

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**SEZGİSEL BULANIK KÜMELERİN
BİLEŞENLERİNİN KOMBİNASYONUNA DAYALI
ZAMAN SERİSİ ÖNGÖRÜ MODELİ**

YÜKSEK LİSANS TEZİ

Şule Nazlı ARSLAN

Tezin Enstitüye Verildiği Tarih : 26.08.2021

Enstitü Anabilim Dalı : İstatistik Anabilim Dalı

Tez Danışmanı : Doç. Dr. Özge CAĞCAĞ YOLCU

Temmuz 2021

GİRESUN

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**SEZGİSEL BULANIK KÜMELERİN
BİLEŞENLERİNİN KOMBİNASYONUNA DAYALI
ZAMAN SERİSİ ÖNGÖRÜ MODELİ**

YÜKSEK LİSANS TEZİ

Şule Nazlı ARSLAN

Enstitü Anabilim Dalı : İstatistik Anabilim Dalı

Bu tez 27/07/2021 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

**Doç. Dr. Cem
KOÇAK
Jüri Başkanı**

**Doç. Dr. Fâtma Zehra
DOĞRU
Üye**

**Doç. Dr. Özge
CAĞCAĞ YOLCU
Üye**

Doç. Dr. Bahadır KOZ
.....
Enstitü Müdürü

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Şule Nazlı ARSLAN

27/07/2021

TEŞEKKÜR

Öncelikle, lisansüstü öğrenimim boyunca, her anımda yanımda olan, hiçbir zaman desteğini esirgemeyen, değerli fikirleriyle bana yol gösteren Sayın Doç. Dr. Özge CAĞCAĞ YOLCU'ya tez danışmanlığımı üstlendiği ve çalışmamın her aşamasında yanımda olarak desteğini hiç eksik etmediği ve hiç bitip tükenmeyen özverisi ve sabrı için sonsuz minnet ve şükranlarımı sunarım. Tüm lisansüstü öğrenimim süresince verdikleri destek ve katkıdan dolayı İstatistik bölümü değerli hocalarıma sonsuz teşekkürlerimi sunmak isterim. Ayrıca değerli katkıları ve eleştirileri için tez jüri üyelerim Sayın Doç. Dr. Cem KOÇAK ve Sayın Doç. Dr. Fatma Zehra DOĞRU'ya teşekkür ederim.

Hayatımın her evresinde bana destek vermesede hayattaki tüm zorlukları benimle göğüsleyen, bir kişinin sahip olabileceği en güzel arkadaş olan sevgili Huriye AKCAN'a teşekkür ederim.

Ve en sonunda bugünlere gelmemde maddi ve manevi desteklerini hiçbir zaman üzerimden eksik etmeyen en büyük destekçilerim ve haklarını hiçbir zaman ödeyemeyeceğim canım annem Yadigar ARSLAN ve babam Salih ARSLAN'a sonsuz minnet ve şükranlarımı sunarım. Ayrıca hayatımın hiçbir noktasında eksikliğini hissetmediğin kardeşim Tuncay ARSLAN ve canımdan öte olan hayatımın olmazsa olmazı küçüğüm, canımın içi Cansu ARSLAN'a en içten dileklerle teşekkür ederim.

Temmuz, 2021

Şule Nazlı ARSLAN

İÇİNDEKİLER

TEŞEKKÜR.....	I
İÇİNDEKİLER	II
KISALTMALAR LİSTESİ.....	IV
ŞEKİLLER LİSTESİ	V
TABLolar LİSTESİ.....	VI
ÖZET.....	VII
SUMMARY	VIII
BÖLÜM 1. GİRİŞ.....	1
BÖLÜM 2. BULANIK KÜME KURAMI	12
2.1. Bulanık Küme	14
2.1.1. Bulanık Küme İşlemleri	15
2.2. Sezgisel Bulanık Küme	18
2.2.1. Sezgisel Bulanık Küme İşlemleri.....	21
BÖLÜM 3. BULANIK ZAMAN SERİLERİ VE TEMEL TANIMLAR	23
3.1. Bulanık Zaman Serileri	25
3.2. Sezgisel Bulanık Zaman Serileri	29
3.3. Bulanık C Ortalamalar Yöntemi	30
3.4. Sezgisel Bulanık C Ortalamalar Yöntemi	31
BÖLÜM 4. YAPAY SİNİR AĞI.....	34
4.1. Pi-Sigma Yapay Sinir Ağı.....	39
4.2. Parçacık Sürü Optimizasyon Yöntemi	42
BÖLÜM 5. ÖNERİLEN YÖNTEMLER.....	47
5.1. Yeni Bir Melez Pi-Sigma Sinir Ağı	47
5.2. Yeni Bir Sezgisel Bulanık Zaman Serisi Tahmin Modeli.....	49
BÖLÜM 6. UYGULAMALAR.....	56
6.1. Veri Hazırlama	56
6.2. Performans Ölçüsü	56
6.3. Alternatif Karşılaştırma Modelleri	58
6.4. Model Performansının Değerlendirilmesi.....	58

6.4.1. TAIEX Uygulamaları.....	59
6.4.2. EIX Uygulaması.....	63
BÖLÜM 7. SONUÇLAR VE ÖNERİLER.....	67
KAYNAKLAR.....	69
ÖZGEÇMİŞ	82



KISALTMALAR LİSTESİ

ANFIS	: Uyarlanabilir nöro-bulanık çıkarım sistemi
AR-ANFIS	: AR yapısı ile uyarlanabilir nöro-bulanık çıkarım sistemi
ARIMA	: Otoregresif entegre hareketli ortalama yöntemi
ES	: Üstel düzgünleştirme
FF-T1	: Tip 1 bulanık Regresyon fonksiyonu yaklaşımı
FTS	: Bulanık zaman serisi
FTS-N	: Bulanık zaman serisi ağı
MPS-YSA	: Melez Pi-Sigma yapay sinir ağı
IEX	: İstanbul Menkul Kıymetler Borsası
I-FRF	: Sezgisel bulanık regresyon fonksiyonları yaklaşımı
IFTS	: Sezgisel bulanık zaman serisi
I-TSFIS	: Sezgisel zaman serisi bulanık çıkarım sistemi
MANFIS	: Modifiye uyarlanabilir nöro-bulanık çıkarım sistemi
MLP	: Çok katmanlı algılayıcı
PSO	: Parçacık sürü optimizasyonu
MPSO	: Modife edilmiş parçacık sürü optimizasyonu
SBZS	: Sezgisel bulanık zaman serisi
SMNM	: Tek çarpımsal nöron modeli
TAIEX	: Tayvan Menkul Kıymetler Borsası

ŞEKİLLER LİSTESİ

Şekil 2.1. μA , vA ve πA gösterimi	19
Şekil 2.2. İlk geometrik yorumlama.....	20
Şekil 2.3. İlk geometrik yorumlamanın modife edilmiş göreseli.....	20
Şekil 2.4. İkinci geometrik yorumlama.....	21
Şekil 4.1. Biyolojik noron yapısı	35
Şekil 4.2. Çok tabakalı YSA mimarisi	38
Şekil 4.3. Pi-Sigma YSA mimarisi	41
Şekil 4.4. PSO'nun akış şeması	45
Şekil 5.1. Genel modelleme için tasarlanmış MPS-YSA yapısı	48
Şekil 5.2. SBZS tahmin modelinin grafiksel özeti.....	53
Şekil 6.1. 2000 yılı için dağılım grafiği	62
Şekil 6.2. 2001 yılı için dağılım grafiği	62
Şekil 6.3. 2002 yılı için dağılım grafiği	62
Şekil 6.4. 2003 yılı için dağılım grafiği	62
Şekil 6.5. 2004 yılı için dağılım grafiği	62
Şekil 6.6. Zaman serisi 6 için uyum grafiği	65
Şekil 6.7. Zaman serisi 7 için uyum grafiği	65
Şekil 6.8. Zaman serisi 8 için uyum grafiği	65
Şekil 6.9. Zaman serisi 9 için uyum grafiği	65
Şekil 6.10. Zaman serisi 10 için uyum grafiği	65
Şekil 6.11. Zaman serisi 11 için uyum grafiği	65
Şekil 6.12. Zaman serisi 12 için uyum grafiği	66
Şekil 6.13. Zaman serisi 13 için uyum grafiği	66
Şekil 6.14. Zaman serisi 14 için uyum grafiği	66
Şekil 6.15. Zaman serisi 15 için uyum grafiği	66

TABLÖLER LİSTESİ

Tablo 5.1. Optimizasyon sürecinin özellikleri	51
Tablo 6.1. Veri organizasyonunun özellikleri.....	56
Tablo 6.2. Uygulamaların özellikleri	59
Tablo 6.3. TAIEX için modellerin tahmin performansları	60
Tablo 6.4. Doğrusal bir regresyon modelinin özellikleri	61
Tablo 6.5. Sonuçların IEX veri setleri için RMSE açısından değerlendirilmesi	64



SEZGİSEL BULANIK KÜMELERİN BİLEŞENLERİNİN KOMBİNASYONUNA DAYALI ZAMAN SERİSİ ÖNGÖRÜ MODELİ

ÖZET

Zaman serilerinin tahmini, günlük hayatımızda hem teorik hem de pratik olarak önemli bir etkiye sahiptir. Sezgisel bulanık zaman serisi modelleri, bulanık zaman serisi modellerinden farklı olarak, gözlemlerin tereddüt derecesini hesaba katar ve tahmin sisteminde girdi olarak üyelik ve üyelik dışı değerleri birlikte kullanır. Tahmin sisteminde üyelik ve üye olmama etkilerini ortaya koyabilmek için üyelik ve üyelik dışı değerlerin tahmin modelinde ayrı girdiler olarak ele alınması gerekmektedir. Ayrıca bu ayrı modelleri birleştirerek sistemin çıktıları almak hem daha doğru tahminler hem de esnek bir yaklaşım sağlayacaktır. Bu tez kapsamında, sezgisel bir bulanık zaman serisi tahmin modeli (SBZS-TM) önerilmiştir. Ayrıca lineer olmayan ilişkilerin belirlenmesi için literatürde ilk kez yeni bir melez Pi-Sigma sinir ağı (MPS-YSA) kullanılmıştır. Yeni önerilen MPS-YSA, girdilerin doğrusal fonksiyonlarını eşit olmayan ağırlıklarla çarpar ve bunları doğrusal olmayan ilişkilere dönüştürür. İki farklı MPS-YSA, üyelikleri ve üyelik dışı katkıları ayrı ayrı dikkate alarak tahminler üretir. Ve bu çıktıların birleştirilmesiyle nihai çıktılar elde edilir. Hem MPS-YSA'lerin optimal ağırlıklarını hem de kombinasyon ağırlıklarını elde edebilmek için modifiye parçacık sürü optimizasyonu kullanılmıştır. Ve, bulanık kümeler, üyelik ve üyelik dışı değerleri elde etmek için sezgisel bulanık C-ortalamlar kullanılmıştır. Önerilen modellerin performansını değerlendirebilmek için TAIEX ve IEX zaman serilerine ait 15 farklı uygulama gerçekleştirilmiştir. Sonuçlar, önerilen modelin diğer bazı tahmin araçlarına kıyasla farklı hata kriterleri açısından daha üstün tahminlere sahip olduğunu göstermiştir.

Anahtar kelimeler: Sezgisel bulanık zaman serisi; hybrid Pi-Sigma sinir ağı; tahmin ve kombinasyonu; modifiye edilmiş parçacık sürü optimizasyonu

A NEW TIME SERIES FORECASTING MODEL BASED ON THE COMBINATION OF INTUITIONISTIC FUZZY SETS COMPONENTS

SUMMARY

The forecasting of time series has a significant impact in our daily life, both theoretically and practically. Intuitionistic fuzzy time series models, unlike fuzzy time series models, take into account the degree of hesitation of the observations, and they use memberships and non-membership values together as inputs in the forecasting system. To be able to reveal the membership and non-membership effects in the forecasting system, the membership and non-membership values need to be considered as separate inputs in the forecasting model. Moreover getting the outputs of the system by combining these separate models will provide both more accurate forecasts and a flexible approach. In the scope of this thesis, an intuitionistic fuzzy time series forecasting model (IFTS-PM) is proposed. Also for the determination of non-linear relations part a new hybrid sigma-pi neural network (HSP-NN) is used for the first time in the literature. Newly proposed HSP-NN multiples linear functions of inputs by unequal weights and converts them to nonlinear relationships. Two different HSP-NNs generate forecasts by considering the memberships and non-membership contributions separately. And final outputs are obtained by combining these outputs. To be able to obtain both optimal weights of HSP-NN s and combination weights modified particle swarm optimization is utilized. And, intuitionistic fuzzy C-means is performed to get fuzzy clusters, membership, and non-membership values. 15 implementations belong to TAIEX and IEX time series have been carried out in order to present the proposed models' performance. The results showed that the proposed model has superior forecasts compared to some other state-of-the-art forecasting tools in terms of different error criteria.

Keywords: Intuitionistic fuzzy time series; hybrid sigma-pi neural network; prediction combination; modified particle swarm optimization

BÖLÜM 1. GİRİŞ

Gelecekteki bir olay için karar verme sürecinde geçmiş ve günümüzdeki bilgileri kullanarak bir tahmin ya da öngöründe bulunmamız kaçınılmazdır. Çünkü geçmişin verdiği tecrübeler gelecekteki kararımızda bize kar – zarar ilişkisi konusunda fayda sağlamaktadır. Karar verici kim olursa olsun geleceği tahmin ederken belirsizlik yerine tutarlı ve geçerli kararlar almayı tercih etmektedir. Günlük yaşantımızdaki tercihlerimiz de bu yöndedir. Örneğin, işe gitmek için vapur kullanan bir kişi sabahları vapurun kalkış zamanına göre iskeleye hangi zaman aralığında gitmesi gerektiğini bilmesi ve yine aynı şekilde işten dönerken de akşam vapurunun kalkış saatine göre iskeleye varması, kişinin daha önce tecrübe ettiği bilgilere dayanmaktadır. Geçmiş ve günümüzdeki bilgileri kullanarak yaptığımız tahmin ya da öngörüler, geçmiş ile geleceğin ilişkili olduğu varsayımı ile yapılmaktadır. Tahmin ya da öngörü yapma sürecinde temel amaç, gerçekleşmesi beklenen olayın en az hatayla ya da mümkünse hatasız olarak tahmin edilmesidir.

Hem özel hem de kamu sektöründe hemen her alanda, geleceğe yönelik doğru ve etkin strateji ve politikalar oluşturulmasında öngörü oldukça önemlidir. Günümüzde tüm sektörler geleceğe yönelik stratejilerini ve politikalarını belirlemede kendi ihtiyaçlarına ve gelişmelerine göre rasyonel kararlar almayı hedeflemektedir. Hedeflenen rasyonel kararlar doğrultusunda karar verici belirsiz olan gelecek için ortaya konan öngörülerin en iyi şekilde tutarlı ve geçerli olmasını beklemektedir. Tüm sektörlerde ileriye yönelik ne olacağı, seçilen strateji ve politikaların ne gibi sonuçlar doğuracağı vb. gibi soruların cevapları için tahmin ve öngörülerin elde edilmesinde istatistiksel yöntemler kullanılmaktadır. Bu istatistiksel yöntemlerden en çok tercih edilenlerinden biri zaman serisi analizi yöntemleridir.

Zaman serisi analizi, zaman faktörünü dikkate alarak meydana gelen olayların ölçülmesi sonucu elde edilen serilerin incelenmesi olarak ifade edilebilir. Kronolojik sırayla gözlemlenen verilere uygun bir model bulmak ve bu verilerin gelecekte hangi değerleri alabileceği ya da ilgili zaman serisi ile farklı zaman serileri arasındaki

ilişkileri istatistiksel olarak incelemek ve/veya ortaya koymak zaman serisi analizinin amaçları arasında yer almaktadır. Zaman serisi analizi geçmişten günümüze pek çok alanda sıklıkla kullanılmaktadır. Finans, sağlık, çevre, enerji, tarım, endüstri gibi kullanım alanlarına sahip olmak, zaman serileri analizlerini çekici kılmaktadır.

Klasik zaman serileri analizi yöntemlerinin avantajları olduğu gibi çeşitli bazı katı varsayımlar içeren dezavantajları da bulunmaktadır. Olasılıksal yöntemler olarak da adlandırılabilir bu yöntemlerde model seçimi, modele değişken seçimi, gözlem sayısı, durağanlık, tersinirlik gibi bazı katı varsayımlar sebebiyle oluşabilecek dezavantajları ortadan kaldırmak amacıyla alternatif olarak olasılıksal olmayan modeller ortaya konmuştur. Son yıllarda geniş bir kullanım alanına sahip olan olasılıksal olmayan modeller, katı varsayımlara gereksinim duymadıkları için neredeyse bütün zaman serilerinin analizine kolaylıkla uygulanabilmektedir. Olasılıksal olmayan zaman serisi analiz yöntemleri, temel olarak hesaplamalı ve bulanık-tabanlı modeller olmak üzere iki ana grupta ele alınabilir. Hesaplamalı modeller farklı yapay sinir ağlarını içerirken, bulanık-tabanlı modeller bulanık zaman serisi yöntemleri, bulanık fonksiyon yaklaşımı, bulanık çıkarım sistemleri gibi farklı modellerden oluşur.

Bu tez kapsamında bulanık-tabanlı bir olasılıksal olmayan model olarak yeni bir bulanık zaman serisi öngörü modeli önerilmiştir. Modelin temelini oluşturan bulanıklık (fuzzy) kavramı, farklı şekillerde ortaya çıkan karmaşık ve belirsiz ya da tam ve kesin olmayan bilgi olarak ifade edilebilir. Bulanıklık kavramı ilk olarak Zadeh (1965) tarafından ortaya atılan bulanık küme teorisiyle literatüre kazandırılmıştır. Bulanık küme teorisi basitçe, sözel veya dilsel verilerin matematiksel modeller olarak tanımlanmasıdır. Bulanık küme teorisinde, klasik kümelerin aksine, elemanların ilgili kümeye ait olup olmamasını temsil eden $\{0, 1\}$ değerleri yerine dereceli bir aitlik söz konusudur ve bu aitlik derecesi $[0, 1]$ aralığında değerlerle temsil edilir. Bulanık kümeler keskin ifadelerin yerine belirsizlik içeren verileri de içinde barındırması nedeniyle günlük problemlerin çözümünde daha iyi çözümleme imkânı sağlamaktadır.

Bulanık zaman serisi yöntemleri, klasik zaman serileri katı varsayımları içermemesi ve ilgilenilen serinin içerisindeki belirsizliği dikkate almasından dolayı son yıllardaki yeni araştırmaların dikkat çekici konularından biri olmuştur. Gerçek hayatta birçok zaman serisinin çözümlenmesinde klasik zaman serisi yöntemlerine göre daha doğru gerçekçi sonuçlar vermesi ve verinin içerdiği belirsizliği de dikkate alarak işlem yapması, bulanık zaman serisi analizlerini günümüzde daha popüler kılmaktadır. Bulanık zaman serisi yöntemleri de bilişim teknolojileri, veri madenciliği, ekonomi, hidroloji, çevre bilimi, mühendislik gibi birçok farklı alanlarda yaygın olarak kullanılmaktadır.

Bulanık zaman serisi kavramı literatürde ilk olarak Song ve Chissom (1993a) tarafından yapılan çalışmada ileri sürülmüştür. Bulanık zaman serileri Zadeh (1965) tarafından ortaya atılan bulanık küme teorisine dayandırılarak ortaya konulmuştur. Song ve Chissom (1993a) temel olarak bulanık zaman serilerini, zamanla değişen ve zamanla değişmez bulanık zaman serileri olarak iki kısımda incelemiştir. Zamanla değişen bulanık zaman serilerinde ilgili zaman serisi ile gözlemlerin birbiri arasındaki ilişkinin belirli bir süre devam ettikten sonra değiştiği, zamanla değişmeyen bulanık zaman serilerinde ise aralarındaki ilişkinin zamana bağlı olarak değişmediği varsayılmaktadır. Her ikisi de kullanılmasına rağmen zamanla değişen bulanık zaman serileri literatürde daha yaygın olarak kullanılmaktadır.

Bulanık zaman serisi analizi; gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve berraklaştırma (durulaştırma) aşamaları olmak üzere üç aşamadan oluşan bir süreçtir. Bu yöntemlerin ilk aşaması olan bulanıklaştırma aşamasında gözlemleri reel olan ilgili zaman serisini, birçok farklı yöntemden birini kullanarak gözlemleri bulanık olan bulanık zaman serisine dönüştürme işlemi gerçekleştirilir. İkinci aşama bulanık ilişkilerin belirlenmesi aşamasıdır. Bulanıklaştırma aşamasından elde ettiğimiz bulanık zaman serilerinin gözlemleri arasındaki ilişkinin modellendiği aşamadır. Bulanık zaman serisi analizinin son aşaması olan durulaştırma aşaması ise bulanık gözlemlerin reel veriye dönüştürülerek sonucun elde edildiği aşamadır.

İlgili literatür incelendiğinde bulanık zaman serisi analizi yöntemlerinin zaman içerisinde gerek kullanılan yaklaşımlar gerekse de önerilen modeller olmak üzere birçok farklı şekillerde ele alındıkları görülmektedir. Bulanık zaman serisi analizinin üç aşaması da aşağıda ayrı ayrı incelenmiş ve geçmişten günümüze kadar olan sürede gerçekleşen ilerleme ve gelişim gözlemlenmiştir.

İlk adım olan bulanıklaştırmada, evrensel küme parçalanması sıklıkla kullanılan yöntemlerden biridir. Evrensel küme parçalanmasında ihtiyaç duyulan aralık uzunluğu, yöntemlerin tahmin performanslarını etkilemektedir. Bu yüzden aralık uzunluğunun belirlenmesi ile ilgili literatürde çok sayıda çalışma bulunmaktadır. İlk olarak Song ve Chissom (1993a, 1993b, 1994) ve Chen (1996, 2002) çalışmalarında aralık uzunluklarını sabit ve sübjektif olarak belirlemişlerdir. Huarng (2001) sübjektif olarak belirlenen aralık uzunlukları yerine ortalamaya ve dağılıma dayalı bir yöntem önermiştir. Birinci ve yüksek dereceden bulanık zaman serileri için Eğrioğlu ve ark. (2010, 2011a) tarafından yapılan çalışmalarda aralık uzunlukları optimizasyona dayalı bir yaklaşım ile belirlenmiştir. Bu çalışmalardan farklı olarak trend içeren zaman serilerinin analizinde Huarng ve Yu (2006a), değişen aralık uzunluğunun tahmin performansını iyileştirebileceği görüşü açısından dinamik aralıkları belirlemede orana dayalı model kullanan yöntemi geliştirmişlerdir. Yolcu ve ark. (2009) ise Huarng ve Yu (2006a) tarafından ortaya atılan fikri iyileştirmek üzere oranın optimizasyonuna dayalı yeni bir model önermişlerdir. Panigrahi ve Behera (2020) motive edilmiş ortalama tabanlı bir model geliştirmişlerdir. Bulanıklaştırma aşamasında sezgisel algoritmaları kullanan farklı çalışmalar da mevcuttur. Genetik algoritmayı Cheng ve Chung (2006), Lee ve ark. (2007, 2008) çalışmalarında kullanmışlardır. Kuo ve ark. (2009, 2010), Davari ve ark. (2009), Park ve ark. (2010), Hsu ve ark. (2010), Aladağ (2013), Çağcağ Yolcu ve Lam (2017) çalışmalarında parçacık sürü optimizasyon algoritmasını tercih etmişlerdir. Yolcu ve ark. (2014) yapay arı kolonisi, Cai ve ark. (2015) karınca kolonisi, Jiang ve ark. (2017) ise armoni arama algoritmasından yararlanmışlardır. Diğer yandan öznel yargılardan kaçınan, evrensel kümenin parçalanmasına gerek duymayan bir yöntem olan bulanık C- ortalamalar yöntemini Cheng ve ark. (2008), Li ve ark. (2008), Yolcu ve ark. (2011), Aladağ ve ark. (2012), Alpaslan ve ark. (2012), Eğrioğlu (2013), Eğrioğlu ve

ark. (2013), Wei ve ark. (2014), Cheng ve ark. (2015), Sun ve ark. (2015), Wang ve Liu (2015), Çağcağ Yolcu ve Alpaslan (2018) çalışmalarında kullanmışlardır. Bu çalışmalara ek olarak Gustafson-Kessel bulanık kümeleme yaklaşımını Eğrioğlu ve ark. (2011b), otomatik kümeleme yöntemini Wang ve Chen (2009), Chen ve Tanuwijaya (2011), Wang ve Liu (2015), bulanık kümeleme yöntemini Askari ve ark. (2015) ve Askari ve Montazerin (2015), K-ortalımalı kümeleme yaklaşımını Cheng ve ark. (2015), sağlam kümeleme yöntemini Akkuş (2018), aksiyomatik bulanık küme teorisini Guo ve ark. (2018) çalışmalarında kullanmışlardır.

İkinci adım olan bulanık ilişkilerin belirlenmesi aşaması, modelin tahmin performansını önemli derecede etkileyen aşamadır. Literatürde bulanık zaman serisi ilişkilerinin belirlendiği ve bu belirlenen ilişkiler ile modelin tahmininde oldukça etkili olan bulanık ilişkilerin belirlenmesi aşaması için farklı yaklaşımlar önerilmiştir. Bulanık ilişkileri Song ve Chissom (1993a, 1993b, 1994) çalışmalarında matris işlemleriyle belirlemiştir. Sullivan ve Woodall (1994) tarafından yapılan çalışmada ise karmaşık matris işlemleri yerine Markov zincirinden oluşan geçiş matrisleri kullanılmıştır. Öte yandan Chen (1996), yapılan matris işlemlerini daha kolaylaştırmak için bulanık ilişki tablolarına dayanan yeni bir model ortaya atmıştır. Bulanık mantık ilişkisi ve grup ilişki tablolarını içeren yaklaşımlar, bulanık ilişkilerin belirlenmesinde oldukça sık kullanılmış ve bu ilişkilere dayanan yeni modeller önerilmiştir. Chen (1996) bulanık ilişki tablolarını birinci dereceden bulanık zaman serilerine uygularken, Chen (2002) yaptığı çalışmada yüksek dereceli bulanık zaman serilerine ait yeni bir modele uygulamıştır. Literatürde Chen (1996, 2002)'nin yaklaşımlarına benzer şekilde Chen ve Chen (2011), Chen ve Tanuwijaya (2013), Koçak (2013), Cheng ve ark. (2016), Koçak (2017) bulanık ilişki tablolarına dayanan yeni modeller ortaya atmışlardır. Gerek bulanık ilişki tablolarının oluşmasında işlem kalabalıklığı olması nedeniyle gerekse de sahip olduğu avantajlar nedeniyle son yıllarda yapay sinir ağlarını kullanan çok sayıda çalışma dikkat çekmektedir. Huarng ve Yu (2006b) bulanık ilişkinin tanımlanmasında ileri beslemeli yapay sinir ağlarının kullanıldığı birinci dereceden bir bulanık zaman serisi tahmin yöntemi önermiştir. Aladağ ve ark. (2009), Huarng ve Yu (2006b)'nin çalışmasını geliştirerek ileri beslemeli yapay sinir ağlarının kullanıldığı yeni bir yüksek dereceli bulanık zaman

serisi tahmin yöntemini ortaya koymuşlardır. Ayrıca Yu ve Huarng (2008, 2010), Eğrioğlu ve ark. (2009a, 2009b, 2009c, 2014), Aladağ ve ark. (2010), Wei ve ark. (2014), Wang ve Xiong (2014), Eğrioğlu (2014), Chen ve Chen (2015), Lee ve Hong (2015), Chen ve Chen (2015) çalışmalarında ileri beslemeli yapay sinir ağı modeli kullanılmıştır. Aladağ ve ark. (2013) tek çarpımsal nöron modeli yapay sinir ağına dayanan bir bulanık zaman serisi tahmin yöntemi önermiştir. Öte yandan Çağcağ Yolcu (2013) çalışmasında, bulanık ilişkileri PSO ile eğitilmiş tek çarpımsal nöron model YSA ile belirlemiştir. Ayrıca Yu ve Huarng (2008, 2010), Alpaslan ve Çağcağ (2012), Alpaslan ve ark. (2012) ve Yolcu ve ark. (2013) çalışmalarında üyelik derecelerini dikkate alan öngörü modelleri fikirlerini ileri sürmüşlerdir. Baş ve ark. (2017) çalışmalarında zaman serisine ilişkin hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilmek adına bir bulanık zaman serisi yöntemi geliştirmiştir. Baş ve ark. (2018), Pi-Sigma sinir ağına dayanan yüksek dereceli bir bulanık zaman serisi yöntemi önermişlerdir.

Bulanık zaman serisi analizinin son aşaması olan durulaştırma aşaması bulanık gözlemlerin reel veriye dönüştürülmesi işlemini içerir. Literatürde birçok araştırmacı merkezileştirme yöntemini oldukça sık kullanmaktadır. Chen (1996), Huarng (2001), Huarng ve Yu (2006) çalışmalarında merkezileştirme yöntemini tercih etmişlerdir. Bu aşamada da yapay sinir ağlarını kullanan çalışmalar mevcuttur. Song ve Chissom (1994) YSA modelini kullanmıştır. Diğer yandan Cheng ve ark. (2006), Alpaslan ve ark. (2012) çalışmalarında uyumlu (adaptif) beklenti yöntemini kullanmayı tercih etmişlerdir. Yolcu ve ark. (2013) tüm üyelik değerlerini dikkate alan bir yaklaşım önermişlerdir. Bu çalışmalara ek olarak Jilani ve Burney (2008), Jilani ve ark. (2007) durulaştırma aşaması için farklı yöntemler ileri sürmüşlerdir.

Son zamanlarda bulanık zaman serisi analizini oluşturan üç aşamayı ardışık bir yapıda çözümlemek yerine eş zamanlı olarak ele alan çalışmalara da rastlamak mümkündür. Çağcağ Yolcu ve Alpaslan (2018) tarafından yapılan çalışmada üç aşamayı tek bir süreçte eş zamanlı olarak değerlendirme yapabilen bir model önerilmiştir. Chen ve Hsu (2004), hisse senedi fiyatlarını düşürmek için tanecikli (granular) hesaplamaya dayalı bir melez bulanık zaman serisi modeli ortaya atmıştır.

Chen (2009) çalışmasında TAİEX zaman serilerinin analizi için hem benzerlik ölçümlerini hem de PSO'yu kullanan yeni bir bulanık tahmin modelini tercih etmiştir. Koçak (2017), stok verilerinin öngörülmesinde ARMA-tipi bulanık mantık ilişkileri kullanan bir FTS modeli önermiştir.

Bulanık zaman serisi modelleri geniş bir literatüre sahip olsa da halen çözülmesi gereken bazı problemler de bulunmaktadır. Temel aldıkları bulanık teori değerlendirildiğinde, bulanık kümelerin belirsizliği modellerken veri yapısında belirsizliğin bir başka boyutu olarak görülebilecek tereddüt derecesini dikkate almadığı ve böylece belirsizliği tam olarak tahmin edemediği ve/veya yorumlayamadığı söylenebilir. Literatürde mevcut bulanık zaman serisi modellerinde sadece üyelik değerleri dikkate alınmaktadır. Oysaki bulanık zaman serilerinin çözümünde her zaman üyelik değerleri yeterli olmamaktadır. Gerçek hayatta insanların çoğu tek bir sayısal değeri saptamakta ve/veya belirlemekte tereddüt etmektedirler. Çünkü tek bir değeri belirlemek için güçlü kanıtlar ile birlikte kesin ve eksiksiz verilerin elde bulunması gerekmektedir. Bulanık zaman serisi modelleri, analiz sürecinde, hem üye olmama değerlerinden gelen bilgileri hem de tereddüt derecesinin hesaba katılmamasından dolayı olumsuz etkilenmektedir.

Genellikle çevresel, iş, psikolojik davranış gibi bazı faktörlerden etkilenip karar alma aşamasında tereddüt yaşamak hayatın doğal akışı içerisinde yer almaktadır. Ne klasik zaman serisi modelleri ne de bulanık zaman serisi modelleri tereddütlük ile başa çıkamamıştır. Atanassov (1983, 1986, 1999) çalışmalarında üyelik derecelerinin yanı sıra üye olmama (non-membership) derecelerini ve tereddüt derecesini (hesitancy degree) hesaba katan yeni bir sezgisel yöntem önermiştir.

Atanassov'un Sezgisel Bulanık Küme teorisi, Zadeh (1965) tarafından ortaya atılan Bulanık Küme teorisinin genişletilmiş bir halidir. Bulanık Küme'de kümeye ait elemanların üyelik dereceleri $[0, 1]$ aralığında yer almaktadır. Bu şart altında bir kümeye ait elemanın üye olmama derecesi, birden üyelik derecesini çıkartarak elde edilebilmektedir. Yani Bulanık Küme teorisinde, üye olma ve üye olmama derecesinin toplamı bire eşit olmaktadır. Sezgisel Bulanık Küme teorisinde ise üye

olma ve üye olmama derecelerinin her ikisi de $[0, 1]$ aralığında yer almaktadır. Ancak toplamlarının bire eşit olması zorunlu değildir hatta birden daha azda olabilmektedir. Atanassov çalışmasında belirsizliğin bir diğer boyutu olan tereddüt derecesini de dikkate almıştır. Bir konu hakkındaki bilgi eksikliği ve/veya karar veren kişinin kararsızlığı olarak da ifade edilen tereddüt derecesi, üye olma ve üye olmama derecelerinin toplamının birden çıkarılmasıyla elde edilmektedir.

Sezgisel bulanık zaman serileri, bulanık zaman serilerinin genişletilmiş şeklini içermektedir. Ayrıca, bulanık zaman serisi modelleri de analiz sürecinde sadece üyelik değerlerini kullanmasına rağmen, sezgisel bulanık zaman serileri hem üye olma derecelerini hem de üye olmama derecelerini kullanmaktadır. Bu nedenle sezgisel bulanık zaman serisi modelleri, bulanık zaman serisi modellerine göre daha fazla bilgi kullanımını sağlayarak daha avantajlıdır. Bu tez kapsamında önerilen yöntemde de daha fazla bilginin kullanılması nedeniyle öngörü performansının artacağı ve modelin gerçek problemlere daha uyumlu olacağı düşünülmektedir.

Sezgisel bulanık zaman serileri, bulanık zaman serilerinden esinlenerek ve sezgisel bulanık kümelerle dayalı olarak önerilmiştir. Zheng ve ark. (2013a) tarafından yapılan çalışmada sezgisel bulanık zaman serilerinin temel tanımları ve ilk sezgisel bulanık zaman serisi tahmin modeli literatürde yer almıştır. Ayrıca Zheng ve ark. (2013b), sezgisel bulanık zaman serisi analizinin bulanıklaştırma aşamasında üye ve üye olmama değerlerini belirlemek için Chaira (2011) tarafından geliştirilen sezgisel bulanık C ortalamalar algoritmasını kullanmayı tercih etmişlerdir. Zheng ve ark. (2014a) parametre uyarlamasına, Zheng ve ark. (2014b) vektör nicelemesine ve Fan ve ark. (2020) trafik ağı öngörüsüne dayanan üç farklı uzun vadeli sezgisel bulanık zaman serisi (SBZS) modellerini önermişlerdir. Wang ve ark. (2016) çalışmalarında Alabama Üniversitesi ve TAIEX verilerini öngörmek amacıyla sezgisel bulanık akıl yürütmeye dayanan SBZS öngörü modelini sunmuşlardır. Eğrioğlu ve ark. (2019), sezgisel zaman serisi bulanık çıkarım sistemlerini önermişlerdir. Bu yöntemde girdi ve çıktılar arasındaki doğrusal olmayan ilişki Pi-Sigma yapay sinir ağıyla belirlenirken üyelik değerlerini elde etmek için sezgisel bulanık C-ortalamalar algoritmasından yararlanılmıştır. Kızılaslan ve ark. (2019) çalışmasında çoklu

doğrusallığı ortadan kaldırabilmek için sezgisel bulanık ridge regresyon fonksiyonlarına dayanan bir yöntem önermiştir. Üye olma ve üye olmama dereceleri sezgisel bulanık C-ortalamar yöntemiyle belirlenmiştir. Çağcağ Yolcu ve ark. (2019) tarafından yapılan çalışmada tereddüt marjına (derecesine) dayalı sezgisel bulanık regresyon fonksiyonu ileri sürülmüştür. Bu modelde de sezgisel bulanık C-ortalamar yöntemiyle üye olma ve üye olmama dereceleri belirlenmiştir. Girdi olarak zaman serisinin reel gözlemlerine ek üye olmama değerleri ve üye olma değerleri, iki farklı girdi olarak kullanılmıştır. Sistemin nihai çıktıları bulanık regresyon fonksiyonlarının tereddüt derecesi aracılığıyla kombine edilmesiyle elde edilmiştir. Eğrioğlu ve ark. (2020), resim bulanık kümelemeye dayalı resim bulanık regresyon fonksiyonları yöntemini önermişlerdir.

Literatürde sınırlı olarak çalışılan sezgisel bulanık küme tabanlı öngörü modellerinin temel özelliği, girdiler ve çıktılar arasındaki ilişkilerin bulanık kurallar, bulanık fonksiyonlar ve/veya Pi-Sigma yapay sinir ağı aracılığıyla belirlenmesidir. Sezgisel bulanık küme tabanlı öngörü modelleri, tarafsızlık/tereddüt bilgisini dikkate alarak belirsizliği açıklamada etkili bir yöntem olmuştur. Ancak yapılan çalışmalarda üyelik değerleri ve üye olmama değerleri, tahmin sisteminde aynı katkıyı sağlıyormuş gibi birlikte değerlendirilmektedir. Bu bağlamda öngörü modellerinde, üye ve üye olmama değerlerinin ayrı ayrı girdi olarak kullanılması ve ayrı ayrı kullanılan bu girdilerin çıktıların birleştirilmesi daha esnek bir yaklaşım oluşturma imkânı verecektir. Böylece daha yüksek bir öngörü performansı elde edilecektir.

Literatürdeki çalışmalarda öngörü aracı olarak kullanılan Pi-Sigma yapay sinir ağı, girdilerin doğrusal fonksiyonlarını (eşit ağırlıklarla) çarparak onları doğrusal olmayan ilişkilere dönüştürmektedir. Ancak girdilerin doğrusal fonksiyonları, doğrusal olmayan ilişkilerin belirlenmesinde farklı düzeylerde katkılara sahip olabilir. Bu durumun hesaba katılmaması tahmin performansını olumsuz yönde etkileyecektir. Bu bağlamda çarpma işlemindeki her bir elemanın farklı ağırlıklara sahip olabileceği gerçeği göz ardı edilmemelidir. Böylelikle verinin doğrusal olmayan kısmının modele uyum sağlaması daha da kolaylaşır. Ayrıca modelin doğrusal olmayan yüzeye yüksek adaptasyonu da tahmin performansını artıracaktır.

Bu tez kapsamında, geleneksel Pi-Sigma yapay sinir ağı yerine, sezgisel bulanık ilişkileri belirlemek için melez bir Pi-Sigma sinir ağı önerilmiştir. Genel olarak bulanık ilişkileri belirlemek için kullanılan geleneksel çok katmanlı algılayıcı (Multi-layer Perceptron- MLP), toplamsal bir birleştirme fonksiyonu kullanmaktadır. Bunlara ek olarak, Yadav (2007) tarafından sunulan tek çarpımsal nöron modeli (Single Multiplicative Neuron Model- SMNM), bulanık ilişkileri belirlemede çarpımsal bir birleştirme fonksiyonundan yararlanır. Önerilen melez Pi-Sigma, her iki birleştirme fonksiyonunu da kullandığı için MLP ve SMNM'yi birleştiren bir melez model olarak adlandırılabilir.

Genel bir bakış açısıyla bakıldığında, bu tez kapsamında ortaya konan öngörü modeli aşağıdaki özelliklere sahiptir:

- SBZS-TM, öngörü sürecinde öngörüler üzerinde farklı etkilere sahip olan üye ve üye olmama değerlerini ayrı ayrı dikkate almaktadır.
- Bu etkileri modellemek için MPS-YSA literatürde ilk kez önerilmiştir.
- Önerilen MPS-YSA, girdilerin doğrusal fonksiyonlarını eşit olmayan ağırlıklarla çarpma ve bunları doğrusal olmayan ilişkilere dönüştürme yeteneğine sahiptir.
- Üyelik değerleri, bir MPS-YSA de gerçek gözlemlerin gecikmeli değişkenleri ile girdi olarak kullanılır. Ayrıca üye olmama değerleri, diğer bir MPS-YSA'daki gerçek gözlemlerin gecikmeli değişkenleri ile girdi olarak kullanılır. Her iki YSA de üyelik değerlerinin ve üye olmama değerlerinin etkilerini içeren öngörüler üretir. Üretilen bu iki öngörü, üye ve üye olmama durumlarının farklı etkileri dikkate alınarak belirlenen ağırlıklarla birleştirilir. Böylece nihai öngörüler üretilir.
- Zaman serisi gözlemlerinin üye ve üye olmama değerleri sezgisel bulanık C-ortalamlar bulanık kümeleme tekniği ile elde edilir.
- MPS-YSA'ların optimum ağırlıklarının yanı sıra kombinasyon ağırlıklarının da elde edilmesi modife edilmiş parçacık sürü optimizasyonu (MPSO) ile gerçekleştirilir.

Önerilen SBZS-ÖM'nin öngörü performansını ortaya çıkarmak için, Tayvan Menkul Kıymetler Borsası Kapitalizasyon Ağırlıklı Stok Endeksi (TAIEX - Taiwan Stock Exchange Capitalization Weighted Stock Index) ve İstanbul Menkul Kıymetler Borsası (IEX) veri setleri kapsamlı bir şekilde analiz edilmiştir. Elde edilen sonuçlar, literatürdeki önemli bazı öngörü yöntemleri ile farklı hata kriterlerinin göz önüne alınmasıyla ve doğrusal regresyon analizinin temel özellikleri ile grafikler kullanılarak karşılaştırmalı olarak değerlendirilmiştir.

Tez sekiz bölümden oluşmaktadır. Çalışmanın ikinci bölümünde, bulanık küme kuramı ile ilgili temel kavramlar verilmektedir. Bu bölümde bulanık küme ve sezgisel bulanık küme alt başlık olarak ayrıntılı bir şekilde açıklanmaktadır. Çalışmanın üçüncü bölümünde, bulanık zaman serileri ve temel kavramlar verilmektedir. Burada bulanık zaman serileri ile sezgisel bulanık zaman serilerinin tanımları ve bu serilere ait özellikler incelenmektedir. Ayrıca bu bölümde bulanık C-ortalamlar ve sezgisel bulanık C-ortalamlara yer verilmiştir. Çalışmanın dördüncü bölümünde, Pi-Sigma yapay sinir ağı ve yapay sinir ağlarının eğitiminde kullanılan PSO yöntemi ile ilgili bilgi sunulmuştur. Çalışmanın beşinci bölümünde, tezde önerilmiş olan melez Pi-Sigma sinir ağı modeli ile yeni bir sezgisel bulanık zaman serisi öngörü modeli tanıtılmış ve her iki önerilen yöntemin algoritması verilmiştir. Çalışmanın altıncı bölümünde, uygulama ana başlığı altında, önerilen yöntemin farklı zaman serilerine uygulanmasından elde edilen sonuçlar detaylı bir şekilde incelenmiştir. Çalışmanın yedinci bölümünde ise elde edilen sonuçlar değerlendirilmiş ve bununla beraber gelecekte yapılabilecek çalışmalar üzerine önerilerde bulunulmuştur.

BÖLÜM 2. BULANIK KÜME KURAMI

Tezin bu bölümünde, bulanık küme ve sezgisel bulanık küme kavramlarının tanımları ile bu kümelere ait bazı özelliklere yer verilmiştir.

Bulanık küme ve bulanık kümenin genişletilmiş hali olan sezgisel bulanık küme kavramlarını tanımlayabilmemiz için klasik küme kavramını bilmemiz gerekmektedir. Genel haliyle küme kavramı, iyi bilinen nesneler topluluğuna ve/veya sınıfına denilmektedir. Bu nesneler topluluğunun içinde bulunan her bir öğeye, üye ya da kümenin elemanı adı verilmektedir. En geniş küme evrensel kümedir. Üzerinde çalıştığımız her bir küme ise evrensel kümenin alt kümeleridir. Klasik bir kümenin elemanları bulunduğu kümeye ya aittir ya ait değildir. Yani kümenin elemanları 0 ya da 1 ikili tanımlama ile belirlenmektedir. Kısacası küme elemanın üyelik değeri 1 ise o kümeye ait olduğunu, 0 ise kümeye ait olmadığını ifade etmektedir. Diğer bir değişle klasik kümelerde üyelik fonksiyonu $\mu(x) \rightarrow \{0,1\}$ şeklinde tanımlanmaktadır (Özkan, 2003; Çağcağ Yolcu, 2013).

Günlük yaşantımızdaki örnekler klasik küme kavramı kadar keskin bir sonuç yani ya var ya yok şeklinde değildir. Sınırları keskin olmayan daha esnek bir yapıya sahiptirler. Örneğin, bir suyun kaynama noktası 100 °C derecedir. Klasik kümelerde suyun 100 °C'nin altında olduğunda kaynamadığı, üstünde olduğunda ise kaynadığı anlamına gelmektedir. Oysaki 99 °C kaynama noktasına çok yakın bir değerdir. Burada suyun kesin olarak kaynamadığını ifade etmek yerine kaynama noktasına ulaşmaya çok yakın olduğunu ifade edebiliriz. Fakat klasik küme yaklaşımı bu duruma izin vermemektedir. Bu keskin sınırları ortadan kaldırmak için bulanık küme yaklaşımları kullanılmaktadır.

Bulanık küme teorisi klasik küme teorine karşı daha güçlü bir hale gelmektir. Nedeni ise bulanık kümeler adından yola çıkılacağı üzere sınırları belli olmayan, belirsizlik içeren üyelik değerlerini ele almaktadır. Klasik küme için verilen örnekte suyun

100 °C de kaynama noktasına yakınlık ve uzaklığına göre daha göreceli, daha esnek yapılar kullanılmaktadır.

Klasik kümede sözel ifadelere yer verilmezken bulanık küme teorisinde sözel ifadelerden yararlanılmaktadır. Bu durumda bir elemanın kümeye ikili tanımlama yerine kısmi üyelik değerleri ile kümeye ait olduğu tanımlanabilmektedir. Örnek ile açıklarsak; klasik kümede soğuk-sıcak yerine bulanık kümelerde çok soğuk - biraz soğuk - soğuk - biraz sıcak - sıcak - çok sıcak gibi daha esnek tanımlamalar kullanılmaktadır. Aslında günlük hayatımızda kullandığımız sözel ifadelere benzetilmeye çalışılmıştır.

Günlük hayatta aldığımız kararların temeline yakın bulunsa da bulanık kümeler, sadece üyelik değerlerini ele aldığı için bazı problemlerin üstesinden gelemediği ve zamanla yetersiz kaldığı durumlarla karşılaşmıştır. Her ne kadar bir karar alsak da içinde ve/veya karar alırken bir tereddüt yaşamamız kaçınılmazdır. Çünkü her zaman güçlü kanıtlar ile birlikte kesin ve eksiksiz veriler elde edilememektedir. Bu durum tereddüt derecesinin ne kadar önemli bir eleman olduğunun göstergesidir.

Ne klasik küme ne de bulanık küme tereddüt ile başa çıkamamıştır. Sezgisel bir yöntem olarak çalışmalarda üyelik derecelerinin yanı sıra üye olmama (non-membership) derecelerini ve tereddüt derecesini (hesitancy degree) hesaba katan yeni yöntem önerilmiştir. Sezgisel bulanık küme olarak adlandırılan bu kümeler bulanık küme teorisinin genişletilmiş bir halidir.

Klasik kümelerde üyelik değerleri $\{0,1\}$ değerlerini, bulanık kümelerde $[0,1]$ aralığındaki sonsuz değerleri, sezgisel bulanık kümeler ise üye olma ve üye olmama değerlerinin her ikisi de $[0,1]$ aralığında yer almaktadır. Bir konu hakkındaki bilgi eksikliği ve/veya karar veren kişinin kararsızlığı olarak da ifade edilen tereddüt derecesi de, üye olma ve üye olmama derecelerinin toplamının birden çıkarılmasıyla elde edilmektedir.

2.1. Bulanık Küme

1965 yılında Prof. Dr. Lotfi A. Zadeh tarafından ortaya konmuş olan “Fuzzy Sets” isimli eser ile ‘bulanık kümeler’ ilk kez literatür de yerini almıştır. Bulanık küme kavramı en basit haliyle sözel veya dilsel verilerin matematiksel modeller olarak ifade edilmesidir. Bulanık kümeler keskin ifadelerin yerine belirsizlik içeren verileri de ele almaktadır.

Bir bulanık küme, kümeye ait olma derecesi olarak ifade edilen üyelik dereceleri ile matematiksel olarak tanımlanmaktadır. Bir elemanın bulanık kümeye ait olma özelliklerine hangi derece benzer ve/veya uygun olduğunu gösteren üyelik dereceleri, $[0,1]$ kapalı aralığında gerçel sayı değerlerini almaktadır.

U evrensel bir küme ve $\underline{A}$ da bir bulanık küme olsun. $\underline{A}$ bulanık kümesine ait üyelik dereceleri;

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

$\mu_{\underline{A}}(x)$, x elemanın kümeye ait olma derecesi ve $[0,1]$ aralığında karşılık gelen fonksiyonu şeklinde tanımlanır.

Bulanık kümeye ait elemanın üyelik derecesi arttıkça kümeye ait olma derecesi de artar. Üyelik derecesi 1 olduğunda tam üyelik derecesi, 0 olduğunda ise tam üye olamama derecesi ile ifade edilmektedir. Bu iki değer arasında değer alması kısmi üyelik derecesini gösterir. Diğer bir deyişle, bulanık kümede tam üye olamama derecesinden yani ilgili nesnenin bulanık kümeye ait olmamasından tam üyelik derecesine doğru geçişin esnek ve göreceli olduğu izlenebilmektedir (Yolcu, 2011).

$\underline{A}$ bulanık kümesinin düzenli çiftleri;

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

olarak gösterilir.

Ω herhangi bir küme ve $\underline{A}$, Ω 'nın bulanık alt kümesi olmak üzere, $\forall x \in \Omega$ için, Ω kümesini $[0,1]$ aralığına eşleştiren, $\underline{A}$ 'nın üyelik fonksiyonu (x) ile gösterilsin. Örneğin $\underline{A}(x_0) = 1$ ise x_0 , $\underline{A}$ bulanık kümesine aittir. $\underline{A}(x_1) = 0$ ise $\underline{A}$ bulanık alt kümesine ait değildir. $\underline{A}(x_2) = 0.6$ ise x_2 'nin $\underline{A}$ bulanık alt kümesine üyelik değeri 0.6'dır. $\underline{A}$ 'nın üyelik fonksiyonu $\underline{A}(x)$, daima 1 veya 0 değerleri alıyor ise $\underline{A}$, Ω kümesinin bir bulanık olmayan (crisp) alt kümesidir. Bulanık kümelerin hemen hepsinde bulanık sayılar kullanılır (Buckley, 2006; Çağcağ Yolcu, 2013).

2.1.1. Bulanık Küme İşlemleri

Kesişim, birleşim ve tümlleme klasik kümelerin en temel küme işlemleridir. U evrensel bir küme ve A ve B kümeleri de klasik küme olsun. A ve B klasik kümelerine ait kesişim, birleşim ve tümlleme işlemleri aşağıdaki gibi tanımlanır (Özkan, 2003) ;

$$\text{Kesişim: } A \cap B = \{x \mid x \in A \text{ ve } x \in B, x \in U\} \quad (2.3)$$

$$\text{Birleşim: } A \cup B = \{x \mid x \in A \text{ veya } x \in B, x \in U\} \quad (2.4)$$

$$\text{Tümlleme: } \bar{A} = \{x \mid x \in U \text{ ve } x \notin A\} \quad (2.5)$$

Bulanık kümelerde, kesişim, birleşim ve tümlleme işlemleri üyelik fonksiyonunu temel alarak belirlenmektedir. Bulanık kümelerde bu üç işlem minimum, maksimum ve değilleme işlemleri kullanılarak yapılmaktadır. $\underline{A}$ ve $\underline{B}$ bulanık iki küme olsun ve bu kümelerine ait kesişim, birleşim ve tümlleme işlemleri aşağıdaki gibi tanımlanır (Özkan, 2003; Çağcağ Yolcu, 2013).

$$\text{Kesişim: } \mu_{\underline{A} \cap \underline{B}}(x) = \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) \quad (2.6)$$

$$\text{Birleşim: } \mu_{\underline{A} \cup \underline{B}}(x) = \max(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) \quad (2.7)$$

$$\text{Tümleme: } \mu_{\underline{A}}(x) = 1 - \mu_{\underline{A}}(x) \quad (2.8)$$

$\mu_{\underline{A}}(x)$ ve $\mu_{\underline{B}}(x)$ sırasıyla $\underline{A}$ ve $\underline{B}$ kümelerinin üyelik fonksiyonları olduğu varsayalım. $\underline{A}$ ve $\underline{B}$ kümelerinin üyelik fonksiyonlarının $[0,1] * [0,1] \rightarrow [0,1]$ eşleşmesi, $\underline{A} \cap \underline{B}$ kesişim kümesinin üyelik fonksiyona dönüştüren eşleşme t , $\underline{A} \cup \underline{B}$ birleşim kümesinin üyelik fonksiyona dönüştüren eşleşme s , $\bar{\underline{A}}$ tümleyen kümesinin üyelik fonksiyona dönüştüren eşleşme c olarak ifade edilmektedir. Burada $\underline{A}$ ve $\underline{B}$ kümeleri $[0,1]$ aralığında değer alırken kesişim ve birleşim kümeleri de $[0,1]$ aralığında yer almaktadır. t , s , c eşleşmeleri aşağıdaki gibi gösterilir (Butnariu ve Klement, 1992; Koçak, 2011; Çağcağ Yolcu, 2013).

$$t(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) = \mu_{\underline{A} \cap \underline{B}}(x) \quad (2.9)$$

$$s(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) = \mu_{\underline{A} \cup \underline{B}}(x) \quad (2.10)$$

$$c(\mu_{\underline{A}}(x)) = \mu_{\bar{\underline{A}}}(x) \quad (2.11)$$

Bulanık kesişim ve birleşim kümeleri işlemlerinde her bir eşleşme sınıfı için seçilebilecek farklı eşleşmeler vardır. t ve s eşleşmeleri için sık kullanılan bazı eşleştirmeler formülleriyle aşağıdaki gibidir (Özkan, 2003; Çağcağ Yolcu, 2013).

t eşleşmesi;

$$\mu_{\underline{A} \cap \underline{B}}(x) = \left\{ \begin{array}{l} \mu_{\underline{A}}(x) * \mu_{\underline{B}}(x) : \text{cebirsel } \text{arpım} \\ \max(0, \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x) - 1) : \text{sınırlı } \text{arpım} \\ \frac{\mu_{\underline{A}}(x) * \mu_{\underline{B}}(x)}{2 - (\mu_{\underline{A}}(x) * \mu_{\underline{B}}(x) - \mu_{\underline{A}}(x) * \mu_{\underline{B}}(x))} : \text{Einstein } \text{arpımı} \\ \min(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) : \text{minimum} \end{array} \right\} \quad (2.12)$$

s eşleşmesi;

$$\mu_{\underline{A} \cup \underline{B}}(x) = \left\{ \begin{array}{l} \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x) - \mu_{\underline{A}}(x) * \mu_{\underline{B}}(x) : \text{cebirsel toplam} \\ \min(1, \mu_{\underline{A}}(x) + \mu_{\underline{B}}(x)) : \text{sınırlı toplam} \\ \frac{\mu_{\underline{A}}(x) + \mu_{\underline{B}}(x)}{1 + (\mu_{\underline{A}}(x) * \mu_{\underline{B}}(x))} : \text{Einstein toplamı} \\ \max(\mu_{\underline{A}}(x), \mu_{\underline{B}}(x)) : \text{maksimum} \end{array} \right\} \quad (2.13)$$

Yukarıda tanımlanan $\underline{A}$ ve $\underline{B}$ bulanık iki kümeye ait kesişim, birleşim ve tümleme işlemleri tanımlanmıştır. Bu işlemlere ek olarak bulanık kümeye ait bazı özellikler aşağıda yer almaktadır:

Sıfırdan farklı üyelik derecelerine sahip olan tüm elemanlarına $\underline{A}$ bulanık kümesinin destek kümesi denir ve aşağıdaki gibi gösterilir.

$$SuppA = \{ \mu_{\underline{A}}(x) > 0 \parallel x \in X \} \quad (2.14)$$

Bulanık kümedeki bütün elemanlardan üyelik derecesi α değerinden büyük veya eşit olan kümeye $\underline{A}$ bulanık kümesinin α - kesim kümesi adı verilir ve A_α şeklinde gösterilir.

$$A_\alpha = \{ \mu_{\underline{A}}(x) \geq \alpha \parallel x \in X \} \quad (2.15)$$

X evrensel kümesindeki $\underline{A}$ bulanık kümesinin her bir elemanın üyelik derecesi, $\underline{B}$ bulanık kümesinin her bir elemanın üyelik derecesinden küçük veya eşitse $\underline{A}$ bulanık kümesi $\underline{B}$ bulanık kümesinin alt kümesidir.

$$\mu_{\underline{A}}(x) \leq \mu_{\underline{B}}(x), x \in X \text{ ise } \underline{A} \subseteq \underline{B} \quad (2.16)$$

$\underline{A}$ bulanık kümesinin elemanlarının üyelik derecesi $\underline{B}$ bulanık kümesinin elemanlarının üyelik derecesine eşitse $\underline{A}$ bulanık kümesi $\underline{B}$ bulanık kümesine eşittir.

$$\mu_{\underline{A}}(x) = \mu_{\underline{B}}(x), x \in X \text{ ise } \underline{A} = \underline{B} \quad (2.17)$$

Eğer bu iki bulanık küme birbirine eşit ise;

$$\underline{A} = \underline{B} \text{ ise } \underline{A} \subseteq \underline{B} \text{ ve } \underline{B} \subseteq \underline{A} \quad (2.18)$$

$\underline{A}$ ve $\underline{B}$ bulanık kümeleri $x \in X$ için elemanlarının üyelik dereceleri birbirine eşit değilse $\underline{A}$ ve $\underline{B}$ bulanık kümeleri eşit değildir.

$$\mu_{\underline{A}}(x) \neq \mu_{\underline{B}}(x), x \in X \text{ ise } \underline{A} \neq \underline{B} \quad (2.19)$$

2.2. Sezgisel Bulanık Küme

Atanassov'un Sezgisel Bulanık Küme teorisi, Zadeh (1965) tarafından ortaya atılan Bulanık Küme teorisinin genişletilmiş bir halidir. Atanassov (1983, 1986, 1999) tarafından yapılan çalışmalarda üyelik derecelerinin yanı sıra üye olmama (non-membership) derecelerini ve tereddüt derecesini (hesitancy degree) hesaba katan yeni bir sezgisel yöntem önermiştir.

Sezgisel Bulanık Küme teorisinde üye olma ($\mu_{\underline{A}}(x)$) ve üye olmama ($1 - \mu_{\underline{A}}(x)$) derecelerinin her ikisi $[0, 1]$ aralığında değer almaktadır. Ancak toplamlarının bire eşit olması zorunlu değildir hatta birden daha azda olabilmektedir. Toplamı

birden daha az olduğu durumda Atanassov, tereddüt derecesi (hesitancy degree) olarak üçüncü bir parametre tanımlamıştır. Bu parametre yani tereddüt derecesi üye olma ve üye olmama derecelerinin toplamını bire tamamlamak için kullanılmıştır. Tereddüt derecesi de $[0, 1]$ aralığında değer almaktadır (Atanassov, 2012).


X boş olmayan bir küme olduğunu kabul edelim. X ' deki bir sezgisel bulanık A kümesi;

$$A = \{ \langle x, \mu_A(x), \nu_A(x) \rangle \mid x \in X \}. \quad (2.20)$$

$$\mu_A(x) : X \rightarrow [0, 1] \quad \nu_A(x) : X \rightarrow [0, 1] \quad (2.21)$$

şeklinde tanımlanır. Burada $\mu_A(x)$, x elemanının A kümesine ait olma derecesini, $\nu_A(x)$ ise x elemanının A kümesine ait olmama derecesini vermektedir. Sezgisel bulanık küme de $\mu_A(x)$ ve $\nu_A(x)$ 'in toplamı $[0, 1]$ aralığında değer almaktadır.

$$0 \leq \mu_A(x) + \nu_A(x) \leq 1 \quad (2.22)$$



Şekil 2.1: μ_A , ν_A ve π_A gösterimi (Atanassov, 2012)

Atanassov tereddüt derecesi, bir konu hakkındaki bilgi eksikliği ve/veya karar veren kişinin kararsızlığını dikkate almamaktadır. Üye olma ve üye olmama derecelerinin toplamının birden çıkarılmasıyla elde edilmektedir Atanassov'un sezgisel bulanık kümesinde üye olma ve üye olmama derecelerinin toplamı her zaman bir olmak zorunda değildir. $\mu_A(x)$ ve $\nu_A(x)$ 'in toplamı birden küçük olduğu durumlarda tereddüt derecesi işleme girmektedir. Tereddüt derecesi, π_A şeklinde


gösterilmektedir. Tereddütlik derecesi, ilgili elemanın kümeye ait olup olmamasının belirsizlik düzeyini ifade etmektedir. Tereddütlik derecesi;

$$\pi_A(x) = 1 - \mu_A(x) - \nu_A(x) \quad (2.23)$$


$$0 \leq \pi_A(x) \leq 1 \quad (2.24)$$

gibi tanımlanır.


Tereddüt derecesi x elemanı hakkında bazı bilgiler vermektedir. Eğer $\pi_A(x)$ derecesi küçük olduğunda x elemanı hakkında bilgi göreceli olarak daha kesin, eğer $\pi_A(x)$ derecesi büyük olduğunda ise x elemanı hakkında bilgi göreceli olarak daha belirsiz olmaktadır. $\pi_A(x) = 0$ ' a eşit olduğunda ise x elemanı hakkında bilgi kesindir ve bu durumda sezgisel bulanık küme bulanık kümeye dönüşmektedir (Aguila ve ark. 2017).



Şekil 2.2: İlk geometrik yorumlama (Atanassov, 2012)



Şekil 2.3: İlk geometrik yorumlamanın modife edilmiş göreseli (Atanassov, 2012)



Şekil 2.4: İkinci geometrik yorumlama (Atanassov, 2012)

2.2.1. Sezgisel Bulanık Küme İşlemleri

X boş olmayan bir küme olduğunu kabul edelim. X ' deki A ve B iki sezgisel bulanık küme;

$$A = \{ \langle x, \mu_A(x), v_A(x) \rangle \mid x \in X \}. \quad (2.25)$$

$$B = \{ \langle x, \mu_B(x), v_B(x) \rangle \mid x \in X \}. \quad (2.26)$$

şeklinde tanımlı ve

$$0 \leq \mu_A(x) + v_A(x) \leq 1 \quad (2.27)$$

$$0 \leq \mu_B(x) + v_B(x) \leq 1 \quad (2.28)$$

aralığında yer alsın. A ve B sezgisel bulanık kümelerine ait üyelik değerleri aşağıdaki verilen aralıklarda tanımlanır;

$$\mu_A(x) : X \rightarrow [0 \ 1] \quad v_A(x) : X \rightarrow [0 \ 1] \quad (2.29)$$

$$\mu_B(x) : X \rightarrow [0 \ 1] \quad v_B(x) : X \rightarrow [0 \ 1] \quad (2.30)$$

Bulanık kümelerde olduğu gibi sezgisel bulanık kümelerde küme işlemlerini, üyelik fonksiyonlarını temel alarak kullanılmaktadır. Sezgisel bulanık kümelerde bulanık kümelerden farklı olarak üye olamama derecelerini de dikkate almaktadır. Yukarıda tanımlanan A ve B sezgisel bulanık iki kümeye ait kesişim, birleşim ve tümleme işlemleri aşağıdaki gibi tanımlanır (Atanassov, 1986; 2012).

Kesişim:

$$\begin{aligned}\mu_{A \cap B}(x) &= \{ \langle x, \mu_A(x) \cap \mu_B(x), v_A(x) \cup v_B(x) \rangle \mid x \in X \} \\ &= \{ \langle x, \min(\mu_A(x), \mu_B(x)), \max(v_A(x), v_B(x)) \rangle \mid x \in X \} \end{aligned} \quad (2.31)$$

Birleşim:

$$\begin{aligned}\mu_{A \cup B}(x) &= \{ \langle x, \mu_A(x) \cup \mu_B(x), v_A(x) \cap v_B(x) \rangle \mid x \in X \} \\ &= \{ \langle x, \max(\mu_A(x), \mu_B(x)), \min(v_A(x), v_B(x)) \rangle \mid x \in X \} \end{aligned} \quad (2.32)$$

Tümleme:

$$\mu_{A^c}(x) = \{ \langle x, v_A(x), \mu_A(x) \rangle \mid x \in X \} \quad (2.33)$$

Yukarıda tanımlanan A ve B sezgisel bulanık iki kümeye ait kesişim, birleşim ve tümleme işlemleri tanımlanmıştır. Bu küme işlemlerine ek olarak sezgisel bulanık küme işlemlerine ait bazı özellikler aşağıda verilmiştir (Atanassov, 1986; De ve ark., 2000).

$$A = B \text{ ise } \forall x \in X \text{ için, } \mu_A(x) = \mu_B(x), v_A(x) = v_B(x) \quad (2.34)$$

$$A \subseteq B \leftrightarrow \mu_A(x) \leq \mu_B(x), v_A(x) \geq v_B(x), \forall x \in X \quad (2.35)$$

$$A = B \leftrightarrow A \subseteq B \text{ ve } B \subseteq A \quad (2.36)$$

$$(A^c)^c = A \quad (2.37)$$

$$(A \cup B)^c = A^c \cap B^c \quad (2.38)$$

$$(A \cap B)^c = A^c \cup B^c \quad (2.39)$$

Sezgisel bulanık küme işlemlerinde ikiden fazla küme için aşağıda bazı küme işlemlerinin özelliklerine yer verilmiştir. X boş olmayan bir küme olduğunu kabul edelim. X’ deki sezgisel bulanık kümeler A, B, C, D olsun;

$$A \subseteq B \text{ ve } B \subseteq C \rightarrow A \subseteq C \quad (2.40)$$

$$A \subseteq B \text{ ve } A \subseteq C \rightarrow A \subseteq B \cap C \quad (2.41)$$

$$A \subseteq B \text{ ve } B \subseteq C \rightarrow A \cup B \subseteq C \quad (2.42)$$

$$A \subseteq B \text{ ve } C \subseteq D \rightarrow A \cup B \subseteq B \cup D \text{ ve } A \cap C \subseteq B \cap D \quad (2.43)$$

X boş küme olmadığını ve A sezgisel bir bulanık küme olduğunu kabul edelim. Bu durumda A’nın üye olma ve üye olmama derecesini sıfırdan büyük yapan değerlere A sezgisel bulanık kümesinin destek kümesi adı verilmektedir.

$$des(A) = \{ \mu_A(x) > 0, v_A(x) \geq 0 \parallel x \in X \} \quad (2.44)$$

X boş küme olsun, A sezgisel bir bulanık kümenin elemanlarının üye olma ve üye olamama dereceleri α değerinden büyük veya eşitse bu kümelere sezgisel bulanık kümenin α -kesim kümesi adı verilir ve αA ile gösterilir.

$$\alpha A = \{ \mu_A(x) \geq \alpha, v_A(x) \geq \alpha, \mu_A(x) + v_A(x) \leq 1 \parallel x \in X \}. \quad (2.45)$$

BÖLÜM 3. BULANIK ZAMAN SERİLERİ VE TEMEL KAVRAMLAR

Tezin bu bölümünde, bulanık zaman serileri ve sezgisel bulanık zaman serilerinin kavramları ve tanımları ile bu serilere ait bazı özelliklere yer verilmiştir.

Zaman serisi, zaman faktörünü dikkate alarak yani gün, hafta, ay, mevsim veya yıl bazındaki verileri analiz etmek için elde edilen verilerin incelenmesi olarak ifade edilebilir. Zaman serisi analizi kronolojik sırayla gözlemlenen verilere uygun bir model bulmak ve bu verilerin gelecekte hangi değerleri alabileceği ya da ilgili zaman serisi ile farklı zaman serileri arasındaki ilişkileri istatistiksel olarak incelemek ve/veya ortaya koymak zaman serisi analizinin amaçları arasında yer almaktadır. Zaman serisi analizi için kullanılan verilerin tutarlı, etkin, sıralı ve güvenilir olması gerekmektedir.

Geçmişten günümüze pek çok alanda zaman serisi analizleri sıklıkla kullanılmaktadır. Klasik zaman serileri analizi yöntemlerinin avantajları olduğu gibi çeşitli bazı katı varsayımlar içeren dezavantajları da bulunmaktadır. Olasılıksal yöntemler olarak da adlandırılabilen bu yöntemlerde model seçimi, modele değişken seçimi, gözlem sayısı, durağanlık, tersinirlik gibi bazı katı varsayımlar sebebiyle oluşabilecek dezavantajları ortadan kaldırmak amacıyla alternatif olarak olasılıksal olmayan modeller ortaya konmuştur.

Katı varsayımlara gereksinim duymadıkları için neredeyse bütün zaman serilerinin analizine kolaylıkla uygulanabilen olasılıksal olmayan zaman serisi analiz yöntemleri, temel olarak hesaplamalı ve bulanık-tabanlı modeller olmak üzere iki ana grupta ele alınabilir. Bulanık-tabanlı modeller bulanık zaman serisi yöntemleri ve bulanık ile ilişkili farklı modellerden oluşur.

Bulanık zaman serisinin değerleri bulanık kümelerdeki üyelik derecelerinden elde edilmektedir. Ele alınan serinin içerisindeki belirsizliği dikkate alması ve klasik

zaman serilerinin katı varsayımlarını içermemesi ve aynı zamanda gerçek hayat problemlerine daha gerçekçi sonuçlar vermesi bulanık zaman serilerini dikkat çekici konulardan biri haline getirmektedir. Geçmiş ile günümüzdeki gözlemler arasındaki ilişkiyle geleceğe yönelik tahmin yapmak için kullanılmaktadır. Bulanık zaman serisi analizleri çoğunlukla gözlemlerin bulanıklaştırılması, bulanık ilişkilerin belirlenmesi ve durulaştırma aşaması olmak üzere üç aşama ile çözümlenmektedir. Bu aşamaların daha iyi sonuç verebilmesi açısından birçok araştırmacı yeni yöntemler geliştirmiş ve önermiştir.

Literatüre de geniş bir alana sahip olan bulanık zaman serisi modellerinde sadece üyelik değerleri dikkate alınmaktadır. Bu durum gerçek hayat problemlerinde bazı olumsuzluklara neden olmaktadır. Sadece üyelik değerlerini ele alan bir zaman serisi analizinde hem üye olmama değerlerinden gelen bilgileri hem de tereddüt derecesinin hesaba katılmamasından dolayı olumsuz etkilenmektedir. Bu durumu ortadan kaldırmak için sezgisel bulanık küme tabanlı sezgisel bulanık zaman serileri analizi önerilmiştir.

Sezgisel bulanık zaman serileri, bulanık zaman serilerinin genişletilmiş şeklini içermektedir. Sezgisel bulanık zaman serileri üye olma, üye olmama ve tereddüt derecelerini kullanmaktadır. Bu sayede bulanık zaman serisi modellerine göre daha fazla bilgi kullanımını sağlayarak daha avantajlı hale gelmektedir. Bulanık zaman serilerine göre gerçek hayat problemlerine daha uyumlu ve daha gerçekçi sonuçlar vermesi sezgisel bulanık zaman serilerini son zamanlarda daha da dikkat çekici konulardan biri haline getirmektedir.

3.1. Bulanık Zaman Serileri

Bulanık zaman serisi kavramı literatürde ilk olarak Song ve Chissom (1993a, 1993b, 1994) tarafından yapılan çalışmada ileri sürülmüştür. Bulanık zaman serileri Zadeh (1965, 1973, 1975) tarafından ortaya atılan bulanık küme teorisine dayandırılarak ortaya konulmuştur.

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

Evrensel küme $U = \{u_1, u_2, u_3, \dots, u_n\}$ olsun ve evrensel kümenin belirlenen bir sabit aralık uzunluğuna göre parçalanması ile elde edilen u_i 'ler alt aralıklar olmak üzere bulanık kümeler,

$$A_i = \frac{f_{A_i}(u_1)}{u_1} + \frac{f_{A_i}(u_2)}{u_2} + \frac{f_{A_i}(u_3)}{u_{i3}} + \dots + \frac{f_{A_i}(u_b)}{b} \quad (3.1)$$

gibi tanımlanmaktadır. Burada f_{A_i} , A_i bulanık kümesinin üyelik fonksiyonunu göstermekte ve $f_{A_i} : U \rightarrow [0,1]$ aralığında yer almaktadır. $f_{A_i}(u_a)$ ifadesi ise u_a alt aralığının A_i bulanık kümesine ait olmasının üyelik derecesini göstermektedir. $0 \leq a \leq b$ olmak üzere $f_{A_i}(u_a) \in [0,1]$ aralığında olmaktadır.

Tanım 1. $Y(t), (t = 1,2,3, \dots)$ reel değerli zaman serisi olduğunu kabul edelim. 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 (Song ve Chissom, 1993a);

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

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

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

şeklinde ifade edilir ve birinci dereceden bulanık zaman serisi öngörü modeli olarak adlandırılır. Bu ilişki Song ve Chissom 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 $F(t)$ ve $F(t - 1)$ bulanık zaman serisi arasındaki bulanık ilişki,

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

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

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

$$F(t - n), \dots, F(t - 3), F(t - 2), F(t - 1) \rightarrow F(t) \quad (3.5)$$

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

Tanım 4. İki bulanık zaman serisi $F_1(t)$ ve $F_2(t)$ olduğunu kabul edelim. Bulanık zaman serisi, gecikmeli $F_1(t - 1), F_2(t - 2)$ bulanık zaman serilerinden etkilenmekte ise, $F_1(t)$ bulanık zaman serisi ile $F_1(t - 1), F_2(t - 2)$ bulanık zaman serileri arasındaki bulanık ilişki,

$$F_1(t - 1), F_2(t - 2) \rightarrow F_1(t) \quad (3.6)$$

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, $F_1(t)$ bulanık zaman serisi, gecikmeli $F_1(t-1), \dots, F_1(t-n)$ ve $F_2(t-1), \dots, F_2(t-n)$ bulanık zaman serilerinden etkilenmekte ise n 'inci dereceden iki değişkenli bulanık zaman serisi öngörü modeli,

$$F_1(t-1), \dots, F_1(t-n) F_2(t-1), \dots, F_2(t-n) \rightarrow F_1(t) \quad (3.7)$$

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, gecikmeli $F_1(t-m_1), \dots, F_1(t-m_{k-1}), F_2(t-m_k), F_2(t-n_1), \dots, F_2(t-n_{l-1}), F_2(t-n_l)$ bulanık zaman serilerinden etkilenmekte ise (k, l) 'inci dereceden, kısmi yüksek dereceli, iki değişkenli bulanık zaman serisi öngörü modeli,

$$F_1(t-m_1), \dots, F_1(t-m_k), F_2(t-n_1), \dots, F_2(t-n_l) \rightarrow F_1(t) \quad (3.8)$$

ifadesi ile verilebilir. Burada, $m_i, (i = 1, 2, 3, \dots, k)$ ve $n_j, (j = 1, 2, 3, \dots, l)$ tamsayılar ve $1 \leq m_1 < \dots < m_k, 1 \leq n_1 < \dots < n_l$ şeklindedir ve aynı zamanda $F_1(t)$ ana faktör, $F_2(t)$ ise ikincil faktör olarak adlandırılır.

Tanım 7. $F_1(t) F_2(t) F_3(t), \dots, F_m(t)$ m adet bulanık zaman serisi iken, $F_1(t)$, bulanık zaman serisi, $F_1(t-1), \dots, F_m(t-1), \dots, F_1(t-n), \dots, F_m(t-n)$ gecikmeli bulanık zaman serilerinden etkilenmekte ise n 'inci dereceden m değişkenli (m -faktör) bulanık zaman serisi öngörü modeli,

$$F_1(t-1), \dots, F_m(t-1), \dots, F_1(t-n), \dots, F_m(t-n) \rightarrow F_1(t) \quad (3.9)$$

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

3.2. Sezgisel Bulanık Zaman Serileri

Sezgisel bulanık zaman serileri, sezgisel bulanık kümelerle dayalı bulanık zaman serilerinden esinlenerek önerilmiştir. Zheng ve ark. (2013a) tarafından yapılan çalışmada sezgisel bulanık zaman serilerinin temel tanımları ve ilk sezgisel bulanık zaman serisi tahmin modeli literatürde yer almıştır.

Tanım 1. Sezgisel bulanık zaman serisi (**SBZS**) modeli; X_t gerçek gözlemleri bir zaman serisi olduğunu kabul edelim. $A_1, A_2, A_3, \dots, A_c$ evrensel küme üzerinde sezgisel bulanık küme olarak adlandırılır. $SBZS_t$, her bir bulanık küme için gerçek gözlemler, üye ve üye olmama değerlerini içeren çok değişkenli bir zaman serisi olmaktadır. Birinci mertebeden model aşağıdaki gibi tanımlanabilir (Eğrioğlu ve ark., 2019; Koçak ve ark., 2021a; 2021b).

$$SBZS_t = \{X_t, \mu_{A_1}(t), \mu_{A_2}(t), \mu_{A_3}(t), \dots, \mu_{A_c}(t), v_{A_1}(t), v_{A_2}(t), v_{A_3}(t), \dots, v_{A_c}(t)\} \quad (3.10)$$

Burada $\mu_{A_j}(t), v_{A_j}(t)$ sırasıyla t 'inci gözlemin j 'inci sezgisel bulanık kümeye ait üye olma ve üye olma değerini göstermektedir. Bu değerler Sezgisel Bulanık C-ortalamalar yöntemi veya diğer sezgisel bulanık kümeleme yöntemleriyle elde edilebilir.

Tanım 2. Yüksek dereceli tek değişkenli sezgisel bulanık zaman serisi tahmin modeli $SBZS_t$ sezgisel bulanık bir zaman serisi olsun. $A_1, A_2, A_3, \dots, A_c$ evrensel küme üzerinde sezgisel bulanık kümelerdir. $\mu_{A_j}(t), v_{A_j}(t)$ sırasıyla t 'inci gözlemin j 'inci sezgisel bulanık kümeye ait üye olma ve üye olma değerini göstermektedir. Yüksek dereceli tek değişkenli sezgisel bulanık zaman serisi tahmin modeli aşağıda gösterilmektedir.

$$\begin{aligned} X_t = G(& X_{t-1}, \dots, X_{t-p}, \mu_{A_1}(t-1), \mu_{A_2}(t-1), \dots, \mu_{A_c}(t-1), \dots, \\ & \mu_{A_1}(t-p), \mu_{A_2}(t-p), \dots, \mu_{A_c}(t-p), v_{A_1}(t-1), v_{A_2}(t-1), \\ & \dots, v_{A_c}(t-1), \dots, v_{A_1}(t-p), v_{A_2}(t-p), \dots, v_{A_c}(t-p)) + \varepsilon_t. \end{aligned} \quad (3.11)$$

Buradaki denklemde G , linear ya da linear olmayan fonksiyondur. ε_t , sıfır ortalamalı hata terimini ifade etmektedir. $X_{t-1}, \dots, X_{t-p}$, X_t 'in gecikmeli değişkenleridir. $\mu_{A_1}(t-1), \dots, \mu_{A_C}(t-p)$ ve $v_{A_2}(t-1), \dots, v_{A_C}(t-p)$ ise gecikmeli üye ve üye olmama değerleridir ve $X_{t-1}, \dots, X_{t-p}$ elde edilir.

3.3. Bulanık C Ortalamalar Yöntemi

Bulanık C-Ortalamalar (BCO)-(Fuzzy C-Means) yöntemi, Dunn tarafından 1973 yılında önerilmiştir. Çalışmayı daha sonra 1981 yılında Bezdek geliştirmiştir. Literatürde en çok kullanılan kümeleme yöntemlerinden biridir. Görüntü işleme, veri madenciliği, astronomi gibi birçok farklı alanda kullanılmaktadır.

Amaç fonksiyonuna ve kısıtlamaların minimize edilmesi temeline dayanan bulanık C-ortalamalar yöntemi, verilerin birden fazla kümeye farklı üyelik dereceleriyle eklenmesiyle oluşan bir yöntemdir. Bulanık küme mantığındaki gibi üyelik dereceleri $[0, 1]$ aralığında yer almaktadır. Burada verinin tüm kümelere ait olduğu üyelik derecelerinin toplamı bire eşit olmalıdır. Veri küme merkezlerinden hangisine yakın ise o kümeye ait olma üyelik derecesi daha büyük olmaktadır.

Bulanık C-ortalamalar yöntemi en küçük hata kareleri minimize ederek verileri bulanık kümelere bölmektedir. Yöntemin uygulanabilmesi için küme sayısı ve değişkenlerin üyelik değerleri belirlenmelidir. Bu belirleme işlemi rasgele olabileceği gibi bazı yöntemler kullanılarak da bulunabilmektedir. Üye değerleri, kümenin merkezi ve değişken sayısı sırasıyla u_{ij} , v_i ve c şeklinde temsil edilsin. Bu durumda amaç fonksiyonu aşağıdaki gibi ifade edilir (Eğrioğlu, 2013; Çağcağ Yolcu ve ark., 2016).

$$J_\beta(X, V, U) = \sum_{i=1}^c \sum_{j=1}^n u_{ij}^\beta d^2(x_j, v_i) \quad (3.12)$$

Burada X, V, U sırasıyla veri matrisini, küme merkezlerinin matrisini ve üyelik değerleri matrisini göstermektedir. β değeri bulanık indeksini ifade eder ve $\beta > 1$

olarak alınmaktadır. $d(x_j, v_i)$ ise gözlem ile küme merkezi arasındaki uzaklık ölçüsüdür. J_β amaç fonksiyonunu minimize ederken bazı kısıtlamalar bulunmaktadır. Bu kısıtlamalar aşağıda yer almaktadır (Eğrioğlu, 2013; Çağcağ Yolcu ve ark., 2016).

$$0 \leq u_{ij} \leq 1, \forall i, j \quad (3.13)$$

$$0 < \sum_{j=1}^n u_{ij} \leq n, \forall i \quad (3.14)$$

$$\sum_{i=1}^c u_{ij} = 1, \forall j \quad (3.15)$$

Bulanık C-ortalamalar yönteminde minimizasyon işlemi yinelemeli algoritma kullanılarak gerçekleştirilmektedir. Her iterasyonda u_{ij} ve v_i değerleri aşağıda verilen formülleri kullanarak güncellenir (Eğrioğlu, 2013; Çağcağ Yolcu ve ark., 2016).

$$v_i = \frac{\sum_{j=1}^n u_{ij}^\beta x_j}{\sum_{j=1}^n u_{ij}^\beta} \quad (3.16)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d(x_j, v_1)}{d(x_j, v_k)} \right)^{\frac{2}{\beta-1}}} \quad (3.17)$$

3.4. Sezgisel Bulanık C Ortalamalar Yöntemi

Chaira (2011) tarafından yapılan çalışmada Sezgisel Bulanık C-Ortalamlar (SBCO)- (Intuitionistic Fuzzy C Means-IFCM) yöntemi önerilmiştir. Atanassov'un Sezgisel Bulanık Küme teorisine dayanan ve Bezdek tarafından geliştirilen bulanık C-ortalamlar yönteminin genişletilmiş halidir.

Chaira'nın önermiş olduğu sezgisel bulanık kümeleme yönteminde, amaç fonksiyonu iki bileşeni içerir: bunlardan birisi bulanık C-ortalamların sezgisel bulanık kümeleri kullanarak değiştirilmiş amaç fonksiyonunu ve diğeri ise sezgisel bulanık entropidir.

Sezgisel bulanık C-ortalamalar yönteminin minimize eden amaç fonksiyon aşağıdaki gibi hesaplanmaktadır (Chaira, 2011; Çağcağ Yolcu ve ark., 2019; Eğrioğlu ve ark., 2019).

$$J_{BCO(IFCM)} = \sum_{i=1}^c \sum_{k=1}^n u_{ik}^{*m} d_{ik}^2 + \sum_{i=1}^c \pi_i^* e^{(1-\pi^*)} \quad (3.18)$$

Burada u_{ik}^* ifadesi sezgisel bulanık üyeliğini gösterir ve aşağıdaki gibi tanımlanmaktadır.

$$u_{ik}^* = u_{ik} + \pi_{ik} \quad (3.19)$$

u_{ik} , i . Kümedeki k . veri noktasındaki bulanık küme üyeliği olarak tanımlanmaktadır. π_{ik} ifadesi de tereddüt derecesini vermekte ve aşağıdaki gibi açıklanmaktadır.

$$\pi_{ik} = 1 - u_{ik} - (1 - u_{ik}^a)^{\frac{1}{a}}, a > 0 \quad (3.20)$$

ve Yager'in sezgisel bulanık tamamlayıcısı hesaplanır:

$$N(X) = (1 - x^a)^{\frac{1}{a}}, a > 0 \quad (3.21)$$

Böylece Yager'in sezgisel bulanık tamamlayıcısı ile sezgisel bulanık kümenin yeni tanımlaması:

$$A_{\lambda}^{SBK(IFC)} = \left\{ x, \mu_A(x), (1 - \mu_A(x)^a)^{\frac{1}{a}} / x \in X \right\} \quad (3.22)$$

ve

$$\pi_i^* = \frac{1}{N} \sum_{k=1}^n \pi_{ik}, k \in [1, N] \quad (3.23)$$

Bir bulanık kümedeki entropi, bulanıklığın veya belirsizliğin miktarını temsil etmektedir. Benzer şekilde sezgisel bulanık kümelerde de sezgisel bulanık entropi

(SBE)-(Intuitionistic Fuzzy Entropi-IFE), bir kümedeki bulanıklığın veya belirsizliğin miktarını vermektedir. Amaç fonksiyonunun ikinci terimini oluşturan sezgisel bulanık entropi, sınıftaki en iyi noktaları en üst düzeye çıkarmayı amaçlayan ikinci objektif olarak tanımlanmıştır. Sezgisel bulanık durumlar için $\mu_A(x)$, $v_A(x)$ ve $\pi_A(x)$ yani üye olma, üye olmama ve tereddüt dereceleri $X = \{x_1, x_2, x_3, \dots, x_n\}$ kümesinin elemanları ise sezgisel bulanık kümedeki belirsizlik derecesini gösteren sezgisel bulanık entropi aşağıdaki gibi verilmektedir (Chaira, 2011; Çağcağ Yolcu ve ark., 2019; Eğrioğlu ve ark., 2019).

$$SBE(A) = \sum_{i=1}^n \pi_A(x_i) e^{[1-\pi_A(x_i)]}, k \in [1, N] \quad (3.24)$$

Burada:

$$\pi_A(x_i) = 1 - \mu_A(x) - v_A(x) \quad (3.25)$$

SBE sınıftaki iyi noktaları maksimum yapmak için amaç fonksiyonu işlenmiştir. Burada amaç entropiyi en aza indirmektedir. Bu nedenle değiştirilmiş küme merkezleri aşağıdaki gibidir (Chaira, 2011; Çağcağ Yolcu ve ark., 2019; Eğrioğlu ve ark., 2019).

$$v_i(x)^* = \frac{\sum_{k=1}^n u_{ik}^* x_k}{\sum_{k=1}^n u_{ik}^*} \quad (3.26)$$

Her iterasyonda, küme merkezi ve üyelik matrisi güncellenir ve güncellenen üyelik dereceleri ile önceki üye dereceleri $\max_{ik} |U_{ik}^{*yeni} - U_{ik}^{*önceki}| < \varepsilon$ ulaşana kadar devam eder. Burada ε önceden tanımlanan değerdir. Durdurma kriteri maksimuma ulaştığı zaman algoritma durumaktadır (Chaira, 2011; Çağcağ Yolcu ve ark., 2019; Eğrioğlu ve ark., 2019).


BÖLÜM 4. YAPAY SİNİR AĞLARI

Tezin bu bölümünde, yapay sinir ağı ve işleyiş süreci ile Pi-Sigma yapay sinir ağı modelinin tanıtımı ile bu modellere ait bazı özelliklere yer verilmiştir.

İnsan sinir sisteminin çok basit bir taklidi olan yapay sinir ağları, en çok kullanılan yapay zeka ve veri madenciliğinde kullanılan yöntemlerinden biridir. İnsanların karar verme sürecinde sinir sistemlerinin önemli yeri vardır. Çünkü insan sinir sistemi ile bilgiyi kabul eder ve daha sonra onu işler ve sonunda da değerlendirir. Bu görevler insan vücudunda sinir sisteminin ne kadar önemli olduğunu göstermektedir. İnsanların bilgiyi öğrenebilmesi ve daha sonrasında bu bilgiyi tecrübe edebilmesi sinir sistemi ile gerçekleşmektedir (Eğrioğlu ve ark., 2020).

Biyolojik sinir ağlarından esinlenerek oluşturulan yapay sinir ağları genel olarak, matematiksel bir algoritma ifadesi ile tanımlanabilmektedir. Bilgiyi örnekler yardımıyla öğrenebilen ve öğrendiğini genelleyerek tahmin yapma olanağı sunan bir algoritmadır. Eldeki verileri kullanarak öğrenme, ilişki kurma, sınıflandırma, genelleme ve son olarak iyileştirme işlemlerinde YSA'ların farklı mimarileri kullanılmaktadır. YSA'ların mimari yapısında girişten çıkış tabakasına doğru paralel bir bilgi akışı sağlanmaktadır (Cağcağ Yolcu, 2013).

Yapay sinir ağları, insanın biyolojik sinir sisteminden yola çıkarak ortaya konmuştur. Sinir sisteminin en temel yapı taşına nöron adı verilmektedir. Nöronun gövdesi soma adı verilen, nöronun bilgi işlem merkezini ve nöronun çekirdeğini içermektedir. Nöronun uzantıları ise akson ve dentritlerden oluşmaktadır. Aksonlar, sinyal sistemine sahip iken dentritler sinyal alma görevini üstlenmektedirler. Sinyal alma görevini dentritlere sinaps denilen bölgeler sağlamaktadır. Aksonlar sinir hücresinin uzun uzantılarını, dentritler ise kısa uzantılarını göstermektedir. Her nöronda bir akson bulunurken, dentritler genellikle birden fazla bulunabilmektedir. Genel biyolojik nöron yapısının görseli aşağıda verilmiştir (Eğrioğlu ve ark., 2020).



Şekil 4.1: Biyolojik noron yapısı

İlk kez biyolojik nöronu yapay matematiksel forma dönüştüren çalışma McCulloch ve Pitts tarafından 1943 yılında ileri sürülmüştür. 1949 yılında ise Hebb'in çalışmasıyla yapay sinir ağları gelişmeye başlamıştır. 'The Organization of Behaviour' adlı kitabında Hebb, biyolojik öğrenme ile beynin öğrenme sürecini 'Hebbian öğrenme' diye adlandırdığı teoriyle açıklamıştır. 1959 yılına gelindiğinde Rosenblatt tarafından önerilen çok tabakalı algılayıcının yani perseptronun temeli oluşturan basit algılayıcı ileri sürülmüştür. Diğer bir değişle tek katmanlı YSA modelinin ilk temelleri Rosenblatt tarafından yapılan çalışmada ortaya çıkmıştır. Widrow ve Hoff'un 1960 da öğrenme sürecini basit algılayıcı nöron modelini kullanarak önerdiği ilk adaptif yapay sinir ağlarını önermiştir. Uyarlanabilen doğrusal nöron (adaptive linear neuron- ADALINE) ve çoklu uyarlanabilen doğrusal nöron (multiple adaptive linear elements- MADALINE) diye isimlendirdikleri yapay sinir ağı modellerini ortaya atmışlardır. Giles and Maxwell 1987 yılında yüksek dereceli işlem birimi sinir ağı çalışmasını yapmışlardır. Durbin ve Rumelhart 1989'da ürün birim sinir ağını (product unit neural network- PUNN) önermişlerdir. 1991'de Shin ve Ghosh tarafından önerilen Pi-Sigma yapay sinir ağı (Sigma-Pi artificial neural networks- SP-ANN) modeli tanıtılmıştır. Chen ve Jain 1994'te ve Hsiao ve ark. 2012'de M-tahmin ediciye dayalı dayanıklı öğrenme algoritmasını önermişleridir. Lin ve ark. 1998'de ve Giles ve ark. 2001 yıllarında tekrarlayan YSA (recurrent neural network- RNN) Y modelini ileri sürmüşlerdir. Thomas 1999'da çok katmanlı algılayıcı yapay sinir ağı (Multilayer perceptron artificial neural network- MLPANN) için öğrenme algoritması önermişlerdir. 2007 yılında Yadav ve ark. tarafından tek çarpımsal nöron (single multiplicative neuron model artificial neural

network- SMNM-ANN) modeli tanıtılmıştır. El Melegly ve ark. tarafından 2009 yılında ve Rusiecki tarafından 2012 yılında YSA'lar için en küçük medyan kareler algoritması ileri sürülmüştür. Attia ve ark. 2012'de genelleştirilmiş tek çarpımsal nöron modeli üzerine çalışmışlardır. 2013 yılında Yolcu ve ark. yaptığı çalışmada zaman serisi tahmini için doğrusal ve doğrusal olmayan YSA (linear & nonlinear artificial neural network- L&NL-ANN) modeli, yine aynı yıl Aladağ ve ark. tarafından çarpımsal mevsimsel yapay sinir ağı (MS-ANN) modeli geliştirmişlerdir. 2014 yılında Aladağ ve ark. tarafından yapılan çalışmada medyan sinir ağına dayalı dayanıklı çok katmanlı YSA modeli ortaya koymuştur. Eğrioğlu ve ark. tarafından 2014 yılında yapılan çalışmada tekrarlayan çarpımsal nöron (recurrent multiplicative neuron model artificial neural network- RMNM-ANN) modeli doğrusal olmayan zaman serileri için önerilmiştir. 2015'te Gündoğdu ve ark., gauss aktivasyon fonksiyonuna dayalı yeni bir çarpımsal nöron model ileri sürülmüştür. Yolcu ve ark. 2015'te budanmış ortalama sinir modeline dayanan çok katmanlı geri beslemeli YSA (trimmed ANN) model yöntemini geliştirmişlerdir. Chen ve ark. 2015'te, Zhou ve ark. 2016'da dendritik nöron (dendritic neuron) modelini çalışmışlardır. 2018'te Çağcağ Yolcu ve ark. yaptıkları çalışmalarında otoregresif katsayılı tek çarpımsal nöron modeli YSA (single multiplicative neuron model with autoregressive coefficient- AC-S-MNM) önermişlerdir. Yolcu ve ark. 2019 çalışmalarında ise doğrusal ve doğrusal olmayan YSA modelini geliştirerek bootstrap doğrusal ve doğrusal olmayan YSA (bootstrapped linear and non-linear artificial neural network- B-L&NL-ANN) yöntemini ileri sürmüşlerdir. Eğrioğlu ve Fildes'in 2020 yılı çalışmalarında bootstrap melez bir YSA (bootstrapped hybrid artificial neural network- B-HANN) modeli ortaya koymuşlardır.

Günümüzde YSA'lar çok geniş kullanım alanlarına sahiptir. Genetik mühendisliğinden harita mühendisliğine kadar birçok mühendislik bölümleri, matematik, istatistik, fizik gibi bölümlerinin yanı sıra astronomi ve uzay bilimleri bölümlerinde de YSA yaygın bir şekilde başarıyla kullanılmaktadır. Kullanım alanlarının dışında teoride de YSA modelleri sıklıkla tercih edilmektedir. Son zamanlarda bulanık zaman serileri analizinde ilişkilerin belirlenme aşaması ve/veya belirli aşamalarda yapılan yöntemlere YSA'ları alternatif bir imkân sunmaktadır.

Yapay sinir ağlarının yapısı üç ana başlık altında incelenebilir. Bunlar; mimari yapı, aktivasyon fonksiyonu ve öğrenme algoritmasıdır.

Yapay nöronların birbiriyle bağlanmasıyla YSA'ları oluşmaktadır. YSA mimari, belli sayıda nöronların bilgi akışını sağlamak için birbirleriyle bağlanması sonucu elde edilen yapıdır. YSA mimari içerisinde nöronlar, bağlantı ağırlıkları ve işlemciler bulunmaktadır. YSA'ların temel yapı taşı 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 (Yolcu, 2011; Çağcağ Yolcu, 2013).


Aktivasyon fonksiyonu, nöron çıktı değerinin hesaplamasında kullanılan fonksiyondur. Diğer bir ifadeyle, girdi ve çıktı arasındaki doğrusal ya da doğrusal olmayan eşleştirmeyi sağlayan bir fonksiyon olarak da tanımlanabilir. Bu fonksiyon hücreye gelen *net* girdiyi işleyerek, hücrenin bu girdiye karşılık üreteceği çıktıyı hesaplar. Aktivasyon fonksiyonu ağın performansını etkileyen önemli bir faktördür. Bu yüzden doğru ve etkin seçilmesi son derece önemlidir. YSA'nın birçok farklı aktivasyon fonksiyonu geliştirilmiştir. Hatta ağın kendi içinde bile farklı aktivasyon fonksiyonları olabilmektedir.

YSA için girdi ve çıktı arasındaki ilişkiyi en iyi şekilde elde edilmesi öğrenme algoritması gerçekleşmektedir. Öğrenme algoritması eğitim, geçerlilik ve test gibi aşamalardan oluşmaktadır. En önemli özelliği, bilgi kaynağından öğrenebilme yeteneği sağlamaktır. Ağırlıkların en iyi değerinin bulunması işlemi olarak geçmektedir ve başlangıçta bu ağırlıklar rastgele olarak seçilir. Burada amaç, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmaktır. Ağın doğru ağırlık değerlerine ulaşması örneklerin temsil ettiği olay hakkında

genellemeler yapabilme yeteneğine kavuşması demektir. Bu genelleştirme özelliğine kavuşması işlemine ağıın öğrenmesi denir. YSA'nın eğitiminde en iyi öğrenme algoritması için geliştirilen sezgisel algoritmalar da kullanılmaktadır.

YSA'lar genel olarak girdi, gizli ve çıktı olmak üzere üç katmandan oluşmaktadır. Girdi katmanı, dış ortamdan nöron ve giriş bilgilerinin aktarıldığı katmandır. Burada bilgiler ağırlıklar vasıtasıyla gizli katmana aktarılmaktadır. Gizli katman da aktarılan bilgileri aktivasyon fonksiyonundan geçerek çıktı tabakasına gönderilmektedir. Çıktı katmanı girdi tabakasından gelen ve işleme tabi tutulan bilgiyi dışa aktaran katmandır.

YSA'lar nöronları içeren tabakalardan meydana gelmektedir. Tabakalarda nöronlar bir ya da birden fazla sayıda bulunabilirler. Tabaka sayısına göre YSA mimarisi sınıflanabilir. Bu katmalar tek tabakalı ve çok tabakalı sinir ağıları başlıkları altında toplanır. Tek tabakalı YSA, bir girdi katmanı ve bir çıktı katmanını içermektedir. Girdi katmanından herhangi bir işleme uğramadan çıktı tabakasına iletilir ve tüm hesaplamalar çıktı katmanında gerçekleşir. Çok tabakalı YSA ise girdi ile çıktı katmanı arasında bir ve ya birden fazla gizli katmana sahiptir. Girdi katmanından giren veri çıktı katmanına gitmeden önce gizli katmanda işleme tabi tutulur. Aradaki gizli tabaka bir tane olabileceği gibi birden fazlada olabilmektedir.



Şekil 4.2: Çok tabakalı YSA mimarisi

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 ifade etmektedir. Nöronlar birbirlerine ağırlıklarla bağlıdır ve nöronlar arasında bağlantı yoktur. Şekilde çıktı tabakasında sadece bir nöron bulunmaktadır. Ama probleme ya da isteğe göre birden çok nöron da kullanılabilir.

4.1. Pi-Sigma Yapay Sinir Ağı


Pi-Sigma terimi, birimlerin bir toplam ve çarpma işlemi boyunca işlenmesidir. 1991 yılında Shin ve Ghosh tarafından Pi-Sigma yapay sinir ağı (PS-YSA) önerilmiştir. PS-YSA'da ağıın çıktısı girdilerin farklı doğrusal kombinasyonlarının çarpımından oluşmaktadır. PS-YSA derecesi ise lineer kombinasyonların sayısıdır. PS-YSA'nın derecesinin artırılması, girdi ile çıktı arasındaki ilişkiyi tanımlayan fonksiyonun daha fazla parametreye bağlı olmasına neden olur. Bu da daha karmaşık bir yapıyı oluşturmaktadır. Bununla birlikte, fazla parametrelerle çalışmak, aşırı tahmin (overfitting) sorununa ve eğitim algoritması için daha fazla hesaplama süresine neden olmaktadır. Bu nedenle PS-YSA için çapraz geçerlilik yöntemleri kullanılarak, ağıın ezberlemeden öğrenmesine dikkat edilmelidir (Eğrioğlu, 2020).

Literatürde PS-YSA'yı kullanan birçok çalışma bulunmaktadır. Bu çalışmalar geliştirilen yöntem ve kullandıkları yapay zeka optimizasyonları gibi birçok farklı PS-YSA yöntemi geliştirilmiştir. PS-YSA'na ait özet ampirik bulgular aşağıda yer almaktadır.

Tawfik ve Liatsis (1997), Ghazali ve ark. (2006), Ghazali ve ark. (2008) çalışmalarında PS-YSA kullanmışlardır. Kuo-Chien (2002), bellek tabanlı bir Pi-Sigma (memory based -SPNN) algoritması ileri sürmüştür. Yong ve Wei (2008) melez bir genetik algoritma eğitilmiş PS-YSA önermişlerdir. Ghazali ve Jumeily (2009) finansal zaman serileri tahmini için PS-ANN ile polinom sinir ağını (polynomial neural networks) uygulamışlardır. Husaini ve ark.. (2011, 2012, 2014) çalışmalarında sıcaklık tahmini için PS-YSA kullanmışlardır. Nayak ve ark. (2014b) parçacık sürü optimizasyonu (PSO) ve genetik algoritmanın (GA) birlikte

kullanıldığı PS-YSA algoritması ortaya koymuşlardır. Hussain ve Liatsis (2003), Ghazali ve ark. (2014) çalışmalarında tekrarlayan PS-YSA (recurrent Pi-Sigma neural networks- R-PS-ANN) geliştirmişlerdir. Nayak ve ark. (2015), PSO ve gradyan inişe dayalı melez bir öğrenme PS-YSA modeli önermişlerdir. Mohamed ve ark. (2016), PS-YSA eğitimi için toplu gradyan yöntemini kullanmışlardır. Eğrioğlu ve ark. (2017) tarafından yapılan çalışmada çarpımsal nöron modeli ile medyan nöron modelini kullanarak yeni bir medyan-PS-YSA (Median-Pi artificial neural network- MdPNN) modeli geliştirmişlerdir. Dash ve ark. (2018), altın fiyat tahmini için evrimsel algoritmalar (evolutionary algorithms- PS-ANN) dayalı bir PS-YSA modeli çalışmışlardır. Deepa ve ark. (2018), multimodal tümör veri analizi için biyo-ilhamlı sürü zekası optimizasyon algoritmasına (bioinspired swarm intelligence optimization algorithm- PS-ANN) dayalı bir yöntem uygulamışlardır. Baş ve ark. (2018), PS-YSA kullanan yüksek mertebeden bulanık zaman serileri tahminleri için bulanık ilişkilerin belirlenmesinde yeni bir yöntem önermişlerdir. Ayrıca PS-YSA eğitiminde motive edilmiş PSO yöntemini kullanmışlardır. Akdeniz ve ark. (2018) tarafından yapılan çalışmada otoregresif hareketli ortalama (ARMA) tipli PS-YSA (ARMA type Pi-Sigma artificial neural network for nonlinear time series- ARMATPS-ANN) geliştirmişlerdir. Ayrıca PS-YSA modelinde hem zaman serisinin gecikmeli değişkenlerini hem de hata terimlerinin gecikmeli değişkenini kullanan YSA modeli kullanmışlardır. Koçak ve ark. (2019), ARMA tipi tekrarlayan PS-YSA dayalı yeni bir bulanık zaman serisi (new fuzzy time series algorithm based on an ARMA-type recurrent Pi-Sigma artificial neural network- FTS-ARMATPS-ANN) algoritması geliştirmişlerdir. Pattanayak ve ark. (2020) çalışmalarında PS-YSA ile melez kimyasal reaksiyon optimizasyonunu (hybrid chemical reaction optimization with PS-ANN) kullanarak çok adımlı bir bulanık zaman serisi için elde etmişlerdir. Nayak ve Ansari (2020), hisse senedi tahmini için PS-YSA'de işbirlikli optimizasyon (cooperative optimization algorithm in PS-ANN) algoritmasını kullanmıştır. Panda ve Majhi (2020), PS-YSA eğitimi için uzay dönüşümsel arama ile geliştirilmiş benekli sırtlan iyileştirici modeli uygulamıştır. Yılmaz ve ark. (2021), PS-YSA eğitimi için diferansiyel evrim algoritmasını (DEA-PS-ANN) uygulamışlardır.

K . dereceden N girdili bir PS-YSA mimarisi aşağıdaki şekilde verilmiştir. Burada x_i girdileri ($i = 1, 2, \dots, n$) göstermektedir. Girdi birimlerinin doğrusal kombinasyonları w_{ij} ($i = 1, 2, \dots, N, j = 1, 2, \dots, K$) ağırlıkları ve θ_j ($j = 1, 2, \dots, K$) yanları ile elde edilmektedir. w_{ij} , i . girdiden j . gizli tabaka birimine giden ağırlığı, θ_j ise j . gizli tabaka birimi için yan değerini göstermektedir (Eğrioğlu va ark. 2020).



Şekil 4.3: Pi-Sigma YSA mimarisi

Gizli tabaka birim sayısı kadar doğrusal kombinasyon, doğrusal aktivasyon fonksiyonundan geçerek gizli tabakaların çıktılarını oluşturmaktadır. h_j j . gizli tabaka biriminin çıktısını gösterir ve aşağıdaki formül ile hesaplanır.

$$h_j = f_1 \left(\sum_{i=1}^N w_{ij} x_i + \theta_j \right), j = 1, 2, \dots, K \quad (4.1)$$

Burada $f_1(x) = x$ şeklinde doğrusal aktivasyon fonksiyonunu göstermektedir. Ağın çıktısı ise $f_2(x) = \frac{1}{1+\exp(-x)}$ lojistik aktivasyon fonksiyonu olmak üzere aşağıdaki formül ile hesaplanır.

$$\hat{y} = f_2 \left(\prod_{j=1}^K h_j \right) = \frac{1}{1+\exp(-\prod_{j=1}^K h_j)} \quad (4.2)$$

4.2. Parçacık Sürü Optimizasyonu

YSA'nın en önemli aşamalarından biri ağı eğitilmesidir. YSA'nın eğitiminde öğrenme tekniklerinin yanı sıra sezgisel optimizasyon yöntemleri de kullanılmaktadır. Bu optimizasyon yöntemleri için farklı eğitim algoritmaları önerilmiştir. Günümüzde en yaygın olarak; parçacık sürü optimizasyonu (particle swarm optimization - PSO), genetik algoritma (Genetic algorithm - GA), diferansiyel gelişim algoritması (differential evolution algorithm - DEA), yapay arı kolonisi (Artificial bee colony algorithm - ABC), karınca kolonisi optimizasyonu (ant colony optimization - ACO) gibi yöntemler kullanılmaktadır. Son yıllarda sıklıkla kullanılan optimizasyon algoritmaları tatmin edici sonuçlar ortaya koymaktadır.

Ampirik literatür incelendiğinde basitliği ve yüksek çözüm kalitesi iyiliği ile yaygın bir kullanım alanına sahip olan parçacık sürü optimizasyon algoritmasıdır. Parçacık sürü optimizasyonu ilk kez Kennedy ve Eberhart (1995) tarafından önerilmiştir. Sürü halinde yaşayan kuş sürülerinin sosyal hayatından esinlenerek geliştirilen sezgisel optimizasyon yöntemi olarak bilinmektedir. Sürü kavramıyla popülasyon, parçacık kavramıyla da popülasyondaki bireyler yani sürüdeki kuşlar temsil edilmektedir. Böylece gerçek hayat problemlerinin çözümünde pratik yol sağlamaktadır. Ayrıca klasik optimizasyon tekniklerinden farklı bir özellik olarak türev bilgisine ihtiyaç duymaması PSO'yu daha kullanışlı bir optimizasyon yapmaktadır.

Literatürde PSO'yu kullanan birçok çalışma bulunmaktadır. Bu çalışmalar geliştirilen yöntem ve kullandıkları yapay zeka optimizasyonları gibi birçok farklı PSO için melez yöntem kullanılmıştır. PS-YSA'na ait özet ampirik bulgular aşağıda yer almaktadır.

Wang ve ark. (2004), PSO tekniği ile QSAR (Quantitative structure-activity relationship) modellerinin inşası için geri yapay sinir ağı (back propagation neural network) kullanılmıştır. Ma ve ark. (2012) gelişmiş bir karma tekrarlayan sinir ağı modeline ve daha basit bir PSO'ya dayalı bir model sunmuşlardır. Wang ve ark. (2013) Elman tipi tekrarlayan sinir ağlarının eşzamanlı yapısı ve parametre

öğrenmesi için PSO kullanan yeni bir melez optimizasyon algoritması önermişlerdir. Eğrioğlu ve ark. (2014), doğrusal olmayan zaman serisi tahmini için tekrarlayan çoklu nöron modeli yapay sinir ağlarının eğitimi için PSO kullanmışlardır. Moalla ve ark. (2017), uzun kısa süreli bellek (Long Short-Term Memory- LSTM) ve PSO'yu birleştiren karma bir yaklaşım ileri sürmüşlerdir. Akdeniz ve ark. (2018), tekrarlayan Pi-Sigma yapay sinir ağının eğitimi için PSO kullanmıştır. İbrahim ve El-Amary (2018), PSO ile eğitilmiş tekrarlayan sinir ağı (recurrent neural network- RNN) modeli sunmuşlardır. Yao ve ark. (2018), PSO tabanlı bir LSTM önermişlerdir. Kim ve Cho (2019), PSO tabanlı bir uzun kısa süreli bellek ile evrimsel sinir ağları (convolutional neural network- CNN-LSTM) yöntemi sunmuşlardır. Shao ve ark. (2019), nikel-metal fiyat tahmin için LSTM-YSA ile geliştirilen PSO'ya dayalı bir model önermişlerdir. Baş ve ark. (2021), PSO'nu kullanarak basit tekrarlayan derin yapay sinir ağı (simple recurrent deep artificial neural network) modelini geliştirmiştir.

Parçacık sürü optimizasyonu, sürü halindeki parçacıkların genel hareketinden faydalanan bir yaklaşımdır. Sürü ve parçacık sırasıyla popülasyon ve popülasyondaki bireyler olarak ifade edilmektedir. Parçacıklar arama uzayı içerisinde olup her bir parçacığın pozisyonu kendisinin ve komşularının tecrübelerine göre belirlenmekte ve her bir parçacığın pozisyon bilgisi bir çözümü göstermektedir. Parçacığın pozisyon değiştirme miktarı ise parçacığın hızını vermektedir. Uygunluk fonksiyonuna bağlı olarak her bir parçacığın pozisyon değeri ile karar verilir. Bütün parçacıklar kendi keşfettikleri en iyi pozisyon değerini ve sürüde keşfedilen en iyi pozisyon değerine sahip parçacığı referans alarak çözüme ulaşmaya çalışırlar (Cağcağ Yolcu, 2013).

PSO, bir grup rastgele çözümle (parçacık sürüsü) başlatılır ve güncellemelerle optimum çözüm bulunmaya çalışılır. Her iterasyonda parçacık konumları, iki en iyi değere göre güncellenir. İlki; o ana kadar parçacığın elde ettiği en iyi çözümü sağlayan koordinatlardır. Bu değer "*pbest*" olarak adlandırılır ve hafızada saklanmalıdır. Diğer en iyi değer ise, popülasyonda o ana kadar tüm parçacıklar tarafından elde edilen en iyi çözümü sağlayan koordinatlardır. Bu değer global en iyidir ve "*gbest*" ile gösterilir. Örneğin, D adet karar değişkeninden oluşan bir

optimizasyon probleminin çözümü için n adet parçacık olduğunu varsayalım. Bu durumda popülasyon parçacık matrisi eşitlik 4.3 gibi olacaktır.

$$x = \begin{bmatrix} x_{11} & x_{12} & \cdots & \cdots & x_{1D} \\ x_{21} & x_{22} & \cdots & \cdots & x_{2D} \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ \cdots & \cdots & \cdots & \cdots & \cdots \\ x_{n1} & x_{n2} & \cdots & \cdots & x_{nD} \end{bmatrix}_{n \times D} \quad (4.3)$$


Matrise göre i 'inci parçacık $x_i = [x_{i1}, x_{i2}, \dots, x_{iD}]$ olarak ifade edilir. Önceki en iyi uygunluk değerini veren i 'inci parçacığın pozisyonu $pbest_i = [p_{i1}, p_{i2}, \dots, p_{iD}]$ olarak ifade edilir. $gbest$ ise her iterasyonda tüm parçacıklar için tektir ve $gbest = [p_1, p_2, \dots, p_D]$ şeklinde gösterilir. i 'inci parçacığın hızı $v_i = [v_{i1}, v_{i2}, \dots, v_{iD}]$ olarak ifade edilir. İki en iyi değer bulunmasından sonra $(k + 1)$ 'inci iterasyondaki parçacık hızları ve konumları aşağıda verilen denklemlere göre güncellenir.

$$v_{ij}^{k+1} = w \times v_{ij}^k + c_1 rand_1^k [pbest_{ij}^k - x_{ij}^k] + c_2 rand_2^k [gbest_j^k - x_{ij}^k] \quad (4.4)$$

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1} \quad (4.5)$$

İlk denklemde c_1 bilişsel (cognitive) ve c_2 sosyal (social) katsayılar olarak tanımlanır ve her parçacığı $pbest$ ve $gbest$ pozisyonlarına doğru çeken, olasılıksal hızlanma terimlerini ifade eden sabitler olarak ifade edilmektedir. c_1 katsayısı parçacığın kendi tecrübelerine göre hareket etmesini, c_2 katsayısı ise sürüdeki diğer parçacıkların tecrübelerine göre hareket etmesini sağlamaktadır. Katsayılar için düşük değerler seçilmesi parçacıkların hedef bölgeye doğru toplanmadan daha uzak yerlerde dolaşma imkânı sunarken hedef bölgeye ulaşma süresini uzatabilir. Yüksek değerler seçilmesi ise hedefe ulaşmayı hızlandırır ama beklenmedik hareketlerin oluşmasına ve hedef bölgenin es geçilmesine sebep olabilir. Bu iki katsayı için birçok çalışma bulunsa da Kennedy ve Eberhart (1999) tarafından yapılan çalışmada $c_1 = c_2 = 2$ alınmış ve iyi sonuçlar elde edildiği belirtilmiştir. Denklemdeki $rand_1$ ve $rand_2$, $[0,1]$ arasında düzgün dağılımlı rastgele sayılardır. k ise iterasyon sayısını belirtmektedir.

Klasik PSO algoritmasının akış diyagramı aşağıda verilmiştir.



Şekil 4.4: PSO'nun akış şeması

PSO parametreleri ve bazı tipik değerleri şu şekilde sıralanabilir (Cağcağ Yolcu, 2013);

- Parçacık sayısı, 20-40 arasında olmaktadır. Bazı problemler için 10 parçacık yeterli olurken bazıları için ise 100 veya 200 parçacık kullanılabilir.
- Parçacık boyutu, optimize edilecek probleme göre değişiklik göstermektedir
- Parçacık aralığı, optimize edilecek probleme göre değişmekle birlikte farklı boyutlarda ve aralıklarda parçacıklar tanımlanabilir.

- Parçacık pozisyonu, x_k^i ile gösterilip problem d boyutlu ise i . parçacığın pozisyon vektörü $x_k^i = [x_{i1}^k, x_{i2}^k, x_{i3}^k, \dots, x_{id}^k]$ şeklinde belirlenmektedir. Bu formüldeki k iterasyon sayısını ifade etmektedir. Örneğin; x_{i2}^k , k . iterasyonda i . parçacığın pozisyon vektöründeki ikinci değeri olarak ifade edilir.
- Parçacık hızı, parçacığın bir sonraki pozisyonuna ulaşması ve $v_i^k = [v_{i1}^k, v_{i2}^k, v_{i3}^k, \dots, v_{id}^k]$ ile ifade etmektedir. Örneğin; v_{i2}^k , k . iterasyonda i . parçacığın hız vektöründeki ikinci değeri olarak ifade edilir.
- v^{max} , bir iterasyondaki parçacığın maksimum değişikliği (hız) belirler ve genellikle parçacık aralığına göre hesaplanır.
- Hızlandırma katsayıları, c_1 parçacıkların $pbest$ değerine, c_2 ise $gbest$ değerlerine doğru çekilmesini kontrol eden katsayılardır.
- Uygunluk fonksiyonu, parçacığın pozisyon vektörünü kullanarak ve varsa problemle ilgili kısıtlamaları da göz önüne alarak uygunluk değeri üreten bir fonksiyondur.
- Kişisel en iyi değer yani $pbest$ parçacığın iterasyondaki en iyi çözüme ulaşmayı amaçlar. Parçacık, önceki pozisyon değerlerini ve yeni iterasyondaki pozisyon değerini karşılaştırır. Eğer yeni pozisyon değeri, öncekilere göre optimum sonuca daha yakın ise en iyi konum olarak belirlenir $p_{best} = [p_{i1}, p_{i2}, \dots, p_{id}]$ olarak tanımlanır. Örneğin; p_{i2} , i . pozisyondaki en iyi vektörün ikinci değerini göstermektedir.
- Global en iyi değer yani $gbest$ sürüdeki tüm parçacıkların konum değerleri karşılaştırıldığında en iyi uygunluğa sahip parçacığın konum değeridir. Her iterasyonda $gbest$ değeri değişebilir veya aynı kalabilir.
- Durdurma koşulu, kullanıcı tarafından belirlenen iterasyon sayısına göre veya istenilen hata seviyesine ulaşılması durumunda gerçekleştirilir. Ayrıca son iki iterasyondaki farklı $gbest$ değerleri arasındaki farkın belirli bir tekrar sayısında yeterince küçük bir seviyenin altına düşmesi de PSO'yu durdurmak için bir ölçüt olabilir.

BÖLÜM 5. ÖNERİLEN YÖNTEMLER


5.1. Yeni Bir Melez Pi-Sigma Sinir Ağı

Literatürde, MLP'ler genellikle toplama işlevini kullanırken, Yadav tarafından önerilen tek çarpımsal sinir ağı, çarpımsal işlev kullanır. Klasik bir PS-YSA'da girdilerin lineer fonksiyonlarının çarpımı elde edilse de bu modeldeki her lineer fonksiyonun 1 değerinde sabit bir katsayıya sahip olması dikkat çekicidir. Ancak girdilerin her bir doğrusal fonksiyonu çıktı üzerinde farklı etkilere sahip olabilir. Bu nedenle, bunlar farklı ağırlıklarla temsil edilmelidir.

Bu bağlamda, bu lineer fonksiyonların farklı katsayılarla çarpma fonksiyonuna tabi tutulduğu yeni bir melez PS-YSA yapısı önerilmiştir. Bu yeni yapı, klasik MLP ve tek çarpımsal nöron modelinin bir melezi olarak düşünülebilir. Bu yeni yapı, sadece klasik PS'nın özelliklerini değil, kendine has özellikleri de barındırıyor. Melez PS-YSA (MPS-YSA), tıpkı klasik pi sigma sinir ağları gibi, birçok giriş katmanı değişkeni için verimli polinomlar kullanarak ağ karmaşıklığını azaltan hızlı öğrenme yeteneğine sahiptir.

MPS-YSA'nın temel yapısı giriş, gizli ve çıkış katmanları olmak üzere üç katmana sahiptir. Gizli katmanda bulunan birimlerin toplamından elde edilen lineer kombinasyonların sayısı MPS-YSA derecesini temsil eder. Hem toplama hem de çarpma işlevlerine sahip olması, bu modeli daha esnek ve uyarlanabilir kılan ana özellikleridir.

N girişli ve K 'inci dereceden bellek tabanlı bir MPS-YSA yapısı şekilde verilebilir.



Şekil 5.1: Genel modelleme için tasarlanmış MPS-YSA yapısı

Bu yapıda w_{ij} ($i = 1, 2, \dots, K; j = 1, 2, \dots, N$) j^{th} giriş katmanı nöronu ile i^{th} gizli katman nöronu arasındaki ağırlığı temsil eder. b_i ($i = 1, 2, \dots, K$), i^{th} gizli katman nöronu için yandır. w_i ($i = 1, 2, \dots, K$) j^{th} girdi katmanı nöronu ile çıktı katmanı nöronu arasındaki ağırlığı temsil eder. Son olarak, b_o , çıktı katmanı nöronunun yanıdır. Klasik PS-YSA'da, gizli ve çıkış katmanları arasındaki ağırlık dikkate alınmaz, sadece 1'e eşit bir sabit olarak kabul edilir. Ancak, önerilen MPS-YSA, bu ağırlıkları 1 almak yerine farklı olarak ele alır. Girdilerin lineer fonksiyonlarının çıktıları üzerindeki farklı etkileri bir optimizasyon süreci ile elde edilir. Gizli katman nöronlarının çıktıları Denklem 5.1 ile elde edilir.

$$o_i = f_1\left(\sum_{j=1}^N w_{ij}X_j + b_i\right), i = 1, 2, \dots, K \quad (5.1)$$

Burada f_1 lineer aktivasyon fonksiyonunu temsil eder ve $f_1(x) = x$ 'dir. Gizli ve çıkış katmanları arasındaki ağırlıklar kullanılarak, denklem 5.2'de verilen formülde olduğu gibi sistemin çıktıları elde edilir.

$$o_{\text{MPS-YSA}} = \hat{Y} = f_2((\prod_{i=1}^K o_i * w_i) + b_o) = \frac{1}{1 + \exp(-((\prod_{i=1}^K o_i * w_i) + b_o))} \quad (5.2)$$

Denklem 5.2'deki f_2 , lojistik aktivasyon fonksiyonudur.

5.2. Yeni Bir Sezgisel Bulanık Zaman Serisi Tahmin Modeli

Bulanık zaman serisi yöntemlerinin tahmin yaklaşımlarının tahmin performansını olumlu etkilediği bilinen bir gerçek haline gelmiştir. Bununla birlikte, diğer taraftan birçok durumda, bulanık kümeler, verilerin belirsizliğini kapsamlı bir şekilde tatmin edemez veya karakterize edemez. Çünkü bu çalışmalarda zaman serilerinin tarafsızlık derecesi dikkate alınmamaktadır. Bu bağlamda temel amacımız, bu çalışmada yeni bir sezgisel bulanık zaman serisi tahmin modeli önermektir. Bu model, kendi özel analiz süreci sayesinde zaman serilerinin önemli özelliklerini çıkararak göze çarpan (dikkate değer) tahmin sonuçları üretebilir.

Bazı güncel tahmin modelleri ile karşılaştırıldığında, önerilen yeni sezgisel bulanık zaman serisi tahmin modelinin temel katkıları aşağıdaki gibi verilebilir;

- Bu çalışma, üye ve üye olmama değerlerin birleşimine dayalı yeni bir sezgisel bulanık zaman serisi modeli olarak adlandırılmıştır.
- MPS-YSA, önerilen modelin girdileri ve çıktıları arasındaki doğrusal olmayan ilişkileri belirlemek için literatürde ilk kez sunulmuştur.
- Bu modelde üye, üye olmama değerleri ve çıktıları arasındaki sezgisel bulanık ilişkiler MPS-YSA tarafından belirlenir.
- Çalışmada, sezgisel yapının faydaları dikkate alınarak hem üyelik değerlerinin hem de üye olmama değerlerinin sisteme katkısı ayrı ayrı değerlendirilmiştir.
- Bulanık kümeleri ve üyelik değerlerini belirleyebilmek için SBCO yapılır.

- MPS-YSA'nın optimal parametreleri MPSO aracılığıyla elde edilir.
- Sistemin nihai çıktıları, iki farklı MPS-YSA'dan elde edilen sonuçların birleştirilmesiyle elde edilir.

Bu bilgiler ışığında önerilen yöntemin algoritması bazı adımlarla özetlenmiştir:

Adım 1. (Sürecin) tüm gereklilik parametreleri belirlenir.

pn	: # sürünün parçacıkları
$maxitr$	: Maksimum yineleme sayısı
(c_{1i}, c_{1f})	: Bilişsel katsayıların olası değerleri için aralıklar (c_1).
(c_{2i}, c_{2f})	: Olası sosyal katsayı değerleri için aralıklar (c_2).
(w_1, w_2)	: Ağırlığın olası değerleri için aralıklar (w).
m_1	: # ilk melez MPS-YSA için gecikmeli net değişkenler
m_2	: # ikinci MPS-YSA için gecikmeli net değişkenler
K_1	: İlk hibrit MPS-YSA'nın sırası
K_2	: İkinci MPS-YSA'nın sırası
t_{train}	: Eğitim testinin uzunluğu
t_{test}	: Test setinin uzunluğu
c	: # sezgisel bulanık kümeler
T	: # zaman serisi gözlemleri

Adım 2. SBZS kümeleme algoritması gerçekleştirilir. Bu adımda eğitim veri seti için küme merkezleri, üye ve üye olmama değerleri elde edilir. Ve elde edilen bu değerler MPS-YSA'ların girişleri için kullanılır. Küme numaraları $L_l, (l = 1, 2, \dots, c)$ ile temsil edilir. SBZS sürecinin sonunda üye ve üye olmama değerleri S_1 ve S_2 matrislerinde saklanır. Küme merkezleri C vektöründe düzenlenir.

$$S_1 = [\mu_{lt}], l = 1, 2, \dots, c ; t = 1, 2, \dots, t_{train} \quad (5.3)$$

$$S_2 = [v_{lt}], l = 1, 2, \dots, c ; t = 1, 2, \dots, t_{train} \quad (5.4)$$

$$C = [c_1, c_2, \dots, c_c] \quad (5.5)$$

Burada S_1 ve S_2 matrisi, L_l bulanık kümeye ait zaman serisi gözlemlerinin üyelik ($\mu_{L_l}(y_t)$) ve üyelik dışı ($\nu_{L_l}(y_t)$) değerlerini göstermektedir.

Adım 3. MPS-YSA'lar için girişler (I_1, I_2) ve hedefleri (targets) oluşturmaktır. Bu çalışmada, gözlemlerin üyelik ve gecikmeli değişkenleri ile gözlemlerin üye olmama değişkenleri ve gecikmeli değişkenleri iki ayrı girdi grubu olarak ele alınmıştır. Oluşturulan bu girdiler ayrıca iki farklı MPS-YSA için ayrı ayrı kullanılır. MPS-YSA'nın girdileri aşağıdaki gibi iki matrisle (I_1 ve I_2) verilebilir:

$$M_1 = [S_1, y_{t-1}, \dots, y_{t-m_1}], t = m_1 + 1, \dots, n - t_{train} \quad (5.6)$$

$$M_2 = [S_2, y_{t-1}, \dots, y_{t-m_2}], t = m_2 + 1, \dots, n - t_{train} \quad (5.7)$$

Bu aşamada kullanılan iki sinir ağı için ayrı bir hedef yoktur. Bu iki ayrı sinir ağı tarafından üretilen çıktıların birleştirilmesiyle elde edilecek nihai çıktıya karşılık gelen tek bir hedef değer vardır. Ve tahmin modelinin hedefi aşağıdaki gibi verilebilir:

$$T = y_t, t = q + 1, \dots, t_{train} \quad (5.8)$$

Adım 4. Parçacıkların yapısının belirlenmesidir. Optimizasyon sürecinin ilgili konumlarının tahmin modeline ait bazı özellikleri Tablo 5.1'de verilebilir.

Tablo 5.1: Optimizasyon sürecinin özellikleri

Sinir Ağları	# Girdiler	# Çıktı	# Ağırlıklar (girdi- ağırlıkları)	# Yanlar (girdi- yanları)	# Ağırlıklar (çıktı- ağırlıkları)	# Yanlar (çıktı- yanları)	# Kombinasyon
MPS-YSA1	$(m_1 + c)$	1	$(m_1 + c) * K_1$	K_1	K_1	1	1
MPS-YSA2	$(m_2 + c)$	1	$(m_2 + c) * K_2$	K_2	K_2	1	1
Toplam Parametreler		$p = ((m_1 + c) * K_1 + (m_2 + c) * K_2 + 2K_1 + 2K_2 + b_1 + b_2 + 2)$					

Bu aşamada, başlangıç konumları ve hızları üretilerek parçacık yapıları elde edilir. Parçacıkların konumları ve hızları, $Uniform(-1,1)$ dağılımından rastgele oluşturulur, P ve V matrislerinde depolanır:


$$P = [p_{rs}]; r = 1, 2, \dots, pn; s = 1, 2, \dots, p \quad (5.9)$$

$$V = [v_{rs}]; r = 1, 2, \dots, pn; s = 1, 2, \dots, p \quad (5.10)$$

Adım 5. MPS-YSA çıkışlarının hesaplanmasıdır. MPS-YSA'nın her biri parçacıkların konumları dikkate alınarak her parçacık için çıktılar elde edilir. Önerilen yeni sezgisel bulanık zaman serisi tahmin modelinin grafiksel özeti Şekil 5.2 ile verilebilir.

Gizli katmanın her bir nöronundaki bilgiyi temsil eden girdilerin doğrusal kombinasyonları, ağırlıklar (w_t^{ij} ve w_t^{il}) ve yanlar (b_t^i) kullanılarak elde edilir. Klasik PS-YSA da gizli ve çıkış katmanları arasındaki ağırlık dikkate alınmazken sadece 1'e eşit bir sabit olarak kabul edilir, önerilen bu çalışmada ise MPS-YSA çıktılarının elde edilebilmesi için ağırlıklar ve yanlar tek bir optimizasyon sürecinde belirlenmiştir. Daha sonra MPS-YSA 1 (üyelik kısmı için) için gizli katman nöronlarının çıktıları Denk. 5.11 ile elde edilir.

$${}^{\mu}o_i^l = f_1 \left(\left(\sum_{l=1}^c {}^{\mu}w_t^{il} \mu_{L_l} \right) + \left(\sum_{j=1}^{m1} {}^{\mu}w_t^{ij} Y_{t-j} \right) + b_t^i \right), i = 1, 2, \dots, K_1 \quad (5.11)$$



Şekil 5.2: SBZS tahmin modelinin grafiksel özeti

MPS-YSA 1'in çıktıları, tüm gizli katmanların çıktılarının, gizli ve çıktı katmanları arasında belirlenen ağırlıklarla çarpılmasıyla elde edilir. İlk MPS-YSA'ya ait çıktının formülü Denklem 5.12 ile hesaplanabilir.

$$o_t^{MPS-YSA_1} = \mu \hat{y}_t = f_2\left(\prod_{i=1}^{K_1} \mu o_i^i \mu w_t^i\right) = \frac{1}{1 + \exp\left(-\prod_{i=1}^{K_1} \mu o_i^i \mu w_t^i\right)} \quad (5.12)$$

MPS-YSA 2 (üye olmayan kısım) için benzer işlemler yapılır ve çıktılar ($o_t^{MPS-YSA_2} = v \hat{y}_t$) elde edilir. Sistemin nihai çıktısı, yani t zamanındaki gözlemin tahmini, bu iki farklı MPS-YSA'nın çıktılarının ağırlıklandırılmasıyla elde edilir. Bu birleşik çıktı Denklem 5.13'deki gibi hesaplanır.

$$\hat{Y}_t = w_1 o_t^{\text{MPS-YSA}_1} + w_2 o_t^{\text{MPS-YSA}_2} = w_1 \mu \hat{Y}_t + w_2 \nu \hat{Y}_t \quad (5.13)$$

Her iki MPS-YSA için gizli katman nöronlarında lineer aktivasyon fonksiyonu $f_1(x) = x$ kullanılmış ve çıkış katmanında lojistik aktivasyon fonksiyonu tercih edilmiştir.

Adım 5. Uygunluk fonksiyonu değerlerinin değerlendirilmesidir. En iyi parçacıkları belirleyebilmek için her parçacığın uygunluk fonksiyonu değerleri elde edilir. Bu çalışmada, bir değerlendirme kriteri veya kayıp fonksiyonu olarak RMSE tercih edilmiştir. Formülü Denklem 5.14'te verilmiştir.

$$RMSE = \sqrt{\sum_{t=\max(m_1, m_2)+1}^{t_{train}} (Hedef_t - Çıktı_t)^2} \quad (5.14)$$

Adım 7. $Pbest$ ve $Gbest$ 'i belirlenir. Parçacıkların her birine ait RMSE değerleri hesaplandıktan sonra $Pbest$ ve $Gbest$ değerlerine karar verilir. $Pbest$ ve $Gbest$ sırasıyla her bir parçacıktan en iyi değerleri temsil eden değerlerdir ve global en iyi değer sırasıyla tüm sisteme aittir. Bu değerler Denk. 5.15 ve 5.16 'da verilebilir.

$$Pbest = [Pb_{rs}]; r = 1, 2, \dots, pn; s = 1, 2, \dots, p \quad (5.15)$$

$$Gbest = [Pg_s]; s = 1, 2, \dots, p \quad (5.16)$$

Adım 8 MPSO'nun parametrelerini güncelleme sürecidir. Bu aşamada güncellenecek parametreler aşağıdaki formüller kullanılarak yeniden elde edilmiştir.

$$c_1 = (c_{1f} - c_{1i}) \frac{itr}{maxitr} + c_{1i} \quad (5.17)$$

$$c_2 = (c_{2f} - c_{2i}) \frac{itr}{maxitr} + c_{2i} \quad (5.18)$$

$$w = (w_1 - w_2) \frac{maxt-itr}{maxitr} + w_2 \quad (5.19)$$

Burada itr geçerli yineleme sayısıdır.

Adım 9. Konumlar ve hızlar güncelenir. Bu aşamada optimal parametrelerin belirlenebilmesi için hız ve konumları Eşitlik 5.20 ve 5.21'de verilen formüller kullanılarak güncellenmesi yapılmaktadır.

$$v_{rs}^{itr+1} = w \cdot v_{rs}^{itr} + c_1 \cdot rand_1^{itr} \cdot (Pbest_{rs}^{itr} - p_{rs}^{itr}) + c_2 \cdot rand_2^{itr} \cdot (gbest_s^{itr} - p_{rs}^{itr}) \quad (5.20)$$

$$p_{r,s}^{itr+1} = p_{r,s}^{itr} + v_{r,s}^{itr+1} \quad (5.21)$$

Adım 10. Durdurma kriterlerinin kontrol edilmesidir. Tahmin sisteminin son aşamasında ise nihai çıktıların alınması gerekmektedir. Bunu gerçekleştirmek için önceden belirlenmiş iterasyon sürelerine ulaşıp ulaşılmadığı kontrol edilir. Tekrar sayısı maksimum yineleme sayısına ($maxitr$) ulaşırsa işlem durur veya sistem, önceden belirlenmiş maksimum yineleme sayısına ($maxitr$) ulaşana kadar Adım 5'ten Adım 9'a kadar tekrarlanır. $maxitr$ değerine ulaşıldığında, $Gbest$ vektörünün elemanları, MPS-YSA'ların ağırlıklarının ve yanlarının optimal değerleri ve birleşim kısmının ağırlıkları olarak belirtilir.

BÖLÜM 6. UYGULAMALAR

6.1. Veri Hazırlama

Önerilen SBZS-TM tahmin modelinin tahmin performansı, iki farklı finansal zaman serisinin analizi ile değerlendirilmiştir; TAIEX ve IEX ve tahmin sonuçlarına dayalı bulgular, önerilen modelin üstün performansının yanı sıra literatüre katkısının somut kanıtı olarak sunulmaktadır.

Son iki aylık döneme ait gözlemler ve son 7 ve 15 gözlem sırasıyla TAIEX ve IEX veri setleri için örneklem dışı (test seti) olarak alınmıştır. Her iki zaman serisine ait verilerin özellikleri Tablo 6.1'de sunulmuştur.

Tablo 6.1:Veri organizasyonunun özellikleri

Seri No	Zaman Serisi	Yıl	Eğitim	Test
1	TAIEX	2000	224	47
2		2001	201	43
3		2002	205	43
4		2003	206	43
5		2004	205	45
6		2009	96	7
7			88	15
8	IEX	2010	97	7
9			89	15
10		2011	99	7
11			91	15
12		2012	99	7
13			91	15
14		2013	99	7
15			91	15

6.2. Performans Ölçüsü

Önerilen SBZSTM'nin tahminleri farklı değerlendirme ölçütleri ile incelenmiştir. Modellerin performanslarını karşılaştırmak için kullanılan çeşitli değerlendirme

ölçüleri dikkate alındığında, tahmin çalışmalarının çoğunda hata kareler ortalamasının karekökü (RMSE) tercih edildiği görülmektedir. RMSE, Denk. (5.14)'deki gibi hesaplanır.

RMSE kriteri, modelleri karşılaştırmada etkili bir değerlendirme kriteri olarak kabul edilse de, tek başına modelin ürettiği tahminlerin doğruluk düzeyi, yani tatmin edici tahmin sonuçları üretilip üretilmediği hakkında net bilgi veremez.

RMSE kriterinden farklı olarak, ortalama mutlak yüzde hata (MAPE) kriteri, veri seti değerlerinin seviyesinden bağımsızdır. Bu özellik, tek başına bir tahmin modelinin performansını değerlendirmede onu üstün kılar. Bu noktadan hareketle, bu çalışmada önerilen modeli farklı açılardan değerlendirebilmek için Denklem 6.1'de verilen MAPE'yi değerlendirme ölçütü olarak seçtik.

$$MAPE = \frac{1}{n_{trn}} \sum_{t=1}^{n_{trn}} \left| \frac{Hedef_t - Çıktı_t}{Hedef_t} \right| \times 100\% \quad (6.1)$$

MAPE yukarıda özetlenen avantajlara sahip olsa da, ortalamaya dayalı bir performans ölçüsüdür, bu nedenle herhangi bir gözlem hatası bir aykırı değer ise yanlış değerler üretir. Böyle bir durumda MAPE yerine aykırı değerlerden etkilenmeyen medyan mutlak yüzde hata (MdAPE) kriterinin kullanılması daha uygundur. Denklem 6.2'de verilen bu kriter de bu gibi durumları dikkate alarak değerlendirilmiştir.

$$MdAPE = medyan \left(\left| \frac{Hedef_t - Çıktı_t}{Hedef_t} \right| \times 100\% \right), t = 1, 2, \dots, n_{trn} \quad (6.2)$$

Diğer yandan sonuçları farklı bir bakış açısıyla değerlendirebilmek için regresyon analizi yapılmaktadır. Tahminler ve hedef değerler için oluşturulan bu regresyon modeli Denklem 6.3'te verilebilir.

$$Y_t = \beta \hat{Y}_t + \varepsilon_t \quad (6.3)$$

Üstün bir tahmin aracı için bu modelin regresyon ve spesifikasyon katsayılarının 1'e oldukça yakın olması beklenir.

Gözlemleri ve tahmin değerlerini gösteren kartezyen koordinatları kullanan dağılım diyagramları, önerilen SBZSTM'nin üstün tahmin performansını görselleştirmek için kullanılır.

6.3. Alternatif Karşılaştırma Modelleri

Çalışmada, önerilen SBZS modelinin tahmin yeteneğinin karşılaştırılması ve yorumlanması için üstün tahmin performansı bilinen çeşitli yöntemler seçilmiştir. TAIEX veri seti için, birçok çalışmanın sonuçları önerilen ile değerlendirilmiştir. Ayrıca IEX için karşılaştırmada kullanılan tahmin araçları aşağıda verilebilir;

ARIMA	: Otoregresif entegre hareketli ortalama yöntemi (Box and Jenkins).
ES	: Üstel Düzgünleştirme
MLP	: Çok katmanlı algılayıcı yapay sinir ağı
SC	: Song ve Chissom'un bulanık zaman serisi tahmin modeli
FF-T1	: Tip 1 bulanık Regresyon fonksiyonu yaklaşımı
FTS-N	: Bulanık zaman serisi ağı
ANFIS	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
MANFIS	: Modifiye Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
AR-ANFIS	: AR yapısı ile Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
I-TSFIS	: Sezgisel zaman serisi bulanık çıkarım sistemi
I-FRF	: Sezgisel bulanık regresyon fonksiyonları yaklaşımı

6.4. Model Performansının Değerlendirilmesi

Önerilen modelin performans kısmının değerlendirilmesinde, modelin üstün tahmin kabiliyetini ortaya koyabilmek için farklı zaman serisi veri setleri seçilmiştir. Veri hazırlama bölümünde de bahsedildiği gibi veri setlerinin her biri eğitim ve test setleri olarak ikiye ayrılmaktadır. Önerilen modelin girdileri sırasıyla üyelikler ve gecikmeli

zaman serilerinden ve gecikmeli zaman serileri ile üye olmamalardan oluşmaktadır. Bunun dışında uygulamaların tüm özellikleri Tablo 6.2'de özetlenebilir.

Tablo 6.2: Uygulamaların özellikleri

Sezgisel Bulanık Küme Sayısı	Gecikmeli Değişken Sayısı (m_1 / m_2)	Gizli Tabaka ve ANN'nin Model derecesi (d_1 / d_2)	Modelin Hedef Sayısı
3-10	2-5	2-5	1

6.4.1. TAIEX Uygulamaları

İlk olarak, önerilen SBZS tahmin modeli ile beş yıla ait günlük TAIEX verileri analiz edilmekte ve elde edilen sonuçlar çeşitli güncel modellerin sonuçları ile birlikte değerlendirilmektedir. Analiz sürecinde zaman serilerinin ilk on aydaki gözlemleri eğitim seti olarak, son iki aydaki gözlemler ise her yıl için test seti olarak alınmıştır. Önerilen modelin girdileri sırasıyla üyelikler ve gecikmeli zaman serilerinden ve gecikmeli zaman serileri ile üye olmamalardan oluşmaktadır.

Karşılaştırma işleminde tüm mimariler arasında en iyi tahmin performansını üreten mimari kullanılmıştır. Ayrıca önerilen SBZS tahmin modelinin ürettiği sonuçlar birlikte değerlendirilmiş ve diğer son teknoloji modellerin sonuçları ile kapsamlı bir karşılaştırma yapılmıştır. Tablo 6.3, tüm sonuçları RMSE kriteri açısından temsil etmektedir.

Tablo 6.3'te verilen bulgular değerlendirildiğinde, önerilen SBZSTM'nin, örneklem dışı veri için RMSE açısından tüm durumlarda iyi bilinen diğer tahmin yöntemlerine kıyasla en iyi tahmin sonuçlarını ürettiği açıkça görülmektedir. Ayrıca her yıl için elde edilen tahmin sonuçları ayrı ayrı incelendiğinde 2000, 2001 ve 2003 yıllarında SBZS-TM 'nin diğer modeller arasında en iyisine göre yaklaşık %20 iyileşme sağladığı görülmüştür. 2002 ve 2004 yıllarında bu iyileştirme oranları %20'yi bile aşmaktadır. Bu durumun temel nedeni, MPSO tarafından eğitilen iki farklı MPS-YSA'dan elde edilen sonuçları birleştiren SBZS-TM'nin hem yerel optimumlara takılma riskinin daha az olması hem de veri setlerinden önemli öznitelikleri

çıkarabilme yeteneğine sahip olmasıdır. RMSE kriterinin ortalama ve medyan istatistikleri, önerilen SBZS-TM'nin üstün performans ürettiği sonucunun bir başka kanıtı olarak görülebilir. Ortalama bir oran olarak, aslında, iyileşme yaklaşık %35'tir.

Tablo 6.3: TAIEX için modellerin tahmin performansları.

Modeller	ZAMAN SERİSİ / TAIEX VERİ SETİ					RMSE	
	2000	2001	2002	2003	2004	Ortalama	Medyan
Song ve Chissom (1993)	293	116	76	77	82	129	82
Chen (1996)	225	116	76	77	82	115	82
Huarng (2001a)	473	359	234	247	384	339	359
Huarng (2001b)	473	810	116	308	384	418	384
Huarng (2006)	133	124	82	62	85	97	85
Hsu ve ark. (2010)	152	130	84	56	116	108	116
Huarng (2007)	154	124	93	66	72	102	93
Yu ve Huarng (2008)	131	130	80	58	67	93	80
Aladağ ve ark. (2010)	168	120	76	58	63	97	76
Chen ve Chang (2010)	129	113	67	54	60	85	67
Chen ve Chen (2011)	124	115	71	58	58	85	71
Chen ve Cheng (2014)	120	114	67	52	52	81	67
Chen ve ark. (2013)	131	113	66	52	54	83	66
Eğrioğlu ve ark. (2010)	255	130	84	56	116	128	116
Yolcu ve ark. (2013)	227	102	66	51	55	100	66
Chen ve Cheng (2014)	126	114	65	54	53	82	65
Chen ve Chen (2015)	125	115	65	53	53	82	65
Cai ve ark. (2015)	132	113	60	52	50	81	60
Baş ve ark. (2015)	140	120	77	60	59	91	77
Cheng ve ark. (2016)	126	113	63	51	54	81	63
Chen ve ark. (2016)	180	134	81	77	55	105	81
Tak ve ark. (2018)	128	106	65	52	54	81	65
Jang (1993)	137	115	66	57	61	87	66
Eğrioğlu ve ark. (2015)	124	112	63	52	54	81	63
Sarıca ve ark. (2018)	123	111	66	52	54	81	66
Eğrioğlu ve ark. (2019)	209	73	22	43	54	80	54
Cağcağ Yolcu ve ark. (2020)	122	110	54	51	50	77	54
Önerilen SBZS-TM	98	60	17	35	40	50	40
İyileşme (%)	18.33	17.81	22.73	18.60	20.00	35.06	25.93

Bir tahmin modelinin üstün tahmin yeteneğini ortaya çıkarmanın bir başka yolu da, tahminler ile reel değerler arasında kurulacak bir lineer regresyon modelinin bazı özelliklerini incelemektir. $Y_t = \beta \hat{Y}_t + \varepsilon_t$ olarak kurulan bir lineer regresyon modelinin regresyon katsayısı ($\hat{\beta}$) ve ayrıca belirleme katsayısının (R^2) 1 veya 1'e oldukça yakın olması istenir. Tablo 6.4, bu regresyon analizi için tüm bulguları

özetlemektedir. Analiz sürecinde gözlenen değerler bağımlı değişken olarak alınırken, tahmin edilen değerler bağımsız değişken olarak kabul edilir.

Tablo 6.4'te verilen bulgular üç farklı açıdan değerlendirilebilir. Farklı yıllara ait tüm zaman serileri için elde edilen beta katsayı tahminleri başarılı bir tahmin modeli için beklendiği gibi 1'e oldukça yakındır. Bu sonuçlar, SBZS-TM tarafından üretilen tahminlerin reel gözlemlere çok yakın olduğunun somut göstergesidir. Ayrıca betanın standart hatası, elde edilen tahminlerin güvenilirliğinin bir ölçüsü olarak düşünülebilir. Çünkü bu değer, regresyon katsayısının örnekten örneğe gösterebileceği değişimin ölçüsüdür. Bu değer, her bir TAIEX veri seti ile ilgili tahminler için çok düşük hatta sıfıra çok yakın olarak elde edilmiştir. Bu, modelin ürettiği tahminlerin oldukça güvenilir olduğunun bir göstergesidir. Ek olarak, belirleme katsayısının 1'e çok yakın olması, tüm veri setleri için önerilen SBZSTM'nin tahminleri ile reel gözlemler arasında çok yüksek doğrusal bir ilişkinin varlığının diğer kanıtıdır.


Tablo 6.4: Doğrusal bir regresyon modelinin özellikleri $Y_t = \beta(\hat{Y})_t + \varepsilon_t$

Zaman Serisi	Model Tahmini	p_F	Standart Hata $\hat{\beta}$	p_β	R^2
1	$Y_t = 1.014310\hat{Y}_t$	2.15E-88	1.79E-03	4.17E-90	0.999857
2	$Y_t = 1.000736\hat{Y}_t$	7.55E-80	1.935E-03	1.53E-81	0.999843
3	$Y_t = 1.000062\hat{Y}_t$	2.87E-101	5.80E-04	1.75E-103	0.999986
4	$Y_t = 0.996021\hat{Y}_t$	1.12E-98	6.68E-04	7.88E-101	0.999981
5	$Y_t = 0.997538\hat{Y}_t$	1.30E-96	9.41E-04	1.32E-98	0.999961


Tüm bu istatistiksel bakış açılarının yanı sıra, önerilen modelin performansını değerlendirmek için dağılım diyagramları da yorumlanabilir. Şekil 6.1'den 6.5'e kadar incelendiğinde dağılım grafiğindeki noktaların çoğunun beklendiği gibi doğru parçasına yakın olduğu görülmektedir. Bu dağılım grafikleri ayrıca gözlemlerin tahminlerle güçlü bir pozitif doğrusal ilişkiye sahip olduğunu göstermektedir. Bu, tahmin değerlerinin gerçek gözlemlere oldukça yakın olduğu anlamına gelir.

MAPE ve MdAPE kriterleri açısından, önerilen yöntemin 2000 ve 2001 yılları için yaklaşık %1 hata ile tahmin sonuçları ürettiği görülmektedir. Ayrıca 2002, 2003 ve 2004 için bu değerler %1'in altında hatta 0,5 civarındadır.


Tüm bu değerlendirme kriterleri ve yaklaşımları dikkate alındığında önerilen SBZS tahmin modelinin TAIEX tahmin literatürü için güçlü ve tercih edilebilir bir aday model olduğu söylenebilir.




Şekil 6.1: 2000 yılı için dağılım grafiği




Şekil 6.2: 2001 yılı için dağılım grafiği



Şekil 6.3 : 2002 yılı için dağılım grafiği



Şekil 6.4: 2003 yılı için dağılım grafiği



Şekil 6.5: 2004 yılı için dağılım grafiği

6.4.2. IEX Uygulaması

SBZS-TM tahmin yeteneğini ortaya çıkarmak için ikinci olarak, 2009'dan 2013'e kadar farklı 5 yılda gözlemlenen günlük IEX verileri değerlendirilmiştir. Analiz sürecinde her yıl için son 7 ve 15 günün gözlemleri test seti olarak alınmıştır. TAIEX veri setlerinin uygulamaları gibi, tüm modellerden elde edilen sonuçlar, tüm modellerin davranışları değerlendirilerek kapsamlı bir şekilde tartışılmıştır. Hem bulanık tabanlı hem de YSA tabanlı modeller, geleneksel zaman serisi tahmin yöntemlerinin yanı sıra karşılaştırma için kullanılmıştır. Modellerin doğruluk hataları RMSE cinsinden Tablo 6.5'te gösterilmiştir.

Tablo 6.5 ışığında, önerilen SBZSTM'nin zaman serisi 9 dışındaki tüm veri setleri için diğer yöntemlerden daha küçük RMSE değerleri üretebildiği açıkça görülmektedir. SBZS-TM, tüm IEX zaman serileri için üstün tahmin performansı üretmiştir.

Öte yandan, önerilen SBZS-TM, tahmin doğruluğundaki iyileştirme oranları açısından değerlendirildiğinde, önerilen modelin dikkate değer iyileştirme oranının vurgulanması gerekmektedir. 10 ve 12 zaman serileri için önerilen SBZS-TM, literatürde önerilen diğer modellere kıyasla %59.12 ve %64.98 gibi olağanüstü bir iyileştirme oranına sahiptir. 13 ve 14 zaman serileri için önerilen model, diğer modeller arasında en iyi modele kıyasla %20'den fazla performans artışı sağlamıştır. Ayrıca 6, 7 ve 8 zaman serilerinde önerilen model, diğer modeller arasında en iyi modele kıyasla %10 civarında bir performans artışı ile dikkat çekici bir performans üretmiştir.


Tablo 6.5: Sonuçların IEX veri setleri için RMSE açısından değerlendirilmesi.

	ZAMAN SERİSİ / IEX VERİ SETİ										RMSE ortalaması
	6	7	8	9	10	11	12	13	14	15	
ARIMA	345	540	1221	1612	1058	1130	651	621	1362	1269	981
ES	345	540	1208	1612	1057	1130	651	621	1362	1269	980
MLP	325	525	1077	1603	920	1096	775	783	1315	1233	965
SC	1402	1754	1128	1742	1396	1360	1292	1047	1450	1931	1450
FF-T1	446	534	1180	1852	1083	1146	1034	1038	1512	1279	1110
FTS-N	267	514	1050	1357	765	917	590	582	786	1208	804
ANFIS	405	647	1141	2033	1007	1134	634	938	1447	1413	1080
MANFIS	261	503	1144	1303	960	1009	634	629	1418	1264	913
AR-ANFIS	240	467	1136	1451	987	999	631	619	1362	1256	915
I-TSFIS	166	1046	250	251	817	384	277	228	451	1106	498
I-FRF	240	507	963	1390	658	994	296	530	690	1172	744
SBZS-TM	152	425	217	360	269	373	97	173	356	1056	348
İyileşme (%)	8.43	8.99	13.20	-	59.12	2.86	64.98	24.12	21.06	4.52	30.1


Önerilen modelin ulaşılan sonuçları ve üstün performansını desteklemek için, hata çizgisini gösteren grafikler Şekil 6.6'dan 6.15'e kadar verilmiştir.

Şekillerde gözlemler ve tahminler arasındaki çizgilerin tüm zaman serileri için oldukça kısa olduğunu göstermektedir. Zaman serisinin her noktası için bir hata ölçüsü olan bu çizgilerin oldukça kısa olması ve birçok noktada gözlem ve tahminlerin neredeyse örtüşüyor olması önerilen modelin üstün tahmin performansının bir başka göstergesidir. Bu grafiklerde sunulan MAPE ve MdAPE kriterlerinin değerleri de model tarafından üretilen tahminlerin doğruluğunun ölçüleridir. Bu ölçümlere dayanarak, önerilen modelin, yaklaşık %1 hata ile tahmin ürettiği 7 ve 15 zaman serileri dışındaki diğer zaman serileri için %0,5'ten daha az hata ile tahminler ürettiği açıkça söylenmektedir. Tahminler ve gözlemler arasında çok yüksek bir doğrusal ilişkinin varlığını yansıtan doğrusal regresyon analizi bulguları da bu grafiklerle sunulmaktadır. Bu bulgulara, başarılı bir tahmin modeli için beklendiği gibi tüm zaman serileri için regresyon ve belirleme katsayıları 1'e oldukça yakındır.


Tüm bu değerlendirme kriterleri ve yaklaşımları dikkate alındığında önerilen SBZS tahmin modelinin IEX tahmin literatürü için güçlü ve tercih edilebilir bir aday model olduğu söylenebilir.




Şekil 6.6: Zaman serisi 6 için uyum grafiği




Şekil 6.7: Zaman serisi 7 için uyum grafiği




Şekil 6.8: Zaman serisi 8 için uyum grafiği




Şekil 6.9: Zaman serisi 9 için uyum grafiği




Şekil 6.10: Zaman serisi 10 için uyum grafiği




Şekil 6.11: Zaman serisi 11 için uyum grafiği




Şekil 6.12: Zaman serisi 12 için uyum grafiği



Şekil 6.13: Zaman serisi 13 için uyum grafiği



Şekil 6.14: Zaman serisi 14 için uyum grafiği



Şekil 6.15: Zaman serisi 15 için uyum grafiği

BÖLÜM 7. SONUÇLAR VE ÖNERİLER

Sezgisel bulanık tabanlı zaman serisi tahmin modelleri, verilerin belirsizliğini kapsamlı bir şekilde karakterize edebildikleri için tatmin edici tahmin sonuçları üretebilir. Bu çalışmada, yeni bir sezgisel bulanık zaman serisi tahmin modeli önerilmiştir. Önerilen model, üyeliklerin ve üyelik olmayanların doğrusal olmayan fonksiyonları olarak bireysel olarak üretilen tahminlerin kombinasyonuna dayanmaktadır. Modelde kullanılan fonksiyon yaklaşım aracı, yine bu çalışmada ilk kez önerilen melez Pi-Sigma sinir ağıdır. TAİEX ve İEX zaman serileri için toplam 15 uygulama gerçekleştirilmiştir. Sonuçlar, önerilen modelin farklı hata kriterleri açısından diğer modellere göre oldukça üstün olduğunu göstermiştir. RMSE hata kriterlerine göre TAİEX zaman serisi için 5 farklı yılda tahmin performansında yaklaşık %20 ilerleme sağlanmıştır. Ayrıca tüm yıllar dikkate alındığında ortalama ilerlemenin %30'un üzerinde olduğu gözlemlenmiştir. İEX zaman serisinin 10 uygulamasından 9'unda, önerilen model tahmin performansını iyileştirmiş ve hatta iki uygulama için (zaman serisi 10 ve 12) yaklaşık %60 ilerleme kaydedilmiştir. Bu 10 analizin tümü dikkate alındığında tahmin performansında ortalama %30'un üzerinde bir iyileşme gözlemlenmektedir. Yüzde hata değeri ölçümleri, MAPE ve MdAPE, toplam 15 analiz için %1 civarında bir değere sahip birkaç analiz dışında %1'in altında ve hatta çoğunda %0,5'in altında elde edilmiştir. Sadece bu kadar düşük MAPE ve MdAPE değerlerinin gözlemlenmesi düşünüldüğünde bile, önerilen SBZSTM'nin üstün tahmin performansı netlik kazanmaktadır.

Bu çalışmanın iki ana unsurundan biri, önerilen sezgisel bulanık zaman serisi olan tahmin modelidir. Diğer, bu tahmin modelinde girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri modellemek için bir fonksiyon yaklaşım aracı olarak tanıtılan önerilen melez Pi-Sigma sinir ağıdır. Önerilen tahmin modeli, üyelik ve üyelik dışı değerlerin tahminler üzerindeki etkilerini ayrı ayrı ele almaktadır. Ayrıca, önerilen MPS-YSA, üyelik ve üyelik dışı değerlerin doğrusal fonksiyonlarının tahminlerin üretilmesinde farklı ağırlıklara sahip olmasına izin verir. Böylece daha

esnek bir hesaplama ve analiz süreci sağlar. Bu, önerilen tahmin modelinin bu kadar üstün tahmin performansı sergilemesinin ana nedeni olarak görülebilir.

Gelecekteki çalışmalarda, bir fonksiyon yaklaşımı aracı olarak farklı sinir ağı yapıları kullanılabilir. Ayrıca üyelik ve üyelik dışı değerlerin farklı fonksiyonları model girdileri olarak kullanılabilir.



KAYNAKLAR

- Aguila, A.H., Valdez, M.G. & Castillo, O. 2017. An open source implementation of an intuitionistic fuzzy inference system in Clojure. 1-6.
- Akdeniz, E., Eğrioglu E., Baş, E. & Yolcu, U. 2018. An ARMA type PiSigma artificial neural network for nonlinear time series forecasting. *Journal of Artificial Intelligence and Soft Computing Research*. 8(2):121–132.
- Aladağ, Ç.H. 2013. Using multiplicative neuron model to establish fuzzy logic relationships. *Expert Systems with Applications*. 40(3): 850–853.
- Aladağ, Ç.H., Başaran, M.A., Eğrioglu, E., Yolcu, U. & Uslu, V.R. 2009. Forecasting in high order fuzzy times series by using neural networks to define fuzzy relations. *Expert Systems with Applications*. 36(3): 4228-4231.
- Aladağ, Ç.H., Eğrioglu, E. & Yolcu, U. 2014. Robust multilayer neural network based on median neuron model. *Neural Computing and Applications*. 24(3): 945-956.
- Aladağ, Ç.H., Yolcu, U. & Eğrioglu, E. 2010. A high order fuzzy time series forecasting model based on adaptive expectation and artificial neural networks. *Mathematics and Computers in Simulation*. 81(4): 875-882.
- Aladağ, Ç.H., Yolcu, U. & Eğrioglu, E. 2013. A new multiplicative seasonal neural network model based on particle swarm optimization. *Neural Process Letters*. 37(3): 251–262.
- Aladağ, Ç.H., Yolcu, U., Eğrioglu, E. & Dalar, A.Z. 2012. A new time invariant fuzzy time series forecasting method based on particle swarm optimization. *Applied Soft Computing*. 12(10): 3291-3299.
- Alpaslan, F. & Çağcağ, Ö. 2012. A seasonal fuzzy time series forecasting method based on Gustafson-Kessel fuzzy clustering, *Journal of Social and Economic Statistics*. 2(1): 1-13.
- Alpaslan, F., Çağcağ, Ö., Aladağ, Ç.H., Yolcu, U. & Eğrioglu, E. 2012. A novel seasonal fuzzy time series method. *Hacettepe Journal of Mathematics and Statistics*. 41(3): 375-385.
- Askari, S. & Montazerin, N. 2015. A high-order multi-variable fuzzy time series forecasting algorithm based on fuzzy clustering. *Expert Systems with Applications*. 42(4): 2121–2135.

- Askari, S., Montazerin, N. & Zarandi, M.H.F. 2015. A clustering based forecasting algorithm for multivariable fuzzy time series using linear combinations of independent variables. *Applied Soft Computing*. 35: 151–160.
- Atanassov, K.T. 1983. Intuitionistic fuzzy sets. VII ITKR's Session, Sofia deposited in Central Sci. Technical Library of Bulgarian Academy of Sciences. 1697/84.
- Atanassov, K.T. 1986. Intuitionistic fuzzy sets, *Fuzzy Sets Syst.* 20(1): 87-96.
- Atanassov, K.T. 1999. Intuitionistic Fuzzy Sets. In: *Intuitionistic Fuzzy Sets. Studies in Fuzziness and Soft Computing*, Vol. 35. Physica, Heidelberg.
- Atanassov, K.T. 2012. *On Intuitionistic fuzzy sets theory*. Springer, 327s.
- Attia, M.A., Sallam, E.A. & Fahmy, M.M. 2012. A proposed generalized mean single multiplicative neuron model. In 2012 IEEE 8th International Conference on Intelligent Computer Communication and Processing, Cluj-Napoca, Romania, 73-78.
- Baş, E., Eğrioğlu, E. & Kölemen, E. 2021. Training simple recurrent deep artificial neural network for forecasting using particle swarm optimization. *Granular Computing*, 1-10.
- Baş, E., Eğrioğlu, E., Aladağ, Ç.H. & Yolcu, U. 2015. Fuzzy-time-series network used to forecast linear and nonlinear time series. *Applied Intelligence*. 43(2): 343–355.
- Baş, E., Grosan, C., Eğrioğlu, E. & Yolcu, U. 2018. High order fuzzy time series method based on Pi-Sigma neural network. *Engineering Applications of Artificial Intelligence*. 72: 350–356.
- Baş, E., Yolcu, U. & Eğrioğlu, E. 2020. Intuitionistic fuzzy time series functions approach for time series forecasting. *Granular Computing*. 6(3): 619-629.
- Baş, E., Yolcu, U., Eğrioğlu, E., Çağcağ Yolcu, Ö. & Dalar, A.Z. 2016. Single multiplicative neuron model artificial neuron network trained by bat algorithm for time series forecasting. *American Journal of Intelligent Systems*. 6(3): 74–77.
- Bezdek, J.C. 1981. *Pattern recognition with fuzzy objective function algorithms*. New York: Plenum Press.
- Buckley, J.J. 2006. *Fuzzy Probability and Statistics*. Springer-Verlag, Berlin, 270s.
- Butnariu, D. & Klement, E.P., 1992. *Fuzzy Eproach to Reasoning and Decision Making*. Academia, s:90, Prague.

- Cağcağ Yolcu, Ö. & Alpaslan, F. 2018. Prediction of TAIEX based on hybrid fuzzy time series model with single optimization process. *Applied Soft Computing*. 66: 18-33.
- Cağcağ Yolcu, Ö. 2013. Yeni bir melez bulanık zaman serisi yaklaşımı. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ABD, Doktora Tezi.
- Cağcağ Yolcu, Ö. 2013. A Hybrid Fuzzy Time Series Approach Based on Fuzzy Clustering and Artificial Neural Network with Single Multiplicative Neuron Model. *Mathematical Problems in Engineering*.
- Cağcağ Yolcu, Ö. 2017. A combined robust fuzzy time series method for prediction of time series. *Neurocomputing*. 247: 87-101.
- Cağcağ Yolcu, Ö., Baş, E., Eğrioğlu, E. & Yolcu, U. 2018. Single multiplicative neuron model artificial neural network with autoregressive coefficient for time series modelling. *Neural Processing Letters*. 47(3): 1133–1147.
- Cağcağ Yolcu, Ö., Baş, E., Eğrioğlu, E. & Yolcu, U. 2019. A new intuitionistic fuzzy functions approach based on hesitation margin for time-series prediction.
- Cağcağ Yolcu, Ö., Yolcu, U., Eğrioğlu, E. & Aladağ, C.H. 2016. High order fuzzy time series forecasting method based on an intersection operation. *Applied Mathematical Modelling*. 40(19-20): 8750-8765.
- Cai, Q., Zhang, D., Zheng, W. & Leung, S.C. 2015. A new fuzzy time series forecasting model combined with ant colony optimization and auto-regression. *Knowledge-Based Systems*. 74: 61-68.
- Chaira, T. 2011. A novel intuitionistic fuzzy C means clustering algorithm and its application to medical images. *Applied Soft Computing*. 11(2): 1711–1717.
- Chen, D.S. & Jain R.C. 1994. A robust backpropagation learning algorithm for function approximation. *IEEE Trans Neural Networks*. 5(3): 467–479.
- Chen, M.Y. & Chen, B.T. 2015. A hybrid fuzzy time series model based on granular computing for stock price forecasting. *Information Sciences*. 294: 227-241.
- Chen, S.M. & Chen, S.W. 2015. Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and the probabilities of trends of fuzzy logical relationships. *IEEE Transactions of Cybernetics*. <https://doi.org/10.1109/TCYB.2014.2326888>.
- Chen, S.M. & Chen, C.D. 2011. Handling forecasting problems based on high-order fuzzy logical relationships. *Expert Systems with Applications*. 38(4):3857–3864.

- Chen, S.M. & Chung, N.Y. 2006. Forecasting enrolments using high order fuzzy time series and genetic algorithms. *International Journal of intelligent systems*. 21(5): 485-501.
- Chen, S.M. & Hsu, C.C. 2004. A New Method to Forecast Enrollments Using Fuzzy Time Series. *International Journal of Applied Science and Engineering* 2(3): 234-244.
- Chen, S.M. & Tanuwijaya, K. 2013. Fuzzy forecasting on high-order relationships and automatic clustering techniques. *Expert Systems with Applications*. 38(12): 15425–15437.
- Chen, S.M. 1996. Forecasting enrollments based on fuzzy time-series. *Fuzzy Sets and Systems*. 81(3):311-319.
- Chen, S.M. 2002. Forecasting enrollments based on high-order fuzzy time series. *Cybernetics and Systems*. 33(1): 1-16.
- Chen, S.M., Wang, N.Y. & Pan, J.S. 2009. Forecasting enrollments using automatic clustering techniques and fuzzy logical relationships. *Expert Systems with Applications*. 36(8): 11070-11076.
- Chen, W., Sun, J., Gao, S., Cheng, J.J., Wang, J. & Todo, Y. 2017. Using a single dendritic neuron to forecast tourist arrivals to Japan. *IEICE TRANSACTIONS on Information and Systems*. 100(1):190–202.
- Cheng, C.H., Chang, J.R. & Yeh, C.A. 2006. Entropy-based and trapezoid fuzzification-based fuzzy time series approaches for forecasting IT project cost. *Technological Forecasting and Social Change*. 73(5): 524-542.
- 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(2): 1235–1242.
- Cheng, S.H., Chen, S.M. & Jian, W.S. 2015. A novel fuzzy time series forecasting method based on fuzzy logical relationships and similarity measures. In 2015 IEEE International Conference on Systems, Man, and Cybernetics. 2250-2254
- Cheng, S.H., Chen, S.M. & Jian, W.S. 2016. Fuzzy time series forecasting based on fuzzy logical relationships and similarity measures. *Information Sciences*. 327: 272-287.
- Dash, R., Routray, A., Rautray, R. & Dash, R. 2018. Gold price prediction using an evolutionary pi-sigma neural network. *International Journal of Engineering & Technology*. 7(4.5), 742–746.

- Davari, S., Zarandi, M.H.F. & Türkşen, İ.B. 2009. An improved fuzzy time series forecasting model based on particle swarm intervalization. In: The 28th North American Fuzzy Information Processing Society Annual Conference (NAFIPS2009), Cincinnati, Ohio, 1–5.
- De, S.K., Biswas, R. & Roy, A.R. 2000. Some operations on intuitionistic fuzzy sets. *Fuzzy sets and Systems*. 114(3): 477-484.
- Deepa, M., Rajalakshmi, M. & Nedunchezian, R. 2018. Higher order neural networks based on bioinspired swarm intelligence optimization algorithm for multimodal tumor data analysis. *Biomedical Research Special Issue*, 29, 113–117.
- Dunn, J.C. 1973. A fuzzy relative of the isodata process and its use in detecting compact well-separated clusters. *Journal of Cybernetics*. 3(3): 32–57.
- Durbin, R. & Rumelhart, D.E. 1989. Product units: a computationally powerful and biologically plausible extension to back propagation networks. *Neural Computation*. 1(1): 133–142.
- Eberhart, R. & Kennedy, J. 1995. A new optimizer using particle swarm theory. In: MHS 95., Proceedings of the Sixth International Symposium on Micro Machine and Human Science. 39–43.
- Eğrioğlu, E. & Fildes, R. 2020. A New Bootstrapped Hybrid Artificial Neural Network Approach for Time Series Forecasting. *Computational Economics*. 1-29.
- Eğrioğlu, E. 2012. A new time-invariant fuzzy time series forecasting method based on genetic algorithm. *Advances in Fuzzy Systems*.
- Eğrioğlu, E. 2014. PSO-based high order time invariant fuzzy time series method: Application to stock exchange data. *Economic Modelling*. 38: 633-639.
- Eğrioğlu, E., Aladağ, Ç.H. & Yolcu, U. 2013. A Hybrid Fuzzy Time Series Forecasting Model Based on Fuzzy C-Means and Artificial Neural Networks. *Expert Systems with Applications*. 40(3): 854-857.
- Eğrioğlu, E., Aladağ, Ç.H., Başaran, M.A., Yolcu, U. & Uslu, V.R. 2011a. A new approach based on the optimization of the length of intervals in fuzzy time series. *Journal of Intelligent & Fuzzy Systems*. 22 (1): 15-19.
- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Baş, E. & Dalar, A.Z. 2017. A new neural network model with deterministic trend and seasonality components for time series forecasting. In: *Advances in time series forecasting*. 2: 76-92.

- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Başaran, M.A. & Uslu, V.R., 2009a. A new hybrid approach based on SARIMA and partial high order bivariate fuzzy time series forecasting model. *Expert Systems with Applications*. 36(4): 7424-7434.
- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Uslu, V.R. & Başaran, M.A. 2009b. A new approach based on artificial neural networks for high order multivariate fuzzy time series. *Expert Systems with Applications*. 36(7): 10589-10594.
- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Uslu, V.R. & Başaran, M.A. 2010. Finding an optimal interval length in high order fuzzy time series. *Expert Systems with Applications*. 37(7): 5052-5055.
- Eğrioğlu, E., Aladağ, Ç.H., Yolcu, U., Uslu, V.R. & Erilli, N.A. 2011b. Fuzzy time series forecasting method based on Gustafson–Kessel fuzzy clustering. *Expert Systems with Applications*. 38(8): 10355-10357.
- Eğrioğlu, E., Baş, E., Çağcağ Yolcu, Ö. & Yolcu, U. 2019. Intuitionistic time series fuzzy inference system. *Engineering Applications of Artificial Intelligence*. 82: 175-183.
- Eğrioğlu, E., Baş, E., Yolcu, U. & Chen, M.Y. 2020. Picture fuzzy time series: Defining, modeling and creating a new forecasting method. *Engineering Applications of Artificial Intelligence*. 88. 103367.
- Eğrioğlu, E., Uslu, V.R., Yolcu, U., Başaran, M.A. & Aladağ, Ç.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.
- Eğrioğlu, E., Yolcu, U. & Baş, E. 2019. Intuitionistic high-order fuzzy time series forecasting method based on pi-sigma artificial neural networks trained by artificial bee colony. *Granular Computing*. 4(4): 639-654.
- Eğrioğlu, E., Yolcu, U. & Baş, E. 2020. *Yapay Sinir Ağları Öngörü ve Tahmin Uygulamaları*. 2. Baskı, Nobel Akademik Yayıncılık, 262.
- Eğrioğlu, E., Yolcu, U., Aladağ, Ç.H. & Baş E. 2014. Recurrent multiplicative neuron model artificial neural network for nonlinear time series forecasting. *Neural Processing Letters*. 41(2): 249–258.
- Eğrioğlu, E., Yolcu, U., Baş, E., & Dalar, A.Z. 2017. Median-Pi artificial neural network for forecasting. *Neural Computing and Applications*.
- El-Melegy, M.T., Essai, M.H. & Ali, A.A. 2009. Robust training of artificial feedforward neural networks. In *Foundations of Computational*, Springer, Berlin Heidelberg. 217-242.

- Fan, X., Wang, Y. & Zhang, M. 2020. Network traffic forecasting model based on long-term intuitionistic fuzzy time series. *Information Sciences*. 506: 131-147.
- Ghazali, R. & Jumeily, D.A. 2009. Application of Pi-Sigma neural networks and ridge polynomial neural networks to financial time series prediction. *Artificial Higher Order Neural Networks for Economics and Business*. 271–293.
- Ghazali, R., Husaini, A. & El-Deredy, W. 2006. Application of ridge polynomial neural networks to financial time series prediction. In: *International joint conference on neural networks*. 913–920.
- Ghazali, R., Hussain, A.J., Liatsis, P. & Tawfik, H. 2008. The application of ridge polynomial neural network to multi-step ahead financial time series prediction. *Neural Computing & Applications*. 17(3): 311–323.
- Giles, C.L. & Maxwell, T. 1987. Learning, invariance, and generalization in a high-order neural network. *Applied Optics*. 26(23): 4972–4978.
- Giles, C.L., Lawrence, S. & Tsoi, A.C. 2001. Noisy time series prediction using recurrent neural networks and grammatical inference. *Machine Learning*. 44(1): 161–183.
- Gündoğdu, O., Eğrioğlu, E., Aladağ Ç.H. & Yolcu, U. 2015. Multiplicative neuron model artificial neural network based on gauss activation function. *Neural Computing and Applications*. 27(4): 927-935.
- Guo, H., Pedrycz, W. & Liu, X. 2018. Fuzzy time series forecasting based on axiomatic fuzzy set theory. *Neural Computing and Applications*.
- Hebb, D. O. 1949. The organization of behaviour. The first stage of perception: growth of the assembly, 4, 60-78.
- Hsiao, C.C., Chuang C.C. & Jeng J.T. 2012. Robust back propagation learning algorithm based on near sets. In 2012 International Conference on System Science and Engineering (ICSSE), Dalian, China, 19-23.
- 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 Applications*. 37(4): 2756-2770.
- 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(2): 328-340.

- Huarng, K. & Yu, T.H.K. 2006b. The application of neural networks to forecast fuzzy time series. *Physica A: Statistical mechanics and its applications*. 363(2): 481-491.
- Huarng, K. 2001. Effective lengths of intervals to improve forecasting in fuzzy time series. *Fuzzy sets and systems*. 123(3): 387-394.
- Husaini, N.A., Ghazali, R., Nawawi, N.M. & Ismail, L.H. 2011. Pi-Sigma neural network for temperature forecasting in batu pahat. In *International Conference on Software Engineering and Computer Systems*. Springer Berlin Heidelberg, 530-541.
- Husaini, N.A., Ghazali, R., Nawawi, N.M., & Ismail, L.H. 2012. The Effect of Network Parameters on Pi-Sigma Neural Network for Temperature Forecasting. *International Journal of Modern Physics: Conference Series*. 9: 440–447.
- Husaini, N.A., Ghazali, R., Nawawi, N.M., Ismail, L. H., Deris, M.M., & Herawan, T. 2014. Pi-Sigma neural network for a one-step-ahead temperature forecasting. *International Journal of Computational Intelligence and Applications*. 13(4): 1450023.
- Hussain, A.J. & Liatsis, P. 2003. Recurrent Pi-Sigma networks for DPCM image coding, *Neurocomputing*. 55(1-2): 363–382.
- Ibrahim, A.M. & El-Amary, N.H. 2018. Particle swarm optimization trained recurrent neural network for voltage instability prediction. *Journal of Electrical Systems and Information Technology*. 5(2):216–228.
- Jilani, T. A. & Burney, S.M.A. 2008. Multivariate stochastic fuzzy forecasting models. *Expert Systems with Applications*. 35: 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.
- Kennedy, J. & Eberhart, R. 1995 Particle swarm optimization. In: *Proceedings of IEEE International Conference on Neural Networks*. 4: 1942–1948.
- Kim, T.Y. & Cho, S.B. 2019. Particle swarm optimization-based CNNLSTM networks for forecasting energy consumption. In *2019 IEEE Congress on Evolutionary Computation (CEC)*. 1510–1516.
- Kızılaslan, B., Eğrioğlu, E. & Evren, A. A. 2019. Intuitionistic fuzzy ridge regression functions. *Communications in Statistics-Simulation and Computation*. 49(3): 699-708.

- Koçak, C. 2011. Bulanık zaman serileri öngörüsü için yeni bir model sınıfı. Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, İstatistik ABD, Doktora Tezi.
- Koçak, C. 2013. First-order ARMA type fuzzy time series method based on fuzzy logic relation tables. *Mathematical Problems in Engineering*.
- Koçak, C. 2017. ARMA(p, q) type high order fuzzy time series forecast method based on fuzzy logic relations. *Applied Soft Computing*. 58: 92–103.
- Koçak, C., Dalar, A.Z., Çağcağ Yolcu, Ö., Baş, E. & Eğrioğlu, E. 2019. A new fuzzy time series method based on an ARMA-type recurrent Pi-Sigma artificial neural network. *Soft Computing*. 1-10.
- Koçak, C., Eğrioğlu, E. & Baş, E. 2021a. A New Explainable Robust High Order Intuitionistic Fuzzy Time Series Method.
- Koçak, C., Eğrioğlu, E., & Baş, E. 2021b. A new deep intuitionistic fuzzy time series forecasting method based on long short-term memory. *The Journal of Supercomputing*. 77(6): 6178-6196.
- Kuo, I.H., Horng, S.J., Chen, Y.H., Run, R.S., Kao, T.W., Chen, R.J., Lai, T.L. & Lin, T.L. 2010. Forecasting TAIEX based on fuzzy time series and particle swarm optimization. *Expert Systems with Applications*. 37(2): 1494-1502.
- 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 System Applications*. 36(3): 6108–6117.
- Kuo-Chien, L. 2002. Memory-based Sigma–Pi–Sigma neural network, *IEEE International Conference on Systems, Man and Cybernetics*, TP1F5; 112–8.
- 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(3): 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(1): 328-336.
- Lee, W.J. & Hong J. 2015. A hybrid dynamic and fuzzy time series model for mid-term power load forecasting. *International Journal of Electrical Power & Energy Systems*. 64, 1057-1062.
- Li, S.T., Cheng, Y.C. & Lin, S.Y. 2008. A FCM-based deterministic forecasting model for fuzzy time series. *Computers & Mathematics with Applications*. 56(12): 3052–3063.

- Lin, T., Horne, B.G. & Giles, C.L. 1998. How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies. *Neural Netw.* 11(5): 861–868.
- Ma, L., Ge, Y.P. & Cao, X. 2012. Superheated steam temperature control based on improved recurrent neural network and simplified PSO algorithm. In *Applied Mechanics and Materials*. 128:1065–1069.
- McCulloch, W.S. & Pitts, W. 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*. 5(4): 115–133.
- Moalla, H., Elloumi, W. & Alimi, A.M. 2017. H-PSO-LSTM: Hybrid LSTM trained by PSO for online handwriting identification. In: *International Conference on Neural Information Processing*. 41–50.
- Mohamed, K. S., Liu, Y., Wu, W. & Alemu, H.Z. 2016. Batch gradient method for training of Pi-Sigma neural network with penalty. *International Journal of Artificial Intelligence & Applications (IJAIA)*. 7(1): 11–20.
- Nayak, J., Naik B. Behera, H.S. & Abraham, A. 2015. Particle swarm optimization based higher order neural network for classification. *Smart Innovation, Systems and Technologies*. 1: 401-414.
- Nayak, J., Naik, B. & Behera H.S. 2014b A hybrid PSO-GA based Pi sigma neural network (PSNN) with standard back propagation gradient descent learning for classification. *International Conference on Control, Instrumentation, Communication and Computational Technologies, ICCICCT 2014*. 878-885.
- Nayak, S.C. & Ansari, M. 2020. Cooperative optimization algorithm Based higher order neural networks for stock forecasting. *Recent Advances in Computer Science and Communications*. 13(1).
- Özkan, M.M., 2003. Bulanık Hedef Programlama, Ekin Kitabevi, Bursa.
- Öztemel, E. 2003. Yapay sinir ağları. Papatya Yayıncılık, İstanbul, 238s.
- Panda, N. & Majhi, S.K. 2020. Improved spotted hyena optimizer with space transformational search for training Pi-Sigma higher order neural network. *Computational Intelligence*. 36(1): 320–350.
- Panigrahi, S. & Behera, H.S. 2020. A study on leading machine learning techniques for high order fuzzy time series forecasting. *Engineering Applications of Artificial Intelligence*. 87. 103245.
- Park, J.I., Lee, D.J., Song, C.K. & Chun, M.G. 2010. TAIFEX and KOSPI 200 forecasting based on two-factors high-order fuzzy time series and particle swarm optimization. *Expert Systems with Applications*. 37(2): 959-967.

- Pattanayak, R.M., Behera, H.S. & Panigrahi, S. 2020. A multi-step-ahead fuzzy time series forecasting by using hybrid chemical reaction optimization with Pi-Sigma higher-order Neural Network. *Computational Intelligence in Pattern Recognition*, 1029–1041.
- Rosenblatt, F. 1959, *Principles of Neurodynamics*, Spartan Books, New York.
- Rusiecki, A. 2012. Robust learning algorithm based on iterative least median of squares. *Neural Processing Letters*. 36(2): 145–160.
- Shao, B., Li, M., Zhao, Y. & Bian, G. 2019. Nickel price forecast based on the LSTM neural network optimized by the improved PSO algorithm. *Mathematical Problems in Engineering* 2019.
- Shin, Y. & Gosh, J. 1991. The Pi-sigma Network: An efficient higher-order neural network for pattern classification and function approximation. In *Proceedings of the International Joint Conference on Neural Networks*. 1: 13-18.
- Song, Q. & Chissom, B.S. 1993a. Fuzzy time series and its models. *Fuzzy Sets and Systems*. 54(3): 269-277.
- Song, Q. & Chissom, B.S. 1993b. Forecasting enrollments with fuzzy time series- Part I. *Fuzzy Sets and Systems*. 54(1), 1-10.
- Song, Q. & Chissom, B.S. 1994. Forecasting enrollments with fuzzy time series- Part II. *Fuzzy Sets and Systems*. 62(1): 1-8.
- Sullivan, J. & Woodall, W.H. 1994. A comparison of fuzzy forecasting and Markov modeling. *Fuzzy Sets and Systems*. 64(3): 279-293.
- Sun, B., Guo, H., Karimi, H.R., Ge, Y. & Xiong, S. 2015. Prediction of stock index futures prices based on fuzzy sets and multivariate fuzzy time series. *Neurocomputing*. 151: 1528–1536.
- Tawfik, H. & Liatsis, P. 1997. Prediction of non-linear time-series using higher-order neural networks, *Proceeding IWSSIP'97 Conference*, Poznan, Poland.
- Thomas. P., Bloch, G., Sirou, F. & Eustache, V. 1999. Neural modeling of an induction furnace using robust learning criteria. (I. Press, Éd.) *Integrated Computer-Aided Engineering*. 6(1): 15–26.
- Wang, J. & Xiong, S. 2014. A hybrid forecasting model based on outlier detection and fuzzy time series - A case study on Hainan wind farm of China, *Energy*. 76: 526-541.
- Wang, N.Y. & Chen, S.M. 2009. Temperature prediction and TAIFEX forecasting based on automatic clustering techniques and two-factors high-order fuzzy time series. *Expert Systems with Applications*. 36(2): 2143-2154.

- Wang, W. & Liu, X. 2015. Fuzzy forecasting based on automatic clustering and axiomatic fuzzy set classification. *Information Sciences*. 294: 78-94.
- Wang, X., Ma, L., Wang, B. & Wang, T. 2013. A hybrid optimizationbased recurrent neural network for real-time data prediction. *Neurocomputing*. 120:547–559.
- Wang, Y., Lei, Y., Fan, X. & Wang, Y. 2016. Intuitionistic Fuzzy Time Series Forecasting Model Based on Intuitionistic Fuzzy Reasoning. *Mathematical Problems in Engineering*. <https://doi.org/10.1155/2016/5035160>.
- Wang, Z., Durst, G.L., Eberhart, R.C., Boyd, D.B. & Miled, Z.B. 2004. Particle Swarm Optimization and Neural Network Application for QSAR. *Proceedings 18th Parallel and Distributed Processing Symposium*. 194.
- Wei, L.Y., Cheng, C.H. & Wu, H.H. 2014. A hybrid ANFIS based on n-period moving average model to forecast TAIEX stock. *Applied Soft Computing*. 19: 86-92.
- Widrow, B. & Hoff, M. 1960, Adaptive switching circuits. *IRE WESCON Convention Record*. 4: 96-104.
- Yadav, R.N., Kalra P.K. & John J. 2007. Time series prediction with single multiplicative neuron model. *Applied Soft Computing*. 7(4): 1157-1163.
- Yao, Y., Han, L. & Wang, J. 2018. LSTM-PSO: Long Short-Term Memory ship motion prediction based on particle swarm optimization. In: 2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC). 1–5.
- Yılmaz, O., Baş, E. & Eğrioğlu, E. 2021. The Training of Pi-Sigma Artificial Neural Networks with Differential Evolution Algorithm for Forecasting. *Computational Economics*, 1-13.
- Yolcu, U. 2011. Bulanık Zaman Serilerinde Çok Değişkenli Çözümleme. *Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, İstatistik ABD, Doktora Tezi*.
- Yolcu, U., Aladağ, Ç.H. & Eğrioğlu, E. 2013. A new linear & nonlinear artificial neural network model for time series forecasting. *Decision Support Systems*. 54(3):1340–1347.
- Yolcu, U., Baş, E., Eğrioğlu, E. & Aladağ, Ç.H. 2015. A new multilayer feed forward network model based on trimmed mean neuron model. *Neural Network World Journal*. 25:587–602.
- Yolcu, U., Çağcağ, Ö., Aladağ, Ç.H., Eğrioğlu E. 2014. An enhanced fuzzy time series forecasting method based on artificial bee colony algorithm. *Journal of Intelligent and Fuzzy Systems*. 26(6): 2627-2637.

- Yolcu, U., Eğrioğlu, E., Baş, E., Yolcu, O.C. & Dalar, A.Z. 2019. Probabilistic forecasting, linearity and nonlinearity hypothesis tests with bootstrapped linear and nonlinear artificial neural network. *Journal of Experimental & Theoretical Artificial Intelligence*. 1-22.
- Yolcu, U., Eğrioğlu, E., Uslu, V.R., Başaran, M.A. & Aladağ, Ç.H. 2009. A new approach for determining the length of intervals for fuzzy time series. *Applied Soft Computing*. 9(2): 647-651.
- Yong, N. & Wei, D. 2008. A hybrid genetic learning algorithm for Pi– sigma neural network and the analysis of its convergence, In: *IEEE fourth international conference on natural computation*. 3: 19–23.
- Yu, T.H.K. & Huarng, K.H. 2008. A bivariate fuzzy time series model to forecast the TAIEX. *Expert Systems with Applications*. 34(4): 2945-2952.
- Yu, T.H.K. & Huarng, K.H. 2010. A neural network-based fuzzy time series model to improve forecasting. *Expert Systems with Applications*. 37(4): 3366-3372.
- 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 Transactions on Systems, Man and Cybernetics*. 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.
- Zheng, K.Q., Lei, Y.J., Wang, R. & Wang, Y.F. 2013a. Modeling and application of IFTS. *Control and Decision*. 28(10):1525–1530.
- Zheng, K.Q., Lei, Y.J., Wang, R. & Yu, X.D. 2014b. Long-term intuitionistic fuzzy time series forecasting based on vector quantization. *Jilin Daxue Xuebao (Gongxueban)/J Jilin Univ (Engineering and Technology Edition)*. 44(3): 795–800.
- Zheng, K.Q., Lei, Y.J., Wang, R. & Wang, Y.F. 2013b. Prediction of IFTS based on deterministic transition. *Journal of Applied Sciences-Electronics and Information Engineering*. 31(2): 204–211.
- Zheng, K.Q., Lei, Y.J., Wang, R. & Xing, Y.Q. 2014a. Method of long-term IFTS forecasting based on parameter adaptation. *Systems Engineering and Electronics*. 36(1): 99–104.
- Zhou, T., Gao, S., Wang, J., Chu, C., Todo, Y. & Tang, Z. 2016. Financial time series prediction using a dendritic neuron model. *Knowledge-Based Systems*. 105: 214–224.

ÖZGEÇMİŞ

Şule Nazlı ARSLAN 2006 yılında Konuralp İlköğretim Okulu'nu; 2010 yılında Şehit Yüzbaşı Halil İbrahim Sert Anadolu Lisesi'ni; 2015 yılında Karadeniz Teknik Üniversitesi İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü'nü bitirdi. 2019 yılında Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalında yüksek lisans programına bitirdi. 2019 yılında Giresun Üniversitesi Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalında yüksek lisans programına başladı.

Arslan, bekar olup ingilizce bilmektedir.