

**YARI-NEMLİ İKLİM KOŞULLARINDA SÜRDÜRÜLEBİLİR
SU YÖNETİMİ İÇİN DERİN ÖĞRENME KULLANILARAK
REFERANS BİTKİ SU TÜKETİMİNİN TAHMİN EDİLMESİ**

ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YARI-NEMLİ İKLİM KOŞULLARINDA SÜRDÜRÜLEBİLİR SU YÖNETİMİ
İÇİN DERİN ÖĞRENME KULLANILARAK REFERANS BİTKİ SU
TÜKETİMİNİN TAHMİN EDİLMESİ**

ABDELRAHMAN AMR ALI RABIE
0000-0003-4304-1075

Doç. Dr. Burak Nazmi CANDOĞAN
(Danışman)

YÜKSEK LİSANS TEZİ
BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2021
Her Hakkı Saklıdır

TEZ ONAYI

Abdelrahman Amr Ali Rabie Elsayed Saleh tarafından hazırlanan “YARI-NEMLİ İKLİM KOŞULLARINDA SÜRDÜRÜLEBİLİR SU YÖNETİMİ İÇİN DERİN ÖĞRENME KULLANILARAK REFERANS BİTKİ SU TÜKETİMİNİN TAHMİN EDİLMESİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Burak Nazmi CANDOĞAN

Başkan : Doç. Dr. Burak Nazmi CANDOĞAN İmza
0000-0001-9898-5685
Bursa Uludağ Üniversitesi,
Ziraat Fakültesi,
Biyosistem Mühendisliği Anabilim Dalı

Üye : Doç. Dr. Ferhat KURTULMUŞ İmza
0000-0002-7862-6909
Bursa Uludağ Üniversitesi,
Ziraat Fakültesi,
Biyosistem Mühendisliği Anabilim Dalı

Üye : Dr. Öğr. Üyesi Murat KARAER İmza
0000-0002-1920-181X
Bilecik Şeyh Edebali Üniversitesi,
Ziraat ve Doğa Bilimleri Fakültesi,
Biyosistem Mühendisliği Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr. Hüseyin Aksel EREN
Enstitü Müdürü
.././2021

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

12/07/2021

ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH

ÖZET

Yüksek Lisans Tezi

YARI-NEMLİ İKLİM KOŞULLARINDA SÜRDÜRÜLEBİLİR SU YÖNETİMİ İÇİN DERİN ÖĞRENME KULLANILARAK REFERANS BİTKİ SU TÜKETİMİNİN TAHMİN EDİLMESİ

ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Biyosistem Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Burak Nazmi CANDOĞAN

Su kaynaklarının sürdürülebilirliği, iyi bir sulama planlaması ve programlamasında Referans Evapotranspirasyonun (ET_o) son derece doğru bir şekilde tahminine bağlıdır. Sürdürülebilirliğe ulaşmak için, Derin Öğrenme (DÖ) gibi modern teknolojiler kullanılmaktadır. Bu çalışmanın, günlük ET_o tahmininde DÖ yöntemleri kullanılarak modeller geliştirilmesi ile tarımda yapay zekâ kullanımını alanına bilimsel olarak katkı sağlayacağı düşünülmektedir. Çalışmanın amacı, günlük ET_o tahmin etmede DÖ ÇKA, 1D-CNN, LSTM, Bi-LSTM ve Hibrit mimarilerini test ederek en iyi mimari tipinin belirlenmesi, sınırlı parametreler olduğu durumlarda ET_o değerini iyi düzeyde tahmin etmek için meteoroloji parametrelerinin seçilebilmesi olmuştur. Son olarak ET_o tahmininde yüksek doğruluk elde etmek için kullanılması gereken en az veri miktarının ve az veri miktarı kullanılması durumunda en iyi mimarinin belirlenmesi amaçlanmaktadır. Günlük ET_o tahmin etmek için meteoroloji parametrelerinden 22 veri kombinasyonu oluşturularak 93 farklı DÖ mimarisi K-katlamalı yöntemi kullanılarak test edilmiştir. FAO Penman-Monteith yöntemiyle tahmin edilen ET_o değerleri, DÖ modellerinden çıkan sonuçların karşılaştırılmasında kullanılmıştır. ET_o tahmin etmede DÖ mimarileri türlerinin performansları değerlendirildiğinde, en yüksek ve dengeli performansları hibrit mimarileri sonrasında 1D-CNN mimarileri göstermişlerdir. En düşük ve dengesiz performans ise ÇKA mimarilerinde belirlenmiştir. Tekrarlayan sinir ağı yapısına ait LSTM ve Bi-LSTM mimarilerinin ikisi de iyi performanslıdır, ayrıca ikisinin performansı arasında büyük bir fark yoktur, ancak Bi-LSTM, LSTM'den çok hafif farkla iyidir. Herhangi bir DÖ mimarisi ile yüksek verimli ET_o tahmin etmek için mevcut olan meteoroloji parametreleri seçilirken; öncelikle ortalama sıcaklık veya minimum-maksimum sıcaklık ve güneş süresinin diğer parametrelere göre tercih edilmesi gerektiği bulunmuştur. Buna bağlı olarak, ET_o tahmin etmede en iyi tek, iki ve üç parametreden oluşan veri kombinasyonları; sıcaklık, sıcaklık-güneş süresi, sıcaklık-güneş süresi-rüzgâr hızıdır. Son olarak, beş tür DÖ mimarisinde, modellerin eğitiminde kullanılan veri miktarının 1 ile 26 yıl arasında değiştirilmesi, 5 yıllık günlük ET_o tahminini önemli ölçüde etkilememiş, ayrıca az veri miktarı kullanıldığında Hibrit mimari diğer mimarilerden daha yüksek performans göstermiştir.

Anahtar Kelimeler: Derin Öğrenme, ÇKA, 1D-CNN, LSTM, Bi-LSTM, Hibrit mimari, Referans Evapotranspirasyon, Sınırlı meteoroloji parametreleri, Yarı-Nemli İklim.

2021, x+ 126 sayfa.

ABSTRACT

MSc Thesis

APPLICATION OF DEEP LEARNING FOR SUSTAINABLE WATER
MANAGEMENT BY ESTIMATING REFERENCE CROP
EVAPOTRANSPIRATION IN SUB-HUMID CLIMATIC CONDITIONS

ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Biosystems Engineering

Supervisor: Assoc. Prof. Burak Nazmi CANDOĞAN

The sustainability of water resources depends on a very accurate Reference Evapotranspiration (ET_o) estimation of good irrigation planning and scheduling. Achieving sustainability uses modern technologies like Deep Learning (DL). This study will contribute to filling the gap in the artificial intelligence uses in agriculture that related to using DL methods in estimating daily ET_o. The study aims to determine the best DL architecture type in estimating daily ET_o by testing MLP, 1D-CNN, LSTM, Bi-LSTM, and Hybrid (CNN-LSTM) architectures, defining the best selection of meteorological parameters to estimate a high accuracy of ET_o with limited parameters. Finally, it aims to determine the minimum amount of data used in training DL models to achieve high accuracy in ET_o estimation and which the best DL architecture uses a small amount of data. In this study, daily ET_o was estimated by 22 data combinations created from meteorology parameters, and each of the data combinations was tested by K-Fold Cross Validation on 93 different DL architecture types. Daily ET_o values estimated by the FAO Penman-Monteith method were used when comparing results from DL models. The evaluation of DL architectures' performances in estimating daily ET_o showed that the highest and balanced performance DL architectures is hybrid, and 1D-CNN architecture comes after it. The lowest and unstable performance one is MLP architectures. As for LSTM and Bi-LSTM architecture performances are well; there is no significant difference in performance between each other, but Bi-LSTM is slightly better than LSTM. The selection of limited parameters to predict high-efficiency ET_o with any DL architecture; It has been found that average or minimum-maximum temperature and sunshine duration should be preferred over other parameters. Accordingly, the best data combinations were created from one, two, and three parameters for estimating ET_o: temperature, temperature- sunshine duration, temperature- sunshine duration-wind speed. Finally, in the five types of DL architectures, changing the amount of data used in training the models between 1 and 26 years did not significantly affect the estimation of 5 years of daily ET_o in addition, Hybrid architecture outperformed other DL architectures when using a fewer amount of data in estimating ET_o.

Key words: Deep Learning, MLP, 1D-CNN, LSTM, Bi-LSTM, Hybrid Architecture, Reference evapotranspiration, Limited meteorological parameters, Sub-Humid Climatic. **2021, x + 126 pages.**

TEŞEKKÜR

Öncelikle bu yüksek lisans tezini yazmama, çalışmama ve bitirmeme başarı getirmiş olan Allah'a hamd olsun, yaşadığım ve yaşayacağım nimetleri için Allah'a daima şükretmekteyim.

Bu çalışmanın ve araştırmanın danışmanlığını üzerine alan, hazırlanması ve yürütülmesinde her türlü desteği gösteren ve yardımcı olan danışmanım Doç. Dr. Burak Nazmi CANDOĞAN'a teşekkürlerimi sunarım.

Bana bursluluk veren yüksek lisans yapma şansımı kolaylaştıran Yurtdışı Türkler ve Akraba Topluluklar Başkanlığı'na teşekkürlerimi sunarım.

Türkiye gelmeden önce bana akademik tavsiyeler veren ve yardımcı olan Prof. Dr. Ahmet KURUNÇ'a teşekkürlerimi sunarım.

Çalışmam boyunca bana gösterdikleri anlayış için ve büyük manevi destek veren sevgili annem ve sevgili babama sonsuz teşekkürler.

ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH
12/07/2021

İÇİNDEKİLER

	Sayfa
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	ix
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	4
2.1. Derin Öğrenme ve Makine Öğrenimi.....	4
2.1.1 Algoritma Türleri.....	4
2.1.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark.....	5
2.1.3. Derin Öğrenme Prensipleri.....	6
2.1.4. Nöron veya Algılayıcı.....	7
2.1.5. Aktivasyon Fonksiyonu.....	8
2.1.6. Ana Derin Öğrenme Mimarileri.....	9
2.1.7. Öğrenme Yöntemi.....	10
2.1.8. Derin Öğrenme Parametreleri.....	13
2.2. Referans Bitki Su Tüketiminin Tahmininde Derin Öğrenme ve Yapay Sinir Ağları Kullanımı ile İlgili Çalışmalar.....	14
3. MATERYAL ve YÖNTEM.....	23
3.1. Araştırma Verilerinin Yeri.....	23
3.2. Referans Bitki Su Tüketiminin Hesaplanması.....	24
3.3. K-katlamalı çapraz doğrulama yöntemi.....	24
3.4. Derin Öğrenme Modelleri.....	27
3.4.1. Çok katmanlı algılayıcı (ÇKA).....	27
3.4.2. Tek boyutlu evrişimli sinir ağları (1D-CNN).....	28
3.4.3. Uzun kısa süreli hafıza ağları (LSTM).....	31
3.4.4. Çift yönlü LSTM (Bi-LSTM).....	32
3.4.5. Hibrit mimari (1D-CNN-LSTM).....	33
3.5. Optimizasyonu Algoritması (Adam).....	34
3.6. Kodlama Dili.....	35
3.7. Verilerin Hazırlanması.....	36
3.7.1 Zaman serisi verileri.....	36
3.7.2. Korelasyon analiziyle kontrol işlemi.....	37
3.7.3. Veri kombinasyonları oluşturma ve veri senaryoları.....	37
3.7.4. Veri normalizasyonu.....	38
3.8. Test Edilen Mimariler.....	39
3.8.1. Standart mimariler.....	39
3.8.2. Hibrit modeller.....	40

3.9. Modellerin Eğitim ve Testi	40
4. BULGULAR ve TARTIŞMA.....	45
4.1. Verilerin Hazırlanması ve Tanımlanması	45
4.2. Derin Öğrenme Modellerinin Yapısını Oluşturma	47
4.3. K-katlamalı Çapraz Doğrulama Bulguları	50
4.4. Derin Öğrenme Modelleri Performanslarının Karşılaştırılması.....	72
4.5. Kombinasyon Parametrelerinin ETo Tahmin Performansına Etkisinin Karşılaştırılması	74
4.6. Optimizasyon Bulguları	75
4.7. Eğitimde Kullanılan Veriler ile Tahmin Verimliliği Arasındaki İlişki.....	113
5. SONUÇ	119
KAYNAKLAR	121
ÖZGEÇMİŞ	121

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
\hat{Y}	Tahmin edilen değeri
Y	gerçek beklenen değer
w_i	Ağırlık (regresyon katsayısı) değerini
X_i	Giriş eğitim verilerini
b	Bias (Regresyon sabitini)
m	Giriş eğitim verilerinin sayısını göstermektedir
ET_o	Referans Evapotranspirasyon ($mm\ gün^{-1}$)
R_n	Bitki yüzeyindeki net radyasyon ($MJ\ m^{-2}\ gün^{-1}$)
G	Toprak ısı akış yoğunluğu ($MJ\ m^{-2}\ gün^{-1}$)
T	2 m yükseklikte ortalama günlük hava sıcaklığı ($^{\circ}C$)
u_2	2 metre yükseklikte rüzgar hızı ($m\ s^{-1}$)
e_s	Doygun buhar basıncı (kPa)
e_a	Gerçek buhar basıncı (kPa)
Δ	Buhar basıncı eğrisinin eğimi ($kPa\ ^{\circ}C^{-1}$)
γ	Psikrometrik sabiti ($kPa\ ^{\circ}C^{-1}$) göstermektedir
n	Deneme sayısını
Y	Modelle ulaşılacak istenen değerleri (gerçek çıktı)
\hat{Y}	Model tarafından tahmin edilen değerleri göstermektedir
X_n	X değişkeninin yeni değeri
X_i	Değiştirilecek X değişkeninin mevcut sayısı
X_{min}	Sütündeki en küçük olan veri
X_{maks}	Sütündeki en büyük olan veriyi göstermektedir
y	Gözlenmiş ET_o i'ninci değeri
\hat{y}	Hesaplanan ET_o i'ninci değeri
\bar{y}	Gözlenmiş ET_o i'ninci ortalaması
n	Toplam gözlem sayısını ifade etmektedir

Kısaltmalar Açıklama

DÖ	Derin öğrenme
ET_o	Referans Evapotranspirasyon
YSA	Yapay Sinir Ağları
ÇKA	Çok Katmanlı Algılayıcı
RNN	Tekrarlayan sinir ağları
LSTM	Uzun kısa süreli bellek
Bi-LSTM	Çift yönlü LSTM
1D-CNN	Tek boyutlu Evrişimli sinir ağları
MSE	Ortalama Kare Hata
RMSE	Karekök hata kareler ortalaması
MAE	Ortalama mutlak hata
R^2	belirleme katsayısı

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1. Derin Öğrenmenin, Yapay Zekâ konusu içerisindeki yeri.....	4
Şekil 2.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark.	5
Şekil 2.3. Makine Öğrenimi ve Derin Öğrenmenin doğruluğunun karşılaştırılması	6
Şekil 2.4. Yapay sinir ağları genel yapısı.....	6
Şekil 2.5. Basit bir algılayıcının çalışma yönteminin açıklanması	7
Şekil 2.6. Çeşitli aktivasyon fonksiyonları	8
Şekil 2.7. Basit ve derin sinir ağı	9
Şekil 2.8. Üç katmanlı ileri beslemeli sinir ağı	10
Şekil 2.9. Global ve yerel maksimum hata ile global ve yerel minimum hata	11
Şekil 2.10. Optimizasyonun çalışma yöntemi.....	12
Şekil 2.11. Hiperparametrelerin ağ doğruluğunu nasıl etkilediğine ilişkin bir görsel	14
Şekil 3.1. Bursa ili ve Bursa meteoroloji istasyonunun konumuna ait bir görünüm	23
Şekil 3.2. K-katlamalı çapraz doğrulama yönteminin prosedürü.....	25
Şekil 3.3. K parametresi 5 seçildiğinde K-katlamalı çalışma yöntemi	26
Şekil 3.4. ÇKA mimarisi ve çalışma yöntemi.....	28
Şekil 3.5. Veriler için 1 boyutlu evrişimli sinir ağının bir bütün olarak gösterimi.	30
Şekil 3.6. Standart RNN mimari	31
Şekil 3.7. Uzun Kısa Süreli Bellek (LSTM) modeli	32
Şekil 3.8. Bi-LSTM derin sinir ağının yapısı.....	33
Şekil 3.9. Hibrit mimari genel yapısı.....	33
Şekil 3.10. Adam'ın diğer optimizasyon algoritmalarıyla karşılaştırılması	34
Şekil 3.11. ETo, çok değişkenli bir zaman serisidir.....	36
Şekil 3.12. Relu ve Swish Aktivasyon fonksiyonu.....	42
Şekil 3.13. Araştırma Metodoloji.....	44
Şekil 4.1. Meteorolojik değişkenlerin ve ETo değeri histogramları	45
Şekil 4.2. 1990-2020 döneminde referans evapotranspirasyondaki (ETo) değişim.	46
Şekil 4.3. Meteoroloji verilerinin pearson korelasyon analizi	46
Şekil 4.4. ETo ana meteorolojik parametrelerin korelasyonu.....	47
Şekil 4.5. ÇKA modellerin ısı haritası.	52
Şekil 4.6. ÇKA modellerin Kutu grafiği.	52
Şekil 4.7. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 2).....	55
Şekil 4.8. 1D-CNN modellerinin Kutu grafiği.....	56
Şekil 4.9. Farklı çekirdek boyutulu 1D-CNN modellerin performansı.....	58
Şekil 4.10. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 3).	57
Şekil 4.11. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 4).	57
Şekil 4.12. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 5).	58
Şekil 4.13. LSTM modelleri ısı haritası	61
Şekil 4.14. LSTM modelleri Kutu grafiği.....	61
Şekil 4.15. LSTM ve Bi-LSTM için farklı veri senaryolarındaki performanslar	63
Şekil 4.16. Bi-LSTM modelleri ısı haritası.....	62
Şekil 4.17. Bi-LSTM modelleri Kutu grafiği.....	63
Şekil 4.18. 1. Grup hibrit modellerin ısı haritası.....	68
Şekil 4.19. 2. Grup hibrit modellerin ısı haritası.....	68
Şekil 4.20. 1. Grup hibrit modellerin Kutu grafiği.....	69
Şekil 4.21. 2. Grup hibrit modellerin Kutu grafiği.....	69
Şekil 4.22. 1. ve 2. grubun hibrit modelleri arasında performans karşılaştırması.....	70

Şekil 4.23. Çalışmada ele alınan derin öğrenme model tipleri arasında performans karşılaştırması	73
Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı	84
Şekil 4.25. ETo tahmininde 2016-2020 yılları arası karıştırılmış veri kombinasyon performansı	99
Şekil 4.26. Veri miktarının tahmin verimliliği üzerine etkisi	118

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 2.1. Derin öğrenmedeki yaygın hiperparametrelere örnekler.	13
Çizelge 3.1. Çalışmada kullanılan Python kütüphaneleri	35
Çizelge 3.2. Oluşturulan test edilmiş veri kombinasyonları	38
Çizelge 3.3. K-katlamalı yöntemi için seçilmiş sabit olan hiperparametre.....	41
Çizelge 4.1. Bursa merkez istasyonu için meteorolojik değişkenlerin ve ETo değeri istatistiksel parametreleri	45
Çizelge 4.2. ÇKA ile test edilen mimarileri.....	48
Çizelge 4.3. 1D-CNN test edilen mimarileri.....	49
Çizelge 4.4. LSTM ve Bi-LSTM'nin test edilen mimarileri.....	50
Çizelge 4.5. ETo tahmininde veri kombinasyonları performansının sınıflandırılması...	51
Çizelge 4.6. ÇKA veri kombinasyonlarının tahmin performansına göre sırası	53
Çizelge 4.7. Veri kombinasyonlarının, bileşenlerine ve performanslarına göre sırası ...	54
Çizelge 4.8. 1D-CNN veri kombinasyonlarının tahmin performansına göre sırası.....	59
Çizelge 4.9. Veri kombinasyonlarının bileşenlerine ve performanslarına göre sırası	60
Çizelge 4.10. LSTM ve Bi-LSTM veri kombinasyonlarının tahmin performansına göre sırası	64
Çizelge 4.11. Veri kombinasyonlarının bileşenlerine ve performanslarına göre sırası ..	65
Çizelge 4.12. Birinci grup test edilen hibrit modellerin gizli katmanları	66
Çizelge 4.13. İkinci grup test edilen hibrit modellerin gizli katmanları	67
Çizelge 4.14. Hibrit modeller veri kombinasyonlarının tahmin performansına göre sırası	71
Çizelge 4.15. Veri kombinasyonlarının, bileşenlerine ve performanslarına göre sırası .	72
Çizelge 4.16. ÇKA ile ilgili seçilmiş optimize edilen 5 mimari	75
Çizelge 4.17. 1D-CNN ile ilgili seçilmiş optimize edilen 5 mimari.....	76
Çizelge 4.18. LSTM ile ilgili seçilmiş optimize edilen 5 mimari.....	76
Çizelge 4.19. Bi-LSTM ile ilgili seçilmiş optimize edilen 5 mimari.....	76
Çizelge 4.20. Optimizasyon için Hibrit modellerden seçilen 5 mimari.....	77
Çizelge 4.21 Optimizasyon için seçilen hiperparametre.....	77
Çizelge 4.22. Karıştırılmamış veri kombinasyonlarıyla tüm modellerin bulgularının ortalama ve standart sapması.	84
Çizelge 4.23. Karıştırılmamış veri kombinasyonlarıyla ÇKA modellerin bulguları	79
Çizelge 4.24. Karıştırılmamış veri kombinasyonlarıyla 1D-CNN modellerin bulguları	80
Çizelge 4.25. Karıştırılmamış veri kombinasyonlarıyla LSTM modellerin bulguları	81
Çizelge 4.26. Karıştırılmamış veri kombinasyonlarıyla Bi-LSTM modellerin bulguları	82
Çizelge 4.27. Karıştırılmamış veri kombinasyonlarıyla Hibrit modellerin bulguları	83
Çizelge 4.28. Karıştırılmış veri kombinasyonlarıyla tüm modellerin bulgularının ortalama ve standart sapması.	99
Çizelge 4.29. Karıştırılmış veri kombinasyonlarıyla ÇKA modellerin bulguları	94
Çizelge 4.30. Karıştırılmış veri kombinasyonlarıyla 1D-CNN modellerin bulguları.....	95
Çizelge 4.31. Karıştırılmış veri kombinasyonlarıyla LSTM modellerin bulguları.....	96
Çizelge 4.32. Karıştırılmış veri kombinasyonlarıyla Bi-LSTM modellerin bulguları....	97
Çizelge 4.33. Karıştırılmış veri kombinasyonlarıyla eğitilen hibrit modellerin bulguları.	98

Çizelge 4.34. ETo tahmin etmede karıştırılmış ve karıştırılmamış veri kombinasyonlarının performansını karşılaştırması	104
Çizelge 4.35. Swish aktivasyon fonksiyonlu tüm modellerin bulgularının ortalama ve standart sapması	111
Çizelge 4.36. ETo tahmin etmede Relu fonksiyonlu mimarileri ve Swish fonksiyonlu mimarileri performansını karşılaştırması	112
Çizelge 4.37. Swish aktivasyon fonksiyonlu ÇKA modellerin bulguları	106
Çizelge 4.38. Swish aktivasyon fonksiyonlu 1D-CNN modellerin bulguları.....	107
Çizelge 4.39. Swish aktivasyon fonksiyonlu LSTM modellerin bulguları.....	108
Çizelge 4.40. Swish aktivasyon fonksiyonlu Bi-LSTM modellerin bulguları.....	109
Çizelge 4.41. Swish aktivasyon fonksiyonlu Hibrit modellerin bulguları.....	110
Çizelge 4.42. Veri miktarının tahmin verimliliği üzerine etkisinin araştırılmasında kullanılan veri kombinasyonları.....	113
Çizelge 4.43. Veri miktarı değişirken ETo tahmini için R2'nin ortalama ve standart sapması.....	117
Çizelge 4.44. Veri miktarının tahmin verimliliği üzerine etkisi	115

1. GİRİŞ

İklim deęişiklięi ve küresel ısınma, kurak ve yarı kurak bölgeleri tehdit eden en önemli sorunlardan biridir. Buna baęlı olarak, su stresinin artmasına neden olmaktadır. Dünya Kaynakları Enstitüsü (WRI) tarafından 2015 yılında yayınlanan Su Kemerini Öngörülen Su Stresi Ülke Sıralamaları adlı teknik notta 2020, 2030 ve 2040'a kadar 167 ülke için gelecekteki su stresi puanlanmış ve sıralanmıştır (Luo ve ark., 2015). Ek olarak, 2040'ta 33 ülkenin son derece yüksek su stresiyle karşı karşıya olacağı işaret edilmiştir. Bu 33 ülkeden çoęu Orta Doęu'da bulunmaktadır. Ayrıca, Türkiye, bu 33 ülke arasında 27. sırada yer almaktadır. Bundan dolayı, artan su stresi sorunu yanında nüfus artışından kaynaklanan zorluklar, Türkiye ve onun gibi ülkeleri tehlikeye atmakta ve onların gelişmeleri ve ekonomik büyümelerini zorlaştırmaktadır. Bu nedenle, artan su ihtiyacı koşullarında su kaynakları son derece iyi yönetilmeli ve korunmalıdır.

Birleşmiş Milletler tarafından 2015 yılında 2030 yılı için önerilen sürdürülebilir kalkınma gündemine göre, ülkeler tarım sektöründe su kaynaklarının sürdürülebilirliği için tarıma en iyi uygulamaları sağlamaya çalışmaktadır. Bu açıdan, bütün ülkeler 4. Nesil Tarım yolunda ilerlemektedir. 4. Nesil Tarım (Zarco-Tejada ve ark., 2014; FAO, 2020) ve Akıllı Tarım (Liakos ve ark., 2018) yeni kavramlar olarak, Nesnelerin İnterneti (IoT) ve Yapay Zekâ (AI) gibi yeni teknolojiler ile bitkisel ve hayvansal üretimde ihtiyaçları karşılamayı, verimlilięi arttırmayı ve çevresel zararlı etkileri azaltmayı amaçlamaktadır. Su kaynaklarının sürdürülebilirliği ile ilgili olarak, 4. Nesil Tarımda sulama yönetiminde yapay zekâ ile Referans Evapotranspirasyon'un (ET_o) doğru tahmininin önemi ortaya çıkmaktadır. ET_o, küresel ölçekte hidrolojik döngüdeki en büyük su ihtiyacı göstergesidir. ET_o deęerinin tahmin edilmesi, tarım üzerine iklim deęişikliklerinin etkisinin deęerlendirilmesine yardımcı olur, ayrıca su kaynaklarının sınırlı olduęu kurak ve yarı kurak bölgelerde su kullanımına ilişkin karar vermede önemli bir kriter haline gelmektedir (Long ve ark., 2014; Shiri, 2019). Sulama yönetimi alanında, ET_o tahmini, bir sulama sisteminde uygulanacak su hacmini iklim verilerine dayalı olarak tanımladığı için etkin su uygulaması için çok önemli bir role sahiptir (Patil ve Deka, 2016).

Kurak ve yarı kurak bölgelerde tarımsal alanlarda su yönetiminde kullanılan referans bitki su tüketimi meteorolojik parametreleri kullanan FAO tarafından önerilen Penman-Monteith yöntemiyle tahmin edilmektedir. Su kaynaklarının tarımsal yönden korunması, iyi sulama planlaması ve programlamasında önemli hale gelmektedir. İyi bir sulama planlaması ve programlaması, son derece doğru bir şekilde ETo tahminine dayalıdır. Bu açıdan, ETo tahmin etmek için matematiksel yöntemlerin sınırlamalarını aşmak amacıyla günümüzde mevcut yöntemlerden daha iyi ve daha verimli yöntemler geliştirilmeye çalışılmaktadır. Araştırmacılar ETo tahmin eden matematiksel yöntemlerden Penman-Monteith gibi çoğu koşullarda hem maliyeti yüksek hem de kullanım zorluğu olduğundan Yapay Zeka ile düşük maliyetli ve esnek kullanımlı yöntemleri araştırmaya ve geliştirmeye uğraşmaktadırlar. Özellikle, bilimsel araştırmalar için ETo tahminini kolaylaştırılması amaçlanmaktadır.

Son on yılda araştırmacılar, Yapay Zekâ uygulamaları ile özellikle Yapay Sinir Ağları (YSA) ve Derin Öğrenme (DÖ) kullanımıyla tarım bilimlerinin gelişimine katkı sağlamışlardır. Van ve ark. (2020) 1D-CNN ve LSTM derin öğrenme yöntemleri standart sinir ağlarından yağış akışı tahmininde daha iyi performans sağladıklarını bulmuşlar, Derbela ve Nouiri (2020) gelecekteki yer altı suyu seviyesi tahmini için standart yapay sinir ağlarının kullanılabileceği sonucuna ulaşmışlar, Elbeltagi ve ark. (2020) bitki katsayıları (kc) tahminin de standart YSA ile yüksek performans almışlar, Mohan ve ark. (2017) ürün maliyetini tahmin etmek için standart YSA ile bir model geliştirmişler, Adeyemi ve ark. (2018) Dinamik Sinir Ağlarıyla mevcut durumda elde edilen verimle aynı verime ulaşan ve %20 ile %46 arasında değişen bir su tasarrufu sağlayan bir tahmin sistemiyle suyun etkin kullanımını gerçekleştirmişler ve Akhand ve ark. (2018) buğday verimini tahmin etmek için uydudan gelen verilerden YSA ile yüksek performanslı bir model geliştirmişlerdir. Bu çalışmalar yanında, tarım sektöründe derin öğrenme ve makine öğrenimi kullanımıyla ilgili pek çok çalışma bulunmaktadır (Kamileris, 2018; Liakos ve ark., 2018).

Son on yılda, YSA ETo zaman serisi tahminine uygulanmış ve yaygın regresyon modellerine kıyasla iyileştirmeler sağlanmış, son zamanlarda derin öğrenme (DÖ) yöntemleri kullanılmaya başlanmıştır. Afzaal ve ark. (2020) ETo değerini tekrarlayan

sinir ağıları (RNNs), uzun kısa süreli bellek (LSTM) ve çift yönlü LSTM (Bi-LSTM) ile tahmin etmişler ve ETo değerini doğru bir şekilde ($R^2 > 0,90$) tahmin etmek için uygun yöntemler olduklarını bildirmişlerdir. Chen ve ark. (2020), eksik meteorolojik verileri kullanarak günlük referans evapotranspirasyonu (ETo) tahmin etmek için derin sinir ağı (DNN), zamansal evrişimli sinir ağı (TCN) ve uzun kısa süreli bellek sinir ağı (LSTM) geliştirmişler, sonuç olarak sıcaklık temelli girdi mevcut olduğunda, TCN ve LSTM modellerinin, çalışma alanlarının ötesinde sıcaklığa dayalı deneysel modellerden belirgin şekilde daha iyi performans gösterdiklerini bulmuşlardır. Ferreira ve da Cunha (2020) DÖ mimarilerini (LSTM, CNN, CNN-LSTM, YSA ve rastgele orman (RF)) çok aşamalı ileri günlük ETo (yedi gün) tahmininde kullanmışlar ve karşılaştırılmışlardır. Değerlendirilen üç girdi verisi kombinasyonu sadece ETo, ETo + gün ve ETo + gün + meteorolojik veriler olmuştur. Sonuç olarak, geliştirilen modellerin yüksek doğruluklar göstermemiş olsalar da ETo değerini tahmin etmek için tarihsel aylık ortalama ETo kullanıldığı yerlerde yararlı araçlar olabileceklerini bildirmişlerdir. Yukarıda bahsedilen çalışmalara rağmen, DÖ yöntemlerinin ETo tahminine uygulanmasında hala büyük bir boşluk vardır. Ayrıca DÖ yöntemleriyle ETo tahmini ile ilgili yapılan az sayıda çalışmalar 2020 yılında başlamış gibidir.

Bu çalışmada, (i) günlük ETo değerini tahmin etmede Derin Öğrenme mimarilerinin (ÇKA-1D-CNN-LSTM-Bi-LSTM-Hibrit) test edilmesi ve günlük ETo tahmininde en iyi mimari tipinin belirlenmesi, (ii) Derin Öğrenme mimarileriyle ETo tahmininde az sayıda meteorolojik parametre kullanım olanağının belirlenmesi ve az parametre olduğu durumlarda ETo değerini iyi düzeyde tahmin etmek için meteoroloji parametrelerinin seçilebilmesi ve (iii) son olarak Derin Öğrenme ile ETo tahmininde yüksek doğruluk elde etmek için kullanılması gereken en az veri miktarının ve az veri miktarı kullanılması durumunda en iyi mimarinin belirlenmesi amaçlanmıştır. Bu çalışmanın, günlük ETo tahmininde derin öğrenme yöntemleri kullanılarak modeller geliştirilmesi ile tarımda yapay zekâ kullanım alanına bilimsel olarak katkı sağlayacağı düşünülmektedir. Ayrıca, derin öğrenme modellerinde bulunan çeşitli mimariler, hiperparametreler ve optimizasyon algoritmaları kullanıldığından bu alanda daha fazla katkısı olacağı düşünülmektedir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1. Derin Öğrenme ve Makine Öğrenimi

Derin Öğrenme, makine öğreniminin bir alt alanıdır, her ikisi de makinelere bir insan müdahalesi olmadan eğitim yoluyla öğrenme yeteneği vermektedir (Goodfellow ve ark, 2016). Derin Öğrenme temelde, Yapay Sinir Ağları olarak algoritmalarla ilgilenir. Sonuçta, Derin Öğrenme, standart Yapay Sinir Ağı verileriyle ilgili sorun ve sınırlamaları aşılabilme için geliştirilmiş standart Yapay Sinir Ağı'nın optimizasyonudur (Schmidhuber, 2018). Son yıllarda yeterince hızlı bilgisayar teknolojisi ve yeterli veri sayesinde güncel hale gelmiştir. Derin Öğrenme, araştırmalar da ve sanayi de yeterli veriye (görüntü, yazı, sayı, ses) sahip olunması durumunda bir problemi çözmek için kullanılabilir (Goodfellow ve ark, 2016). Makine Öğrenimi ise, Derin Öğrenme ve Yapay Sinir Ağları ile birlikte Yapay Zekâyı oluşturmaktadır (Şekil 2.1).



Şekil 2.1. Derin Öğrenmenin, Yapay Zekâ konusu içerisindeki yeri

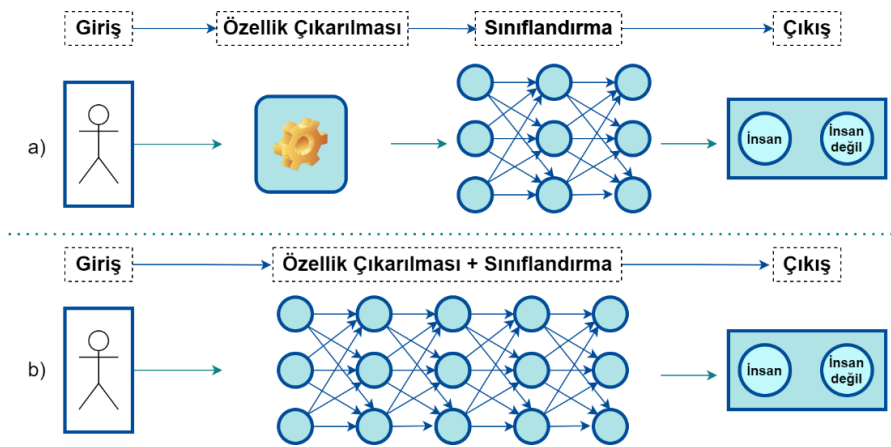
2.1.1 Algoritma Türleri

Makine öğreniminin algoritmaları, öğrenme sürecinde sahip oldukları çalışma yöntemine göre iki türe ayrılır. Bunlar, denetimli öğrenme ve denetimsiz öğrenmedir. Denetimli öğrenme, makine öğreniminin en yaygın kullanılan ve önemli olan bir parçasıdır. Derin öğrenme de, denetimli öğrenme ve denetimsiz öğrenme algoritmalarıyla çalışmaktadır (Goodfellow ve ark, 2016).


Denetimli öğrenmedeki algoritma çalışma yöntemi, mevcut bir veri setiyle başka bir bilgi öğrenebilmek için beslenen algoritmanın verilerini çıktı ve girdi halinde kullanarak çalışmaktadır. Buna karşılık, denetimsiz öğrenmedeki algoritma çalışma yöntemi, bir veri setinin nasıl oluştuğunu belirtmek için veri setindeki önemli özellikleri bularak çalışmaktadır (Goodfellow ve ark, 2016).

2.1.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark

Derin öğrenme ve Makine Öğrenimi arasındaki fark, Derin öğrenmenin büyük miktarda veriyi otomatik olarak işleme yeteneğindedir. Sınıflandırma ve regresyon işlemleri yapıldığında, Derin Öğrenme modelinde kullanılan veri setinin öznitelikleri otomatik olarak çıkarılıp işlem hızlı bir şekilde bitirilmekte, Makine Öğrenimi modelinde ise kullanılan veri setinde bulunan öznitelikler manuel olarak çıkarılıp işlem iki adımda bitirilmektedir (Goodfellow ve ark, 2016). Sonuçta, derin öğrenme ağları ham verilerle istenilen bir görevi gerçekleştirir ve bunu otomatik olarak nasıl yapacağını öğrenir. Makine öğrenimi ve derin öğrenme adımları Şekil 2.2’de gösterilmiştir. Ek olarak, Şekil 2.3.’den izleneceği üzere, Derin Öğrenmede veri kullanımı verimliliği, Makine öğrenmesine göre daha iyi olduğundan, yeterli veriler bulunduğu Derin Öğrenme daha cazip gelmektedir (Schmidhuber, 2018). Özet olarak, Makine Öğreniminde, insan tarafından bilgisayarlara verilerin işlenmesi ve nasıl öğrenmesi gerektiği öğretilmekte, Derin Öğrenmede ise, bilgisayarlar verileri işlemeyi ve nasıl öğrenmesi gerektiğini kendi kendilerini eğiterek yapmaktadırlar.



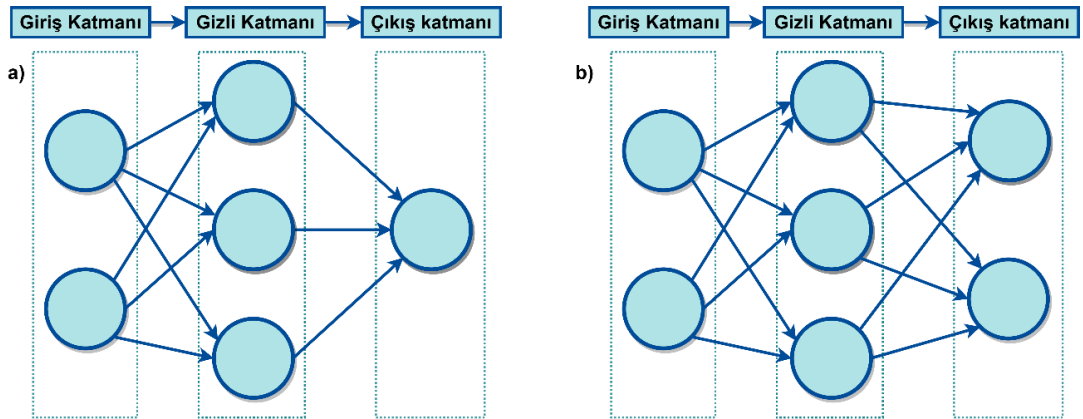
Şekil 2.2. Derin Öğrenme ve Makine Öğrenimi Arasındaki Fark. a) Makine öğreniminin çalışma akışı, b) Derin öğrenmenin çalışma akışı



Şekil 2.3. Makine Öğrenimi ve Derin Öğrenmenin doğruluğunun karşılaştırılması

2.1.3. Derin Öğrenme Prensipleri

Derin Öğrenme modelleri mimarisinin özü Yapay Sinir Ağıdır. Yani, YSA'nın prensipleri derin öğrenme ağlarında da aynıdır (Pérez-Enciso ve Zingaretti, 2019). Şekil 2.4'ten izleneceği gibi, Sinir Ağların genel yapısına benzeyen bir Derin Öğrenme mimarisi, birkaç "nöron" bulunduran katmanlarla birbirine bağlı olarak üç katmandan oluşmaktadır. İlk katman girdi katmanı, verileri sinir ağının son katmanına (çıkış katmanı) iletmektedir. Girdi ve çıkış katmanları arasındaki gizli katman (hesaplama katmanı), nöronlardan oluşur ve içerisinde nöronlar ilk katmandan gelen veriler üzerine hesaplamalar yaparak çıkış katmanının girdilerini sağlamaktadır. Çıkış katmanındaki nöron sayısı, çözülmek istenen probleme göre yani regresyon ya da sınıflandırmaya bağlı olmaktadır (Schmidhuber, 2018).



Şekil 2.4. Yapay sinir ağları genel yapısı: a) regresyon problemleri, b) sınıflandırma problemleri

2.1.4. Nöron veya Algılayıcı

Algılayıcı (Perceptron), sinir ağının temel birimidir. 1950'lerde Rosenblatt tarafından insan beyninin çalışmasını simüle ederek önerilmiştir (Pérez-Enciso ve Zingaretti, 2019). Algılayıcı tek başına, eski yapay öğrenme prosedürlerinden biridir ve kullanılan verileri girdi olarak alıp, iki farklı denkleme geçirerek bir çıktı oluşturmaktadır. Birinci denklem (doğrusal regresyon), girdileri rastgele ağırlıklarla (regresyon katsayısı) çarparak hesaplar ve bir regresyon sabiti ekler (Eşitlik 2.1). Algılayıcı amacına göre ikinci denklem, doğrusal regresyondan çıkan değeri doğrusal olmayan fonksiyonlara (aktivasyon fonksiyonu) geçirerek çıktıyı (kararı) tanıtmaktadır (Sandro Skansi, 2018). Genel olarak, Şekil 2.5'te gösterildiği gibi sinir ağının doğruluğu, nöronlarındaki ağırlıkları doğru seçmeye bağlıdır (Goodfellow, 2016).

$$\hat{Y} = f\left(\sum_{i=1}^m w_i X_i + b\right) \quad (2.1)$$

Eşitlikte;

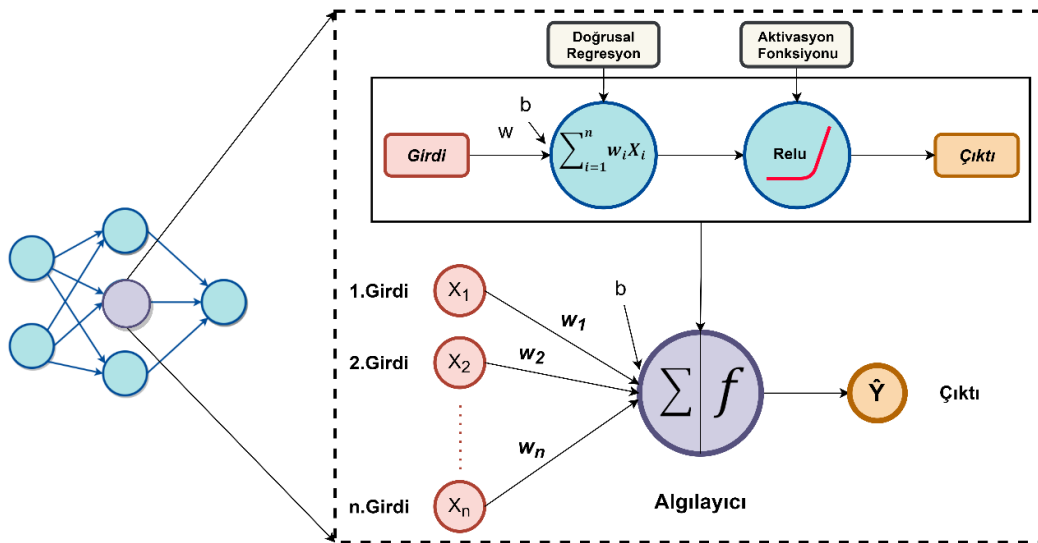
\hat{Y} : Tahmin edilen değeri,

w_i : Ağırlık (regresyon katsayısı) değerini,

X_i : Giriş eğitim verilerini,

b : Bias (Regresyon sabitini),


m : Giriş eğitim verilerinin sayısını göstermektedir.



Şekil 2.5. Basit bir algılayıcının çalışma yönteminin açıklanması

2.1.5. Aktivasyon Fonksiyonu


Aktivasyon fonksiyonu matematiksel doğrusal olmayan bir denklem olup, sinir ağı mimarilerindeki nöronun doğrusal girdisini doğrusal olmayan çıktıya dönüştürmektedir. (Pérez-Enciso & Zingaretti, 2019). Aktivasyon fonksiyonu, sinir ağlarının daha karmaşık görevleri yapabilmesi ve eğitme hızını attırmasını sağlamaktadır. Nörondaki aktivasyon fonksiyonu bulunmadığında, bu nöron sadece doğrusal bir regresyon modelidir ve problemin çözülmesini gerçekleştirmemektedir (Schmidhuber, 2018). Geçmişte en popüler aktivasyon fonksiyonu lojistik (sigmoid) fonksiyonudur. bu fonksiyonunun performansı, çoğu uygulama için yeterince esnek olmadığından "Relu" veya "Selu" gibi fonksiyonlar şu anda daha popülerdir (Pérez-Enciso & Zingaretti, 2019). Relu fonksiyonu, çoğu problemlerde hızlı ve yüksek performanslı olduğundan derin öğrenmede en yaygın kullanılan aktivasyon fonksiyonudur (François Chollet, 2018). Sinir ağı çıktısı katmanındaki aktivasyon fonksiyonu, çözmek istenilen probleme göre seçilmektedir. Örnek olarak, sınıflandırma problemleri için ağı çıktısı katmanında sıklıkla bir "softmax" aktivasyon fonksiyonu kullanılmaktadır (Pérez-Enciso & Zingaretti, 2019). Derin öğrenmede yaygın olarak aktivasyon fonksiyonlarıdır Şekil 2.6'te gösterilmiştir (Schmidhuber, 2018).



Şekil 2.6. Çeşitli aktivasyon fonksiyonları

2.1.6. Ana Derin Öğrenme Mimarileri

YSA sadece üç nöron katmanından oluşabilir; bunlar girdi katmanı, gizli katman, çıktı katmanıdır. Bu ağ, tek gizli katmana sahip olduğundan dolayı basit bir sinir ağıdır (shallow network). Fakat, bu ağdaki gizli katman sayısı ikiden daha fazla olduğunda bu ağa Derin Sinir Ağı veya Çok Katmanlı Algılayıcı (multilayer perceptron) denilebilmektedir. Sinir ağındaki gizli katman sayısını arttırmak, derin öğrenmenin ortaya çıkmasına neden olmuştur (Şekil 2.7). Derin öğrenme gelişimi, ÇKA ile başlamıştır. Bundan dolayı, Derin Öğrenme ve Yapay Sinir Ağları arasındaki benzerlik, derin öğrenmenin YSA'ya bağlı olmasından kaynaklanmaktadır. Sonuçta, Yapay Sinir Ağları olmasaydı Derin Öğrenme ortaya çıkmazdı diyebiliriz.




Şekil 2.7. Basit ve derin sinir ağı

Son on yılda, Derin Öğrenmedeki gelişmeler, her alanda işe yarayabilecek derin öğrenme yöntemlerinin artmasına sebep olmuştur. Buna bağlı olarak, Derin Öğrenme yöntemleri tüm veri tiplerine işlenebildiğinden sınıflandırma, regresyon vb. problemlerde kullanılabilir. Tüm Derin Öğrenme yöntemleri, ÇKA'da bulunan yığılmış nöron katmanları gibi çalışmaktadır. Bu çalışmada, zaman serisi probleminde kullanılan en popüler yöntemler; çok katmanlı algılayıcı (ÇKA), evrişimli sinir ağları (CNN), tekrarlayan sinir ağına (RNN) ait Uzun Kısa Süreli Hafıza Ağları (LSTM) ve Çift Yönlü LSTM (Bi-LSTM) kullanılmıştır (Goodfellow ve ark., 2016). Bunlar sırayla “Materyal ve Yöntem” bölümünde açıklanacaktır.

2.1.7. Öğrenme Yöntemi

Derin öğrenmenin diğer modellere göre tercih edilmesinin nedeni, öğrenme yeteneğine sahip olduğudur. Geçen son yılda yeni keşfedilmiş verimli algoritmalar, yeniden Derin Öğrenmeye can vermiştir. Bu algoritmalarından örnek olarak, Geri Yayılım (backpropagation) derin sinir ağlarındaki parametreleri hesaplayıp birkaç otomatik görevi yüksek doğrulukla bitirebilmektedir (Pérez-Enciso ve Zingaretti, 2019).

İleri yayılım (forward propagation), derin öğrenme kavramlarından birisidir ve derin öğrenme algoritmalarının çalışma yöntemini anlamak için önemlidir. Sinir ağındaki girdi katmanından son katmana tahmin edilen sonucu (\hat{Y}) alana kadar verilerin hareketidir. Ek olarak, Şekil 2.8’de gösterilen Hornik tarafından 1989 yılında tasarlanan ilk sinir ağı, sadece ileri yayılım ile çalıştığından dolayı ileri beslemeli bir sinir ağı olarak adlandırılmıştır. Son yirmi yılda sinir ağı üzerine araştırmacılar tarafından birçok katkı yapılmıştır (Ojha ve ark., 2017).

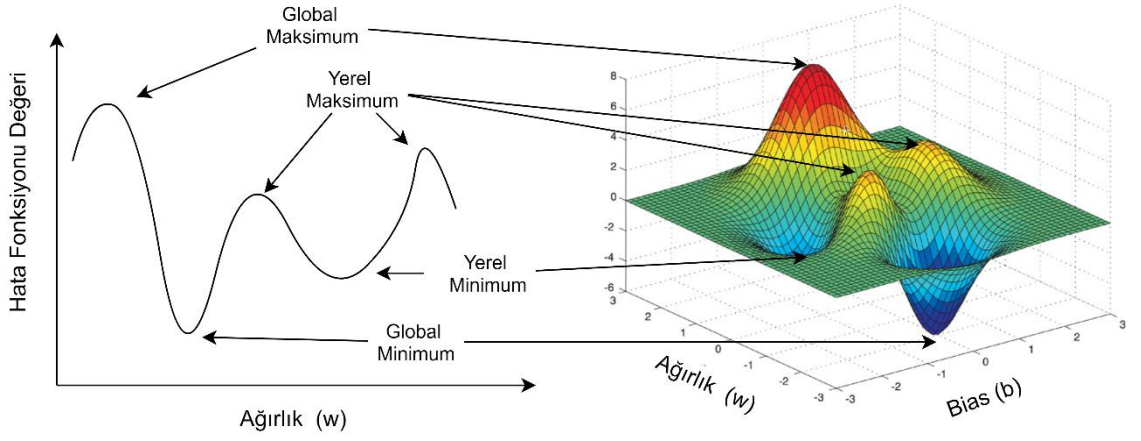


Şekil 2.8. Üç katmanlı ileri beslemeli sinir ağı

Bütün Derin Öğrenme algoritmaları Geri Yayılım gibi, hata fonksiyonunu optimize etmek için geliştirilmektedir. Hata fonksiyonu, derin öğrenme modellerinin eğitimi sırasında performansını ölçen bir fonksiyondur. Bir modelden elde edilen tahmin (\hat{Y}) ile gerçekte beklenen değer (Y) arasındaki farkı (hatayı) ölçüp bir sayı şeklinde sunmaktadır (Eşitlikte 2.2).

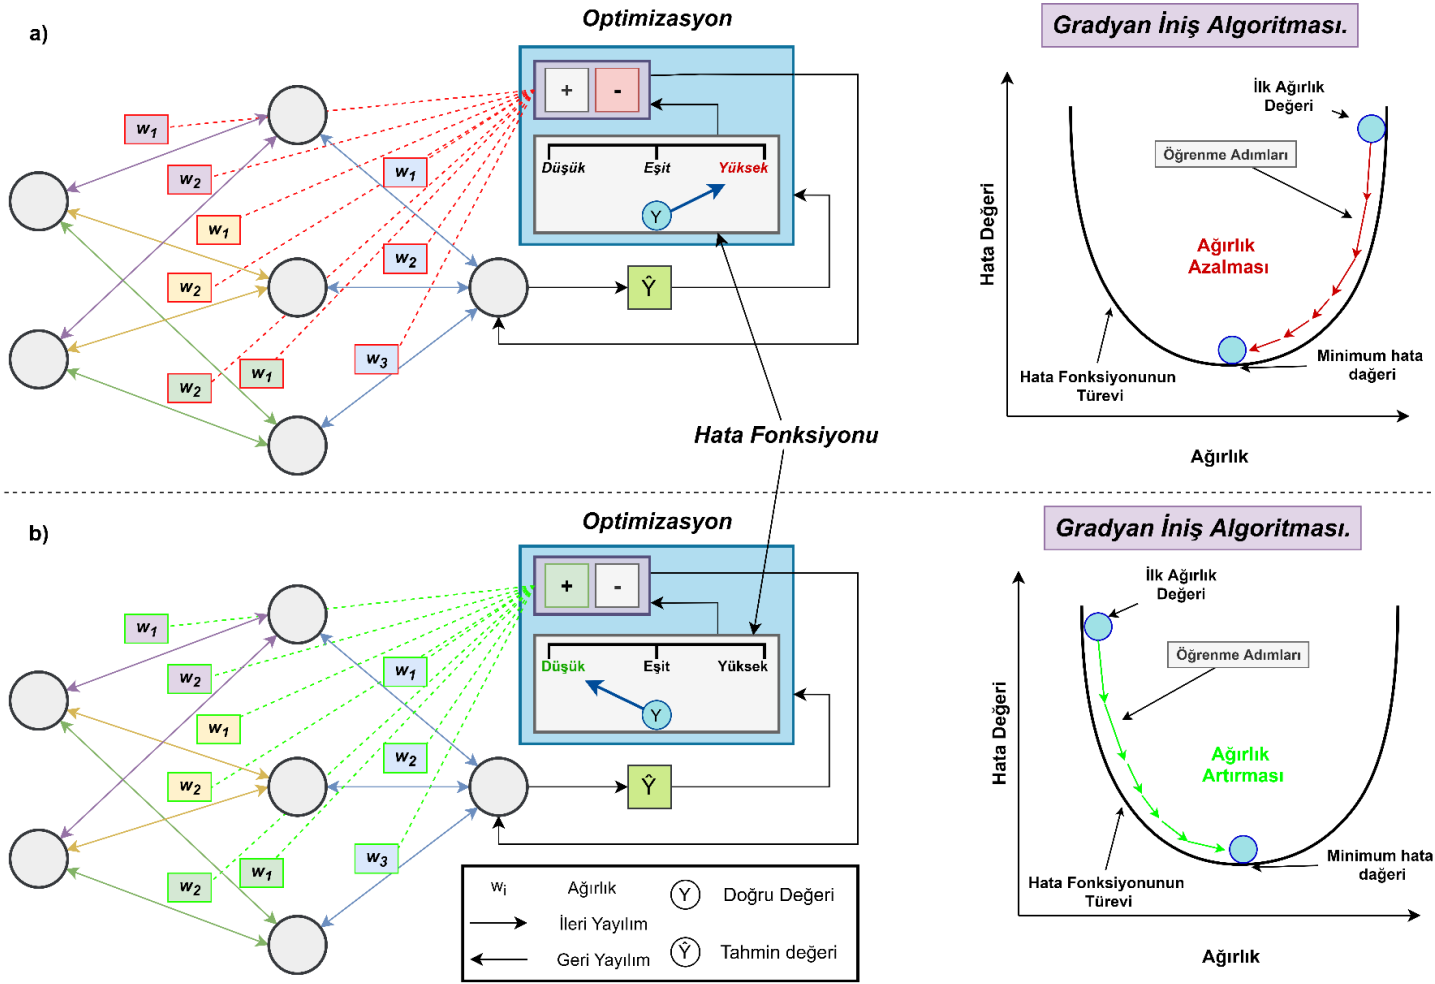
$$Hata\ fonksiyonu = E = \frac{1}{2} \sum_i (\hat{Y}_i - Y_i)^2 \quad (2.2)$$

Hata fonksiyonu değerin pozitif veya negatif olup olmadığı, sıfırdan ne kadar uzak olursa, o kadar modelin düşük performanslı olduğunu göstermektedir. Diğer taraftan, hata fonksiyonu sıfıra yaklaştıkça, modelin performansı o kadar yüksek olmaktadır. Yani, Hata fonksiyonu değeri, model performansının nasıl olduğunu yansıtmaktadır. Model performansı, modelin içindeki ağırlıkların doğru seçilmesine bağlı olduğundan, derin öğrenme algoritmaları modelin içindeki ağırlıkları ayarlayarak hata fonksiyonun değerini küçültmeye çalışmaktadır. Yani, optimizasyon algoritmaları, hata fonksiyonu değerini azaltmaktan ve derin öğrenme modellerinden mümkün olan en doğru sonuçları alınmaktan sorumludur. Ek olarak, burada amaç yerel minimum hata değil, global minimum hatadır (Şekil 2.9).



Şekil 2.9. Global ve yerel maksimum hata ile global ve yerel minimum hata

Geri Yayılım, hata fonksiyonu optimizasyonu için Gradyan İniş kullanan denetimli öğrenme algoritmalarından biridir. Basitçe, hata fonksiyonu değerini mümkün olduğunca küçülterek, modeldeki parametrelerin (Ağırlık (w) ve Bias (b)) değerlerini bulmaya çalışmaktadır. Geri Yayılım, modeldeki ilk parametrelerin değerlerini tanımlamaya başlayarak hata değerini azaltmakta ve modeldeki parametrelerin değerlerini yinelemeli olarak ayarlamak için Kalkülüs kullanılmaktadır. Bunun için, iki kavram vardır; öğrenme oranı (Learning Rate) ve öğrenme sayısı (Epoch). Öğrenme oranı, global minimum hataya ulaşmak için Gradyan İniş'in aldığı adım miktarıdır. Öğrenme sayısı, global minimum hataya ulaşmak için modeldeki parametrelerin yenilenme sayısıdır (Goodfellow ve ark., 2016). Şekil 2.10'da basit olarak Geri Yayılım çalışma yöntemi gösterilmiştir.



Şekil 2.10. Optimizasyonun çalışma yöntemi, a) Hata fonksiyonuna göre ağın çıktısını doğru değere ulaştırmak için ağın ağırlıklarını azaltması, b) Hata fonksiyonuna göre ağın çıktısını doğru değere ulaştırmak için ağın ağırlıklarını yükseltmesi

Özet olarak, optimizasyon algoritması, en düşük hata fonksiyonu değerine ulaşmak için, seçilen öğrenme oranını ve öğrenme sayısını kullanan yinelemeli matematiksel bir işlemdir. Son on yılda, araştırmacıların denetimli öğrenme algoritmalarının geliştirilmesine katkıları ile daha hızlı ve yüksek performansa sahip yeni algoritmaların ortaya çıkmasına neden olmuştur. Derin öğrenme algoritmalarından en yaygın kullanılanlar SGD, AdaGrad, RMSProp ve Adam algoritmalarıdır (Goodfellow ve ark., 2016; Schmidhuber, 2018).

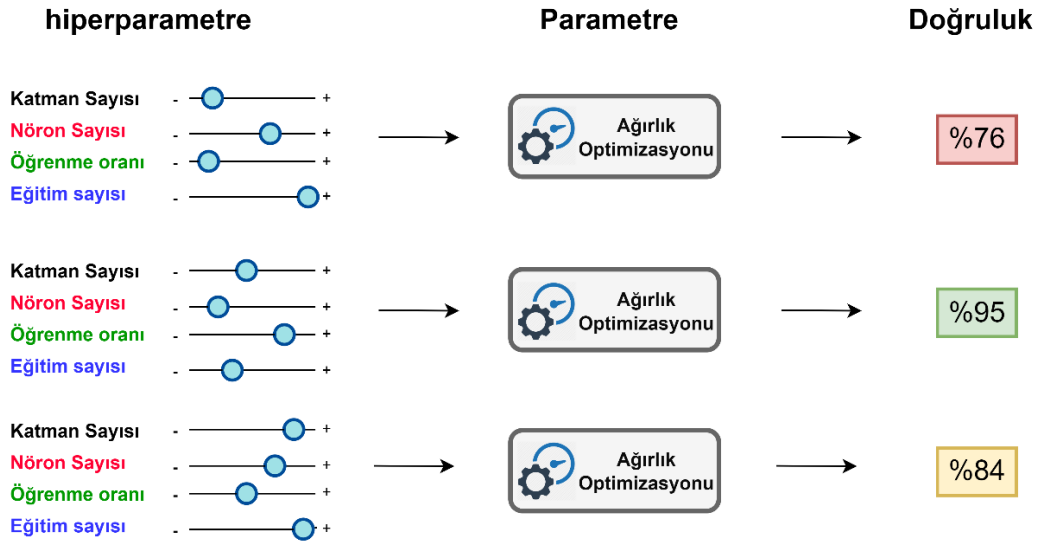
2.1.8. Derin Öğrenme Parametreleri

Derin öğrenme modelleri içerisinde farklı iki sinir ağı parametresi vardır. Modeller eğitilmeden modelin tasarımını düzenleyen ayarlanabilen parametrelere, Hiperparametre denilmektedir. Diğerisi ise, Hiperparametre seçimine bağlı model parametresi olarak adlandırılan, ağırlık gibi tahmin etmede optimizasyon algoritması tarafından kullanılan parametrelerdir.

Hiperparametreler, sinir ağı yapısının nasıl oluşturulduğunu, nasıl eğitildiğini ve nasıl çalıştığını belirtmekten sorumludur. Onlar iki türde sınıflandırılmış olup, Çizelge 2.1’de verildiği gibi sinir ağı yapısı ve öğrenme algoritmasıyla ilgilenmektedirler (Schmidhuber, 2018). Derin öğrenme, öğrenme oranı, öğrenme sayısı vb. gibi hiperparametrelere sahip olduğundan, hiperparametreleri ayarlamak bir sanattır. Derin öğrenme modellerinden maksimum performans alınabilmesi için hiperparametrelerle en doğru kombinasyonu bulmaya çalışılmalıdır (Şekil 2.11).

Çizelge 2.1. Derin öğrenmedeki yaygın hiperparametrelere örnekler.

Sinir Ağı Yapısıyla İlgili Hiperparametreler	Eğitim Algoritmasıyla İlgili Hiperparametreler.
– Gizli Katmanların Sayısı	– Öğrenme Oranı
– Nöron sayısı	– Eğitim Sayısı
– Aktivasyon Fonksiyonu	– Optimizasyon Algoritması



Şekil 2.11. Hiperparametrelerin ağ doğruluğunu nasıl etkilediğine ilişkin bir görsel

2.2. Referans Bitki Su Tüketiminin Tahmininde Derin Öğrenme ve Yapay Sinir Ağları Kullanımı ile İlgili Çalışmalar

Antonopoulos ve Antonopoulos (2017), Yunanistan'ın kuzeyindeki bir istasyondan sağlanan beş yıllık (2009-2013) günlük meteorolojik verilerle referans evapotranspirasyonu (ET_o) tahmin etmek için yapay sinir ağları (YSA) ve Priestley-Taylor, Makkink, Hargreaves'in deneysel yöntemleri ile kütle transferini kullanmışlardır. Kullanılan algoritma, çok katmanlı ileri beslemeli yapay sinir ağları ve optimizasyon için geri yayılımdır. Çalışmada seçilen mimari, sigmoid fonksiyonu kullanılarak 4-6-1 yapısına sahiptir. Çalışma sonucunda, YSA modelleri, ET_o değerini 0,574 ile 1,33 mm gün⁻¹ arasında değişen bir ortalama kare hatası (RMSE) ve 0,955 ile 0,986 arasında değişen korelasyon katsayısı (r) doğruluğu ile tahmin etmişlerdir. YSA'nı eğitmek için sınırlı girdi değişkenlerinin (3 veya 2) kullanılması, biraz daha düşük doğrulukta ET_o değerleri ile sonuçlanmıştır. Çalışmada, 3 girdi değişkeni kullanıldığında, RMSE 0,598 ile 0,954 mm gün⁻¹ arasında ve r değeri 0,952 ile 0,978 arasında değişirken, 2 girdi değişkeni kullanıldığında RMSE 0,846 ile 1,326 mm gün⁻¹ arasında ve r ise 0,910 ile 0,956 arasında değişmiştir.

Sekendur ve ark. (2018), Kayseri ilinde Meteoroloji Genel Müdürlüğünden temin edilen 2010-2017 yılları arasını kapsayan günlük meteorolojik veriler kullanılarak günlük

referans evapotranspirasyonunu (ET_o) tahmin etmek için YSA yöntemini kullanılmışlardır. Çalışmalarında, iklim verileri göz önüne alınarak oluşturulan 11 farklı YSA modelinin tahmin performansını karşılaştırmışlardır. En iyi sonuç; belirleme katsayısının (R^2) 0,998 olarak bulunduğu rüzgar, minimum ve maksimum bağıl nem, minimum ve maksimum sıcaklık, güneşlenme şiddeti, güneşlenme süresi ve günlük zaman indisi parametrelerinin kullanıldığı modelde bulunmuştur. Bir sonraki en iyi performans ise $R^2=0,997$ ile güneşlenme şiddeti, buhar basıncı açığı, ortalama sıcaklık, rüzgâr ve günlük zaman indisi parametrelerini modele eğittirerek belirlenmiştir. Çalışmada, en az parametrelili kombinasyondan (nispi güneşlenme süresi, buhar basıncı açığı ve günlük zaman indisi) oluşan modelde en düşük performans alınmış ve belirleme katsayısı= 0,950 olarak belirlenmiştir. Çalışma sonucunda, araştırmacılar YSA modelleri tarafından verilen başarılı sonuçlardan, Kayseri ili günlük ET_o hesaplamalarında daha az veri kombinasyonları kullanılarak doğruya yakın ET_o değerlerinin tahmin edilebileceğini bildirmişlerdir.

Saggi ve Jain (2019), Pencap'ın Hoshiarpur ve Patiala bölgeleri koşulları altında günlük ET_o değerini belirlemek için H₂O model yapısını çalışmalarında sunmuşlardır. Dört denetimli öğrenme algoritmasının (Derin Öğrenme-Çok Katmanlı Algılayıcılar (DL), Genelleştirilmiş Doğrusal Model (GLM), Rastgele Orman (RF) ve Gradyan Artırma Makinesi (GBM)) ET_o tahmin etme yeteneğini değerlendirmişlerdir. Bu dört modelin analizi H₂O yapısı altında gerçekleştirilmiştir. DL modelinin performansını, RF, GLM ve GBM gibi diğer son teknoloji modellerle karşılaştırmışlardır. Sonuç olarak, modellerin günlük ET_o modelleme için yüksek performans sunduğunu göstermişlerdir (Örneğin; NSE=0,95-0,98, $R^2=0,95-0,99$, ACC=85-95, MSE=0,0369-0,1215, RMSE=0,1921-0,2691).

Yamaç (2019), çalışmasında dört iklim verisi kombinasyonu kullanarak günlük ET_o değerini k-En Yakın Komşu (kNN) ve Yapay Sinir Ağları (YSA) ile tahmin edip modellerin performansını değerlendirmiştir. Araştırmacı, Orta Anadolu bölgesinde 1996-2015 yıllarını kapsayan günlük iklim verilerinin dört kombinasyonu üzerinde kNN ve YSA çalışmıştır. ET_o değerlerinin sonuçları, tüm kombinasyonlarda kNN'nin YSA'dan daha yüksek performansa sahip olduğunu göstermiştir. kNN modeli test edildiğinde

MSE, RMSE, MAE, NSE ve R^2 değerlerinin sırasıyla 0,541-0,031 mm gün⁻¹, 0,735-0,175 mm gün⁻¹, 0,547-0,124 mm gün⁻¹, 0,937-0,997 ve 0,900-0,994 arasında değiştiği belirlenmiştir. Çalışma sonucunda, kNN yönteminin, tam ve sınırlı girdi meteorolojik verileri ile ETo tahmini için kullanılabileceği belirtilmiştir.

Afzaal ve ark. (2020), çalışmalarında ETo değerini tekrarlayan sinir ağları (RNNs), uzun kısa süreli bellek (LSTM) ve çift yönlü LSTM (Bi-LSTM) ile tahmin etmişlerdir. Bu amaçla Kanada, Prince Edward Adası (PEI) genelinde dört temsili bölgenin (North Cape, Summerside, Harrington ve Saint Peters) iklim değişkenlerinin ortalama değerlerini kullanmışlardır. Altküme regresyon analizlerine dayalı olarak, en yüksek katkıda bulunan iklim değişkenleri maksimum hava sıcaklığı ve bağıl nem olduğundan RNN eğitimi ve test etmek için girdi değişkenleri olarak seçilmişlerdir. Sonuç olarak, LSTM ve çift yönlü LSTM'nin, yaklaşık tüm bölgeler için ETo değerini doğru bir şekilde ($R^2 > 0,90$) tahmin etmek için uygun yöntemler olduğunu bildirmişlerdir. LSTM ve çift yönlü LSTM yöntemlerinin doğruluğunda önemli bir farklılık gözlemlenmemişlerdir.

Chen ve ark. (2020), Çin'in Kuzeydoğu ovasında eksik meteorolojik verileri kullanarak günlük referans evapotranspirasyonu (ETo) tahmin etmek için derin sinir ağı (DNN), zamansal evrişimli sinir ağı (TCN) ve uzun kısa süreli bellek sinir ağı (LSTM) geliştirmişlerdir. Çalışmada, üç derin öğrenme (DL) modelinin performanslarını, iki klasik makine öğrenimi modeli ve diğer modellere göre değerlendirilmişlerdir. Modellerin eğitilmesi ve değerlendirmek için kullanılan iki strateji, meteoroloji istasyonlarından gelen verileri ayrı ayrı kullanma ve tüm istasyonlardan gelen veriler birleştirip K-ortalama yöntemini kullanarak birkaç gruba bölerek kullanma stratejileri olmuştur. Genel olarak, sıcaklık temelli girdi mevcut olduğunda, TCN ve LSTM modelleri, çalışma alanlarının ötesinde sıcaklığa dayalı deneysel modellerden belirgin şekilde daha iyi performans göstermiştir. Ek olarak, radyasyona dayalı veya neme dayalı girdi mevcut olduğunda, önerilen tüm derin öğrenme ve klasik makine öğrenimi modelleri eğitim gördükleri çalışma alanlarının ötesinde radyasyon veya neme dayalı ampirik denklemlerden daha iyi performans göstermiştir.

de Oliveira e Lucas ve ark. (2020), Evrişimli Sinir Ağlarının (CNNs) zaman serilerinin tahmininde kullanımını değerlendirdikleri çalışmalarında, günlük bir zaman serisini tahmin etmek için üç farklı CNN modeli yapısı kullanmışlardır. Ayrıca, zaman serilerinin topluluk tahminini değerlendirmek için, olasılıklı bir tahmin üretmek amacıyla sözkonusu olan CNN'lerden oluşan dört topluluk modeli uygulamışlardır. Sonuç olarak, varyans, hassasiyet ve hata oranına göre ETo tahmininde CNN modellerinin, Mevsimsel Naive ve Mevsimsel ARIMA modellerinden daha iyi tahmin yaptığını bulmuşlardır.

Ferreira ve da Cunha (2020a), Brezilya'nın Minas Gerais eyaletinde bulunan 53 meteoroloji istasyonundan gelen verileri kullanılmış, bölgesel ve yerel sınırlı saatlik meteorolojik verilerini kullanarak günlük ve saatlik ETo değerini doğrudan tahmin etmek için RF, XGBoost, YSA ve CNN modelleri kullanmışlardır. Değerlendirilen senaryolar: (1) günlük girdi verilerinin kullanılması (2) günlük ETo değerini doğrudan tahmin etmek için 24 saatlik bir süre + saatlik radyasyon (Ra) (3) son senaryonun aynı konfigürasyonu, ancak saatlik Ra yerine günlük Ra (4) saatlik ETo'ı tahmin etmek için saatlik verilerin kullanılması ve saatlik ETo'ı toplayarak günlük ETo'ı tahmin etmek olmuştur. Tüm seçeneklerde Ra kullanmışlardır. Modelleri geliştirmek ve değerlendirmek için, iki günlük ETo ile karşılaştırılmış: ETo_d ve ETo_{soh} . Tüm modeller için en iyi tahminleri saatlik verileri kullanmaları sonucunda bulmuşlardır. 24 saat saatlik veri + saatlik Ra ile geliştirilen CNN modellerinin tüm senaryolarda en iyi performansı sunduğunu bildirmişlerdir.

Ferreira ve da Cunha (2020b), derin öğrenme mimarilerini (LSTM, 1D-CNN, CNN-LSTM, YSA ve rastgele orman (RF)) çok aşamalı ileri günlük ETo (yedi gün) tahmininde kullanmışlar ve karşılaştırılmışlardır. Çalışmada, oluşturulan modelleri, bölgesel ve yerel girdi verilerden oluşturularak, çoklu girdi ve çoklu çıktı (MIMO) tahmin stratejilerini kullanarak çalıştırmışlardır. Değerlendirilen üç girdi verisi kombinasyonu sadece ETo, ETo + gün ve ETo + gün + meteorolojik veriler olmuştur. Brezilya Minas Gerais'de bulunan 53 meteoroloji istasyonundan gelen veriler kullanılmış ve test istasyonları olarak da dört istasyon kullanmışlardır. Genel olarak, MIMO'nun, iyi performans gösterdiğini ve daha düşük hatalı en iyi tahmin stratejisi olduğunu bildirmişlerdir. Çalışmalarında, derin öğrenme modellerinin, makine öğrenimi modellerinden biraz daha iyi performans

gösterdiğini bulmuşlardır. Benzer performans sergiledikleri ve genelleme kapasiteleri daha yüksek olduğu için yerel modeller yerine bölgesel modelleri önermişlerdir. Sonuç olarak, geliştirilen modellerin yüksek doğruluklar göstermemiş olsalar da, ETo değerini tahmin etmek için tarihsel aylık ortalama ETo kullanıldığı yerlerde yararlı araçlar olabileceklerini bildirmişlerdir.

Kumar ve ark. (2020), çalışmalarında batı Himalaya bölgesinde referans evapotranspirasyonu (ET_o) tahmin etmek için yapay sinir ağlarının (YSA) kullanımını incelemeyi amaçlamışlardır. Bu amaçla, 1979-2011 yılları arasında 47 istasyondan, 3 alt bölgenin meteorolojik verileri temin edilmiştir. Bu çalışmada, farklı girdi veri kombinasyonlarını kullanarak iki YSA modeli test edilmiştir. Test edilen modellerin birincisi, 5 giriş değişkeni (minimum sıcaklık, maksimum sıcaklık, nispi nem, güneş radyasyonu ve rüzgâr hızı) içeren A1 modeli, diğeri 2 giriş değişkeni (maksimum ve minimum sıcaklık) içeren A2 modeli olmuştur. YSA modellerinin performansı, hataların karesi (SSE), kök ortalama hata karesi (RMSE) ve R² değerleri kullanılarak değerlendirilmiştir. Model A1, tüm alt bölgeler için A2'den nispeten daha iyi performans göstermiştir, ancak A2 modelinde, çoğu konum için test aşamasında A1'den daha iyi performans elde edilmiştir. Çalışma sonucunda, hata istatistiklerine göre yetersiz veri olduğunda A2 modeli A1 modeli ile karşılaştırılarak ETo değerini tahmin etmek için etkin bir şekilde kullanılabilceği belirtilmiştir.

Nagappan ve ark. (2020), Hindistan'daki Veeranam Gölü'nde yürüttükleri bir çalışmada, 1995-2016 yılları arası ETo değerlerinin tahmin ve modellemesinde ilişkilendirilmiş değişkenleri çok değişkenli analizini yapmışlardır. Bu çalışmada aynı zamanda, ETo değerini tahmin etmede az sayıda parametre ile bir derin öğrenme sinir ağının (DLNN) etkinliğini, Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO-56) Penman-Monteith denklemi kullanarak, temel makine öğrenimi olarak radyal temelli fonksiyon sinir ağı (RBFNN) ile karşılaştırmışlardır. Girdi değişkeni sayısı, ETo modellemesinde altıdan en önemli üç değişkene indirilmiştir. Sonuç olarak, DLNN modelinin diğeri makine öğrenimi modelleri arasında, az sayıda veriyle ETo tahmininde etkili bir şekilde kullanılabilceğini göstermişlerdir.

Nawandar ve ark. (2020), Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) tarafından ETo hesaplamak için önerilen Penman-Montieth (PM) yönteminin yoğun girdi ihtiyacı nedeniyle girdiler eksik olduğunda kullanımının zor olduğunu belirtmişlerdir. Çalışmalarında sunulan model, PM yöntemini taklit etmeyi hedeflemiş ve minimum girdi değişkenlerini kullanarak aynı sonuçları elde etmeyi amaçlamıştır. Önerdikleri YSA modeli kullanılarak tahmin edilen çıktıda, maksimum 0,4 mm gün⁻¹ gibi son derece küçük bir hatanın mevcut olduğunu bildirmişlerdir.

Özgür ve Yamaç (2020), günlük ETo değerini tahmin etmek için yapay sinir ağı (YSA) ve derin sinir ağı (DNN) modellerinin performanslarını karşılaştırmışlardır. Bu amaçla, maksimum hava sıcaklığı (Tmaks), minimum hava sıcaklığı (Tmin), güneş radyasyonu (Rn), maksimum bağıl nem (RHmaks), minimum bağıl nem (RHmin) ve rüzgâr hızı (U₂) dahil olmak üzere altı giriş verisini Türkiye’de 1999-2018 yılları için 4 farklı meteoroloji istasyonundan (Adana, Aksaray, Isparta ve Niğde) sağlamışlardır. Sonuçlar, çalışmada önerilen DNN modellerinin, önceki YSA ve DNN modellerine kıyasla günlük ETo tahmini için tatmin edici doğruluk elde ettiğini göstermiştir. Araştırmacılar, en iyi performans gösteren modelin, 0.9934 belirleme katsayısı ve 0.2073 kök ortalama kare hatası bulunan SeLu aktivasyon fonksiyonu ile önerilen DNN modeli olduğunu belirtmişlerdir. Çalışmada dünyanın diğer iklim bölgelerinde de ETo tahmini için P-DNN-SeLU modeli önerilmiştir.

Sattari ve ark. (2020), günlük referans evapotranspirasyon (ETo) değerini, ağaç tabanlı regresyon ve derin öğrenmede geçitli tekrarlayan birim (GRU) modellerini kullanarak tahmin etmişlerdir. Bu amaç için, maksimum ve minimum sıcaklık, rüzgar hızı, maksimum ve minimum bağıl nem, çiğlenme noktası sıcaklığı (işba) ve güneşlenme süresini içeren meteorolojik değişkenlerden 15 girdi senaryosu oluşturmuşlardır. ETo değerleri, Birleşmiş Milletler Gıda ve Tarım Örgütü (FAO) Penman-Monteith yöntemi kullanılarak hesaplanmıştır. Sonuçlar olarak, rastgele orman modellerinden korelasyon katsayısı 0,9926 bulunanın, diğer ağaç temelli modellerden daha iyi olduğunu göstermişlerdir. Ek olarak, r=0.9837 olan GRU modeli, diğer modellere göre iyi performans göstermiştir. Çalışmada, maksimum sıcaklığın, modellere girdi olarak

kullanıldığında ETo deęerini tahmin etmede performansın daha etkili olduęunu bildirmişlerdir.

Sowmya ve ark. (2020), çalışmalarında, minimum meteorolojik verileri kullanarak zaman serisi verilerinin derin öğrenme potansiyelini araştıran bir ETo tahmin yöntemi önermişlerdir. Derin öğrenme ETo modellemesi için Kaliforniya, ABD'ndeki California Sulama Yönetim Bilgi Sistemi (CIMIS) iklim istasyonlarından gelen verilerden oluşturan iki veri setinin farklı özellik kombinasyonları kullanılarak derin bir sinir ağı modelinin dört çeşidini geliştirilip, tahmin performanslarını değerlendirmişlerdir. Sonuç olarak, geliştirilen modeller (DnnV1, DnnV2, DnnV3 ve DnnV6) arasında, iki giriş derin sinir ağı olan DnnV2 (RMSE = 0,36 mm gün⁻¹ ve 0,52 mm gün⁻¹, R²=0,94 ve R²=0,94) modelini diğer modellerle karşılaştırarak en iyi performans elde edilen model olarak önermişlerdir.

Yin ve ark. (2020), Standart ETo hesaplama yönteminin (Penman-Monteith) eksik parametreye sahip bir bölgede kullanım zorluğu sorununu aşılabilme için kısa süreli (1-7 günlük) günlük ETo deęerini tahmin etmek amacıyla bir hibrit iki yönlü uzun kısa süreli bellek (Bi-LSTM) modeli geliştirmişlerdir. Bu amaçla, Çin'de yarı kurak iklime sahip olan merkez Ningxia'da 2006–2018 yılları için üç meteoroloji parametresini (maksimum sıcaklık, minimum sıcaklık ve güneşlenme süresi) kullanarak modeli eğitmiş, doğrulamış ve test etmişlerdir. Sonuçlar, üç meteorolojik girdinin bir kombinasyonuna sahip hibrit Bi-LSTM modelinin, kısa süreli günlük ETo tahmin etmek için en iyi tahmin performansını sağladığını göstermiştir. Tahmin edilen seçilmiş günlük sürenin istatistiksel performansı, 1 günlük tahmin süresi için RMSE=0,159 mm gün⁻¹, 4 günlük tahmin süresi için RMSE=0,247 mm gün⁻¹, 7 günlük süre için RMSE=0,323 mm gün⁻¹ olarak bulunmuştur. Ek olarak, bu çalışmada geliştirilen hibrit Bi-LSTM modeli, sınırlı meteorolojik verilere sahip bir bölge olan Çin'in merkez Ningxia bölgesindeki 30 hektarlık *Lycium barbarum* plantasyonunun modern akıllı sulama sistemine entegre edilmiştir. Ayrıca araştırmacılar hibrit Bi-LSTM modelinin dünyanın farklı bölgelerindeki çok çeşitli iklim koşullarında değerlendirilmesini önermişlerdir.

Yu ve ark. (2020), kurak Altay ili koşulları altında günlük evapotranspirasyonu (ET_o) tahmin etmek için yapay sinir ağı (YSA), destek vektör regresyonu (SVR) ve aşırı öğrenme makinesi (ELM) uygulayarak maksimum ve minimum sıcaklık, rüzgâr hızı, bağıl nem, güneş radyasyonu, güneşlenme süresi ve atmosfer basıncınının 29 kombinasyon senaryosunu incelenmişlerdir. Modellerin performanslarını, Penman-Monteith denkleminde göre test ettiklerinde korelasyon katsayısı (r), kök ortalama kare hatası (RMSE), ortalama mutlak hata (MAE) ve Nash-Sutcliffe verimliliği (NS) ile sonuçları değerlendirmişlerdir. Sonuçlar, evapotranspirasyon sürecinde sıcaklığın vazgeçilmez rolünü ve aerodinamik kısmın baskın işlevini doğrulamıştır. ET_o tahmininde hem SVR hem de ELM modelleri, karşılaştırılabilir simülasyon yeteneği ve daha düşük belirsizlik nedeniyle ET_o tahmini için şiddetle tavsiye edilmiştir.

Yusuf ve ark. (2020), Kuzey Nijerya'daki Kano Eyaleti'nde Genelleştirilmiş Regresyon Sinir Ağı (GRNN) ve İleri Besleme Geri Yayılma Sinir Ağı'nın (FFBP NN), evapotranspirasyon değerini tahmin etmek amacıyla daha az girdi parametresi altında performansını belirlemek için bir çalışma yapmışlardır. Bu amaçla, Uluslararası Tropikal Tarım Enstitüsü istasyonundan 25 yıllık aylık meteoroloji verileri temin etmişlerdir. Verileri, eğitim ve doğrulama setleriyle birlikte 12 farklı girdi kombinasyonu haline getirmişlerdir. Farklı girdi kombinasyonlarına göre, GRNN modeli yalnız güneş radyasyonu girdi kombinasyonu olarak en düşük performansı (RMSE=1.982) göstermiş, diğer yandan sıcaklık ve rüzgar hızınının girdi kombinasyonu olarak kullanıldığı durumda en yüksek performansı (RMSE=0,7777) göstermiştir. Gözlemler, iki katmanlı İleri Beslemeli Sinir Ağı (FFNN) (10 gizli nöronlu) ile benzer girdi kombinasyonları sıralaması göstermiştir. Sonuç olarak, FFBP modelinin sıcaklık, rüzgar hızı ve güneş radyasyonlu girdi kombinasyonu ile yüksek performans (RMSE=0,6333) gösterirken, güneş radyasyonu ve nem giriş kombinasyonunun altında düşük performans gösterdiğini belirlemişlerdir.

Zhu ve ark. (2020), Kuzeybatı Çin'in kurak bölgesinde günlük ET_o değerini sınırlı girdi verileriyle tahmin etmek için aşırı öğrenme makineleri (ELM) modelinin parametrelerini en iyi şekilde belirlemek amacıyla parçacık sürüsü optimizasyonu (PSO) algoritması kullanmışlar ve böylece yeni bir hibrit PSO-ELM modeli oluşturmuşlardır. Çalışmada,

PSO-ELM modelini, orijinal ELM, yapay sinir ağı (YSA) ve rastgele ormanlar (RF) modelleriyle ve altı deneysel modelle (radyasyon, sıcaklık ve kütle aktarımına dayalı deneysel modeller dahil) karşılaştırmışlardır. Radyasyon, sıcaklık ve kütle transferi verilerinden modelleri geliştirmek için üç girdi kombinasyonu kullanılmışlardır. Sonuç olarak, makine öğrenimi modellerinin, aynı girdilere sahip ilgili deneysel modellere kıyasla daha doğru ETo tahminleri sağladığını görmüşler, Kuzeybatı Çin'in kurak bölgesinde sınırlı girdilerle günlük ETo değerini tahmin etmek için özellikle PSO-ELM modelini önermişlerdir.


Roy (2021), çalışmasında hesaplanan ETo geçmiş değerlerini kullanarak farklı derin ve makine öğrenme yöntemleriyle bir adım ileri ETo tahminlerini sağlamayı amaçlamıştır. Bu bağlamda, günlük ETo değerleri, beş iklim değişkenini kullanan FAO-56 Penman-Monteith yaklaşımı ile hesaplanmıştır. Bir adım önde ETo değerleri tahmin etmek için, derin öğrenme algoritmalarından, Uzun-Kısa Süreli Bellek (LSTM) ve iki yönlü LSTM (Bi-LSTM) ağının tahmin doğruluğunu ve tahmin kabiliyetini değerlendirmiştir. LSTM ve Bi-LSTM tahmin performanslarını, Sıradan Sıraya Regresyon LSTM ağı (SSR-LSTM) ve Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ile karşılaştırmıştır. Sonuç olarak, Bi-LSTM modelinin bir adım önde ETo değerlerini oldukça kesin bir şekilde tahmin etmek için başarıyla kullanılabileceğini göstermiştir.

3. MATERYAL ve YÖNTEM

3.1. Araştırma Verilerinin Yeri

Bu çalışmada kullanılan iklim verileri, T.C. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü'ne bağlı 17116 numaralı Bursa meteoroloji istasyonundan sağlanmıştır. İklim verileri 1990-2020 yılları arasında kaydedilen günlük verilerden oluşmuştur. Sağlanan veriler maksimum-minimum sıcaklık ($^{\circ}\text{C}$), ortalama sıcaklık ($^{\circ}\text{C}$), ortalama nispi nem (%), ortalama rüzgâr hızı (m s^{-1}) ve güneşlenme süresini (saat) içermiştir. Bursa meteoroloji istasyonunun deniz seviyesinden yüksekliği 100 m olup $44^{\circ} 13'$ kuzey enlemi, $29^{\circ} 00'$ doğu boylamında yer almaktadır (Şekil 3.1.).

Bursa İli Aydeniz, Erinç ve Thornthwaite İklim Sınıflandırmalarına göre yarı nemli, DeMartonne İklim Sınıflandırmasına göre de yarı kurak-nemli arası bir iklime sahiptir (MGM, 2021). Uzun yıllar (1960-2019) iklim verilerine göre; toplam yıllık yağış ortalaması 697,5 mm, yıllık ortalama sıcaklık $14,6^{\circ}\text{C}$, yıllık ortalama nispi nem %69,2 ve yıllık ortalama rüzgâr hızı $2,1 \text{ m s}^{-1}$ olarak ölçülmüştür (MGM, 2020).



Şekil 3.1. Bursa ili ve Bursa meteoroloji istasyonunun konumuna ait bir görünüm

3.2. Referans Bitki Su Tüketiminin Hesaplanması

Referans bitki su tüketiminin hesaplanmasında FAO Penman-Monteith yöntemi kullanılmıştır. FAO tarafından önerilen Penman-Monteith yöntemine ait denklem Eşitlik 3.1’de verilmiştir. Penman-Monteith yöntemi hem kurak hem de nemli iklimlere uygun olduğundan ve ASCE ve Avrupa çalışmalarında yüksek verimlilik gösterdiğinden tercih edilmiştir (Allen ve ark., 1998).

$$ET_o = \frac{0.408\Delta(R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma(1+0.34u_2)} \quad (3.1)$$

Eşitlikte;

ET_o : Referans Evapotranspirasyon (mm gün^{-1}),

R_n : Bitki yüzeyindeki net radyasyon ($\text{MJ m}^{-2} \text{gün}^{-1}$),

G : Toprak ısı akış yoğunluğu ($\text{MJ m}^{-2} \text{gün}^{-1}$),

T : 2 m yükseklikte ortalama günlük hava sıcaklığı ($^{\circ}\text{C}$),

u_2 : 2 metre yükseklikte rüzgar hızı (m s^{-1}),

e_s : Doygun buhar basıncı (kPa),

e_a : Gerçek buhar basıncı (kPa),

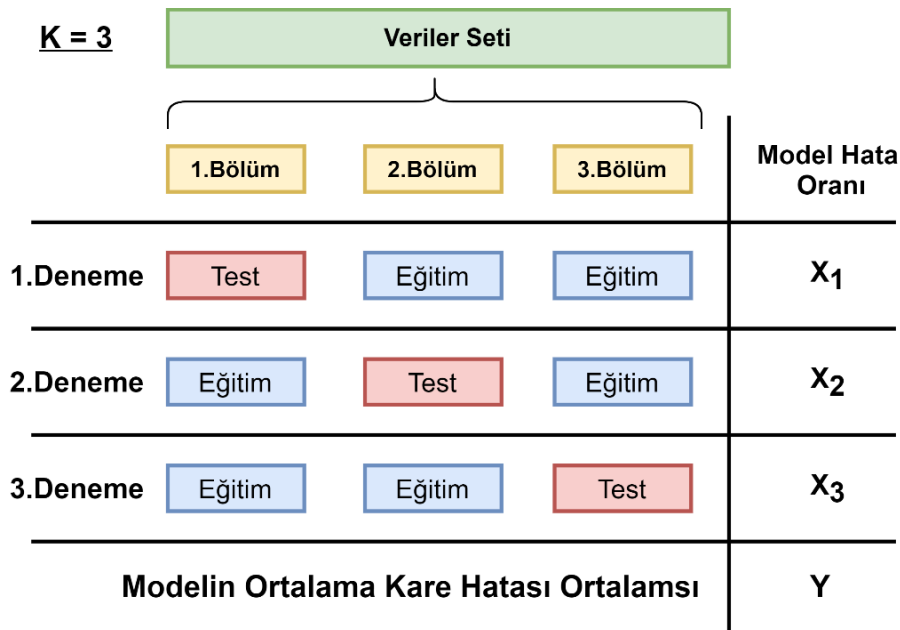
Δ : Buhar basıncı eğrisinin eğimi ($\text{kPa } ^{\circ}\text{C}^{-1}$),

γ : Psikrometrik sabiti ($\text{kPa } ^{\circ}\text{C}^{-1}$) göstermektedir.

3.3. K-katlamalı çapraz doğrulama yöntemi

Derin öğrenme modellerinin değerlendirilme ve sınıflandırılmasında en yaygın kullanılan yöntem Eğitim-Test Ayrımı yöntemidir. Bu yöntemde, model kurmadan önce kullanılacak veriler yatay olarak iki sete (eğitim seti – test seti) ayrılmakta, model eğitim seti üzerinden eğitilmekte ve test seti üzerinden modelin ne kadar başarılı olduğu belirtilebilmektedir. Eğitim-Test Ayrımı yöntemi kullanılırken çıkan problemlerden dolayı, bu yöntem model kurmak ve seçmek için tercih edilmemektedir. Eğitim-Test Ayrımı yöntemi, aşırı öğrenme (over-fitting) problemini doğurabilir. Eğitim-Test Ayrımı yöntemi tarafından ortaya çıkan problemlerin aşılabilmesi için K-katlamalı çapraz doğrulama yöntemi kullanılabilir (Goodfellow ve ark., 2016).

K-katlamalı çapraz doğrulama, oluşturulan tüm modellerden en iyi modelleri karşılaştırmak ve seçmek için kullanılan istatistiksel yöntemlerden biridir. K-katlamalı çapraz doğrulama, derin öğrenme oluşturulacak modellerin veriler setini seçilen K sayısına göre alt setlere böler ve her modelin performansını değerlendirebilmek için deneme sayısı K sayısına göre belirlenir. Her modelin denemesinde, bölünmüş veri setinin bölümlerinden biri sırasıyla ve modelin diğer denemelerinde tekrarlanmaması sağlanarak test için, kalanlar da model eğitmek için kullanılmaktadır. K değeri genellikle 5 veya 10 seçilir, ancak sabit bir kural yoktur. K büyüdükçe, eğitim seti ve test seti arasındaki boyut farkı küçülür. Bu fark azaldıkça tekniğin önyargısı küçülmektedir. Yöntemle ilgili prosedür Şekil 3.2’de bir örnekle gösterilmiştir. Örnekte K sayısı 3 olarak seçilmiştir. X_n Modelin bir denemesinin ortalama kare hatası (MSE) değeri, Y modelin denemelerinin MSE ortalamasıdır (Kuhn ve Johnson, 2013).



Şekil 3.2. K-katlamalı çapraz doğrulama yönteminin prosedürü

K-katlamalı yöntemi, her modelin denemesinde Ortalama Kare Hata (MSE) değerini kullanarak modelin performansının nasıl olduğunu gösterir. Bir modelin performansını diğer modellerle karşılaştırırken, o modelin tüm denemelerindeki MSE ortalamasını diğer modellerin MSE ortalamasıyla karşılaştırmaktadır (Feng ve ark., 2017).

Ortalama Kare Hata (MSE) (Eşitlik 3.2), bir derin öğrenme modelinin, tahmin edebilme performansını ölçer. Her zaman pozitif değerlidir ve MSE değeri sıfıra yakın olan modelin daha iyi bir tahmin performansı gösterdiği söylenebilir.

$$MSE = \frac{1}{n} \sum (Y - \hat{Y})^2 \quad (3.2)$$

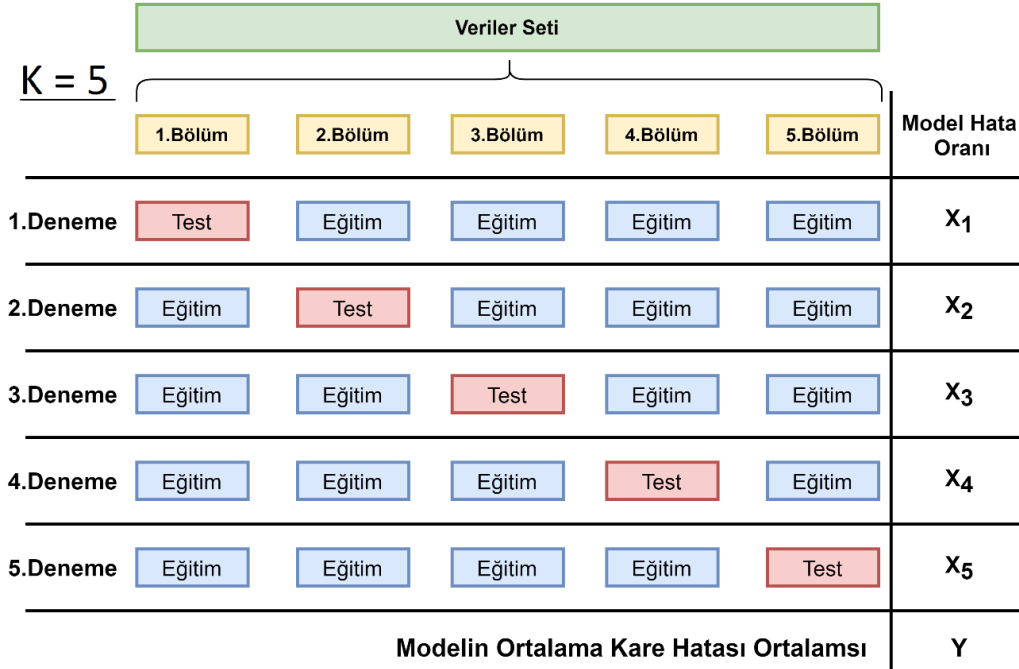
Eşitlikte;

n: Deneme sayısını,

Y: Modelle ulaşılmak istenen değerleri (gerçek çıktı),

\hat{Y} : Model tarafından tahmin edilen değerleri (tahmin ettiği çıktı) göstermektedir.

Bu çalışmada, K-katlamalı yönteminin K parametresi 5 seçilmiştir. Yani, verilerin dört parçası eğitim için bir parçası test için bölünmüştür. Ek olarak, her modelin denemelerinin sayısı 5 olmuş, her modelin denemesinde kullanılan veri kombinasyonu diğer denemelerde değişmiştir (Şekil 3.3).



Şekil 3.3. K parametresi 5 seçildiğinde K-katlamalı çalışma yöntemi

3.4. Derin Öğrenme Modelleri

Derin öğrenme, karmaşık problemlerin çözülmesinde standart yapay sinir ağları (tek gizli katmanından oluşan yapay sinir ağı) yerine tercih edilmektedir. Derin öğrenme ile çeşitli problemler için geliştirilen mimariler (yöntemler veya derin ağları), problemlerin çözümünde yüksek performans gösterdiğinden yaygın olarak kullanılmaktadır.

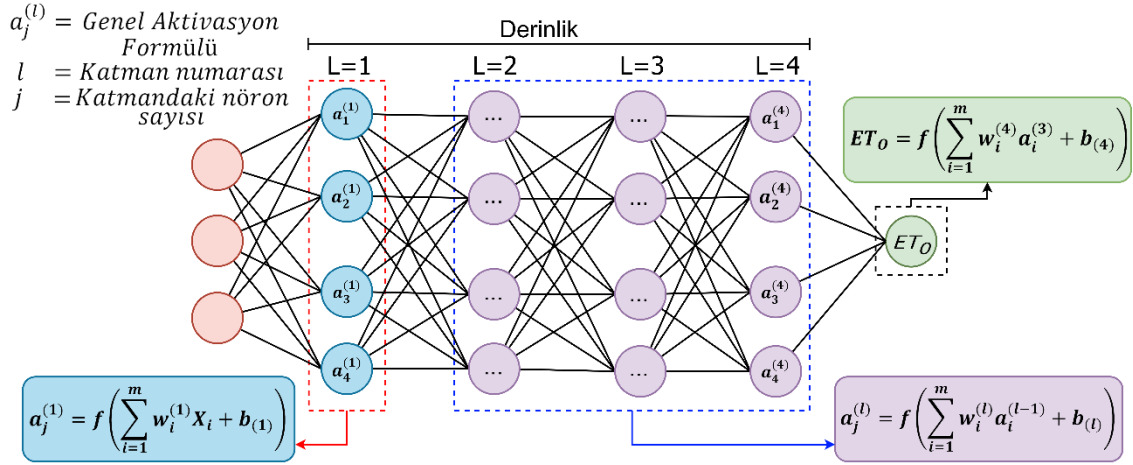
Bu çalışmada, ETo değerinin tahmin edilmesinde, derin öğrenme yöntemlerinin verimliliği test edilip sonuçlar belirtilmiştir. Çalışmada, standart ve hibrit derin öğrenme mimarileri kullanılmıştır. Standart mimari sadece bir katman türünden oluşur, hibrit mimari birden fazla katman türünden oluşmaktadır. Yapılan çalışmada, kullanılan standart modeller içerisinde Tekrarlayan Sinir Ağı (RNN) hariç, Tek boyutlu Evrişimli Sinir Ağları (1D-CNN), Uzun Kısa Süreli Hafıza Ağları (LSTM) ve Çift Yönlü LSTM (Bi-LSTM) ile Çok Katmanlı Algılayıcı (ÇKA) kullanılmıştır.

Hibrit modeller, her derin öğrenme mimarisinin güçlü yönlerinden yararlanmak için birden fazla algoritmayı tek bir modelde birleştirmektedir. Bu modeller, daha iyi performans elde edilmesine yardımcı olabilmektedir. Bu çalışmada test edilen hibrit mimari, 1D-CNN, LSTM ve ÇKA'dan oluşmuştur.

3.4.1. Çok katmanlı algılayıcı (ÇKA)

ÇKA, en popüler Derin Öğrenme mimarilerinden biridir. Literatürde genellikle tam bağlantılı ağlar (fully-connected layer) olarak anılmaktadır. Girdi katmanı, gizli katman ve çıktı katmanından Standart Yapay sinir Ağları gibi oluşur, fakat gizli katmanın sayısı ikiden fazla olmalıdır. ÇKA mimarinde bulunan gizli katmanların sayısı arttıkça, ağın derinliği artırmaktadır. ÇKA, ikiden çok katman halinde organize edilmiş grup şeklinde basit algılayıcılardan oluşmaktadır. ÇKA mimarisi Şekil 3.4'te gösterilmiştir. ÇKA mimarisinde, soldaki birinci katmanda bulunan her algılayıcı, ikinci katmandaki tüm algılayıcılara sinyaller gönderir ve bu durum sağdaki çıktı katmanına kadar devam etmektedir. Ek olarak, problemlerin regresyon ya da sınıflandırma olmasına göre çıktı

katmanındaki algılayıcı sayısı seçilmelidir (Goodfellow ve ark., 2016; Pérez-Enciso ve Zingaretti, 2019).




Şekil 3.4. ÇKA mimarisi ve çalışma yöntemi

3.4.2. Tek boyutlu evrişimli sinir ağları (1D-CNN)

Evrişimli Sinir Ağları (CNN) ile standart YSA arasındaki temel fark, evrişim katmanlarının varlığıdır. Bu katmanlar, girdi verileri ve çıktı tahmin olarak değişkenler arasındaki önemli ilişkiyi bulmak için önemli olan girdi verilerinin özelliklerini yakalayıp otomatik özellik çıkarma işlemini gerçekleştirebilmektedirler (Goodfellow ve ark., 2016; Lecun ve ark., 2015).

Genellikle, CNN görüntü (iki boyutlu veri) sınıflandırması için kullanılır ve bunun için sınıflandıran derin öğrenme mimarisinde iki boyutlu evrişim katmanı (Conv2D) bulunmaktadır. Diğer veri türlerinin boyutuna göre uygun bir evrişim katmanı türü var olduğundan, evrişim sinir ağları tek boyutlu veriler (zaman serisi), iki boyutlu veriler (görüntü) ve üç boyutlu veriler (3D görüntü) ile çalışabilmektedir. Yani, zaman serisi için evrişim sinir ağlarında tek boyutlu evrişim katmanı (Conv1D) kullanılabilir (Goodfellow ve ark., 2016; Lecun ve ark., 2015). Referans evapotranspirasyon değeri bir-boyutlu olduğu için kullanılan evrişim katmanı tek-boyutludur (Ferreira ve da Cunha, 2020).


Her bir evriřimli katmanda, tanımlanmış girilecek verilerin genişliđi ve adımları boyunca bir evriřimli iřlem gerekleřtirilir. Bu evriřimli iřlemlerin her birine "kernal" veya "filtre" denir ve bir YSA'daki nörone eř deđerdir. Evriřimli sinir ađlarının yüksek performanslı olmasının nedeni Pooling katmanı ve düzleřtirme (flatten) katmanının varlıđıdır. Pooling katmanı, evriřim katmanından sonra gelir. Bu katmanın görevi, evriřim katmanında hesaplanan parametre boyutunu küültürerek düzeltmektedir. Düzleřtirme (flatten) katmanı, Pooling katmanından sonra gelir ve Pooling katmanından ıkan verilerin tam bađlantılı ađlar (KA) iin hazırlanmasını sađlar (Kiranyaz ve ark., 2021; Pérez-Enciso ve Zingaretti, 2019). 1D-CNN iin alıřma yöntemi Őekil 3.5'te basite açıklanmıştır.



Şekil 3.5. Veriler için 1 boyutlu evrişimli sinir ağının bir bütün olarak gösterimi. Evrişim çıktıları mavi ile gösterilir. Pooling katmanları, yeşil renkle gösterilir. Düzleştirme (flatten) katmanı, kırmızı renkle gösterilir. Son katman, standart bir YSA'dır. a) Bir-boyutlu evrişim işlemi, b) Düzleştirme katmanı işlemi ve c) Pooling katmanının işlevidir.


3.4.3. Uzun kısa süreli hafıza ağları (LSTM)

LSTM, sıralı verileri işlemek için kullanılan geleneksel tekrarlayan sinir ağlarına (RNN) göre avantajları olan özel bir RNN türüdür (Hochreiter ve Schmidhuber, 1997). LSTM özellikleri, RNN özelliklerine benzer, fakat LSTM hücresi RNN hücresinden farklıdır. RNN hücresinin içerisinde tek sinir ağı katmanı (aktivasyon fonksiyonu) vardır (Şekil 3.6).



Şekil 3.6. Standart RNN mimari, a) RNN hücresi b) RNN hürseinde bulunan katman


LSTM, strandart RNN'nin uzun dizi verilerinden öğrenme problemini aşabilmektedir. LSTM hücresinin özel mimarisi, sinir ağında verilerin ne zaman unutulacağını ve ne kadar süreyle saklanacağını öğrenmesini sağlar. LSTM hücresi, unutma geçidi, girdi (input) geçidi, çıktı (output) geçidi, hücre durumu (C_t) ve gizli hücre durumunu (Y_t) içerir. Hücre durumu (C_t), sinir ağının hücresinde verilerin değişmeden akmasını sağlamaktadır. Unutma geçidi, input geçidi ve output geçidi, hücre durumunda (C_t) veriler akarken düzenli bir hale getirmektedirler. Unutma geçidi, hücre durumu içerisinde kontrol ederek unutulacağı elemanların unutulmasına izin verir. İnut geçidi, hücre durumundan hangi verilerin güncellenmesi gerektiğine karar verir. Output geçidi, son hücre haline göre gizli hücre durumu (Y_t) üretmekten sorumludur (Ferreira ve da Cunha, 2020; Goodfellow ve ark., 2016). Şekil 3.7'de bir LSTM hücresinin yapısı açıklanmıştır.



Şekil 3.7. Uzun Kısa Süreli Bellek (LSTM) modeli, a) hücre mimarisini b) ETo tahmin etmek için LSTM modelini göstermektedir.

3.4.4. Çift yönlü LSTM (Bi-LSTM)

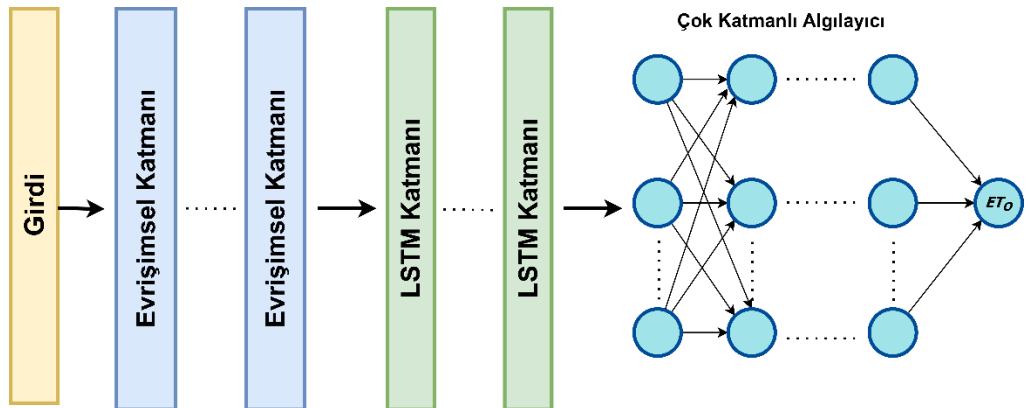
Bir Çift Yönlü LSTM veya Bi-LSTM, iki LSTM'den oluşan bir dizi işleme derin sinir ağıdır. Çift yönlü LSTM, sinir ağında ileri ve geri yönlü girdileri alıp birbirine bağlayarak çıktının tahmin edilmesini sağlamaktadır. Diğer bir ifadeyle, Çift yönlü LSTM'lerde, öğrenme algoritması orijinal verilerle bir kez baştan sona ve bir kez de sondan başa beslenilmektedir. Bu sinir ağında, girdiler iki yönde girdiğinden dolayı, ağda mevcut olan bilgi miktarını etkin bir şekilde arttırarak, ağ girdileri arasındaki ilişkiyi daha iyi hale getirilmektedir. Bazı araştırmalarda, Çift Yönlü LSTM'nin, Standart LSTM'den daha hızlı öğrendiği bildirilmektedir (Roy, 2021). Bi-LSTM çalışma yöntemi Şekil 3.8'de açıklanmıştır.



Şekil 3.8. Bi-LSTM derin sinir ağının yapısı

3.4.5. Hibrit mimari (1D-CNN-LSTM)

Çalışmada ele alınan hibrit mimari, Tek Boyutlu Evrişimli Sinir Ağı, Uzun Kısa Süreli Hafıza Ağları ve Çok Katmanlı Algılayıcı'yı (1D-CNN – LSTM) birleştiren hibrit bir derin öğrenme mimarisidir. Bu hibrit mimaride, Şekil 3.9'da gösterilen girdi verilerinden yararlı özellikleri çıkarmak için bir veya daha fazla evrişimli katmanla işleme başlanmaktadır. Evrişimli katmanından çıktı, bir veya daha fazla LSTM katmanında girdi olarak kullanılmaktadır. Son olarak, LSTM katmanlarından gelen çıktı, sonuçların son tam bağlı katmanda (çıkı katmanı) elde edildiği, tam bağlı katmanlara geçirilmektedir (Ferreira ve da Cunha, 2020).

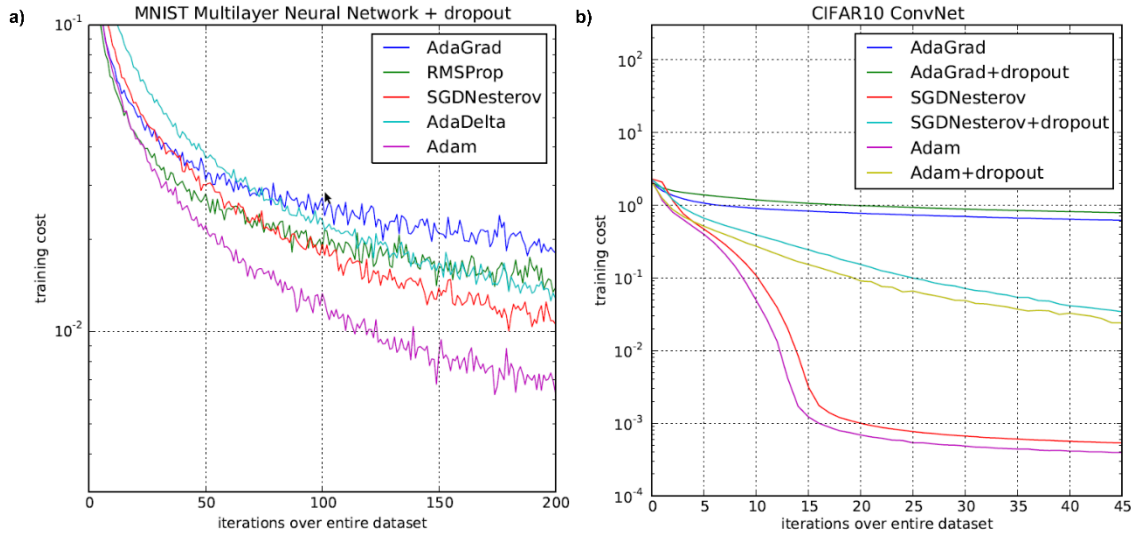


Şekil 3.9. Hibrit mimari genel yapısı

3.5. Optimizasyonu Algoritması (Adam)

Adam, yinelemeli ağ ağırlıklarını güncellemek için klasik Stokastik Gradyan İniş (SGD) algoritması yerine kullanılabilen, derin öğrenme modellerini eğitmek için SGD'ye yönelik bir değiştirme optimizasyon algoritmasıdır. Adam, derin öğrenme alanında, kolay ve hızlı bir şekilde iyi sonuçlara ulaştığından çok popüler bir algoritmadır. Derin öğrenme çalışanlar Adam'ı, klasik SGD, Uyarlanabilir Gradyan Algoritması (AdaGrad) ve Kök Ortalama Kare Yayılımının (RMSProp) avantajlarını birleştiren bir optimizasyon algoritması olarak tanımlamaktadırlar (Goodfellow ve ark., 2016).

Kingma ve Ba (2015) tarafından yapılan çalışmada, Adam algoritması diğer algoritmalarla karşılaştırılmış ve tüm oluşturulan modellerde Adam algoritması diğerlerine göre tercih edilmiştir (Şekil 3.10). Ek olarak, onların çalışmasına göre, Adam algoritması Drop out yöntemi ile kullanıldığında modelin performansı düştüğünden, bu güncel çalışmada modellerin optimizasyonunda Drop out kullanılmamıştır.



Şekil 3.10. Adam'ın diğer optimizasyon algoritmalarıyla karşılaştırılması. a) çok katmanlı bir algılayıcı eğitimi, b) evrişimli sinir ağları eğitimi.

3.6. Kodlama Dili

Derin sinir ağlarının kurulması, eğitilmesi ve geliştirilmesi için çok fazla araç vardır. Araştırmalarda eski ve yaygın sinir ağlarını geliştiren MATLAB bilgisayar programı kullanılmaktadır. Son yıllarda, problemlerin çözümünde sinir ağlarını geliştirmek için, Python, kütüphaneleriyle birlikte MATLAB'tan daha yaygın kullanılan bir programlama dilidir. Python, derin öğrenme ve veri analizinde kolay öğrenme ve kullanma, ücretsiz, genişletilebilir, açık kaynak ve topluluk geliştirmeden dolayı diğer programlama dillerine göre tavsiye edilmektedir. Bu çalışmada, Python programlama dili altında modeller geliştirilmiş ve test edilmiştir. Python'da bulunan ve Çizelge 3.1'de verilen kütüphaneler farklı işlemler yapmak için donanım olarak kullanılmıştır. Modelleri geliştirmek için kullanılan kişisel bilgisayar 2.60GHz işlemci bulunduran ve 16GB RAM'e sahip bir bilgisayardır.

Çizelge 3.1. Çalışmada kullanılan Python kütüphaneleri

No	Adı	Giriş ve çalışmada kullanımı
1	 Numpy	Makine öğrenimi temelidir. Numpy, verilerle farklı boyutlu diziler olarak çalışma imkânı sunmaktadır. Veriler modeller tarafından kullanılabilir şekilde biçimlendirilmiştir.
2	 Pandas	Veri seti üzerinde işlem ve analiz yapmak için bir Python kütüphanesidir. Bu çalışmada, verileri okuyabilmek, verilerin analizi ve modellerden elde edilen verileri kaydetmek için kullanılmıştır.
3	 Scikit-learn	Kütüphane olarak veri analizi ve makine öğrenme modellerine faydalı araçlar sunmaktadır. Bu çalışmada, normalizasyon, verileri bölmek ve K-katlamalı analizini uygulamak için kullanılmıştır.
4	 TensorFlow	Makine öğrenimi modelleri için Google tarafından geliştirilen bir platformdur. Makine öğrenme modellerini kolay bir şekilde geliştirmek ve uygulamak için araçlar bulunmaktadır.
5	 Keras	TensorFlow'un sunduğu en önemli araçlardan biridir. Derin sinir ağları tasarlayarak geliştiren bir kütüphanedir. Bu çalışmada, tüm modeller Keras ile tasarlanmıştır.


3.7. Verilerin Hazırlanması

Meteoroloji istasyonundan sağlanan verilerde, derin öğrenme modelleri geliştirilmeden önce Pandas kullanılarak eksiklikler bulunmaya ve düzgün hale getirilmeye çalışılmıştır. Düzenlenen meteoroloji verileriyle FAO Penman-Monteith yöntemi kullanılarak 1990-2020 yılları arası günlük ETo değerleri hesaplanmıştır.

3.7.1 Zaman serisi verileri

Zaman serisi, genellikle zaman içinde eşit aralıklarla yerleştirilmiş sıralı bir değerler dizisi olarak tanımlanmaktadır. Bundan dolayı, ETo, veri olarak bir zaman serisidir. Zaman serisi, iki tipe bölünmektedir. Tek değişkenli zaman serisi, tek bir değişkenden oluşur, istatistiksel analizde sadece zamana göre incelenmektedir. Çok değişkenli zaman serisi, iki ya da ikiden fazla değişkenden oluşur, istatistiksel analizde bir değişken diğer bağımlı değişkenlere göre incelenmektedir.

Bu çalışmada, ETo çok değişkenli zaman serisi olarak modelleri eğitmek ve test etmek için kullanılmıştır (Şekil 3.11). Buna bağlı olarak, çalışmada oluşturulan test edilmiş senaryolardır.



Şekil 3.11. ETo, çok değişkenli bir zaman serisidir

3.7.2. Korelasyon analiziyle kontrol işlemi

Derin öğrenmede iyi düzeyde elde edilebilen bir sonuç almak için, kullanılan veri setindeki parametreler doğru seçilmelidir. Meteoroloji verileri için istatistiksel parametreler hesaplanmış ve onların histogramları oluşturulmuştur. Ek olarak, meteoroloji verileri ve ETo arasında korelasyon olup olmadığını kontrol edebilmek için Pearson korelasyon ve Belirleme Katsayısı analizi kullanılmıştır (Antonopoulos ve Antonopoulos, 2017).

3.7.3. Veri kombinasyonları oluşturma ve veri senaryoları

Bu çalışmada, Bursa ilinin meteoroloji verilerinden, ETo tahmininde sınırlı parametrelerle kabul edilebilen ETo değeri veren kombinasyonları bulmak için mümkün olduğu kadar çok sayıda kombinasyon oluşturulmuştur.

Çalışmada, seçilen derin öğrenme modelleri, 22 senaryo altında test edilmiştir (Çizelge 3.2). Oluşturulan veri kombinasyonları, modellerde girdi ve çıktı olarak temsil edilmektedir. Bu şekilde veri kombinasyonları oluşturmanın nedeni, ETo tahmininde her bir iklim parametresinin bireysel kabiliyeti ve diğer parametrelerle arasındaki ilişkiyi gösterebilmektir. Ek olarak, bu çalışmada minimum sıcaklık ve maksimum sıcaklık parametreleri bir parametre olarak sayılmaktadır. Çizelge 3.2’de bulunan veri kombinasyonları, bulgulardaki aynı veri kombinasyonlarına atıfta bulunmak için kullanılmıştır.

Çizelge 3.2. Oluşturulan test edilmiş veri kombinasyonları

Girdi		Çıktı	
No	Veri Kombinasyonu	Kısaltmalar	
1	Maks-Min Sıcaklık	MNS	ET _o
2	Ortalama Sıcaklık	OS	ET _o
3	Güneş Süresi	GS	ET _o
4	Nem	N	ET _o
5	Rüzgâr hızı	R	ET _o
6	Ortalama Sıcaklık- Güneş Süresi	OS-GS	ET _o
7	Ortalama Sıcaklık- Nem	OS-N	ET _o
8	Ortalama Sıcaklık- Rüzgâr hızı	OS-R	ET _o
9	Güneş Süresi- Nem	GS-N	ET _o
10	Güneş Süresi- Rüzgâr hızı	GS-R	ET _o
11	Nem- Rüzgâr hızı	N-R	ET _o
12	Maks-Min Sıcaklık- Güneş Süresi	MNS-GS	ET _o
13	Maks-Min Sıcaklık- Nem	MNS-N	ET _o
14	Maks-Min Sıcaklık- Rüzgâr hızı	MNS-R	ET _o
15	Maks-Min Sıcaklık- Rüzgâr hızı- Güneş Süresi	MNS-R-GS	ET _o
16	Maks-Min Sıcaklık- Rüzgâr hızı- Nem	MNS-R-N	ET _o
17	Maks-Min Sıcaklık- Güneş Süresi- Nem	MNS-GS-N	ET _o
18	Ortalama Sıcaklık- Rüzgâr hızı- Nem	OS-R-N	ET _o
19	Ortalama Sıcaklık- Güneş Süresi- Nem	OS-GS-N	ET _o
20	Ortalama Sıcaklık- Rüzgâr hızı- Güneş Süresi	OS-R-GS	ET _o
21	Maks-Min Sıcaklık- Güneş Süresi- Nem- Rüzgâr hızı	MNS-GS-N-R	ET _o
22	Ortalama Sıcaklık- Güneş Süresi- Nem- Rüzgâr hızı	OS-GS-N-R	ET _o

3.7.4. Veri normalizasyonu

Derin öğrenme algoritmaları, standart ölçekte sayısal verilerle eğitildiğinde daha iyi performans göstermektedir. Derin öğrenme modellerinin verilerini işlenmeye hazırlamak için Normalizasyon yöntemi kullanılmaktadır. Normalizasyon, algoritmaların hızını arttırmasını ve modellerin doğruluğunun iyileştirilmesini sağlayan yöntemlerden biridir. Normalizasyon, girdi ve çıktı ölçeklerini standart ölçüğe dönüştürmeyi amaçlamaktadır. Normalizasyon işleminde sabit bir kural yoktur. Bu çalışmada, Normalizasyon yöntemlerinden Maks-Min Normalizasyon yöntemi kullanılarak girdi ve çıktı verileri üzerinde uygulanmıştır. Maks-Min Normalizasyon yönteminde kullanılan Eşitlik 3.3 ile

verilerin orijinal ölçeği 0 ile 1 arasındaki yeni ölçeğe çevrilmiştir (Antonopoulos ve Antonopoulos, 2017; Ferreira ve da Cunha, 2020) .

$$X_n = \frac{X_i - X_{min}}{X_{maks} - X_{min}} \quad (3.3)$$

Eşitlikte;

X_n = X değişkeninin yeni değeri,

X_i = Değiştirilecek X değişkeninin mevcut sayısı,

X_{min} = Sütündeki en küçük olan veri,

X_{maks} = Sütündeki en büyük olan veriyi göstermektedir.

3.8. Test Edilen Mimariler

Araştırmada ETo değerini en iyi tahmin edebilen derin öğrenme modeli mimarisini bulmak için, çeşitli mimariler (Standart Mimari – Hibrit Mimari) test edilmiştir. Test edilen her bir mimari, diğer mimarilerinden farklı sinir ağı türü (ÇKA-1D-CNN-LSTM-Bi-LSTM), katmanlar ve algılayıcı sayısından (farklı yapısı) oluşturulmuştur.

3.8.1. Standart mimariler

Standart mimarilerin katmanları, yalnızca bir tür katmandan oluşturulmaktadır. Bu çalışmada, her bir standart tür mimaride çeşitli yapılar kurularak test edilmiştir. Yani, model mimarinin katman sayısı ve katmanlardaki nöron sayısı değiştirilerek denenmiştir. Ek olarak, katman sayısı ve katmandaki nöron sayısı, hiperparametrelerden biri olarak sayılmaktadır.

Bu çalışmada, ÇKA, 1D-CNN, LSTM ve Bi-LSTM standart derin öğrenme modelleri oluşturularak ETo tahmin edilmesi için denemeler yapılmıştır. Her tip modelde en iyi mimariye ulaşmak için, her türe göre kademeli olarak hiperparametre artırılarak test edilen modeller oluşturulmuştur. Her türün hiperparametreleri diğer türlerden farklıdır. Örnek, ÇKA hiperparametreleri, katman sayısı ve katmanlardaki nöron sayısıdır. 1D-CNN hiperparametreleri ise, evrişimli katmanın sayısı, evrişimli katmanındaki filtre sayısı ve çekirdek boyutudur (Kernel Size).

3.8.2. Hibrit modeller

Hibrit mimariler, derin öğrenmenin güçlü noktalarından biridir. Çeşitli sinir ağı türlerinden katmanlar şeklinde oluşturulmaktadır. Her tür sinir ağının tüm avantajları tek bir modelde birleştirebilmektedir. Bu çalışmada, hibrit mimarilerinden iki grup oluşturulmuştur. Ayrıca, her grubun mimarileri, farklı bir yöntem kullanılarak oluşturulmuştur. Birinci grubun modelleri, test edilen standart modellerden en iyi performans mimarilerini seçip birleştirilerek bir hibrit mimari oluşturulmuştur. İkinci grubun modelleri, birinci grubun mimarilerinde aşırı öğrenme sorunu ile karşılaşma olasılığından dolayı, birinci grubun modellerinde bulunan katman sayısından daha az sayıda katmandan oluşturulacaktır.

3.9. Modellerin Eğitim ve Testi

Kurulan farklı mimarilerde modeller, bütün oluşturulan senaryolar atında K-katlamalı çapraz doğrulama analizi kullanılarak test edilmiştir. K-katlamalı analizi ile modeller test edilirken MSE istatistiksel analizini kullanmıştır. Her senaryoda en iyi model performansı, modeller arasında en düşük MSE değerine göre belirlenmiştir.

Her bir senaryoya ait en iyi mimariyi bulmak için K-katlamalı analizi yapılırken farklı mimari modelleri eşit hiperparametre altında (eşit koşullarda) test edilmiştir. Yani, sinir ağı yapısıyla ilgili hiperparametrelerde aktivasyon fonksiyonu ve tüm eğitim algoritmasıyla ilgili hiperparametreler sabittir.

Sabit olan eğitim algoritmasıyla ilgili hiperparametreler; öğrenme oranı, eğitim sayısı ve optimizasyon algoritması, sinir ağı yapısı ile ilgili hiperpareametre de sadece aktivasyon fonksiyonudur (Çizelge 3.3). Bu çalışmada, çalışılan tüm senaryolarda oluşturulan tüm modellerin performansı K-katlamalı yöntemi kullanılarak belirtilmiştir.

Çizelge 3.3. K-katlamalı yöntemi için seçilmiş sabit olan hiperparametre.


Kullanıldığı bölüm	Hiperparametre	Seçilen
Sinir ağı yapısı	Aktivasyon fonksiyonu	Relu
	Öğrenme oranı	0,01
	Eğitim sayısı	20
Eğitim algoritması	Optimizasyon algoritması	Adam

3.10. Modellerin Optimizasyonunu

K-katlamalı analizi kullanılarak her senaryo için en iyi performans (en düşük MSE değeri) gösteren modellerin, yeniden ayrı bir şekilde performansı arttırılmaya çalışılmıştır. Modellerin optimizasyonunda optimum öğrenme oranı bulunarak, en yüksek performansa ulaşmak için bulunan öğrenme oranıyla çalışılmıştır. Optimum öğrenme oranı, TensorFlow kütüphanesinde bulunan Learning Rate Schedule ile bulunmuştur.

K-katlamalı analizi tarafından tüm senaryolarda belirlenen MSE değerine göre, tüm derin ağ türlerinde en iyi beş performans modeli seçilmiştir. Ek olarak, aşırı öğrenme sorunlarından kaçınmak için, modellerin MSE değerleri eşit olduğunda az katmanlı ağ çoklu katmanlı ağa göre tercih edilmiştir. Ayrıca, aynı makinede veya farklı makinelerde bu çalışmada elde edilen sonuçlara yeniden ulaşmak için modelleri eğittirirken aynı rastgele işlevi sabitlemek için modelleri geliştiren TensorFlow çevresinde Global Seed İngilizce olarak 51 ayarlamıştır.

Performansı iyileştirme bağlamında, Relu aktivasyon fonksiyonunun yeteneği, Google tarafından üretilen Swish adlı aktivasyon fonksiyonu ile karşılaştırılmıştır (Şekil 3.12). Ek olarak, veri çerçevesinin karıştırılıp karıştırılmamasının performans üzerindeki etkisi belirlenmiştir. Dropout yöntemi ile ilgili olarak, Garbin ve ark. (2020) tarafında yapılan çalışmada derin öğrenme modelleri geliştirmede dropout yönteminin kullanılmaması önerildiğinden dolayı bu çalışmada kullanılmamıştır.



Şekil 3.12. Relu ve Swish Aktivasyon fonksiyonu.

3.11. Model Performanslarının Değerlendirilmesi

Derin öğrenme modelleri eğitildiğinde modellerin performansının ne düzeyde olduğunu belirtmek için, modellerin eğitildiği veriler dışında ki veriler üzerinde test edilmektedir. Derin öğrenme modellerinin performansını belirtmek için çeşitli istatistiksel analiz yöntemleri kullanılmaktadır.

Bu çalışmada, kurulan derin öğrenme modellerinde K-katlamalı analizi yaptıktan sonra, modellerden referans bitki su tüketimini en iyi tahmin eden modelleri çıkarıp, yeniden eğitilen modellerin ETo tahmin değerlerinin karşılaştırılmasında doğrulama yöntemlerinden, karekök hata kareler ortalaması (RMSE) (Eşitlik 4), ortalama mutlak hata (MAE) (Eşitlik 5) ve belirleme katsayısı (R^2) (Eşitlik 6) kullanılmıştır (Ferreira ve da Cunha, 2020).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4)$$

$$MAE = \frac{1}{n} |y_i - \hat{y}_i| \quad (5)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (6)$$

Eşitliklerde;

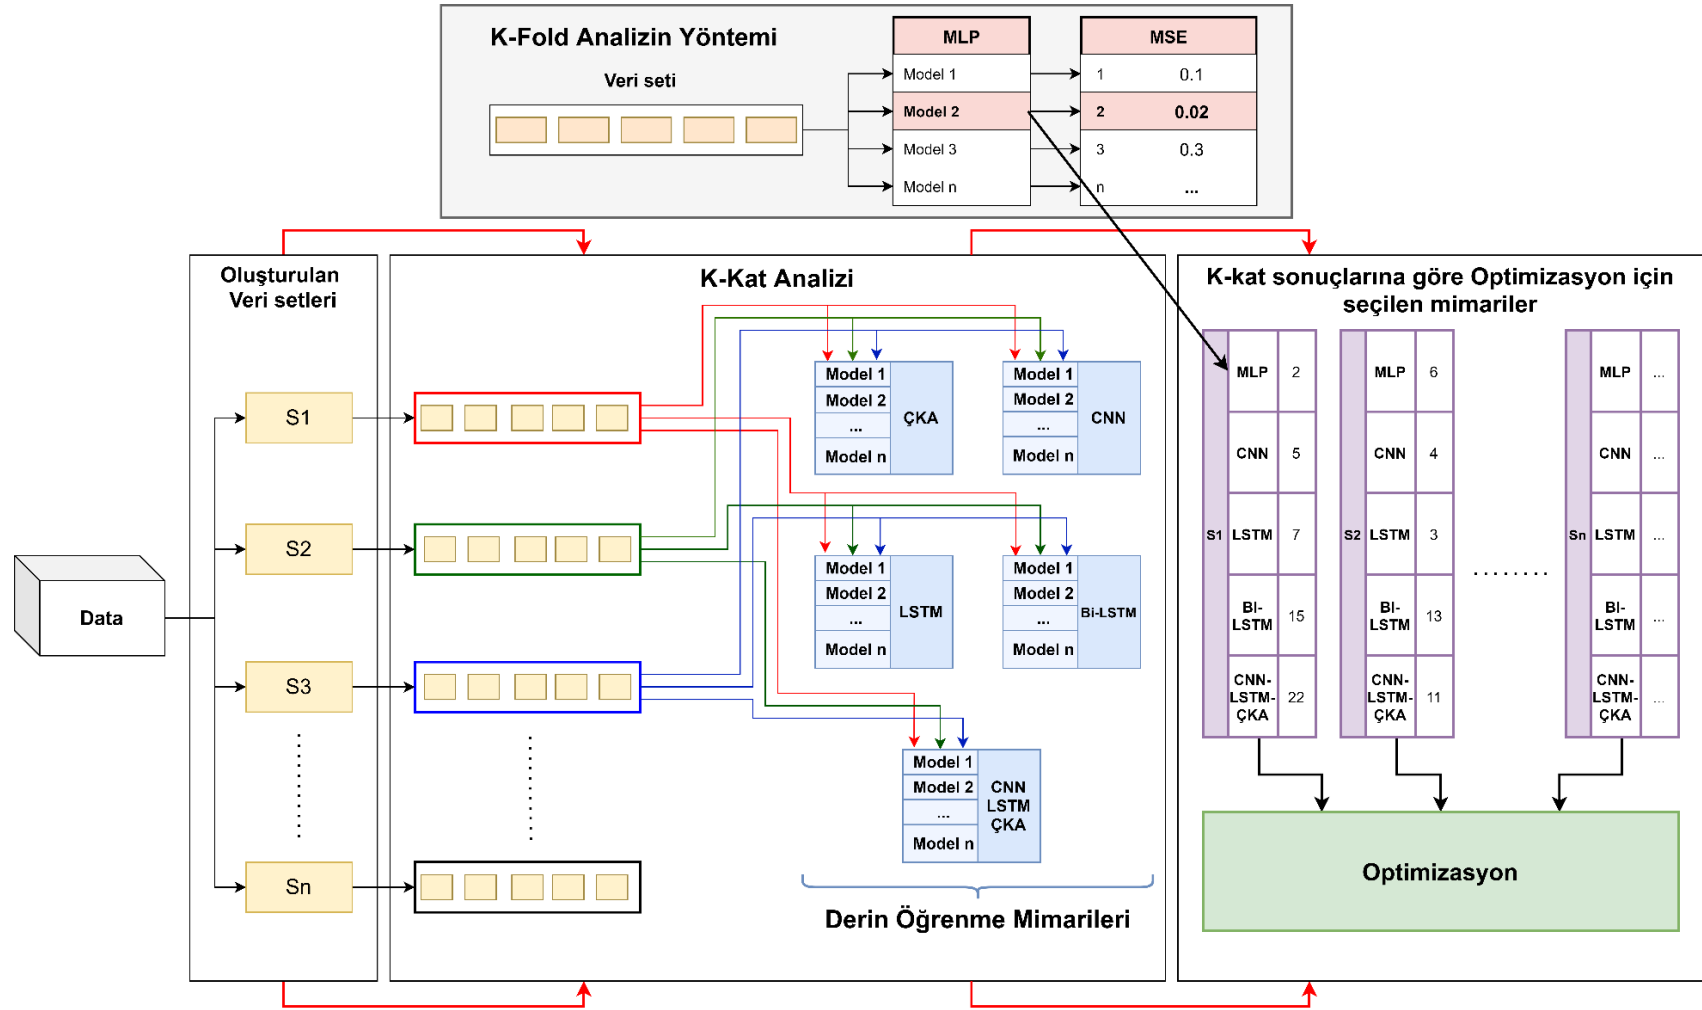
y: Gözlenmiş ETo i'ninci değeri,

\hat{y} : Hesaplanan ET_0 i'ninci deęeri,

\bar{y} : Gzlenmiř ET_0 i'ninci ortalaması,

n: Toplam gzlem sayısını ifade etmektedir.

Bu alıřma da izlenen metodoloji ayrıntılı olarak Őekil 3.13'te gsterilmiřti



Şekil 3.13. Araştırma Metodoloji

4. BULGULAR ve TARTIŞMA


4.1. Verilerin Hazırlanması ve Tanımlanması

Meteoroloji istasyonundan sağlanan veriler, 1990 – 2020 yılları arası günlük veriler olduğundan, veri seti boyutunun 11342 veri miktarından oluştuğu bulunmuştur. Verilerin Pandas kütüphanesi kullanılarak tanımlanmasında, günlük güneşlenme süresi verilerinde 284 eksik bulunmuştur. Derin öğrenme verimliliği, modellerin eğitimi için sağlanan veri miktarına bağlıdır. Modellerin eğitimi ve testinde meteoroloji istasyonundan gelen verileri bir bütün olarak kullanmak için esik veriler tamamlanmıştır. Günlük ETo değerleri, FAO Penman-Monteith yöntemi kullanılarak hesaplanmış ve günlük değişimi Şekil 4.2’de gösterilmiştir. Bursa’nın 1990 – 2020 yılları arası günlük iklimini tanımlamak için meteoroloji verilerinin istatistiksel parametreleri hesaplanmış (Çizelge 4.1) ve histogramları oluşturulmuştur (Şekil 4.1).


Çizelge 4.1. Bursa merkez istasyonu için meteorolojik değişkenlerin ve ETo değeri istatistiksel parametreleri

	MS (°C)	NS (°C)	OS (°C)	N (%)	R (m/s)	GS (saat)	ETo
Maks	43,8	25,1	31	99,2	13,1	14,2	8,5
Min	-4,0	-14,8	-6,8	12,3	0,0	0,0	0,1
Ortalama	20,81	9,66	14,97	69,21	2,00	5,68	2,67
SD	8,99	7,04	7,89	12,97	1,02	4,23	1,83

MS: Maksimum Sıcaklık **NS:** Minimum sıcaklık **OS:** Ortalama sıcaklık **N:** Ortalama Nispi Nem, **R:** Ortalama Rüzgâr hızı, **GS:** Ortalama Güneş süresi, **ETo:** Bitki su tüketimi (Evapotranspirasyon)




Şekil 4.1. Meteorolojik değişkenlerin ve ETo değeri histogramları




Şekil 4.2. 1990-2020 döneminde referans evapotranspirasyonun (ETo) değişimi

Bu çalışmanın amaçlarından birisi olarak, ETo tahmininde derin öğrenme modellerini kullanarak meteoroloji verisinin kullanım olanağının araştırılması belirtilmiştir. Buna bağlı olarak, ETo değerini derin öğrenme ile yüksek verimlilikle tahmin etmek için kullanılacak meteorolojik parametreler ile ETo arasındaki ilişki yüksek olmalıdır. Bundan dolayı, ETo üzerine iklim parametrelerinin etkisi Pearson korelasyon (Şekil 4.3) ve Belirleme Katsayısı analizi (Şekil 4.4) yapılarak belirlenmiştir. Analiz sonucunda, ETo üzerinde yüksek etkiye sahip parametreler maksimum sıcaklık ve ortalama sıcaklık parametreleri olarak belirlenmiştir. Orta etkiye sahip olanlar; minimum sıcaklık, ortalama nispi nem ve ortalama günlük güneşlenme süresi olmuştur. En düşük etkiye sahip olan ise, ortalama rüzgar hızıdır.



Şekil 4.3. Meteoroloji verilerinin pearson korelasyon analizi



Şekil 4.4. ETo ana meteorolojik parametrelerin korelasyonu: (a) maksimum sıcaklık- ETo, (b) minimum sıcaklık- ETo, (c) ortalama sıcaklık- ETo, (d) güneş süresi- ETo (e) rüzgar hızı- ETo (f) bağıl nem- ETo.

4.2. Derin Öğrenme Modellerinin Yapısını Oluşturma

Yüksek performanslı modellerin en iyi mimarisini bulmak için modellerin yapısıyla ilgili hiperparametredeki artış ve azalış yöntemi kullanılmıştır. Modelleri oluşturma süreci,

modellerin hiperparametreleri değiştirildiğinde modellerin performansı herhangi bir iyileşme kazanmadığında sona ermektedir. Bu çalışmada, farklı mimariye sahip oluşturulan modeller, tüm derin öğrenme sinir ağları türlerinden 93 mimari ile test edilmiştir. Ayrıca, K-katlamalı yöntemiyle her test edilen veri kombinasyonu her oluşturulan modelle değerlendirilmiştir, toplam yapılan deneme sayısı 2046 olmuştur.

ÇKA şeklinde oluşturulan modellerde, ETo tahmininde yüksek doğruluğa ulaşırken, ÇKA modellerinin katman ve algılayıcı sayısını arttırmanın etkisi gösterilmiştir. Çalışmada, ÇKA ile ilgili 18 model oluşturulmuştur (Çizelge 4.2). Bu modellerin çıktı katmanında sadece tek bir doğrusal aktivasyon fonksiyonlu algılayıcı bulunmaktadır.

Çizelge 4.2. ÇKA ile test edilen mimarileri.

Mimari Numarası	Çok Katmanlı Algılayıcı (ÇKA)			
	Mimarindeki Gizli Katman Sayısı			
	1	2	3	4
1	5	3	-	-
2	5	5	-	-
3	10	5	-	-
4	10	10	-	-
5	20	20	-	-
6	5	3	5	-
7	10	5	10	-
8	10	10	10	-
9	10	10	3	-
10	20	20	20	-
11	10	5	10	5
12	10	10	10	10
13	20	10	20	10
14	20	10	10	20
15	20	20	20	20
16	50	50	50	50
17	100	100	100	100
18	200	200	200	200

Aynı şekilde, 1D-CNN şeklinde oluşturulmuş modellerde, modeldeki evrişimli katmanın sayısı, evrişimli katmanın filtre sayısı ve çekirdek boyutu (Kernel Size) hiperparametre olarak değiştirilerek etkileri gösterilmiştir. 1D-CNN modelinde en yüksek performansa

ulaşmak için 12 model yapılmıştır (Çizelge 4.3). Oluşturulan 1D-CNN modelleri mimarilerinin tümünün evrişimli katmanlarından sonra 1x1 max pooling katmanı, sonrasında flatten katmanı ve çıktı katmanında sadece tek bir doğrusal aktivasyon fonksiyonlu algılayıcı bulunmaktadır. Çizelge 4.3'te model mimarisinde bulunan evrişim katman sayısı ve bu katmandaki filtre sayısı belirtilmektedir.

Çizelge 4.3. 1D-CNN test edilen mimarileri.

		Tek Boyutlu Evrişimli Sinir Ağları (1D-CNN)			
		Evrişim Katman Sayısı			
Mimari Numarası		1	2	3	4
1	Evrişim Katmandaki Filtre sayısı	32	-	-	-
2		64	-	-	-
3		128	-	-	-
4		64	32	-	-
5		64	64	-	-
6		128	64	-	-
7		32	32	-	-
8		32	32	32	-
9		64	64	64	-
10		128	128	128	-
11		128	64	32	-
12		256	128	64	32

Uzun Kısa Süreli Hafıza (LSTM) ve Çift yönlü Uzun Kısa Süreli Hafıza (Bi-LSTM) sinir ağlarına ait oluşturulmuş modellerde, ETo tahmininde LSTM ve Bi-LSTM doğruluğu arasındaki fark belirtilirken, her ikisinde de aynı model yapısı kullanılmıştır. LSTM ve Bi-LSTM için her türdeki toplam kurulan model sayısı 16 olmuştur (Çizelge 4.4). Ayrıca önceki modellerde olduğu gibi, oluşturulan model mimarisi çıktı katmanında sadece tek bir doğrusal aktivasyon fonksiyonlu algılayıcı bulunmaktadır. Günlük ETo tahmin edildiğinden dolayı LSTM ve Bi-LSTM tek adımlı olacaktır.

Çizelge 4.4. LSTM ve Bi-LSTM'nin test edilen mimarileri.

		LSTM & Bi-LSTM			
		LSTM Katman sayısı			
Model Numarası		1	2	3	4
1	LSTM Katmandaki hücre sayısı	10	-	-	-
2		25	-	-	-
3		50	-	-	-
4		75	-	-	-
5		100	-	-	-
6		25	25	-	-
7		25	50	-	-
8		50	25	-	-
9		50	100	-	-
10		100	50	-	-
11		100	100	-	-
12		10	10	10	-
13		25	25	25	-
14		50	75	100	-
15		100	75	50	-
16		50	100	50	-

Bu çalışmada, test edilen hibrit modeller iki gruba ayrılmıştır. Birinci grupta en iyi performanslı standart modellerin mimarilerinden oluşturulan hibrit modeller bulunmakta, ikinci grupta ise birinci grupta meydana gelen aşırı öğrenme azaltmak için yeni geliştirilen hibrit modeller bulunmaktadır.

4.3. K-katlamalı Çapraz Doğrulama Bulguları

Araştırmada, her tür derin öğrenme sinir ağının tüm modelleri K-katlamalı yöntemi ile test edilmiştir. Test sonucunda çıkan verileri kolay inceleyebilmek için her derin öğrenme türü modellerinin sonuçları ayrı ısı haritası olarak özetlenmiştir. Ek olarak, ETo tahmin etmek için hazırlanan veri kombinasyonları kabiliyeti ve doğruluğu ve derin öğrenme aynı sinir ağ türündeki modellerin performansındaki değişikliğin kapsamı kutu grafiği olarak gösterilmiştir. Ayrıca, Çizelge 4.5'de oluşturulan veri kombinasyonlarının


performansı, MSE istatistik yöntemi göre elde edilen sonuçlardan ETo tahmin etme kabiliyetine göre 5 kategoride sınıflandırılmıştır (Barnston, A., 1992).

Çizelge 4.5. ETo tahmininde veri kombinasyonları performansının sınıflandırılması

Sınıflandırmalar	MSE değeri
Çok iyi	$MSE < 0,004$
İyi	$0,004 \leq MSE \leq 0,007$
Orta	$0,007 \leq MSE \leq 0,011$
Kötü	$0,015 \leq MSE \leq 0,02$
Çok kötü	$MSE \geq 0,02$

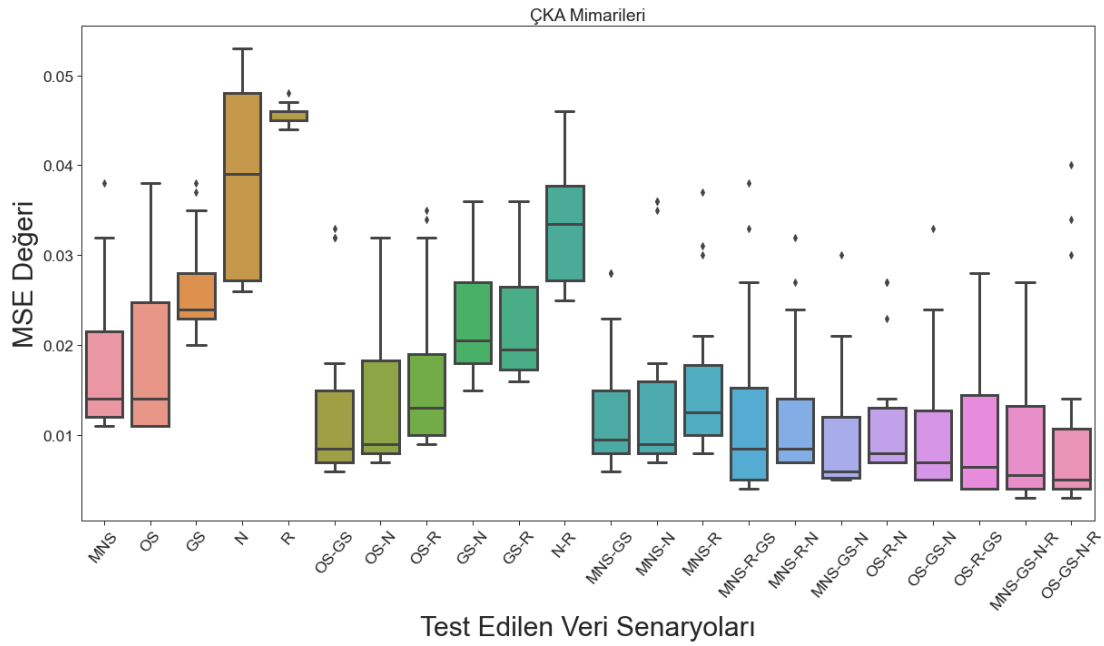
4.3.1. ÇKA modellerinin performansı

ÇKA modelleri ile ilgili K-katlamalı sonuçları ısı haritası ve Kutu grafiği sırasıyla Şekil 4.5 ve Şekil 4.6'da detaylı olarak gösterilmiştir. ÇKA ısı haritasına göre iki katmandan oluşan 1.'den 5.'ye kadar olan modeller, en düşük performanslıdır. Ayrıca, 6.'dan 10.'ya kadar olan üç katmanlı modellerin performansı, iki katmanlı modellerin performansına yaklaşık bulunmuştur. En iyi performans gösteren modeller, dört katmanlı modellerdir. Dört katmanlı modelleri birbirleriyle karşılaştırırken, model katmanının nöron sayısını arttırarak performansları sabit olarak değerlendirilmiştir. En iyi ÇKA modeli mimarisi, tüm senaryolarda ortalama performansa göre 17. model bulunmuştur. ÇKA modelleri Kutu grafiği ve ısı haritasına göre modellerin ortalama performansı (MSE ortalaması olarak), test edilen veri kombinasyonlarında yaklaşık eşittir. Bundan dolayı, ETo değerini doğru bir şekilde tahmin etmek için yeterli parametrelili veri kombinasyonları bulunmasına rağmen iki katmanlı gibi modellerin performansının zayıf olduğu kolayca fark edilebilmektedir. Bu sonuç, ÇKA modellerle yüksek doğrulukla ETo tahmin etmek için bu tür modellerin yapısının derin olması ve geliştirilmesi gerektiği anlamına gelmektedir.



K-kat Yöntemi ile Test Edilen ÇKA Mimarileri

Şekil 4.5. ÇKA modellerin ısı haritası.



Şekil 4.6. ÇKA modellerin Kutu grafiği.

4.3.2. ÇKA modellerinde oluşturulan veri senaryolarının performansı

Veri kombinasyonları, ETo tahmin performansına göre Çizelge 4.6'da sıralanmıştır. ÇKA modellerin ETo tahmin etmede performansı, model eğitimi ve testinde kullanılan veri kombinasyonuna göre değişiklik göstermiştir. Genel olarak, ÇKA modelleri, 2'den fazla meteoroloji parametrelerinden sıcaklık parametresinin dahil olduğu kombinasyonları kullanırken, ETo tahmin etmede en iyi performansı elde edebilmektedir. İkili ve tek bir meteoroloji parametresinden oluşan kombinasyonlarda ise düşük performans elde edebilmektedir. Fakat içinde maksimum-minimum sıcaklık ya da ortalama sıcaklık içeren veri kombinasyonları, içermeyenlere göre daha iyi performanslıdır.

Çizelge 4.6. ÇKA veri kombinasyonlarının tahmin performansına göre sırası

ETo Senaryoları	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma
MNS + GS + R + N	0,027	0,003	88,89	Çok iyi
OS + GS + R + N	0,04	0,003	92,5	Çok iyi
MNS + GS + R	0,038	0,004	89,47	Çok iyi
OS + GS + R	0,028	0,004	85,71	Çok iyi
MNS + GS + N	0,03	0,005	83,33	İyi
OS + GS + N	0,033	0,005	84,85	İyi
OS + GS	0,033	0,006	81,82	İyi
MNS + GS	0,028	0,006	78,57	İyi
OS + N	0,032	0,007	78,13	Orta
MNS + N	0,036	0,007	80,56	Orta
MNS + R + N	0,032	0,007	78,13	Orta
OS + R + N	0,027	0,007	74,07	Orta
MNS + R	0,037	0,008	78,38	Orta
OS + R	0,035	0,009	74,29	Orta
MNS	0,038	0,011	71,05	Orta
OS	0,038	0,011	71,05	Orta
GS + N	0,036	0,015	58,33	Kötü
GS + R	0,036	0,016	55,56	Kötü
GS	0,038	0,02	47,37	Çok kötü
N + R	0,046	0,025	45,65	Çok kötü
N	0,053	0,026	50,94	Çok kötü
R	0,048	0,044	8,33	Çok kötü

¹Elde edilen en yüksek MSE, ²Elde edilen en düşük MSE değeri

4.3.3. ÇKA için kombinasyon parametrelerinin ETo tahmin performansına etkisi

ÇKA modellerin performansını ve oluşturulan veri kombinasyonları arasındaki ilişkileri daha iyi anlayabilmek için aynı sayıda meteoroloji parametrelerinden oluşan benzer veri kombinasyonları birbiriyle Çizelge 4.7'de karşılaştırılmıştır. Tek parametreden oluşan

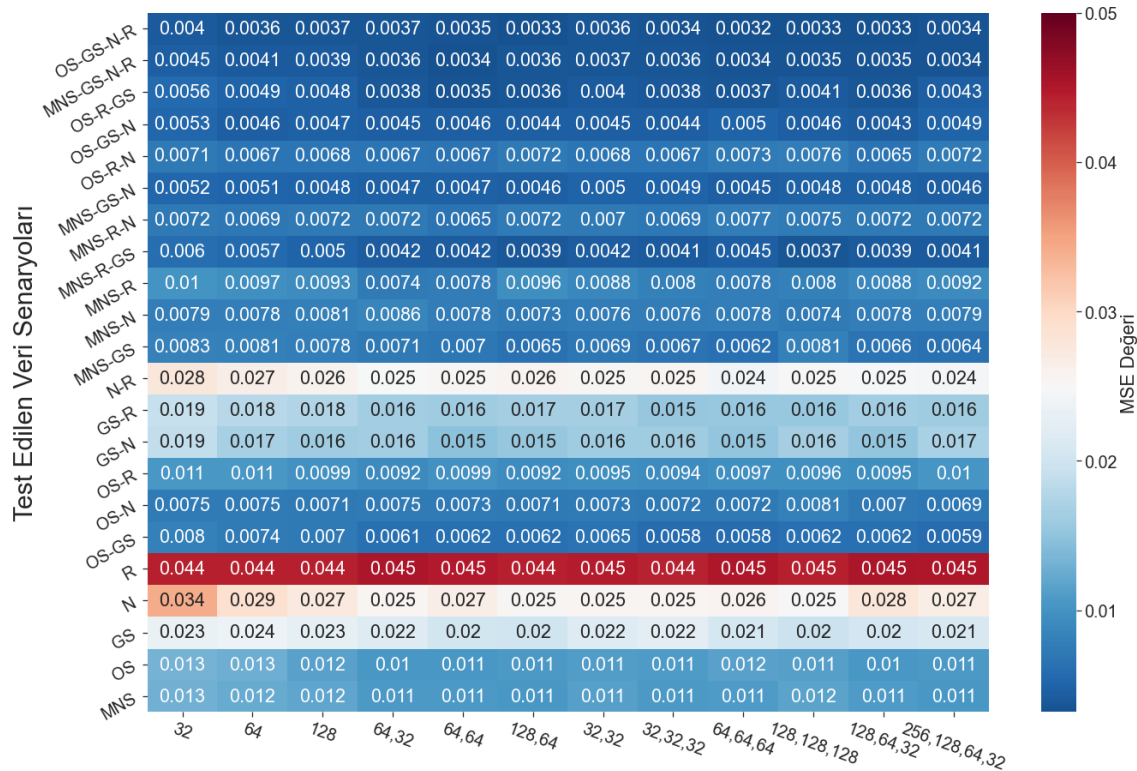
kombinasyonların performansı incelediğinde, sadece sıcaklık parametresinden oluşan kombinasyonların performansı orta düzeyde kabul edilebilir olmuş, diğer meteoroloji parametreleri tek başına sıcaklık parametresi olmadan ETo tahmin etmede çok düşük performanslı olduğundan kabul edilebilir olmamıştır. İki parametreden oluşan veri kombinasyonlarına bakıldığında, iki parametreden oluşmasına rağmen sıcaklık parametresi dahil olmayan kombinasyonların performansı düşüktür. Diğer açıdan, sıcaklık parametresinden oluşan kombinasyonlara ikinci parametre olarak güneş süresi girdiğinde, kombinasyonun performansını arttırmış ve ETo tahmin edilmesinde daha kabul edilebilir olmuştur. Bundan dolayı, az parametreden oluşan kombinasyonla kabul edilebilirliği yüksek ETo tahmin etmek için sıcaklık ve güneş süresi parametrelerinden oluşan kombinasyon öne çıkmıştır. Ek olarak, sıcaklık ve güneş süresi parametrelerine nispi nem yerine rüzgar hızı eklendiğinde kombinasyonun performansını arttırmıştır.

Çizelge 4.7. Veri kombinasyonlarının, bileşenlerine ve performanslarına göre sırası

Veri Senaryoları	MSE	ETo Tahminde
Dört Parametrelili Veri Kombinasyonlar		
MNS+ GS + R + N	0,003	Çok iyi
OS + GS + R + N	0,003	Çok iyi
Üç Parametrelili Veri Kombinasyonlar		
MNS+ GS + R	0,004	Çok iyi
OS + GS + R	0,004	Çok iyi
MNS+ GS + N	0,005	İyi
OS + GS + N	0,005	İyi
MNS+ R + N	0,007	Orta
OS + R + N	0,007	Orta
İki Parametrelili Veri Kombinasyonlar		
OS + GS	0,006	İyi
MNS+ GS	0,006	İyi
OS + N	0,007	Orta
MNS+ N	0,007	Orta
MNS+ R	0,008	Orta
OS + R	0,009	Orta
GS + N	0,015	Kötü
GS + R	0,016	Kötü
N + R	0,025	Çok kötü
Bir Parametrelili Veri Kombinasyonlar		
MNS	0,011	Orta
OS	0,011	Orta
GS	0,02	Çok kötü
N	0,026	Çok kötü
R	0,044	Çok kötü


4.3.4. 1D-CNN modellerinin performansı

1D-CNN modelleri ile ilgili K-katlamalı sonuçlarını ısı haritası ve Kutu grafiği sırasıyla Şekil 4.7 ve Şekil 4.8’de detaylı olarak gösterilmiştir. 1D-CNN ısı haritasına göre ilk üç mimari hariç tüm 1D-CNN mimarilerin performansları oluşturulan senaryolarda yaklaşık eşit bulunmuştur. 1D-CNN mimarileri birbirleriyle kıyaslanırken, bir evrişim katmanından oluşan ilk üç modelin performansı diğer modellerin performansından çok düşük değildir. Bu düşüş fark edilmeyebilir ve iki, üç ve dört evrişim katmanlı modellerin arasındaki performansa tamamen eşit olduğu söylenebilir. Sonuç olarak, 1D-CNN mimarileri ETo tahmin performansı katman sayısı veya katmanların içindeki filtre sayısı arttıkça model performansının artmayacağı söylenebilir. Ek olarak, ETo tahmin etmek için sadece iki evrişim katmanından oluşan 1D-CNN modelleriyle kullanılan kombinasyonun maksimum performansına ulaşılabilir. Son olarak, 1D-CNN modellerinin iyi ETo tahmin performansının, modelde girdi olarak kullanılan kombinasyona bağlı olduğu, modelin yapısına bağlı olmadığı söylenebilir. En iyi 1D-CNN modeli mimarisi, tüm veri senaryolarında ortalama performansa göre 6. model bulunmuştur.



K-kat Yöntemi ile Test Edilen 1D-CNN Mimarileri (çekirdek boyutu = 2)


Şekil 4.7. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 2)



Şekil 4.8. 1D-CNN modellerinin Kutu grafiği


4.3.5. Farklı çekirdek boyutu olduğunda 1D-CNN modellerinin performansı

Gelişim oranı düşük olduğundan yapılan 1D-CNN modeli mimarisini geliştirme çalışmasında, 1D-CNN modeli evrişim katman sayısı ve evrişim katmanındaki filtre sayısı değiştirilerek aynı 1D-CNN modelleri mimarisi farklı çekirdek boyutuyla test edilmiştir. Seçilmiş test edilen çekirdek boyutu, 3, 4 ve 5 olmuştur. 1D-CNN için tasarlanan modellerin yapısı, farklı çekirdek boyutu kullanıldığında aynı sonucu vermiştir (sırasıyla Şekil 4.9, 4.10 ve 4.11). Ayrıca, farklı çekirdek boyutlu 1D-CNN modellerinin ortalama performansları Şekil 12'den izleneceği üzere bütün modeller için eşit olmuştur. Sonuç olarak, 1D-CNN modelinin evrişim katmanındaki çekirdek boyutunun değiştirilmesi modelin performansına yansımamıştır.




K-kat Yöntemi ile Test Edilen 1D-CNN Mimarileri (çekirdek boyutu = 3)

Şekil 4.9. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 3).




K-kat Yöntemi ile Test Edilen 1D-CNN Mimarileri (çekirdek boyutu = 4)

Şekil 4.10. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 4).



K-kat Yöntemi ile Test Edilen 1D-CNN Mimarileri (çekirdek boyutu = 5)

Şekil 4.11. 1D-CNN modellerinin ısı haritası (çekirdek boyutu = 5).



Şekil 4.12. Farklı çekirdek boyutlu 1D-CNN modellerin performansı.

4.3.6. 1D-CNN modellerinde oluşturulan veri senaryolarının performansı

ETo tahmin etmek amacıyla oluşturulan veri kombinasyonları performansı ile ilgili ÇKA modellerinden elde edilen sonuç 1D-CNN modellerinde de elde edilmiştir (Çizelge 4.8). 1D-CNN modelleriyle kabul edilebilir düzeyde ETo tahmini, sıcaklık parametresinin dahil olduğu iki parametrelili kombinasyonlarda elde edilmiştir. Veri kombinasyonlarında

meteorolojik parametre sayısındaki artış, ETo tahminin doğruluğunu arttırmıştır. Sıcaklık, rüzgar hızı ve nispi nem parametrelerinden oluşan kombinasyonlar, 1D-CNN modellerinde daha iyi performans göstermiştir. 1D-CNN modelleri için ETo tahmininde diğer veri kombinasyonlarının performansı, ÇKA modellerinde bulunan performanstan düşük olmasına rağmen genel performans aynı olmuştur.

Çizelge 4.8. 1D-CNN veri kombinasyonlarının tahmin performansına göre sırası

ETo Senaryoları	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma
OS + GS + R + N	0,004	0,0032	19,78	Çok İyi
MNS+ GS + R + N	0,0045	0,0034	24,73	Çok İyi
OS + GS + R	0,0056	0,0035	37,07	Çok İyi
MNS+ GS + R	0,006	0,0037	38,89	Çok İyi
OS + GS + N	0,0053	0,0043	19,17	İyi
MNS+ GS + N	0,0052	0,0045	14	İyi
OS + GS	0,008	0,0058	27,44	İyi
MNS+ GS	0,0083	0,0062	24,64	İyi
MNS+ R + N	0,0077	0,0065	15	İyi
OS + R + N	0,0076	0,0065	14,39	İyi
OS + N	0,0081	0,0069	14,7	Orta
MNS+ N	0,0086	0,0073	14,62	Orta
MNS+ R	0,0101	0,0074	26,07	Orta
OS + R	0,0107	0,0092	13,99	Orta
OS	0,0132	0,0103	21,38	Orta
MNS	0,0129	0,0105	18,32	Orta
GS + N	0,0189	0,0147	21,8	Kötü
GS + R	0,0192	0,0153	19,9	Kötü
GS	0,0236	0,0196	16,89	Çok Kötü
N + R	0,0279	0,0242	13,36	Çok Kötü
N	0,0343	0,0251	26,76	Çok Kötü
R	0,0453	0,0442	2,36	Çok Kötü

¹Elde edilen en yüksek MSE, ²Elde edilen en düşük MSE değeri

4.3.7. 1D-CNN için kombinasyon parametrelerinin ETo tahmin performansına etkisi

1D-CNN için kombinasyon parametrelerinin ETo tahmin performansına etkisi Çizelge 4.9’da verilmiştir. 1D-CNN modellerinden elde edilen sonuç, ÇKA modellerinden elde edilen sonucun doğrulanması şeklinde yorumlanabilir. İyi ve kabul edilebilir ETo tahmini elde edebilmek için kullanılan kombinasyonlar içerisinde sıcaklık parametresinin olması gerektiği söylenebilir. Ek olarak, diğer parametreler, ETo tahmin etmede sıcaklık parametresinin yanına yardımcı parametre olarak gelmektedir. Diğer bir ifadeyle, ETo

tahmin etmede sıcaklık parametresi birincil, diğer parametreler ikincildir. ETo tahmin etmede az sayıda parametreden oluşan en iyi kombinasyon sıcaklık ve güneşlenme süresi parametrelerinden oluşan kombinasyon olmuştur.


Çizelge 4.9. Veri kombinasyonlarının bileşenlerine ve performanslarına göre sırası

Veri Senaryoları	MSE	ETo Tahminde
Dört Parametrelili Veri Kombinasyonlar		
OS + GS + R + N	0,0032	Çok iyi
MNS+ GS + R + N	0,0034	Çok iyi
Üç Parametrelili Veri Kombinasyonlar		
OS + GS + R	0,0035	Çok iyi
MNS+ GS + R	0,0037	Çok iyi
OS + GS + N	0,0043	İyi
MNS+ GS + N	0,0045	İyi
MNS+ R + N	0,0065	İyi
OS + R + N	0,0065	İyi
İki Parametrelili Veri Kombinasyonlar		
OS + GS	0,0058	İyi
MNS+ GS	0,0062	İyi
OS + N	0,0069	Orta
MNS+ N	0,0073	Orta
MNS+ R	0,0074	Orta
OS + R	0,0092	Orta
GS + N	0,0147	Kötü
GS + R	0,0153	Kötü
N + R	0,0242	Çok kötü
Bir Parametrelili Veri Kombinasyonlar		
MNS	0,0105	Orta
OS	0,0103	Orta
GS	0,0196	Çok kötü
N	0,0251	Çok kötü
R	0,0442	Çok kötü


4.3.8. LSTM ve Bi-LSTM modellerinin performansı

LSMT ve Bi-LSTM modelleri, ikisi de tekrarlayan sinir ağı türüne girdikleri için ikisinin sonuçları birlikte anlatılmış ve birbirleriyle karşılaştırılmıştır. LSTM modellerinin sonuçlarının yer aldığı ısı haritası (Şekil 4.13), ETo tahmin etmek amacıyla oluşturulan kombinasyonların tümünde tek bir LSTM katmanından oluşan modellerin zayıf olduğunu

göstermiştir. Ayrıca, LSTM katmanındaki hücre sayısı artışına rağmen yine zayıf bulunmuştur. LSTM modellerinin en yüksek performansı, model katmanlarının sayısı arttırıldığında elde edilmiştir. Ek olarak, Şekil 4.13'den görüleceği üzere, LSTM modeli hem üç katmanlı olduğunda hem de her katmandaki hücre sayısı fazlaca arttırıldığında performansında düşme meydana gelmiştir. Sonuç olarak, ETo tahmininde LSTM modeli kullanıldığında modelin katman sayısı 2'den az olmamalıdır ve Şekil 4.14'te gösterilen Kutu grafiğine göre LSTM modelinde en yüksek performansa ulaşmak için modelin yapısında araştırma ve geliştirme yapılmalıdır.

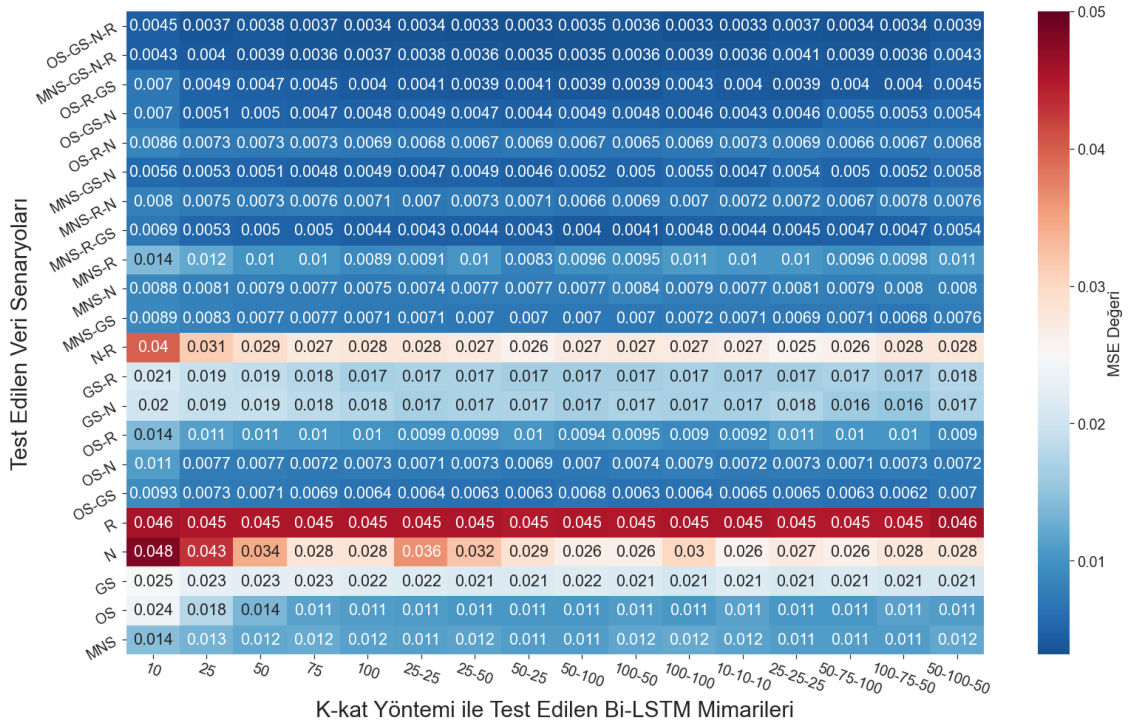


Şekil 4.13. LSTM modelleri ısı haritası




Şekil 4.14. LSTM modelleri Kutu grafiği


Bi-LSTM modelleri ısı haritası (Şekil 4.15) ve Kutu grafiği (Şekil 4.16), LSTM modellerinininkilerle karşılaştırıldığında küçük bir fark olduğu görülmüştür. Her iki türün performansı hakkında daha fazla ayrıntı göstermek için ikisinde oluşturulan senaryolarda ortalama performansın izlenebileceği Şekil 4.17 hazırlanmıştır. Şekilden, LSTM ve Bi-LSTM performanslarının çoğu senaryoda birbirlerine yakın olduğu görülmüş fakat Bi-LSTM bazı senaryolarda LSTM'den daha iyi performans göstermiştir. Sonuç olarak, ETo değerinin tahmin edilmesinde tekrarlayan sinir ağı türüne ait modeller kullanılırken Bi-LSTM diğer türlere göre tercih edilebilir.



Şekil 4.15. Bi-LSTM modelleri ısı haritası.



Şekil 4.16. Bi-LSTM modelleri Kutu grafiği



Şekil 4.17. LSTM ve Bi-LSTM için farklı veri senaryolarındaki performanslar

4.3.9. LSTM ve Bi-LSTM modellerinde oluşturulan veri senaryolarının performansı

LSTM ve Bi-LSTM için ETo tahmin etmek amacıyla oluşturulan kombinasyonların performansları Çizelge 4.10'da verilmiştir. LSTM ve Bi-LSTM modellerinden elde edilen sonuçlar, ÇKA ve 1D-CNN modellerinde bulunan sonuçları doğrular niteliktedir. ETo değerini herhangi bir derin öğrenme modeline göre iyi düzeyde tahmin etmek için model eğitimi ve testinde kullanılan kombinasyonlar içinde sıcaklık parametresi bulunması gerektiği söylenebilir. Ayrıca, kombinasyonlarda meteorolojik parametre sayısı arttıkça, ETo tahmininin doğruluğunun arttığı ispatlanmıştır.

Çizelge 4.10. LSTM ve Bi-LSTM veri kombinasyonlarının tahmin performansına göre sırası

Senaryolar	LSTM				Bi-LSTM			
	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma
MNS	0,02	0,011	45,1	Orta	0,014	0,011	22,92	Orta
OS	0,025	0,01	59,06	Orta	0,024	0,011	56,07	Orta
GS	0,027	0,021	22,56	Çok Kötü	0,025	0,021	17,27	Çok Kötü
N	0,049	0,031	37,09	Çok Kötü	0,048	0,026	46,25	Çok Kötü
R	0,046	0,045	3,02	Çok Kötü	0,046	0,045	2,4	Çok Kötü
OS-GS	0,011	0,006	43,24	İyi	0,009	0,006	33,33	İyi
OS-N	0,02	0,007	65,69	İyi	0,011	0,007	37,84	İyi
OS-R	0,02	0,009	52,04	Orta	0,014	0,009	36,17	Orta
GS-N	0,023	0,017	26,52	Kötü	0,02	0,016	22,39	Kötü
GS-R	0,023	0,017	27,59	Kötü	0,021	0,017	19,9	Kötü
N-R	0,045	0,027	40,18	Çok Kötü	0,04	0,026	36,09	Çok Kötü
MNS-GS	0,01	0,007	32,69	Orta	0,009	0,007	23,6	Orta
MNS-N	0,009	0,008	18,48	Orta	0,009	0,007	15,9*1	Orta
MNS-R	0,014	0,009	35,46	Orta	0,014	0,008	41,13	Orta
MNS-R-GS	0,011	0,004	58,1	Çok İyi	0,007	0,004	42,03	Çok İyi
MNS-R-N	0,019	0,007	64,21	Orta	0,008	0,007	17,5	Orta
MNS-GS-N	0,008	0,005	37,97	İyi	0,006	0,005	20,69	İyi
OS-R-N	0,019	0,007	65,43	Orta	0,009	0,007	24,42	Orta
OS-GS-N	0,006	0,005	25,81	İyi	0,007	0,004	38,57	Çok İyi
OS-R-GS	0,011	0,004	63,96	Çok İyi	0,007	0,004	44,29	Çok İyi
MNS-GS-N-R	0,005	0,004	28,57	Çok İyi	0,004	0,004	18,6	Çok İyi
OS-GS-N-R	0,006	0,003	45	Çok İyi	0,005	0,003	26,67	Çok İyi

¹Elde edilen en yüksek MSE, ²Elde edilen en düşük MSE değeri.

4.3.10. LSTM ve Bi-LSTM için veri kombinasyon parametrelerinin ETo tahmin performansına etkisi

Veri kombinasyonların bileşenlerinin ETo tahmin performansına etkisi ile ilgili olarak, LSTM ve Bi-LSTM modellerinde bulunan sonuçlar, ÇKA ve 1D-CNN modellerinde elde edilen sonuçlardan farklı olmamıştır (Çizelge 4.11).

Çizelge 4.11. Veri kombinasyonlarının bileşenlerine ve performanslarına göre sırası

LSTM			Bi-LSTM		
Veri Senaryoları	MSE	ETo Tahminde	Veri Senaryoları	MSE	ETo Tahminde
Dört Parametrelili Veri Kombinasyonlar					
OS-GS-N-R	0,0033	Çok İyi	OS-GS-N-R	0,0033	Çok İyi
MNS-GS-N-R	0,0035	Çok İyi	MNS-GS-N-R	0,0035	Çok İyi
Üç Parametrelili Veri Kombinasyonlar					
OS-R-GS	0,0040	İyi	OS-R-GS	0,004	İyi
MNS-R-GS	0,0044	İyi	MNS-R-GS	0,0044	İyi
OS-GS-N	0,0046	İyi	OS-GS-N	0,0046	İyi
MNS-GS-N	0,0049	İyi	MNS-GS-N	0,0049	İyi
OS-R-N	0,0065	İyi	OS-R-N	0,0065	İyi
MNS-R-N	0,0068	İyi	MNS-R-N	0,0068	İyi
Bir Parametrelili Veri Kombinasyonlar					
OS-GS	0,0063	İyi	OS-GS	0,0063	İyi
OS-N	0,0070	İyi	OS-N	0,007	İyi
MNS-GS	0,0070	Orta	MNS-GS	0,007	Orta
MNS-N	0,0075	Orta	MNS-N	0,0075	Orta
MNS-R	0,0091	Orta	MNS-R	0,0091	Orta
OS-R	0,0094	Orta	OS-R	0,0094	Orta
GS-R	0,0168	Kötü	GS-R	0,0168	Kötü
GS-N	0,0169	Kötü	GS-N	0,0169	Kötü
N-R	0,0268	Çok Kötü	N-R	0,0268	Çok Kötü
Bir Parametrelili Veri Kombinasyonlar					
OS	0,0104	Orta	OS	0,0104	Orta
MNS	0,0112	Orta	MNS	0,0112	Orta
GS	0,0206	Çok Kötü	GS	0,0206	Çok Kötü
N	0,0307	Çok Kötü	N	0,0307	Çok Kötü
R	0,0450	Çok Kötü	R	0,045	Çok Kötü

4.3.11. Hibrit modellerin performansı

Daha önce belirtildiği gibi hibrit modellerden oluşan 2 grup test edilmiştir. Birinci grup, oluşturulan standart modellerin mimarileri (ÇKA-1D-CNN-LSTM-Bi-LSTM) test edildikten sonra onların her türünde en iyi sonuç veren mimariler birleştirilerek oluşturup test edilmiştir. Birinci grup için oluşturulan modellerin 22 adet mimarisi Çizelge 4.12’de gösterilmiştir. Oluşturulan hibrit modellerin mimarisinde çıktı katmanı sadece tek bir doğrusal aktivasyon fonksiyonlu algılayıcıdan oluşmuştur.

Beklenildiği gibi, birinci grupta aşırı öğrenme olduğundan, birinci grubun hibrit modelleri mimarisindeki katmanların sayısı azaltılarak ikinci grubun hibrit modelleri

oluşturulmuştur. İkinci grup için oluşturulan modellerin 18 adet mimarisi Çizelge 4.13'te temsil edilmiştir. Yeni hibrit modellerin mimarisinde çıktı katmanı yine sadece tek bir doğrusal aktivasyon fonksiyonlu algılayıcıdan oluşmuştur.

Çizelge 4.12. Birinci grup test edilen hibrit modellerin gizli katmanları


Hibrit Mimarilerin Katmanları													
Mimari Numarası	Evrişim Katmanı sayısı			LSTM Katmanı sayısı			ÇKA Katmanı sayısı						
	1	2	3	1	2	3	1	2	3	4			
1		128	64	-		10	10	10		20	10	20	10
2		64	32	-		50	75	100		20	10	20	10
3		128	128	128		100	100	-		50	50	50	50
4		128	128	128		100	75	50		20	20	20	20
5	Evrişim Katmanındaki Filtre sayısı	32	32	32	LSTM Katmanındaki Hücre sayısı	50	100	-	Gizli Katmanındaki algılayıcı sayısı	100	100	100	100
6		64	64	64		25	25	25		20	20	20	20
7		128	64	32		100	75	50		20	10	20	10
8		64	64	-		25	25	25		100	100	100	100
9		32	32	32		50	25	-		50	50	50	50
10		64	64	-		100	50	-		100	100	100	100
11		64	64	64		10	10	10		20	20	20	-
12		64	64	64		50	100	-		50	50	50	50
13		128	64	-		25	50	-		20	10	20	10
14		128	128	128		100	50	-		20	20	20	20
15		64	64	-		25	25	25		20	20	20	-
16		64	32	-		10	10	10		20	20	20	20
17		64	64	64		50	50	-		50	50	50	50
18		64	64	64		100	50	-		50	50	50	50
19		128	64	32		50	25	-		20	10	20	10
20		64	64	-		50	25	-		20	10	20	10
21		128	64	32		100	50	-		20	10	20	10
22		128	64	-		25	50	-		100	100	100	100

Çizelge 4.13. İkinci grup test edilen hibrit modellerin gizli katmanları

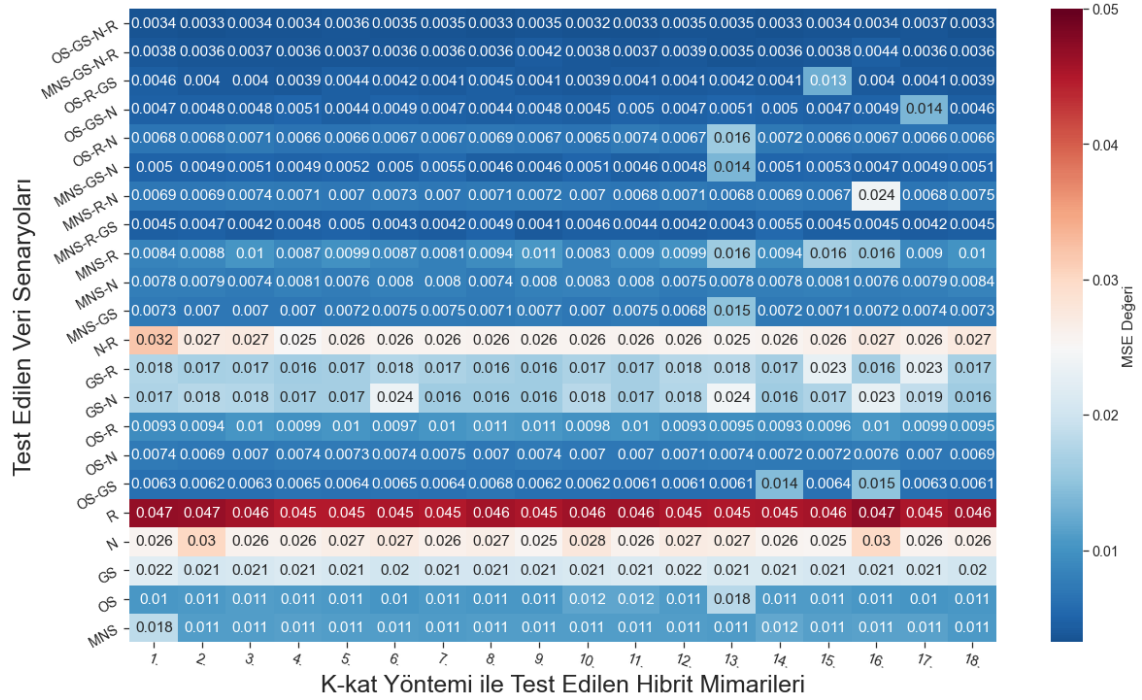
Hibrit Mimarilerin Katmanları									
Model Numarası	Evrışim		LSTM			ÇKA			
	Katmanı sayısı		Katmanı sayısı			Katman sayısı			
		1	1	2		1	2	3	
1	Evrışim Katmanındaki Filtre sayısı	128	LSTM Katmanındaki Hücre sayısı	20	Gizli Katmanındaki algılayıcı sayısı	10	10	10	
2		64		20		20	10	10	10
3		32		20		20	10	10	10
4		128		40		40	20	20	20
5		64		40		40	20	20	20
6		32		40		40	20	20	20
7		128		60		60	30	30	30
8		64		60		60	30	30	30
9		32		60		60	30	30	30
10		128		20		20	20	20	20
11		64		20		20	20	20	20
12		32		20		20	20	20	20
13		128		40		40	10	10	10
14		64		40		40	10	10	10
15		32		40		40	10	10	10
16		128		60		60	10	10	10
17		64		60		60	10	10	10
18		32		60		60	10	10	10

1. ve 2. Grup hibrit modellerin ısı haritaları sırasıyla Şekil 4.18 ve Şekil 4.19’da gösterilirken, Kutu grafikleri sırasıyla Şekil 4.20 ve Şekil 4.21’de verilmiştir.


ETo değerini tahmin etmede en iyi performanslı modeller elde etmek için test edilen standart modellerin mimarileri birleştirilerek yeni hibrit model oluşturma yönteminin, 1. grup modellerin sonuçlarına göre iyi bir yöntem olmadığı söylenebilir. Ayrıca, 2. grubun hibrit modelleri için hazırlanan Kutu grafiği incelendiğinde, 2. grubun hibrit modellerinde aşırı öğrenme fazla olduğundan 4 meteorolojik parametreden oluşan kombinasyon modeli eğitim ve test için kullanılmasına rağmen bazı hibrit modellerin mimarisi kötü bir ETo tahmini geliştirmiştir. Sonuç olarak, 1. grubun hibrit modellerinin mimarilerindeki gibi ETo tahmininde en yüksek verimliliği elde edebilmek için hibrit modelin mimarisini iyileştirme, geliştirme ve araştırmada daha uzun zaman harcanmalıdır. Bununla birlikte, hibrit modellerin hiperparametreleri diğer standart modellerin hiperparametrelerinden daha fazla olduğundan genel olarak hibrit modellerin hiperparametrelerini düzenlemek çok zordur.




Şekil 4.18. 1. Grup hibrit modellerin ısı haritası



Şekil 4.19. 2. Grup hibrit modellerin ısı haritası.




Şekil 4.20. 1. Grup hibrit modellerin Kutu grafiği



Şekil 4.21. 2. Grup hibrit modellerin Kutu grafiği.

Birinci grubun hibrit modellerinde olduğu gibi sorunu aşabilmek için ikinci grubun hibrit modelleri mimarileri az katmanlı oluşturulmuştur. Yani, ikinci grubun hibrit modelleri mimarileri, en fazla tek bir evrişim katmanlı, iki LSTM katmanlı ve üç ÇKA katmanından oluşmuştur. Geliştirilen yeni hibrit modellerin tüm kombinasyonlarında elde edilen

ortalama performans, birinci grubun hibrit modelleri ortalama performansından daha iyi olmuştur (Şekil 4.22). Ek olarak, aşırı öğrenme yeni modellerde azaldığında yine modellerin kombinasyon kullanma performansı ETo tahmininde artmıştır.



Şekil 4.22. 1.Grubun ve 2. grubun hibrit modelleri arasında performans karşılaştırması

4.3.12. Hibrit modellerde oluşturulan veri senaryolarının performansı

ETo tahmin etmek amacıyla oluşturulan kombinasyonların performanslarıyla ilgili olarak, hibrit modellerinden elde edilen sonucun (Çizelge 4.14), diğer model tiplerinde bulunan sonuçları doğruladığı söylenebilir. ETo değerini herhangi bir derin öğrenme modeline göre iyi düzeyde tahmin etmek için, model eğitimi ve testinde kullanılan kombinasyonlarda sıcaklık parametresinin bulunması gerektiği ve meteorolojik parametre sayısı arttıkça ETo tahmin doğruluğunun arttığı söylenebilir.

Çizelge 4.14. Hibrit modeller veri kombinasyonlarının tahmin performansına göre sırası

1. Gurubun hibirt modelleri					2. Grurubun hibirt modelleri			
Senaryolar	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma	Yüksek ¹	Düşük ²	İyileşme oranı (%)	Sınıflandırma
MNS	0,0188	0,0108	42,48	Orta	0,0184	0,0108	41,2	Orta
OS	0,012	0,0104	12,79	Orta	0,0181	0,0102	43,5	Orta
GS	0,0322	0,0202	37,36	Çok Kötü	0,0221	0,0203	8,09	Çok Kötü
N	0,0299	0,0249	16,65	Çok Kötü	0,0302	0,0254	16,05	Çok Kötü
R	0,0465	0,0427	8,16	Çok Kötü	0,0472	0,0447	5,44	Çok Kötü
OS-GS	0,0149	0,006	59,73	İyi	0,015	0,0061	59,75	İyi
OS-N	0,0233	0,0069	70,25	Orta	0,0076	0,0069	9,03	İyi
OS-R	0,0121	0,0087	28,26	Orta	0,0108	0,0093	13,91	Orta
GS-N	0,0252	0,0153	39,39	Kötü	0,0242	0,016	34,01	Kötü
GS-R	0,0249	0,0159	36,06	Kötü	0,023	0,0161	29,98	Kötü
N-R	0,0327	0,0251	23,16	Çok Kötü	0,032	0,025	22,11	Çok Kötü
MNS-GS	0,0149	0,0067	54,98	Orta	0,0149	0,0068	54,49	Orta
MNS-N	0,0236	0,0074	68,51	Orta	0,0084	0,0074	12,6	Orta
MNS-R	0,0167	0,0075	55,1	Orta	0,0164	0,0081	50,55	Orta
MNS-R-GS	0,014	0,0039	71,78	Çok İyi	0,0055	0,0041	25,38	İyi
MNS-R-N	0,015	0,0067	55,17	Orta	0,024	0,0067	72	Orta
MNS-GS-N	0,0054	0,0044	18,86	İyi	0,0136	0,0046	66,47	İyi
OS-R-N	0,0148	0,0067	54,88	Orta	0,0159	0,0065	59,16	Orta
OS-GS-N	0,0139	0,0045	67,55	İyi	0,0136	0,0044	67,93	İyi
OS-R-GS	0,0131	0,0037	72,01	Çok İyi	0,0128	0,0039	69,65	Çok İyi
MNS-GS-N-R	0,0122	0,0034	71,86	Çok İyi	0,0044	0,0035	19,8	Çok İyi
OS-GS-N-R	0,0209	0,0033	84,22	Çok İyi	0,0037	0,0032	12,28	Çok İyi

¹Elde edilen en yüksek MSE, ²Elde edilen en düşük MSE değeri.

4.3.13. Hibrit modeller için kombinasyon parametrelerinin ETo tahmin performansına etkisi


Veri kombinasyonları bileşenlerinin ETo tahmin performansına etkisi ile ilgili olarak, Hibirt modellerinde elde edilen sonuçların, diğer model tiplerinde bulunan sonuçlardan herhangi bir farkının olmadığı söylenebilir (Çizelge 4.15).

Çizelge 4.15. Veri kombinasyonlarının, bileşenlerine ve performanslarına göre sırası

1.Grup Hibrit			2.Grup Hibrit		
Veri Senaryoları	MSE	ETo Tahminde	Veri Senaryoları	MSE	ETo Tahminde
Dört Parametrelili Veri Kombinasyonlar					
OS-GS-N-R	0,0033	Çok İyi	OS-GS-N-R	0,0032	Çok İyi
MNS-GS-N-R	0,0034	Çok İyi	MNS-GS-N-R	0,0035	Çok İyi
Üç Parametrelili Veri Kombinasyonlar					
OS-R-GS	0,0037	Çok İyi	OS-R-GS	0,0039	Çok İyi
MNS-R-GS	0,0039	Çok İyi	MNS-R-GS	0,0041	İyi
OS-GS-N	0,0045	İyi	OS-GS-N	0,0044	İyi
MNS-GS-N	0,0044	İyi	MNS-GS-N	0,0046	İyi
MNS-R-N	0,0067	Orta	MNS-R-N	0,0067	Orta
OS-R-N	0,0067	Orta	OS-R-N	0,0065	Orta
İki Parametrelili Veri Kombinasyonlar					
OS-GS	0,0060	İyi	OS-GS	0,0061	İyi
MNS-GS	0,0067	Orta	MNS-GS	0,0068	Orta
OS-N	0,0069	Orta	OS-N	0,0069	İyi
MNS-N	0,0074	Orta	MNS-N	0,0074	Orta
MNS-R	0,0075	Orta	MNS-R	0,0081	Orta
OS-R	0,0087	Orta	OS-R	0,0093	Orta
GS-N	0,0153	Kötü	GS-N	0,0160	Kötü
GS-R	0,0159	Kötü	GS-R	0,0161	Kötü
N-R	0,0251	Çok Kötü	N-R	0,0250	Çok Kötü
Bir Parametrelili Veri Kombinasyonlar					
OS	0,0104	Orta	OS	0,0102	Orta
MNS	0,0108	Orta	MNS	0,0108	Orta
GS	0,0202	Çok Kötü	GS	0,0203	Çok Kötü
N	0,0249	Çok Kötü	N	0,0254	Çok Kötü
R	0,0427	Çok Kötü	R	0,0447	Çok Kötü

4.4. Derin Öğrenme Modelleri Performanslarının Karşılaştırılması

Derin öğrenme model türlerinin tamamı için, kurulan mimarilerin tümü K-katlamalı yöntemiyle test edilmiştir. En doğru ETo değerini tahmin etmede hangi derin öğrenme modelinin öne çıktığını belirlemek için, bu çalışmada tüm oluşturulan ÇKA, 1D-CNN, LSTM, Bi-LSTM ve Hibrit modellerin tüm mimarileri ve tüm test edilen kombinasyonlarda performans sonuçları Şekil 4.23'te özetlenmiştir.



Şekil 4.23. Çalışmada ele alınan derin öğrenme model tipleri arasında performans karşılaştırması

Şekil 4.23 incelendiğinde, test edilen tüm kombinasyonlarda en iyi standart model tipi 1D-CNN olarak belirlenmiştir. 1D-CNN modelleri diğer modellere göre basit mimarisiyle en yüksek ETo tahmin doğruluğu vermiştir. K-katlamalı yönteminin sonuçlarına göre, LSTM ve Bi-LSTM arasındaki performans farkının küçük olduğu söylenebilir. Ayrıca Bi-LSTM ETo tahmin etmede LSTM yerine tercih edilebilir. Diğer yandan sonuçlara göre, ÇKA modellerinin, bütün diğer model tiplerinden performans bakımından zayıf olduğu belirlenmiştir. Hibrit modellerin ise, elde edilen sonuçlara göre, eğer model mimarileri optimum hale getirilebilirse, ETo tahmin etmede tüm standart modellerden daha iyi performans gösterebilecekleri belirlenmiştir.

Ferreira ve da Cunha (2020), çalışmalarında ETo tahmin etmede derin öğrenme yöntemleri CNN ve CNN-LSTM (Hibrit) kullanımının düşük performans gösterdiğini belirlemişler ve bu derin öğrenme yöntemlerini ETo tahmin etmek için önermemişlerdir. Fakat onlar çalışmalarında, bu çalışmanın aksine haftalık ETo tahmin etmeye odaklanmışlardır. Yin ve ark. (2020), çalışmalarında ETo tahmin etmede CNN yönteminin başarılı olduğu sonucuna varmışlardır. Yukarıdaki çalışmada elde edilen sonuç, bu çalışmada elde edilen sonuçla paralellik göstermiştir.

4.5. Kombinasyon Parametrelerinin ETo Tahmin Performansına Etkisinin Karşılaştırılması

Çalışmada, derin öğrenme yöntemlerinde beş meteorolojik parametreden oluşturulan 22 veri kombinasyonunun ETo tahmin performansına etkisi belirlenmiştir. Genel olarak, tüm derin öğrenme mimarilerinde, ETo tahmin etmede en iyi performans 2'den fazla meteoroloji parametrelerinde sıcaklık parametresinin dahil olduğu kombinasyonlar kullanıldığında elde edebilmiştir. İkili ve tek bir meteoroloji parametresinden oluşan kombinasyonlarda ise düşük performans elde edilmiştir. Fakat içinde maksimum-minimum sıcaklık ya da ortalama sıcaklık içeren veri kombinasyonları, içermeyenlere göre daha iyi performanslıdır.

Tek parametreden oluşan kombinasyonların performansı ile ilgili olarak, sadece sıcaklık parametresinden oluşan kombinasyonların performansı orta düzeyde kabul edilebilir olmuş, diğer meteoroloji parametreleri tek başına ETo tahmin etmede çok düşük performanslı olduğundan kabul edilebilir olmamıştır. Diğer bir ifadeyle, ortalama rüzgar hızı, ortalama nispi nem ve ortalama güneş süresi parametrelerinin tek başına ETo tahmin edemediği söylenebilir. Ayrıca ETo tahmin etmede ortalama sıcaklık, maksimum-minimum sıcaklıktan daha iyi performans göstermiştir.

İki parametreden oluşan veri kombinasyonlarının ETo tahmin etmede performansı, iki parametreden oluşmasına rağmen sıcaklık parametresi dahil olmayan kombinasyonlara göre performansı düşüktür. Diğer açıdan, sıcaklık parametresinden oluşan kombinasyonlara ikinci parametre olarak güneş süresi girdiğinde, kombinasyonun performansını arttırmış ve ETo tahmin edilmesinde daha kabul edilebilir olmuştur. Ek olarak, diğer parametreler, ETo tahmin etmede sıcaklık parametresinin yanına yardımcı parametre olarak gelebilir. Diğer bir ifadeyle, ETo tahmin etmede sıcaklık parametresi birincildir, diğer parametreler ikincildir. Ayrıca, az parametreden oluşan kombinasyonla kabul edilebilirliği yüksek ETo tahmin etmek için sıcaklık ve güneş süresi parametrelerinden oluşan kombinasyon öne çıkmıştır. ETo tahmin etmede az sayıda parametreden oluşan en iyi kombinasyon sıcaklık ve güneşlenme süresi parametrelerinden oluşan kombinasyon olmuştur. Yin ve ark. (2020), çalışmalarında geliştirilen hibrit Bi-LSTM mimariyle aynı sonucu bulmuşlardır. Ek olarak, sıcaklık ve

güneş süresi parametrelerine nispi nem yerine rüzgâr hızı eklendiğinde kombinasyonun performansını arttırmıştır. Son olarak, elde edilen sonuçlara göre üç veya dörtten fazla meteorolojik parametreden oluşan veri kombinasyonları, günlük ETo tahmin etmede yüksek performans göstermiştir. Tekrar veri kombinasyonlarının performansı optimizasyon kısmında test edilmiştir.

4.6. Optimizasyon Bulguları

K-katlamalı yönteminin sonuçları ve modellerin ETo tahmin performansına göre optimizasyon alan modeller, her oluşturulan model türünden beş model seçilerek belirlenmiştir. Bu modeller, ETo tahmin etmede en iyi performans ve aşırı öğrenme derecesi düşük mimariye göre seçilmiştir (Çizelge 4.16, 4.17, 4.18, 4.19, 4.20 ve 4.21). Çizelgelerde kırmızı ile işaretlenen modeller eğitimde kullanılan veriler ile tahmin verimliliği arasındaki ilişki belirtilirken kullanılmıştır. Optimizasyon aşamasında seçilen modeller için optimum öğrenme oranı Keras kütüphanesinin Öğrenme Oranı Planlayıcı (Learning Rate Scheduler) özelliği kullanılarak bulunmuştur. Bütün modellerin en iyi öğrenme oranı 0,001 olarak belirlenmiştir. Ek olarak, eğitim sayısı 200 olmuş ve öğrenme algoritması olarak Adam kullanılmıştır. Ayrıca, modellerin optimizasyon işleminde Grup Boyutu (Batch Size) 256 seçilmiş ve optimizasyonlarda aynı hiperparametreler ele alınmıştır. Fakat modellerin performansını arttırmak için sinir ağı yapısıyla ilgili Relu yerine Swish aktivasyon fonksiyonu test edilmiştir (Çizelge 4.22). Optimizasyon sürecinde, veriler karıştırılmış durum ve karıştırılmamış durum olmak üzere iki durumda test edilmiştir.

Çizelge 4.16. ÇKA ile ilgili seçilmiş optimize edilen 5 mimari

Mimari Numarası	Gizli Katmanı Sayısı	Gizli Katmanı Sayısı			
		1	2	3	4
1	Nöron sayısı	10	10	10	-
2		20	20	20	-
3		20	10	20	10
4		20	10	10	20
5		20	20	20	20

Çizelge 4.17. 1D-CNN ile ilgili seçilmiş optimize edilen 5 mimari

		Evrşim Katmanı sayısı		
Mimari Numarası		1	2	3
1	Filtre sayısı	128	64	-
2		64	64	-
3		32	32	32
4		64	64	64
5		128	64	32

Çizelge 4.18. LSTM ile ilgili seçilmiş optimize edilen 5 mimari

		LSTM Katmanı sayısı		
Mimari Numarası		1	2	3
1	Hücre sayısı	100	50	-
2		25	25	25
3		100	75	50
4*		50	50	50
5*		60	60	60

*Oluşturulan modellerden seçilmemiş, K-katlamalı yöntemi işlemine girmemiştir

Çizelge 4.19. Bi-LSTM ile ilgili seçilmiş optimize edilen 5 mimari

		LSTM Katmanı sayısı		
Mimari Numarası		1	2	3
1	Hücre sayısı	50	25	-
2		50	100	-
3		100	50	-
4		50	75	100
5		10	10	10

Çizelge 4.20. Optimizasyon için Hibrit modellerden seçilen 5 mimari

Model numarası		Evrişim	LSTM			Algılayıcı			
		Katmanı sayısı	Katmanı sayısı			Katmanı sayısı			
		1	1	2		1	2	3	
1	Filtre sayısı	128	Hücre sayısı	60	Nöron sayısı	30	30	30	
2		64		60		60	30	30	30
3		32		60		60	30	30	30
4		128		40		40	20	20	20
5		64		40		40	20	20	20

Çizelge 4.21 Optimizasyon için seçilen hiperparametre

Kullanım yeri	Hiperparametre	Seçilen
Sinir ağı yapısı	Aktivasyon fonksiyonu	Relu yerine Swish
	Öğrenme oranı	0,001
Eğitim algoritması	Eğitim Sayısı	200
	Optimizasyon algoritması	Adam
	Grup Boyutu (Batch Size)	256

4.6.1. Veri Durumuna Göre Bulgular

Optimizasyon amacıyla seçilen tüm modeller, her veri kombinasyonu için test edilmiştir. Ayrıca, her veri kombinasyonu için karıştırılmış ve karıştırılmamış durumun ikisinde de modellerin performansı ve hangisinin daha iyi performans verdiği belirtilmiştir.

ETo tahmin etmede karıştırılmamış veri kombinasyonlarıyla eğitilen modellerin sonuçları sırasıyla Çizelge 4.22, 4.23, 4.24, 4.25 ve 4.26'da verilmiş ve sonuçlar toplu olarak Çizelge 4.27'de özetlenmiştir. Şekil 4.24'de de her bir veri kombinasyonu ile eğitilen derin öğrenme modellerinden elde edilen en iyi ETo tahmini gerçek ETo ile kıyaslanmıştır. Sonuç olarak, derin öğrenme mimarisi bakımından, ETo tahmininde tekrarlayan sinir ağlarına ait LSTM ve Bi-LSTM mimarileri, diğer mimarilerden çoğu

veri kombinasyonu ile daha iyi bir performansı göstermiş fakat fark küçük bulunmuştur. Veri kombinasyonları bakımından ise, optimizasyonda elde edilen sonuçlar önceki K-katlamalı yönteminde ortaya çıkan sonuçları destekler nitelikte olmuş, ayrıca genel olarak optimizasyonda bütün veri kombinasyonları daha iyi bir performans göstermişlerdir.

Çizelge 4.22. Karıştırılmamış veri kombinasyonlarıyla eğitilen ÇKA modellerin bulguları

Senaryolar	ÇKA Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,108	0,086	0,754	0,106	0,083	0,763	0,107	0,084	0,76	0,104	0,082	0,770	0,107	0,084	0,759
OS	0,104	0,083	0,771	0,107	0,086	0,757	0,104	0,083	0,771	0,105	0,084	0,766	0,106	0,084	0,765
GS	0,157	0,127	0,477	0,155	0,124	0,494	0,156	0,126	0,489	0,157	0,126	0,478	0,156	0,125	0,487
N	0,157	0,124	0,477	0,153	0,122	0,507	0,152	0,123	0,512	0,154	0,122	0,497	0,153	0,122	0,506
R	0,218	0,185	-0,002	0,208	0,177	0,084	0,210	0,178	0,072	0,208	0,176	0,090	0,211	0,180	0,061
OS-GS	0,077	0,06	0,874	0,079	0,06	0,868	0,078	0,060	0,871	0,076	0,059	0,877	0,076	0,059	0,878
OS-N	0,084	0,065	0,851	0,083	0,065	0,854	0,083	0,065	0,854	0,083	0,065	0,855	0,083	0,065	0,854
OS-R	0,099	0,08	0,795	0,098	0,079	0,797	0,101	0,081	0,785	0,103	0,083	0,777	0,099	0,079	0,793
GS-N	0,130	0,105	0,644	0,134	0,106	0,619	0,129	0,104	0,647	0,134	0,106	0,622	0,135	0,107	0,618
GS-R	0,134	0,108	0,623	0,134	0,107	0,623	0,133	0,107	0,627	0,134	0,109	0,620	0,135	0,109	0,614
N-R	0,156	0,121	0,488	0,159	0,121	0,469	0,153	0,119	0,509	0,158	0,120	0,473	0,159	0,121	0,466
MNS-GS	0,081	0,062	0,861	0,081	0,062	0,861	0,079	0,061	0,867	0,079	0,061	0,868	0,079	0,06	0,869
MNS-N	0,084	0,065	0,851	0,084	0,065	0,852	0,085	0,067	0,846	0,084	0,065	0,851	0,084	0,065	0,851
MNS-R	0,092	0,074	0,821	0,098	0,079	0,798	0,101	0,081	0,787	0,101	0,081	0,786	0,096	0,077	0,804
MNS-R-GS	0,063	0,050	0,915	0,060	0,047	0,925	0,066	0,052	0,907	0,059	0,048	0,926	0,066	0,052	0,908
MNS-R-N	0,079	0,062	0,869	0,080	0,062	0,866	0,082	0,065	0,858	0,083	0,065	0,854	0,078	0,061	0,872
MNS-GS-N	0,064	0,051	0,914	0,064	0,050	0,913	0,063	0,050	0,916	0,064	0,051	0,913	0,065	0,051	0,912
OS-R-N	0,081	0,063	0,862	0,081	0,063	0,861	0,080	0,061	0,867	0,079	0,062	0,867	0,082	0,064	0,856
OS-GS-N	0,064	0,051	0,913	0,064	0,050	0,913	0,065	0,052	0,910	0,065	0,051	0,912	0,066	0,052	0,908
OS-R-GS	0,059	0,047	0,928	0,061	0,048	0,923	0,059	0,048	0,926	0,057	0,046	0,930	0,060	0,048	0,925
MNS-GS-N-R	0,055	0,045	0,936	0,052	0,042	0,943	0,053	0,043	0,940	0,052	0,041	0,944	0,052	0,042	0,943
OS-GS-N-R	0,051	0,041	0,945	0,051	0,040	0,946	0,050	0,040	0,947	0,053	0,042	0,942	0,050	0,040	0,947

Çizelge 4.23. Karıştırılmamış veri kombinasyonlarıyla eğitilen 1D-CNN modellerin bulguları

Senaryolar	1D-CNN Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,104	0,082	0,773	0,104	0,082	0,773	0,104	0,082	0,770	0,104	0,082	0,774	0,104	0,081	0,774
OS	0,103	0,081	0,777	0,103	0,082	0,774	0,103	0,082	0,775	0,103	0,081	0,778	0,102	0,081	0,779
GS	0,157	0,125	0,482	0,157	0,125	0,479	0,157	0,125	0,480	0,157	0,125	0,479	0,157	0,125	0,481
N	0,158	0,124	0,474	0,157	0,123	0,480	0,157	0,123	0,477	0,158	0,124	0,473	0,158	0,124	0,471
R	0,208	0,176	0,086	0,208	0,176	0,086	0,208	0,176	0,083	0,208	0,176	0,089	0,208	0,176	0,085
OS-GS	0,078	0,059	0,873	0,077	0,059	0,874	0,077	0,059	0,874	0,078	0,060	0,872	0,078	0,059	0,873
OS-N	0,083	0,064	0,855	0,083	0,064	0,854	0,083	0,064	0,854	0,083	0,064	0,854	0,083	0,064	0,854
OS-R	0,096	0,077	0,805	0,096	0,077	0,804	0,097	0,078	0,801	0,096	0,076	0,807	0,096	0,076	0,807
GS-N	0,134	0,105	0,622	0,134	0,106	0,622	0,134	0,106	0,619	0,135	0,105	0,618	0,135	0,105	0,615
GS-R	0,134	0,107	0,620	0,134	0,107	0,621	0,134	0,107	0,619	0,135	0,108	0,617	0,134	0,108	0,619
N-R	0,155	0,119	0,490	0,156	0,119	0,489	0,155	0,118	0,492	0,155	0,118	0,493	0,156	0,119	0,488
MNS-GS	0,081	0,061	0,863	0,081	0,061	0,862	0,081	0,062	0,862	0,080	0,061	0,864	0,080	0,061	0,864
MNS-N	0,084	0,064	0,853	0,084	0,064	0,852	0,084	0,064	0,851	0,084	0,064	0,852	0,084	0,064	0,852
MNS-R	0,094	0,076	0,815	0,094	0,076	0,815	0,093	0,074	0,819	0,093	0,074	0,818	0,093	0,075	0,817
MNS-R-GS	0,060	0,048	0,925	0,059	0,047	0,926	0,060	0,048	0,925	0,061	0,048	0,922	0,059	0,047	0,925
MNS-R-N	0,079	0,062	0,869	0,080	0,063	0,865	0,078	0,061	0,872	0,080	0,063	0,864	0,080	0,063	0,864
MNS-GS-N	0,065	0,051	0,910	0,064	0,050	0,912	0,065	0,051	0,911	0,065	0,05	0,912	0,065	0,051	0,910
OS-R-N	0,077	0,060	0,873	0,077	0,060	0,873	0,077	0,06	0,874	0,077	0,06	0,874	0,078	0,06	0,873
OS-GS-N	0,065	0,051	0,911	0,065	0,051	0,911	0,066	0,052	0,908	0,065	0,051	0,911	0,065	0,051	0,911
OS-R-GS	0,057	0,046	0,930	0,059	0,047	0,927	0,058	0,047	0,930	0,057	0,046	0,932	0,057	0,046	0,931
MNS-GS-N-R	0,054	0,042	0,940	0,054	0,042	0,939	0,052	0,041	0,943	0,053	0,041	0,941	0,052	0,041	0,942
OS-GS-N-R	0,051	0,04	0,946	0,051	0,041	0,945	0,050	0,040	0,946	0,051	0,04	0,945	0,051	0,04	0,944

Çizelge 4.24. Karıştırılmamış veri kombinasyonlarıyla eğitilen LSTM modellerin bulguları

Senaryolar	LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,105	0,083	0,766	0,105	0,083	0,765	0,104	0,082	0,772	0,106	0,083	0,765	0,104	0,082	0,771
OS	0,103	0,082	0,775	0,103	0,082	0,776	0,103	0,082	0,775	0,103	0,082	0,775	0,103	0,082	0,774
GS	0,159	0,127	0,464	0,160	0,129	0,462	0,157	0,125	0,477	0,158	0,126	0,476	0,157	0,126	0,477
N	0,157	0,123	0,482	0,157	0,123	0,483	0,157	0,123	0,483	0,157	0,123	0,477	0,157	0,123	0,480
R	0,208	0,176	0,084	0,208	0,176	0,086	0,208	0,176	0,090	0,208	0,176	0,090	0,208	0,175	0,091
OS-GS	0,076	0,059	0,877	0,076	0,059	0,877	0,078	0,06	0,872	0,077	0,059	0,874	0,077	0,059	0,875
OS-N	0,083	0,064	0,855	0,083	0,064	0,854	0,083	0,064	0,854	0,083	0,064	0,854	0,083	0,064	0,854
OS-R	0,100	0,080	0,791	0,100	0,080	0,789	0,097	0,078	0,800	0,099	0,079	0,792	0,096	0,076	0,806
GS-N	0,133	0,106	0,628	0,133	0,105	0,628	0,133	0,106	0,626	0,134	0,106	0,623	0,133	0,105	0,628
GS-R	0,134	0,107	0,622	0,134	0,108	0,622	0,134	0,108	0,619	0,134	0,107	0,623	0,134	0,107	0,624
N-R	0,156	0,119	0,488	0,155	0,119	0,496	0,157	0,119	0,483	0,156	0,12	0,489	0,156	0,119	0,489
MNS-GS	0,080	0,061	0,865	0,080	0,061	0,864	0,081	0,062	0,862	0,081	0,062	0,862	0,081	0,062	0,862
MNS-N	0,084	0,064	0,852	0,084	0,065	0,852	0,084	0,065	0,852	0,085	0,066	0,846	0,084	0,065	0,852
MNS-R	0,092	0,073	0,821	0,094	0,075	0,813	0,094	0,075	0,813	0,092	0,074	0,821	0,093	0,074	0,817
MNS-R-GS	0,063	0,051	0,915	0,061	0,049	0,921	0,062	0,049	0,919	0,064	0,05	0,915	0,064	0,05	0,915
MNS-R-N	0,079	0,061	0,869	0,080	0,062	0,865	0,078	0,061	0,870	0,079	0,062	0,868	0,079	0,061	0,870
MNS-GS-N	0,067	0,053	0,907	0,065	0,051	0,910	0,066	0,051	0,909	0,067	0,053	0,906	0,066	0,052	0,907
OS-R-N	0,078	0,06	0,870	0,080	0,062	0,865	0,078	0,06	0,873	0,079	0,061	0,868	0,079	0,060	0,869
OS-GS-N	0,066	0,052	0,908	0,066	0,051	0,909	0,065	0,051	0,910	0,066	0,052	0,908	0,066	0,051	0,909
OS-R-GS	0,059	0,047	0,927	0,059	0,047	0,927	0,058	0,047	0,929	0,059	0,047	0,928	0,059	0,047	0,927
MNS-GS-N-R	0,052	0,042	0,942	0,054	0,043	0,938	0,053	0,043	0,940	0,054	0,044	0,938	0,053	0,043	0,940
OS-GS-N-R	0,051	0,041	0,945	0,052	0,042	0,943	0,051	0,040	0,946	0,051	0,041	0,945	0,051	0,041	0,945

Çizelge 4.25. Karıştırılmamış veri kombinasyonlarıyla eğitilen Bi-LSTM modellerin bulguları

Senaryolar	Bi-LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,104	0,081	0,773	0,104	0,081	0,773	0,104	0,082	0,771	0,104	0,082	0,772	0,104	0,082	0,772
OS	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778
GS	0,157	0,125	0,477	0,157	0,125	0,477	0,157	0,124	0,483	0,157	0,124	0,482	0,156	0,125	0,484
N	0,159	0,124	0,467	0,159	0,124	0,467	0,158	0,124	0,471	0,158	0,123	0,474	0,159	0,124	0,469
R	0,208	0,176	0,084	0,208	0,176	0,084	0,208	0,176	0,087	0,208	0,176	0,085	0,208	0,176	0,09
OS-GS	0,077	0,059	0,874	0,077	0,059	0,874	0,077	0,059	0,873	0,077	0,059	0,874	0,078	0,059	0,872
OS-N	0,083	0,064	0,853	0,083	0,064	0,853	0,083	0,064	0,853	0,083	0,064	0,854	0,083	0,064	0,853
OS-R	0,096	0,076	0,806	0,096	0,076	0,806	0,096	0,076	0,807	0,095	0,076	0,808	0,096	0,077	0,805
GS-N	0,135	0,105	0,615	0,135	0,105	0,615	0,134	0,105	0,62	0,134	0,105	0,62	0,133	0,105	0,626
GS-R	0,134	0,108	0,621	0,134	0,108	0,621	0,135	0,107	0,618	0,135	0,108	0,617	0,135	0,108	0,617
N-R	0,157	0,12	0,477	0,157	0,12	0,477	0,158	0,12	0,475	0,157	0,12	0,48	0,157	0,119	0,482
MNS-GS	0,081	0,061	0,861	0,081	0,061	0,861	0,080	0,061	0,864	0,080	0,061	0,864	0,08	0,061	0,865
MNS-N	0,084	0,064	0,852	0,084	0,064	0,852	0,084	0,064	0,852	0,084	0,065	0,852	0,084	0,064	0,852
MNS-R	0,093	0,074	0,817	0,093	0,074	0,817	0,095	0,076	0,809	0,094	0,075	0,813	0,094	0,075	0,813
MNS-R-GS	0,060	0,048	0,925	0,06	0,048	0,925	0,059	0,048	0,926	0,061	0,049	0,922	0,06	0,048	0,924
MNS-R-N	0,079	0,062	0,867	0,079	0,062	0,867	0,081	0,063	0,862	0,079	0,062	0,867	0,079	0,061	0,868
MNS-GS-N	0,067	0,052	0,905	0,067	0,052	0,905	0,066	0,052	0,907	0,067	0,052	0,904	0,066	0,052	0,908
OS-R-N	0,078	0,06	0,871	0,078	0,06	0,871	0,078	0,06	0,871	0,078	0,06	0,87	0,078	0,06	0,872
OS-GS-N	0,066	0,052	0,908	0,066	0,052	0,908	0,066	0,051	0,909	0,066	0,051	0,909	0,066	0,051	0,909
OS-R-GS	0,057	0,046	0,931	0,057	0,046	0,931	0,057	0,046	0,931	0,057	0,046	0,932	0,057	0,046	0,931
MNS-GS-N-R	0,054	0,042	0,939	0,054	0,042	0,939	0,055	0,043	0,937	0,055	0,043	0,937	0,053	0,042	0,940
OS-GS-N-R	0,051	0,041	0,944	0,051	0,041	0,944	0,051	0,041	0,945	0,051	0,041	0,944	0,051	0,041	0,945

Çizelge 4.26. Karıştırılmamış veri kombinasyonlarıyla eğitilen Hibrit modellerin bulguları


Senaryolar	Hibrit Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,104	0,081	0,773	0,104	0,081	0,773	0,104	0,082	0,771	0,104	0,082	0,772	0,104	0,082	0,772
OS	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778	0,103	0,081	0,778
GS	0,157	0,125	0,477	0,157	0,125	0,477	0,157	0,124	0,483	0,157	0,124	0,482	0,156	0,125	0,484
N	0,159	0,124	0,467	0,159	0,124	0,467	0,158	0,124	0,471	0,158	0,123	0,474	0,159	0,124	0,469
R	0,208	0,176	0,084	0,208	0,176	0,084	0,208	0,176	0,087	0,208	0,176	0,085	0,208	0,176	0,09
OS-GS	0,077	0,059	0,874	0,077	0,059	0,874	0,077	0,059	0,873	0,077	0,059	0,874	0,078	0,059	0,872
OS-N	0,083	0,064	0,853	0,083	0,064	0,853	0,083	0,064	0,853	0,083	0,064	0,854	0,083	0,064	0,853
OS-R	0,096	0,076	0,806	0,096	0,076	0,806	0,096	0,076	0,807	0,095	0,076	0,808	0,096	0,077	0,805
GS-N	0,135	0,105	0,615	0,135	0,105	0,615	0,134	0,105	0,62	0,134	0,105	0,62	0,133	0,105	0,626
GS-R	0,134	0,108	0,621	0,134	0,108	0,621	0,135	0,107	0,618	0,135	0,108	0,617	0,135	0,108	0,617
N-R	0,157	0,12	0,477	0,157	0,12	0,477	0,158	0,12	0,475	0,157	0,12	0,48	0,157	0,119	0,482
MNS-GS	0,081	0,061	0,861	0,081	0,061	0,861	0,08	0,061	0,864	0,08	0,061	0,864	0,08	0,061	0,865
MNS-N	0,084	0,064	0,852	0,084	0,064	0,852	0,084	0,064	0,852	0,084	0,065	0,852	0,084	0,064	0,852
MNS-R	0,093	0,074	0,817	0,093	0,074	0,817	0,095	0,076	0,809	0,094	0,075	0,813	0,094	0,075	0,813
MNS-R-GS	0,06	0,048	0,925	0,06	0,048	0,925	0,059	0,048	0,926	0,061	0,049	0,922	0,06	0,048	0,924
MNS-R-N	0,079	0,062	0,867	0,079	0,062	0,867	0,081	0,063	0,862	0,079	0,062	0,867	0,079	0,061	0,868
MNS-GS-N	0,067	0,052	0,905	0,067	0,052	0,905	0,066	0,052	0,907	0,067	0,052	0,904	0,066	0,052	0,908
OS-R-N	0,078	0,06	0,871	0,078	0,06	0,871	0,078	0,06	0,871	0,078	0,06	0,87	0,078	0,06	0,872
OS-GS-N	0,066	0,052	0,908	0,066	0,052	0,908	0,066	0,051	0,909	0,066	0,051	0,909	0,066	0,051	0,909
OS-R-GS	0,057	0,046	0,931	0,057	0,046	0,931	0,057	0,046	0,931	0,057	0,046	0,932	0,057	0,046	0,931
MNS-GS-N-R	0,054	0,042	0,939	0,054	0,042	0,939	0,055	0,043	0,937	0,055	0,043	0,937	0,053	0,042	0,94
OS-GS-N-R	0,051	0,041	0,944	0,051	0,041	0,944	0,051	0,041	0,945	0,051	0,041	0,944	0,051	0,041	0,945

Çizelge 4.27. Karıştırılmamış veri kombinasyonlarıyla eğitilen tüm model bulgularının ortalama ve standart sapması.


Senaryolar	ÇKA		1D-CNN		LSTM		Bi-LSTM		Hibrit	
	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*
MNS	0,104 (±0,0000)	0,772 (±0,0008)	0,104 (±0,0000)	0,773 (±0,0016)	0,105 (±0,0008)	0,768 (±0,0034)	0,104 (±0,0005)	0,769 (±0,003)	0,104 (±0,0000)	0,772 (±0,0010)
OS	0,103 (±0,0000)	0,778 (±0,0000)	0,103 (±0,0004)	0,777 (±0,0021)	0,103 (±0,0000)	0,775 (±0,0007)	0,103 (±0,0005)	0,775 (±0,002)	0,103 (±0,0000)	0,778 (±0,0000)
GS	0,157 (±0,0004)	0,481 (±0,0034)	0,157 (±0,0000)	0,480 (±0,0013)	0,158 (±0,0013)	0,471 (±0,0075)	0,158 (±0,0017)	0,471 (±0,010)	0,157 (±0,0004)	0,481 (±0,0030)
N	0,159 (±0,0005)	0,470 (±0,0030)	0,158 (±0,0005)	0,475 (±0,0035)	0,157 (±0,0000)	0,481 (±0,0025)	0,157 (±0,0004)	0,480 (±0,003)	0,159 (±0,0005)	0,470 (±0,0030)
R	0,208 (±0,0000)	0,086 (±0,0025)	0,208 (±0,0000)	0,086 (±0,0022)	0,208 (±0,0000)	0,088 (±0,0030)	0,208 (±0,0000)	0,086 (±0,002)	0,208 (±0,0000)	0,086 (±0,0030)
OS-GS	0,077 (±0,0004)	0,873 (±0,0009)	0,078 (±0,0005)	0,873 (±0,0008)	0,077 (±0,0008)	0,875 (±0,0021)	0,077 (±0,0008)	0,876 (±0,002)	0,077 (±0,0004)	0,873 (±0,0010)
OS-N	0,083 (±0,0000)	0,853 (±0,0004)	0,083 (±0,0000)	0,854 (±0,0004)	0,083 (±0,0000)	0,854 (±0,0004)	0,083 (±0,0000)	0,854 (±0,000)	0,083 (±0,0000)	0,853 (±0,0000)
OS-R	0,096 (±0,0004)	0,806 (±0,0011)	0,096 (±0,0004)	0,805 (±0,0025)	0,098 (±0,0018)	0,796 (±0,0072)	0,097 (±0,0017)	0,799 (±0,007)	0,096 (±0,0004)	0,806 (±0,0010)
GS-N	0,134 (±0,0008)	0,619 (±0,0045)	0,134 (±0,0005)	0,619 (±0,0029)	0,133 (±0,0004)	0,627 (±0,0022)	0,133 (±0,0004)	0,628 (±0,002)	0,134 (±0,0008)	0,619 (±0,0050)
GS-R	0,135 (±0,0005)	0,619 (±0,0020)	0,134 (±0,0004)	0,619 (±0,0015)	0,134 (±0,0000)	0,622 (±0,0019)	0,134 (±0,0004)	0,621 (±0,002)	0,135 (±0,0005)	0,619 (±0,0020)
N-R	0,157 (±0,0004)	0,478 (±0,0028)	0,155 (±0,0005)	0,490 (±0,0021)	0,156 (±0,0007)	0,489 (±0,0046)	0,156 (±0,0015)	0,490 (±0,011)	0,157 (±0,0004)	0,478 (±0,0030)
MNS-GS	0,080 (±0,0005)	0,863 (±0,0019)	0,081 (±0,0005)	0,863 (±0,0010)	0,081 (±0,0005)	0,863 (±0,0014)	0,080 (±0,0009)	0,864 (±0,003)	0,080 (±0,0005)	0,863 (±0,0020)
MNS-N	0,084 (±0,0000)	0,852 (±0,0000)	0,084 (±0,0000)	0,852 (±0,0007)	0,084 (±0,0004)	0,851 (±0,0027)	0,084 (±0,0004)	0,852 (±0,001)	0,084 (±0,0000)	0,852 (±0,0000)
MNS-R	0,094 (±0,0008)	0,814 (±0,0033)	0,093 (±0,0005)	0,817 (±0,0018)	0,093 (±0,0010)	0,817 (±0,0040)	0,094 (±0,0021)	0,815 (±0,009)	0,094 (±0,0008)	0,814 (±0,0030)
MNS-R-GS	0,060 (±0,0007)	0,924 (±0,0015)	0,060 (±0,0006)	0,925 (±0,0015)	0,063 (±0,0013)	0,917 (±0,0028)	0,061 (±0,0012)	0,922 (±0,003)	0,060 (±0,0007)	0,924 (±0,0020)
MNS-R-N	0,079 (±0,0009)	0,866 (±0,0024)	0,079 (±0,0009)	0,867 (±0,0036)	0,079 (±0,0007)	0,868 (±0,0021)	0,079 (±0,0007)	0,869 (±0,003)	0,079 (±0,0009)	0,866 (±0,0020)
MNS-GS-N	0,067 (±0,0005)	0,906 (±0,0016)	0,065 (±0,0004)	0,911 (±0,0010)	0,066 (±0,0008)	0,908 (±0,0016)	0,066 (±0,0017)	0,908 (±0,005)	0,067 (±0,0005)	0,906 (±0,0020)
OS-R-N	0,078 (±0,0000)	0,871 (±0,0007)	0,077 (±0,0004)	0,873 (±0,0005)	0,079 (±0,0008)	0,869 (±0,0029)	0,078 (±0,0007)	0,871 (±0,003)	0,078 (±0,0000)	0,871 (±0,0010)
OS-GS-N	0,066 (±0,0000)	0,909 (±0,0005)	0,065 (±0,0004)	0,910 (±0,0013)	0,066 (±0,0004)	0,909 (±0,0008)	0,066 (±0,0005)	0,909 (±0,001)	0,066 (±0,0000)	0,909 (±0,0010)
OS-R-GS	0,057 (±0,0000)	0,931 (±0,0004)	0,058 (±0,0009)	0,930 (±0,0019)	0,059 (±0,0004)	0,928 (±0,0009)	0,058 (±0,0008)	0,928 (±0,002)	0,057 (±0,0000)	0,931 (±0,0000)
MNS-GS-N-R	0,054 (±0,0008)	0,938 (±0,0013)	0,053 (±0,0010)	0,941 (±0,0016)	0,053 (±0,0008)	0,940 (±0,0017)	0,053 (±0,0008)	0,941 (±0,002)	0,054 (±0,0008)	0,938 (±0,0010)
OS-GS-N-R	0,051 (±0,0000)	0,944 (±0,0005)	0,051 (±0,0004)	0,945 (±0,0008)	0,051 (±0,0004)	0,945 (±0,0011)	0,051 (±0,0004)	0,945 (±0,001)	0,051 (±0,0000)	0,944 (±0,0010)

*Ortalama ve standart sapma


Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı




Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)




Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)




Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)




Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)




Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)



Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)



Şekil 4.24. ETo tahmininde 2016-2020 yılları arası karıştırılmamış veri kombinasyon performansı (devamı)



ETo tahmin etmede karıştırılmış veri kombinasyonlarıyla eğitilen modellerin sonuçları sırasıyla Çizelge 4.28, 4.29, 4.30, 4.31 ve 4.32’de verilmiş ve sonuçlar toplu olarak Çizelge 4.33’te özetlenmiştir. Şekil 4.25’de de her veri kombinasyonundan elde edilen ETo tahmini gerçek ETo ile kıyaslanmıştır. Sonuç olarak, derin öğrenme mimarisi bakımından, en iyi performans gösteren mimariler 1D-CNN ve hibrit mimari olmuştur. Veri kombinasyonları bakımından ise, karıştırılmış veri kombinasyonları karıştırılmamış veri kombinasyonlarına göre ETo tahmin verimliliğini artırmayı başarmıştır.

Çizelge 4.28. Karıştırılmış veri kombinasyonlarıyla eğitilen ÇKA modellerin bulguları

Senaryolar	ÇKA Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,102	0,081	0,785	0,103	0,079	0,779	0,101	0,078	0,782	0,102	0,08	0,776	0,102	0,079	0,776
OS	0,101	0,08	0,792	0,099	0,078	0,794	0,099	0,078	0,793	0,100	0,079	0,795	0,10	0,079	0,797
GS	0,142	0,114	0,566	0,141	0,111	0,578	0,137	0,108	0,619	0,142	0,112	0,575	0,139	0,112	0,596
N	0,157	0,129	0,485	0,158	0,128	0,470	0,158	0,129	0,483	0,156	0,125	0,506	0,161	0,128	0,461
R	0,200	0,171	0,139	0,208	0,176	0,109	0,207	0,176	0,133	0,206	0,175	0,126	0,202	0,171	0,130
OS-GS	0,077	0,058	0,878	0,075	0,058	0,881	0,075	0,059	0,883	0,076	0,058	0,882	0,072	0,056	0,891
OS-N	0,081	0,064	0,858	0,082	0,064	0,864	0,082	0,066	0,856	0,082	0,064	0,857	0,082	0,064	0,864
OS-R	0,093	0,073	0,823	0,095	0,074	0,806	0,095	0,074	0,810	0,095	0,072	0,813	0,094	0,072	0,812
GS-N	0,116	0,091	0,715	0,118	0,094	0,711	0,116	0,093	0,722	0,115	0,091	0,712	0,117	0,092	0,710
GS-R	0,116	0,091	0,715	0,116	0,093	0,723	0,118	0,093	0,707	0,121	0,095	0,690	0,117	0,090	0,715
N-R	0,151	0,120	0,530	0,151	0,12	0,522	0,154	0,124	0,496	0,151	0,119	0,515	0,150	0,119	0,524
MNS-GS	0,082	0,064	0,862	0,075	0,058	0,887	0,077	0,058	0,876	0,079	0,061	0,865	0,078	0,060	0,869
MNS-N	0,083	0,065	0,861	0,082	0,063	0,858	0,086	0,067	0,844	0,083	0,065	0,855	0,082	0,063	0,857
MNS-R	0,085	0,065	0,850	0,085	0,066	0,85	0,085	0,066	0,853	0,084	0,066	0,853	0,081	0,064	0,855
MNS-R-GS	0,057	0,045	0,934	0,057	0,044	0,932	0,055	0,043	0,934	0,057	0,045	0,931	0,057	0,045	0,931
MNS-R-N	0,080	0,062	0,861	0,074	0,057	0,885	0,074	0,057	0,891	0,075	0,057	0,880	0,076	0,058	0,880
MNS-GS-N	0,062	0,048	0,920	0,063	0,049	0,914	0,062	0,048	0,920	0,067	0,052	0,904	0,063	0,049	0,917
OS-R-N	0,079	0,061	0,873	0,076	0,060	0,876	0,077	0,059	0,874	0,079	0,060	0,875	0,075	0,057	0,879
OS-GS-N	0,062	0,049	0,921	0,064	0,050	0,913	0,063	0,049	0,918	0,062	0,048	0,919	0,063	0,049	0,919
OS-R-GS	0,056	0,043	0,932	0,057	0,044	0,931	0,056	0,044	0,936	0,058	0,045	0,929	0,057	0,045	0,931
MNS-GS-N-R	0,052	0,041	0,944	0,051	0,040	0,944	0,052	0,04	0,942	0,051	0,039	0,946	0,050	0,039	0,948
OS-GS-N-R	0,050	0,040	0,948	0,050	0,039	0,948	0,049	0,039	0,950	0,051	0,040	0,949	0,051	0,039	0,946

Çizelge 4.29. Karıştırılmış veri kombinasyonlarıyla eğitilen 1D-CNN modellerin bulguları

Senaryolar	1D-CNN Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,100	0,078	0,793	0,100	0,078	0,792	0,100	0,078	0,791	0,100	0,078	0,793	0,100	0,078	0,793
OS	0,100	0,079	0,794	0,099	0,079	0,794	0,100	0,079	0,794	0,099	0,079	0,795	0,099	0,079	0,795
GS	0,140	0,110	0,594	0,140	0,110	0,593	0,140	0,110	0,593	0,140	0,110	0,593	0,140	0,110	0,593
N	0,158	0,128	0,481	0,158	0,128	0,480	0,158	0,128	0,480	0,158	0,128	0,480	0,158	0,128	0,480
R	0,204	0,174	0,133	0,205	0,174	0,131	0,205	0,175	0,131	0,204	0,174	0,134	0,204	0,174	0,132
OS-GS	0,074	0,058	0,886	0,074	0,058	0,887	0,073	0,057	0,888	0,074	0,058	0,886	0,074	0,058	0,887
OS-N	0,082	0,064	0,861	0,082	0,064	0,862	0,081	0,064	0,862	0,082	0,064	0,861	0,082	0,064	0,860
OS-R	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,071	0,823	0,092	0,072	0,823
GS-N	0,117	0,092	0,714	0,118	0,092	0,712	0,117	0,092	0,713	0,118	0,092	0,713	0,118	0,092	0,713
GS-R	0,119	0,091	0,708	0,119	0,091	0,708	0,118	0,091	0,709	0,119	0,091	0,708	0,118	0,091	0,708
N-R	0,152	0,120	0,522	0,151	0,120	0,524	0,152	0,120	0,523	0,151	0,120	0,523	0,152	0,120	0,523
MNS-GS	0,076	0,058	0,882	0,076	0,059	0,880	0,076	0,059	0,880	0,076	0,058	0,881	0,075	0,058	0,882
MNS-N	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,859
MNS-R	0,083	0,064	0,857	0,083	0,064	0,858	0,082	0,063	0,860	0,083	0,063	0,858	0,083	0,064	0,858
MNS-R-GS	0,056	0,043	0,935	0,055	0,043	0,936	0,056	0,043	0,936	0,055	0,043	0,936	0,055	0,042	0,936
MNS-R-N	0,074	0,057	0,887	0,073	0,057	0,888	0,074	0,057	0,887	0,074	0,056	0,887	0,074	0,057	0,887
MNS-GS-N	0,061	0,048	0,922	0,062	0,048	0,921	0,061	0,048	0,922	0,061	0,047	0,923	0,061	0,047	0,922
OS-R-N	0,077	0,059	0,876	0,077	0,059	0,876	0,077	0,059	0,876	0,077	0,059	0,877	0,077	0,059	0,877
OS-GS-N	0,062	0,048	0,921	0,062	0,048	0,920	0,062	0,049	0,920	0,062	0,048	0,921	0,062	0,048	0,921
OS-R-GS	0,057	0,044	0,933	0,056	0,044	0,934	0,056	0,043	0,935	0,057	0,044	0,933	0,057	0,044	0,934
MNS-GS-N-R	0,050	0,038	0,949	0,050	0,039	0,948	0,050	0,039	0,948	0,050	0,038	0,949	0,050	0,038	0,949
OS-GS-N-R	0,050	0,039	0,948	0,050	0,039	0,948	0,050	0,039	0,947	0,050	0,039	0,948	0,050	0,039	0,947

Çizelge 4.30. Karıştırılmış veri kombinasyonlarıyla eğitilen LSTM modellerin bulguları

Senaryolar	LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,100	0,078	0,791	0,100	0,078	0,791	0,100	0,078	0,791	0,100	0,078	0,791	0,101	0,079	0,789
OS	0,100	0,080	0,792	0,100	0,079	0,792	0,099	0,079	0,795	0,100	0,079	0,793	0,099	0,079	0,794
GS	0,140	0,111	0,591	0,140	0,111	0,590	0,140	0,110	0,591	0,140	0,110	0,593	0,141	0,111	0,586
N	0,158	0,128	0,479	0,158	0,128	0,479	0,158	0,128	0,480	0,158	0,128	0,481	0,158	0,128	0,479
R	0,204	0,174	0,131	0,205	0,174	0,131	0,204	0,174	0,133	0,204	0,174	0,132	0,204	0,174	0,132
OS-GS	0,074	0,058	0,887	0,074	0,058	0,887	0,074	0,058	0,886	0,074	0,058	0,886	0,074	0,058	0,887
OS-N	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862
OS-R	0,092	0,072	0,824	0,092	0,072	0,823	0,093	0,073	0,820	0,093	0,073	0,821	0,092	0,072	0,824
GS-N	0,118	0,093	0,712	0,119	0,093	0,708	0,118	0,093	0,709	0,118	0,092	0,712	0,118	0,093	0,711
GS-R	0,118	0,092	0,709	0,118	0,092	0,708	0,119	0,092	0,707	0,118	0,092	0,709	0,119	0,092	0,708
N-R	0,152	0,120	0,523	0,151	0,120	0,523	0,152	0,120	0,523	0,151	0,120	0,524	0,152	0,120	0,522
MNS-GS	0,076	0,059	0,880	0,076	0,059	0,880	0,076	0,059	0,879	0,076	0,059	0,879	0,077	0,06	0,878
MNS-N	0,082	0,064	0,861	0,082	0,064	0,860	0,082	0,064	0,860	0,083	0,065	0,857	0,082	0,064	0,860
MNS-R	0,082	0,064	0,859	0,082	0,064	0,859	0,082	0,064	0,859	0,082	0,064	0,859	0,083	0,065	0,856
MNS-R-GS	0,056	0,044	0,935	0,056	0,044	0,934	0,057	0,044	0,933	0,057	0,044	0,934	0,057	0,044	0,933
MNS-R-N	0,074	0,057	0,885	0,075	0,057	0,884	0,074	0,057	0,886	0,075	0,058	0,883	0,075	0,057	0,884
MNS-GS-N	0,061	0,048	0,922	0,062	0,049	0,919	0,062	0,049	0,920	0,062	0,048	0,921	0,062	0,049	0,920
OS-R-N	0,077	0,060	0,876	0,078	0,060	0,875	0,077	0,059	0,876	0,077	0,060	0,876	0,078	0,060	0,874
OS-GS-N	0,062	0,049	0,919	0,063	0,049	0,919	0,062	0,049	0,920	0,062	0,049	0,919	0,062	0,049	0,920
OS-R-GS	0,056	0,044	0,934	0,056	0,044	0,934	0,056	0,044	0,934	0,057	0,044	0,933	0,057	0,044	0,933
MNS-GS-N-R	0,050	0,040	0,947	0,051	0,040	0,946	0,050	0,039	0,948	0,050	0,039	0,948	0,050	0,039	0,947
OS-GS-N-R	0,051	0,039	0,947	0,051	0,040	0,945	0,051	0,039	0,947	0,051	0,040	0,946	0,050	0,039	0,947

Çizelge 4.31. Karıştırılmış veri kombinasyonlarıyla eğitilen Bi-LSTM modellerin bulguları.

Senaryolar	Bi-LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,100	0,078	0,791	0,100	0,078	0,791	0,100	0,078	0,791	0,100	0,078	0,792	0,100	0,078	0,791
OS	0,100	0,080	0,792	0,100	0,079	0,794	0,100	0,080	0,793	0,099	0,079	0,794	0,100	0,079	0,793
GS	0,140	0,111	0,590	0,140	0,110	0,592	0,141	0,111	0,589	0,140	0,110	0,594	0,140	0,111	0,591
N	0,158	0,128	0,480	0,158	0,128	0,480	0,158	0,128	0,481	0,158	0,128	0,481	0,158	0,128	0,479
R	0,205	0,174	0,131	0,204	0,174	0,132	0,205	0,174	0,131	0,204	0,174	0,132	0,205	0,174	0,130
OS-GS	0,074	0,057	0,888	0,073	0,057	0,888	0,074	0,057	0,888	0,074	0,058	0,887	0,074	0,057	0,887
OS-N	0,081	0,064	0,862	0,081	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,860	0,082	0,064	0,862
OS-R	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,072	0,823
GS-N	0,118	0,093	0,709	0,118	0,092	0,711	0,118	0,093	0,710	0,118	0,093	0,712	0,119	0,093	0,707
GS-R	0,118	0,091	0,711	0,118	0,091	0,710	0,119	0,092	0,707	0,119	0,091	0,708	0,118	0,091	0,711
N-R	0,152	0,120	0,522	0,152	0,120	0,521	0,151	0,120	0,526	0,152	0,120	0,523	0,151	0,120	0,526
MNS-GS	0,076	0,059	0,880	0,076	0,059	0,879	0,076	0,059	0,879	0,076	0,058	0,881	0,076	0,058	0,881
MNS-N	0,082	0,064	0,860	0,082	0,064	0,861	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,860
MNS-R	0,082	0,064	0,859	0,083	0,064	0,857	0,082	0,064	0,859	0,083	0,064	0,856	0,082	0,063	0,861
MNS-R-GS	0,056	0,044	0,935	0,056	0,044	0,935	0,056	0,043	0,935	0,056	0,044	0,934	0,056	0,044	0,934
MNS-R-N	0,074	0,057	0,886	0,074	0,056	0,887	0,074	0,057	0,887	0,074	0,056	0,888	0,075	0,058	0,883
MNS-GS-N	0,061	0,048	0,922	0,061	0,048	0,922	0,062	0,048	0,921	0,061	0,048	0,922	0,064	0,050	0,915
OS-R-N	0,077	0,060	0,876	0,078	0,060	0,875	0,078	0,060	0,874	0,077	0,059	0,876	0,077	0,060	0,876
OS-GS-N	0,062	0,049	0,920	0,062	0,049	0,920	0,062	0,049	0,920	0,062	0,049	0,920	0,063	0,049	0,919
OS-R-GS	0,056	0,044	0,934	0,056	0,044	0,934	0,056	0,044	0,935	0,057	0,044	0,933	0,056	0,044	0,934
MNS-GS-N-R	0,050	0,039	0,948	0,050	0,039	0,948	0,050	0,039	0,949	0,050	0,039	0,948	0,052	0,040	0,945
OS-GS-N-R	0,051	0,040	0,946	0,051	0,039	0,947	0,051	0,039	0,946	0,050	0,039	0,947	0,051	0,040	0,946

Çizelge 4.32. Karıştırılmış veri kombinasyonlarıyla eğitilen hibrit modellerin bulguları.


Senaryolar	Hibrit Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,100	0,078	0,792	0,100	0,078	0,793	0,100	0,078	0,794	0,100	0,078	0,794	0,100	0,078	0,794
OS	0,099	0,079	0,796	0,099	0,079	0,796	0,099	0,079	0,795	0,099	0,079	0,795	0,099	0,079	0,795
GS	0,140	0,110	0,593	0,140	0,110	0,593	0,140	0,111	0,593	0,140	0,110	0,592	0,140	0,111	0,593
N	0,159	0,128	0,477	0,159	0,128	0,477	0,159	0,128	0,477	0,159	0,128	0,477	0,159	0,128	0,477
R	0,204	0,175	0,132	0,204	0,175	0,132	0,204	0,175	0,132	0,204	0,175	0,131	0,204	0,175	0,132
OS-GS	0,073	0,057	0,889	0,073	0,057	0,888	0,073	0,057	0,888	0,073	0,057	0,888	0,074	0,058	0,887
OS-N	0,082	0,064	0,861	0,082	0,064	0,861	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,860
OS-R	0,092	0,072	0,823	0,092	0,072	0,823	0,092	0,072	0,824	0,092	0,072	0,824	0,092	0,072	0,823
GS-N	0,118	0,093	0,712	0,118	0,092	0,712	0,118	0,092	0,713	0,118	0,092	0,713	0,118	0,092	0,713
GS-R	0,119	0,091	0,708	0,118	0,091	0,708	0,118	0,091	0,709	0,118	0,091	0,710	0,118	0,091	0,712
N-R	0,151	0,120	0,527	0,152	0,120	0,523	0,151	0,120	0,525	0,152	0,120	0,523	0,151	0,120	0,528
MNS-GS	0,076	0,059	0,880	0,075	0,058	0,882	0,076	0,058	0,881	0,076	0,058	0,881	0,076	0,059	0,880
MNS-N	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,860	0,082	0,064	0,861	0,082	0,064	0,861
MNS-R	0,082	0,063	0,860	0,082	0,064	0,859	0,083	0,065	0,856	0,083	0,064	0,856	0,083	0,064	0,858
MNS-R-GS	0,056	0,043	0,935	0,056	0,043	0,936	0,056	0,044	0,934	0,056	0,043	0,935	0,056	0,044	0,935
MNS-R-N	0,074	0,057	0,887	0,074	0,056	0,888	0,074	0,057	0,887	0,074	0,057	0,886	0,074	0,057	0,887
MNS-GS-N	0,062	0,048	0,921	0,062	0,048	0,921	0,062	0,048	0,921	0,062	0,049	0,920	0,061	0,048	0,922
OS-R-N	0,077	0,059	0,876	0,077	0,059	0,877	0,077	0,059	0,876	0,077	0,059	0,877	0,077	0,059	0,876
OS-GS-N	0,062	0,049	0,919	0,062	0,049	0,920	0,062	0,049	0,920	0,062	0,049	0,919	0,062	0,049	0,919
OS-R-GS	0,057	0,044	0,933	0,057	0,044	0,932	0,057	0,044	0,933	0,057	0,044	0,933	0,057	0,044	0,933
MNS-GS-N-R	0,050	0,039	0,949	0,050	0,039	0,948	0,050	0,040	0,947	0,050	0,039	0,948	0,050	0,039	0,948
OS-GS-N-R	0,051	0,039	0,947	0,050	0,039	0,947	0,050	0,039	0,947	0,050	0,039	0,947	0,051	0,039	0,947

Çizelge 4.33. Karıştırılmış veri kombinasyonlarıyla eğitilen tüm model bulgularının ortalama ve standart sapması.


Senaryolar	ÇKA		1D-CNN		LSTM		Bi-LSTM		Hibrit	
	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*	RMSE*	R2*
MNS	0,102 (±0,0007)	0,780 (±0,004)	0,100 (±0,0000)	0,792 (±0,001)	0,100 (±0,0004)	0,791 (±0,001)	0,100 (±0,0000)	0,791 (±0,001)	0,100 (±0,0000)	0,793 (±0,001)
OS	0,100 (±0,0008)	0,794 (±0,002)	0,099 (±0,0005)	0,794 (±0,001)	0,100 (±0,0005)	0,793 (±0,001)	0,100 (±0,0004)	0,793 (±0,001)	0,099 (±0,0000)	0,795 (±0,001)
GS	0,140 (±0,0022)	0,587 (±0,021)	0,140 (±0,0000)	0,593 (±0,000)	0,140 (±0,0004)	0,590 (±0,003)	0,140 (±0,0004)	0,591 (±0,002)	0,140 (±0,0000)	0,593 (±0,000)
N	0,158 (±0,0019)	0,481 (±0,017)	0,158 (±0,0000)	0,480 (±0,000)	0,158 (±0,0000)	0,480 (±0,001)	0,158 (±0,0000)	0,480 (±0,001)	0,159 (±0,0000)	0,477 (±0,000)
R	0,205 (±0,0034)	0,127 (±0,011)	0,204 (±0,0005)	0,132 (±0,001)	0,204 (±0,0004)	0,132 (±0,001)	0,205 (±0,0005)	0,131 (±0,001)	0,204 (±0,0000)	0,132 (±0,000)
OS-GS	0,075 (±0,0019)	0,883 (±0,005)	0,074 (±0,0004)	0,887 (±0,001)	0,074 (±0,0000)	0,887 (±0,001)	0,074 (±0,0004)	0,888 (±0,001)	0,073 (±0,0004)	0,888 (±0,001)
OS-N	0,082 (±0,0004)	0,860 (±0,004)	0,082 (±0,0004)	0,861 (±0,001)	0,082 (±0,0000)	0,862 (±0,000)	0,082 (±0,0005)	0,862 (±0,001)	0,082 (±0,0000)	0,860 (±0,001)
OS-R	0,094 (±0,0009)	0,813 (±0,006)	0,092 (±0,0000)	0,823 (±0,000)	0,092 (±0,0005)	0,822 (±0,002)	0,092 (±0,0000)	0,823 (±0,000)	0,092 (±0,0000)	0,823 (±0,001)
GS-N	0,116 (±0,0011)	0,714 (±0,005)	0,118 (±0,0005)	0,713 (±0,001)	0,118 (±0,0004)	0,710 (±0,002)	0,118 (±0,0004)	0,710 (±0,002)	0,118 (±0,0000)	0,713 (±0,001)
GS-R	0,118 (±0,0021)	0,710 (±0,013)	0,119 (±0,0005)	0,708 (±0,000)	0,118 (±0,0005)	0,708 (±0,001)	0,118 (±0,0005)	0,709 (±0,002)	0,118 (±0,0004)	0,709 (±0,002)
N-R	0,151 (±0,0015)	0,517 (±0,013)	0,152 (±0,0005)	0,523 (±0,001)	0,152 (±0,0005)	0,523 (±0,001)	0,152 (±0,0005)	0,524 (±0,002)	0,151 (±0,0005)	0,525 (±0,002)
MNS-GS	0,078 (±0,0026)	0,872 (±0,010)	0,076 (±0,0004)	0,881 (±0,001)	0,076 (±0,0004)	0,879 (±0,001)	0,076 (±0,0000)	0,880 (±0,001)	0,076 (±0,0004)	0,881 (±0,001)
MNS-N	0,083 (±0,0016)	0,855 (±0,007)	0,082 (±0,0000)	0,860 (±0,000)	0,082 (±0,0004)	0,860 (±0,002)	0,082 (±0,0000)	0,860 (±0,000)	0,082 (±0,0000)	0,860 (±0,001)
MNS-R	0,084 (±0,0017)	0,852 (±0,002)	0,083 (±0,0004)	0,858 (±0,001)	0,082 (±0,0004)	0,858 (±0,001)	0,082 (±0,0005)	0,858 (±0,002)	0,083 (±0,0005)	0,858 (±0,002)
MNS-R-GS	0,057 (±0,0009)	0,932 (±0,002)	0,055 (±0,0005)	0,936 (±0,000)	0,057 (±0,0005)	0,934 (±0,001)	0,056 (±0,0000)	0,935 (±0,001)	0,056 (±0,0000)	0,935 (±0,001)
MNS-R-N	0,076 (±0,0025)	0,879 (±0,011)	0,074 (±0,0004)	0,887 (±0,000)	0,075 (±0,0005)	0,884 (±0,001)	0,074 (±0,0004)	0,886 (±0,002)	0,074 (±0,0000)	0,887 (±0,001)
MNS-GS-N	0,063 (±0,0021)	0,915 (±0,007)	0,061 (±0,0004)	0,922 (±0,001)	0,062 (±0,0004)	0,920 (±0,001)	0,062 (±0,0013)	0,920 (±0,003)	0,062 (±0,0004)	0,921 (±0,001)
OS-R-N	0,077 (±0,0018)	0,875 (±0,002)	0,077 (±0,0000)	0,876 (±0,001)	0,077 (±0,0005)	0,875 (±0,001)	0,077 (±0,0005)	0,875 (±0,001)	0,077 (±0,0000)	0,876 (±0,001)
OS-GS-N	0,063 (±0,0008)	0,918 (±0,003)	0,062 (±0,0000)	0,921 (±0,001)	0,062 (±0,0004)	0,919 (±0,001)	0,062 (±0,0004)	0,920 (±0,000)	0,062 (±0,0000)	0,919 (±0,001)
OS-R-GS	0,057 (±0,0008)	0,932 (±0,003)	0,057 (±0,0005)	0,934 (±0,001)	0,056 (±0,0005)	0,934 (±0,001)	0,056 (±0,0004)	0,934 (±0,001)	0,057 (±0,0000)	0,933 (±0,000)
MNS-GS-N-R	0,051 (±0,0008)	0,945 (±0,002)	0,050 (±0,0000)	0,949 (±0,001)	0,050 (±0,0004)	0,947 (±0,001)	0,050 (±0,0009)	0,948 (±0,002)	0,050 (±0,0000)	0,948 (±0,001)
OS-GS-N-R	0,050 (±0,0008)	0,948 (±0,001)	0,050 (±0,0000)	0,948 (±0,001)	0,051 (±0,0004)	0,946 (±0,001)	0,051 (±0,0004)	0,946 (±0,001)	0,050 (±0,0005)	0,947 (±0,000)

*Ortalama ve standart sapma

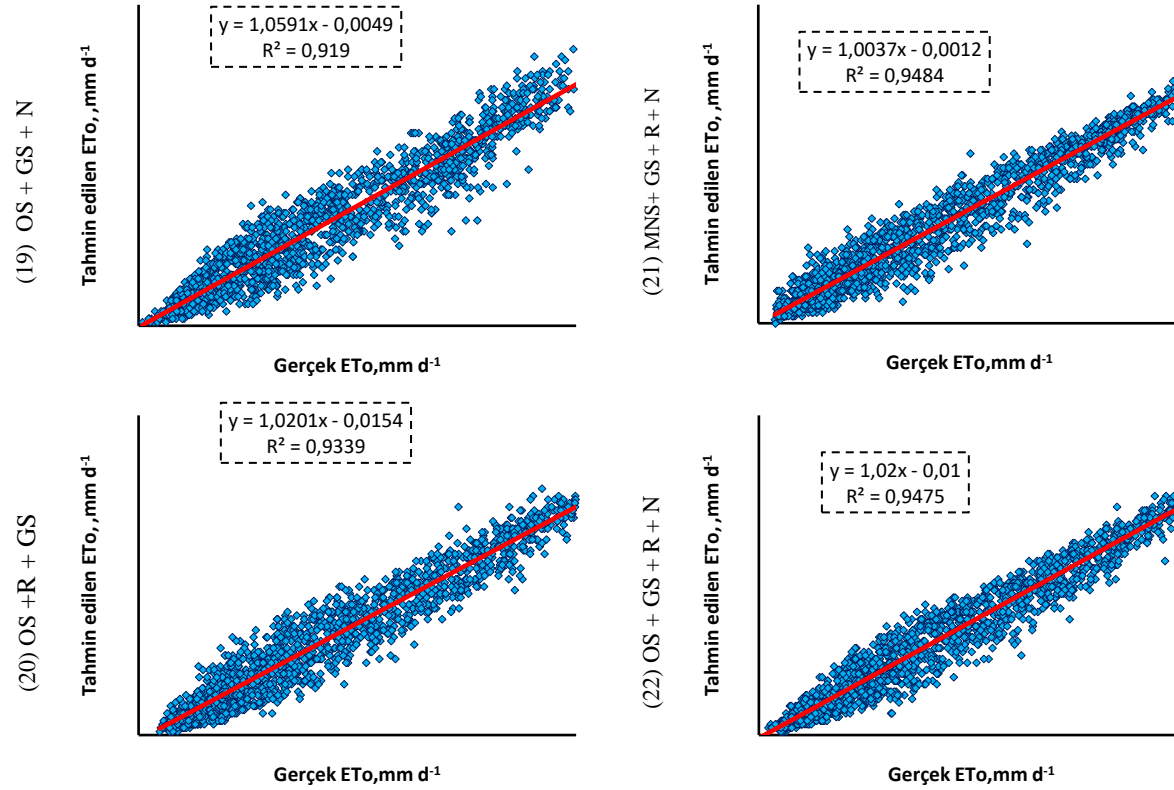
Şekil 4.25. ETo tahmininde 2016-2020 yılları arası karıştırılmış veri kombinasyon performansı



Şekil 4.25. ETo tahmininde 2016-2020 yılları arası karıştırılmış veri kombinasyon performansı (devamı)



Şekil 4.25. ETo tahmininde 2016-2020 yılları arası karıştırılmış veri kombinasyon performansı (devamı)



ETo tahmin etmede karıştırılmış ve karıştırılmamış veri kombinasyonlarının performans karşılaştırması sonuçları Çizelge 34’te verilmiştir. Çizelge 34’ten izleneceği üzere, derin öğrenme mimarileri karıştırılmış veri kombinasyonları ile eğitildiğinde şüphesiz daha iyi sonuçlar vermiştir. Bundan dolayı, farklı bölgelerde ETo tahmin etmede o bölgelerin meteoroloji parametrelerini kullanma potansiyeli olabileceği söylenilebilir.

Cizelge 4.34. ETo tahmin etmede karıştırılmış ve karıştırılmamış veri kombinasyonlarının performans karşılaştırması

Senaryolar	ÇKA		1D-CNN		LSTM		Bi-LSTM		Hibrit	
	Karıştırılmamış*	Karıştırılmış*	Karıştırılmamış*	Karıştırılmış*	Karıştırılmamış*	Karıştırılmış*	Karıştırılmamış*	Karıştırılmış*	Karıştırılmamış*	Karıştırılmış*
MNS	0,772 (±0,0008)	0,780 (±0,004)	0,773 (±0,0016)	0,792 (±0,001)	0,768 (±0,0034)	0,791 (±0,001)	0,769 (±0,003)	0,791 (±0,001)	0,772 (±0,0010)	0,793 (±0,001)
OS	0,778 (±0,0000)	0,794 (±0,002)	0,777 (±0,0021)	0,794 (±0,001)	0,775 (±0,0007)	0,793 (±0,001)	0,775 (±0,002)	0,793 (±0,001)	0,778 (±0,0000)	0,795 (±0,001)
GS	0,481 (±0,0034)	0,587 (±0,021)	0,480 (±0,0013)	0,593 (±0,000)	0,471 (±0,0075)	0,590 (±0,003)	0,471 (±0,010)	0,591 (±0,002)	0,481 (±0,0030)	0,593 (±0,000)
N	0,470 (±0,0030)	0,481 (±0,017)	0,475 (±0,0035)	0,480 (±0,000)	0,481 (±0,0025)	0,480 (±0,001)	0,480 (±0,003)	0,480 (±0,001)	0,470 (±0,0030)	0,477 (±0,000)
R	0,086 (±0,0025)	0,127 (±0,011)	0,086 (±0,0022)	0,132 (±0,001)	0,088 (±0,0030)	0,132 (±0,001)	0,086 (±0,002)	0,131 (±0,001)	0,086 (±0,0030)	0,132 (±0,000)
OS-GS	0,873 (±0,0009)	0,883 (±0,005)	0,873 (±0,0008)	0,887 (±0,001)	0,875 (±0,0021)	0,887 (±0,001)	0,876 (±0,002)	0,888 (±0,001)	0,873 (±0,0010)	0,888 (±0,001)
OS-N	0,853 (±0,0004)	0,860 (±0,004)	0,854 (±0,0004)	0,861 (±0,001)	0,854 (±0,0004)	0,862 (±0,000)	0,854 (±0,000)	0,862 (±0,001)	0,853 (±0,0000)	0,860 (±0,001)
OS-R	0,806 (±0,0011)	0,813 (±0,006)	0,805 (±0,0025)	0,823 (±0,000)	0,796 (±0,0072)	0,822 (±0,002)	0,799 (±0,007)	0,823 (±0,000)	0,806 (±0,0010)	0,823 (±0,001)
GS-N	0,619 (±0,0045)	0,714 (±0,005)	0,619 (±0,0029)	0,713 (±0,001)	0,627 (±0,0022)	0,710 (±0,002)	0,628 (±0,002)	0,710 (±0,002)	0,619 (±0,0050)	0,713 (±0,001)
GS-R	0,619 (±0,0020)	0,710 (±0,013)	0,619 (±0,0015)	0,708 (±0,000)	0,622 (±0,0019)	0,708 (±0,001)	0,621 (±0,002)	0,709 (±0,002)	0,619 (±0,0020)	0,709 (±0,002)
N-R	0,478 (±0,0028)	0,517 (±0,013)	0,490 (±0,0021)	0,523 (±0,001)	0,489 (±0,0046)	0,523 (±0,001)	0,490 (±0,011)	0,524 (±0,002)	0,478 (±0,0030)	0,525 (±0,002)
MNS-GS	0,863 (±0,0019)	0,872 (±0,010)	0,863 (±0,0010)	0,881 (±0,001)	0,863 (±0,0014)	0,879 (±0,001)	0,864 (±0,003)	0,880 (±0,001)	0,863 (±0,0020)	0,881 (±0,001)
MNS-N	0,852 (±0,0000)	0,855 (±0,007)	0,852 (±0,0007)	0,860 (±0,000)	0,851 (±0,0027)	0,860 (±0,002)	0,852 (±0,001)	0,860 (±0,000)	0,852 (±0,0000)	0,860 (±0,001)
MNS-R	0,814 (±0,0033)	0,852 (±0,002)	0,817 (±0,0018)	0,858 (±0,001)	0,817 (±0,0040)	0,858 (±0,001)	0,815 (±0,009)	0,858 (±0,002)	0,814 (±0,0030)	0,858 (±0,002)
MNS-R-GS	0,924 (±0,0015)	0,932 (±0,002)	0,925 (±0,0015)	0,936 (±0,000)	0,917 (±0,0028)	0,934 (±0,001)	0,922 (±0,003)	0,935 (±0,001)	0,924 (±0,0020)	0,935 (±0,001)
MNS-R-N	0,866 (±0,0024)	0,879 (±0,011)	0,867 (±0,0036)	0,887 (±0,000)	0,868 (±0,0021)	0,884 (±0,001)	0,869 (±0,003)	0,886 (±0,002)	0,866 (±0,0020)	0,887 (±0,001)
MNS-GS-N	0,906 (±0,0016)	0,915 (±0,007)	0,911 (±0,0010)	0,922 (±0,001)	0,908 (±0,0016)	0,920 (±0,001)	0,908 (±0,005)	0,920 (±0,003)	0,906 (±0,0020)	0,921 (±0,001)
OS-R-N	0,871 (±0,0007)	0,875 (±0,002)	0,873 (±0,0005)	0,876 (±0,001)	0,869 (±0,0029)	0,875 (±0,001)	0,871 (±0,003)	0,875 (±0,001)	0,871 (±0,0010)	0,876 (±0,001)
OS-GS-N	0,909 (±0,0005)	0,918 (±0,003)	0,910 (±0,0013)	0,921 (±0,001)	0,909 (±0,0008)	0,919 (±0,001)	0,909 (±0,001)	0,920 (±0,000)	0,909 (±0,0010)	0,919 (±0,001)
OS-R-GS	0,931 (±0,0004)	0,932 (±0,003)	0,930 (±0,0019)	0,934 (±0,001)	0,928 (±0,0009)	0,934 (±0,001)	0,928 (±0,002)	0,934 (±0,001)	0,931 (±0,0000)	0,933 (±0,000)
MNS-GS-N-R	0,938 (±0,0013)	0,945 (±0,002)	0,941 (±0,0016)	0,949 (±0,001)	0,940 (±0,0017)	0,947 (±0,001)	0,941 (±0,002)	0,948 (±0,002)	0,938 (±0,0010)	0,948 (±0,001)
OS-GS-N-R	0,944 (±0,0005)	0,948 (±0,001)	0,945 (±0,0008)	0,948 (±0,001)	0,945 (±0,0011)	0,946 (±0,001)	0,945 (±0,001)	0,946 (±0,001)	0,944 (±0,0010)	0,947 (±0,000)

*Ortalama ve standart sapma

4.6.2. Relu ve Swish Performans Karşılaştırması

Swish aktivasyon fonksiyonlu model bulguları Çizelge 4.35-4.39'da gösterilmiş ve Çizelge 4.40'da özetlenmiştir. Karıştırılmış veri kombinasyonlarında test edilen modellerin performansını arttırmak amacıyla modellerin mimarilerinde Relu aktivasyon fonksiyonu yerine Google tarafından üretilen Swish aktivasyon fonksiyonu kullanılmıştır. Elde edilen sonuçlar, modellerin mimarilerinde aktivasyon fonksiyonu olarak, Relu yerine Swish kullanıldığında, modellerin ETo tahmin etme performansının düştüğünü göstermiştir (Çizelge 4.41).

Çizelge 4.35. Swish aktivasyon fonksiyonlu ÇKA modellerin bulguları

Senaryolar	ÇKA Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,103	0,081	0,779	0,103	0,082	0,778	0,103	0,081	0,781	0,102	0,080	0,782	0,102	0,081	0,782
OS	0,101	0,080	0,779	0,102	0,080	0,777	0,102	0,080	0,777	0,101	0,079	0,779	0,102	0,080	0,776
GS	0,142	0,113	0,583	0,141	0,113	0,585	0,141	0,112	0,585	0,142	0,113	0,582	0,142	0,113	0,581
N	0,158	0,130	0,449	0,158	0,130	0,449	0,158	0,129	0,451	0,157	0,128	0,457	0,158	0,129	0,450
R	0,202	0,173	0,120	0,203	0,174	0,118	0,202	0,174	0,119	0,203	0,174	0,119	0,203	0,174	0,118
OS-GS	0,075	0,060	0,880	0,074	0,059	0,883	0,075	0,060	0,880	0,076	0,061	0,878	0,076	0,061	0,878
OS-N	0,084	0,065	0,850	0,084	0,065	0,850	0,084	0,065	0,850	0,084	0,065	0,849	0,084	0,066	0,849
OS-R	0,094	0,074	0,814	0,094	0,074	0,813	0,094	0,074	0,813	0,094	0,074	0,813	0,094	0,073	0,814
GS-N	0,120	0,098	0,696	0,119	0,097	0,701	0,119	0,097	0,704	0,118	0,096	0,707	0,118	0,097	0,707
GS-R	0,123	0,098	0,685	0,122	0,096	0,691	0,121	0,096	0,693	0,121	0,095	0,697	0,121	0,095	0,694
N-R	0,153	0,124	0,506	0,154	0,124	0,505	0,152	0,121	0,518	0,153	0,123	0,510	0,153	0,123	0,507
MNS-GS	0,079	0,062	0,871	0,078	0,061	0,874	0,077	0,060	0,878	0,077	0,060	0,877	0,077	0,060	0,878
MNS-N	0,086	0,066	0,849	0,085	0,065	0,850	0,085	0,065	0,852	0,085	0,064	0,853	0,085	0,064	0,853
MNS-R	0,089	0,070	0,834	0,089	0,070	0,837	0,090	0,070	0,834	0,088	0,069	0,839	0,088	0,069	0,838
MNS-R-GS	0,063	0,051	0,914	0,062	0,050	0,916	0,061	0,049	0,919	0,060	0,048	0,921	0,060	0,047	0,922
MNS-R-N	0,079	0,061	0,874	0,080	0,062	0,871	0,078	0,060	0,877	0,079	0,061	0,873	0,079	0,061	0,874
MNS-GS-N	0,064	0,051	0,917	0,065	0,052	0,915	0,063	0,050	0,920	0,065	0,052	0,916	0,064	0,052	0,916
OS-R-N	0,077	0,060	0,876	0,077	0,060	0,876	0,077	0,060	0,878	0,077	0,060	0,877	0,077	0,060	0,876
OS-GS-N	0,063	0,050	0,917	0,063	0,051	0,917	0,064	0,051	0,916	0,063	0,050	0,917	0,064	0,051	0,916
OS-R-GS	0,059	0,047	0,924	0,060	0,047	0,923	0,058	0,046	0,927	0,059	0,047	0,924	0,059	0,047	0,924
MNS-GS-N-R	0,054	0,043	0,940	0,053	0,042	0,942	0,054	0,042	0,939	0,054	0,042	0,940	0,053	0,042	0,942
OS-GS-N-R	0,054	0,042	0,941	0,055	0,043	0,938	0,054	0,042	0,941	0,054	0,043	0,940	0,054	0,043	0,940

Çizelge 4.36. Swish aktivasyon fonksiyonlu 1D-CNN modellerin bulguları

Senaryolar	1D-CNN Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,103	0,081	0,780	0,103	0,081	0,779	0,103	0,081	0,780	0,102	0,081	0,782	0,101	0,079	0,790
OS	0,100	0,080	0,792	0,100	0,080	0,791	0,100	0,080	0,792	0,100	0,080	0,792	0,100	0,080	0,793
GS	0,144	0,114	0,570	0,144	0,114	0,570	0,143	0,114	0,572	0,143	0,114	0,578	0,141	0,111	0,589
N	0,161	0,132	0,464	0,161	0,132	0,464	0,161	0,132	0,464	0,161	0,132	0,464	0,161	0,132	0,464
R	0,205	0,176	0,127	0,205	0,176	0,125	0,205	0,177	0,124	0,205	0,175	0,127	0,205	0,176	0,127
OS-GS	0,077	0,061	0,877	0,076	0,060	0,880	0,077	0,061	0,878	0,076	0,060	0,880	0,075	0,059	0,883
OS-N	0,082	0,065	0,859	0,083	0,066	0,857	0,082	0,064	0,861	0,082	0,064	0,861	0,082	0,064	0,862
OS-R	0,094	0,074	0,817	0,094	0,074	0,817	0,094	0,074	0,816	0,094	0,074	0,817	0,094	0,073	0,818
GS-N	0,123	0,098	0,688	0,122	0,098	0,689	0,122	0,098	0,689	0,122	0,098	0,690	0,118	0,093	0,710
GS-R	0,123	0,096	0,688	0,123	0,097	0,685	0,121	0,095	0,695	0,121	0,095	0,694	0,120	0,094	0,701
N-R	0,154	0,124	0,505	0,155	0,125	0,503	0,154	0,124	0,504	0,154	0,124	0,505	0,154	0,124	0,506
MNS-GS	0,079	0,062	0,871	0,079	0,062	0,872	0,080	0,063	0,868	0,079	0,062	0,869	0,077	0,060	0,877
MNS-N	0,085	0,066	0,851	0,085	0,066	0,851	0,084	0,066	0,853	0,083	0,065	0,855	0,083	0,065	0,858
MNS-R	0,086	0,067	0,848	0,087	0,068	0,843	0,087	0,068	0,843	0,086	0,067	0,846	0,084	0,066	0,853
MNS-R-GS	0,059	0,047	0,927	0,060	0,048	0,925	0,061	0,049	0,923	0,060	0,048	0,925	0,057	0,045	0,932
MNS-R-N	0,078	0,061	0,874	0,078	0,061	0,873	0,078	0,061	0,874	0,076	0,059	0,879	0,075	0,058	0,883
MNS-GS-N	0,064	0,051	0,915	0,064	0,051	0,914	0,064	0,051	0,915	0,064	0,051	0,915	0,063	0,050	0,919
OS-R-N	0,079	0,061	0,870	0,080	0,062	0,867	0,079	0,061	0,869	0,080	0,062	0,867	0,078	0,061	0,872
OS-GS-N	0,064	0,051	0,914	0,065	0,053	0,911	0,065	0,051	0,913	0,064	0,051	0,914	0,063	0,050	0,918
OS-R-GS	0,060	0,048	0,926	0,061	0,050	0,922	0,060	0,048	0,925	0,060	0,049	0,925	0,058	0,046	0,929
MNS-GS-N-R	0,053	0,042	0,941	0,055	0,044	0,937	0,055	0,044	0,938	0,054	0,043	0,940	0,052	0,041	0,944
OS-GS-N-R	0,054	0,044	0,939	0,055	0,044	0,938	0,055	0,044	0,938	0,055	0,043	0,938	0,053	0,042	0,942

Çizelge 4.37. Swish aktivasyon fonksiyonlu LSTM modellerin bulguları

Senaryolar	LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,104	0,082	0,776	0,101	0,079	0,787	0,101	0,079	0,786	0,101	0,079	0,786	0,101	0,079	0,786
OS	0,101	0,081	0,788	0,100	0,079	0,792	0,100	0,080	0,791	0,100	0,080	0,791	0,101	0,080	0,789
GS	0,143	0,114	0,573	0,143	0,114	0,573	0,144	0,114	0,570	0,144	0,114	0,571	0,144	0,114	0,570
N	0,160	0,130	0,468	0,158	0,128	0,481	0,158	0,128	0,481	0,158	0,128	0,481	0,158	0,128	0,481
R	0,206	0,177	0,122	0,206	0,177	0,120	0,206	0,177	0,121	0,206	0,177	0,120	0,206	0,177	0,122
OS-GS	0,077	0,061	0,878	0,076	0,060	0,881	0,076	0,060	0,880	0,076	0,060	0,880	0,076	0,060	0,880
OS-N	0,082	0,064	0,861	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862
OS-R	0,095	0,076	0,811	0,094	0,074	0,815	0,094	0,074	0,816	0,094	0,074	0,815	0,095	0,075	0,814
GS-N	0,121	0,096	0,694	0,120	0,095	0,699	0,120	0,094	0,701	0,121	0,095	0,696	0,121	0,095	0,696
GS-R	0,123	0,097	0,688	0,121	0,095	0,695	0,122	0,095	0,691	0,122	0,095	0,692	0,122	0,096	0,690
N-R	0,155	0,125	0,502	0,153	0,122	0,516	0,153	0,123	0,511	0,152	0,121	0,517	0,154	0,123	0,508
MNS-GS	0,079	0,062	0,871	0,079	0,062	0,870	0,079	0,062	0,871	0,078	0,062	0,872	0,079	0,062	0,870
MNS-N	0,084	0,066	0,853	0,084	0,066	0,854	0,084	0,066	0,853	0,084	0,066	0,854	0,084	0,066	0,854
MNS-R	0,088	0,069	0,841	0,086	0,068	0,846	0,085	0,067	0,848	0,086	0,067	0,847	0,086	0,068	0,845
MNS-R-GS	0,059	0,047	0,927	0,059	0,046	0,927	0,059	0,047	0,926	0,059	0,047	0,927	0,060	0,047	0,926
MNS-R-N	0,079	0,061	0,872	0,078	0,061	0,873	0,078	0,061	0,873	0,078	0,061	0,873	0,078	0,061	0,874
MNS-GS-N	0,063	0,050	0,917	0,065	0,051	0,913	0,064	0,051	0,914	0,064	0,051	0,914	0,064	0,051	0,914
OS-R-N	0,079	0,062	0,869	0,079	0,062	0,870	0,079	0,061	0,870	0,079	0,061	0,870	0,079	0,062	0,870
OS-GS-N	0,064	0,051	0,915	0,065	0,051	0,913	0,065	0,051	0,913	0,064	0,051	0,914	0,064	0,051	0,914
OS-R-GS	0,059	0,048	0,926	0,059	0,047	0,927	0,060	0,048	0,925	0,060	0,048	0,926	0,060	0,048	0,926
MNS-GS-N-R	0,053	0,042	0,941	0,055	0,043	0,938	0,054	0,043	0,939	0,056	0,044	0,936	0,055	0,043	0,938
OS-GS-N-R	0,054	0,043	0,939	0,055	0,044	0,938	0,055	0,044	0,937	0,055	0,044	0,938	0,055	0,044	0,937

Çizelge 4.38. Swish aktivasyon fonksiyonlu Bi-LSTM modellerin bulguları

Senaryolar	Bi-LSTM Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,104	0,082	0,776	0,104	0,083	0,774	0,104	0,082	0,775	0,102	0,080	0,784	0,101	0,079	0,787
OS	0,101	0,081	0,788	0,101	0,081	0,787	0,101	0,081	0,788	0,101	0,081	0,790	0,100	0,079	0,793
GS	0,143	0,114	0,573	0,144	0,114	0,572	0,144	0,114	0,571	0,144	0,114	0,572	0,143	0,114	0,574
N	0,160	0,130	0,467	0,161	0,131	0,465	0,160	0,131	0,466	0,158	0,128	0,479	0,158	0,128	0,481
R	0,206	0,177	0,122	0,206	0,177	0,122	0,206	0,177	0,122	0,206	0,177	0,122	0,206	0,177	0,118
OS-GS	0,077	0,061	0,878	0,077	0,062	0,877	0,076	0,060	0,881	0,076	0,061	0,880	0,076	0,060	0,881
OS-N	0,082	0,064	0,861	0,083	0,065	0,858	0,082	0,064	0,861	0,082	0,064	0,861	0,082	0,064	0,862
OS-R	0,095	0,076	0,811	0,095	0,075	0,813	0,095	0,075	0,814	0,094	0,075	0,815	0,094	0,074	0,816
GS-N	0,121	0,096	0,695	0,122	0,098	0,690	0,121	0,097	0,694	0,120	0,095	0,700	0,120	0,095	0,699
GS-R	0,123	0,097	0,688	0,122	0,097	0,688	0,122	0,097	0,689	0,122	0,095	0,693	0,121	0,095	0,695
N-R	0,155	0,125	0,503	0,155	0,125	0,502	0,155	0,125	0,502	0,153	0,121	0,516	0,153	0,123	0,512
MNS-GS	0,079	0,063	0,870	0,080	0,064	0,868	0,079	0,063	0,870	0,078	0,061	0,873	0,079	0,062	0,871
MNS-N	0,084	0,066	0,853	0,085	0,067	0,848	0,084	0,066	0,853	0,084	0,066	0,853	0,084	0,066	0,854
MNS-R	0,088	0,069	0,841	0,088	0,069	0,840	0,087	0,068	0,843	0,085	0,067	0,849	0,085	0,067	0,849
MNS-R-GS	0,059	0,047	0,927	0,061	0,049	0,923	0,059	0,047	0,928	0,059	0,046	0,928	0,059	0,047	0,927
MNS-R-N	0,078	0,061	0,874	0,079	0,062	0,871	0,077	0,060	0,877	0,077	0,060	0,875	0,077	0,060	0,876
MNS-GS-N	0,064	0,050	0,916	0,064	0,051	0,914	0,063	0,050	0,917	0,064	0,050	0,915	0,064	0,051	0,915
OS-R-N	0,079	0,062	0,869	0,080	0,063	0,866	0,079	0,062	0,869	0,079	0,061	0,870	0,079	0,062	0,869
OS-GS-N	0,064	0,051	0,915	0,064	0,051	0,914	0,064	0,051	0,915	0,064	0,051	0,914	0,064	0,051	0,914
OS-R-GS	0,059	0,047	0,927	0,061	0,049	0,924	0,059	0,048	0,927	0,059	0,047	0,927	0,059	0,047	0,927
MNS-GS-N-R	0,053	0,042	0,943	0,054	0,043	0,940	0,053	0,042	0,942	0,053	0,042	0,941	0,053	0,042	0,941
OS-GS-N-R	0,054	0,043	0,940	0,054	0,043	0,939	0,053	0,042	0,942	0,054	0,042	0,940	0,054	0,043	0,939

Çizelge 4.39. Swish aktivasyon fonksiyonlu Hibrit modellerin bulguları

Senaryolar	Hibrit Mimarileri														
	1. Mimari			2. Mimari			3. Mimari			4. Mimari			5. Mimari		
	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2	RMSE	MAE	R2
MNS	0,101	0,079	0,787	0,101	0,079	0,787	0,101	0,079	0,787	0,101	0,079	0,790	0,101	0,079	0,788
OS	0,100	0,079	0,793	0,100	0,079	0,794	0,100	0,079	0,794	0,099	0,079	0,795	0,100	0,079	0,794
GS	0,143	0,114	0,574	0,140	0,111	0,590	0,141	0,111	0,589	0,140	0,110	0,591	0,141	0,110	0,589
N	0,158	0,128	0,481	0,158	0,128	0,480	0,158	0,128	0,481	0,158	0,128	0,481	0,158	0,128	0,481
R	0,206	0,177	0,118	0,204	0,174	0,132	0,204	0,174	0,132	0,204	0,174	0,132	0,204	0,174	0,132
OS-GS	0,076	0,060	0,881	0,075	0,059	0,884	0,075	0,059	0,885	0,074	0,058	0,885	0,074	0,058	0,886
OS-N	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,862	0,082	0,064	0,861	0,082	0,064	0,862
OS-R	0,094	0,074	0,816	0,092	0,072	0,822	0,093	0,073	0,821	0,092	0,072	0,823	0,093	0,072	0,822
GS-N	0,120	0,095	0,699	0,118	0,093	0,710	0,118	0,093	0,709	0,118	0,093	0,710	0,118	0,093	0,711
GS-R	0,121	0,095	0,695	0,120	0,093	0,703	0,120	0,093	0,701	0,119	0,092	0,708	0,119	0,092	0,707
N-R	0,153	0,123	0,512	0,152	0,121	0,521	0,153	0,121	0,517	0,151	0,120	0,524	0,152	0,120	0,523
MNS-GS	0,079	0,062	0,871	0,077	0,060	0,877	0,078	0,061	0,873	0,076	0,059	0,879	0,077	0,060	0,878
MNS-N	0,084	0,066	0,854	0,084	0,066	0,854	0,084	0,066	0,854	0,084	0,066	0,853	0,084	0,066	0,854
MNS-R	0,085	0,067	0,849	0,083	0,065	0,857	0,083	0,065	0,856	0,083	0,065	0,857	0,083	0,065	0,856
MNS-R-GS	0,059	0,047	0,927	0,057	0,044	0,933	0,057	0,045	0,932	0,057	0,045	0,933	0,057	0,044	0,933
MNS-R-N	0,077	0,060	0,876	0,075	0,058	0,883	0,075	0,058	0,883	0,075	0,058	0,884	0,075	0,058	0,884
MNS-GS-N	0,064	0,051	0,915	0,063	0,050	0,919	0,063	0,050	0,916	0,062	0,050	0,919	0,063	0,050	0,918
OS-R-N	0,079	0,062	0,869	0,078	0,060	0,873	0,079	0,061	0,871	0,078	0,060	0,873	0,079	0,061	0,871
OS-GS-N	0,064	0,051	0,914	0,063	0,050	0,917	0,064	0,051	0,915	0,063	0,049	0,919	0,064	0,050	0,916
OS-R-GS	0,059	0,047	0,927	0,057	0,045	0,932	0,058	0,045	0,931	0,057	0,045	0,932	0,058	0,045	0,931
MNS-GS-N-R	0,053	0,042	0,941	0,051	0,040	0,946	0,052	0,041	0,944	0,051	0,040	0,946	0,051	0,040	0,946
OS-GS-N-R	0,054	0,043	0,939	0,051	0,040	0,945	0,054	0,043	0,939	0,052	0,040	0,945	0,052	0,040	0,945

Çizelge 4.40. Swish aktivasyon fonksiyonlu tüm model bulgularının ortalama ve standart sapması

Senaryolar	ÇKA		1D-CNN		LSTM		Bi-LSTM		Hibrit	
	RMSE*	R2*	RMSE*	R2*	RMSE*	RMSE*	R2*	RMSE*	R2*	RMSE*
MNS	0,103 ± (0,0005)	0,780 ± (0,002)	0,102 ± (0,0009)	0,782 ± (0,004)	0,102 ± (0,0013)	0,784 ± (0,005)	0,103 ± (0,0014)	0,779 ± (0,006)	0,101 ± (0,0000)	0,788 ± (0,001)
OS	0,102 ± (0,0005)	0,778 ± (0,001)	0,100 ± (0,0000)	0,792 ± (0,001)	0,100 ± (0,0005)	0,790 ± (0,002)	0,101 ± (0,0004)	0,789 ± (0,002)	0,100 ± (0,0004)	0,794 ± (0,001)
GS	0,142 ± (0,0005)	0,583 ± (0,002)	0,143 ± (0,0012)	0,576 ± (0,008)	0,144 ± (0,0005)	0,571 ± (0,002)	0,144 ± (0,0005)	0,572 ± (0,001)	0,141 ± (0,0012)	0,587 ± (0,007)
N	0,158 ± (0,0004)	0,451 ± (0,003)	0,161 ± (0,0000)	0,464 ± (0,000)	0,158 ± (0,0009)	0,478 ± (0,006)	0,159 ± (0,0013)	0,472 ± (0,008)	0,158 ± (0,0000)	0,481 ± (0,000)
R	0,203 ± (0,0005)	0,119 ± (0,001)	0,205 ± (0,0000)	0,126 ± (0,001)	0,206 ± (0,0000)	0,121 ± (0,001)	0,206 ± (0,0000)	0,121 ± (0,002)	0,204 ± (0,0009)	0,129 ± (0,006)
OS-GS	0,075 ± (0,0008)	0,880 ± (0,002)	0,076 ± (0,0008)	0,880 ± (0,002)	0,076 ± (0,0004)	0,880 ± (0,001)	0,076 ± (0,0005)	0,879 ± (0,002)	0,075 ± (0,0008)	0,884 ± (0,002)
OS-N	0,084 ± (0,0000)	0,850 ± (0,001)	0,082 ± (0,0004)	0,860 ± (0,002)	0,082 ± (0,0000)	0,862 ± (0,000)	0,082 ± (0,0004)	0,861 ± (0,002)	0,082 ± (0,0000)	0,862 ± (0,000)
OS-R	0,094 ± (0,0000)	0,813 ± (0,001)	0,094 ± (0,0000)	0,817 ± (0,001)	0,094 ± (0,0005)	0,814 ± (0,002)	0,095 ± (0,0005)	0,814 ± (0,002)	0,093 ± (0,0008)	0,821 ± (0,003)
GS-N	0,119 ± (0,0008)	0,703 ± (0,005)	0,121 ± (0,0019)	0,693 ± (0,009)	0,121 ± (0,0005)	0,697 ± (0,003)	0,121 ± (0,0008)	0,696 ± (0,004)	0,118 ± (0,0009)	0,708 ± (0,005)
GS-R	0,122 ± (0,0009)	0,692 ± (0,004)	0,122 ± (0,0013)	0,693 ± (0,006)	0,122 ± (0,0007)	0,691 ± (0,003)	0,122 ± (0,0007)	0,691 ± (0,003)	0,120 ± (0,0008)	0,703 ± (0,005)
N-R	0,153 ± (0,0007)	0,509 ± (0,005)	0,154 ± (0,0004)	0,505 ± (0,001)	0,153 ± (0,0011)	0,511 ± (0,006)	0,154 ± (0,0011)	0,507 ± (0,007)	0,152 ± (0,0008)	0,519 ± (0,005)
MNS-GS	0,078 ± (0,0009)	0,876 ± (0,003)	0,079 ± (0,0011)	0,871 ± (0,004)	0,079 ± (0,0004)	0,871 ± (0,001)	0,079 ± (0,0007)	0,870 ± (0,002)	0,077 ± (0,0011)	0,876 ± (0,003)
MNS-N	0,085 ± (0,0004)	0,851 ± (0,002)	0,084 ± (0,0010)	0,854 ± (0,003)	0,084 ± (0,0000)	0,854 ± (0,001)	0,084 ± (0,0004)	0,852 ± (0,002)	0,084 ± (0,0000)	0,854 ± (0,000)
MNS-R	0,089 ± (0,0008)	0,836 ± (0,002)	0,086 ± (0,0012)	0,847 ± (0,004)	0,086 ± (0,0011)	0,845 ± (0,003)	0,087 ± (0,0015)	0,844 ± (0,004)	0,083 ± (0,0009)	0,855 ± (0,003)
MNS-R-GS	0,061 ± (0,0013)	0,918 ± (0,003)	0,059 ± (0,0015)	0,926 ± (0,003)	0,059 ± (0,0004)	0,927 ± (0,001)	0,059 ± (0,0009)	0,927 ± (0,002)	0,057 ± (0,0009)	0,932 ± (0,003)
MNS-R-N	0,079 ± (0,0007)	0,874 ± (0,002)	0,077 ± (0,0014)	0,877 ± (0,004)	0,078 ± (0,0004)	0,873 ± (0,001)	0,078 ± (0,0009)	0,875 ± (0,002)	0,075 ± (0,0009)	0,882 ± (0,003)
MNS-GS-N	0,064 ± (0,0008)	0,917 ± (0,002)	0,064 ± (0,0004)	0,916 ± (0,002)	0,064 ± (0,0007)	0,914 ± (0,002)	0,064 ± (0,0004)	0,915 ± (0,001)	0,063 ± (0,0007)	0,917 ± (0,002)
OS-R-N	0,077 ± (0,0000)	0,877 ± (0,001)	0,079 ± (0,0008)	0,869 ± (0,002)	0,079 ± (0,0000)	0,870 ± (0,000)	0,079 ± (0,0004)	0,869 ± (0,002)	0,079 ± (0,0005)	0,871 ± (0,002)
OS-GS-N	0,063 ± (0,0005)	0,917 ± (0,001)	0,064 ± (0,0008)	0,914 ± (0,003)	0,064 ± (0,0005)	0,914 ± (0,001)	0,064 ± (0,0000)	0,914 ± (0,001)	0,064 ± (0,0005)	0,916 ± (0,002)
OS-R-GS	0,059 ± (0,0007)	0,924 ± (0,002)	0,060 ± (0,0011)	0,925 ± (0,003)	0,060 ± (0,0005)	0,926 ± (0,001)	0,059 ± (0,0009)	0,926 ± (0,001)	0,058 ± (0,0008)	0,931 ± (0,002)
MNS-GS-N-R	0,054 ± (0,0005)	0,941 ± (0,001)	0,054 ± (0,0013)	0,940 ± (0,003)	0,055 ± (0,0011)	0,938 ± (0,002)	0,053 ± (0,0004)	0,941 ± (0,001)	0,052 ± (0,0009)	0,945 ± (0,002)
OS-GS-N-R	0,054 ± (0,0004)	0,940 ± (0,001)	0,054 ± (0,0009)	0,939 ± (0,002)	0,055 ± (0,0004)	0,938 ± (0,001)	0,054 ± (0,0004)	0,940 ± (0,001)	0,053 ± (0,0013)	0,943 ± (0,003)

*Ortalama ve standart sapma

Çizelge 4.41. ETo tahmin etmede Relu fonksiyonlu mimariler ve Swish fonksiyonlu mimarilerin performans karşılaştırması

Senaryolar	ÇKA		1D-CNN		LSTM		Bi-LSTM		Hibrit	
	Relu*	Swish*	Relu*	Swish*	Relu*	Swish*	Relu*	Swish*	Relu*	Swish*
MNS	0,780 (±0,004)	0,780 ± (0,002)	0,792 (±0,001)	0,782 ± (0,004)	0,791 (±0,001)	0,784 ± (0,005)	0,791 (±0,001)	0,779 ± (0,006)	0,793 (±0,001)	0,788 ± (0,001)
OS	0,794 (±0,002)	0,778 ± (0,001)	0,794 (±0,001)	0,792 ± (0,001)	0,793 (±0,001)	0,790 ± (0,002)	0,793 (±0,001)	0,789 ± (0,002)	0,795 (±0,001)	0,794 ± (0,001)
GS	0,587 (±0,021)	0,583 ± (0,002)	0,593 (±0,000)	0,576 ± (0,008)	0,590 (±0,003)	0,571 ± (0,002)	0,591 (±0,002)	0,572 ± (0,001)	0,593 (±0,000)	0,587 ± (0,007)
N	0,481 (±0,017)	0,451 ± (0,003)	0,480 (±0,000)	0,464 ± (0,000)	0,480 (±0,001)	0,478 ± (0,006)	0,480 (±0,001)	0,472 ± (0,008)	0,477 (±0,000)	0,481 ± (0,000)
R	0,127 (±0,011)	0,119 ± (0,001)	0,132 (±0,001)	0,126 ± (0,001)	0,132 (±0,001)	0,121 ± (0,001)	0,131 (±0,001)	0,121 ± (0,002)	0,132 (±0,000)	0,129 ± (0,006)
OS-GS	0,883 (±0,005)	0,880 ± (0,002)	0,887 (±0,001)	0,880 ± (0,002)	0,887 (±0,001)	0,880 ± (0,001)	0,888 (±0,001)	0,879 ± (0,002)	0,888 (±0,001)	0,884 ± (0,002)
OS-N	0,860 (±0,004)	0,850 ± (0,001)	0,861 (±0,001)	0,860 ± (0,002)	0,862 (±0,000)	0,862 ± (0,000)	0,862 (±0,001)	0,861 ± (0,002)	0,860 (±0,001)	0,862 ± (0,000)
OS-R	0,813 (±0,006)	0,813 ± (0,001)	0,823 (±0,000)	0,817 ± (0,001)	0,822 (±0,002)	0,814 ± (0,002)	0,823 (±0,000)	0,814 ± (0,002)	0,823 (±0,001)	0,821 ± (0,003)
GS-N	0,714 (±0,005)	0,703 ± (0,005)	0,713 (±0,001)	0,693 ± (0,009)	0,710 (±0,002)	0,697 ± (0,003)	0,710 (±0,002)	0,696 ± (0,004)	0,713 (±0,001)	0,708 ± (0,005)
GS-R	0,710 (±0,013)	0,692 ± (0,004)	0,708 (±0,000)	0,693 ± (0,006)	0,708 (±0,001)	0,691 ± (0,003)	0,709 (±0,002)	0,691 ± (0,003)	0,709 (±0,002)	0,703 ± (0,005)
N-R	0,517 (±0,013)	0,509 ± (0,005)	0,523 (±0,001)	0,505 ± (0,001)	0,523 (±0,001)	0,511 ± (0,006)	0,524 (±0,002)	0,507 ± (0,007)	0,525 (±0,002)	0,519 ± (0,005)
MNS-GS	0,872 (±0,010)	0,876 ± (0,003)	0,881 (±0,001)	0,871 ± (0,004)	0,879 (±0,001)	0,871 ± (0,001)	0,880 (±0,001)	0,870 ± (0,002)	0,881 (±0,001)	0,876 ± (0,003)
MNS-N	0,855 (±0,007)	0,851 ± (0,002)	0,860 (±0,000)	0,854 ± (0,003)	0,860 (±0,002)	0,854 ± (0,001)	0,860 (±0,000)	0,852 ± (0,002)	0,860 (±0,001)	0,854 ± (0,000)
MNS-R	0,852 (±0,002)	0,836 ± (0,002)	0,858 (±0,001)	0,847 ± (0,004)	0,858 (±0,001)	0,845 ± (0,003)	0,858 (±0,002)	0,844 ± (0,004)	0,858 (±0,002)	0,855 ± (0,003)
MNS-R-GS	0,932 (±0,002)	0,918 ± (0,003)	0,936 (±0,000)	0,926 ± (0,003)	0,934 (±0,001)	0,927 ± (0,001)	0,935 (±0,001)	0,927 ± (0,002)	0,935 (±0,001)	0,932 ± (0,003)
MNS-R-N	0,879 (±0,011)	0,874 ± (0,002)	0,887 (±0,000)	0,877 ± (0,004)	0,884 (±0,001)	0,873 ± (0,001)	0,886 (±0,002)	0,875 ± (0,002)	0,887 (±0,001)	0,882 ± (0,003)
MNS-GS-N	0,915 (±0,007)	0,917 ± (0,002)	0,922 (±0,001)	0,916 ± (0,002)	0,920 (±0,001)	0,914 ± (0,002)	0,920 (±0,003)	0,915 ± (0,001)	0,921 (±0,001)	0,917 ± (0,002)
OS-R-N	0,875 (±0,002)	0,877 ± (0,001)	0,876 (±0,001)	0,869 ± (0,002)	0,875 (±0,001)	0,870 ± (0,000)	0,875 (±0,001)	0,869 ± (0,002)	0,876 (±0,001)	0,871 ± (0,002)
OS-GS-N	0,918 (±0,003)	0,917 ± (0,001)	0,921 (±0,001)	0,914 ± (0,003)	0,919 (±0,001)	0,914 ± (0,001)	0,920 (±0,000)	0,914 ± (0,001)	0,919 (±0,001)	0,916 ± (0,002)
OS-R-GS	0,932 (±0,003)	0,924 ± (0,002)	0,934 (±0,001)	0,925 ± (0,003)	0,934 (±0,001)	0,926 ± (0,001)	0,934 (±0,001)	0,926 ± (0,001)	0,933 (±0,000)	0,931 ± (0,002)
MNS-GS-N-R	0,945 (±0,002)	0,941 ± (0,001)	0,949 (±0,001)	0,940 ± (0,003)	0,947 (±0,001)	0,938 ± (0,002)	0,948 (±0,002)	0,941 ± (0,001)	0,948 (±0,001)	0,945 ± (0,002)
OS-GS-N-R	0,948 (±0,001)	0,940 ± (0,001)	0,948 (±0,001)	0,939 ± (0,002)	0,946 (±0,001)	0,938 ± (0,001)	0,946 (±0,001)	0,940 ± (0,001)	0,947 (±0,000)	0,943 ± (0,003)

*Ortalama ve standart sapma

4.7. Eğitimde Kullanılan Veriler ile Tahmin Verimliliği Arasındaki İlişki

Eğitimde kullanılan veriler ile tahmin verimliliği arasındaki ilişkiyi belirlemek amacıyla bir çalışma yapılmış ve 7 veri kombinasyonu seçilmiştir (Çizelge 4.42). Bu amaçla, kötü performanslı veri kombinasyonları elenerek farklı sayıda meteorolojik parametreden oluşan kombinasyonlar seçilmiş ve karıştırılmış durumda ki veri kombinasyonları kullanılmıştır.

Çizelge 4.42. Veri miktarının tahmin verimliliği üzerine etkisinin araştırılmasında kullanılan veri kombinasyonları

No	Veri Kombinasyonlarında bulunan parametreler
1	Maksimum- Minimum Sıcaklık
2	Ortalama Sıcaklık
3	Ortalama Sıcaklık + Güneş süresi
4	Ortalama Sıcaklık + Nispi Nem
5	Ortalama Sıcaklık + Güneş süresi+ Nispi Nem
6	Ortalama Sıcaklık + Güneş süresi + Rüzgâr hızı
7	Ortalama Sıcaklık + Güneş süresi+ Nispi Nem + Rüzgâr hızı

ETo tahmin verimliliği mevcut veri miktarına bağlı olduğundan, iyi ve kabul edilebilir ETo tahmini elde edebilmek için seçilen mimariler 1 yıllık, 2 yıllık, 3 yıllık, 4 yıllık, 5 yıllık, 10 yıllık, 20 yıllık ve 26 yıllık verilerle eğitilip 5 yıl için ETo tahmini test edilmiştir. Bu deneme, optimize edilen mimarilerde her mimari türünden, tüm veri kombinasyonlarında mimari performansının ortalamasına göre sadece bir mimari seçilerek yapılmıştır. Hatırlanacağı üzere seçilen mimariler Çizelge 4.16-4.20'de kımızıyla işaretlenmiştir.

Elde edilen sonuçlar Çizelge 4.43'te verilmiştir. Çizelgeden, ETo tahmin etmede kullanılan veri miktarındaki artışın tahmin doğruluğunu arttırması üzerine etkisinin çok büyük olmadığı görülmektedir. ETo tahmin doğruluğunu araştırmak için 1 yıllık veri miktarıyla eğitilen modeller, 26 yıllık veri miktarıyla eğitilen modellerle performans bakımından benzer sonuçlar vermiştir. Eğitimde kullanılan veri miktarı değiştiğinde 5 yıllık ETo tahmin etmede modellerin performansı R^2 ortalaması ve standart sapması hesaplanarak Çizelge 4.44'te verilmiştir. Sonuç olarak, ETo tahmin etmek için bir yıllık

meteorolojik verinin derin öğrenme modellerinde kullanılabileceği söylenebilir, ayrıca veri miktarı bir yıldan 26 yıla yükseldiğinde, R^2 değeri yaklaşık 0,012 artmıştır.

ETo tahmininde, meteoroloji verilerinin verimli bir şekilde kullanılmasını sağlayan en iyi model Hibrit mimaridir. Şekil 4.26'dan izleneceği üzere, ETo tahmininde Hibrit mimari, ÇKA, 1D-CNN, LSTM ve Bi-LSTM mimarilerine göre iyi performans göstermiştir. Ek olarak, veri miktarı az olsa dahi, en iyisi olduğu söylenebilir. Bu nedenle, ETo tahmininde veriler az olduğunda, diğer mimarilerden ziyade Hibrit mimari kullanılması önerilmektedir.

Çizelge 4.43. Veri miktarının tahmin verimliliği üzerine etkisi

ÇKA Mimari																
Senaryo	1 Yıl		2 Yıl		3 Yıl		4 Yıl		5 Yıl		10 Yıl		20 Yıl		26 Yıl	
	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2
MNS	0,104	0,777	0,102	0,785	0,101	0,786	0,101	0,787	0,101	0,786	0,102	0,783	0,1	0,792	0,101	0,782
OS	0,1	0,783	0,1	0,786	0,1	0,783	0,1	0,785	0,1	0,783	0,1	0,786	0,1	0,786	0,099	0,793
OS-GS	0,077	0,877	0,077	0,875	0,077	0,878	0,077	0,876	0,077	0,877	0,076	0,88	0,075	0,882	0,075	0,883
OS-N	0,082	0,851	0,082	0,85	0,083	0,849	0,082	0,852	0,082	0,852	0,082	0,852	0,082	0,853	0,082	0,856
OS-GS-N	0,067	0,903	0,065	0,909	0,064	0,912	0,063	0,914	0,063	0,915	0,062	0,919	0,062	0,918	0,063	0,918
OS-GS-R	0,064	0,913	0,062	0,918	0,059	0,924	0,06	0,923	0,06	0,924	0,06	0,924	0,058	0,929	0,056	0,936
OS-GS-R-N	0,056	0,932	0,055	0,935	0,053	0,939	0,054	0,937	0,053	0,939	0,053	0,94	0,052	0,942	0,049	0,95

1D-CNN Mimari																
Senaryo	1 Yıl		2 Yıl		3 Yıl		4 Yıl		5 Yıl		10 Yıl		20 Yıl		26 Yıl	
	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2
MNS	0,104	0,775	0,103	0,78	0,1	0,79	0,101	0,79	0,1	0,79	0,104	0,777	0,101	0,79	0,1	0,793
OS	0,1	0,792	0,1	0,793	0,099	0,795	0,1	0,794	0,099	0,795	0,101	0,787	0,1	0,793	0,099	0,795
OS-GS	0,075	0,883	0,075	0,884	0,075	0,884	0,075	0,883	0,075	0,883	0,075	0,884	0,074	0,887	0,074	0,886
OS-N	0,083	0,858	0,083	0,857	0,082	0,86	0,082	0,86	0,082	0,861	0,082	0,861	0,082	0,862	0,082	0,861
OS-GS-N	0,066	0,91	0,065	0,912	0,064	0,915	0,064	0,914	0,064	0,916	0,062	0,919	0,062	0,921	0,062	0,921
OS-GS-R	0,06	0,925	0,059	0,927	0,058	0,93	0,058	0,929	0,057	0,932	0,057	0,933	0,056	0,934	0,057	0,933
OS-GS-R-N	0,055	0,937	0,058	0,929	0,053	0,943	0,052	0,943	0,052	0,944	0,051	0,945	0,051	0,946	0,05	0,948

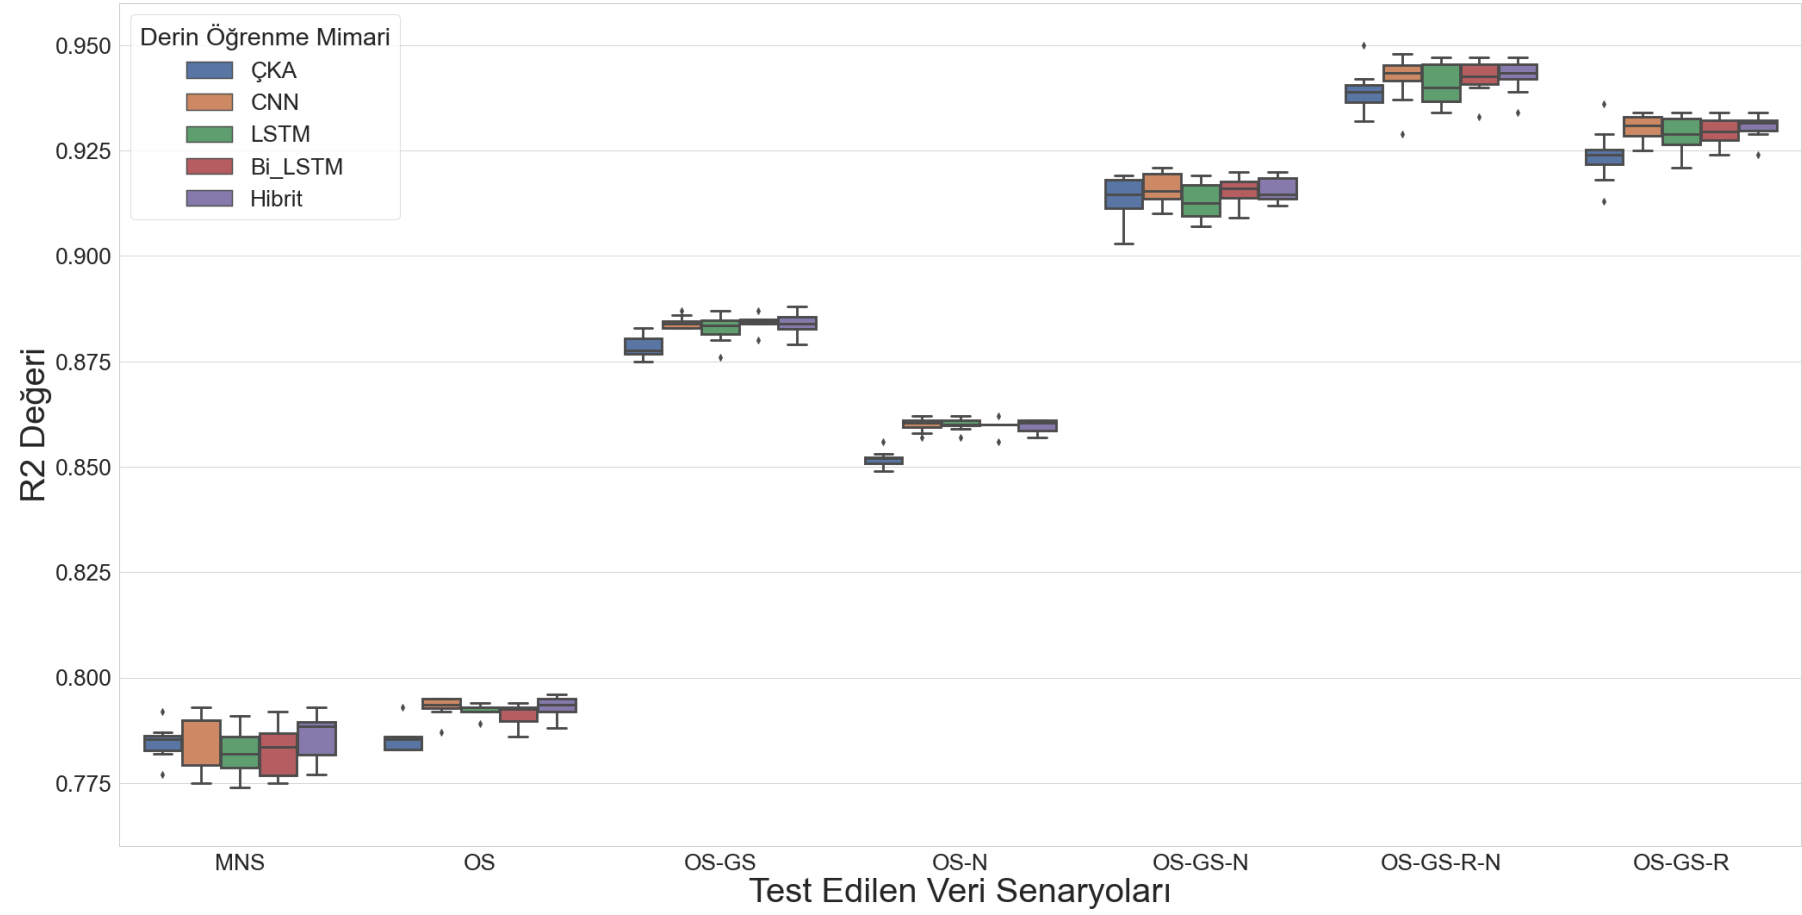
LSTM Mimari																
Senaryo	1 Yıl		2 Yıl		3 Yıl		4 Yıl		5 Yıl		10 Yıl		20 Yıl		26 Yıl	
	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2
MNS	0,104	0,774	0,103	0,779	0,103	0,778	0,102	0,782	0,102	0,782	0,102	0,785	0,101	0,789	0,1	0,791
OS	0,1	0,793	0,1	0,793	0,101	0,789	0,1	0,793	0,1	0,794	0,1	0,792	0,1	0,793	0,1	0,792
OS-GS	0,077	0,876	0,076	0,88	0,075	0,884	0,075	0,884	0,075	0,883	0,075	0,882	0,074	0,887	0,074	0,887
OS-N	0,083	0,857	0,082	0,859	0,082	0,861	0,082	0,86	0,082	0,86	0,082	0,86	0,082	0,861	0,082	0,862
OS-GS-N	0,066	0,908	0,067	0,907	0,066	0,91	0,065	0,912	0,065	0,913	0,063	0,916	0,062	0,919	0,062	0,919
OS-GS-R	0,062	0,921	0,06	0,925	0,059	0,927	0,059	0,928	0,058	0,93	0,057	0,932	0,056	0,934	0,056	0,934
OS-GS-R-N	0,056	0,934	0,056	0,936	0,055	0,937	0,053	0,942	0,055	0,938	0,052	0,945	0,05	0,947	0,051	0,947

Çizelge 4.43. Veri miktarının tahmin verimliliği üzerine etkisi (devamı)

Bi-LSTM Mimari																
Senaryo	1 Yıl		2 Yıl		3 Yıl		4 Yıl		5 Yıl		10 Yıl		20 Yıl		26 Yıl	
	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2
MNS	0,104	0,775	0,104	0,776	0,102	0,785	0,102	0,783	0,102	0,784	0,104	0,777	0,1	0,792	0,1	0,792
OS	0,101	0,789	0,1	0,793	0,1	0,792	0,1	0,793	0,101	0,79	0,101	0,786	0,1	0,793	0,099	0,794
OS-GS	0,076	0,88	0,075	0,884	0,075	0,884	0,074	0,885	0,075	0,884	0,074	0,885	0,074	0,885	0,074	0,887
OS-N	0,083	0,856	0,082	0,86	0,082	0,86	0,082	0,86	0,082	0,86	0,082	0,86	0,082	0,862	0,082	0,86
OS-GS-N	0,066	0,909	0,065	0,913	0,064	0,914	0,064	0,915	0,063	0,917	0,063	0,917	0,062	0,92	0,062	0,92
OS-GS-R	0,061	0,924	0,059	0,928	0,058	0,929	0,06	0,926	0,058	0,93	0,057	0,932	0,056	0,934	0,057	0,933
OS-GS-R-N	0,057	0,933	0,054	0,94	0,053	0,941	0,053	0,941	0,052	0,944	0,051	0,945	0,05	0,947	0,05	0,947
Hibrit Mimari																
Senaryo	1 Yıl		2 Yıl		3 Yıl		4 Yıl		5 Yıl		10 Yıl		20 Yıl		26 Yıl	
	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2	RMSE	R2
MNS	0,103	0,781	0,103	0,782	0,101	0,789	0,101	0,788	0,101	0,789	0,104	0,777	0,1	0,791	0,1	0,793
OS	0,101	0,789	0,1	0,793	0,099	0,795	0,099	0,795	0,099	0,794	0,101	0,788	0,1	0,793	0,099	0,796
OS-GS	0,076	0,879	0,075	0,883	0,075	0,885	0,075	0,883	0,075	0,882	0,074	0,885	0,074	0,887	0,073	0,888
OS-N	0,083	0,857	0,083	0,857	0,082	0,86	0,082	0,861	0,082	0,859	0,082	0,861	0,082	0,861	0,082	0,861
OS-GS-N	0,065	0,912	0,065	0,912	0,064	0,914	0,064	0,914	0,064	0,915	0,063	0,918	0,062	0,92	0,062	0,92
OS-GS-R	0,06	0,924	0,058	0,929	0,058	0,931	0,058	0,93	0,057	0,932	0,057	0,933	0,057	0,934	0,057	0,932
OS-GS-R-N	0,057	0,934	0,054	0,939	0,052	0,943	0,052	0,943	0,052	0,945	0,052	0,944	0,05	0,947	0,05	0,947

Çizelge 4.44. Veri miktarı değiştiğinde ETo tahmini için R^2 ortalama ve standart sapması

Senaryolar	Derin öğrenme mimarileri				
	ÇKA	1D-CNN	LSTM	Bi-LSTM	Hibrit
MNS	0,785± (0,004)	0,786± (0,007)	0,783± (0,006)	0,783± (0,007)	0,786± (0,006)
OS	0,786± (0,003)	0,793± (0,003)	0,792± (0,002)	0,791± (0,003)	0,793± (0,003)
OS-GS	0,879± (0,003)	0,884± (0,001)	0,883± (0,004)	0,884± (0,002)	0,884± (0,003)
OS-N	0,852± (0,002)	0,860± (0,002)	0,860± (0,002)	0,860± (0,002)	0,860± (0,002)
OS-GS-N	0,914± (0,005)	0,916± (0,004)	0,913± (0,005)	0,916± (0,004)	0,916± (0,003)
OS-GS-R	0,924± (0,007)	0,930± (0,003)	0,929± (0,005)	0,930± (0,003)	0,931± (0,003)
SO-GS-R-N	0,939± (0,005)	0,942± (0,006)	0,941± (0,005)	0,942± (0,005)	0,943± (0,004)



Şekil 4.26. Veri miktarının tahmin verimliliği üzerine etkisi

5. SONUÇ

Bu çalışmada, Bursa merkez meteoroloji istasyonu 1990-2020 yılları arası günlük iklim verilerinden, az ve çok parametrelili olarak oluşturulan veri kombinasyonlarının ETo tahmin etmedeki performansları derin öğrenme ÇKA, CNN, LSTM, Bi-LSTM ve hibrit mimarileri kullanılarak test edilmiş ve sonuçlar aşağıda özetlenmiştir.

Günlük ETo tahmin etmek amacıyla kullanılan veri kombinasyonlarının performansı, veri kombinasyonunun hangi parametreden oluştuğuna bağlı olarak değişmiştir. Tek parametreden oluşan veri kombinasyonlarından sadece sıcaklık parametrelili kombinasyonun ETo tahmin etmede kullanılabilir olduğu söylenebilir. Rüzgâr hızı, nispi nem ve güneş süresi parametrelerinin tek başına ETo tahmininde tercih edilmemesi gerektiği belirlenmiştir. ETo tahmininde iki parametrelili veri kombinasyonlarından sırasıyla sıcaklık-güneş süresi ve sıcaklık-nispi nem parametrelili kombinasyonların tercih edilebileceğini söylemek mümkündür. En iyi düzeyde elde edilebilen ETo tahmini için üç parametreden fazla oluşan veri kombinasyonları kullanılmalıdır. ETo tahmin etmede en iyi sonuç veren üç parametrelili veri kombinasyonu, sıcaklık-güneş süresi-rüzgâr hızı parametrelili kombinasyon olmuştur. Bu çalışmanın sonuçlarına göre, herhangi bir derin öğrenme yöntemi ile yüksek verimli ETo tahmin etmek için mevcut olan meteoroloji parametreleri seçilirken; ortalama sıcaklık veya minimum-maksimum sıcaklık, ortalama güneş süresi, ortalama rüzgâr hızı ve ortalama nispi nem sıralamasının kullanılması önerilebilir. Bu sıra, meteoroloji verilerinin azalan önem sırasına göre düzenlenmiştir. Ayrıca, ETo değerinin iyi bir şekilde tahmin edilmesi için, önerilen sıradaki ilk iki meteoroloji parametresinin elde edilmesine dikkat edilmesi önerilmektedir.

ETo tahmin etmede derin öğrenme modelleri türlerinin performansları değerlendirildiğinde, en yüksek performansları 1D-CNN modeller ve hibrit modeller göstermişlerdir. Tekrarlayan sinir ağı yapısına sahip Bi-LSTM modellerin performansı, LSTM modellerin performansından biraz daha iyi bulunmuştur. ETo tahmin etmede en düşük performans ÇKA modellerde belirlenmiştir. ETo tahmin etmede, ÇKA için dört katmanlı mimariler, iki ve üç katmanlı olarak oluşan mimarilerden çok daha iyi performans göstermiştir. 1D-CNN için iki, üç ve dört evrimsel katmanlı olan mimariler,

tek katmanlı olan hariç performansları eşit bulunmuş ve ETo tahmin etmede iki evrimsel katmandan oluşturulan mimari yeterli olmuş, ek olarak evrimsel katmanındaki çekirdek boyutunun değiştirilmesi tahmin performansı üzerine hiçbir etki göstermemiştir. LSTM ve Bi-LSTM ile ilgili mimariler bir LSTM katmanından oluşmalıdır ve ETo tahmin etmek için mimarilerin çalıştırılması zordur. Hibrit mimari ise bir evrimsel katmanı, iki LSTM katmanı ve sonunda algılayıcı ile üç katmandan oluşan mimarisiyle en iyi ETo tahminini sağlayabilmiştir.

Optimizasyon sırasında karıştırılmamış veri kombinasyonları ile eğitilen modeller, karıştırılmış veri kombinasyonları ile eğitilen modellerden biraz daha düşük performans göstermişlerdir. Genel olarak, modeller karıştırılmış halde veri kombinasyonları oluşturulduğunda daha iyi bir performans verebilmişlerdir. Bundan dolayı, farklı bölgelerde ETo tahmin etmede o bölgelerin meteoroloji parametrelerini kullanma potansiyeli olabileceği söylenilebilir.

Bu çalışmada, optimize edilen model mimarilerinde aktivasyon fonksiyonu olarak Relu yerine Swish kullanıldığında modellerin ETo tahmin performansı düşmüştür.

Modellerin eğitiminde kullanılan veri miktarının değiştirilmesinin ETo tahmin doğruluğuna etkisi çok büyük olmamıştır. Sonuç olarak, 1 yıllık veriyle eğitilen modelin performansı 26 yıllık veriyle eğitilen modelin performansına çok yakın bulunmuş ve tüm veri senaryolarında 26 yıllık veri kullanıldığında bir yıllık veriden R^2 değeri yaklaşık 0,012 kadar fazla olmuştur. Ayrıca derin öğrenme mimarilerinin performansı bakımından, ETo tahmin etmede az veri kullanıldığında Hibrit mimari diğer mimarilerden yüksek performans göstermiştir.

KAYNAKLAR

- Afzaal, H., Farooque, A. A., Abbas, F., Acharya, B., & Esau, T. (2020). Computation of evapotranspiration with artificial intelligence for precision water resource management. *Applied Sciences (Switzerland)*, *10*(5), 1–17. <https://doi.org/10.3390/app10051621>
- Andrew W.Trask. (2019). *Deep Learning* (first; L. W. Christina Taylor, Aleksandar Dragosavljevic, ed.). United States of America: Manning.
- 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. <https://doi.org/10.1016/j.compag.2016.11.011>
- Barnston, A., (1992). Correspondence among the Correlation [root mean square error] and Heidke Verification Measures; Refinement of the Heidke Score.
- Charu C. Aggarwal. (2018). Neural Networks and Deep Learning. In *Artificial Intelligence*. <https://doi.org/10.1201/b22400-15>
- Chen, Z., Zhu, Z., Jiang, H., & Sun, S. (2020). Estimating daily reference evapotranspiration based on limited meteorological data using deep learning and classical machine learning methods. *Journal of Hydrology*, *591*(July), 125286. <https://doi.org/10.1016/j.jhydrol.2020.125286>
- de Oliveira e Lucas, P., Alves, M. A., de Lima e Silva, P. C., & Guimarães, F. G. (2020). Reference evapotranspiration time series forecasting with ensemble of convolutional neural networks. *Computers and Electronics in Agriculture*, *177*(May), 105700. <https://doi.org/10.1016/j.compag.2020.105700>
- Factors, E. (1992). *Reference evapotranspiration factors*. *117*(5), 758–773.
- FAO. (2020). Agriculture 4.0: Start Agricultural robotics and automated equipment for sustainable crop production. *Integrated Crop Management*, *24*.
- Fatih Sekendur, Ali Ünlükara, B. C. (2018). Estimation of Daily Reference Evapotranspiration by Using Artificial Neural Networks For The Province of Kayseri ABSTRACT. *Erciyes Tarım ve Hayvan Bilimleri Dergisi*, *1*(1),25-37 *Kayseri*, *1*(1), 25–37.
- Feng, Y., Cui, N., Gong, D., Zhang, Q., & Zhao, L. (2017). Evaluation of random forests and generalized regression neural networks for daily reference evapotranspiration modelling. *Agricultural Water Management*, *193*, 163–173. <https://doi.org/10.1016/j.agwat.2017.08.003>

- Feng, Y., Peng, Y., Cui, N., Gong, D., & Zhang, K. (2017). Modeling reference evapotranspiration using extreme learning machine and generalized regression neural network only with temperature data. *Computers and Electronics in Agriculture*, *136*, 71–78. <https://doi.org/10.1016/j.compag.2017.01.027>
- 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*(February), 106113. <https://doi.org/10.1016/j.agwat.2020.106113>
- 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*(December 2019), 106113. <https://doi.org/10.1016/j.agwat.2020.106113>
- Ferreira, L. B., & da Cunha, F. F. (2020). Multi-step ahead forecasting of daily reference evapotranspiration using deep learning. *Computers and Electronics in Agriculture*, *178*(May), 105728. <https://doi.org/10.1016/j.compag.2020.105728>
- François Chollet. (2018). DEEP LEARNING with Python. In *MANNING*. United States of America.
- Garbin, C., Zhu, X., & Marques, O. (2020). Dropout vs. batch normalization: an empirical study of their impact to deep learning. *Multimedia Tools and Applications*, *79*(19–20), 12777–12815. <https://doi.org/10.1007/s11042-019-08453-9>
- Ian Goodfellow and Yoshua Bengio and Aaron Courville. (2016). Deep Learning. In *MIT Press*. Retrieved from <http://www.deeplearningbook.org>
- Kamilaris, A., & Prenafeta-Boldú, F. X. (2018). Deep learning in agriculture: A survey. *Computers and Electronics in Agriculture*, *147*(July 2017), 70–90. <https://doi.org/10.1016/j.compag.2018.02.016>
- Kingma, D. P., & Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.
- Kiranyaz, S., Avci, O., Abdeljaber, O., Ince, T., Gabbouj, M., & Inman, D. J. (2021). 1D convolutional neural networks and applications: A survey. *Mechanical Systems and Signal Processing*, *151*, 107398. <https://doi.org/10.1016/j.ymsp.2020.107398>
- Kuhn, M., & Johnson, K. (2013). Applied Predictive Modeling with Applications in R. In *Springer* (Vol. 26). Retrieved from http://appliedpredictivemodeling.com/s/Applied_Predictive_Modeling_in_R.pdf

- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine learning in agriculture: A review. *Sensors (Switzerland)*, *18*(8), 1–29. <https://doi.org/10.3390/s18082674>
- Long, D., Longuevergne, L., Scanlon, B.R., 2014. Uncertainty in evapotranspiration from land surface modeling, remote sensing, and GRACE satellites. *Water Resour. Res.* *50* (2), 1131–1151. <https://doi.org/10.1002/2013WR014581>.
- Luo, T., Young, R., & Reig., P. (2015). *Aqueduct Projected Water Stress Country Rankings. Technical Note. Washington, D.C.: World Resources Institute.* (August), 1–16.
- Nagappan, M., Gopalakrishnan, V., & Alagappan, M. (2020). Prediction of reference evapotranspiration for irrigation scheduling using machine learning. *Hydrological Sciences Journal*, *65*(16), 2669–2677. <https://doi.org/10.1080/02626667.2020.1830996>
- Nawandar, N. K., Cheggoju, N., & Satpute, V. (2021). ANN-Based Model to Predict Reference Evapotranspiration for Irrigation Estimation. *Advances in Intelligent Systems and Computing*, *1245*, 671–679. https://doi.org/10.1007/978-981-15-7234-0_63
- Ojha, V. K., Abraham, A., & Snášel, V. (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*, *60*(January), 97–116. <https://doi.org/10.1016/j.engappai.2017.01.013>
- Ozgur, A., & Yamac, S. S. (2020). Modelling of daily reference evapotranspiration using deep neural network in different climates. *ArXiv*.
- Patil, A. P., & Deka, P. C. (2016). An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs. *Computers and Electronics in Agriculture*, *121*, 385–392. <https://doi.org/10.1016/j.compag.2016.01.016>
- Pérez-Enciso, M., & Zingaretti, L. M. (2019). A guide for using deep learning for complex trait genomic prediction. *Genes*, *10*(7), 1–19. <https://doi.org/10.3390/genes10070553>
- Red, G., Hospital, C., & Medicine, T. C. (2020). Application of Artificial Neural Networks for Estimating Reference Evapotranspiration in Western Himalayan Region. *Roorkee Water Conclave 2020 Application*, *28*(13), 1220–1226.
- Roy, D. K. (2021). Long Short-Term Memory Networks to Predict One-Step Ahead Reference Evapotranspiration in a Subtropical Climatic Zone. *Environmental Processes*. <https://doi.org/10.1007/s40710-021-00512-4>

- Saggi, M. K., & Jain, S. (2019). Reference evapotranspiration estimation and modeling of the Punjab Northern India using deep learning. *Computers and Electronics in Agriculture*, 156(June 2018), 387–398. <https://doi.org/10.1016/j.compag.2018.11.031>
- Sandro Skansi. (2018). Introduction to deep learning. In *Introduction to Deep Learning* (p. 191). https://doi.org/10.1007/978-981-15-4095-0_1
- Sattari, M. T., Apaydin, H., & Shamshirband, S. (2020). Performance evaluation of deep learning-based gated recurrent units (GRUs) and tree-based models for estimating ETo by using limited meteorological variables. *Mathematics*, 8(6), 1–18. <https://doi.org/10.3390/MATH8060972>
- Schmidhuber, J. (2015). Deep Learning in neural networks: An overview. *Neural Networks*, 61, 85–117. <https://doi.org/10.1016/j.neunet.2014.09.003>
- Shiri, J. (2017). Evaluation of FAO56-PM, empirical, semi-empirical and gene expression programming approaches for estimating daily reference evapotranspiration in hyper-arid regions of Iran. *Agricultural Water Management*, 188, 101–114. <https://doi.org/10.1016/j.agwat.2017.04.009>
- Sowmya, M. R., Santosh Kumar, M. B., & Ambat, S. K. (2020). Comparison of deep neural networks for reference evapotranspiration prediction using minimal meteorological data. *Proceedings - 2020 Advanced Computing and Communication Technologies for High Performance Applications, ACCTHPA 2020*, 27–33. <https://doi.org/10.1109/ACCTHPA49271.2020.9213201>
- Tinchcombe, M. (1989). *Multilayer Feedforward Networks are Universal Approximators*. 2, 359–366.
- YAMAÇ, S. S. (2021). Reference evapotranspiration estimation with k-Nearest Neighbour and Artificial neural network models using different climate input variables in the semi-arid environment. *Tarım Bilimleri Dergisi*, (1), 1–16. <https://doi.org/10.15832/ankutbd.630303>
- Yin, J., Deng, Z., Ines, A. V. M., Wu, J., & Rasu, E. (2020). Forecast of short-term daily reference evapotranspiration under limited meteorological variables using a hybrid bi-directional long short-term memory model (Bi-LSTM). *Agricultural Water Management*, 242(June), 106386. <https://doi.org/10.1016/j.agwat.2020.106386>
- Yu, H., Wen, X., Li, B., Yang, Z., Wu, M., & Ma, Y. (2020). Uncertainty analysis of artificial intelligence modeling daily reference evapotranspiration in the northwest end of China. *Computers and Electronics in Agriculture*, 176(February). <https://doi.org/10.1016/j.compag.2020.105653>

Yusuf, H. A., Agbaje, N., & Olorunfemi, I. E. (2020). Estimation of evapotranspiration rate in the sahelian region of nigeria using generalized regression neural network and feed forward neural network. *Agricultural Engineering International: CIGR Journal*, 22(4), 31–39.

Zarco-Tejada, P.J., Hubbard, N., Loudjani, P., 2014. Precision agriculture: an opportunity for EU farmers - potential support with the CAP 2014–2020. European Parliament’s Committee on Agriculture and Rural Development. URL http://www.europarl.europa.eu/RegData/etudes/note/join/2014/529049/IPOL-AGRI_NT%282014%29529049_EN.pdf.

Zhu, B., Feng, Y., Gong, D., Jiang, S., Zhao, L., & Cui, N. (2020). Hybrid particle swarm optimization with extreme learning machine for daily reference evapotranspiration prediction from limited climatic data. *Computers and Electronics in Agriculture*, 173(October 2019), 105430. <https://doi.org/10.1016/j.compag.2020.105430>

ÖZGEÇMİŞ

Adı Soyadı : ABDELRAHMAN AMR ALI RABIE ELSAYED SALEH
Doğum Yeri ve Tarihi : Fayoum, Mısır, 25/4/1995
Yabancı Dil : İngilizce, Türkçe

Eğitim Durumu

Lise : Cemal Abdül Nasır Lisesi, 2011-2013

Lisans : Kafrelsheikh Üniversitesi Ziraat Fakültesi Ziraat Mühendisliği Bölümü (Biyosistem Mühendisliği), 2013-2017

Lisans Üstü : Beni Suef Üniversitesi İleri Bilimler için Lisansüstü Çalışmalar Fakültesi Çevre Bilimi ve Endüstriyel Gelişim Bölümü, 2017-2018

Yüksek Lisans : Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı, 2019-2021

Çalıştığı Kurum/Kurumlar : -

İletişim (e-posta) : abdulrahman.amr.ali@gmail.com
a3.relsayed@gmail.com

Yayımları :-