

BULANIK ZAMAN SERİLERİNDE ÇOK
DEĞİŞKENLİ ÇÖZÜMLEME

UFUK YOLCU

DOKTORA TEZİ
İSTATİSTİK ANABİLİM DALI

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BULANIK ZAMAN SERİLERİNDE
ÇOK DEĞİŞKENLİ ÇÖZÜMLEME

UFUK YOLCU

DOKTORA TEZİ
İSTATİSTİK ANABİLİM DALI

AKADEMİK DANIŞMAN
Doç. Dr. Vedide Rezan USLU

İKİNCİ AKADEMİK DANIŞMAN
Doç. Dr. Erol EĞRİOĞLU

SAMSUN – 2011

T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bu çalışma jürimiz tarafından 27/06/2011 tarihinde yapılan sınav ile İstatistik Anabilim Dalı'nda DOKTORA tezi olarak kabul edilmiştir.

Başkan: Prof. Dr. Reşat KASAP

Üye: Prof. Dr. Hüseyin DEMİR

Üye: Prof. Dr. Faruk ALPASLAN

Üye: Doç. Dr. Vedide Rezan USLU (danışman)

Üye: Doç. Dr. Vedat SAĞLAM

ONAY:

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylarım.

.../.../2011

Prof. Dr. Hasan GÜMÜŞ
Fen Bilimleri Enstitüsü Müdürü

BULANIK ZAMAN SERİLERİNDE ÇOK DEĞİŞKENLİ ÇÖZÜMLEME

ÖZET

Birçok bilim dalında zaman serisi problemlerini oluşturan verilerin belirsizlik içermesi, bu tür problemleri çözmede, klasik zaman serisi yaklaşımlarındaki kısıtlamalara gerek duymayan, bulanık zaman serisi yöntemlerinin kullanılması gereğini ortaya koymaktadır. Bulanık zaman serisi yöntemleri, bulanıklaştırma, bulanık ilişkilerin belirlenmesi ve durulaştırma gibi, her biri yöntemin öngörüsü üzerinde belirleyici rol oynayan üç temel aşamadan oluşur. Birçok çalışmada bulanıklaştırma aşamasında sübjektif yargılara gerek duyan yaklaşımlar kullanılırken, bulanık ilişkilerin belirlenmesinde bulanık mantık grup ilişki tabloları ve yapay sinir ağları kullanılır. Çalışmaların hemen hepsinde bulanık ilişkileri belirlemede gözlemlerin her bir bulanık kümeye ait olmasının üyelik dereceleri ihmal edilmektedir. Bu ise bilgi kaybı sebebiyle yöntemin öngörüsünü olumsuz etkiler. Gözlemlerin her bir bulanık kümeye ait olmasının üyelik derecesini, bulanık ilişkileri belirlemede kullanan Yu ve Huarng (2010) üyelik derecelerini keyfi belirlerken, bu sorunu bulanık C-ortalama yöntemini ile aşan Yolcu ve ark. (2010) yalnızca tek değişkenli ve birinci dereceden bir model ortaya koymuşlardır. Ancak karşılaşılan bulanık zaman serilerinin büyük bir kısmının öngörülmesinde, diğer bazı bulanık zaman serileri ile aralarında mevcut olan bulanık ilişkileri ortaya çıkaracak, çok değişkenli bulanık zaman serisi öngörü modelinin oluşturulması gerekmektedir. Bu tez kapsamında önerilen yöntem, bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan, her bir gözlemin bulanık kümelerine ait olma üyelik değerlerinin sübjektif yargılardan uzak belirlendiği, bulanık C-ortalama yöntemini, bulanık ilişki belirlenmesi aşamasında, girdileri ve hedefleri belirlenen üyelik değerlerinden oluşan yapay sinir ağlarını kullanan, çok değişkenli bir bulanık zaman serisi öngörü modelini içermektedir. Önerilen yöntemin performans değerlendirmesi dört farklı veriye uygulanarak gerçekleştirilmiş ve dikkat çekici sonuçlara ulaşılmıştır.

Anahtar Sözcükler: Çok değişkenli bulanık zaman serisi, bulanık C-ortalama, yapay sinir ağları, üyelik derecesi, öngörü.

MULTIVARIATE ANALYSIS IN FUZZY TIME SERIES

ABSTRACT

In many disciplines, including uncertainty of data obtained from time series problems, generates the needs to fuzzy time series methods which do not require the assumptions of traditional time series methods. Fuzzy time series analysis method consist of three main steps such as fuzzification, identification of fuzzy relation and de fuzzification and each plays a decisive role of forecasting. While in many studies, approaches that require subjective judgments are used in the fuzzification stage, fuzzy logic group relation tables and artificial neural networks are used in identification of fuzzy relation. Almost in all studies, membership degree belonging to each set of the observations is ignored in identifying fuzzy relations. This negatively affects forecasting performance of the method in consequence of information loss. While Yu and Huarng (2010) used membership degrees of observations which are arbitrarily chosen, in identifying fuzzy relations, Yolcu et al. (2010), who eliminate this problem by using fuzzy C-means method, proposed a first order univariate model. However, for forecasting most of the fuzzy time series encountered in daily lives, multivariate forecasting fuzzy time series models are required to define their relations to the other fuzzy time series. The method which was proposed within the scope of this thesis involves fuzzy C-means method which does not require partitioning of the universal discourse and in which membership value of each observation belonging to fuzzy set are determined by non-subjective judgments in fuzzification stage; and multivariate fuzzy time series method which uses artificial neural network consisting of membership values in which inputs and outputs are determined in stage of determination of the fuzzy relations. Performance evaluation of the proposed method was assessed by applying it to four different data and remarkable results are reached.

Key Words: Multivariate fuzzy time series, fuzzy C-means, artificial neural network, membership degree, forecasting.

TEŞEKKÜR

Öncelikle, bugün bu tezi yazabilme telaşını yaşamamı sağlayan en temel vesile olan ve hiçbir an desteğini, yardımını ve en önemlisi güvenini benden esirgemeyen sevgili hocam Doç. Dr. Vedide Rezan USLU'ya ve elbette, bu çalışmanın oluşumunda en az benim kadar emeği olan, çalışmanın temel fikrinin oluşmasından, olgunlaşmış hale gelene kadar tüm aşamalarında, bilgisini ve fikrini sunmada alabildiğine cömert davranan hocam Doç. Dr. Erol EĞRİOĞLU'na sonsuz minnetlerimi sunmalıyım.

Ayrıca, bu uzun ve yorucu süreçte bana yoldaşlık eden, tüm sıkıntılarımı gülen yüzü ve hoşgörüsü ile dağıtan, yol arkadaşım Arş. Gör. Özge CAĞCAĞ'a teşekkürlerimi bir borç bilirim.

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

İÇİNDEKİLER

1.	GİRİŞ	1
2.	GENEL BİLGİLER	6
2.1.	Bulanık Mantık	6
2.1.1.	Bulanık Küme Kuramı	8
2.1.1.1.	Bulanık Kümeler ve Üyelik Fonksiyonu	10
2.1.1.2.	Bulanık Kümelerle İlgili Bazı Kavramlar	12
2.1.1.3.	Genişleme Kuralı	14
2.1.2.	Bulanık Sayılar	16
2.1.2.1.	Bulanık Sayılarda Cebirsel İşlemler	19
2.1.2.2.	Bulanık Sayılarda Minimum ve Maksimum	20
2.2.	Yapay Sinir Ağları (YSA)	21
2.2.1.	Mimari Yapı	22
2.2.2.	Aktivasyon Fonksiyonu	25
2.2.3.	Öğrenme Algoritması	27
2.2.3.1.	Levenberg-Marquardt Öğrenme Algoritması	28
2.3.	Bulanık C-Ortalamalar (BCO)	31
3.	MATERYAL VE YÖNTEM	32
3.1.	Bulanık Zaman Serileri ve Temel Kavramlar	32
3.2.	Yolcu ve ark. Tarafından Önerilen Yöntem	35
3.3.	Önerilen Yöntem ve Algoritması	39
4.	BULGULAR VE TARTIŞMA	44
4.1.	Belçika'da Gerçekleşen Ölümlü Araba Kazaları Verisi Çözümlemesi	45
4.2.	TAIFEX (Taiwan Futures Exchange) Verisi Çözümlemesi	48
4.3.	TAIEX (Taiwan Stock Exchange) Verisi Çözümlemesi	51
4.4.	IMKB Verisi Çözümlemesi	54
5.	SONUÇ VE ÖNERİLER	62
6.	KAYNAKLAR	66
7.	EKLER	73
8.	ÖZGEÇMİŞ	79

SİMGE VE KISALTMALAR LİSTESİ

(a, b)	Açık aralık
α	Alpha
USD	Amerikan para birimi (dolar)
+	Artı
EURO	Avrupa Birliği para birimi
β	Beta
\div	Bölme işareti
BCO	Bulanık C-ortalamalar
\underline{A}	Bulanık küme
$F(t)$	Bulanık zaman serisi
$>$	Büyük
\geq	Büyük ve eşit
\times	Çarpım işareti
-	Eksi
ϵ	Elemanındır
\int	Entegral
=	Eşit
\mathbb{R}	Gerçek sayılar kümesi
HKOK	Hata kareler ortalaması karekökü
IMKB	İstanbul Menkul Kıymetler Borsası
$[a, b]$	Kapalı aralık
∂	Kısmi türev
\cos	Kosinüs fonksiyonu
$\sqrt{\quad}$	Kök işareti (karekök)
$<$	Küçük
\leq	Küçük ve eşit
λ	Lambda
\max	Maksimum
\wedge	Mantıksal “ve”
\vee	Mantıksal “veya”

min	Minimum
μ	Mu
OMYH	Ortalama mutlak yzdelik hata
$^{\circ}C$	Santigrat derece
sin	Sins fonksiyonu
sup	Supremum (en kk st sınır)
/	art / Blme iareti
TAIFEX	Taiwan Futures Exchange
TAIEX	Taiwan Stock Exchange
Σ	Toplam
\forall	Tm iin
exp	stel
\exists	Var
YSA	Yapay sinir ađı
$(a, b]$	Yarı aık aralık
YD	Yn dođruluđu

ŞEKİLLER LİSTESİ

Şekil 2.1.	Klasik küme için sıcaklık örneği	8
Şekil 2.2.	Bulanık küme için sıcaklık örneği	9
Şekil 2.3.	Bulanık kümelerde örtüşüm	10
Şekil 2.4.	Farklı bulanık kümeler için merkez noktalar	14
Şekil 2.5.	Üçgensel bulanık sayı	17
Şekil 2.6.	Yamuk bulanık sayı	18
Şekil 2.7.	McCulloch-Pitts nöron modeli	23
Şekil 2.8.	Genel yapay nöron modeli	23
Şekil 2.9.	Çok tabakalı ileri beslemeli yapay sinir ağı mimarisi	24
Şekil 3.1.	Yedi küme için ileri beslemeli yapay sinir ağı mimarisi	37
Şekil 3.2.	Üç küme için ileri beslemeli yapay sinir ağı mimarisi	41
Şekil 4.1.	Zaman serisi gözlemleri ve öngörülerinin birlikte grafiği	48
Şekil 4.2.	TAIFEX verisi test kümesi için gerçek değerler ve öngörülerin grafiği	51
Şekil 4.3.	“TAIEX” (Taiwan Stock Exchange) zaman serisi	52
Şekil 4.4.	TAIEX verisi test kümesi için gerçek değerler ve öngörülerin grafiği	53

ÇİZELGELER LİSTESİ

Çizelge 2.1.	Aktivasyon fonksiyonu tipine göre nöron çıktı değeri	26
Çizelge 3.1.	Bir bulanıklaştırma örneği	41
Çizelge 3.2.	Bulanık ilişkilerin belirlenmesi üzerine bir örnek	42
Çizelge 4.1.	“Belçika’da gerçekleşen ölümlü araba kazaları” zaman serisi	45
Çizelge 4.2.	Eğitim kümesi için gerçek değerler ve yöntemlerin öngörülleri	47
Çizelge 4.3.	“TAIFEX” ve “TAIEX” zaman serileri	49
Çizelge 4.4.	Test kümesi için gerçek değerler ve yöntemlerin öngörülleri	50
Çizelge 4.5.	Test kümesi için yöntemlere ait sonuçlar	53
Çizelge 4.6.	“IMKB”, “USD”, ve “EURO” zaman serileri (veri-set 1)	55
Çizelge 4.7.	“IMKB”, “USD”, ve “EURO” zaman serileri (veri-set 2)	56
Çizelge 4.8.	“IMKB”, “USD”, ve “EURO” zaman serileri (veri-set 3)	57
Çizelge 4.9.	Veri-Set 1 ve 7 gözlemlili test kümesi için yöntemlere ait sonuçlar	59
Çizelge 4.10.	Veri-Set 1 ve 15 gözlemlili test kümesi için yöntemlere ait sonuçlar	59
Çizelge 4.11.	Veri-Set 2 ve 7 gözlemlili test kümesi için yöntemlere ait sonuçlar	60
Çizelge 4.12.	Veri-Set 2 ve 15 gözlemlili test kümesi için yöntemlere ait sonuçlar	60
Çizelge 4.13.	Veri-Set 3 ve 7 gözlemlili test kümesi için yöntemlere ait sonuçlar	61
Çizelge 4.14.	Veri-Set 3 ve 15 gözlemlili test kümesi için yöntemlere ait sonuçlar	61

1. GİRİŞ

Son yıllarda birçok araştırmacının dikkatini çeken bulanık zaman serisi analizi yöntemleri, bilişim teknolojileri, ekonomi, çevre bilimleri, hidroloji gibi, oldukça geniş bir kullanım alanına sahiptir. Bunun nedeni olarak, tüm bu alanlarda üzerinde çalışılan problemleri oluşturan verilerin, içerdikleri belirsizlik nedeniyle, bulanık zaman serisi olarak ele alınmasının daha uygun olması gösterilebilir.

Bulanık zaman serileri zamanla değişir ve zamanla değişmez olmak üzere ikiye ayrılmaktadır. Zamanla değişmez bulanık zaman serilerinde ilişkinin zamanla değişmediği, zamanla değişir bulanık zaman serilerinde ise zaman serisinin iç ilişkisinin belirli bir süre sonra değiştiği varsayılmaktadır. Literatürde hem zamanla değişir hem de zamanla değişmez bulanık zaman serileri için çözüm yöntemleri geliştirilmiş olmasına rağmen çalışmaların çok büyük bir kısmını zamanla değişmez bulanık zaman serileri oluşturmaktadır. Bu tezin kapsamını da zamanla değişmez bulanık zaman serileri oluşturmaktadır.

İlk olarak Song ve Chissom (1993a) tarafından ortaya atılan bulanık zaman serileri Zadeh (1965) tarafından verilen bulanık küme teorisine dayanmaktadır. Bulanık zaman serisi öngörü yöntemleri, üzerinde birçok çalışma yapılan, üç temel aşamadan oluşmaktadır. Bunlar sırasıyla, gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve berraklaştırma aşamalarıdır.

İlk aşama olan bulanıklaştırma aşamasında evrensel küme parçalanması sırasında ihtiyaç duyulan aralık uzunlukları öngörü üzerinde oldukça etkindir. Bu nedenle aralık uzunluklarının belirlenmesi üzerine literatürde birçok çalışma mevcuttur. Bu çalışmaların birçoğunda aralık uzunluğu sabit olarak belirlenmekte olup, Song ve Chissom (1993a, 1993b, 1994) ve Chen (1996, 2002) keyfi, Huarng (2001) ortalamaya ve dağılıma dayalı ve Eğrioğlu ve ark. (2010, 2011) optimizasyona dayalı olarak aralıkları belirledikleri çalışmalar ortaya koymuşlardır. Son yıllarda ise bu aşamada, Kuo ve ark. (2009, 2010), Davari ve ark. (2009), Park ve ark (2010) ve Hsu ve ark. (2010) parçacık sürü optimizasyonunu, Chen ve Chung (2006), Lee ve ark. (2007, 2008) ise genetik algoritmaları kullanan yöntemler önermişlerdir. Bunun yanında trend içeren zaman serilerinin çözümlenmesinde, değişken aralık uzunluğuna sahip, orana dayalı yaklaşımı Huarng ve Yu (2006a) ve oranın optimizasyonuna dayalı yaklaşımı

Yolcu ve ark. (2009) ortaya koymuştur. Bulanıklaştırma aşamasında, evrensel küme parçalanmasına ihtiyaç duymayan, bulanık C-ortalama yöntemini kullanan yaklaşımlar ise Cheng ve ark. (2008) ve Li ve ark. (2008) tarafından önerilmiştir.

Bulanık zaman serilerinde bulanık ilişkilerin belirlenmesi aşaması da yöntemin öngörü performansını oldukça etkilemektedir. Bu bakımdan bu aşama üzerine de ortaya atılmış farklı yaklaşımlar mevcuttur. Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya konan çalışmalarda bulanık ilişkiler karmaşık matris operasyonları ile belirlenmektedir. Bunun yanında Chen (1996), bulanık grup ilişki tablolarına dayalı daha kolay işlemler içeren yeni bir yaklaşım önermiştir. Huarng ve Yu (2006b), Aladağ ve ark. (2009), Eğrioğlu ve ark. (2009a, 2009b, 2009c) ve Yu ve Huarng (2008, 2010) bulanık ilişkilerin belirlenmesinde yapay sinir ağlarını kullanan yaklaşımlar önermişlerdir. Bulanık ilişkilerin bulanık mantık ilişki ve grup ilişki tabloları ile belirlendiği yaklaşımlar literatürde birçok çalışmada kullanılmasına karşın, bulanık ilişkilerin yapay sinir ağları ile belirlendiği çalışmalara da özellikle son yıllarda sıklıkla rastlanmaktadır.

Berraklaştırma aşamasında genel olarak merkezileştirme yöntemi kullanılmakla birlikte, Jilani ve Burney (2007, 2008) ve Jilani ve ark. (2007) bazı farklı yöntemler ortaya koymuşlardır.

Bazı bulanık zaman serilerinin çözümlenmesinde birinci dereceden bulanık zaman serisi öngörü modelleri yeterli olmakla birlikte karşılaşılan birçok gerçek hayat probleminin, içerdikleri karmaşık ilişkiler nedeniyle, yüksek dereceli bulanık zaman serisi öngörü modelleri ile çözümlenmesi daha uygun olacaktır. Bulanık zaman serisi yöntemlerinin aşamaları ile ilgili verilen literatürde değinilen çalışmalardan, Song ve Chissom (1993a, 1993b, 1994), Chen (1996), Huarng (2001), Davari ve ark. (2009), Huarng ve Yu (2006a, 2006b), Yolcu ve ark. (2009), Cheng ve ark. (2008), Li ve ark. (2008) ve Yu ve Huarng (2008, 2010) çalışmalarında bulanık zaman serisi çözümlemesi için birinci dereceden modeller kullanılırken, Chen (2002), Eğrioğlu ve ark. (2010), Kuo ve ark. (2009, 2010), Park ve ark (2010), Hsu ve ark. (2010), Chen ve Chung (2006), Lee ve ark. (2007, 2008), Aladağ ve ark. (2009), Eğrioğlu ve ark. (2009a, 2009c), Jilani ve Burney (2007, 2008) ve Jilani ve ark. (2007) çalışmalarında ise yüksek dereceden modeller kullanılmıştır. Bunun yanında karşılaşılan bazı bulanık zaman

serileri mevsimsel ilişkiler içerebilir. Bu tip bulanık zaman serilerinin öngörülmesinde mevsimsel bulanık zaman serisi öngörü modelleri kullanılmalıdır. Chang (1997), Song (1999) ve Eğrioğlu ve ark. (2009b) literatürde, mevsimsel ilişkiler içeren bulanık zaman serilerinin analizi için önerilmiş ender çalışmalardan bazılarıdır.

Benzer şekilde bir kısım bulanık zaman serisi tek değişkenli modellerle çözümlenebilmekle birlikte, birçok bulanık zaman serisinin çözümlenmesinde iki ya da çok değişkenli bulanık zaman serisi öngörü modellerine ihtiyaç duyulmaktadır. Bu bakımdan literatürde, Song ve Chissom (1993a, 1993b, 1994), Chen (1996, 2002), Huarng (2001), Eğrioğlu ve ark. (2010, 2011), Kuo ve ark. (2009, 2010), Davari ve ark. (2009), Chen ve Chung (2006), Huarng ve Yu (2006a, 2006b), Yolcu ve ark. (2009), Aladağ ve ark. (2009), Yu ve Huarng (2010), Chang (1997) ve Song (1999) tek değişkenli, Park ve ark (2010), Hsu ve ark. (2010), Lee ve ark. (2006, 2007, 2008), Li ve ark. (2008), ve Eğrioğlu ve ark. (2009b, 2009c) iki değişkenli ve Cheng ve ark. (2008), Eğrioğlu ve ark. (2009a), Jilani ve Burney (2007, 2008), Jilani ve ark. (2007), Huarng ve ark. (2007), ve Chen ve Chen (2011) ise çok değişkenli bulanık zaman serisi öngörü modellerini içeren yaklaşımlar ortaya koymuşlardır.

Bulanık zaman serisi yöntemlerinde, bulanıklaştırma aşaması sırasında evrensel küme parçalanmasında kullanılan aralık uzunluklarının yöntemin öngörü performansı üzerindeki etkisi literatürde birçok çalışmada gösterilmiştir. Bu bakımdan bu aralıkların daha sistematik ya da öngörü doğruluğunu arttıracak yönde optimizasyon ile belirlenmesi gerekmektedir. Bununla birlikte bu aşamada evrensel küme parçalanmasına ihtiyaç duymayan ve böylece yöntemi sübjektif yargılardan uzak tutan, bulanık kümeleme yöntemleri de kullanılabilir.

Bulanık ilişki belirlenmesi aşamasında ise farklı yaklaşımların farklı öngörü performansları sergilediği de araştırmacılar tarafından gösterilmiştir. Bu aşamada, sıklıkla bulanık mantık grup ilişki tabloları kullanılmakla beraber son çalışmalarda yapay sinir ağları da kullanılmaktadır. Ancak tüm bu yaklaşımlarda, bulanık ilişkiler belirlenirken, gözlemlerin ait olduğu kümeleri temsil eden küme numaraları ile işlem yapılmaktadır. Oysaki bir bulanık zaman serisi gözlemi, ait olduğu düşünülen bulanık küme dışında diğer kümelere de belirli üyelik değerleri ile aittir. Bu bakımdan 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 (hedefleri) gözlemlerin üyelik değerlerinden oluşan yapay sinir ağlarını bulanık ilişkilerin belirlenmesinde kullanmıştır. Bu durumda da gözlemlerin bulanık kümelere ait olmasının üyelik değerlerinin nasıl belirleneceği problemi ortaya çıkmaktadır. Yu ve Huarng (2010) tarafından önerilen yaklaşımda, evrensel küme parçalanması kullanılmasının yanı sıra, her bir gözlemin belirlenen bulanık kümelere ait olmasının üyelik değerleri de keyfi olarak belirlenmektedir. Ancak daha önce de vurgulandığı gibi, bulanık ilişkilerin belirlenmesi aşamasında kullanılan yapay sinir ağlarının girdi ve çıktılarını (hedeflerini) oluşturan bu üyelik değerleri öngörü performansını oldukça etkilemektedir. Bu sorunları ortadan kaldırmak adına, Yolcu ve ark (2010), bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan bulanık C-ortalama yöntemini kullanan ve bulanık ilişkilerin belirlenmesi aşamasında girdileri ve çıktılarını (hedefleri), bulanık C-ortalama yöntemi ile belirlenen üyelik değerlerinden oluşan yapay sinir ağlarını kullandığı bir yöntem önermişlerdir.

Yolcu ve ark. (2010) tarafından önerilen bulanık zaman serisi analizi yaklaşımı ile ortadan kaldırılan sorunların yanında, göz önüne alınması gereken diğer bir husus da, bulanık zaman serilerinin öngörülmesinde bulanık zaman serisinin kendi gecikmeli değişkeninin yanı sıra farklı bulanık zaman serilerinden ve onların gecikmeli değişkenlerinden de etkilenebileceğidir. Bu nedenle gerçek hayat bulanık zaman serilerinin büyük bir kısmının öngörülmesinde, diğer bazı bulanık zaman serileri ile aralarında mevcut olan bulanık ilişkileri ortaya çıkaracak, çok değişkenli bulanık zaman serisi öngörü modelinin oluşturulması gerekmektedir.

Bu tez kapsamında önerilen yöntem, bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan, her bir gözlemin bulanık kümelere ait olma üyelik değerlerinin subjektif yargılardan uzak belirlendiği, bulanık C-ortalama yöntemini, bulanık ilişki belirlenmesi aşamasında, girdileri ve çıktılarını (hedefleri) belirlenen üyelik değerlerinden oluşan yapay sinir ağlarını kullanan, iki ya da çok değişkenli bir bulanık zaman serisi öngörü modelini içermektedir. Önerilen yöntemin performans değerlendirmesi dört farklı veriye uygulanarak gerçekleştirilmiş ve dikkat çekici sonuçlara ulaşılmıştır.

Çalışmanın ikinci bölümünde, genel bilgiler başlığı altında, bulanık mantık, yapay sinir ağları ve bulanık C-ortalamlar hakkında temel bilgiler verilecektir. Üçüncü bölümde, materyal ve yöntem başlığı altında, bulanık zaman serisi ve temel kavramları özetlenecek, bu tezde önerilen yönteme esas teşkil eden ve Yolcu ve ark. (2010) tarafından ortaya konan yöntem ve sonrasında bu çalışmada önerilen çok değişkenli bulanık zaman serisi yöntemi tanıtılarak algoritması verilecektir. Dördüncü bölümde ise, bulgular ve tartışma ana başlığı altında önerilen yeni yöntem 4 farklı gerçek hayat zaman serisine uygulanarak, elde edilen sonuçlar diğer bazı yöntem sonuçları ile birlikte özetlenecektir. Son olarak beşinci bölümde, elde edilen sonuçlar değerlendirilip tartışılacak ve gelecek çalışmalar ile ilgili öneriler ortaya konmaya çalışılacaktır.

2. GENEL BİLGİLER

2.1. Bulanık Mantık

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

Geleneksel mantıkta, önermelerin tamamen doğru veya tamamen yanlış olduğu kabul edildiğinden iki değerli mantık olarak adlandırılabilir. Bunun yanında, geleneksel kümelerle dayanarak oluşturulan önermelerin, ikiden fazla doğruluk değeri ile eşleştirilebildiği mantık sistemleri ise çok değerli mantık olarak adlandırılır. Çok değerli mantıkta önermelerin tamamen doğru, tamamen yanlış ve kısmen doğru (kısmen yanlış) olduğu kabul edilir. Bulanık mantık, belirsizlik altında akıl yürütme ile çok değerli mantığın birleştirildiği bir sistemdir. (Özkan, 2003).

Bulanık mantık, bulanık küme teorisine dayanan bir matematiksel disiplin olup, insan mantığında olduğu gibi, uzun-kısa, sıcak-soğuk, hızlı-yavaş, siyah-beyaz gibi keskin değerler yerine, çok uzun-uzun-orta-kısa-çok kısa, sıcak-ılık-az soğuk-soğuk-çok soğuk vb. gibi ara değerlere göre çalışmaktadır. Belirtilen bu ara değer terimleri sözel terimler olup bulanık değişkenler olarak isimlendirilir. Bulanık mantık için, gerçek dünyada her an değişen durumlarda değişik sonuçlar ortaya çıkabileceğinden, matematiğin gerçek dünyaya uygulanması denilebilir.

Bulanık mantık yaklaşımı, makinelere, insanların özel verilerini işleyebilme ve onların deneyimlerinden ve önsezilerinden yararlanarak çalışabilme yeteneği verir. Bu yeteneği kazandırırken de sayısal ifadeler yerine sembolik ifadeler kullanır ki bu

sembolik ifadelerin makinelere aktarılması matematiksel bir temele dayanır. Bu matematiksel temel, bulanık küme kuramı ve buna dayanan bulanık mantıktır.

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

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


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

Bulanık mantık uygulaması ilk olarak, 1974 yılında Mamdani tarafından, bir buhar makinesinin bulanık denetiminin gerçekleştirilmesi ile olmuştur. Bu çalışmayı takiben, dünyanın çeşitli yerlerindeki birçok firma birçok başarılı uygulama gerçekleştirmiştir. Bulanık mantık uygulamaları, son senelerde özellikle Japonya, Amerika ve Almanya'da ticari ve endüstri alanlarında oldukça yaygın ve başarıyla gerçekleştirilmekte ve gelecekte de bu uygulamaların hızla gelişeceği ve yaygınlaşacağı öngörülmektedir. Bulanık kuramının uygulamalarının ürünleri de Japonya'da 1990 yılında tüketicilerin hizmetine sunulmaya başlanmıştır. Örneğin, bulanık denetimli çamaşır makinesi, çamaşırın cinsine, miktarına, kirliliğine göre en etkili yıkama ve su

kullanım programını seçebilmektedir. Benzer uygulamalar arabalarda yakıt püskürtme ve ateşlemede, elektrik süpürgesi, televizyon ve müzik kümeleri gibi aygıtlarda da kullanılabilir (Elmas, 2003).

2.1.1. Bulanık Küme Kuramı

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




Şekil 2.1. Klasik küme için sıcaklık örneği

Klasik kümelere örnek olarak, Şekil 2.1. incelendiğinde, sıcaklığın 20°C 'nin altında olmasının soğuk, üstünde olmasının ise sıcak olarak nitelendirildiği görülür. Bu durumda $19,5^{\circ}\text{C}$ sıcak değildir. Doğal olarak bu mantığın esnekliği söz konusu değildir. Oysaki gerçek yaşamda ise, sınırlar bu kadar keskin çizgilerle nitelendirilemez.

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

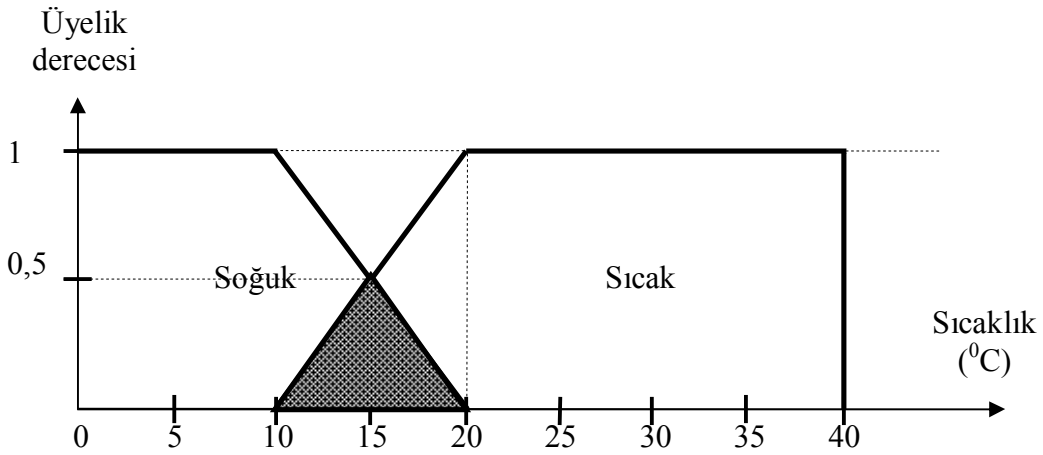
soğuk, biraz sıcak, biraz aydınlık gibi esnek betimleyicilerle esnetilerek gerçek yaşam şartlarına benzetilirler.

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



Şekil 2.2. Bulanık küme için sıcaklık örneği

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



Şekil 2.3. Bulanık kümelerde örtüşüm

Bulanık kümeler kuramını gerektiğince anlayabilmek için, bulanık kümeler, bulanık sayılar, genişleme prensibi, alfa(α) kesim ve aralık aritmetiği, gibi, bulanık kümeler kuramına temel oluşturacak, kavramlar tanımlanmalıdır.

2.1.1.1. Bulanık Kümeler ve Üyelik Fonksiyonu

Ele alınan herhangi bir konuya ilişkin bilgi, küme terimiyle sistematik olarak bir araya toplanır. İyi tanımlı nesnelere topluluğu veya sınıfı küme adını alır. Bir kümeyi oluşturan nesnelere her birine kümenin elemanları (öge, üye) ve üzerinde çalışılan kümelerin her birini alt küme olarak kabul eden en geniş kümeye evrensel küme denir. Geleneksel bir küme, evrensel kümedeki nesnelere ortak özelliklerine göre bir araya getirilme işlemi olarak ifade edilebilir. Geleneksel bir kümenin elemanları, mantıkta yer alan ikiye bölme kuralına (1 veya 0, doğru veya yanlış, evet veya hayır vb.) dayanarak belirlenir (Özkan, 2003).

Bazı kümelerin yapıları gereği geleneksel anlamda oluşturulması doğru değildir. Canlı veya cansız, 2 ile tam bölünebilen veya bölünemeyen sayılar gibi ifadeler geleneksel kümelere dayanarak oluşturulan önermeleri ifade etmek için uygun örnekler olmasına karşın bazı kümeler çok net sınırlarla ifade edilemezler. Çünkü “belirli bir toplulukta yaşlı, zeki ya da zengin olanlar” gibi küme üyeliğini belirleyen sınır koşulu net olarak ifade edilemeyebilir. Bulanık bir küme ise sınır koşulları esnek olarak tanımlanan bir kümedir. Bulanık küme teorisi kısmi üyeliğe izin vererek geleneksel

küme teorisini genelleştirir ve küme üyeliği için $[0,1]$ aralığındaki herhangi bir değeri kabul eder (Özkan, 2003).

Bulanık bir küme, evrensel kümedeki her bir elemanın $[0,1]$ aralığındaki bir sayı ile eşlendiği bir üyelik fonksiyonu olarak aşağıdaki gibi tanımlanır (Jamshidi, 1997).

$$\mu_{\tilde{A}}(x) \rightarrow [0,1] \quad (2.1)$$

Bulanık kümelerde bir nesnenin üyelik derecesinin 0 olması ilgili nesnenin bulanık kümenin üyesi olmadığı, 1 olması ise tam üyesi olduğu anlamına gelirken, üyelik derecesinin bu iki değer arasında olması kısmi üyeliği gösterir. Buradan hareketle, bulanık küme teorisinde kümenin elemanı olmayan nesnelere kümenin tam elemanı olan nesnelere doğru esnek ve dereceli bir geçiş olduğu söylenebilir.

Bulanık bir küme, bir nesne ve bu nesnenin ilgili kümeye üyelik derecesini gösteren sıralı çiftlerle ifade edilebilir (Zimmermann1993).

$$\tilde{A} = \left(x, \mu_{\tilde{A}}(x) \right), \forall x \in U \quad (2.2)$$

Burada her bir $(x, \mu_{\tilde{A}}(x))$ çiftine bir “bulanık teklik” adı verilir. Bunun yanında bir bulanık teklik,

$$\mu_{\tilde{A}}(x) /_x \quad (2.3)$$

şeklinde de tanımlanabilir (Tsoukalas ve Uhrig, 1997). Bulanık kümelerde, üyelik derecesi 0 olan bulanık teklikler genellikle gösterilmez. Bu durumda evrensel küme sonlu olduğunda bir bulanık küme (2.4) ifadesi ile verilebilir.

$$\tilde{A} = \sum_{i=1}^n \frac{\mu_{\tilde{A}}(x_i)}{x_i} = \frac{\mu_{\tilde{A}}(x_1)}{x_1} + \frac{\mu_{\tilde{A}}(x_2)}{x_2} + \dots + \frac{\mu_{\tilde{A}}(x_n)}{x_n} \quad (2.4)$$

Everensel kümenin sonsuz olması durumunda ise bulanık küme (2.5) ifadesi ile verilir.

$$\underline{A} = \int \frac{\mu_{\underline{A}}(x_i)}{x_i}, \quad \forall x_i \in U \quad (2.5)$$

Yukarıda verilen tüm ifadelerde kullanılan, Σ , \int , $/$ ve $+$ işaretleri cebirsel anlamda sırasıyla toplam, integral alma, bölme ve toplama işlemlerini göstermez. Σ ve \int işaretleri, bulanık tekliklerin sırasıyla kesikli ve sürekli evrenlerde bir araya getirilmesini ifade ederken, $/$ simgesi, matematiksel olarak $(x, \mu_{\underline{A}}(x))$ tekliğini ifade etmek için kullanılan bir araçtır. $+$ işareti ise, bulanık tekliklerin birleşimini ifade eder.

2.1.1.2. Bulanık Kümelerle İlgili Bazı Kavramlar

Bulanık bir kümenin üyelik fonksiyonunun en büyük üyelik derecesi, ilgili bulanık kümenin yüksekliğini gösterir. Yükseklik aşağıda verilen formül ile ifade edilebilir (Fedrizzi, 1987).

$$\text{yükseklik}(\underline{A}) = \sup [\mu_{\underline{A}}(x)], \quad \forall x \in U \quad (2.6)$$

\underline{A} kümesinin sonlu bir evrensel kümede tanımlı olması durumunda (2.6) eşitliğindeki en küçük üst sınırı gösteren \sup (*supremum*) teriminin yerine *max* (*maksimum*) terimi kullanılır.

Yüksekliği 1'e eşit olan bulanık kümeler normal bulanık kümeler olarak adlandırılırlar. Normal bir bulanık küme aşağıdaki gibi ifade edilebilir (Özkan, 2003).

$$\text{yükseklik}(\underline{A}) = \sup [\mu_{\underline{A}}(x)] = 1, \quad \exists x \in U \quad (2.7)$$

Yüksekliği birden küçük olan kümeler ise, normal altı bulanık kümeler olarak adlandırılır. Normal altı bir bulanık kümede kümenin herhangi bir elemanı, ilgili bulanık kümeye yalnızca kısmen üyedir. Normal altı bir bulanık kümenin normal bir bulanık kümeye dönüştürülmesi aşağıdaki ifade ile gerçekleştirilebilir (Özkan, 2003).

$$NORM(\underline{A}) = \frac{yükseklik(\underline{A})}{\mu_{\underline{A}}(x)},$$

$$\forall x \in U \quad (2.8)$$

Bulanık bir kümenin üyelik fonksiyonunda, üyelik derecesi sıfırdan büyük elemanlardan oluşan küme destek kümesi olarak isimlendirilir. Destek kümesi bulanık olmayan, yani geleneksel bir kümedir. Destek kümesi (2.9) eşitliği ile ifade edilebilir (Dubois ve Prade, 1980).

$$Destek(\underline{A}) = \{x \in U \mid \mu_{\underline{A}}(x) > 0\} \quad (2.9)$$

Bulanık bir kümeye tamamen üye olan yani üyelik fonksiyonundaki üyelik derecesi 1 olan elemanların oluşturduğu kümeye kernel kümesi denir ve aşağıdaki ifade ile verilebilir (Lin ve Lee, 1996).

$$Kernel(\underline{A}) = \{x \in U \mid \mu_{\underline{A}}(x) = 1\} \quad (2.10)$$

Bulanık bir kümeye kısmen üye olan elemanlardan oluşan geleneksel küme sınır kümesi adını alır ve (2.11) ifadesi ile verilebilir (Timoty, 1995).

$$Sınır(\underline{A}) = \{x \in U \mid 0 < \mu_{\underline{A}}(x) < 1\} \quad (2.11)$$


Bulanık bir kümeye ilişkin üyelik fonksiyonunun maksimum değeri sonlu sayıda olduğunda, ilgili bulanık kümede yer alan elemanların üyelik derecelerinin ortalama değeri, bulanık kümenin merkezini verecektir. Üyelik fonksiyonunun maksimum değerine ulaştığı noktalar arasından en büyük (ya da en küçük) olan nokta da merkez adını alır (Özkan, 2003). Şekil 2.4'de \underline{A} , \underline{B} , \underline{C} ve \underline{D} kümeleri için merkez noktaları grafik olarak verilmiştir. Şekil 2.4 incelendiğinde \underline{A} , \underline{B} , \underline{C} ve \underline{D} kümelerine ilişkin merkez noktaların sırasıyla $x = 2$, $x = 5$, $x = 9$ ve $x = 13$ olduğu görülür.

Bulanık bir kümenin α -kesimi ise üyelik fonksiyon değeri α 'ya eşit veya daha büyük olan elemanların oluşturduğu bulanık olmayan bir kümedir. Seçilen farklı α değerleri farklı bir α -kesim kümesi oluşturur. α , $\alpha \in (0, 1]$ koşulu ile tanımlanan gerçel bir

sayıdır. α değeri arttıkça α -kesimi ile oluşturulan geleneksel kümedeki eleman sayısı azalacaktır. α -kesim kümesi (2.12) eşitliği ile ifade edilebilir (Li ve Yen, 1995).

$$A_\alpha = \{x \in U \mid \mu_{\tilde{A}}(x) \geq \alpha\}, \alpha \in (0, 1] \quad (2.12)$$

α -kesim kümesi, $\alpha = 0$ olduğunda evrensel kümeye, $\alpha = 1$ olduğunda ise kernel kümesine denk gelmektedir. Ve sırasıyla, $A_0 = U$ ve $A_1 = \text{Kernel}(\tilde{A})$ şeklinde ifade edilir (Kendel, 1986).



Şekil 2.4. Farklı bulanık kümeler için merkez noktalar

2.1.1.3. Genişleme Kuralı

Genişleme kuralı, matematiksel kavram ve teorilerin bulanık ortamda kullanılmasını sağlayan bir yöntemdir. x ve y değişkenleri sırasıyla \tilde{A} ve \tilde{B} bulanık kümelerindeki elemanları gösterebilir. Ayrıca \tilde{A} ve \tilde{B} kümelerinin sırasıyla U ve V

evrenlerinde tanımlı olduğu kabul edilsin. Bunun yanında \underline{A} kümesinin üyelik fonksiyonu (2.13)'deki gibi verilsin.

$$\underline{A} = \frac{\mu_{\underline{A}}(x_1)}{x_1} + \frac{\mu_{\underline{A}}(x_2)}{x_2} + \dots + \frac{\mu_{\underline{A}}(x_n)}{x_n} \quad (2.13)$$

Böylesi bir durumda, x ve y değişkenleri arasında fonksiyonel bir ilişki varsa veya bu değişkenlerin tanımlı olduğu evrensel kümeler arasında $f: U \rightarrow V$ şeklinde bir eşleşme söz konusu ise, \underline{B} kümesinin üyelik fonksiyonu, genişleme kuralı ile aşağıdaki gibi elde edilir (Jamshidi, 1997).

$$\underline{B} = f(\underline{A}) = f\left(\frac{\mu_{\underline{A}}(x_1)}{x_1} + \frac{\mu_{\underline{A}}(x_2)}{x_2} + \dots + \frac{\mu_{\underline{A}}(x_n)}{x_n}\right) = \frac{\mu_{\underline{A}}(x_1)}{f(x_1)} + \frac{\mu_{\underline{A}}(x_2)}{f(x_2)} + \dots + \frac{\mu_{\underline{A}}(x_n)}{f(x_n)} \quad (2.14)$$

Burada, $y = f(x)$ fonksiyonunun birebir özellikte olması gerekir. Diğer bir ifadeyle, x değişkeninin alabileceği değerleri gösteren evrensel kümeden (tanım kümesi U 'dan), y değişkeninin alabileceği değerleri gösteren evrensel kümeye (değer kümesi V 'ye) doğru bire bir nitelikte fonksiyonel bir eşleşme olmalıdır. Genişleme kuralı, bulanık bir küme ve fonksiyonel bir ilişkinin yeni bir bulanık kümeyle sonuçlanacağını ifade eder (Tsoukalas ve Uhrig, 1997). Burada \underline{B} kümesindeki elemanların üyelik derecelerinin, \underline{A} kümesinde yer alan elemanların üyelik derecelerinden oluştuğuna dikkat edilmelidir. $y = f(x)$ fonksiyonundan elde edilen $x = f^{-1}(y)$ ters fonksiyonunda, y değişkeni için x hesaplanamıyorsa, ilgili elemanın üyelik değeri sıfır olarak kabul edilir.

Tanım kümesi, U 'nun birden fazla elemanı, değer kümesi V 'de aynı eleman ile eşleşiyor ise veya $y = f(x)$ fonksiyonunda farklı x değerleri ile aynı y değerleri elde ediliyorsa, tanım kümesindeki bu elemanlar (x_i) arasından, üyelik derecesi en büyük olan eleman ($\max(x_i)$), değer kümesi V 'de ilgili y elemanının üyelik derecesini belirler. Bu durum, matematiksel olarak aşağıdaki gibi ifade edilir (Lin ve Lee, 1996).

$$\mu_{\underline{B}=f(\underline{A})}(y) = \max \left[\mu_{\underline{A}}(x_i) \right], \quad \begin{array}{l} x_i \in U, \\ y = f(x) \end{array} \quad (2.15)$$

Burada, x_i aynı y ile eşleşen elemanları göstermektedir. Tanım kümesindeki herhangi bir elemanın değer kümesindeki elemanlar ile eşlenememesi durumunda, ilgili y elemanının üyelik derecesi sıfır olarak kabul edilir.

2.1.2. Bulanık Sayılar


Bulanık sayılar, bulanık kümelerin özel bir alt kümesidir. 8 civarı, hemen hemen 15, 300'den küçük vb. gibi kesin olmayan ya da yaklaşık olarak ifade edilen sayısal miktarların nitelenmesinde bulanık sayıların kullanımı daha doğru bir yaklaşım olacaktır. Bulanık sayıların tanımlı olduğu evrensel küme, gerçel sayılar kümesi, tamsayılar kümesi ya da doğal sayılar kümesidir. Her bulanık sayı bulanık bir küme olmasına karşın, her bulanık küme bulanık bir sayı değildir. Bulanık bir kümenin bulanık bir sayı olabilmesi için, aşağıda verilen özelliklerin gerçekleşmesi gerekmektedir (Pedrycz, 1989).

- Bulanık küme normal bir bulanık küme olmalıdır.
- Bulanık küme, dış bükey bir bulanık küme olmalıdır.
- Bulanık kümenin destek kümesi sınırlı olmalıdır.
- Bulanık kümenin her bir α -kesimi, gerçel sayı doğrusunun kapalı bir aralığında tanımlı olmalıdır.

Bulanık sayının genel bir tanımı Buckley ve Elsamî (2002), Klir ve Yuan (1995) tarafından yapılan çalışmalardan da edinilebilir. Bu çalışmada bulanık sayılardan, üçgensel ve yamuk bulanık sayılar ile ilgili bilgilerin verilmesi yeterli görülmüştür. Bu bulanık sayılar, isimlerini üyelik fonksiyonlarının biçimlerinden alırlar. Gerçel sayı doğrusunda tanımlı olan üçgensel bir bulanık sayı (2.16)'da verildiği şekilde tanımlanır (Pedryca ve Gomide, 1998).

$$\mu_{\tilde{A}}(x) = \mu_{\tilde{A}}(x; a, b, c) = \begin{cases} \frac{x-a}{b-a} & ; a \leq x \leq b \\ \frac{c-x}{c-b} & ; b \leq x \leq c \\ 0 & ; x \geq c \text{ veya } x \leq a \end{cases} \quad (2.16)$$

Burada, b parametresi üyelik derecesinin 1'e eşit olduğu noktayı verir. a ve c parametreleri ise, üçgensel bulanık bir sayının kanat açıklıklarını veya üyelik derecesinin sıfır olduğu noktaları gösterir. $a = 1,2$, $b = 2$ ve $c = 2,4$ olduğu durumda üçgensel bir bulanık sayı Şekil 2.5'de verildiği gibi olacaktır.




Şekil 2.5. Üçgensel bulanık sayı

Gerçel sayı doğrusunda tanımlı olan yamuk bir bulanık sayı ise (2.17)'de verildiği gibi ifade edilir (Wang, 1997).

$$\mu_{\tilde{A}}(x) = \mu_{\tilde{A}}(x; e, f, g, h) = \begin{cases} \frac{x-e}{f-e} & ; e \leq x \leq f \\ 1 & ; f \leq x \leq g \\ \frac{h-x}{h-g} & ; g \leq x \leq h \\ 0 & ; x \geq h \cup x \leq e \end{cases} \quad (2.17)$$

Burada, e ve h parametreleri yamuksal bir bulanık sayının kanat açıklıklarını ya da üyelik derecesinin sıfır olduğu elemanları, f ve g parametreleri ise, bulanık sayının kernel kümesini gösterir. $e = 1,2$, $f = 2$, $g = 2,4$ ve $h = 2,7$ olduğu durumda üçgensel bir bulanık sayı Şekil 2.6'da verildiği gibi olacaktır.



Şekil 2.6. Yamuk bulanık sayı

Bulanık sayılarla hesap yapmanın temeli aralık aritmetiğine dayanır. Aralık analizi, bulanık sayılarda bir çeşit güven aralığı olarak algılanabilir. Bulanık sayıların α -kesimlerinin gerçel sayı doğrusunun kapalı bir aralığında tanımlı olduğundan, aralık halinde ifade edilen sayılar için temel cebirsel işlemler aşağıda verildiği gibi olacaktır (Kerre ve Scooten, 1988).

Toplama:

$$[a, b] + [c, d] = [a + c, b + d] \quad (2.18)$$

Çıkarma:

$$[a, b] - [c, d] = [a - c, b - d] \quad (2.19)$$

Çarpma:

$$[a, b] \times [c, d] = [\min(a \times c, a \times d, b \times c, b \times d), \max(a \times c, a \times d, b \times c, b \times d)] \quad (2.20)$$

Bölme:

$$[a, b] / [c, d] = [\min(a/c, a/d, b/c, b/d), \max(a/c, a/d, b/c, b/d)], c \neq 0, d \neq 0 \quad (2.21)$$

Eğer incelenen aralıklar negatif olmayan gerçel sayı doğrusu üzerinde tanımlıysalar, çarpma ve bölme işlemleri sırasıyla aşağıdaki ifadelere dönüşür.

$$[a, b] \times [c, d] = [a \times c, b \times d] \quad (2.22)$$

$$[a, b] \div [c, d] = [a \div d, b \div c] \quad (2.23)$$

Ters alma:

$$[a, b]^{-1} = [\min(1 \div a, 1 \div b), \max(1 \div a, 1 \div b)] , a \neq 0, b \neq 0 \quad (2.24)$$

Skaler sayı k ile çarpma:

$$k \times [a, b] = [k, k] \times [a, b] = [k \times a, k \times b] , k > 0 \quad (2.25)$$

Maksimum (\vee):

$$[a, b] \vee [c, d] = [\max(a \vee c), \max(b \vee d)] \quad (2.26)$$

Minimum (\wedge):

$$[a, b] \wedge [c, d] = [\min(a \wedge c), \min(b \wedge d)] \quad (2.27)$$

2.1.2.1. Bulanık Sayılarda Cebirsel İşlemler

Geleneksel sayılarda olduğu gibi bulanık sayılarda da temel cebirsel işlemler kolaylıkla uygulanabilir. Literatürde, bulanık sayılarda temel cebirsel işlemler için yaygın olarak α -kesim yöntemi ve genişleme kuralı kullanılmaktadır. Bu iki yöntem temel cebirsel işlemler için özdeş sonuçlar vermektedir.

α -kesim yöntemi ile \underline{A} ve \underline{B} sayılarına uygulanan temel cebirsel işlemler yeni bir bulanık sayı doğurur. \underline{A} ve \underline{B} bulanık sayılarının α -kesimleri, $A_\alpha = [a_1^{(\alpha)}, a_2^{(\alpha)}]$ ve $B_\alpha = [b_1^{(\alpha)}, b_2^{(\alpha)}]$ olarak belirlendiğinde, bu iki bulanık sayının α -kesimleri arasında aşağıdaki ilişkiler oluşturulabilir (Wang, 1997).

$$(A + B)_\alpha = A_\alpha + B_\alpha = C_\alpha \quad (2.28)$$

$$(A - B)_\alpha = A_\alpha - B_\alpha = D_\alpha \quad (2.29)$$

$$(A \times B)_\alpha = A_\alpha \times B_\alpha = E_\alpha \quad (2.30)$$

$$(A \div B)_\alpha = A_\alpha \div B_\alpha = F_\alpha \quad (2.31)$$

Buradan, \underline{A} ve \underline{B} sayılarının α -kesimlerine sırasıyla toplama, çıkarma, çarpma ve bölme işlemlerinin uygulanması ile elde edilen \underline{C} , \underline{D} , \underline{E} ve \underline{F} sayılarının α -kesimleri aşağıda verildiği gibi olacaktır (Lai ve Hwang, 1992).

$$C_\alpha = [a_1^{(\alpha)} + b_1^{(\alpha)}, a_2^{(\alpha)} + b_2^{(\alpha)}] = [c_1^{(\alpha)}, c_2^{(\alpha)}] \quad (2.32)$$

$$D_\alpha = [a_1^{(\alpha)} - b_1^{(\alpha)}, a_2^{(\alpha)} - b_2^{(\alpha)}] = [d_1^{(\alpha)}, d_2^{(\alpha)}] \quad (2.33)$$

$$E_\alpha = [a_1^{(\alpha)} \times b_1^{(\alpha)}, a_2^{(\alpha)} \times b_2^{(\alpha)}] = [e_1^{(\alpha)}, e_2^{(\alpha)}] \quad (2.34)$$

$$F_\alpha = [a_1^{(\alpha)} \div b_1^{(\alpha)}, a_2^{(\alpha)} \div b_2^{(\alpha)}] = [f_1^{(\alpha)}, f_2^{(\alpha)}] \quad (2.35)$$

Aynı temel cebirsel işlemler genişleme kuralı ile aşağıda verildiği şekilde gerçekleştirilir (Buckley ve Siler, 1988).

$$\mu_{\underline{C}}(z) = \max \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(y)) \quad , z = x + y \quad (2.36)$$

$$\mu_{\underline{D}}(z) = \max \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(y)) \quad , z = x - y \quad (2.37)$$

$$\mu_{\underline{E}}(z) = \max \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(y)) \quad , z = x \times y \quad (2.38)$$

$$\mu_{\underline{F}}(z) = \max \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(y)) \quad , z = x \div y \quad (2.39)$$

2.1.2.2. Bulanık Sayılarda Minimum ve Maksimum

Gerçel sayı doğrusu üzerinde tanımlı iki bulanık sayının minimum ve maksimumu α -kesimlerine göre aşağıda verilen ifadelerle elde edilebilir.

$$\text{Minimum: } A_\alpha(\wedge)B_\alpha = [\{\min(a_1^{(\alpha)}, b_1^{(\alpha)})\}, \{\min(a_2^{(\alpha)}, b_2^{(\alpha)})\}] \quad (2.40)$$

$$\text{Maksimum: } A_\alpha(\vee)B_\alpha = [\{\min(a_1^{(\alpha)}, b_1^{(\alpha)})\}, \{\min(a_2^{(\alpha)}, b_2^{(\alpha)})\}] \quad (2.41)$$

2.2. Yapay Sinir Ağları (YSA)

Yakın geçmişte bulanık zaman serilerinin analizinde ilişki belirleme ve bunun gibi belirli aşamalarında, diğer yöntemlere seçenek olarak yapay sinir ağları (YSA) yöntemi de kullanılmaya başlanmıştır. Huarng ve Yu (2006b) çalışmalarında bulanık zaman serilerinde bulanık ilişkilerin belirlenmesinde ileri beslemeli yapay sinir ağı kullanmışlardır. Bunun yanında son yıllarda, bulanık ilişkilerin YSA ile belirlendiği ve Aladağ ve ark. (2009), Eğrioğlu ve ark. (2009a, 2009b, 2009c) ve Yu ve Huarng (2010) tarafından ortaya konan çalışmalara da rastlanmaktadır. YSA ile bulanık ilişki belirlenmesi, özellikle yüksek dereceli modellerde kolaylık sağlar ve bulanık mantık ilişki ve grup ilişki tablolarının oluşturulmasındaki karmaşıklığı ortadan kaldırdığı gibi öngörülerini de iyileştirir.

Diğer analiz yöntemlerine göre daha iyi sonuçlar elde edildiğinden, YSA'na olan ilgi giderek artmıştır. Bu bölümde, YSA'nın bileşenleri ve öngörü probleminde YSA'nın kullanımı ile ilgili temel bilgiler verilecektir.

Yapay sinir ağları, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgi türetebilme, yeni bilgi oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan doğrudan gerçekleştirmek amacı ile geliştirilen algoritmalar olarak tanımlanabilir (Öztemel, 2003). YSA, biyolojik sinir ağlarını taklit eden sentetik ağlar olarak da tanımlanabilir. Günümüzde, YSA, kullanım kolaylığı ve ürettiği iyi sonuçlardan dolayı, matematik, istatistik, fizik, mühendislik ve bilgisayar bilimleri uygulama alanlarında başarıyla kullanılmaktadır.

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

YSA genel olarak, biyolojik sinir ağlarından esinlenerek oluşturulmuş matematiksel algoritmalar şeklinde tanımlanabilir. Matematiksel bir algoritma olarak

tanımlanan YSA, örneklerden öğrenebilen ve öğrendiğini genelleştirebilen algoritmadır. Ağ gösterimi, matematiksel algoritmanın grafiksel ifadesidir. (Günay ve ark., 2007).

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


2.2.1. Mimari Yapı

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

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

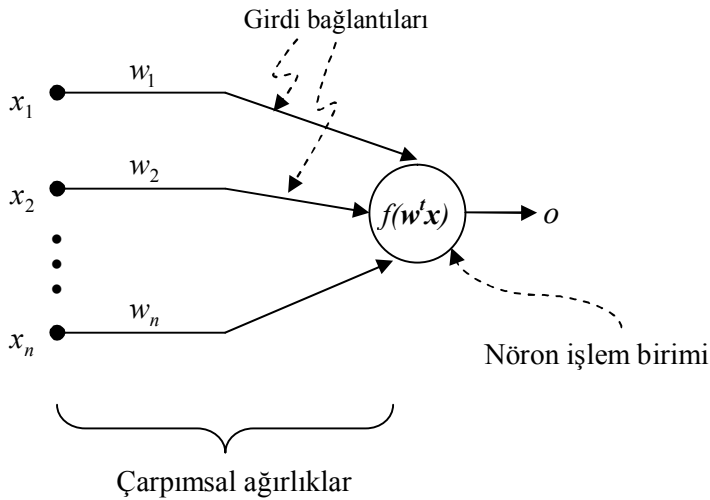
$$o^{k+1} = \begin{cases} 1 & , \sum_{i=1}^n w_i x_i^k \geq T \\ 0 & , \sum_{i=1}^n w_i x_i^k < T \end{cases} \quad (2.42)$$

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



Şekil 2.7. McCulloch-Pitts nöron modeli

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



Şekil 2.8. Genel yapay nöron modeli

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

$$o = f(w^t, x) \quad (2.43)$$

ya da

$$o = f\left(\sum_{i=1}^n w_i x_i\right) \quad (2.44)$$

şeklinde ifade edilir. w , ağırlık vektörü,


$$w = [w_1 \ w_2 \ \dots \ w_n]^t \quad (2.45)$$

ifadesi ile tanımlanabilirken x girdi vektörü ise,

$$x = [x_1 \ x_2 \ \dots \ x_n]^t \quad (2.46)$$

ile gösterilir.

Çok tabakalı YSA mimarileri, tek girdi ve çıktı tabakası içerirken, birden çok gizli tabaka içerebilirler. Mimari yapının belirlenmesi, tabakalardaki nöron sayılarının belirlenmesi anlamına gelir. Şekil 2.9.'da çok tabakalı ileri beslemeli bir YSA mimarisi görülmektedir.



Şekil 2.9. Çok tabakalı ileri beslemeli yapay sinir ağı mimarisi

Şekilden de anlaşılacağı üzere, nöronlar birbirlerine ağırlıklarla bağlıdır, aynı tabakanın nöronları arasında bağlantı yoktur, bağlantılar tek yönlü ve ileri doğrudur. Şekilde çıktı tabakasında yalnızca bir nöron varken, isteğe göre birden çok nöron da

kullanılabilir. Burada w_{ij} , girdi tabakasındaki i nöronu ile gizli tabakadaki j nöronu arasındaki ağırlığı ve w_{jk} , gizli tabakadaki j nöronu ile çıktı tabakasındaki k nöronu arasındaki ağırlığı gösterir. Şekilde çıktı tabakasinda, yalnızca bir nöron olduğu için, k indisi bu tek nöronu göstermektedir. Benzer şekilde oluşturulabilecek bir başka mimaride ise girdi tabakasındaki nöronlar ile çıktı tabakasındaki nöron (ya da nöronlar) arasında doğrudan bağlantı da kurulabilir.

2.2.2. Aktivasyon Fonksiyonu

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

$$net = w^t x \quad (2.47)$$

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

Çizelge 2.1. Aktivasyon fonksiyonu tipine göre nöron çıktı değeri

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

Sıklıkla kullanılan aktivasyon fonksiyonları ise aşağıdaki gibi verilebilir.

- Doğrusal aktivasyon fonksiyonu:

$$f(net) = net \quad (2.48)$$

- Adımsal aktivasyon fonksiyonu:

$$f(net) = \begin{cases} 0, & net > 0 \\ 1, & net < 0 \end{cases} \quad (2.49a)$$

ya da

$$f(net) = \begin{cases} -1, & net > 0 \\ 1, & net < 0 \end{cases} \quad (2.49b)$$

- λ eğim parametresini göstermek üzere Lojistik aktivasyon fonksiyonu:

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} \quad (2.50a)$$

ya da

$$f(net) = \frac{1}{1 + \exp(-\lambda net)} - 1 \quad (2.50b)$$

- Radyal Temelli aktivasyon fonksiyonu:

$$f(net) = \exp(-\lambda net^2) \quad (2.51)$$

- Tanjant hiperbolik aktivasyon fonksiyonu:

$$f(net) = \frac{\exp(net) - \exp(-net)}{\exp(net) + \exp(-net)} \quad (2.52)$$

- Sinüs, Kosinüs aktivasyon fonksiyonu:

$$f(net) = \text{Sin}(net) \quad (2.53a)$$

$$f(net) = \text{Cos}(net) \quad (2.53b)$$

2.2.3. Öğrenme Algoritması

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

YSA'da en iyi ağırlıkların bulunması bir optimizasyon problemi olarak düşünülebilir. Bununla birlikte YSA'nın eğitiminde kullanılan yöntemler arasında, genetik algoritmalar, parçacık sürü optimizasyonu, tavlama benzetimi ve tabu arama algoritması gibi sezgisel algoritmalar da bulunmaktadır.

Öğrenme algoritmaları, *öğrenme kuralı* adı verilen değişik kurallara göre işler. En çok bilinen ve kullanılan iki öğrenme kuralı, *denetimli* (supervised) ve *denetimsiz* (unsupervised) öğrenme kuralıdır. Denetimli öğrenmede, elde edilecek her bir çıktı değerinin, önceden bilinen bir hedef değeri vardır. Buna göre, öğrenme algoritmasının her bir adımında, yapay sinir ağının çıktı değeri ve karşılık gelen hedef değeri arasındaki hata azaltılarak ağırlık değerleri güncellenir. Bir başka sözle, denetimli

öğrenmede amaç, YSA'nın çıktı değeriyle, bu değer in hedef değeri arasındaki farkı minimum yapacak ağırlık değerlerini bulmaktır. Denetimsiz öğrenmede ise çıktı değerlerine karşılık gelen hedef değerleri yoktur. Girdi değerleri arasındaki benzerliklere göre, bu değerler kümelendirilir. Denetimsiz öğrenmede amaç, YSA çıktısının, girdi verisindeki istatistiksel düzeni en iyi şekilde yakalamasını sağlayacak ağırlıkların belirlenmesidir.

2.2.3.1. Levenberg – Marquardt Öğrenme Algoritması

En çok kullanılan öğrenme algoritmaları geri yayılım öğrenme algoritması ve Levenberg – Marquardt öğrenme algoritmasıdır. Geri yayılım (backpropagation) öğrenme algoritması geliştirilmiş delta kuralı olarak da bilinir. İlk olarak Werbos (1974) tarafından ortaya konmuş ve Parker (1982) tarafından yeniden gündeme taşınmıştır. Rumelhart ve ark. (1986) da bu konuda çalışmışlar ve Le Chun (1988) yaptığı çalışmada çok benzer bir algoritma sunmuştur. İleri beslemeli ağlarda kullanılan öğrenme algoritmaları, performans fonksiyonunu en küçük yapacak ağırlıkları ayarlayabilmek için, performans fonksiyonunun gradyenini kullanırlar. Geriye yayılım algoritması da, ağ boyunca gradyen hesaplamalarını geriye doğru yapar. En basit geriye yayılım öğrenme algoritması Gradyen Azalması algoritmasıdır. Bu algoritmada ağırlıklar, performans fonksiyonunun azalması yönünde ayarlanır. Fakat bu yöntem, pek çok problem için çok yavaş kalmaktadır.

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

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

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

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

$$H(n) = \frac{\partial^2 E(n)}{\partial w^2(n-1)} \quad (2.54)$$

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

$$E(n) = E_{ort}(n) \sum_{n=1}^N \frac{1}{2} \sum_{j=c} e_j^2(n) \quad (2.55)$$

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

$$e_j(n) = d_j(n) - y_j(n) \quad (2.56)$$

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

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

$$H(n) = J^T(n)J(n) + \mu I \quad (2.57)$$

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

$$J(n) = \frac{\partial e(n)}{\partial w(n-1)} \quad (2.58)$$

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

$$g(n) = J^T(n)e(n) \quad (2.59)$$

şeklinde hesaplanır ve sonuç olarak ağırlıklar,

$$w(n+1) = w(n) - [H(n)]^{-1}g(n) \quad (2.60)$$

ifadesine göre değiştirilerek güncellenir.

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

2.3. Bulanık C-Ortalamlar (BCO)

Bulanık C-ortalamlar (BCO) kümeleme yöntemi Bezdek (1981) tarafından önerilmiştir. Bu yöntem, literatürde en yaygın kullanılan bulanık kümeleme algoritmasıdır. Yöntemde gruplar için, en küçük kareler hatası minimize edilerek veri bulanık kümelerine ayrılmaktadır. u_{ij} ; üyelik değerini, v_j ; küme merkezini ve n değişken sayısını göstermek üzere, bulanık kümelemede minimize edilecek amaç fonksiyonu;

$$J_{\beta}(X, V, U) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^{\beta} d^2(x_j, v_j) \quad (2.61)$$

Burada $\beta > 1$ olacak şekilde alınan bir sabittir. Bu değer bulanıklık indeksi olarak isimlendirilir. $d(x_j, v_j)$; veri ile küme merkezi arasındaki benzerlik ölçüsüdür. J_{β} 'nin en küçüklemesinde aşağıdaki kısıtlar dikkate alınır.

$$0 \leq u_{ij} \leq 1 \quad , \forall i, j \quad (2.62a)$$

$$0 \leq \sum_{j=1}^n u_{ij} \leq n \quad , \forall i \quad (2.62b)$$

$$\sum_{i=1}^c u_{ij} = 1 \quad , \forall j \quad (2.62c)$$

BCO yönteminde bu en küçükleme yinelemeli bir algoritma ile sağlanır. Her bir yinelemede u_{ij} ve v_j değerleri aşağıdaki formüller ile güncellenir.

$$v_i = \frac{\sum_{j=1}^n u_{ij}^{\beta} x_j}{\sum_{j=1}^n u_{ij}^{\beta}} \quad (2.63)$$

$$u_{ij} = \left[\sum_{k=1}^c \left(\frac{d(x_j, v_j)}{d(x_j, v_k)} \right)^{2/(\beta-1)} \right]^{-1} \quad (2.64)$$

3. MATERYAL VE YÖNTEM

3.1. Bulanık Zaman Serileri ve Temel Kavramlar

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

İlk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından ortaya atılan bulanık zaman serisi kavramı Zadeh (1965, 1973, 1975) tarafından verilen bulanık küme teorisine dayanmaktadır. Bulanık zaman serisi analizi yöntemleri genel olarak, gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve durulaştırma olmak üzere üç aşamadan oluşmaktadır ve bu üç aşama üzerine literatürde bir çok çalışma mevcuttur.

Bulanık zaman serisi yaklaşımları bazı temel kavram ve tanımlara bağlıdır. Dolayısıyla bulanık zaman serilerine bir giriş niteliğinde olan bu tanım ve kavramlar gözden geçirilmelidir.

$U = \{u_1, u_2, \dots, u_{b1}\}$ evrensel küme ve evrensel kümenin belirlenen bir sabit aralık uzunluğuna göre parçalanması ile elde edilen u_i 'ler alt aralıklar olmak üzere bulanık kümeler,

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

şeklinde tanımlanır. Burada, f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonunu gösterir ve $f_{A_i}: U \rightarrow [0,1]$ olacaktır. Bunun yanında $f_{A_i}(u_a)$ ise u_a alt aralığının A_i bulanık kümesine ait olmasının üyelik derecesidir ve $1 \leq a \leq b$ olmak üzere $f_{A_i}(u_a) \in [0,1]$ olacaktır (Song ve Chissom, 1993a, 1993b, 1994).

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

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

i. $F(t)$ zamanın bir fonksiyonudur.

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

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

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

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

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

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

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

olacaktır, ki burada A_i , bulanık ilişkinin sol yanı, A_j ise bulanık ilişkinin sağ yanı olarak isimlendirilir (Song ve Chissom, 1993a, 1993b, 1994).

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

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

ifadesi ile verilebilir ve n 'nci dereceden bulanık zaman serisi öngörü modeli olarak adlandırılır (Chen, 2002).

Tanım 4. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olsun. $F_1(t)$ bulanık zaman serisi, gecikmeli $F_1(t - 1), F_2(t - 1)$ bulanık zaman serilerinden etkilenmekte ise, $F_1(t)$

bulanık zaman serisi ile $F_1(t-1), F_2(t-1)$ bulanık zaman serileri arasındaki bulanık ilişki,

$$F_1(t-1), F_2(t-1) \rightarrow F_1(t) \quad (3.6)$$

ifadesi ile verilebilir ve birinci dereceden iki değişkenli (iki faktör) bulanık zaman serisi öngörü modeli olarak adlandırılır. Burada $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak anılmaktadır.

Tanım 5. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olmak üzere, $F_1(t)$, gecikmeli $F_1(t-1), F_1(t-2), \dots, F_1(t-n)$ ve $F_2(t-1), F_2(t-2), \dots, F_2(t-n)$ bulanık zaman serilerinden etkilenmekte ise n 'inci dereceden iki değişkenli bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} (F_1(t-n), F_2(t-n)), \\ \vdots \\ (F_1(t-2), F_2(t-2)), \\ (F_1(t-1), F_2(t-1)) \end{array} \right\} \rightarrow F_1(t) \quad (3.7)$$

ifadesi ile verilebilir. Burada da yine $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır.

Tanım 6. $F_1(t)$ ve $F_2(t)$ iki bulanık zaman serisi iken, $F_1(t)$ bulanık zaman serisi, $F_1(t-m_1), F_1(t-m_2), \dots, F_1(t-m_k), F_2(t-n_1), F_2(t-n_2), \dots, F_2(t-n_l)$ bulanık zaman serilerinden etkilenmekte ise (k, l) 'inci dereceden, kısmi yüksek dereceli, iki değişkenli bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} F_1(t-m_1), F_1(t-m_2), \dots, F_1(t-m_k), \\ F_2(t-n_1), F_2(t-n_2), \dots, F_2(t-n_l) \end{array} \right\} \rightarrow F_1(t) \quad (3.8)$$

ifadesi ile verilebilir. Burada, m_i ($i = 1, 2, \dots, k$) ve n_j ($j = 1, 2, \dots, l$) tamsayılar ve $1 \leq m_1 < m_2 < \dots < m_k$, $1 \leq n_1 < n_2 < \dots < n_l$ şeklindedir ve aynı zamanda $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır (Eğrioğlu ve ark., 2009b).

Tanım 7. $F_1(t), F_2(t), \dots, F_m(t)$, m adet bulanık zaman serisi iken, $F_1(t)$, bulanık zaman serisi $(F_1(t-1), F_2(t-1), \dots, F_m(t-1)), (F_1(t-2), F_2(t-2), \dots, F_m(t-2)), \dots, (F_1(t-n), F_2(t-n), \dots, F_m(t-n))$ gecikmeli bulanık zaman serilerinden etkilenmekte ise n 'inci dereceden m değişkenli (m -faktör) bulanık zaman serisi öngörü modeli,

$$\left. \begin{array}{l} (F_1(t-n), F_2(t-n), \dots, F_m(t-n)), \\ \vdots \\ (F_1(t-2), F_2(t-2), \dots, F_m(t-2)), \\ (F_1(t-1), F_2(t-1), \dots, F_m(t-1)) \end{array} \right\} \rightarrow F_1(t) \quad (3.9)$$

şeklinde ifade edilir. Burada, $F_1(t)$ ana faktör, $F_2(t), F_3(t), \dots, F_m(t)$ ise ikincil faktör olarak adlandırılır (Jilani ve Burney, 2008).

3.2. Yolcu ve ark. Tarafından Önerilen Yöntem

Literatürde önerilen bulanık zaman serisi yaklaşımları üzerine genel bir değerlendirme yapıldığında, bulanıklaştırma aşamasında sabit veya değişken aralık uzunluğuna göre evrensel küme parçalanmasının yapıldığı çalışmalarda küme üyelik değerleri keyfi olarak belirlenmektedir. Ayrıca, bulanıklaştırmanın evrensel küme parçalanması ile yapıldığı yöntemlerde, bulanık ilişki belirleme ve durulaştırma aşamasında belirlenen üyelik değerlerinin öngörü doğruluğunu oldukça etkileyeceği açıktır. Bulanıklaştırma aşamasında bulanık kümeleme kullanıldığında aralık uzunluğu, aralık sayısı gibi değerleri belirlemeye ihtiyaç olmadığı gibi üyelik değerleri de keyfi belirlenmemektedir. Bulanık kümelemede üyelik değerleri kümelerin merkezlerine olan uzaklıklara göre belirlenmektedir. Bulanık ilişki belirlemede kurallar, literatürde birçok çalışmada, üyelik değerleri göz ardı edilerek küme numaraları ve kümelerin sıralanışları dikkate alınarak oluşturulmuştur. Bu durumda her bir bulanık kümede en yüksek üyelik değerine sahip olan küme elemanı dışındaki elemanlar göz ardı edilmekte, bu da bilgi kaybına neden olmaktadır. Yu ve Huarng (2010), bulanık ilişki belirlemede tüm üyelik değerlerinin dikkate alındığı bir yöntem önermiştir. Yu ve Huarng (2010) bulanıklaştırma aşamasında evrensel küme parçalanması yöntemini kullanmış ve küme

üyelik değerlerini keyfi olarak belirlemiştir. Yu ve Huarng (2010) tarafından önerilen bu yöntemde ileri beslemeli yapay sinir ağının girdileri bir önceki verinin küme üyelik değerleri olup hedef değerler ise bir sonraki verinin küme üyelik değerleridir.


Yolcu ve ark. (2010) ise, tüm bu sorunları ortadan kaldırmak amacıyla, bulanıklaştırma aşamasında bulanık C-ortalamlar ve bulanık ilişki belirlemede ileri beslemeli yapay sinir ağlarının kullanıldığı yeni bir bulanık zaman serisi öngörü yöntemi önermişlerdir. Önerilen yöntemde bulanıklaştırma aşamasında üyelik değerleri keyfi olarak belirlenmemekte, evrensel küme parçalanmasına ve aralık uzunluğu belirlenmesine gerek duyulmamakta, bulanık ilişki belirlemede ve durulaştırmada tüm küme elemanları dikkate alınmaktadır. Önerilen yöntem, literatürdeki diğer yöntemlere göre her aşamada daha sistematiktir ve açık avantajlara sahiptir. Önerilen yöntemin algoritması aşağıda adımlar halinde verilmiştir.

Adım1. Zaman serisi Bulanık C-ortalamlar yöntemi ile bulanıklaştırılır.

Crisp zaman serisine, bulanık küme sayısı $2 \leq c \leq n$ olacak şekilde belirlenerek, bulanık C-Ortalamlar (BCO) algoritması uygulanır. Küme merkezleri ve her bir gözlemin bu merkezlere göre hesaplanan küme üyelik değerleri elde edilir ve küme merkezleri küçükten büyüğe doğru sıralanarak, sıralanmış bulanık kümeler L_r , $r = 1, 2, \dots, c$ elde edilir. Sıralanmış bulanık kümelerin merkezleri v_r , $r = 1, 2, \dots, c$ ile gösterilir.

Adım 2. İleri beslemeli yapay sinir ağları ile bulanık ilişkileri oluşturulur.

Bulanık ilişki belirlemede kullanılacak ileri beslemeli yapay sinir ağının girdi ve çıktı tabakasındaki nöron sayısı, bulanık küme sayısı (c) kadar olmaktadır. Gizli tabaka birim sayısına ise yapay sinir ağının genelleştirme yeteneğini kaybetmeyecek şekilde, deneme yanılma yöntemi ile karar verilmektedir. Buna göre küme sayısını 7 olduğu ve gizli tabaka birim sayısının 2 olduğu durumda yapay sinir ağı mimarisi Şekil 3.1'de verildiği gibi olacaktır. Şekil 3.1'de $\mu_l(X(t))$, $X(t)$ zaman serisi gözleminin l 'inci bulanık kümeyle ait olmasının üyelik değerini göstermektedir. Yapay sinir ağının girdileri $(t - 1)$ anında zaman serisi değerinin c adet kümeyle ait olmasının üyelik değerleri, hedef değerleri ise t anında zaman serisi değerinin c adet kümeyle ait olmasının üyelik değerleridir.



Şekil 3.1. Yedi küme için ileri beslemeli yapay sinir ağı mimarisi

Bulanık ilişki belirlemede kullanılan ve mimari yapısı yukarıda örneklendirilen ileri beslemeli yapay sinir ağının tüm tabakalarında (3.10) eşitliğinde verilen lojistik aktivasyon fonksiyonu kullanılmaktadır.

$$f(x) = (1 + \exp(-x))^{-1} \quad (3.10)$$

İleri beslemeli yapay sinir ağı Levenberg-Marquardt öğrenme algoritmasına göre eğitilerek optimal ağırlıklar elde edilmektedir. Eğitilen yapay sinir ağı ardışık zaman serisi gözlemlerinin kümelere üyelik değerleri arasındaki ilişkiyi öğrenmiş olmaktadır.

Adım 3. Öngörülerin elde edilmesi ve durulaştırılması

Zaman serisinin t 'nci gözlemi ($X(t)$) için öngörü elde etmek istenildiğinde, $(t-1)$ 'nci gözlemin üyelik değerleri, bulanık C-ortalamar yöntemine göre elde edilen v_r , $r = 1, 2, \dots, c$ küme merkezleri kullanılarak eşitlik (2.62)'den elde edilir. Elde edilen üyelik değerleri Adım 2'de eğitilen yapay sinir ağına girdi olarak verilerek, çıktılar elde edilir. Elde edilen çıktılar t 'nci gözlemin bulanık öngörüsü için bulunan üyelik değerleridir. Üyelik değerleri yapay sinir ağının çıktıları olduğundan bulanık C-ortalamar yönteminde olduğu gibi küme üyelik değerleri toplamı 1 olmadığına dikkat edilmelidir. Öngörülerin durulaştırılmasında, bulanık öngörünün üyelik değerleri (3.11)'de verilen formül yardımıyla ağırlıklara dönüştürülerek küme merkezleri ile çarpılması yöntemi kullanılmaktadır. Duru öngörüler (3.12) formülünden hesaplanır.

$$w_{it} = \frac{\hat{u}_{it}}{\hat{u}_{1t} + \hat{u}_{2t} + \dots + \hat{u}_{ct}} \quad (3.11)$$

$$\hat{X}_t = \sum_{i=1}^c w_{it} v_i \quad (3.12)$$

Burada, X_t gözlemi için yapay sinir ağından çıktı olarak elde edilen üyelik değerleri \hat{u}_{it} , $i = 1, 2, \dots, c$ ve t 'inci gözlemin duru öngörüsü için kullanılacak ağırlıklar w_{it} , $t = 1, 2, \dots, n$ ile gösterilmektedir.

Yolcu ve ark. (2010) tarafından önerilen bu yöntemin temel avantajları şu şekilde sıralanabilir;

- Bulanıklaştırma aşamasında bulanık C- ortalamalar kullanılmaktadır. Bu sayede önerilen yöntemde aralık uzunluğu belirlemesi, küme üyelik değerlerinin keyfi olarak belirlenmesi gibi sorunlar bulunmamaktadır.
- Bulanık ilişki belirleme aşamasında, bulanık c-ortalamalar yönteminden elde edilen küme üyelik değerleri ileri beslemeli yapay sinir ağının girdi ve hedef değerlerini oluşturmaktadır. Yu ve Huarng (2010) çalışmasında ise ileri beslemeli yapay sinir ağının girdi ve hedef değerleri keyfi olarak belirlenen üyelik değerleridir. Ayrıca bu aşamada yapay sinir ağlarının kullanımı özellikle yüksek dereceli ve çok değişkenli modeller için oldukça kolaylık sağlamaktadır.
- Durulaştırma aşamasında merkezileştirme yöntemi yerine, küme üyelik değerlerinden hesaplanan ağırlıkların, küme merkezleri ile çarpılması yöntemi kullanılmaktadır. Bu durum düşük üyelik değerine sahip kümelerin de göz ardı edilmemesini sağlamaktadır.

Tüm bunların yanında göz önüne alınması gereken diğer bir husus da, bulanık zaman serilerinin öngörülmesinde, bulanık zaman serisinin kendi gecikmeli değişkeninin yanı sıra farklı bulanık zaman serilerinden ve onların gecikmeli değişkenlerinden de etkilenebileceğidir.

3.3. Önerilen Yöntem ve Algoritması

Bulanık zaman serisi yöntemlerinde, bulanıklaştırma aşamasında evrensel küme parçalanması çoğunlukla sübjektif kararlara ihtiyaç duyar. Bu durum ise yöntemin öngörü performansını olumsuz şekilde etkiler. Bu aşamada evrensel küme parçalanmasına ihtiyaç duymayan ve böylece yöntemi sübjektif yargılardan uzak tutan, bulanık kümeleme yöntemleri kullanılabilir.

Bulanık ilişki belirlenmesi aşaması da yöntemin öngörü performansı üzerinde diğer aşamalar kadar etkindir. Literatürde, bu aşamada, sıklıkla bulanık mantık grup ilişki tabloları kullanılmakla beraber, bu yöntemin yüksek dereceli ve çok değişkenli bulanık zaman serisi öngörü modellerinde özellikle test kümesi üzerinden değerlendirme yapıldığında yetersiz kaldığı söylenebilir. Bu durumu ortadan kaldırmak adına son çalışmalarda yapay sinir ağları da kullanılmaktadır. Bunun yanında literatürde ortaya konan yaklaşımların çoğunda, bulanık ilişkiler belirlenirken, gözlemlerin kümelere ait olmalarının üyelik değerleri göz ardı edilerek yalnızca gözlemlerin ait olduğu kümeleri temsil eden küme numaraları ile işlem yapılmaktadır. Bu ise bulanık ilişkilerin belirlenmesi aşamasında bir bilgi kaybına neden olmakta ve böylece öngörü performansını olumsuz yönde etkilemektedir. Literatürde, küme üyelik değerlerini ilişki belirlemede dikkate alan iki çalışmadan birinde, Yu ve Huarng (2010) evrensel küme parçalanmasını kullanmanın yanı sıra üyelikleri de keyfi belirlemektedir. Yolcu ve ark. (2010), ise bulanık ilişkilerin belirlenmesi aşamasında bulanık C-ortalamar yöntemi ile belirlenen üyelik değerlerini dikkate alan bir çalışma ortaya koymuştur.

Bulanık zaman serilerinin çözümlenmesinde dikkate alınması gereken diğer bir önemli özellik de, bulanık zaman serisinin kendi gecikmeli değişkenlerinin yanı sıra farklı bulanık zaman serilerinden ve onların gecikmeli değişkenlerinden de etkilenebileceğidir. Bu nedenle gerçek hayat bulanık zaman serilerinin öngörülmesine katkı sağlayacak diğer bazı bulanık zaman serilerini de içeren çok değişkenli bulanık zaman serisi öngörü modelinin oluşturulması gerekmektedir.

Tez kapsamında önerilen yöntem, bulanıklaştırma aşamasında bulanık C-ortalamar yöntemini kullanan, bulanık ilişki belirlenmesi aşamasında üyelik değerlerini dikkate alan, çok değişkenli bir bulanık zaman serisi öngörü modelini içermektedir. Önerilen yöntemin algoritması adımlar halinde aşağıdaki gibi verilebilir.

Adım 1. Model derecesi belirlenir ve gecikmeli değişkenler oluşturulur.

Oluşturulması planlanan ve k değişkenden oluşan yüksek dereceli çok değişkenli bulanık zaman serisi öngörü modelinin model derecesi (d) belirlenir. Çok değişkenli zaman serisi gözlemleri, belirlenen derecenin bir eksiği yani, $d - 1$ kadar geciktirilerek gecikmeli zaman serisi gözlemleri oluşturulur.

Adım 2. Zaman serisi bulanıklaştırılır.

$2 \leq c \leq n$ ve n gözlem sayısı olmak üzere bulanık küme sayısı c belirlenir. Çok değişkenli yapıya sahip zaman serisinin gecikmelerini de kapsayan veri seti bulanık C-ortalamalar kümeleme yöntemi ile kümelenir. Böylece veri setini oluşturan $k \times d$ adet değişkenin her biri için bulanık küme merkezleri ve her bir gözlem setinin bulanık kümelerine ait olmasının derecesini gösteren üyelik değerleri elde edilir. Bu adımda son olarak bulanık kümeler v_r , $r = 1, 2, \dots, c$ ile temsil edilen küme merkezlerine göre küçükten büyüğe göre sıralandırılarak L_r , $r = 1, 2, \dots, c$, bulanık kümeleri elde edilir.

Bu adımı daha iyi anlayabilmek adına iki değişkenli bir yapıyı ele alalım. Varsayalım ki öngörülmesi amaçlanan zaman serisi $X(t)$ ve bu zaman serisini öngörmede kullanılacak diğer bir zaman serisi $Y(t)$ olsun ve ikinci dereceden bir model oluşturmayı amaçladığımızı düşünelim. Bulanık küme sayısı $c = 3$ olmak üzere bulanık C-ortalamalar uygulandıktan sonra elde edilen bulanık küme merkezleri ve her bir veri setinin bulanık kümelerine ait olmalarının üyelik değerleri Çizelge 3.1'de verilmiştir. Çizelge 3.1'de $X(t), Y(t), X(t - 1), Y(t - 1)$ değişkenlerinden oluşan ve $VS(t)$ ile gösterebileceğimiz üçüncü veri setinin ($t = 3$) ikinci küme (L_2) ait olmasının üyelik değeri $\mu_{L_2}(VS(3)) = 0,193983$ olarak elde edildiği görülür.


Bulanık ilişkileri belirlemede kullanılan ileri beslemeli yapay sinir ağlarının (YSA) girdi ve çıktı tabakasındaki nöron sayısı bulanık küme sayısına (c) eşittir. Gizli tabakadaki nöronların sayısına deneme yanılma yolu ile karar verilir. Burada dikkat edilmesi gereken nokta, gizli tabaka birim sayısının ileri beslemeli yapay sinir ağının genelleştirme yeteneğini kaybetmeyecek şekilde seçilmesidir.

Çizelge 3.1. Bir bulanıklaştırma örneği

		1. Küme Merkezi (v_1)	2. Küme Merkezi (v_2)	3. Küme Merkezi (v_3)			
	$X(t)$	7346,214	7459,926	7524,701			
	$Y(t)$	7368,646	7470,834	7548,423			
	$X(t - 1)$	7368,029	7487,07	7550,88			
	$Y(t - 1)$	7383,522	7500,169	7590,13			
Gözlemlerin Üyelik Değerleri							
t	$X(t)$	$Y(t)$	$X(t - 1)$	$Y(t - 1)$	Küme 1 (L_1)	Küme 2 (L_2)	Küme 3 (L_3)
1	7552	7599	---	---			
2	7560	7593	7552	7599	0,017022	0,077107	0,905871
3	7487	7500	7560	7593	0,025555	0,193983	0,780462
4	7462	7472	7487	7500	0,000110	0,999631	0,000259
5	7515	7530	7462	7472	0,076097	0,680865	0,243038
6	7365	7372	7515	7530	0,261166	0,554542	0,184292
7	7360	7384	7365	7372	0,984459	0,011441	0,004101
8	7330	7352	7360	7384	0,986328	0,009835	0,003838

Adım 3. İleri beslemeli yapay sinir ağları (YSA) ile bulanık ilişkiler belirlenir.

Üç küme içeren bir model için iki gizli tabaka birimine sahip ileri beslemeli yapay sinir ağı mimarisi Şekil 3.2’de görülmektedir. Şekil 3.2’de $\mu_{L_i}(VS(t))$, zaman serisinin t anındaki veri seti $VS(t)$ ’nin i ’nci bulanık kümeye ait olmasının üyelik derecesini ifade eder. Ayrıca zaman serisinin $(t - 1)$ anındaki veri setinin c adet bulanık kümenin her birine ait olmasının üyelik değerleri ileri beslemeli yapay sinir ağının girdilerini oluştururken, hedeflerini yine zaman serisinin t anındaki veri setinin c adet bulanık kümenin her birine ait olmasının üyelik değerleri ve çıktılarını ise bu değerlerin tahminleri oluşturur.



Şekil 3.2. Üç küme için ileri beslemeli yapay sinir ağı mimarisi

İleri beslemeli yapay sinir ağının tüm tabakalarında eşitlik (3.10) ile verilen lojistik aktivasyon fonksiyonu kullanılır.

Bu yapıdaki ileri beslemeli yapay sinir ağının öğrenmesi Levenberg-Marquardt öğrenme algoritması ile eğitim kümesi üzerinden gerçekleştirilir. Böylece ileri beslemeli yapay sinir ağı, zaman serisinin ardışık gözlemlerinin bulanık kümelerle ait olmasının üyelik dereceleri arasındaki ilişkiyi öğrenmiş olur.

Örnek olarak Çizelge 3.1’de verilen iki değişkenli zaman serisi ve Şekil 3.1’de verilen bir ileri beslemeli yapay sinir ağı mimarisi ele alındığında ağın girdi ve hedef değerleri Çizelge 3.2’de verildiği gibi olmaktadır.

Çizelge 3.2. Bulanık ilişkilerin belirlenmesi üzerine bir örnek

Gözlemlerin Üyelik Değerleri							
Öğrenme Örneği	t	Girdi 1	Girdi 2	Girdi 3	Hedef 1	Hedef 2	Girdi 3
		$\mu_{L_2}(VS(t-1))$	$\mu_{L_2}(VS(t-1))$	$\mu_{L_3}(VS(t-1))$	$\mu_{L_1}(VS(t))$	$\mu_{L_2}(VS(t))$	$\mu_{L_3}(VS(t))$
1	3	0,017022	0,077107	0,905871	0,025555	0,193983	0,780462
2	4	0,025555	0,193983	0,780462	0,000110	0,999631	0,000259
3	5	0,000110	0,999631	0,000259	0,076097	0,680865	0,243038
4	6	0,076097	0,680865	0,243038	0,261166	0,554542	0,184292
5	7	0,261166	0,554542	0,184292	0,984459	0,011441	0,004101
6	8	0,984459	0,011441	0,004101	0,986328	0,009835	0,003838

Adım 4. Öngörülerin durulaştırılması.

Bulanık zaman serisinin t anına ait bulanık öngörülerini elde edilmek istendiğinde öncelikle, bulanık C-ortalamalar yöntemi ile elde edilen v_r , $r = 1, 2, \dots, c$ bulanık küme merkezlerine bağlı olarak $t - 1$ anına ait gözlemin bulanık kümelerle ait olmasının üyelik değerleri belirlenir. Daha sonra bu üyelikler ileri beslemeli yapay sinir ağında girdi olarak verilir ve ileri beslemeli yapay sinir ağının çıktıları üretilir. Bu çıktılar, t anındaki gözlemin bulanık öngörüsü için üyelik değerlerini temsil eder. Burada da, bulanık öngörü değeri için elde edilen üyelik değerlerinin toplamının, bulanık C-ortalamalar yönteminin aksine 1’e eşit olmadığı görülür. Berraklaştırma aşamasında, bulanık öngörülerin üyelik değerleri (3.13)’deki gibi ağırlıklara dönüştürülür ve durulaştırılmış öngörü (3.14)’de verildiği gibi elde edilir.

$$w_{it} = \frac{\hat{u}_{it}}{\hat{u}_{1t} + \hat{u}_{2t} + \dots + \hat{u}_{ct}} \quad (3.13)$$

$$\hat{X}_t = \sum_{i=1}^c w_{it} v_i \quad (3.14)$$

Burada, \hat{u}_{it} , ileri beslemeli yapay sinir ağının çıktısından elde edilen t anındaki gözlemin bulanık öngörüsü için üyelik değerleri, w_{it} ise berrak öngörülerin elde edilmesinde kullanılan ağırlıklardır.

4. BULGULAR VE TARTIŞMA

Önerilen yeni yöntemin uygulaması bulanık zaman serisi literatüründe kullanılmış 4 farklı bulanık zaman serisi üzerinde gerçekleştirilmiştir. Bunlardan ilki, 1974-2004 yılları arasında yıllık olarak gözlenmiş her bir değişken için 31 gözlemden oluşan ve Belçika'da gerçekleşen ölümlü araba kazaları zaman serileridir. Çözümlemesi yapılacak ikinci veri olarak, yine literatürde sıklıkla kullanılan, 03.08.1998-30.09.1998 dönemlerine ait 47 günlük gözlemden oluşan TAIFEX (Taiwan Futures Exchange) zaman serisi alınmıştır. Önerilen yöntemin uygulamasında çözümlemesi yapılan üçüncü zaman serisi ise, 02.01.2004-31.12.2004 tarihleri arasında günlük olarak gözlemlenmiş 250 gözlemlili TAIEX (Taiwan Stock Exchange) zaman serisidir.

Bunun yanında önerilen yöntem, son olarak, 03/10/2008 - 31/12/2008, 01/10/2009 - 31/12/2009 ve 01/10/2010 - 23/12/2010 dönemlerine ait İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi (İMKB) zaman serisine, her biri için iki farklı test kümesi seçilerek uygulanmıştır.

Çözümlemeler sonucunda elde edilen sonuçların değerlendirilmesi amacıyla, aşağıdaki denklemlerde verilen, hata kareler ortalaması karekökü (HKOK) hata ölçütünün yanında ortalama mutlak yüzdelik hata (OMYH) ve yön doğruluğu (YD) ölçütleri de hesaplanarak diğer yöntemlerle birlikte incelenmiştir.

$$HKOK = \sqrt{\frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{n}} \quad (4.1)$$

$$OMYH = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - \hat{X}_t}{X_t} \right| \quad (4.2)$$

$$YD = \frac{1}{n-1} \sum_{t=1}^{n-1} \begin{cases} 1, & (X_{t+1} - X_t)(\hat{X}_{t+1} - X_t) > 0 \\ 0, & \text{aksi halde} \end{cases} \quad (4.3)$$

Çözümleme aşamasında MATLAB programlama dilinde yazılmış programlar kullanılmış olup, örnek iki programın açık kodları Ek 1. ve Ek 2.' de verilmiştir.

4.1. Belçika’da Gerçekleşen Ölümlü Araba Kazaları Verisi Çözümlemesi

Önerilen yöntem ilk olarak Çizelge 4.1.’de verilen, 1974-2004 yılları arasında yıllık olarak gözlenmiş “Belçika’da gerçekleşen ölümlü araba kazaları” zaman serisine uygulanmıştır.

Çizelge 4.1. “Belçika’da gerçekleşen ölümlü araba kazaları” zaman serisi

Yıllar	Ölüm Sayısı	Ölümcül Yaralanma	30 Gün İçinde Ölüm Sayısı	Şiddetli Yaralanma	Hafif Kayıplar
1974	1574	819	2393	16506	44640
1975	1460	701	2161	15792	42423
1976	1536	728	2264	16057	44227
1977	1597	701	2298	15830	44995
1978	1644	728	2372	16645	44797
1979	1572	544	2116	15750	42346
1980	1616	557	2173	15915	42670
1981	1564	454	2018	15091	41915
1982	1464	406	1870	14601	40936
1983	1479	412	1891	14864	42023
1984	1369	363	1732	14471	42456
1985	1308	352	1660	13287	39879
1986	1456	330	1786	13764	42965
1987	1390	380	1770	13809	44090
1988	1432	339	1771	14029	45956
1989	1488	312	1800	14515	46667
1990	1574	190	1764	13864	46818
1991	1471	209	1680	12965	43578
1992	1380	173	1553	12113	41772
1993	1346	171	1517	11680	41736
1994	1415	149	1564	11160	40294
1995	1228	109	1337	10267	39140
1996	1122	115	1237	9123	38390
1997	1150	105	1255	9229	39594
1998	1224	121	1345	8784	41038
1999	1173	126	1299	8461	41841
2000	1253	103	1356	7990	39719
2001	1288	90	1378	7319	38747
2002	1145	118	1263	6834	39522
2003	1035	101	1136	6898	42445
2004	953	141	1094	5949	41627

Uygulamada öngörülmesi amaçlanan ana faktör “ölüm sayısı” ($X(t)$) olarak alınırken, “ölümcül yaralanma” ($Y_1(t)$), “30 gün içinde ölüm sayısı” ($Y_2(t)$), “şiddetli yaralanma” ($Y_3(t)$) ve “hafif kayıplar” ($Y_4(t)$) ikincil faktör olarak alınmıştır. Zaman serisinin çözümlenmesinde yöntemin performans değerlendirmesi literatürdeki diğer yöntemlerde olduğu gibi eğitim kümesi üzerinden gerçekleştirilmiştir. Çözümleme sırasında belirlenen parametrelere bağlı olarak önerilen yöntemde;

- Algoritmanın birinci adımında belirlenen değişken sayısı; $k = 5$ olmaktadır.
- Model derecesi (d) 1-10 arasında değiştirilerek 10 farklı öngörü modeli için çözümleme yapılmıştır.
- Bulanıklaştırma aşamasında bulanık küme sayısı (c) 5-15 arasında alınarak, bu bulanık kümeler bulanık C-ortalamalar yöntemi ile belirlenmiştir.
- Bulanık ilişkilerin belirlenmesi aşamasında, küme sayısına bağlı olarak c adet girdi ve çıktı tabakası birimine sahip olan, ileri beslemeli yapay sinir ağının gizli tabaka birim sayısı ağın genelleştirme yeteneğini kaybetmemesi amacıyla 1-15 arasında sınırlandırılmıştır.

Tüm bu özellikleri taşıyan ve farklı derecedeki her bir, çok değişkenli bulanık zaman serisi öngörü modeli için $11 \times 15 = 165$ farklı çözümleme yapılmıştır. Çözümlemeler sonucunda zaman serisine en uygun modelin 10. dereceden çok değişkenli bulanık zaman serisi öngörü modeli olduğu saptanmıştır. Önerilen yöntemin bu modelde en iyi öngörü performansı ise bulanık küme sayısının 15 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli yapay sinir ağının gizli tabaka birim sayısının 8 olduğu durumda elde edilmiştir.

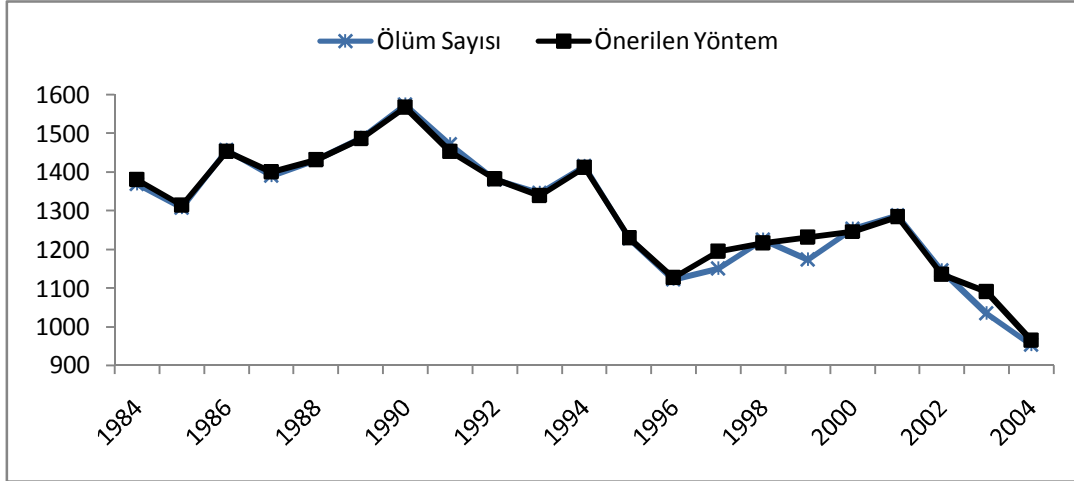
Önerilen yöntemden elde edilen en iyi duruma ait sonuçlarla birlikte, Lee ve ark. (2006), Jilani ve ark. (2007) ve Jilani ve Burney (2008) çalışmalarının sonuçları Çizelge 4.2’de özetlenmiştir.

Tüm yöntemlere ait en iyi durumların sonuçlarını içeren Çizelge 4.2 incelendiğinde, önerilen yöntemin 21,56 HKOK ve 1,13% OMYH değerleri ile diğer yöntemlere göre oldukça yüksek bir öngörü performansına sahip olduğu görülür. Ayrıca, önerilen yöntem 95,00% gibi yüksek bir yön doğruluğuna sahiptir.

Çizelge 4.2. Eğitim kümesi için gerçek değerler ve yöntemlerin öngörülleri

Yıllar	Ölüm Sayısı	Lee ve ark. (2006)	Jilani ve ark. (2007)	Jilani ve Burney (2008)	Önerilen Yöntem
1974	1574		1497		
1975	1460		1497		
1976	1536		1497		
1977	1597	1500	1497	1497	
1978	1644	1500	1497	1497	
1979	1572	1500	1497	1497	
1980	1616	1500	1497	1598	
1981	1564	1500	1497	1598	
1982	1464	1500	1497	1498	
1983	1479	1500	1497	1498	
1984	1369	1500	1497	1398	1380
1985	1308	1400	1396	1298	1314
1986	1456	1300	1296	1498	1452
1987	1390	1500	1497	1398	1401
1988	1432	1400	1396	1398	1431
1989	1488	1400	1396	1498	1486
1990	1574	1500	1497	1598	1566
1991	1471	1500	1497	1498	1453
1992	1380	1500	1497	1398	1382
1993	1346	1400	1396	1298	1338
1994	1415	1300	1296	1398	1411
1995	1228	1400	1396	1198	1229
1996	1122	1100	1095	1098	1127
1997	1150	1200	1196	1198	1195
1998	1224	1200	1196	1198	1216
1999	1173	1200	1196	1198	1232
2000	1253	1300	1296	1298	1247
2001	1288	1300	1296	1298	1284
2002	1145	1100	1095	1098	1135
2003	1035	1000	995	997	1091
2004	953	1000	995	997	965
	HKOK	85,35	83,12	46,78	21,60
	OMYH	5,25%	5,06%	2,70%	1,13%
	YD	62,96%	63,33%	96,30%	95,00%

Ayrıca zaman serisinin gerçek değerlerinin, önerilen yöntemin uygulanması ile elde edilen en iyi duruma ait öngörülerinin birlikte grafiği Şekil 4.1’de görülmektedir. Şekil 4.1 incelendiğinde önerilen yöntemden elde edilen öngörülerin zaman serisinin gözlemleri ile oldukça uyumlu olduğu görülmektedir.



Şekil 4.1. Zaman serisi gözlemleri ve öngörülerin birlikte grafiği

4.2. TAIEX (Taiwan Futures Exchange) Verisi Çözümlemesi

Önerilen yöntemin uygulanmasında ikinci olarak Çizelge 4.3.'de verilen, 03.08.1998-30.09.1998 dönemlerine ait 47 günlük gözlemden oluşan "TAIFEX" (Taiwan Futures Exchange) zaman serisi çözümlenmiştir.

Uygulamada öngörülmesi amaçlanan "TAIFEX" ($X(t)$) ana faktör ve, "TAIEX" ($Y(t)$), ikincil faktör olarak alınmıştır. Zaman serisinin çözümlenmesinde yöntemin performansı bu kez test kümesi üzerinden değerlendirilmiştir. Ancak yöntemin uygulanması sırasında bulanık ilişkilerin belirlenmesi aşaması eğitim kümesinin optimizasyonu ile gerçekleştirilmiştir. Böylece yöntemin görmediği veri (test kümesi) üzerindeki performansını sağlıklı olarak değerlendirme imkânı ortaya çıkmaktadır. Çözümleme sırasında belirlenen parametrelere bağlı olarak önerilen yöntemde;

- 47 gözlemden oluşan zaman serisinin 10.09.1998-30.09.1994 tarihleri arasındaki son 16 gözlemi test verisi olarak alınmıştır.
- Algoritmanın birinci adımında belirlenen değişken sayısı; $k = 2$ olmaktadır.
- Model derecesi (d) 1-10 arasında değiştirilerek 10 farklı öngörü modeli için çözümleme yapılmıştır.
- Bulanıklaştırma aşamasında bulanık küme sayısı (c) 5-15 arasında alınarak, bu bulanık kümeler bulanık C-ortalamalar yöntemi ile belirlenmiştir.

- Bulanık ilişkilerin belirlenmesi aşamasında, küme sayısına bağlı olarak c adet girdi ve çıktı tabakası birimine sahip olan, ileri beslemeli yapay sinir ağının gizli tabaka birim sayısı yine 1-15 arasında sınırlandırılmıştır.

Bu verinin öngörülmesinde de yukarıda verilen özellikleri taşıyan ve farklı derecedeki her bir, çok değişkenli bulanık zaman serisi öngörü modeli için 165 farklı çözümleme yapılmıştır. Çözümlemeler sonucunda zaman serisine en uygun modelin 3. dereceden çok değişkenli bulanık zaman serisi öngörü modeli olduğu saptanmıştır. Önerilen yöntemin bu modelde en iyi öngörü performansı ise bulanık küme sayısının 8 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli yapay sinir ağının gizli tabaka birim sayısının 14 olduğu durumda elde edilmiştir.

Çizelge 4.3. “TAIFEX” ve “TAIEX” zaman serileri

Tarih	TAIFEX	TAIEX	Tarih	TAIFEX	TAIEX
03.08.1998	7.552,00	7.599,00	02.09.1998	6.430,00	6.472,00
04.08.1998	7.560,00	7.593,00	03.09.1998	6.200,00	6.251,00
05.08.1998	7.487,00	7.500,00	04.09.1998	6.403,20	6.463,00
06.08.1998	7.462,00	7.472,00	05.09.1998	6.697,50	6.756,00
07.08.1998	7.515,00	7.530,00	07.09.1998	6.722,30	6.801,00
10.08.1998	7.365,00	7.372,00	08.09.1998	6.859,40	6.942,00
11.08.1998	7.360,00	7.384,00	09.09.1998	6.769,60	6.895,00
12.08.1998	7.330,00	7.352,00	10.09.1998	6.709,75	6.804,00
13.08.1998	7.291,00	7.363,00	11.09.1998	6.726,50	6.842,00
14.08.1998	7.320,00	7.348,00	14.09.1998	6.774,55	6.860,00
15.08.1998	7.320,00	7.372,00	15.09.1998	6.762,00	6.858,00
17.08.1998	7.219,00	7.274,00	16.09.1998	6.952,75	6.973,00
18.08.1998	7.220,00	7.182,00	17.09.1998	6.906,00	7.001,00
19.08.1998	7.285,00	7.293,00	18.09.1998	6.842,00	6.962,00
20.08.1998	7.274,00	7.271,00	19.09.1998	7.039,00	7.150,00
21.08.1998	7.225,00	7.213,00	21.09.1998	6.861,00	7.029,00
24.08.1998	6.955,00	6.958,00	22.09.1998	6.926,00	7.034,00
25.08.1998	6.949,00	6.908,00	23.09.1998	6.852,00	6.962,00
26.08.1998	6.790,00	6.814,00	24.09.1998	6.890,00	6.980,00
27.08.1998	6.835,00	6.813,00	25.09.1998	6.871,00	6.980,00
28.08.1998	6.695,00	6.724,00	28.09.1998	6.840,00	6.911,00
29.08.1998	6.728,00	6.736,00	29.09.1998	6.806,00	6.885,00
31.08.1998	6.566,00	6.550,00	30.09.1998	6.787,00	6.834,00
01.09.1998	6.409,00	6.335,00			

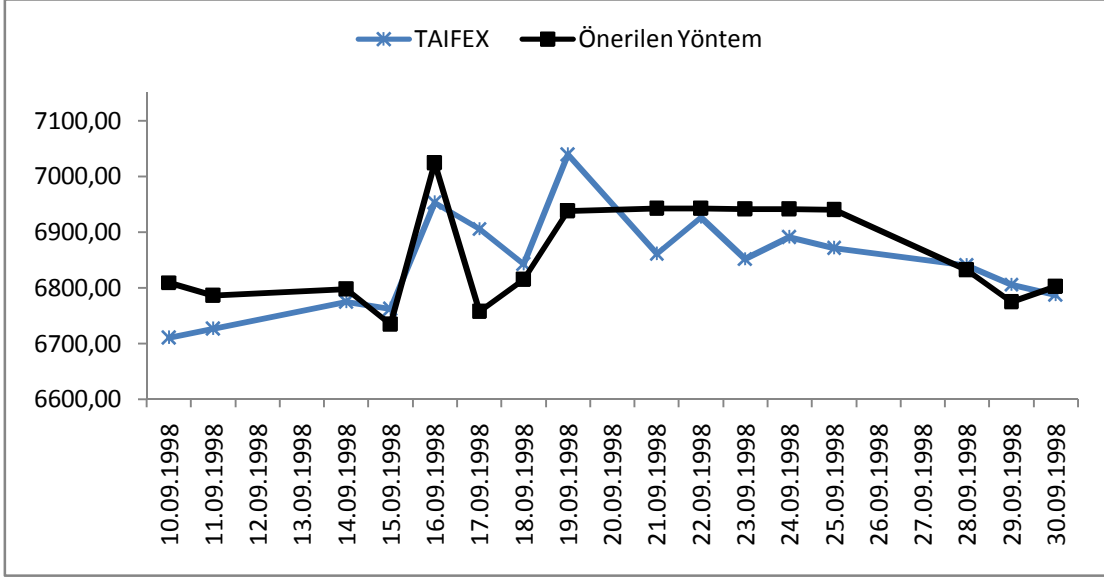
Önerilen yöntemden elde edilen sonuçlar Lee ve ark. (2007, 2008) ve Hsu ve ark. (2010), tarafından önerilen yöntem sonuçları ile karşılaştırılmıştır. Tüm yöntemlerin test kümesi için en iyi durumlarına ait öngörüler ve her birinin hata ölçütleri Çizelge 4.4'de özetlenmiştir.

Tüm yöntemlere ait en iyi durumların sonuçlarını içeren Çizelge 4.4 incelendiğinde, önerilen yöntemin 69,09 HKOK ve 0,84% OMYH ve 86,67% YD değerleri ile diğer yöntemlere göre daha yüksek bir öngörü performansı gösterdiği görülür.

Çizelge 4.4. Test kümesi için gerçek değerler ve yöntemlerin öngörülleri

Tarih	TAIFEX	Lee ve ark. (2007)	Lee ve ark. (2008)	Hsu ve ark. (2010)	Önerilen Yöntem
10.09.1998	6709,75	6621,43	6917,40	6745,45	6809,58
11.09.1998	6726,50	6677,48	6852,23	6757,89	6785,87
14.09.1998	6774,55	6709,63	6805,71	6731,76	6797,25
15.09.1998	6762,00	6732,02	6762,37	6722,54	6733,81
16.09.1998	6952,75	6753,38	6793,06	6753,72	7023,41
17.09.1998	6906,00	6756,02	6784,40	6761,54	6756,94
18.09.1998	6842,00	6804,26	6970,74	6857,27	6814,98
19.09.1998	7039,00	6842,04	6977,22	6898,97	6937,86
21.09.1998	6861,00	6839,01	6874,46	6853,07	6941,81
22.09.1998	6926,00	6897,33	7126,05	6951,95	6941,71
23.09.1998	6852,00	6896,83	6862,49	6896,84	6941,39
24.09.1998	6890,00	6919,27	6944,36	6919,94	6940,54
25.09.1998	6871,00	6903,36	6831,88	6884,99	6940,23
28.09.1998	6840,00	6895,95	6843,24	6894,10	6831,63
29.09.1998	6806,00	6879,31	6858,45	6866,17	6774,57
30.09.1998	6787,00	6878,34	6825,64	6865,06	6802,41
	HKOK	93,49	102,96	80,02	69,09
	OMYH	1,09%	1,14%	0,87%	0,84%
	YD	53,33%	80,00%	73,33%	86,67%

Ayrıca zaman serisinin test kümesine ait gerçek değerlerinin, önerilen yöntemin uygulanması ile elde edilen en iyi duruma ait öngörüler ile birlikte grafiği Şekil 4.2'de görülmektedir.



Şekil 4.2. TAIEX verisi test kümesi için gerçek değerler ve öngörülerin grafiği

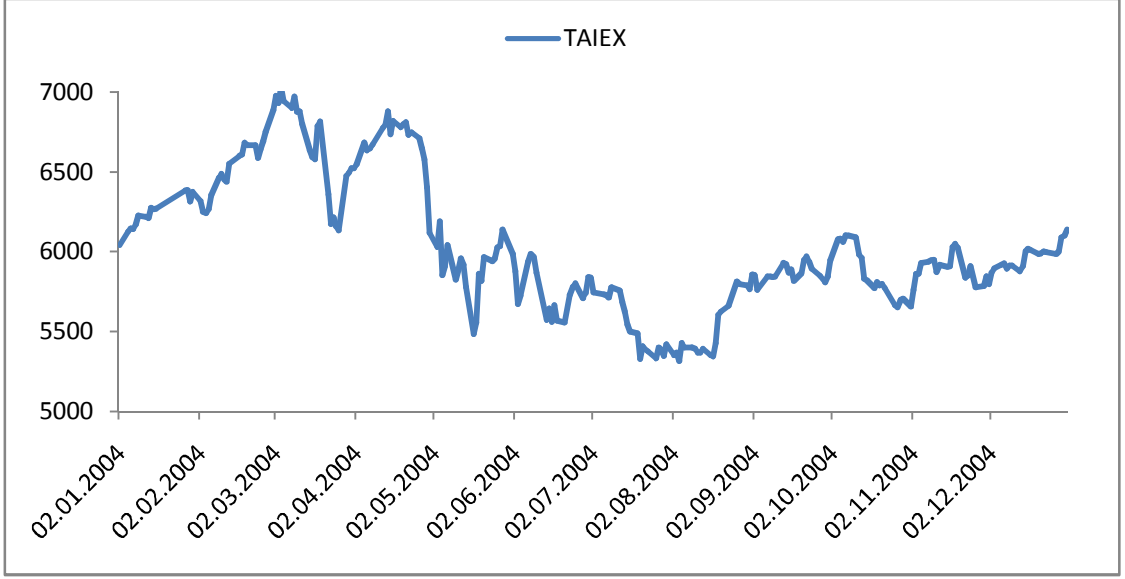
4.3. TAIEX (Taiwan Stock Exchange) Verisi Çözümlemesi

Önerilen yöntemin uygulanmasında üçüncü olarak grafiği Şekil 4.3.'de verilen, 02.01.2004-31.12.2004 dönemlerine ait 250 günlük gözlemden oluşan "TAIEX" (Taiwan Stock Exchange) zaman serisi çözümlenmiştir.

Uygulamada öngörülmesi amaçlanan "TAIEX" ($X(t)$) ana faktör, aynı döneme ait "DOW JONES" endeksi ($Y_1(t)$) ve "NASDAQ" endeksi ($Y_2(t)$) ikincil faktör olarak alınmıştır. Yöntemin performansı yine test kümesi üzerinden değerlendirilmiş olmasına rağmen yöntemin uygulanması sırasında bulanık ilişkilerin belirlenmesi aşaması eğitim kümesinin optimizasyonu ile gerçekleştirilmiştir. Bu nedenle yöntemin görmediği veri (test kümesi) üzerindeki performansı yine sağlıklı olarak değerlendirilebilecektir. Çözümleme sırasında belirlenen parametrelere bağlı olarak önerilen yöntemde;

- 250 gözlemden oluşan zaman serisinin 01.11.2004-31.12.2004 tarihleri arasındaki son 45 gözlemi test verisi olarak alınmıştır.
- Algoritmanın birinci adımında belirlenen değişken sayısı; $k = 3$ olmaktadır.
- Model derecesi(d) 1-10 arasında değiştirilerek 10 farklı öngörü modeli için çözümleme yapılmıştır.

- Bulanıklaştırma aşamasında bulanık küme sayısı (c) 5-15 arasında alınarak, bu bulanık kümeler bulanık C-ortalamalar yöntemi ile belirlenmiştir.
- Bulanık ilişkilerin belirlenmesi aşamasında, küme sayısına bağlı olarak c adet girdi ve çıktı tabakası birimine sahip olan, ileri beslemeli yapay sinir ağının gizli tabaka birim sayısı ağın genelleştirme yeteneğini kaybetmemesi amacıyla 1-15 arasında sınırlandırılmıştır.



Şekil 4.3. “TAIEX” (Taiwan Stock Exchange) zaman serisi

TAIEX verisinin çözümlenmesinde de yukarıda verilen tüm özellikleri taşıyan ve 165 farklı çözümlenme her bir, çok değişkenli bulanık zaman serisi öngörü modeli için gerçekleştirilmiştir. Çözümlenmeler sonucunda zaman serisine en uygun modelin 1. dereceden çok değişkenli bulanık zaman serisi öngörü modeli olduğu saptanmıştır. Önerilen yöntemin bu modelde en iyi öngörü performansı ise bulanık küme sayısının 10 ve ileri beslemeli yapay sinir ağının gizli tabaka birim sayısının 1 olduğu durumda elde edilmiştir.


Önerilen yöntemden elde edilen sonuçlar Song ve Chissom (1993b), Chen (1996, 2002), Huarng ve Yu (2006a) Aladağ ve ark. (2009), Huarng ve ark. (2007), Yu ve Huarng (2008) ve Chen ve Chen (2011) tarafından önerilen yöntem sonuçları ile karşılaştırılmıştır. Tüm yöntemlerin test kümesi için en iyi durumlarına ait hata ölçütleri Çizelge 4.5’de özetlenmiştir.

Çizelge 4.5. Test kümesi için yöntemlere ait sonuçlar

Yöntem	HKOK
Song ve Chissom (1993b),	77,86
Chen (1996)	77,18
Chen (2002)	71,98
Huarng ve Yu (2006a)	63,57
Aladağ ve ark. (2009)	63,01
Huarng ve ark. (2007)	72,35
Yu ve Huarng (2008)	67,00
Chen ve Chen (2011)	57,73
Önerilen Yöntem	53,12

Çizelge 4.5 incelendiğinde, önerilen yöntemin 53,12 HKOK değeri ile en yüksek öngörü performansına sahip olduğu görülmektedir. Bunun yanında, önerilen yöntemin en iyi durumunda, OMYH 0,67 % ve YD 65,91% olarak elde edilmiştir.

Ayrıca zaman serisinin test verisine ait gerçek değerlerinin önerilen yöntemden elde edilen en iyi duruma ait öngörülerle birlikte grafiği Şekil 4.4’de görülmektedir.

**Şekil 4.4.** TAIEX verisi test kümesi için gerçek değerler ve öngörülerin grafiği

4.4. İMKB Verisi Çözümlemesi

Önerilen yöntem son olarak, 03.10.2008 - 31.12.2008 (veri-set 1), 01.10.2009 - 31.12.2009 (veri-set 2) ve 01.10.2010 - 23.12.2010 (veri-set 3) dönemlerine ait İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi (İMKB) zaman serisine uygulanmıştır. Uygulamada, her bir veri seti için son 7 ve 15 gözlemi kapsayan iki farklı test kümesi alınarak, üç veri seti için toplam 6 çözümleme gerçekleştirilmiştir. Bu üç veri setine ait gözlemler sırasıyla Çizelge 4.6, Çizelge 4.7 ve Çizelge 4.8’de görülmektedir.

Uygulamada öngörülmesi amaçlanan “İMKB” ($X(t)$) ana faktör, aynı döneme ait “TL/ DOLAR” döviz kuru ($Y_1(t)$) ve “TL/ EURO” döviz kuru ($Y_2(t)$) ikincil faktör olarak alınmıştır.

Yöntemin performansı yine test kümesi üzerinden değerlendirilmiş, ancak uygulama sırasında bulanık ilişkilerin belirlenmesi aşaması eğitim kümesinin optimizasyonu ile gerçekleştirilmiştir.

Çözümleme sırasında belirlenen parametrelere bağlı olarak önerilen yöntemde;

- 59 gözlemden oluşan 03.10.2008 - 31.12.2008 (veri-set 1) tarihleri arasındaki zaman serisinin son 7 ve 15 gözlemi test verisi olarak alınarak iki farklı uygulama gerçekleştirilmiştir.
- 63 gözlemden oluşan 01.10.2009 - 31.12.2009 (veri-set 2) tarihleri arasındaki zaman serisinin son 7 ve 15 gözlemi test verisi olarak alınarak iki farklı uygulama gerçekleştirilmiştir.
- 53 gözlemden oluşan 01.10.2010 - 23.12.2010 (veri-set 3) tarihleri arasındaki zaman serisinin son 7 ve 15 gözlemi test verisi olarak alınarak iki farklı uygulama gerçekleştirilmiştir.
- Algoritmanın birinci adımında belirlenen değişken sayısı; $k = 3$ olmaktadır.
- Model derecesi (d) 1-10 arasında değiştirilerek 10 farklı öngörü modeli için çözümleme yapılmıştır.
- Bulanıklaştırma aşamasında bulanık küme sayısı (c) 5-15 arasında alınarak, bu bulanık kümeler bulanık C-ortalamalar yöntemi ile belirlenmiştir.

- Bulanık ilişkilerin belirlenmesi aşamasında, küme sayısına bağlı olarak c adet girdi ve çıktı tabakası birimine sahip olan, ileri beslemeli yapay sinir ağının gizli tabaka birim sayısı 1-15 arasında sınırlandırılmıştır.

IMKB verisinin çözümlenmesinde yukarıda verilen özellikleri taşıyan ve farklı derecedeki her bir, çok değişkenli bulanık zaman serisi öngörü modeli için 165 farklı çözümlenme yapılmıştır.

Çizelge 4.6. “IMKB”, “USD” ve “EURO” zaman serileri (veri-set 1)

Tarih	IMKB	USD	EURO	Tarih	IMKB	USD	EURO
03.10.2008	34553	1,2375	1,8065	17.11.2008	24047	1,6339	2,0726
06.10.2008	31575	1,3075	1,8118	18.11.2008	23495	1,6217	2,0537
07.10.2008	31562	1,3399	1,8213	19.11.2008	21929	1,6617	2,0974
08.10.2008	30773	1,3643	1,8519	20.11.2008	21228	1,6729	2,1125
09.10.2008	30879	1,4134	1,9300	21.11.2008	21966	1,7038	2,1338
10.10.2008	28496	1,3839	1,8994	24.11.2008	24137	1,6792	2,1133
13.10.2008	28962	1,4289	1,9403	25.11.2008	24425	1,6145	2,0469
14.10.2008	30536	1,3993	1,9061	26.11.2008	24409	1,5756	2,0265
15.10.2008	29444	1,3772	1,8870	27.11.2008	25383	1,5883	2,0595
16.10.2008	27601	1,3964	1,9022	28.11.2008	25715	1,5731	2,0313
17.10.2008	25870	1,4811	1,9940	01.12.2008	24332	1,5699	2,0136
20.10.2008	26764	1,5107	2,0290	02.12.2008	24425	1,5934	2,0149
21.10.2008	26723	1,4996	2,0183	03.12.2008	23937	1,6018	2,0260
22.10.2008	25624	1,5308	2,0256	04.12.2008	24671	1,5787	1,9961
23.10.2008	25041	1,6425	2,1164	05.12.2008	24035	1,5720	1,9839
24.10.2008	24177	1,7029	2,1818	12.12.2008	24937	1,5718	2,0015
27.10.2008	24337	1,6994	2,1407	15.12.2008	25598	1,5655	2,0860
28.10.2008	24895	1,6942	2,1061	16.12.2008	26396	1,5658	2,1112
30.10.2008	26733	1,6942	2,1061	17.12.2008	26765	1,5666	2,1426
31.10.2008	27833	1,5036	1,9682	18.12.2008	26396	1,5437	2,1772
03.11.2008	27988	1,5678	1,9969	19.12.2008	26205	1,5187	2,2109
04.11.2008	29343	1,5282	1,9614	22.12.2008	26199	1,5157	2,1300
05.11.2008	27856	1,5248	1,9443	23.12.2008	26294	1,5213	2,1336
06.11.2008	27374	1,5068	1,9391	24.12.2008	26055	1,5225	2,1295
07.11.2008	26648	1,5315	1,9723	25.12.2008	26059	1,5185	2,1253
10.11.2008	26798	1,5442	1,9764	26.12.2008	26499	1,5147	2,1221
11.11.2008	25889	1,5232	1,9614	29.12.2008	26424	1,5043	2,1172
12.11.2008	25343	1,5898	2,0262	30.12.2008	26411	1,5138	2,1622
13.11.2008	25100	1,6304	2,0473	31.12.2008	26864	1,5196	2,1511
14.11.2008	25425	1,6387	2,0508				

Çizelge 4.7. “IMKB”, “USD” ve “EURO” zaman serileri (veri-set 2)

Tarih	IMKB	USD	EURO	Tarih	IMKB	USD	EURO
01.10.2009	47804	1,4841	2,1715	17.11.2009	47243	1,4769	2,2108
02.10.2009	46857	1,4904	2,1720	18.11.2009	46420	1,4813	2,2094
05.10.2009	47948	1,5005	2,1820	19.11.2009	46115	1,4796	2,2102
06.10.2009	49466	1,4868	2,1737	20.11.2009	45231	1,4903	2,2152
07.10.2009	49036	1,4670	2,1609	23.11.2009	45801	1,4949	2,2234
08.10.2009	49880	1,4684	2,1603	24.11.2009	45514	1,4928	2,2359
09.10.2009	50218	1,4601	2,1563	25.11.2009	45539	1,4983	2,2389
12.10.2009	51003	1,4640	2,1575	26.11.2009	45350	1,4897	2,2405
13.10.2009	50072	1,4642	2,1569	01.12.2009	46084	1,4897	2,2405
14.10.2009	51026	1,4579	2,1590	02.12.2009	47898	1,5088	2,2736
15.10.2009	51018	1,4464	2,1541	03.12.2009	49677	1,4980	2,2614
16.10.2009	49791	1,4434	2,1531	04.12.2009	50102	1,4883	2,2503
19.10.2009	50287	1,4585	2,1735	07.12.2009	49916	1,4838	2,2352
20.10.2009	51051	1,4575	2,1765	08.12.2009	49591	1,4953	2,2144
21.10.2009	51295	1,4526	2,1748	09.12.2009	49185	1,4985	2,2194
22.10.2009	51017	1,4639	2,1877	10.12.2009	49595	1,5033	2,2171
23.10.2009	51381	1,4696	2,2009	11.12.2009	49386	1,5004	2,2095
26.10.2009	51230	1,4640	2,2008	14.12.2009	50198	1,4942	2,2044
27.10.2009	50401	1,4746	2,2163	15.12.2009	50450	1,5026	2,2012
28.10.2009	48907	1,4894	2,2161	16.12.2009	50817	1,5103	2,1969
30.10.2009	47185	1,4894	2,2161	17.12.2009	49963	1,5084	2,1955
02.11.2009	47456	1,4898	2,2083	18.12.2009	50138	1,5172	2,1807
03.11.2009	46335	1,5003	2,2161	21.12.2009	51281	1,5184	2,1835
04.11.2009	47281	1,5097	2,2181	22.12.2009	51533	1,5232	2,1826
05.11.2009	47298	1,4979	2,2113	23.12.2009	51162	1,5254	2,1827
06.11.2009	46970	1,4917	2,2147	24.12.2009	51461	1,5259	2,1758
09.11.2009	47775	1,4828	2,2067	25.12.2009	51661	1,5143	2,1785
10.11.2009	48135	1,4751	2,2098	28.12.2009	51619	1,5125	2,1807
11.11.2009	48864	1,4749	2,2112	29.12.2009	51786	1,5138	2,1791
12.11.2009	48746	1,4710	2,2115	30.12.2009	51668	1,5098	2,1785
13.11.2009	48442	1,4776	2,2090	31.12.2009	52825	1,5130	2,1707
16.11.2009	48775	1,4817	2,2055				

Çizelge 4.8. “IMKB”, “USD” ve “EURO” zaman serileri (veri-set 3)

Tarih	IMKB	USD	EURO	Tarih	IMKB	USD	EURO
01.10.2010	64883	1,4504	1,9788	10.11.2010	70561	1,4099	1,9606
04.10.2010	65415	1,4459	1,9846	11.11.2010	70085	1,4138	1,9486
05.10.2010	66283	1,4458	1,9816	12.11.2010	69553	1,4210	1,9510
06.10.2010	66880	1,4486	1,9939	15.11.2010	69998	1,4349	1,9624
07.10.2010	66759	1,4218	1,9691	22.11.2010	67926	1,4349	1,9624
08.10.2010	67217	1,4180	1,9821	23.11.2010	66335	1,4429	1,9781
11.10.2010	69000	1,4275	1,9841	24.11.2010	67231	1,4630	1,9838
12.10.2010	69675	1,4110	1,9669	25.11.2010	67149	1,4834	1,9802
13.10.2010	70167	1,4242	1,9677	26.11.2010	66148	1,4764	1,9672
14.10.2010	69226	1,4120	1,9738	29.11.2010	64072	1,4891	1,9719
15.10.2010	70101	1,3988	1,9699	30.11.2010	65351	1,4935	1,9719
18.10.2010	70458	1,4056	1,9813	01.12.2010	66156	1,5063	1,9629
19.10.2010	69839	1,4243	1,9784	02.12.2010	66939	1,4960	1,9586
20.10.2010	69365	1,4227	1,9780	03.12.2010	66860	1,4882	1,9598
21.10.2010	70450	1,4292	1,9757	08.12.2010	67705	1,4753	1,9723
22.10.2010	71007	1,4198	1,9903	09.12.2010	65914	1,4901	1,9704
25.10.2010	70924	1,4285	1,9876	10.12.2010	64759	1,4976	1,9822
26.10.2010	70747	1,4147	1,9862	13.12.2010	66380	1,5012	1,9883
27.10.2010	68589	1,4202	1,9793	14.12.2010	66510	1,5050	1,9925
28.10.2010	60404	1,4370	1,9841	15.12.2010	65499	1,5009	2,0192
01.11.2010	69074	1,4370	1,9841	16.12.2010	64429	1,5182	2,0235
02.11.2010	68522	1,4264	1,9901	17.12.2010	63524	1,5230	2,0160
03.11.2010	68605	1,4169	1,9825	20.12.2010	63502	1,5273	2,0309
04.11.2010	70905	1,4087	1,9775	21.12.2010	64820	1,5536	2,0441
05.11.2010	70779	1,3951	1,9855	22.12.2010	65440	1,5572	2,0488
08.11.2010	70941	1,3987	1,9768	23.12.2010	66219	1,5531	2,0412
09.11.2010	71543	1,4100	1,9634				

Önerilen yöntemden elde edilen sonuçlar Song ve Chissom (1993b) , Chen (1996), Huarng (2001), Huarng ve Yu (2006a) ve Cheng ve ark. (2008) tarafından önerilen yöntem sonuçları ile karşılaştırılmıştır. Tüm yöntemlerin test kümesi için en iyi durumlarına ait hata ölçütleri, öngörülleri ile birlikte her bir durum için ayrı ayrı Çizelge 4.9-4.14 numaralı çizelgelerde özetlenmiştir.

Çözümlemeler sonucunda;

- 03.10.2008 - 31.12.2008 (veri-set 1) dönemine ait IMKB zaman serisinde son 7 gözlem test kümesi olarak kullanıldığında önerilen yöntemin en iyi modeli,

dokuzuncu dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Önerilen yöntem bu modelde en yüksek öngörü performansına bulanık küme sayısının 6 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 6 olduęu durumda ulaşmıştır.

- 03.10.2008 - 31.12.2008 (veri-set 1) dönemine ait IMKB zaman serisinde son 15 gözlem test kümesi olarak kullanıldığında önerilen yöntemden elde edilen en iyi model, beşinci dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Bu modelde bulanık küme sayısının 9 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 2 olduęu durumda en yüksek öngörü performansına ulaşmıştır.
- 01.10.2009 - 31.12.2009 (veri-set 2) dönemine ait IMKB zaman serisinde son 7 gözlem test kümesi olarak kullanıldığında önerilen yöntemin en iyi model, birinci dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Önerilen yöntem bu modelde en yüksek öngörü performansına bulanık küme sayısının 15 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 9 olduęu durumda ulaşmıştır.
- 01.10.2009 - 31.12.2009 (veri-set 2) dönemine ait IMKB zaman serisinde son 15 gözlem test kümesi olarak kullanıldığında önerilen yöntemden elde edilen en iyi model, üçüncü dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Bu modelde bulanık küme sayısının 14 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 14 olduęu durumda en yüksek öngörü performansına ulaşmıştır.
- 01.10.2010 - 23.12.2010 (veri-set 3) dönemine ait IMKB zaman serisinde son 7 gözlem test kümesi olarak kullanıldığında önerilen yöntemin en iyi model, ikinci dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Önerilen yöntem bu modelde en yüksek öngörü performansına bulanık küme sayısının 11 ve bulanık ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 12 olduęu durumda ulaşmıştır.
- 01.10.2010 - 23.12.2010 (veri-set 3) dönemine ait IMKB zaman serisinde son 15 gözlem test kümesi olarak kullanıldığında önerilen yöntemden elde edilen en iyi model, birinci dereceden çok deęişkenli bulanık zaman serisi öngörü modeli olarak tespit edilmiştir. Bu modelde bulanık küme sayısının 8 ve bulanık

ilişkileri belirlemede kullanılan ileri beslemeli YSA'nın gizli tabaka birim sayısının 9 olduğu durumda en yüksek öngörü performansına ulaşılmıştır.

Çizelge 4.9. Veri-Set 1 ve 7 gözlemlenmiş test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
23.12.2008	26294	26410	26400	26200	26100	26091	26390	26415,22
24.12.2008	26055	26410	26400	26200	26367	26091	26390	25881,81
25.12.2008	26059	26410	26400	26200	26100	26091	26390	26246,13
26.12.2008	26499	26410	26400	26200	26100	26091	26390	26646,42
29.12.2008	26424	26410	26400	26200	26500	26608	26390	26332,73
30.12.2008	26411	26410	26400	26200	26500	26608	26390	26401,48
31.12.2008	26864	26410	26400	26200	26500	26091	26390	26705,26
HKOK		261,01	259,76	310,47	251,24	354,72	258,87	138,90
OMYH		0,75%	0,75%	0,96%	0,80%	0,98%	0,76%	0,48%
YD		66,67%	66,67%	83,33%	50,00%	50,00%	66,67%	100,00%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

Çizelge 4.10. Veri-Set 1 ve 15 gözlemlenmiş test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
05.12.2008	24035	24337	24750	25200	24700	25598	25541	24317,16
12.12.2008	24937	24337	24750	23533	24100	24597	25406	25362,67
15.12.2008	25598	25670	24750	25200	26700	25598	25406	25105,15
16.12.2008	26396	25670	26250	24600	24100	25426	25406	26332,66
17.12.2008	26765	26319	26250	26200	26300	26255	25406	26443,36
18.12.2008	26396	26558	26250	26600	26550	26733	25406	26469,05
19.12.2008	26205	26319	26250	26200	26300	26255	25406	26471,74
22.12.2008	26199	26319	26250	26200	26300	26255	25406	26380,10
23.12.2008	26294	26319	26250	26200	26100	26255	25406	26334,62
24.12.2008	26055	26319	26250	26200	26300	26255	25406	26350,68
25.12.2008	26059	26319	26250	26200	26100	26255	25406	26391,44
26.12.2008	26499	26319	26250	26200	26100	26255	25406	26392,34
29.12.2008	26424	26319	26250	26200	26500	26255	25406	26394,20
30.12.2008	26411	26319	26250	26200	26500	26255	25406	26390,80
31.12.2008	26864	26319	26250	26200	26500	26255	25406	26353,89
HKOK		338,96	378,54	718,66	743,54	544,14	987,04	282,01
OMYH		1,03%	1,11%	1,90%	1,83%	1,41%	3,54%	0,89%
YD		71,43%	71,43%	71,43%	50,00%	71,43%	57,14%	71,43%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

Çizelge 4.11. Veri-Set 2 ve 7 gözlemlili test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
23.12.2009	51162	51137	52150	51900	51573	51033	50872	51341
24.12.2009	51461	51137	50850	50700	50373	51033	50763	51336
25.12.2009	51661	51137	50850	50700	51240	51033	50763	51341
28.12.2009	51619	51137	52150	51900	51573	51033	50763	51341
29.12.2009	51786	51137	52150	51900	51573	51033	50763	51341
30.12.2009	51668	51137	52150	51900	51773	52004	50763	51341
31.12.2009	52825	51137	52150	51900	51573	51033	50763	51341
HKOK		771,02	666,50	659,95	671,48	830,44	1084,21	625,26
OMYH		1,16%	1,23%	1,11%	0,97%	1,28%	1,85%	0,86%
YD		33,33%	33,33%	33,33%	33,33%	16,67%	33,33%	50,00%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

Çizelge 4.12. Veri-Set 2 ve 15 gözlemlili test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
11.12.2009	49386	49872	50250	49500	49100	49748	49984	49507,18
14.12.2009	50198	48606	48750	49500	49300	49316	49984	49609,84
15.12.2009	50450	49872	50250	49900	50500	50405	49984	49673,15
16.12.2009	50817	50294	50250	49900	48900	48886	49984	50713,53
17.12.2009	49963	50294	50250	50300	50900	48886	49984	50178,52
18.12.2009	50138	49872	50250	49900	49900	49748	49984	49847,44
21.12.2009	51281	49872	50250	49900	50500	50405	49984	50847,57
22.12.2009	51533	51137	51000	50300	50967	50625	49984	50840,97
23.12.2009	51162	51137	51000	51900	51500	51065	49984	51094,21
24.12.2009	51461	51137	51000	50300	50550	50625	49984	51063,35
25.12.2009	51661	51137	51000	50300	51500	51065	49984	51055,12
28.12.2009	51619	51137	51000	51900	51700	51065	49984	51053,60
29.12.2009	51786	51137	51000	51900	51700	51065	49984	51048,78
30.12.2009	51668	51137	51000	51900	51700	51963	49984	51048,90
31.12.2009	52825	51137	51000	51900	51700	51065	49984	51047,61
HKOK		810,85	820,57	815,99	760,77	917,11	1381,68	668,72
OMYH		1,28%	1,33%	1,34%	1,10%	1,47%	2,25%	1,03%
YD		28,57%	50,00%	28,57%	50,00%	35,71%	42,86%	50,00%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

Çizelge 4.13. Veri-Set 3 ve 7 gözlemlili test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
15.12.2010	65499	65355	65500	66167	66500	67254	65992	66059,58
16.12.2010	64429	65355	65500	65500	66300	66035	65992	65832,91
17.12.2010	63524	65974	65500	66000	64500	65435	65992	64250,22
20.12.2010	63502	64736	64950	63500	63500	63668	65992	64250,22
21.12.2010	64820	64736	64950	63500	63500	63668	65992	64250,22
22.12.2010	65440	65974	65500	66000	65500	66038	65992	64250,22
23.12.2010	66219	65355	65500	65500	66300	66035	65992	66062,72
HKOK		1161,21	1047,84	1212,81	1014,73	1256,90	1544,90	856,66
OMYH		1,39%	1,20%	1,51%	1,17%	1,63%	2,00%	1,18%
YD		50,00%	50,00%	50,00%	50,00%	50,00%	50,00%	50,00%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

Çizelge 4.14. Veri-Set 3 ve 15 gözlemlili test kümesi için yöntemlere ait sonuçlar

Tarih	IMKB	Song-Chissom (1993b)	Chen (1996)	Huarng (2001 ^a)	Huarng (2001 ^b)	Huarng ve Yu (2006a)	Cheng ve ark. (2008)	Önerilen Yöntem
01.12.2010	66156	65974	65500	66500	65300	66035	65776	66155,17
02.12.2010	66939	66163	65500	66167	64100	66048	65600	65204,42
03.12.2010	66860	66163	67517	66167	66700	66946	65776	66775,52
08.12.2010	67705	66163	67517	66167	66700	66946	65600	66775,77
09.12.2010	65914	66206	66325	67833	67700	66035	65776	66777,94
10.12.2010	64759	65974	65500	66500	65900	66048	65600	64938,77
13.12.2010	66380	65974	65500	65500	64700	65435	65776	65037,52
14.12.2010	66510	66163	65500	66167	67100	66946	65600	66758,95
15.12.2010	65499	66163	65500	66167	66500	66946	65776	66772,94
16.12.2010	64429	65974	65500	66500	66300	66035	65600	65154,58
17.12.2010	63524	65277	65500	65500	64500	65435	65776	64959,36
20.12.2010	63502	65277	64950	63500	63500	63668	65600	64960,35
21.12.2010	64820	65277	64950	63500	63500	63668	65776	64960,35
22.12.2010	65440	65974	65500	65500	65500	65435	65600	65073,31
23.12.2010	66219	65974	65500	66500	66300	66035	65776	66095,58
HKOK		998,30	1047,84	1200,93	1283,18	961,50	1197,78	931,96
OMYH		1,27%	1,20%	1,49%	1,56%	1,14%	1,50%	1,11%
YD		57,14%	50,00%	50,00%	57,14%	50,00%	57,14%	64,29%

a. Dağılıma Dayalı b. Ortalamaya Dayalı

5. SONUÇ VE ÖNERİLER

Bulanık zaman serisi analizi yöntemleri, araştırılan hemen tüm problemlerde ortaya çıkan veri topluluklarının belirsizlik içermeleri nedeniyle, oldukça geniş bir kullanım alanına sahiptir. Bu tip belirsizlik içeren ve zaman içerisinde gözlenebilen verilerin, bulanık zaman serisi olarak ele alınması uygun bir yaklaşımdır. Tüm bunların yanında bulanık zaman serilerinin, geleneksel zaman serisi yöntemlerinde olan varsayımları içermemesi de bu alana olan ilgiyi arttıran nedenlerden biri olarak sayılabilir.

Bulanıklaştırma, bulanık ilişkilerin belirlenmesi ve durulaştırma olmak üzere üç aşamadan oluşan bulanık zaman serilerinin öngörü performansı, bu üç aşamaya da oldukça duyarlıdır. Bu nedenle son yıllarda literatürde bu üç aşama üzerine de birçok çalışma ortaya konmaktadır.

Bulanıklaştırma aşamasında hemen tüm çalışmalar evrensel küme parçalanmasını kullanmasına rağmen bu durumun bazı subjektif yargılar içermesi, bulanık kümeleme yöntemleri gibi bazı alternatif yaklaşımların kullanımını doğurmuştur.

Bulanık ilişki belirlenmesi aşamasında ise bir çok çalışmada bulanık mantık grup ilişki tabloları kullanılmakla beraber, bu yöntemin eğitim kümesi ile çalışan yöntemlerde oldukça düşük öngörü hatasına sahip olmalarına rağmen özellikle test kümesi için yeterince üstün bir öngörü performansı sergileyemediği söylenebilir. Bulanık ilişki tablolarına alternatif olarak bulanık ilişkilerin belirlenmesinde yapay sinir ağlarının kullanıldığı çalışmalar da mevcuttur. Ancak tüm bu çalışmalarda, bulanık ilişkiler belirlenirken, gözlemlerin en yüksek üyelik değerine sahip olduğu kümeleri temsil eden küme numaraları ile işlem yapılmakta ve diğer üyelikler göz ardı edilmektedir. Oysa ki bir bulanık zaman serisi gözlemi, en yüksek üyelik değerine sahip olduğu bulanık küme dışında diğer kümelere de belirli üyelik değerleri ile aittir. Bu nedenle, bulanık ilişkiler belirlenirken, her bir gözlemin tüm bulanık kümelere ait olmasının üyelik değerlerinin dikkate alınması, bilgi kaybını önleyecek, bulanık ilişkileri daha gerçekçi olarak ortaya koyacak ve böylece öngörü doğruluğunu arttıracaktır. Bu noktadan hareketle, Yu ve Huarng (2010), girdileri ve hedefleri gözlemlerin üyelik değerlerinden oluşan yapay sinir ağlarını bulanık ilişkilerin

belirlenmesinde kullanmıştır. Yu ve Huarng (2010) tarafından önerilen bu yaklaşımda, üyelik değerlerinin sübjektif belirlenmesinin yanında evrensel küme parçalanması kullanılmaktadır. Bu bilgiler ışığında, Yolcu ve ark. (2010), bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan bulanık C-ortalamlar yöntemini kullanan ve bulanık ilişkilerin belirlenmesi aşamasında girdileri ve hedefleri, bulanık C-ortalamlar yöntemi ile belirlenen üyelik değerlerinden oluşan yapay sinir ağlarının kullanıldığı bir yöntem önermişlerdir.

Yolcu ve ark. (2010) tarafından önerilen bulanık zaman serisi analizi yaklaşımı yukarıda bahsedilen problemleri ortadan kaldırmıştır. Ancak, göz önüne alınması gereken diğer bir husus da, bulanık zaman serilerinin öngörülmesinde bulanık zaman serisinin kendi gecikmeli değişkeninin yanı sıra farklı bulanık zaman serilerinden ve onların gecikmeli değişkenlerinden de etkilenebileceğidir. Bu nedenle karşılaşılan birçok problemde bulanık zaman serilerinin, diğer bazı bulanık zaman serileri ile aralarında mevcut olan bulanık ilişkileri ortaya çıkaracak bir öngörü modeli oluşturulmalıdır. Ancak birden fazla zaman serisi ve bu zaman serilerinin gecikmeli değişkenleri ile Yu ve Huarng (2010) ve Yolcu ve ark. (2010) tarafından önerilen yöntemlerin uygulanması mümkün değildir. Ayrıca bu yöntemlerin çok değişkenli duruma genişletilmesi halinde de yapay sinir ağının çok fazla girdisi olacaktır. Örneğin 3 zaman serisi olduğunda 7 bulanık küme kullanılması durumunda sadece 1 ve 2 adım gecikmeli değişkenler kullanılırsa 42 girdili bir yapay sinir ağı söz konusu olur. Çok fazla girdi ile çalışmak yapay sinir ağlarında eğitim açısından ciddi bazı zorluklar ortaya çıkaracaktır. Dolayısıyla birden fazla zaman serisi kullanıldığı durumda yapay sinir ağının girdi sayısının azaltılması da çözülmesi gereken önemli bir problemdir.

Bu tezde önerilen yöntemle, bahsedilen tüm sorunları gideren bir yaklaşım ortaya konmaya çalışılmıştır. Önerilen yöntem, bulanıklaştırma aşamasında evrensel küme parçalanmasına gerek duymayan, her bir gözlemin bulanık kümelere ait olma üyelik değerlerinin sübjektif yargılardan uzak belirlendiği, bulanık C-ortalamlar yöntemini kullanmaktadır. Bulanık C-ortalamlar yönteminin kullanılması aralık uzunluklarının sübjektif belirlenmesi gibi kararlara da gerek bırakmamaktadır. Zaman serilerinin gecikmeli değişkenlerinin bir arada bulanık C-ortalamlar yöntemi ile kümelenmesi yapay sinir ağının (az) uygun girdi sayısı ile çalışmasını sağlamaktadır. Böylece bulanık ilişki belirlenmesi aşamasında girdileri ve hedefleri bulanık c

ortalamalar yönteminden elde edilen üyelik değerlerinden oluşan yapay sinir ağıları kullanılmaktadır. Üyelik değerlerine bağlı böyle bir yapay sinir ağı mimarisinin kullanılması, önerilen yöntemde üyelik değerleri arasındaki eğrisel ilişkinin modellenmesi imkânını sunmaktadır. Yöntem yapay sinir ağlarının üstün ve esnek modelleme özelliğine sahip olmaktadır. Berraklaştırma aşamasında ise tüm üyelik değerlerinin kullanıldığı bir yaklaşıma iş verilmiştir. Yöntem çok değişkenli bir bulanık zaman serisi öngörü modelini çözümlenmektedir.

Önerilen yöntem literatürde kullanılan 4 farklı veriye uygulanarak elde edilen sonuçlar diğer bazı bulanık zaman serisi yöntemleri ile birlikte değerlendirilmiştir. İlk olarak “Belçika’da gerçekleşen ölümlü araba kazaları” zaman serisi dört farklı zaman serisi yardımıyla eğitim kümesi üzerinden öngörülmuş ve önerilen yöntemin öngörü performansının diğer yöntemlere göre üstün olduğu gözlemlenmiştir. Bunun yanında ikinci olarak çözümlenmesi yapılan “TAIFEX” (Taiwan Futures Exchange) zaman serisi ise literatürdeki diğer çalışmalarda olduğu gibi aynı dönemlere ait “TAIEX” zaman serisi yardımıyla öngörülmuş ve sonuçlar 16 gözlemden oluşan test kümesi üzerinden değerlendirilmiştir. Üçüncü olarak “TAIEX” (Taiwan Stock Exchange) zaman serisi iki farklı zaman serisi yardımıyla öngörülmuş ve sonuçlar 45 gözlemlilik test kümesi üzerinden değerlendirilmiştir. Son olarak, üç farklı veri setinden oluşan İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi (İMKB) zaman serisi, her bir veri setinde son 7 ve 15 gözlem test kümesi alınarak öngörülmiştir. Elde edilen sonuçların tamamı birlikte değerlendirildiğinde, önerilen yöntemin ortadan kaldırdığı tüm sorunların ve sağladığı avantajların yanında, hem eğitim kümesi, hem de test kümesi bakımından oldukça üstün bir öngörü performansına sahip olduğu açık bir şekilde söylenebilir.

Bunun yanında gelecek çalışmalarda, önerilen çok değişkenli öngörü modelinde, değişken ve model derecesinin belirlenmesinde farklı sezgisel yaklaşımlar kullanılabilir. Böylece hem modele katkısı bulunmayan değişkenlerin modelden arındırılması hem de bulanık zaman serisinin barındırdığı bulanık ilişkilerin daha gerçekçi olarak ortaya çıkarılması ile yöntemin öngörü performansının daha üst seviyelere taşınması sağlanmış olacaktır.

Ayrıca, bu çalışmada önerilen yöntemin performansı bazı gerçek hayat bulanık zaman serileri için değerlendirilmesine rağmen, gelecekte simülasyon verileri ve istatistiksel hipotez testleri ile de değerlendirilebilir.

6. KAYNAKLAR

- Aladag, C.H., Basaran, M.A., Egrioglu E., **Yolcu, U.**, Uslu V.R., 2009. Forecasting in high order fuzzy time series by using neural networks to define fuzzy relations. *Expert Systems with Applications*, 36, 4228-4231.
- Bezdek, J.C, 1981. *Pattern recognition with fuzzy objective function algorithms*, NY: Plenum Press.
- Bolat, S., Kalenderli, Ö., 2003. Levenberg-Marquardt Algoritması Kullanılan Yapay Sinir Ağı İle Elektrot Biçim Optimizasyonu. “International XII. Turkish Symposium on Artificial Intelligence and Neural Networks – TAINN 2003”
- Buckley, J.J., Siler, W., 1988. “Fuzzy number for expert systems”, Gupta, M.M., Yakamakawa, T. (ed), *Fuzzy logic in knowledge-based systems, decision and control*. Elsevier, s:153, Amsterdam.
- Buckley, J.J., Elsami, E., 2002. *Introduction to Fuzzy Logic and Fuzzy Sets*. Physica-Verlag, Berlin.
- Chang, P.T., 1997. Fuzzy seasonality forecasting. *Fuzzy Sets and Systems*, 90(1), 1–10.
- Chen, S. M., 1996. Forecasting enrollments based on fuzzy time-series. *Fuzzy Sets and Systems*, 81, 311-319.
- Chen, S.M., 2002. Forecasting enrollments based on high order fuzzy time series. *Cybernetics and Systems*, 33, 1-16.
- Chen, S.M., Chung, N.Y., 2006. Forecasting enrolments using high order fuzzy time series and genetic algorithms. *International Journal of Intelligent Systems*, 21, 485-501.
- Chen, S.M., Chen, C.D., 2011. TAIEX forecasting based on fuzzy time series and fuzzy variation groups, *IEEE Transactions on Fuzzy Systems*, vol. 19 No.1.
- Cheng, C.-H., Cheng, G.-W., Wang, J.-W., 2008. Multi-attribute fuzzy time series method based on fuzzy clustering. *Expert Systems with Applications*, 34, 1235-1242.

- Davari, S., Zarandi, M.H.F., 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.
- Dubois, D., Prade, H., 1980. *Fuzzy sets and systems: theory and applications*. Academic press, s:10, Boston.
- Egrioglu, E., Aladag, C.H., **Yolcu, U.**, Uslu, V.R., 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, 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., Aladag, C.H., 2009c. A new approach based on artificial neural networks for high order bivariate fuzzy time series. J.Mehnen et al. (Eds.): *Applications of Soft Computing*, AISC 58, Springer-Verlag Berlin Heidelberg, 265-273.
- Egrioglu, E., Aladag, C.H., **Yolcu, U.**, Uslu, V.R., Basaran, M.A., 2010. Finding an optimal interval length in high order fuzzy time series. *Expert Systems with Applications*, 37, 5052-5055.
- Egrioglu, E., Aladag, C.H., Basaran, M.A., Uslu, V.R., **Yolcu, U.**, 2011. A New Approach Based on the Optimization of the Length of Intervals in Fuzzy Time Series. *Journal of Intelligent and Fuzzy Systems*, 22,15-19.
- Elmas, Ç., 2003. *Bulanık Mantık Denetleyiciler*. Seçkin Yayıncılık, 230s, Ankara.
- Fedrizzi, M., 1987. "Introduction to fuzzy sets and possibility theory", Kacprzyk, J., Orlovski, S. (ed), *Optimization models using fuzzy sets and possibility theory*. Kluwer Academic Publishers, s:16, Dordrecht.
- Günay, S., Eğrioğlu, E., Aladağ, Ç.H., 2007. *Tek Değişkenli Zaman Serileri Analizine Giriş*. Hacettepe Üniversitesi Yayınları, 230s, Ankara.

- Hsu, L-Y., Horng, S-J., Kao, T-W., Chen, Y-H., Run, R-S, Chen, R-J., Lai, J-L., Kuo, I-H., 2010. Temperature prediction and TAIEX forecasting based on fuzzy relationships and MTPSO techniques. *Expert Systems with application*, 37,2756-2770.
- Huarng, K., 2001. Effective length of intervals to improve forecasting in fuzzy time-series. *Fuzzy Sets and Systems*, 123, 387-394.
- Huarng, K., Yu, T.H.-K., 2006a. Ratio-based lengths of intervals to improve fuzzy time series forecasting. *IEEE Transactions on Systems, Man,, and Cybernetics-Part B: Cybernetics*, 36, 328-340.
- Huarng, K., Yu, H.-K., 2006b. The application of neural networks to forecast fuzzy time series. *Physica A*, 363, 481-491.
- Huarng, K., Yu, H.K., Hsu, Y.W., 2007. A multivariate heuristic model for fuzzy time-series forecasting. *IEEE Transactions on Systems, Man, and, Cybernetics Part-B: Cybernetics*, vol. 37, no. 4, pp. 836-846.
- Jamshidi, M., 1997. *Large scale systems: modeling, control and fuzzy kogig*. Perntice Hall, s:498,507, New Jersey.
- Jilani, T.A., 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. *Advances in Soft Computing*, 41, 246–254.
- Jilani, T.A., Burney, S.M.A., 2008. Multivariate stochastic fuzzy forecasting models. *Expert Systems with Applications*, 35(3), 691–700.
- Jilani, T.A., Burney, S.M.A., Ardil, C., 2007. Multivariate high order fuzzy time series forecasting for car road accidents. *International Journal of Computational Intelligence*, 4(1), 15–20.
- Kendel, A., 1986. *Fuzzy mathematical techniques with applications*. Addison Wesley, s:7, Massachusetts.

- Kerre, E.E., Scooten, A.V., 1988. "A deeper look on fuzzy number from a theoretical as well as from practical point of view", Gupta, M.M., Yakamakawa, T. (ed), *Fuzzy logic in knowledge-based systems, decision and control*. Elsevier, s:184, Amsterdam.
- Klir, G., Yuan, B., 1995. *Fuzzy Set and Fuzzy Logic: Theory and Applications*. Prentice Hall, Upper Saddle River, N.J.
- Kuo, I.-H., Horng, S.-J., Kao, T.-W., Lin, T.-L., Lee, C.-L., Pan, Y., 2009. An improved method for forecasting enrollments based on fuzzy time series and particle swarm optimization. *Expert Systems with application*, 36, 6108-6117.
- Kuo, I.-H., Horng, S.-J., Chen, Y.-H., Run, R.-S., Kao, T.-W., Chen, R.-J., Lai, J.-L., Lin, T.-L., 2010. Forecasting TAIEX based on fuzzy time series and particle swarm optimization. *Expert Systems with application*, 37, 1494-1502.
- Lai, Y.J., Hwang, C.L., 1992. *Fuzzy mathematical programming: methods and applications*. Springer-Verlag, s:61, Heidelberg.
- Le Chun, Y., 1988. A theoretical framework for backpropagation, in proc. Connectionist Model Summer School, June 17-26, Touretzky, D., Hinton, G., and Sejnowski, T. (Eds.), Morgan Kaufmann, pp. 21-28.
- Lee, L.W., Wang, L.H., Chen, S.M., Leu, Y.H., 2006. Handling forecasting problems based on two factor high-order fuzzy time series. *IEEE Trans. on Fuzzy Systems*, 14, No:3, 468-477.
- Lee, L.W., Wang, L.H., Chen, S.M., 2007. Temperature prediction and TAIEX forecasting based on fuzzy logical relationships and genetic algorithms. *Expert Systems with Applications*, 33, 539-550.
- Lee, L.W., Wang, L.H., 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, 328-336.

- Li, S.-T., Cheng, Y.-C., Lin, S.-Y., 2008. A FCM-based deterministic forecasting model for fuzzy time series. *Computers and Mathematics with Applications*, 56, 3052-3063.
- Li, H.X., Yen, V.C., 1995. *Fuzzy sets and fuzzy decision making*. Cec Press, s:15, Boca Raton.
- Lin, C.T., Lee, C.S.G., 1996. *Neural fuzzy systems: a neuro-fuzzy synergism to intelligent systems*. Prentice Hall, s:12,29, New Jersey.
- Ngia, S. H., 2000. Efficient Training of Neural Nets for Nonlinear Adaptive Filtering Using a Recursive Levenberg-Marquardt Algorithm. *IEEE Trans. on Signal Process.*, 48, 1915-1927.
- Oğuz, M., 2001. Yalıtkan Maddelerde Elektriksel Delinme Dayanımının Yapay Sinir Ağları İle Belirlenmesi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Özkan, M.M., 2003. *Bulanık hedef programlama*. Ekin Kitapevi, 288s, Bursa.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Papatya Yayıncılık, 238s, İstanbul.
- Park, J.-I., Lee, D.-J., Song, C.-K., Chun, M.-G., 2010. TAIEX and KOSPI 200 forecasting based on two factors high order fuzzy time series and particle swarm optimization. *Expert Systems with application*, 37, 959-967.
- Parker, D.B., 1982. Learning-Logic, Invention Report. Office of Technology Licensing Stanford University. S81-64, File 1, Stanford.
- Pedrycz, W., 1989. *Fuzzy control and fuzzy systems*. Research studies press, s:22, Taunton.
- Pedrycz, W., Gomide, F., 1998. *An introduction to fuzzy sets, analysis and design*. Mit Press Cambridge, s:135, Massachusetts.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J., 1986. Learning Representations by Backpropagating Errors. *Nature*, 323 (6188), 533-536.

- Song, Q., Chissom, B.S., 1993a. Fuzzy time series and its models. *Fuzzy Sets and Systems*, 54, 269-277.
- Song, Q., Chissom, B.S., 1993b. Forecasting enrollments with fuzzy time series- Part I. *Fuzzy Sets and Systems*, 54, 1-10.
- Song, Q., Chissom, B.S., 1994. Forecasting enrollments with fuzzy time series- Part II. *Fuzzy Sets and Systems*, 62 1-8.
- Song, Q., 1999. Seasonal forecasting in fuzzy time series. *Fuzzy Sets and Systems*, 107(2), 235.
- Timoty, J.R., 1995. *Fuzzy logic with engineering applications*. Mc Graw-Hill, s:88, New York.
- Tsoukalas, L.H., Uhrig, R.E., 1997. *Fuzzy and neural approaches in engineering*. John Wiley & Sons, s:16,30, New York.
- Yolcu, U.**, Egrioglu, E., Uslu, V.R., Basaran, M.A., Aladag, C.H., 2009. A New Approach for Determining the Length of Intervals for Fuzzy Time Series. *Applied Soft Computing*, 9,647-651.
- Yolcu, U.**, Aladag, C.H., Egrioglu, E., Uslu, V.R., 2010. Time series forecasting with a novel fuzzy time series approach: an example for İstanbul stock market. *Journal of Statistical Computation and Simulation (Hakemlik Sürecinde)*.
- Yu, H.-K., Huarng, K., 2008. A bivariate fuzzy time series model to forecast TAIEX. *Expert Systems with Applications*, 34, 2945-2952.
- Yu, T.H.-K., Huarng, K.-H., 2010. A neural network- based fuzzy time series model to improve forecasting. *Expert Systems with application*, 37, 3366-3372.
- Wang, L.X., 1997. *A course in fuzzy systems and control*. Prentice Hall, s:368,370, New Jersey.
- Werbos, P.J., 1974. *Beyond Regression: New tools for Prediction and Analysis in the Behavioral Sciences*. Ph. D. Thesis, Harvard University, Cambridge.

Zadeh L.A., 1965. Fuzzy Sets, Inform and Control, 8,338-353.

Zadeh L.A., 1973. Outline of a new approach to the analysis of complex systems and decisions processes, IEEE Trans. Systems Man Cybernet., 3, 28-44.

Zadeh L.A., 1975. The concept of a linguistic variable and its application to approximate reasoning, Parts 1-3, Information Sciences. 8, 199-249; 8, 301-357; 9, 43-80.

Zimmermann, H.J., 1993. *Fuzzy sets, decision making and expert systems*. Kluwer Academic Publishers, s:11, Boston.

7. EKLER

Ek 1. Birinci Dereceden Çok Değişkenli Bulanık Zaman Serisi Öngörü Modeli İçin Örnek MATLAB Programı

Program Girdi ve Parametreleri

x : Zaman serisi
ks : Bulanık küme sayısı
m : Gizli tabaka birim sayısı
ntest : Test kümesi genişliği

```
function [RMSEtest,MAPEtest,DAtest,rn]=ftsfcmannuylkfocoklu1drc(x,ks,m,ntest)

rand('seed',4.9276984E7);

rn=rand('seed');

n=length(x2);

xegt=x2(1:(n-ntest),:);

xtest=x2((n-ntest+1):n,:);

% Bulanıklaştırma

[C1,U1]=fcm(xegt,ks);

[C,U]=sortcu(C1,U1);

% Bulanık İlişki Belirleme

Gegt=U(:,1:(n-ntest-1));

yegt=U(:,2:(n-ntest));

net=newff(minmax(Gegt),[m,ks],{'logsig','logsig'},'trainlm');

net.trainParam.epochs=500;

net.trainParam.goal=1e-8;

net.trainParam.show=NaN;

%Ağın Eğitimi

[net,tr]=train(net,Gegt,yegt);
```

```

%Çıktılar;

ycegt=sim(net,Gegt);

%Eğitim için Öngörüler

top2=sum(ycegt);

for i=1:ks

    for j=1:(n-ntest-1)

        stdycegt(i,j)=ycegt(i,j)/top2(j);

    end

end

ongegt=((C(:,1))*stdycegt)';

%Öngörü

%Test Kümesi için Üyelikler Elde Ediliyor.

%Bulanık Öngörü

Utest=stepfcm2fts(xtest,U,ks,2,C);

Gtest=[U(:,(n-ntest)),Utest(:,(1:ntest-1))];

yctest=sim(net,Gtest);

%Duru Test Öngörü

top=sum(yctest);

for i=1:ks

    for j=1:ntest

        stdyctest(i,j)=yctest(i,j)/top(j);

    end

end

ongtest=((C(:,1))*stdyctest)';

%rn=rand('seed');

```

%Ölçütler hesaplanıyor

```
[RMSEegt,MAPEegt,DAegt]=kriter(ongegt',xegt(2:(n-ntest),1));
```

```
[RMSEtest,MAPEtest,DAtest]=kriter(ongtest',xtest(:,1));
```

Ek 2. Beşinci Dereceden Çok Değişkenli Bulanık Zaman Serisi Öngörü Modeli İçin Örnek MATLAB Programı

Program Girdi ve Parametreleri

x : Zaman serisi
ks : Bulanık küme sayısı
m : Gizli tabaka birim sayısı
ntest : Test kümesi genişliği

```
function [RMSEtest,MAPEtest,DAtest,rn]=ftsfcmannuyllkfocoklu5drc(x2,ks,m,ntest)

rand('seed',4.9276984E7);

rn=rand('seed');

n=length(x2);

x2=lagmatrix(x2,[0,1,2,3,4]);

xegt=x2(5:(n-ntest),:);

xtest=x2((n-ntest+1):n,:);

% Bulanıklaştırma

[C1,U1]=fcm(xegt,ks);

[C,U]=sortcu(C1,U1);

n1=length(U);

% Bulanık İlişki Belirleme

Gegt=U(:,1:(n1-1));

yegt=U(:,2:n1);

net=newff(minmax(Gegt),[m,ks],{'logsig','logsig'},'trainlm');

net.trainParam.epochs=500;

net.trainParam.goal=1e-8;

net.trainParam.show=NaN;
```

```

%Ağın Eğitimi

[net,tr]=train(net,Gegt,yegt);

%Çıktılar;

ycegt=sim(net,Gegt);

%Eğitim için Öngörüler

top2=sum(ycegt);

for i=1:ks

    for j=1:(n1-1)

        stdycegt(i,j)=ycegt(i,j)/top2(j);

    end

end

ongegt=((C(:,1))*stdycegt)';

%Öngörü

%Test Kümesi için Üyelikler Elde Ediliyor.

%Bulanık Öngörü

Utest=stepfcm2fts(xtest,U,ks,2,C);

Gtest=[U(:,n1),Utest(:,(1:n1-1))];

yctest=sim(net,Gtest);

%Duru Test Öngörü

top=sum(yctest);

for i=1:ks

    for j=1:n1

        stdyctest(i,j)=yctest(i,j)/top(j);

    end

end

end

```

```
ongtest=((C(:,1))*stdyctest)';  
%rn=rand('seed');  
%Ölçütler hesaplanıyor  
[RMSEegt,MAPEegt,DAegt]=kriter(ongegt',xegt(2:(n1),1));  
[RMSEtest,MAPEtest,DAtest]=kriter(ongtest',xtest(:,1));
```

8. ÖZGEÇMİŞ

Ufuk YOLCU

Gaziantep/15.06.1977

Bekar

Yabancı Dil

İngilizce

Eğitim

Lisans : Ondokuz Mayıs Üniversitesi Fen Edebiyat Fakültesi
İstatistik Bölümü 1999-2003

Yüksek Lisans : Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı 2006-2008

Doktora : Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü
İstatistik Anabilim Dalı 2008-2011

Çalıştığı Kurumlar

Türkiye İş Bankası Sultanhamam Şubesi 1905-2007

Ondokuz Mayıs Üniversitesi Fen Edebiyat Fakültesi İstatistik Bölümü 2007-

İletişim

Adres : Ondokuz Mayıs Üniversitesi
Fen Edebiyat Fakültesi İstatistik Bölümü
Kurupelit Kampusu ATAKUM/SAMSUN
55139

Telefon: 0 362 312 19 19 / 5237