

**ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

YÜKSEK LİSANS TEZİ

**SİVAS İLİNE AİT METEOROLOJİK PARAMETRELERİN ARIMA ve LSTM
YÖNTEMLERİ KULLANILARAK MODELLENMESİ ve TAHMİNİ**

Aydın Ozan ÇETİNTAŞ

TARIMSAL YAPILAR VE SULAMA ANABİLİM DALI

**ANKARA
2022**

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

SİVAS İLİNE AİT METEOROLOJİK PARAMETRELERİN ARIMA ve LSTM YÖNTEMLERİ KULLANILARAK MODELLENMESİ ve TAHMİNİ

Aydın Ozan ÇETİNTAŞ

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Tarımsal Yapılar ve Sulama Anabilim Dalı

Danışman: Prof. Dr. Halit APAYDIN

Meteorolojik parametrelerin modellenmesi, tarımsal açıdan su ihtiyacı ve kurak dönemlerin belirlenmesi konusuna ışık tutmaktadır. Yağış ve dolayısıyla kuraklık tahmini yapılabilmesinin, su kaynaklarının daha iyi yönetimi, böylece verim artışı ve ürün kayıplarını önlemek gibi çeşitli faydaları bulunmaktadır. Tarımsal üretimle geçimini sürdüren kırsal nüfusun bu faydalardan yararlanmaları büyük önem taşımaktadır. Geçmişten günümüze birçok istatistik model ve makine öğrenmesi metodu ile meteorolojik parametrelerin tahmini yapılmıştır. Bu çalışmada, Sivas ilinin ilçelerinde ölçülmüş olan meteorolojik veriler kullanılarak ARIMA ve LSTM modellerinin tahmin başarısının ölçülmesi hedeflenmiştir. ARIMA modeli uzun yıllardır kullanılmakta olan yaygın bir model olmasına karşın LSTM modeli son yıllarda geliştirilen derin öğrenme metodlarından biridir. ARIMA modeli daha sınırlı çalışma alanına ve geliştirme alanına sahiptir. LSTM modeli ise nöron kontrolü, veri genişliği kontrolü, optimizatörler ve düzenleme katmanları ile çeşitliliğe sahip bir çalışma alanıdır. LSTM modelinde ağ yapısı ve bileşenleri, değişkenlerin çeşitliliği ve kontrol edilebilirliği ile ARIMA modeline göre üstünlük sağlamakta, daha başarılı sonuçlar elde edilmektedir.

Çalışmada ARIMA modellerinde tek bir parametre kullanılırken, LSTM modellerinde parametreler hem tek hem de bir arada kullanılmıştır. Her iki yöntemde de Sivas ilinin büyük klima özelliğine sahip olan Zara, Suşehri, Ulaş, Kangal, Gemerek, Divriği istasyonlarına ait meteorolojik veriler kullanılmıştır. ARIMA modellerinde R^2 , 0.06-0.94 arasında değişirken, LSTM modellerinde 0.63-0.96 arasında R^2 başarısı elde edilmiştir. Elde edilen sonuçlara göre bölgede meteorolojik parametrelerin tahmin edilmesinde her katmanda ReLu aktivasyonunun kullanıldığı, 8-16-32 aralığında nörona sahip LSTM katmanı, 100-300 aralığında epoch değeri, $5e^{-4}$ ve $146e^{-5}$ learning rate, $1e^{-2} - 1e^{-6}$ aralığında decay, Adam optimizasyonu, 8-256 aralığında batch size konfigürasyonuna sahip LSTM yönteminin en uygun alternatif olduğu belirlenmiştir.

Ocak 2022, 79 sayfa

Anahtar Kelimeler: ARIMA, Derin öğrenme, LSTM, Meteorolojik parametreler, Tahmin

ABSTRACT

Ms. Thesis

MODELING AND PREDICTION OF METEOROLOGICAL PARAMETERS IN SİVAS PROVINCE USING ARIMA AND LSTM METHODS

Aydın Ozan ÇETİNTAŞ

Ankara University
Graduate School of Natural and Applied Sciences
Department of Agricultural Structures and Irrigation

Supervisor: Prof. Dr. Halit APAYDIN

Modeling of meteorological parameters sheds light on the determination of agricultural water needs and dry periods. Predicting precipitation and therefore drought has various benefits such as increased yield and prevention of harvest losses. It is of great importance for the rural population, who makes a living with agricultural production, to benefit from these advantages. From past to present, meteorological parameters have been estimated with many statistical models and machine learning methods. In this study, it is aimed to determine the prediction success of ARIMA and LSTM models by using meteorological data measured in the districts of Sivas province. Although the ARIMA model is a common model that has been used for many years, the LSTM model is one of the deep learning methods developed in recent years. The ARIMA model has more limited workspace and development space. The LSTM model, on the other hand, is a diverse field of study with neuron control, data volume control, optimizers and editing layers. In the LSTM model, the network structure and components are superior to the ARIMA model with the diversity and controllability of the variables, and more successful results are obtained.

While a single parameter is used in ARIMA models in the study, parameters are used both singly and together in LSTM models. In both methods, meteorological data of Zara, Suşehri, Ulaş, Kangal, Gemerek and Divriği stations, which have great climate characteristics of Sivas province, were used. While R^2 ranged between 0.06-0.94 in ARIMA models, R^2 success was between 0.63-0.96 in LSTM models. According to the results obtained, LSTM layer with 8-16-32 neurons, epoch value in the range of 100-300, learning rate of $5e^{-4}$ and $146e^{-5}$, between $1e^{-2}$ – $1e^{-6}$ decay, Adam optimization, in which ReLu activation is used in each layer, in the estimation of meteorological parameters in the region. It has been determined that the LSTM method with batch size configuration in the range of 8-256 is the most suitable alternative.

February 2022, 79 pages

Key Words: ARIMA, Deep learning, LSTM, Meteorological parameters, Prediction, Forecasting

ÖNSÖZ ve TEŞEKKÜR

Lisans öğrenimimde ve yüksek lisans öğrenimime başladığım günden beri aydınlatıcı bilgilerle çalışmalarına ışık tutan, araştırmalarımın her aşamasında bilgi, öneri ve desteklerini esirgemeyen, öğrenim ve araştırma konusunda kendimi geliştirmemde önemli bir yeri olan danışman hocam sayın Prof. Dr. Halit APAYDIN'a ve çalışmalarım süresince birçok fedakarlıklar göstererek beni destekleyen eşime ve aileme en derin duygularla teşekkür ederim. Verilerin düzenlenmesinde yardımlarını esirgemeyen Fatma Akçakoca'ya ve çalışmada kullanılan verilerin günümüze kadar oluşturulmasında emeği geçen ve çalışmada kullanılmasını sağlayan Meteoroloji Genel Müdürlüğü çalışanlarına teşekkürlerimi sunarım.

Aydın Ozan ÇETİNTAŞ

Ankara, Ocak 2022

İÇİNDEKİLER

ÖZET.....	ii
ABSTRACT	iii
ÖNSÖZ ve TEŞEKKÜR.....	iv
KISALTMALAR DİZİNİ.....	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ	3
3.MATERYAL VE YÖNTEM	7
3.1 Materyal	7
3.1.1 Sivas iline ait meteorolojik veriler	9
3.2 Yöntem	10
3.2.1 ARIMA modeli	10
3.2.1.1 Otoregresyon (AR)	13
3.2.1.2 Hareketli ortalama (MA)	14
3.2.1.3 Otoregresif hareketli ortalama (ARMA).....	15
3.2.2 Mevsimsel bütünleşik otoregresif hareketli ortalama modeli (SARIMA).....	15
3.2.3 Uzun-kısa süreli bellek (LSTM) modeli	16
3.2.3.1 Tanım ve temel kavramlar	16
3.2.3.2 ReLU fonksiyonu.....	23
3.2.3.3 Adam optimizasyonu.....	25
3.2.3.4 Kayıp fonksiyonu olarak ortalama kare hatası.....	26
3.3 Değerlendirme Metrikleri.....	27
3.3.1 Ortalama kare hatası	27
3.3.2 Kök ortalama kare hatası	27
3.3.3 Ortalama mutlak hata.....	28
3.3.4 Belirtme katsayısı	28
3.4 ARIMA ve LSTM Yöntemlerinin Karşılaştırılması	28
4. ARAŞTIRMA BULGULARI	31

4.1 Kangal İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini.....	31
4.2 Zara İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini	38
4.3 Divriği ilçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini	45
4.4 Ulaş İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini	52
4.5 Gemerek İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini	59
4.6 Suşehri İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini	66
5. TARTIŞMA VE SONUÇ	73
KAYNAKLAR.....	76



KISALTMALAR DİZİNİ

ACF	Otokorelasyon fonksiyonu (Autocorrelation Function)
ANN	Yapay Sinir Ağları (Artificial Neural Network)
AR	Otoregresyon (Autoregression)
ARIMA	Otoregresif Hareketli Ortalamalar (Autoregressive Integrated Moving Average)
ARMA	Otoregresif Hareketli Ortalama (Autoregressive Moving Average)
LSTM	Uzun Kısa Süreli Bellek (Long- Short Term Memory)
MA	Hareketli Ortalama (Moving Average)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MAPE	Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error)
MSE	Ortalama Kare Hata (Mean Squared Error)
PACF	Kısmi Otokorelasyon fonksiyonu (Autocorrelation Function)
R^2	Belirtme Katsayısı (R-Squared)
ReLU	Doğrultulmuş lineer birim (Rectified Linear Unit)
RMSE	Kök Ortalama Kare Hatası (Root Mean Squared Error)
RMSprop	Kök Ortalama Kare Yayılımı (Root Mean Squared Propagation)
SARIMA	Mevsimsel Otoregresif Entegre Hareketli Ortalama (Seasonal Autoregressive Integrated Moving Average)
SGD	Stokastik Gradyan Azalma (Stochastic Gradient Descent)
YSA	Yapay Sinir Ağları (Artificial Neural Network)

ŞEKİLLER DİZİNİ

Şekil 3.1 Sivas ili ve ilçeleri	7
Şekil 3.2 İlk LSTM mimarisi	18
Şekil 3.3 LSTM kapılarının ifade edildiği LSTM modülü	20
Şekil 3.4 LSTM ağlarında hücre hali	21
Şekil 3.5 LSTM ağlarında sigmoid fonksiyonu	21
Şekil 3.6 Tekrarlayan standart bir tek katmanlı yapay sinir ağı modülü	21
Şekil 3.7 LSTM katmanları	22
Şekil 3.8 ReLU Grafiği	24
Şekil 3.9 MSE Kayıp Fonksiyonu	26
Şekil 4.1 LSTM metodunda Kangal ilçesi yağış verilerine ait loss ve dağılım grafiği ..	32
Şekil 4.2 LSTM metodunda Kangal ilçesi yağış verilerine ait tahmin grafiği	32
Şekil 4.3 LSTM metodunda Kangal ilçesi nem verilerine ait loss ve dağılım grafiği	33
Şekil 4.4 LSTM metodunda Kangal ilçesi nem verilerine ait tahmin grafiği	33
Şekil 4.5 LSTM metodunda Kangal ilçesi sıcaklık verilerine ait loss ve dağılım grafiği	34
Şekil 4.6 LSTM metodunda Kangal ilçesi sıcaklık verilerine ait tahmin grafiği	34
Şekil 4.7 ARIMA metodunda Kangal ilçesi yağış verilerine ait tahmin grafiği	35
Şekil 4.8 ARIMA metodunda Kangal ilçesi nem verilerine ait tahmin grafiği	36
Şekil 4.9 ARIMA metodunda Kangal ilçesi sıcaklık verilerine ait tahmin grafiği	36
Şekil 4.10 LSTM metodunda Zara ilçesi yağış verilerine ait loss ve dağılım grafiği	39
Şekil 4.11 LSTM metodunda Zara ilçesi yağış verilerine ait tahmin grafiği	39
Şekil 4.12 LSTM metodunda Zara ilçesi nem verilerine ait loss ve dağılım grafiği	40
Şekil 4.13 LSTM metodunda Zara ilçesi nem verilerine ait tahmin grafiği	40
Şekil 4.14 LSTM metodunda Zara ilçesi sıcaklık verilerine ait loss ve dağılım grafiği ..	41
Şekil 4.15 LSTM metodunda Zara ilçesi sıcaklık verilerine ait tahmin grafiği	41
Şekil 4.16 ARIMA metodunda Zara ilçesi yağış verilerine ait tahmin grafiği	42
Şekil 4.17 ARIMA metodunda Zara ilçesi nem verilerine ait tahmin grafiği	43
Şekil 4.18 ARIMA metodunda Zara ilçesi sıcaklık verilerine ait tahmin grafiği	43
Şekil 4.19 LSTM metodunda Divriği ilçesi yağış verilerine ait loss ve dağılım grafiği ..	46
Şekil 4.20 LSTM metodunda Divriği ilçesi yağış verilerine ait tahmin grafiği	46
Şekil 4.21 LSTM metodunda Divriği ilçesi nem verilerine ait loss ve dağılım grafiği ..	47
Şekil 4.22 LSTM metodunda Divriği ilçesi nem verilerine ait tahmin grafiği	47

Şekil 4.23 LSTM metodunda Divriği ilçesi sıcaklık verilerine ait loss ve dağılım grafiği	48
Şekil 4.24 LSTM metodunda Divriği ilçesi sıcaklık verilerine ait tahmin grafiği	48
Şekil 4.25 ARIMA metodunda Divriği ilçesi yağış verilerine ait tahmin grafiği	49
Şekil 4.26 ARIMA metodunda Divriği ilçesi nem verilerine ait tahmin grafiği	50
Şekil 4.27 ARIMA metodunda Divriği ilçesi sıcaklık verilerine ait tahmin grafiği	50
Şekil 4.28 LSTM metodunda Ulaş ilçesi yağış verilerine ait loss ve dağılım grafiği	53
Şekil 4.29 LSTM metodunda Ulaş ilçesi yağış verilerine ait tahmin grafiği	53
Şekil 4.30 LSTM metodunda Ulaş ilçesi nem verilerine ait loss ve dağılım grafiği	54
Şekil 4.31 LSTM metodunda Ulaş ilçesi nem verilerine ait tahmin grafiği	54
Şekil 4.32 LSTM metodunda Ulaş ilçesi sıcaklık verilerine ait loss ve dağılım grafiği ..	55
Şekil 4.33 LSTM metodunda Ulaş ilçesi sıcaklık verilerine ait tahmin grafiği	55
Şekil 4.34 ARIMA metodunda Ulaş ilçesi yağış verilerine ait tahmin grafiği	56
Şekil 4.35 ARIMA metodunda Ulaş ilçesi nem verilerine ait tahmin grafiği	57
Şekil 4.36 ARIMA metodunda Ulaş ilçesi sıcaklık verilerine ait tahmin grafiği	57
Şekil 4.37 LSTM metodunda Gemerek ilçesi yağış verilerine ait loss ve dağılım grafiği	60
Şekil 4.38 LSTM metodunda Gemerek ilçesi yağış verilerine ait tahmin grafiği	60
Şekil 4.39 LSTM metodunda Gemerek ilçesi nem verilerine ait loss ve dağılım grafiği	61
Şekil 4.40 LSTM metodunda Gemerek ilçesi nem verilerine ait tahmin grafiği	61
Şekil 4.41 LSTM metodunda Gemerek ilçesi sıcaklık verilerine ait loss ve dağılım grafiği	62
Şekil 4.42 LSTM metodunda Gemerek ilçesi sıcaklık verilerine ait tahmin grafiği	62
Şekil 4.43 ARIMA metodunda Gemerek ilçesi yağış verilerine ait tahmin grafiği	63
Şekil 4.44 ARIMA metodunda Gemerek ilçesi nem verilerine ait tahmin grafiği	64
Şekil 4.45 ARIMA metodunda Gemerek ilçesi sıcaklık verilerine ait tahmin grafiği ...	64
Şekil 4.46 LSTM metodunda Suşehri ilçesi yağış verilerine ait loss ve dağılım grafiği ..	67
Şekil 4.47 LSTM metodunda Suşehri ilçesi yağış verilerine ait tahmin grafiği	67
Şekil 4.48 LSTM metodunda Suşehri ilçesi nem verilerine ait loss ve dağılım grafiği ..	68
Şekil 4.49 LSTM metodunda Suşehri ilçesi nem verilerine ait tahmin grafiği	68
Şekil 4.50 LSTM metodunda Suşehri ilçesi sıcaklık verilerine ait loss ve dağılım grafiği	69
Şekil 4.51 LSTM metodunda Suşehri ilçesi sıcaklık verilerine ait tahmin grafiği	69
Şekil 4.52 ARIMA metodunda Suşehri ilçesi yağış verilerine ait tahmin grafiği	70

Şekil 4.53 ARIMA metodunda Suşehri ilçesi nem verilerine ait tahmin grafiği	71
Şekil 4.54 ARIMA metodunda Suşehri ilçesi sıcaklık verilerine ait tahmin grafiği	71



ÇİZELGELER DİZİNİ

Çizelge 3.1 Büyük klima özelliğine sahip ilçelere ait istasyonlar ve coğrafi bilgileri	9
Çizelge 3.2 İstasyonlara ait 10 yıllık ortalama yağış, nem ve sıcaklık değerleri	9
Çizelge 3.3 Yöntemlerin yapısal karşılaştırılması	29
Çizelge 3.4 LSTM çalışmasında kullanılan alternatif parametreler	30
Çizelge 4.1 Kangal ilçesinde kullanılan LSTM modellerinin özellikleri	31
Çizelge 4.2 Kangal ilçesinde kullanılan ARIMA modellerinin özellikleri	35
Çizelge 4.3 Kangal ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	37
Çizelge 4.4 Zara ilçesinde kullanılan LSTM modellerinin özellikleri	38
Çizelge 4.5 Zara ilçesinde kullanılan ARIMA modellerinin özellikleri	42
Çizelge 4.6 Zara ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	Error!
Bookmark not defined.	
Çizelge 4.7 Divriği ilçesinde kullanılan LSTM modellerinin özellikleri	45
Çizelge 4.8 Divriği ilçesinde kullanılan ARIMA modellerinin özellikleri	49
Çizelge 4.9 Divriği ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	51
Çizelge 4.10 Ulaş ilçesinde kullanılan LSTM modellerinin özellikleri	52
Çizelge 4.11 Ulaş ilçesinde kullanılan ARIMA modellerinin özellikleri	56
Çizelge 4.12 Ulaş ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	58
Çizelge 4.13 Gemerek ilçesinde kullanılan LSTM modellerinin özellikleri	59
Çizelge 4.14 Gemerek ilçesinde kullanılan ARIMA modellerinin özellikleri	63
Çizelge 4.15 Gemerek ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	65
Çizelge 4.16 Suşehri ilçesinde kullanılan LSTM modellerinin özellikleri	66
Çizelge 4.17 Suşehri ilçesinde kullanılan ARIMA modellerinin özellikleri	70
Çizelge 4.18 Suşehri ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması	72
Çizelge 5.1 ARIMA ve LSTM modellerinde ilgili parametrelere ait R^2 sonuç aralıkları	74



1. GİRİŞ

Yağış ve sıcaklık gibi meteorolojik faktörler tarımsal ürün ve üretimin verimliliği, kalitesi ve sulama tercihleri üzerinde oldukça büyük etkiye sahiptir. Bu etki kuraklık, drenaj problemleri, besin maddesi eksikliği, taban suyu ve tuzluluk sorunları gibi çeşitli üretim sorunlarına yol açmaktadır. Günümüzde sıklıkla tartışılan küresel ısınma, gözlemlenebilir şekilde aşırı kurak veya aşırı yağışlı dönemlerin ortaya çıkmasına sebep olmaktadır. Meteorolojik verilerin önceden tahminiyle, üretici bu gibi sorunları henüz ortaya çıkmadan önleyebilme şansı elde edebilmektedir. Üretim desenini planlayabilmek, ekim-dikim zamanını doğru şekilde tespit etmek, doğru zaman ve metot ile sulama planlaması yapmak, üretim sezonu sonunda üreticinin hedeflediği kalite ve verimde ürünü elde etmesini sağlamak meteorolojik faktörlerle doğrudan ilgilidir. Tarımsal üretim ile ilgilenen bilim insanları ve üretici sektör; uzun yıllardır, meteorolojik unsurlar hakkında farklı tahmin metotları yardımıyla bilgi almakta ve planlamayı bu veriler üzerinden yapmaktadır.

Her geçen gün gelişmekte olan bilgisayar kapasiteleri ve yazılımları ile meteorolojik parametreleri tahmin etmek amacıyla bugüne kadar çok çeşitli metotlar denenmiştir. Uzun süredir kullanılmakta olan istatistik modellerden Otoregresif Entegre Hareketli Ortalama (Autoregressive Integrated Moving Average-ARIMA) ve mevsimsellik koşulu sağlayan verilerde başarılı sonuçlar veren SARIMA günümüzde halen tahmin için kullanılan geleneksel yöntemlerdir. Yapay sinir ağları ise düşüncesi ve temel yapısı daha önceki senelere dayanan, ancak özellikle son yıllarda bilgisayarların donanımsal olarak güçlenmesi ile yaygınlaşan bir metottur. Makine öğrenmesi tabanlı, derin öğrenme içerisinde yer alan Uzun-Kısa Süreli Bellek (Long- Short Term Memory-LSTM), çoklu katman yapısının kullanılabilir olması, öğrenmenin derinleştirilebilmesi ve değişken çeşitliliğinin kontrol edilebilirliğinin yüksek olması ile bu alanda sıklıkla kullanılmaktadır (Hochreiter ve Schmidhuber 1997, Gers vd. 2000).

ARIMA geçmişte gözlenen verilerin zaman serisine bağlı analizini gerçekleştirerek kısa vadeli gelecek tahminleri yapabilen bir modeldir. Bu modelde başarı, eğitim setinin verilerine ve model kurulurken seçilen parametrelere doğrudan bağlıdır. Geleneksel yapay zeka metotları, sadece ham (doğal) verilerle çalışabilmektedir. LSTM gibi derin öğrenme metotları ise temel veri kalıplarını belirlemek için birden çok katmandan oluşan hesaplama algoritmalarına sahiptirler. Uzun süreli bağımlılıkları ele almak için tasarlanmış olan LSTM ise fiyat, sıcaklık, güneş ışıınımı, yağış gibi farklı zaman serisi verilerini tahmin etmekte kullanılabilmektedir. LSTM modellerinin kısa ve uzun vadeli tahminlerde derin ileri beslemeli sinir ağlarından ve birçok makine öğrenimi algoritmasından daha başarılı sonuçlar verdiği gözlemlenmiştir (De Gooijer ve Hyndman 2006).

Sivas ili, 28 488 km² yüzölçümü ile Türkiye'nin en büyük ikinci ilidir. Sivas ilinde tarımsal üretim en büyük ekonomik faaliyetlerden biridir. İlin çalışan nüfusunun % 66.5'ini oluşturan tarım sektöründe çalışanların % 54.72'sini kadınlar, % 45.3'ünü erkekler oluşturmaktadır. Tarıma elverişli arazi 1 106 085 hektar olup tüm yüzölçümünün % 41'lik kısmına karşılık gelmektedir. Ayrıca 741 803 ha mera arazisi bulunmaktadır. 986 518 ha alanın 1-4. sınıf araziler olduğu ilde, 5-8. sınıf arazide yaklaşık 200 000 ha alanda işlemeli tarım yaptığı görülmektedir. Ancak bu arazilerin eğiminin % 12'nin üzerinde olması ve su erozyonunun il topraklarında önemli bir sorun olması tarım potansiyelini kötü yönde etkilemektedir (Anonim 2018).

Bu çalışmada, Meteoroloji Genel Müdürlüğü tarafından Sivas ilinin ilçelerinde ölçülmüş olan yağış, sıcaklık ve nem verileri ARIMA ve LSTM metotları kullanılarak modellenmiş ve geliştirilen modellerin tahmin başarısının ölçülmesi hedeflenmiştir.

2. KURAMSAL TEMELLER ve KAYNAK ÖZETLERİ

LSTM metodu özellikle son yıllarda çeşitli alanlarda tahmin amacıyla kullanılan başarılı bir metottur. ARIMA ve SARIMA metotları da uzun yıllardır tahmin amacıyla kullanılmakta ve başarılı sonuçlar vermektedir. Bu metotlar meteorolojik veriler gibi zaman serilerinde sıklıkla kullanılmaktadır.

Tektaş (2010), Uyarlamalı ağ tabanlı bulanık çıkarım sistemi (Adaptive Network Based Fuzzy Inference System -ANFIS) ve ARIMA modellerinde 8 yıla ait günlük sıcaklık, hava basıncı ve rüzgar hızı verileri ile çalışmıştır. ANFIS modelinde 0.9802, ARIMA modelinde ise 0.91 belirtme katsayısı sonuçlarına ulaşmıştır.

Bari vd. (2015), Bangladeş'in Sylhet şehri istasyonunda 1980-2010 yılları arasında ölçülen uzun dönem yağış verileri ile ARIMA modeli üzerinden yağış modellemesi yapmışlardır. ARIMA modelinde güven sınırını %95 olarak bulmuşlardır.

Akbari Asanjan vd. (2018), kısa süreli kantitatif yağış tahminini 0-6 saat süreli veriler kullanarak LSTM ve Yapay Sinir Ağları Kullanarak Uzaktan Algılanan Bilgiden Yağış Tahmini (PERSIANN) ile birleştirilmiş LSTM modelleri kullanarak tahminleri karşılaştırılmıştır. Amerika'nın Oklahoma, Florida ve Oregon eyaletlerine ait yağış verilerinin kullanıldığı çalışmada LSTM ve LSTM-PERSIANN modellerinde korelasyon katsayısı olarak Oregon eyaletinde 0.51, Oklahoma eyaletinde 0.45, Florida eyaletinde 0.48 sonuçlarına ulaşmışlardır.

Duong vd. (2018), Vietnam'ın Camau eyaletine ait aylık yağış verisini kullanarak LSTM, Yapay Sinir Ağları (YSA-ANN), Mevsimsel Yapay Sinir Ağları (SANN) metotlarının başarılarını karşılaştırdıkları çalışmada, LSTM metodunun $0.989 R^2$ değeriyle ANN ve SANN metotlarına göre daha üstün istatistiksel performans gösterdiği sonucuna ulaşmışlardır.

Pasaribu vd. (2018), Endonezya'nın Merauke şehrine ait 12 yıllık meteorolojik veriyi kullanarak ARIMA modeliyle yağış tahmini yapmışlardır. ARIMA (2,0,2) modelin tahminde kullanılacak doğru model olarak belirledikleri çalışmada ortalama, minimum ve maksimum yağış tahminlerinde sapmaları incelemişlerdir.

Salman vd. (2018), tek katmanlı ve çok katmanlı LSTM modelleri ile hava basıncı, nem, çiğlenme noktası sıcaklığı verileri ile tahmin çalışması yapmışlardır. Çalışma sonucunda en iyi sonuç olarak değişkenin basınç olarak kullanıldığı modelde 100 epoch denemesinde 0.0885 RMSE sonucuna ulaşmışlardır.

Kaneko vd. (2019), her yıl şiddetli yağış olaylarının meydana geldiği Japonya'da sel baskınları gibi çeşitli küresel ısınma sorunlarına karşı yağış tahmininde bulunmak amacıyla iki katmanlı LSTM ve yığın normalleştirme katmanlarına sahip model kullanmışlardır. Meso Scale Model (MSM) yöntemi ile LSTM yöntemini karşılaştırdıkları çalışmada her iki modelde de başarılı sonuçlar bulmuşlar ancak LSTM modelinin MSM modelinden daha başarılı olduğu sonucuna ulaşmışlardır.

Li vd. (2019), yağış tahmininin önemli bir göstergesi olan bağıl nemin Çin'in Kansu (Gansu) bölgesine ait meteorolojik verileri kullanılarak ARIMA ve LSTM modelleri aracılığıyla tahmin ederek sonuçların ve modellerin karşılaştırılmasını amaçlamışlardır. Araştırma sonucunda ARIMA modelinin 5.1, LSTM modelinin 7.1 RMSE sonuçlarına ulaşmışlardır. Bağıl nem tahmininde ARIMA modelinin LSTM modeline göre daha başarılı olduğu sonucuna varmışlardır.

Poornima ve Pushpalatha (2019), Hindistan'ın Haydarabad şehrinin 1980 ile 2014 yılları arasında ölçülmüş yağış verilerini kullanarak, yoğunlaştırılmış LSTM tabanlı yapay sinir ağıları metodu ile ARIMA, Holt-Winters gibi metotların performansını karşılaştırmışlardır. Çalışma sonucunda Holt-Winters metodunda 3.08, ARIMA metodunda 2.84, yoğunlaştırılmış LSTM metodunda ise 0.33 RMSE sonuçlarını elde etmişlerdir.

De Saa ve Ranathunga (2020), Macaristan'ın Szeged şehrine ait 2006-2016 yılları arasında ölçülmüş sıcaklık verilerinin ARIMA ve LSTM metotlarındaki performansını karşılaştırmışlardır. Çalışmanın sonucunda ARIMA metodunda 2.42, LSTM metodunda 1.90 MSE değerlerine ulaşmış, LSTM katmanlarının ARIMA metoduna göre daha iyi performans gösterdiği kanısına varmışlardır.

Kumar vd. (2020), NASA'nın Entegre Çoklu-Uydu (IMERG) yağış veri setinin 30 dakikalık yapıdaki döngülerini convLSTM modeli kullanarak kısa dönem yağış tahmini konusunda çalışma yapmışlardır. 30 dakikalık döngüde 0.93, 150 dakikalık döngüde ise 0.87 RMSE sonuçlarına ulaşmışlardır.

Samad vd. (2020), Avustralya'ya ait 2007-2016 arasında ölçülmüş yağış, rüzgar hızı, sıcaklık, basınç, nem ve rüzgar yönü verilerini kullanarak LSTM ve ANN metotlarında yağış tahmini yapmışlardır. Her iki metotta da başarılı sonuçlar alınırken deneme yapılan tüm bölgelerde LSTM metodunun ANN metodundan daha düşük hata ile sonuçlar verdiğini bulmuşlardır.

Şekertekin vd. (2020), Tarsus ilçesinde bulunan güneş enerjisi santralinden elde edilen hava sıcaklığı verilerinin ANFIS, FCM, ANFIS-SC, ANFIS-GP ve LSTM modelleri ile saatlik ve günlük tahmini çalışmasını yapmışlardır. Saatlik veriyle yapılan çalışmalarda LSTM, ANFIS-FCM, ANFIS-SC ve ANFIS-GP modelleri için sırasıyla 0.644, 0.721, 0.722 ve 0.830 RMSE değerine sahip sonuçlara ulaşırken, günlük veriyle yapılan çalışmalarda sırasıyla 1.360, 1.366, 1.405 ve 1.905 sonuçlarına ulaşmışlardır.

Borna vd. (2021), LSTM, GRU ve Lineer Regresyon (LR) metotlarının karşılaştırılması amacıyla 40 yıllık çeşitli hava olaylarına ait 19 farklı veriyle oluşturdukları çalışmanın sonucunda LSTM metodu için $0.80 R^2$, GRU metodu için $0.76 R^2$, LR metodu için $0.44 R^2$ sonuçlarına ulaşmış ve tekrarlayan sinir ağları metotları olan LSTM ve GRU modellerinin başarılı oldukları sonucuna ulaşmışlardır.

Dubey vd. (2021), enerji tüketiminin tahminini, nem, sıcaklık, bulutluluk, rüzgar hızı gibi meteorolojik parametreler kullanarak çalışmışlardır. Kullanılan parametrelerden nemin enerji tüketimiyle pozitif, sıcaklık ile negatif korelasyon gösterdiği sonucuna varılmıştır. LSTM, ARIMA ve SARIMA modellerindeki karşılaştırmalarına sonuçlarda yer verilmiştir. Verilere uygun olarak SARIMAX ve LSTM modelleri kullanılmış, SARIMAX modelinde 0.55, LSTM modelinde 0.23 RMSE değerine ulaşmıştır.

Ouma vd. (2021), Nzoia havzasına ait yağış ve akış verilerini kullanarak LSTM ve Wavelet metodlarını karşılaştırdıkları çalışmada, akış tahminlerinde her iki metot için de 0.8 R^2 sonucuna, yağış tahmininde ise LSTM metodunda 0.86 R^2 başarısına karşın Wavelet metodunda 0.78 R^2 sonucuna ulaşarak her iki metodun da başarılı olduğu sonucuna varmışlardır.

Wu vd. (2021), Çin'in kuzeydoğu bölgesinde bulunan Linjiang, Changchun ve Qian Gorlos bölgelerindeki istasyonlardan edindikleri aylık yağış verilerini kullanarak wavelet dönüşümü-ARIMA-LSTM modellerini hibrit bir model halinde kullanarak aylık yağış ve kuraklık tahmini yapmışlardır. Changchun bölgesinde ARIMA modelinde 0.578, LSTM modelinde 0.663, Linjiang bölgesinde ARIMA modelinde 0.626, LSTM modelinde 0.728, Qian Gorlos bölgesinde ARIMA modelinde 0.366, LSTM modelinde 0.464 belirtme katsayısı sonuçlarına ulaşmışlardır.


3.MATERYAL VE YÖNTEM

Bu bölümde tez çalışmasında kullanılan materyal ve kullanılan yöntemler açıklanmıştır.

3.1 Materyal

Şekil 3.1’de ilçeleriyle birlikte gösterilen ve tez çalışmasında meteorolojik verilerinden yararlanılan Sivas ili, 28488 km² yüz ölçümüne sahip olup, nüfusu 635 889’dır (TÜİK 2020).

Merkez ilçesi dahil olmak üzere 17 ilçe ve 1 233 köye sahip olan Sivas ili çok geniş bir coğrafyaya sahip olmasına karşın nüfusu yıllar içerisinde azalmıştır. Tarım, ildeki en fazla ekonomik harekete sahip çalışma alanıdır. İldeki çalışan nüfusun % 66,5’i tarım sektöründe çalışmaktadır (Anonim 2018).



Şekil 3.1 Sivas ili ve ilçeleri (Anonim 2021)

1930-2020 tarihleri arasında ölçülen verilere göre yıl bazında, ortalama sıcaklığın 9°C, ortalama en yüksek sıcaklığın 15.4°C, en düşük sıcaklığın 2.9°C olduğu ilde ortalama güneşlenme süresi 6.8 saat ve yıllık ortalama yağış 393.2mm'dir (MGM 2021).

2018 yılının verilerine göre toplam 1 106 085 ha tarım arazisine sahip olan Sivas ilinde, 348 845 ha sulanabilir arazi bulunmakta ancak 196 573 ha arazi sulanmaktadır. Sulanabilir arazilerin % 56,3'lük kısmını oluşturan sulanan arazilerin % 43'lük kısmı çiftçi tarafından sulanmaktadır.

TUİK tarafından yapılmış “VII. Genel Tarım Sayımı Tarımsal İşletmeler Anketi”, Sivas ilinde bulunan tarımsal işletme başına düşen ortalama toprak büyüklüğünü 95 da olarak ölçmüştür. 2018 yılında, 78 953 tarımsal işletmenin bulunduğu, bu işletmelerin 7 467 539 da araziyi işlediği belirlenmiştir. Bu işletmelerin % 35.41'i 200-499 da arazi büyüklüğüne sahip olan işletmelerden oluşmaktadır. Tarım işletmelerinin faaliyetleri % 87 oranında bitkisel ve hayvansal üretimin bir arada yapıldığı tespit edilmiştir (TUİK 2018).

Tarımsal arazilerin genişliği ve iklimik gösteren tarımsal havzaların varlığı sebebiyle çeşitli bitkisel ürünlerin yetiştirildiği Sivas ilinde, tritikale, yulaf, korunga, buğday, yonca, aspir, şeker pancarı, patates, arpa ürünleri yoğun şekilde üretilmektedir. Tritikale ve yulaf ekim alanında Türkiye genelinde ikinci sırada olan Sivas ili, buğday ve korunga ekiminde üçüncü, yonca ekiminde altıncı, şeker pancarı ve arpa ekiminde yedinci sıradadır (TUİK 2018).

3.1.1 Sivas iline ait meteorolojik veriler

Bu çalışmada Meteoroloji Genel Müdürlüğü tarafından Sivas ilinin büyük klima özelliğine sahip Zara, Gemerek, Divriği, Ulaş, Suşehri ve Kangal ilçelerine ait yağış, nem ve sıcaklık verilerinden yararlanılmıştır (Çizelge 3.1, Çizelge 3.2).

Çizelge 3.1 Büyük klima özelliğine sahip ilçelere ait istasyonlar ve coğrafi bilgileri

İlçe	İstasyon No	Rakım (metre)	Enlem	Boylam
Zara	17716	1338	39.89	37.74
Suşehri	17684	1164	40.16	38.07
Ulaş	17710	1392	39.44	37.02
Kangal	17762	1521	39.23	37.38
Gemerek	17162	1182	39.18	36.08
Divriği	17734	1121	39.36	38.11

Çizelge 3.2 İstasyonlara ait 10 yıllık ortalama yağış, nem ve sıcaklık değerleri

İlçe	İstasyon No	Ortalama Yağış (mm)	Ortalama Nem (%)	Ortalama Sıcaklık (°C)
Zara	17716	1.14	63.90	9.43
Suşehri	17684	0.99	59.59	11.18
Ulaş	17710	1.11	66.53	9.22
Kangal	17762	1.01	66.56	7.84
Gemerek	17162	0.82	62.83	10.36
Divriği	17734	1.03	53.52	12.48

LSTM modellerinde öğrenmenin artışı ve girdi verisinin güçlenmesi amacıyla yağış, nem ve sıcaklık verilerinin bir gün önceki ölçümlerle oluşturulan veriler de veri setine dahil edilmiştir. Bu veriler tez içerisinde yağış verileri için Y_{t-1} , nem verileri için N_{t-1} , sıcaklık verileri için S_{t-1} şeklinde ifade edilmiştir. Yağış verilerinde öğrenmenin artırılması amacıyla Matlab 2020a sürümünde, wavelet analyzer aracıyla, bir boyutlu haar dalgacık dönüşümü ile tam ayrıştırma (full decomposition) yapılmıştır. Tez içerisinde decompose olarak ifade edilmiştir. İstasyonlara ait 10 yıllık yağış, sıcaklık ve nem verilerinde eksik günler bulunması durumunda bu tarihler çalışma dışı tutulmuştur.

3.2 Yöntem

3.2.1 ARIMA modeli

Zaman serilerinin tahmini için en iyi bilinen ve en başarılı doğrusal istatistiksel modellerden biri ARIMA modelidir. 1970'lerin başında Box ve Jenkins tarafından önerilmiş olan modelin tam adı Otoregresif Entegre Hareketli Ortalama modelidir (Box vd. 2015). ARIMA, bir değişkenin gelecekteki değerini bulmak için kendi geçmiş değerlerini kullanarak tahmin etmede kullanılan bir zaman serisi tahmin yaklaşımıdır (Alabdulrazzaq vd. 2021).

Zaman serisi verileri, durağan ve durağan olmayan veriler olmak üzere iki yapıda olabilmektedir. Durağanlık gösteren zaman serilerinde zamana bağlı bir yapı bulunmamakta, ancak durağanlık göstermeyen serilerde mevsimsellik olarak da adlandırılan yapılar bulunmaktadır. Dolayısıyla, durağanlık göstermeyen verilerin ortalaması ve varyansı zamana bağlı olarak sabit bir ilişki içinde değildir.

Zaman serilerini kullanarak tahmin yapan birçok model olmakla birlikte en yaygın olarak kullanılan yöntem ARIMA yöntemidir. Bu yöntem durağan verilere veya çeşitli istatistiksel yöntemlerle stabilize edilmiş zaman serisi verilerine kolayca uygulanabilir.

ARIMA modeli, verilerin zaman içerisinde birbirini takip eden değerler arasındaki ilişkinin belirlendiği otokorelasyonu ifade etmek amacıyla kullanılmakta ve üç parçadan oluşmaktadır. Oto regresyon (AR), fark derecesi (I), hareketli ortalama (MA) parçalarından oluşan ARIMA modelinde durağanlık aranmaktadır. Zaman serilerinde serinin durağanlığı Dickey-Fuller Testi kullanılarak kontrol edilmektedir. Eşit zaman aralıklarında oluşan gözlem değerlerinin kesikli ve durağan bir seriden oluşması burada aranan özelliktir (Dickey ve Fuller 1979).

Dickey-Fuller Testi eşitliği aşağıda verilmiştir (Eşitlik 3.1):

$$Y_t = \alpha_t Y_{t-1} + u_t \quad (3.1)$$

Eşitlik 3.1’de yer alan formülde $\alpha < 1$ ise seri durağan, $\alpha \geq 1$ ise seri durağan değildir. Eğer durağanlık mevcut değilse fark derecesi parametresi(I) kullanılarak durağanlık sağlanması amaçlanmaktadır. AR ve MA modellerine göre Box-Jenkins olarak bilinen ARIMA modelinin ayrıldığı kısım bu fark derecesinin bulunmasıdır (Box vd. 2015). Durağanlık gösteren zaman serilerinde AR, MA veya ARMA modelleri kullanmak yeterli olurken durağanlık göstermeyen serilerde ARIMA modeli uygulanmaktadır.

ARIMA modelinde çalışılan zaman serisinin durağan olamaması durumunda durağanlık sağlanmalıdır. Durağanlık sağlanmışsa oto regresyon ve hareketli ortalama parametreleri seçilmektedir. ARIMA modelleri tanımlanırken ARIMA (p,d,q) şeklinde tarif edilmektedir.

p: Oto regresyon derecesi (Autoregression-AR)

d: Fark derecesi (I)

q: Hareketli ortalama derecesi (Moving Average-MA)

Özellikle doğa olayları ve tarımsal verilerde mevsimsellik veya trend oluşumu genellikle gözlenen bir durumdur. Bu sebeple fark derecesine sahip modele ihtiyaç duymaktadırlar. Fark derecesi genellikle ‘1’, en fazla ‘2’ değerine sahip olmaktadır.

Dönemsellik göstermeyen modellerde ARIMA (p,d,q) d=0 şeklinde ifade edilebilir ve ARMA (p,q) halini alır. Ayrıca p=0 yada q=0 olması durumunda da AR (p,d) yada MA (d,q) şeklinde kullanılabilir.

ARIMA formülü aşağıda verilmiştir (Eşitlik 3.2):

$$Y_t = c + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (3.2)$$

Eşitlik 3.2’de yer alan c sabiti, β_x otoregresyon katsayısını, $\beta_x Y_{t-x}$ otoregresyon gecikmelerini (p derecesinde), ϕ_q hareketli ortalama katsayısını, ϵ_{t-q} ise hareketli ortalama hatalarını (q derecesinde) ifade etmektedir.

İlk olarak zaman serisinin durağan olup olmadığı belirlenmelidir. Serinin durağan olup olmadığını belirlemek için daha önce bahsedilen durağanlık testi kullanılmaktadır. Zaman serisi durağan ise farkının alınmasına gerekmemekte ve $d=0$ kabul edilmektedir. Seri durağan değilse birinci dereceden fark alınarak tekrar teste tabi tutulur. Fark işleminden sonra seri durağan hale gelirse $d=1$ olarak kabul edilir. Seri hala durağan değilse fark alma ikinci dereceden uygulanır ve fark durağan hale gelene kadar devam eder. Çok karmaşık serilerde ikinci dereceden fark alma uygulaması gerekebilmektedir.

Fark derecesi modelinin eşitliği aşağıda verilmiştir (Eşitlik 3.3):

$$Y'_t = Y_t - Y_{t-1} \quad (3.3)$$

Durağan haldeki zaman serilerinde fark değerinin değiştirilmesine devam edilmesi durumunda aşırı fark alma durumu ortaya çıkabilmektedir. Seriyeye uygun fark derecesi belirlendikten sonra, seriyeye en uygun olan otoregresyon katsayısı ve hareketli ortalama derecesinin aranmaktadır. Bu arayış için otokorelasyon fonksiyonu (ACF) ve kısmi otokorelasyon fonksiyonu (PACF) kullanılabilir. Genel model ve geçici model değerlerini belirlemek için mevcut zaman serisinin otokovaryans ve otokorelasyon değerlerinden yararlanılmaktadır. Serinin geçmiş değerlerle olan ilişkisi bu fonksiyonlar aracılığıyla incelenebilmektedir. Gecikmeler arasında bulunan doğrusal ilişki derecesinin ölçülmesiyle belirlenen otokorelasyon katsayısının belirlendiği fonksiyon otokorelasyon fonksiyonu olarak ifade edilmektedir.

Otokorelasyona benzer şekilde zaman serisi değerleri arasındaki ilişkinin değerlendirilmesi amacıyla kullanılan bir diğer ölçü ise kısmi otokorelasyondur. Kısmi otokorelasyonlar, hareketli ortalama veya otoregresif süreç içerisinde serinin uyumluluğunu ölçmede otokorelasyon sürecinin tamamlayıcısıdır. AR modelinde derecesinin belirlenmesi amacıyla, otokorelasyon değerlerinin sıfır olmayan gecikmelerine bakılarak bu gecikmeler içinde sıfır değeri alan değer p değeri olarak

belirlenmektedir. MA modelinin derecesinin belirlenmesi ise aynı işlem kısmi otokorelasyon üzerinden incelenerek q değeri belirlenmektedir (Çağıl 2017).

3.2.1.1 Otoregresyon (AR)

Zaman serilerinde otoregresyon, zamana bağlı değişen süreçlerin açıklanmasında kullanılan bir yöntemdir. Otoregresyon, değişkenin kendisine karşı olan regresyonunu ifade etmektedir. Değişken, değişkenin geçmiş değerlerinin (gecikmelerinin) doğrusal bir birleşimi kullanılarak tahmin edilmektedir. Bu gecikmeler bir adet gözlem değerine sahipse ‘birinci dereceden-AR (1)’, iki gözlem değerine sahipse ‘ikinci dereceden-AR (2)’ veya p gözlem değerine sahipse ‘p dereceden- AR(p)’ şeklinde ifade edilmektedir.

Otoregresif bir modelin formülü aşağıda verilmiştir (Eşitlik 3.4):

$$Y_t = c + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t \quad (3.4)$$

Eşitlik 3.4’te c sürecin ortalamasına bağlı sabiti, β_x otoregresyon katsayısını, Y_{t-p} otoregresyon gecikmelerinin değerlerini (p derecesinde) ifade etmektedir.

Otoregresyon modellerinde genel olarak geçmiş ve gelecek gözlem değerleri kullanılarak sonuç vermesi beklenmektedir. Geçmiş gözlem değerleri, serinin bir sonraki adımının tahmininde kullanılmaktadır.

Otoregresif süreçte Y_1 değerinin Y_{t-1} , Y_{t-2} gibi kendinden önce gelen değerlerin gecikme değerine bağlı olarak derecesine karar verilmektedir. Bu gecikme değeri yüksek bir dereceye sahip olabilmektedir. AR modelinin sahip olduğu p derecesi, otoregresyon sürecine dahil olan Y_t serisi ve Y_t değerlerinin p dönem önce gelen ağırlıklı ortalaması ile hata değerinin toplamına eşit olmaktadır. Bu derecenin belirlenmesi amacıyla kısmi otokorelasyon katsayılarından (PACF) yararlanılmaktadır. Otoregresyon modellerinde otokorelasyon fonksiyonunda ilişki derecesi gecikme miktarı arttıkça yavaş şekilde azalırken, kısmi otokorelasyon fonksiyonunda azalma hızlı bir şekilde gerçekleşmektedir.

3.2.1.2 Hareketli ortalama (MA)

Hareketli ortalama, zaman serisinin bir dönemine ait gözlem değerinin, aynı dönemdeki hatanın ve belirli sayıda geçmiş dönem hatalarının doğrusal bir birleşiminin kullanıldığı ve ağırlıklı ortalamalarının ifade edildiği yöntemidir. Bu yöntemi uygulamak için, zaman serisinde aşağıdaki şartlar sağlanmalıdır (Brown 1964):

- 1) Trend doğrusal eğimli olmalıdır.
- 2) Dalgaların uzunluğu eşit olmalıdır.
- 3) Dalgaların şiddeti aynı olmalıdır.

Hareketli ortalama eşitliği aşağıdaki gibidir (Eşitlik 3.5):

$$Y_t = c + \phi_0 \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (3.5)$$

Eşitlik 3.5'te bulunan hareketli ortalama eşitliğinde c sürecin ortalamasına bağlı sabiti, ϕ_q hareketli ortalama katsayısını, ϵ_{t-q} hareketli ortalama hatalarını (q derecesinde) ifade etmektedir.

Hareketli ortalama sürecinde q derecesinin belirlenmesi amacıyla otokorelasyon katsayılarından (ACF) yararlanılmaktadır. Herhangi bir modelin otokorelasyon katsayısı belirli bir noktadan itibaren net bir şekilde kesilme göstermesine bağlı olarak modelin hareketli ortalama modeli olduğu belirlenebilmektedir. ACF değerlerindeki zirve noktası hareketli ortalama modelinin q derecesini göstermektedir. Hareketli ortalama modellerinde kısmi otokorelasyon (PACF) fonksiyonunda ilişki derecesi yavaş şekilde azalırken, otokorelasyon (ACF) fonksiyonunda hızlı bir şekilde artmaktadır.

3.2.1.3 Otoregresif hareketli ortalama (ARMA)

Otoregresyon (AR) ve hareketli ortalama (MA) modellerinin bir arada, durağanlık gösteren zaman serilerinde kullanılan model otoregresif hareketli ortalama (ARMA) modelidir. ARMA modelleri zaman serilerinin herhangi bir dönemine ait gözlem değerinin, öncesinde gelen belirli sayıdaki gözlem değerinin ve hata derecesinin doğrusal birleşimi olarak ifade edilmektedir. Yapısı itibarıyla hem otoregresyon hem de hareketli ortalama özelliklerine sahip olan ARMA modelleri, ARIMA (p,0,q) ya da ARMA (p,q) şeklinde ifade edilebilir.

ARMA (p,q) modelinin fark denklemi genel gösterimi aşağıdaki gibidir (Eşitlik 3.6):

$$Y_t = c + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (3.6)$$

Eşitlik 3.6'da c sabiti (Y_t ortalamasına bağlı), β_x otoregresyon katsayısını, $\beta_x Y_{t-x}$ otoregresyon gecikmelerini (p derecesinde), ϕ_q hareketli ortalama katsayısını, ϵ_{t-q} hareketli ortalama hatalarını (q derecesinde) ifade etmektedir.

3.2.2 Mevsimsel bütünleşik otoregresif hareketli ortalama modeli (SARIMA)

Aylık zaman aralıklarının gözlem değerlerinden oluşan zaman serilerinin, ardışık yıllara ait aylarda ya da yıllara ait dönemlerde en fazla ve en aza ulaşma yatkınlığı, mevsimsel dalgalanmalar olarak ifade edilmektedir. Serilere "Mevsimsel Zaman Serileri" denir. Mevsimsel dalgalanmaların oluşturduğu dalga boyu mevsimsellik parametresi (S) ile ifade edilmektedir. Aylık gözlem değerlerinde oluşan serilerin mevsimsellik parametresi 12 olarak kullanılmaktadır. Ayrıca üç veya altı aylık dönemlere ait mevsimsel dalgalanmalar da kullanılabilir.

Mevsimsellik ilkesi zaman serilerindeki istikrarın bozulmasına sebep olan bir etmendir. Bu zaman serilerinde durağanlık sağlanması amacıyla serilerin mevsime bağlı etkilere bağlı olarak düzenlenmesi gerekmektedir. Mevsimsel serilerin modellenmesinde mevsimsellik parametresinin belirlenmesi sayesinde gözlem değerinin fark değeri olarak mevsimsellik farkı kullanılmalıdır. Genellikle ARIMA modeli ile oluşturulan mevsimsel

modeller, serinin durumundaki deęişiklikler ve mevsim sebepli etkilerin deęişikliklerini incelemektedir. Bu modeller gözlem deęerleri arasındaki ilişkilerin yanında mevsimsel yani yıllık bazdaki gözlem deęerleri arasındaki ilişkilerin de modelde yer bulmasını sağlamaktadır.

SARIMA formülü şu şekildedir (Eşitlik 3.7):

$$\phi_p(B)\phi_p(B^m)\nabla^d(\nabla_m)^dX_t = \theta_q(B)\theta(B^m)e_t \quad (3.7)$$

Eşitlik 3.7’de ϕ mevsimsel otoregresyon parametresini, θ mevsimsel hareketli ortalama parametresini, d fark alma derecesini, ∇ fark alma operatörünü, m mevsimsel dalgalanma uzunluęunu, d mevsimsel fark derecesini, p mevsimsel otoregresif model derecesini, q mevsimsel hareketli ortalama derecesini temsil etmektedir.

SARIMA modelleri ARIMA (p,d,q) (P,D,Q) şeklinde ifade edilmektedir. (p,d,q) mevsimsel olmayan modelin derecelerini, (P,D,Q) ise mevsimsel modelin derecelerini ifade etmektedir.

3.2.3 Uzun-kısa süreli bellek (LSTM) modeli

3.2.3.1 Tanım ve temel kavramlar


Özellikle 1990’lı yıllardan itibaren popüler hale gelen ve o dönemde sıklıkla kullanılmakta olan yapay sinir aęları modeli, popülerlięi ve bu alandaki çalışmaların artışıyla birlikte alternatif yeni modellerin ortaya çıkmasını sağlamıştır. Yapay sinir aęları uzun yıllar mühendislik, hidroloji, matematik, ekonomi, tıp, meteoroloji gibi çok çeşitli alanlarda uygulanmıştır. Makine öğrenmesi, derin öğrenme gibi terimlerin her geçen gün daha da önem kazandığı ve hayata entegre olduęu günümüzde gelişmiş sinir aęları modelleri de zaman serilerinin tahmininde kullanılmaktadır. Yapay sinir aęları genel olarak daha basit koşullarda, nispeten az sayıdaki verilerle kullanılır hale gelmiştir. Veri sayısının arttığı ve girdi-çıktı arasındaki bağlantının zor tespit edilebilir olduęu durumlar için Derin Öğrenme (Deep Learning) kavramı ortaya çıkmıştır. Derin öğrenme uygulamalarının zaman serilerindeki hali ise Tekrarlayan Sinir Aęları (Recurrent Neural Network-RNN) ismini almıştır. RNN’in alt yöntemleri ise Uzun-Kısa Süreli Bellek (Long-Short Term Memory-LSTM), İki Yönlü Uzun-Kısa Süreli Bellek (Bidirectional

Long-Short Term Memory-BiLSTM), Geçiti Tekrarlayan Birim (Gated Recurrent Unit-GRU) ve Basit Tekrarlayan Sinir Ağları (Simple Recurrent Network-simpleRNN) dir. LSTM, bu yöntemler içerisinde en yaygın ve bilinir olan modeldir. Verinin öğrenilmesi, genelleme yapabilme yetisi, limitsiz miktarda değişken ile çalışabilme özgürlüğü bu modellerin popüler olmasındaki en büyük etkenlerdir.

Yapay sinir ağları modellerinin en küçük birimleri olan yapay sinir hücreleri aracılığı ile girdi-çıkı (input-output) haritası oluşturularak belirli örnekler kullanılarak öğrenme aşamasına başlanmaktadır. Öğrenme aşamasında sinir ağı eğitim ve test aşamalarını gerçekleştirmek amacıyla girdi verilerine ve bu verilere karşılık gelen çıkı sonuçlarına ihtiyaç duymaktadır.

Bu yapay sinir hücreleri girdi verileri, ağırlıklar (weights), birleştirme fonksiyonu, aktivasyonlar ve çıkı değerlerine sahiptir. Yalnızca girdi ve çıkı katmanlarından oluşan sinir ağları karmaşık işlemlerde başarılı sonuçlar veremezken, bu katmanlarla birlikte gizli katmana sahip olan ağlar karmaşık işlemlerde başarıyla çalışabilmektedir. Bir katmandaki her bir sinir hücresinin çıkısı bir sonraki katmana ait sinir hücrelerinin tamamıyla bağlantılı olup, aynı katmandaki sinirler arasında bir bağlantı bulunmamaktadır.

Sinir ağı modelleri içerisinde yer alan LSTM modeli de insan beyninin çalışma şeklinden ilham alarak geliştirilmiş bir modeldir. Şekil 3.2’de gösterilen, 1997 yılında Hochreiter ve Schmidhuber tarafından tasarlanmış olan model, birleşim noktalarındaki eğitim derecesine bağlı olarak probleme sebep olan yapıları ve uzun vadeli bağımlılıkları hedef alan, doğrusal olmayan modellerde tahmin yapabilmek üzere kullanılabilir. (Hochreiter ve Schmidhuber 1997).



Şekil 3.2 İlk LSTM mimarisi (Pichotta vd. 2016)

Model yapay sinir ağlarında bulunan hücre yapısına sahiptir. LSTM'nin yapay sinir ağı modelinden ana farkı, içerdiği hafıza yapısıdır. Bilgileri uzun süre hafızasında tutabilme kabiliyetine sahip olan LSTM ağlarında bilgi akışı, eşitlik 3.12'de gösterilen hücre durumu (cell state) adı verilen yapılar aracılığı ile kontrol edilmektedir. Bilginin hücre durumuna geçmesine izin verilmesinin kontrolü üç kapı ile kontrol edilmektedir. Kapı (Gate) olarak tanımlanan yapılar aracılığıyla bilginin eklenmesi ya da çıkarılması kabiliyeti bulunmaktadır. Eşitlik 3.8'de gösterilen girdi kapısı (input gate), unutma kapısı (forget gate) ve çıktı kapısı (output gate) olarak üç ayrı kapıya sahip olan LSTM modellerinde girdi kapısı verilerin giriş akışını kontrol etmek için kullanılmaktadır. Eşitlik 3.9'da gösterilen çıktı kapısı ise verilerin bellek hücrelerine çıkışını kontrol etmek amacıyla kullanılmaktadır. Son bellek hücresinden mevcut bellek hücresine hangi bilgilerin geçtiğinin kontrolünü sağlayan katman ise eşitlik 3.10'da gösterilen unutma kapısıdır.


Girdi katmanında, bilginin hücre durumunda hangi sürede girdi olarak işlemden olacağının hesaplandığı ve hangi yeni bilgilerin ekleneceğinin kararının verildiği katmandır. Aktivasyon fonksiyonunun kullanıldığı giriş katmanından sonra yeni duruma eklenebilecek aday verilerin tutulduğu bir aktivasyon fonksiyonlu ara katman kullanılmaktadır. Unutma katmanında ise bilginin hücre durumunda tutulacağı süre hesaplanmakta ve hangi bilgilerin hatırlanacağına ve hangi bilgilerin unutulacağına karar

verilmektedir. Unutma katmanından iletilen hücre durumunun güncellemesinin yapıldığı girdi kapısında öncelikle sigmoid fonksiyonu kullanılarak önemli bilgilerin ayrımı yapılmaktadır. Sigmoid fonksiyonunun kullanılmasının ardından, unutma katmanı ve girdi katmanı tanh fonksiyonu ile birleştirilmekte, sigmoid ve tanh fonksiyonlarının çıktıları çarpılarak hücre durumunun güncelleme kararı verilerek yenilenmiş bir hücre durumu haline almaktadır. Önemli görülen bilgilerin filtrelendiği ve tahmin etme amacıyla kullanılacak olan çıktının üretildiği katman ise çıktı katmanıdır. Hücre durumundaki hangi bilgilerin çıktı katmanına aktarılacağı kararını vermek amacıyla bir sigmoid fonksiyonu kullanılmaktadır. Tanh fonksiyonundan geçirilen hücre durumunun çıktı katmanının çıktısı ile çarpılması sonucunda hücre durumu ve gizli hal bilgileri elde edilmektedir. Kapılarda verilerin “0-1” aralığında değerler almasını sağlayan sigmoid aktivasyon fonksiyonu kullanılmaktadır. “0” değer unutulacak bilgileri, “1” değeri ise hücre halinin devamı yani aktarımın süreceğini ifade etmektedir.

Özetle, yeni bir değer bellekte ne seviyede aktığını kontrol eden kapı girdi, yeni değer bellekte kalma derecesinin hesaplandığı kapı unutma, bloğun çıktı aktivasyonunun hesaplanması amacıyla bellekteki değerinin kullanımının hesaplandığı kapıya ise çıktı kapısı şeklinde ifade edilmektedir.

Zaman serilerinde verileri, öğrenme ve tahmin etme konusunda sınırlı olan yapay sinir ağı yapısına karşın, bu sınırı aşmak amacıyla hatırlanması veya unutulması gereken hücrelerin tespit edilebilmesi bu kapılar aracılığıyla sağlanmaktadır.

Şekil 3.3’te girdi kapısı yeşil, unutma kapısı mavi, çıktı kapısı kırmızı, hücre hali pembe renkte çerçeveler ile belirtilmiştir. Eşitlik 3.8’de girdi kapısının, eşitlik 3.9’da unutma kapısının, eşitlik 3.10’da çıktı kapısının eşitlikleri verilmiştir.



Şekil 3.3 LSTM kapılarının ifade edildiği LSTM modülü

$$I_t = \sigma(W_I h_{t-1} + W_I x_t + b_I) \text{ (girdi kapısı)} \quad (3.8)$$

$$F_t = \sigma(W_F h_{t-1} + W_F x_t + b_F) \text{ (unutma kapısı)} \quad (3.9)$$


$$O_t = \sigma(W_O h_{t-1} + W_O x_t + b_O) \text{ (çıktı kapısı)} \quad (3.10)$$

$$\tilde{C} = \tanh(W_C h_{t-1} + W_C x_t) \text{ (ara hücre hali)} \quad (3.11)$$


$$c_t = (i_t * \tilde{C}) + (f_t * c_{t-1}) \text{ (hücre hali)} \quad (3.12)$$

$$h_t = o_t + \tanh(c_t) \text{ (yeni hücre hali)} \quad (3.13)$$

Şekil 3.4'te LSTM ağında hücre halinde gösterilen hücreler arasındaki bağlantıların sayısal değeri ağırlıklar (weights) olarak ifade edilmekte ve hücreye gelen bilginin önemi ve bu bilginin hücre üzerindeki etkisini belirtmektedir. Toplama fonksiyonu, bir hücreye gelen girdi değerlerinin ağırlıkları ile çarpılıp toplanması işlemiyle o hücrenin net girdisinin hesaplandığı fonksiyondur. Hücreye gelen net girdiyi işleyen ve hücrenin girdiye karşın üreteceği çıktının belirlenmesini sağlayan katman aktivasyon fonksiyonudur. 0 ve 1 rakamları arasında bir çıktı veren, Şekil 3.5'te gösterilen sigmoid katmanında, 0 çıktısı "hiçbir bilgiyi geçirme", 1 çıktısı ile "her şeyi geçir" anlamına gelmektedir.




Şekil 3.4 LSTM ağlarında hücre hali (Colah's Blog 2015)




Şekil 3.5 LSTM ağlarında sigmoid fonksiyonu (Colah's Blog 2015)

Şekil 3.6'da gösterilen standart bir yapay sinir ağı, tekrarlayan ağ mantığı ile hareket eder ve tekli tanh katmanına sahip olan bir yapıdadır. Şekil 3.7'de gösterilen LSTM ise birbirini takip eden ve bir sonraki parçaya aktarım sağlayan daha karmaşık bir yapıdır.



Şekil 3.6 Tekrarlayan standart bir tek katmanlı yapay sinir ağı modülü (Colah's Blog 2015)



Şekil 3.7 LSTM katmanları (Colah's Blog 2015)

Bir LSTM modeli, bir veya daha fazla sayıda katmanın bir arada kullanılması ile uygulanabilmektedir. En başta kullanılan katman, LSTM katmanı olarak seçilmelidir. Ardından gelen katmanlar bir önceki katmanın taşıdığı bilginin kısa vadeli hafıza bellekleri görevi görmektedir. Çoklu katmanların da kullanılabildiği modellerde çok katman olması modelin daha iyi öğreneceği anlamına gelmemektedir. Katman kullanımı, modelin verdiği sonuçlara göre optimum değerlerde olmalıdır.

Araştırmadaki LSTM denemelerinde LSTM katmanlarıyla birlikte yoğunluk (dense), seyreltme (dropout), yığın normalleştirme (batch normalization) katmanları denenmiş ve kullanılmıştır.

Ağın daha kararlı ve düzenli bir şekilde işlem görebilmesi adına, eş zamanlı öğrenmeyi sağlamak ve gizli katmanlar arasındaki kovaryansı azaltmak için LSTM katmanlarıyla birlikte çalışacak şekilde ara katman olarak yığın normalleştirme (batch normalization) katmanı kullanılmıştır.

Başarıyı arttırmak ve ezberlemenin önüne geçmek amacıyla 0.001-0.9 aralığında farklı seyreltme (dropout) katmanları denenmiştir.

Katmanlar arasında geçişi sağlamak amacıyla yoğunluk(dense) katmanları kullanılmıştır. LSTM ve dense katmanlarında farklı aktivasyon fonksiyonları denenmiş, başarılı olarak görülen aktivasyon fonksiyonu olarak ReLU kullanılmıştır.

Kurulan modellerin derlenmesi amacıyla farklı parametreler alarak eğitim ve performansın gözlenebilmesi için compile metodu kullanılmıştır. Araştırmada model compile parametreleri olarak, optimizasyon için Adam, kayıp fonksiyonu için MSE, metrik olarak accuracy kullanılmıştır.


Compile sonrası modelin eğitimi fit metoduyla yapılmaktadır. Fit metodunda eğitim ve test parçalarının tanımı, yığın boyutu (batch size), epoch değerleri kullanılmıştır. Eğitim ve test verilerinin tekil halde ele alınması yerine, gruplar halinde eğitime alınmasını sağlayan yığın boyutu (batch size), modellerin uyumluluğuna ve ağırlık başarısına göre 16-32-64-128-256 değerlerinde denenmiştir. Veri kümelerinin kaç defa eğitime gireceğinin, en uygun ağırlık değerini hesaplaması adına ağırlık başarısına göre 10-1000 aralığında epoch denenmiştir.

Çalışmada farklı katmanlar, çeşitli hiperparametreler denenmiş, en başarılı kombinasyonlar ilgili ilçenin LSTM sonuç tablolarında verilmiştir.

3.2.3.2 ReLU fonksiyonu

Doğrultulmuş lineer birim (rectified linear unit- RELU) doğrusal olmayan, parçalı-lineer olan bir fonksiyondur. Şekil 3.8’de gösterilen ReLU fonksiyonu negatif girdilere sahipken 0 değerinde sahip olmakta, pozitif girdilere sahipken ise pozitif girdi değerini almaktadır. ReLU $(0, +\infty)$ aralığında değer alırken, gelen girdi değeri 0’ dan büyük ise değişim yapmadan çıktı vermektedir. LSTM metodunda, gizli katmanların aktivasyon fonksiyonu olarak yaygın bir şekilde kullanılmaktadır. Genellikle yığın normalleştirme (batch normalization) uygulanmış giriş vektörünün ardından kullanılmaktadır. Çok katmanlı ağ yapılarında sigmoid ve tanh fonksiyonlarına göre daha uyumlu çalışmaktadır. Yakınsamanın (convergence) daha hızlı olması sebebiyle öğrenme de aynı şekilde hızlıdır. Bu bir avantaj olmasına rağmen negatif ekseninde “0” değerlerine sahip olması bu değerlerin türevinin de sıfır olmasına sebep olmaktadır. Ancak pozitif sayılar için türevinin her zaman “1” değerine sahip olması sayesinde gradyan azalma (gradient descent) ortaya çıkmaması önemlidir. Eşitlik 3.14 ve 3.15’te yer alan ReLU fonksiyonunun, Rastgele ReLU (Random ReLU-RRReLU), LeakyReLU, parametrik

ReLU (Parametric ReLU-PReLU), standart ReLU (Standart SeLU) gibi farklı çeşitleri bulunmaktadır.



Şekil 3.8 ReLU Grafiği (Amidi 2021)

$$ReLU(x) = \max(0, x) \quad (3.14)$$

$$g(z) = \max(0, z) \quad (3.15)$$

Bu tezde bulunan LSTM çalışmalarında LSTM katmanlarında aktivasyon fonksiyonu olarak ReLU fonksiyonu kullanılmıştır.

3.3.3.3 Adam optimizasyonu

Adam optimizasyonu birinci dereceden gradyan tabanlı optimizasyon sağlayan, ağırlıkları iteratif şekilde güncellemek amacıyla kullanılan bir optimizasyon algoritmasıdır. Adam optimizasyonunun uygulaması basittir, daha az belleğe ihtiyaç duyar, durağan olmayan, gürültülü ve seyrek veriler için uygundur (Kingma vd. 2014).

Adaptif momentum olarak tanımlanabilen Adam, Stokastik Gradyan Azalma (Stochastic Gradient Descent-SGD) optimizatörünün momentum özelliği ile RMSprop optimizatörünün birleşimi olarak ifade edilebilir ve her iki optimizatörün avantajlarına sahiptir. Adaptif öğrenme faktörüne sahip olup, tüm parametrelerin öğrenme oranları ile momentum değişikliklerini de önbellekte saklama kabiliyetine sahiptir. AdaDelta optimizatörüne de benzemekle birlikte, AdaDelta'nın güncelleme denkleminde pay olarak gradyanın ikinci momentini kullanırken, Adam gradyanın birinci momentini kullanmaktadır.

Adam optimizasyonu eşitlikleri aşağıdaki gibidir:

t süresinde gradyan eşitlikleri:

$$g_t = \frac{\partial f(x, w)}{\partial w} \quad (3.16)$$

Güncellenmiş birinci moment eşitliği:

$$m_t = \beta_1 * m_{t-1} - (1 - \beta_1) * g_t \quad (3.17)$$

Güncellenmiş ikinci moment eşitliği:

$$v_t = \beta_2 * v_{t-2} - (1 - \beta_2) * g_t^2 \quad (3.18)$$

Hesaplanmış birinci moment eşitliği (β_1 genellikle 0.9):

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3.19)$$

Hesaplanmış ikinci moment eşitliği (β_2 genellikle 0.999):

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3.20)$$

Güncellenmiş parametreler eşitliği (α öğrenme oranı, ϵ genellikle $1e^{-8}$):


$$\theta_{t+1} = \theta_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \hat{m}_t \quad (3.21)$$

Bu tezde bulunan LSTM çalışmalarında optimizasyon için Adam optimizasyonu kullanılmıştır.

3.2.3.4 Kayıp fonksiyonu olarak ortalama kare hatası

Yapay sinir ağlarında ve LSTM modellerinde bulunan ağırlıklar güncellenirken, hatanın minimize edilmeye çalışılması için gradyan azalış algoritması kullanılmaktadır. Bu nedenle, ortalama kare hatasının türevi alınarak kullanılmaktadır. Regresyon problemlerinde sıklıkla başvurulanan bir kayıp fonksiyonu olan Ortalama Kare Hatası (Mean Squared Error-MSE), tahmin edilen ve gerçek değerler arasındaki farkların karelerinin ortalamalarının alınması şeklinde kullanılmaktadır. Şekil 3.9’da gösterilen ve eşitlik 3.22’de eşitliği verilen MSE kayıp fonksiyonu bu tezde bulunan LSTM çalışmalarında kayıp fonksiyonu olarak kullanılmıştır.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.22)$$



Şekil 3.9 MSE Kayıp Fonksiyonu

3.3 Değerlendirme Metrikleri

Çalışmada değerlendirme metrikleri olarak Ortalama Kare Hatası (Mean Squared Errors-MSE), Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (Mean Absolute Error-MAE), ve Belirtme Katsayısı (R^2) kullanılmıştır.

3.3.1 Ortalama kare hatası

Regresyon problemlerinde sıklıkla kullanılan MSE veri setinde tahmin edilen ile gerçek değerler arasındaki kare farkının ortalamasını temsil eder. Artık değerlerin karelerinin toplamının ortalaması olarak ifade edilen bu metrik artıkların varyansını ölçmektedir. Sıfıra yakınlığı tahminin doğruluk derecesini ifade etmektedir. Eşitlik 3.23'te y_i gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri ifade etmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3.23)$$

3.3.2 Kök ortalama kare hatası

Tahmin değerleri ve gerçek değerler arasındaki farkın bulunması amacıyla kullanılan bir metriktir. Artık değerlerin standart sapması şeklinde de ifade edilebileceği gibi Ortalama Kare Hatası metriğinin kareköküne eşittir. Negatif eğilimli sonuçlarda başarılı performans gösterebilmektedir. Eşitlik 3.24'te N toplam gözlem değerini, y_i gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri ifade etmektedir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (3.24)$$

$$RMSE = \sqrt{MSE} \quad (3.25)$$

3.3.3 Ortalama mutlak hata

Doğrusal bir metrik olan MAE, tahmin edilen ve gerçek değerler arasındaki mutlak farkı temsil eder. Eşitlik 3.26’da N toplam gözlem değerini, y_i gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri ifade etmektedir.

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (3.26)$$

3.3.4 Belirtme katsayısı

Gerçek değerlerin, tahmin değerler ile arasındaki ilişkinin ifadesi olan R^2 , 0-1 arasında sonuçlar verirken, R^2 değeri “1” değerine yakınlığı, modelin uyumluluğu ve hassasiyetini belirtmektedir. Değerler arasındaki lineer bağıllık düzeyini temsil eder. Eşitlik 3.27’de y_i gerçek değerleri, $\hat{y}_i$ tahmin edilen değerleri ifade etmektedir.

$$R^2 = 1 - \frac{\sum (y_i - \hat{y}_i)^2}{\sum (\hat{y}_i - y_i)^2} \quad (3.27)$$

3.4 ARIMA ve LSTM Yöntemlerinin Karşılaştırılması

Zaman serileri, zamana dayalı bir düzen göstermekte ve bu düzende gözlem değerlerinin tutarlılığının ölçülmesi konusunda farklı yöntemlere tabi tutulmaktadır. Geçmiş verilerden yola çıkarak tahmin yapabilme yetisi bu tahmin metotlarının temel dayanağını oluşturmaktadır. Bu bağlamda, zaman serilerinin tahmininde kullanılan en yaygın metotlardan biri Box-Jenkins metodu olarak da bilinen ARIMA metodudur.

Özellikle günümüzde çeşitli programlama dillerindeki gelişmeler ve gelişen eklentilerinin yanı sıra bilgisayar işlem performanslarının da artması ile yaygınlaşan yapay sinir ağları ve bu ağ yapısının bir geliştirmesi olan LSTM metodu zaman serilerinin tahmininde sıklıkla kullanılan bir başka metottur.

ARIMA ve SARIMA yöntemlerinde eğitim seti, tüm verinin %70'i alınarak oluşturulmuştur. Veriye durağanlık testi uygulanmış ve AIC, BIC sonuçlarından yola çıkılarak en uygun otoregresyon parametresi (p), fark derecesi (d), hareketli ortalama derecesi (q) belirlenmiş ve mevsimsellik derecesi (s) 12 olarak belirlenmiştir.

LSTM yönteminde ise eğitim seti, tüm verinin %70'i, test seti ise %30'u olarak alınmıştır. Öğrenme başarısının artışı ve ağın derinliğinin arttırılması amacıyla klasik tek LSTM katmanı (Vanilla LSTM), İki Yönlü Uzun Kısa Süreli Bellek (Bidirectional LSTM), Yoğun katman (Dense), Seyreltme (Dropout) katmanları kullanılmış, çeşitli yığın sayısı (batch size), iterasyon (epoch), öğrenme oranı (learning rate), decay parametreleri ile çalışılmıştır. Çizelge 3.3'te, çalışmada kullanılan ARIMA-SARIMA ve LSTM yöntemlerinin yapısal karşılaştırması verilmiştir. Çizelge 3.4'te LSTM modellerinde denenen alternatif parametreler sunulmuştur.

Çizelge 3.3 Yöntemlerin yapısal karşılaştırılması

	ARIMA-SARIMA	LSTM
Metot temeli	İstatistik	Derin Öğrenme
Uygun veri seti	Basit yapıda	Basit veya Karmaşık yapıda
Yorumlanabilirlik	Zayıf	Güçlü
Parametreler	p, P (otoregresyon) d, D (fark) q, Q (hareketli ortalama) s (mevsimsellik)	LSTM BiLSTM Dense Dropout
Eğitim Seti	%70	%70
Test Seti	%30	%30
Metrikler	R^2 , RMSE, MAE	R^2 , RMSE, MAE

Çizelge 3.4 LSTM çalışmasında kullanılan alternatif parametreler

Learning Rate	$1e^{-1}$, $1e^{-2}$, $1e^{-3}$, $1e^{-4}$, $5e^{-4}$, $1e^{-5}$, $146e^{-5}$, $1e^{-6}$, $1e^{-7}$, $1e^{-8}$, $1e^{-9}$
Decay	$1e^{-1}$, $1e^{-2}$, $1e^{-3}$, $1e^{-4}$, $1e^{-5}$, $1e^{-6}$, $1e^{-7}$, $1e^{-8}$, $1e^{-9}$
Epoch	10-1000 aralığında 10'un katları şeklinde
LSTM Katmanı	4-256 aralığında 2'nin katları olacak şekilde
Aktivasyon Fonksiyonu	ReLU, SeLU, LeakyReLU, tanh, sigmoid
BiLSTM Katmanı	4-128 aralığında 2'nin katları olacak şekilde
Dropout	0.10, 0.20, 0.30, 0.40, 0.50
Dense Katmanı	Ara katman olarak 4, 8, 16, 32, 64, Çıkış katmanı olarak 1
Batch Size	4-512 aralığında 2'nin katları olacak şekilde
Optimizatör	Adam, Adadelta, SGD, RMSprop
Kayıp Fonksiyonu	MSE, MAE, MAPE, MSLE

Hem ARIMA hem de LSTM modellerinde zaman serilerinin tahmini çalışmalarında kullanılmakta ve başarılı sonuçlar vermektedir. Her iki model de son yıllarda popülerlik kazanan ve kütüphanelerinin içerik zenginliği sebebiyle tercih sebebi olan Python programlama dilinde Anaconda platformu üzerinde JupyterLab arayüzü aracılığıyla kullanılmıştır. Verilerin programda kullanılabilmesi için veriler csv formatına çevrilmiştir.


4. ARAŞTIRMA BULGULARI

4.1 Kangal İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Kangal ilçesine ait meteorolojik parametrelerin tahmininde en iyi sonuç veren LSTM ve ARIMA model yapıları Çizelge 4.1 ve Çizelge 4.2’de verilmiştir.

Çizelge 4.1 Kangal ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	$5 e^{-4}$	$146 e^{-5}$	$1 e^{-2}$
Decay	$1 e^{-2}$	$1 e^{-6}$	$1 e^{-2}$
İterasyon sayısı	150	200	300
Giriş katmanı	LSTM 32	LSTM 128	LSTM 16
Ara katman	LSTM 32	LSTM 128, Dense 15	LSTM 8
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	256	128	64
Ara parametreler	Batch Normalization	Batch Normalization	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.1 LSTM metodunda Kangal ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.2 LSTM metodunda Kangal ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.3 LSTM metodunda Kangal ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.4 LSTM metodunda Kangal ilçesi nem verilerine ait tahmin grafiği




Şekil 4.5 LSTM metodunda Kangal ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.6 LSTM metodunda Kangal ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.2 Kangal ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(1,0,0)(0,0,0)	(5,0,2)(0,0,0)	(5,1,0)(0,0,0)
Mevsimsellik	-	-	12



Şekil 4.7 ARIMA metodunda Kangal ilçesi yağış verilerine ait tahmin grafiği



Şekil 4.8 ARIMA metodunda Kangal ilçesi nem verilerine ait tahmin grafiği



Şekil 4.9 ARIMA metodunda Kangal ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.3 Kangal ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması


Kangal	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.44	-	4.74	-	1.65	-
Test MAE	0.39	0.84	5.89	6.34	1.70	1.75
Eğitim RMSE	0.70	-	6.22	-	2.38	-
Test RMSE	0.63	2.23	7.61	8.72	2.48	2.54
Eğitim R^2	0.94	-	0.84	-	0.94	-
Test R^2	0.93	0.06	0.80	0.73	0.93	0.92

4.2 Zara İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Zara ilçesine ait meteorolojik parametrelerin kullanıldığı LSTM ve ARIMA model yapıları Çizelge 4.4 ve Çizelge 4.5’te verilmiştir.

Çizelge 4.4 Zara ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	$5 \cdot 10^{-4}$	$146 \cdot 10^{-5}$	$146 \cdot 10^{-5}$
Decay	$1 \cdot 10^{-2}$	$1 \cdot 10^{-5}$	$1 \cdot 10^{-5}$
İterasyon sayısı	300	100	100
Giriş katmanı	LSTM 16	LSTM 64	LSTM 10
Ara katman	-	LSTM 16	LSTM 8,Dense 2
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	128	16	128
Ara parametreler	-	Batch Normalization	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.10 LSTM metodunda Zara ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.11 LSTM metodunda Zara ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.12 LSTM metodunda Zira ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.13 LSTM metodunda Zira ilçesi nem verilerine ait tahmin grafiği




Şekil 4.14 LSTM metodunda Zara ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.15 LSTM metodunda Zara ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.5 Zara ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(3,0,3)(0,0,0)	(5,0,1)(0,0,0)	(2,0,3)(1,1,0)
Mevsimsellik	-	-	12



Şekil 4.16 ARIMA metodunda Zara ilçesi yağış verilerine ait tahmin grafiği



Şekil 4.17 ARIMA metodunda Zara ilçesi nem verilerine ait tahmin grafiği



Şekil 4.18 ARIMA metodunda Zara ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.6 Zara ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması


Zara	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.34	-	6.54	-	1.59	-
Test MAE	0.38	1.63	6.56	6.82	1.65	2.18
Eğitim RMSE	0.74	-	8.38	-	2.20	-
Test RMSE	0.89	3.16	8.37	8.90	2.34	2.91
Eğitim R^2	0.97	-	0.68	-	0.94	-
Test R^2	0.96	0.11	0.65	0.60	0.92	0.87

4.3 Divriği ilçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Divriği ilçesine ait meteorolojik parametrelerin kullanıldığı LSTM ve ARIMA model yapıları Çizelge 4.7 ve Çizelge 4.8’de verilmiştir.

Çizelge 4.7 Divriği ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	5×10^{-4}	146×10^{-5}	1×10^{-3}
Decay	1×10^{-2}	1×10^{-4}	1×10^{-3}
İterasyon sayısı	250	2000	2000
Giriş katmanı	LSTM 32	LSTM 128	LSTM 16
Ara katman	LSTM 16, Dense 4	LSTM 64, Dense 8	LSTM 8, Dense 8
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	256	64	128
Ara parametreler	-	-	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.19 LSTM metodunda Divriği ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.20 LSTM metodunda Divriği ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.21 LSTM metodunda Divriği ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.22 LSTM metodunda Divriği ilçesi nem verilerine ait tahmin grafiği




Şekil 4.23 LSTM metodunda Divriği ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.24 LSTM metodunda Divriği ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.8 Divriği ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(3,0,2)(0,0,0)	(2,0,2)(0,0,0)	(1,1,0)(5,1,0)
Mevsimsellik	-	-	12



Şekil 4.25 ARIMA metodunda Divriği ilçesi yağış verilerine ait tahmin grafiği



Şekil 4.26 ARIMA metodunda Divriği ilçesi nem verilerine ait tahmin grafiği



Şekil 4.27 ARIMA metodunda Divriği ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.9 Divriği ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması


Divriği	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.44	-	5.55	-	1.43	-
Test MAE	0.40	0.92	6.20	7.05	1.41	1.69
Eğitim RMSE	0.66	-	7.49	-	1.94	-
Test RMSE	0.54	1.87	7.96	9.28	1.89	2.22
Eğitim R^2	0.97	-	0.82	-	0.96	-
Test R^2	0.95	0.13	0.82	0.75	0.95	0.94

4.4 Ulaş İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Ulaş ilçesine ait meteorolojik parametrelerin kullanıldığı LSTM ve ARIMA model yapıları Çizelge 4.10 ve Çizelge 4.11’de verilmiştir.

Çizelge 4.10 Ulaş ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	$5 \cdot 10^{-4}$	$146 \cdot 10^{-5}$	$1 \cdot 10^{-3}$
Decay	$1 \cdot 10^{-2}$	$1 \cdot 10^{-6}$	$1 \cdot 10^{-3}$
İterasyon sayısı	200	100	200
Giriş katmanı	LSTM 16	LSTM 8	LSTM 16
Ara katman	LSTM 8	LSTM 4	LSTM 8
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	64	16	64
Ara parametreler	-	-	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.28 LSTM metodunda Ulaş ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.29 LSTM metodunda Ulaş ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.30 LSTM metodunda Ulaş ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.31 LSTM metodunda Ulaş ilçesi nem verilerine ait tahmin grafiği




Şekil 4.32 LSTM metodunda Ulaş ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.33 LSTM metodunda Ulaş ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.11 Ulaş ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(5,0,2)(0,0,0)	(2,0,3)(0,0,0)	(5,1,2)(5,1,0)
Mevsimsellik	-	-	12



Şekil 4.34 ARIMA metodunda Ulaş ilçesi yağış verilerine ait tahmin grafiği



Şekil 4.35 ARIMA metodunda Ulaş ilçesi nem verilerine ait tahmin grafiği



Şekil 4.36 ARIMA metodunda Ulaş ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.12 Ulaş ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması


Ulaş	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.34	-	6.78	-	1.64	-
Test MAE	0.26	1.02	6.98	7.30	1.69	1.99
Eğitim RMSE	1.05	-	8.75	-	2.25	-
Test RMSE	0.81	2.38	8.89	9.70	2.35	2.66
Eğitim R^2	0.92	-	0.76	-	0.94	-
Test R^2	0.91	0.14	0.70	0.62	0.93	0.90

4.5 Gemerek İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Gemerek ilçesine ait meteorolojik parametrelerin kullanıldığı LSTM ve ARIMA model yapıları Çizelge 4.13 ve Çizelge 4.14’te verilmiştir.

Çizelge 4.13 Gemerek ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	$1 e^{-3}$	$1 e^{-2}$	$1 e^{-2}$
Decay	$1 e^{-2}$	$1 e^{-2}$	$1 e^{-2}$
İterasyon sayısı	100	50	50
Giriş katmanı	LSTM 8	LSTM 32	LSTM 64
Ara katman	LSTM 4	LSTM 32	LSTM 32, Dense 16
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	256	64	512
Ara parametreler	-	Batch Normalization	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.37 LSTM metodunda Gemerek ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.38 LSTM metodunda Gemerek ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.39 LSTM metodunda Gemerek ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.40 LSTM metodunda Gemerek ilçesi nem verilerine ait tahmin grafiği




Şekil 4.41 LSTM metodunda Gemerek ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.42 LSTM metodunda Gemerek ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.14 Gemerek ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(2,0,2)(0,0,0)	(3,0,3)(0,0,0)	(3,0,2)(0,1,2)
Mevsimsellik	-	-	12



Şekil 4.43 ARIMA metodunda Gemerek ilçesi yağış verilerine ait tahmin grafiği



Şekil 4.44 ARIMA metodunda Gemerek ilçesi nem verilerine ait tahmin grafiği



Şekil 4.45 ARIMA metodunda Gemerek ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.15 Gemerek ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması


Gemerek	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.44	-	5.41	-	1.49	-
Test MAE	0.43	0.95	5.60	5.90	1.56	1.61
Eğitim RMSE	0.93	-	6.89	-	2.07	-
Test RMSE	0.87	2.11	7.23	7.90	2.17	2.21
Eğitim R^2	0.88	-	0.80	-	0.95	-
Test R^2	0.86	0.13	0.77	0.72	0.94	0.93

4.6 Suşehri İlçesine Ait Verilerin ARIMA ve LSTM Modelleriyle Tahmini


Suşehri ilçesine ait meteorolojik parametrelerin kullanıldığı LSTM ve ARIMA model yapıları Çizelge 4.16 ve Çizelge 4.17’de verilmiştir.

Çizelge 4.16 Suşehri ilçesinde kullanılan LSTM modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Nem, Sıcaklık, Yağış, Y_{t-1} , Decompose	Nem, Sıcaklık, Yağış, N_{t-1}	Nem, Sıcaklık, Yağış, S_{t-1}
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Eğitim oranı	$1 e^{-4}$	$146 e^{-5}$	$1 e^{-3}$
Decay	$1 e^{-4}$	$1 e^{-3}$	$1 e^{-3}$
İterasyon sayısı	100	200	100
Giriş katmanı	LSTM 32	LSTM 16	LSTM 16
Ara katman	LSTM 32	LSTM 16	-
Çıkış katmanı	Dense 1	Dense 1	Dense 1
Aktivasyon fonksiyonu	ReLU	ReLU	ReLU
Batch boyutu	64	64	64
Ara parametreler	Batch Normalization	-	-
Optimizasyon	Adam optimizasyonu	Adam optimizasyonu	Adam optimizasyonu
Loss fonksiyonu	Mean Squared Error	Mean Squared Error	Mean Squared Error




Şekil 4.46 LSTM metodunda Suşehri ilçesi yağış verilerine ait loss ve dağılım grafiği




Şekil 4.47 LSTM metodunda Suşehri ilçesi yağış verilerine ait tahmin grafiği




Şekil 4.48 LSTM metodunda Suşehri ilçesi nem verilerine ait loss ve dağılım grafiği



Şekil 4.49 LSTM metodunda Suşehri ilçesi nem verilerine ait tahmin grafiği




Şekil 4.50 LSTM metodunda Suşehri ilçesi sıcaklık verilerine ait loss ve dağılım grafiği




Şekil 4.51 LSTM metodunda Suşehri ilçesi sıcaklık verilerine ait tahmin grafiği

Çizelge 4.17 Suşehri ilçesinde kullanılan ARIMA modellerinin özellikleri


Hedef veri	Yağış	Nem	Sıcaklık
Girdi verisi	Yağış	Nem	Sıcaklık
Eğitim seti	Eğitim %70 Test %30	Eğitim %70 Test %30	Eğitim %70 Test %30
Durağanlık	Durağan	Durağan	Durağan değil
Parametreler	(1,0,0)(0,0,0)	(3,0,1)(0,0,0)	(3,0,2)(0,1,2)
Mevsimsellik	-	-	12



Şekil 4.52 ARIMA metodunda Suşehri ilçesi yağış verilerine ait tahmin grafiği



 ekil 4.53 ARIMA metodunda Su ehri il esi nem verilerine ait tahmin grafi i



 ekil 4.54 ARIMA metodunda Su ehri il esi sıcaklık verilerine ait tahmin grafi i

Çizelge 4.18 Suşehri ilçesinde ARIMA ve LSTM sonuçlarının karşılaştırılması

Suşehri	LSTM Yağış	ARIMA Yağış	LSTM Nem	ARIMA Nem	LSTM Sıcaklık	ARIMA Sıcaklık
Eğitim MAE	0.28	-	7.11	-	1.53	-
Test MAE	0.27	0.92	7.49	7.99	1.56	1.64
Eğitim RMSE	0.54	-	9.10	-	2.08	-
Test RMSE	0.50	2.54	9.33	10.39	2.05	2.22
Eğitim R^2	0.97	-	0.65	-	0.94	-
Test R^2	0.96	0.09	0.63	0.53	0.94	0.93

5. TARTIŞMA VE SONUÇ

Bu tez çalışmasında; meteorolojik parametrelerin tahmininin önemi, bu parametreleri tahmini için kullanılan önemli istatistik metodu ARIMA ve derin öğrenme metodu LSTM modellerine dair genel bilgiler verilmiştir. Bu bilgiler ışığında yapılan uygulamalar sonucunda elde edilen sonuçlar her iki modelin tahmin başarısını ortaya koymaktadır.

ARIMA metodunda, AR ve MA parametrelerinin tercihinde kullanılan ACF ve PACF grafikleri haricinde farklı alternatifler de denenmiştir. Durağanlık testi için Dickey-Fuller testi kullanılmış ve yalnızca sıcaklık verilerinde durağanlık tespit edilememiştir. İstatistik alanındaki çalışmalarda yaygın şekilde kullanılan R programlama dilinin kütüphanesinde bulunan ve veriler için en iyi Arima sonucunu özetleyen auto arima fonksiyonu, Python kütüphanesi olan pyramid kütüphanesinde bulunan auto arima fonksiyonu kullanılarak taramalar yapılmıştır. Bu taramaların ve grafik özetlerinin sonucunda veriyi en iyi şekilde temsil eden (p,d,q) değerleri bulunmuş ve tez içerisinde de bu değerlere ilgili istasyon ve parametrede yer verilmiştir. Özellikle her bir ilçedeki nem ve sıcaklık parametrelerine dair bulunan sonuçlar günümüzde halen zaman serileri tahmininde güçlü bir model olduğunu ortaya koymuştur. Yağış parametresine ait sonuçlar ise başarılı derecede sonuçlar vermemiştir.

LSTM metodunda, yağış, nem ve sıcaklık parametreleri için en başarılı sonuçlar aranırken, farklı katmanlar, optimizasyon fonksiyonları, aktivasyon fonksiyonları, öğrenme oranları ve iterasyon sayılarının kombinasyonları denenmiştir. Genel olarak tüm parametrelerde katman sayısının ve nöron miktarının artışı bir noktaya kadar öğrenmeyi güçlendirerek daha başarılı sonuçlar ortaya konmasını sağlamış olsa da modeller için en iyi öğrenme noktalarından sonra arttırılan bu değerler başarıya olumlu veya olumsuz etki etmemiş ya da aşırı öğrenme (overfitting) durumunu ortaya çıkarmıştır. Tez çalışmasında denenilen bu kombinasyonlar içerisinde aşırı öğrenmeye maruz kalmamış ve diğer kombinasyonlardan daha başarılı, özetle model için en iyi sonuçların alındığı değerlere ve sonuçlara yer verilmiştir. En başarılı kombinasyon aranırken Çizelge 3.4'te yer verilen hiperparametreler ile çalışılmış, çalışmanın sonuç kısmında en başarılı bulunan hiperparametrelere yer verilmiştir.

Derin öğrenme metotlarında $1e^{-3}$, $5e^{-4}$, $146e^{-5}$ öğrenme oranlarının ağırların diğer öğrenme oranlarına kıyasla daha hızlı yakınsamada bulundukları gözlemlenmiştir. Bu çalışmada da en iyi kombinasyon aranırken bu değerlere de yer verilmiş ve sonuçlar kısmında çoğu denemede en iyi sonucun bu değerler ile sağlandığı gözlemlenmiş ve kullanılmıştır (Jindal vd. 2020).

Her iki metodun da nem ve sıcaklık parametrelerinde uygulamalarının sonuçları tatmin edici düzeyde başarılı olmuştur. Ancak LSTM uygulamalarının tamamı ARIMA uygulamalarından daha başarılı bulunmuştur. İki modelin nem ve sıcaklık parametrelerinde en başarılı ve yakın bulunduğu sonuç Divriği ilçesine ait sıcaklık parametresinde LSTM için $0.95 R^2$, ARIMA için $0.94 R^2$ sonuçlarına sahiptir. Divriği ve Kangal ilçelerinin sıcaklık tahmini sonuçlarında da görülen bu yakınlık diğer ilçeler ve parametrelerinde yerini daha büyük farklara bırakmaktadır. MAE ve RMSE değerlendirme metriklerinde de tüm sonuçlarda LSTM modelleri açık şekilde daha başarılı sonuçlar vermiştir.

Yağış verilerinde ise girdi verisi olarak sadece yağış verilerini kullanan ARIMA modelleri kabul edilebilir başarı sınırları dışında kalmıştır. LSTM modelinde ise farklı parametrelere ait verilerle birlikte decompose edilmiş verilerin kullanılması, LSTM modeliyle yağış parametresine dair başarılı sonuçlar elde edilmesine olanak tanımıştır. Bu özelliğiyle LSTM modeli ARIMA modeline göre üstün bulunmuştur. Çizelge 5.1’de her iki metodun tüm ilçelerin sonuçlarına ait minimum ve maksimum R^2 sonuç aralıkları verilmiştir.

Çizelge 5.1 ARIMA ve LSTM modellerinde ilgili parametrelere ait R^2 sonuç aralıkları

ARIMA YAĞIŞ R^2	0.06 – 0.14
LSTM YAĞIŞ R^2	0.86 - 0.96
ARIMA NEM R^2	0.53 – 0.75
LSTM NEM R^2	0.63 – 0.82
ARIMA SICAKLIK R^2	0.87 – 0.94
LSTM SICAKLIK R^2	0.92 – 0.95

Her iki modelin tüm ilçelere ait parametrelerde bütün değerlendirme metriklerinde en başarılı sonuçlar LSTM uygulamalarında bulunmuştur. LSTM metodu başarılı, tutarlı ve geliştirmeye açıktır. ARIMA metodunda yalnızca ARIMA parametreleri ile denemeler yapılabilirken, LSTM metodunda daha önce bahsedilen farklı modellerin ve katmanların bir arada kullanılabilmesi, farklı verilerin bir arada kullanılabilmesi sayesinde daha başarılı sonuçlar alınabilmesi ve gelişmeye açık olmasıyla tercih sebebidir. Farklı kombinasyonların denenebilmesi, bu denemelerin gelecekte de geliştirilebilecek olması LSTM metodunu öne çıkarmaktadır. ARIMA ise, kullanım kolaylığı ve erişilebilirlik açısından tercih edilebilir bir metot olarak görünmektedir. LSTM metodunda ise başarılı sonuçlara ulaşmak için fazlaca kombinasyon denenmesi gerekliliği ve görece daha güçlü bilgisayar donanımına ihtiyaç duyulması olumsuz yönler olarak sayılabilecekken, farklı modellerin ve katmanların bir arada güçlü şekilde kullanılabilmesi, farklı verilerin bir arada kullanılabilmesi sayesinde daha başarılı sonuçlar alınabilmesi ve kontrol edilebilirliği sebebiyle gelişmeye açık olmasıyla önerilmektedir.

Çalışmadan elde edilen sonuçlar ışığında, LSTM metoduyla yağış, nem ve sıcaklık parametrelerinin tahmininin başarılı şekilde yapılmasıyla, tarımsal açıdan sulama takvimi planlaması, ekim-dikim zamanının belirlenmesi ve tahminlere uygun düzenlenmesi açısından yararlanılabilmektedir. Ayrıca çalışma sonuçlarının, mevsimsel aşırı durumların önceden tespiti ve buna göre olası afet, yetiştiricilik yönünden olumsuz hava olayları ile bölgesel ve dönemsel kuraklık gibi tarımsal sorunlara karşı hazırlıklı olunması konusunda da yol gösterici ve önlem almayı sağlayıcı etkide bulunması beklenmektedir. Bu bakımdan çalışma çıktılarının tarımsal üretimde verim ve ürün kayıplarını azaltması, buna bağlı olarak tarımsal gelirin artışının sağlanması konusunda olumlu etkide bulunması beklenmektedir.

KAYNAKLAR

- Akbari Asanjan, A., Yang, T., Hsu, K., Sorooshian, S., Lin, J., & Peng, Q. 2018. Short-term precipitation forecast based on the PERSIANN system and LSTM recurrent neural networks. *Journal of Geophysical Research: Atmospheres*, 123(22); 12-543.
- Alabdulrazzaq, H., Alenezi, M. N., Rawajfih, Y., Alghannam, B. A., Al-Hassan, A. A., & Al-Anzi, F. S. 2021. On the accuracy of ARIMA based prediction of COVID-19 spread. *Results in Physics*, 27, 104509.
- Amidi, A. ve Amidi, S. 2021. Web Sitesi: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-recurrent-neural-networks> Eriřim Tarihi: 22.12.2021.
- Anonim. 2018. T.C. Sivas Valilięi Tarım ve Orman İl Müdürlüęü 2018 Yılı Faaliyet Raporu, Sivas.
- Anonim. 2021. Web Sitesi: <https://yearofthefly.org/10447/sivas-haritasi/sivas-map-and-sivas-satellite-image-sivas-haritasi/> Eriřim Tarihi: 20.12.2021
- Bari, S. H., Rahman, M. T., Hussain, M. M., & Ray, S. 2015. Forecasting monthly precipitation in Sylhet city using ARIMA model. *Civil and Environmental Research*, 7(1); 69-77.
- Borna, A. A., Ani, A. A., Ashhab, M., & Saleh, S. 2021. High frequency rainfall prediction using machine learning approach to numerical weather modelling (Doctoral dissertation, Brac University).
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. 2015. *Time series analysis: forecasting and control*. John Wiley & Sons.
- Brown, R. G. 2004. Smoothing, forecasting and prediction of discrete time series. Courier Corporation.
- Colah's Blog. 2015. Web Sitesi: <https://colah.github.io/posts/2015-08-Understanding-LSTMs/> Eriřim Tarihi: 21.12.2021.
- Çaęıl, G. 2017. Mevsimlik Olmayan Box-Jenkins Modellerinde İki Ařamalı Yapay Sinir Ağlarının Kullanılması. *ACADEMIC PLATFORM-JOURNAL OF ENGINEERING AND SCIENCE*, 5(3); 123-130.
- De Gooijer, J. G., and Hyndman, R. J. 2006. 25 years of time series forecasting . *International journal of forecasting*, 22(3); 443-473.
- De Saa, E., & Ranathunga, L. 2020. Comparison between ARIMA and Deep Learning Models for Temperature Forecasting. *arXiv preprint arXiv:2011.04452*.

- Dickey, D.A. and Fuller, W.A. 1979. "Distribution of the Estimators for Autoregressive Time Series with a Unit Root," *Journal of the American Statistical Association*, 74, p. 427–431
- Dubey, A. K., Kumar, A., García-Díaz, V., Sharma, A. K., & Kanhaiya, K. 2021. Study and analysis of SARIMA and LSTM in forecasting time series data. *Sustainable Energy Technologies and Assessments*, 47, 101474.
- Duong, T. A., Bui, M. D., & Rutschmann, P. 2018. Long Short Term Memory for monthly rainfall prediction in Camau.
- Gers, F. A., Schmidhuber, J., & Cummins, F. 2000. Learning to forget: Continual prediction with LSTM. *Neural computation*, 12(10); 2451-2471.
- Hochreiter, S., Schmidhuber, J. 1997. "Long Short-Term Memory," *Neural Computation* 9(8); 1735-1780.
- Jindal, H., Sardana, N., & Mehta, R. 2020. Analyzing performance of deep learning techniques for web navigation prediction. *Procedia Computer Science*, 167, 1739-1748.
- Kaneko, R., Nakayoshi, M., & Onomura, S. 2019. Rainfall Prediction by a Recurrent Neural Network Algorithm LSTM Learning Surface Observation Data. In *AGU Fall Meeting Abstracts* (Vol. 2019, pp. GC43D-1354).
- Kaynar, O., & Taştan, S. 2009. Zaman serileri tahmininde arima-mlp melez modeli. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 23(3); 141-149.
- Kendal, M.G. 1973. *The advanced Theory of Statics*, Charles Griffin, London, sf: 506-507
- Kingma, D. P., & Ba, J. 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kumar, A., Islam, T., Sekimoto, Y., Mattmann, C., & Wilson, B. 2020. Convcast: An embedded convolutional LSTM based architecture for precipitation nowcasting using satellite data. *Plos one*, 15(3), e0230114.
- Li, Z., Zou, H., & Qi, B. 2019. Application of ARIMA and LSTM in Relative Humidity Prediction. In *2019 IEEE 19th International Conference on Communication Technology (ICCT)* (pp. 1544-1549). IEEE.
- MGM. 2021. Web Sitesi: <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?m=SIVAS> Erişim Tarihi: 20.12.2021
- Ouma, Y. O., Cheruyot, R., & Wachera, A. N. 2021. Rainfall and runoff time-series trend analysis using LSTM recurrent neural network and wavelet neural network

with satellite-based meteorological data: case study of Nzoia hydrologic basin. *Complex & Intelligent Systems*, 1-24.

- Pasaribu, Y. P., Fitrianti, H., & Suryani, D. R. 2018. Rainfall forecast of merauke using autoregressive integrated moving average model. In *E3S Web of Conferences* (73); 12010. EDP Sciences.
- Pichotta, K., & Mooney, R. 2016. Learning statistical scripts with LSTM recurrent neural networks. In *Proceedings of the AAAI Conference on Artificial Intelligence* 30(1).
- Poornima, S., & Pushpalatha, M. 2019. Prediction of rainfall using intensified LSTM based recurrent neural network with weighted linear units. *Atmosphere*, 10(11); 668.
- Salman, A. G., Heryadi, Y., Abdurahman, E., & Suparta, W. 2018. Single layer & multi-layer long short-term memory (LSTM) model with intermediate variables for weather forecasting. *Procedia Computer Science*, 135; 89-98.
- Samad, A., Gautam, V., Jain, P., & Sarkar, K. (2020, October). An Approach for Rainfall Prediction Using Long Short Term Memory Neural Network. In *2020 IEEE 5th International Conference on Computing Communication and Automation (ICCCA)* (pp. 190-195). IEEE.
- Sekertekin, A., Bilgili, M., Arslan, N., Yildirim, A., Celebi, K., & Ozbek, A. 2021. Short-term air temperature prediction by adaptive neuro-fuzzy inference system (ANFIS) and long short-term memory (LSTM) network. *Meteorology and Atmospheric Physics*, 1-17.
- Tektaş, M. 2010. Weather forecasting using ANFIS and ARIMA models. *Environmental Research, Engineering and Management*, 51(1); 5-10.
- TÜİK. 2020. Web Sitesi: <https://biruni.tuik.gov.tr/medas/?kn%3D95%26locale%3Dtr> Erişim Tarihi: 20.12.2021
- Wu, X., Zhou, J., Yu, H., Liu, D., Xie, K., Chen, Y., ... & Xing, F. 2021. The Development of a Hybrid Wavelet-ARIMA-LSTM Model for Precipitation Amounts and Drought Analysis. *Atmosphere*, 12(1); 74.