler üyelik derecelerine ayrılır ve durulaştırma aşaması gerçekleştirilir.

Durulaştırma işleminden sonra, bütün durulaştırılmış öngörü değerleri ve HKOK değerleri hesaplanmıştır.

En iyi sonuç örneğin 2006 yılı için 5-30-10-1 yapısına sahip iki gizli katmanlı ÇKA sinir ağı mimarisiyle elde edilmiştir ve HKOK değeri 350.433'dür. 2006 yılı için gerçek değerler (Kırmızı-Seri 1) ve elde edilen öngörü değerleri (Siyah-Seri 2) Şekil 6.3'de gösterilmiştir.



Şekil 6.3. Önerilen yöntemde 2. veri seti için gerçek değerler ve öngörü değerleri (2006 yılı için)

Önerilen yöntem için en iyi HKOK değerleri hesaplanan her derece için yılların ortalamaları olarak Çizelge 6.11'de verilmiştir.

Çizelge 6.11. Önerilen yöntemde 2. veri seti için sonuçlar

HKOK Değerleri				
1. Derece	2. Derece	3. Derece	4. Derece	5. Derece
402.398	531.423	367.826	378.532	339.253

Çizelge 6.11’de görüldüğü gibi en iyi sonuç 5. dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modeli için ÇKA ile elde edilmiştir. Diğer sinir ağı mimarileri iyi sonuçlar vermediğinden bu aşamada belirtilmemiştir.

GRSA, ÇKA ve RTFSA sinir ağı mimarileri bu veri için öngörü amacıyla kullanılmıştır. Sonrasında, HKOK değerleri yine tüm yılların ortalamaları alınarak her model için sırasıyla hesaplanmıştır. HKOK değerlerine göre her model için en iyileri Çizelge 6.12’de gösterilmiştir.

Çizelge 6.12. 2. veri seti için YSA modellerinde HKOK değerleri

Modeller	HKOK
ÇKA	390.581
RTFSA	391.075
GRSA	673.135

Sinir ağları ile zaman serisi öngörüsünde en iyi sonuç 1-5-3-1 yapısına sahip ÇKA ile elde edilmiştir.

Benzer işlemler, önerilen yaklaşım için de tekrarlanmıştır. Kullanılan her bir sinir ağı mimarisi için HKOK değerleri yine tüm yılların ortalamaları alınarak her model için sırasıyla hesaplanmıştır. HKOK değerlerine göre her model için en iyi sonuçlar Çizelge 6.13’de gösterilmiştir.

Çizelge 6.13. 2. veri seti için farklı YSA modelleri ile önerilen yaklaşımın HKOK değerleri

Modeller	HKOK
ÇKA ile önerilen yaklaşım	367.197
GRSA ile önerilen yaklaşım	373.165
RTFSA ile önerilen yaklaşım	376.615

Önerilen yaklaşımda Çizelge 6.13’e göre en iyi sonuç 8-14-8 yapısına sahip ÇKA ile elde edilmiştir.

Son aşamada ele alınan veri seti için kullanılan bütün modeller karşılaştırılmıştır. Çizelge 6.14, önerilen yaklaşım ve yöntemle sinir ağı tabanlı

bulanık zaman serisi öngörü modellerini, YSA modellerini ve bazı bulanık zaman serisi öngörü modellerini, HKOK değerleri ile göstermektedir.

Çizelge 6.14. 2. veri seti için bütün yöntemlerin en iyi HKOK değerleri

Modeller	HKOK
Chen (1996)	444.421
Chen-3. dereceden model (2002)	432.555
Chen-2. dereceden model (2002)	394.025
ÇKA (YSA modeli)	390.581
Yu ve Huarng (2010)	387.657
ÇKA ile önerilen yaklaşım	367.197
ÇKA ile önerilen Yöntem (5.dereceden model)	339.253

Çizelge 6.14'e göre literatürde önerilen Chen (1996), Chen'in 2. ve 3. dereceden yüksek dereceden modelleri (2002) ve Yu ve Huarng'ın (2010) sinir ağı tabanlı bulanık zaman serisi modeline göre önerilen yaklaşım ve yöntem daha iyi sonuçlar vermiştir. Ayrıca YSA mimarilerinin GRSA, RTFSA ve özellikle de ÇKA ile yapılan öngörülerden sinir ağı tabanlı bulanık zaman serisi yöntemleri daha iyi sonuçlar vermiştir. En iyi sonuç ise önerilen yöntem ile YSA mimarisi olarak ÇKA kullanılarak ve beşinci dereceden model ile elde edilmiştir.

7. SONUÇ ve ÖNERİLER

Borsa, sıcaklık ve kayıt verisi gibi zaman serilerinin çözümlenmesinde belirsizlik içermesinden dolayı bulanık zaman serisi analizi yöntemleri kullanılmaktadır. Bu tip belirsizlik içeren ve belirli bir zaman diliminde birden fazla değere sahip verilerin analizinde bulanık zaman serileri analiz yöntemleri oldukça başarılıdır. Genellikle bulanıklaştırma, bulanık ilişki belirleme ve durulaştırma aşamalarından oluşan yöntemler, bu üç aşamanın çeşitli şekillerde değişim ve gelişimlerinden etkilenmektedir. Bu doğrultuda bu tez çalışmasında, mevcut aşamaları geliştirmeye ve dolayısıyla bulanık zaman serisi öngörülerini geliştirmeye yönelik yeni bir yaklaşım ve yeni bir yöntem önerilmiştir. Geliştirilen yeni yaklaşım ile ilgili ayrıntılar ve elde edilen sonuçlar aşağıda sıralanmıştır:

- Yu ve Huarng'ın (2010) sinir ağı tabanlı bulanık zaman serisi öngörü yöntemi temel alınarak, tek değişkenli birinci dereceden sinir ağı tabanlı bulanık zaman serisi öngörü modelleri için **yeni bir yaklaşım** önerilmiştir.
- Bu yaklaşımda, Yu ve Huarng'ın çalışmasından farklı olarak, *bulanıklaştırma aşamasında dağılım tabanlı* aralık uzunlukları belirlenmiş ve öngörü performansı geliştirilmiştir.
- *Bulanıklaştırma aşamasında yeni bir algoritma* oluşturulmuş ve her bir gözlemin belirlenen bulanık kümelere ait olmasının üyelik değerleri bu algoritma çerçevesinde gerçekleştirilmiştir.
- *Bulanık ilişki belirleme aşamasında* sadece çok katmanlı algılayıcı (ÇKA-Multilayer Perceptron) değil ayrıca Genelleştirilmiş Regresyon Sinir Ağları (GRSA-Generalized Regression Neural Network) ve Radyal Tabanlı Fonksiyon Sinir Ağı (RTFSA-Radial Basis Function Neural Network) gibi diğer sık kullanılan **YSA mimarileri** de kullanılmıştır. Genel olarak en iyi sonuçlar ÇKA mimarisi ile elde edilmiştir.

- Yu ve Huarng'ın çalışmasında kullanılan tek gizli katmanlı ağı gizli katmandaki düğümlerin sayısı, girdi ve çıktı katmanındaki düğümlerin sayısının toplamı kadardır. Tezde önerilen yaklaşımda, **gizli katman sayısı ve gizli düğümlerin sayısı**, YSA'nın performansına göre en iyi sonucu elde edecek şekilde belirlenmiştir.
- Ayrıca, tezde **yeni bir sinir ağı tabanlı bulanık zaman serisi öngörü yöntemi** önerilmiştir.
- *Bulanık ilişki belirleme aşamasında*, veriyi daha iyi temsil eden ve bütün üyelik derecelerinin kullanımını sağlayan ağırlıklandırılmış ortalamalar yöntemine benzer olarak, bulanık kümeler yerine, indisleri temsilen **ağırlıklandırılmış indis değerleri** kullanılmıştır. Bilgi kaybı önlenerek verinin daha etkili ve iyi bir şekilde temsil edilmesi sağlanmıştır. Ayrıca, bu yöntemle bulanık zaman serisinde var olan bulanık ilişkiler, daha gerçekçi olarak ortaya çıkmış ve öngörü performansı artarak daha doğru öngörüler gerçekleştirilmiştir.
- *Durulaştırma işleminden önce*, elde edilen çıktı indislerinin üyelik derecelerine ayrılması ile ilgili **yeni bir algoritma** oluşturulmuştur.
- Tezde 6. bölümde yapılan uygulamalar sonucunda, 5. bölümde ifade edilen *yeni yaklaşım ve yöntem* için elde edilen sonuçların, Çizelge 6.8'e göre Song ve Chissom (1993a), Song ve Chissom (1994), Sullivan ve Woodall (1994), Chen (1996), Hwang ve ark. (1998), Chen (2002), Huarng (2001b), Aladağ ve ark. (2009), Yu ve Huarng (2010), Tsaur ve ark. (2005), Li ve Chen (2004), Li ve Cheng (2007), Eğrioglu ve ark. (2009) ve Eğrioglu ve ark. (2010) yöntemlerinden daha iyi olduğu ve Çizelge 6.14'e göre Chen (1996), Chen'in 2. ve 3. dereceden yüksek dereceden modelleri (2002) ve yine Yu ve Huarng'ın (2010) yöntemlerinden üstün olduğu görülmektedir.
- Ayrıca YSA mimarilerinin GRSA, RTFSA ve özellikle de ÇKA ile yapılan öngörülerden, sinir ağı tabanlı bulanık zaman serisi yöntemleri daha iyi sonuçlar vermiştir.

- Tez çalışması kapsamında, bilime katkı sağlayacak, öngörü açısından yapılacak diğer çalışmalara yardımcı olacak, daha başarılı ve yeni bir yöntem literatüre kazandırılmıştır.

Gelecek çalışmalar için, veri yapılarına ve problem çeşidine bağlı olarak önerilen yaklaşım ve yöntemi geliştirecek şekilde çalışmalar yapılabilir. Tek değişkenli yerine çok değişkenli bulanık zaman serileri önerilen yöntemler için uygulanabilir. Birinci derece yerine yüksek dereceli olarak sınır ağı tabanlı bulanık zaman serisi öngörü modelleri önerilen yöntemler için incelenebilir bu yöntemlere bağlı olarak mevsimsel modeller de oluşturulabilir. Ayrıca farklı aralık uzunluğu belirleme yöntemleri kullanarak farklı öngörü sonuçlarına ulaşılabilir.

KAYNAKLAR

- Aladag, C. H., Basaran, M. A., Egrioglu, E., Yolcu, U. ve Uslu, V. R. (2009), “Forecasting in High Order Fuzzy Time Series by Using Neural Networks to Define Fuzzy Relations”, *Expert Systems with Applications*, 36, pp. 4228-4231.
- Anderson, D. ve McNeill, G. (1992), *Artificial neural networks technology*, Kaman Science Corporation, New York, USA.
- Aslanargun, A., Mammadov, M., Yazici, B. ve Yolacan, S. (2007), “Comparison of ARIMA, Neural Networks and Hybrid Models in Time Series Tourist Arrival Forecasting”, *Journal of Statistical Computation and Simulation*, 77 (1), 29-53.
- Asma, S., Sezer, A. ve Ozdemir, O. (2012), “MLR and ANN models of significant wave height on the West Coast of India”, *Computers & Geosciences*, Vol. 49, pp. 231-237.
- Baykal, N. ve Beyan, T. (2004), *Bulanık Mantık İlke ve Temelleri*, Bıçaklar Kitabevi, No: 9.
- Bayramoğlu, M. F. (2007), *Finansal endekslerin öngörüsünde yapay sinir ağı modellerinin kullanılması: İMKB ulusal 100 endeksinin gün içi en yüksek ve en düşük değerlerinin öngörüsü üzerine bir uygulama*, Yüksek Lisans Tezi, Karaelmas Üniversitesi, Sosyal Bilimler Enstitüsü, Zonguldak.
- Bishop, C. M. (1995), *Neural networks for pattern recognition*, Clarendon Pres, Oxford.
- Bolat, S., Kalenderli, Ö. ve Önal, E. (2004), “Yapay sinir ağı ile gaz karışımında elektrot açıklığına ve karışım yüzdelere bağlı olarak delinme gerilimlerinin belirlenmesi”, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, Yıldız Teknik Üniversitesi Elektrik-Elektronik Fakültesi.
- Chang, P.T. (1997), “Fuzzy Seasonality Forecasting”, *Fuzzy Sets and Systems*, 90(1), pp. 1-10.
- Chen, S.-M. (1996), “Forecasting Enrollments Based on Fuzzy Time Series”, *Fuzzy Sets and Systems*, 81(3), pp. 311-319.

- Chen, S.-M. ve Hwang, J. R. (2000), "Temperature Prediction Using Fuzzy Time Series", *IEEE Transactions on Systems, Man, and Cybernetics Part B*, 50(2), pp. 263-275.
- Chen, S.-M. (2002), "Forecasting Enrollments Based on High-Order Fuzzy Time Series", *Cybernetics and Systems*, 33(1), pp. 1-16.
- Chen, S.-M. ve Chung, N. Y. (2006), "Forecasting Enrollments Using High Order Fuzzy Time Series and Genetic Algorithms", *International Journal of Intelligent Systems*, 21, pp. 485-501.
- Cheng, C.-H., Cheng, G.-W. ve Wang, J.-W. (2008), "Multi-Attribute Fuzzy Time Series Method Based on Fuzzy Clustering", *Expert Systems with Applications*, 34(2), pp. 1235-1242.
- Davari, S., Zarandi, M.H.F. ve Turksen, I.B. (2009), "An Improved Fuzzy Time Series Forecasting Model Based on Particle Swarm Intervalization", *The 28th North American Fuzzy Information Processing Society Annual Conferences (NAFIPS 2009)*, Cincinnati, Ohio, USA, June 14-17.
- Diamantaras, K. I. ve Kung, S. Y. (1996), *Principal component neural networks: theory and applications*, John Wiley and Sons Inc., New York, USA.
- Dubois, D. ve Prade, H. (1980), *Fuzzy Sets and Systems Theory and Applications*, Academic Press Inc. New York.
- Egrioglu, E., Aladag, C.H., Yolcu, U., Uslu, V.R. ve Basaran, M.A. (2009a), "A new approach based on artificial neural networks for high order multivariate fuzzy time series", *Expert Systems with Applications*, 36, 10589-10594.
- Egrioglu, E., Aladag, C.H., Yolcu, U., Basaran, M.A. ve Uslu, V.R. (2009b), "A new hybrid approach based on SARIMA and partial high order bivariate fuzzy time series forecasting model", *Expert Systems with Applications*, 36, 7424-7434.
- Egrioglu, E., Uslu, V.R., Yolcu, U., Basaran, M.A. ve Aladag, C.H. (2009c), "A new approach based on artificial neural networks for high order bivariate fuzzy time series", *J. Mehnen et al. (Eds.): Application of Soft Computing*, AISC 58, Springer-Verlag Berlin Heidelberg, 265-273.

- Egrioglu, E., Aladag, C.H., Yolcu, U., Uslu, V.R. ve Basaran, M.A. (2010), "Finding an optimal interval length in high order fuzzy time series", *Expert Systems with Applications*, 37, 5052-5055.
- Elmas, Ç. (2003), *Yapay sinir ağları*, Seçkin Yayıncılık, Ankara.
- Erdoğan, G. (2006), *Yapay sinir ağları ile iktisadi ve finansal zaman dizilerinin kestirimi*, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Fausett, L. (1994), *Fundamentals of neural networks*, Prentice Hall, USA.
- Guyton, A. C. ve Hall, J. E. (2006), *Textbook of medical physiology*, Elsevier Saunders, Pennsylvania, USA.
- Haykin, S. (1999), *Neural networks: a comprehensive foundation*, Pearson Prentice Hall, India.
- Hsu, Y.-Y., Tse, S.-M. ve Wu, B. (2003), "A New Approach of Bivariate Fuzzy Time Series Analysis to the Forecasting of a Stock Index", *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*, 11(6), pp. 671-690.
- Hsu, L.Y., Horng, S.-J., Kao, T.-W., Chen Y.-H., Run, R.-S., Chen, R.-J., Lai, J.-L. ve Kuo, I.-H. (2010), "Temperature prediction and TAIEX forecasting based on fuzzy relationships and MTPSO techniques", *Expert Systems with Application*, 37, pp. 2756-2770.
- Huarng, K. (2001a), "Heuristic Models of Fuzzy Time Series for Forecasting", *Fuzzy Sets and Systems*, 123(3), pp. 369-386.
- Huarng, K. (2001b), "Effective Lengths of Intervals to Improve Forecasting in Fuzzy Time Series", *Fuzzy Sets and Systems*, 123(3), pp. 387-394.
- Huarng, K. ve Yu, H.-K. (2003a), "An Information Criterion for Fuzzy Time Series to Forecast the Stock Exchange Index on the TAIEX", *In Ninth International Conference on Fuzzy Theory and Technology*, pp. 187-189.
- Huarng, K. ve Yu, H.-K. (2003b), "An N-th Order Heuristic Fuzzy Time Series Model for TAIEX Forecasting", *International Journal of Fuzzy Systems*, 5(4), pp. 247-253.

- Huarng, K. ve Yu, H.-K. (2004), "A Dynamic Approach to Adjusting Lengths of Intervals in Fuzzy Time Series Forecasting", *Intelligent Data Analysis*, 8(1), pp. 3-27.
- Huarng, K. ve Yu, H.-K. (2005), "A Type 2 Fuzzy Time Series Model for Stock Index Forecasting", *Physica A*, 353, pp. 445-462.
- Huarng, K. ve Yu, H.-K. (2006a), "Ratio-Based Lengths of Intervals to Improve Fuzzy Time Series Forecasting", *IEEE Transactions on Systems, Man, and Cybernetics Part B*, 36(2), pp. 328-340.
- Huarng, K. ve Yu, H.-K. (2006b), "The application of neural networks to forecast fuzzy time series", *Physica A*, 363, pp. 481-491.
- Hwang, J. R., Chen, S.-M. ve Lee, C.-H. (1998), "Handling Forecasting Problems Using Fuzzy Time Series", *Fuzzy Sets and Systems*, Vol. 100, No. 1-3, pp. 217-228.
- Jain, L. C. ve Martin, N. M. (1998), *Fusion of neural networks, fuzzy systems and genetic algorithms: industrial applications*, CRC Press, USA.
- Jang, J. S. R. ve Sun, C. T. (1993), "Functional Equivalence Between Radial Basis Function Networks and Fuzzy Inference Systems", *IEEE Transactions on Neural Networks*, Vol. 4, No:1.
- Jilani, T. A., Burney, S. M. A. ve Ardil, C. (2007), "Multivariate High Order Fuzzy Time Series Forecasting for Car Road Accidents", *International Journal of Computational Intelligence*, 4(1), pp. 15-20.
- Jilani, T. A. ve Burney, S. M. A. (2007), "M-factor High Order Fuzzy Time Series Forecasting for Road Accident Data: Analysis and design of intelligent systems using soft computing techniques", *Advanced in Soft Computing*, 41, pp. 246-254.
- Jilani, T. A. ve Burney, S. M. A. (2008), "Multivariate Stochastic Fuzzy Forecasting Models", *Expert Systems with Applications*, 35(3), pp. 691-700.
- Khashei, M., Hejazi, S. R. ve Bijari, M. (2008), "A New Hybrid Artificial Neural Networks and Fuzzy Regression Model for Time Series Forecasting", *Fuzzy Sets and Systems*, 159, pp. 769-786.
- Kuo, I.-H., Horng, S.-J., Kao, T.-W., Lin, T.-L., Lee, C.-L. ve Pan, Y. (2009), "An improved method for forecasting enrollments based on fuzzy time series and

- particle swarm optimization”, *Expert Systems with Application*, 36, pp. 6108-6117.
- Kuo, I.-H., Horng, S.-J., Chen, Y.-H., Run, R.-S., Kao, T.-W., Chen, R.-J., Lai, J.-L. ve Lin, T.-L. (2010), “Forecasting TAIEX based on fuzzy time series and particle swarm optimization”, *Expert Systems with Application*, 37, pp. 1494-1502.
- Lee, M.-J. ve Choi, Y.-K. (2001), “An Adaptive Control Method for Robot Manipulators using Radial Basis Function Networks”, *Industrial Electronics*, IEEE International Symposium, Vol. 3, p. 1827-1832, Pusan, South Korea.
- Lee, K. H. (2005), *First Course on Fuzzy Theory and Applications*, Springer-Verlag, Berlin Heidelberg New York.
- Lee, L.-W., Wang, L.-H., Chen, S.-M. ve Leu, Y.-H. (2006), “Handling Forecasting Problems Based on Two Factors High-Order Fuzzy Time Series”, *IEEE Transactions on Fuzzy Systems*, 14(3).
- Lee, L.-W., Wang, L.-H. ve Chen, S.-M. (2007), “Temperature Prediction and TAIEX Forecasting Based on Fuzzy Logical Relationships and Genetic Algorithms”, *Expert Systems with Applications*, 33, pp. 539-550.
- Lee, L.-W., Wang, L.-H. ve Chen, S.-M. (2008), “Temperature Prediction and TAIEX Forecasting Based on High-Order Fuzzy Logical Relationships and Genetic Simulated Annealing Techniques”, *Expert Systems with Applications*, 34, pp. 328-336.
- Li, S.-T. ve Chen, Y.-P. (2004), “Natural partitioning-based forecasting model for fuzzy time-series”, *Proceedings IEEE International Conference on Fuzzy Systems*, 3, 1355-1359.
- Li, S.-T. ve Cheng, Y.-C. (2007), “Deterministic fuzzy time series model for forecasting enrollments”, *Computers & Mathematics with Applications*, 53, 1904-1920.
- Li, S.-T., Cheng, Y.-C. ve Lin, S.-Y. (2008), “A FCM-based deterministic forecasting model for fuzzy time series”, *Computers & Mathematics with Applications*, 56, 3052-3063.

- Lin, C.-T. ve Lee, G.C.S. (1996), *Neural Fuzzy Systems A Neuro-Fuzzy Synergism to Intelligent Systems*, Prentice-Hall, Inc.
- MacKay, D. J. C. (2003), *Information theory, inference and learning algorithms*, Cambridge University Press, UK.
- Memmedli, M. ve Ozdemir, O. (2010), “An Application of Fuzzy Time Series to Improve ISE Forecasting”, *WSEAS Transactions on Mathematics*, (Compendex, Scopus), Issue 1, Vol. 9, pp. 12-21.
- Memmedli, M. ve Ozdemir, O. (2012), “An Empirical Study of Fuzzy Approach with Artificial Neural Network Models”, *International Journal of Mathematical Models and Methods in Applied Sciences*, Issue 1, Vol. 6, pp. 114-121.
- Moody, T. ve Darken, C. (1989), “Fast learning in networks of locally tuned processing units”, *Neural Computation*, 1, 281-194.
- Mori, H. ve Awata, A. (2007), “Data Mining of Electricity Price Forecasting with Regression Tree and Normalized Radial Basis Function Network”, *IEEE Transactions on Systems, Man, and Cybernetics*, IEEE International Conference, pp. 3743-3748.
- Mostafa, M. M. (2010), “Forecasting stock exchange movements using neural networks: Empirical evidence from Kuwait”, *Expert Systems with Applications*.
- Özdemir, Ü. (2007), *Çevre duyarlı hidrojellerin şişme kinetiğinin yapay sinir ağları ile modellenmesi*, Yüksek Lisans Tezi, Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü, Sivas.
- Özdemir, Ö. (2008), *Zaman Serisi Modellemesinde Yapay Sinir Ağlarının Kullanımı ve bir Uygulama*, Yüksek Lisans Tezi, Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Ozdemir, O., Aslanargun, A. ve Asma, S. (2010), “ANN Forecasting Models for ISE National-100 Index”, *Journal of Modern Applied Statistical Methods*, Vol. 9, No. 2, pp. 584-588.
- Öztemel, E. (2003), *Yapay sinir ağları*, Papatya Yayıncılık, İstanbul.
- Paksoy, T., Pehlivan N. Y. ve Özceylan, E. (2013), *Bulanık Küme Teorisi*, Nobel Yayınevi, 1. basım.

- Park, J.-I., Lee, D.-J., Song, C.-K. ve Chun, M.-G. (2010), “TAIFEX and KOSPI 200 forecasting based on two factors high order fuzzy time series and particle swarm optimization”, *Expert Systems with Applications*, 37, 959-967.
- Renals, S. ve Rohwer, R. (1989), “Phoneme classification experiments using radial basis functions”, *In Proceedings of International Joint Conference on Neural Networks*, Washington, DC, 461-467.
- Ross, J. T., (1995), *Fuzzy logic with engineering applications*, McGraw Hill, New York.
- Roychowdhury, S. ve Pedrycz, W. (2001), “A survey of defuzzification strategies”, *International Journal of Intelligent Systems*, 16(6), 679-695.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. (1986), “Learning internal representations by error propagation”, In D. E. Rumelhart & J. L. McClelland, *Parallel distributed processing: explorations in the microstructure of cognition*, Cambridge, MA: MIT Press, 318–362.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M. (2003), *Mühendislikte yapay zeka uygulamaları-1: yapay sinir ağları*, Ufuk Yayıncılık, Kayseri.
- Smith, K. A. (2002), “Neural Networks for Business: An Introduction”, *Neural Networks in Business: Techniques and Applications*, (Ed.: Smith, K. A. ve Gupta, J. N. D.) Idea Group Publishing, USA.
- Song, Q. ve Chissom, B. S. (1993a), “Fuzzy Time Series and its Models”, *Fuzzy Sets and Systems*, 54, pp. 269-277.
- Song, Q. ve Chissom, B. S. (1993b), “Forecasting Enrollments with Fuzzy Time Series, Part 1”, *Fuzzy Sets and Systems*, 54, pp. 1-10.
- Song, Q. ve Chissom, B. S. (1994), “Forecasting Enrollments with Fuzzy Time Series, Part 2”, *Fuzzy Sets and Systems*, 62, pp. 1-8.
- Song, Q. (1999), “Seasonal Forecasting in Fuzzy Time Series”, *Fuzzy Sets and Systems*, 107(2), pp.235.
- Sullivan, J. ve Woodall, W. H. (1994), “A Comparison of Fuzzy Forecasting and Markov Modeling”, *Fuzzy Sets and Systems*, 64(3), pp. 279-293.
- Şen, Z. (2004), *Yapay sinir ağları ilkeleri*, Su Vakfı Yayınları, İstanbul.

- Terence, F. L. (1999), *Feedforward neural network methodology*, Springer-Verlag Inc., New York, USA.
- Trenn, S. (2008), "Multilayer Perceptrons: Approximation Order and Necessary Number of Hidden Units", *IEEE Transactions on Neural Networks*, 19(5).
- Tsaur, R.-C., Yang, J.-C. ve Wang, H.-F. (2005), "Fuzzy relation analysis in fuzzy time series model", *Computers & Mathematics with Applications*, 49, 539–548.
- Tseng, F.-M. ve Tzeng, G.-H. (2002), "A Fuzzy Seasonal ARIMA Model for Forecasting", *Fuzzy Sets and Systems*, 126(3), pp. 367-376.
- Vaughn, M. L. (1999), "Derivation of the Multilayer Perceptron Weight Constraints for Direct Network Interpretation and Knowledge Discovery", *Neural Networks*, 12, 1259-1271.
- Wasserman, P.D. (1993), *Advanced Methods in Neural Computing*, New York, Van Nostrand Reinhold, NY, USA.
- www.tcmb.gov.tr.
- Yolcu, U., Egrioglu, E., Uslu, V. R., Basaran, M. A. ve Aladag, C. H. (2009), "A new approach for determining the length of intervals for fuzzy time series", *Applied Soft Computing*, 9, 647-651.
- Yu, H.-K. (2005), "Weighted Fuzzy Time Series Models for TAIEX Forecasting", *Physica A*, 349, pp. 609-624.
- Yu, H.-K. ve Huarng, K.-H. (2008), "A Bivariate Fuzzy Time Series Model to Forecast the TAIEX", *Expert Systems with Applications*, 34(4), pp. 2945-2952.
- Yu, T. H.-K. ve Huarng, K.-H. (2010), "A Neural Network-Based Fuzzy Time Series Model to Improve Forecasting", *Expert Systems with Applications*, 37, pp. 3366-3372.
- Yurtoğlu, H. (2005), *Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği*, Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, <http://ekutup.dpt.gov.tr/>.
- Zadeh, L.A. (1965), "Fuzzy Sets", *Information and Control*, 8, pp. 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, Information Sciences*, 8, 199-249; 8, 301-357; 9, 43-80.
- Zadeh, L.A. (1978), "Fuzzy Sets As a Basis for a Theory of Possibility", *Fuzzy Sets and Systems*, 1(1), 3-28.
- Zhang, G., Patuwo, B. E. ve Hu, Y. M. (1998), "Forecasting with artificial neural networks", *International Journal of Forecasting*, 14, 35-62.
- Zilouchian, A. (2001), "Fundamentals of Neural Networks", *Intelligent Control Systems Using Soft Computing Methodologies*, (Ed.: Zilouchian, A. ve Jamshidi, M.), CRC Press, USA.

EKLER

Ek-1 Bütün $V(t-1, t)$ 'leri bulan algoritma

Adım 1. Bir sonraki adımı kullanarak bütün $d'(t-1, t)$ için A_i , $i = 1, 2, \dots, k$ hesapla.

Adım 2. Her $d'(t-1, t)$ için, bu adımı tekrarla.

$i = 1$ İÇİN,

EĞER $d'(t-1, t) > (i-1)*l$ VE $d'(t-1, t) < i*l$ İSE

$$A_i = 1$$

DEĞİL EĞER $d'(t-1, t) > i*l$ VE $d'(t-1, t) < (i+1)*l$ İSE

$$A_i = \frac{((i+1)*l) - d'(t-1, t)}{l}$$

HİÇBİRİ İSE

$$A_i = 0$$

$i = 2$ DEN $i < k$ KADAR,

EĞER $d'(t-1, t) > (i-1)*l$ VE $d'(t-1, t) < i*l$ İSE

$$A_i = 1$$

DEĞİL EĞER $d'(t-1, t) > i*l$ VE $d'(t-1, t) < (i+1)*l$ İSE

$$A_i = \frac{((i+1)*l) - d'(t-1, t)}{l}$$

DEĞİL EĞER $d'(t-1, t) > (i-2)*l$ VE $d'(t-1, t) < (i-1)*l$ İSE

$$A_i = \frac{d'(t-1, t) - ((i-2)*l)}{l}$$

HİÇBİRİ İSE

$$A_i = 0$$

$i = k$ İÇİN

EĞER $d'(t-1, t) > (i-1)*l$ VE $d'(t-1, t) < i*l$ İSE

$$A_i = 1$$

DEĞİL EĞER $d'(t-1, t) > (i-2)*l$ VE $d'(t-1, t) < (i-1)*l$ İSE

$$A_i = \frac{d'(t-1, t) - ((i-2)*l)}{l}$$

HİÇBİRİ İSE

$$A_i = 0$$

Adım 3. $d'(t-1, t)$, bir $V(t-1, t)$ üyelik dereceleri kümesine bulanıklaştırıldıktan sonra bütün $V(t-1, t)$ bulunana kadar bütün adımları tekrarla.

Ek-2 Önerilen yöntemde 2. veri seti için $obs(t)$ ve $obs(t-1)$ farkları

$obs(t)$	$obs(t-1)$	$d(t-1,t)$
41905,4	-	-
41905,4	41905,4	0
44465,7	41905,4	2560,27
45315,2	44465,7	849,47
44228	45315,2	-1087,13
44772,9	44228	544,91
46244,3	44772,9	1471,39
46838,1	46244,3	593,78
46366,2	46838,1	-471,87
42521,9	46366,2	-3844,29
44688,1	42521,9	2166,18
43273,9	44688,1	-1414,18
42911,3	43273,9	-362,62
44284,2	42911,3	1372,85
42212	44284,2	-2072,14
45075,9	42212	2863,86
43880,4	45075,9	-1195,46
44212,8	43880,4	332,33
41970,8	44212,8	-2241,96
39643,7	41970,8	-2327,12
38593,5	39643,7	-1050,21
39285,8	38593,5	692,33
34802,6	39285,8	-4483,22
34048	34802,6	-754,54
33132,3	34048	-915,74
35453,3	33132,3	2321,01
36202,2	35453,3	748,92
33831,7	36202,2	-2370,54

34988,8	33831,7	1157,11
36101,9	34988,8	1113,09
36159,6	36101,9	57,72
37418,1	36159,6	1258,5
37384,8	37418,1	-33,32
36861,7	37384,8	-523,13
37414,9	36861,7	553,28
37372	37414,9	-42,95
38143,9	37372	771,92
36390	38143,9	-1753,9
36924,9	36390	534,85
36737,6	36924,9	-187,24
38486,1	36737,6	1748,47
39643,8	38486,1	1157,67
40683,3	39643,8	1039,49
39307,1	40683,3	-1376,2
39627,2	39307,1	320,13
38432,8	39627,2	-1194,38
37582,1	38432,8	-850,67
38196,5	37582,1	614,39
39320,5	38196,5	1123,95
40204,8	39320,5	884,33
39180,2	40204,8	-1024,6
39117,5	39180,2	-62,74

Ek-3 Önerilen yöntemde 2. veri seti için mutlak farklar (2006 yılı için)

A_i	Mutlak farklar (A_{i+1} ve A_i)	A_i	Mutlak farklar (A_{i+1} ve A_i)
4500	2560,27	2129,46	3527,65
7060,27	1710,8	5657,11	44,02
5349,47	1936,6	5613,09	1055,37
3412,87	1632,04	4557,72	1200,78
5044,91	926,48	5758,5	1291,82
5971,39	877,61	4466,68	489,81
5093,78	1065,65	3976,87	1076,41
4028,13	3372,42	5053,28	596,23
655,71	6010,47	4457,05	814,87
6666,18	3580,36	5271,92	2525,82
3085,82	1051,56	2746,1	2288,75
4137,38	1735,47	5034,85	722,09
5872,85	3444,99	4312,76	1935,71
2427,86	4936	6248,47	590,8
7363,86	4059,32	5657,67	118,18
3304,54	1527,79	5539,49	2415,69
4832,33	2574,29	3123,8	1696,33
2258,04	85,16	4820,13	1514,51
2172,88	1276,91	3305,62	343,71
3449,79	1742,54	3649,33	1465,06
5192,33	5175,55	5114,39	509,56
16,78	3728,68	5623,95	239,62
3745,46	161,2	5384,33	1908,93
3584,26	3236,75	3475,4	961,86
6821,01	1572,09	4437,26	
5248,92	3119,46	Ort.	1848,681

Ek-4 Önerilen yöntemde 2. veri seti farkları için üyelik dereceleri (2006 yılı için)

$d'(t-1, t)$	A_1	A_2	A_3	A_4	A_5	A_6	A_7	A_8
4500	0,00	0,00	0,00	0,50	1,00	0,50	0,00	0,00
7060,27	0,00	0,00	0,00	0,00	0,00	0,00	0,94	1,00
5349,47	0,00	0,00	0,00	0,00	0,65	1,00	0,35	0,00
3412,87	0,00	0,00	0,59	1,00	0,41	0,00	0,00	0,00
5044,91	0,00	0,00	0,00	0,00	0,96	1,00	0,04	0,00
5971,39	0,00	0,00	0,00	0,00	0,03	1,00	0,97	0,00
5093,78	0,00	0,00	0,00	0,00	0,91	1,00	0,09	0,00
4028,13	0,00	0,00	0,00	0,97	1,00	0,03	0,00	0,00
655,71	1,00	0,66	0,00	0,00	0,00	0,00	0,00	0,00
6666,18	0,00	0,00	0,00	0,00	0,00	0,33	1,00	0,67
3085,82	0,00	0,00	0,91	1,00	0,09	0,00	0,00	0,00
4137,38	0,00	0,00	0,00	0,86	1,00	0,14	0,00	0,00
5872,85	0,00	0,00	0,00	0,00	0,13	1,00	0,87	0,00
2427,86	0,00	0,57	1,00	0,43	0,00	0,00	0,00	0,00
7363,86	0,00	0,00	0,00	0,00	0,00	0,00	0,64	1,00
3304,54	0,00	0,00	0,70	1,00	0,30	0,00	0,00	0,00
4832,33	0,00	0,00	0,00	0,17	1,00	0,83	0,00	0,00
2258,04	0,00	0,74	1,00	0,26	0,00	0,00	0,00	0,00
2172,88	0,00	0,83	1,00	0,17	0,00	0,00	0,00	0,00
3449,79	0,00	0,00	0,55	1,00	0,45	0,00	0,00	0,00
5192,33	0,00	0,00	0,00	0,00	0,81	1,00	0,19	0,00
16,78	1,00	0,02	0,00	0,00	0,00	0,00	0,00	0,00
3745,46	0,00	0,00	0,25	1,00	0,75	0,00	0,00	0,00
3584,26	0,00	0,00	0,42	1,00	0,58	0,00	0,00	0,00
6821,01	0,00	0,00	0,00	0,00	0,00	0,18	1,00	0,82
5248,92	0,00	0,00	0,00	0,00	0,75	1,00	0,25	0,00
2129,46	0,00	0,87	1,00	0,13	0,00	0,00	0,00	0,00

5657,11	0,00	0,00	0,00	0,00	0,34	1,00	0,66	0,00
5613,09	0,00	0,00	0,00	0,00	0,39	1,00	0,61	0,00
4557,72	0,00	0,00	0,00	0,44	1,00	0,56	0,00	0,00
5758,5	0,00	0,00	0,00	0,00	0,24	1,00	0,76	0,00
4466,68	0,00	0,00	0,00	0,53	1,00	0,47	0,00	0,00
3976,87	0,00	0,00	0,02	1,00	0,98	0,00	0,00	0,00
5053,28	0,00	0,00	0,00	0,00	0,95	1,00	0,05	0,00
4457,05	0,00	0,00	0,00	0,54	1,00	0,46	0,00	0,00
5271,92	0,00	0,00	0,00	0,00	0,73	1,00	0,27	0,00
2746,1	0,00	0,25	1,00	0,75	0,00	0,00	0,00	0,00
5034,85	0,00	0,00	0,00	0,00	0,97	1,00	0,03	0,00
4312,76	0,00	0,00	0,00	0,69	1,00	0,31	0,00	0,00
6248,47	0,00	0,00	0,00	0,00	0,00	0,75	1,00	0,25
5657,67	0,00	0,00	0,00	0,00	0,34	1,00	0,66	0,00
5539,49	0,00	0,00	0,00	0,00	0,46	1,00	0,54	0,00
3123,8	0,00	0,00	0,88	1,00	0,12	0,00	0,00	0,00
4820,13	0,00	0,00	0,00	0,18	1,00	0,82	0,00	0,00
3305,62	0,00	0,00	0,69	1,00	0,31	0,00	0,00	0,00
3649,33	0,00	0,00	0,35	1,00	0,65	0,00	0,00	0,00
5114,39	0,00	0,00	0,00	0,00	0,89	1,00	0,11	0,00
5623,95	0,00	0,00	0,00	0,00	0,38	1,00	0,62	0,00
5384,33	0,00	0,00	0,00	0,00	0,62	1,00	0,38	0,00
3475,4	0,00	0,00	0,52	1,00	0,48	0,00	0,00	0,00
4437,26	0,00	0,00	0,00	0,56	1,00	0,44	0,00	0,00

**Ek-5 Önerilen yöntemde 2. veri seti için ağırlıklandırılmış indis değerleri
(2006 yılı için)**

$d'(t-1,t)$	a_t
4500	5,00
7060,27	7,29
5349,47	5,85
3412,87	3,91
5044,91	5,54
5971,39	6,47
5093,78	5,59
4028,13	4,53
655,71	1,16
6666,18	7,17
3085,82	3,59
4137,38	4,64
5872,85	6,37
2427,86	2,93
7363,86	6,23
3304,54	3,80
4832,33	5,33
2258,04	2,76
2172,88	2,67
3449,79	3,95
5192,33	5,69
16,78	0,52
3745,46	4,25
3584,26	4,08
6821,01	7,32
5248,92	5,75
2129,46	2,63

5657,11	6,16
5613,09	6,11
4557,72	5,06
5758,5	6,26
4466,68	4,97
3976,87	4,48
5053,28	5,55
4457,05	4,96
5271,92	5,77
2746,1	3,25
5034,85	5,53
4312,76	4,81
6248,47	6,75
5657,67	6,16
5539,49	6,04
3123,8	3,62
4820,13	5,32
3305,62	3,81
3649,33	4,15
5114,39	5,61
5623,95	6,12
5384,33	5,88
3475,4	3,98
4437,26	4,94