

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
TARIMSAL YAPILAR VE SULAMA ANA BİLİM DALI**



**SUDAN'IN GÜNLÜK REFERANS BİTKİ SU TÜKETİMİNİN
DETERMİNİSTİK VE STOKASTİK YÖNTEMLERLE MODELLENMESİ**

Doktora Tezi

Mawadda AHMED MOHAMMED ABDALLAH

Danışman
Prof.Dr. Bilal CEMEK

SAMSUN
2023

TEZ KABUL VE ONAYI

Mawadda ABDALLAH tarafından, Prof. Dr. Bilal CEMEK danışmanlığında hazırlanan “SUDAN’IN GÜNLÜK REFERANS BİTKİ SU TÜKETİMİNİN DETERMİNİSTİK VE STOKASTİK YÖNTEMLERLE MODELLENMESİ” başlıklı bu çalışma, jürimiz tarafından 23.1.2023 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Doktora Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Prof. Dr. Ali ÜNLÜKARA Erciyes Üniversitesi Arazi ve Su Kaynakları Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Prof. Dr. Bilal CEMEK (Danışman)Ondokuz Mayıs Üniversitesi Tarımsal Yapılar ve Sulama Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Prof. Dr. Vedat CEYHAN Ondokuz Mayıs Üniversitesi Tarım İşletmeciliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Prof. Dr. Hakan ARSLAN Ondokuz Mayıs Üniversitesi Tarımsal Yapılar ve Sulama Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Prof. Dr. Ramazan MERAL Bilecik Şeyh Edebali Üniversitesi Tarımsal Yapılar Ana Bilim Dalı	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Doktora tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

23 /01 / 2023

Mawadda ABDALLAH

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : SUDAN'IN GÜNLÜK REFEREANS BİTKİ SU TÜKETMİNİN DETERMİNSTİK VE STOKASTİK YÖNTEMLERLE MODELLENMESİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 19.12.2022 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 8

Tek kaynak oranı : % 2 çıkmıştır.

20/12/ 2022

Prof. Dr. Bilal CEMEK

ÖZET

SUDAN’IN GÜNLÜK REFERANS BİTKİ SU TÜKETİMİNİN DETERMİNİSTİK VE STOKASTİK YÖNTEMLERLE MODELLENMESİ

Mawadda AHMED MOHAMMED ABDALLAH

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Tarımsal Yapılar Ve Sulama Ana Bilim Dalı

Doktora, Ocak/2023

Danışman: Prof. Dr. Bilal CEMEK

Bitki su tüketimi bir sulama projesinin temel verisi ve sulama uygulamalarının en önemli unsurlarından birisidir. Sulama sistemlerinin yatırım maliyetleri çok yüksek olup bu sistemlerin planlanmasında bitkilerin su tüketimlerinin belirlenmesinde iklim parametelerinin dikkate alınması çok önemlidir. Referans evapotranspirasyonu (ETo) tahmin etmek için doğru modellerin geliştirilmesi, özellikle su kaynaklarının sınırlı olduğu kurak ve yarı kurak bölgelerde etkin su yönetimi için gereklidir. Bu çalışmada referans bitki su tüketimi (ETo) ASCE Penman Monteith eşitliği kullanılarak Sudandaki 120 istasyonun günlük iklim verileri gözönüne alınarak hesaplanmıştır. Çalışmada üç aşamada gerçekleştirilmiştir. Birinci aşamada zaman serileri ile ETo tahmini, ikinci aşamada farklı enterpolasyon teknikleri ile Sudan için ETo haritaları elde edilmiştir. Üçüncü aşamada çoklu regresyon ve yapay zeka uygulamaları ile ETo tahmini gerçekleştirilmiştir. Sudan’ın 33 ilinde Otoresif Entegre Hareketli Ortalama (ARIMA) modelleri ile analizler yapılmıştır. İkinci yöntem’de, Enterpolasyon yöntemlerinden Ordinary Kriging, Basit Kriging, ve Ters Mesafe Ağırlığı (IDW) yöntemlerini kullanılmıştır. Jeostatistik analiz sonuçlarına göre Gaussian, Exponential, ve Spherical en iyi yarı variogram modelleri çıkmıştır. Üçüncü yöntem’de çoklu doğrusal regresyon, çok katmanlı yapay sinir ağları (ÇKYSA) ve Bulanık yapay sinir ağları sistemini (ANFIS) uygulanmıştır. Girdi verileri olarak hem yapay zeka modellerinde hem de geleneksel çoklu regresyon modellerinde bağıl nem, sıcaklık, rüzgar hızı ve güneş radyasyonu değişkenlerini kullanılmış ve çıktı verisi olarak ETo tahmini başarılı olarak yapılmıştır. Deterministik ve stokastik modeller Sudan’ın su kaynakları yönetimi ve sulama planlaması için yararlı bir araç olacağı ortaya konmuştur.

Anahtar Sözcükler: Referans bitki su tüketimi, Zaman serisi, yapay sinir ağları, Bulanık yapay sinir ağları, Sudan

ABSTRACT

MODELING OF DAILY REFERENCE EVAPOTRANSPIRATION USING DETERMINISTIC AND STOCHASTIC METHODS OF SUDAN

Mawadda AHMED MOHAMMED ABDALLAH

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Agricultural Structures and Irrigation

Ph.D., January/2023

Supervisor: Prof. Dr. Bilal CEMEK

Plant water consumption is the basic data of an irrigation project and one of the most important elements of irrigation applications. The investment costs of irrigation systems are very high, and it is very important to consider climate parameters for determining the water consumption of plants in the planning of these systems. The development of accurate models to predict reference evapotranspiration (ET₀) is necessary for effective water management, especially in arid and semi-arid regions where water resources are limited. In this study, reference plant water consumption (ET₀) was calculated by considering the daily climate data of 120 stations in Sudan using the ASCE Penman-Monteith equation. The study was carried out in three stages. In the first stage, estimating of ET₀ by time series, and in the second stage, maps of ET₀ for Sudan were obtained by different interpolation techniques. In the third stage, the estimation of ET₀ was carried out with multiple regression and artificial intelligence applications. Autoregressive Integrated Moving Average (ARIMA) models were used for analyses in 33 provinces of Sudan. In the second method, Ordinary Kriging, Simple Kriging, and Inverse Distance Weight (IDW) methods were used from interpolation methods. According to the results of geostatistical analysis, Gaussian, Exponential, and Spherical are the best semi-variogram models. In the third method, multiple linear regression, multilayer artificial neural networks (MLP), and fuzzy artificial neural network system (ANFIS) were applied. ET₀ estimation was successfully performed using relative humidity, temperature, wind speed, and solar radiation variables as input data in both artificial intelligence models and traditional multiple regression models, and ET₀ was used as output data. Deterministic and stochastic models will serve as useful tools for Sudan's water resource management and irrigation planning.

Keywords: Reference, plant Water Consumption, Time Series, Artificial Neural Network, Fuzzy Artificial Neural network, Sudan

ÖN SÖZ VE TEŞEKKÜR

Çalışma sürecinde her türlü yol gösterici olan, olumlu tavrıyla beni destekleyen, bilgi birikimiyle çalışmama farklı açılardan bakmamı sağlayan beraber çalışmaktan ve her zaman öğrencisi olmaktan gurur duyduğum değerli danışman hocam Prof. Dr. Bilal CEMEK'e sonsuz teşekkür ederim. Son olarak tüm hayatım boyunca benim yanımda olan, aldığım kararları her zaman destekleyen, sadece bu çalışma sürecinde değil tüm hayatım boyunca beni cesaretlendiren ve moral veren annem Mona Hussein'e, babam Ahmed Mohammed'e ve kardeşlerim Yusuf, Yousra, ve Yassir'e sonsuz şükranlarımı sunar teşekkür ederim.

Mawadda AHMED MOHAMMED ABDALLAH

İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	viii
TABLolar DİZİNİ	x
1. GİRİŞ	1
2. LİTERATÜR TARAMASI	4
2.1. ASCE Penman-Monteith denklemi	4
2.2. Zaman serileri analiz teknikleri	6
2.3. Mekansal veya Konumsal Enterpolasyon Teknikleri	9
2.4. Yapay Sinir Ağları Yöntemleri	11
3. MATERYAL VE METOT	15
3.1. Çalışma Alanı	15
3.2. Veri setlerinin Hazırlanması	15
3.3. Tahmin Yöntemleri	16
3.3.1. ASCE Penman-Monteith yöntemi:	17
3.3.2. Refereans Evapotraspirasyonu parametrelerinin Analiz İçin Hazırlanması	18
3.3.3. Zaman Serileri Analiz Teknikleri	18
3.3.4. Enterpolasyon Yöntemleri	22
3.3.5. Çoklu Doğrusal Regresyon Uygulamaları	25
3.3.6. Yapay Zeka Uygulamaları	25
4. BULGULAR VE TARTIŞMA	32
4.1. Otoregresif Entegre Hareketli Ortalama Modelleri (ARIMA)	33
4.1.1. Zaman Serisi Modellerinin Değerlendirilmesi (ARIMA modelleri)	34
4.2. Enterpolasyon Teknikleri	58
4.2.1. Ordinary Kriging Yöntemini Değerlendirilmesi	64
4.2.2. Basit Kriging Yönteminin Değerlendirilmesi	86
4.2.3. Ters Mesafe Ağırlığının Yönteminin Değerlendirilmesi (IDW)	108
4.2.4. Mekansal Enterpolasyon Yöntemlerinin En iyi Modelleri	130
4.3. Çoklu Doğrusal Regresyon Yöntemi	131
4.4. Yapay Zeka Uygulamaları	137
4.4.1. Çok Katmanlı Yapay Sinir Ağları Yöntemi	137
4.4.2. Bulanık Yapay Sinir Ağları (ANFIS)	144
5. SONUÇ VE ÖNERİLER	158
KAYNAKLAR	161
ÖZ GEÇMİŞ	167

SİMGELER VE KISALTMALAR

ET ₀	: Referans Bitki Su Tüketimi (mm gün ⁻¹)
ASCE	: Amerikan İnşaat Mühendisleri Derneği
PM	: Penman Montheith
C _d	: Payda referans bitki tipi ve zamansal değişen katsayı (sm ⁻¹)
C _n	: Pay referans bitki tipi ve zamansal değişen katsayı (K mm s 3mg ⁻¹ d ⁻¹)
e _s	: Doyma Buhar Basıncı (kPa)
(e _s -e _a)	: Doyma Buhar Basıncı Açığı (kPa)
R _h	: Bağlı Nem (%)
R _n	: Kırpma Yüzeyi Net Radyasyon (MJm ⁻² day ⁻¹)
R _s	: Güneş Radyasyon (MJm ⁻² day ⁻¹)
T	: Ortalama Sıcaklığı (C ⁰)
U ₂	: Rüzgar Hızı (2m yükseklikte) (m/s)
W	: Rüzgar (m/s)
γ	: Psikrometrik Sabiti (kPa °C ⁻¹)
λ	: Buharlaşma Gizli Isı
Δ	: Eğim Buhar Basıncı, (kPa)
YSA	: Yapay Sinir Ağları
ANFIS	: Adaptif Sinirsel Bulanık Çıkarım Sistemi
ÇKYSA	: Çok Katmanlı Yapay Sinir Ağları
LM	: Levenberg-Marquardt
MAE	: Ortalama Mutlak Hata
R ²	: Belirleme Katsayısı
RMSE	: Tahmin Hatası Standart Sapması
AIC	: Akaike Bilgi Kriteri
BIC	: Bayesian Bilgi Kriteri
Xi	: Gözlenen Değer
OK	: Ordinary Kriging
PACF	: Partial Otokorelasyon Fonksiyonu
ACF	: Otokorelasyon Fonksiyonu
ARIMA	: Otoregresif Enteger Hareketli Ortalama

ŞEKİLLER DİZİNİ

Şekil 3. 2. Tahmin yöntemleri.....	16
Şekil 3. 3. Çok Katmanlı Yapay Sinir Ağının yapısı	27
Şekil 3. 4 . Bulanık Yapay Sinir Ağının yapısı.....	28
Şekil 4. 1. 1982-2020 ET ₀ verilerin grafikleri.....	43
Şekil 4. 2. Her istasyon için ACF ve PACF grafikleri.....	52
Şekil 4. 3. ASCE PM ET ₀ ve tahmin referans evapotranspirasyon değerlerinin karşılaştırılması	58
Şekil 4. 4. Yarıvariogram modellerinin parametreleri	63
Şekil 4. 5. Her ayın hata grafiklerinin dağılımları	68
Şekil 4. 6. ASCE PM ve tahmin edilen ET ₀ 'nın değerlerinin dağılım grafikleri	72
Şekil 4. 7. Ordinary Kriging haritası (Ocak).....	74
Şekil 4. 8. Ordinary Kriging haritası (Şubat)	75
Şekil 4. 9. Ordinary Kriging haritası (Mart)	76
Şekil 4. 10. Ordinary Kriging haritası (Nisan).....	77
Şekil 4. 11. Ordinary Kriging haritası (Mayıs)	78
Şekil 4.12. Ordinary Kriging haritası (Haziran).....	79
Şekil 4. 13. Ordinary Kriging (Temmuz).....	80
Şekil 4. 14. Ordinary Kriging (Ağustos).....	81
Şekil 4. 15. Ordinary Kriging (Eylül)	82
Şekil 4. 16. Ordinary Kriging (Ekim)	83
Şekil 4. 17. Ordinary Kriging (Kasım)	84
Şekil 4. 18. Ordinary Kriging (Aralık).....	85
Şekil 4.19. Hataların aylara göre dağılım grafikleri.....	90
Şekil 4. 20. ET ₀ 'ın gerçek ve öngörülen değerlerinin dağılım grafikleri.....	94
Şekil 4. 21. Basit kriging haritası (Ocak).....	96
Şekil 4. 22. Basit Kriging Haritası (Şubat)	97
Şekil 4. 23. Basit Kriging haritası (Mart).....	98
Şekil 4. 24. Basit kriging haritası (Nisan).....	99
Şekil 4. 25. Basit kriging (Mayıs)	100
Şekil 4. 26. Basit kriging (Haziran)	101
Şekil 4. 27. Basit Kriging (Temmuz).....	102
Şekil 4. 28. Basit Kriging haritası (Ağustos)	103
Şekil 4. 29. Basit Kriging haritası (Eylül).....	104
Şekil 4. 30. Basit Kriging haritası (Ekim).....	105
Şekil 4. 31. Basit Kriging haritası (Kasım)	106
Şekil 4. 32. Basit Kriging haritası (Aralık)	107
Şekil 4. 33. Hataların aylara göre dağılım grafikleri.....	112
Şekil 4. 34. ET ₀ 'ın ve öngörülen değerlerinin dağılım grafikleri	116
Şekil 4. 35. Ters Mesafe Ağırlığın haritası (Ocak)	118
Şekil 4. 36. Ters Mesafe Ağırlığın haritası (Şubat)	119
Şekil 4. 37. Ters Mesafe Ağırlığın haritası (Mart).....	120
Şekil 4. 38. Ters Mesafe Ağırlığın haritası (Nisan)	121
Şekil 4. 39. Ters Mesafe Ağırlığın (Mayıs)	122
Şekil 4. 40. Ters Mesafe Ağırlığın haritası (Haziran).....	123
Şekil 4. 41. Ters Mesafe Ağırlığın haritası (Temmuz)	124
Şekil 4. 42. Ters Mesafe Ağırlığın haritası (Ağustos)	125
Şekil 4. 43. Ters Mesafe Ağırlığının haritası (Eylül).....	126

Şekil 4. 44. Ters Mesafe Ağırlığın haritası (Ekim).....	127
Şekil 4. 45. Ters Mesafe Ağırlığın haritası (Kasım).....	128
Şekil 4. 46. Ters Mesafe Ağırlığın haritası (Aralık).....	129
Şekil 4. 47. Farklı iklim kombinasyonlarına dayalı modellerle tahmin edilen ET ₀ ve ASCE PM ET ₀ karşılaştırılması (Eğitim ve test)	136
Şekil 4. 48. ÇKYSA ile tahmin edilen ET ₀ (mm / gün) ve ASCE Penman–Monteith karşılaştırılması	139
Şekil 4. 49. ÇKYSA ile tahmin edilen ET ₀ (mm / gün) ve ASCE Penman–Monteith karşılaştırılması	140
Şekil 4. 50. ÇKYSA tahmin ET edilen ET ₀ (mm / gün) ve ASCE Penman Monthith ET ₀ karşılaştırılması	141
Şekil 4. 51. ÇKYSA tahmin edilen ET ₀ ve ASCE Penman Monthieth ET ₀ değerlerinin Karşılaştırılması	142
Şekil 4. 52. ÇKYSA tahmin edilen ET ₀ ve ASCE Penman Monthith ET ₀ karşılaştırılması	143
Şekil 4. 53. ÇKYSA tahmin edilen ET ₀ ve ASCE Penman Monthith ET ₀ karşılaştırılması	144
Şekil 4. 54. ANFIS tahmini ET ₀ (mm / gün) ve ASCE PM ET ₀ (mm/gün) karşılaştırılması	146
Şekil 4. 55. ANFIS tahmini ET ₀ (mm / gün) ve ASCE PM ET ₀ (mm/gün) karşılaştırılması	147
Şekil 4. 56. ANFIS tahmini ET ₀ (mm / gün) ve ASCE PM ET ₀ (mm/gün) karşılaştırılması	148
Şekil 4. 57. Sıcaklık (C0) ve Güneş radyosunu dayalı model, ASCE PM ET ₀ ve ET ₀ tahmini (mm/gün) karşılaştırılması	149
Şekil 4. 58. Sıcaklık, Rüzgar, ve güneş radyosununa dayalı model, tahmin ve ASCE heaplanan ET ₀ karşılaştırılması.....	150
Şekil 4. 59. Sıcaklık, rüzgar, güneş radyosunu, ve bağıl nem dayalı model, gerçek ve tahmin ET ₀ karşılaştırılması	151
Şekil 4. 60. Matlab arayüzde referans evapotranspirasyonu tahmin oluşturulan model görünümü	153
Şekil 4. 61. Sıcaklık ve güneş radyosunu dayalı model, ASCE PM ET ₀ ve ANFIS modelleri tahmini karşılaştırılması (Eğitim).....	156
Şekil 4. 62. Sıcaklık ve güneş radyosunu dayalı model, ASCE PM ET ₀ ve ANFIS tahmin edilen ET ₀ 'nın değerlerinin karşılaştırılması (test)	157

TABLÖLAR DİZİNİ

Tablo 4. 1. Sudan'ın 33 il merkezi için ET_0 değerlerine ait Tanımlayıcı İstatistikler	33
Tablo 4. 2. Her istasyon için ARIMA modellerinin parametreleri	53
Tablo 4. 3. ET_0 değerlerine ait izotropik yarıvariogram bileşenleri	59
Tablo 4. 4. Referans evapotranspirasyonun Ordinary kriging yöntemi ile tahminin içi,n modeller ve hata değerleri.....	64
Tablo 4. 5.Yarı variogram parametrelerine göre basit Kriging modelleri	86
Tablo 4. 6. Ters mesafe ağırlığı modelinin parametreleri (IDW)	108
Tablo 4. 7. R^2 ve RSS değerlerine dayalı yarı varyans parametrelerini kullanan mekansal otokorelasyon yöntemlerinin en iyi modelleri	130
Tablo 4. 8. RMSE ve MSE değerlerine dayalı en iyi uzamsal enterpolasyon yöntemleri	131
Tablo 4. 9. Sudan'da ET_0 için çoklu doğrusal regresyonun parametrelerin özeti....	133
Tablo 4. 10. Eğitim ve test aşamalarındaki MLR modellerinin MAE, RMSE ve R^2 istatistikleri.....	134
Tablo 4. 11. Eğitim ve Test için İklim Değişkenlerin Tanımlayıcı İstatistikleri	137
Tablo 4. 12. Eğitim ve test veri sitelerindeki ÇKYSA modellerinin istatistikleri ...	138
Tablo 4. 13. Eğitim ve test değerlendirme veri kümelerinde ANFIS modellerinin istatistikleri.....	145
Tablo 4. 14. ANFIS (Takagi- Sugeno) bulanık mantık Kuralları ve parametreleri .	153
Tablo 4. 15. Eğitim aşamalarındaki ANFIS modellerinin MAE, RMSE ve R^2 istatistikleri.....	154

1. GİRİŞ

Su kıtlığı, dünyadaki birçok gelişmiş ve gelişmekte olan ülkeler için önemli bir sorundur. Genellikle bir gıda krizinin ortaya çıkmasına neden olan ciddi bir tehditle sonuçlanmaktadır. Su kıtlığı arttıkça, mevcut su kaynaklarını yönetme talebi çok önemli hale gelmektedir (Khan et al., 2011). Tarımda su kaynaklarının verimli planlanması, geliştirilmesi ve yönetimi için, bitki su tüketimi (ET)'nin tahmini oldukça önemlidir. (V. Kumar, 2007).

ET, su dengesi çalışmaları için en önemli hidrolojik bileşenlerden biridir ve sulama suyu gereksinimlerinin tahmininde önemli bir rol oynamaktadır (Nikam et al., 2010). ET, toprak ve bitki yüzeylerinden buharlaşmanın birleşik süreçleri ve bitki terlemesi ile atmosfere su kaybıdır (Rojas and Sheffield, 2013). ET'yi etkileyen çeşitli faktörler bulunmaktadır ve bu nedenle kolaylıkla modellenmesi mümkün değildir (Bachour et al., 2016).

ET'yi etkileyen en önemli faktörler iklimsel parametrelerdir (Caminha et al., 2017). Doğal bir süreç olan ET süreci, zamansal ve mekânsal olarak değişen sıcaklık, güneş radyasyonu ve nem gibi faktörler tarafından kontrol edilir ve ET, bu etkileyen faktörler açısından ifade edilir (Mohan and Arumugam, 1995).

ET bir lizimetre veya su bütçesi yaklaşımı ile ölçülebilir veya klimatolojik verilerden tahmin edilebilir. ET'nin bir lizimetre ile ölçülmesi zaman alıcıdır ve bakım gerektirir dikkatli planlama Lizimetreler kurulum ve bakım için daha vasıflı işgücü gerektirir, bu nedenle bu nedenlerden dolayı, ET'yi tahmin etmek için iklimsel verilere dayanan dolaylı yöntemler kolay bir şekilde kullanılır (Jain et al., 2008).

Bitki su tüketimi (ET_c), referans bitki su tüketimi (ET_o)'nin ve referans çim yüzeyi arasındaki ET farkı ifade eden bir katsayı olan K_c ile çarpılmasıyla hesaplanır. Fark, tek bir katsayı halinde birleştirilebilir veya her iki yüzey arasındaki buharlaşma ve terlemedeki farklılıkları ayrı ayrı açıklayan iki faktöre ayrılabilir.

ET_o çok yıllık bir çim gibi bir referans mahsulden doğrudan ölçülebilir veya sıcaklık modelleri, radyasyon kullanılarak hava verilerinden hesaplanabilir tartım modelleri ve kombinasyon modelleri lizimetreler, ET_o ve ET_c 'yi doğrudan ölçmek için kullanılır.

Gocić et al. (2015)'ye göre birçok ampirik eşitlik ET_o modifiye edilerek kullanılmaktadır. Penman Monteith (PM) denklemi saatlik, günlük, ve aylık ET_o dahil olmak üzere farklı zaman adımları için kabul edilen ve Birleşmiş Milletler Gıda ve

Tarım Örgütü (FAO) Dünya Meteoroloji Örgütü tarafından tavsiye edilmiştir (Dai et al., 2009).

ET, sıcaklık, bağıl nem, güneş radyasyonu, rüzgar hızı, bitkinin büyüme aşaması gibi çeşitli etkileşimli iklimsel faktörlere bağımlılığı nedeniyle karmaşık doğrusal olmayan bir fenomendir (Nikam et al., 2010).

ET₀, su ve enerji dengesi çalışmalarında ihtiyaç duyulan önemli bir parametredir. Ayrıca, iklim, tarım ve ekoloji ile ilgili çeşitli çalışmalarda gereklidir.

Bu çalışmada Sudan genelinde 120 ana ve alt meteoroloji istasyonundan alınan iklim verileri, bağıl nem, sıcaklık, rüzgar hızı ve radyasyon gibi farklı parametreler kullanılarak ET₀ değerlerini hesaplanmıştır. Yapay zeka uygulamaları arasında ET₀, jeoistatistik ve ARIMA modelleriyle karşılaştırılan makine öğrenimi teknikleri kullanılarak tahmin edilmektedir. Bu çalışma üç aşamada değerlendirilmiştir.

- Zaman serisi analiz modelleri,
- Enterpolasyon yöntemleri,
- Yapay zekâ uygulamaları.

ET₀ tahmini, hidrolik tasarımlarda ve sulama yönetiminde önemli bir rol oynamaktadır. Bilindiği gibi, ET işlemi, esas olarak yüksek doğrusallık veya durağansızlık tarafından yönlendirilen karmaşık bir işlemdir. Ayrıca, ET₀ zaman serisinin durağanlık dışı doğası, gelecekteki değerlerin tahmin edilmesinde zorluklara yol açmaktadır (Bachour et al., 2016) ve bu nedenle de, modellenmesi oldukça karmaşık ve zordur. Bu açıdan, ET'nin tahmin yöntemleri ile değerlendirilmesi çalışmanın ana amacıdır. Ayrıca, bu çalışmanın diğer amaçları aşağıdaki gibi sıralanabilir.

- Sudan ülkesi ile ilgili meteorolojik verileri kullanarak günlük ET₀ hesaplanması,
- Deterministik ve stokastik yöntemler ve farklı yapay sinir ağı algoritmaları kullanılarak günlük ET₀'nin tahmin edilmesi,
- Her bir yöntem için tahmin yetenekleri istatistiksel performans ölçütleriyle karşılaştırarak ve gelecekteki değerleri tahmin etmek için kullanılacak en iyi modellerin belirlenmesi,
- İklim verileri ile birlikte kullanılarak Sudan'da yetiştirilen tüm bitkileri göz önüne alarak her bir bitkinin su tüketimi belirlenmesi amaçlanmıştır.

Böylece ülkede su kaynaklarının yeterli ve/veya kısıtlı olduğu bölgelerde ve kurak dönemlerde su kaynakları yönetimine önemli düzeyde katkı sağlanmış olacaktır.

Hazırlanan bu tez ile, su yapılarının, sulama sistemlerinin ve tarımsal alt yapı tesislerinin projelendirilmesi ve işletilmesine sağlayacağı katkı ile hem Sudan ekonomisine hem de doğal kaynakların sürdürülebilir bir biçimde kullanılmasına çok büyük katkı sağlayacaktır.



2. LİTERATÜR TARAMASI

Evapotranspirasyon süreci doğada stokastiktir. Stokastik modelleme teknikleri bu tesadüfi ya da bilinmeyen değişkenlere dair olasılıkları kullanarak belirsizliği modele katarlar. Deterministik kavramıyla “tam olarak belirlilik” kastedilmektedir. Deterministik modellerde ilgili tüm girdi verilerin kesin ve tam olarak bilindiği kabul edilir. Bu yüzden deterministik modeller evapotranspirasyonunu doğru bir şekilde temsil etmeyebilir. Öte yandan, stokastik modeller zamana bağlı varyasyonlara dayanır ve sürece dahil olan rastgele etkileri gözönüne alır. Stokastik modeller, önceden gönderilen bir gözlemin geçmiş gözlemlere bağımlılığının derecesini açıklanmaktadır. Bir stokastik model matematiksel soyutlamadır ampirik bir süreç ve olasılıksal tarafından yönetilir yasalardır (Pandey et al., 2009).

Stokastik modelin amacı temsil etmektir bir veya daha fazla zaman serisinin önemli istatistiksel özellikleridir. Gerçekten de, farklı stokastik model türleri sıklıkla incelenip istatistiksel zaman serileriyle üretilmektedir. Modeller stokastik kavram üzerine formüle edilen kapsamı açıklayıp mevcut gözlemlerin geçmişe bağımlılığı gözlemektedir. Evapotranspirasyon işlemi esas olarak doğrusallık veya doğransızlık tarafından karmaşık ve zor bir işlemdir. Bu açıdan evapotranspirasyonu hesaplamak ve tahmin etmek için birçok yöntem kullanılmıştır.

2.1. ASCE Penman-Monteith denklemi

Birinci bölümde daha önce de belirtildiği gibi, ET_0 değerlerini hesaplamak için saatlik, günlük ve aylık olmak üzere farklı zaman adımları için yaygın olarak kullanılan ET_0 değerlerini (Ampirik denklemler ve yapay zekâ uygulamaları) tahmin etmek için farklı yöntemler vardır. Araştırmacılar tarafından çok sayıda ET_0 denklemi geliştirilmiş ve kullanılmıştır (İtenfisu vd., 2003). Bu denklemlerin arasında en çok kullanılan ET_0 tahmin denklemleri Penman denklemi ve Penman-Monteith (PM) denklemleridir. Ek olarak, ampirik Hargreaves denklemi de popüler bir yöntem olarak kabul edilir.

Bu çalışmada hesaplamada en etkili ampirik denklemlerden biri olan ASCE Penman-Monteith denklem yöntemi kullanılmıştır. ASCE-EWRI Penman-Monteith (ASCE PM) denklemi, Amerikan İnşaat Mühendisleri Derneği Çevre ve Su Kaynakları Enstitüsü tarafından ET_0 'yı tahmin etmek için standart denklem olarak önerildi (Rojas ve Sheffield, 2013). Bitki su tüketimi (ET_c), gerçekleşen bitki su tüketimi (ET_a) ve

kısa boylu bitki esaslı referans bitki su tüketimidir (ET_0). Bunların dışındaki diğer bitki su tüketimi ifade biçimleri, kavram karışıklığını önlemek için bu rehberin kapsamı dışında tutulmuştur. ET_c , bir bitkinin ele alınan bir dönem için, her hangi bir hastalık zararlı etkisinin bulunmadığı, bitki besin elementi bakımından eksiklik çekmediği ve su stresi olmadığı standart koşullar altındaki su tüketimidir. ET_a , bir bitkinin ele alınan bir dönem için, standart olarak tanımlanan koşullardan farklı bir ortamdaki su tüketimidir. Buna göre ET_a standart koşullarda ET_c ' ye eşit olabileceken, standart olmayan koşullarda daima ET_c ' den daha düşüktür. ET_0 , kısa boylu (ortalama 12 cm) ve tam örtüye sahip bir bitkinin (çoğunlukla çim olarak kabul edilir) ele alınan bir dönemde, standart koşullar altındaki su tüketimidir. Çim için ET_0 ve ET_c birbirine eşittir. Birçok ulusal ve uluslararası kaynakta, ET_0 bitkiler için atmosferin nem talebini gösteren bir parametre olarak da değerlendirilmektedir (TAGEM.,2017).

Temesgen vd (2005) çalışmalarında, Kaliforniya eyaletindeki 37 meteoroloji istasyonundan toplanan iklim değişkenlerine dayanarak saatlik ve günlük ET_0 değerlerini değerlendirmek için Penman-Monteith yönteminin üç farklı denklemini kullanmışlardır.

Amatya vd (1995) çalışmalarında, Penman-Monteith, Priestley-Taylor, Hargreaves-Samani, Makkink ve Thornthwaite yöntemlerine ET_0 değerleri tahmin etmek için Penman-Monteith sonuçlarına göre karşılaştırmışlardır. Sonuç olarak en iyi tahmin eden modelin Penman-Monteith olduğu belirlenmiş ve araştırmacılar Penman-Monteith yöntemini tüm alanlar için tavsiye etmişlerdir.

Gavilán vd (2006) çalışmalarında, günlük ET_0 değerleri güney İspanya'da Hargreaves denklemi kullanılarak tahmin edilmiş ve standart denklem olarak kullanılan FAO Penman-Monteith denklemi ile karşılaştırılmıştır. Ek olarak, her bir istasyon için aynı değişkenlerin bir fonksiyonu olarak ampirik katsayı için ayarlanan değerlerin dağılımını elde etmek için kriging enterpolasyon yöntemi kullanılmıştır.

Nandagiri ve Kovoov, (2006) yaptıkları çalışmada Hindistan'daki kurak ve yarı kurak bölgelerin ET_0 değerlerini değerlendirmek için farklı modeller kullanmışlardır.

Grazhdani vd (2010) çalışmalarında ET_0 değerleri, standartlaştırılmış ASCE Penman-Monteith ve ASCE Penman-Monteith denklemleri kullanılarak Arnavutluk'un farklı yerlerinden toplanan saatlik ve günlük iklim verilerine dayanarak değerlendirilmiştir. Bu çalışmada günlük ve saatlik ET_0 değerlerinin kombinasyonları yapılmış ve spesifik yönetime göre karşılaştırılmıştır.

C-Y Xu and Singh (2002) çalışmalarında, (1) kütle-transferine dayalı yöntemler (Rohwer), (2) radyasyona dayalı yöntemler (Makkink ve Priestley-Taylor) ve (3) sıcaklığa dayalı yöntemler (Hargreaves ve Blaney-Criddle) olmak üzere üç kategoriye dayanarak beş ampirik denklem tartışılmıştır.

Ampirik Hargreaves denklemi, Batı Balkanlar ve Güneydoğu Avrupa bölgelerinde kullanıma olasılığını gerçekleştirmek için (Trajkovic, 2007) çalışmasında kalibre edilmiştir. Hargreaves denklemi ile FAO-56 PM karşılaştırılmış ve düzeltilmiş Hargreaves denkleminin sonuçları çoğu yerde FAO-56 PM tahminlerine yakın bulunmuştur.

Hargreaves denklemini kalibre etmek için böyle bir yaklaşımın (Martinez-Cob and Tejero-Juste, 2004), aylık ET_0 değerlerini değerlendirmek üzere İspanya'da yarı değişken koşullar altında rüzgar değişkenlerine dayalı denklemi kalibre etmesi önerilmiştir. Hargreaves denklemi FAO-PM denklemi ile karşılaştırıldı ve fazla tahmin edilen ET_0 değerleri bulunmaktaydı (ortalama hatalar %14-20 arasında değişiyordu), bu da yarı kurak koşullar altında yerel kalibrasyon için rüzgarlı koşullara ihtiyaç duyulmayacağı anlamına geliyordu.

Lopez-Urrea et al (2006)'ya göre saatlik ET_0 değerleri , FAO-56 ve Amerikan İnşaat Mühendisleri Derneği (ASCE) Penman-Monteith (PM) denklemleri kullanılarak Albacete eyaletinin (İspanya) yarı kurak koşulları altında tahmin edilmiştir.

FAO-56 ve ASCE sonuçları ölçülen lizimetre ET_0 değerleri ile karşılaştırıldıktan sonra FAO-56 Penman-Monteith denklemi Albacete'de yarı kurak hava koşullarında ASCE Penman-Monteith yöntemine göre daha doğru sonuçlar vermiştir.

Birçok çalışma da, günlük ve saatlik ET_0 değerleri tahmin etmek için yeni ampirik denklemler önerilmiştir ve ASCE PM Monteith denklemi; diğer yaygın olarak kullanılan denklemler ile karşılaştırıldığında, rüzgar, güneş ışıınımı, bağıl nem olarak daha az sayıda değişkene bağlı olarak en iyi model olarak kabul edilmiştir (Alexandris et al., 2006; Irmak et al., 2006).

2.2. Zaman serileri analiz teknikleri

Zaman serileri analizi istatistiksel tahminde önemli bir araçtır (Arca et al., 2003; Box et al., 2008, 2015). Gelecekteki eğilimleri tahmin edebilecek bir model geliştirmek için bir değişkenin geçmiş gözlemlerin toplanması ve analizine ihtiyaç

duymaktadır. Bir zaman serisi, bir dizi eşit aralıklı zaman periyodu boyunca alınan bir dizi $y_1, y_2, \dots, y_n$ gözlemidir. Analiz, zaman serilerindeki noktaların bir çizimi ile başlar. Ayrıca serinin otokorelasyonları ve kısmi otokorelasyonları yapılmış olup serideki her noktanın zaman serisindeki önceki değerlerle nasıl ve ne derece ilişkili olduğunu göstermektedir (Psilovikos and Elhag, 2013).

Zaman serileri analizi, hidroloji alanında karmaşık bir süreç olarak kabul edilen ET süreci gibi en zor hidrolojik parametrelerin gelecekteki değerlerini analiz etmek ve tahmin etmek için son derece yararlı bir yöntemdir. Ek olarak, zaman serisi analizi, geçmişten gelen yeniden yapılandırılmış hidrolojik akırlarla hidrolojik ve iklimsel modelleri test etmek için çok yararlıdır (Palmroth et al., 2010). Zaman serisi verilerinde ortaya çıkan en belirgin kalıpların eğilimler ve mevsimsellik olduğunu belirtmek gerekmektedir (Box et al., 2015).

Hidrolojik zaman serilerinin analizinde kullanılan en yaygın stokastik modellerden biri, geçmiş davranış kalıplarını geleceğe tahmin etmek için kullanılan otoregresif entegre hareketli ortalama (ARIMA) modeli stokastik modelleri olarak adlandırılan Box-Jenkins modelidir (Mohan and Arumugam, 1995).

ARIMA, Box-Jenkins tarafından tanıtılan ilk yöntemdir ve şimdiye kadar tek değişkenli zaman serisi verilerini tahmin etmek için en popüler model haline gelmiştir (Lee, 2011).

Zaman serisi analiz tekniğinin birçok avantajı vardır. (Asteriou and Hall, 2007) çalışmalarında, verileri temsil etmek için varsayımsal bir olasılık modeli oluşturmak gereklidir. Uygun bir model grubu seçildikten sonra, verilere uygunluğun iyi olup olmadığını kontrol eden parametreleri tahmin etmek ve muhtemelen seriyi üreten mekanizma hakkındaki anlayışımızı geliştirmek için takılı modeli kullanmak mümkündür.

Ayrıca, işsizlik gibi ekonomik istatistikler için mevsimsel bileşenlerin varlığını fark etmek ve bunları uzun vadeli eğilimlerle karıştırmamak çok önemlidir. Zaman serisi modelleri, parametreleri ayarlayarak serilerin gelecekteki değerlerini kontrol etmek için başvurabilmektedir. Örneğin, zaman serileri analizi, sıcaklık verilerinin kaydedilmesi bir serinin başka bir popülasyon verisinin gözlemlerinden tahmin edilmesi kullanılarak küresel ısınmanın test hipotezi gibi gelecekteki değerlerin tahmininde ana rolü oynamaktadır.

Landeras et al (2009)'ye göre haftalık ET_0 değerlerini tahmin etmek için ARIMA ve yapay sinir ağı modelleri kullanılmıştır.

Ashrafzadeh et al (2020) tarafından yapılan çalışmada, ET_0 aylık 1993-2014 yılları arası Zaman Serileri Modelleri İran'da, Destek Vektör Makineleri (SVM) ve grup veri işleme yöntemi (GMDH) farklı yöntemler kullanılarak ET_0 tahmin edilmiş ve bu modeller (2013-2014) 2 yıl ileriye dönük ET_0 tahmini için kullanılmıştır.

Luo et al (2014) çalışmalarında, Hargreaves-Samani modelini ve sıcaklık tahminlerini kullanarak kısa vadeli günlük ET_0 tahmin etmek için bir yöntem önermiştir. Hargreaves-Samani (HS) modelini kalibre etmek ve doğrulamak için HS modeli Penman-Monteith modeli ile karşılaştırılmıştır.

ARIMA modelleri, ET_0 zaman serilerini geliştirmek için günlük metrolojik parametreleri kullanarak kurak iklimlerde aylık ET_0 tahmin etmek için (Mossad and Alazba, 2016) tarafından yapılan çalışmada uygulanmıştır. (Kim et al., 2011) tarafından yapılan çalışmada, Moğolistan'daki zamansal-mekânsal Yağışları değerlendirmek ve tahmin etmek için mevsimsel ARIMA modellerini uygulanmıştır.

Han et al (2010) standartlaştırılmış yağış endeksini (SPI endeksi) kullanarak kuraklığı tahmin etmek için ARIMA modelleri ve sonuçlar, modelin SPI endeksi için nasıl güçlü kısa vadeli tahminlere sahip olduğunu gösterilmiştir.

ARIMA modelleri (Han et al., 2010) tarafından yapılan çalışmada, VTCI (vejetasyon sıcaklık durum indeksi) serilerini simüle etmek ve tahmin etmek için uygulanmış ve Mekânsal zamansal seriler için yeni bir modelleme yöntemi kullanılmıştır.

G. P. Zhang (2003) çalışmalarına göre, doğrusal ve doğrusal olmayan durumlarda tahmin doğruluğunu artırmak ve modellemenin gücünü tahmin etmek için ARIMA ve yapay sinir ağları (YSA) modellerinin hibrit bir yöntemini önermiştir. Hibrit bir ARIMA ve sinir ağı modelleri, farklı veri desenleri çıkarmak ve verilerdeki doğrusallığı yakalama yeteneğini göstermek için özellikle önemlidir.

YSA, tahmin doğruluğunu geliştirmek ve zaman serisi verilerinde yüksek derecede model performansı elde etmek için etkili bir araçtır (Khashei and Bijari, 2010) ve (Kaur et al., 2015) çalışmalarına göre, sinir ağının yöntemini kullanarak ARIMA ve dalgacık dönüşüm modellerinin iki yöntemi olarak kabul edilen hibrit bir model uygulanmıştır.

Bazrafshan et al (2015) ARIMA ve SARIMA modelleri aylık ve sezonluk ölçeklerinde, hidrolojik kuraklık tahmini için bilinen stokastik etkinliğini değerlendirdi ve tahmin süresi modellerinden verim miktarı belirlenmiştir. Aynı yöntemlerle (Mishra and Desai, 2005) Hindistan'daki Kansabati nehri havzasında

standart yağış endeksini kullanarak kuraklıkları tahmin etmek için SARIMA modelini kullanmışlardır (Grazhdani et al.) .

Juma and Fathi (2016.) yaptıkları çalışmalarında Box- Jenkins modelleri kullanılarak Irak'ta bölgeye ve verime göre pamuk üretimi öngörülmüştür. Rüzgar hızını tahmin etmek için ARMA ve ARMA-ARCH (Otoregresif Koşullu Heteroskedastisite) modelleri (Gao et al., 2009) tarafından yapılan çalışmada, önerilmiş ve sonuçlar ARMA-ARCH modelinin daha yüksek doğruluğa sahip olduğunu göstermiştir. Böyle bir yaklaşımda (Ling-ling et al., 2011) rüzgar hızını tahmin etmek için Dalgacık dönüşümü analizi (WMA) ve ARIMA modeli kullanılmıştır. Dalgacık teorisi, tüm rüzgar hızının ayrışması yoluyla düşük frekanslı parçaları almak için kullanılmıştır.

Arca et al (2003) saatlik Penman-Monteith denklemi olan saatlik ve günlük ET_0 tahminlerinin doğruluğunu ve sayısal bir hava tahmini modelinden tahmin edilen hava durumu verilerini ve iki zamanlı seri tahmin modellerini değerlendirmek için farklı yöntemler kullanılmıştır.

Rana and Katerji (2000) Akdeniz iklimi altında alanında gerçek bitki su tüketimi tahmin etmek için On yöntemleri gözden geçirildi ve bu yöntemler, toprak su dengesi vardı: lizimetre, enerji dengesi/Bowen oranı, aerodinamik yöntem, eddy kovaryans, sap akış yöntemi, chambers sistemi, CBS yaklaşımları modelleme Monteith model, bitki katsayısı yaklaşımı ve toprak su dengesi ağırlığında kullanılmıştır.

2.3. Mekânsal veya Konumsal Enterpolasyon Teknikleri

Uzamsal enterpolasyon tekniklerinin iki ana grubu vardır: deterministik ve Jeostatistik. Deterministik enterpolasyon teknikleri, ölçülen verilerden benzerlik derecesine (ters mesafe ağırlıklı) veya yumuşatma derecesine (radyal temel fonksiyonlar) dayalı yüzeyler oluşturmaktadır.

Deterministik bir enterpolasyon, Jeostatistik teknikler, ölçülen noktalar arasındaki uzamsal korelasyonu ölçmekte ve tahmin yeri etrafındaki örnek noktaların uzamsal konfigürasyonunu açıklamaktadır. Jeostatistik enterpolasyon teknikleri, raster haritaları üretmek için ölçülen verilerin istatistiksel özelliklerini kullanmaktadır (Matheron, 1963).

Citakoglu et al (2017) çalışmalarında Türkiye genelinde ölçülen aylık yağış verilerini kullanarak mevsimsel yağışların mekânsal değişimi araştırılmıştır. Gauss

yaklaşımı ile analiz 200 yağış ölçülen en az 20 yıllık kaydedilmiş verilere dayalı, ulaşılabilen coğrafi bölgelerdeki mevsimsel yağışların büyüklüğünün yeterli doğrulukla kolayca tahmin edilmesini sağlamıştır.

Harcum and Loftis (1987) Thiessen poligonu, basit ortalama ve ters mesafe ağırlığını içeren günlük ET_0 tahmin etmek için üç farklı enterpolasyon yöntemi kullanmıştır. Ek olarak, Kalman filtreleme yaklaşımı, hataları ölçmek ve hataları açıkça modellemek için stokastik bir işlem olarak kullanılmaktadır. ET_0 'yı belirlemek ve CBS tekniklerini kullanarak mekansal dağılım yapmak için iki yaklaşım uygulanmıştır (Kamali et al., 2015). İlk yöntemde, ET_0 meteoroloji istasyonunun bulunduğu yerdeki iklim verileri ve Hargreaves-Samani denklemi kullanılarak hesaplanmış ve daha sonra enterpolasyona tabi tutulmuştur. İkinci yöntemde, Hargreaves-Samani denkleminin bileşenleri enterpolasyon uygulandıktan sonra CBS'de Hargreaves-Samani denklemi ve uygun yöntemler uygulanarak ET_0 haritaları hazırlanmıştır.

Aynı yöntemler ile (Ahmadi and Sedghamiz, 2008), 12 yılda farklı iklim koşulları (kuru, ıslak ve normal) yaşayan bir ovada yeraltı suyu derinliğinin haritalanması için kriging ve cokriging yöntemlerini kullanmışlardır.

Ashraf et al (1997) çalışmalarında, Nebraska, Kansas ve Colorado eyaletlerindeki farklı istasyonlar için ET_0 değerlerini tahmin etmek için farklı enterpolasyon yöntemleri kullanmıştır. Bölgeselleştirilmiş değişkenlerin konturlanması ve haritalanması için kriging gibi jeostatistik teknikler kullanılarak optimal enterpolasyon kullanmışlardır.

Bechini et al (2000) tarafından yapılan araştırmaya göre küresel güneş radyasyonu verileri, Kuzey İtalya için güneş radyasyonunun gelecekteki değerlerini tahmin etmek için enterpolasyon ve stokastik yöntemler uygulanarak spesifik iklim parametreleri kullanılarak simüle edilmiştir.

Tabari et al (2012) çalışmalarında kurak ve yarı kurak İran'daki aylık ET_0 değerlerindeki değişiklikleri tahmin etmek için mekansal enterpolasyon yaklaşımlarını önermişlerdir.

V. Kumar (2007) y'e göre Universal kriging, yeraltı suyu seviyelerini tahmin etmek için kuzeybatı Hindistan'daki bir dizi kanal sulama projesine uygulanmıştır.

Dalezios et al (2002) Yunanistan'da aylık ve yıllık ET_0 haritalanması için kriging gibi jeostatistik teknikler kullanılarak enterpolasyon uygulanmıştır. Ayrıca, (Mardikis et al., 2005) tarafından yapılan çalışma, uzun vadeli bir dönemin ET_0 (Penman-

Monteith) tahmin etmek için dört enterpolasyon yöntemini karşılaştırmış ve değerlendirmiştir.

Vicente-Serrano et al (2007) tarafından yapılan çalışma, ET_0 parametresini tahmin etmek için farklı mekansal enterpolasyon teknikleri yöntemlerini karşılaştırmıştır.

Chong-yu Xu et al (2006) tarafından yapılan çalışmada, ET_0 analiz edilerek, meteorolojik değişkenler kullanılarak zamansal eğilimlerin mekânsal dağılımlarını uygulanmaktadır. Bian et al (2020) çalışmalarında, Moğolistan'daki ET_0 eğilimlerini uzun vadeli veriler (1971-2016) kullanarak ve regresyon ve kısmi korelasyon analizi uygulayarak tahmin etmek için mekânsal dağılım tekniklerini kullanmıştır. Aynı şekilde (Ullah et al., 2001) çalışmalarında, ET_0 'yi değerlendirmek için mekansal enterpolasyon yöntemlerini tartışmışlardır.

Hart et al (2009) çalışmalarında, günlük ET_0 , Penman-Monteith denklemi kullanılarak ve ET_0 değerlerinin enterpolasyonu için ise uydu görüntü teknikleri uygulanarak hesaplanmıştır. Aynı yöntemde (Naoum and Tsanis, 2003) tarafından yapılan çalışmada, ET_0 tahmin etmek için hidro bilişim sistemleri uygulamıştır.

2.4. Yapay Sinir Ağları (YSA) Yöntemleri

YSA, deneysel bilgiyi depolamak ve öngörülebilir modelleri kullanmak için kullanılabilir hale getirmek için doğal bir eğilime sahip olan basit işlem birimlerinden oluşan kitlesel olarak paralel dağıtılmış bir işlemcidir (Karunasinghe and Liong, 2006). Zaman serisi modelleri ve YSA algoritmaları ile birlikte dalgacık dönüşüm yöntemleri gibi yeni geliştirilen yumuşak hesaplama modellerini kullanarak ET tahminlerini değerlendiren birçok çalışma literatürde mevcuttur.

Türkiye'de, farklı yöntemler (Dalgacık Dönüşümü ve YSA algoritmaları), ET_0 ve diğer örnekler kullanarak günlük yağış yöntemlerin gelecekteki değerini tahmin etmek için sınırlı bir süre kullanmıştır (T Partal, 2007).

Ayrıca bu çalışmada yağış değerlerini tahmin etmede kullanılan verileri seçmek ve hazırlamak için veri madenciliği teknikleri kullanılmaktadır. Böyle bir yaklaşımda (Falamarzi et al., 2014), sıcaklık ve rüzgar hızı verilerini kullanarak ET_0 tahmin etmek için yapay ve dalgacık sinir ağlarını önermiştir. Öte yandan, (Nikam et al., 2010) ET_0 tahmin etmek için FFBP ve EBP (ileri besleme geri yayılımı ve Elman geri yayılımı algoritmaları) kullanarak YSA modelini uygulanmıştır.

Tahmin amacıyla kullanılan yapay zeka modellerinin yanı sıra, M5T veri

madenciliği yöntemini kullanarak ET_0 tahmin etmiştir (Kaya et al., 2016).

Kişi (2011) çalışmasında bazı günlük meteorolojik verileri kullanarak ET'yi tahmin etmek için dalgacık regresyon yaklaşımı (WR) kullanılarak modelleme yapılmıştır. . Burada WR, ayırık dalgacık dönüşümleri (DWT) ve doğrusal regresyon modeli olmak üzere iki yöntemin birleşimidir. Öte yandan, YSA kullanarak ET tahmin etmek için (M. Kumar et al., 2002) ağırlıkları ayarlamak için bir geri yayılım eğitim yöntemi önermiş ve hesaplanan hata sinyalleri ağ üzerinden geriye doğru yayılmıştır.

Böyle bir yaklaşımda (Gocić et al., 2015) bu çalışmada tahmin için ET_0 belirlemek ve FAO-56 Penman-Monteith denklemi kullanılır, ET_0 dört esnek hesaplama yöntemleri, Genetik programlama (GP), destek vektör makinesi (SVM-FFA), ve destek vektör makinesi-dalgacık analiz (SVM-dalgacık) algoritmalarını kullanılarak SVM dalgacık yöntemi en iyi yöntem bulunmuştur.

Abghari et al (2012) çalışmalarının amacına göre, çok katmanlı yapay sinir ağları (MLP), Mexican hat ve Poli WOG1 ana dalgacık NN algoritmaları olan dalgacık-Sinir ağları türlerini kullanarak günlük buharlaşma tahmini idi. Mexican Hat ve PolywoG1 işlevleri adlı bir dalgacık sinir ağının geliştirilmesi için iki ana dalgacığın göz önünde bulundurulduğu anlamına gelmektedir.

Lin and Wu (2009) çalışmalarında, iki farklı YSA kullanarak tayfun yağışının gelecekteki miktarını tahmin etmek için yapay sinir ağların yöntemleri kullanılmıştır. Bu çalışmada, modelin doğruluğunu artırmak için kendi kendini organize eden harita ve MLP birleştirilmiştir.

Turgay Partal (2009) yaptığı çalışmada, ET_0 tahmini için dalgacık dönüşümleri ve ileri beslemeli sinir ağı yöntemlerinin kombinasyonunu önermiştir. Kullanılan iklim verileri (hava sıcaklığı, güneş radyasyonu, rüzgar hızı, bağıl nem) Amerika Birleşik Devletleri'ndeki iki istasyondan alınmış iklim verileri kullanılmıştır. Dalgacık ve sinir ağı (WNN) modeli için, giriş verileri dalgacık dönüşümü ile dalgacık alt zaman serilerine ayrıştırılmıştır. Aynı yöntemler ile (Turgay Partal, 2016) tarafından yapılan çalışmada, dalgacık tabanlı radyal tabanlı ağların karşılaştırmalı performansı ve günlük referans evapotranspirasyon tahmininde iklimsel veriler (hava sıcaklığı, güneş radyasyonu, rüzgar hızı ve bağıl nem) kullanılarak çok doğrusal regresyon üzerinde çalışılmıştır. Dalgacık tabanlı regresyon modeli dalgacık dönüşümünü ve çok doğrusal regresyonu birleştirirken, dalgacık tabanlı radyal tabanlı ağ dalgacık dönüşümünü ve radyal tabanlı sinir ağını birleştirmiştir.

Patil and Deka (2017) yaptıkları çalışmada, temel olarak Hindistan'ın kurak bölgelerinde ET tahmin etmek için YSA ve bulanı yapay sinir ağı sistemleri (ANFIS) modellerinin doğruluğunu arttırmada dalgacık dönüşümünün yeteneğini ortaya koymuşlardır.

Rahimikhoob (2010) çalışmasına göre, Hazar Denizi'nin kuzeyinde yer alan Hazar Denizi'nin güney kıyısındaki nemli subtropikal koşullar altında hava sıcaklığı verilerine dayanarak ET_0 tahmin etmek için YSA kullanım potansiyelini incelenmiştir. Bilindiği gibi, ET sürecinin modellenmesiyle ilgili en büyük sorun, doğrusal olmayan dinamik yüksek karmaşıklığıdır.

Bu nedenle, Araştırmacılar zengin ve zayıf veri durumlarında ET_0 tahmin modelleri geliştirdiler (Traore et al., 2010) ve esas olarak Burkina Faso'nun Sudano-Sahelian bölgesinde ET_0 modellemek için YSA kullanmışlardır. Genelleştirilmiş regresyon sinir ağları modeli (GRNN) ve radyal temel fonksiyon sinir ağı (RBFNN), Cezayir'de ilk kez referans ET_0 'ı tahmin etmek için (Ladlani et al., 2012) tarafından yapılan çalışmalarında geliştirilip karşılaştırılmıştır.

Kurak bölgelerdeki suyun kısıtlılığını çözmek için bitki suyu gereksinimlerinin tahmin edilmesinin özellikle önemli olduğunu belirtmek gerekir. Dolayısıyla, hidrolojik döngü sürecinin ana bileşeni olduğu için ET_0 tahmini gereklidir. Ek olarak, eksik meteorolojik parametreleri kullanarak ET_0 değerlendirmek için YSA kullanımının etkinliği üzerinde çalışılmıştır.

Dai et al (2009) tarafından yapılan çalışmada, Kuzeybatı Çin'deki üç istasyondan 50 yıllık meteorolojik verileri ET_0 tahmin etmek için YSA'nın performansını karşılaştırmak için çoklu doğrusal regresyonlar (MLR), Penman denklemi ve iki ampirik denklem kullanılmıştır.

Benzer yaklaşımda (Jahanbani and El-Shafie, 2011) İran'ın kuzey kesiminde bulunan Rasht şehrinde günlük ET_0 minimum ve maksimum günlük sıcaklıkları kullanarak tahmin etmek için YSA geliştirmiştir. YSA modellerinin, çok fazla iklim parametresine ihtiyaç duymadan sadece maksimum ve minimum sıcaklık ve güneş radyasyonu kullanarak günlük ET_0 aylık zaman serilerini tahmin etmesi önerilmiştir.

Ferreira and da Cunha (2020) tarafından yapılan çalışmada, 53 meteoroloji istasyonundan toplanan verileri ve Brezilya'nın Minas Gerais eyaletindeki 53 meteoroloji istasyonuna ilişkin verileri kullanarak günlük ET_0 değerlerini tahmin etmek için önerilmiştir. Günlük ET_0 tahmini doğrudan (ASCE PM denklemi kullanılarak) ve dolaylı olarak (saatlik tahmini ET_0 'nın toplamı) kullanılmıştır.

Ayrıca, RF, XGBoost, YSA ve CNN algoritmaları olan makine öğrenimi ve derin öğrenme teknikleri uygulanmıştır. Aynı şekilde (M. Kumar et al., 2008) çalışmalarında, Turc, FAO-24 Blaney-Criddle (BC) ve ASCE PM yöntemleri olan ampirik denklemler kullanılarak hesaplanan günlük referans evapotranspirasyon değerlerini tahmin etmek için YSA geliştirilmiştir. ASCE PM değerlerine dayanan YSA modelleri diğer yöntemlere göre en iyi sonuçları bulunmuştur.

Dogan (2009) çalışmasına göre, Penman-Monteith denklemi kullanılarak hesaplanan günlük referans evapotranspirasyon değerlerini tahmin etmek için bulanık yapay sinir ağları (ANFIS) araştırılmıştır. ANFIS Modelinin sonuçları çoklu doğrusal regresyon ile karşılaştırılarak ve istatistiksel kriterlere göre ANFIS modelini en iyi tahmini gerçekleştirmiştir. Aynı yöntemleri (Pour-Ali Baba et al., 2013) tarafından yapılan çalışmalarında kullanılmıştır.

Walia et al (2015) tarafından yapılan çalışmalarına göre ANFIS'in mimarisi ve temel öğrenme süreci, doğrusal olmayan fonksiyonların modellenmesi, indüksiyon makinesinin en önemli parametrelerinden birinin kontrol edilmesi ve kaotik bir zaman serisini tahmin etmek için kullanılmıştır. Hepsi daha etkili, daha hızlı tepki veya çökme süreleri sağlar. Böyle bir yaklaşımda, (Abyaneh et al., 2011) çalışmalarında Sarımsak bitkisi evapotranspirasyonunu tahmin etmek için YSA ve ANFIS teknikleri uygulanmış ve bu teknikler ile hesaplamalı ET_c'yi simüle etmek için uygun olmuştur.


3. MATERYAL VE METOT

3.1. Çalışma Alanı

Sudan, Afrika'nın kuzeydoğusundadır. Sudan, kuzeyde Mısır, kuzeybatıda Libya, batıda Çad, güneybatıda Orta Afrika Cumhuriyeti, Güneyde Güney Sudan, güneydoğuda Etiyopya, Doğuda Eritre ve doğuda Kızıldeniz ile sınırlanmıştır. Sudan, 12° 51.768' enleminde ve 30° 13.02' boylamında, ayrıca ortalama deniz seviyesinden 405 m yükseklikte yer almaktadır. Çalışmada kullanılan meteorolojik verilerin elde edildiği gözlem istasyonlarının çalışma alanı ve konumları Şekil 3.1'de gösterilmiştir. Meteorolojik veriler 120 ana meteoroloji istasyonundan toplanmıştır. Meteorolojik verilerini <https://www.soda-pro.com/> sitesinden temin edilmiştir. 1982-2020 yılları arasında Sudan'ın farklı bölgelerinden seçilmektedir.

3.2. Veri setlerinin Hazırlanması


Toplanan veriler günlük ET_0 değerlerini tahmin etmek için değerlendirilir. Günlük ET_0 hesaplanmasında en önemli değişkenler psikrometrik ve atmosferik değişkenler olan günlük metrolojik verilerdir. Çalışmada, iklim verileri: (γ) psikometrik sabite, (G) toprak ısı akış (U2) buhar basıncı (ea) (s), Gerçek buhar basıncı, rüzgar hızı, doymun yoğunluk, sıcaklık (Ortalama, en düşük ve en yüksek günlük sıcaklıklar)- Sıcaklık eğrisi (D, Bağlı nem, Net radyasyon (Rn), eğim ve doymunluk buhar basıncı) verilerini kullanılmaktadır. Üstelik, mekansal dağılımlarını belirlemek ve günlük ET_0 değerlerinin haritalarını oluşturmak için enlem, boylam ve yükseklik değişkenleri kullanılmaktadır.



Şekil 3. 1. Sudan'da meteorolojik gözlem istasyonlarının dağılımı

3.3. Tahmin Yöntemleri

Bu çalışmada, referans evapotranspirasyonun değerlerini tahmin ve modelleri oluşturmak için farklı yöntemleri kullanılmıştır. Bu yöntemleri Şekil 3.2.'deki gibi gösterilmektedir:



Şekil 3. 2. Tahmin yöntemleri

3.3.1. ASCE Penman-Monteith yöntemi:

ET₀'ı hesaplamak için Amerikan inşaat mühendisleri derneği çevre (ASCE) su kaynakları enstitüsü'nün standartlaştırılmış ET₀ yöntemi kullanılmıştır (Allen et al., 2006). Bitki su tüketimi tahmini amacıyla geliştirilmiş çok sayıda eşitlikten bahsedilebilir. Bu eşitliklerden günümüzde en yaygın olarak kullanılanı FAO-Penman Monteith yaklaşımıdır. Söz konusu yaklaşımda ET₀' nun tahmini ASCE Penman-Monteith eşitliği olarak 2004 yılında ASCE-EWRI tarafından kullanıma sunulmuştur. ASCE Standardize Penman-Monteith yaklaşımı Sudan'daki günlük iklim verilerinin kullanılarak ET₀ tahmin edilmiştir.

$$ET_0 = \frac{0.408 (R_n - G) \gamma \frac{C_n}{T} + 237 U_2 (e_s - e)}{\Delta + \gamma (1 + C \ U_2)} \quad (3.2.1)$$

Eşitlikte;

R_n = Bitki yüzeyi için hesaplanan net radyasyon (MJ m⁻² g⁻¹),

G = Toprak ısı akısı (MJ m⁻² g⁻¹),

T = Günlük ortalama hava sıcaklığı, 1,5 ile 2,5m arasında yükseklikte ölçülmüş, (°C),

u₂ = Günlük ortalama rüzgar hızı, 2,0 m yükseklikte ölçülmüş, (m s⁻¹),

e_s = Doygun buhar basıncı, 1,5 ile 2,5m arasında yükseklik için hesaplanmış, (kPa),

e_a = Gerçek buhar basıncı, 1,5 ile 2,5m arasında yükseklik için hesaplanmış, (kPa),

Δ = Doygun buhar basıncı-sıcaklık eğrisinin eğimi (kPa, 0C-1),

γ = Psikrometrik sabite (kPa, 0C-1),

C_n = Referans bitki tipi ve hesaplamanın yapıldığı zaman dilimi için sabit pay katsayısı, (kısa boylu bitki ve günlük hesaplama için C_n= 900,0)

C_d = Referans bitki tipi ve hesaplamanın yapıldığı zaman dilimi için sabit payda katsayısı, (kısa boylu bitki ve günlük hesaplama için C_n= 0,34)

Kısa boylu bitki için Eşitlik 3.2.1' in kullanılması durumunda standart koşullara ilişkin aşağıdaki varsayımlar geçerlidir.

- Bitki boyu 0,12 m' dir.

- Hava sıcaklığı ve oransal nem ölçümleri 1,5-2,5 m arasında yapılmıştır.
- Rüzgar hızı ölçümü 2,0 m yükseklikte yapılmıştır.
- Sıfır düzlemi yüksekliği 0,08 m' dir.
- Buharlaşma gizli ısı 2,45 MJ kg⁻¹ dır.
- Yüzey direnci ortalama 70 s.m⁻¹, gündüz saatlerinde 50 s.m⁻¹ ve gece saatlerinde 200 s.m⁻¹ dir.
- Net radyasyon gündüz saatlerinde sıfırdan büyük ve gece saatlerinde sıfırdan küçüktür.

ET₀' nun hesaplanabilmesi için gerekli olan asgari veriler hava sıcaklığı (T), oransal nem (RH), güneş radyasyonu (R_s), atmosferik basınç (P) ve rüzgar (u) hızıdır. Hesaplanan ET₀ değerinin doğruluğu bütünüyle kullanılan iklim verilerinin kalitesine dayanmaktadır. En doğru sonucun elde edilebilmesi için bu iklim elemanlarının, zemini bitki ile kaplı (tercihen bakımlı çim bitkisi) meteoroloji istasyonlarında ölçülmüş olması gereklidir.

3.3.2. Referans Evapotranspirasyonu Hesaplanması

Günlük gözlem değerlerine ait verilerden çalışmada kullanılacak olan parametreler (ortalama sıcaklık, rüzgar hızı, güneş radyosunu, ve bağıl nem) seçilerek Ms Excel formatında kaydedilmiştir. Her bir dosya içerisinde günlük ortalama değerler ile gözlem istasyonlarına ait il, enlem, boylam, yükseklik, ölçüm süresi bilgileri yer almıştır (Şekil 3.3.).

3.3.3. Zaman Serileri Analiz Teknikleri

Çalışmanın bu kısmında, ARIMA modelleri kullanılarak ET₀ tahmin etmek ve tahmin etmek için zaman serisi analiz teknikleri kullanılmıştır. Ayrıca Eviews 12 versiyon programının üzerinde zaman serisi analizleri yapılmıştır (Şekil 3.4). ARIMA modeli aşağıdaki gibi gösterilen matematiksel fonksiyonları kullanma (Box et al., 2015).

(i) Otokorelasyon Fonksiyonu (ACF)

Zaman serisi verilerindeki tüm noktalar arasındaki korelasyonu ayrı ayrı zaman veya gecikme ile açıklayan matematiksel bir işlem. Bu işlemde gecikmeler, serinin statik olarak anlamlı mı yoksa anlamlı olmayan bir korelasyon mu olduğunu gösteren

her gecikme için Ljung-Box Q ve p-değerleri güven aralıklarını kullanarak serinin durağanlığını ve durağanlığını göstermektedir.

(ii) Kısmi Otokorelasyon Fonksiyonu (PACF)

Kısmi otokorelasyon fonksiyonu (PACF) eğilimleri ve mevsimselliği tespit etmek için kullanılır. Bu süreçte gecikmeler, otoregresif bir modeldeki gecikmenin derecesini belirlemeyi amaçlayan veri analizinde önemli bir rol oynamaktadır; burada bu işlevi çizerek, bir AR (p) modelinde veya genişletilmiş bir ARIMA (p, d, q) modelinde uygun “P” gecikmeleri uygulanabilir kısmi otokorelasyon fonksiyonunu (PACF) belirlemek için olacaktır (Chen vd., 2009).

3.3.3.1. ARIMA Modellerinin Aşamaları

İstatistikte otoregresif entegre hareketli ortalama (ARIMA) modeli, otoregresif hareketli ortalama veya ARMA modelinin geliştirilmesidir. Bu modeller, verileri daha iyi anlamak veya serideki gelecekteki noktaları tahmin etmek için zaman serisi verilerine uyarlanmıştır.

ARIMA modeli, verilerin durağan olmayan özelliklerin kanıtını gösterdiği bazı durumlarda uygulanır; burada durağan olmayan özellikleri kaldırmak için bir başlangıç farklandırma adımı (modelin “Tümleşik” bölümüne karşılık gelir) uygulanabilmektedir. Model genel olarak ARIMA (p, d, q) modeli olarak adlandırılır; burada p, d ve q sıfırdan büyük veya sıfıra eşit tamsayılardır ve sırasıyla modelin otoregresif, bütünleşik ve hareketli ortalama parçalarının sırasını ifade eder. İlk parametre “p” otoregresif gecikme sayısını (birim kökleri saymaz), ikinci parametre “d” entegrasyon sırasını, üçüncü parametre “q” ise hareketli ortalama gecikme sayısını belirtir. ARIMA modelleri, Box-Jenkins’in zaman serisi modellemesine yaklaşımının önemli bir parçasını oluşturmaktadır (Box et al., 2015).

Bu çalışmada durağan durumda olan bazı veri serilerinde ARMA modeli uygulanmıştır. ARMA modelinin süreci, tanımlayıcı denklemlerin durağan çözümlerinin varlığını ve benzersizliğini ve nedensellik ve tersine çevrilebilirlik kavramlarını içeriyordur. Yansıma serisi $[y_t]$ için ARMA modelinin aşağıdaki alt kategorileri açıklanmıştır, ARMA modelinin şekli şöyledir:

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = Z_t + \Theta_1 Z_{t-1} + \dots + \Theta_q Z_{t-q} \quad (3.3.2)$$

$\{Z_t\} \sim WN(0, \sigma^2)$, Polinomları $(1 - \phi_1 z - \dots - \phi_p z^p)$ ve $(1 + \theta_1 z + \dots + \theta_q z^q)$ ortak faktörlere sahip değildir. $\{X_t - \mu\}$ bir ARMA (p, q) işlemi ise $\{X_t\}$ işleminin ortalama μ olan bir ARMA (p, q) işlemi olduğu söylenir. Denklemin daha özlü formunu kullanmak için uygundur. Parametrelerin değerleri olarak denklemi 3.2.3. ile gösterilmektedir.

$$\phi(B)X_t = \theta(B)Z_t, \quad (3.3.3)$$

burada: $\phi(B)$, $\theta(B)$, pth ve qth dereceli polinomlardır.

$\phi(z) = 1 - \phi_1 z - \dots - \phi_p z^p$ ve $\theta(z) = 1 + \theta_1 z + \dots + \theta_q z^q$, denklemlerde B , geriye doğru kaydırma operatörüdür. ($B^j X_t = X_{t-j}$, $B^j Z_t = Z_{t-j}$, $j = 0, \pm 1, \dots$) $\{X_t\}$ zaman serisinin $\theta(z)$ ise p (veya AR (p)) sırasının otoregresif bir işlemi olduğu söylenir ≤ 1 ve $\phi(z) \leq 1$ ise hareketli ortalama orderi q (veya MA (q)) işlemidir.

Öte yandan, veri serileri durağan olmadığında, ARIMA modelleri farklılaştırma işlemleri kullanılarak uygulanabilir ve gelecekteki değerleri tahmin etmek için daha uygun hale getirilebilir. Başka bir deyişle, ARIMA (p, d, q) modelleme yöntemi, geçmiş veri serilerindeki durağanlığa uygun değildir (Mohan and Arumugam, 1995). Serilerin yansımaları $[y_t]$ için aşağıdaki ARIMA modeli alt kategorileri açıklanmıştır, ARIMA modelinin şekli şöyledir:

$$\Phi(\beta)(\omega_t - \mu) = \Theta(\beta) a_t \quad (3.3.4)$$

Burada: t; zaman endeksi, β = backshift operatörü şu şekilde tanımlanır: $y_t = y_{t-1}$, $\omega_t = (1-b)^d y_t$; farklılıktan sonra tepki serisi, μ ; ortalama terimi, $\Phi(\beta)$ ve $\Theta(\beta)$ otoregresif operatör ve hareketli ortalama operatör sırasıyla göstermektedir.

(Box et al., 2015) tarafından yapılan çalışmalarına göre ARIMA model sürecini yürütmek için belirli adımlar vardır. ARIMA model yöntemi kullanılarak geliştirilmiştir. Bilindiği gibi üç ana yinelemeli adımı içeren Box-Jenkins prosedürüne dayanan bir ARIMA modelinin oluşturulmasındaki bu ana aşamalar; Tanımlama aşamasında, mevsimsel ve mevsimsel olmayan eğilimleri ortadan kaldırmak için verilerin farklılık dönüşümleri uygulanmıştır.

3.3.3.2. ARIMA (Box-Jenkins) Modellerinin Değerlendirme Aşamaları

Bu çalışmada, Sudan'ın farklı istasyonları için referans evapotranspirasyon değerlerini zaman serisi analiz teknikleri kullanarak tahmin etmek ve zaman serisi analiz adımlarını aşağıda, yöntemlere göre uygulamak için ARIMA modelleri kullanılmıştır (Box et al., 2008):

(i) Verileri Tanımlama

İlk olarak, farklı veri serileri için ARIMA modellerini bulmak için, orijinal veriler, grafiklerin gecikmelerine dayanarak istatistiksel önemi gösteren hem ACF, PACF hem de ilişkili korelogram grafiklerinin çizilmesiyle tanılandırmaktadır. Zaman serilerinin durağanlığını bilmek için farklı güven düzeyleri uygulanarak Artırılmış Dickey-Fuller testi veya birim kök testi (ADF) kullanıldı. Bu test, seri verilerinin geçerli mi yoksa sahte mi olduğunu belirlemek için gereklidir. Meclis hukukunda geçerli veri üretebilmek için hem değişkenlerin hem de hata teriminin durağan olması gerekmektedir. Hata teriminin ortalama değerine geri dönmenin bir yolu olması gerektiği anlamına gelmektedir (Saravanan, 2015).

$$\Delta Z_t = \alpha + \theta_t + \lambda Z_{t-1} + \sum_k \phi_i \Delta Z_{t-1} + \varepsilon_t \quad (3.3.5)$$

Null hipotezler $H_0 : \lambda = 0$ (Z_t durağan değildir, Z_t birim kök içerir) ve alternatif hipotezler $H_a = \lambda < 0$ (Z_t sabittir). Örneğin, hata teriminin araçları (μ) ve varyansı (σ^2) sabit olmalıdır. ADF testi trendle birlikte alınmalı ve önce seviyede kesişmelidir (Orijinal veriler), Eğer boş hipotez düşmezse, ilk fark alınmalıdır. İkinci fark, yalnızca ilk fark önemli değilse test edilir (Ibrahim and Amin, 2005).

(ii) ARIMA Modellerinin Tahmini

ACF ve PACF korelasyon grafikleri en az değer belirleme kriteri ve en hassas model ile değerlendirilerek ARIMA ve ARMA paternleri en hassas modeller olarak değerlendirildi. En iyi model seçimi için anlamlı olan karşılaştırma en uygun modeli en önemli faktörü, en az dalgalanma, en yüksek düzeltilmiş R^2 , P olan zaman serisi analizinde doğruluk kriterlerine göre seçildi-değerleri (0.05'den büyük olmalıdır), en güçlü (Schwarz bilgi kriteri) (Akaike bilgi kriteri) ve SIC değerleri. Ek olarak, RMSE ve MAE'NİN en küçük değerleri en iyi modeli seçmek için kriterler olarak kabul edilmektedir.

(iii) Denetim

Bu aşamada, otokorelasyonu test etmek için Ljung-box testi yapılır ve buna otokorelasyon testi de denir. Bu test, modelde henüz yakalanmamış herhangi bir bilgi

olup olmadığını anlamak için artıkların korelasyonunu kontrol etmek için kullanılırken, ACF ve PACF grafiklerindeki düz korelasyonda en ideal modele atıfta bulunulmuştur. Örneğin, korelogram kalıntılarını kontrol ederken aşırı uyumdan kaçınmak çok önemlidir.

(iv) Öngörü Değerleri

Tahmin süreci, orijinal veri kümesinin geçmiş değerlerini kullanarak serinin gelecekteki değerlerini tahmin etmek için bir ARIMA modeline uymanın özüdür. Tahmin seçilen modele dayanmaktadır. Bu adımda, tahmin grafikleri çizilir ve ne kadar başarılı olduğu doğrulanır ve tahmin serinin gelecekteki değerlerini tahmin etmektedir.

3.3.4. Enterpolasyon Yöntemleri

Bu kısımda, boylam, enlem ve yükseklik koordinatları konum bilgisi kullanılarak 120 ana ve alt ana istasyon değerine ilişkin günlük ET_0 elde edilen aylık ET_0 değerleri kullanılarak mekansal dağılım haritaları oluşturmak için farklı enterpolasyon yöntemleri kullanılmıştır. ArcGIS 10.7 version ve GS+ programların üzerinde enterpolasyonun analizlerini yapılarak haritaları oluşturulmaktadır.

Bu tezin kısmında, İklim verilerinin konumsal dağılımlarının belirlenmesi için yapılan çalışmalarda kullanılan ve sonuçta en doğru sonucu veren yöntemler değişkenlikler göstermektedir. Bu çalışmada kullanılan enterpolasyonun yöntemleri şu şekilde açıklanmıştır.

3.3.4.1. Ters Mesafe Ağırlığı (IDW) Yöntemi

Ters Mesafe Ağırlığı (IDW) yaygın olarak kullanılan hızlı, deterministik, kesin ve konumsal bir enterpolasyondur. Bir noktanın değerini, bu iki nokta arasındaki mesafenin ters bir fonksiyonu ile ağırlıklandırılmış, örneklenmiş bir veri noktasındaki değerlin doğrusal bir kombinasyonunu kullanarak tahmin eder. Yöntem, tahmin noktasına daha yakın olan gözlem noktalarının daha uzak noktalar olarak daha fazla olduğunu varsayar (Ahmadi and Sedghamiz, 2008).

IDW, her bir noktaya ağırlık vererek noktaları enterpolasyonda geleneksel olarak kullanılan deterministik bir yöntemdir, böylece noktadan uzaklık arttıkça tahmin

üzerindeki etkileri azalır (Adhikary and Dash, 2017). Matematiksel olarak, ağırlıklar aşağıdaki gibi hesaplanır:

$$Z(x_0) = \frac{\sum_{i=1}^n \frac{x_i}{h_i^b}}{\sum_{i=1}^n \frac{1}{h_i^b}} \quad (3.3.11)$$

$Z(x_0)$ interpolasyonlu değeri; n , örnek veri değerlerinin toplam sayısını temsil eder; x_i , i th veri değerlerini, bu interpolasyonlu değer ile örnek veri değeri arasındaki ayırma mesafesidir ve b , ağırlıklandırma gücüdür; ağırlıklandırma gücü, tahmin kalitesini önemli ölçüde etkileyebilir. Optimum ağırlıklandırma gücü, verilerin uzamsal yapısına bağlıdır ve verilerin varyasyon katsayısı (CV), çarpıklık ve basıklık katsayısından etkilenir (Stroud et al., 2001).

3.3.4.2. Kriging Yöntemleri

Bu çalışmada ET_0 değerlerini interpolasyonda stokastik yöntem olarak kriging teknikleri kullanılmıştır. Kriging, kriging ile interpolasyonda yarı değişken grafikleri (veya sadece variogramları) tanımlayan bir interpolasyon yöntemidir. Kriging, kesin veya pürüzsüz olabilen çok esnek bir interpolatördür. Tahminler, tahmin standart hataları ve olasılık dahil olmak üzere çeşitli çıktı yüzeylerine izin verir (Johnston et al., 2001). Kriging yöntemlerinin jeostatistik analizindeki ana araçtır, komşu gözlemler arasındaki mekansal korelasyonu ifade eden yarı variogramdır.

Kriging yöntemlerini analiz etmek ve tahmin etmek için en çok kullanılan doğrusal, küresel, Gauss ve Üstel olarak adlandırılan yarı variogram modelleri de dahil olmak üzere dört Kriging modeli vardır. Ayrıca, verilerin uzamsal korelasyonu semivariogram değeri ile değerlendirilmelidir. Jeostatistik tahminden önce, olası herhangi bir örnekleme aralığı için bir variogram değerinin hesaplanmasını sağlayan bir modele ihtiyacımız vardır.

Yarı değişkenlik değeri $\gamma(h)$, h ile ayrılan tüm noktadaki öznitelik değerleri arasındaki farkın yarısının varyansı olarak tanımlanabilir:

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)] \quad (3.3.12)$$

$Z(x)$, N değişkeninin büyüklüğünü gösterir; (h) , h mesafesiyle ayrılan öznitelik çiftlerinin toplam sayısıdır. Kriging yöntemlerini analiz etmek ve tahmin etmek için

en çok kullanılan doğrusal, küresel, Gauss ve Üstel olarak adlandırılan yarı variogram modelleri de dahil olmak üzere dört Kriging modeli vardır.

3.3.4.3. Ordinary Kriging (OK)

OK, bir değişkenin değerini tek bir noktada veya blokta tahmin etmek için jeoistatistik çalışmalarda kullanılan yaygın bir yöntemdir. Verilerde eğilim olmadığında sıradan kriging yöntemi kullanılabilir. Ek olarak, hataların beklenen değerine tarafsız olan doğrusal ağırlıklı ortalama bir tekniktir. Sabit bir rastgele alanın bilinmeyen bir sabit ortalama ile doğrusal tarafsız tahminini bulmak için yaygın olarak kullanılır ve aşağıdaki gibi ifade edilir:

$$\hat{Z}(x_0) = \sum_{i=1}^n \lambda_i z(x_i) \quad (3.3.13)$$

$Z(x_0)$, x_0 konumundaki kriging tahminidir; $Z(x_i)$, x_i 'de örneklenmiş değerdir ve λ_i , $Z(x_i)$ ile ilişkili ağırlıklandırma faktörüdür. Tahmin hatası şu şekilde tanımlanır:

$$\varepsilon(x_0) = Z(x_0) - \sum_{i=1}^n \lambda_i z(x_i) \quad (3.3.14)$$

$Z(x_0)$, x_0 uzamsal konumundaki bölgeselleştirilmiş değişkenin gerçek değeridir; $\varepsilon(x_0)$ tahmin hatasıdır. Buna ek olarak, sıradan karşılaştırıldığında düşük yöntemi kullanarak, veri serisi normal dağılım olmalı o zaman; aksi takdirde, doğrusal olmayan karşılaştırıldığında düşük kullanılmalı ya da verileri kullanarak doğrusal fonksiyonları normal dağılım dönüşmek zorunda, ve sonra Lineer karşılaştırıldığında düşük, bu Nedenle kullanılabilir, verilerin dağılım fonksiyonu kontrol edilmelidir fazlaşmıştır. Örneğin, sıradan Kriging ve evrensel Kriging yöntemlerinin her ikisi de model seçimi için yarı variogram parametrelerine bağlıdır. Ayrıca, IDW yöntemi güç fonksiyonu seçimine bağlıdır (Kamali et al., 2015).

3.3.5. Çoklu Doğrusal Regresyon Uygulamaları

Sebeup sonuç ilişkisine dayanan regresyon analizi, iki ya da daha çok değişken arasındaki ilişkiyi modellemek için kullanılan yöntemler arasındaki en çok kullanılanıdır. Çıktıyı modellemek için tek bir değişken kullanılıyorsa tek değişkenli regresyon, birden çok değişken kullanılıyorsa çok değişkenli regresyon olarak isimlendirilir. Basit bir doğrusal regresyon modeli ve bağımlı değişkenin gerçek ve tahmin edilen değeri arasındaki ilişki aşağıdaki eşitliklerde verilmiştir. Basit doğrusal regresyon bize normal dağılmış, hakkında aralıklı/oranlı ölçekle veri toplanmış iki değişken arasındaki doğrusal ilişki olup olmadığını test etme olanağı verir. Değişkenlerden biri tahmin, biri sonuç değişkenidir.

$$Y = a + bx \quad (3.3.15)$$

Burada ; a ve b sabitleri en küçük kareler yöntemi ile tahmin edilir. Çoklu doğrusal regresyon modeli birinci varsayımı basit doğrusal regresyon benzemektedir. Fakat iki yöntem arasındaki fark bağımlı değişkenin bağımsız bir değişkenden daha fazla fonksiyonu bulunur. Çoklu regresyon denkleminde birden fazla tahmin değişkeni vardır. Aşağıda Çoklu doğrusal regresyon eşitliliği verilmiştir.

$$Y = (b_0 + b_1 x_1 + b_2 x_2 + \dots b_n x_n) + e_i \quad (3.3.16)$$

Burada; Y bağımlı değişken, b_0 , regresyon eğrisinin y eksenin kesim noktası, b_1 ilk tahmin değişkeninin x_1 katsayısı, b_2 ikinci tahmin değişkeninin x_2 katsayısı ve e_i ise i'inci örnek için Y'nin edilen değeriyle gözlenen değeri arasındaki farktır.

3.3.6. Yapay Zeka Uygulamaları

YSA birçok bilimsel disiplinde geleneksel istatistiksel modelleme tekniklerine faydalı alternatifler olarak karşımıza çıkmaktadır. Bu tezin kısmında, yapay Sinir Ağları (YSA), ET_0 modellemesinde iki farklı YSA tekniği uygulayarak günlük ET_0 tahmin etmek için Sudan'daki iklimsel verileri kullanarak ET_0 doğrusal olmayan karmaşık işlemi modellemek için kullanılır. Bu teknikler çok Katmanlı algılayıcı (MLP) ve uyarlamalı nöro-bulanık sistem (ANFIS) ağlarıdır. MATLAB R2011a version kullanılarak YSA uygulanmaktadır.

3.3.6.1. Çok Katmanlı Yapay Sinir Ağları (ÇKYSA)

ÇKYSA, giriş verilerinin haritalarını ileriye dönük bir şekilde temel alan bir yapay sinir ağıdır ve bu ağın birbirine tamamen bağlı olan birden fazla katmanı (giriş, gizli ve çıkış katmanları) vardır (C. Zhang et al., 2018). Tipik yapı, MLP'nin birden çok katmandaki (giriş, gizli ve çıkış katmanları) birbirine bağlı düğümlerden oluşması ve her katmanın önceki katmana ve sonraki katmana tam olarak bağlanmasıdır (G. P. Zhang, 2003).

ÇKYSA ağ yapısı Şekil 3.5.'de gösterilmiştir. Bu ağ, bir veya daha fazla gizli katman ekleyerek daha yüksek istatistikler çıkarabilir (Kisi, 2008). Her düğümün çıktıları, doğrusal olmayan verileri ayırt etmek için doğrusal olmayan bir etkinleştirme işlevi tarafından takip edilen ağırlıklı birimlerdir.

ÇKYSA yöntemi, her düğüm için ağırlıklı birimlere dayalı verilerin doğrusal olmayanlığını ayırt etmek için kullanılır (Wang et al., 2009). Bu tezin kısmında çok katmanlı yapay sinir ağlarını uygulanmaktadır (Şekil 3.6).

Matematiksel olarak, katmanındaki çıkış aktivasyonu $a^{(l+1)}$, giriş aktivasyonu $a^{(l)}$ ile türetilir:


$$a^{(l+1)} = \sigma(w^{(l)} a^{(l)} + b^{(l)}) \quad (3.3.15)$$

Burada l belirli bir katmana karşılık gelir, $w^{(l)}$ ve $b^{(l)}$, l. katmanındaki ağırlığı ve eğimi gösterir ve doğrusal olmayan aktivasyon işlemi işlevini temsil eder (örneğin, sigmoid, hiperbolik teğet, doğrultulmuş doğrusal birimler). Bir m katmanlı çok katmanlı algılayıcı için, ilk giriş katmanı $a^{(1)} = x$ iken son çıkış katmanı:

$$h_{w,b}(x) = a^{(m)} \quad (3.3.16)$$

Bu denklemdeki (w) ve önyargı (b) ağırlıkları, bilinmeyen bir girdi-çıkı ilişkisine yaklaşmak için bir geri yayılım algoritması kullanılarak denetimli eğitim ile öğrenilir. Ek olarak, bu işlev kullanılarak tahmin edilen ve çıktı arasındaki fark en aza indirilecek ve çıktılar aşağıdaki gibi gösterilebilir:

$$J(W, b, x, y) = \frac{1}{2} |h_{w,b}(x) - y|^2 \quad (3.3.17)$$



Note: n is each pattern of training, s represents each iteration of training, and η is the learning rate.

Şekil 3. 3. Çok Katmanlı Yapay Sinir Ağının yapısı (Landeras et al., 2009).

3.3.6.2. Bulanık Yapay Sinir Ağları (ANFIS)

YSA ve bulanık mantığın tamamlayıcı bir şekilde bir füzyon ANFIS modelini vermektedir. YSA ile bulanık mantık entegrasyonu, azaltılmış yürütme zamanında hata toleransı azalma ile sonuçlanır, ve adaptasyon büyük ölçüde geliştirilmiştir.

ANFIS, geri yayılım gradyanı iniş hatası sindirimini ve en küçük kare hata yöntemini birleştiren karma bir öğrenme kuralı aracılığıyla bir parametre kümesini tanımlar. Bulanık çıkarım sistemleri için başlıca iki yaklaşım vardır, yani Mamdani (Mamdani, 1977) ve Sugeno'nun (Takagi and Sugeno, 1985) yöntemleridir.

İki yaklaşım arasındaki farklar Mamdani'nin yaklaşımının ortaya çıktığı kısımdan kaynaklanır Sugeno'nun yaklaşımında doğrusal veya sabit fonksiyonlar kullanılırken bulanık üyelik fonksiyonlarını (MFs) kullanır. (Pour-Ali Baba et al., 2013).

Bu kısımda, günlük referans ET_0 değerlerini tahmin etmek için Sugeno yöntemi uygulanmaktadır. Bulanık teoremin birlikte kullanımı YSA, bulanık kümenin anlaşılabilir insan bilgisini temsil etme yeteneğini öğrenme yeteneği ile birleştirir.


ANFIS yapısı, Şekil 3.7.'de gösterildiği gibi beş katmanlı ileri beslemeli bir sinir ağı içerir. Her ANFIS katmanı, düğüm işlevi tarafından açıklanan birkaç düğümden oluşur. Katman 1 ve 4'teki düğümler, dikdörtgen olarak temsil edilen uyarlanabilir düğümlerdir. 2., 3. ve 5. Katmanlardaki düğümler sabit düğümlerdir ve daireler olarak temsil edilirler. İlk katmanda, her düğüm bir dilsel etiketin üyelik notlarını oluşturur ve bir bulanıklaştırma uygulanır (Masoudi et al., 2018). Düğüm işlevi şu şekilde tanımlanabilir:

$$O^1_i = \mu_{A_i}(x) \quad (3.3.18)$$

Burada, (x) düğüm i'ye giriştir ve A_i , bu düğüm işleviyle ilişkili dilsel etikettir (bulanık kümeler: küçük, büyük). İkinci katmanda, düğümler kuralların ateşleme ağırlığını hesaplar ve ürünü gönderir. Örneğin:

$$w_i = \mu_{A_i}(y) \times \mu_{B_i}(y), \quad i = 1,2 \quad (3.3.19)$$

Bu araştırmanın bölümünde, girdi verisi olarak ortalama sıcaklık, rüzgar hızı, güneş radyasyonu ve bağıl nem olmak üzere dört parametre kullanılarak eğitim sürecindeki ET_0 tahmin etmek için bir ANFIS modeli geliştirilmektedir (Şekil 3.8). Parametreler standart min-max normalleştirme tekniği kullanılarak 0 ve 1 aralık olarak normalleştirilmiştir. Veri setleri iki gruba bölünüp, %50 eğitim ve %30 test için kullanılmıştır.



Şekil 3. 4 . Bulanık Yapay Sinir Ağı'nın yapısı

3.3.6.3. Matematiksel ve İstatistiksel Kriterleri

- (i) Tahmin Hatası Standart Sapması (RMSE):

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (O_i - P_i)^2}{n}} \quad (3.3.20)$$

- (ii) Belirleme katsayısı (R^2):

$$R^2 = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (P_i - \bar{P})^2} \quad (3.3.21)$$

- (iii) Ortalama Mutlak Hatası (MAE)

$$MAE = \frac{\sqrt{|\sum (O_i - P_i)|}}{n} \quad (3.3.22)$$

P_i , ETo'nın tahmini değeridir; O_i , Penman-Monteith denklemi kullanılarak et_0 'ın gözlemlenen veya hesaplanan değeridir; i tahmini örnek sıra numarasıdır; $i = 1, 2, \dots, n$; P , örnek sıra numarasının tahmin edilen ortalama değeridir; O , örnek sıra numarasının gözlenen ortalama değeridir; ve n , tahmin edilen değerinin örnek numarasıdır.

- (iv) Akaike Bilgi kriteri (AIC):

Akaike'nin entropiye dayalı Bilgi Kriteri (AIC) istatistiksel model değerlendirme problemlerinde temel bir etkiye sahiptir. Ayrıca seri verilerin değerlerini tahmin etmek için en uygun modeli seçmek önemlidir (Ozaki and Oda, 1977):

$$\hat{A} = n \ln R + 2 K n \quad (3.3.23)$$

n , deneysel noktaların veya gözlemlerin sayısı, ve R , karelerin toplamıdır. $\ln$; denklem tarafından hesaplanan log-olasılık fonksiyonudur (normalde dağıtılmış hatalar varsayılarak):

$$\ell = -n/2 \cdot (1 + \ln(2 \cdot \pi)) + \ln(1/n \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2) \quad (3.3.24)$$

Seilecek modeldeki parametre sayısı, A'nın en az olduėu parametredir. Birok alternatif modeli karřılařtırırken, minimum AIC deėerine sahip olan model, iyi bir uyum ve karmařıklık dengesi saėlar (Webster and McBratney, 1989).

(v) Bayesian Bilgi kriteri (BIC)

Bayesian Bilgi kriteri, Schwarz Kriteri (SIC) olarak da bilinir zaman serisi modelleri arasında karřılařtırmalı deėerlendirme iin bařka bir istatistiksel ldr, AIC ile yakından iliřkilidir (Profillidis and Botzoris, 2018).

BIC ve AIC arasındaki fark, modelin uyumunun iyiliėini arttırmak iin K parametrelerinin sayısını (regresrler veya / ve kesiřme) eklediėimizde ortaya ıkmaktadır. BIC, parametrelerin artmasıyla daha fazla ilgilenir (AIC'ye kıyasla). BIC ařaėıdaki denklem ile hesaplanır:

$$SIC \text{ or } BIC = -2 \cdot \ell/n + k \cdot \ln n / n \quad (3.3.25)$$

BIC, AIC ile aynıdır. farklı alternatif modellere gre tercih edilecek model minimum BIC deėerine sahip olan modeldir.

(vi) Nash–Sutcliffe model Efficiency Katsayısı (NSE)

Hidrolojik modellerin ngrc becerisini deėerlendirmek iin kullanılır. Olarak tanımlanır:

$$NSE = 1 - \frac{\sum_{t=1}^T (Q_0^t - Q_m^t)^2}{\sum_{t=1}^T (Q_0^t - Q_0^-)^2} \quad (3.3.26)$$

Q_0^- = Gzlenen deėerlerin ortalaması,

Q_m = Tahmin edilen deėeridir,

Q_0 = Gzlenen deėeridir.

Nash-Sutcliffe verimliliėi, modellenen zaman serisinin hata varyansının, gzlemlenen zaman serisinin varyansına blnmesinin bir eksi oranı olarak hesaplanır. Sıfıra eřit bir tahmin hatası varyansına sahip mkemmek bir model durumunda, elde edilen Nash–Sutcliffe Verimliliėi 1'e eřitir (NSE = 1). Tersine, gzlemlenen zaman serisinin varyansına eřit bir tahmin hatası varyansı reten bir model, Nash–Sutcliffe Verimliliėi 0.0 (NSE = 0). Gerekte, NSE = 0, modelin kare hatanın toplamı aısından

zaman serilerinin ortalamasıyla aynı tahmin becerisine sahip olduğunu gösterir. Gözlemlerin varyansından önemli ölçüde daha büyük bir tahmin hatası varyansına sahip modellenmiş bir zaman serisi durumunda, NSE negatif hale gelir. Gözlemlenen ortalama modelden daha iyi bir yordayıcı olduğunda sıfırdan küçük bir verimlilik ($NSE < 0$) oluşur. NSE'nin 1'e yakın değerleri, daha öngörücü beceriye sahip bir model önerir. Farklı NSE değerlerinin yeterlilik eşikleri olarak öznel uygulaması birkaç yazar tarafından önerilmiştir (McCuen et al., 2006).



4. BULGULAR VE TARTIŞMA

Bu çalışmada bulgular ve tartışma üç şamada değerdendirilmiştir. Birinci aşamada zaman serisi analizleri, ikinci aşmada enterpolasyom teknikleri ve üçüncü aşmada ise yapay zeka teknikleri ile ET_0 tahmin edilmiştir. Sudanın 120 farklı istasyonundan elde edilen veriler göz önüne alınarak ET_0 tahmin etmede kullanılan iklim parametreleri ve ET_0 tanımlayıcı istatistik verileri Tablo 4.1' de verilmiştir.

Her bir ana istasyon için ET_0 değerdelerinin tanımlayıcı istatistikleri (Tablo 4.1)'de gösterilmektedir. Tablo 4.1.'da incelendiğinde en yüksek ET_0 değerdelerin 14.01, 14.82, ve 13.61 mm.d⁻¹ ile Atbara, Halfa Elgadida, ve Kassala istasyonlarında ortaya çıktığı gözlenmektedir. En düşük ET_0 0.57, 0.61 mm.d⁻¹ ile Babanusa ve Kadugli istasyonlarında gösterilmiştir. Görüldüğü gibi Al Damazin ve Niyala istasyonlarında gözlemlenen en yüksek standart sapma değerdelerin 3.65 ve 6.17 ile en düşük değerdelerin sırasıyla 0.66 ve 0.48 ile Al Neihud ve Singa istasyonlarında elde edilmiştir.

Tablo 4. 1. Sudan'ın 33 il merkezi için ET₀ değerlerine ait Tanımlayıcı İstatistikler

İstasyon	Boylam	Enlem	Max.	Min.	Orta.	Çarpıklık	Basıklık
Abuhamed	33.44	19.51	12.03	1.186	4.94	0.352	0.53
Abunaama	34.06	12.65	11.22	0.76	3.64	0.38	0.61
Al Damazin	34.337	11.78	8.49	1.19	3.12	-0.04	-0.93
Al Gadaref	35.31	14.21	5.19	1.35	3.5	-0.85	0.16
Al Genina	22.5	13.27	13.39	0.65	4.00	0.23	0.78
Aroma	35.94	15.77	8.40	0.78	3.63	-0.11	0.29
Atbara	33.75	17.64	14.01	3.55	10.52	0.56	3.14
Huddiba	33.93	17.56	11.67	1.05	4.58	0.39	0.73
Karima	31.88	18.58	11.13	1.04	5.08	-0.09	0.26
Kadugli	29.71	11	11.75	0.61	3.77	-0.65	0.70
Kassala	36.25	15.46	13.61	3.55	7.38	0.22	2.72
Khartoum	32.5	15.46	11.25	0.84	4.60	-0.29	0.43
Kosti	32.81	12.96	10.40	0.67	3.87	-0.43	0.48
Niyala	24.88	12.05	13.06	0.76	4.64	-0.87	0.40
Sennar	37.19	19.83	10.64	0.68	3.74	-0.21	2.71
Portsudan	33.61	13.55	8.56	0.71	2.81	0.78	1.02
Babanusa	27.817	11.33	11.67	0.57	4.16	-0.78	0.53
Dongola	30.63	19.2	11.81	1.10	5.15	0.01	0.19
Eddueim	32.19	13.89	13.45	3.55	8.5	0.56	3.14
Al Fashir	25.31	13.58	10.46	0.62	3.83	-0.50	0.42
Al Neihud	28.44	12.65	12.67	0.66	4.51	-0.78	0.46
Al Obeid	30.31	13.27	11.14	0.91	4.53	-0.54	0.43
Halfa	35.6	15.31	14.82	3.57	7.73	0.22	2.82
Hayya	26.32	18.2	6.23	2.60	5.09	0.15	-0.18
Shambat	32.53	15.66	11.22	0.97	4.62	-0.26	0.45
Shendi	33.44	16.7	10.73	0.75	4.36	0.54	0.74
Singa	34.06	12.96	4.37	0.48	3.27	-0.30	0.48
Station6	32.54	20.75	12.02	1.55	5.44	0.30	0.36
Um Benin	33.95	13.6	10.63	0.67	3.74	-0.21	0.48
Madani	33.44	14.52	10.82	0.73	3.97	-0.15	0.48
Zalingi	23.44	12.96	12.46	0.72	3.79	-0.26	0.44
Wadi halfa	31.48	21.81	11.47	1.10	5.02	0.61	0.31
Tokar	37.81	18.89	8.33	1.05	3.23	3.11	1.39

4.1. Otoregresif Entegre Hareketli Ortalama Modelleri (ARIMA)

Zaman serisi analiz yöntemlerini, ARIMA (Otoregresif Entegre Hareketli Ortalama Modelleri) uygulanarak referans evapotranspirasyon değerlerini tahmin etmek için kullanılmıştır. Bu modellerini Box Jenkins modelleri olarak adlandırılır.





Bu bölümde, ARIMA modellerini kullanılarak günlük ET₀ tahmin edilmesi için Sudan'daki 33 ana meteoroloji istasyonlarından gerçekleştirilen (1982'den 2020'ye kadar) günlük zamana dayalı uzun verilerini kullanılmıştır. ARIMA modelleri, zaman serisi analizi teknikleri kullanılarak ET₀ değerlerini değerlendirmek için oluşturulmuştur. Bu amaçla, zaman serisi modellerini geliştirmek ve gelecekteki değerleri tahmin etmek için EViews version lite istatistiksel yazılım programı kullanılmıştır.





4.1.1. Zaman Serisi Modellerinin Değerlendirilmesi (ARIMA modelleri)





İlk olarak, ET_0 değerlerinin orijinal verilerinin grafiklerini çizilmektedir. Bütün istasyonları durağan olduğu bulunmaktadır. Örneğin, Şekil 4.1' de meteorolojik istasyonlarını incelendiğinde zaman serisinde herhangi bir eğilim veya trend göstermemiştir (Box et al., 2015). Üstelik, ortalama ve varyans 1982'den 2020'ye kadar sabit olup değişmemiştir. Gelecekteki değerleri tahmin etmek için fark alma işlemlerine ihtiyaç duymadığını anlamına gelmektedir.





Ayrıca, orijinal serilerinin durağan olduğunu göstermektedir. Verileri durağanlığın sabit halinde gelecekteki değerleri tahmin etmek için uygun olabilecek model belirlenmektedir.








































Şekil 4. 1. 1982-2020 ET₀ zaman serisi grafikleri


Günlük ET₀ verileri, Box-Jenkins tahmin modelleri kullanılarak ACF ve PACF grafiklerinde gecikmeler ile ilişkili olduğunu göstermektedir. Şekil 4.2 'de ACF ve PACF grafiklerinde her istasyon için orijinal verileri tanımlanmıştır. İdeal modele karar vermeden önce tüm bilgileri ve korelogram hatalarının yakalandığı için kontrol edilmesi gerekmektedir. Korelogramın artıkları ve hataları, güven sınırları içinde düz olmalıdır (Asteriou and Hall, 2007). Ayrıca, Durağan olan ya da durağan hale dönüştürülen serinin ACF ve PACF grafiklerine göre seriye uygun olabilecek model belirlenir. Şekil 4.2'de gösterildiği gibi, tüm istasyonlar 'da hem ACF hem de PACF grafiklerinde ilişkili miktarının azalışı yavaş olduğu için otoregresif hareketli ortalama modellerini oluşturulmaktadır. Bu azalışların hızlı ya da yavaş olduğuna karar vermek oldukça zor olup doğru kararı vermek yılların deneyimini gerektirmektedir.




Abuhamed İstasyonu




Al Damazin




Al Gadaref




Al Genina




Dongola İstasyonu



El fashier İstasyonu



Aroma İstasyonu



Babanusa

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.740	0.740	1807.8	0.000
		2	0.543	-0.012	12004.	0.000
		3	0.474	0.169	15208.	0.000
		4	0.459	0.121	18212.	0.000
		5	0.449	0.091	21082.	0.000
		6	0.445	0.059	23908.	0.000
		7	0.454	0.106	26843.	0.000
		8	0.446	0.052	29680.	0.000
		9	0.433	0.058	32357.	0.000
		10	0.427	0.059	34960.	0.000
		11	0.428	0.060	37574.	0.000
		12	0.422	0.036	40112.	0.000
		13	0.407	0.022	42474.	0.000
		14	0.391	0.016	44658.	0.000
		15	0.385	0.030	46773.	0.000
		16	0.387	0.036	48914.	0.000
		17	0.385	0.021	51029.	0.000
		18	0.375	0.011	53039.	0.000
		19	0.367	0.016	54959.	0.000
		20	0.359	0.008	56794.	0.000
		21	0.350	0.007	58539.	0.000
		22	0.341	0.005	60202.	0.000
		23	0.341	0.019	61859.	0.000
		24	0.336	0.003	63472.	0.000
		25	0.324	-0.005	64973.	0.000
		26	0.314	0.001	66380.	0.000
		27	0.309	0.003	67740.	0.000
		28	0.301	-0.005	69037.	0.000
		29	0.288	-0.015	70223.	0.000
		30	0.285	0.011	71380.	0.000
		31	0.276	-0.016	72469.	0.000
		32	0.264	-0.012	73467.	0.000
		33	0.257	-0.002	74412.	0.000
		34	0.247	-0.019	75284.	0.000
		35	0.243	0.003	76127.	0.000
		36	0.236	-0.011	76924.	0.000

Autocorrelation	PartialCorrelation	AC	PAC	Q-Stat	Prob	
		1	0.683	0.683	6645.6	0.000
		2	0.413	-0.101	9072.6	0.000
		3	0.314	0.137	10474.	0.000
		4	0.287	0.072	11645.	0.000
		5	0.277	0.072	12738.	0.000
		6	0.273	0.068	13802.	0.000
		7	0.272	0.064	14859.	0.000
		8	0.268	0.053	15886.	0.000
		9	0.265	0.033	16811.	0.000
		10	0.262	0.058	17717.	0.000
		11	0.242	0.020	18551.	0.000
		12	0.234	0.037	19331.	0.000
		13	0.227	0.025	20063.	0.000
		14	0.225	0.036	20785.	0.000
		15	0.227	0.034	21522.	0.000
		16	0.229	0.032	22269.	0.000
		17	0.226	0.025	23001.	0.000
		18	0.221	0.021	23697.	0.000
		19	0.214	0.019	24353.	0.000
		20	0.210	0.021	24984.	0.000
		21	0.206	0.016	25589.	0.000
		22	0.198	0.008	26148.	0.000
		23	0.192	0.013	26673.	0.000
		24	0.184	0.002	27155.	0.000
		25	0.175	0.004	27593.	0.000
		26	0.166	-0.001	27986.	0.000
		27	0.169	0.021	28394.	0.000
		28	0.163	-0.011	28771.	0.000
		29	0.154	0.003	29109.	0.000
		30	0.148	0.001	29422.	0.000
		31	0.136	-0.015	29685.	0.000
		32	0.137	0.019	29955.	0.000
		33	0.143	0.006	30246.	0.000
		34	0.137	-0.007	30514.	0.000
		35	0.131	0.003	30758.	0.000
		36	0.127	0.002	30988.	0.000

El Obied İstasyonu

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.790	0.790	8895.1	0.000
		2	0.615	-0.026	14279.	0.000
		3	0.543	0.173	18481.	0.000
		4	0.515	0.104	22263.	0.000
		5	0.504	0.105	25883.	0.000
		6	0.497	0.055	29402.	0.000
		7	0.491	0.078	32842.	0.000
		8	0.483	0.059	36164.	0.000
		9	0.469	0.043	39307.	0.000
		10	0.464	0.051	42370.	0.000
		11	0.463	0.053	45420.	0.000
		12	0.462	0.049	48459.	0.000
		13	0.456	0.034	51425.	0.000
		14	0.448	0.031	54290.	0.000
		15	0.441	0.029	57051.	0.000
		16	0.437	0.033	59783.	0.000
		17	0.430	0.016	62417.	0.000
		18	0.420	0.015	64937.	0.000
		19	0.413	0.016	67368.	0.000
		20	0.404	0.007	69700.	0.000
		21	0.400	0.020	71980.	0.000
		22	0.400	0.023	74257.	0.000
		23	0.397	0.013	76508.	0.000
		24	0.396	0.019	78731.	0.000
		25	0.390	0.010	80902.	0.000
		26	0.381	0.000	82970.	0.000
		27	0.369	-0.004	84914.	0.000
		28	0.360	0.000	86762.	0.000
		29	0.348	-0.016	88487.	0.000
		30	0.339	-0.001	90125.	0.000
		31	0.333	-0.000	91712.	0.000
		32	0.327	-0.006	93242.	0.000
		33	0.323	0.004	94734.	0.000
		34	0.317	-0.007	96166.	0.000
		35	0.312	0.004	97558.	0.000
		36	0.305	-0.009	98888.	0.000

Hayya İstasyonu

Halfa Elgadida

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.690	0.690	6780.3	0.000
		2 0.449	-0.051	9652.8	0.000
		3 0.358	0.131	11484.	0.000
		4 0.334	0.092	13073.	0.000
		5 0.324	0.078	14574.	0.000
		6 0.323	0.081	16059.	0.000
		7 0.325	0.076	17568.	0.000
		8 0.317	0.048	18996.	0.000
		9 0.305	0.048	20318.	0.000
		10 0.299	0.049	21589.	0.000
		11 0.294	0.041	22820.	0.000
		12 0.295	0.050	24059.	0.000
		13 0.291	0.032	25266.	0.000
		14 0.283	0.028	26405.	0.000
		15 0.276	0.030	27493.	0.000
		16 0.278	0.039	28593.	0.000
		17 0.271	0.014	29638.	0.000
		18 0.263	0.022	30624.	0.000
		19 0.252	0.008	31530.	0.000
		20 0.247	0.020	32401.	0.000
		21 0.239	0.005	33217.	0.000
		22 0.233	0.012	33992.	0.000
		23 0.234	0.019	34771.	0.000
		24 0.236	0.019	35566.	0.000
		25 0.237	0.018	36368.	0.000
		26 0.230	0.004	37120.	0.000
		27 0.217	-0.001	37793.	0.000
		28 0.201	-0.012	38367.	0.000
		29 0.188	-0.005	38874.	0.000
		30 0.175	-0.017	39312.	0.000
		31 0.175	0.010	39750.	0.000
		32 0.174	-0.007	40181.	0.000
		33 0.172	0.002	40601.	0.000
		34 0.170	0.003	41013.	0.000
		35 0.163	-0.005	41394.	0.000
		36 0.159	0.002	41755.	0.000

Shambat İstasyonu

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.718	0.718	7337.9	0.000
		2 0.505	-0.021	10969.	0.000
		3 0.448	0.192	13831.	0.000
		4 0.436	0.107	16544.	0.000
		5 0.426	0.086	19125.	0.000
		6 0.415	0.082	21679.	0.000
		7 0.411	0.082	23987.	0.000
		8 0.410	0.074	26389.	0.000
		9 0.405	0.068	28733.	0.000
		10 0.403	0.074	31102.	0.000
		11 0.405	0.061	33455.	0.000
		12 0.399	0.045	35729.	0.000
		13 0.388	0.030	37871.	0.000
		14 0.380	0.035	39928.	0.000
		15 0.371	0.022	41895.	0.000
		16 0.359	0.012	43733.	0.000
		17 0.351	0.019	45486.	0.000
		18 0.341	0.006	47149.	0.000
		19 0.336	0.023	48789.	0.000
		20 0.334	0.007	50378.	0.000
		21 0.328	0.013	51911.	0.000
		22 0.317	-0.004	53344.	0.000
		23 0.303	-0.007	54652.	0.000
		24 0.294	0.000	55882.	0.000
		25 0.281	-0.015	57012.	0.000
		26 0.278	0.010	58113.	0.000
		27 0.276	0.000	59197.	0.000
		28 0.268	-0.004	60222.	0.000
		29 0.257	-0.009	61166.	0.000
		30 0.249	-0.003	62053.	0.000
		31 0.244	-0.002	62903.	0.000
		32 0.236	-0.002	63718.	0.000
		33 0.232	-0.005	64483.	0.000
		34 0.215	-0.024	65146.	0.000
		35 0.207	-0.000	65758.	0.000
		36 0.199	-0.016	66321.	0.000

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.824	0.824	9672.2	0.000
		2 0.675	-0.011	16173.	0.000
		3 0.616	0.194	21981.	0.000
		4 0.596	0.122	26639.	0.000
		5 0.595	0.103	31529.	0.000
		6 0.575	0.082	36245.	0.000
		7 0.569	0.087	40857.	0.000
		8 0.564	0.071	45396.	0.000
		9 0.560	0.065	49957.	0.000
		10 0.554	0.054	54250.	0.000
		11 0.552	0.061	58596.	0.000
		12 0.548	0.044	62885.	0.000
		13 0.538	0.023	67014.	0.000
		14 0.531	0.040	71095.	0.000
		15 0.525	0.026	74966.	0.000
		16 0.519	0.026	78813.	0.000
		17 0.511	0.012	82533.	0.000
		18 0.505	0.024	86164.	0.000
		19 0.499	0.015	89721.	0.000
		20 0.494	0.016	93207.	0.000
		21 0.488	0.008	96599.	0.000
		22 0.478	0.001	99953.	0.000
		23 0.469	0.003	103008.	0.000
		24 0.462	0.002	106051.	0.000
		25 0.451	-0.011	108964.	0.000
		26 0.443	0.003	111755.	0.000
		27 0.437	-0.002	114476.	0.000
		28 0.427	-0.013	117077.	0.000
		29 0.417	-0.008	119567.	0.000
		30 0.411	0.003	121972.	0.000
		31 0.403	-0.014	124295.	0.000
		32 0.396	-0.003	126532.	0.000
		33 0.388	-0.007	128685.	0.000
		34 0.374	-0.028	130685.	0.000
		35 0.366	0.002	132597.	0.000
		36 0.361	-0.004	134459.	0.000

Shendi İstasyonu


Singa İstasyonu

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.810	0.810	9348.2	0.000
		2 0.674	0.051	15814.	0.000
		3 0.616	0.165	21214.	0.000
		4 0.592	0.124	26205.	0.000
		5 0.578	0.102	30974.	0.000
		6 0.572	0.098	35636.	0.000
		7 0.569	0.087	40247.	0.000
		8 0.561	0.063	44738.	0.000
		9 0.558	0.073	49170.	0.000
		10 0.556	0.064	53576.	0.000
		11 0.558	0.070	58016.	0.000
		12 0.556	0.048	62416.	0.000
		13 0.544	0.025	66644.	0.000
		14 0.537	0.040	70758.	0.000
		15 0.539	0.056	74908.	0.000
		16 0.536	0.022	78968.	0.000
		17 0.529	0.026	82988.	0.000
		18 0.523	0.022	86883.	0.000
		19 0.523	0.039	90785.	0.000
		20 0.519	0.015	94626.	0.000
		21 0.508	0.001	98311.	0.000
		22 0.505	0.026	101944.	0.000
		23 0.502	0.016	105547.	0.000
		24 0.497	0.008	109076.	0.000
		25 0.492	0.012	112534.	0.000
		26 0.487	0.005	115913.	0.000
		27 0.482	0.009	119234.	0.000
		28 0.478	0.005	122492.	0.000
		29 0.473	0.005	125683.	0.000
		30 0.466	-0.004	128779.	0.000
		31 0.454	-0.016	131727.	0.000
		32 0.445	-0.005	134569.	0.000
		33 0.444	0.011	137369.	0.000
		34 0.442	-0.001	140153.	0.000
		35 0.441	0.008	142924.	0.000
		36 0.434	-0.009	145612.	0.000


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.819	0.819	9567.0	0.000
		2 0.667	-0.014	15501.	0.000
		3 0.601	0.180	21056.	0.000
		4 0.577	0.117	25797.	0.000
		5 0.568	0.115	30402.	0.000
		6 0.565	0.096	34947.	0.000
		7 0.560	0.081	39416.	0.000
		8 0.553	0.068	43778.	0.000
		9 0.545	0.057	48010.	0.000
		10 0.539	0.059	52157.	0.000
		11 0.537	0.056	56266.	0.000
		12 0.533	0.042	60309.	0.000
		13 0.526	0.037	64255.	0.000
		14 0.518	0.030	68088.	0.000
		15 0.514	0.038	71950.	0.000
		16 0.508	0.019	75535.	0.000
		17 0.499	0.018	79052.	0.000
		18 0.493	0.020	82567.	0.000
		19 0.487	0.017	85945.	0.000
		20 0.480	0.009	89234.	0.000
		21 0.473	0.012	92429.	0.000
		22 0.466	0.005	95524.	0.000
		23 0.463	0.020	98580.	0.000
		24 0.460	0.010	101597.	0.000
		25 0.456	0.013	104566.	0.000
		26 0.444	-0.015	107385.	0.000
		27 0.434	0.002	110070.	0.000
		28 0.421	-0.019	112595.	0.000
		29 0.408	-0.013	114969.	0.000
		30 0.401	0.001	117268.	0.000
		31 0.392	-0.020	119463.	0.000
		32 0.385	0.003	121594.	0.000
		33 0.379	-0.013	123647.	0.000
		34 0.367	-0.021	125572.	0.000
		35 0.358	-0.004	127407.	0.000
		36 0.353	-0.005	129183.	0.000

Umbenin İstasyonu


Wad medani İstasyonu




Zalingi İstasyonu



Wadi halfa İstasyonu



Atbara İstasyonu



Edduim İstasyonu

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.621	0.621	5494.9	0.000
		2 0.362	-0.038	7365.4	0.000
		3 0.297	0.143	9626.7	0.000
		4 0.294	0.098	9864.9	0.000
		5 0.274	0.064	10922.0	0.000
		6 0.247	0.048	11793.0	0.000
		7 0.246	0.069	12647.0	0.000
		8 0.261	0.061	13647.0	0.000
		9 0.241	0.034	14372.0	0.000
		10 0.224	0.032	15088.0	0.000
		11 0.220	0.041	15779.0	0.000
		12 0.216	0.028	16447.0	0.000
		13 0.206	0.018	17044.0	0.000
		14 0.184	0.003	17525.0	0.000
		15 0.170	0.010	17939.0	0.000
		16 0.173	0.024	18363.0	0.000
		17 0.162	0.003	18736.0	0.000
		18 0.148	0.006	19060.0	0.000
		19 0.140	0.005	19331.0	0.000
		20 0.137	0.006	19698.0	0.000
		21 0.122	-0.013	19810.0	0.000
		22 0.114	0.006	19966.0	0.000
		23 0.100	-0.017	20139.0	0.000
		24 0.093	-0.001	20263.0	0.000
		25 0.089	-0.002	20377.0	0.000
		26 0.087	0.002	20485.0	0.000
		27 0.078	-0.009	20671.0	0.000
		28 0.068	-0.006	20838.0	0.000
		29 0.059	-0.010	20988.0	0.000
		30 0.044	-0.020	20716.0	0.000
		31 0.025	-0.027	20725.0	0.000
		32 0.024	0.001	20734.0	0.000
		33 0.023	-0.012	20741.0	0.000
		34 0.003	-0.004	20741.0	0.000
		35 -0.008	-0.011	20742.0	0.000
		36 -0.004	-0.001	20743.0	0.000

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.600	0.600	5126.2	0.000
		2 0.262	-0.153	6101.6	0.000
		3 0.149	0.086	6417.5	0.000
		4 0.138	0.063	6690.3	0.000
		5 0.149	0.068	7008.6	0.000
		6 0.148	0.039	7320.2	0.000
		7 0.131	0.026	7563.0	0.000
		8 0.113	0.024	7744.1	0.000
		9 0.112	0.039	7924.4	0.000
		10 0.125	0.044	8148.5	0.000
		11 0.125	0.021	8370.1	0.000
		12 0.124	0.038	8589.5	0.000
		13 0.119	0.022	8792.6	0.000
		14 0.106	0.012	8964.3	0.000
		15 0.097	0.017	9089.6	0.000
		16 0.108	0.039	9266.8	0.000
		17 0.111	0.013	9430.3	0.000
		18 0.099	0.008	9570.5	0.000
		19 0.097	0.026	9704.6	0.000
		20 0.098	0.016	9842.7	0.000
		21 0.093	0.007	9966.0	0.000
		22 0.090	0.017	10081.0	0.000
		23 0.084	0.004	10182.0	0.000
		24 0.079	0.009	10271.0	0.000
		25 0.079	0.014	10360.0	0.000
		26 0.082	0.012	10457.0	0.000
		27 0.089	0.020	10569.0	0.000
		28 0.087	0.008	10678.0	0.000
		29 0.079	0.003	10766.0	0.000
		30 0.064	-0.006	10824.0	0.000
		31 0.064	-0.001	10866.0	0.000
		32 0.066	0.008	10911.0	0.000
		33 0.062	0.006	10965.0	0.000
		34 0.065	0.009	11026.0	0.000
		35 0.065	0.007	11087.0	0.000
		36 0.062	0.003	11141.0	0.000

Tokar İstasyonu


Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.695	0.695	6882.9	0.000
		2 0.442	-0.079	9665.7	0.000
		3 0.355	0.154	11467.0	0.000
		4 0.333	0.082	13048.0	0.000
		5 0.321	0.075	14519.0	0.000
		6 0.316	0.077	15944.0	0.000
		7 0.318	0.075	17386.0	0.000
		8 0.311	0.048	18760.0	0.000
		9 0.295	0.039	20000.0	0.000
		10 0.291	0.056	21206.0	0.000
		11 0.294	0.051	22439.0	0.000
		12 0.291	0.037	23650.0	0.000
		13 0.288	0.042	24832.0	0.000
		14 0.277	0.019	25926.0	0.000
		15 0.278	0.048	27026.0	0.000
		16 0.286	0.044	28189.0	0.000
		17 0.283	0.025	29336.0	0.000
		18 0.276	0.024	30420.0	0.000
		19 0.266	0.016	31427.0	0.000
		20 0.266	0.034	32436.0	0.000
		21 0.259	0.006	33393.0	0.000
		22 0.255	0.025	34320.0	0.000
		23 0.258	0.026	35270.0	0.000
		24 0.266	0.033	36277.0	0.000
		25 0.267	0.023	37298.0	0.000
		26 0.265	0.021	38297.0	0.000
		27 0.266	0.009	39236.0	0.000
		28 0.242	-0.003	40069.0	0.000
		29 0.227	-0.002	40806.0	0.000
		30 0.213	-0.011	41453.0	0.000
		31 0.212	0.013	42094.0	0.000
		32 0.213	0.002	42744.0	0.000
		33 0.221	0.023	43443.0	0.000
		34 0.219	-0.003	44126.0	0.000
		35 0.210	0.002	44758.0	0.000
		36 0.208	0.011	45378.0	0.000

Huddiba İstasyonu


Station 6 İstasyonu

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob
		1 0.626	0.626	6681.0	0.000
		2 0.419	-0.094	9183.6	0.000
		3 0.324	0.141	10677.0	0.000
		4 0.304	0.086	11993.0	0.000
		5 0.297	0.073	13248.0	0.000
		6 0.293	0.073	14467.0	0.000
		7 0.285	0.056	15622.0	0.000
		8 0.275	0.051	16703.0	0.000
		9 0.271	0.052	17746.0	0.000
		10 0.273	0.056	18807.0	0.000
		11 0.278	0.054	19906.0	0.000
		12 0.280	0.048	21022.0	0.000
		13 0.268	0.023	22049.0	0.000
		14 0.266	0.030	22982.0	0.000
		15 0.266	0.041	23910.0	0.000
		16 0.261	0.040	24882.0	0.000
		17 0.264	0.036	25878.0	0.000
		18 0.266	0.016	26812.0	0.000
		19 0.246	0.023	27678.0	0.000
		20 0.246	0.031	28539.0	0.000
		21 0.250	0.030	29432.0	0.000
		22 0.247	0.015	30301.0	0.000
		23 0.241	0.019	31128.0	0.000
		24 0.239	0.023	31941.0	0.000
		25 0.236	0.015	32736.0	0.000
		26 0.236	0.020	33523.0	0.000
		27 0.229	0.007	34272.0	0.000
		28 0.223	0.012	34984.0	0.000
		29 0.218	0.007	35662.0	0.000
		30 0.212	0.006	36307.0	0.000
		31 0.204	-0.000	36904.0	0.000
		32 0.202	0.011	37488.0	0.000
		33 0.203	0.009	38079.0	0.000
		34 0.208	0.018	38697.0	0.000
		35 0.207	0.006	39307.0	0.000
		36 0.200	0.002	39878.0	0.000


Karima İstasyonu




Kadugli İstasyonu





Khartoum İstasyonu




Kassala İstasyonu



Kosti İstasyonu




Niyala İstasyonu




Portsudan İstasyonu

Sinnar İstasyonu



Abu naama İstasyonu



Şekil 4. 2. Her istasyon için ACF ve PACF grafikleri

Günlük ET_0 değerlerini, en uygun ARIMA modeller ile 1982-2020 dönemi için tahmin edilmektedir. Çizelge 4.2' de incelendiğinde, en iyi modellerin en yüksek belirleme katsayısı (R^2) görülmektedir. Bilindiği gibi, R^2 katsayısı gerçek ve tahmin edilen değerlerin arasındaki ilişkili gösteren katsayısıdır. Ayrıca, ARIMA modellerin sonuçlarına göre, en küçük ortalama kare hatası (RMSE), Volatilite (Sigma^2), AIC ve SIC parametrelerin değerlerine sahip elde edilmektedir.

Tablo 4.2'de inceleceğinde en iyi modeller, en büyük R^2 değerlerine sahip ARIMA (1,0,1), (1,0,2) ve (2,0,2) modellerinde göstermektedir. Ayrıca, modellerin en düşük AIC ve SIC değerlerine sahip, gelecekteki ET_0 değerlerini tahmin etmek için uygun modeller olarak kabul edilebilmektedir. ARIMA modellerinde fark alma işlemleri yapıldığında belirleme katsayısı (R^2) değerleri azaltılıp ve hata değerleri artırılmıştır. Bunun nedenle kullanılan verilerin durağan bir durumda olduğunu açıklanmaktadır. Bu amaçla, gelecekteki değerlerini tahmin edilebilmektedir.







Tablo 4.2'de gösterildiği gibi referans evapotranspirasyon için en yüksek R^2 değerleri sırasıyla 0.84, 0.85, 0.83 ve 0.82 olan Kadugli, Babanusa, El neihud ve Niyala istasyonlarında elde edilmiştir. En düşük değerler sırasıyla 0.35, 0.38, 0.39, ve 0.38 ile









Wadi Halfa, Atbara, Tokar, ve Station6 istasyonlarında elde edilmektedir. Öte yandan, en düşük hata, AIC, SIC ve R^2 değerlerine sahip gelecekteki ET_0 değerlerini tahmin etmek için her istasyon için en iyi modeller belirlenmiştir.









Tablo 4. 2. Her istasyon için ARIMA modellerinin parametreleri









İstasyon	Model	R^2	RMSE	AIC	SIC	P- değeri
Abuhamed	(1,0,2)	0.65	0.079	4.115	4.11	0.0000
Abunaama	(1,0,1)	0.60	0.024	3.25	3.26	0.0000
AlDamazin	(1,0,1)	0.67	0.059	2.126	2.127	0.0000
Al Gadaref	(1,0,1)	0.67	0.060	2.529	2.531	0.0000
Al Genina	(1,0,1)	0.74	0.005	3.028	3.667	0.0000
Aroma	(1,0,1)	0.49	0.032	3.291	3.293	0.0000
Huddiba	(1,0,1)	0.49	0.038	3.622	3.624	0.0000
Karima	(2,0,1)	0.47	0.036	3.559	3.561	0.0000
Kadugli	(1,0,1)	0.84	0.001	3.325	3.324	0.0000
Kassala	(1,0,2)	0.57	0.041	2.973	2.972	0.0000
Khartoum	(1,0,1)	0.67	0.053	2.836	2.838	0.0000
Kosti	(2,0,2)	0.63	0.061	2.854	2.855	0.0000
Niyala	(1,0,1)	0.82	0.004	3.374	3.372	0.0000
Sinnar	(1,0,1)	0.68	0.058	3.149	3.151	0.0000
Portsudan	(1,0,2)	0.56	0.053	3.286	3.288	0.0000
Babanusa	(2,0,1)	0.85	0.002	2.627	2.628	0.0000
Al Fashir	(1,0,2)	0.68	0.052	2.676	2.675	0.0000
El Neihud	(1,0,2)	0.83	0.004	3.319	3.313	0.0000
Al Obied	(1,0,2)	0.77	0.001	2.617	2.618	0.0000
Halfa	(1,0,2)	0.56	0.042	3.090	3.092	0.0000
Haya	(1,0,1)	0.56	0.034	0.243	0.243	0.0000
Shambat	(1,0,2)	0.64	0.008	3.402	3.404	0.0000
Shendi	(1,0,1)	0.48	0.036	3.474	3.477	0.0000
Singa	(1,0,2)	0.53	0.024	2.172	2.174	0.0000
Um Benin	(1,0,2)	0.74	0.001	2.362	2.363	0.0000
Madani	(1,0,2)	0.73	0.0011	2.499	2.501	0.0000
Zalingi	(1,0,2)	0.69	0.0019	2.884	2.885	0.0000
Wadi Halfa	(1,0,2)	0.345	1.69	3.366	3.368	0.0000
Dongola	(1,0,2)	0.46	0.038	3.539	3.541	0.0000
Atbara	(1,0,1)	0.38	1.472	2.201	2.202	0.0000
Edduim	(1,0,2)	0.69	0.073	3.214	3.216	0.0000
Tokar	(2,0,1)	0.39	1.47	2.931	2.933	0.0000
Station6	(1,0,1)	0.38	1.48	3.631	3.630	0.0000


Şekil 4.2.'de gerçek ve tahmin ET_0 değerlerinin dağılım grafiklerini gösterilmektedir. Bu grafiklerde, tahmin edilen referans evapotranspirasyonun değerleri, gerçek değerleri ile ne kadar uyumlu ve bağlı olduğunu gösterilmektedir.











Şekil 4. 3. ASCE PM ET0 ve tahmin referans evapotranspirasyon değerlerinin karşılaştırılması

Çok değişkenli ARIMA modelleri, modelin uyum iyiliğini düzeltilmiş R^2 ve hatayı artıracaktır. Ayrıca zayıf tahmin edilen modeli yapılacaktır. Az parametrelili modeller, aşırı parametrelili modellerden daha iyi sonuçlar vermektedir.

Başka deyişle, ARIMA modelleri, referans evapotranspirasyon parametresinde tatmin edici sonuçlar elde etmiştir ancak, birçok değişkene sahip ARIMA modellerinin modelin uyum iyiliğini etkilediğini ve onu kötü tahmin edilen bir model haline getirdiğini ve bunun da modellerin performansını düşürdüğünü belirtmek gerekir. Bu nedenle, parsimonious modeller aşırı parametrelili modellerden daha iyi sonuçlar verir.

4.2. Enterpolasyon Teknikleri

Bu bölümde, günlük referans evapotranspirasyondan elde edilen günlük referans evapotranspirasyon değerleri, boylam, enlem ve yükseklik koordinatları olan konum bilgileri kullanılarak (Tablo 4.3.) sunulan 120 istasyon ile ilgili mekansal dağılım haritaları oluşturmak için farklı enterpolasyon yöntemleri kullanılmıştır. Jeostatistik analizin sonuçları aşağıda verilmiştir.

Bu bölümde Yarı variogram parametreleri (Nugget C0, sill C0+C ve range A) kullanılarak noktaların uzamsal otokorelasyonunu gösteren sıradan kriging modellerini tahmin etmek için Yarı variogram modellerinin uydurma testleri uygulanmaktadır (Vieira et al., 1983).

Önceki bölümde belirtildiği gibi, Kriging enterpolasyon yöntemlerini kullanmak için verilerin dağılım fonksiyonu analiz edilmiş ve tüm verilerin Sudan'daki 33 ana konum bilgilerine dayanarak ET0'a dayalı normal bir olasılık dağılımına sahip olduğu bulunmuştur. Daha sonra verilerin semivariogram değerleri hesaplanmış ve en uygun modeller en yüksek düzeltilmiş R^2 ve RSS değerlerinin artık toplamalarının en düşük

değeri esas alınarak belirlenmiştir. Verilerin uzamsal otokorelasyonu, ET0 verilerinin uzamsal korelasyonunu gösteren Tablo 4.3.'de gösterildiği gibi Nugget, Sill, ve Range parametrelerine göre incelenmiştir.

Öte yandan, Mayıs, Temmuz, Ağustos, Eylül, Ekim ve Kasım aylarında gözlemlere çok yakın noktalar arasındaki en küçük mesafelerin, konumsal olarak ilişkili olan ve birbirinden ayrılan gözlemlerden daha benzer değerlere sahip olduğu gözlenmiştir.

Tablo 4. 3. ET₀ değerlerine ait izotropik yarıvariogram bileşenleri


Aylar	Model	Nugget (C ⁰)	Sill(C ⁰ +C)	Range(A)	R ²	RSS
Ocak	Spherical	0.522	2.05	106.61	0.22	1.97
Şubat	Spherical	2.944	8.823	404.20	0.231	1.78
Mart	Linear	2.523	2.523	10.89	0.66	0.577
Nisan	Gaussian	2.37	4.457	12.09	0.243	1.28
Mayıs	Spherical	1.297	3.152	12.68	0.958	0.119
Haziran	Spherical	0.067	1.431	1.01	0.163	0.069
Temmuz	Spherical	0.800	2.222	28.13	0.840	0.096
Ağustos	Exponential	1.146	2.293	6.360	0.68	0.221
Eylül	Gaussian	0.802	1.825	4.550	0.98	0.013
Ekim	Spherical	0.820	2.654	7.640	0.89	0.299
Kasım	Exponential	0.970	4.157	1.660	0.68	1.530
Aralık	Spherical	3.289	7.553	74.90	0.154	1.03

Gösterildiği gibi, en önemli indeksler R² ve RSS değerleri olup, gözlemler ile yarı değerler arasındaki mesafeye (ET₀) göre yarı değişkenlik parametrelerinin çizilmesiyle ET₀ değerleri arasındaki uzamsal otokorelasyonu göstermiştir.


En yüksek R² değerleri Eylül, Mayıs, Ekim ve Temmuz aylarında 0.98, 0.95, 0.84 ve 0.89 iken, orta değerler Mart, Ağustos ve Kasım aylarında sırasıyla 0.66,0.68 ve 0.68 olarak gözlenmiştir. Her ayın yarı variogram modelleri Şekil 4.3.'de görüldüğü gibi yarı variogram parametrelerinin değerleri ile çizilmiştir. Ayrıca Eylül, Haziran, Ocak, Temmuz, ve Mayıs aylarında sırasıyla modellerle 0.013, 0.069, 0.085, 0.069 ve 0.11 olan en düşük RSS değerleri elde edilmiştir. Bu bölümde R² ve RSS değerlerine göre gaussian ve spherical modelleri en iyi modeller olarak kabul edilmektedir.

Şekil 4.4.'de görüldüğü gibi, Ocak ayındaki yarı değişkenlik değerlerinin, yarı değişkenliğin artmayı bıraktığı mesafeyi gösteren daha karmaşık veya gürültülü bir model göstermesi muhtemeldir ve bu, daha az benzer değerlere sahip daha uzak noktaları göstermiştir; bu, mesafenin mekansal olarak otokorelasyon olmadığı anlamına gelmektedir. Aynı şey Şubat, Mart, Nisan, ve Aralık aylarında da açıkça görülmüştür. Aşağıdaki grafiklerine göre, konumsal mesafelerin daha uzak


özelliklerin belirli bir mesafede daha büyük bir yarı değişkenliğe veya daha az ilişkili değerlere sahip olduğunu anlamına gelmiştir.




Spherical model ($C_0 = 0.5221$; $C_0 + C = 2.0709$; $A_{Major} = 106$,
 $A_{Minor} = 106.61$; $r^2 = 0.225$; $RSS = 1.96$)




Spherical model ($C_0 = 2.9440$; $C_0 + C = 8.8231$; $A_{Major} = 404$,
 $A_{Minor} = 404.20$; $r^2 = 0.230$; $RSS = 17.8$)




Linear model ($C_0 = 2.5239$; $C_0 + C = 2.5239$; $A_0 = 10.89$; $r^2 =$
 $RSS = 0.577$)



Gaussian model ($C_0 = 0.4310$; $C_0 + C = 2.3160$; $A_0 = 0.57$; r^2 RSS = 0.310)




Spherical model ($C_0 = 1.2970$; $C_0 + C = 3.1520$; $A_0 = 12.68$; r^2 RSS = 0.119)




Spherical model ($C_0 = 0.0670$; $C_0 + C = 1.4310$; $A_0 = 1.01$; r^2 RSS = 0.0696)

July




Spherical model ($C_0 = 0.8000$; $C_0 + C = 2.2220$; $A_0 = 28.13$; r^2
RSS = 0.0964)

August




Exponential model ($C_0 = 1.1460$; $C_0 + C = 2.2930$; $A_0 = 6.36$; r^2
RSS = 0.221)


September




Gaussian model ($C_0 = 0.8020$; $C_0 + C = 1.8250$; $A_0 = 4.55$; r^2
RSS = 0.0137)



Spherical model ($C_0 = 0.8200$; $C_0 + C = 2.6540$; $A_0 = 7.64$; r^2
RSS = 0.299)



Exponential model ($C_0 = 0.9700$; $C_0 + C = 4.1570$; $A_0 = 1.66$; r
RSS = 1.53)



Spherical model ($C_0 = 0.1400$; $C_0 + C = 3.3190$; $A_0 = 0.99$; r^2
RSS = 1.41)

Şekil 4. 4. Yarıvariogram modellerinin parametreleri




4.2.1. Ordinary Kriging Yönteminin Değerlendirilmesi




kriging yöntemi, ET_0 değerlerini enterpolasyon Modelleri olan yarı değişkenlik parametrelerine dayanarak sıradan kriging modellerini tahmin etmek için kullanılmıştır. Bu modeller aylık ET_0 verileri için uygulanmıştır. Her ay için RMSE, MAE ve MBE hata değerlerine sahip modellerin gösterildiği Tablo 4.4.'de sunulduğu gibi, M.E'nin en düşük değeri Şubat ayında -0.00135, en yüksek değeri Nisan ayında 1.30 idi. Diğer taraftan en düşük değerler sırasıyla Ocak, Şubat, Nisan, Haziran ve Aralık aylarında 0.034, 0.24, 0.22, 0.16 ve 0.04 olarak gözlenmiştir. RMSE'NİN en düşük değeri Nisan ayında 0.059, en yüksek değeri ise Mart ayında 2,59 olarak gerçekleşmiştir. MSE'nin en düşük değeri Temmuz ayında -0.003, en yüksek değeri Nisan ayında 1.0095 ortaya çıkmıştır.




Tablo 4. 4. Referans evapotranspirasyonun Ordinary kriging yöntemi ile tahminin içi,n modeller ve hata değerleri


Ay	Model	M.E	RMSE	M.S. E
Ocak	Spherical	0.034	0.878	0.022
Şubat	Spherical	-0.013	1.668	-0.010
Mart	Linear	0.100	2.59	0.0228
Nisan	Gaussian	1.30	0.059	1.0095
Mayıs	Spherical	-0.026	1.28	-0.001
Haziran	Spherical	0.07	1.168	0.041
Temmuz	Spherical	-0.037	0.956	-0.003
Ağustos	Exponential	-0.015	1.35	-0.017
Eylül	Gaussian	0.009	1.039	0.0131
Ekim	Spherical	-0.004	1.216	-0.003
Kasım	Exponential	0.0138	1.528	0.0085
Aralık	Spherical	0.0329	1.694	0.017

Şekil 4.4. ve 4.5.'de gösterildiği gibi, hesaplanan ET_0 ile karşılaştırılarak tahmin edilen değerlerin doğruluğunu tahmin etmek için hata diyagramlarının sayısı tüm aylar boyunca Kök Ortalama Kare Standart Hatası (RMSE) temel alınarak çizilmiş ve hesaplanmıştır.





















Şekil 4. 5. Her ayın hata grafiklerinin dağılımları










Şekil 4. 6. ASCE PM ve tahmin edilen ET₀'nın değerlerinin dağılım grafikleri


Aylık ET_0 verilerinin mekansal dağılım haritaları, farklı meteoroloji istasyonlarının boylamı, enlemi ve yüksekliği olan konum bilgilerine göre oluşturulmaktadır (Şekil 4.6).

Mekansal haritalara göre, Ocak, Şubat ve Mart aylarında Sudan'ın Kuzey, güney ve doğu kesiminde yüksek oranda ET_0 vardı. Nisan ayında, ET_0 değerleri kuzeybatı, uzak batı ve Sudan'ın merkezinde elde edildi. Tüm doğu kısmı Mayıs, Haziran ve Temmuz aylarında çok yüksek ET_0 oranlarından etkilenmektedir. Ağustos ayında, en yüksek oranlar kuzey ve doğu bölgelerinde yoğunlaştı. Öte yandan uzak kuzey ve batıda Eylül ve Ekim aylarında yüksek değerler gözlenmektedir.


Sudan'ın merkezi Kasım ayında en yüksek ET_0 değerlerini gözlemlerken, Kuzey ve güney batı kısımları Aralık ayında yüksek değerler elde etti. Tüm bu farklı değişiklikler, ET_0 değerini hesaplamak ve tahmin etmek için ana değişkenler olarak sıcaklık, rüzgar, güneş radyasyonu ve bağıl nem parametrelerini kullanan ASCE PM denklemini kullanarak ET_0 değerlerini hesaplamak için kullanılan iklimsel değişkenlere bağlıdır.




Şekil 4. 7. Ordinary Kriging haritası (Ocak)




Şekil 4. 8. Ordinary Kriging haritası (Şubat)




Şekil 4. 9. Ordinary Kriging haritası (Mart)




Şekil 4. 10. Ordinary Kriging haritası (Nisan)




Şekil 4. 11. Ordinary Kriging haritası (Mayıs)




Şekil 4.12. Ordinary Kriging haritası (Haziran)




Şekil 4. 13. Ordinary Kriging (Temmuz)




Şekil 4. 14. Ordinary Kriging (Ağustos)




Şekil 4. 15. Ordinary Kriging (Eylül)



Şekil 4. 16. Ordinary Kriging (Ekim)



Şekil 4. 17. Ordinary Kriging (Kasım)



Şekil 4. 18. Ordinary Kriging (Aralık)




4.2.2. Basit Kriging Yönteminin Değerlendirilmesi




Sudan ın ET_0 basit kriging yöntemiyle haritalanmasında semivariogram değerleri ve hata değerleri Tablo 4.5.'te verilmiştir. Seçilen semivariogram modellerinin performans göstergesi R^2 değerlerine göre, en yüksek değerler Eylül 0.68 olan 0.961, 0,90 ve orta değerleri Ağustos ayında gözlemlendi 0.834 ise, ve Kasım ayları, 0.682 sırasıyla; en düşük değerleri 0.02 olan, Eylül, Haziran, Ocak ve Temmuz aylarında 0.069, 0,085 elde edilirken, ve 0.099 ocak alanı olan, Mayıs, Ekim ve Temmuz aylarında elde edilmiştir. Diğer taraftan, hata değerleri Tablo 4.5.'te gösterildiği gibi ay bazında modellerin doğruluğuna da belirtilmiştir. M.E'nin en düşük değeri Şubat ayında -0.22, en yüksek değeri Mayıs ayında 0.057 olarak elde edilmiştir. Ocak ayında en düşük RMSSE değeri 0.918, Mart ayında en yüksek değer 1.71 iken, Eylül ve Aralık aylarında sırasıyla 1.086 ve 0.002 olan en düşük ve en yüksek RMSSE değerleri elde edilmektedir.




Tablo 4. 5.Yarı variogram parametrelerine göre basit Kriging modelleri




Aylar	Model	R^2	RSS	M.E	RMSE	RMSSE
Ocak	Spherical	0.22	1.97	0.0086	0.918	0.904
Şubat	Exponential	0.231	1.78	-0.22	1.63	0.822
Mart	Gaussian	0.000	0.577	0.0013	1.68	0.971
Nisan	Spherical	0.243	1.28	-0.003	1.270	0.91
Mayıs	Gaussian	0.961	0.109	0.057	1.280	1.066
Haziran	Gaussian	0.163	0.069	0.025	1.191	0.955
Temmuz	Exponential	0.834	0.099	-0.004	0.95	0.905
Ağustos	Exponential	0.68	0.221	-0.003	1.33	0.96
Eylül	Spherical	0.982	0.020	0.00008	1.033	1.086
Ekim	Gaussian	0.900	0.295	-0.0043	1.126	1.08
Kasım	Exponential	0.689	1.53	-0.020	1.22	1.07
Aralık	Spherical	0.154	1.13	0.051	1.71	0.002

Penman -Montieth ET_0 ve öngörülen değerler Şekil 4.8.'de görüldüğü gibi çizilmiştir. Bu, modellerin gelecekteki değerleri tahmin etmeye daha uygun hale getirmek için modellerin doğruluğunu tahmin eden tahminlerin hatalarını değerlendirmek için modellerin hatalarını şekil 4.7'de gösterilmiştir.





















Şekil 4.19. Hataların aylara göre dağılım grafikleri











Şekil 4.20. ET0'ın gerçek ve öngörülen değerlerinin dağılım grafikleri

Şekil 4.9.'da Aylık ET_0 verilerinin mekansal dağılım haritalarının, farklı meteoroloji istasyonlarının boylamı, enlemi ve yüksekliği olan konum bilgilerine göre oluşturulduğunu göstermektedir. Dağılım haritalarına göre Ocak ve Şubat aylarında Sudan'ın Kuzey, güney ve doğu kesimlerinde aynı aylarda daha yüksek olan normal kriging haritalarına kıyasla yüksek oranda ET_0 görülmemiştir. Mart, Nisan ve Mayıs aylarında kuzeybatı, uzak batı ve Sudan'ın merkezinde ET_0 değerleri elde edildi ve bu normal Kriging yönteminde aynı etkilenen oranlardı. Tüm doğu kısmı Mayıs, Haziran ve Temmuz aylarında çok yüksek ET_0 oranlarından etkilenmektedir. Ağustos ayında, en yüksek oranlar kuzey ve doğu bölgelerinde yoğunlaştı. Öte yandan uzak kuzey ve batıda Eylül ve Ekim aylarında yüksek değerler gözlenmektedir.







Şekil 4. 21. Basit kriging haritası (Ocak)




Şekil 4.22. Basit Kriging Haritası (Şubat)




Şekil 4. 23. Basit Kriging haritası (Mart)




Şekil 4. 24. Basit kriging haritası (Nisan)




Şekil 4. 25. Basit kriging (Mayıs)




Şekil 4. 26. Basit kriging (Haziran)




Şekil 4. 27. Basit Kriging (Temmuz)




Şekil 4. 28. Basit Kriging haritası (Ağustos)




Şekil 4. 29. Basit Kriging haritası (Eylül)



Şekil 4. 30. Basit Kriging haritası (Ekim)



Şekil 4. 31. Basit Kriging haritası (Kasım)



Şekil 4. 32. Basit Kriging haritası (Aralık)

Şekil 4.10. ve 4.11.'a göre, ET_0 gerçek ve öngörülen değerleri arasındaki hatalar ve karşılaştırmalar çizildi; bu, tüm noktalar arasındaki korelasyonu gözlemleyen regresyon çizgisi etrafındaki değerlerin dağılımını açıkça gösterilmiştir.




4.2.3. Ters Mesafe Ağırlığının Yönteminin Değerlendirilmesi (IDW)




Ters mesafe ağırlığı yöntemin RMSE değerleri çok yüksek olduğunu gösterilmiştir (Tablo 4.6). Basit kriging modellerine kıyasla her ay için en düşük RMSE değerlerini gösterir, bu da IDW yönteminin öngörülebilir modeller olmak için uygun olduğu anlamına gelir. Ayrıca, M.E değerleri de sıradan ve basit kriging modellerinin ortalama hatalarından daha düşüktür.




Tablo 4. 6. Ters mesafe ağırlığı modelinin parametreleri (IDW)




Ay	RMSE	M.E
Ocak	0.95	0.147
Şubat	0.295	1.70
Mart	0.176	1.726
Nisan	0.197	1.266
Mayıs	0.325	1.268
Haziran	0.211	1.17
Temmuz	0.113	0.980
Ağustos	0.214	1.343
Eylül	0.199	1.326
Ekim	0.223	1.304
Kasım	0.218	1.301
Aralık	1.66	0.02

Şekil 4.10. ve 4.11.'a göre, ET_0 gerçek ve öngörülen değerleri arasındaki hatalar ve karşılaştırmalar çizildi; bu, tüm noktalar arasındaki korelasyonu gözlemleyen regresyon çizgisi etrafındaki değerlerin dağılımını açıkça gösterilmiştir.





















Şekil 4. 33. Hataların aylara göre dağılım grafikleri











Şekil 4.34. ET_o'ın ve öngörülen değerlerinin dağılım grafikleri


Mekansal haritaları oluşturuldu ve Sudan'ın farklı bölgelerinde ET_0 değerlerinde farklı değişiklikler gösterdi(Şekil 4.13). Mekansal haritalara göre Ocak ayında Sudan'ın tüm bölgelerinde mantıksal ET_0 değerleri en az değer olarak görülmüştür. En yüksek değerler Şubat, Mart ve Nisan aylarında daha düşük değerler elde eden uzak doğu kısmı hariç tüm Sudan'da elde edilmiştir. Mayıs ayında güneybatı kısmı Sudan'ın diğer bölgelerine göre daha yüksek değerler gösterirken, en yüksek değerler Haziran ve Temmuz aylarında uzak kuzey ve uzak doğu'da (kızıldeniz eyaleti) elde edilmiştir. En yüksek değerler Ağustos ayında Sudan'ın uzak kuzeyindeydi. Kuzey eyaletlerinde, orta kesimlerde ve kuzeybatıda (Çöl) daha yüksek ET_0 değerleri ile eylül ve Ekim ayları gözlenmiştir. Öte yandan, Sudan'ın çoğu eyaleti, hem Kasım hem de Aralık aylarında uzak doğu ve orta Sudan'da en az değerler elde edilmesi dışında yüksek değerlerden etkilenmiştir.




Şekil 4. 35. Ters Mesafe Ağırlığın haritası (Ocak)




Şekil 4. 36. Ters Mesafe Ağırlığın haritası (Şubat)




Şekil 4. 37. Ters Mesafe Ağırlığın haritası (Mart)




Şekil 4. 38. Ters Mesafe Ağırlığın haritası (Nisan)




Şekil 4. 39. Ters Mesafe Ağırlığın (Mayıs)




Şekil 4. 40. Ters Mesafe Ağırlığın haritası (Haziran)




Şekil 4. 41. Ters Mesafe Ağırlığın haritası (Temmuz)




Şekil 4. 42. Ters Mesafe Ağırlığın haritası (Ağustos)




Şekil 4. 43. Ters Mesafe Ağırlığının haritası (Eylül)



Şekil 4. 44. Ters Mesafe Ağırlığın haritası (Ekim)



Şekil 4. 45. Ters Mesafe Ağırlığın haritası (Kasım)



Şekil 4. 46. Ters Mesafe Ağırlığın haritası (Aralık)

4.2.4. Mekansal Enterpolasyon Yöntemlerinin En iyi Modelleri

Tablo 4.7. ve 4.8.'ye göre, jeostatik analiz yöntemlerinin en iyi modelleri kısaca her ay için en yüksek R^2 ve en azından RSS değerlerine dayalı semivariance modelleri gösterdi ve Sıradan karşılaştırıldığında düşük, basit kriging ve IDW yöntemleri olan ara değerlendirme yöntemleri sunulmuştur.

İlk olarak, Tablo 4.7.'de sunulan yarı değişkenlik parametreleri kullanılarak referans evapotranspirasyon değerlerinin uzamsal otokorelasyonunu göstermek için yarı değişkenlik modelleri kullanılmıştır. Her ay için en yüksek R^2 ve en düşük RSS değerlerine dayanan uzamsal otokorelasyon yönteminin en iyi modellerini gösterir. Genel olarak, Spherical ve Gaussian modelleri diğer modellere göre daha iyi sonuçlar gösterip en iyi modeller olarak kabul edilmiştir.

En yüksek R^2 değerleri 0.958,0.84, 0.98,0.89, en düşük RSS değerleri ise Mayıs, Temmuz, Eylül ve Ekim aylarına göre 0.119, 0.096, 0.013, 0.299 bulunmuştur.

Tablo 4. 7. R^2 ve RSS değerlerine dayalı yarı varyans parametrelerini kullanan mekansal otokorelasyon yöntemlerinin en iyi modelleri

Ay	Model	Nugget (C^0)	Sill (C^0+C)	Range(A)	R^2	RSS
Mayıs	Spherical	1.297	3.152	12.68	0.958	0.119
Temmuz	Spherical	0.800	2.222	28.13	0.84	0.096
Eylül	Gaussian	0.802	1.825	4.550	0.98	0.013
Ekim	Spherical	0.820	2.654	7.640	0.89	0.299

Ayrıca, en iyi konumsal enterpolasyon yöntemleri, her ay için en az RMSE ve MSE değerlerine göre seçilmiştir. Modellerin çoğunun gösterildiğini belirtmek gerektirmektedir. En iyi sonuçlar Spherical ve Gaussian modelleriydi.

Tablo 4. 8. RMSE ve MSE değerlerine dayalı en iyi uzamsal enterpolasyon yöntemleri

Ay	Seçilen Model	RMSE	M.E
Ocak	Ordinary Kriging/Spherical	0.87	0.034
Şubat	IDW	0.295	1.70
Mart	IDW	0.176	1.72
Nisan	Ordinary Kriging/Gaussian	0.059	1.30
Mayıs	IDW	0.325	1.266
Haziran	Basit Kriging/Gaussian	1.191	0.025
Temmuz	IDW	0.113	0.98
Ağustos	IDW	0.214	1.343
Eylül	Basit Kriging/Spherical	1.033	-0.003
Ekim	IDW	0.223	1.304
Kasım	IDW	0.218	1.301
Aralık	IDW	0.166	0.02

Şekil 4.13.'de, farklı meteoroloji istasyonlarının boylamı, enlemi ve yüksekliği olan konum bilgilerine göre Sudan'daki farklı konumların aylık ET_0 değerlerinin dağılımını göstermek için mekansal haritalar oluşturulmuştur. Farklı yöntemlere ilişkin haritalara göre, Ocak, Şubat ve Mart aylarında Sudan'ın Kuzey, güney ve doğu kesiminde yüksek oranda ET_0 vardı. Nisan ayında, ET_0 değerleri kuzeybatı, uzak batı ve Sudan'ın merkezinde elde edildi. Tüm doğu kısmı Mayıs, Haziran ve Temmuz aylarında çok yüksek ET_0 oranlarından etkilenmektedir.

Ağustos ayında, en yüksek oranlar kuzey ve doğu bölgelerinde yoğunlaştı. Öte yandan uzak kuzey ve batıda Eylül ve Ekim aylarında yüksek değerler gözlenmiştir. Sudan'ın merkezi Kasım ayında en yüksek ET_0 değerlerini gözlemlerken, Kuzey ve güney batı kısımları Aralık ayında yüksek değerler elde etmektedir. Enterpolasyon yöntemleri arasındaki farklar farklı konumlara, zaman aralıklarına, veri sayısına, enterpolasyon işlevlerine ve her yöntem için farklı doğrulukları gösteren diğer değişkenlere bağlıdır (Kamali et al., 2015). Sudan'da Ocak ayın boyunca, genellikle ortalama maksimum sıcaklık $23^{\circ}C$ ile yüksek ila $36^{\circ}C$ ile çok yüksek ila $36^{\circ}C$ ile çok yüksek arasında değişir, bu da kışın bile havanın gün ortasında sıcak olduğu ve gece vaktinde sıcaklığı yaklaşık $19^{\circ}C$ 'ye düşmeye başlamaktadır. Bu nedenle ET_0 oranları gün ortasında artmaktadır. Enterpolasyon teknikleri, farklı sıcaklığın değişikliklerinden dolayı etkilenmiştir.

Sudan'nın iklimi çok farklı olduğu için interpolasyon tekniklerindeki değişiklikleri olmuştur. Sudan tropikal bölgede yer bulunmaktadır. Bu nedenle Sudan iklim bölgeleri genellikle çöl ikliminden tropikal iklime kadar değişmiştir. Dağılımı kuzey Sudan'daki sıcak çöl iklimine benzemektedir. İklim, Kızıldeniz kıyısındaki Akdeniz iklimine, kuzey-orta Sudan'daki yarı çöl iklimine, Güney-Orta ve batı Sudan'daki zayıf savan iklimine, ardından Güney Sudan'daki zengin savan iklimine ve Güney Sudan'ın aşırı tropikal iklimine sahip olduğu için interpolasyon yöntemleri arasındaki farklar farklı aylara göre değişmiştir. Sudan'da Ocak ayında yaklaşık 31 °C derece yüksek sıcaklıklarla kış bile sıcaktır, ancak bazen geceleri soğuk olabilir, aslında rekor soğuk 1°C derecedir ve ilkbaharda sıcaklıklar hızla yükselir ve 40 °C dereceye zaten Nisan ayında ve Nisan-Mayıs aylarında sıcaklık bazen 47 °C dereceye ulaşır. Temmuz ve Ağustos aylarında (Sonbahar mevsimi) yağmurla birlikte mevsimsel rüzgarın etkisi altında sıcaklık biraz düşer, ancak yaklaşık 38-39 °C derecede oldukça yüksek kalır, ardından sonbaharın sonunda Ekim ve Kasım ayları arasında hafifçe yükselir. Bu açısından, Sudan'ın farklı iklimsel bölgeleri olduğu için ET_0 değerlerini değiştirip interpolasyonun tekniklerin parametreleri etkilenmiştir.

4.3. Çoklu Doğrusal Regresyon Yöntemi

Bu çalışmanın bölümünde, modellerin performansını istatistiksel olarak değerlendirmek için yapay zeka yöntemleri ile karşılaştırmak amacıyla çoklu doğrusal regresyon yöntemi uygulanarak standart hata, T-testi, F, ve P değerlerine göre modelleri değerlendirilip T- değerinden bu ilişkinin istatistiksel açıdan anlamlı olduğunu gösterilmiştir. Ayrıca, istatistiksel açıdan anlamlı pozitif doğrusal bir ilişki vardır (Tablo 4.15).

Tablo 4. 9. Sudan'da ET_o için çoklu doğrusal regresyonun parametrelerin özeti




Girdi	Katsayı	Standart Hata	Eğitim		F	R^2
			T değeri	Olasılık P-değeri		
Intercept	49.59	0.461	107.37	0	5613.97	0.70
Tort	-0.83	0.0097	-85.64	0		
Rn	-2.11	0.0199	-105.96	0		
Intercept	16.76	0.168	99.47	0	15875.7	0.93
Tort	-0.272	0.002	-94.12	0		
U2	1.1008	0.006	158.42	0		
Rn	-0.883	0.0093	-95.01	0		
Intrcept	5.628	0.093	59.96	0	73663.79	0.98
Tort	-0.123	0.001	-83.68	0		
U2	0.996	0.0030	329.50	0		
RH	-0.045	0.0002	-185.05	0		
Rn	0.037	0.0063	5.840	0		
Test						
Intercept	24.42	0.453	53.85	0	1031.94	0.60
Tort	-0.35	0.008	-43.19	0		
Rn	-1.03	0.026	-38.99	0		
Intercept	15.14	0.238	63.40	0	6680.34	0.92
Tort	-0.24	0.004	-58.88	0		
U2	1.08	0.010	107.183	0		
Rn	-0.79	0.013	-60.27	0		
Intercept	4.827	0.118	40.67	0	3764.31	0.98
Tort	-0.106	0.001	-56.49	0		
U2	1.029	0.003	259.21	0		
RH	-0.04	0.000	-141.68	0		
Rn	0.051	0.0078	6.53	0		




Ayrıca, R^2 , MAE, RMSE ve NSE değerlerine göre modelleri tablo 4.16'te gösterildiği gibi değerlendirilmiştir. Eğitim ve test veri setlerindeki tüm değişkenlerin dayalı modeli en iyi çıkmıştır. Başka bir deyişle, en düşük RMSE ve MAE değerlerine sahip tüm değişkenlerine dayalı modelini seçilmiştir. Eğitim ve test veri setlerinde R^2 değeri 0.97 çıkmıştır. Öte yandan, 0 ile 1 arasındaki NSE değeri, çoklu doğrusal regresyon modeli iyi tahmin edici olduğunu göstermiştir (Ritter and Munoz-Carpena, 2013) Başka bir ifadeyle, daha öngörücü beceriye sahip bir modeldir. Eğitim ve test verilerinde Tablo 4.16'da tüm kombinasyonlarına dayanan modelin NSE değerleri 0.99 olarak elde edilmiştir.

Tablo 4. 10. Eğitim ve test aşamalarındaki çoklu doğrusal regresyon modellerinin MAE, RMSE ve R2 istatistikleri

Girdi	Eğitim			
	MAE	RMSE	NSE	R2
Tort,Rn	1.49	1.80	0.84	0.51
Tort,U2,Rn	0.52	0.64	0.98	0.86
Tort,,U2,Rn,RH	0.20	0.27	0.99	0.97
Test				
Tort,Rn	1.01	1.24	0.91	0.60
Tort,U2,Rn	1.51	0.62	0.98	0.85
Tort,U2,Rn,RH	0.38	0.43	0.99	0.97

Şekil 4.29.'de gösterildiği gibi, eğitim ve test veri setlerinde sıcaklık, güneş radyasyonu, rüzgar hızı ve nem parametrelerinin kombinasyonlarına dayanan modellerin regresyonun grafiklerini gösterilmiştir. Çoklu regresyon tahmini ve ASCE hesaplanan referans evapotranspirasyonun değerleri arasındaki korelasyonu bulunmuştur. Çoklu lineer regresyon modeli, yapay zeka yöntemleri ile karşılandığında, sonuçların doğrulukları çok iyi bulunmuştur. Çoklu lineer regresyon modeli istatistiksel olarak çok iyi sonuçlar göstermiştir. Başka bir ifadeyle, iyi öngörücü bir modeldir.





Şekil 4. 47. Farklı iklim kombinasyonlarına dayalı modellerle tahmin edilen ETo ve ASCE PM ETo karşılaştırılması (Eğitim ve test)

4.4. Yapay Zeka Uygulamaları

Sudan'ın ET_0 değerlerinin tahmininde yapay zeka uygulamaları olarak çok katmanlı yapay sinir ağları, Bulanık yapay sinir ağları yöntemleri kullanılmıştır.

Çalışmanın bu bölümünde ET_0 değerlerini tahmin etmek kullanılan değişkenler ortalama sıcaklık (Tort), rüzgar hızı (W m/s), güneş radyasyonu (Rs MJ/m²/gün), ve bağıl nemdir (RH%). Referans evapotranspirasyon değerleri, Sudan'ın farklı bölgelerinden 38 yıl ilişkin toplanan günlük meteorolojik veriler kullanılarak hesaplanmıştır (1982-2020). Referans evapotranspirasyon değerlerini hesaplamak için ASCE Penman-Monteith denklemi kullanılmıştır. Referans bitki su tüketimi tahmin etmek için veriler eğitim ve test veri setlerine ayrılmıştır. Eğitim ve test verileri için her bir değişkenin tanımlayıcı istatistikleri Tablo 4.9'da gösterilmiştir.

Tablo 4. 11. Eğitim ve Test için İklim Değişkenlerinin Tanımlayıcı İstatistikleri

Değişken	Ortalama	Maksimum	Eğitim			
			Minimum	SD	Basıklık	Çarpıklık
Sıcaklık	28.04	40.07	18.23	3.166	-0.092	-0.095
Rüzgar	3.72	10.25	0.316	4.01	3.99	4.45
Bağıl Nem	39.21	90.94	4.44	22.6	-1.29	0.31
Güneş Radyosu	8.12	11.28	4.07	1.54	-0.6	0.55
Değişken	Ortalama	Maksimum	Test			
			Minimum	SD	Basıklık	Çarpıklık
Sıcaklık	30.04	38.07	19.45	3.33	-0.15	-0.41
Rüzgar	3.45	6.70	0.86	1.03	-0.24	0.09
Bağıl Nem	38.01	89.5	9.12	19.84	-0.77	0.63
Güneş Radyosu	9.54	12.14	6.63	1.03	-0.59	-0.10

4.4.1. Çok Katmanlı Yapay Sinir Ağları Yöntemi

Her bir değişkenin ET_0 parametresi üzerindeki etkinliğini göstermek için sıcaklık, rüzgar, güneş radyasyonu, ve bağıl nem olan ayrılmış değişkenlere dayanarak dört model üretilmiştir (Tablo 4.10). Ayrıca, diğer modeller günlük referans değerlerini tahmin etmek için değişken kombinasyonlarını göstermektedir. Gizli ve çıktı katmanlarında, tansing ve purelin fonksiyonları kullanılmış ve eğitim algoritması Levenberg-Marquardt algoritması uygulanmıştır. Tablo 4.10.'da gösterildiği gibi, günlük referans evapotranspirasyonun tahmin edilmesinde sıcaklık tahmin sürecinde orta etkinlik gösteren diğerlerdir ve ayrılmış değişkenlere kıyasla değer değişkenler güçlü bir şekilde etkilenmiştir. Sıcaklık modelin eğitim ve test verilerin R^2 değerleri sırasıyla 0.74 ve 0.731. Rüzgar modeli için eğitim ve test veri setinin R^2 değerleri 0.612 ve 0.563 bulunmuştur. Güneş radyosunu modeli için R^2 değerleri sırasıyla 0.72 ve 0.717 dir.



Sıcaklık ve Güneş radyosunu R^2 değerleri, eğitim ve test verileri için sırasıyla 0.863 ve 0.8315'tir. Sıcaklık, Rüzgar ve Bağıl nem R^2 değerleri sırasıyla 0.959 ve 0.955'tir. Bütün değişkenlerin kombinasyonları, günlük referans evapotranspirasyonu tahmin etmek için en iyi model gösterilmiştir. Eğitim ve test R^2 değerleri sırasıyla 0.9991 ve 0.9996 elde edilmiştir.

Güneş radyasyonun parametresine dayanan model, modelin doğruluğunu azaltmış, böylece güneş radyasyonu parametresi yerine girdi parametresi olarak güneş sürelerinin kullanılması tahmin gücünü artırmıştır (Pour-Ali Baba et al., 2013).

Tablo 4. 12. Eğitim ve test veri sitelerindeki ÇKYSA modellerinin istatistikleri



Girdi	Aktivasyonun Fonksiyonu		Sinir sayısı	Eğitim		Test	
	Gizli	Çıkış		RMSE	R^2	RMSE	R^2
Tort.	Tansig	Purelin	1	1.2	0.734	1.21	0.731
U2	Tansig	Purelin	1	0.83	0.612	0.88	0.563
Rn	Tansig	Purelin	1	1.12	0.72	1.13	0.717
Tort, Rn	Tansig	Purelin	3	0.904	0.863	0.982	0.832
T, U2, Rn	Tansig	Purelin	5	0.7	0.956	0.701	0.959
T, U2, Rn, and RH	Tansig	Purelin	5	0.0021	0.9991	0.0008	0.9996

Şekil 4.14.'de gösterildiği gibi, sıcaklık modelinde, YSA tahmini ET_0 ve ASCE Penman–Monteith ET_0 değerleri doğrusal regresyon grafikleri olarak çizilmiştir. Her veri kümesi için Penman–Monteith ET_0 değerleri ile sıcaklık modelin tahmin edilen ET_0 değerleri arasındaki regresyon ilişkisini göstermiştir.




Şekil 4. 48 ÇKYSA ile tahmin edilen ET₀ (mm / gün) ve ASCE Penman–Monteith karşılaştırılması

Rüzgar parametresinin girdi olarak kullanıldığı model Şekil 4.15.'de YSA tahmin edilen ET₀ ve ASCE Penman Monteith ET₀ değerleri arasındaki regresyon grafiği çizilmiştir. Regresyon grafiğine göre, Sudan'ın kurak ve yarı kurak bir iklime sahip olduğu ve rüzgara dayalı modelin sonuçlarını net bir şekilde etkilediği bilinen bir parametre olduğu şeklinde gösterilmiştir.





Şekil 4. 49. ÇKYSA ile tahmin edilen ET_0 (mm / gün) ve ASCE Penman–Monteith karşılaştırılması

Şekil 4.16'ye göre, güneş radyasyonunun modelinde YSA tahmin edilen ET_0 ve ASCE Penman–Monteith ET_0 değerlerin arasındaki korelasyonu gösterilmiştir.




Şekil 4. 50. ÇKYSA tahmin ET edilen ET₀ (mm / gün) ve ASCE Penman Monthith ET₀ karşılaştırılması

Diğer taraftan, Şekil 4.17.'te gösterildiği gibi, orta sıcaklık ve rüzgar hızı kombinasyonunun modelinde, YSA tahmin edilen ET₀ ve ASCE Penman Monthith ET₀ değerlerinin arasındaki regresyonu gösterilmiştir. R² değerlere göre, sıcaklık ve rüzgar modeli daha güçlü olup etkilendiği gösterilmiştir.




Şekil 4. 51. ÇKYSA tahmin edilen ET₀ ve ASCE Penman Monthieth ET₀ değerlerinin Karşılaştırılması

Şekil 4.18.'da gösterildiği gibi, sıcaklık, rüzgar, ve bağıl nem modelinde YSA tahmin edilen ve ASCE Penman Monthieth ET₀ değerleri arasında daha yüksek bir ilişki göstermiştir.



Şekil 4. 52. ÇKYSA tahmin edilen ET₀ ve ASCE Penman Monthith ET₀ karşılaştırılması

Şekil 4.19.'ye göre. Tüm değişkenlere dayanan model, ASCE Penman Monthieth ve öngörülen ET₀ değerlerinden yüksek R² değerlerinin elde edildiğini gösteren iyi modeldir.



Şekil 4. 53. ÇKYSA tahmin edilen ET_0 ve ASCE Penman Monthith ET_0 karşılaştırılması

4.4.2. Bulanık Yapay Sinir Ağları (ANFIS)


Farklı değişken kombinasyonları kullanılarak Tablo 4.11'da gösterildiği gibi ANFIS modelleri uygulanmıştır. RMSE ve R^2 değerlerine dayanan en iyi modelleri gözlemlenmiştir. Her bir değişkenin ET_0 parametresi üzerindeki etkinliğini göstermek için sıcaklık, rüzgar, güneş radyasyonu, ve bağıl nem olan ayrılmış değişkenlere dayanarak dört model üretilmiştir. Ayrıca, diğer modeller günlük referans değerlerini tahmin etmek için değişken kombinasyonlarını gösterilmiştir. Sıcaklık modelin R^2 değerleri, eğitim ve test kümesi için sırasıyla 0.76 ve 0.74'dir. Rüzgara dayalı modelinde R^2 değerleri 0.579 ve 0.54'dir. Ayrıca, Güneş radyasyonu dayalı modelinde R^2 değerleri sırasıyla eğitim ve test veri setleri için 0.652 ve 0.63 idi. Sıcaklık ve güneş radyasyonu modeli, diğer değişkenlerin modellerine göre çok iyi sonuçlar ve yüksek sonuçlar elde edilmiştir. Eğitim ve test R^2 değerleri sırasıyla 0.8736 ve 0.8296'dır. Ancak sıcaklık, rüzgar ve bağıl nem modelin R^2 değerleri sırasıyla 0.96 ve 0.94 tir.

Bütün deęişkenlerin kombinasyonları, günlük referans evapotranspirasyonu tahmin etmek için en iyi model çıkmıştır. Eğitim ve test R^2 deęerleri sırasıyla 0.9947 ve 0.9926 dir.

Tablo 4. 13. Eğitim ve test deęerlenme veri kümelerinde ANFIS modellerinin istatistikleri


Girdi	Model	Aktivasyon Fonksyonu	Eđitim		Test	
			RMSE	R^2	RMSE	R^2
T_{ort}	GP,Trimf3mf	Lineer	1.017	0.76	1.156	0.74
U_2	GP,Gauss3mf	Lineer	1.212	0.579	1.197	0.549
R_n	GP,Gauss3mf	Lineer	0.88	0.652	1.127	0.63
T_{ort}, R_n	GP,Gauss33mf	Constant	0.834	0.874	0.96	0.836
T_{ort}, U_2, R_n	GP,Trimf333mf	Lineer	0.257	0.96	0.344	0.942
T_{ort}, U_2, R_n, RH	GP,Gaussf3333mf	Lineer	0.005	0.9947	0.017	0.9926

Şekil 4.20.'de gösterildiđi gibi. ANFIS tahmini ET_0 ve Sıcaklık modelinde ASCE PM ET_0 deęerleri doğrusal regresyon grafikleri olarak çizilmiştir. R^2 deęerlerine göre, sıcaklık parametresinin tek deęişken etkili olmadığını gösterilmiştir. Referans evapotranspirasyonu tahmin etmek için deęer iklim deęişkenleri ile kombinasyon edilmesi gerekmektedir.




Şekil 4. 54. ANFIS tahmini ET₀ (mm / gün) ve ASCE PM ET₀ (mm/gün) karşılaştırılması

Şekil 4.21.'de gösterildiği gibi rüzgar modelinde, referans evapotranspirasyon değerleri üzerinde çok etkili olmuştur. Korelasyon grafiğine göre, rüzgara dayanan modelinde tahmin edilen referans evapotranspirasyon değerleri ve ASCE PM referans evapotranspirasyon değerleri arasındaki korelasyon yüksek oranda birbiriyle ilişkili olduğunu gösterilmiştir. Ayrıca, referans evapotranspirasyonu tahmin etmek için rüzgar parametresi etkili olduğu görülmektedir.





Şekil 4. 55. ANFIS tahmini ET₀ (mm / gün) ve ASCE PM ET₀(mm/gün) karşılaştırılması

ANFIS tahmini, ÇKYSA tahmine göre performansı daha az yüksekti, başka klemlemlerle ANFIS modeli, ANNS'tan daha iyidir. Grafiğe göre, güneş radyasyonuun modelinde ÇKYSA tahmin edilen ET₀ ve ASCE Penman monthieth ET₀ değerlerin arasındaki korelasyonu gösterilmiştir (Şekil 4.22). Güneş radyasyonun parametresine dayanan model, modelin doğruluğunu arttırmak için radyasyonu parametresinin yerine kaydedilen güneş saatleri kullanılabilmektedir (Pour-Ali Baba et al., 2013).





Şekil 4. 56. ANFIS tahmini ET₀ (mm / gün) ve ASCE PM ET₀(mm/gün) karşılaştırılması

Diğer taraftan, değişkenlerin kombinasyonları genel olarak grafikler 'de gösterildiği gibi referans evapotranspirasyon oranları üzerinde daha etkili gösterilmiştir. Şekil 4.23.'ya göre, sıcaklık ve güneş radyasyonu parametrelerinin tahmin edilen ET₀ değerleri ve ASCE PM hesaplanan ET₀'nın değerlerin arasındaki ilişki çizilmiştir. Eğitim ve test R² değerlerine göre, sıcaklık ve rüzgar modeli güçlü olduğunu çıkmıştır.





Şekil 4. 57. Sıcaklık (C0) ve Güneş radyosunu dayalı model, ASCE PM ET₀ ve ET₀ tahmini (mm/gün) karşılaştırılması

Şekil 4.24.'de gösterildiği gibi, sıcaklık, rüzgar ve güneş radyasyonu parametrelerinin kombinasyonuna dayanan model, tahmin edilen ve ASCE hesaplanan ET₀ değerleri arasında daha yüksek bir ilişki bulunmuştur.



Şekil 4. 58. Sıcaklık, Rüzgar, ve güneş radyosununa dayalı model, tahmin ve ASCE hesaplanan ET₀ karşılaştırılması

Şekil 4.25.'de tüm değişkenlere dayanan modelinde, ASCE PM hesaplanan ve öngörülen ET₀'nın değerlerin arasındaki ilişkinin grafiği çizilmiştir. R² değerine göre, en iyi bir model bulunmuştur.





Şekil 4. 59. Sıcaklık, rüzgar, güneş radyosunu, ve bağıl nem dayalı model, gerçek ve tahmin ET0 karşılaştırılması

Antonopoulos and Antonopoulos (2017) sınırlı meteorolojik değişkenler kullanarak YSA ile tahminler yapmış ve sonuçları farklı ampirik yöntemlerle karşılaştırmıştır. Farklı girdi varyasyonları ile optimum girdi kombinasyonu belirlenmiştir. Beş yıllık günlük verilerin normalleştirilmesi sonucunda YSA modeli ve diğer deterministik modellerin sonuçları, yaygın olarak kabul gören Penman & Monteith yönteminin sonuçları dikkate alınarak değerlendirilmiştir. Tahminler için en uygun YSA yapısı (4-6-1) elde edilmiş ve daha az sayıda sıcaklık ve güneş radyasyonu değişkenin kullanılmasıyla daha iyi tahminler elde edilebileceği sonucuna varılmıştır. Buna göre, elde edilen sonuçları karşılaştığında bu anlamda çok iyi sonuçları göstermiştir. Özellikle, sıcaklık, güneş radyasyonu, rüzgar, ve nem bağıl bir araya getirince bir model oluşturularak yüksek regresyon katsayısı verilmiştir. Modelin R^2 99% değerini verilmiştir. Ayrıca, tüm değişkenlerine dayanan modelin hataları eğitim ve test veri setlerinde çok düşüktür. Bu yüzden, modelin performansının çok iyi olduğunu anlamına gelmektedir (Tbalo 4.11).

4.4.2.1. ANFIS Analizleri

ANFIS modelinde aynı giriş ve çıkış değişkenleri ve aynı giriş kombinasyonları kullanılmıştır. Benzer şekilde, üyelik fonksiyonlarının sayısı ve en uygun transfer fonksiyonları deneme yanılma yoluyla tanımlanmıştır. Trimf, Trapmf ve gaussmf giriş üyelik fonksiyonları olarak ve lineer ve sabit çıkış üyelik fonksiyonları olarak seçilmiştir. Üyelik işlevlerinin sayısı 3, yineleme sayısı ise 1 ile 5 arasında değişim göstermiştir. Birçok kombinasyon oluşturuldu ve karşılaştırılmıştır. Deneme yanılma, ANFIS giriş ve çıkışları için optimum üyelik fonksiyonlarını tanımlamak için kullanılmıştır. En iyi performansa sahip ANFIS kombinasyonları tüm modeller için Tablo 4.12 'de verilmiştir. Başka bir deyişle, ANFIS'te en düşük RMSE değerlerini üreten modeller seçilmiştir. Örnek olarak Matlab arayüzde ET_0 tahmin oluşturulan model üçgen üyelik fonksiyonlu ortalama sıcaklık ve güneş radyosunu seçimi ve analiz görünümü Şekil 4.26 'de verilmiştir.





Şekil 4. 60. Matlab arayüzde referans evapotranspirasyonu tahmin oluşturulan model görünümü

Tablo 4. 14. ANFIS (Takagi- Sugeno) bulanık mantık Kuralları ve parametreleri

Kurallar	Girdi		Çıktı		
	Sıcaklık (C^0)	Güneş Radyosunu (J/m^2)	Referans Evapotranspirasyonu (mm/gün)		
			Parameters		
1	Düşük	Düşük	-8.35	-49.47	784.8
2	Düşük	Orta	0.93	-1.182	-2.23
3	Düşük	Yüksek	-31.47	-7.81	632
4	Orta	Düşük	14.23	12.55	-461
5	Orta	Orta	-0.24	13.42	-116
6	Orta	Yüksek	-30.61	14.81	651.6
7	Yüksek	Düşük	14.6	-58.01	-165.9
8	Yüksek	Orta	-0.026	-57.06	548.3
9	Yüksek	Yüksek	-27.19	-42.16	1609

ANFIS ile ET_0 modellenmesinde Tablo 4.12 görüldüğü gibi lineer model seçilmiştir. Bu seçim sonucunda 9 adet kural ve tüm kuralların genel yapısı sözel olarak ifade edilmiştir. Bulanık modellemenin temel karakteristik özelliği, sayısal değişkenler yerine veya bunlara ek olarak dilsel değişkenlerin kullanılmasıdır. Geliştirilen sistem, bulanık değişkenler arasındaki bağlantıları belirlemek için bazı eğer/sonra bulanık kurallar içerir. Birinci dereceden Sugeno'nun tarzının bulanık kuralı aşağıdaki biçime ifade edilir:

Rule 1: If (X1 is in 1mf1) and (X2 is in 2mf1) then (Y is out1mf1)

Rule 2: If (X1 is in 1mf1) and (X2 is in 2mf2) then (Y is out1mf2)

Burada X1 (ortalama sıcaklık) ve X2 (Güneş radyosunu), bulanık anlamı olan dilbilimsel terimlerdir ve X ve Y sırasıyla giriş ve çıkış değişkenleridir. p, q ve r sonuçta ortaya çıkan parametrelerdir (Jang, 1993). Matlab'dan elde edilen üçgen üyelik fonksiyonu seçilerek elde edilen parametreler Tablo 4.12'de verilmiştir. En yüksek belirleme katsayısı (R^2) ve en düşük RMSE değerlerine sahip en iyi tahmin modeli Gauss üyelik fonksiyonuna sahip modelden elde edilmiştir. Eğitim veri setin'de üç modelin Tablo 4.13'te görüldüğü gibi belirleme katsayıları R2 sırasıyla 0.90, 0.89 ve 0.89 Trimf, Tramf, ve Guassimf modellerinde çıkmıştır.

Tahmin hatasının standart sapma RMSE değeri en düşük değer Gauss modelinde elde edildiği için seçilmiştir. Test seti olarak 3 modeli için ANFIS analizleri Tablo 4.14'te verilmiştir. Test veri sitin'de en iyi tahmin modeli gauss üyelik fonksiyonu olarak 'ta seçilen linear modelde elde edilmiştir. Belirleme katsayıları R2 sırasıyla 0.87, 0.86 ve 0.86 Trimf, Tramf, ve Guassimf modellerinde çıkmıştır.

Tablo 4. 15. Eğitim aşamalarındaki ANFIS modellerinin MAE, RMSE ve R^2 istatistikleri




Girdi Kombinasyonu	Membership function		Eğitim			
	Girdi	Çıktı	MAE	RMSE	NSE	R2
Tort (C^0)	Trimf	Linear	0.81	0.79	0.966	0.902
Rn (J/m^2)	Trapmf	Linear	0.78	0.83	0.96	0.898
	Gaussmf	Linear	0.77	0.82	0.965	0.896

Tablo 4.1. Test aşamalarındaki ANFIS modellerinin MAE, RMSE ve R2 istatistikleri

Girdi Kombinasyonu	Membership function		Test			
	Girdi	Çıktı	MAE	RMSE	NSE	R2
Tort (C^0)	Trimf	Linear	0.80	0.78	0.966	0.877
Rn (J/m^2)	Trapmf	Linear	0.77	0.81	0.96	0.866
	Gaussmf	Linear	0.79	0.80	0.965	0.865

Şekil 4.27.'de gösterildiği gibi, eğitim verisinde sıcaklık ve güneş radyasyonu parametrelerinin kombinasyonuna dayanan model, Trimf, Tramf, ve Gauss Anfis modellerin tahmin edilen ve ASCE hesaplanan referans evapotranspirasyonun değerleri arasındaki ilişki gösterilmiştir.






Şekil 4. 61. Sıcaklık ve güneş radyosunu dayalı model, ASCE PM ET₀ ve ANFIS modelleri tahmini karşılaştırılması (Eğitim)

Şekil 4.28.'de gösterildiği gibi, test verisinde sıcaklık ve güneş radyasyonu parametrelerinin kombinasyonuna dayanan model, Trimf, Tramf, ve Gauss Anfis

modellerin tahmin edilen ve ASCE hesaplanan referans evapotranspirasyonun değerleri arasındaki ilişki gösterilmiştir.



Şekil 4. 62. Sıcaklık ve güneş radyosunu dayalı model, ASCE PM ET₀ ve ANFIS tahmin edilen ET₀'nın değerlerinin karşılaştırılması (test)

5. SONUÇ VE ÖNERİLER

Su kıtlığı, dünyanın birçok gelişmiş ve gelişmekte olan ülkesi için büyük bir sorundur ve bu da genellikle bir gıda krizinin yaşanmasına yol açan ciddi bir tehditle sonuçlanır. Su kıtlığı arttıkça, mevcut su kaynaklarını yönetme talebi çok önem kazanmaktadır. Bu nedenle, evapotranspirasyon (ET) tahminleri, hidrolik tasarım ve sulama yönetiminde önemli bir rol oynamaktadır. Bu tez çalışmasında farklı lokasyonlarda ve zaman dilimlerinde ET_0 değerlerini tahmin etmek için birçok farklı deterministik ve stokastik yaklaşım kullanılmıştır.

Bitki su tüketimi yüksek doğrusalılık veya durağansızlık tarafından yönlendirilen karmaşık bir süreçtir, bu da birçok iklim değişikliğinin içinde büyük bir karmaşıklığa neden olabileceği anlamına gelir. ET_0 zaman serisinin durağanlık dışı doğası, gelecekteki değerleri tahmin etmede zorluklara yol açar. Bu nedenlerden dolayı, bu çalışma Sudan ile ilgili iklimsel verileri kullanarak günlük referans evapotranspirasyonu tahmin etmeyi amaçlamıştır.

Bu çalışmada, Sudan'ın farklı bölgelerinde tarımsal süreci yöneterek ve planlayarak tarımsal verimi geliştirmek ve artırmak için stokastik ve deterministik yöntemler uygulanmıştır. Bu araştırmada kullanılan yöntemleri, zaman serileri analizi, enterpolasyon teknikleri, yapay zekâ uygulamaları ve çoklu doğrusal regresyon tekniklerinden oluşmaktadır. Çalışmada Sudan'ın 120 istasyonu 1982-2020 yılları arası iklim verileri kullanılmıştır. Bu yöntemler, ET_0 'ın gelecekteki değerlerini tahmin etmek için modeller oluşturmak için uygulanmıştır. İlk yöntemde, Sudan'ın 33 istasyonu gözönüne alınarak zaman serisi analizi gerçekleştirilmiştir. ARIMA modellerini uygulanarak ve kriterlerin belirlenmesine göre en iyi modeller seçilerek kullanılan zaman serisi analizi yapılmıştır. Zaman serisi model sonuçları belirleme katsayısı R^2 değerleri 0.35 ile 0.84 arasında değişim göstermiştir. Model sonuçlarına göre en iyi istatistiksel performans kriterleri Kadugli, Alneihud, Niyala, ve Babanusa şehirlerinde elde edilmiştir. Tüm 33 istasyon göz önüne alındığında düzeyde durağan bulunmuştur. Belirleme katsayısı R^2 değerleri yüksek çıkan istasyonlar genellikle Sudanın batısında gözlenmiştir.

İkinci yöntemde, enterpolasyon teknikleri kullanılmıştır. Enterpolasyon yöntemlerinden Ordinary Kriging, Basit Kriging, ve Ters Mesafe Ağırlığı (IDW) yöntemlerini kullanılmıştır. Enterpolasyon teknikleri 120 istasyon gözönüne alınarak aylık ortalama değerler elde edilerek haritalandırılmıştır. Jeostatistik analiz

sonuçlarına göre en iyi modeller semivariogram modelleri Gaussian, Exponential, ve Spherical modelleri çıkmıştır.

Üçüncü yöntem’de yapay sinir ağları tekniklerinden çok katmanlı yapay sinir ağları (ÇKYSA) ve Bulanık yapay sinir ağları sistemini (ANFIS) uygulanmıştır. Yapay sinir ağları, bulanık yapay sinir ağları ve çoklu regresyon modelleri oluşturulurken girdi parametresi olarak sıcaklık, güneş radyosunu, bağıl nem ve rüzgâr hızı farklı kombinasyonları kullanılarak ETo tahmin modelleri oluşturulmuştur. Çok katmanlı yapay sinir ağları, bulanık yapay sinir ağları ve çoklu doğrusal regresyon modelleri karşılaştırıldığında üç modelde tüm girdi değişkenlerinin kullanıldığı modellerde en iyi tahmin gerçekleştirilmiştir. Üç yöntemde karşılaştırıldığında en iyi bulanık yapay sinir ağları en iyi tahmin modelleri vermiş bunu sırasıyla çok katmanlı yapay sinir ağları ve çoklu doğrusal regresyon modelleri takip etmiştir.

İklim değişkenleri olarak rüzgar ve bağıl nem tek girdi olarak model sonuçları istatistiksel performans kriterlerinin düşük olduğu ortaya çıkmıştır. Sıcaklık ve güneş radyasyonu göz önüne alındığında daha yüksek ve daha doğru sonuçlarla gözlenmiştir. Başka bir deyişle, Sudan’da referans evapotranspirasyon parametrelerinin tahmininde sıcaklık ve Güneş radyosunu etkili değişkenlerdir. Bilindiği gibi Sudan iklimi, ekvator ormanları ile rüzgârlı sıcak çöller arasında bulunan geçici bir iklim türüdür, bu nedenle sıcaklık sadece bitki su tüketimi üzerinde en etkili değişken değildir.

Bu araştırmanın bulguları, tarımsal üretimi doğrudan etkileyen gelecekteki su tüketimi öngörülerinden büyük beklentilerle elde edilebilecek modellerde yüksek istatistiksel performans elde edilmiştir. Bu nedenle, bu çalışma ziraat mühendisleri, su yöneticileri ve çiftçilerin tarımsal uygulamalarla ilgili tüm süreçleri farklı konumlara göre gerçekleştirmeleri için son derece yararlı olabilmektedir. Ek olarak, bu araştırmanın bir kısmında, jeoistatistik analiz tekniklerini uygulanarak belirli bir yere göre referans evapotranspirasyon değişikliklerini tartıştığını belirtmek gerekmektedir. Bu nedenle, farklı modellerden elde edilen sonuçlara göre, araştırma hedeflerine yaklaşık olarak gerçek hayatta uygulanacak şekilde ulaşılmıştır. Bir ziraat mühendisi olarak kişisel düşüncem, farklı modellerin miktarına, zamanına, iklim koşullarına ve coğrafi konumlara göre değişince sonuçların kalitesini ve doğruluğunu güçlü bir şekilde etkileyebilmektedir. Üstelik, gelecekteki değişen iklim koşullarında olumsuz etkilerini azaltmak için buharlaşmayı, terlemeyi ve evapotranspirasyonu anlamak önemlidir. Araştırmacılar, su tutma kapasitesi yüksek toprakların ve olumsuz etkilere toleranslı bitki çeşitlerinin birlikte yönetim stratejilerinin uygulanmasının kuraklığın

etkisiyle yüzleşmek için daha iyi olacaktır. Sulanan alanları artırabilirsek, toplam bitki üretimi, artan nüfusun gıda güvenliğine yükseltilebilecektir.

Sudan da yetiştirilen bitkilerin ekim , dikim büyüme, gelişme ve verim gibi fizyolojik yetiştirme evreleri göz önüne alınarak FAO 56 da verilen bitki katsayıları (Kc) belirlenmesi gerekir. Daha sonra bu çalışmada elde edilen modeller gözönüne alınarak gerçek bitki su tüketimlerinin ETC nin belirlenmesi Sudan su kaynaklarının planlanması küresel iklim ve kuraklık açısından gerçek su tüketimlerinin belirlenmesi açısından gelecekteki çalışmalara faydalı olacaktır. Sudan'ın Kızıldeniz kıyısı, kuzeyi, merkezi ve güneyi olmak üzere dört iklimsel bölgesi vardır. Sudan tropikal bölgelerde yer alır, iklim kuzeyde aşırı kurak, uzak güneybatıda tropikal ıslak ve kurak arasında değişir. Sıcaklıklar herhangi bir yerdeki mevsime göre büyük ölçüde değişmez; En önemli iklim değişkenleri yağış ve yağışlı ve kurak mevsimlerin uzunluğudur. Bu nedenle, referans evapotranspirasyonun tahmini ile Sudan'da yetiştirilen bitkilerin bitki su ihtiyacının belirlenmesi su kaynaklarının planlaması ve geliştirilmesi açısından çok önemlidir.

KAYNAKLAR

- Abghari, H., Ahmadi, H., Besharat, S., & Rezaverdinejad, V. (2012). Prediction of daily pan evaporation using wavelet neural networks. *Water resources management*, 26(12), 3639-3652.
- Abyaneh, H. Z., Nia, A. M., Varkeshi, M. B., Marofi, S., & Kisi, O. (2011). Performance evaluation of ANN and ANFIS models for estimating garlic crop evapotranspiration. *Journal of Irrigation and Drainage Engineering*, 137(5), 280-286.
- Ahmadi, S. H., & Sedghamiz, A. (2008). Application and evaluation of kriging and cokriging methods on groundwater depth mapping. *Environmental monitoring and assessment*, 138(1), 357-368.
- Alexandris, S., Kerkides, P., & Liakatas, A. (2006). Daily reference evapotranspiration estimates by the “Copais” approach. *Agricultural Water Management*, 82(3), 371-386.
- Allen, R. G., Pruitt, W. O., Wright, J. L., Howell, T. A., Ventura, F., Snyder, R., . . . Yrisarry, J. B. (2006). A recommendation on standardized surface resistance for hourly calculation of reference ETo by the FAO56 Penman-Monteith method. *Agricultural Water Management*, 81(1-2), 1-22.
- Antonopoulos, V. Z., & Antonopoulos, A. V. (2017). Daily reference evapotranspiration estimates by artificial neural networks technique and empirical equations using limited input climate variables. *Computers and Electronics in Agriculture*, 132, 86-96.
- Arca, B., Duce, P., Snyder, R. L., Spano, D., & Fiori, M. (2003). *Use of numerical weather forecast and time series models for predicting reference evapotranspiration*. Paper presented at the IV International Symposium on Irrigation of Horticultural Crops 664.
- Ashraf, M., Loftis, J. C., & Hubbard, K. (1997). Application of geostatistics to evaluate partial weather station networks. *Agricultural and forest meteorology*, 84(3-4), 255-271.
- Ashrafzadeh, A., Kişi, O., Aghelpour, P., Biazar, S. M., & Masouleh, M. A. (2020). Comparative study of time series models, support vector machines, and GMDH in forecasting long-term evapotranspiration rates in northern Iran. *Journal of Irrigation and Drainage Engineering*, 146(6), 04020010.
- Asteriou, D., & Hall, S. G. (2007). *Applied Econometrics: a modern approach*, revised edition. Hampshire: Palgrave Macmillan, 46(2), 117-155.
- Bachour, R., Maslova, I., Ticlavilca, A. M., Walker, W. R., & McKee, M. (2016). Wavelet-multivariate relevance vector machine hybrid model for forecasting daily evapotranspiration. *Stochastic environmental research and risk assessment*, 30(1), 103-117.
- Bazrafshan, O., Salajegheh, A., Bazrafshan, J., Mahdavi, M., & Fatehi Maraj, A. (2015). Hydrological drought forecasting using ARIMA models (case study: Karkheh Basin). *Ecopersia*, 3(3), 1099-1117.
- Bechini, L., Ducco, G., Donatelli, M., & Stein, A. (2000). Modelling, interpolation and stochastic simulation in space and time of global solar radiation. *Agriculture, ecosystems & environment*, 81(1), 29-42.
- Bian, Y., Dai, H., Zhang, Q., Yang, L., & Du, W. (2020). Spatial distribution of potential evapotranspiration trends in the Inner Mongolia Autonomous Region (1971–2016). *Theoretical and Applied Climatology*, 140(3), 1161-1169.

- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2008). Time series analysis: forecasting and control John Wiley & Sons. Hoboken, NJ.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*: John Wiley & Sons.
- Citakoglu, H., Cetin, M., Cobaner, M., & Haktanir, T. (2017). Modeling of Seasonal Precipitation with Geostatistical Techniques and Its Estimation at Un-gauged Locations. *Teknik Dergi*, 28(1), 7725-7745. doi:10.18400/tekderg.299132
- Dai, X., Shi, H., Li, Y., Ouyang, Z., & Huo, Z. (2009). Artificial neural network models for estimating regional reference evapotranspiration based on climate factors. *Hydrological Processes: An International Journal*, 23(3), 442-450.
- Dalezios, N. R., Loukas, A., & Bampzelis, D. (2002). Spatial variability of reference evapotranspiration in Greece. *Physics and Chemistry of the Earth, Parts A/B/C*, 27(23-24), 1031-1038.
- Dogan, E. (2009). Reference evapotranspiration estimation using adaptive neuro-fuzzy inference systems. *Irrigation and drainage*.
- Falamarzi, Y., Palizdan, N., Huang, Y. F., & Lee, T. S. (2014). Estimating evapotranspiration from temperature and wind speed data using artificial and wavelet neural networks (WNNs). *Agricultural Water Management*, 140, 26-36.
- Ferreira, L. B., & da Cunha, F. F. (2020). New approach to estimate daily reference evapotranspiration based on hourly temperature and relative humidity using machine learning and deep learning. *Agricultural Water Management*, 234, 106113.
- Gao, S., He, Y., & Chen, H. (2009). *Wind speed forecast for wind farms based on ARMA-ARCH model*. Paper presented at the 2009 International Conference on Sustainable Power Generation and Supply.
- Gocić, M., Motamedi, S., Shamshirband, S., Petković, D., Ch, S., Hashim, R., & Arif, M. (2015). Soft computing approaches for forecasting reference evapotranspiration. *Computers and Electronics in Agriculture*, 113, 164-173.
- Grazhdani, S., Ahmeti, A., & Bitri, M. (2010). An evaluation and comparison of reference crop evapotranspiration in climatic conditions of albania. *NaturaMontenegrina, Montenegro*, 9(3), 937-950.
- Han, P., Wang, P. X., & Zhang, S. Y. (2010). Drought forecasting based on the remote sensing data using ARIMA models. *Mathematical and computer modelling*, 51(11-12), 1398-1403.
- Harcum, J., & Loftis, J. C. (1987). Spatial interpolation of Penman evapotranspiration. *Transactions of the ASAE*, 30(1), 129-0136.
- Hart, Q., Brugnach, M., Temesgen, B., Rueda, C., Ustin, S., & Frame, K. (2009). Daily reference evapotranspiration for California using satellite imagery and weather station measurement interpolation. *Civil engineering and environmental systems*, 26(1), 19-33.
- Ibrahim, M. H., & Amin, R. M. (2005). EXCHANGE RATE, MONETARY POLICY AND MANUFACTURING OUTPUT IN MALAYSIA. *Journal of Economic Cooperation among Islamic Countries*, 26(3).
- Irmak, S., Payero, J. O., Martin, D. L., Irmak, A., & Howell, T. A. (2006). Sensitivity analyses and sensitivity coefficients of standardized daily ASCE-Penman-Monteith equation. *Journal of Irrigation and Drainage Engineering*, 132(6), 564-578.

- Jahanbani, H., & El-Shafie, A. H. (2011). Application of artificial neural network in estimating monthly time series reference evapotranspiration with minimum and maximum temperatures. *Paddy and Water Environment*, 9(2), 207-220.
- Jang, J.-S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.
- Johnston, K., Ver Hoef, J. M., Krivoruchko, K., & Lucas, N. (2001). *Using ArcGIS geostatistical analyst* (Vol. 380): Esri Redlands.
- JUMA, A. A., & FATHI, H. M. M. (2016.). Using Box-Jenkins Models to Forecast the Cotton Crop In Iraq. *1 The Language of Life: When Mathematics Speaks to Biology*, 32.
- Kamali, M. I., Nazari, R., Faridhosseini, A., Ansari, H., & Eslamian, S. (2015). The determination of reference evapotranspiration for spatial distribution mapping using geostatistics. *Water resources management*, 29(11), 3929-3940.
- Karunasinghe, D. S., & Liong, S.-Y. (2006). Chaotic time series prediction with a global model: Artificial neural network. *Journal of Hydrology*, 323(1-4), 92-105.
- Kaur, D., Lie, T. T., Nair, N. K., & Vallès, B. (2015). Wind speed forecasting using hybrid wavelet transform—ARMA techniques. *Aims Energy*, 3(1), 13-24.
- Khashei, M., & Bijari, M. (2010). An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with applications*, 37(1), 479-489.
- Kim, B. S., Hossein, S. Z., & Choi, G. (2011). Evaluation of temporal-spatial precipitation variability and prediction using seasonal ARIMA model in Mongolia. *KSCE Journal of Civil Engineering*, 15(5), 917-925.
- Kisi, O. (2008). The potential of different ANN techniques in evapotranspiration modelling. *Hydrological Processes: An International Journal*, 22(14), 2449-2460.
- Kiş, Ö. (2011). Evapotranspiration modeling using a wavelet regression model. *Irrigation science*, 29(3), 241-252.
- Kumar, M., Bandyopadhyay, A., Raghuwanshi, N., & Singh, R. (2008). Comparative study of conventional and artificial neural network-based ETo estimation models. *Irrigation science*, 26(6), 531-545.
- Kumar, M., Raghuwanshi, N., Singh, R., Wallender, W., & Pruitt, W. (2002). Estimating evapotranspiration using artificial neural network. *Journal of Irrigation and Drainage Engineering*, 128(4), 224-233.
- Kumar, V. (2007). Optimal contour mapping of groundwater levels using universal kriging—a case study. *Hydrological sciences journal*, 52(5), 1038-1050.
- Ladlani, I., Houichi, L., Djemili, L., Heddam, S., & Belouz, K. (2012). Modeling daily reference evapotranspiration (ET₀) in the north of Algeria using generalized regression neural networks (GRNN) and radial basis function neural networks (RBFNN): a comparative study. *Meteorology and Atmospheric Physics*, 118(3), 163-178.
- Landeras, G., Ortiz-Barredo, A., & López, J. J. (2009). Forecasting weekly evapotranspiration with ARIMA and artificial neural network models. *Journal of Irrigation and Drainage Engineering*, 135(3), 323-334.
- Lee, M. H. (2011). Forecasting of tourist arrivals using subset, multiplicative or additive seasonal Arima Model. *MATEMATIKA: Malaysian Journal of Industrial and Applied Mathematics*, 27, 169-182.
- Lin, G.-F., & Wu, M.-C. (2009). A hybrid neural network model for typhoon-rainfall forecasting. *Journal of Hydrology*, 375(3-4), 450-458.

- Ling-ling, L., Li, J.-H., He, P.-J., & Wang, C.-S. (2011). *The use of wavelet theory and ARMA model in wind speed prediction*. Paper presented at the 2011 1st International Conference on Electric Power Equipment-Switching Technology.
- Lopez-Urrea, R., de Santa Olalla, F. M., Fabeiro, C., & Moratalla, A. (2006). An evaluation of two hourly reference evapotranspiration equations for semiarid conditions. *Agricultural Water Management*, 86(3), 277-282.
- Luo, Y., Chang, X., Peng, S., Khan, S., Wang, W., Zheng, Q., & Cai, X. (2014). Short-term forecasting of daily reference evapotranspiration using the Hargreaves–Samani model and temperature forecasts. *Agricultural Water Management*, 136, 42-51.
- Mamdani, E. H. (1977). Application of fuzzy logic to approximate reasoning using linguistic synthesis. *IEEE transactions on computers*, 26(12), 1182-1191.
- Mardikis, M., Kalivas, D., & Kollias, V. (2005). Comparison of interpolation methods for the prediction of reference evapotranspiration—an application in Greece. *Water resources management*, 19(3), 251-278.
- Martinez-Cob, A., & Tejero-Juste, M. (2004). A wind-based qualitative calibration of the Hargreaves ET0 estimation equation in semiarid regions. *Agricultural Water Management*, 64(3), 251-264.
- Matheron, G. (1963). Principles of geostatistics. *Economic geology*, 58(8), 1246-1266.
- McCuen, R. H., Knight, Z., & Cutter, A. G. (2006). Evaluation of the Nash–Sutcliffe efficiency index. *Journal of hydrologic engineering*, 11(6), 597-602.
- Mishra, A., & Desai, V. (2005). Drought forecasting using stochastic models. *Stochastic environmental research and risk assessment*, 19(5), 326-339.
- Mohan, S., & Arumugam, N. (1995). Forecasting weekly reference crop evapotranspiration series. *Hydrological sciences journal*, 40(6), 689-702.
- Mossad, A., & Alazba, A. (2016). Simulation of temporal variation for reference evapotranspiration under arid climate. *Arabian Journal of Geosciences*, 9(5), 386.
- Naoum, S., & Tsanis, I. K. (2003). Hydroinformatics in evapotranspiration estimation. *Environmental Modelling & Software*, 18(3), 261-271.
- Nikam, S. S., Mishra, A., Sarangi, A., Shirsath, P. B., Singh, D., & Ramasubramanian, V. (2010). Artificial neural network models to predict wheat crop evapotranspiration. *Journal of Agricultural Engineering*, 47(2), 20-25.
- Palmroth, S., Katul, G. G., Hui, D., McCarthy, H. R., Jackson, R. B., & Oren, R. (2010). Estimation of long-term basin scale evapotranspiration from streamflow time series. *Water Resources Research*, 46(10).
- Pandey, P. K., Pandey, V., Singh, R., & Bhakar, S. (2009). Stochastic modelling of actual Black Gram evapotranspiration. *Journal of Water Resource and Protection*, 1(6), 448.
- Partal, T. (2007). Estimation of Turkish Precipitation Data Using Artificial Neural Networks and Wavelet Transformation Methods. *Institute of Science, Department of Civil Engineering, Istanbul Technical University, Istanbul, Turkey*.
- Partal, T. (2009). Modelling evapotranspiration using discrete wavelet transform and neural networks. *Hydrological Processes: An International Journal*, 23(25), 3545-3555.
- Partal, T. (2016). Comparison of wavelet based hybrid models for daily evapotranspiration estimation using meteorological data. *KSCE Journal of Civil Engineering*, 20(5), 2050-2058.

- Patil, A. P., & Deka, P. C. (2017). Performance evaluation of hybrid Wavelet-ANN and Wavelet-ANFIS models for estimating evapotranspiration in arid regions of India. *Neural Computing and Applications*, 28(2), 275-285.
- Piccinni, G., Ko, J., Marek, T., & Howell, T. (2009). Determination of growth-stage-specific crop coefficients (KC) of maize and sorghum. *Agricultural Water Management*, 96(12), 1698-1704.
- Pour-Ali Baba, A., Shiri, J., Kisi, O., Fard, A. F., Kim, S., & Amini, R. (2013). Estimating daily reference evapotranspiration using available and estimated climatic data by adaptive neuro-fuzzy inference system (ANFIS) and artificial neural network (ANN). *Hydrology Research*, 44(1), 131-146.
- Profillidis, V. A., & Botzoris, G. N. (2018). *Modeling of transport demand: Analyzing, calculating, and forecasting transport demand*: Elsevier.
- Psilovikos, A., & Elhag, M. (2013). Forecasting of remotely sensed daily evapotranspiration data over Nile Delta region, Egypt. *Water resources management*, 27(12), 4115-4130.
- Rahimikhoob, A. (2010). Estimation of evapotranspiration based on only air temperature data using artificial neural networks for a subtropical climate in Iran. *Theoretical and Applied Climatology*, 101(1), 83-91.
- Rana, G., & Katerji, N. (2000). Measurement and estimation of actual evapotranspiration in the field under Mediterranean climate: a review. *European Journal of agronomy*, 13(2-3), 125-153.
- Ritter, A., & Munoz-Carpena, R. (2013). Performance evaluation of hydrological models: Statistical significance for reducing subjectivity in goodness-of-fit assessments. *Journal of Hydrology*, 480, 33-45.
- Saravanan, V. (2015). The Determinant of Consumer Price Index in Malaysia. *Journal of Economics, Business and Management*, 3(12).
- Stroud, J. R., Müller, P., & Sansó, B. (2001). Dynamic models for spatiotemporal data. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 63(4), 673-689.
- TAGEM. (2017). Türkiye’de Sulanan Bitkilerin Bitki Su Tüketimi Rehberi. Ankara.
- Tabari, H., Amini, A., Talaei, P. H., & Some’e, B. S. (2012). Spatial distribution and temporal variation of reference evapotranspiration in arid and semi-arid regions of Iran. *Hydrological Processes*, 26(4), 500-512.
- Trajkovic, S. (2007). Hargreaves versus Penman-Monteith under humid conditions. *Journal of Irrigation and Drainage Engineering*, 133(1), 38-42.
- Traore, S., Wang, Y.-M., & Kerh, T. (2010). Artificial neural network for modeling reference evapotranspiration complex process in Sudano-Sahelian zone. *Agricultural Water Management*, 97(5), 707-714.
- Ullah, M. K., Habib, Z., & Muhammad, S. (2001). *Spatial distribution of reference and potential evapotranspiration across the Indus Basin Irrigation Systems* (Vol. 24): IWMI.
- Vicente-Serrano, S. M., Lanjeri, S., & López-Moreno, J. I. (2007). Comparison of different procedures to map reference evapotranspiration using geographical information systems and regression-based techniques. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 27(8), 1103-1118.
- Vieira, S., Hatfield, J., Nielsen, D., & Biggar, J. (1983). Geostatistical theory and application to variability of some agronomical properties. *Hilgardia*, 51(3), 1-75.

- Walia, N., Singh, H., & Sharma, A. (2015). ANFIS: Adaptive neuro-fuzzy inference system-a survey. *International Journal of Computer Applications*, 123(13).
- Wang, J.-J., Jing, Y.-Y., Zhang, C.-F., & Zhao, J.-H. (2009). Review on multi-criteria decision analysis aid in sustainable energy decision-making. *Renewable and sustainable energy reviews*, 13(9), 2263-2278.
- Xu, C.-y., Gong, L., Jiang, T., Chen, D., & Singh, V. (2006). Analysis of spatial distribution and temporal trend of reference evapotranspiration and pan evaporation in Changjiang (Yangtze River) catchment. *Journal of Hydrology*, 327(1-2), 81-93.
- Xu, C.-Y., & Singh, V. (2002). Cross comparison of empirical equations for calculating potential evapotranspiration with data from Switzerland. *Water resources management*, 16(3), 197-219.
- Zhang, C., Pan, X., Li, H. P., Gardiner, A., Sargent, I., Hare, J., & Atkinson, P. M. (2018). A hybrid MLP-CNN classifier for very fine resolution remotely sensed image classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, 133-144. doi:10.1016/j.isprsjprs.2017.07.014
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

ÖZ GEÇMİŞ

Fajer Al fatih, Libya, Bengazi Lisesi'ni bitirdikten sonra Khartoum Üniversitesi Ziraat Fakültesi, Tarımsal Mühendisliğin bölümünden 25.12.2012 tarihinde mezun oldu. 2013 yılında Khartoum üniversitesi, Tarımsal Mühendisliğin bölümünde Yüksek Lisans programına girdi. Doktora için 28.09.2018 tarihte OMÜ'de doktora programına başladı. Mezuniyetinden bu yana , öğrenci olarak Türkçe ve Yabancı Dil Araştırma ve uygulama Merkezinde (TÖMER) 01.10.2017 tarihine Türkçe okuyarak iyi derece kazanmıştır (85%).

İletişim Bilgileri

ORCID ID : 000-0002-9135-3025

Yayınlar:

1. M.A.Abdallah, Cemek.B & E. Küçüktopcu,(2019). Spatial Analysis of Temperature-Humidity Index used to evaluate Risky Sites for Cattle Production in Sudan. *the 9th international symposium on Atmospheric Sciences* (pp. 250-265). Istanbul: Istanbul Technical University.
2. B. Cemek & M.A.Abdallah, (2022). Estimation of Temperature Parameter Using Times Series Analysis of Wad madani City in Sudan. *The 10th international Symposium on Atmospheric Sciences* (p. 7). İstanbul: İstanbul Technichal Universisty.
3. Abdallah.M.A.& B.Cemek,(2022). Modeling of Climatic Variables using Stochastic Approaches in Sudan. *Anadolu Journal of Agricultural Sciences*, 12.