Dalar / Journal of Economics and Administrative Sciences, 26(4): 680-698, 2025
DOI: 10.37880/cumuiibf.1749594

Journal of Economics and Administrative Sciences

| esjournal.cumhuriyet.edu.tr | Founded: 2000 Available online, ISSN: 1303-1279 Publisher: Sivas Cumhuriyet Üniversitesi

Deep Fuzzy Functions Approach for Time Series Forecasting

Ali Zafer Dalar[1,a,*]

[1]*Department of Data Science and Analytics, Faculty of Arts and Sciences, Giresun University, Giresun, Türkiye*
**Corresponding author*

Research Article

History

Received: 23/06/2025
Accepted: 08/10/2025

JEL Codes: *C51, C52, C53, C61, C63, C45*

ABSTRACT

In this study, a novel forecasting method is proposed by integrating classical type-1 fuzzy functions with deep learning models based on Long Short-Term Memory (LSTM) artificial neural networks, aiming to enhance forecast accuracy and systematically address uncertainty in time series data. In the developed approach, an independent LSTM model is constructed for each fuzzy cluster, and these models are trained using lagged variables derived from the time series. During the forecasting phase, the output of each model is weighted according to the degree of membership of the corresponding observation to its respective cluster, and the final prediction is computed accordingly. In this way, the proposed Deep Fuzzy Forecasting Functions (DBF) approach simultaneously captures both the dynamic temporal patterns of the series and the structural uncertainty among observations. The training process employs the Adam optimization algorithm, and various combinations of hyperparameters — including the number of epochs, the number of hidden units, the number of clusters, and the α-cut threshold — were systematically evaluated via grid search over predefined candidate ranges and time-series cross-validation; the optimal configuration was selected according to error criteria. The proposed DBF approach was evaluated on time series datasets with distinct characteristics, including financial and meteorological data, and benchmarked against widely used forecasting methods. Experimental results demonstrated that the proposed DBF model achieved the lowest prediction errors in many scenarios and delivered high accuracy, particularly for short- and medium-term forecasts. These findings indicate that the developed approach is flexible, generalizable, and effective as a forecasting tool across various domains.

Keywords: Time series forecasting, Fuzzy inference systems, Long short-term memory, Artificial neural networks, Deep learning

Zaman Serisi Öngörüsü için Derin Bulanık Fonksiyonlar Yaklaşımı

ÖZET

Çalışmada, zaman serisi öngörülerinde doğruluk düzeyini artırmak ve verideki belirsizlikleri yapılandırılmış biçimde dikkate almak amacıyla, klasik tip-1 bulanık fonksiyonlar yaklaşımı ile uzun kısa süreli bellek (LSTM) yapay sinir ağları temelli derin öğrenme modellerinin bir araya getirildiği yeni bir öngörü yöntemi geliştirilmiştir. Geliştirilen yöntemde, her bir bulanık kümeye karşılık gelen bağımsız LSTM modelleri yapılandırılmış ve bu modeller, belirli gecikmeli değişkenlere dayalı olarak eğitilmiştir. Her bir modelin çıktısı, ilgili gözlemin kümelere aitlik dereceleri ile ağırlıklandırılarak öngörü elde edilmiştir. Bu sayede, önerilen derin bulanık öngörü fonksiyonları (DBF) yaklaşımı ile hem zaman serisinin dinamik örüntüleri hem de gözlemler arasındaki belirsizlikler aynı anda dikkate alınabilmiştir. Modeli eğitmek için Adam optimizasyon algoritması kullanılmıştır. Epoch sayısı, gizli birim sayısı, küme sayısı ve α-kesim katsayısı gibi hiperparametre kombinasyonları, önceden tanımlı aday aralıklarında ızgara araması ile ve hata ölçütüne göre sistematik olarak seçilmiştir. Önerilen DBF yaklaşımı, farklı özelliklere sahip finansal ve meteorolojik zaman serisi veri kümeleri üzerinde değerlendirilmiş ve alternatif öngörü yöntemleri ile karşılaştırılmıştır. Uygulama sonuçlarında, önerilen DBF yönteminin pek çok senaryoda en düşük öngörü hatasını verdiği, özellikle kısa ve orta vadeli öngörülerde yüksek başarı sağladığı görülmüştür. Bu bulgular, geliştirilen yaklaşımın genellenebilirliğe sahip, esnek ve tutarlı bir öngörü çerçevesi sunduğunu ve çeşitli alanlarda kullanılabilecek nitelikte olduğunu göstermektedir.

Anahtar Kelimeler: Zaman serisi öngörüsü, Bulanık çıkarım sistemleri, Uzun kısa süreli bellek, Yapay sinir ağları, Derin öğrenme

Süreç

Geliş: 23/06/2025
Kabul: 08/10/2025

Jel Kodları: C51, C52, C53, C61, C63, C45

License

This work is licensed under Creative Commons Attribution-NonCommercial 4.0 International License International License

[a] *ali.zafer.dalar@giresun.edu.tr* *0000-0002-8574-461X*

Giriş

Zaman serileri analizi, belirli periyotlarla kaydedilen verilerin analiz edilmesini ve geleceğe yönelik tahminlerde bulunulmasını sağlayan bir çalışma alanıdır. Ekonomi, finans, meteoroloji ve mühendislik gibi pek çok alanda, zaman serilerinin güvenilir tahminlerinin karar verme süreçlerini doğrudan etkilediği bilinmektedir. Dolayısıyla, zaman serisi öngörü modellerinin doğruluğu kadar belirsizlik yönetimi de büyük önem taşımaktadır. Ancak, mevcut tahmin yöntemleri genellikle doğruluğu artırmaya odaklanmakta, belirsizliği etkin bir şekilde yönetememektedir. Dolayısıyla bu durum, özellikle finansal tahminler, hava durumu öngörüleri ve mühendislik uygulamaları gibi belirsizliğin yüksek olduğu alanlarda karar verme süreçlerini olumsuz etkileyebilmektedir.

Geleneksel tahmin yöntemleri belirsizliği ele alma konusunda yetersiz kalmakta ve karar verme süreçlerinde hata oranlarını artırabilmektedir (Egrioglu ve Bas, 2023). Bu yetersizlikler, özellikle veri yapısında belirsizlik bulunan alanlarda daha esnek ve öğrenmeye dayalı yöntemlerin kullanılmasını zorunlu kılmaktadır. Zaman serisi öngörü yöntemleri, genel olarak doğrusal modeller, istatistiksel yaklaşımlar ve makine öğrenmesi tabanlı teknikler olmak üzere farklı kategorilere ayrılmaktadır (Box ve Jenkins, 1976; Hamilton, 1994).

Geleneksel öngörü yöntemleri arasında yer alan otoregresif bütünleşik hareketli ortalama (ARIMA) ve mevsimsel ARIMA (SARIMA) modellerinin, güçlü istatistiksel varsayımlara dayandığı ancak doğrusal olmayan süreçlerin modellenmesinde yetersiz kaldığı bilinmektedir (Hyndman ve Athanasopoulos, 2021). Ayrıca, bu yöntemler yalnızca belirli veri yapılarına uygun olup belirsizlik içeren ve aykırı değerlere duyarlı zaman serilerinde düşük performans sergilemektedir (Chakravarty vd., 2022). Bu yöntemlerin sınırlılıkları, daha esnek yapılarla çalışan yeni modellerin geliştirilmesini gerekli kılmıştır.

Doğrusal olmayan yapıların modellenebilmesi için yapay sinir ağları (YSA) gibi esnek öğrenme algoritmalarına ihtiyaç duyulmuştur. Yapay sinir ağları, insan beyninin öğrenme mekanizmasını taklit ederek karmaşık veri ilişkilerini modelleyebilme yeteneğine sahiptir (Rumelhart vd., 1986). Ancak, YSA uzun vadeli bağımlılıkları öğrenmedeki eksikliği derin öğrenme yöntemlerinin çok katmanlı yapıları sayesinde giderilmiş ve başarılı tahminler sunulabilmesini sağlamıştır (LeCun vd., 2015). Özellikle uzun kısa süreli bellek (LSTM) ve geçitli tekrarlayan birim (GRU) ağları, zaman serisi öngörüsünde yaygın olarak kullanılmaktadır (Hochreiter ve Schmidhuber, 1997). LSTM sinir ağları, uzun vadeli bağımlılıkları öğrenme kapasitesi sunmasına karşın, belirsizlik yönetiminde yetersiz kalmaktadır. Bunun yanı sıra, LSTM modelleri kesin sınırlarla çalışan bir yapıdadır ve belirsizliği esnek bir biçimde modelleyememektedir. Dolayısıyla, yalnızca derin öğrenme tekniklerini kullanmak, özellikle belirsizliğin yüksek olduğu finansal zaman serileri ve iklim verileri gibi alanlarda güvenilir tahminler üretmek için yeterli olmayabilir. Literatürde, derin öğrenme ile bulanık sistemlerin entegrasyonu bu eksikliği giderebilecek önemli bir adım olarak öne çıkmaktadır. Bu bağlamda, bulanık sistemlerin derin sinir ağları ile entegrasyonu, özellikle belirsizlik içeren zaman serisi tahminlerinde avantaj sağlamaktadır (Chakravarty vd., 2022; Gawlikowski vd., 2023; Guo vd., 2017; Imamguluyev, 2025; Kendall ve Gal, 2017; Kocak vd., 2021).

Belirsizlik sorununun üstesinden gelebilmek adına, bulanık küme teorisi gibi yaklaşımların etkili olduğu gösterilmiştir (Zadeh, 1965). Bulanık küme teorisi ile, kesin sınırlar yerine üyelik dereceleri kullanılarak belirsizlikler ele alınmakta ve veri daha esnek bir biçimde modellenebilmektedir (Mamdani ve Assilian, 1975). Ancak, geleneksel bulanık modellerin kural tabanlı yapıları nedeniyle büyük veri setleriyle çalışırken hesaplama verimliliği açısından sorunlar yaşadığı bilinmektedir (Ducange vd., 2020; Fernández vd., 2016; W. Li vd., 2025; Y. Li vd., 2021; Mikus vd., 2025). Bu bağlamda, Turksen (2008) tarafından önerilen tip-1 bulanık fonksiyonlar (T1BF) yaklaşımı, bulanık çıkarım sistemlerine kıyasla kural tabanlı sistemlere olan bağımlılığı ortadan kaldırarak daha esnek ve hesaplamalı olarak verimli bir yapı sunmaktadır. T1BF yaklaşımının temelinde, veri setindeki gözlemlerin bulanık bir uzayda temsil edilmesi ve bu uzay üzerinden çıkarımların yapılması yer almaktadır. T1BF yaklaşımı, regresyon problemlerinde ve zaman serisi analizlerinde başarılı sonuçlar vermiştir (Turksen, 2008). Literatürde, T1BF'nin farklı yapay zeka yöntemleri ile birleştirilerek kullanıldığı çeşitli çalışmalar mevcuttur (Aktoprak ve Cagcag Yolcu, 2025; Aladag vd., 2014; Bas ve Egrioglu, 2022; Baser ve Demirhan, 2017; Celikyilmaz ve Turksen, 2007; Chakravarty vd., 2020, 2022a, 2022b; Dalar, 2023; Dalar ve Egrioglu, 2018, 2025; Demirhan ve Baser, 2024; Demirkan Piskin ve Bas, 2022; Egrioglu vd., 2022; Tak, 2021; Tak vd., 2018; Tak ve Inan, 2022; Yıldırım ve Bas, 2022).

Aktoprak ve Cagcag Yolcu (2025) tarafından önerilen yöntem, zaman serisi verilerini gerçek değerli gözlemler ve bu gözlemlerden elde edilen üyelik derecelerine dayalı olarak modellemektedir. Çalışmada, her bir bulanık küme kendisine karşılık gelen ileri beslemeli sinir ağları ile eğitilmekte ve nihai tahmin değeri, gözlemlerin ilgili kümelere aitlik derecelerine göre bu ağların çıktılarının ağırlıklı ortalaması alınarak elde edilmektedir. Aktoprak ve Cagcag Yolcu (2025) çalışması, doğrusal olmayan yapıları modelleme açısından önemli bir katkı sunmasına rağmen, zaman serilerindeki uzun vadeli bağımlılıkları yakalama konusunda sınırlı kalmaktadır. Bu sınırlılığın aşılabilmesi için hem zaman bağımlılıklarını öğrenebilen hem de belirsizlikleri üyelik temelli modelleyebilen bir yapının gerekliliği ortaya çıkmaktadır. Sonuç olarak, LSTM gibi zaman duyarlı yapılarla derin öğrenmenin belirsizlik yönetimi ile bütünleştirildiği daha kapsamlı modellere ihtiyaç duyulmaktadır. Önerilen Derin Bulanık Fonksiyonlar (DBF) yöntemi, hem belirsizlikleri dikkate alan üyelik temelli yapısı hem de zaman bağımlı örüntüleri yakalama yeteneği ile literatürdeki mevcut modellere kıyasla daha gelişmiş bir yaklaşım sunmaktadır.

Bununla birlikte, literatürde derin öğrenme ile belirsizliğin bir arada ele alınması konusu günümüzde hala sınırlı bir araştırma alanı olarak görülmektedir. Derin öğrenme yöntemlerinin yüksek öngörü kapasitesine sahip olduğu, bulanık sistemlerin ise belirsizliği yönetme konusunda başarılı olduğu bilinmektedir. Ancak, bu iki yöntemin entegrasyonuna yönelik çalışmaların yeterli olmadığı gözlemlenmektedir (Alateeq ve Pedrycz, 2024; AL-Sukeinee ve Khudeyer, 2024; Cagcag Yolcu ve Yolcu, 2024; Gawlikowski vd., 2023; Imamguluyev, 2025; Kocak vd., 2021; Krauss vd., 2017; Latifi vd., 2024; Sagheer vd., 2021; X. Song vd., 2024; Zheng vd., 2024).

Mevcut çalışmaların büyük çoğunluğu ya yalnızca derin öğrenmeye ya da yalnızca bulanık sistemlere odaklanmıştır. Ancak, bu modellerin ayrı ayrı kullanımı, model doğruluğu ile belirsizlik yönetimi arasındaki dengeyi sağlamakta eksikliklere yol açmaktadır.

Son yıllarda, sezgisel bulanık regresyon fonksiyonları (IFRFs) ile LSTM'nin birleştirildiği bazı çalışmaların yapıldığı görülmektedir (Cagcag Yolcu ve Yolcu, 2024). Ancak bu çalışmalar, yalnızca sezgisel bulanık regresyon tabanlı yapılar sunmaktadır. T1BF ve derin öğrenmenin doğrudan entegrasyonuna yönelik kapsamlı bir model geliştirilmemiştir. Ayrıca, mevcut literatürde bulunan geliştirilmiş bulanık regresyon fonksiyonları (MFRFN) ve dayanıklı sezgisel bulanık regresyon fonksiyonları gibi yaklaşımlar, belirsizlik yönetimi ve aykırı değerlerin etkisini azaltma konusunda başarılı olsa da zaman serisi tahmini için LSTM ile birleşimleri yeterince incelenmemiştir (Chakravarty vd., 2022a; Egrioglu ve Bas, 2023).

Çalışmada tip-1 bulanık fonksiyonlar yaklaşımı ile LSTM sinir ağlarının doğrudan entegrasyonu önerilmektedir. Önerilen yöntem, derin öğrenmenin veri odaklı öğrenme kapasitesi ile bulanık fonksiyonların belirsizlik yönetimi yeteneğini birleştirerek daha güvenilir öngörüler sunmayı hedeflemektedir. Önerilen DBF yaklaşımı, model doğruluğu ile belirsizlik yönetimini birlikte geliştirerek zaman serisi öngörüsüne yeni bir bakış açısı kazandırmaktadır.

Çalışmanın materyal ve yöntem bölümünde, önerilen yaklaşım ayrıntılı şekilde tanımlanacak ve kullanılan veri setleri ile model yapısı açıklanacaktır. Ardından bulgular bölümünde, geliştirilen yöntemin performansı farklı zaman serileri üzerinde değerlendirilecek ve geleneksel yöntemlerle karşılaştırılacaktır. Son olarak, sonuçlar bölümünde çalışmanın temel bulguları özetlenerek, yöntemin üstünlük ve kısıtları tartışılacak ve gelecekteki araştırmalara yönelik öneriler sunulacaktır.

Materyal ve Yöntem

Çalışmada kullanılan veri setleri, önerilen yöntemin temel bileşenleri, karşılaştırmalı analizde kullanılan yöntemler ve önerilen yöntemin değerlendirme süreci bu bölümde ayrıntılı şekilde ele alınmaktadır.

Kullanılan Veri Setleri

Önerilen yöntemin performansını değerlendirmek amacıyla iki farklı zaman serisi veri kümesi kullanılmıştır:

- Finansal zaman serileri: Borsa İstanbul (BIST) 100 endeksi, Londra borsası (FTSE) 100 endeksi, Tayvan borsası (TAIEX) ve ABD borsası (NASDAQ 100) endekslerinin 2010-2014 yılları arasındaki günlük kapanış fiyatları kullanılmıştır. Özellikle volatilite ve uzun vadeli bağımlılık içeren finansal zaman serilerinde önerilen yöntemin başarısını ölçmek amaçlanmıştır.
- Meteorolojik veri seti: Giresun iline ait 2017 yılının ilk dört ayında kaydedilen günlük minimum sıcaklık değerlerinden oluşmaktadır. Bu veri seti, mevsimselliğin tahmin performansına etkisini incelemek amacıyla seçilmiştir.

Her iki veri kümesi de farklı türde zaman serisi dinamiklerini temsil ettiği için, önerilen yöntemin farklı veri yapılarında gösterdiği performans değerlendirilmiştir. Finansal veri setleri için Dalar ve Egrioglu (2025) çalışmasında olduğu gibi kısa, orta ve uzun vadeli tahminler incelenmiştir (10, 20 ve 40 gözlem içeren test kümeleri oluşturulmuştur). Meteorolojik veri seti için ise Kocak vd. (2021) çalışmasında da olduğu gibi test kümesi uzunluğu 14 gün olarak belirlenmiştir. Veri setlerinin temel özellikleri ve test kümesi boyutları Çizelge 1'de sunulmaktadır.

Çizelge 1. Kullanılan Zaman Serilerine İlişkin Temel Bilgiler
Table 1. Fundamental Characteristics of the Time Series Used

Seri No	Seri / Yıl	Gözlem Sayısı	n_{test}
1	BIST 100 / 2010	250	10–20–40
2	BIST 100 / 2011	253	10–20–40
3	BIST 100 / 2012	253	10–20–40
4	BIST 100 / 2013	251	10–20–40
5	BIST 100 / 2014	251	10–20–40
6	FTSE 100 / 2010	252	10–20–40
7	FTSE 100 / 2011	251	10–20–40
8	FTSE 100 / 2012	252	10–20–40
9	FTSE 100 / 2013	253	10–20–40
10	FTSE 100 / 2014	253	10–20–40
11	TAIEX / 2010	251	10–20–40
12	TAIEX / 2011	247	10–20–40

13	TAIEX / 2012	250	10–20–40
14	TAIEX / 2013	246	10–20–40
15	TAIEX / 2014	248	10–20–40
16	NASDAQ 100 / 2010	252	10–20–40
17	NASDAQ 100 / 2011	251	10–20–40
18	NASDAQ 100 / 2012	250	10–20–40
19	NASDAQ 100 / 2013	252	10–20–40
20	NASDAQ 100 / 2014	252	10–20–40
21	Giresun İli Günlük Sıcaklık	120	14

Çizelge 1'de görüldüğü üzere, borsa endeksi zaman serileri için test kümesindeki veri sayısı (n_{test}) 2 haftaya karşılık gelecek şekilde 10, 4 hafta için 20 ve 8 hafta için ise 40 olarak ve Giresun ili günlük minimum sıcaklık değerleri zaman serisi için ise 14 olarak alınarak toplamda 61 durum için çözümleme yapılmıştır.

Önerilen Yöntem

Çalışmada, Derin Bulanık Fonksiyonlar yöntemi geliştirilmiştir. Önerilen yöntem ile, LSTM sinir ağları ve tip-1 bulanık fonksiyonlar yaklaşımı birleştirilerek tahmin doğruluğunu artırmak ve belirsizlikleri daha etkin yönetmek hedeflenmiştir.

Önerilen DBF yönteminde, klasik tip-1 bulanık fonksiyonlar yapısına sadık kalınmakla birlikte, her bulanık küme için doğrusal regresyon modeli yerine doğrusal olmayan ve zaman bağımlı örüntüleri öğrenebilen LSTM modelleri kullanılmaktadır. DBF yapısı içinde her küme için aynı mimariye sahip ancak farklı eğitim verisiyle eğitilmiş bağımsız LSTM modelleri oluşturulmuştur. LSTM modelleri, zaman serisindeki gecikmeli girdilerden tahmin edilen çıktıları üretmekte, ardından bu çıktılar, ilgili gözlemin kümelere aitlik (üyelik) derecelerine göre ağırlıklandırılarak klasik bulanık fonksiyonlar yaklaşımında olduğu gibi birleştirilmektedir. Nihai tahmin, bu ağırlıklı birleşim sonucunda elde edilmektedir. Önerilen yöntemin yapısındaki her bir fonksiyon ile hem belirsizlikler (üyelik dereceleri üzerinden) hem de zaman serisinin dinamik yapısı (LSTM'nin bellek özelliği aracılığıyla) göz önünde bulundurulmaktadır. Çalışmada, ağırlıklı ortalama dışındaki alternatif çıkarım teknikleri test edilmemiştir.

Önerilen yöntemin temel bileşenleri dört aşamada özetlenmektedir. Aşağıda, bu dört temel aşamaya karşılık gelen işlem adımları ayrıntılı biçimde açıklanmıştır.

1. Veri Ön İşleme:
   a. Zaman serisi verileri, gecikmeli değişkenler kullanılarak yeniden yapılandırılmıştır.
   b. Veriler yalnızca z-skor standardizasyonu ile ölçeklendirilmiştir (eğitim seti istatistikleri kullanılarak). Ek bir ön-işleme uygulanmamıştır.
2. Bulanık Kümeleme:
   a. Bulanık C-Ortalamalar (BCO) algoritması (Bezdek vd., 1984) kullanılarak veri noktaları kümelere ayrılmıştır.
   b. Her veri noktası için üyelik dereceleri hesaplanarak belirsizlikler modellenmiştir.
3. LSTM Tabanlı Tahmin Modeli Oluşturma:
   a. Her bir bulanık küme için bağımsız bir LSTM modeli eğitilmiştir.
4. Bulanık Fonksiyonların Çıkarımı:
   a. LSTM modellerinden elde edilen tahminler, üyelik fonksiyonları ile ağırlıklandırılmıştır.
   b. Nihai tahmin değeri, kümelerin üyelik derecelerine göre birleştirilmiştir.

Önerilen yöntemin algoritma adımları aşağıdaki gibidir.

Adım 1. Veri yapısı ve ön işleme

Zaman serisi verisi $X = \{x_1,\ x_2,\ \cdots,\ x_N\}$ eğitim ve test olmak üzere iki alt kümeye ayrılır:

- Eğitim seti $X_{eğitim} = \{x_1, x_2, \cdots, x_{N-n_{test}}\}$, N: $zaman\ serisi\ uzunluğu, n_{test}$: $test\ verisi\ uzunluğu$
- Test seti $X_{test} = \{x_{N-n_{test}+1}, x_{N-n_{test}+2}, \cdots, x_N\}$.

Standartlaştırma işlemi eğitim seti kullanılarak gerçekleştirilir ($\tilde{x}_t$: standartlaştırılmış veri noktası):

$$\tilde{x}_t = \frac{x_t - \mu_{eğitim}}{\sigma_{eğitim}},\quad \forall t = 1, 2, \ldots, N. \tag{1}$$

Adım 2. Gecikmeli vektör matrisi

Bu adımda, girdi verisinin zamansal yapısı dikkate alınacak şekilde gecikmeli biçimde temsil edilmesi sağlanır. Gecikme derecesi gs olmak üzere, her gözlem için bir gecikmeli vektör oluşturulur:

$$D_t = \left[\tilde{x}_t, \tilde{x}_{t-1}, \cdots, \tilde{x}_{t-gs}\right]. \tag{2}$$

Böylece toplamda $n = N - gs$ satırlık bir veri matrisi elde edilir ($D \in \mathbb{R}^{n\times(gs+1)}$).

Adım 3. Bulanık kümeleme

Bulanıklaştırma işlemi ile her gözlem için çoklu kümelere aitlik dereceleri elde edilir. Bu sayede belirsizlik doğrudan modelleme sürecine dahil edilir.

D matrisi üzerinde ks adet kümeleme işlemi uygulanır. Sonuç olarak:

- Üyelik dereceleri matrisi $U \in [0,1]^{ks\times n}$,
- Küme merkezleri $C \in \mathbb{R}^{ks\times(gs+1)}$.

Adım 4. Eşik değer ile üyelik filtreleme

Her gözlem için tüm kümelere ait üyelik derecelerinin toplamı 1 ($\sum_{i=1}^{ks} U_{i,t} = 1,\ \forall t = 1,2,\ldots,n$) olacak şekilde normalize edilmiştir. Bu sayede, her gözlemin kümülatif belirsizlik düzeyi kontrol altında tutulur.

Belirsizlik sınırı (eşik değer, α-kesim katsayısı) olarak tanımlanan $\alpha \in (0,1)$ değeriyle düşük üyelik dereceleri sıfırlanır:

$$\bar{U}_{i,t} = \begin{cases} U_{i,t}, & eğer\ U_{i,t} > \alpha \\ 0, & diğer\ durumda \end{cases}. \quad (3)$$

Adım 5. Normalleştirilmiş üyelik ağırlıkları

Her gözlem için üyelik ağırlıkları normalize edilerek toplamın 1 olmasına dikkat edilir:

$$\mu_{i,t} = \frac{\bar{U}_{i,t}}{\sum_{j=1}^{ks} \bar{U}_{j,t}},\ payda \neq 0. \quad (4)$$

Ayrı ayrı eğitilen bu modellerin çıktıları, klasik bulanık çıkarım sistemlerinde olduğu gibi daha sonra ağırlıklandırılmak üzere kaydedilir. Bu ağırlıklar, her küme için girdi oluşturma sürecinde kullanılacaktır.

Adım 6. Girdi vektörünün oluşturulması

Her i-inci küme için, aşağıdaki şekilde bir değişken (özellik) vektörü tanımlanır:

$$X_t^{(i)} = \left[1, \mu_{i,t}, \mu_{i,t}^2, e^{\mu_{i,t}}, \tilde{x}_{t-1}, \tilde{x}_{t-2}, \cdots, \tilde{x}_{t-gs}\right],\ i = 1,2,\ldots,ks.$$

Vektör içinde kümeye ait üyelik derecesinin [0,1] aralığındaki nüanslarını daha görünür kılmak amacıyla iki doğrusal-olmayan dönüşüm kullanılmıştır: karesel ($\mu_{i,t}^2$) ve üstel ($e^{\mu_{i,t}}$). Bu tür dönüşümlerin bulanık sistemlerde doğruluğu artırabildiği literatürdeki çalışmalarda (Beyhan ve Alci, 2010, 2011; Celikyilmaz vd., 2009; Celikyilmaz ve Turksen, 2007, 2008) rapor edilmiştir.

Bu vektörler küme bazlı LSTM modelinin girdileridir. Çıktı ise $Y_t = \tilde{x}_t$'dir.

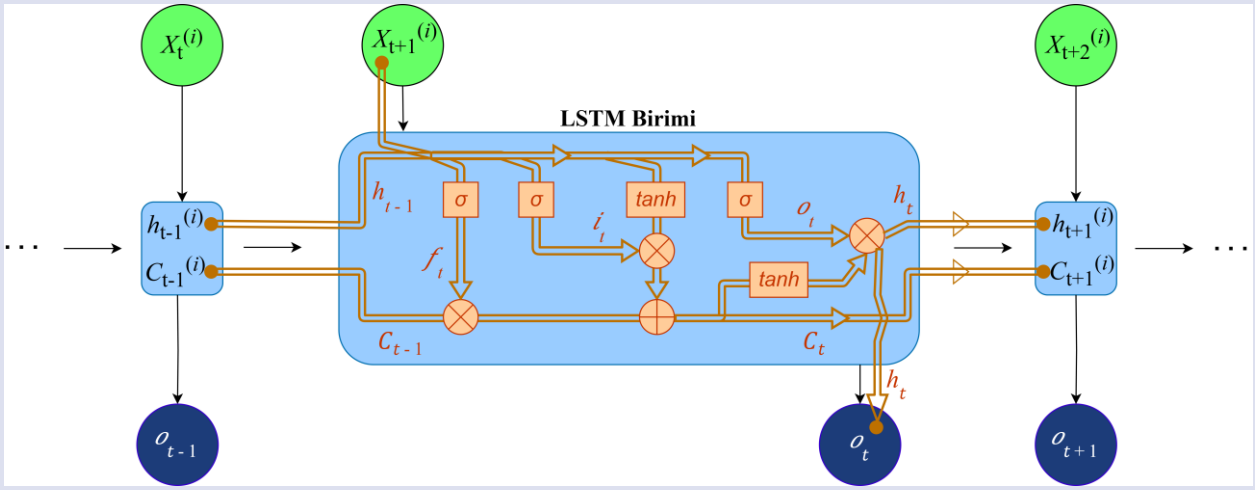
Adım 7. LSTM eğitimi

Eğitim ve test kümesi ayrımı yapılır. Eğitim verisi $X_{1:T}$, test verisi ise $X_{T+1:T+n_{test}}$ olarak tanımlanır.

Her değişken eğitim setine göre normalize edilir:

$$\tilde{X}_{j,t} = \frac{X_{j,t} - \mu_j}{\sigma_j},\quad \tilde{Y}_t = \frac{Y_t - \mu_Y}{\sigma_Y}. \quad (5)$$

Önerilen yöntemin yapısal bileşenlerinden biri olan LSTM tabanlı tahmin sürecini daha net bir şekilde ortaya koyabilmek amacıyla, modelde kullanılan LSTM fonksiyonunun yapısı Şekil 1'de görsel olarak sunulmuş ve LSTM yapısında kullanılan parametrelerin açıklamaları adım 8'de verilmiştir.



Şekil 1. Her Bir Küme İçin Oluşturulan LSTM Yapısı

Figure 1. Architectural Structure of the LSTM Constructed for Each Fuzzy Cluster

Şekil 1 incelendiğinde, önerilen yöntemin her bir bulanık küme için bağımsız olarak eğitilen LSTM fonksiyonlarını içerdiği görülmektedir. Model yapısında, zaman serisi verilerinin gecikmeli değişken vektörleri girdi olarak kullanılmış ve her bir LSTM modeli ile bu girdiler işlenerek tahmin çıktıları üretilmiştir. Şekil, LSTM modellerinin zaman bağımlılıklarını öğrenme süreçlerini ve her kümenin tahmin çıktısının nasıl elde edildiğini görsel olarak ifade etmektedir. Modelde yer alan her küme için bu LSTM yapısı bağımsız olarak eğitilmiş olup tahmin sürecinde elde edilen çıktıların kümelere aitlik derecelerine göre ağırlıklandırılarak nihai tahmin oluşturulmaktadır. Bu sayede, önerilen modelde zaman bağımlılıklarını öğrenme kapasitesi yüksek olan LSTM fonksiyonları etkin biçimde kullanılmıştır. Bu yapıyı daha ayrıntılı olarak incelemek amacıyla, modelde kullanılan LSTM mimarisinin yapısal özellikleri ve eğitim süreci aşağıda detaylandırılmaktadır.

Çalışmada kullanılan LSTM mimarisi, üç temel katmandan oluşmaktadır: sırasıyla bir girdi katmanı, belleği yöneten bir LSTM katmanı ve nihai tahmini gerçekleştiren tam bağlantılı regresyon katmanı. Modelin eğitimi, yaygın olarak tercih edilen Adam optimizasyon algoritması ile gerçekleştirilmiştir. Hiperparametrelerin arama aralığı ve nihai değerleri "Model Eğitimi ve Parametre Değerleri" başlığı altında sunulmuştur.

Adım 8. LSTM ile tahmin

Test aşamasında tahminler adım adım yapılır. Bu süreçte kullanılan LSTM hücresi, her bir t zaman adımı için aşağıdaki denklemlerle çalışır. Bir LSTM hücresinde t-inci zaman adımı için girdi vektörü X_t, gizli durum h_t, hücre durumu c_t, ağırlık matrisleri (W_i, W_f, W_c, W_o) ve yan değerleri (b_i, b_f, b_c, b_o) ile aşağıdaki işlemler yapılır:

Girdi kapısı $i_t = \sigma\left(W_i \times \left[h_{t-1}, X_t^{(i)}\right] + b_i\right)$,

Unutma kapısı $f_t = \sigma\left(W_f \times \left[h_{t-1}, X_t^{(i)}\right] + b_f\right)$,

Aday hücre $\tilde{c}_t = tanh\left(W_c \times \left[h_{t-1}, X_t^{(i)}\right] + b_c\right)$,

Hücre durumu güncellemesi $c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t$, $\odot$: Eleman bazlı çarpma işlemi,

Çıktı kapısı $o_t = \sigma\left(W_o \times \left[h_{t-1}, X_t^{(i)}\right] + b_o\right)$,

Gizli durum güncellemesi (Çıktı) $h_t = o_t \odot tanh(c_t)$.

Burada σ sigmoid aktivasyon fonksiyonu, $tanh$ ise hiperbolik tanjant aktivasyon fonksiyonudur.

Her test adımı için $\hat{y}_t^{(i)} = f_{LSTM}\left(X_t^{(i)}; h_{t-1}, c_{t-1}\right)$ tahmini üretilir. h_t ve c_t hücre durumları güncellenir. Güncellenen durumla bir sonraki adımın girdisi işlenir. LSTM katmanı sonrası, çıktı doğrusal bir regresyon katmanına aktarılmakta ve bu katman nihai tahmini üretmektedir.

Adım 9. Ağırlıklandırılmış tahmin

Her küme için LSTM modeli tarafından üretilen tahmin çıktıları, o gözleme ait üyelik dereceleri ile çarpılarak ağırlıklı ortalama alınmıştır. Bu sayede belirsizlik doğrudan tahmin sürecine entegre edilmiştir.

$$\hat{x}_t = \frac{\sum_{i=1}^{k} \mu_{i,t} \times \hat{y}_t^{(i)}}{\sum_{i=1}^{k} \mu_{i,t}}. \quad (6)$$

Elde edilen bulanık çıktı, ters normalizasyon ile kesin değerlere çevrilerek nihai tahmin ($\hat{x}_t^{final} = \hat{x}_t \times \sigma_{eğitim} + \mu_{eğitim}$) elde edilir.

Adım 10. Performans ölçütleri

Öngörü hatalarının mutlak düzeyini ve oransal boyutunu analiz etmek için hata kareler ortalaması karekökü (HKOK) ve ortalama mutlak yüzdelik hata (OMYH) ölçütleri birlikte kullanılmıştır.

$$HKOK = \sqrt{\frac{1}{n_{test}} \sum_t \left(\hat{x}_t^{final} - x_t\right)^2}, \quad (7)$$

$$OMYH = \frac{100}{n_{test}} \sum_t \left| \frac{\hat{x}_t^{final} - x_t}{x_t} \right|.$$

Yukarıda açıklanan işlem adımları, önerilen DBF yönteminin tüm bileşenlerini sırasıyla temsil etmektedir. Önerilen yöntemin performansını değerlendirmek amacıyla, literatürde yaygın olarak kullanılan yöntemlerle karşılaştırmalı analizler gerçekleştirilmiştir.

Alternatif Yöntemler ve Karşılaştırma

Önerilen yöntemin performansını değerlendirmek amacıyla, literatürde yaygın olarak kullanılan farklı tahmin yöntemleri ile karşılaştırmalar yapılmıştır. Finansal zaman serileri için Dalar ve Egrioglu (2025) çalışmasında yer alan yöntemler, meteorolojik veri seti için ise Kocak vd. (2021) çalışmasında tanıtılan yöntemler karşılaştırma amacıyla ele alınmıştır.

Doğrusal varsayımlara dayanan istatistiksel yöntemlerin, belirsizlik içeren karmaşık zaman serilerinde yetersiz kaldığı önceki çalışmalarda gösterilmiştir (Chakravarty vd., 2020, 2022a, 2022b; Hyndman ve Athanasopoulos, 2021). Dolayısıyla karşılaştırmalı analizler, yapay zeka ve bulanık sistem temelli yöntemlerle sınırlandırılmıştır.

Önerilen yöntemin finansal zaman serileri üzerindeki performansını değerlendirmek için aşağıdaki yöntemlerle karşılaştırmalar yapılmıştır:

- ANFIS-GP — Grid Partitioning-based Adaptive Neuro-Fuzzy Inference System (Izgara Bölümleme Tabanlı Uyarlamalı Sinir-Bulanık Çıkarım Sistemi): ANFIS-GP, bulanık mantık kurallarını ızgara tabanlı bölümlendirme yöntemiyle belirleyen bir ANFIS modelidir. Doğrusal olmayan zaman serilerini modellemek için iyi bir seçim olmasına rağmen büyük veri kümelerinde hesaplama maliyeti yüksektir (Jang 1993).
- ANFIS-SC — Subtractive Clustering-based ANFIS (Bölütleme Kümeleme Tabanlı ANFIS): ANFIS-SC, ızgara tabanlı bölümlendirme yerine kümeleme tabanlı bir yapı kullanarak hesaplama karmaşıklığını azaltır. Bu yöntem, sistemin yapısını ve parametrelerini optimize ederek tahmin doğruluğunu artırmaktadır (Jang 1993).
- MANFIS — Modified ANFIS (Geliştirilmiş ANFIS): MANFIS, klasik ANFIS modeline kıyasla üyelik fonksiyonlarını ve çıkarım kurallarını dinamik olarak ayarlama yeteneğine sahiptir. Bu nedenle hem doğrusal hem de doğrusal olmayan zaman serilerini modellemede esneklik sunmaktadır (Egrioglu vd., 2014).
- T1BF: Turksen (2008) tarafından önerilen bu yöntem, bulanık kümeleme ve regresyon analizine dayanarak kural tabanlı sistemlerden bağımsız bir tahmin modeli sunmakta olup finansal zaman serileri gibi karmaşık veri setlerinde belirsizlikleri modelleme yeteneğiyle öne çıkmaktadır.

Önerilen yöntemin sıcaklık verisi üzerindeki performansını ölçmek için aşağıdaki yöntemlerle karşılaştırmalar yapılmıştır:

- MLP-ANN — Multi-Layer Perceptron Artificial Neural Network (Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı): Bu yöntem, ileri beslemeli çok katmanlı yapay sinir ağı kullanarak tahmin yapan klasik bir modeldir. Finansal ve çevresel tahminlerde yaygın olarak kullanılmıştır.
- PS-ANN — Pi-Sigma Artificial Neural Network (Pi-Sigma Yapay Sinir Ağı): Pi-Sigma ANN, Shin ve Ghosh (1991) tarafından önerilen yüksek dereceli bir yapay sinir ağı modelidir. Çok değişkenli zaman serisi analizlerinde iyi sonuçlar elde etmekte ve düşük hesaplama maliyeti sunmaktadır.
- C-FTS — Classical Fuzzy Time Series (Klasik Bulanık Zaman Serileri): Chen (1996) tarafından geliştirilen bu model, bulanık mantık ilişkilerini kullanarak zaman serisi tahmini yapar. Ancak, doğrusal olmayan veri setlerinde modelleme gücü sınırlıdır.
- S&C-FTS — Song and Chissom Fuzzy Time Series (Song ve Chissom Bulanık Zaman Serileri): Q. Song ve Chissom (1994) tarafından önerilen bu yöntem, kompleks matris işlemleri kullanarak bulanık ilişkileri belirleyen ilk bulanık zaman serisi modelidir.
- FTS-N — Fuzzy Time Series Network Model (Bulanık Zaman Serileri Ağ Modeli): Bu yöntem, Bas vd. (2015) tarafından önerilmiş olup doğrusal ve doğrusal olmayan zaman serileri için kullanılan bir yapay sinir ağı modelidir.
- FTS-SMN — Single Multiplicative Neuron-based Fuzzy Time Series (Tek Çarpımsal Nöron Tabanlı Bulanık Zaman Serisi): Aladag (2013) tarafından geliştirilen bu model, tek nöronlu çarpımsal yapay sinir ağlarına dayalıdır. Düşük hesaplama maliyeti ile yüksek tahmin performansı sunar.
- FTS-PS — Pi-Sigma ANN-based Fuzzy Time Series (Pi-Sigma YSA Tabanlı Bulanık Zaman Serisi): Bas vd. (2018) tarafından önerilen bu model, pi-sigma yapay sinir ağları ile bulanık zaman serisi yöntemini birleştirerek tahmin gücünü artırmayı amaçlar.
- IFTS-PS-ABC — Intuitionistic Fuzzy Time Series based on Pi-Sigma ANN and Artificial Bee Colony (Pi-Sigma YSA ve Yapay Arı Kolonisi Tabanlı Sezgisel Bulanık Zaman Serisi): Egrioglu vd. (2019) tarafından geliştirilen bu model, sezgisel bulanık zaman serisi tahmini için PS-ANN ile yapay arı kolonisi optimizasyonunu birleştirmiştir.
- DIFTS-LSTM — Deep Intuitionistic Fuzzy Time Series based on LSTM (LSTM Tabanlı Derin Sezgisel Bulanık Zaman Serisi): Kocak vd. (2021) tarafından geliştirilen bu yöntem, sezgisel bulanık zaman serisi yaklaşımı ile derin öğrenme yöntemlerinden LSTM'nin entegrasyonunu esas alır. Modelde, verinin hem belirsizliği hem de zamansal bağımlılığı dikkate alınarak tahmin yapılır.

Model Eğitimi ve Parametre Değerleri

Hiperparametre seçimi iki aşamada gerçekleştirilmiştir. İlk aşamada yapılan ön tarama, pratik aralıkların belirlenmesine yöneliktir. Bu kapsamda gizli birim sayısı (gbs) başlangıçta 2–64 aralığında denenmiş; 8'den büyük değerlerin hata kriteri bakımından kayda değer bir iyileşme sağlamadığı, buna karşın eğitim süresini belirgin biçimde artırdığı gözlenmiştir. Bu bulgu doğrultusunda, izleyen deneylerde arama alanı 2–8 ile sınırlandırılmıştır. Epoch sayısı ise 100 ile 500 arasında test edilmiş; 250 epoch'un doğruluk-kararlılık dengesini sağladığı görülmüştür. Öğrenme sürecinin daha hızlı ve stabil hale gelmesi için yaygın olarak tercih edilen Adam optimizasyon algoritması kullanılmıştır.

İkinci aşamada, raporlanan tüm deneylerde kullanılan nihai sabit değerler belirlenmiştir. Epoch sayısı 250 olarak sabitlenmiş; doğrulama kümesi kullanılmadığı için erken durdurma uygulanmamıştır. Öğrenmenin kararlı seyretmesi amacıyla başlangıç öğrenme oranı 0.01 seçilmiş ve her 125 epoch sonunda %80 oranında azaltılarak eğitim kalan aşamada sürdürülmüştür. Gradyan eşiği 1 olarak atanmış ve tüm koşullarda sabit tutulmuştur. Gizli birim sayısı, her veri seti için 2–8 aralığında deneysel olarak belirlenmiş; her veri setinde en düşük hatayı veren değer sabitlenmiştir. Bu yapılandırma, küçük/orta ölçekli veri setlerinde doğruluk–kararlılık–maliyet dengesini korumakta; LSTM'nin zamansal örüntüleri öğrenme ve hatırlama kapasitesini sabit epoch ve kontrollü öğrenme oranı azaltımı ile desteklemektedir.

Bulanık kümeleme parametreleri kapsamında, kümelerin belirsizliğinin ne ölçüde temsil edeceğini belirleyen kesim katsayısı (α-cut) değeri 0 ile 0,4 aralığında değiştirilerek modelin farklı belirsizlik seviyelerine tepkisi incelenmiştir. α-kesim katsayısının küçük değerleri daha fazla veriyi dikkate almayı sağlarken, büyük değerler kümeleri daha keskin hale getirerek üyelik derecelerinin sıfırlanmasına neden olmuştur. Bu nedenle, Dalar ve Egrioglu (2025) çalışmasına dayalı olarak 0–0,4 aralığı seçilmiş; daha geniş değer aralıklarının belirsizliği yönetmeyi zorlaştırdığı ve model performansını düşürdüğü tespit edilmiştir.

Son olarak, bulanık kümelerin sayısı 2 ile 10 arasında test edilerek veri yapısına uygun en iyi küme sayısı belirlenmiştir.

Bulgular

Bu bölümde, önerilen derin bulanık fonksiyonlar yaklaşımının performansı finansal ve meteorolojik zaman serileri üzerinde değerlendirilmiş ve alternatif yöntemlerle karşılaştırılmıştır. Performans değerlendirme ölçütü olarak HKOK

değeri esas alınmıştır. Çizelgelerde kullanılan OMYH değeri ise, en düşük HKOK değerine karşılık gelen OMYH değeri olarak hesaplanmıştır.

Finansal Zaman Serisi Sonuçları

Önerilen yöntemin finansal zaman serisi verilerindeki başarısını değerlendirmek için ANFIS-GP, ANFIS-SC, MANFIS ve T1BF yöntemleriyle karşılaştırmalar yapılmıştır. Karşılaştırmalı analizler, her bir yıl ve her bir endeks için ayrı ayrı yapılmış ve farklı test kümesi boyutları (n_{test}: 10, 20, 40) dikkate alınmıştır.

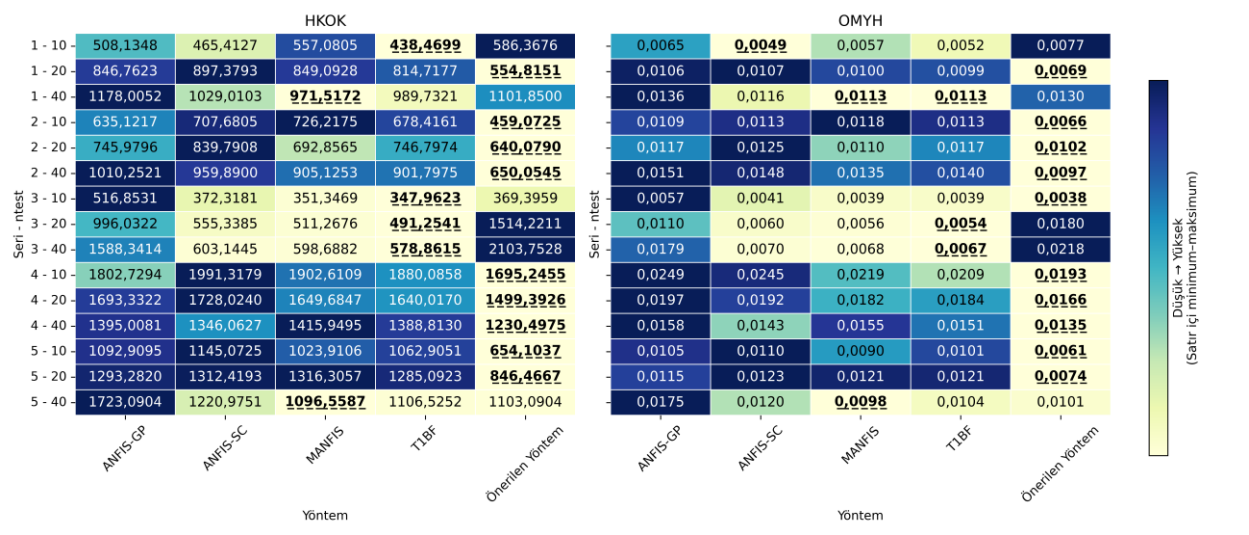
Çizelge 2'de, finansal veri setlerinde kullanılan yöntemlerin temel parametreleri olan gecikme sayısı (*gs*) ve küme sayısı (*ks*) aralıkları özetlenmiştir. Her yöntemin test edildiği parametre aralıkları, model yapılarını kıyaslayabilmek adına görsel olarak sadeleştirilmiş biçimde sunulmuştur.

Çizelge 2. Finansal Veri Setleri İçin Kullanılan Yöntemlerin Gecikme Sayısı ve Küme Sayısı Aralıkları
Table 2. Lag Orders and Cluster Number Ranges of the Methods Applied to Financial Datasets

Yöntem	Gecikme Sayısı (*gs*)	Küme Sayısı (*ks*)
ANFIS-GP	[1 2 0]	3, 4, 5
	[1 5 0]	3, 4, 5
	[1 2 5 0]	3, 4, 5
	[1 2 5 10 0]	3, 4, 5
	[1 2 3 4 5 0]	3, 4, 5
ANFIS-SC	[1 2 0]	3, 4, 5
	[1 5 0]	3, 4, 5
	[1 2 5 0]	3, 4, 5
	[1 2 5 10 0]	3, 4, 5
	[1 2 3 4 5 0]	3, 4, 5
MANFIS	1, 2, 5, 10	3, 4, 5
T1BF	1:10	3, 4, 5
Önerilen Yöntem (DBF)	1:10	3, 4, 5

Çizelge 2 incelendiğinde, önerilen DBF yönteminde gecikme sayısı 1 ila 10 arasında, küme sayısı ise 3, 4 ve 5 olarak seçilmiştir. Bu değerler, hem veri örüntülerinin yakalanmasını sağlayacak esneklik sunmakta hem de hesaplama maliyetlerini sınırlı tutmaktadır. Diğer yöntemlerde de benzer aralıklar kullanılarak yöntemler arası karşılaştırmanın adil olması hedeflenmiştir. Özellikle MANFIS ve T1BF gibi modellerde daha geniş gecikme aralıkları denenmiş, bu parametre uyumları sayesinde, önerilen yöntem ile diğer modeller arasındaki kıyaslamaların tutarlılığı korunmuştur.

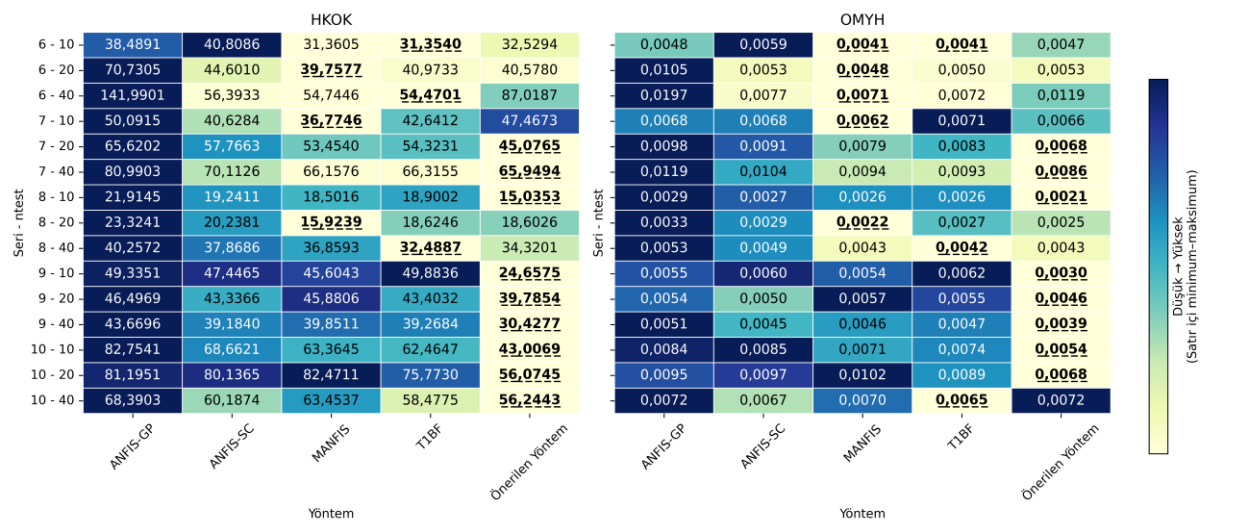
Şekil 2, Şekil 3, Şekil 4 ve Şekil 5'te sırasıyla BIST 100, FTSE 100, TAIEX ve NASDAQ 100 endeksleri için kullanılan beş farklı yöntemin her test kümesi boyutundaki hata kriteri değerleri karşılaştırmalı olarak sunulmuştur. İlgili şekillerde sol panelde HKOK, sağ panelde ise OMYH değerleri yer almaktadır. Renk skalası, hata düzeyinin büyüklüğünü temsil etmekte; koyu ve altı çizili değerlere sahip hücreler, ilgili satırda (yani her senaryoda) en düşük hatayı veren yöntemi göstermektedir.



Şekil 2. BIST 100 Endeksine Ait Öngörü Senaryolarında Karşılaştırmalı Yöntemlerin HKOK (Sol) ve OMYH (Sağ) Değerleri

Figure 2. RMSE (left) and MAPE (right) Values of Comparative Methods in the Forecasting Scenarios for the BIST 100 Index

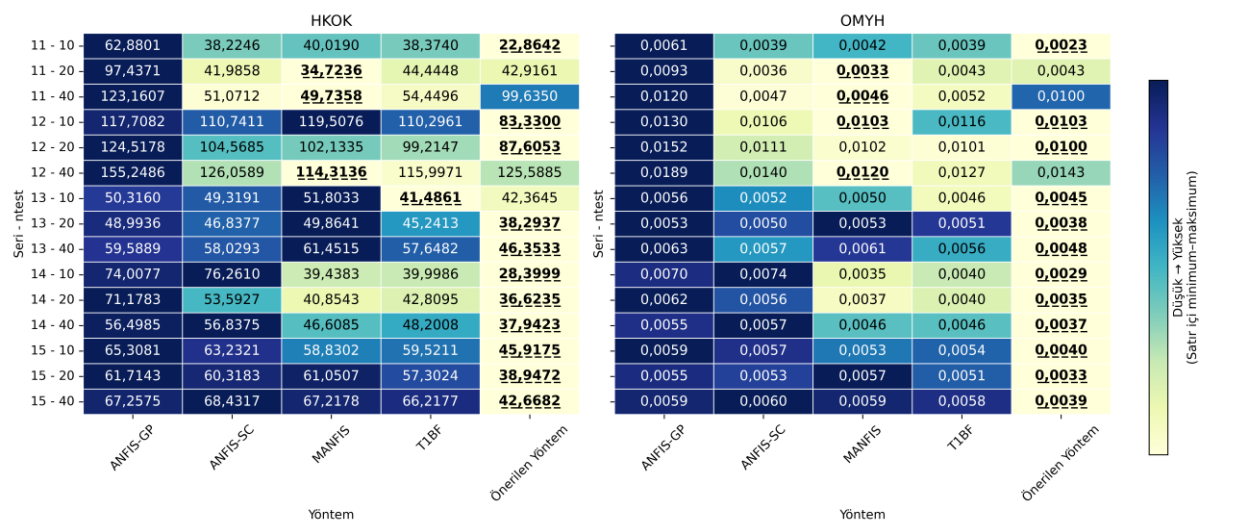
Şekil 2'de görüldüğü üzere, önerilen DBF yöntemi özellikle kısa vadeli test kümesi boyutlarında (n_{test} = 10) daha başarılı performans sergilemiştir. 2. seri (BIST 100/2011) örneğinde, DBF yöntemi HKOK = 459,0725 değeriyle en düşük hata oranına ulaşmıştır. Ayrıca, 5. seride hem HKOK hem de OMYH açısından en düşük hatayı verdiği görülmüştür. Bu sonuçlar, önerilen yapının yalnızca ortalamada değil, farklı yıl ve test senaryoları özelinde de tutarlı ve üstün tahmin başarısı sunduğunu göstermektedir.



Şekil 3. FTSE 100 Endeksine Ait Öngörü Senaryolarında Karşılaştırmalı Yöntemlerin HKOK (Sol) ve OMYH (Sağ) Değerleri

Figure 3. RMSE (left) and MAPE (right) Values of Comparative Methods in the Forecasting Scenarios for the FTSE 100 Index

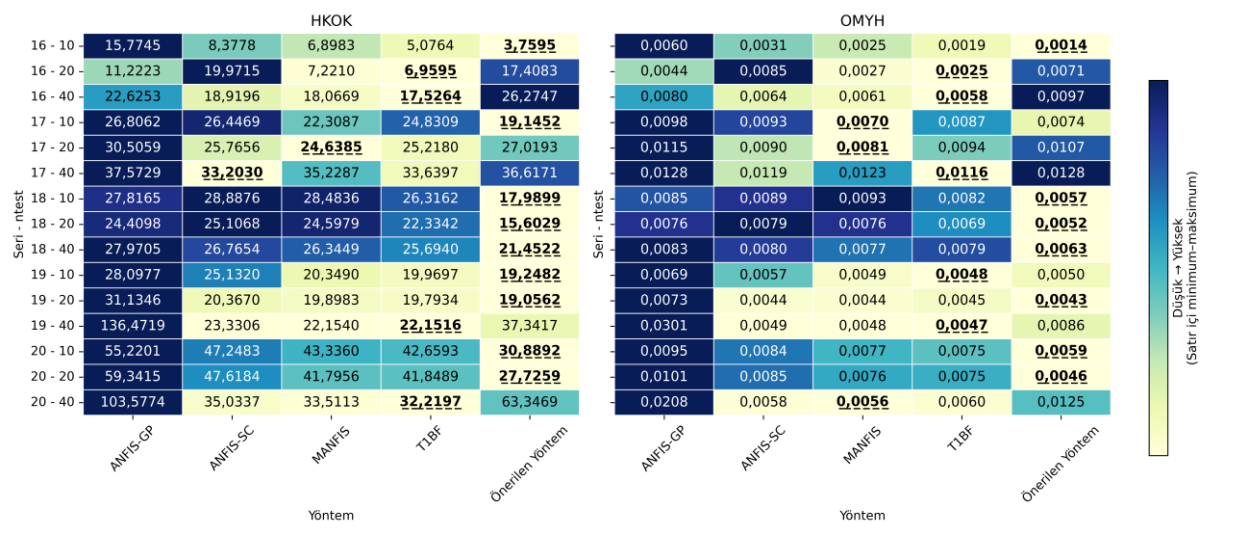
Şekil 3 incelendiğinde, önerilen DBF yöntemi özellikle 2012 ve 2013 yıllarına ait kısa vadeli öngörülerde (n_{test} = 10) dikkat çekici şekilde düşük hata oranları üretmiştir. Örneğin, Seri 8 için 10 gözlemli test kümesinde DBF yöntemi HKOK = 15,0353 ile tüm yöntemler arasında en düşük hatayı vermiştir. Benzer şekilde, 2014 yılına ait Seri 10 için de en düşük OMYH değerinin DBF yöntemiyle elde edildiği görülmektedir. Bu sonuçlar, önerilen yöntemin farklı yıllarda ve test senaryolarında istikrarlı bir biçimde düşük hata üretme kapasitesine sahip olduğunu ortaya koymaktadır.



Şekil 4. TAIEX Endeksine Ait Öngörü Senaryolarında Karşılaştırmalı Yöntemlerin HKOK (Sol) ve OMYH (Sağ) Değerleri

Figure 4. RMSE (left) and MAPE (right) Values of Comparative Methods in the Forecasting Scenarios for the TAIEX Index

Şekil 4 incelendiğinde, önerilen DBF yönteminin özellikle 2010 ve 2011 yıllarına ait kısa ve orta vadeli test senaryolarında başarılı öngörü performansı sergilediği görülmektedir. Özellikle 2011 yılına ait Seri 11 için 10 gözlemli test kümesinde DBF yöntemi, HKOK = 22,8642 değeriyle açık ara en düşük hata değerine ulaşmıştır. Ayrıca 2012 ve 2013 yıllarına ait verilerde hem HKOK hem de OMYH açısından rekabetçi ve istikrarlı sonuçlar elde edilmiştir. Bu bulgular, TAIEX gibi yüksek volatiliteye sahip veri setlerinde dahi önerilen yöntemin öngörü başarısını koruyabildiğini göstermektedir.

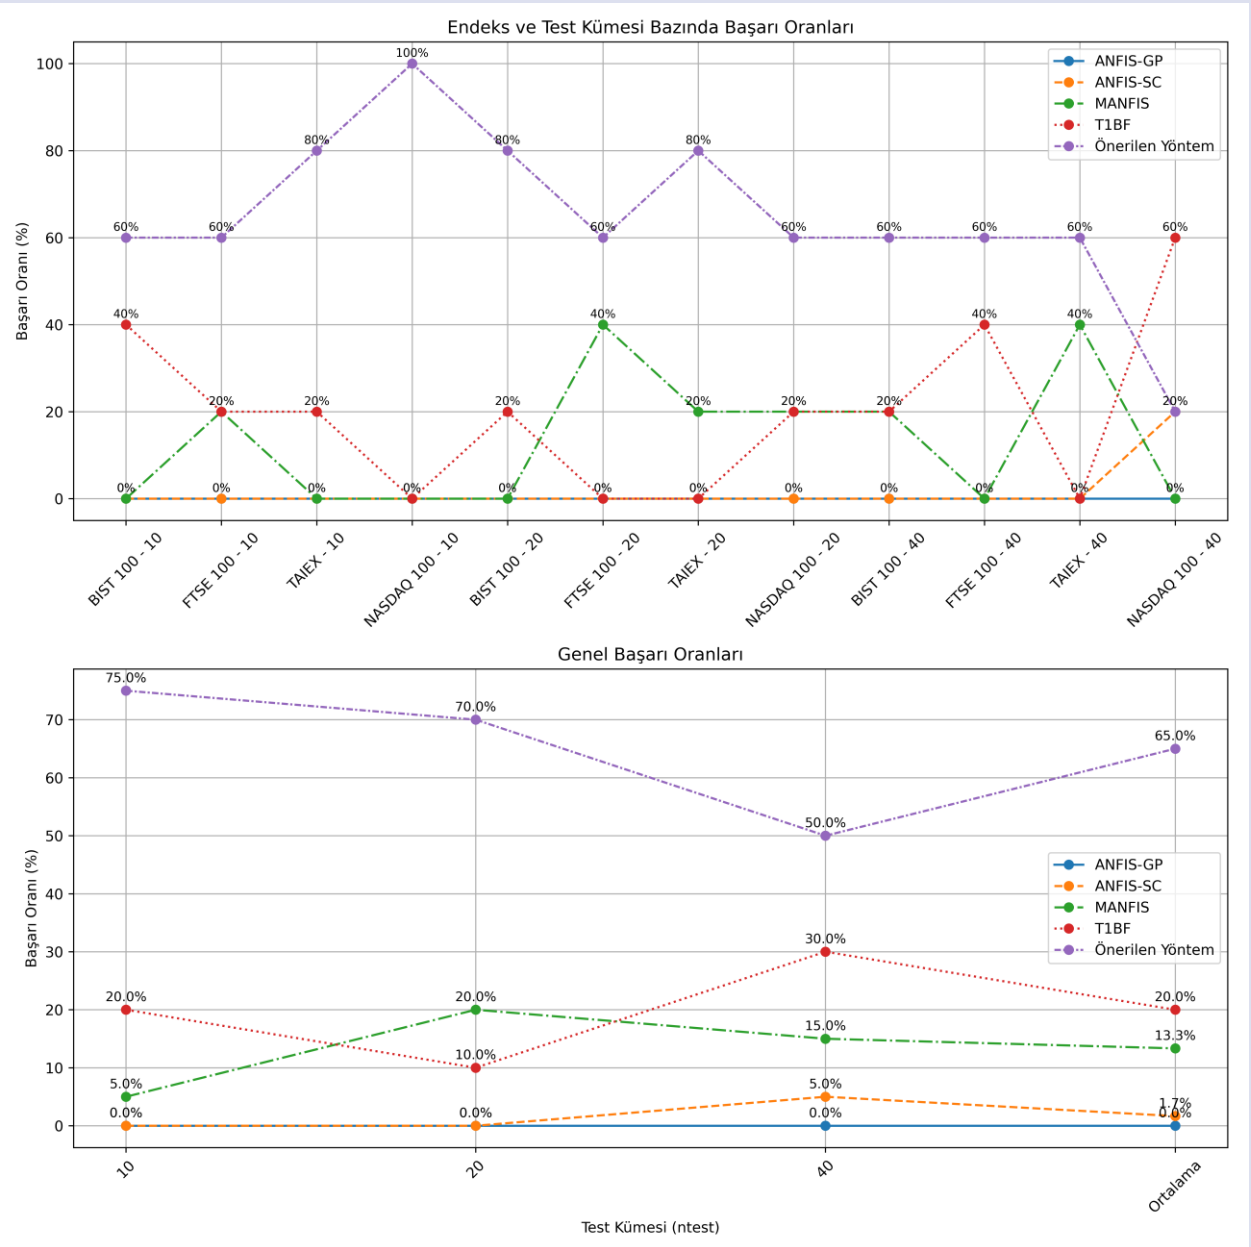


Şekil 5. NASDAQ 100 Endeksine Ait Öngörü Senaryolarında Karşılaştırmalı Yöntemlerin HKOK (Sol) ve OMYH (Sağ) Değerleri

Figure 5. RMSE (left) and MAPE (right) Values of Comparative Methods in the Forecasting Scenarios for the NASDAQ 100 Index

Şekil 5 incelendiğinde, önerilen DBF yönteminin özellikle kısa vadeli test kümelerinde dikkat çeken performans sergilediği gözlemlenmektedir. Özellikle 2010 yılına ait 16. Seri için elde edilen HKOK = 3,7595 ve OMYH = 0,0014 değerleri, diğer yöntemlere kıyasla anlamlı ölçüde düşük çıkmıştır. Ayrıca, Seri 19 ve 20 için de hem HKOK hem OMYH açısından önerilen yöntemin birçok test senaryosunda en düşük hata ürettiği görülmektedir. Bu durum, NASDAQ 100 gibi yüksek oynaklığa sahip veriler üzerinde önerilen yöntemin güvenilir ve kararlı sonuçlar sunduğunu göstermektedir.

Şekil 6'da önerilen yöntem ile karşılaştırmalı yöntemlerin dört farklı finansal endeks üzerindeki başarı oranları, test kümesi boyutlarına (n_{test}: 10, 20, 40) göre ayrıntılı biçimde sunulmuştur. Üst panelde, her bir endeks ve test kümesi kombinasyonu için yöntemlerin en düşük hata oranına sahip olup olmadığı yüzdesel başarı ile ifade edilmiştir. Alt panelde ise test kümesi uzunluklarına göre genel başarı oranları verilmiştir.



Şekil 6. Yöntemlerin Test Kümesi Uzunluklarına ve Endeks Türlerine Göre Başarı Oranlarının Yüzdesel Dağılımı
Figure 6. Percentage Distribution of Success Rates of the Methods According to Test Set Lengths and Index Types

Şekil 6'da da görüldüğü üzere, önerilen yöntem toplam 60 karşılaştırmalı tahmin senaryosunun 39'unda (%65) en düşük öngörü hatasını üretmiştir. Kısa vadeli tahminlerde (n_{test} = 10) bu oran %75'e ulaşırken, orta vadeli tahminlerde (n_{test} = 20) %70, uzun vadeli tahminlerde (n_{test} = 40) ise %50 başarı sağlanmıştır. Bu oranlar, yöntemin özellikle kısa ve orta vadeli öngörülerde daha etkin performans sergilediğini ve genel olarak tutarlı tahmin kabiliyetine sahip olduğunu göstermektedir.

Ayrıca, NASDAQ 100 veri setinde 10 gözlemli test kümesi için yapılan tüm tahmin senaryolarında önerilen yöntemin en iyi sonucu verdiği gözlemlenmiştir (%100 başarı). Bu bulgu, önerilen yöntemin yüksek volatilite içeren verilerde bile kararlı tahmin yeteneği sunduğunu göstermektedir.

Önerilen yöntemin finansal zaman serisi üzerinde elde edilen en düşük HKOK değerine sahip hiperparametre kombinasyonları, her bir endeks ve test kümesi boyutu için ayrı ayrı belirlenmiştir. Bu kombinasyonlar, modelin öngörü performansını en üst düzeye çıkaracak şekilde optimize edilmiştir. Çizelge 3, her bir veri seti için en iyi hiperparametre değerlerini özetlemektedir.

Çizelge 3. Önerilen Yöntemin Finansal Zaman Serisi İçin En İyi Hiperparametre Değerleri
Table 3. Optimal Hyperparameter Values of the Proposed Method for the Financial Time Series

BIST 100	n_{test}	gs	ks	α	gbs	FTSE 100	n_{test}	gs	ks	α	gbs
	10	4	2	0,00	5		10	4	4	0,20	5
2010	20	3	2	0,00	2	2010	20	4	3	0,00	6
	40	4	3	0,20	8		40	3	4	0,20	7
	10	3	2	0,20	5		10	3	3	0,10	2
2011	20	3	2	0,00	2	2011	20	4	3	0,10	8
	40	3	4	0,10	5		40	4	3	0,10	6
	10	3	3	0,20	5		10	4	2	0,00	6
2012	20	3	2	0,20	8	2012	20	4	2	0,10	8
	40	3	2	0,00	8		40	4	2	0,00	2
	10	4	2	0,10	7		10	4	2	0,20	8
2013	20	4	2	0,20	7	2013	20	4	2	0,10	2
	40	3	2	0,00	8		40	4	2	0,10	2
	10	3	2	0,20	5		10	4	2	0,20	8
2014	20	3	2	0,10	2	2014	20	4	2	0,20	4
	40	3	2	0,20	4		40	3	2	0,10	2

TAIEX	ntest	gs	ks	α	gbs	NASDAQ 100	ntest	gs	ks	α	gbs
	10	4	2	0,10	6		10	3	2	0,00	6
2010	20	4	2	0,20	5	2010	20	4	2	0,10	8
	40	4	2	0,20	7		40	3	2	0,20	4
	10	3	2	0,20	7		10	4	2	0,00	8
2011	20	3	2	0,20	7	2011	20	3	2	0,10	6
	40	3	2	0,00	7		40	3	2	0,20	3
	10	3	2	0,10	6		10	4	2	0,20	3
2012	20	3	2	0,10	5	2012	20	4	2	0,10	2
	40	3	2	0,10	2		40	4	2	0,20	3
	10	4	2	0,20	2		10	3	2	0,20	5
2013	20	3	2	0,00	7	2013	20	3	2	0,20	5
	40	3	2	0,00	3		40	4	2	0,00	8
	10	4	2	0,20	3		10	3	2	0,10	6
2014	20	4	2	0,10	3	2014	20	4	3	0,10	4
	40	4	2	0,10	2		40	3	2	0,00	5

Çizelge 3'te, önerilen DBF yönteminin farklı finansal veri setlerinde değişken test kümesi boyutlarına göre en düşük hatanın elde edildiği durumdaki hiperparametre kombinasyonları verilmiştir. Kısa vadeli öngörülerde daha düşük gecikme sayıları ve daha az sayıda küme kullanımı öne çıkmaktadır. Bu bulgular, modelin parametrik esnekliğinin farklı senaryolara uyum sağlama kapasitesini desteklemektedir.

Bu bulgular, özellikle bulanık fonksiyonlar yaklaşımının belirsizlik yönetimi açısından güçlü bir araç olduğunu ve LSTM'nin uzun vadeli bağımlılıkları öğrenme kapasitesi ile birleştirildiğinde daha iyi sonuçlar verdiğini ortaya koymaktadır.

Meteorolojik Zaman Serisi Sonuçları

Önerilen yöntemin borsa verileri haricinde bir verideki performansını gözlemlemek için 21'inci seri olan ve Kocak vd. (2021) çalışmasında kullanılan Giresun ili günlük sıcaklık verisi kullanılmıştır. Kocak vd. (2021) çalışmasında MLP-ANN, PS-ANN, C-FTS, S&C FTS, FTS-N, FTS-SMN, FTS-PS ve IFTS-PS-ABC yöntemlerini önerdikleri yöntem olan DIFTS-LSTM ile karşılaştırmışlardır Kocak vd. (2021) çalışmasında karşılaştırmada kullanılan öngörü yöntemlerinin parametre değerleri; model derecesi 1 ile 5 arasında, küme sayısı 3 ile 10 arasında, gizli katman nöron sayısı 1 ile 5 arasında deneme yanılma yöntemi kullanılarak test kümesine ait en iyi HKOK değerine göre belirlenmiştir.

Önerilen yöntemin meteorolojik veri setindeki başarısı, Giresun iline ait 2017 yılı günlük minimum sıcaklık verileri kullanılarak analiz edilmiştir. Model, MLP-ANN, PS-ANN, C-FTS, S&C-FTS, FTS-N, FTS-SMN, FTS-PS, IFTS-PS-ABC ve DIFTS-LSTM yöntemleri ile karşılaştırılmıştır.

Giresun iline ait günlük minimum sıcaklık verileri kullanılarak yapılan tahmin sonuçları Çizelge 4'te gösterilmektedir. Çizelge, önerilen yöntem ile birlikte çok sayıda alternatif yöntemin (MLP-ANN, PS-ANN, C-FTS, S&C-FTS, FTS-N, FTS-SMN, FTS-PS, IFTS-PS-ABC ve DIFTS-LSTM) aynı 14 günlük test dönemi için gerçekleştirdiği öngörüleri ve bu öngörülere karşılık gelen HKOK değerini kapsamaktadır. Bu karşılaştırma, önerilen yöntemin yalnızca finansal değil, meteorolojik zaman serileri üzerindeki performansını da test etme imkânı sunmaktadır.

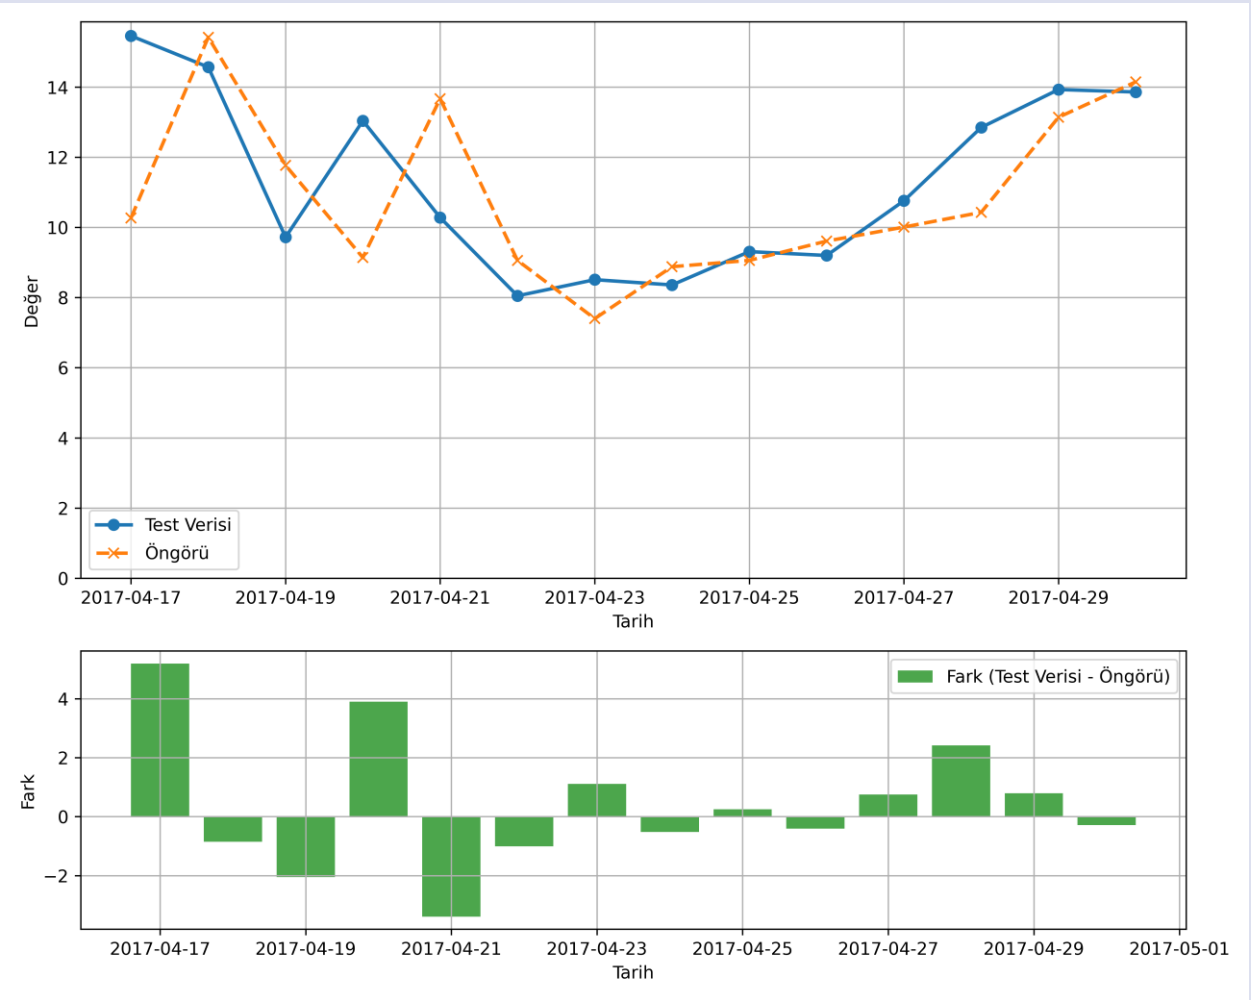
Çizelge 4. Giresun ili sıcaklık verisi için HKOK değerleri
Table 4. RMSE values for the temperature data of Giresun province

Tarih	Test Verisi	MLP-ANN	PS-ANN	C-FTS	S&C FTS	FTS-N	FTS-SMN	FTS-PS	IFTS-PS-ABC	DIFTS-LSTM	Önerilen Yöntem
17.04.2017	15,46	10,16	10,65	10,47	9,96	11,40	10,97	9,91	11,27	10,71	10,27
18.04.2017	14,57	11,50	13,58	14,93	14,85	14,76	13,09	14,15	12,72	10,89	15,42
19.04.2017	9,72	11,24	9,80	6,01	8,50	12,48	8,85	9,91	6,34	11,78	11,77
20.04.2017	13,04	9,06	7,88	10,13	9,96	8,76	8,85	9,91	9,37	10,35	9,14
21.04.2017	10,28	11,14	12,65	10,47	14,85	13,13	13,09	9,91	13,16	10,41	13,67
22.04.2017	8,05	9,78	9,14	10,47	9,96	9,60	8,85	9,91	9,90	8,82	9,06
23.04.2017	8,51	8,17	7,96	7,35	8,17	8,63	8,85	9,91	8,03	8,45	7,40
24.04.2017	8,36	9,09	9,64	8,09	8,17	8,79	8,85	9,91	7,92	8,34	8,88
25.04.2017	9,31	8,88	8,83	8,09	8,17	8,65	8,85	9,91	8,04	8,34	9,06
26.04.2017	9,20	9,67	9,95	10,13	9,26	9,38	8,85	9,91	8,35	10,80	9,61
27.04.2017	10,76	9,46	9,35	10,13	9,26	8,75	8,85	9,91	10,02	11,33	10,01
28.04.2017	12,85	10,43	10,98	10,47	10,87	10,41	10,97	9,91	11,68	11,81	10,43
29.04.2017	13,93	11,07	12,06	10,47	14,85	11,90	10,97	14,15	12,04	13,57	13,14
30.04.2017	13,86	11,21	11,08	14,04	9,62	12,63	10,97	9,91	13,46	13,39	14,15
HKOK		2,4394	2,3438	2,3148	2,5682	2,2254	2,3017	2,3091	2,1728	1,9500	**0,9309***

*; En düşük HKOK değeri kalın yazı tipi ve yıldız işareti kullanılarak gösterilmiştir.

Çizelge 4 incelendiğinde, önerilen yöntemin Giresun ili sıcaklık verisi için yapılan 14 günlük tahmin sürecinde en düşük HKOK değerine (0,9309) sahip olduğu görülmektedir. Bu değer, gecikme sayısı 1, küme sayısı 4, α-kesim katsayısı 0,40 ve gizli birim sayısı 8 olarak belirlenen hiperparametre kombinasyonu ile elde edilmiştir. Özellikle PS-ANN (2,3438), C-FTS (2,3148) ve FTS-N (2,2254) gibi literatürde sıklıkla kullanılan yöntemlere ve LSTM tabanlı DIFTS-LSTM (1,9500) yöntemine kıyasla elde edilen bu düşük hata değeri, önerilen yöntemin mevsimsel değişkenlik ve sıcaklık dalgalanmalarına karşı daha başarılı tahminler ürettiğini göstermektedir. Bu durum, önerilen DBF yönteminin farklı veri tiplerinde de başarılı bir öngörü aracı olabileceğini ortaya koymaktadır.

Giresun ili günlük minimum sıcaklık verisinin test kümesi gözlemleri ve önerilen yöntem ile elde edilen öngörüler görsel olarak Şekil 7'de sunulmaktadır.



Şekil 7. Giresun İli Günlük Minimum Sıcaklık Verisi İçin Test Verisi ve Önerilen Yöntemle Elde Edilen Öngörü Değerlerinin Karşılaştırılması

Figure 7. Comparison of the Test Data and the Forecast Values Obtained by the Proposed Method for the Daily Minimum Temperature Data of Giresun Province

Şekil 7 incelendiğinde üst panelde, test verisi ile öngörü değerlerinin zaman eksenindeki değişimi karşılaştırmalı olarak gösterilmiştir. Alt panelde ise, test verisi ile öngörü arasındaki farklar çubuk grafik formatında sunulmuştur. Görüldüğü üzere, önerilen modelin öngörüleri genellikle gerçek değerlere yakın seyretmekte ve özellikle belirli tarihlerde hata düzeyinin düşük olduğu gözlemlenmektedir. Bu sonuçlar, önerilen yöntemin meteorolojik veri seti üzerinde güvenilir tahminler ürettiğini ve kısa vadeli öngörülerde yüksek başarı sağladığını göstermektedir.

Genel Değerlendirme ve Karşılaştırmalı Performans Analizi

Önerilen yöntem hem finansal hem de meteorolojik zaman serisi öngörülerinde diğer yöntemlere kıyasla daha iyi performans sergilemiştir. Ayrıca önerilen yöntem;

- Kısa vadeli (n_{test} = 10) tahminlerde %75 oranında en iyi performansı göstermiştir.
- Uzun vadeli (n_{test} = 40) tahminlerde hata oranlarını düşürerek istikrarlı sonuçlar üretmiştir.

LSTM tabanlı bellek yapısı, volatilitenin yüksek olduğu finansal serilerdeki dalgalanmalara karşı uyum sağlayarak başarılı tahminler üretmesini sağlamıştır.

Sonuçlar ve Tartışma

Çalışmada, zaman serisi öngörü problemlerinde sıkça karşılaşılan belirsizlikleri daha etkili biçimde ele alabilmek amacıyla, tip-1 bulanık fonksiyonlar ile uzun kısa süreli bellek yapılarının entegrasyonuna dayanan yeni bir model olan Derin Bulanık Fonksiyonlar yöntemi geliştirilmiştir. Önerilen yöntem ile yalnızca tahmin doğruluğu değil, aynı zamanda belirsizliklerin sistematik olarak modellenmesi hedeflenmiştir.

Önerilen yöntem hem finansal hem de meteorolojik zaman serileri üzerinde test edilmiş; literatürde yaygın olarak kullanılan klasik, sezgisel ve bulanık tabanlı modellerle kapsamlı biçimde karşılaştırılmıştır. Yapılan değerlendirmeler, DBF'nin çeşitli veri türlerinde ve farklı test senaryolarında istikrarlı ve yüksek doğrulukta sonuçlar sunduğunu göstermiştir. Hata ölçütleri olarak kullanılan HKOK ve ona karşılık gelen OMYH değerleri üzerinden yapılan analizlerde, DBF yöntemi toplam 60 test koşulunun 39'unda (%65) en düşük hata değerini üretmiştir.

Kısa vadeli öngörülerde (n_{test}= 10) önerilen yöntemin başarı oranı %75'e ulaşırken, orta vadeli tahminlerde (n_{test}= 20) bu oran %70, uzun vadeli tahminlerde (n_{test}= 40) ise %50 seviyesinde kalmıştır. Bu bulgular, yöntemin özellikle kısa ve orta vadeli öngörü senaryolarında yüksek performans sergilediğini ortaya koymaktadır.

Elde edilen sonuçlar, önerilen DBF yönteminin, zaman serisi öngörülerinde hem belirsizliğin modellenmesi hem de örüntü öğrenimi açısından mevcut yöntemlere kıyasla daha iyi düzeyde bir yaklaşım sunduğunu göstermektedir. Yöntemin modüler yapısı, farklı sektörlerdeki öngörü uygulamaları için uyarlanabilirliğini artırmakta ve derin öğrenme ile bulanık mantığın bütünleştiği esnek bir çerçeve oluşturmaktadır.

Önerilen DBF yönteminin temel üstünlükleri aşağıdaki gibi özetlenebilir:

- *Belirsizlik yönetimi*: Bulanık kümeleme yaklaşımı ile her gözlemin birden fazla kümeye aitliği modellenerek, tahmin sürecine belirsizlik dahil edilmiştir.
- *LSTM yapısıyla yüksek tahmin kabiliyeti*: Modelin, uzun vadeli bağımlılıkları öğrenme yeteneği sayesinde finansal serilerdeki dalgalanmalara karşı başarılı öngörüler üretmesi sağlanmıştır.
- *Modüler yapı*: Her bir kümeye ait LSTM modelinin, o kümeye özgü veriyi öğrenmesine olanak tanımakta ve böylece modelin genel performansını artırmaktadır. Bu yaklaşım, önerilen yöntemin farklı veri yapıları üzerindeki uyarlanabilirliğini artırmakta ve tahmin doğruluğuna katkı sağlamaktadır.
- *Parametrik esneklik*: Küme sayısı, gecikme sayısı ve LSTM hiperparametreleri, önceden tanımlı aday uzayda ızgara araması ile ve HKOK ölçütüne göre sistematik olarak seçilmektedir.

Tüm bu özellikler, DBF yöntemini yalnızca teorik olarak değil, aynı zamanda pratik uygulamalar açısından da başarılı ve uyarlanabilir bir model hâline getirmektedir. Elde edilen sonuçlar hem akademik çalışmalar hem de karar destek sistemleri açısından yöntemin uygulanabilirliğini ve genellenebilirliğini desteklemektedir.

Sınırlılıklar ve Gelecek Çalışma Önerileri

Önerilen yöntemin güçlü yönlerine karşın, bazı sınırlılıkları da göz ardı edilmemelidir. Her bir küme için ayrı ayrı LSTM modeli eğitilmesi yüksek hesaplama maliyeti doğurabilmekte ve büyük veri setlerinde eğitimi zaman alıcı hale getirmektedir. Ayrıca, yöntemin tahmin sürecinde yalnızca ağırlıklı ortalama çıkarımı kullanılmış, alternatif teknikler test edilmemiştir. Gelecek çalışmalarda, farklı çıkarım stratejileri ile yöntemin esnekliği ve tahmin gücü artırılabilir. Ek olarak, DBF yönteminin farklı alanlardaki çok değişkenli zaman serilerine uygulanması, genellenebilirliğini daha geniş veri türleri üzerinde sınamak açısından önem arz etmektedir.

Bu çalışmada, önerilen yöntemin genel öngörü performansı değerlendirilmiş olup her küme bazında detaylı analiz yapılmamıştır. Küme bazlı analiz yapıldığında, her bir kümenin üyelik derecelerine bağlı olarak farklı hata oranları gözlemlenebilir. Gelecek çalışmalarda, kümeler arası performans farklılıklarının belirlenmesi ve bu farklılıkların model yapısına etkisinin incelenmesi planlanmaktadır.

Gelecekte yapılacak çalışmalarda;

- Yöntemin hiperparametre ayarlarının otomatikleştirilmesi,
- Tip-2 bulanık sistemlerin entegrasyonu,
- Enerji, sağlık, trafik gibi farklı alanlardaki zaman serilerine uygulanması,
- Açıklanabilir yapay zeka yöntemleriyle önerilen yöntemin yorumlanabilirliğinin artırılması önerilmektedir.

Extended Abstract

Forecasting time series with high accuracy is a central objective in many application areas including finance, meteorology and energy systems. Real-world time series frequently exhibit nonlinear dynamics, regime shifts and diverse sources of uncertainty — properties that complicate modelling and often reduce the robustness of single-model forecasts. Motivated by these challenges, we present Deep Fuzzy Forecasting Functions (DBF), a hybrid framework that integrates classical type-1 fuzzy partitioning with per-region recurrent learners based on long short-term memory. DBF is intended to preserve linguistic interpretability via fuzzy memberships while exploiting learned temporal patterns through recurrent sequence learners to produce robust point forecasts.

The DBF workflow begins with careful preprocessing and temporal embedding of the univariate series so that past context is explicitly represented in model inputs. Preprocessing follows a strict train-only normalization protocol to avoid information leakage: statistics used for scaling are computed exclusively on training partitions and then applied to validation and test sets; model outputs are inverse-scaled before computation of natural-scale errors. The lagged

input space is subsequently partitioned using a fuzzy clustering procedure, yielding overlapping regions and a membership map that quantifies each observation's degree of affiliation to the identified regions. To limit the influence of negligible affiliations during aggregation, a thresholding mechanism (α-cut) is applied so that membership values below the chosen threshold are set to zero.

For each fuzzy region identified by the clustering process, a region-specific input representation is formed by augmenting lagged observations with membership-based features. Specifically, each region's feature vector includes the normalized membership contribution and two simple nonlinear transforms of that contribution. The inclusion of these low-complexity transformations enhances the discriminative power of membership information near region boundaries without introducing additional trainable parameters. As a result, each region yields its own training set and an independent recurrent model targeted at local temporal behaviour.

Region-specific recurrent models are trained independently yet under a common, consistent protocol: an adaptive optimizer is employed with a fixed number of training epochs, a conservative mid-training reduction of the learning rate to aid convergence, and gradient clipping to prevent numerical instability. To reduce stochastic variability arising from random initialization, candidate configurations are repeated multiple times (five repeats in our experiments) and the best repeat (the one yielding the lowest RMSE) is used when comparing repeats for a candidate. Inputs and targets are standardized using only training-set statistics, and predictions are inverse-scaled prior to error calculation to ensure fair, natural-scale evaluation.

Hyperparameter selection was designed with reproducibility and objectivity in mind. Predefined candidate ranges were established for the number of fuzzy regions, embedding lag length, the α-cut threshold and recurrent model sizes. We performed a systematic grid search over these candidate sets; each candidate configuration was evaluated using time-aware out-of-sample holdouts, and compared using standard point-forecast error metrics. The configuration reported for each candidate is the one that produced the lowest RMSE among repeats for that candidate; mean absolute percentage error is reported as a complementary metric. Pilot exploration on our datasets indicated that very large recurrent models provided limited additional benefit; therefore reported experiments constrain recurrent model sizes to modest values to balance expressiveness and generalization.

At forecasting time, each region model produces a point forecast and the DBF aggregator computes a normalized, membership-weighted average of these region outputs. Normalization by the sum of active membership contributions ensures that the final forecast is dominated by models whose region membership is strong for the current observation; ambiguous observations therefore receive proportionate contributions from multiple region models. The implementation preserves internal recurrent states across forecasting steps in order to maintain temporal consistency in sequential predictions.

We validated DBF on two complementary groups of real datasets. The financial group comprises multiple equity indices from different exchanges across a multi-year window to capture varied market dynamics; the meteorological group consists of daily minimum temperature observations from a Turkish location, selected to examine seasonal structure and abrupt transitions. Representative fuzzy and neural forecasting baselines from the literature were reproduced under the same preprocessing and validation framework to ensure comparability. Reported experiments present the performance of the selected (minimum-RMSE) configuration for each candidate, and descriptive summaries (e.g., median and spread across independent repeats) are provided to illustrate result stability.

Experimental results show that DBF reduces point-forecast errors relative to many baselines in the tested scenarios, especially at short- and medium-term horizons where local regime adaptation is critical. In the meteorological two-week forecast case, the DBF configuration selected by the search yielded substantially lower RMSE than several comparative methods under the identical evaluation protocol, and graphical comparisons demonstrate that DBF's aggregated forecasts more closely follow seasonal cycles and sudden transitions in many instances. Beyond raw error metrics, per-region outputs offer interpretable insights: the membership trajectories and per-region predictions help identify regime shifts and localized dynamics that would be difficult to capture with a single global model.

From an implementation and deployment perspective, training multiple region-specific models increases aggregate computation compared to a single global model. However, region models are independent and thus training can be parallelized to reduce wall-clock time; for the dataset scales used in this study, the total training time remained practical. Stabilization practices — such as training-only standardization, gradient clipping, conservative learning-rate scheduling and modest recurrent sizes — were important to obtain consistent and robust training behaviour across regions. Random seeds and repetition metadata were saved during experiments to support reproducibility.

In summary, Deep Fuzzy Forecasting Functions provide a modular, reproducible hybrid framework that combines fuzzy structural uncertainty modelling with per-region temporal learners. The combination of lightweight membership transforms, systematic hyperparameter exploration, and independent region models produces robust and interpretable point forecasts across heterogeneous real-world time series.

Katkı Oranları ve Çıkar Çatışması / Contribution Rates and Conflicts of Interest

Etik Beyan	Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur.	**Ethical Statement**	It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited.
Yazar Katkıları	Çalışmanın Tasarlanması: AZD (%100) Veri Toplanması: AZD (%100) Veri Analizi: AZD (%100) Makalenin Yazımı: AZD (%100) Makale Gönderimi: AZD (%100)	**Author Contributions**	Research Design: AZD (%100) Data Collection: AZD (%100) Data Analysis: AZD (%100) Writing the Article: AZD (%100) Article Submission: AZD (%100)
Etik Bildirim	iibfdergi@cumhuriyet.edu.tr	**Complaints**	iibfdergi@cumhuriyet.edu.tr
Çıkar Çatışması	Çıkar çatışması beyan edilmemiştir.	**Conflicts of Interest**	The author(s) has no conflict of interest to declare.
Finansman	Bu çalışma, Giresun Üniversitesi tarafından desteklenen "Zaman Serisi Öngörüsü için Derin Bulanık Fonksiyonlar Yaklaşımı" başlıklı proje kapsamında gerçekleştirilmiştir (Proje No: FEN-BAP-A-250221-36, 2021-2022).	**Grant Support**	This study was conducted within the scope of the project titled "Deep Fuzzy Functions Approach for Time Series Forecasting", supported by Giresun University (Project No: FEN-BAP-A-250221-36, 2021–2022).
Telif Hakkı & Lisans	Yazar dergide yayınlanan çalışmalarının telif hakkına sahiptir ve çalışmaları **CC BY-NC 4.0** lisansı altında yayımlanmaktadır.	**Copyright & License**	Author publishing with the journal retains the copyright to his work licensed under the **CC BY-NC 4.0**.

Kaynakça

Aktoprak, M. R., & Cagcag Yolcu, O. (2025). A New Approach for Time Series Prediction: Fuzzy Regression Network Functions. *International Journal of Advances in Engineering and Pure Sciences*, *37*(1), 36-52. https://doi.org/10.7240/jeps.1573839

Aladag, C. H. (2013). Using multiplicative neuron model to establish fuzzy logic relationships. *Expert Systems with Applications*, *40*(3). https://doi.org/10.1016/j.eswa.2012.05.039

Aladag, C. H., Turksen, I. B., Dalar, A. Z., Egrioglu, E., & Yolcu, U. (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*(1), 1309-1190.

Alateeq, M., & Pedrycz, W. (2024). Logic-oriented fuzzy neural networks: A survey. *Expert Systems with Applications*, *257*, 125120. https://doi.org/10.1016/j.eswa.2024.125120

AL-Sukeinee, R. J., & Khudeyer, R. S. (2024). Review: Deep Learning and Fuzzy Logic Applications. *Engineering and Technology Journal*, *09*(06). https://doi.org/10.47191/etj/v9i06.09

Bas, E., & Egrioglu, E. (2022). A fuzzy regression functions approach based on Gustafson-Kessel clustering algorithm. *Information Sciences*, *592*, 206-214.

Bas, E., Egrioglu, E., Aladag, C. H., & Yolcu, U. (2015). Fuzzy-time-series network used to forecast linear and nonlinear time series. *Applied Intelligence*, *43*, 343-355. https://doi.org/10.1007/s10489-015-0647-0

Bas, E., Grosan, C., Egrioglu, E., & Yolcu, U. (2018). High order fuzzy time series method based on pi-sigma neural network. *Engineering Applications of Artificial Intelligence*, *72*, 350-356. https://doi.org/10.1016/j.engappai.2018.04.017

Baser, F., & Demirhan, H. (2017). A fuzzy regression with support vector machine approach to the estimation of horizontal global solar radiation. *Energy*, *123*, 229-240. https://doi.org/10.1016/j.energy.2017.02.008

Beyhan, S., & Alci, M. (2010). Stable modeling based control methods using a new RBF network. *ISA Transactions*, *49*(4), 510-518. https://doi.org/10.1016/j.isatra.2010.04.005

Beyhan, S., & Alci, M. (2011). Extended fuzzy function model with stable learning methods for online system identification. *International Journal of Adaptive Control and Signal Processing*, *25*(2). https://doi.org/10.1002/acs.1214

Bezdek, J. C., Ehrlich, R., & Full, W. (1984). FCM: The fuzzy c-means clustering algorithm. *Computers & geosciences*, *10*(2-3), 191-203.

Box, G. E. P., & Jenkins, G. M. (1976). Time Series Analysis: Forecasting and Control. Içinde *Holden-Day series in time series analysis and digital processing* (Rev. ed.). Holden-Day. https://books.google.com.tr/books?id=1WVHAAAAMAAJ

Cagcag Yolcu, O., & Yolcu, U. (2024). A new ensemble intuitionistic fuzzy-deep forecasting model: Consolidation of the IFRFs-bENR with LSTM. *Information Sciences*, *679*. https://doi.org/10.1016/j.ins.2024.121007

Celikyilmaz, A., & Turksen, I. B. (2007). Fuzzy functions with support vector machines. *Information Sciences*, *177*(23), 5163-5177. https://doi.org/10.1016/j.ins.2007.06.022

Celikyilmaz, A., & Turksen, I. B. (2008). Enhanced fuzzy system models with improved fuzzy clustering algorithm. *IEEE Transactions on Fuzzy Systems*, *16*(3), 779-794.

Celikyilmaz, A., Turksen, I. B., & Kacprzyk, J. (2009). Modeling Uncertainty with Fuzzy Logic: With Recent Theory and Applications. Içinde *Studies in Fuzziness and Soft Computing* (C. 240). Springer-Verlag Berlin Heidelberg. https://books.google.com.tr/books?id=Xj1vCQAAQBAJ

Chakravarty, S., Demirhan, H., & Baser, F. (2020). Fuzzy regression functions with a noise cluster and the impact of outliers on mainstream machine learning methods in the regression setting. *Applied Soft Computing*, *96*, 106535. https://doi.org/https://doi.org/10.1016/j.asoc.2020.106535

Chakravarty, S., Demirhan, H., & Baser, F. (2022a). Modified fuzzy regression functions with a noise cluster against outlier contamination. *Expert Systems with Applications*, *205*. https://doi.org/10.1016/j.eswa.2022.117717

Chakravarty, S., Demirhan, H., & Baser, F. (2022b). Robust wind speed estimation with modified fuzzy regression functions with a noise cluster. *Energy Conversion and Management*, *266*. https://doi.org/10.1016/j.enconman.2022.115815

Chen, S. (1996). Forecasting enrollments based on fuzzy time series. *Fuzzy Sets and Systems*, *81*(3), 311-319. https://doi.org/10.1016/0165-0114(95)00220-0

Dalar, A. Z. (2023). Ensemble Based Type-1 Fuzzy Functions Approach for Time Series Forecasting. Içinde S. Küçükkolbaşı (Ed.), *2023 Proceedings of International E-Conference on Mathematical and Statistical Sciences: A Selcuk Meeting* (ss. 78-78). Selçuk University.

Dalar, A. Z., & Egrioglu, E. (2018). Bootstrap Type-1 Fuzzy Functions Approach for Time Series Forecasting. Içinde M. Tez & D. von Rosen (Ed.), *Trends and Perspectives in Linear Statistical Inference* (ss. 69-87). Springer, Cham. https://doi.org/10.1007/978-3-319-73241-1_5

Dalar, A. Z., & Egrioglu, E. (2025). Blending traditional and novel techniques: Hybrid type-1 fuzzy functions for forecasting. *Engineering Applications of Artificial Intelligence*, *148*, 110445. https://doi.org/10.1016/J.ENGAPPAI.2025.110445

Demirhan, H., & Baser, F. (2024). Hierarchical fuzzy regression functions for mixed predictors and an application to real estate price prediction. *Neural computing & applications (Print)*, *36*, 11545-11561. https://doi.org/10.1007/s00521-024-09673-3

Demirkan Piskin, M., & Bas, E. (2022). Forecasting Monthly Housing Sales to Foreigners with Type 1 Fuzzy Regression Functions Approach Based on Ridge Regression. *Karadeniz Fen Bilimleri Dergisi*, *12*(2). https://doi.org/10.31466/kfbd.1074832

Ducange, P., Fazzolari, M., & Marcelloni, F. (2020). An overview of recent distributed algorithms for learning fuzzy models in Big Data classification. *Journal of Big Data*, *7*(1). https://doi.org/10.1186/s40537-020-00298-6

Egrioglu, E., Aladag, C. H., Yolcu, U., & Bas, E. (2014). A new adaptive network based fuzzy inference system for time series forecasting. *Aloy Journal of Soft Computing and Applications*, *2*(1), 25-32.

Egrioglu, E., & Bas, E. (2023). Robust intuitionistic fuzzy regression functions approaches. *Information Sciences*, *638*. https://doi.org/10.1016/j.ins.2023.118992

Egrioglu, E., Fildes, R., & Bas, E. (2022). Recurrent fuzzy time series functions approaches for forecasting. *Granular Computing*, *7*(1). https://doi.org/10.1007/s41066-021-00257-3

Egrioglu, E., Yolcu, U., & Bas, 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). https://doi.org/10.1007/s41066-018-00143-5

Fernández, A., Carmona, C. J., del Jesus, M. J., & Herrera, F. (2016). A View on Fuzzy Systems for Big Data: Progress and Opportunities. *International Journal of Computational Intelligence Systems*, *9*. https://doi.org/10.1080/18756891.2016.1180820

Gawlikowski, J., Tassi, C. R. N., Ali, M., Lee, J., Humt, M., Feng, J., Kruspe, A., Triebel, R., Jung, P., Roscher, R., Shahzad, M., Yang, W., Bamler, R., & Zhu, X. X. (2023). A survey of uncertainty in deep neural networks. *Artificial Intelligence Review*, *56*(S1), 1513-1589. https://doi.org/10.1007/s10462-023-10562-9

Guo, C., Pleiss, G., Sun, Y., & Weinberger, K. Q. (2017). On calibration of modern neural networks. *34th International Conference on Machine Learning, ICML 2017*, *3*.

Hamilton, J. D. (1994). Time Series Analysis Princeton University Press. Içinde *Princeton, NJ*.

Hochreiter, S., & Schmidhuber, J. (1997). Long Short Term Memory. Neural Computation. *Neural Computation*, *9*(8).

Hyndman, R. J., & Athanasopoulos, G. (2021). Forecasting: principles and practice, 3rd edition. *International Journal of Forecasting*, *22*(4).

Imamguluyev, R. (2025). Integrating Fuzzy Logic with Deep Learning: A New Approach to Explainable Artificial Intelligence. *2025 6th International Conference on Mobile Computing and Sustainable Informatics (ICMCSI)*, 1701-1706. https://doi.org/10.1109/ICMCSI64620.2025.10883618

Jang, J. S. R. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man, and Cybernetics*, *23*(3), 665-685. https://doi.org/10.1109/21.256541

Kendall, A., & Gal, Y. (2017). What uncertainties do we need in Bayesian deep learning for computer vision? *Advances in Neural Information Processing Systems*, *2017-December*.

Kocak, C., Egrioglu, E., & Bas, E. (2021). A new deep intuitionistic fuzzy time series forecasting method based on long short-term memory. *Journal of Supercomputing*, *77*(6). https://doi.org/10.1007/s11227-020-03503-8

Krauss, C., Do, X. A., & Huck, N. (2017). Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. *European Journal of Operational Research*, *259*(2), 689-702. https://doi.org/https://doi.org/10.1016/j.ejor.2016.10.031

Latifi, F., Hosseini, R., & Sharifi, A. (2024). Fuzzy deep learning for modeling uncertainty in character recognition using EEG signals. *Applied Soft Computing*, *159*, 111575. https://doi.org/10.1016/j.asoc.2024.111575

LeCun, Y., Hinton, G., & Bengio, Y. (2015). Deep learning (2015), Y. LeCun, Y. Bengio and G. Hinton. *Nature*, *521*.

Li, W., Fujita, H., Zhang, C., & Su, S.-F. (2025). Editorial: Fuzzy Big Data-Driven Computational Intelligence Models and Applications. *International Journal of Fuzzy Systems*, *27*(2), 522-527. https://doi.org/10.1007/s40815-024-01821-0

Li, Y., Chen, C., Hu, X., Qin, J., & Ma, Y. (2021). Fuzzy Rule-Based Models: A Design with Prototype Relocation and Granular Generalization. *Information Sciences*, *562*. https://doi.org/10.1016/j.ins.2020.12.093

Mamdani, E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, *7*(1), 1-13. https://doi.org/http://dx.doi.org/10.1016/S0020-7373(75)80002-2

Mikus, M., Konecny, Ja., Krömer, P., Bancik, K., Konecny, Ji., Choutka, J., & Prauzek, M. (2025). Analysis of the computational costs of an evolutionary fuzzy rule-based internet-of-things energy management approach. *Ad Hoc Networks*, *168*, 103715. https://doi.org/10.1016/j.adhoc.2024.103715

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, *323*(6088), 533-536. http://dx.doi.org/10.1038/323533a0

Sagheer, A., Hamdoun, H., & Youness, H. (2021). Deep LSTM-Based Transfer Learning Approach for Coherent Forecasts in Hierarchical Time Series. *Sensors*, *21*(13). https://doi.org/10.3390/s21134379

Shin, Y., & Ghosh, J. (1991). The pi-sigma network: an efficient higher-order neural network for pattern classification and function approximation. *IJCNN-91-Seattle International Joint Conference on Neural Networks*, 13-18. https://doi.org/10.1109/IJCNN.1991.155142

Song, Q., & Chissom, B. S. (1994). Forecasting enrollments with fuzzy time series — Part II. *Fuzzy Sets and Systems*, *62*(1), 1-8. https://doi.org/10.1016/0165-0114(94)90067-1

Song, X., Deng, L., Wang, H., Zhang, Y., He, Y., & Cao, W. (2024). Deep learning-based time series forecasting. *Artificial Intelligence Review*, *58*(1), 23. https://doi.org/10.1007/s10462-024-10989-8

Tak, N. (2021). Meta fuzzy functions based feed-forward neural networks with a single hidden layer for forecasting. *Journal of Statistical Computation and Simulation*, *91*(13). https://doi.org/10.1080/00949655.2021.1909024

Tak, N., Evren, A. A., Tez, M., & Egrioglu, E. (2018). Recurrent type-1 fuzzy functions approach for time series forecasting. *Applied Intelligence*, *48*(1), 68-77. https://doi.org/10.1007/s10489-017-0962-8

Tak, N., & Inan, D. (2022). Type-1 fuzzy forecasting functions with elastic net regularization. *Expert Systems With Applications*, *199*. https://doi.org/10.1016/j.eswa.2022.116916

Turksen, I. B. (2008). Fuzzy functions with LSE. *Applied Soft Computing*, *8*(3), 1178-1188. https://doi.org/10.1016/j.asoc.2007.12.004

Yıldırım, A., & Bas, E. (2022). Monthly Average Wind Speed Forecasting in Giresun Province with Fuzzy Regression Functions Approach. *Journal of Anatolian Environmental and Animal Sciences*, *7*(1). https://doi.org/10.35229/jaes.1022200

Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, *8*(3), 338-353. https://doi.org/https://doi.org/10.1016/S0019-9958(65)90241-X

Zheng, Y., Xu, Z., Wu, T., & Yi, Z. (2024). A systematic survey of fuzzy deep learning for uncertain medical data. *Artificial Intelligence Review*, *57*(9), 230. https://doi.org/10.1007/s10462-024-10871-7