

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

**YAPAY ZEKÂ YÖNTEMLER İLE GİRESUN İLİ
SICAKLIK ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Adı SOYADI

: İbrahim ÇETİN

Tezin Enstitüye Verildiği Tarih :

Enstitü Anabilim Dalı

: İstatistik

**Tez
Danışmanı**

: Erol EĞRİOĞLU

**Ekim 2021
GİRESUN**

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YAPAY ZEKÂ YÖNTEMLER İLE GİRESUN İLİ
SICAKLIK ÖNGÖRÜSÜ

YÜKSEK LİSANS TEZİ

İbrahim ÇETİN

Enstitü Anabilim Dalı : İstatistik

Bu tez .././20.. tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

Doç. Dr.
Taner TUNÇ
Jüri Başkanı

Doç. Dr.
Eren BAŞ
Üye

Prof. Dr.
Erol EĞRİOĞLU
Üye

Doç. Dr.
Bahadır KOZ
Enstitü Müdürü

BEYAN

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

İbrahim ÇETİN

TEŞEKKÜR

Tez çalışmam da bana destek olan çok kıymetli hocam Prof. Dr. Erol EĞRİOĞLU'na sonsuz teşekkürlerimi sunarım.



İÇİNDEKİLER

TEŞEKKÜR.....	I
İÇİNDEKİLER	II
SİMGELER VE KISALTMALAR LİSTESİ	III
ŞEKİLLER LİSTESİ	IV
TABLOLAR LİSTESİ.....	V
ÖZET.....	VI
SUMMARY	VII
1. GİRİŞ	1
2. MATERYAL VE METOT	HATA! YER İŞARETİ TANIMLANMAMIŞ.
2.1. Holt Üstel Düzleştirme Yöntemi	4
2.2. ARIMA Yöntemi	4
2.3. MLP-ANN Yapay Sinir Ağları	5
2.4. SMN-ANN Yapay Sinir Ağları.....	Hata! Yer işareti tanımlanmamış.
2.5. PS-ANN Yapay Sinir Ağları	Hata! Yer işareti tanımlanmamış.
2.6. DNM-ANN Yapay Sinir Ağları	7
2.7. LSTM Yapay Sinir Ağları.....	8
2.8. Resim Bulanık Zaman Serisi Yöntemi.....	8
2.9. Zaman Serisi Bulanık Çıkarım Sistemi.....	11
2.10. Bulanık Zaman Serisi Ağı.....	12
3. EN DÜŞÜK VE EN YÜKSEK SICAKLIK ZAMAN SERİLERİNİN ÇÖZÜMLENMESİ	14
4. SONUÇ VE TARTIŞMA	22
KAYNAKLAR	24
ÖZGEÇMİŞ	25

SİMGELER VE KISALTMALAR LİSTESİ

ARIMA	: Otoregresif Bütünleşik Hareketli Ortalamalar
ÇNM-ANN	: Çarpımsal Nöron Model Yapay Sinir Ağı
DNM-ANN	: Dentrit Nöron Model Yapay Sinir Ağı
MASE	: Ortalama Mutlak Yüzde Hata
MLP-ANN	: Çok Katmanlı Algılayıcı Yapay Sinir Ağı
PSO	: Parçacık Sürü Optimizasyonu
PS-ANN	: Pi-Sigma Yapay Sinir Ağı
SMAPE	: Simetrik Ortalama Mutlak Yüzde Hata
RMSE	: Hata Kareler Ortalaması Karekökü
ANN	: Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 2.1.	: Çok Katmanlı Algılayıcı Mimarisi.....	5
Şekil 2.2.	: SMN-ANN'nin öngörü problemi için çözüm mimarisi.....	6
Şekil 2.3.	: PS-ANN mimarisi.....	7
Şekil 2.4.	: DNM-ANN mimarisi.....	8
Şekil 2.5.	: LSTM genel mimarisi	9
Şekil 2.6.	: PFTS yönteminde kullanılan PS-ANN'nin mimarisi	10
Şekil 2.7.	: Zaman serisi bulanık çıkarım sisteminin grafiksel gösterimi	11
Şekil 2.8.	: FTS-N mimarisi	12
Şekil 3.1.	: 01.01.2018 ile 19.03.2019 tarihleri arasında günlük Giresun ili en düşük ve en yüksek sıcaklık zaman serileri	14
Şekil 3.2.	: En Düşük Sıcaklık Zaman Serisi İçin Yöntemlerin Hata Ölçütü Değerleri.....	21
Şekil 3.3.	: En Yüksek Sıcaklık Zaman Serisi İçin Yöntemlerin Hata Ölçütü Değerleri.....	21

TABLÖLAR LİSTESİ

Tablo 3.1.	: Çözümlemede kullanılan yöntemler.....	15
Tablo 3.2.	: Çözümlemede kullanılan yöntemlerin hiperparametre tahminleri	15
Tablo 3.3.	: En düşük sıcaklık zaman serisinin test kümesi için elde edilen öngörü sonuçları.....	16
Tablo 3.4.	En yüksek sıcaklık zaman serisinin test kümesi için elde edilen öngörü sonuçları.....	18
Tablo 3.5.	En Düşük Sıcaklık Zaman Serisi Test Kümesi İçin Hata Ölçütü Değerleri.....	20
Tablo 3.6.	En Yüksek Sıcaklık Zaman Serisi Test Kümesi İçin Hata Ölçütü Değerleri.....	20

YAPAY ZEKÂ YÖNTEMLER İLE GİRESUN İLİ SICAKLIK ÖNGÖRÜSÜ

ÖZET

Sıcaklık değerlerinin öngörülmesinde çeşitli gözlem ve ölçüm sonuçlarını kullanan sayısal hava tahmin modelleri kullanılmaktadır. Sıcaklık öngörüsü için zaman serisi öngörü yöntemlerinin kullanılması da mümkündür. Bu tez çalışmasında Giresun ili il merkezi için minimum ve maksimum sıcaklık değerlerinin bir adım öngörülleri çeşitli yapay zeka yöntemler ile elde edilerek Türkiye Meteoroloji Genel Müdürlüğü'nün tahmin sonuçları ile karşılaştırılmıştır. Elde edilen bulgular ışığında bazı yapay zeka öngörü yöntemlerinin tahmin sonuçlarının Türkiye Meteoroloji Genel Müdürlüğü tahmin performansından üstün olduğu gözlemlenmiştir.

Anahtar kelimeler: Öngörü, Sayısal Hava Tahmini, Yapay Zeka Yöntemler, Zaman Serileri

FORECASTING GIRESUN TEMPERATURE WITH ARTIFICIAL INTELLIGENCE METHODS

SUMMARY

Numerical temperature prediction models use various observations and measures are used forecasting temperature. Time series forecasting methods can also be used for temperature forecasting. In this thesis, the forecasting performance of artificial intelligence methods is compared with the Turkish State Meteorological Service forecasting performance for Giresun maximum and minimum temperature. According to thesis findings, it is concluded that the forecasting results of some artificial intelligence methods are superior to Turkish State Meteorological Service forecasts.

Keywords: Forecasting, Numerical temperature forecasting, artificial intelligence methods, time series.

BÖLÜM 1. GİRİŞ

İllere göre sıcaklık tahminleri günlük olarak ulusal basında yayımlanmakta ve tahmin edilmektedir. Sıcaklık tahminleri T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü tarafından gerçekleştirilmekte ve resmi web sayfasından günlük olarak ilan edilmektedir. İllere göre sıcaklık tahmini sayısal hava tahmini çalışmaları kapsamında gerçekleştirilmektedir. Çeşitli matematiksel model sonuçlarının, uzmanlar tarafından incelenen radarlar ve yine illerdeki Meteoroloji Müdürlükleri tarafından gözlem istasyonlarından toplanan verilere dayalı olarak düzeltilmesi ile illere göre sayısal hava tahminleri oluşturulmaktadır. Sayısal hava tahminleri için oluşturulan özel modeller T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü web sayfasında aşağıdaki gibi listelenmiştir.

- Mm5 Modeli
- ALADIN
- WRF Modeli
- ECMWF Deterministik Model
- ECMWF'nin Operasyonel Demet Yöntemi
- Grup Ortalaması ve Farklar
- Meteogramlar, Tüp Yöntemi, EPS Olasılık Haritaları.

T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü tarafından gerçekleştirilen tahminler çeşitli yardımcı değişkenlerin de kullanılması ile gerçekleştirilmektedir. Sayısal tahmin problemi, bir zaman serisi öngörü problem olarakta ele alınarak çözümlenebilir. Sayısal hava tahmini için kullanılacak yardımcı değişkenlerin etkisi zaman serileri analizindeki gecikmeli değişkenler sayesinde zaman serisi modeline dahil edilebilmektedir. Özellikle son yıllarda geliştirilen yapay zeka öngörü yöntemleri sayısal hava tahminleri için kullanılabilecek bir yöntemler yelpazesi sunmaktadır.

Zaman serisi öngörüsü için klasik istatistiksel modellerin yanı sıra yapay sinir ağları, bulanık çıkarım sistemleri ve melez yaklaşımlar literatürde önerilmiştir. Bu tez çalışması kapsamında sıcaklık tahmini için aşağıdaki yöntemler ele alınmıştır.

Klasik İstatistiksel Yöntemler:

- Holt (1957) çalışmasında önerilen Holt üstel düzleştirme yöntemi
- Box ve Jenkins (1976)'da önerilen otoregresif bütünleşik hareketli ortalamalar (ARIMA) yöntemi

Yapay Sinir Ağları:

- Rumelhart ve ark. (1986) tarafından önerilen çok katmalı algılayıcı yapay sinir ağı (MLP-ANN)
- Yadav ve ark. (2007)'de önerilen çarpımsal nöron model yapay sinir ağı (SMN-ANN)
- Shin ve Ghosh (1991)'de önerilen pi-sigma yapay sinir ağı (PS-ANN)
- Todo ve ark. (2014)'de önerilen dendritic nöron model yapay sinir ağları (DNM-ANN)
- Hochreiter ve Schmidhuber (1997) de önerilen uzun kısa dönem hafıza derin yapay sinir ağları (LSTM)

Bulanık Çıkarım Sistemleri:

- Egrioglu ve ark. (2020)'de önerilen resim bulanık zaman serisi yöntemi (PFTS)
- Yolcu ve ark. (2018)'de önerilen zaman serisi bulanık çıkarım sistemi (TSFIS)
- Bas ve ark. (2015)'de önerilen bulanık zaman serisi ağı (FTS-N)

Tez çalışmasının amacı Giresun ili günlük en düşük ve en yüksek sıcaklık değerlerini bir gün önceden tahmin etmede yukarıda verilen zaman serisi tahmin yöntemlerinin performansının araştırılması ve T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü tarafından gerçekleştirilen tahmin sonuçları ile karşılaştırılmasıdır. Tez çalışması kapsamında sıcaklık tahmini için ele alınan veriyi en etkili öngören yöntemin belirlenmesi hedeflenmiştir.

Tez çalışmasının ikinci bölümünde uygulamada kullanılan zaman serisi öngörü yöntemleri özet bir şekilde açıklanmıştır. Üçüncü bölümde Giresun ili en düşük ve en yüksek sıcaklık tahmini için elde edilen sonuçlar ve uygulama ayrıntıları verilmiştir. Son bölümde ise elde edilen bulgular tartışılmış ve tezin sonuçları verilmiştir.



BÖLÜM 2. MATERYAL VE METOT

Bu bölümde tez çalışması kapsamında Giresun ili en düşük ve en yüksek sıcaklık tahmini için kullanılan tüm zaman serisi yöntemleri sırasıyla kısaca açıklanmıştır.

2.1. Holt Üstel Düzleştirme Yöntemi

Holt (1957) çalışmasında önerilen Holt üstel düzleştirme yönteminde zaman serisinin trende sahip olduğu kabul edilerek serisini seviyesi ve artışı için dinamik model denklemleri oluşturulmaktadır. Yöntem “ARIMA(0,2,2)” diye gösterilmekte ve ARIMA modelinin özel bir hali olmaktadır. Yöntemde iki adet düzleştirme parametresi yer almakta olup, bu parametrelerin optimum değerleri optimizasyon algoritmaları ile veriye özgü olarak belirlenmektedir. Holt yöntemi aşağıda verilen güncelleştirme denklemleri ile uygulanmaktadır.

$$\hat{x}_{t+h} = \hat{L}_t + h\hat{b}_t \quad (2.1)$$

$$\hat{L}_t = \lambda_1 x_t + (1 - \lambda_1)\hat{x}_t \quad (2.2)$$

$$\hat{b}_t = \lambda_2(\hat{L}_t - \hat{L}_{t-1}) + (1 - \lambda_2)\hat{b}_{t-1} \quad (2.3)$$

(2.1) serinin seviyesi ve (2.2) serinin trendinin güncellenmesi için kullanılan denklemlerdir. Bu denklemlerde λ_1 ve λ_2 üstel düzleştirme parametreleri olup bu parametrelerin değerleri (0,1) aralığına kısıtlanmaktadır. Yöntem hakkında daha fazla ve ayrıntılı bilgi Eğrioğlu ve Bas (2020) kaynağından elde edilebilir.

2.2. ARIMA Yöntemi

ARIMA modelleri literatürde daha önceleri kullanılan modeller olsa da modellerin ayrıntılı özellikleri ve zaman serisi tahminin de kullanım prosedürü Box ve Jenkins (1976)’da önerilmiştir. Yöntem zaman serisinin ve hatanın gecikmeli değişkenlerine göre oluşturulan bir çoklu regresyon modeli olup (p,q) dereceli ARIMA modeli aşağıdaki gibi yazılmaktadır.


$$x_t = \phi_0 + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.4)$$

Burada ϕ_0 zaman serisinin seviyesini, $\phi_1, \phi_2, \dots, \phi_p$ otoregresif parametreleri $\theta_1, \theta_2, \dots, \theta_q$ hareketli ortalamalar parametrelerini göstermektedir. ε_t ise beyaz gürültü sürecini göstermektedir.

Modeldeki parametrelerin tahmini için çok değişkenli kısıtlı optimizasyon teknikleri kullanılmakta olup, modelleme detayları ve Box ve Jenkins prosedürü ile ilgili detaylı bilgi Eğrioğlu ve Bas (2020) kaynağından elde edilebilir.

2.3. MLP-ANN Yapay Sinir Ağları

Rumelhart ve ark. (1986) tarafından önerilen çok katmanlı algılayıcı yapay sinir ağı doğrusal olmayan zaman serilerinin öngörülmesinde etkili bir araçtır. Çok katmanlı algılayıcı girdi, gizli ve çıktı katmanlarında oluşmaktadır. Zaman serisi öngörü probleminde MLP-ANN'nin girdileri zaman serisinin gecikmeli değişkeni hedef değer ise öngörülmek istenen değer olmaktadır. Zaman serisi öngörü problemi için kullanılabilecek bir MLP-ANN mimarisi Şekil 2.1'de verilmiştir.




Şekil 2.1. Çok Katmanlı Algılayıcı Mimarisi

MLP-ANN'nin öngörü problemine uygulanmasında girdi sayısı, gizli tabaka birim sayısı gibi parametrelerin belirlenmesi gerekmektedir. Daha sonra MLP-ANN'nin bir eğitim algoritması kullanılarak eğitilmesi ve öngörü elde etmeye hazır hale getirilmesi gerekmektedir. Bu tez kapsamında MLP-ANN'nin eğitimi için parçacık sürü optimizasyonu (PSO) kullanılmıştır. MLP-ANN ile ilgili daha detaylı bilgi Egrioglu ve ark. (2019) çalışmasından elde edilebilir.

2.4. SMN-ANN Yapay Sinir Ağları

Yadav ve ark. (2007)'de önerilen çarpımsal nöron model yapay sinir ağı MLP-ANN den farklı olarak sadece tek bir nörondan oluşan mimariye sahiptir. SMN-ANN'nin mimarisi şekil 2.2 de verilmiştir.




Şekil 2.2 ÇNM-YSA'nin öngörü problemi için çözüm mimarisi

SMN-ANN'nin MLP-ANN'den en önemli farkı çarpımsal birleştirme fonksiyonunu kullanmasıdır. Bu birleştirme fonksiyonu sayesinde SMN-ANN en az MLP-ANN kadar etkin öngörü sonuçları sunabilmektedir. SMN-ANN eğitiminde bu çakışmada PSO algoritmasının kullanılması tercih edilmiştir. SMN-ANN ile ilgili daha detaylı bilgi Egrioglu ve ark. (2019) çalışmasından elde edilebilir.

2.5. PS-ANN Yapay Sinir Ağları

Shin and Ghosh (1991)'de önerilen PS-ANN çarpımsal ve toplamsal nöron modelleri bir arada kullanan bir mimariye sahiptir. Yüksek dereceden bir yapay sinir

ağı olan PS-ANN zaman serisi öngörü problemi için literatürde etkili öngörü sonuçları verdiği gözlemlenmektedir. PS-ANN'nin mimarisi Şekil 2.3'de verilmiştir.




Şekil 2.3. PS-ANN mimarisi

PS-ANN, MLP-ANN gibi üç tabaka sahip olup, MLP-ANN'den farklı olarak gizli ve çıktı tabakası arası ağırlıkları ve yan değerleri sabittir. Ayrıca PS-ANN'de çıktı nöronunda çarpımsal birleştirme fonksiyonu kullanılmaktadır. PS-ANN ile ilgili daha detaylı bilgi Egrioglu ve ark. (2019) çalışmasından elde edilebilir.

2.6. DNM-ANN Yapay Sinir Ağları

Todo ve ark. (2014)'de önerilen dendritic nöron model yapay sinir ağları yüksek dereceden sinir ağları olup zaman serisi öngörü probleminde başarılı sonuçlar üretebilmektedir. Diğer yapay sinir ağlarından farklı olarak girdi tabakasında girdilerin doğrusal olmayan dönüşümleri elde edilmekte, bu doğrusal olmayan dönüşümler ağın kalan kısmında işlenmektedir. DNM-ANN'nin mimarisi Şekil 2.4'de verilmiştir.




Şekil 2.4. DNM-ANN mimarisi

DNM-ANN toplamsal ve çarpımsal nöron modelleri bir arada kullanılmaktadır. Gizli tabaka birimleri dendrite'ler olarak isimlendirilmekte olup, ağın çıktısının hesplanma şekli diğer YSA'lardan oldukça farklıdır. Daha detaylı bilgi için Todo ve ark. (2014) çalışması incelenebilir.

2.7. LSTM Yapay Sinir Ağları

LSTM yapay sinir ağları, bir tür geri beslemeli yapay sinir ağları olup, aslında birden fazla MLP-ANN birbirine bağladığı bir yapı sunmaktadır. Derin bir yapay sinir ağı olan LSTM, parametre paylaşımı sayesinde modeldeki gecikme sayısı artırılrsa bile parametre sayısında artış yaşamadığından zaman serisi öngörü problemine oldukça uygun bir yapı sunmaktadır. Öngörü problemi için kullanılabilecek bir LSTM genel mimarisi Şekil 2.5'de verilmiştir.

LSTM yapay sinir ağında en önemli fark bir LSTM hücresinin yapısındaki kapılardır. Bu kapılar sayesinde basit geri beslemeli ağlarda ortaya çıkan patlayan ve sıfırlanan gardiyent problemleri çözüm bulabilmiştir. LSTM'nin eğitiminde modifiye edilmiş Gradyente dayalı yöntemler kullanılmaktadır. Daha detaylı bilgi ve LSTM'nin R ortamında uygulamaları için Eğrioğlu ve Baş (2020) çalışması incelenebilir. Bu tez çalışması kapsamında LSTM'nin uygulamaları MATLAB Neural Network Toolbox kullanılarak gerçekleştirilmiştir.



Şekil 2.5. LSTM genel mimarisi

2.8. Resim Bulanık Zaman Serisi Yöntemi

Egrioglu ve ark. (2020)'de önerilen resim bulanık zaman serisi yöntemi (PFTS) yöntemi aşağıdaki resim bulanık zaman serisi ve yüksek dereceden resim bulanık zaman serisi öngörü modelini kullanarak çözüm yapan bir öngörü yöntemidir.

Tanım 1. (Resim bulanık zaman serisi) X_t , reel gözlemlere sahip zaman serisi olsun. $A_1, A_2, \dots, A_c$ evrensel küme üzerinde tanımlı resim bulanık kümeler olsun. Resim bulanık zaman serisi (PF_t) reel gözlemler, pozitif üyelikler, negative üyelikler ve nötr üyeliklerden oluşan çok değişkenli zaman serisidir. Resim bulanık zaman serisi

$$PF_t = \{X_t, \mu_{A_1}(t), \mu_{A_2}(t), \dots, \mu_{A_c}(t), \eta_{A_1}(t), \eta_{A_2}(t), \dots, \eta_{A_c}(t), \nu_{A_1}(t), \nu_{A_2}(t), \dots, \nu_{A_c}(t)\} \quad (2.5)$$


$\mu_{A_j}(t)$, $\eta_{A_j}(t)$, $\nu_{A_j}(t)$ sırasıyla pozitif, nötr ve negatif üyelik değerlerini göstermektedir.

Tanım 2. (Yüksek dereceli bulanık zaman serisi öngörü modeli) PF_t bulanık zaman serisi, $A_1, A_2, \dots, A_c$ evrensel küme üzerinde tanımlı resim bulanık kümeler olsun. Yüksek dereceden bulanık zaman serisi öngörü modeli aşağıdaki gibidir.

$$X_{t+1} = G \left(X_t, \dots, X_{t-p+1}, \mu_{A_1}(t), \mu_{A_2}(t), \dots, \mu_{A_c}(t), \dots, \mu_{A_1}(t-p+1), \mu_{A_2}(t-p+1), \dots, \mu_{A_c}(t-p+1), \eta_{A_1}(t), \eta_{A_2}(t), \dots, \eta_{A_c}(t), \dots, \eta_{A_1}(t-p+1), \eta_{A_2}(t-p+1), \dots, \eta_{A_c}(t-p+1), v_{A_1}(t), v_{A_2}(t), \dots, v_{A_c}(t), \dots, v_{A_1}(t-p+1), v_{A_2}(t-p+1), \dots, v_{A_c}(t-p+1) \right) + \varepsilon_t = G(PF_t, \dots, PF_{t-p+1}) + \varepsilon_t \quad (2.6)$$

burada G fonksiyonu doğrusal ya da doğrusal olmayan bir fonksiyonu ve ε_t sıfır ortalamalı rastgele hata terimini göstermektedir.

PFTS yönteminde G fonksiyonu pi-sigma yapay sinir ağı ile tahmin edilen doğrusal olmayan bir fonksiyon olmaktadır. PFTS yönteminde kullanılan PS-ANN'nin mimarisi Şekil 2.6 da verilmiştir.




Şekil 2.6. PFTS yönteminde kullanılan PS-ANN'nin mimarisi

Şekil 2.6 da birinci dereceden öngörü modeli çözümü için kullanılan PS-ANN mimarisi verilmiştir. Görüldüğü gibi girdiler üyelik değerleri ve zaman serisinin bir adım gecikmeli değişkenleri olmaktadır.

2.9. Zaman Serisi Bulanık Çıkarım Sistemi

Yolcu ve ark. (2018)'de önerilen zaman serisi bulanık çıkarım sistemi (TSFIS), bulanık c-ortalamlar yöntemi ve PS-ANN yapay sinir ağını kullanmaktadır. Yöntemin grafiksel gösterimi Şekil 2.7 de verilmiştir.




Şekil 2.7. Zaman serisi bulanık çıkarım sisteminin grafiksel gösterimi

Şekil 2.7'de görüldüğü gibi girdiler bulanık kümeler için minimum operatörü ile birleştirilmiş üyelik değerleri ve zaman serisinin gecikmeli değişkenleri olmaktadır. PS-ANN'nin eğitimi ile zaman serisi bulanık çıkarım sisteminin eğitimi gerçekleştirilmiş olmaktadır. PS-ANN'nin eğitimin PSO algoritması kullanılmaktadır.

2.10. Bulanık Zaman Serisi Ağı

Bas et al. (2015)'de önerilen bulanık zaman serisi ağı (FTS-N) yöntemi aynı zamanda melez bir yöntemdir. FTS-N yöntemi Şekil 2.8'de özetlenmiştir.



Şekil 2.8 FTS-N mimarisi


FTS-N yöntemi bulanık zaman serisi çözüm yöntemi ile doğrusal otoregresif modelin bir ağ mimarisinde bir araya getirilmesi ile oluşturulmuştur. Yöntemin uygulanmasında bulanık ortalamalar yöntemi bulanık zaman serisinin bulanıklaştırılması aşamasında kullanılmaktadır. FTS-N'nin optimize edilmesinde ise PSO algoritması kullanılmaktadır. FTS-N'de bulanık zaman serisi ve otoregresif

kisimlardan oluřan mimari yapıda kombinasyon iřlemi yine ağırlıklar ile saėlanmaktadır. FTS-N’de bulanık zaman serisi ve otorogresif kisimların ıktı zerindeki ağırlığı yine PSO yntemi ile otomatik olarak belirlenmektedir.



BÖLÜM 3. GİRESUN İLİ EN DÜŞÜK VE EN YÜKSEK SICAKLIK ZAMAN SERİLERİNİN ÇÖZÜMLENMESİ

Giresun iline ait en düşük ve en yüksek sıcaklık değerleri Giresun Meteoroloji Müdürlüğünde resmi başvuru ile alınmıştır. En düşük ve en yüksek sıcaklık zaman serileri 01.01.2018 ile 19.03.2019 tarihleri arasında günlük olarak ölçülmüşlerdir. Tez çalışmasının amacı bu zaman serilerinin öngörülmesi için kullanılabilecek en iyi zaman serisi öngörü yönteminin belirlenmesidir.



Şekil 3.1. 01.01.2018 ile 19.03.2019 tarihleri arasında günlük Giresun ili en düşük ve en yüksek sıcaklık zaman serileri

Çözümlemede zaman serisinin son 78 gözlemi test kümesi olarak alınmıştır. Test kümesinden önceki 60 gözlem geçerlilik kümesi olarak alınmıştır. Kalan ilk gözlemler ise eğitim verisi olarak kullanılmıştır. Eğitim verisi ile yöntemlerin parametreleri tahmin edilmiş, geçerlilik kümesi üzerinden ise modeldeki hiper parametre ve gecikmeli değişken seçimleri gerçekleştirilmiştir. Test verileri sadece alternatif yöntemlerin performansının karşılaştırılmasında kullanılmıştır. Çözümlemede kullanılan yöntemler Tablo 3.1 de verilmiştir. Tablo 3.1 de T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü tarafından gerçekleştirilen tahminlerde MGM kısaltması altında verilmiştir.

Tablo 3.1. Çözümlemede kullanılan yöntemler

Yöntem Kısa İsmi	Açıklama
MGM	T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü Tahminleri
TSFIS	Zaman Serisi Bulanık Çıkarım Sistemi
ARIMA	Otoregresif Bütünleşik Hareketli Ortalamalar Modeli
Holt	Holt Üstel Düzleştirme Yöntemi
FTS-N	Bulanık Zaman Serisi Ağı
DNM-ANN	Dendritik Nöron Model Yapay Sinir Ağı
MLP-ANN	Çok Katmanlı Algılayıcı Yapay Sinir Ağı
PS-ANN	Pi-Sigma Yapay Sinir Ağı
SMN-ANN	Çarpımsal Nöron Model Yapay Sinir Ağı
PFTS	Resim Bulanık Zaman Serisi Yöntemi
LSTM	Uzun Kısa Dönem Hafıza Derin Yapay Sinir Ağı

En düşük ve en yüksek zaman serileri için çözümlemede kullanılan yöntemlerin geçerlilik kümesi üzerinden gerçekleştirilen hiper parametre seçimleri Tablo 3.2’de verilmiştir. Bu tabloda p gecikmeli değişken sayısını, c bulanık küme sayısını ve m gizli tabaka birim sayısını göstermektedir. LSTM yönteminde tek gizli tabaka kullanılmıştır. MGM’de uygulanan yöntemin ayrıntıları bilinmediğinden ve Holt yönteminde hiper parametre bulunmadığından tabloda ilgili satırlar boş bırakılmıştır.

Tablo 3.2. Çözümlemede kullanılan yöntemlerin hiper parametre tahminleri

Yöntem	En Düşük Sıcaklık	En Yüksek Sıcaklık
MGM	-	-
TSFIS	$c=5, p=2$	$c=5, p=2$
ARIMA	ARIMA(0,1,2)	ARIMA(2,1,1)
Holt	-	-
FTS-N	$c=5, p=6$	$c=6, p=6$
DNM-ANN	$p=3, m=4$	$p=6, m=5$
MLP-ANN	$p=5, m=5$	$p=5, m=5$
PS-ANN	$p=5, m=6$	$p=5, m=6$
SMN-ANN	$p=3$	$p=5$
PFTS	$p=1, c=5$	$p=1, c=6$
LSTM	$p=5, m=4$	$p=5, m=1$

Zaman serilerinin test kümesi olan 01.01.2019 ile 19.03.2019 tarihleri için tüm yöntemlerden elde edilen ve Meteoroloji Genel Müdürlüğünden alınan tahmin sonuçları en düşük sıcaklık zaman serisi için Tablo 3.3’de ve en yüksek sıcaklık zaman serisi için Tablo 3.4’de verilmiştir.

Tablo 3.3. En düşük sıcaklık zaman serisinin test kümesi için elde edilen öngörü sonuçları

No	MGM	TSFIS	ARIMA	Holt	FTS-N	DNM-ANN	MLP-ANN	PS-ANN	SMN-ANN	PFTS	LSTM
1	4	4,4	5,4	5,6	5,8	5,0	5,5	4,8	5,5	4,4	5,7
2	6	5,7	4,6	4,8	4,4	4,6	4,7	4,8	4,7	5,2	5,3
3	9	9,7	5,8	5,6	5,7	5,8	6,0	5,7	5,9	10,6	6,0
4	10	8,4	8,7	9,0	8,4	9,0	9,4	8,7	9,4	8,6	8,3
5	8	10,9	7,6	8,7	7,6	7,6	8,0	7,5	8,0	3,5	6,9
6	2	7,6	4,6	4,8	4,5	4,4	4,2	4,4	4,1	8,9	3,7
7	7	5,6	7,5	6,5	7,4	7,9	7,9	8,1	7,2	5,7	6,8
8	3	7,3	5,0	5,4	5,2	5,3	4,8	5,0	4,4	0,0	5,1
9	4	2,6	3,0	2,4	2,6	2,3	2,0	1,9	2,1	2,5	3,2
10	0	2,7	3,3	2,3	3,8	3,3	2,9	3,6	3,2	2,6	3,9
11	8	5,3	2,9	2,5	3,7	2,9	2,5	2,6	2,7	5,5	4,4
12	9	7,7	7,5	7,3	7,1	7,1	7,8	7,2	7,9	7,9	8,4
13	7	7,1	6,1	7,5	6,7	6,1	6,8	6,3	6,5	7,5	6,6
14	7	5,8	6,9	7,2	6,8	6,5	7,2	5,6	6,9	5,9	6,5
15	10	9,2	5,6	5,9	5,4	6,1	6,1	6,3	6,0	10,2	6,6
16	5	11,3	9,6	9,3	9,1	9,8	10,3	9,0	9,8	6,6	8,8
17	1	1,9	2,2	3,3	2,2	2,3	1,6	2,2	0,3	2,5	2,1
18	-1	3,6	4,2	2,4	3,9	3,7	3,7	3,3	2,5	2,7	2,7
19	3	3,9	3,5	3,2	4,3	4,8	3,7	4,1	3,7	3,8	3,8
20	4	7,4	4,0	3,7	4,2	3,4	3,6	3,3	3,6	8,4	4,6
21	6	7,2	6,2	6,2	6,0	5,9	6,3	6,8	6,5	7,0	6,4
22	9	5,9	6,2	6,9	7,2	6,2	6,7	5,9	6,6	5,9	6,3
23	7	5,5	5,6	6,0	5,3	5,4	5,8	5,1	5,7	5,8	5,5
24	11	9,3	5,5	5,5	5,2	5,7	5,7	5,8	5,7	10,3	6,0
25	13	11,8	8,7	8,7	8,5	9,0	9,4	8,6	9,1	11,7	8,2
26	12	10,5	10,1	11,2	9,9	10,3	11,0	10,1	11,2	10,4	10,1
27	13	9,7	9,2	10,2	9,1	9,0	9,5	8,7	9,6	10,0	8,7
28	8	8,4	9,6	9,7	9,5	9,7	10,0	9,8	9,8	7,5	9,8
29	8	6,4	7,8	7,9	7,8	8,2	7,9	7,8	8,1	5,5	8,4
30	8	7,6	6,5	6,0	6,0	6,4	6,0	5,9	6,4	7,6	6,8
31	12	9,3	8,2	7,5	8,2	8,3	8,0	8,3	8,1	8,7	8,4
32	10	9,1	9,1	9,3	9,7	9,1	9,2	9,3	9,3	9,4	9,3
33	8	7,9	8,7	9,1	8,9	8,3	8,6	8,5	8,8	7,8	8,4
34	8	8,4	8,0	8,1	8,2	7,9	8,0	8,2	8,0	8,4	8,2

Tablo'nun devamı

35	10	7,8	8,5	8,2	8,5	8,6	8,6	8,4	8,6	8,0	8,7
36	8	7,5	7,7	7,8	7,5	7,8	7,6	7,7	7,8	7,7	7,7
37	10	8,4	7,7	7,4	7,5	7,5	7,4	7,5	7,6	8,0	7,2
38	8	8,5	8,2	8,1	8,4	8,2	8,2	8,4	8,3	8,5	7,7
39	9	7,9	8,3	8,4	8,5	8,2	8,3	8,3	8,4	8,2	7,5
40	7	6,9	7,9	8,0	7,9	7,7	7,8	7,8	7,9	7,0	6,9
41	3	6,9	7,3	7,2	7,4	7,3	7,2	7,3	7,3	7,1	6,5
42	6	6,8	7,2	6,9	7,2	7,2	7,0	7,1	7,2	7,0	6,3
43	7	6,8	7,1	7,0	7,1	7,1	7,0	7,1	7,1	7,0	6,1
44	8	8,0	7,0	6,9	7,1	6,9	6,8	7,0	7,0	7,4	5,9
45	7	7,0	8,1	8,1	8,3	8,1	8,2	8,2	8,3	6,8	7,1
46	5	6,1	6,4	6,7	6,6	6,4	6,2	6,4	6,3	6,4	5,6
47	5	5,9	6,5	6,1	6,4	6,3	6,3	6,3	6,3	6,0	5,5
48	4	5,6	6,0	5,8	6,2	6,2	5,9	6,2	6,1	5,8	5,8
49	4	4,4	6,0	5,7	6,0	5,8	5,7	5,7	5,8	4,5	5,7
50	5	5,6	4,6	4,4	4,7	4,4	4,1	4,5	4,4	5,3	5,1
51	2	4,9	6,3	5,8	6,5	6,2	6,2	6,3	6,2	4,1	6,7
52	6	7,4	4,1	4,4	4,4	4,0	3,8	4,1	3,8	8,5	5,5
53	7	6,8	7,0	6,5	6,8	6,7	7,1	6,6	6,8	6,8	7,6
54	7	6,7	6,1	6,8	6,5	6,4	6,5	6,7	6,3	6,9	7,4
55	6	6,1	6,8	6,9	6,7	6,4	6,9	6,1	6,8	6,3	7,3
56	7	5,0	6,1	6,3	5,9	6,3	6,2	6,6	6,3	5,1	7,3
57	5	4,0	5,6	5,4	5,7	5,6	5,5	5,3	5,6	3,7	6,5
58	3	4,6	4,1	3,8	3,9	4,0	3,6	3,9	4,0	4,1	5,1
59	3	3,7	5,3	4,6	5,3	5,2	5,0	5,1	5,1	2,5	6,0
60	-1	3,6	2,9	3,0	3,3	2,9	2,4	2,8	2,6	3,4	4,4
61	6	6,8	4,0	3,3	4,1	3,6	3,6	3,6	3,6	7,4	5,3
62	6	10,5	7,2	7,2	7,5	7,5	7,8	7,7	7,7	2,5	8,1
63	4	4,0	3,8	4,9	4,2	3,7	3,8	3,8	3,3	4,4	5,0
64	4	5,2	4,7	4,1	4,2	4,3	4,5	4,5	4,0	4,5	4,8
65	10	8,8	5,1	5,0	5,4	5,6	5,5	5,8	5,4	9,6	6,3
66	6	8,3	8,5	8,7	8,2	8,5	9,1	8,0	9,1	7,3	7,9
67	4	6,1	6,3	7,5	6,1	6,3	6,6	6,7	6,4	6,0	6,0
68	5	7,5	6,4	6,2	6,5	6,1	6,4	6,1	6,0	7,1	5,7
69	9	11,9	7,7	7,6	7,7	8,2	8,3	8,4	8,1	12,7	7,9
70	10	11,5	10,0	10,4	9,8	10,2	10,7	9,8	10,7	11,3	9,5
71	12	10,8	10,2	11,2	9,9	10,2	10,7	10,2	10,9	11,1	9,7
73	8	7,2	7,7	7,9	7,8	7,9	7,7	7,8	7,9	7,5	8,1
74	7	7,2	8,1	7,3	7,7	8,1	8,0	7,7	8,1	7,3	8,1
75	8	6,9	7,6	7,3	7,6	7,8	7,3	7,6	7,6	7,2	8,1
76	5	6,6	7,1	6,9	7,4	6,8	6,6	6,8	6,9	6,8	8,2
77	4	6,2	6,9	6,6	7,3	6,7	6,5	7,0	6,8	6,5	8,4
78	5	4,8	6,4	6,2	6,9	6,2	6,1	6,3	6,3	4,8	8,1

Tablo 3.4. En yüksek sıcaklık zaman serisinin test kümesi için elde edilen öngörü sonuçları

No	MGM	TSFIS	ARIMA	Holt	FTS-N	DNM-ANN	MLP-ANN	PS-ANN	SMN-ANN	PFTS	LSTM
1	11	9,3	16,9	8,8	8,6	8,4	8,1	8,6	8,4	10,0	10,2
2	12	11,8	18,9	9,2	10,1	10,3	10,3	10,5	10,2	12,8	11,5
3	13	14,2	20,0	10,4	11,3	11,7	11,4	11,7	11,7	14,0	12,9
4	14	22,7	20,2	11,6	11,4	12,4	11,5	11,5	12,4	19,6	12,6
5	10	12,6	26,2	14,9	17,5	19,8	17,6	17,4	19,5	11,8	15,3
6	5	10,7	16,5	12,8	7,4	6,0	7,1	6,5	5,5	12,3	9,5
7	9	7,0	23,8	12,5	15,2	13,5	15,0	15,6	13,3	9,6	11,1
8	7	6,1	18,6	11,1	9,3	7,9	9,6	8,7	8,0	7,3	9,4
9	6	7,5	18,0	9,5	10,2	8,5	9,0	7,8	7,9	8,2	9,4
10	11	12,7	17,9	8,7	8,2	7,8	9,1	9,0	10,1	10,6	10,1
11	15	18,1	20,4	10,0	12,9	11,8	11,9	11,9	11,6	15,5	12,8
12	14	11,5	22,5	12,6	13,6	14,4	13,2	13,4	15,2	14,9	14,2
13	12	9,1	20,2	13,3	11,4	12,2	10,7	8,9	12,4	12,2	11,4
14	12	12,1	20,0	12,3	10,9	12,2	11,3	12,1	11,6	13,2	10,1
15	15	20,4	22,9	12,5	14,0	13,8	14,4	14,0	13,7	16,9	12,0
16	5	19,9	25,6	14,7	17,0	17,3	17,5	17,5	17,3	19,7	13,8
17	5	12,5	24,8	16,4	16,0	16,4	15,8	15,4	16,9	12,2	12,6
18	9	7,5	16,4	12,7	7,3	7,9	7,1	7,9	7,0	9,3	7,4
19	11	10,0	22,8	11,3	14,2	10,5	12,8	11,9	12,1	10,3	10,2
20	12	10,9	19,7	10,7	11,0	8,7	10,8	8,7	8,8	11,1	10,5
21	13	15,0	19,4	10,6	11,1	10,5	10,9	10,4	10,3	13,6	10,9
22	13	9,6	22,4	12,2	13,2	14,2	13,7	15,0	14,8	12,7	12,9
23	15	12,0	19,2	12,2	11,2	10,4	10,1	9,6	10,4	11,4	10,4
24	16	20,2	21,0	12,1	11,9	13,1	12,5	13,0	12,6	16,7	10,7
25	18	17,8	25,5	14,3	16,6	17,7	17,1	17,8	17,5	17,8	13,2
26	17	19,7	23,7	15,6	15,2	14,8	15,0	14,4	15,6	19,5	11,6
27	16	19,0	26,1	16,9	17,0	19,2	17,6	17,5	18,7	19,3	12,1
28	13	11,0	26,6	17,7	17,7	18,9	18,0	18,6	18,8	10,1	12,5
29	15	11,9	20,9	15,1	12,1	12,2	12,0	11,8	11,1	13,3	10,3
30	16	14,6	25,2	14,3	16,1	14,4	15,9	15,2	15,9	14,4	13,6
31	17	16,8	23,7	14,3	15,1	13,6	14,9	14,3	13,8	17,5	15,0
32	13	17,5	25,4	15,6	17,2	17,1	16,9	16,9	17,0	16,6	16,7
33	13	12,4	24,2	16,2	15,0	15,8	15,0	15,8	16,0	14,8	15,7
34	16	12,3	21,7	14,8	13,2	13,5	12,8	13,1	12,8	12,4	13,1
35	17	13,9	23,4	13,9	14,2	13,8	14,4	14,4	14,5	13,9	14,0
36	16	15,2	23,0	13,7	14,3	13,6	14,4	13,7	13,7	15,7	14,6
37	17	17,8	23,8	14,4	15,1	15,2	15,3	15,4	15,2	18,6	15,7
38	13	14,9	25,6	16,0	16,8	17,7	16,7	17,4	17,8	17,1	17,0
39	11	9,7	23,7	16,2	15,1	15,5	14,7	14,6	15,3	10,2	15,1

Tablo'nun devamı

40	10	9,0	19,9	13,6	10,8	11,3	10,8	11,4	11,0	8,0	11,3
41	9	8,4	21,2	11,7	12,3	10,3	11,5	10,4	12,0	8,3	11,6
42	11	10,1	19,5	10,5	10,9	9,1	10,4	8,6	9,7	10,8	11,7
43	16	19,8	20,0	10,5	11,5	10,7	11,3	11,1	11,0	16,3	13,1
44	11	11,4	23,9	13,0	15,3	16,1	14,9	16,0	16,3	14,8	17,0
45	9	9,0	20,0	13,5	11,5	10,7	10,3	9,0	11,2	11,1	14,5
46	8	8,1	18,3	11,6	9,2	10,4	9,5	10,3	9,5	7,1	11,5
47	7	7,7	19,4	10,1	10,3	9,1	10,1	9,5	10,4	8,1	11,1
48	8	9,4	18,3	9,2	9,9	8,4	9,5	7,8	8,3	9,7	11,3
49	11	11,5	18,7	9,3	9,9	9,6	10,1	10,1	10,0	12,0	12,8
50	7	8,8	19,5	10,2	10,9	11,0	10,6	11,4	11,2	10,4	14,5
51	10	11,3	17,7	10,1	9,2	9,4	8,8	9,0	9,2	11,5	13,3
52	12	13,0	19,6	10,4	10,7	11,5	11,1	11,6	11,3	13,9	14,0
53	9	8,5	21,7	11,7	12,9	13,6	13,2	13,6	13,5	11,6	16,4
54	13	16,7	18,1	11,2	9,3	9,4	9,4	9,4	9,1	14,1	13,8
55	9	9,6	24,1	12,8	15,3	16,2	15,9	16,6	15,8	10,9	16,8
56	9	4,8	17,2	11,4	8,3	7,0	8,2	8,6	6,5	7,3	12,4
57	8	8,1	18,3	9,7	9,8	8,8	9,3	9,1	8,6	8,4	10,2
58	7	7,9	19,0	9,1	9,7	8,9	10,0	9,3	10,4	6,9	11,5
59	7	7,0	16,7	8,4	8,7	7,2	8,0	7,3	6,9	6,0	11,0
60	11	15,3	16,3	7,8	7,1	7,3	7,5	8,0	8,0	13,2	10,4
61	11	14,4	22,3	10,4	14,1	14,6	13,8	14,6	14,2	13,8	15,9
62	9	8,8	19,0	11,7	10,3	9,1	9,4	8,5	10,3	11,2	16,0
63	9	9,9	17,2	10,6	8,2	9,9	8,6	8,6	8,7	10,4	11,7
64	15	13,8	20,1	10,2	10,9	10,7	11,3	11,9	11,6	12,6	12,3
65	16	16,2	22,2	11,6	14,0	13,5	14,0	13,4	13,1	17,1	15,1
66	11	11,1	22,9	13,5	14,0	14,6	14,2	14,3	15,1	13,1	16,6
67	13	12,2	18,5	12,5	9,5	10,3	9,4	9,7	9,9	12,8	13,2
68	17	15,2	22,7	12,5	14,2	13,7	14,1	14,9	13,8	15,6	14,1
69	18	18,7	24,1	13,9	15,3	15,3	15,7	15,7	15,3	19,3	15,8
70	19	18,2	25,6	16,0	17,1	17,8	17,2	16,8	18,0	18,4	16,5
71	19	20,7	24,6	16,8	15,3	16,8	15,5	15,5	16,9	21,3	14,3
72	15	21,6	29,0	18,6	20,6	22,0	20,7	20,8	21,4	21,1	15,2
73	11	15,1	28,2	19,7	19,2	20,1	19,6	19,7	20,1	14,7	14,5
74	13	9,4	19,5	15,6	10,4	10,8	10,3	10,3	9,6	11,0	9,7
75	10	8,4	25,2	13,7	16,2	12,2	14,8	13,1	15,4	9,3	12,5
76	10	10,6	20,1	11,9	11,6	8,5	10,7	8,1	8,7	11,8	12,0
77	12	11,6	21,6	11,8	13,4	12,1	12,8	12,1	12,2	12,0	14,0
78	12	11,5	20,0	11,7	10,7	10,4	10,9	12,1	11,1	11,6	14,2

Elde edilen öngörü sonuçlarının performansının değerlendirilmesinde hata kareler ortalaması karekök değeri (RMSE), simetrik mutlak hata yüzdelik ortalaması

(SMAPE) ve tartırlı mutlak hata ortalaması (MASE) hata ölçütleri kullanılmıştır. Bu ölçütlerin formülleri aşağıda verilmiştir. Bu ölçütlerden RMSE bir günlük tahmin için ortalama hatayı gösterirken, SMAPE ise verinin biriminden bağımsız bir günlük tahmin için yüzdelik ortalama hatayı göstermektedir. MASE ölçütü ise rastgele yürüyüş sürecinin performansı ile bir karşılaştırma imkânı sunmaktadır. Birden küçük MASE ölçütü rastgele yürüyüşten daha iyi öngörü performansını işaret etmektedir.

$$RMSE = \sqrt{\frac{1}{n_{test}} \sum_{t=1}^{n_{test}} (x_t - \hat{x}_t)^2} \quad (3.1)$$

$$SMAPE = 200 \times \frac{1}{n_{test}} \sum_{t=1}^{n_{test}} \frac{|x_t - \hat{x}_t|}{|x_t| + |\hat{x}_t|} \quad (3.2)$$

$$MASE = \frac{1}{n_{test}} \sum_{t=1}^{n_{test}} \left| \frac{x_t - \hat{x}_t}{\frac{1}{n-1} \sum_{i=m+1}^n |x_t - x_{t-m}|} \right| \quad (3.3)$$


En düşük ve en yüksek sıcaklık değerleri için hata ölçütü değerleri Tablo 3.5 ve Tablo 3.6'da verilmiştir. Performansların değerlendirilmesi için ayrıca sonuçlar Şekil 3.2 ve 3.3'de de sunulmuştur.

Tablo 3.5. En Düşük Sıcaklık Zaman Serisi Test Kümesi İçin Hata Ölçütü Değerleri


	MGM	DNM-ANN	TSFIS	FTS-N	ARIMA	Holt ES	MLP-ANN	PS-ANN	SMN-ANN	PFTS	LSTM
RMSE	1,89	2,01	1,78	2,00	2,00	2,08	2,07	1,97	2,05	0,88	1,94
SMAPE	7,48	5,82	2,75	5,91	5,81	6,19	5,98	5,67	6,49	2,68	5,88
MASE	1,15	1,14	0,57	1,16	1,13	1,20	1,15	1,10	1,18	0,40	1,17

Tablo 3.6. En Yüksek Sıcaklık Zaman Serisi Test Kümesi İçin Hata Ölçütü Değerleri

	MGM	DNM-ANN	TSFIS	FTS-N	ARIMA	Holt ES	MLP-ANN	PS-ANN	SMN-ANN	PFTS	LSTM
RMSE	2,74	3,86	1,50	3,85	9,49	4,05	3,75	3,79	3,94	1,36	3,87
SMAPE	3,69	5,71	2,06	6,02	13,42	6,47	5,76	5,85	6,00	1,87	6,26
MASE	0,85	1,34	0,45	1,40	4,07	1,53	1,34	1,36	1,41	0,40	1,48



Şekil 3.2. En Düşük Sıcaklık Zaman Serisi İçin Yöntemlerin Hata Ölçütü Değerleri



Şekil 3.3. En Yüksek Sıcaklık Zaman Serisi İçin Yöntemlerin Hata Ölçütü Değerleri

BÖLÜM 4. SONUÇ VE TARTIŞMA

Bu tez çalışmasında Giresun ili en düşük ve en yüksek sıcaklık değerleri çeşitli klasik ve yapay zekâ öngörü yöntemleri ile elde edilerek bu veriler için en iyi öngörü yöntemi belirlenmeye çalışılmıştır. Ayrıca modellerden elde edilen tahmin performansı Meteoroloji Genel Müdürlüğü'nün tahminleri ile de karşılaştırılmıştır. Elde edilen bulgular aşağıda özetlenmiştir.

En iyi performans her iki zaman serisi içinde PFTS yönteminde elde edilmiştir. Bu yöntem MGM tahminlerini en düşük sıcaklık serisinde %53 oranında, en yüksek sıcaklık serisi için ise %50 oranında iyileştirmiştir. Bu yöntem ayrıca serilerin çözümlenmesinde en iyi yapay zeka yöntem olarak da göze çarpmıştır.

En düşük sıcaklık zaman serisinin çözümlenmesinde ARIMA yöntemi, en yüksek sıcaklık zaman serisinin çözümlenmesinde Holt yöntemi en iyi klasik öngörü yöntemleri olmasına rağmen bu yöntemlerin performansı MGM tahminlerinin çok gerisinde kalmıştır. En iyi yapay sinir ağı yöntemi en düşük sıcaklık zaman serisi için RMSE ölçütüne göre LSTM, SMAPE ve MASE ölçütüne göre ise PS-ANN olmuştur. En iyi yapay sinir ağı yöntemi en yüksek sıcaklık zaman serisi için RMSE ölçütüne göre MLP-ANN, MASE ve SMAPE'ye göre DNM-ANN olmuştur. Yöntemlerin performansı rastgele yürüyüş süreci ile MASE ölçütüne göre karşılaştırıldığında en düşük sıcaklık zaman serisi için TSFIS ve PFTS dışındaki tüm yöntemler rastgele yürüyüş sürecinden kötü sonuç vermiştir. MGM tahminleri bile rastgele yürüyüş sürecinden kötü sonuç vermiştir. Bunun anlamı MGM tahminleri yerine bir önceki günün sıcaklığını bugünün sıcaklığı olarak kabul etmekte daha doğru olmaktadır. En yüksek sıcaklık zaman serisi için ise MGM, TSFIS ve PFTS yöntemlerinin performansı rastgele yürüyüş sürecine göre daha iyidir.

Nihai sonuç olarak sadece zaman serisi verisini kullanarak, ek gözlem ve ölçümlere ihtiyaç duymadan TSFIS ve PFTS yöntemleri ile Giresun ili en düşük ve en

yüksek sıcaklık zaman serileri MGM'ye göre daha başarılı bir şekilde öngörülebilir. Gelecek çalışmalarda çok değişkenli resim bulanık zaman serisi yönteminin performansı sıcaklık zaman serilerinin öngörülmesinde kullanılması planlanmaktadır.



KAYNAKLAR

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 (2), 343-355.

Box, G.E.P., Jenkins G.M. (1976), *Time Series Analysis, Forecasting and Control*, Holden Day.

Egrioglu E., Bas E., Yolcu U., Chen MY, (2020). Picture fuzzy time series: Defining, modeling and creating a new forecasting method. *Engineering Applications of Artificial Intelligence* 88, 103367.

Egrioglu E., Baş E., (2020) *Zaman Serileri ve Öngörü Yöntemleri (R Uygulamalı)* , Nobel Yayınevi, Türkiye.

Eğrioglu E., Yolcu U., Baş E. (2019). *Yapay Sinir Ağları (Öngörü ve Tahmin Uygulamaları)*. Nobel Akademik Yayıncılık.

Egrioglu E., Yolcu U., Baş E., (2019) *Yapay Sinir Ağları*, Nobel Yayınevi, Türkiye.
Hochreiter S, Schmidhuber J (1997) Long short-term memory. *Neural Computing*, 9:1735–1780.

Holt, C.E. (1957) Forecasting seasonals and trends by exponentially weighted averages (O.N.R. Memorandum No. 52). Carnegie Institute of Technology Pittsburgh, USA.

Rumelhart DE, McClelland JL (1986) *Parallel distributed processing: explorations in the microstructure of cognition*. Cambridge (Britian): MIT Press.

Shin, Y., Gosh, J., (1991), The Pi-sigma Network: An efficient higher-order neural network for pattern classification and function approximation. In *Proceedings of the International Joint Conference on Neural Networks*.

Todo, Y., Tamura, H., Yamashita, K., Tang, Z., (2014). Unsupervised learnable neuron model with nonlinear interaction on dendrites. *Neural Network*. 60, 96–103.

Yadav RN, Kalra PK, John J. (2007). Time series prediction with single multiplicative neuron model. *Applied Soft Computing*. 7, 1157-1163.

Yolcu U., Bas E., Egrioglu E., (2018). A new fuzzy inference system for time series forecasting and obtaining the probabilistic forecasts via subsampling block bootstrap. *Journal of Intelligent & Fuzzy Systems* 35 (2), 2349-2358.



ÖZGEÇMİŞ

Ortaöğrenimini Kâhta Lisesi'nde tamamladı. 2011 yılında Adıyaman Üniversitesi Gölbaşı Meslek Yüksekokulu İşletme Yönetimi Bölümünden, 2016 yılında Anadolu Üniversitesi İşletme Fakültesi İşletme Bölümünden mezun oldu.

