



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ZAMAN SERİSİ ÖNGÖRÜSÜ İÇİN YAPAY SİNİR AĞLARINA DAYALI YENİ BİR BULANIK FONKSİYON YAKLAŞIMI

MEHMET RACİ AKTOPRAK

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

DANIŞMAN

Doç. Dr. Özge CAĞCAĞ YOLCU

İSTANBUL, 2023



MARMARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ZAMAN SERİSİ ÖNGÖRÜSÜ İÇİN YAPAY SİNİR AĞLARINA DAYALI YENİ BİR BULANIK FONKSİYON YAKLAŞIMI

MEHMET RACİ AKTOPRAK

521320002

YÜKSEK LİSANS TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

DANIŞMAN

Doç. Dr. Özge CAĞCAĞ YOLCU

İSTANBUL, 2023

TEŞEKKÜR

Yüksek Lisans eğitimim ve tez çalışmalarım boyunca beni her konuda destekleyen, emeğini ve sonsuz katkısını benden esirgemeyen saygıdeğer hocam Sayın Doç. Dr. Özge CAĞCAĞ YOLCU' ya ve beni bugünlere getirip hep yanımda duran canım annem Merese AKTOPRAK, Babam Mehmet Naci AKTOPRAK ile kardeşlerim Semanur AKTOPRAK, Ümit AKTOPRAK ve İnci AKTOPRAK' a teşekkürlerimi sunarım.

Bu çalışma Marmara Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü tarafından Yüksek Lisans Tez Projeleri (FYL-2022-10538) kapsamında desteklenmiştir, bu anlamda Marmara Üniversitesi Bilimsel Araştırma Projeleri Koordinatörlüğü'ne de teşekkürlerimi sunarım.

Mehmet Raci AKTOPRAK

Eylül 2023

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	iii
ABSTRACT.....	iv
SEMBOLLER.....	v
KISALTMALAR.....	vi
ŞEKİL	vii
TABLO LİSTESİ.....	viii
1. GİRİŞ	1
2. İLİŞKİLİ YÖNTEMLER.....	6
2.1. Bulanık C-Ortalamlar	6
2.2. Tip 1 Bulanık Regresyon Fonksiyonları	7
2.3. İleri Beslemeli Yapay Sinir Ağları.....	9
3. METERYAL VE YÖNTEM.....	10
3.1. Önerilen Bulanık Regresyon Ağ Fonksiyonları (FRNF)	10
4. UYGULAMA SONUÇLARI VE DEĞERLENDİRME	15
4.1. Veri Hazırlığı.....	15
4.2. Performans Ölçütü.....	16
4.3. Uygulama Sonuçları.....	17
4.3.1. TAIEX uygulamaları - 2000-2004 yılları arasındaki günlük veri setleri	17
4.3.2. TAIEX uygulamaları - 2008-2018 yılları arasındaki günlük veri seti.....	20
4.3.3. IEX uygulamaları.....	25
5. SONUÇLAR	27
KAYNAKLAR	29
ÖZGEÇMİŞ	38

ÖZET

ZAMAN SERİSİ ÖNGÖRÜSÜ İÇİN YAPAY SİNİR AĞLARINA DAYALI YENİ BİR BULANIK FONKSİYON YAKLAŞIMI

Zaman serisi tahmin problemi, birçok alanda karar vericilerin karşılaştığı bir problemdir. İlgili sektör veya alanlarda gelecekte neler ile karşılaşılabilceği, belirlenen strateji ve politikaların ne gibi sonuçlara yol açabileceği gibi sorulara cevap bulmada önemli rol oynayan tahminleri elde etmek için farklı modeller geliştirilmiştir. Geleneksel modeller birçok alanda yaygın olarak kullanılmakla birlikte, gerektirdikleri katı varsayımların yol açtığı dezavantajları aşmak için farklı yaklaşım ve modeller de ortaya konulmuştur. Zaman serisi problemlerinde bulanık tabanlı modeller, belirsizliklere yaklaşımları sayesinde üstün performans gösterirken, hesaplama tabanlı modeller, doğrusal olmayan modellere yüksek adaptasyon kabiliyeti sayesinde üstün performans göstermektedir.

Zaman serileri çok sayıda ve kaotik ilişkilerden oluşabileceğinden doğru tahminlere ulaşmak oldukça zor bir iştir. Bulanık Regresyon Fonksiyonları (FRF) yaklaşımı, girdilerin bir dizi doğrusal fonksiyonunun bir kombinasyonu olan bütünsel bir model oluşturur. Ancak, girdi ve çıktı arasındaki ilişki her zaman doğrusal olmayabilir. Bu yüksek lisans tezinde yeni bir FRF yaklaşımı önerilmektedir. Hem hesaplamalı hem de bulanık tabanlı modellerin avantajlarına sahip, sinir ağlarına dayalı doğrusal olmayan yapıda bulanık regresyon fonksiyonları oluşturularak literatürdeki bazı boşlukların doldurulması amaçlanmaktadır.

Önerilen tahmin aracı, Bulanık C-Ortalamlar (FCM) kümeleme algoritması aracılığıyla, zaman serilerinin reel gözlemlerini bulanıklaştırarak üyelikleri üretmektedir. Reel değerli zaman serisinin gecikmeli gözlemlerinden ve bu üyelik değerlerinin bazı dönüşümlerinden girdiler üretilir. Bulanık küme sayısına eşit sayıda ileri beslemeli sinir ağı, girdilerin doğrusal olmayan fonksiyonu olarak çıktıları üretir. Bu çıktılar, ilgili zaman noktasının ilgili bulanık kümelerine ait olma derecesini temsil eden üyelik değerleri ile birleştirilerek nihai çıktılarına dönüştürülür. Önerilen model Bulanık Regresyon Ağ Fonksiyonları (FRNF) olarak adlandırılabilir. Önerilen FRNF'in performansı bazı kriterler açısından, farklı gerçek hayat zaman serilerine uygulanarak ortaya konmuştur.

Anahtar Kelimeler: Yapay sinir ağları; tip-1 bulanık fonksiyonlar; zaman serisi tahmini; bulanık C-ortalamlar

ABSTRACT

A NEW FUZZY FUNCTION APPROACH BASED ON ARTIFICIAL NEURAL NETWORKS FOR TIME SERIES FORECASTING

The time series forecasting problem is a problem faced by decision makers in many fields. Different models have been developed to obtain predictions that play an important role in finding answers to questions such as what may be encountered in the future in the relevant sector or fields, what results the determined strategies and policies may lead to. Although traditional models are widely used in many fields, different approaches and models have also been put forward to overcome the disadvantages caused by the strict assumptions they require. In time series problems, fuzzy-based models show superior performance due to their approach to uncertainty, while computation-based models show superior performance thanks to their high adaptability to nonlinear patterns.

It is a challenging task to achieve accurate predictions as time series can consist of a variety and chaotic relationships. Fuzzy Regression Functions (FRF) approach creates a holistic model that is a combination of a series of linear function of inputs. However, the relationship between input and output may not always be just linear. In this study, a new FRF approach is proposed. It is aimed to fill all these gaps by creating fuzzy regression functions with nonlinear structure based on neural networks, having the advantages of both computational and fuzzy based models.

The proposed prediction tool, via Fuzzy C-Means (FCM) clustering algorithm, produces the memberships by fuzzifying the actual observations of the time series. From a lagged observations of real time series and some transformation of these membership values, the inputs are generated. A number of feed-forward neural networks, in equal to the number of fuzzy sets, produce outputs as nonlinear function of the inputs. These outputs are converted the final outputs by combining in the direction of membership values representing the degree to which the relevant time point belongs to the relevant fuzzy sets. The proposed model can be called as Fuzzy Regression Network Functions (FRNF). The performance of FRNFs, in terms of some criteria, is put forward by applied it to different real-world time series.

Key Words: Artificial neural networks; type-1 fuzzy functions; time series forecasting; fuzzy C-means

SEMBOLLER

u_{ij}	: Üyelik değerleri
v_i	: Küme merkezi
n	: Değişken sayısı
β	: Ağırlıklandırma üssü
c	: Bulanık küme sayısı
maxitr	: Maksimum İterasyon Sayısı
P	: Gecikmeli net değişkenler
K	: Gizli katman nöronu
t_{tr}	: Eğitim kümesinin (setinin) uzunluğu
t_{val}	: Doğrulama kümesinin (setinin) uzunluğu
t_{test}	: Test kümesinin (setinin) uzunluğu
β_f	: Bulanıklık indeksi
T	: Zaman serisindeki gözlem sayısı
$d(x_j, v_i)$	: Gözlem ile küme merkezleri arasındaki uzaklık
R^2	: Determinasyon Katsayısı
Σ	: Toplam işareti
%	: Yüzde

KISALTMALAR

ANFIS	: Uygulamalı Ağ Tabanlı Bulanık Çıkarım Sistemi
CNN	: Evrişimli Sinir Ağları
FCM	: Bulanık C Ortalamalar
FFNN	: İleri Beslemeli Yapay Sinir Ağları
FIS	: Bulanık Çıkarım Sistemleri
FRF	: Bulanık Regresyon Fonksiyonları
FRNF	: Önerilen Bulanık Regresyon Ağ Fonksiyonları
FTS	: Zaman Serisi Yöntemleri
HKOK	: Hata Kareler Ortalaması Karekökü
IEX	: İstanbul Menkul Kıymetler Borsası
LSTM	: Uzun Kısa Süreli Bellek
MA	: Hareketli Ortalama
OKH	: Ortalama Karesel Hata
OLS	: Sıradan En Küçük Kareler
OMYH	: Ortalama Mutlak Yüzdelik Hata
OrMYH	: Medyan Mutlak Yüzdelik Hata
T1FF	: Tip 1 Bulanık Fonksiyonlar
T1FRF	: Tip 1 Bulanık Regresyon Fonksiyonları
TAIEX	: Tayvan Borsası Kapitalizasyon Ağırlıklı Hisse Senedi Endeksi
YSA	: Yapay Sinir Ağları

ŞEKİL

Şekil 2.1. FFNN modeli.	9
Şekil 3.1. Önerilen T1-Bulanık Regresyon Ağı Fonksiyonlarının mimarisi.....	12
Şekil 4.1. Tahminler ve gözlemler arasındaki uyum.....	19
Şekil 4.2. TAIEX için gözlenen, tahmin edilen ve artık değerler (2008-2018)	21



TABLO LİSTESİ

Tablo 4.1. Uygulama özellikleri ve veri setleri.	15
Tablo 4.2. Hiper-parametrelerin olası değerleri.	16
Tablo 4.3. TAIEX 2000-2004 veri setleri için kullanılan yöntemlerin performansları. .	18
Tablo 4.4. TAIEX 2000-2004 için parametreler için elde edilen en iyi değerler	20
Tablo 4.5. TAIEX için HKOK açısından mevcut modellerin sonuçları (2008-2018). ...	24
Tablo 4.6. TAIEX 2008-2018 için parametreler için elde edilen en iyi değerler	25
Tablo 4.7. IEX veri setleri için HKOK değerleri açısından sonuçlar.	26



1. GİRİŞ

Herhangi bir olayın ve/veya olgunun doğru tahmin edilmesi günlük hayatımızda önemli bir rol oynamaktadır. Özellikle belirsiz durumlarda, kesin değerleri tahmin etmek oldukça zor bir iştir. Bunun nedeni ise, gerçek dünyadaki olayların sıklıkla içerdiği belirsizlik ve doğrusal olmama durumudur. Zaman serisi verilerinin doğru ve tarafsız tahmini her zaman iyi bilinen doğrusal teknikler kullanılarak elde edilemez. Tatmin edici tahmin sonuçları elde etmenin yolu, uygun ve yetkin tahmin araçlarının kullanılması ile mümkündür. Son yıllarda zaman serisi tahmini için alternatif yöntemler kullanılmaya başlanmıştır. Bu modeller genellikle bulanık küme teorisine veya hesaplama tabanlı yaklaşımlara dayanmaktadır. Hesaplama tabanlı modeller doğrusal olmayan örüntülere yüksek adaptasyon kabiliyetleri sayesinde üstün performans gösterirken belirsizliğe yönelik ise herhangi bir yaklaşım içermemektedirler. Bu açıdan bakıldığında, bulanık küme teorisine dayalı, bulanık zaman serisi yöntemleri (FTS), zaman serilerinin içerdiği belirsizliğe sundukları etkin yaklaşımları sayesinde üstün tahmin performansı gösterebilmektedir. Ayrıca, geleneksel zaman serisi yöntemlerinin aksine, FTS yöntemleri katı varsayımlar da gerektirmez. Tüm bu avantajlar FTS yöntemleri de dahil olmak üzere bulanık küme teorisine dayalı yöntemlere olan ilgiyi artırmış ve onları bilgi teknolojileri, tıp, işletme, finans ve farklı mühendislik alanları başta olmak üzere farklı alanlar için cazip ve popüler hale getirmiştir. İlk olarak Song ve Chissom [1] tarafından ortaya atılan bulanık zaman serileri, temel olarak Zadeh'in [2] bulanık küme teorisine dayanmaktadır. Bulanık zaman serisi tahmin modelleri temel olarak üç aşamadan oluşmaktadır: gözlemlerin bulanıklaştırılması, bulanık ilişkilerin tanımlanması ve berraklaştırma. Bulanıklaştırma aşamasında, reel gözlemlere sahip ilgili zaman serisi, farklı bulanıklaştırma yöntemleri kullanılarak bulanık gözlemlere sahip bulanık bir zaman serisine dönüştürülür. Bulanık ilişkilerin belirlenmesi aşamasında bulanık zaman serilerinin gözlemleri arasındaki bulanık ilişkiler modellenir. Bulanık ilişkilerin modellenmesi aşamasından elde edilen bulanık tahminler, berraklaştırma aşamasında benimsenen bir yaklaşımla gerçek tahminlere dönüştürülerek karar vericiye sunulur. Bulanık zaman serileri literatürü incelendiğinde, yöntemlerin tahmin performansını iyileştirmek amacıyla analiz sürecinin her üç aşaması için de farklı yaklaşımların ortaya konulduğu görülmektedir. İlk çalışmalarda ortaya konan yöntemler, bulanıklaştırma aşamasında evrensel küme parçalanmasını kullanmaktadır. Bu işlem belirlenen aralık

uzunlukları ve aralıklara dayalı olarak gerçekleştirilir. Song ve Chissom [1, 3, 4] ve Chen [5, 6] aralık uzunluklarını sabit ve öznel kararlara dayalı olarak belirlemişlerdir. Huarng ise aralık uzunluklarını ortalama ve dağılım tabanlı bir yaklaşımla belirlemiş ve öznel yargıların etkisi ortadan kaldırılmıştır [7]. Ayrıca Eğrioğlu ve arkadaşları [8, 9] optimizasyon süreci içerisinde sabit aralık uzunluklarının belirlendiği farklı yaklaşımlar ortaya koymuşlardır. Huarng ve Yu, özellikle trend içeren zaman serilerinin tahmininde tahmin performansını artırmak amacıyla evrensel küme parçalanması aşamasında değişen aralık uzunlukları üreten orana dayalı bir yaklaşım kullanmışlardır [10]. Öte yandan, Yolcu ve arkadaşları bu fikri daha da geliştirmiş ve oranın optimizasyonunu önermiştir [11]. Panigrahi ve Behera ortalamaya dayalı bir model geliştirmiştir [12]. Bu yaklaşımlara ek olarak; bulanıklaştırma aşamasında, Cheng ve Chung ile Lee ve arkadaşları [13, 14] genetik algoritma kullanırken, Kuo ve arkadaşları [15, 16], Davari ve arkadaşları [17], Hsu ve arkadaşları [18], Aladağ [19], Çağcağ Yolcu ve Lam [20] bulanıklaştırma işlemini parçacık sürü optimizasyonu algoritması ile gerçekleştirmişlerdir. Ayrıca, Yolcu ve arkadaşları [21], Cai ve arkadaşları [22] ve Jiang ve arkadaşları [23], reel zaman serilerini bulanık zaman serilerine dönüştürmek için sırasıyla yapay arı kolonisi, karınca kolonisi ve harmoni arama algoritmalarını kullanmışlardır. Ayrıca Cheng ve arkadaşları [24], Li ve arkadaşları [25], Alpaslan ve Çağcağ Yolcu [26], Eğrioğlu ve arkadaşları [27], Wei ve arkadaşları [28], Cheng ve arkadaşları [29], Sun ve arkadaşları [30], Wang ve Liu [31] ve Çağcağ Yolcu ve Alpaslan [32] bulanıklaştırma aşamasında evrensel küme parçalanması yerine bulanık C-ortalamalar kümeleme yöntemine dayalı yaklaşımları tercih etmişlerdir.

Bulanık zaman serilerinin iç ilişkilerinin belirlendiği bulanık ilişkilerin belirlenmesi aşamasında Song ve Chissom [1, 3, 4] matris işlemlerine dayalı yaklaşımlar kullanırken, Sullivan ve Woodall [33] Markov zincirlerinden oluşan dönüşüm matrislerini kullanmıştır. Diğer yandan, Chen [5, 6], Cheng ve arkadaşları [29] ve Koçak [34, 35] bulanık ilişkileri tablolar ile belirlemişlerdir. Yapay sinir ağlarının kullanımının yaygınlaşması ile birlikte Huarng ve Yu [36], Aladağ ve arkadaşları [37], Koçak ve arkadaşları [38], Wei ve arkadaşları [28], Wang ve Xiong [31], Chen ve Chen [39], Arslan ve Çağcağ Yolcu [40] farklı yapılar sahip yapay sinir ağı modelleri ile bulanık ilişkileri belirlemişlerdir. Yapay Sinir Ağları (YSA) kullanımı popüler bir araç haline gelmesine rağmen, gizli katman nöron sayısının fazlalığı çözülmesi gereken bir sorundur. Bu doğrultuda Çağcağ Yolcu [41] tarafından, gizli tabaka birim sayısı belirleme problemi

olmayan ve PSO ile eğitilmiş tek çarpımlı nöron modeli YSA ile bulanık ilişkiler belirlenmiştir. Tüm bu çalışmalara ek olarak Yu ve Huarng [42], Alpaslan ve Çağcağ Yolcu [26], Alpaslan ve arkadaşları [43] ve Yolcu ve arkadaşları [44] yapay sinir ağları ile bulanık ilişkilerin belirlenmesinde gözlemlerin üyelik derecelerini dikkate alan tahmin modelleri önermişlerdir. Bulanık zaman serisi analiz sürecinin son aşaması için merkezileştirme (centroid) yöntemi yaygın bir şekilde tercih edilmesine rağmen, Cheng ve arkadaşları [45] ve Aladağ ve arkadaşları [46] berraklaştırma aşaması için uyarlanabilir beklenti yöntemini (adaptive expectation method) kullanmışlardır. Tüm bu çalışmalar göstermektedir ki; bulanık zaman serisi tahmin modellerinin performansları modellerin aşamalarının her birine oldukça bağımlıdır ve bu aşamalarda yapılacak bazı değişimlerle performansları iyileştirilebilir. Bulanık zaman serisi modellerinin yanı sıra, çıktıları bulanık mantıktan ve bir grup bulanık kurallardan (if-then), türeten bir tür doğrusal olmayan eşleme olan çıkarım tabanlı sistemler de popüler hale gelmiştir. Bulanık mantık tabanlı bir model olan Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) algoritması zaman serilerinin tahmini için yaygın olarak kullanılmaktadır. Literatürde Sarıca ve arkadaşları [47], Catalao ve arkadaşları [48], Chang [49], Cheng ve arkadaşları [50, 51], Ho ve Tsai [52] ve Pousinho ve arkadaşları [53] tahmin problemlerinde ANFIS kullanmışlardır.

Öte yandan, bu çalışmanın temel fikrini oluşturan Tip-1 Bulanık Fonksiyonlar (T1FF'ler), basitliği ve kural gerektirmeyen yapısı nedeniyle bir Bulanık Çıkarım Sistemi (FIS) yaklaşımı olarak son zamanlarda daha popüler hale gelmiştir. Türkşen [54] ilk olarak regresyon ve sınıflama problemlerinin çözümü için T1FF olarak adlandırılan bir bulanık fonksiyon yaklaşımını tanıtmış ve bu yaklaşım bir regresyon mantığı çerçevesinde belirlenen bulanık küme sayısına eşit sayıdaki regresyon fonksiyonun her birinin eş zamanlı kullanımı ile zaman serisi tahmini için de kullanılmıştır. Aladağ ve arkadaşları [55] daha iyi tahmin performansları elde edebilmek için zaman serilerinin gecikmeli değişkenlerini açıklayıcı değişken olarak dikkate almışlardır. Daha sonra Aladağ ve arkadaşları [56], T1FF'lerin girdilerinin gecikmeli değişkenlerinin ikili (binary) parçacık sürüsü optimizasyonu ile belirlendiği başka bir tahmin yöntemi önermiştir. Tak ve arkadaşları [57] çalışmalarında hareketli ortalama (MA) modelini

dikkate alarak T1FF'leri kullanmışlardır. Bunlara ek olarak, Goudarzi [58] ve Zarandi [59] tarafından T1FF'leri kullanan çeşitli çalışmalar da önerilmiştir.

Literatür detaylı olarak incelendiğinde, yapay zeka ve bulanık mantık temelli tahmin araçlarının zaman serisi tahminine hizmet etmek için yaygın olarak kullanıldığı görülmektedir. Ancak zaman serileri çok çeşitli ve kaotik ilişkilerden oluşabildiği için doğru tahminler elde etmek oldukça zor bir iştir. Bulanık regresyon fonksiyonları (FRF) yaklaşımı, serilerin reel değerlerinin yanı sıra üyeliklerin bazı dönüşümlerini de kullanarak daha fazla bilgi içeren bir model oluşturur. Bununla birlikte, FRF'nin girdilerinin bir dizi doğrusal fonksiyonunun bir kombinasyonu olan bütünsel bir model oluşturduğu unutulmamalıdır. Girdi ve çıktı arasındaki ilişki her zaman basit bir şekilde doğrusal değildir. Bu durum, bulanık regresyon fonksiyonları literatüründe doldurulması gereken boşluklardan biridir. Ayrıca literatürdeki FRF çalışmalarında her bir bulanık fonksiyon çoklu doğrusal regresyon modelinden oluşturulmasına rağmen bu modelin temel varsayımları incelenmemiş ve modelin geçerliliği kontrol edilmemiştir. Bu doğrultuda, sunulan modelin geçerliliği önemli bir husustur ve kontrol edilmesi gerekmektedir. Bu çalışmada, ileri beslemeli sinir ağlarına dayalı doğrusal olmayan yapıya sahip bulanık regresyon fonksiyonları oluşturularak bu boşlukların doldurulması amaçlanmıştır. Bu çalışmada, yeni bir yaklaşım olarak, girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri modelleyebilen Bulanık Regresyon Ağı Fonksiyonları tanıtılmıştır. Önerilen yaklaşımda, her bir bulanık fonksiyon, doğrusal regresyon modeli yerine İleri Beslemeli Yapay Sinir Ağları (FFNN) ile oluşturulmuş ve girdiler ile çıktılar arasında doğrusal olmayan eşleştirme elde edilmiştir. Ayrıca, önerilen FRNF yaklaşımının yapısı ve FFNN'nin bulanık bir fonksiyon olarak kullanılması nedeniyle, katı varsayımlara ve bu varsayımların incelenmesine gerek duyulmaz. Bunun yanı sıra, önerilen yaklaşımın doğrusal olmayan eşleştirme sağlama kabiliyeti nedeniyle üstün

tahmin performansına sahip olduđu da birçok gerek zaman serisi üzerinde gsterilmiřtir. nerilen yntemin literature katkısını maddeler halinde zetlemek gerekirse;

- nerilen FRNF, serilerin gerek deęerlerinin yanı sıra yeliklerin bazı dnüşmlerini de kullanarak daha gereki bir yaklaşıma sunar ve ayrıca daha fazla bilgi ieren bir model oluřturur.
- Bulanık ıkarım sistemleri genellikle kural tabanlıdır ve genellikle uzman grüşne ihtiya duyar T1FRF'nin yaklaşıma bu sorunu zmiř olsa da; retilen fonksiyonlar parametreler aısından doęrusaldır. Ancak buna karřın birçok gerek hayat problemi ise doęrusal deęildir. Bu nedenle, nerilen FRNF'ler zaman serilerinde bulunan doęrusal olmayan iliřkileri modellemek iin FFNN'leri kullanır.
- Literatürdeki T1FRF alıřmalarında her bir bulanık fonksiyon oklu doęrusal regresyon modelinden oluřmasına raęmen bu modelin temel varsayımları grmezden gelinmiřtir. Ayrıca Modelin geerlilięi de kontrol edilmemiřtir. Bu aıdan bakıldığında, nerilen FRNF'lerin doęrusal regresyon modelinde var olan katı varsayımları saęlamasına ihtiya bulunmamaktadır.
- FRNF hem hesaplamalı hem de bulanık tabanlı modellerin avantajlarını sunmaktadır.
- Ayrıca, nerilen FRNF'ler, bu tezde kullanılan neredeyse tm zaman serisi veri kmeleri iin tahmin doęruluęunu artırarak son derece iyi bir performans sergilemektedir.

olarak zetlenebilir.

Bu tezin geri kalan kısmı řu řekilde ilerlemektedir. İkinci blmde, Bulanık C-Ortalamlar, Tip 1 Bulanık Fonksiyonlar ve İleri Beslemeli Yapay sinir Aęları hakkında bilgi verilmiřtir. Ünc blmde, nerilen yeni yaklaşıma da ieren metodoloji detaylı bir řekilde zellikleriyle birlikte sunulmaktadır. Drdnc blmde, uygulama ve uygulamanın kapsamlı sonularına iliřkin karřılařtırmalı yorum ve deęerlendirme ile inceleme yapılmıřtır. Elde edilen bulgular ve sonular ise beřinci blmde tartıřılmaktadır.

2. İLİŞKİLİ YÖNTEMLER

2.1.Bulanık C-Ortalamalar

Bulanık kümeleme yöntemlerinin kullanılmasındaki en temel amaç küme elemanlarının kümelere ne ölçüde üye olduklarının belirlenmesi ve bu konuda büyük önem taşıyan üyelik fonksiyonlarının hesaplanabilmesidir. Bu sayede birbirleriyle uyum içinde olan kümelerin belirlenmesine olanak sağlanır.

Bulanık kümeleme yöntemlerinin yapı taşıını oluşturan Bulanık C- Ortalamalar (FCM) algoritması, özünde amaç fonksiyonu üzerine kurulmuş birbirleriyle belirli bir kıstas çerçevesinde benzer özellikler taşıyan verilerin kümelenmesi için kullanılır. FCM algoritması literatürde sıklıkla kullanılan bulanık kümeleme yönteminden biri olmakla beraber çoğu kümeleme yönteminin de temelini oluşturmaktadır.

FCM algoritmasında ilk adım olarak her bir veri noktası için birden çok kümeye aidiyetliği olabilen üyelik değerlerinin bulunması hedeflenir. Bulunan bu üyelik değerlerinin $[0, 1]$ arasında değişkenlik gösteren değerlerden olması gereklidir. Ayrıca bu üyelik değerlerinin toplamı da 1 olmalıdır. Üyelik değerlerinin belirlenmesinde küme merkezine yakınlık büyük önem taşımaktadır. Küme merkezine yakınlık arttıkça üyelik derecesinin değeri büyürken merkezden uzaklaştığında bu değer küçülmektedir.

Bulanık C-ortalamalar algoritması Bezdek [60] tarafından önerilen bulanık parçacıklı kümeleme algoritmalarından biridir. FCM yaklaşımı, her sınıf için bir üyelik derecesi atayan bulanık bir üyelik kullanır. Veri, gruplar için hata kareler toplamını minimize ederek bulanık kümelere ayrılır. Bulanık C-ortalamalar algoritmasının amaç fonksiyonunun hesaplanmasında üyelik değeri ve Euclidian uzaklığı kullanılır. Minimize edilmeye çalışılan amaç fonksiyonunun formu Denklem (2.1) de verilmiştir.

$$J_m(X, V, U) = \sum_{i=1}^c \sum_{j=1}^N u_{ij}^{\beta} d^2(x_j, v_i) \quad (2.1)$$

Burada u_{ij} üyelik değerini, v_i küme merkezlerini N ise gözlem sayısını göstermektedir. Öte yandan β , elde edilen kümelerin bulanıklığını tanımlayan ağırlıklandırma üssüdür (β

> 1) ve $d(x_j, v_i)$ ise gözlem ile küme merkezi arasındaki uzaklık ölçüsüdür. J_β Eşitlik (2.2) de verilen kısıtlar altında minimize edilmeye çalışılır.

$$\begin{aligned} 0 &\leq u_{ij} \leq 1, \forall i, j \\ 0 &\leq \sum_{j=1}^n u_{ij} \leq n, \quad \forall i \\ \sum_{i=1}^c u_{ij} &= 1, \quad \forall j \end{aligned} \tag{2.2}$$

J_β 'nın amaç fonksiyonunun minimizasyon işlemi tekrarlamalı olarak gerçekleştirilir. Bu süreçte u_{ij} ve v_i değerleri Denklem (2.3) ve Denklem (2.4) de belirtilen şekliyle güncellenir.

$$v_i = \frac{\sum_{j=1}^n u_{ij}^\beta X_j}{\sum_{j=1}^n u_{ij}^\beta} \tag{2.3}$$

$$u_{ij} = \frac{1}{\sum_{k=1}^c \left(\frac{d(X_j, v_i)}{d(X_j, v_k)} \right)^{2/(\beta-1)}} \tag{2.4}$$

FCM algoritmasında ilk adım olarak her bir veri için birden çok kümeye aidiyetliği olabilen üyelik değerlerinin bulunması hedeflenir. Bulunan bu üyelik değerlerinin $[0, 1]$ arasında değişkenlik gösteren değerlerden olması gereklidir. Ayrıca bu üyelik değerlerinin toplamı da 1 olmalıdır. Üyelik değerlerinin belirlenmesinde küme merkezine yakınlık büyük önem taşımaktadır. Küme merkezine yakınlık arttıkça üyelik derecesinin değeri büyürken merkezden uzaklaştığında bu değer küçülmektedir.

FCM algoritması tıp, ekonomi, yapay zekâ, görüntü işleme vb. sayısız alanda araştırmacılara uygulama imkânı sunmuş ve çalışmaların hızlı ve verimli bir şekilde yapılmasını sağlamıştır.

2.2. Tip 1 Bulanık Regresyon Fonksiyonları

Türkşen [61] tarafından önerilen Tip-1 bulanık regresyon fonksiyonları (T1FRF), çoklu doğrusal regresyon modeline ve FCM'ye dayanmaktadır. T1FRF'lerde bulanık küme

sayısı kadar fonksiyon kullanılmaktadır. Her bir bulanık küme için oluşturulan regresyon modellerinde, girdiler, orijinal zaman serisi gözlemlerine ek olarak, ilgili bulanık kümenin üyelik değerleri ve bu üyeliklerin bazı fonksiyonlarından oluşmaktadır. Her bir regresyon denkleminin ürettiği çıktılar/tahminler, ilgili üyelik değerleri ile ağırlıklandırılarak nihai tahminlere dönüştürülmektedir. “c” bulanık küme sayısını temsil etmektedir. Dolayısıyla, her bir bulanık küme için regresyon fonksiyonu Denklem (2.5)'te verilmiştir.

$$Y^{(i)} = X^{(i)}\beta^{(i)} + \varepsilon^{(i)}, \quad i = 1, 2, \dots, c \quad (2.5)$$

Bu durumda, açıklayıcı (girdiler) ve bağımlı (hedefler) değişkenler Denklem (2.6) ve Denklem (2.7)'de verilmiştir.

$$X^{(i)} = \begin{bmatrix} u_{i1} & u_{i1}^2 & \exp(u_{i1}) & \log\left(\frac{1-u_{i1}}{u_{i1}}\right) & x_{11} & x_{21} & \dots & x_{p1} \\ u_{i2} & u_{i2}^2 & \exp(u_{i2}) & \log\left(\frac{1-u_{i2}}{u_{i2}}\right) & x_{12} & x_{22} & \dots & x_{p2} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \dots & \vdots \\ u_{iN} & u_{iN}^2 & \exp(u_{iN}) & \log\left(\frac{1-u_{iN}}{u_{iN}}\right) & x_{1N} & x_{2N} & \dots & x_{pN} \end{bmatrix}, i = 1, 2, \dots, c \quad (2.6)$$

$$Y^{(i)} = [y_1 \quad y_2 \quad \dots \quad y_N]^T \quad (2.7)$$

Her bir T1FRF'yi tahmin etmek için OLS (sıradan en küçük kareler) yöntemi kullanılır. Böylelikle, tahmin edilen fonksiyon Denklem (2.8)'deki gibi olmaktadır.

$$\hat{Y}^{(i)} = X^{(i)}\hat{\beta}^{(i)}, \quad i = 1, 2, \dots, c \quad (2.8)$$

Burada, $\hat{\beta}^{(i)}$ Denklem (2.9) da yer alan matris işlemleri kullanılarak OLS yöntemi ile elde edilir.


$$\hat{\beta}^{(i)} = (X^{(i)'}X^{(i)})^{-1}X^{(i)'}Y^{(i)}, \quad i = 1, 2, \dots, c \quad (2.9)$$

Her bir veri noktası için her bir bulanık fonksiyon tarafından üretilen çıktılar (tahminler), karşılık gelen üyelik değerleriyle ağırlıklandırılarak Denklem (2.10)'daki gibi nihai tahminlere dönüştürülür.

$$\hat{y}_k = \frac{\sum_{i=1}^c \hat{y}_{ik} u_{ik}}{\sum_{i=1}^c u_{ik}}, \quad k = 1, 2, \dots, N \quad (2.10)$$

2.3.İleri Beslemeli Yapay Sinir Ağları

Öğretmenli algoritmaların içerisinde yer alan FFNN araştırmacılar tarafından çeşitli alanlarda sıklıkla kullanılan Yapay Sinir Ağları (YSA) türlerinden biridir. FFNN kullanım alanlarına örnek vermek gerekirse genellikle verilerin analiz edinmesi, verilerin sınıflandırılması ve tahmin edilmesini örnek olarak sayabiliriz. Ayrıca sunduğu avantajlar nedeniyle zaman serisi öngörüsünde de sıklıkla kullanılmaktadır. FFNN’de bilgi girişten çıkışa doğru tek yönlü olarak hep ileriye doğru gerçekleşmektedir. Şekil 2.1 de FFNN modeline ait görsel yer almaktadır.



Şekil 2.1. FFNN modeli.

FFNN’ler özünde 3 katmandan oluşmaktadır. Bunlar giriş, gizli ve çıkış katmanlarıdır. Giriş katmanı verilerin ilk girişinin yapıldığı katman olup gizli katman ya da katmanlarda veriler işlenerek eğitim sürecinin tamamlanmasıyla çıkış katmanında yanıtlar verilir. Katmanların her birinde nöronlar yer almaktadır. Birbirini takip eden nöronlar arasında kesintisiz kuvvetli bir bağ mevcutken katmanlar içinde bu bağdan söz etmek mümkün değildir.

3. METERYAL VE YÖNTEM

3.1.Önerilen Bulanık Regresyon Ağ Fonksiyonları (FRNF)

Yapay sinir ağları zaman serisi tahmin problemlerinde yaygın olarak kullanılmasına rağmen, ilişkiler belirlenirken veri yapısındaki varlığı kaçınılmaz olan belirsizlik anlamlı bir şekilde dikkate alınmamaktadır. Oysa bu belirsizlik hem bulanık ilişkilerin varlığını hem de bunların modellenmesinin gerekliliğini ortaya koymaktadır. Bu noktada T1FRF'ler bu anlamda literatüre önemli bir katkı sağlamış olsa da her bir bulanık fonksiyon çoklu doğrusal regresyon modelinden oluştuğu için çıktıları girdilerin doğrusal bir fonksiyonu olarak üretmektedir. Kısacası, parametreler açısından doğrusal bir model içerir. Ancak birçok zaman serisi doğrusal olmayan ilişkiler içermektedir. Bu bağlamda, bu tez çalışmasında yapay sinir ağlarının veriye üstün uyum yeteneği ve doğrusal olmayan ilişkileri modelleme yeteneği sayesinde zaman serisi tahmini için üstün bir tahmin aracı ortaya konulmuştur. Tez çalışmasında, tanıtılan yeni yaklaşımın girdileri sadece FCM tarafından üretilen üyeliklerden değil, aynı zamanda bu üyeliklerin bazı fonksiyonlarından ve reel değerli gecikmeli değişkenlerden oluşmaktadır. Bu yaklaşımda her bir regresyon fonksiyonu bir FFNN'den oluşmaktadır.

Bu tez çalışmasında, üyelik dönüşümlerinden elde edilen daha fazla bilgiyi girdilere dönüştürerek FRF'den yararlanan ve FFNN'leri bir araç olarak kullanarak doğrusal olmayan ilişkileri modelleme yeteneğine sahip bir tahmin aracı önerilmiştir.

Bu bilgiler ışığında önerilen yaklaşımın algoritması 8 adımda özetlenmiştir:

Adım 1 Sürecin tüm gerekli parametreleri belirlenir.

$maxitr$	: Maksimum iterasyon (yineleme) sayısı
p	: Reel değerli gecikmeli değişken sayısı
K	: Gizli katman nöron sayısı
t_{tr}	: Eğitim kümesinin (setinin) uzunluğu
t_{val}	: Doğrulama kümesinin (setinin) uzunluğu
t_{test}	: Test kümesinin (setinin) uzunluğu
c	: Bulanık küme sayısı
β_f	: Bulanıklık indeksi

Adım 2 Veri kümesini parçalama işlemi gerçekleştirilir.

Veri kümesi (seti) eğitim, doğrulama ve test kümesi (seti) olmak üzere üç bölüme ayrılmıştır. Veri kümesini (setini) bölümlenmek için, veriye bağımlılığın olması nedeniyle bir blok bölümlenme yapısı kullanılmıştır. Bu yapı Denklem (3.1), Denklem (3.2), Denklem (3.3) ve Denklem (3.4) de verilmiştir.

$$X = [x_{it}], i = 1, 2, \dots, p ; t = 1, 2, \dots, T - p \quad (3.1)$$

$$X_{tr} = [x_{it}], i = 1, 2, \dots, p ; t = 1, 2, \dots, t_{tr} \quad (3.2)$$

$$X_{val} = [x_{it}], i = 1, 2, \dots, p ; t = t_{tr} + 1, t_{tr} + 2, \dots, t_{tr} + t_{val} \quad (3.3)$$

$$X_{test} = [x_{it}], i = 1, 2, \dots, p ; t = t_{tr} + t_{val} + 1, t_{tr} + t_{val} + 2, \dots, T \quad (3.4)$$

Burada T, zaman serisindeki gözlem sayısını temsil etmektedir. Ayrıca, X veri setinin bütünü temsil ederken X_{tr} , X_{val} ve X_{test} , sırasıyla, eğitim, doğrulama ve test veri setlerini temsil etmektedir.

Adım 3 Verilere bir standardizasyon işlemi uygulanır.

Bu adımda, farklı ölçeklerde değerler alan veri kümelerinin yapısını ortak bir veri ölçeğine dönüştürebilmek için veri standardizasyonu Denklem (3.5)'deki gibi gerçekleştirilir;

$$\text{Ölçekli}_{Gözlem} = \frac{\text{Gerçek Gözlem} - \text{Minimum}_{Eğitim Gerçek Gözlemi}}{\text{Maksimum}_{Eğitim Gerçek Gözlem} - \text{Minimum}_{Eğitim Gerçek Gözlem}} \quad (3.5)$$

Adım 4 FCM kümeleme algoritması uygulanır.

FCM, bulanık küme sayısı olan c'ye bağlı olarak eğitim seti üzerinde uygulanır. FCM için girdi matrisi Denklem (3.6) ve Denklem (3.7) 'de verilmiştir,

$$X_{tr} = [X_{t-1}, X_{t-2}, \dots, X_{t-p}] \quad (3.6)$$

Bu şu anlama geliyor;

$$X_{tr} = \begin{bmatrix} x_p & x_{p-1} & \cdots & x_1 \\ x_{p+1} & x_p & \cdots & x_2 \\ \vdots & \vdots & \cdots & \vdots \\ x_{t_{tr}-1} & x_{t_{tr}-2} & \cdots & x_{t_{tr}-p} \end{bmatrix} \quad (3.7)$$

Böylece, μ_{tk} , $t = 1, 2, \dots, t_{tr} - p$; $k = 1, 2, \dots, c$ üyelik değerleri ve v_k küme merkezleri elde edilir.

Adım 5 Girdi matrisi oluşturulur.


Bu adımda, her bir bulanık regresyon ağı için bir girdi matrisi oluşturulur. Girdi matrisi gecikmeli değişkenlerden, üyeliklerden ve bu üyeliklerin bazı dönüşümlerinden oluşur. k^{th} , $k = 1, 2, \dots, c$ bulanık regresyon ağı için girdi matrisi Denklem (3.8) de verilmiştir.

$${}^{(k)}X = \begin{bmatrix} {}^{(k)}\mu_1 & {}^{(k)}\mu_1^2 & \exp({}^{(k)}\mu_1) & \log\left(\frac{1-{}^{(k)}\mu_1}{{}^{(k)}\mu_1}\right) & x_p & x_{p-1} & \cdots & x_1 \\ {}^{(k)}\mu_2 & {}^{(k)}\mu_2^2 & \exp({}^{(k)}\mu_2) & \log\left(\frac{1-{}^{(k)}\mu_2}{{}^{(k)}\mu_2}\right) & x_{p+1} & x_p & \cdots & x_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \cdots & \vdots \\ {}^{(k)}\mu_{t_{tr}-p} & {}^{(k)}\mu_{t_{tr}-p}^2 & \exp({}^{(k)}\mu_{t_{tr}-p}) & \log\left(\frac{1-{}^{(k)}\mu_{t_{tr}-p}}{{}^{(k)}\mu_{t_{tr}-p}}\right) & x_{t_{tr}-1} & x_{t_{tr}-2} & \cdots & x_{t_{tr}-p} \end{bmatrix} \quad (3.8)$$

Bu girdilere karşılık gelen hedef değerler Denklem (3.9)'daki gibidir.

$${}^{(k)}Y = [x_{p+1}, x_{p+2}, \dots, x_{t_{tr}}]^T \quad (3.9)$$

Önerilen yaklaşımın temel yapısı Şekil 3.1'de görsel olarak verilmiştir.



Şekil 3.1. Önerilen Bulanık Regresyon Ağı Fonksiyonlarının mimarisi.

Adım 6 Ağların eğitimi gerçekleştirilir.

Potansiyel parametre değerlerine bağlı olarak, ağlar olası tüm kombinasyonlar için eğitilir. Sinir ağlarının eğitimi Levenberg Marquardt geri yayılım algoritması ile gerçekleştirilir. Her kombinasyon için eğitilen ağ fonksiyonlarının sayısı bulanık küme sayısına eşittir. Her bir bulanık regresyon ağ fonksiyonu, girdilerinin doğrusal olmayan bir kombinasyonu olarak çıktılar (tahminler) üretir. Bu çıktılar ilgili gözlem kümesinin üyelik değerleri ile ağırlıklandırılır ve böylece nihai çıktılara dönüştürülür.

Adım 7 En iyi parametre kombinasyonu belirlenir.

Doğrulama setlerinin veri noktaları, eğitilen ağlar için örneklem dışı olarak girdilere dönüştürülür. Bu amaçla öncelikle doğrulama seti için Denklem (3.10)'daki gibi gecikmeli değişkenler oluşturulur. Doğrulama seti için ayrıca denklem (3.11)'de verilen hedef değerler vektörü de oluşturulur.

$$X_{val} = \begin{bmatrix} x_{t_{tr}} & x_{t_{tr}-1} & \cdots & x_{t_{tr}-p} \\ x_{t_{tr}+1} & x_{t_{tr}} & \cdots & x_{t_{tr}-p+1} \\ \vdots & \vdots & \cdots & \vdots \\ x_{t_{tr}+t_{val}-1} & x_{t_{tr}+t_{val}-2} & \cdots & x_{t_{tr}+t_{val}-p} \end{bmatrix} \quad (3.10)$$

$${}^{(k)}_{val}Y = [x_{t_{tr}+1}, x_{t_{tr}+2}, \cdots, x_{t_{tr}+t_{val}}]^T \quad (3.11)$$

İkinci olarak, üyelik değerleri FCM tarafından belirlenen küme merkezlerine göre Denklem (3.12)'deki gibi hesaplanır.

$$\mu_{tk} = \frac{1}{\sum_{l=1}^c \left(\frac{d(X_t, v_k)}{d(X_t, v_l)} \right)^{2/(\beta-1)}}, \quad k = 1, 2, \cdots, c \quad (3.12)$$

Ayrıca doğrulama kümesi için üyelikler, üyeliklerin bazı dönüşümleri ve gerçek değerlere sahip gecikmeli değişkenler eğitilen sinir ağlarının girdilerini oluşturur. Doğrulama kümesi için uygunluk fonksiyonu değerleri, eğitilen sinir ağlarının nihai çıktıları üzerinden hesaplanmaktadır. Bu süreçte uygunluk fonksiyonu olarak Ortalama Karesel

Hata (OKH) kriteri alınmıştır. Böylece doğrulama seti için Denklem (3.13)'de verilen en düşük MSE değerini veren kombinasyon en iyi parametreler değeri olarak belirlenmiştir.

$$OKH = \sqrt{\frac{1}{t_{val}} \sum_{t=1}^{t_{val}} (Hedef_t - Öngörü_t)^2} \quad (3.13)$$

Adım 8 En iyi parametre kombinasyonu ile test seti için tahminler elde edilir.

Önerilen FRNF'lerin performansını değerlendirmek için örneklem dışı veri kümesi için tahminler elde edilir. Doğrulama kümesine benzer şekilde test kümesi için de üyelikler ve girdi matrisi oluşturulabilir. Test setinin tahminleri, parametre değerlerinin en iyi kombinasyonu kullanılarak FRNF'ler tarafından üretilir ve üyelik dereceleri aracılığıyla nihai tahminlere dönüştürülür.

4. UYGULAMA SONUÇLARI VE DEĞERLENDİRME

4.1. Veri Hazırlığı

Önerilen FRNF'lerin tahmin kapasitesi ve performansları çeşitli finansal zaman serisi uygulamaları ile incelenmiştir. Bu zaman serileri Tayvan Borsası Kapitalizasyon Ağırlıklı Hisse Senedi Endeksi (TAIEX) ve İstanbul Menkul Kıymetler Borsası'dır (IEX). Veri kümeleri, ilgili uygulama özellikleri ile birlikte Tablo 4.1'de özetlenmiştir.

Tablo 4.1. Uygulama özellikleri ve veri setleri.

Seri No	Zaman Serileri	Yıl	Gözlemler	Boyut Eğitim Seti	Boyut Doğrulama & Test Seti
1	TAIEX	2000	271	177	47
2		2001	244	158	43
3		2002	248	162	43
4		2003	249	163	43
5		2004	250	160	45
6	TAIEX	2008	249	163	43
7		2009	247	159	44
8		2010	250	160	45
9		2011	247	159	44
10		2012	246	162	42
11		2013	244	158	43
12		2014	248	162	43
13		2015	244	156	44
14		2016	242	154	44
15		2017	243	157	43
16		2018	245	161	42
17 / 22	IEX	2009	103 / 103	89 / 73	7 / 15
18 / 23		2010	104 / 104	90 / 74	7 / 15
19 / 24		2011	106 / 106	92 / 76	7 / 15
20 / 25		2012	106 / 106	92 / 76	7 / 15
21 / 26		2013	106 / 106	92 / 76	7 / 15

Veri setleri eğitim, doğrulama ve test seti olmak üzere üç bölüme ayrılmıştır. Potansiyel parametre değerlerine bağlı olarak, ağlar tüm olası kombinasyonlar için eğitilmiştir.

En iyi parametre kombinasyonu doğrulama setleri üzerinde belirlenmiştir. Performans değerlendirmesi ise test setleri üzerinde ele alınmıştır. Doğrulama ve test setlerinin boyutu tüm uygulamalarda birbirine eşit olarak seçilmiştir. Toplamda 26 farklı veri seti için analizler gerçekleştirilmiştir.

Ayrıca, en iyi hiper-parametreleri belirlemek için grid-search algoritması kullanılmıştır. Grid-search' de arama uzayının noktalarını üreten temel hiper-parametreler ve bunların potansiyel değerleri Tablo 4.2'de verilmiştir.

Tablo 4.2. Hiper-parametrelerin olası değerleri.

Bulanik Kümeler	Gecikmeli Net Değişken	Gizli Katman Nöron	Bulanıklık İndeksi	Modelin Hedefi
3 den 7 ye	2 den 5 e	2 den 5 e	(1.8, 1.9, 2.0, 2.1, 2.2)	1

4.2. Performans Ölçütü

Tanıtilan yaklaşım olan FRNF'nin tahmin performansı farklı değerlendirme ölçütleri ile incelenmiştir. Birçok çalışmada olduğu gibi, performans ölçütü olarak Hata Kareler Ortalaması Karekökü (HKOK) ve Ortalama Mutlak Yüzdelik Hata (OMYH) kriterleri kullanılmıştır. Tahmin problemlerinde deneysel sonuçları doğrulamak için yaygın olarak kullanılan artıkların standart bir ölçüsü olan HKOK'nın formülasyonu Denklem (4.14)'te verilmiştir.

$$HKOK = \sqrt{\frac{1}{T} \sum_{t=1}^T (Hedef_t - Öngörü_t)^2} \quad (4.14)$$

HKOK kriteri modellerin karşılaştırılmasında etkili bir değerlendirme kriteri olarak kabul edilmekle birlikte, tek başına modelin ürettiği tahminlerin doğruluk derecesi, yani tatmin edici tahmin sonuçları üretip üretmediği hakkında net bilgi verememektedir. Bu noktadan hareketle, bu çalışmada önerilen modelin farklı açılardan değerlendirilebilmesi için OMYH de seçilmiştir. OMYH, model performansını anlamak ve karşılaştırmak için

kullanılabilecek, ölçekten bağımsız, bir ölçüm üretmektedir. Ayrıca, verilerin boyutundan bağımsız olarak bu doğruluğu yüzde olarak hesaplamaktadır. OMYH'nın formülasyonu Denklem (4.15)'te verilmiştir.

$$OMYH = \frac{1}{T} \sum_{t=1}^T \left| \frac{Hedef_t - \hat{Y}_t}{Hedef_t} \right| \times 100\% \quad (4.15)$$

Elde edilen tahmin sonuçlarının gerçek gözlemlerle ne kadar uyumlu olduğunu gösteren bir diğer bakış açısı ise tahminler ile hedefler arasında kurulacak bir doğrusal regresyon modeli tasarlamaktır. Bu doğrultuda, önerilen modelin tahmin performansını ortaya koyabilmek adına bir doğrusal regresyon modelinin bazı özellikleri incelenebilir. Denklem (4.16) ile verilen regresyon modelinin iki temel parametresi (β ve R^2), önerilen modelin performansını ölçmek için diğer ölçütler olarak kullanılmıştır.

$$Y_t = \beta \hat{Y}_t + \varepsilon_t \quad (4.16)$$

Tüm bu ölçütlerin dışında tahmin edilen ve ulaşılan değerler arasındaki uyumu ortaya koyan farklı grafikler de görsel ölçütler olarak kullanılmıştır.

4.3.Uygulama Sonuçları

Önerilen FRNF'lerin performansı, bazı farklı finansal zaman serisi analizlerinden elde edilen sonuçlar üzerinden değerlendirilmiştir.

4.3.1. TAIEX uygulamaları - 2000-2004 yılları arasındaki günlük veri setleri

İlk olarak, 2000-2004 yılları arasında kaydedilen günlük gözlemlenmiş TAIEX veri setleri önerilen FRNF'ler kullanılarak analiz edilmiştir. Üretilen tahmin sonuçları, RMSE ölçüsü cinsinden, karşılaştırmalı bir bakış açısı sağlamak amacıyla diğer bazı son teknoloji modellerin sonuçları ile birlikte Tablo 4.3 'te özetlenmiştir. Tablo4.3'te verilen bu sonuçlar değerlendirildiğinde, TAIEX 2000-2004 veri setleri için önerilen FRNF'ler tarafından üretilen tahminlerin en yüksek doğruluğa sahip olduğu görülmektedir. Önerilen model birçok bulanık zaman serisi yöntemine göre üstün performansa sahiptir. Ayrıca, önerilen FRNF yönteminin özellikle hem bazı YSA ((Evrışimli Sinir Ağları (CNN) ve Uzun Kısa Süreli Bellek (LSTM) [62]) hem de bazı T1FF yaklaşımları ([57, 63, 64]) ile karşılaştırıldığında daha üstün olduğu görülmektedir. Veri kümelerine


bütünsel bir bakış açısıyla yaklaşıldığında, önerilen FRFN'lerin ortalama ve medyan istatistikleri açısından da en iyi performansla sahip olduğu görülmektedir.

Tablo 4.3. TAIEX 2000-2004 veri setleri için kullanılan yöntemlerin performansları.

Modeller	Zaman Serileri / TAIEX Veri					HKOK'lar	
	Setleri					Ortalama	Medyan
	2000	2001	2002	2003	2004		
[1]	293	116	76	77	82	129	82
[5]	225	116	76	77	82	115	82
[7] ¹	473	359	234	247	384	339	359
[7] ²	473	810	116	308	384	418	384
[36]	133	124	82	62	85	97	85
[18]	152	130	84	56	116	108	116
[65]	154	124	93	66	72	102	93
[42]	131	130	80	58	67	93	80
[37]	168	120	76	58	63	97	76
[66]	129	113	67	54	60	85	67
[67]	124	115	71	58	58	85	71
[68]	131	113	66	52	54	83	66
[8]	255	130	84	56	116	128	116
[44]	227	102	66	51	55	100	66
[69]	126	114	65	54	53	82	65
[39]	125	115	65	53	53	82	65
[22]	132	113	60	52	50	81	60
[70]	140	120	77	60	59	91	77
[29]	126	113	63	51	54	81	63
[71]	180	134	81	77	55	105	81
[72]	129	110	60	51	53	81	60
[73]	127	110	62	53	53	81	62
[57]	128	106	65	52	54	81	65
[74]	137	115	66	57	61	87	66
[75]	124	112	63	52	54	81	63
[47]	123	111	66	52	54	81	66
[63]	120	113	63	49	52	79	63
[76]	122	110	54	51	50	77	54
[77]	122	107	64	52	53	80	64
[62]	105	110	60	51	50	75	60

LSTM [62]	136	101	89	92	70	98	92
[64]	118	104	64	51	52	78	64
Önerilen FRFNler	100	96	51	44	48	68	51

Tüm veri kümeleri için, önerilen tahmin aracının üstün performansının bir diğer kanıtı olarak, Şekil 4.1'deki görseller FRNF'ler tarafından üretilen tahminler ile gözlemlenen zaman serisi noktaları arasında güçlü bir tutarlılık olduğunu göstermektedir.



Şekil 4.1. Tahminler ve gözlemler arasındaki uyum.

Yine bu şekillerle birlikte verilen ve veri noktalarının gözlenen ve tahmin edilen değerleri arasında kurulan regresyon modellerinin parametre değerleri de aynı yöndeki sonuçlara

işaret etmektedir. Tüm TAIEX zaman serileri için tahmin edilen regresyon katsayısı ($\hat{\beta}$) ve determinasyon katsayısı (R^2), 1'e çok yakındır. Ayrıca, β için belirlenen 95% seviyesinde, tüm güven aralıkları 1'i kapsamaktadır. Bu bulgular, önerilen FRFN'ler yaklaşımının yüksek kabiliyete sahip bir tahmin aracı olduğunun kanıtı olarak görülebilir. Ayrıca performans ölçütü olarak Medyan Mutlak Yüzdelik Hata (OrMYH) ölçütü de Denklem (4.17) verilmiştir. TAIEX2000 ve TAIEX2001 veri kümeleri için elde edilen tahminler %2'nin altında OMYH ve OrMYH değerleri ile elde edilmiştir. Ayrıca, diğer 3 TAIEX zaman serisi için bu değerler %1 civarında hatta %1'in de altında elde edilmiştir.

$$OrMYH = Medyan \left(\frac{Hedef_t - \hat{Ongörü}_t}{Hedef_t} \right), t = \overline{1, T} \quad (4.16)$$

Parametreler için elde edilen en iyi değerler Tablo 4.4'te sunulmuştur.

Tablo 4.4. TAIEX 2000-2004 için parametreler için elde edilen en iyi değerler


Veri Setleri		Parametreler		
TAIEX	p	K	c	β_f
2000	5	4	3	1.9
2001	4	2	6	1.8
2002	4	2	5	1.8
2003	3	2	3	2.2
2004	3	3	5	1.8

4.3.2. TAIEX uygulamaları - 2008-2018 yılları arasındaki günlük veri seti


İkinci olarak, 2008'den 2018'e kadar günlük olarak gözlemlenen 11 TAIEX veri seti analiz edilmiştir. Elde edilen sonuçlar, diğer bazı çalışmalarda üretilen sonuçlarla karşılaştırılarak tartışılmıştır. HKOK metriği açısından sonuçlar Tablo 4.5'te verilmiştir. TAIEX veri setinin bu 11 yıla ait zaman serileri için önerilen yöntemin de en iyi tahmin performanslarını sergilediği Tablo 4.5 'den açıkça görülmektedir. Ayrıca 11 farklı zaman serisi için elde edilen HKOK değerlerinin ortalamasına bakıldığında yaklaşık %7'lik ((74,32-67,87)/74,32) bir ilerleme kaydedildiği görülmektedir.

Önerilen FRFN yaklaşımının bu TAIEX veri setleri için çok başarılı tahmin sonuçları ürettiğini gösteren bazı görsel grafikler de oluşturulabilir. Bu görseller, gözlenen ve


tahmin edilen değerleri ve aralarındaki artıkları gösteren grafiklerdir. Böyle bir görsel grubu Şekil 4.2'de ve devamında verilmiştir.




(a) TAIEX2008




(b) TAIEX2009




(c) TAIEX2010



(d) TAIEX2011




(e) TAIEX2012




(f) TAIEX2013


Şekil 4.2. TAIEX için gözlenen, tahmin edilen ve artık değerler (2008-2018)




(g) TAIEX2014




(h) TAIEX2015



(i) TAIEX2016



(j) TAIEX2017



(k) TAIEX2018

Şekil 4.2. TAIEX için gözlenen, tahmin edilen ve artık değerler (2008-2018) (devamı)

Şekil 4.2 ve devamı detaylı olarak incelendiğinde, tahmin edilen değerlerin gözlemlenen veri noktaları ile uyum içinde olduğu açıkça görülmektedir. Artık değerleri temsil eden kırmızı çizgiler, özellikle 3 yıla ait veri setleri (2011, 2016 ve 2018 yılları) haricinde, neredeyse tüm veri noktalarında oldukça kısadır. Bu 3 veri kümesi (2011, 2016 ve 2018 yılları) için bile, bazı artıklar nispeten büyük görünse de, yine de oldukça makul düzeyde hata seviyelerine işaret etmektedir. Oransal bir hata ölçütü olan OMYH değeri 2011 yılı

iin yaklaşık %1 gibi olađanüstü bir tahmin performansına sahipken, 2016 ve 2018 yılları iin ise bu deđerler %1'in bile altında kalmıřtır. OMYH deđerlerinin diđer yılların çođu iin %1'in bile altında olduđu düşünöldüğünde, önerilen FRNF yaklaşımının üstün performansı bir kez daha dikkat çekmektedir.

Parametreler iin elde edilen en iyi deđerler Tablo 4.6'da sunulmuřtur.



Tablo 4.5. TAİEX için HKOK açısından mevcut modellerin sonuçları (2008-2018).

Modeller	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017	2018	Ortalama HKOK
[4]	225.38	204.11	151.42	237.43	81.08	82.3	98.64	176.6	122.71	91.69	173.36	149.52
[5]	186.48	207.42	211.21	215.13	78.37	184.83	308.72	100.75	316.57	902.18	492.89	291.32
[7]	105.10	78.25	103.84	117.78	59.14	49.59	87.52	90.72	80.98	63.20	186.21	92.94
[78]	138.94	71.30	72.92	115.54	62.32	49.53	69.60	78.73	82.22	62.98	102.19	82.39
[79]	142.38	110.88	100.76	180.79	63.30	63.16	71.62	104.4	88.35	89.02	231.35	113.27
[10]	131.18	71.48	74.07	119.34	59.55	50.09	65.72	79.93	82.10	61.67	101.99	81.56
[65]	144.23	72.16	62.23	114.25	59.94	50.97	64.79	79.27	82.29	62.15	107.08	81.76
[42]	129.48	69.91	67.11	123.03	58.37	50.39	69.15	78.22	80.51	64.25	103.74	81.29
[18]	140.49	70.34	93.08	118.89	62.35	49.63	66.55	78.46	82.73	62.21	109.39	84.92
[80]	142.37	112.45	99.83	164.97	63.31	64.76	74.85	94.33	86.59	88.93	161.78	104.92
[81]	114.03	70.91	68.59	117.02	60.50	49.92	70.44	77.67	80.86	62.61	106.75	79.94
[82]	129.29	70.27	75.46	111.45	63.20	50.84	67.67	78.33	84.39	61.09	103.26	81.39
[83]	137.44	71.76	74.52	117.38	61.59	51.37	69.23	79.89	83.53	62.37	103.24	82.94
[84] ¹	108.52	121.46	75.33	128.46	60.43	51.17	79.44	94.92	80.39	78.76	88.23	87.92
[84] ²	108.57	68.57	52.15	113.38	58.84	48.87	65.90	80.22	82.24	64.31	74.52	74.32
[85]	140.19	73.22	80.37	124.38	62.53	52.39	66.26	82.78	80.14	61.98	99.03	83.93
[86]	126.29	73.77	143.53	122.49	60.73	55.38	66.15	79.47	83.18	65.54	203.72	98.20
[87]	140.48	70.63	67.46	121.27	61.10	50.23	67.08	80.65	81.12	66.34	98.13	82.23
[88]	113.03	72.30	62.82	113.69	60.45	50.17	68.28	78.65	82.43	62.49	104.49	78.98
Önerilen FRFNler	<u>95.81</u>	<u>59.85</u>	<u>51.38</u>	<u>106.07</u>	<u>51.68</u>	<u>46.32</u>	<u>60.04</u>	<u>70.98</u>	<u>69.59</u>	<u>58.00</u>	<u>74.31</u>	<u>67.87</u>

Tablo 4.6. TAIEX 2008-2018 için parametreler için elde edilen en iyi değerler

Veri Setleri		Parametreler		
TAIEX	p	K	c	β_f
2008	5	3	3	1.9
2009	3	3	6	2.1
2010	4	3	3	1.9
2011	2	5	7	2.2
2012	3	3	5	2.2
2013	2	4	3	1.9
2014	5	5	4	2.1
2015	4	4	6	1.9
2016	2	4	3	2.0
2017	4	3	4	2.0
2018	2	4	7	1.8

4.3.3. IEX uygulamaları

Son olarak, önerilen FRNF'lerin öngörü yeteneği 2009-2013 yılları arasındaki 5 farklı yılda gözlemlenen günlük IEX veri setleri analiz edilerek ortaya konmuştur. Her bir IEX zaman serisi için uzunlukları 7 ve 15 olan iki farklı test seti kullanılarak toplam 10 farklı analiz gerçekleştirilmiştir. Elde edilen sonuçlar hem geleneksel zaman serisi tahmin yöntemleri hem de bulanık tabanlı ve YSA tabanlı modeller ile karşılaştırmalı olarak değerlendirilmiştir. Bu amaçla, tüm tahmin modelleri için HKOK kriter değerleri Tablo 4.7'de verilmiştir. Önerilen FRFN'ler, tek bir IEX veri seti hariç tüm zaman serileri için en iyi tahmin performansını sergilemişlerdir. Özellikle test seti uzunlukları 7 olan 2010, 2011 ve 2013 yıllarındaki zaman serilerinde tahmin doğruluğunda 40% 'a yakın ilerleme sağlanmıştır. Ayrıca, test seti uzunluğunun 15 olduğu 2011 ve 2013 yıllarındaki zaman serilerinde tahmin doğruluğunda %10'un üzerinde ilerleme kaydedilmiştir. Ek olarak, 2012 yılında test kümesi uzunluğunun 7 olduğu zaman serisinde ilerleme seviyesinin 20% 'ye yakın olduğu gözlemlenmiştir.

10 veri setinin tamamı dikkate alındığında ortalama 20%'lik bir performans artışı sağlandığı açıkça görülmektedir.

Tablo 4.7. IEX veri setleri için HKOK değerleri açısından sonuçlar

Yöntem	Yıl / Test Seti Boyuut										Ortalama
	2009/7	2009/15	2010/7	2010/15	2011/7	2011/15	2012/7	2012/15	2013/7	2013/15	HKOK
[89]	345	540	1221	1612	1058	1130	651	621	1362	1269	981
[90]	345	540	1208	1612	1057	1130	651	621	1362	1269	980
[91]	325	525	1077	1603	920	1096	775	783	1315	1233	965
[1]	1402	1754	1128	1742	1396	1360	1292	1047	1450	1931	1450
[70]	267	514	1050	1357	765	917	590	<u>582</u>	786	1208	804
[74]	405	647	1141	2033	1007	1134	634	938	1447	1413	1080
[75]	261	503	1144	1303	960	1009	634	629	1418	1264	913
[47]	240	467	1136	1451	987	999	631	619	1362	1256	915
[54]	446	534	1180	1852	1083	1146	1034	1038	1512	1279	1110
[63]	319	495	1080	1575	915	1028	720	676	1251	1237	930
[64]	240	500	1045	1300	946	1000	662	762	832	1207	849
Önerilen FRFNler	<u>213</u>	<u>466</u>	<u>663</u>	<u>1247</u>	<u>442</u>	<u>806</u>	<u>477</u>	716	<u>477</u>	<u>1084</u>	<u>649</u>
İlerleme (%)	11.25	0.21	36.56	4.08	42.22	12.10	19.15	NA	39.31	10.19	19.28

5. SONUÇLAR

Bulanık tabanlı tahmin modelleri, zaman serilerinin içerdiği belirsizliğe esnek bir yaklaşım sundukları için oldukça tatminkâr sonuçlar üretebilmektedir. Ayrıca, T1FRF yaklaşımı, serilerin gerçek değerlerinin yanı sıra üyeliklerin bazı dönüşümlerini de kullanarak daha fazla bilgi içeren bir model oluşturmaktadır. Ancak, literatürde bir boşluk olarak değerlendirilen ve araştırılmaya değer bazı önemli sorunlar da bulunmaktadır. Bunlardan birincisi, T1FRF'nin girdilerin bir dizi doğrusal fonksiyonunun birleşimi olan bütünsel bir model oluşturmaktır. Ancak girdi ve çıktı arasındaki ilişki her zaman basit bir şekilde doğrusal değildir. İkinci eksiklik ise, literatürdeki FRF çalışmalarının doğrusal regresyon modelinin katı varsayımlarını dikkate almaması ve modelin geçerliliğinin kontrol edilmemesidir. Ayrıca, zaman serisi tahminine üzerine yapılan mevcut çalışmalar, veri setlerini ya hesaplama temelli bakış açısıyla ya da bulanık temelli bakış açısıyla ele almaktadır. Dolayısıyla, bu konu mevcut çalışmalara ait bir başka boşluk olarak değerlendirilebilmektedir.

Bu çalışmada, hem literatürdeki tüm bu önemli boşlukları doldurmak hem de modelin tahmin performansını önemli ölçüde iyileştirmek amacıyla yeni bir tahmin yaklaşımı önerilmiştir. Önerilen FRNF'ler, serilerin gerçek değerlerinin yanı sıra üyeliklerin bazı dönüşümlerini de kullanarak daha fazla bilgi içeren bir model oluşturmakta ve böylece daha gerçekçi bir yaklaşım sunmaktadır. Önerilen FRNF'ler, özellikleri ve yapıları sayesinde zaman serilerindeki doğrusal olmayan ilişkileri modelleme yeteneğine sahiptir. Önerilen FRNF'ler, kullanılan hesaplama tabanlı yaklaşım sayesinde doğrusal regresyon modelinde var olan katı varsayımların karşılanma gereksinimine ihtiyaç duymamaktadır. Literatürdeki mevcut çalışmaların eksikliklerinin tamamlanmasının yanı sıra, önerilen yöntemin üstün tahmin performansı farklı gerçek hayat zaman serilerinin analizi ile kanıtlanmıştır.

Bu sebeple önerilen tahmin aracının literatürde mevcutda bulunan sorunların üstesinden gelmesine ek olarak üstün bir tahmin performansı sunduğuda açıkça ortaya konmuştur. Bu yönleriyle, önerilen FRNF'nin zaman serisi problemi ile ilgilenen birçok alandaki araştırmacı ve uygulayıcının faydalanabileceği etkin bir tahmin aracı olması beklenmektedir. Mevcut yaklaşımda, doğrusal olmayan bir bulanık fonksiyon olarak

kullanılan FFNN'nin hiper parametrelerini ayarlamakla sınırlı kalmaktadır. Bu sorun doğrulama kümesi kullanılarak aşılmaya çalışılmış olsa da arama uzayı sınırlı kalmıştır. Bu nedenle gelecek çalışmalarda hiperparametre ayarlaması bir optimizasyon süreci içerisinde gerçekleştirilebilir.



KAYNAKLAR

- [1] Song, Q., Chissom BS (1993) Fuzzy time series and its models. Fuzzy Sets Syst 54:. [https://doi.org/10.1016/0165-0114\(93\)90372-O](https://doi.org/10.1016/0165-0114(93)90372-O)
- [2] Zadeh LA. (1965) Fuzzy sets. Information and Control 8:. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
- [3] Song Q., Chissom BS. (1993) Forecasting enrollments with fuzzy time series - Part I. Fuzzy Sets Syst 54:. [https://doi.org/10.1016/0165-0114\(93\)90355-L](https://doi.org/10.1016/0165-0114(93)90355-L)
- [4] Song Q., Chissom BS. (1994) Forecasting enrollments with fuzzy time series - part II. Fuzzy Sets Syst 62:. [https://doi.org/10.1016/0165-0114\(94\)90067-1](https://doi.org/10.1016/0165-0114(94)90067-1)
- [5] Chen SM. (1996) Forecasting enrollments based on fuzzy time series. Fuzzy Sets Syst 81:. [https://doi.org/10.1016/0165-0114\(95\)00220-0](https://doi.org/10.1016/0165-0114(95)00220-0)
- [6] Chen SM. (2002) Forecasting enrollments based on high-order fuzzy time series. Cybern Syst 33:. <https://doi.org/10.1080/019697202753306479>
- [7] Huarng K. (2001) Effective lengths of intervals to improve forecasting in fuzzy time series. Fuzzy Sets Syst 123:. [https://doi.org/10.1016/S0165-0114\(00\)00057-9](https://doi.org/10.1016/S0165-0114(00)00057-9)
- [8] Egrioglu E., Aladag CH., Yolcu U., et al (2010) Finding an optimal interval length in high order fuzzy time series. Expert Syst Appl 37:. <https://doi.org/10.1016/j.eswa.2009.12.006>
- [9] Egrioglu E., Aladag CH., Basaran MA., et al (2011) A new approach based on the optimization of the length of intervals in fuzzy time series. Journal of Intelligent and Fuzzy Systems 22:. <https://doi.org/10.3233/IFS-2010-0470>
- [10] Huarng K., Yu THK (2006) Ratio-based lengths of intervals to improve fuzzy time series forecasting. IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics 36:. <https://doi.org/10.1109/TSMCB.2005.857093>
- [11] Yolcu U., Egrioglu E., Uslu VR., et al (2009) A new approach for determining the length of intervals for fuzzy time series. Applied Soft Computing Journal 9:. <https://doi.org/10.1016/j.asoc.2008.09.002>
- [12] Panigrahi S, Behera HS (2020) A study on leading machine learning techniques for high order fuzzy time series forecasting. Eng Appl Artif Intell 87:. <https://doi.org/10.1016/j.engappai.2019.103245>

- [13] Lee LW, Wang LH, Chen SM (2007) Temperature prediction and TAIEX forecasting based on fuzzy logical relationships and genetic algorithms. *Expert Syst Appl* 33:.. <https://doi.org/10.1016/j.eswa.2006.05.015>
- [14] Lee LW, Wang LH, Chen SM (2008) Temperature prediction and TAIEX forecasting based on high-order fuzzy logical relationships and genetic simulated annealing techniques. *Expert Syst Appl* 34:.. <https://doi.org/10.1016/j.eswa.2006.09.007>
- [15] Kuo IH, Horng SJ, Kao TW, et al (2009) An improved method for forecasting enrollments based on fuzzy time series and particle swarm optimization. *Expert Syst Appl* 36:.. <https://doi.org/10.1016/j.eswa.2008.07.043>
- [16] Kuo IH, Horng SJ, Chen YH, et al (2010) Forecasting TAIEX based on fuzzy time series and particle swarm optimization. *Expert Syst Appl* 37:.. <https://doi.org/10.1016/j.eswa.2009.06.102>
- [17] Davari S, Zarandi MHF, Turksen IB (2009) An improved fuzzy time series forecasting model based on particle swarm intervalization. In: Annual Conference of the North American Fuzzy Information Processing Society - NAFIPS
- [18] Hsu LY, Horng SJ, Kao TW, et al (2010) Temperature prediction and TAIEX forecasting based on fuzzy relationships and MTPSO techniques. *Expert Syst Appl* 37:.. <https://doi.org/10.1016/j.eswa.2009.09.015>
- [19] Aladag CH (2013) Using multiplicative neuron model to establish fuzzy logic relationships. In: *Expert Systems with Applications*
- [20] Cagcag Yolcu O, Lam HK (2017) A combined robust fuzzy time series method for prediction of time series. *Neurocomputing* 247:.. <https://doi.org/10.1016/j.neucom.2017.03.037>
- [21] Yolcu U, Cagcag O, Aladag CH, Egrioglu E (2014) An enhanced fuzzy time series forecasting method based on artificial bee colony. *Journal of Intelligent and Fuzzy Systems* 26:.. <https://doi.org/10.3233/IFS-130933>
- [22] Cai Q, Zhang D, Zheng W, Leung SCH (2015) A new fuzzy time series forecasting model combined with ant colony optimization and auto-regression. *Knowl Based Syst* 74:.. <https://doi.org/10.1016/j.knosys.2014.11.003>
- [23] Jiang M, Jia L, Chen Z, Chen W (2022) The two-stage machine learning ensemble models for stock price prediction by combining mode decomposition, extreme learning machine

and improved harmony search algorithm. *Ann Oper Res* 309:.. <https://doi.org/10.1007/s10479-020-03690-w>

- [24] Cheng CH, Cheng GW, Wang JW (2008) Multi-attribute fuzzy time series method based on fuzzy clustering. *Expert Syst Appl* 34:.. <https://doi.org/10.1016/j.eswa.2006.12.013>
- [25] Li ST, Cheng YC, Lin SY (2008) A FCM-based deterministic forecasting model for fuzzy time series. *Computers and Mathematics with Applications* 56:.. <https://doi.org/10.1016/j.camwa.2008.07.033>
- [26] Alpaslan F, Cagcag Yolcu O (2012) A Seasonal Fuzzy Time Series Forecasting Method Based On Gustafson-Kessel Fuzzy Clustering. *Journal of Social and Economic Statistics* 1:1–13
- [27] Egrioglu E, Aladag CH, Yolcu U (2013) Fuzzy time series forecasting with a novel hybrid approach combining fuzzy c-means and neural networks. In: *Expert Systems with Applications*
- [28] Wei LY, Cheng CH, Wu HH (2014) A hybrid ANFIS based on n-period moving average model to forecast TAIEX stock. *Applied Soft Computing Journal* 19:.. <https://doi.org/10.1016/j.asoc.2014.01.022>
- [29] Cheng SH, Chen SM, Jian WS (2016) Fuzzy time series forecasting based on fuzzy logical relationships and similarity measures. *Inf Sci (N Y)* 327:.. <https://doi.org/10.1016/j.ins.2015.08.024>
- [30] Sun BQ, Guo H, Reza Karimi H, et al (2015) Prediction of stock index futures prices based on fuzzy sets and multivariate fuzzy time series. *Neurocomputing* 151:.. <https://doi.org/10.1016/j.neucom.2014.09.018>
- [31] Wang W, Liu X (2015) Fuzzy forecasting based on automatic clustering and axiomatic fuzzy set classification. *Inf Sci (N Y)* 294:.. <https://doi.org/10.1016/j.ins.2014.09.027>
- [32] Cagcag Yolcu O, Alpaslan F (2018) Prediction of TAIEX based on hybrid fuzzy time series model with single optimization process. *Applied Soft Computing Journal* 66:.. <https://doi.org/10.1016/j.asoc.2018.02.007>
- [33] Sullivan J, Woodall WH (1994) A comparison of fuzzy forecasting and Markov modeling. *Fuzzy Sets Syst* 64:.. [https://doi.org/10.1016/0165-0114\(94\)90152-X](https://doi.org/10.1016/0165-0114(94)90152-X)
- [34] Kocak C (2013) First-order ARMA type fuzzy time series method based on fuzzy logic relation tables. *Math Probl Eng* 2013:.. <https://doi.org/10.1155/2013/769125>

- [35] Kocak C (2017) ARMA(p,q) type high order fuzzy time series forecast method based on fuzzy logic relations. *Applied Soft Computing Journal* 58:.. <https://doi.org/10.1016/j.asoc.2017.04.021>
- [36] Huarng K, Yu THK (2006) The application of neural networks to forecast fuzzy time series. *Physica A: Statistical Mechanics and its Applications* 363:.. <https://doi.org/10.1016/j.physa.2005.08.014>
- [37] Aladag CH, Yolcu U, Egrioglu E (2010) A high order fuzzy time series forecasting model based on adaptive expectation and artificial neural networks. *Math Comput Simul* 81:.. <https://doi.org/10.1016/j.matcom.2010.09.011>
- [38] Kocak C, Dalar AZ, Cagcag Yolcu O, et al (2020) A new fuzzy time series method based on an ARMA-type recurrent Pi-Sigma artificial neural network. *Soft comput* 24:.. <https://doi.org/10.1007/s00500-019-04506-1>
- [39] Chen SM, Chen SW (2015) Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and the probabilities of trends of fuzzy logical relationships. *IEEE Trans Cybern* 45:.. <https://doi.org/10.1109/TCYB.2014.2326888>
- [40] Arslan SN, Cagcag Yolcu O (2022) A hybrid sigma-pi neural network for combined intuitionistic fuzzy time series prediction model. *Neural Comput Appl* 34:.. <https://doi.org/10.1007/s00521-022-07138-z>
- [41] Cagcag Yolcu O (2013) A hybrid fuzzy time series approach based on fuzzy clustering and artificial neural network with single multiplicative neuron model. *Math Probl Eng* 2013:.. <https://doi.org/10.1155/2013/560472>
- [42] Yu THK, Huarng KH (2008) A bivariate fuzzy time series model to forecast the TAIEX. *Expert Syst Appl* 34:.. <https://doi.org/10.1016/j.eswa.2007.05.016>
- [43] Alpaslan F, Cagcag O, Aladag CH, et al (2012) A novel seasonal fuzzy time series method. *Hacettepe Journal of Mathematics and Statistics* 41:
- [44] Yolcu U, Aladag CH, Egrioglu E, Uslu VR (2013) Time-series forecasting with a novel fuzzy time-series approach: An example for Istanbul stock market. *J Stat Comput Simul* 83:.. <https://doi.org/10.1080/00949655.2011.630000>
- [45] Chen SM, Chung NY (2006) Forecasting enrollments using high-order fuzzy time series and genetic algorithms. *International Journal of Intelligent Systems* 21:.. <https://doi.org/10.1002/int.20145>

- [46] Aladag CH, Yolcu U, Egrioglu E, Dalar AZ (2012) A new time invariant fuzzy time series forecasting method based on particle swarm optimization. *Applied Soft Computing Journal* 12:. <https://doi.org/10.1016/j.asoc.2012.05.002>
- [47] Sarıca B, Eğrioglu E, Aşıkgil B (2018) A new hybrid method for time series forecasting: AR–ANFIS. *Neural Comput Appl* 29:. <https://doi.org/10.1007/s00521-016-2475-5>
- [48] Catalão JPS, Pousinho HMI, Mendes VMF (2011) Hybrid wavelet-PSO-ANFIS approach for short-term electricity prices forecasting. *IEEE Transactions on Power Systems* 26:. <https://doi.org/10.1109/TPWRS.2010.2049385>
- [49] Chang BR (2008) Resolving the forecasting problems of overshoot and volatility clustering using ANFIS coupling nonlinear heteroscedasticity with quantum tuning. *Fuzzy Sets Syst* 159:. <https://doi.org/10.1016/j.fss.2008.04.003>
- [50] Cheng CH, Wei LY, Chen YS (2009) Fusion ANFIS models based on multi-stock volatility causality for TAIEX forecasting. *Neurocomputing* 72:. <https://doi.org/10.1016/j.neucom.2008.09.027>
- [51] Cheng CH, Wei LY, Liu JW, Chen TL (2013) OWA-based ANFIS model for TAIEX forecasting. *Econ Model* 30:. <https://doi.org/10.1016/j.econmod.2012.09.047>
- [52] Ho YC, Tsai CT (2011) Comparing ANFIS and SEM in linear and nonlinear forecasting of new product development performance. *Expert Syst Appl* 38:. <https://doi.org/10.1016/j.eswa.2010.11.095>
- [53] Pousinho HMI, Mendes VMF, Catalão JPS (2012) Short-term electricity prices forecasting in a competitive market by a hybrid PSO-ANFIS approach. *International Journal of Electrical Power and Energy Systems* 39:. <https://doi.org/10.1016/j.ijepes.2012.01.001>
- [54] Türkşen IB (2008) Fuzzy functions with LSE. *Applied Soft Computing Journal* 8:. <https://doi.org/10.1016/j.asoc.2007.12.004>
- [55] Aladag CH, Turksen IB, Dalar AZ, et al (2014) Application of Type-1 Fuzzy Functions Approach for Time Series Forecasting. *TJFS: Turkish Journal of Fuzzy Systems An Official Journal of Turkish Fuzzy Systems Association* 5:
- [56] Aladag CH, Yolcu U, Egrioglu E, Turksen IB (2016) Type-1 fuzzy time series function method based on binary particle swarm optimisation. In: *International Journal of Data Analysis Techniques and Strategies*

- [57] Tak N, Evren AA, Tez M, Egrioglu E (2018) Recurrent type-1 fuzzy functions approach for time series forecasting. *Applied Intelligence* 48:.. <https://doi.org/10.1007/s10489-017-0962-8>
- [58] Goudarzi S, Khodabakhshi MB, Moradi MH (2016) Interactively recurrent fuzzy functions with multi objective learning and its application to chaotic time series prediction. *Journal of Intelligent and Fuzzy Systems* 30:.. <https://doi.org/10.3233/IFS-151839>
- [59] Zarandi MHF, Zarinbal M, Ghanbari N, Turksen IB (2013) A new fuzzy functions model tuned by hybridizing imperialist competitive algorithm and simulated annealing. Application: Stock price prediction. *Inf Sci (N Y)* 222:.. <https://doi.org/10.1016/j.ins.2012.08.002>
- [60] Bezdek JC (1981) Pattern Recognition with Fuzzy Objective Function Algorithms
- [61] Türkşen IB (2008) Fuzzy functions with LSE. *Applied Soft Computing Journal* 8:.. <https://doi.org/10.1016/j.asoc.2007.12.004>
- [62] Kirisci M, Cagcag Yolcu O (2022) A New CNN-Based Model for Financial Time Series: TAIEX and FTSE Stocks Forecasting. *Neural Process Lett* 54:.. <https://doi.org/10.1007/s11063-022-10767-z>
- [63] Bas E, Egrioglu E, Yolcu U, Grosan C (2019) Type 1 fuzzy function approach based on ridge regression for forecasting. *Granular Computing* 4:.. <https://doi.org/10.1007/s41066-018-0115-4>
- [64] Tak N, İnan D (2022) Type-1 fuzzy forecasting functions with elastic net regularization. *Expert Syst Appl* 199:.. <https://doi.org/10.1016/j.eswa.2022.116916>
- [65] Huarng KH, Yu THK, Hsu YW (2007) A multivariate heuristic model for fuzzy time-series forecasting. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics* 37:.. <https://doi.org/10.1109/TSMCB.2006.890303>
- [66] Chen SM, Chang YC (2010) Multi-variable fuzzy forecasting based on fuzzy clustering and fuzzy rule interpolation techniques. *Inf Sci (N Y)* 180:.. <https://doi.org/10.1016/j.ins.2010.08.026>
- [67] Chen SM, Chen CD (2011) TAIEX forecasting based on fuzzy time series and fuzzy variation groups. *IEEE Transactions on Fuzzy Systems* 19:.. <https://doi.org/10.1109/TFUZZ.2010.2073712>

- [68] Chen SM, Manalu GMT, Pan JS, Liu HC (2013) Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and particle swarm optimization techniques. *IEEE Trans Cybern* 43:. <https://doi.org/10.1109/TSMCB.2012.2223815>
- [69] Chen YS, Cheng CH, Tsai WL (2014) Modeling fitting-function-based fuzzy time series patterns for evolving stock index forecasting. *Applied Intelligence* 41:. <https://doi.org/10.1007/s10489-014-0520-6>
- [70] Bas E, Egrioglu E, Aladag CH, Yolcu U (2015) Fuzzy-time-series network used to forecast linear and nonlinear time series. *Applied Intelligence* 43:. <https://doi.org/10.1007/s10489-015-0647-0>
- [71] Chen YS, Cheng CH, Chiu CL, Huang ST (2016) A study of ANFIS-based multi-factor time series models for forecasting stock index. *Applied Intelligence* 45:. <https://doi.org/10.1007/s10489-016-0760-8>
- [72] Chen SM, Jian WS (2017) Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups, similarity measures and PSO techniques. *Inf Sci (N Y)* 391–392:. <https://doi.org/10.1016/j.ins.2016.11.004>
- [73] Chen SM, Phuong BDH (2017) Fuzzy time series forecasting based on optimal partitions of intervals and optimal weighting vectors. *Knowl Based Syst* 118:. <https://doi.org/10.1016/j.knosys.2016.11.019>
- [74] Jang JSR (1993) ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Trans Syst Man Cybern* 23:. <https://doi.org/10.1109/21.256541>
- [75] Egrioglu E, Aladag CH, Yolcu U, Bas E (2015) A New Adaptive Network Based Fuzzy Inference System for Time Series Forecasting. *Aloy Journal of Soft Computing and Applications* 2:
- [76] Cagcag Yolcu O, Bas E, Egrioglu E, Yolcu U (2020) A new intuitionistic fuzzy functions approach based on hesitation margin for time-series prediction. *Soft comput.* <https://doi.org/10.1007/s00500-019-04432-2>
- [77] Tak N (2020) Type-1 recurrent intuitionistic fuzzy functions for forecasting. *Expert Syst Appl* 140:. <https://doi.org/10.1016/j.eswa.2019.112913>
- [78] Huarng K (2001) Heuristic models of fuzzy time series for forecasting. *Fuzzy Sets Syst* 123:. [https://doi.org/10.1016/S0165-0114\(00\)00093-2](https://doi.org/10.1016/S0165-0114(00)00093-2)

- [79] Yu HK (2005) Weighted fuzzy time series models for TAIEX forecasting. *Physica A: Statistical Mechanics and its Applications* 349:.. <https://doi.org/10.1016/j.physa.2004.11.006>
- [80] Chen SM, Tanuwijaya K (2011) Fuzzy forecasting based on high-order fuzzy logical relationships and automatic clustering techniques. *Expert Syst Appl* 38:.. <https://doi.org/10.1016/j.eswa.2011.06.019>
- [81] Aladag CH, Yolcu U, Egrioglu E, Bas E (2014) Fuzzy lagged variable selection in fuzzy time series with genetic algorithms. *Applied Soft Computing Journal* 22:.. <https://doi.org/10.1016/j.asoc.2014.03.028>
- [82] Askari S, Montazerin N, Zarandi MHF (2015) A clustering based forecasting algorithm for multivariable fuzzy time series using linear combinations of independent variables. *Applied Soft Computing Journal* 35:.. <https://doi.org/10.1016/j.asoc.2015.06.028>
- [83] Cagcag Yolcu O, Bas E, Egrioglu E, Yolcu U (2020) A new intuitionistic fuzzy functions approach based on hesitation margin for time-series prediction. *Soft comput* 24:.. <https://doi.org/10.1007/s00500-019-04432-2>
- [84] Sadaei HJ, Enayatifar R, Lee MH, Mahmud M (2016) A hybrid model based on differential fuzzy logic relationships and imperialist competitive algorithm for stock market forecasting. *Applied Soft Computing Journal* 40:.. <https://doi.org/10.1016/j.asoc.2015.11.026>
- [85] Ye F, Zhang L, Zhang D, et al (2016) A novel forecasting method based on multi-order fuzzy time series and technical analysis. *Inf Sci (N Y)* 367–368:.. <https://doi.org/10.1016/j.ins.2016.05.038>
- [86] Wan Y, Si YW (2017) Adaptive neuro fuzzy inference system for chart pattern matching in financial time series. *Applied Soft Computing Journal* 57:.. <https://doi.org/10.1016/j.asoc.2017.03.023>
- [87] Cheng CH, Yang JH (2018) Fuzzy time-series model based on rough set rule induction for forecasting stock price. *Neurocomputing* 302:.. <https://doi.org/10.1016/j.neucom.2018.04.014>
- [88] Wu H, Long H, Jiang J (2019) Handling forecasting problems based on fuzzy time series model and model error learning. *Applied Soft Computing Journal* 78:.. <https://doi.org/10.1016/j.asoc.2019.02.021>

- [89] Box GEP, Jenkins GM, and, Reinsel G (2008) Time Series Analysis, Forecasting and Control, 4th edition. Wiley. Prentice-Hall, Englewood Cliffs
- [90] Brown RG (1957) Exponential Smoothing for predicting demand. In: Operations Research
- [91] Rumelhart DE, Hinton GE, Williams RJ (1986) Learning representations by back-propagating errors. Nature 323:. <https://doi.org/10.1038/323533a0>



ÖZGEÇMİŞ

MEHMET RACİ AKTOPRAK

Öğrenim Bilgileri

Lise : Şişli Çok Programlı Anadolu Lisesi (2005-2009)

Lisans

: Selçuk Üniversitesi

Fen Fakültesi / İstatistik Bölümü (2010-2014)

: Anadolu Üniversitesi

Açık Öğretim Fakültesi / Coğrafi Bilgi Sistemleri
(2019-2021)

: Atatürk Üniversitesi

Açık ve Uzaktan Öğretim Fakültesi / Bilgisayar
Programcılığı (2021-2023)

: İstanbul Teknik Üniversitesi

Mimarlık Fakültesi / Şehir Bölge Planlama (2021-)

Yüksek Lisans

: Marmara Üniversitesi

Fen Bilimleri Enstitüsü/ İstatistik (YL Tezli) (2020-)

İş Deneyimleri

Memur (İstatistikçi)

: İstanbul Büyükşehir Belediye Başkanlığı (2017-)