

T.C.
BALIKESİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI



**KAVRAMSAL YAĞIŞ AKIŞ MODELİ ÇIKTILARININ YAPAY
ZEKA METOTLARIYLA ENTEGRASYONU**

HANDE YALÇIN

DOKTORA TEZİ

Jüri Üyeleri : Prof. Dr. Umut OKKAN (Tez Danışmanı)
Doç. Dr. Atilla MUTLU
Doç. Dr. Ahmet Ali KUMANLIOĞLU
Doç. Dr. Sinan NACAR
Dr. Öğr. Üyesi Mustafa Utku YILMAZ

BALIKESİR, HAZİRAN -2025

ETİK BEYAN

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan “**Kavramsal Yağış Akış Modeli Çıktılarının Yapay Zeka Metotlarıyla Entegrasyonu**” başlıklı tezde;

- Tüm bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Kullanılan veriler ve sonuçlarda herhangi bir değişiklik yapmadığımı,
- Tüm bilgi ve sonuçları bilimsel araştırma ve etik ilkelere uygun şekilde sunduğumu,
- Yararlandığım eserlere atıfta bulunarak kaynak gösterdiğimi,

beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ederim.

Hande YALÇIN

ÖZET

KAVRAMSAL YAĞIŞ AKIŞ MODELİ ÇIKTILARININ YAPAY ZEKA METOTLARIYLA ENTEGRASYONU

DOKTORA TEZİ

HANDE YALÇIN

BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: PROF. DR. UMUT OKKAN)

BALIKESİR, HAZİRAN-2025

Bu çalışmada, kavramsal yağış-akış model (CRR) çıktılarının Yapay Sinir Ağlarına (YSA) entegrasyonu ile oluşturulan çok aşamalı hibrit model zincirinin, model tahminlerinin performansını iyileştirilmesi hedeflenmiştir. Temez, Dinamik Su Bütçesi, abcde, Avusturalya Su Bütçesi, Guo ve Thornthwaite Su Bütçesi CRR modelleri hidrolojik ve meteorolojik parametrelerinin farklı olması ve temsil yeteneklerinden dolayı seçilmiştir. Üç farklı veri ağırlıklandırma yöntemiyle ERA5 yeniden analiz verileri kullanılarak CRR modelleri optimize edilmiştir. Elde edilen model çıktıları ve bu çıktıları oluşturan model bileşenlerinden oluşturulan veri seti YSA'lara girdi olarak entegre edilmiştir. Bu hibrit model stratejisi ile simülasyon performansının iyileştirilmesi ve belirsizliklerin azaltılması amaçlanmıştır. Temel Bileşen Analizi (PCA) ve En Küçük Mutlak Küçülme ve Seçim Operatörü (LASSO) yöntemleri ile küçültülen veri setlerinin yüksek korelasyonunun azaltılması ve işlem yükünün YSA'nın performansına olumsuz etkisinin giderilmesi hedeflenmiştir. Hidrolojik modellerin ve hibrit model zincirinde kullanılan yöntemlerin determinasyon katsayısı (R^2), Nash-Sutcliffe verimlilik sabiti (NSE), en küçük hataların karesinin ortalamasının karekökü (RMSE), Yanlılık yüzdesi (PBIAS) ve Kling Gupta verimlilik sabiti (KGE) değerlerine göre kıyaslanarak, model simülasyonlarının performansına etkisi değerlendirilmiştir. Uygulanan w_1 , w_2 ve w_3 veri ağırlıklandırma yöntemleri arasında bazı istasyonlarda bazı metriklerde farklılıklar görülsede w_3 yönteminin genel olarak diğer yöntemlerden daha başarılı performans göstermiştir. Validasyon döneminde; R^2 metriğine göre w_3 yönteminin en iyi tekli model performansı ile en iyi YSA performansı kıyaslandığında, uygulanan Orhaneli-Küçükilet, Kocaçay-Kayaca, Simav Çayı-Yahyaköy, Nilüfer Çayı-Geçitköy ve Emet Çayı-Dereli istasyonları için iyileşme oranı, sırasıyla, %1,83, %3,34, %7,11, %4,75, %4,47 hesaplanmıştır. w_1 yönteminin en iyi tekli model performansı ile w_3 yönteminin en iyi YSA performansı kıyaslandığında, uygulanan aynı istasyonlar için iyileşme oranı, sırasıyla, %11,34, %2,01, %8,56, %6,2, %13,39 hesaplanmıştır.

ANAHTAR KELİMELER: CRR, hibrit model, hidroloji, ortak optimizasyon, veri ağırlıklandırma, YSA

ABSTRACT

INTEGRATION OF CONCEPTUAL RAINFALL RUNOFF MODEL OUTPUTS WITH ARTIFICIAL INTELLIGENCE METHODS

PH.D THESIS

HANDE YALÇIN

BALIKESİR UNIVERSITY INSTITUTE OF SCIENCE
CIVIL ENGINEERING

(SUPERVISOR: PROF. DR. UMUT OKKAN)

BALIKESİR, JUNE - 2025

In this study, it is aimed to improve the performance of model predictions of multi-stage hybrid model chain formed by integrating conceptual rainfall-runoff model (CRR) outputs into Artificial Neural Networks (ANN). Temez, Dynamic Water Budget, abcde, Australian Water Budget, Guo and Thornthwaite Water Budget CRR models were selected due to their different hydrological and meteorological parameters and their representation abilities. CRR models were optimized using ERA5 reanalysis data with three different data weighting methods. Obtained model outputs and the data set formed from model components forming these outputs were integrated as input to ANNs. It is aimed to improve simulation performance and reduce uncertainties with this hybrid model strategy. It is aimed to reduce the high correlation of data sets reduced with Principal Component Analysis (PCA) and Least Absolute Shrinkage and Selection Operator (LASSO) methods and to eliminate the negative effect of processing load on the performance of ANN. The effects of the hydrological models and the methods used in the hybrid model chain on the performance of the model simulations were evaluated by comparing them with respect to the coefficient of determination (R^2), Nash-Sutcliffe efficiency constant (NSE), root mean square error (RMSE), Percentage of bias (PBIAS) and Kling Gupta efficiency constant (KGE) values. Although there were differences in some metrics at some stations among the applied w_1 , w_2 and w_3 data weighting methods, the w_3 method generally showed a better performance than the other methods. During the validation period; according to the R^2 metric, when the best single model performance of the w_3 method is compared with the best ANN performance, the improvement rate for the applied stations Orhaneli-Küçükilet, Kocaçay-Kayaca, Simav Stream-Yahyaköy, Nilüfer Stream-Geçitköy and Emet Stream-Dereli is calculated as 1.83%, 3.34%, 7.11%, 4.75%, 4.47%, respectively. When the best single model performance of the w_1 method is compared with the best ANN performance of the w_3 method, the improvement rate for the mentioned stations is calculated as 11.34%, 2.01%, 8.56%, 6.2%, 13.39%, respectively.

KEYWORDS: CRR, hybrid model, hydrology, joint optimization, data weighting, ANN

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	iv
TABLO LİSTESİ	viii
ÖNSÖZ	ix
1. GİRİŞ	1
2. ÇALIŞMA ALANI VE VERİ	10
3. YÖNTEM	15
3.1 Kavramsal Yağış Akış Modelleri	16
3.1.1 Temez modeli (HM1)	16
3.1.2 Dinamik su bütçesi modeli (HM2)	17
3.1.3 abcde modeli (HM3)	18
3.1.4 Avusturalya su bütçesi modeli (HM4).....	19
3.1.5 Guo modeli (HM5)	20
3.1.6 Thornthwaite su bütçesi modeli (HM6).....	20
3.2 Kavramsal Model Parametreleri ve ERA5 Yeniden Analiz Izgara Verilerinin Ağırlıklarının Ortak Optimizasyonu	23
3.2.1 Thiessen poligon ağırlıklandırma yöntemi (w1).....	23
3.2.2 Thiessen poligonlarından serbest seçimli ağırlıklandırma yöntemi (w2)	23
3.2.3 Dörtgenel alan serbest seçimli ağırlıklandırma yöntemi (w3)	23
3.3 Veri Daraltma Yöntemleri	23
3.3.1 Temel bileşen analizi (PCA).....	24
3.3.2 En küçük mutlak küçülme ve seçim operatörü (LASSO).....	24
3.4 Kullanılan Yapay Zekâ Teknikleri	24
3.4.1 İleri beslemeli sinir ağı (FFNN).....	24
3.4.2 Radyal tabanlı fonksiyon ağı (RBFN)	25
3.5 Kavramsal Modellerle Yapay Zekâ Entegrasyonu Şemaları.....	26
3.6 Modelleme Zincirinin Dinamik Hassasiyetinin Belirlenmesi	28
3.7 Performans Metrikleri.....	28
4. BULGULAR	31
4.1 Veri Ağırlıklandırma Yöntemlerinin Karşılaştırılması.....	31
4.2 Yapay Zekâ Entegrasyonu Çıktılarının Karşılaştırılması	40
4.3 Modelleme Zincirinin Dinamik Hassasiyetinin Karşılaştırılması	47
5. SONUÇ VE ÖNERİLER	51
6. KAYNAKLAR	55
EKLER	61
EK A: İstasyonların CRR model ve ağırlıklandırma grafikleri	61
EK B: İstasyonların çoklu model tahminlerinin yapay zekâ entegrasyonu grafikleri .	73
EK C: İstasyonların çoklu model tahminlerinin yapay zekâ entegrasyonu gidiş ve saçılım grafikleri	85
ÖZGEÇMİŞ	89

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1: Susurluk Havzası'nda seçilen istasyonların yıllara göre veri dağılım grafiği	11
Şekil 2.2: Susurluk Havzası ve alt havzaların bulunduğu gridler, istasyonların konumu ..	13
Şekil 3.1: Yöntem akış şeması	16
Şekil 3.2: HM1 modelini akış şeması ve formülleri	17
Şekil 3.3: HM2 modelini akış şeması ve formülleri	18
Şekil 3.4: HM3 modelini akış şeması ve formülleri	19
Şekil 3.5: HM4 modelini akış şeması ve formülleri	19
Şekil 3.6: HM5 modelini akış şeması ve formülleri	20
Şekil 3.7: HM6 modelini akış şeması ve formülleri	21
Şekil 3.8: Model kombinasyonları ve yapay zekâ entegrasyon prosesi.....	27
Şekil 4.1: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	33
Şekil 4.2: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE (mm biriminde) performans grafiği.....	33
Şekil 4.3: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R ² performans grafiği.....	35
Şekil 4.4: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği.....	36
Şekil 4.5: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği.....	37
Şekil 4.6: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği.....	39
Şekil 4.7: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	40
Şekil 4.8: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği	41
Şekil 4.9: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R ² performans grafiği	42
Şekil 4.10: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği	43
Şekil 4.11: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği	44
Şekil 4.12: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği	46

Şekil 4.13: E311 Orhaneli Çayı- Küçükilet İstasyonunun w3 yöntemi ile Q_{pr2} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri ..	47
Şekil A.1: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	61
Şekil A.2: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	61
Şekil A.3: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	62
Şekil A.4: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	62
Şekil A.5: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	63
Şekil A.6: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	63
Şekil A.7: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	64
Şekil A.8: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	64
Şekil A.9: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	65
Şekil A.10: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	65
Şekil A.11: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	66
Şekil A.12: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	66
Şekil A.13: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	67
Şekil A.14: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	67
Şekil A.15: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	68
Şekil A.16: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	68
Şekil A.17: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği.....	69
Şekil A.18: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği.....	69
Şekil A.19: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği.....	70

Şekil A.20:	E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği....	70
Şekil A.21:	E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....	71
Şekil A.22:	E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....	71
Şekil A.23:	E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....	72
Şekil A.24:	E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....	72
Şekil B.1:	E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	73
Şekil B.2:	E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	73
Şekil B.3:	E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	74
Şekil B.4:	E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği.....	74
Şekil B.5:	E314 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	75
Şekil B.6:	E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	75
Şekil B.7:	E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	76
Şekil B.8:	E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği.....	76
Şekil B.9:	E314 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	77
Şekil B.10:	E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	77
Şekil B.11:	E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	78
Şekil B.12:	E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 grafiği.....	78
Şekil B.13:	E314 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	79
Şekil B.14:	E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	79
Şekil B.15:	E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	80
Şekil B.16:	E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği.....	80
Şekil B.17:	E314 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği...	81
Şekil B18:	E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği.....	81

- Şekil B.19:** E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği....82
- Şekil B.20:** E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği....82
- Şekil B.21:** E314 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....83
- Şekil B.22:** E316 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....83
- Şekil B.23:** E321 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....84
- Şekil B.24:** E328 istasyonun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği.....84
- Şekil C.1:** E314 Kocaçay- Kayaca İstasyonunun w3 yöntemi ile Q_{lr2} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri.....85
- Şekil C.2:** E316 Simav Çayı-Yahyaköy İstasyonunun w3 yöntemi ile Q_{lr3} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri.....86
- Şekil C.3:** E321 Nilüfer Çayı-Geçitköy İstasyonunun w3 yöntemi ile Q_{lr1} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri.....87
- Şekil C.4:** E328 Emet Çayı-Dereli İstasyonunun w3 yöntemi ile Q_{lr1} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri.....88

TABLO LİSTESİ

	<u>Sayfa</u>
Tablo 2.1: Alt havza ve seçilen istasyonların bilgileri	14
Tablo 3.1: Şekil 3.2-Şekil 3.7'deki akış bileşenleri veya ara değişkenlere ilişkin sembollerin tanımları	21
Tablo 3.2: CRR Modellerinin kalibrasyonunda kullanılan parametre adları ve parametre değer aralıkları	22
Tablo 4.1: İstasyonların ağırlıklandırma yöntemine göre seçilen gridler.....	32
Tablo 4.2: İstasyonlara göre katkı oranlarının karşılaştırılması. Her metriğin kalibrasyon ve validasyon dönemlerine ait en yüksek katkı oranı kalın (bold) gösterilmiştir	49
Tablo 4.3: Tüm istasyonlar için ağırlıklandırma yöntemine göre en iyi tekli model ve en iyi YSA performansı arasında IR (%). Validasyon döneminin en iyi sonuçları kalın olarak gösterilmiştir.	50

ÖNSÖZ

Hidroloji alanında en hayati kaynak olan suyun yönetimi için yapılacak planlamalarda ihtiyaç duyulan öngörülere yönelik çalışmalar yapılmaktadır. Bu çalışma ile yağış-akış tahminlerinde hidrolojik model stratejisi ile literatüre bir katkı sunmak amaçlanmıştır.

Öncelikle, tez sürecim boyunca bilimsel rehberliği, sabrı ve yol göstericiliği ile bana her zaman destek olan değerli danışmanım Prof. Dr. Umut OKKAN'a en içten teşekkürlerimi sunarım. Kendisi sadece akademik anlamda değil, araştırma disiplini ve bilimsel bakış açım üzerinde de derin izler bırakmıştır.

Çalışmanın idari ve teknik süreçlerinde yardımlarını esirgemeyen Arş. Gör. Zeynep Beril ERSOY'a, birlikte çalışmaktan memnuniyet duyduğum Berkay DERİN'e ve tez izleme komitesi üyelerine teşekkür ederim.

Bu süreçte her zaman yanımda olan, manevi desteğini hiç eksik etmeyen sevgili eşime ve çocuklarıma, sabırları, anlayışları ve sevgileri için minnettarım. Onların varlığı bu sürecin en kıymetli dayanağı olmuştur.

Tüm katkı sunanlara şükran ve saygılarımla...

Bahkesir, 2025

Hande Yalçın

1. GİRİŞ

Dünyanın küresel ısınmaya bağlı olarak değişen iklim özellikleri, sanayileşmeye bağlı olarak artan su ihtiyacı ve sanayileşme sonucu hızla kirlenen su kaynakları, artan nüfus ve şehirleşmenin getirdiği su tüketimi artışı su yönetiminin önemini gün geçtikçe artırmaktadır. Su kaynaklarının sürdürülebilir bir şekilde kullanılabilmesi için her bölgenin nüfusuna, tarımsal ve endüstriyel faaliyetlerine göre su bütçesi oluşturması ve geleceğe dönük bir su planlaması yapması önemli bir ihtiyaç haline gelmiştir.

Suyun yönetilebilmesi varlığına ve miktarına bağlıdır. Su kullanımının planlanabilmesi için mevcut su miktarının bilinmesi ve gelecekteki miktarının da tahmin edilmesi su yönetiminin en kritik noktasıdır. Yıllardır suyun gelecekteki miktarını öngörebilmek için hidrolojik modeller tasarlanmış, geliştirilmiş ve geliştirilmesi için çalışmalar da sürdürülmektedir (Perez-Sanchez, et al.,2019).

Hidrolojik modeller havzanın hidrolojik süreçlerini tek bir hidrolojik değişkene göre inceleyen süreç modellerinden zaman içinde tüm havza süreçlerini ele alan bütüncül bakışla tasarlanan parametrik havza modellerine evrilmiştir. Havzanın içsel yapısı, zamansal ve alansal değerlendirme durumuna göre ele alındığında farklı kategorilerde hidrolojik modeller bulunmaktadır (Fıstıkoğlu,1999). Etkili olan göstergeler bağlamında hidrolojik modellerin kategori sınıfı yukarıda bahsedilen iç yapı, alansal ya da zaman göstergesine göre değişiklik gösterebilir.

Xu and Singh (1998), model seçiminde rehber olması düşüncesiyle yaptıkları çalışmada, uzun yıllardır kullanılan aylık su bütçesi modellerinin zamanla değişimlerini ve uygulamalarını derlemiştir. Modeller yapılarına ve amaçlarına göre sınıflandırılarak, ihtiyaç duyulan veriler, parametreler ve temel bileşenler değerlendirilmiştir. Model seçiminde, havzanın coğrafi özelliklerinin, mevcut ölçülmüş verilerin, parametrelerin ve amacın göz önünde bulundurulmasının önemine dikkat çekilmiştir. Nemli, bölgelerde az parametrelili modellerin yeterli olabileceği kurak ve yarı kurak bölgelerde daha karmaşık modellerin tercih edilebileceği belirtilmiştir. Aylık modellerin, su kaynaklarının planlanması-iklim değişikliği etkilerinin tahmin edilmesi ve aylık hidroklimatolojik verilerin elde edilmesinde kullanışlı olduğu ifade edilmiştir. Kapsam dahilindeki havza temelli model seçiminde yukarıda bahsedilen parametre sayısının az veya çok olmasında ana etkili unsurun yağışlı ya

da kurak olması olduğu söylenebilir. Bu bağlamda, parametre sayısı belirlenirken havza karakteristiğinin diğer bilinen havzalarla kıyaslanabilir olması doğru sayıda parametre seçimine yardımcı olacaktır.

Toplu kavramsal yağış-akış modelleri (CRR) akış tahminleri üretmede yaygın olarak kullanılan yöntemlerdir. Havzayı birbirine bağlı depolar olarak kavramsallaştırarak, suyun bu depolara girişte, depolar arasında ve dışında nasıl hareket ettiğini tanımlamayı amaçlayan matematiksel ifadelerdir. Bu yöntemlerin uygulanabilmesi için yağış ve hava sıcaklığı veri setlerine ve uygun model parametrelerini belirleyebilmek için model kalibrasyonuna ihtiyaç vardır. Seçilen bölgeden birden fazla ölçüm veri seti olması durumunda havza ortalamalı yöntemlerle oluşturulan veri seti CRR modeli kalibrasyonunda kullanılır. CRR modelinin parametrelerini belirlerken aynı anda meteorolojik veri setlerini ağırlıklandırarak kalibre eden çeşitli optimizasyon yöntemlerinin denenebileceği fikriyle yaptıkları çalışmada kalibrasyon sürecinde ortak optimizasyonun sonuçları iyileştirdiğini, validasyon sürecindeyse istenen iyileştirmeye ulaşamadıklarını, sonuçların model seçimi, havza özellikleri, optimizasyon algoritmasına bağlı olarak değişebileceğini göstermişlerdir (Piotrowski, et al., 2019). Bu durumda, yukarıda ifade edilen havza karakteristiğinin model seçiminden önce doğru olarak ortaya konmasının model tahmin başarısında çok etkili olacağı öngörülebilir. Yaptıkları çalışmada CRR model performansının, verilerin havzayı temsil yeteneğine ve kalibrasyon sürecinde parametrelerin belirlenme hassasiyetine bağlı olduğuna dikkat çekilmiştir (Jaiswal et al., 2020).

İspanya'nın 16 farklı havzasında (Temez, Gr2m, abcd, awbm, Guo-5p ve Thornthwaite-Mather) altı farklı toplulaştırılmış CRR modelinin karşılaştırmalı bir analizini yaparak akış tahmini en iyi olanı bulmayı amaçladıkları çalışmada, bazı modellerin havza nemli olduğunda en iyi tahminleri ürettiğini bazı modellerin kurak ve yarı kurak dönemde daha iyi performans sergilediği ortaya konmuştur. Kullanılan modellerden biri genel olarak iyi sonuç verse de tek bir hidrolojik modele güvenmenin yeterli olmayacağı sonucuna ulaşmışlardır (Perez-Sanchez, et al.,2019). Bu bağlamda, modellerin ayrı ayrı her bir havza için farklı sonuçlar üretmesi, havza bazlı değerlendirmelerde havza karakteristiğinin doğru belirlenmesinin model başarısında ana etken olduğunu göstermektedir.

Tek bir yağış-akış modeline alternatif olarak birden fazla modelin çıktılarını birleştirerek genel bir birleşik çıktı elde edebilmek amacıyla 11 farklı havza ve 5 farklı yağış-akış

modelinin üç farklı kombinasyon yöntemiyle test edildiği çalışmada, farklı modellerin farklı kombinasyonlarıyla çok daha başarılı performans sergilediği ortaya konmuştur. Kullanılan üç farklı kombinasyon yöntemi -basit ortalama (BO), ağırlıklı ortalama (AO) ve yapay sinir ağı (YSA) temelli yöntem - ile elde edilen tahminler incelendiğinde, en basit ağı mimarisi ve nöron sayısı kullanıldığı halde yapay sinir ağı temelli yöntemin diğer yöntemlerden daha yüksek doğruluk sağladığı belirlenmiştir (Shamseldin et al., 1997). Kombinasyonların karakteristiğini ortaya koyan her model bileşenin parametre türü ve sayısı kombinasyon yöntemleri içinde de farklı senaryolar ortaya koyabilmektedir. YSA'ların kombinasyon yöntemindeki bu öne çıkışı temelinde, başka bir çalışmada sekiz farklı havzada dört farklı yağış-akış modelinden elde edilen günlük simülasyon verileri üç farklı yapay sinir ağı yapısına giriş verisi olarak sunulmuştur. Basit yapay sinir ağı (BYSA), radyal tabanlı fonksiyon ağı (RBFN) ve çok katmanlı algılayıcı ağı (MLPN) kombinasyon yöntemleri karşılaştırılmış, bulgular kombinasyon yöntemlerinin çoğu durumda tekli modellerden daha başarılı performans sergilediğini ortaya koymuştur. MLPN yöntemi her ne kadar validasyon döneminde kalibrasyon dönemi kadar başarılı tahminler üretmese de birleşik tahminlerde en başarılı yapı olduğu sonucuna ulaşılmıştır (Shamseldin et al., 2007). Bu tespite dayalı olarak, model zincirinin oluşturulmasında YSA yöntemlerinin kullanılması anlamlı olacaktır.

Kore'deki Daecheong barajının aylık akışını tahmin etmek için kullanılan TANK modelinin çıktılarının iki farklı sinir ağı temelli model ile iyileştirmesinin amaçlandığı çalışmada, çoklu sinir ağı modelinin hem tekli sinir ağı modelinden hem de TANK modelinden daha iyi performans gösterdiği sonucuna ulaşılmıştır (Kim et al., 2006). Bu sonuca dayalı olarak, yukarıda ifade edilen çoklu YSA modelinin üstünlüğünü desteklediği söylenebilir.

YSA yaklaşımının kullanıldığı bir diğer çalışmada, sinir ağı modeli ve temel bileşen analizi (PCA) ile yağış-akış tahmini yapılması hedeflenerek, PCA uygulanan ve uygulanmayan model performansları değerlendirilmiştir. Çok fazla giriş verisi olmasının YSA modelinin yapısal karmaşıklığını arttırarak, modelin genelleme yeteneğini zayıflatabileceği düşüncesi test edilmiştir. PCA yardımıyla girdi nöron sayısı azaltılarak modelin genelleme yeteneğinin korunması hedeflenmiştir. Elde edilen deneysel sonuçlar, bu yaklaşımın havzayı daha iyi temsil eden simülasyonlar üreterek, model performansını artırdığını ortaya koymuştur (Hu et al., 2007). Giriş veri sayısı azaltılarak, bir diğer ifadeyle, analiz girdilerinin boyutu daraltılarak, modelin havza temsil yeteneğinin iyileştirildiği ifade edilmiştir.

Model çıktılarının değerlendirilmesi bağlamında; havza özellikleri, iklim koşulları gibi birçok değişkeni kullanarak yağış-akış sürecini kurgulamayı hedefleyerek geliştirilmeye çalışılan hidrolojik modellemeye farklı modellerin çıktılarını birleştiren yeni bir yöntem uygulanan çalışmada, dalgacık dönüşümü (DD) tabanlı çoklu model yaklaşımını önerilmiştir. Yedi farklı havzada seçilen beş yağış-akış modeli ile elde edilen tahminleri kullanarak DD ile zenginleştirilmiş verilerin entegre edildiği dört farklı veri odaklı model sonuçlarının kombinasyonu için çok katmanlı algılayıcı ağı (MLPN) kullanılmıştır. Elde edilen bulgulardan DD ile zenginleştirilmiş model kombinasyonlarının başarılı performans sergilediği sonucuna ulaşılmıştır (Shoaib et al., 2018).

Havza tabanlı değerlendirmelerde, dünya genelinde 16.218 havzada dört yaygın hidrolojik model ile dört makine öğrenmesi modelinin performanslarının ve birleşim stratejilerinin değerlendirildiği çalışmada, makine öğrenmesi modelleri genellikle daha yüksek performans gösterirken, hidrolojik modellerin de Güney Yarımküre, Kuzey Amerika'nın güneydoğusu, Batı Avrupa gibi bölgelerde daha başarılı bir performans sergilediği ortaya konmuştur. Çalışmanın bulguları her iki model türünün de belirli coğrafi ve iklim koşullarında avantajlar sunduğunu göstermektedir. Bu sonuç bağlamında daha önce de ifade edildiği üzere, coğrafi karakteristiklerin yanında iklim şartlarının da oldukça etkili olduğu tespitini desteklemektedir. Dört hidrolojik model ve dört makine öğrenmesi modelinin sonuçlarının farklı ağırlıklandırma yöntemleriyle kombinasyonu karşılaştırıldığında ters sıra tahmin kombinasyonu yönteminin, hidrolojik model ve makine öğrenmesi modelinin en iyi sonuçlarından daha başarılı tahminler ürettiği ortaya konmuştur. Ancak bu yönteminde kuru, soğuk ve düşük oranda bitki örtüsüne sahip havzalarda akış tahminlerinin zorluğunun sürdüğü bulunmuştur. Ayrıca yoğun insan faaliyetlerinin olduğu bölgelerde simülasyon doğruluğunun azaldığı gözlemlenmiştir (Zhang et al., 2025). İfade edilen bulgular ışığında, model doğruluğuna negatif etki eden bu parametreleri de göz önüne alan yeni model ve model kombinasyonlarına ihtiyaç olduğu söylenebilir.

Model kombinasyonları ve bu kombinasyonların ağırlıklandırılması açısından ele alınacak olursa, hidrolojik modellerin ağırlıklandırılmış kombinasyonunu, tek modellerle karşılaştırarak test etmeyi amaçlayan çalışmada, dört model ve üç metrik kullanılarak elde edilen 12 hidrograf dokuz farklı çoklu model ortalama yaklaşımıyla ağırlıklandırılmıştır. Ağırlıklı yöntemlerin farklı kombinasyonlarının %76'sının tek modellerin en iyilerinden daha iyi tahminler ürettiği görülmüştür. 12 modelin tamamı yerine havzaya göre seçilmiş

modellerle yapılan kombinasyonların daha başarılı performans sergilediği ve tekli model yaklaşımı yerine çoklu model ortalaması kullanımının hidrolojik modellerde daha isabetli tahminler ürettiği sonucuna ulaşılmıştır (Arsenault et al., 2015). Herhangi bir havzada, bir model kombinasyonunun başarılı olmaması bir başka havza için de aynı sonucu vereceği anlamına gelmez. Havzayı en iyi şekilde temsil eden indikatörlerin kullanılması model çıktılarının başarı oranını artıracaktır.

En iyilerin kombinasyonu ele alınacak olursa, çok modelli topluluk stratejileri ile farklı modellerin yetenekli tahminlerinin çeşitliliğinden yararlanarak daha isabetli tahminler üretilebileceği fikriyle, Bayes Model Ortalaması (BMA) yöntemiyle üç farklı hidrolojik model ve üç farklı amaç fonksiyonu kullanarak yaptıkları çalışmada elde ettikleri tahminlerin bireysel modellerin tahminlerinden daha iyi ve eşit derecede güvenilir olduğunu ifade etmişlerdir (Duan et al., 2007). Kombine edilen modellerin hidrolojik akış simülasyonunun iyileştirilmesi amaçlansa da bu sonuca ulaşabilmek için modellerin seçimi, topluluk üyelerinin sayısı ve seçilen kalibrasyon tekniğinin performansa etkisi araştırılmış, birleştirilen model sayısının en çok altı olmasının performansa olumlu etkisi gözlenirken, altıdan fazla model sayılarında tahminlerdeki iyileşmenin sınırlandığı, model kombinasyonlarının ıslak havzalarda daha iyi performans gösterdiği bildirilmiştir (Wan et al., 2021). Optimal model sayısına sahip kombinasyon yaklaşımına ışık tutan bir sonuç olarak değerlendirilebilir.

Oluşturulan model kombinasyonları yağış-akış açısından ele alındığında, yağış-akış ilişkisinin modellenmesine yönelik çeşitli kavramsal modellerin (Xinanjiang, SMAR ve Tank) farklı mekansal temsillerle (toplu, yarı-dağıtılmış ve entegre) karşılaştırmalı analizinin yapıldığı çalışmada, özellikle yapay sinir ağları ile kavramsal modellerin bütünleştirildiği entegre yapının, geleneksel modellere kıyasla daha başarılı çıktılar ürettiği ortaya konmuştur. Havza içi hidrolojik farklılıkları daha etkin yansıtılabilmek adına yarı-dağıtılmış modelleme tercih edilmiş; bu modelleme yaklaşımı, alt havzalardan elde edilen akışların yapay sinir ağları (YSA) aracılığıyla bütün havzayı temsil eden çıktılara dönüştürülmesini mümkün kılmıştır. Ancak sadece yarı-dağıtılmış model kullanımı ya da basit regresyon yöntemleri tek başına yeterli düzeyde doğruluk sağlayamamıştır. Bu bağlamda, çalışmanın bulguları, özellikle karmaşık havza yapılarında kavramsal model ve YSA entegrasyonunun öne çıktığını göstermektedir (Chen and Adams, 2006).

Geleneksel süreç modeli ile veriye dayalı derin öğrenme modelini birleştiren hibrit bir model stratejisi ile aylık yağış-akış modellerinin tahmin performansında umut verici sonuçlara ulaşıldığı bildirilmiştir. Bu çalışmada ayrıca veri setlerine, model simülasyonları ile hesaplanan farklı hidrolojik veriler eklenerek model performanslarının iyileştiği ifade edilmiştir (Xu et al., 2024). Bu bağlamda, ölçülen değerlerin yanı sıra modelin hesaplama adımında elde edilen verilerle genişletilen veri setleri ile model performanslarının iyileşmesi beklenen sonuçtur.

Veri elde edilemeyen ya da eksik veri kaynağı olan havzalarda, sadece havza karakteristiklerini ve meteorolojik kayıtları referans alarak günlük akış tahmini için veri odaklı modellerin etkinliğinin incelendiği bu çalışmada, Tekrarlayan Sinir Ağları ve Karar Ağacı tabanlı algoritmaların birleşimiyle geliştirilen model, komşu ya da yakın havzaların meteorolojik verilerini ve havza özelliklerini kullanarak akış tahminleri yapmaktadır. Kore’de bulunan 25 farklı havzanın 24’ünün ölçülmüş verilerinden ifade edilen metotlarla öğrenmesi sağlanan model, ölçülmemiş havza için tahminler üretmiştir. Modelin performansı değerlendirildiğinde, gözlem verisi bulunmayan havzalarda da başarılı tahminler yaptığı bulunmuştur. Sonuçlar, önerilen modelin, geleneksel fiziksel tabanlı modellerle karşılaştırıldığında daha esnek ve genel bir yaklaşım sunduğunu göstermektedir. Bu çalışma, veri odaklı modellerin, gözlem verisi eksik olan bölgelerde hidrolojik tahminler için potansiyel bir alternatif sunduğunu ortaya koymaktadır (Won et al., 2023). Buradan, eksik veriler söz konusu olan havzalar için sağlıklı model çıktısı elde etmek zordur yaklaşımı ortadan kalkabilir ve havza karakteristikleri doğru tanımlanırsa doğruluğu yüksek model çıktıları elde etmek mümkün olacaktır denebilir.

YSA metotlarıyla optimize edilen yağış-akış modellerinin veri setine farklı girdilerin dahil edilmesiyle performansların iyileştirilmesinin hedeflendiği araştırmalar değerlendirildiğinde, odak noktası olarak seçilen bölgenin sahip olduğu zemin nemliliği, yeraltı suyu biriktirme kapasitesi ve toprak geçirimsizliği gibi faktörler yağış-akış modellerinin yakınsaması üzerinde son derece etkilidir (Anctil et al., 2004; Okkan ve Serbes, 2012; Robertson et al., 2013; Humphrey et al., 2016; Kumanlıoğlu ve Fıstıkoğlu, 2019). Ancak iklim değişikliğinin ortaya çıkardığı belirsizlikler ve bu belirsizliklerin ileri projeksiyonların tahmin edilmesi üzerindeki yüksek etki oranları sebebiyle model parametreleri olarak sisteme dahil edilmesi noktasında bazı zorlukları da beraberinde getirmiştir (Okkan ve İnan 2015; Kumanlıoğlu ve Fıstıkoğlu, 2019). Bu zorlukların

giderilmesi noktasında, havza ıslakken önceki yağışın önceki akışa katılması, havza kuruyken yağışın akıştan önce zemin nemi ve yeraltı suyu depolarına aktarılması ve havzanın ilk koşulunun doygunluğa yakın olduğu zamanlarda akışın durumu gibi üç ana faktörün göz ardı edilmemesi gerektiği ifade edilmiştir. Hidrolojik model simülasyonlarının farklı optimizasyon yöntemlerinde girdi olarak kullanılmasının tahminleri iyileştirmedeki becerisinin mevsime, havzanın konumuna bağlı olduğu belirtilmiştir (Robertson ve ark. 2013).

YSA'ların rastgele seçilen başlangıç ağırlıkları, yerel minimumu aşamama ihtimali, parametreleri belirlemeyi araştırmacıya bırakmasının yarattığı belirsizlik gibi dezavantajların göz ardı edilmemesi önerilmiştir (Okkan ve Serbes, 2012).

İklim tahmin modellerinin veri odaklı modellerle birleştirilmesiyle oluşturulan hibrit modellerin yağış, kuraklık, seller gibi meteorolojik olayları tahmin kabiliyetinde umut verici iyileştirmeler sağladığını belirtilmiştir. Uzun ve zahmetli matematiksel işlemlerle oluşturulan modellerin yerine fiziksel modellerden elde edilen çıktıların yapay zeka modelleriyle dinamik belirsizliklerin azaltılabileceği ifade edilmiştir (Slater et al.,2023). Aylık su bütçesi modelline makine öğrenmesi tabanlı bir yönlendirme parametresi ekleyerek iki parametrelili modeli, üç parametrelili hibrit modele dönüştürmüşlerdir (Okkan vd., 2024). Hibrit modelin makine öğrenmesinin yardımıyla klasik modelden daha başarılı bir performans gösterdiği sonucuna ulaşmışlardır.

Ölçülen veri setlerinin olmadığı havzalarda, uluslararası kabul görmüş türetilmiş veri setlerinden yararlanılabilir. ERA5 yeniden analiz verileri, Avrupa Orta Vadeli Hava Tahminleri Merkezi (ECMWF) bünyesinde geliştirilmiş, uydu tabanlı, yüksek çözünürlüklü ve küresel kapsamlı bir veri setidir. Kuzey Amerika'da yapılan geniş kapsamlı çalışmada, ERA5 yeniden analiz verilerinin ABD'nin doğu yarısı hariç, Kuzey Amerika'da gözlenmiş meteorolojik verilerin yerine kullanılabilecek eşdeğer veri setleri olduğunu, özellikle daha az ölçümü olan ya da ölçümü bulunmayan bölgelerde ölçülmüş verilere güvenilir oranda yakınlık sağladığını bildirmiştir (Tarek et al., 2020).

Türkiye'nin Doğu Karadeniz Havzası özelinde yapılan değerlendirmede iklim değişikliği çalışmalarında yaygın olarak kullanılan NCEP/NCAR, ERA-Interim ve ERA5 ızgaralı yeniden analiz veri setinin tahminleri, 12 meteoroloji istasyonunun aylık ortalama sıcaklık

ve toplam yağış ölçüm verileri ile karşılaştırılmıştır. Farklı istatistiksel modeller aracılığıyla en uygun ölçek küçültme modelini belirlemeyi amaçlayan çalışmada, üç ızgaralı yeniden analiz veri setinden ERA5 verilerini kullanan modelin çıktıları ölçülen değerlere en yakın sonuçları elde ettiği bildirilmiştir. ERA5 yeniden analiz verilerinin havza atmosferik koşullarını en uygun temsil eden ızgaralı veri seti olduğu sonucuna varıldığı bildirilmiştir (Nacar vd., 2022).

Türkiye Karasu Havzasında yapılan çalışmada, 2015-2019 su yılları arasındaki 23 meteoroloji istasyonunda ölçülen günlük yağış verileri 13 farklı ızgara veri seti ile karşılaştırılmıştır. Akış tahmini için kullanılan veri setlerinden ERA5 yeniden analiz verilerinin uzamsal ve zamansal doğrulamada iyi performans gösterdiği ancak yağış-akış model simülasyonunda düşük performans gösterdiği sonucuna ulaşılmıştır. Seçilen havza gibi dağlık bölgelerde karmaşık topografik özellikler gösteren havzalarda, bu verilerin yağış-akış simülasyonunda daha iyi performans gösterebilmesi için her ızgara veri setinin ayrı kalibre edilmesi önerilmiştir (Hafizi and Sorman, 2022).

Sri Lanka'nın tamamı ve ayrıca orta, kuru, ıslak üç bölgesi için yapılan çalışmada, ERA5 ızgaralı veri setinin özellikle orta ve kuru iklim bölgelerinde başarılı tahminler ürettiği bildirilmiştir. Islak bölgelerde farklı ızgaralı veri setinin daha başarılı olduğunu sonucuna ulaşılmıştır. ızgaralı verilerin özellikle ölçümü bulunmayan bölgelerde hidrolojik model geliştirmede kullanılabileceğini ancak kullanılacak hidrolojik süreçlere uygun hassasiyette ızgaralı veri uygulaması seçilmesi önerilmiştir (Bandara et al., 2021).

Yaptıkları çalışmada ERA5 veri setinin gözlemlerle yüksek uyum gösterdiği sonucuna ulaştıklarını bildirmişlerdir. ERA5 verilerinin diğer ızgara verilere göre özellikle yağış ve sıcaklıkta daha iyi olduğunu, birden fazla değişkenin tutarlı bir kümesine ihtiyaç duyulduğunda ERA5'in meteorolojik veri setlerinin kullanılabileceğini ancak havzanın aşırı olaylarının analizinin hedeflendiği çalışmalarda sağlamlığının iyi değerlendirilmesi tavsiye edilmiştir (Gleixner et al., 2020).

Çin'de yapılan çalışmada farklı zamansal ölçek ve konumlarda gözlemsel veriler ve ERA5 verileri karşılaştırıldığında yıllık ve mevsimsel modelleri iyi yakalayabildiğini, yaz ayları tahminlerinde ise yağışları biraz fazla tahmin ettiğini ve 1000 m'nin altındaki yükseltilerde

tahminler tutarlı iken yüksek rakım ve karmaşık topoğrafik yapıda önemli farklılıklar gösterdiği sonucuna ulaşmışlardır (Jiao et al., 2021).

Çalışmada tek yağış istasyonu, Thiessen ortalaması ve interpolasyonla elde edilmiş yağış yüzeyinin ortalaması yöntemleriyle elde edilen üç yağış serisi kullanılan CRR model sonuçları karşılaştırılmıştır. Özellikle interpolasyon yöntemiyle elde edilen ortalama yağış değerlerinin hidrolojik model kalibrasyon ve validasyon dönemlerinde daha başarılı sonuçlar verdiği ortaya konmuştur. Böylece yağış verisinin miktarı kadar havza üzerindeki dağılımının da dikkate alınması gerektiği gösterilmiştir (Vaze et al., 2011).

Bu tez çalışması, Kavramsal Yağış-Akış (CRR) modellerinin tahmin tutarlılığına ilişkin model kombinasyonlarının yapay zekâ entegrasyonu ile oluşturulan hibrit model zinciri ile anlamlı biçimde geliştirilebileceği varsayımına dayanmaktadır. Bununla birlikte, veri kalitesindeki iyileşmenin hem tekli model sonuçlarını hem de model kombinasyonları ile yapay zekâ destekli yaklaşımların doğruluğunu artırabileceği öngörülmüştür. Bu çerçevede, çalışmada belirsizlikleri en aza indirmek amacıyla, modelleme sürecinin her aşamasında alternatif yöntemler ve stratejiler denenmiş; veri, model ve entegrasyon seçeneklerinin etkileşimi çok yönlü olarak ele alınmıştır.

Bu çalışmada elde edilen iyileştirme çalışma alanında geçerlidir. Uzamsal ve zamansal doğrulama sağlanabilmesi için farklı havzalarda da denenmesi gerektiği göz ardı edilmemelidir.

Bu tez beş bölümden oluşmaktadır. Birinci bölümde çalışmanın amacı ve önceki çalışmalar yer almaktadır. İkinci bölümde çalışma alanı ve verilerin kapsamı ele alınmıştır. Üçüncü bölümde seçilen yöntemler detaylandırılmıştır. Dördüncü bölümde bulgular sunulmuş ve değerlendirilmiştir. Son bölümde sonuçlar ortaya konmuş ve önerilere yer verilmiştir.

2. ÇALIŞMA ALANI VE VERİ

Çalışma alanı olarak, Anadolu yarımadasının kuzeybatısında 39°-40° kuzey enlemleri ile, 27°-30° doğu boylamları arasında bulunan, yaklaşık 24.319 km² yağış alanıyla Türkiye'nin kuzey batısında yer alan, Marmara, Sakarya, Gediz ve Kuzey Ege havzalarına komşu; tarım, hayvancılık, sanayi ve nüfus yoğunluğu olan Türkiye'nin Marmara bölgesinin güneyinde bulunan Susurluk havzası seçilmiştir.

Susurluk Havzası'nın kuzeyinde Mudanya Tepeleri ve Karadağ ile Marmara Denizi, güneyinde Şaphane ve Simav dağları, doğusunda Murat, Gümeş, Yırce ve Uludağ ve batısında Simav ve Şaphane dağları ile çevrilidir. Balıkesir, Bursa, Kütahya, Bilecik, Çanakkale, Manisa ve İzmir illerinin bir kısmı Susurluk Havzası'nda yer alırken, Orhaneli Alt Havzası, Bandırma-Kapıdağ-Kocaçay-Manyas Alt Havzası, Göynük-Simav-Susurluk Alt Havzası, Mustafa Kemal Paşa-Uluabat Alt Havzası, Nilüfer Alt Havzası, ve Emet Alt Havzası olarak adlandırılan altı alt havzaya bölünmüştür (Tarım ve Orman Bakanlığı, 2023). Susurluk Havzası'nda seçilen istasyonların yıllara göre veri dağılım grafiği Şekil 2.1'de verilmiştir.


Bu çalışmada, CRR modellerinin girdi olarak kullanılan veri kalitesinden nasıl etkilendiğini de test etmeyi amaçladık. European Centre for Medium-Range Weather Forecasts (ECMWF) tarafından sunulan ERA5 yeniden analiz verilerinin kullanımının CRR hidrolojik modellerin performansına etkisinin belirlenmesini hedeflemektedir.

Susurluk Havzası'nda bulunan akım gözlem istasyonlarından (AGİ) ölçülmüş akış verisi kesintisiz en uzun olan ve havzanın farklı noktalarını temsil kabiliyetine sahip beş adet istasyon seçilmiştir. Bu seçim yapılırken havzada bulunan AGİ'lerin ölçülmüş akış verilerinin gidiş grafikleri çizilerek homojen verilere ve natürel akıma sahip olduğu düşünülen istasyonlar tercih edilmiştir. İstasyon verilerinin zaman periyodu model sonuçlarındaki olası farklılıkların zamansal sebeplerden kaynaklanmaması için aynı zaman periyodu alınmıştır. Böylece Susurluk Havzası' temsil edebilecek bir hibrit model belirleme ihtimali artırılmıştır. İstasyonların 1981-2006 yılları arasında ölçülen aylık akış yüksekliği verileri gözlenmiş veri seti olarak kullanılmıştır. Veri setlerinin toplamı 312 adet veriden oluşurken, 1981-1994 yılları arasındaki 156 adedi ile model kalibrasyonu için, 1994-2006 yılları arasındaki 156 adet veri model verifikasyonu için kullanılmıştır. Seçilen altı CRR model girdileri olan aylık yağış ve aylık sıcaklık değerleri için ERA5 yeniden analiz 1981-2006 yılları arasındaki verileri kullanılmıştır. ERA5 verileri havzada seçilen istasyonların bulunduğu havzanın ayrıldığı alt havzaların bulunduğu gridler seçilmiştir. Grid seçimlerinde kullanılan üç farklı ağırlıklandırma yöntemi bölüm 3.2 de açıklanacaktır. ERA5 yeniden analiz tabanlı verilerinden alansal yağış ve aylık ortalama sıcaklık değerleri alınmıştır. Evapotranspirasyon (EPOT) değeri Kharrufa yönteminden hesaplanmıştır.

$$EPOT = a \times p_k \times T_{ao}^b \quad (2.1)$$

Denklem 2.1'den EPOT, T alansal ortalama sıcaklık (°C) iken, hesaplanan aylık p_k değerleriyle ortalama gündüz saatlerinin yıllık ortalama gündüz saatlerine oranıdır. Ampirik katsayılarından $a=0.34$ ve $b=1.3$ enleme bağılı olarak hesaplanmıştır (Nourani et al., 2020).

Alt havzalar ile seçilen istasyonlar Şekil 2.2'deki haritada gösterilmiştir.



Şekil 2.2: Susurluk Havzası ve alt havzaların bulunduğu gridler, istasyonların konumu


Havzanın konum ve alan bilgileri Tablo 2.1’de verilmiştir.

Tablo 2.1: Alt havza ve seçilen istasyonların bilgileri

Alt Havza	İstasyon kodu	Adı	Enlem	Boylam	Drenaj Alanı (km²)	Alt Havza Alanı (km²)
Orhaneli	E 311	Orhaneli Çayı - Küçükilet	39,62528	29,46444	1.621,6	4.727,89
Bandırma-Kapıdağ-Kocaçay-Manyas	E 314	Kocaçay - Kayaca	40,07639	27,96972	2.308,8	4.594,62
Göynük-Simav-Susurluk	E 316	Simav Çayı - Yahyaköy	39,98611	28,17611	6.454	7.116,04
Nilüfer	E 321	Nilüfer Çayı - Geçitköy	40,28056	28,93639	1.290,8	1.989,34
Emet	E 328	Emet Çayı - Dereli	39,45222	29,25611	1.125,6	4.910,43

3. YÖNTEM

Bu çalışmada, çok aşamalı bir model stratejisi benimsenmiş her adımda belirsizliklerin azaltılarak model tahminlerinin performansının artırılması hedeflenmiştir (Şekil 3.1). Sürecin ilk basamağı Veri Ağırlıklandırma (WD) sürecidir. Bu basamakta çalışma alanında belirlenen alt havza için bir ızgara veri ağı oluşturulmuştur. En genel tanımıyla alt havzanın alanının bulunduğu her bir ızgara hücrelerini içine alan düzgün karesel bir geometriye sahip enlem ve boylamdaki ızgara verileri belirlenmiştir. Belirlenen ızgaralara ait aylık ortalama yağış ve alansal ortalama sıcaklık verileri ERA5 yeniden analiz uygulamasından alınmış, Denklem 2.1 ile EPOT değerleri hesaplanarak veri setleri hazırlanmıştır. Hazırlanan veri setleri seçilen ve Bölüm 3.1 'de tanımlanan altı CRR modeline girdi olarak kaydedilmiştir. Bu veri setleri Bölüm 3.2'de tanımlanan w_1 , w_2 ve w_3 ağırlıklarına göre optimize edilerek ilk basamak model tahminleri elde edilmiştir. Kullanılan altı CRR modelinin tahminlerinden ve bu tahminlerin varyantlarından oluşan ve Bölüm 3.3'te tanımlanan Model Çıktı Türleri (COT1, COT2 ve COT3) ile bir sonraki basamağın veri setleri hazırlanmıştır. Üçüncü basamakta COT1, COT2 ve COT3 veri setleri Bölüm 3.3'te tanımlanan iki farklı Veri Daraltma Yöntemi (DRM) ile Temel Bileşen Analizi (PCA) ve En Küçük Mutlak Küçülme ve Seçim Operatörü (LASSO) daraltılmıştır. DRM'den çıkan veriler YSA entegrasyonu aşamasında iki farklı Veri Odaklı Modeli (DDM) ile İleri Beslemeli Sinir Ağı (FFNN) ve Radyal Tabanlı Fonksiyon Ağı (RBFN) ile model stratejisinin tüm basamakları tamamlanmış olur. Kullanılan performans metrikleri Bölüm 3.7'de açıklanmıştır. Modelleme zincirinin hassasiyet analizi yapılarak model stratejinin adımlarının sonuçlara etkisi değerlendirilmiştir. Kurulan model stratejisi ile veri kaynakları ve model parametrelerinin ortak kalibrasyonu, CRR model tahminleri ve tahminlerin varyantlarından oluşturulan model kombinasyon verilerinin daraltılması, CRR model kombinasyon verilerinin yapay zekâya entegrasyonu eş zamanlı olarak değerlendirilerek tüm basamakların adım adım ve bütün olarak nihai tahmin başarısının artırılması hedeflenmektedir.




Şekil 3.1: Yöntem akış şeması

3.1 Kavramsal Yağış Akış Modelleri

Yağış-akış toplu CRR modellerinden havzanın hidrolojik ve meteorolojik özelliklerini temsil edebilecek, fazla işlem yükü gerektirmeyecek altı hidrolojik model seçilmiştir. Aşağıda tanımlanan hidrolojik modeller, YSA'ların parametrelerin optimizasyonunu dikkate almadığı için oluşabilecek belirsizlikleri azaltabilmek, parametrelerin belirlenmesi ve meteorolojik verilerin hazırlanması amacıyla planlanan stratejinin ilk adımdır. Hidrolojik modellerde gözlenmiş veri bulunmadığından, optimizasyon başlangıcında zemin nemi (S_0) ve yeraltı suyu depolaması (G_0) sıfır alınmıştır. CRR modellerinin (Şekil 3.2-Şekil 3.7) akış bileşenleri ve ara değişkenlerinin sembolleri Tablo 3.1'de tanımlanmıştır. Tüm modellere ait parametrelerin tanımı ve alt-üst sınır değerleri Tablo 3.2'de özetlenmiştir.

3.1.1 Temez modeli (HM1)

Temez (1977) tarafından geliştirilmiştir, sistem doymamış üst bölge (S) ve doymuş alt bölge (G) olarak ikiye ayrılır. Bu modelde yağışın (P) bir kısmı doğrudan akışa (Q_s) katılırken bir kısmı buharlaşır. Akışa katılan kısmın bir bölümü (Q_g) akiferde depolanır ve gecikmeli olarak akışa katılır (Perez-Sanchez, J. et al. 2019, Zuniga et al. 2022). Model parametreleri maksimum zemin nemi (SM), maksimum infiltrasyon (R_{max}), akifer deşarj katsayısı (c) ve havza katsayısı (k) şeklinde tanımlanır (Şekil 3.2).




$$\begin{aligned}
 (1) \quad & P_{0,t} = c \times (SM - S_{t-1}) \\
 (2) \quad & EW_t = \max\left(0, \frac{(P_t - P_{0,t})^2}{P_t + SM - S_{t-1} - 2P_{0,t}}\right) \\
 (3) \quad & AET_t = \max(0, \min(S_{t-1} + P_t - EW_t, PET_t)) \\
 (4) \quad & S_t = \max(0, S_{t-1} + P_t - EW_t - AET_t) \\
 (5) \quad & R_t = R_{max} \times \frac{EW_t}{EW_T + R_{max}} \\
 (6) \quad & Q_{s,t} = EW_T - R_t \\
 (7) \quad & G_t = \max\left(0, G_{t-1}e^{-k} + R_t \left(\frac{1 - e^{-k}}{k}\right)\right) \\
 (8) \quad & Q_{gw,t} = G_{t-1} - G_t + R_t \\
 (9) \quad & Q_{m,t} = Q_{s,t} + Q_{gw,t}
 \end{aligned}$$

Şekil 3.2: HM1 modelini akış şeması ve formülleri

3.1.2 Dinamik su bütçesi modeli (HM2)

Budyko (1958) tarafından önerilen su bütçesi modeli yağış ve evapotranspirasyon verilerine ihtiyaç duymaktadır, Zhang vd. (2008) tarafından dört parametrelili bir modele dönüştürülmüştür. Okkan (2015) tarafından atanan yeni yeraltı suyu biriktirme parametresi ile beş parametrelili versiyonu kullanılmaya başlanmıştır. Modelde iki biriktirme haznesi tanımlanmıştır, maksimum zemin nemi (SM), yüzeysel akış katsayısı (α_1), evapotranspirasyon etkinliği katsayısı (α_2), doğrusal yeraltı suyu haznesi parametresi (d) ve yeraltı biriktirme sistemi parametresi (e) olarak tanımlanan beş parametrelili bir CRR modelidir (Şekil 3.3).



$$(10) \quad Q_{s,t} = P_t \times \left[1 - F \left(\frac{SM - S_{t-1} + PET_t}{P_t}, \alpha_1 \right) \right]$$

$$(11) \quad AW_t = S_{t-1} + P_t \times F \left(\frac{SM - S_{t-1} + PET_t}{P_t}, \alpha_1 \right)$$

$$(12) \quad R_t = AW_t \times \left[1 - F \left(\frac{SM + PET_t}{AW_t}, \alpha_2 \right) \right]$$

$$(13) \quad AET_t = AW_t \times F \left(\frac{PET_t}{AW_t}, \alpha_2 \right)$$

$$(14) \quad S_t = \max \left[AW_t \times F \left(\frac{SM + PET_t}{AW_t}, \alpha_2 \right) - AET_t, 0 \right]$$

$$(15) \quad Q_{gw,t} = d \times G_{t-1}$$


$$(16) \quad G_t = \max[0, (R_t + G_{t-1}) \times e - Q_{gw,t}]$$

$$(17) \quad Q_{m,t} = Q_{s,t} + Q_{gw,t}$$

Şekil 3.3: HM2 modelini akış şeması ve formülleri

3.1.3 abcde modeli (HM3)

Thomas (1981) tarafından abcd modeli imiyle geliştirildiğinde dört parametrelilik olarak birçok havzada kullanılan model, Okkan vd. (2020)'nin yeraltı depolama fonksiyonu için ilave ettikleri parametre ile beş parametrelilik abcde versiyonuna dönüştürülmüştür. Modelin iki biriktirme haznesi vardır ve parametreleri zemin doygunluğu katsayısı (a), maksimum zemin nemi (b), sızma (c), yeraltı suyu akış katsayısı (d) ve yeraltı biriktirme katsayısı (e) şeklinde ifade edilir (Şekil 3.4).



$$(18) \quad AW_t = S_{t-1} + P_t$$

$$(19) \quad EW_t = AW_t - \left(\frac{AW_t + b}{2a} - \sqrt{\left(\frac{AW_t + b}{2a} \right)^2 - \frac{AW_t \times b}{a}} \right)$$

$$(20) \quad Q_{s,t} = EW_t \times (1 - c)$$

$$(21) \quad R_t = EW_t \times c$$

$$(22) \quad S_t = \left(\frac{AW_t + b}{2a} - \sqrt{\left(\frac{AW_t + b}{2a} \right)^2 - \frac{AW_t \times b}{a}} \right) \times e^{-PET_t/b}$$

$$(23) \quad Q_{gw,t} = d \times G_{t-1}$$


$$(24) \quad G_t = \max[0, (R_t + G_{t-1}) \times e - Q_{gw,t}]$$

$$(25) \quad Q_{m,t} = Q_{s,t} + Q_{gw,t}$$

Şekil 3.4: HM3 modelini akış şeması ve formülleri

3.1.4 Avusturalya su bütçesi modeli (HM4)

Taban akış sabiti (δ), ilk haznenin alanı (A_1), ikinci haznenin alanı (A_2), durgunluk sabiti (d) ve yeraltı suyu parametresi (e) olarak tanımlanan altı parametresi bulunan Avustralya Su Bütçesi Modeli, Avusturalya'daki havzalarda kullanılmak için tasarlanmış ve Boughton (2004) tarafından geliştirilmiştir (Şekil 3.5).



$$(26) \quad P_{k,t} = A_k \times P_t, \quad k = 1,2,3$$

$$(27) \quad AET_{k,t} = \min(A_k \times PET_t, S_{k,t-1} + P_{k,t})$$

$$(28) \quad EW_{k,t} = \max(S_{k,t-1} + P_{k,t} - AET_{k,t} - SM_k, 0)$$

$$(29) \quad S_{k,t} = \max(0, S_{k,t-1} + P_{k,t} - EW_{k,t} - AET_{k,t})$$

$$(30) \quad TEW_t = \sum_{k=1}^3 EW_{k,t}$$

$$(31) \quad Q_{s,t} = TEW_t \times (1 - \delta)$$

$$(32) \quad R_t = TEW_t \times \delta$$

$$(33) \quad Q_{gw,t} = d \times G_{t-1}$$

$$(34) \quad G_t = \max(0, (R_t + G_{t-1}) \times e - Q_{gw,t})$$


$$(35) \quad Q_{m,t} = Q_{s,t} + Q_{gw,t}$$

Eğer $(A_1 + A_2) > 1 \rightarrow A_2 = 1$
Eğer $(A_1 + A_2) = 1 \rightarrow 10^{-6}$ değilse $A_3 = 1 - (A_1 - A_2)$

Şekil 3.5: HM4 modelini akış şeması ve formülleri

3.1.5 Guo modeli (HM5)

Başlarda iki parametrelili olarak geliştirilen model, yıllar içerisinde evapotranspirasyon düzeltme faktörü eklemesiyle üç parametrelili olarak kullanılmıştır. Son versiyonu (Guo, 1995) modelin maksimum zemin nemi (SM), yüzey akış katsayısı(α), havza gecikme katsayısı (β), yeraltı suyu hazne katsayısı (d), yeraltı suyu gecikme katsayısı(e) ve potansiyel evapotranspirasyon katsayısı (θ) eklenmiş altı parametrelili versiyonundadır (Şekil 3.6).



$$(36) \quad PET_{adj,t} = \theta \times PET_t$$

$$(37) \quad \text{if } AET_t < P_t \rightarrow S_t = \min[SM, \max(S_{t-1} + P_t - PET_{adj,t}, 0)]$$

$$\text{else} \rightarrow S_t = \min(SM, S_{t-1} \times e^{(PE - PET_{adj,t})/SM})$$

$$(38) \quad EW_t = \max(S_{t-1} + P_t - PET_{adj,t} - SM, 0)$$

$$(39) \quad Q_{s,t} = \alpha \times EW_t$$

$$(40) \quad REW_t = (1 - \alpha) \times EW_t$$

$$(41) \quad Q_{ss,t} = \beta \times REW_t$$

$$(42) \quad R_t = (1 - \beta) \times REW_t$$

$$(43) \quad Q_{gw,t} = d \times G_{t-1}$$


$$(44) \quad G_t = \max[0, (R_t + G_{t-1}) \times e - Q_{gw,t}]$$

$$(45) \quad Q_{m,t} = Q_{s,t} + Q_{ss,t} + Q_{gw,t}$$

Şekil 3.6: HM5 modelini akış şeması ve formülleri

3.1.6 Thornthwaite su bütçesi modeli (HM6)

İlk olarak 1955 yılında Thornthwaite ve Matter tarafından geliştirilen model, 2001 yılında Fıstıkoğlu ve Harmancıoğlu (2001) tarafından potansiyel evapotranspirasyon katkısı eklenerek modifiye edilmiştir. Modelin, maksimum zemin nemi (SM), yüzey akış katsayısı (α), yüzey altı akış katsayısı (β), doğrusal yeraltı suyu katsayısı (γ) ve yeraltı biriktirme katsayısı (e) olarak tanımlanan beş parametresi bulunmaktadır (Şekil 3.7).



$$(46) \quad Q_{s,t} = \alpha \times P_t$$

$$(47) \quad I_t = (1 - \alpha) \times P_t$$

$$(48) \quad S_t = \min[SM, \max(S_{t-1} + I_t - PET_t, 0)]$$

$$(49) \quad EW_t = \max[S_{t-1} + I_t - PET_t - SM, 0]$$

$$(50) \quad Q_{ss,t} = \beta \times EW_t$$

$$(51) \quad R_t = (1 - \beta) \times EW_t$$

$$(52) \quad Q_{gw,t} = \gamma \times G_{t-1}$$

$$(53) \quad G_t = \max[0, (R_t + G_{t-1}) \times e - Q_{gw,t}]$$

$$(54) \quad Q_{m,t} = Q_{s,t} + Q_{ss,t} + Q_{gw,t}$$

Şekil 3.7: HM6 modelini akış şeması ve formülleri

Tablo 3.1: Şekil 3.2-Şekil 3.7'deki akış bileşenleri veya ara değişkenlere ilişkin sembollerin tanımları

Kısaltma	Tanım						
		HM1	HM2	HM3	HM4	HM5	HM6
AET	Gerçek evapotranspirasyon	♦	♦		♦♦♦		
AW	Mevcut su			♦			
EW	Aşırı su	♦		♦	♦♦♦	♦	♦
G	Yeraltı suyu depolaması	♦	♦	♦	♦	♦	♦
P	Yağış	♦	♦	♦	♦	♦	♦
PET _{adj}	Ayarlanmış potansiyel buharlaşma					♦	
Q _s	Yüzey akışı	♦	♦	♦	♦	♦	♦
Q _{ss}	Yeraltı akışı					♦	♦
Q _{gw}	Yeraltı suyu akışı	♦	♦	♦	♦	♦	♦
Q _m	Toplam simüle edilmiş akış	♦	♦	♦	♦	♦	♦
R	Yeraltı suyu beslemesi	♦	♦	♦	♦	♦	♦
REW	Yüzey akışından sonra kalan fazla su					♦	
S	Toprak nem depolaması	♦	♦	♦	♦♦♦	♦	♦
TEW	Total excessive water				♦		

Tablo 3.2: CRR Modellerinin kalibrasyonunda kullanılan parametre adları ve parametre değer aralıkları

CRR	Parametre	Tanım	Aralık
HM1	SM	Toprak nemi depolama kapasitesinin maksimum değeri	10-1000 mm
	R_{max}	Derin sızmanın maksimum kapasitesi	0,01-1000 mm
	c	Yüzey akışı kontrol katsayısı	0,01-0,99
	k	Yeraltı suyu depolama katsayısı	0,01-2
HM2	SM	Toprak nemi depolama kapasitesinin maksimum değeri	10-1000 mm
	α_1	Yüzey akışı kontrol katsayısı	0,01-0,99
	α_2	Evapotranspirasyon verimliliği parametresi	0,01-0,99
	d ve e	Temel akış parametreleri	0,01-0,99
HM3	a	Toprak doymuş hale gelmeden önce yüzey akışının oluşumunu kontrol eden katsayı	0,01-0,99
	b	Toprak nemi depolama kapasitesinin maksimum değeri	10-1000 mm
	c	Hem yüzey akışını hem de yeraltı suyu dolumunu kontrol eden katsayı	0,01-0,99
	d ve e	Temel akış parametreleri	0,01-0,99
HM4	SM_k	k'inci toprak nem depolama kapasitesinin maksimum akış parametreleri	10-1000 mm
	A_k	k'inci toprak nem depolama alanının kısmi alanı	0,001-1,0
	δ	Hem yüzey akışını hem de yeraltı suyu dolumunu kontrol eden katsayı	0,001-0,99
	d ve e	Temel akış parametreleri	0,010-0,99
HM5	SM	Toprak nemi depolama kapasitesinin maksimum değeri	0,1-1000 mm
	θ	Potansiyel buharlaşmayı ayarlayan katsayı	0,001-2,0
	α	Yüzey akışını kontrol eden katsayı	0,001-1,0
	β	Yeraltı akışını ve yeraltı suyu dolumunu kontrol eden katsayı	0,001-1,0
d ve e	Temel akış parametreleri	0,01-1,0	
HM6	SM	Toprak nemi depolama kapasitesinin maksimum değeri	10-1000 mm
	α	Yüzey akışını kontrol eden katsayı	0,01-0,99
	β	Yeraltı akışını ve yeraltı suyu dolumunu kontrol eden katsayı	0,01-0,99
	d ve e	Temel akış parametreleri	0,01-0,99

3.2 Kavramsal Model Parametreleri ve ERA5 Yeniden Analiz Izgara Verilerinin Ağırlıklarının Ortak Optimizasyonu

Bu çalışmada hidrolojik modelleri temsil eden en doğru veri kombinasyonunu belirlemek amacıyla üç farklı ağırlıklandırma yöntem kullanılarak veriler ağırlıklandırılmıştır. Ölçülmüş meteorolojik verilere alternatif olarak ERA5 verilerinin alt havzanın tüm alanını kapsayacak ızgaralar kullanılarak mekânsal temsiliyet kabiliyetinin artırılacağı düşüncesiyle farklı ağırlıklandırma yöntemleri sınanmıştır.

3.2.1 Thiessen poligon ağırlıklandırma yöntemi (w1)

Thiessen poligon alanlarının (Thiessen vd., 1911) yüzdeliği oranınca yağış ve sıcaklık verilerinin ağırlıklandırılmasıyla oluşturulan veri setinin altı farklı kavramsal yağış-akış parametresinin MS-Excel Çözücü eklentisi ile optimize edilmesidir. w1 yönteminde sadece model parametreleri optimize edilir (Piotrowski, et al., 2019).

3.2.2 Thiessen poligonlarından serbest seçimli ağırlıklandırma yöntemi (w2)

Meteorolojik verilerden gridlerin yağış verileri ve model parametreleri ağırlık toplamı 1 olacak şekilde MS-Excel Çözücü eklentisi ile optimize edilmiş, evapotranspirasyon verileri aynı griddeki yağış verisi oranında ağırlıklandırılmıştır (Piotrowski, et al, 2019). Burada amaç istasyonu temsil kabiliyeti en yüksek meteorolojik veri setinin seçimini sağlamaktır.

3.2.3 Dörtgensel alan serbest seçimli ağırlıklandırma yöntemi (w3)

Meteorolojik verilerden havzayı düzgün bir dörtgen şeklinin içine alacak şekilde oluşturulmuş çerçevede bulunan gridlerin yağış verileri ve model parametreleri ağırlık toplamı 1 olacak şekilde MS-Excel Çözücü eklentisi ile optimize edilmiş, evapotranspirasyon verileri aynı griddeki yağış verisi oranında ağırlıklandırılmıştır. Burada amaç istasyonu temsil kabiliyeti en yüksek meteorolojik veri setinin seçimini sağlamaktır.

3.3 Veri Daraltma Yöntemleri

YSA'ların veri girişi arttıkça genelleme yeteneğini kaybettiği görüşünden yola çıkarak model çıktıları ve bu çıktıları oluşturan bileşenlerden oluşan veri setlerinin seçilen veri daraltma yöntemleri ile veri temsil kabiliyetini bozmadan daraltılması için seçilen iki veri daraltma yöntemi tercih edilmiştir.

3.3.1 Temel bileşen analizi (PCA)

Yağışın akışa dönüşümü; havzanın topoğrafyası, bitki örtüsü, toprak tipleri, jeomorfolojik özellikleri, iklim özellikleri, sıcaklık, yağış rejimi, buharlaşma, terleme, kar yağışı gibi fiziksel faktörlere ve arazi kullanımı, insan faaliyetleri gibi yapay faktörlere bağlı olduğunu, yapay sinir ağlarının hidrolojik modellemede kullanımının arttığını ancak genelleme yeteneğinin girdi sayısı arttıkça azaldığını bildirmiştir (Hu 1997). YSA 'ların genelleme özelliğinin havza özelliklerini ve yağış rejimini korurken bu faktörleri aralarındaki korelasyona bağlı olarak mümkün olan en az bilgi kaybını sağlayarak giriş verilerinin boyutunu azaltabilen etkili ve verimli PCA yöntemi önerilmiştir (Rencher 1998).

3.3.2 En küçük mutlak küçülme ve seçim operatörü (LASSO)

Artık karelerin hatasını minimize eden sıradan en küçük kareler yöntemi (OLS) düşük yanlılık ve büyük varyansa sahip olsa da tahminlerini doğruluğu her zaman yeterli gelmemektedir. OLS tahminlerini iyileştirmek için alt küme seçimi ve sırt regresyonu kullanılsa bile alt küme seçimi yorumlanabilir modeller sağlarken verilerdeki küçük değişiklikler sebebiyle doğru veri setini seçemeyebilirken, katsayıları düşürerek daha kararlı bir süreç oluşturan sırt regresyonu kolay yorumlanamayabilir. 'En az mutlak küçülme ve seçim operatörü' olarak adlandırılan katsayıları küçültür değerlerini 0'a ayarlayan ve böylece hem sırt regresyonunun hem alt küme seçiminin iyi yanlarını koruyan kement tekniğini geliştirmişlerdir (Tibshirani, 1996).

3.4 Kullanılan Yapay Zekâ Teknikleri

Çalışmada esnek ve veri odaklı çözümler sunabilen iki farklı yapay zeka tekniği akış yüksekliği tahmini için kullanılmıştır. Kullanılan teknikler aşağıda açıklanmıştır.

3.4.1 İleri beslemeli sinir ağı (FFNN)

İnsanın öğrenme sürecini ve sinir sistemini oluşturan nöronların ilişkilerinden yola çıkılarak tasarlanan YSA'lar insan beynine benzer çalışması istenen bilgisayar sistemleridir (Haykin, 1994). İlk uygulamaları tek katmanlı olsa da giderek yaygınlaşan çok katmanlı algılayıcı modelleri giriş katmanı, gizli katman ve çıktı katmanından oluşmaktadır. Modelleme aşamasında kullanılacak verilere göre giriş-çıkış katmanlarına ait hücreler belirlenirken, hedef çözüme göre deneme yanılma yöntemiyle gizli katman hücreleri belirlenmektedir (Haykin 1994, Ham ve Kostanic, 2001).

Çok katmanlı YSA'lar girdiler (x), girdilerin etkinliğini belirleyen ağırlıklar (w), ağırlıklandırılmış girdilerin toplamı olarak bulunan net fonsiyon (net), hücrelere gelen girdileri ara katman hücre çıktısına (y) dönüştüren aktivasyon fonksiyonu (f) şeklinde tanımlanan 5 ana unsurdan oluşmaktadır (Haykin, 1994; Ham ve Kostanic, 2001; Öztemel, 2003). Çalışmada aktivasyon fonksiyonu olarak logaritmik sigmoid fonksiyon kullanılmaktadır (Öztemel, 2003).

YSA'nın girdilerle hedeflenen çıktıları öğrenebilmesi için doğru seçilmiş bir algoritma ile eğitilmesi gerekmektedir (Mandic ve Chambers, 2001). YSA'nın ilk aşaması girdi katmanı ile ağa tanıtılan girdilerin seçilen ağırlıklar oranında gizli katmandaki her hücreye iletilerek net girdi değerleri üretilmektedir. Her katman için bu işlemlerin tamamlanmasıyla ileri hesaplama aşaması tamamlanmış olur. İkinci aşama ise girdiler ile çıktıların karşılaştırıldığı ve amaç fonksiyonu olan en küçük hataların karesinin ortalamasının karekökü (RMSE) değerini en küçükleyerek sıfıra doğru yaklaştırması için iteratif bir yaklaşımla ağırlıkları güncelleyerek minimize etmektedir. Bu iki aşamalı çalışma prensibinden dolayı YSA'lara ileri beslemeli geri yayımlı yapay sinir ağları da denmektedir.

Çalışma kapsamında ileri beslemeli geri yayımlı yapay sinir ağı Levenberg-Marquardt optimizasyon algoritmasıyla optimize edilmiştir (Okkan, U, vd. 2010).

3.4.2 Radyal tabanlı fonksiyon ağı (RBFN)

Sinir hücrelerinin davranışlarından esinlenerek 1988 yılında uzayda eğri uydurma yaklaşımıyla geliştirilmiştir (Broomhead vd., 1988; Ham, F vd, 2001). RBFN giriş katmanı, gizli katman ve çıktı katmanı olarak tanımlanan 3 katmandan oluşmuştur ve verilere çıktı vektör uzayındaki en uygun yüzeyi bulmayı amaçlayan bir interpolasyon yaklaşımıdır. Klasik YSA'lardan farkı verilerin girdi katmanından gizli katmana geçişte radyal tabanlı aktivasyon fonksiyonları ve doğrusal olmayan bir kümeleme analizinden geçmesidir. Gizli katman ile çıktı katmanı arasındaki işleyiş ise YSA yaklaşımına benzer biçimde eğitimin gerçekleştirildiği kısımdır (Okkan, U. vd. 2012). RBFN 'lerde hücre merkezleri, çıktı katmanındaki ağırlıklar ve kullanılan aktivasyon fonksiyonu en önemli unsurlardır. Pek çok aktivasyon fonksiyonu kullanılsa da çalışmada Gauss aktivasyon fonksiyonu seçilmiştir. Gauss fonksiyonuyla model performansına önemli ölçüde katkısı olan olan dağılma (spread) parametresi girdi vektörünü (x), hücre merkezleri (ck) ve standart sapma (σ) elemanlarıyla hesaplanmaktadır (Ham ve Kostanic, 2001).

Modelin eğitim süreci iki aşamadan oluşmaktadır, ilk aşamada RBFN modeline ait (ck) K-ortalamlar yöntemi kullanılarak (MacQueen ve Some, 1967) belirlenen hücre merkezleri ile belirlenen eğitim seti için ağırlık çıktısı (y) hesaplanmaktadır. Dağılım parametresi deneme-yanılma yöntemiyle belirlenmektedir. Ağırlık çıktıları gözlenen çıktılar ile karşılaştırılarak amaç fonksiyonunu (RMSE) minimize edecek şekilde hesaplanır.

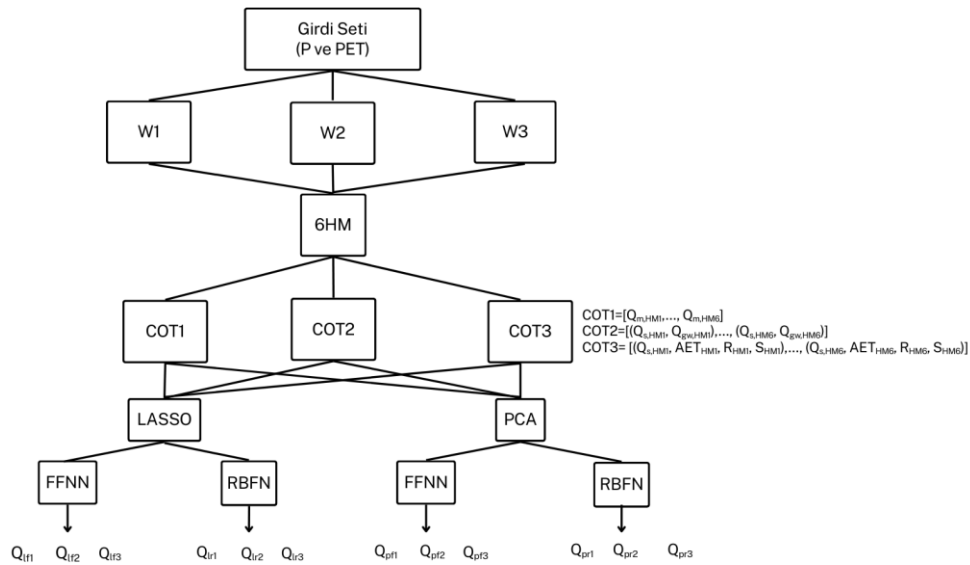
3.5 Kavramsal Modellerle Yapay Zekâ Entegrasyonu Şemaları

Bu çalışmada CRR modellerinin ERA5 ızgara veri setleri ile w_1 , w_2 ve w_3 ağırlıklandırmaları MS Excel Çözücü eklentisi kullanılarak model simülasyonları üretildi. Tüm modellerin akış tahminlerinden oluşan model çıktısı (Q_m) oluşan altı veri setleri (COT1) oluşturuldu. Ayrıca modellerin iç dinamiklerinin belirlediği süreçlerden gelen belirsizlikleri azaltabilmek düşüncesiyle Q_m 'i oluşturan alt varyantlardan iki farklı veri seti oluşturuldu. Bu veri setlerinden tüm hidrolojik modellerin yüzey akışı (Q_s) ve yeraltı suyu (Q_{gw}) bileşenleri ile 12 verili (COT2) giriş veri seti oluşturuldu. Son veri seti olarak da tüm hidrolojik modellerin yüzey akışı (Q_s), gerçek evapotranspirasyon (AET), yeraltı suyu depolaması (R) ve zemin nemi depolaması (S) alt varyantlarından oluşan 24 verili giriş seti (COT3) oluşturuldu. Veri setlerinin büyüklüğü yapay sinir ağlarının veriler arasındaki korelasyona bağlı olarak doğru veri setini seçmesini zorlaştırarak tahmin gücünü zayıflatabileceğinden ve işlem yükünü artırdığından tüm veri setleri COT1, COT2 ve COT3 yazılan MATLAB kodları ile veri daraltma yöntemlerinden PCA ve LASSO yöntemleri ile daraltılmıştır. Daraltılan veriler MATLAB ortamında kodlanan iki farklı yapay sinir ağı algoritması FFNN ve RBFN ile optimize edilerek model simülasyonları oluşturulmuştur.

İleri Beslemeli yapay sinir ağları (FFNN) ile seçilen ağırlıklandırma yöntemleriyle hesaplanan model çıktıların, veri küçültme işlemi sonrası eğitim oranı 0,5, gizli katmandaki hücre sayısı maksimum 20, iterasyon sayısı maksimum 20 olacak şekilde en küçük RMSE validasyon sonucunu bulacak şekilde Levenberg-Marquardt (LM) algoritmasıyla her bir deneme için 10 kez toplamda en fazla 4000 defa koşturularak elde edilen en iyi model çıktısının performans değerlendirme kriterlerine göre sonuçları aşağıdaki tablo ve grafiklerde verilmiştir. FFNN yönteminde tüm değişkenler [0,1] aralığında ölçeklenmiştir. Elde edilen sonuçlar ters ölçekleme ile başlangıç ölçeği olan mm/ay birimine çekilmiştir. Bu yöntem ile elde edilen çıktılar girdi türüne ve veri boyutu indirgeme yöntemine göre Q_{f1} , Q_{f2} , Q_{f3} ve Q_{pf1} , Q_{pf2} , Q_{pf3} olarak gösterilmiştir. Q_{f1} , Q_{f2} , Q_{f3} LASSO ile boyutu indirgenen sırasıyla COT1, COT2 ve COT3 veri setinin FFNN yöntemiyle elde

edilen model çıktılarıdır. Q_{pf1} , Q_{pf2} , Q_{pf3} PCA ile boyutu indirgenen sırasıyla COT1, COT2 ve COT3 veri setinin FFNN yöntemiyle elde edilen model çıktıları temsil etmektedir (Şekil 3.8).

Radyal Tabanlı yapay sinir ağları (RBFN) ile seçilen ağırlıklandırma yöntemleriyle hesaplanana model çıktılarının, veri küçültme işlemi sonrası eğitim oranı: 0.5, gizli katmandaki hücre sayısı 2-20 arasında 1'er 1'er artırılarak maksimum 20, sigma değeri 0,1-10 arasında 0,05 artırılarak maksimum 10 olacak şekilde en küçük RMSE validasyon sonucunu ulaşma hedefiyle her adımda 10 kez toplamda 37.810 defa koşturularak elde edilen en iyi model çıktısı kullanılarak performans değerlendirme kriterlerine göre sonuçları sonuçlar bölümünde detaylı olarak değerlendirilecektir. RBFN yönteminde tüm değişkenler [0,1] aralığında ölçeklenmiştir. Elde edilen sonuçlar ters ölçekleme ile başlangıç ölçeği olan mm/ay birimine çekilmiştir. Bu yöntem ile elde edilen çıktılar girdi türüne ve veri boyutu indirgeme yöntemine göre Q_{lr1} , Q_{lr2} , Q_{lr3} ve Q_{pr1} , Q_{pr2} , Q_{pr3} olarak gösterilmiştir. Q_{lr1} , Q_{lr2} , Q_{lr3} LASSO ile boyutu indirgenen sırasıyla COT1, COT2 ve COT3 veri setinin RBFN yöntemiyle elde edilen model çıktılarıdır. Q_{pr1} , Q_{pr2} , Q_{pr3} PCA ile boyutu indirgenen sırasıyla COT1, COT2 ve COT3 veri setinin RBFN yöntemiyle elde edilen model çıktıları temsil etmektedir (Şekil 3.8).



Şekil 3.8: Model kombinasyonları ve yapay zekâ entegrasyon prosesi

3.6 Modelleme Zincirinin Dinamik Hassasiyetinin Belirlenmesi

Kullandıkları optimizasyon algoritmasındaki parametrelerin kalibrasyon problemine etkisini ve parametrelerin birbirleriyle etkileşiminin etkisini üç yollu ANOVA analizi ile ortaya koymuştur (Qi et al., 2016). Dört parametrelili bir hidrolojik modelde fourway Anova olarak adlandırılan ve parametre kombinasyonlarının ve birbirleriyle etkileşimli terimlerin birinci, ikinci ve üçüncü mertebeden etkileşimlerinin analizini ortaya koymuşlardır (Okkan vd., 2021).

3.7 Performans Metrikleri

Kalibrasyon ve validasyon dönemlerine ait model çıktılarının performansları RMSE'nin yanı sıra R^2 , NSE, Kling Gupta Verimliliği (KGE) ve PBIAS kriterlerine göre değerlendirildi. RMSE kriteri model ile gözlem arasındaki hata büyüklüğünü ölçen bir metrik olup, model çıktısı olan aylık ortalama akış yüksekliği milimetre (mm) cinsinden ifade edildiğinden birimi mm'dir. Denklem 3.1 de N veri adedini, Q_{obs} gözlenen değeri ve Q_m model tarafından üretilen tahmini temsil etmektedir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_{obs,i} - Q_{m,i})^2} \quad (3.1)$$

Bu kriterlerden R^2 değerinin 1'e yaklaşması tahminin gerçek değere yakınsadığını göstermektedir. Denklem 3.2'de N veri adedini, Q_{obs} gözlenen değeri ve Q_m model tarafından üretilen tahmini temsil etmektedir. \bar{Q}_{obs} ve \bar{Q}_m sırasıyla gözlenen değerlerin ve model çıktılarının ortalamasını göstermektedir.

$$R^2 = \left[\frac{\sum_{i=1}^N (Q_{obs,i} - \bar{Q}_{obs})(Q_{m,i} - \bar{Q}_m)}{\sqrt{\sum_{i=1}^N (Q_{obs,i} - \bar{Q}_{obs})^2} \sqrt{\sum_{i=1}^N (Q_{m,i} - \bar{Q}_m)^2}} \right]^2 \quad (3.2)$$

Hidrolojik modellerin performansının değerlendirilmesi için sıklıkla kullanılan NSE performans değerlendirme aralıkları aşağıda Denklem 3.3'te verilmiştir. N veri adedini, Q_{obs} gözlenen değeri ve Q_m model tarafından üretilen tahmini ve \bar{Q}_{obs} gözlenen değerlerin ortalamasını göstermektedir (Moriasi vd., 2007; Noori vd., 2020, Okkan vd. 2021).

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (Q_{obs,i} - Q_{m,i})^2}{\sum_{i=1}^N (Q_{obs,i} - \bar{Q}_{obs})^2} \right] \quad (3.3)$$

Çok iyi: $0.75 < NS \leq 1$

İyi: $0.65 < NS \leq 0.75$

Kabul edilebilir: $0.50 < NS \leq 0.65$

Uygun değil: $NS \leq 0.50$

KGE (Gupta vd., 2009) NS'ye benzer şekilde değerlendirilir. Sonucun 1'e yaklaştıkça tahmin performansının iyileştirme gösterdiğini ifade etmektedir. Denklem 3.4'te, r gözlem ve model çıktıları arasındaki lineer korelasyonunu, α model çıktısının standart sapmasının (σ_m) gözlenen değerlerin standart sapmasına (σ_{obs}) oranını ve β model çıktısının standart sapmasının (μ_m) gözlenen değerlerin standart sapmasına (μ_{obs}) oranını ifade etmektedir.

$$KGE = 1 - \sqrt{(r - 1)^2 + (\alpha - 1)^2 + (\beta - 1)^2} \quad (3.4)$$

PBIAS, model tahminlerinin gözlenen değerden ortalama negatif sapmasını hesaplamak için kullanılır. N veri adedini, Q_{obs} gözlenen değeri ve Q_m model tarafından üretilen tahmini temsil etmektedir (Moriassi vd., 2007).

$$PBIAS = \frac{\sum_{i=1}^N (Q_{obs} - Q_m)}{\sum_{i=1}^N Q_{obs}} * 100 \quad (3.5)$$

Çok iyi: $PBIAS \leq \pm 10$

İyi: $\pm 10 \leq PBIAS < \pm 15$

Kabul edilebilir: $\pm 15 \leq PBIAS \leq \pm 25$

Uygun değil: $PBIAS \geq \pm 25$

Bu çalışmada model zinciri stratejisinin farklı basamaklarına ait model performansları karşılaştırılmıştır. Bu karşılaştırma kalibrasyon ve validasyon dönemlerine ait model performanslarından R^2 , NSE, KGE kriterleri için yapılmıştır. Bu karşılaştırmayı yüzdesel olarak ifade etmek için Denklem 3.6'da ifade edilen İyileştirme Oranı (IR) formülü kullanılmıştır.

$$IR = \frac{P_{YSA} - P_{HM}}{P_{YSA}} \times 100 \quad (3.6)$$

Bu ifadede, P_{YSA} ve P_{HM} sırasıyla en iyi yapay zeka modelinin ve en iyi tekli modelin performans kriterine göre deęerini temsil etmektedir.

Pozitif deęerler hibrit modelin tekli modele gre performans artışı saęladığını, negatif deęerler ise performans dşşn gstermektedir.

Bu oran temelli yaklaşıım, benzer performans deęerlendirme yntemlerine dayanmaktadır (Moriasi et al., 2007; Gupta et al., 2009; Harris, 2015).

4. BULGULAR

Çalışmada elde edilen sonuçlar oluşturulan model zinciri stratejisinin önemli basamaklarının değerlendirilmesi için üç kısımda verilmiştir. Model zincirinde uygulanan üç farklı ağırlıklandırma yönteminin karşılaştırması 4.1’de, YSA entegrasyonunun sonuçları 4.2’de ve modelleme zincirinin dinamik hassasiyet analizi 4.3’te sunulmuştur.


4.1 Veri Ağırlıklandırma Yöntemlerinin Karşılaştırılması

Bu tez çalışmasında öncelikle altı farklı hidrolojik modelin w_1 , w_2 ve w_3 ağırlıklandırma yöntemleri kullanılarak model performansları değerlendirilmiştir. Her ağırlıklandırma yöntemi bir öncekine kıyasla model yanlılıklarını düzelterek performansı iyileştirdiği görülmüştür. Seçilen istasyona yakın meteorolojik istasyonlar veya yakın havzalardaki meteorolojik verilerin farklı yöntemlerle ağırlıklandırılması ile yaptıkları çalışmalarda kalibrasyon dönemi verilerinde gözlemledikleri iyileşmeyi validasyon döneminde elde edemedikleri çalışmanın (Piotrovski, A. P. vd., 2019) aksine ERA5 verilerinin üç farklı ağırlıklandırma yöntemi bu çalışmada hem kalibrasyon döneminde hem de validasyon döneminde model tahminlerinde iyileşme sağlamıştır. Tüm performans değerlendirme metriklerine göre seçilen 5 istasyon için genel bir değerlendirilme yapıldığında ortak optimizasyon ağırlıkları w_2 ve w_3 ’ün, w_1 ağırlığından, w_3 ’ün de w_2 ‘den daha iyi tahminler oluşturduğu belirlenmiştir. İki istasyonda w_2 ve w_3 tahminlerinde performans değerlerinin neredeyse aynı olduğu gözlenmiştir. Bunun sebebinin grid seçimlerinin neredeyse aynı olmasından kaynaklandığı düşünülmektedir. Tablo 4.1’de ağırlıklara göre istasyonların grid seçimleri gösterilmektedir.

Tablo 4.1: İstasyonların ağırlıklandırma yöntemine göre seçilen gridler

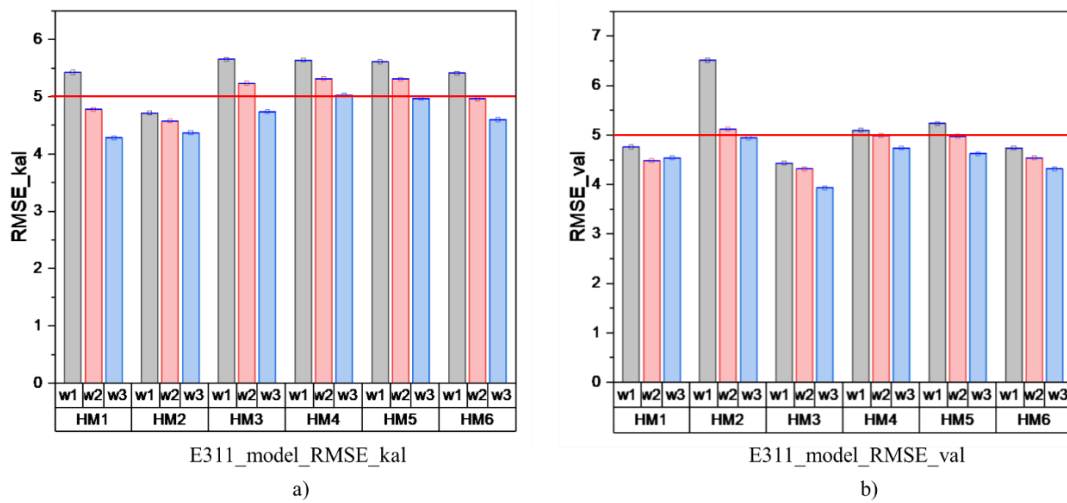
Ağırlıklandırma Yöntemi	E311	E314	E316	E321	E328	
W1	HM1, HM2, HM3, HM4, HM5, HM6 (17 Adet Grid)	31-35,43-47, 57- 59, 70, 71, 82, 83 (17 Adet Grid)	3-6, 15-18,26-29, 37-40,49-51 (19 Adet Grid)	17-19, 28-30, 50-55, 63-68, 76-80 (27 Adet Grid)	18-21, 31-33 (7 Adet Grid)	30, 31, 42-45, 54-58, 67- 70, 81, 82 (17 Adet Grid)
	HM1 (4 Adet Grid)	44, 45, 71, 82 (4 Adet Grid)		17, 63, 76, 78 (4 Adet Grid)	31, 32 (2 Adet Grid)	31, 67 (2 Adet Grid)
	HM2 (3 Adet Grid)	32, 45, 82 (3 Adet Grid)		63, 78 (2 Adet Grid)	20, 31, 32 (3 Adet Grid)	30, 45, 67, 69, 81 (5 Adet Grid)
W2	HM3 (3 Adet Grid)	44, 45, 82 (3 Adet Grid)	49 (1 Adet Grid)	17, 51, 63, 76, 78 (5 Adet Grid)	31, 32 (2 Adet Grid)	30, 67, 81 (3 Adet Grid)
	HM4 (3 Adet Grid)	44, 45, 82 (3 Adet Grid)		17, 50, 63, 65, 78 (5 Adet Grid)	31 (1 Adet Grid)	30, 67, 81 (3 Adet Grid)
	HM5 (3 Adet Grid)	44, 45, 82 (3 Adet Grid)		17, 50, 63, 78 (4 Adet Grid)	32, 33 (2 Adet Grid)	30, 67, 81 (3 Adet Grid)
	HM6 (3 Adet Grid)	44, 45, 82 (3 Adet Grid)		50, 51, 63, 76, 78 (5 Adet Grid)	31, 32 (2 Adet Grid)	30, 67, 81 (3 Adet Grid)
	HM1 (3 Adet Grid)	31, 71, 79 (3 Adet Grid)		16, 63, 75, 78 (4 Adet Grid)	31, 32 (2 Adet Grid)	32, 33, 66 (3 Adet Grid)
	HM2 (4 Adet Grid)	31, 45, 46, 79 (4 Adet Grid)		63, 78 (2 Adet Grid)	20, 30, 31, 32 (4 Adet Grid)	30, 58, 78, 79, 80 (5 Adet Grid)
W3	HM3 (1 Adet Grid)	79 (1 Adet Grid)		16, 75, 78 (3 Adet Grid)	31, 32 (2 Adet Grid)	58, 78 (2 Adet Grid)
	HM4 (4 Adet Grid)	31, 56, 67, 79 (4 Adet Grid)	49 (1 Adet Grid)	16, 63, 65, 66, 78 (5 Adet Grid)	31 (1 Adet Grid)	30, 33, 66, 67, 69, 70, 78 (7 Adet Grid)
	HM5 (1 Adet Grid)	79 (1 Adet Grid)		16, 75, 78 (3 Adet Grid)	32, 33 (2 Adet Grid)	30, 66, 70, 78 (4 Adet Grid)
	HM6 (2 Adet Grid)	45, 79 (2 Adet Grid)		13, 63, 75, 78 (4 Adet Grid)	31, 32 (2 Adet Grid)	30, 58, 66, 78, 81 (5 Adet Grid)

Şekil 4.1’de E311 istasyonunun model tahminlerinin ağırlık yöntemleri ve hidrolojik modellere göre kalibrasyon ve validasyon dönemi kutu grafiği verilmiştir. Grafiklerde kutuların ortasındaki çizgi medyanı, kare ortalamayı göstermektedir. Kutu grafiğinin üzerinde kalan noktalar havzadaki aşırı yağışlara işaret etmektedir. Diğer istasyonlara ait kalibrasyon ve validasyon dönemi kutu grafikleri Ek A bölümünde verilmiştir (Şekil A1-A4).



Şekil 4.1: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği

E311 istasyonunda RMSE değerinin 6 hidrolojik modelin 18 tahmin serisinde kalibrasyon döneminde 5 mm’nin altında olduğu, validasyon döneminde ise 18 tahmin serisinin 5 mm’nin altında olduğu sonucuna ulaşılmıştır. E311 istasyonuna ait RMSE kalibrasyon ve validasyon dönemi grafikleri Şekil 4.2’de verilmiştir.




Şekil 4.2: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE (mm biriminde) performans grafiği

E314 istasyonunda RMSE deęeri, 6 hidrolojik modelin 18 tahmin serisinde kalibrasyon doneminde 21mm'nin altında olduęu, validasyon doneminde ise 18 tahmin serisinin 21mm'nin altında olduęu sonucuna ulařılmıştır. E316 istasyonunda RMSE deęeri, 6 hidrolojik modelin 18 tahmin serisinde kalibrasyon doneminde 12 mm'nin altında olduęu, validasyon doneminde ise 18 tahmin serisinin 12mm'nin altında olduęu sonucuna ulařılmıştır. E321 istasyonunda RMSE deęeri 6 hidrolojik modelin 18 tahmin serisinde kalibrasyon doneminde 18 mm'nin altında olduęu, validasyon doneminde ise 18 tahmin serisinin 15 mm'nin altında olduęu sonucuna ulařılmıştır. E328 istasyonunda RMSE deęeri, 6 hidrolojik modelin 18 tahmin serisinde kalibrasyon doneminde 8 mm'nin altında olduęu, validasyon doneminde ise 18 tahmin serisinin 7 mm'nin altında olduęu sonucuna ulařılmıştır. Dięer istasyonlara ait kalibrasyon ve validasyon donemi RMSE grafikleri Ek A bolumunde verilmiřtir (řekil A5-A8).

RMSE sonularına gore aęırlıklandırma yontemleri deęerlendirildięinde beř istasyon kalibrasyon ve validasyon donemlerinde ancak bir model ya da aęırlıkta dięerlerinin altında bir performans gosterebilmiřtir. Akıř yuksekliginde E314 ve E321 istasyonlarında dięer istasyonların neredeyse iki katı kadar hatalı tahminler uretmiřtir, w2 ve w3 yontemlerinin sonuları birbirine yakındır. Genel olarak en duřuk RMSE deęerleri w3 aęırlıklandırma yonteminde elde edilmiřtir.

E311 nolu istasyonun 6 adet hidrolojik model sonucunun R^2 performans kriterine gore 18 tahmin serisinden kalibrasyon doneminde 10 adedinin $>0,65$ ve bunlardan 2 adedini $>0,75$, validasyon donemindeyse 12 adedinin $> 0,65$ ve 1 adedinin $>0,75$ deęerine ulařtıęı gorulmuřtur (řekil 4.3).



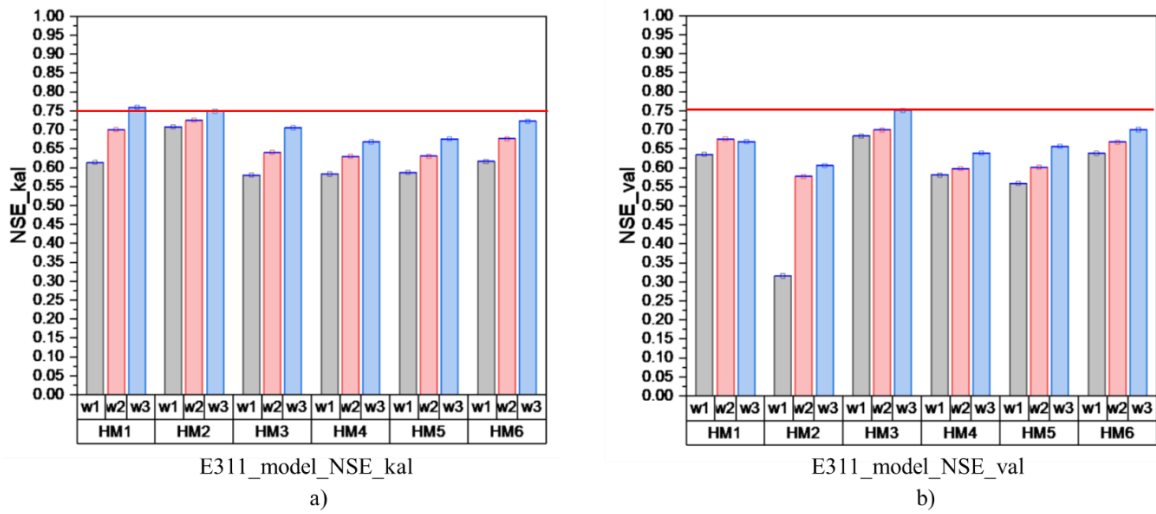
Şekil 4.3: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R² performans grafiği

E314 nolu istasyonun 6 adet hidrolojik model sonucunun R² performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 8 adedinin >0,65, validasyon dönemindeyse 16 adedinin >0,65 ve bunlardan 2 adedinin >0,75 değerine ulaştığı görülmüştür. E316 nolu istasyonun 6 adet hidrolojik model sonucunun R² performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 18 adedinin >0,65 ve bunların 4 adedinin >0,75, validasyon dönemindeyse 17 adedinin >0,65 ve bunlardan 1 adedinin >0,75 değerine ulaştığı görülmüştür. E321 nolu istasyonun 6 adet hidrolojik model sonucunun R² performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 11 adedinin >0,65 ve bunların 3 adedinin >0,75, validasyon dönemindeyse 16 adedinin >0,65 ve bunlardan 1 adedinin >0,75 değerine ulaştığı görülmüştür. E328 nolu istasyonun 6 adet hidrolojik model sonucunun R² performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 14 adedinin >0,65, validasyon dönemindeyse 18 adedinin >0,65 ve bunlardan 2 adedinin >0,75 değerine ulaştığı görülmüştür. Diğer istasyonlara ait kalibrasyon ve validasyon dönemi R² grafikleri Ek A bölümünde verilmiştir (Şekil A9-A12).

R² metriğine göre modellerin kalibrasyon ve validasyon dönemlerinde 0,75'e yaklaşan zaman zaman üzerine çıkan değerlere ulaştığı, genel olarak w2 ve w3 yöntemlerinin performansının w1'den daha yüksek olduğu görülmüştür. Modellerin kalibrasyon döneminde 0,75 sınırına yaklaşma eğiliminin daha yüksek olduğu validasyon döneminde

0,75 sınırının daha altında kaldığı ancak 0,75'in üzerindeki model sayısının görece az olduğu her iki dönemde birbirine yakın olduğu grafiklerde görülmüştür.

E311 istasyonunun 6 adet hidrolojik model sonucunun NSE performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 18 adedinin $>0,65$ ve bunlardan 1 adedinin $>0,75$, validasyon dönemindeyse 17 adedinin $>0,65$ ve 1 adedinin $=0,75$ değerine ulaştığı görülmüştür (Şekil 4.4).



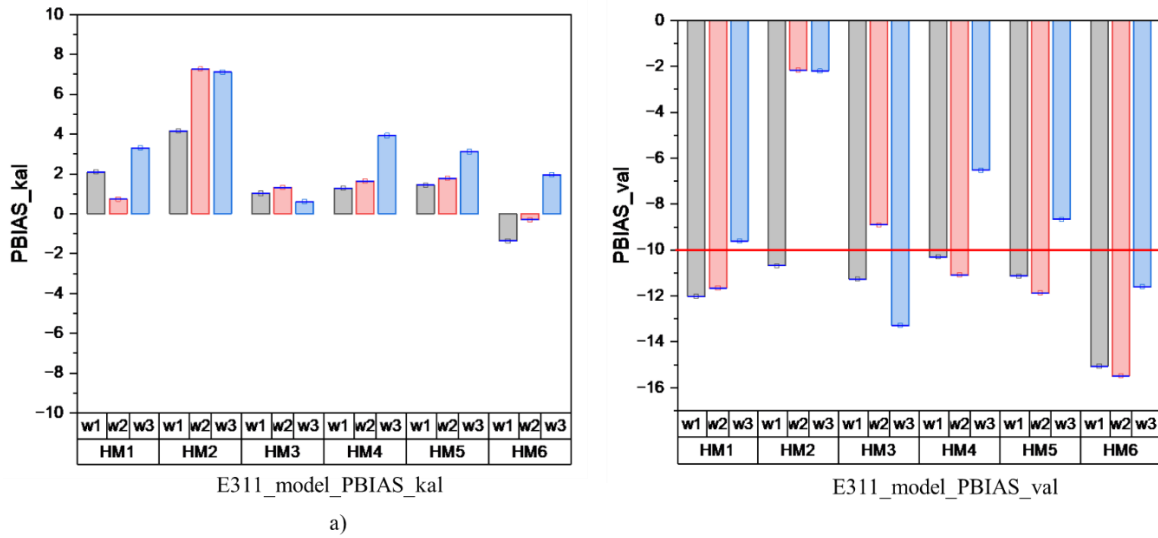
Şekil 4.4: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği

E314 istasyonunun 6 adet hidrolojik model sonucunun NSE performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 8 adedinin $>0,65$, validasyon dönemindeyse 17 adedinin $>0,65$ ve bunların 1 adedinin $>0,75$ değerine ulaştığı görülmüştür. E316 istasyonunun 6 adet hidrolojik model sonucunun NSE performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 18 adedinin $>0,65$ ve bunlardan 7 adedinin $>0,75$, validasyon dönemindeyse 11 adedinin $>0,65$ değerine ulaştığı görülmüştür. E321 istasyonunun 6 adet hidrolojik model sonucunun NSE performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 13 adedinin $>0,65$ ve bunlardan 2 adedinin $>0,75$, validasyon dönemindeyse 4 adedinin $>0,65$ değerine ulaştığı görülmüştür. E328 istasyonunun 6 adet hidrolojik model sonucunun NSE performans kriterine göre 18 tahmin serisinden kalibrasyon döneminde 13 adedinin $>0,65$ ve bunlardan 2 adedinin $>0,75$, validasyon dönemindeyse 4 adedinin $>0,65$ değerine ulaştığı görülmüştür. İstasyonların

kalibrasyon ve validasyon dönemi NSE grafikleri Ek A bölümünde verilmiştir (Şekil A13-A16).

NSE metriğine göre ise kalibrasyon dönemi ve validasyon dönemi birlikte değerlendirildiğinde her ağırlıklandırma yöntemi performans değerini biraz daha yukarı taşımayı başarmıştır. Modellerin kalibrasyon döneminde çok az bir kısmı 0,75 değerine yakın veya az üzerindedir, validasyon döneminde tüm istasyonlarda sadece bir model 0,75'i aştığı gözlenmiştir.

E311 istasyonu PBIAS performans değerlendirmesine göre 6 hidrolojik modelin 18 tahmin serisinin validasyon döneminde tamamı ± 10 değerinin arasındadır. Modellerin tahminleri çok iyi kategorisindedir. 16 model için pozitif yönde yani akımı olduğundan az, iki model içinde negatif yönde, yani akımı olduğundan fazla tahminlemiştir. Validasyon dönemindeyse tüm değerler negatif yöndedir 18 adet tahminin 16 adedi > -15 ile iyi, 6 adedi > -10 ile çok iyi performans sınıfındadır. Validasyon dönemi akış yüksekliğini eksik tahmin etme eğilimindedir (Şekil 4.5).



Şekil 4.5: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği


E314 istasyonu PBIAS performans değerlendirmesine göre 6 hidrolojik modelin 18 tahmin serisinin validasyon döneminde tamamı ± 10 değerinin arasındadır. Modellerin tahminleri

çok iyi kategorisindedir. 15 model için pozitif yönde yani akımı olduğundan az, 3 model içinde negatif yönde, yani akımı olduğundan fazla tahmin edilmiştir. Validasyon dönemindeyse tüm değerler pozitif yöndedir 18 adet tahminin hepsi <15 ile iyi, 13 adedi <10 ile çok iyi performans sınıfındadır. Validasyon dönemi akış yüksekliğini eksik tahmin etme eğilimindedir. E316 istasyonu PBIAS performans değerlendirmesine göre 6 hidrolojik modelin 18 tahmin serisinin validasyon döneminde tamamı ± 10 değerinin arasındadır. Modellerin tahminleri çok iyi kategorisindedir. 9 model için pozitif yönde yani akımı olduğundan az, 9 model içinde negatif yönde, yani akımı olduğundan fazla tahmin edilmiştir. Validasyon dönemindeyse tüm değerler negatif yöndedir 18 adet tahminin hepsi >-15 ile iyi, 6 adedi >10 ile çok iyi performans sınıfındadır. Validasyon dönemi akış yüksekliğini fazla tahmin etme eğilimindedir. E321 istasyonu PBIAS performans değerlendirmesine göre 6 hidrolojik modelin 18 tahmin serisinin validasyon döneminde tamamı ± 10 değerinin arasındadır. Modellerin tahminleri çok iyi kategorisindedir. 4 model için pozitif yönde yani akımı olduğundan az, 14 model içinde negatif yönde, yani akımı olduğundan fazla tahmin edilmiştir. Validasyon dönemindeyse tüm değerler negatif yöndedir 18 adet tahminin 2 adedi >-15 ile iyi performans sınıfındadır. Validasyon dönemi akış yüksekliğini fazla tahmin etme eğilimindedir. E328 istasyonu PBIAS performans değerlendirmesine göre 6 hidrolojik modelin 18 tahmin serisinin validasyon döneminde 17 adet model tahmini ± 15 değerinin arasındadır. Modellerin tahminleri iyi kategorisindedir. 16 adet model tahmini ± 10 değerinin arasındadır. 13 model için pozitif yönde, yani akımı olduğundan az, 3 model içinde negatif yönde, yani akımı olduğundan fazla tahmin etmiştir. Validasyon dönemindeyse 18 adet tahminin 16 adedi ± 15 ile iyi ve bunların 12 adedi ± 10 ile çok iyi performans sınıfındadır. Validasyon dönemi akış yüksekliğini fazla tahmin etme eğilimindedir. İstasyonların kalibrasyon ve validasyon dönemi PBIAS grafikleri Ek A bölümünde verilmiştir (Şekil A17-A20).

PBIAS grafikleri değerlendirildiğinde modellerin performansının w3 ağırlığında daha iyi olduğu modellerin sayıca daha fazla olmasına karşın net olarak bu metriği iyileştirdiğini söylemeye yetecek bir performans gösteremediği -10 ile +10 aralığına giren model kadar neredeyse bunu aşan model bulunduğu ve sistematik olarak negatif yönde performansın fazla olduğu yani modellerin akışı olduğundan fazla tahmin ettiği görülmüştür.

E311 istasyonu Performans değerlendirme kriterlerinden bir diğeri olan KGE'ye göre 6 hidrolojik modelin tahmini değerlendirildiğinde 18 adet tahmin serisinden kalibrasyon

döneminde 18 adedinin $>0,65$ ile iyi ve 9 adedinin $>0,75$ ile çok iyi, validasyon döneminde 17 adet $>0,65$ ile iyi ve 16 adet $>0,75$ ile çok iyi olduğu tespit edilmiştir (Şekil 4.6).



Şekil 4.6: E311 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği

E314 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE'ye göre 6 hidrolojik modelin tahmini değerlendirildiğinde 18 adet tahmin serisinden kalibrasyon döneminde 13 adedinin $>0,65$ ile iyi ve bunların 6 adedinin $>0,75$ ile çok iyi, validasyon döneminde 12 adet $>0,65$ ile iyi ve bunlardan 3 adedinin $>0,75$ ile çok iyi olduğu tespit edilmiştir. E316 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE'ye göre 6 hidrolojik modelin tahmini değerlendirildiğinde 18 adet tahmin serisinden kalibrasyon döneminde 18 adedinin $>0,65$ ile iyi ve bunların 15 adedinin $>0,75$ ile çok iyi, validasyon döneminde 18 adet $>0,65$ ile iyi ve bunlardan 16 adedinin $>0,75$ ile çok iyi olduğu tespit edilmiştir. E321 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE'ye göre 6 hidrolojik modelin tahmini değerlendirildiğinde 18 adet tahmin serisinden kalibrasyon döneminde 16 adedinin $>0,65$ ile iyi ve bunların 7 adedinin $>0,75$ ile çok iyi, validasyon döneminde 18 adet $>0,65$ ile iyi ve bunlardan 6 adedinin $>0,75$ ile çok iyi olduğu tespit edilmiştir. E328 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE'ye göre 6 hidrolojik modelin tahmini değerlendirildiğinde 18 adet tahmin serisinden kalibrasyon döneminde 18 adedinin $>0,65$ ile iyi ve bunların 11 adedinin $>0,75$ ile çok iyi, validasyon döneminde 18 adet $>0,65$ ile iyi ve bunlardan 16 adedinin $>0,75$ ile çok iyi olduğu


tespit edilmiştir. İstasyonların kalibrasyon ve validasyon dönemi KGE grafikleri Ek A bölümünde verilmiştir (Şekil A21-A24)

KGE metriğine göre bir genel değerlendirme yapılırsa, ağırlık yönteminin istasyonlara göre değişiklik gösterdiği kalibrasyon ve validasyon dönemlerinde 0,75 sınırını aşan çok az sayıda model bulunduğu, 0,65 sınırını aşan modellerin genellikle w2 veya w3 yöntemine göre ağırlıklandırıldığı gözlenmiştir.

4.2 Yapay Zekâ Entegrasyonu Çıktılarının Karşılaştırılması

Bu tez çalışmasında çoklu model sonuçlarının yapay zekâ entegrasyonu ile sınıyan tüm model ve istasyonlarda w3 yönteminin tüm kavramsal akış çıktı tiplerinde w1 yönteminden daha iyi olduğu sonucu elde edilmiştir. Bazı istasyonlarda w2 yöntemi w3 yöntemiyle aynı performansı yakalasa bile ortak optimizasyon yöntemleriyle iyileştirilen model çıktıların kullanıldığı yapay zekâ entegrasyonlarının tahmin performanslarını arttırdığı görülmüştür.


E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen model tahminlerinin kutu grafiği verilmiştir (Şekil 4.7). Grafikte kutuların ortasındaki çizgi medyanı göstermektedir. Ağırlıklandırma yöntemlerinin iyileştirdiği verilerin kullanıldığı çoklu model yaklaşımı tahminlerinin de benzer oranlarda iyileştiği, belirsizliklerin azaldığı sonucuna ulaşılmıştır. Diğer istasyonlara ait kalibrasyon ve validasyon dönemi kutu grafikleri Ek B bölümünde verilmiştir (Şekil B.1-B.4).



Şekil 4.7: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği

RMSE grafikleri yorumlandığında kalibrasyon ve validasyon dönemlerinde en düşük RMSE değerine w3 yönteminde ulaşıldığı görülmektedir. E311 ve E328 istasyonlarında $RMSE < 5$ sonuçlarının hem kalibrasyon hem validasyon döneminde olduğu görülmektedir. RMSE değerlerinin w2 ve w3 yöntemlerinde w1'den daha düşük olduğu, ancak modellerin bu iki istasyonda performansını geliştirmekte en zorlandığı metriğin RMSE olduğu görülmektedir.

E311 istasyonunda RMSE değerinin model kombinasyonlarına göre 36 tahminin kalibrasyon döneminde tamamı 6 mm'nin altında kalırken bunların 12 adedi 4 mm'nin altındadır. Validasyon döneminde 36 model tahmininin tamamı 6 mm'nin altında, bunların 4 adedi 4 mm'nin altındadır.




Şekil 4.8: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği

E314 istasyonunda RMSE değeri model kombinasyonlarına göre 36 tahminin kalibrasyon döneminde tamamı 20mm'nin altında kalırken bunların 18 adedi 14 mm'nin altındadır. Validasyon döneminde 36 model tahmininin tamamı 20 mm'nin altında, bunların 4 adedi 16 mm'nin altındadır. E316 istasyonunda RMSE değeri model kombinasyonlarına göre 36 tahminin kalibrasyon döneminde tamamı 12 mm'nin altında kalırken bunların 24 adedi 10 mm'nin altındadır. Validasyon döneminde 36 model tahmininin tamamı 12 mm'nin altında, bunların 19 adedi 10 mm'nin altındadır. E321 istasyonunda RMSE değeri model kombinasyonlarına göre 36 tahminin kalibrasyon döneminde 35 adedi 16 mm'nin altında kalırken bunların 3 adedi 12 mm'nin altındadır. Validasyon döneminde 36 model tahmininin

tamamı 16 mm'nin altında, bunların 5 adedi 12 mm'nin altındadır. E328 istasyonunda RMSE değeri model kombinasyonlarına göre 36 tahminin kalibrasyon döneminde 36 adedi 7 mm'nin altındadır. Validasyon döneminde 36 model tahmininin 35 adedi 6 mm'nin altında, bunların 5 adedi 5 mm'nin altındadır. İstasyonların kalibrasyon ve validasyon dönemi RMSE performans grafikleri Ek B bölümünde verilmiştir (Şekil B.5-B.8)

R^2 metriği ne göre performans değerlendirildiğinde yine w3 yönteminin kalibrasyon ve validasyon dönemlerinde öne çıktığı, kalibrasyon döneminde hem w2 hem w3 yönteminin tahminleri yakın performans gösterirken, validasyon döneminde w3 yönteminin öne geçtiği sonucuna ulaşılmıştır. Tüm istasyonlarda kalibrasyon döneminde daha çok sayıda 0,75 değerinin aşıldığı, ancak validasyon döneminde her istasyonda en az bir değerin $>0,75$ olduğu sonucuna ulaşılmıştır.

E311 nolu istasyonun model kombinasyonları R^2 performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 31 adedi $>0,65$ ve 19 adedi $>0,75$, validasyon döneminde 27 adedi $>0,65$ ve 5 adedi $>0,75$ değerine ulaşmıştır (Şekil 4.9).




Şekil 4.9: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 performans grafiği

E314 nolu istasyonun için model kombinasyonları R^2 performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 27 adedi $>0,65$ bunların 19 adedi $>0,75$, validasyon döneminde 36 adedi $>0,65$ ve 10 adedi $>0,75$ değerine ulaşmıştır. E316 nolu istasyonu için

model kombinasyonları R^2 performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 36 adedi $>0,65$ bunların 35 adedi $>0,75$, validasyon döneminde 31 adedi $>0,65$ ve bunların 2 adedi $>0,75$ değerine ulaşmıştır. E321 nolu istasyon için model kombinasyonları R^2 performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 36 adedi $>0,65$ bunların 26 adedi $>0,75$, validasyon döneminde 36 adedi $>0,65$ ve 13 adedi $>0,75$ değerine ulaşmıştır. E328 nolu istasyon için model kombinasyonları R^2 performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 36 adedi $>0,65$ bunların 16 adedi $>0,75$, validasyon döneminde 36 adedi $>0,65$ ve bunların 27 adedi $>0,75$ değerine ulaşmıştır. İstasyonların kalibrasyon ve validasyon dönemi R^2 performans grafikleri Ek B bölümünde verilmiştir (Şekil B.9-B.12).

NSE performans kriterine göre değerlendirildiğinde kalibrasyon döneminde tüm istasyonlarda 0,75 değerinin üzerine çıkan sonuçların olduğu, validasyon döneminde tüm istasyonlarda en az bir sonucun $>0,75$ olduğu görülmüştür. NSE metriğine göre de w3 yönteminin sonuçlarının diğer iki yöntemden çok daha iyi performans değerleriyle ‘çok iyi’ seviyesine ulaşmayı başardığı görülmüştür.



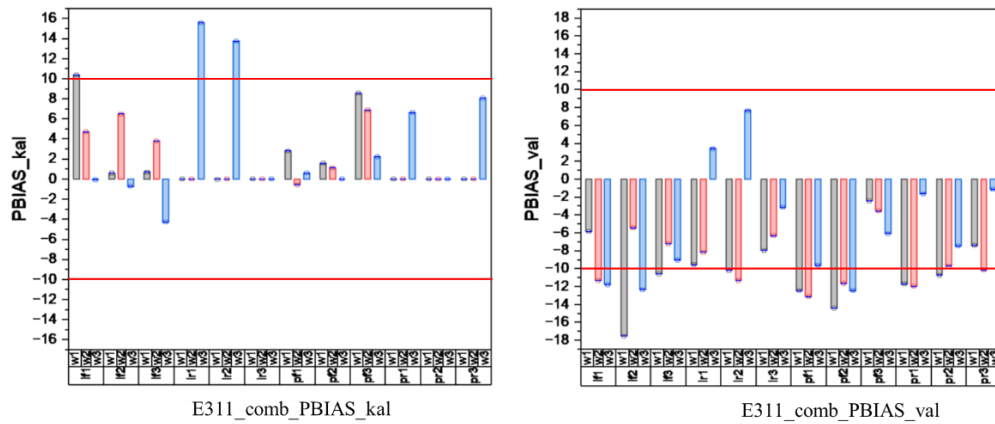
Şekil 4.10: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği

E314 istasyonu için model kombinasyonları NSE performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 27 adedi $>0,65$ ve bunların 18 adedi $>0,75$ ve validasyon döneminde 35 adedi $>0,65$ ve bunlardan 4 adedi $>0,75$ değerine ulaşmıştır. E316 istasyonu

için model kombinasyonları NSE performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 36 adedi $>0,65$ ve bunların 32 adedi $>0,75$ ve validasyon döneminde 26 adedi $>0,65$ ve bunlardan 1 adedi $>0,75$ değerine ulaşmıştır. E321 istasyonu için model kombinasyonları NSE performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 35 adedi $>0,65$ ve bunların 16 adedi $>0,75$ ve validasyon döneminde 28 adedi $>0,65$ ve bunlardan 1 adedi $=0,75$ değerine ulaşmıştır. E328 istasyonu için model kombinasyonları NSE performans kriterine göre toplam 36 model tahmininin kalibrasyon döneminde 36 adedi $>0,65$ ve bunların 16 adedi $>0,75$ ve validasyon döneminde 36 adedi $>0,65$ ve bunlardan 21 adedi $>0,75$ değerine ulaşmıştır. İstasyonların kalibrasyon ve validasyon dönemi NSE performans grafikleri Ek B bölümünde verilmiştir (Şekil B.13-B.16).

PBIAS metriğinde hem kalibrasyon hem validasyon döneminde veri ağırlıklandırma yöntemlerinin çok üstünde bir sayıda -10 ile +10 arasında değer bulunduğu, bunların çoğunun w3 yöntemine ait sonuçlar olduğu dikkat çekmektedir. Tüm istasyonların PBIAS metriğine göre tahminlerin yanlışlıklarının yapay zekâ entegrasyonu ile azaltıldığı, her istasyon için ‘çok iyi’ kriterini sağlayan tahminlerin olduğu sonucuna varılmıştır.

E311 istasyonu model kombinasyonları PBIAS’a göre değerlendirildiğinde 36 tahmin serisinin kalibrasyon döneminde 35 adedi ± 15 ile iyi, bunların 33 adedi ± 10 ile çok iyi değerindedir. 16 tahmin ise 0’a çok yakındır. Validasyon döneminde 35 adedi ± 15 ile iyi, bunların 19 adedi ± 10 çok iyi kategorisinde yer almaktadır (Şekil 4.11).

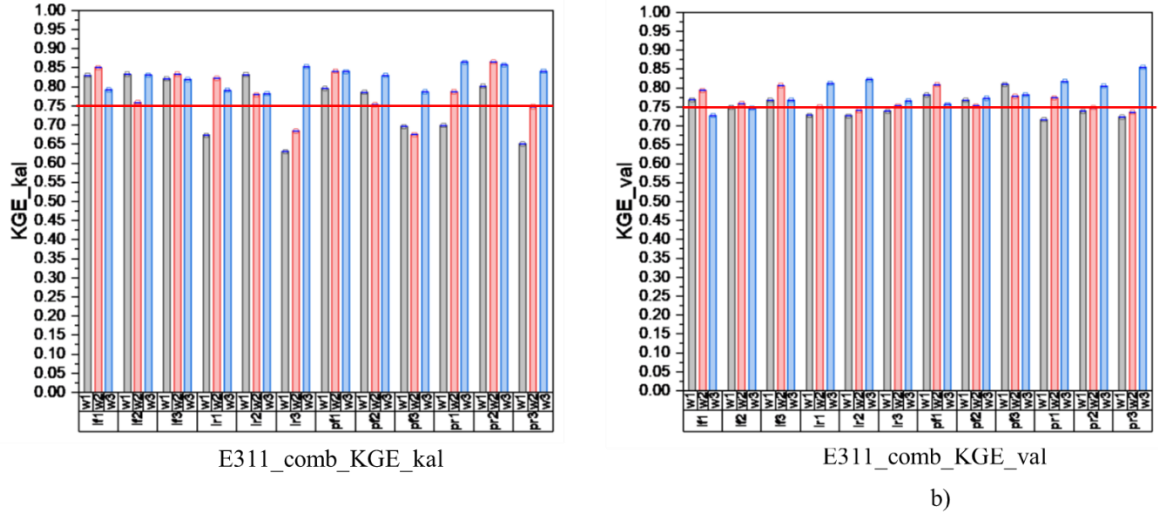


Şekil 4.11: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği

E314 istasyonu model kombinasyonları PBIAS'a göre değerlendirildiğinde 36 tahmin serisinin kalibrasyon döneminde 35 adedi ± 15 ile iyi, bunların 31 adedi ± 10 ile çok iyi değerindedir. 9 tahmin ise 0'a çok yakındır. Validasyon döneminde 36 adedin tamamı ± 10 çok iyi kategorisinde yer almaktadır. E316 istasyonu model kombinasyonları PBIAS'a göre değerlendirildiğinde 36 tahmin serisinin kalibrasyon döneminde 34 adedi ± 15 ile iyi, bunların 29 adedi ± 10 ile çok iyi değerindedir. 5 tahmin ise 0'a çok yakındır. Validasyon döneminde 22 adedin tamamı ± 10 çok iyi kategorisinde yer almaktadır. E321 istasyonu model kombinasyonları PBIAS'a göre değerlendirildiğinde 36 tahmin serisinin kalibrasyon döneminde 27 adedi ± 15 ile iyi, bunların 20 adedi ± 10 ile çok iyi değerindedir. 2 tahmin ise 0'a çok yakındır. Validasyon döneminde 30 adedi ± 15 ile iyi, 19 adedin tamamı ± 10 çok iyi kategorisinde yer almaktadır. E328 istasyonu model kombinasyonları PBIAS'a göre değerlendirildiğinde 36 tahmin serisinin kalibrasyon döneminde 34 adedi ± 15 ile iyi, bunların 29 adedi ± 10 ile çok iyi değerindedir. 10 tahmin ise 0'a çok yakındır. Validasyon döneminde 36 adedi ± 15 ile iyi, 24 adedin tamamı ± 10 çok iyi kategorisinde yer almaktadır. İstasyonların kalibrasyon ve validasyon dönemi PBIAS performans grafikleri Ek B bölümünde verilmiştir (Şekil B.17-B.20).

KGE performans kriterine göre hem kalibrasyon hem validasyon dönemlerinde w_1 , w_2 ve w_3 yöntemlerinde $>0,75$ değerine çoğunlukla ulaşılmıştır. Bu metriği diğerlerinden farklı kılan her istasyonda farklı bir ağırlıklandırma yöntemi öne çıkmıştır. Tüm istasyonlarda 'çok iyi' seviyesinde çok fazla tahmin olduğu gözlenmiştir.

E311 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE model kombinasyonlarının 36 adet tahmin serisinden kalibrasyon döneminde 35 adedi $>0,65$ iyi ve bunlardan 27 adedi $>0,75$ çok iyi, validasyon döneminde 36 adedi $>0,65$ iyi ve 23 adedi $<0,75$ çok iyi performans göstermiştir (Şekil 4.12).

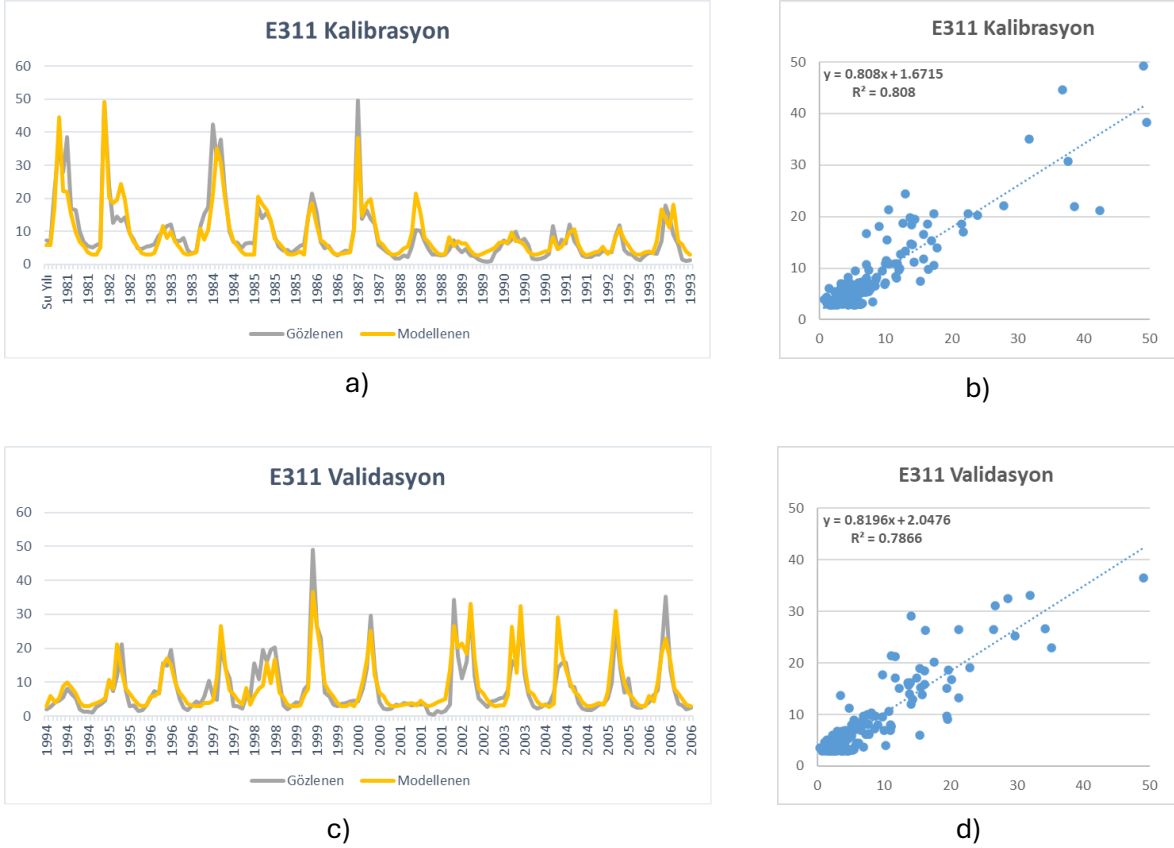


Şekil 4.12: E311 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi ile elde edilen tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği

E314 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE model kombinasyonlarının 36 adet tahmin serisinden kalibrasyon döneminde 30 adedi $>0,65$ iyi ve bunlardan 14 adedi $>0,75$ çok iyi, validasyon döneminde 27 adedi $>0,65$ iyi ve bunların 13 adedi $<0,75$ çok iyi performans göstermiştir. E316 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE model kombinasyonlarının 36 adet tahmin serisinden kalibrasyon döneminde 35 adedi $>0,65$ iyi ve bunlardan 27 adedi $>0,75$ çok iyi, validasyon döneminde 33 adedi $>0,65$ iyi ve bunların 23 adedi $<0,75$ çok iyi performans göstermiştir. E321 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE model kombinasyonlarının 36 adet tahmin serisinden kalibrasyon döneminde 36 adedi $>0,65$ iyi ve bunlardan 22 adedi $>0,75$ çok iyi, validasyon döneminde 36 adedi $>0,65$ iyi ve bunların 34 adedi $<0,75$ çok iyi performans göstermiştir. E328 istasyonu performans değerlendirme kriterlerinden bir diğeri olan KGE model kombinasyonlarının 36 adet tahmin serisinden kalibrasyon döneminde 36 adedi $>0,65$ iyi ve bunlardan 30 adedi $>0,75$ çok iyi, validasyon döneminde 36 adedi $>0,65$ iyi ve bunların 26 adedi $<0,75$ çok iyi performans göstermiştir. İstasyonların kalibrasyon ve validasyon dönemi PBIAS performans grafikleri Ek B bölümünde verilmiştir (Şekil B.21-B.24).

Uygulanan stratejinin sonuçlarının yüksek ve düşük akış yüksekliklerinde nasıl performans gösterdiği performans metriklerinin yanında gidiş ve saçılım grafiklerine bakılarak

değerlendirilebilir. E311 Orhaneli Çayı- Küçükilet İstasyonunun en başarılı performansının gidiş ve saçılım grafikleri aşağıda verilmiştir (Şekil 4.13). Diğer dört istasyona ait grafikler Ek C bölümünde verilmiştir (Şekil C.1-C.4)



Şekil 4.13: E311 Orhaneli Çayı- Küçükilet İstasyonunun w3 yöntemi ile Q_{pr2} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri

4.3 Modelleme Zincirinin Dinamik Hassasiyetinin Karşılaştırılması

Bu çalışmada Fourway Anova kullanarak kurguladığımız modelin her aşamasının veri ağırlıklandırma (WD), kavramsal akış çıktı tipleri (COT), boyut küçültme yöntemleri (DRM) ve veri odaklı modeller (DDM) basamaklarının sonuca ulaşırken etkileşimleri ve bu basamakların her birinin birbiri arasındaki iletişimin analizi aşağıdaki grafiklerle açıklanmıştır. Etkileşimin tamamındaki etki oranını tespit edebilmek için en yüksek toplam varyansa oranla etkileşim yüzdeleri hesaplanmış, böylece toplam varyansın içindeki etkileşim oranları belirlenerek etkinin gerçek oranı tespit edilmiştir.

Tüm havza için yapılan çalışmanın sonuçları analiz edildiğinde uygulanan modelleme zincirinin en etkin olduğu kısmın öne çıkarılması ve bir genelleme yapılması mümkün olmamıştır. Bu tez çalışmasının dinamik hassasiyetlerine bakıldığında tüm performans metriklerinin değerlendirmesinde her istasyon ve performans değeri için farklı bir sonuç ortaya çıkmaktadır. Tüm bunların yanında tüm istasyonlarda modelleme zincirinin birbiri arasında önemli bir etkileşimi olduğu gözlenmiştir.

Performans metriklerinden NSE için değerlendirme yapıldığında kalibrasyon döneminde E311, E36 ve E321 istasyonlarında tüm basamakların toplam etkileşim sonuç üzerinde etkili olurken, E314 ve E328 istasyonlarında WD en yüksek etkileşimi sağlamıştır. NSE validasyon dönemindeyse E311 ve E328 istasyonlarının en yüksek etkileşimi WD, E314 ve E321 için tüm basamakların toplam etkileşiminin, E316 istasyonu için DDM etkileşimi olduğu görülmüştür.

RMSE için kalibrasyon döneminde E314'te WD etkileşimi en yüksekken diğer istasyonlarda tüm basamaklar arası etkileşimin sonuç üzerinde etkisinin bakın olduğu gözlenmiştir. Validasyon döneminde ise E311 ve E328 istasyonlarında WD, E316 için DDM, E314 ve E321 için toplam etkileşimin etkin olduğu görülmüştür.

Kalibrasyon ve validasyon döneminde PBIAS metriği E321'de DDM'nin, diğer dört istasyon ise toplam etkileşimin en yüksek hassasiyeti gösterdiği sonucuna ulaşılmıştır.

KGE performans kriteri kalibrasyon döneminde E311, E316 ve E321 için toplam etkileşimden, E314 ve E328 istasyonlarında WD'den etkilenmiş gözükmektedir. Validasyon döneminde E311, E316, E321 ve E328 tüm basamakların birbiri ile olan etkileşime hassasiyet gösterirken E314 istasyonunda WD basamağı sonuç üzerinde belirleyici bir etki göstermiştir (Tablo 4.2).

Bu çalışmada, dört farklı modelleme işlem basamağının tüm kombinasyonları üzerinden üretilen tahmin serileri, dört performans metriği (NSE, RMSE, PBIAS ve KGE) ile değerlendirilmiş ve beş farklı havza özelinde analiz edilmiştir. ANOVA sonuçları göstermektedir ki, performans çıktıları hem kullanılan metriklere hem de çalışılan havzaya bağlı olarak işlem basamaklarına karşı farklı duyarlılıklar göstermektedir. Bu bulgu, hidrolojik modelleme süreçlerinin hem mekânsal hem de hedef odaklı değerlendirme

gerektirdiğini ortaya koymaktadır. Tek bir metrik ya da işlem basamağı üzerinden yapılan genellemeler, model başarımının farklı yönlerini göz ardı edebilir. Bu nedenle birden fazla performans metriği ve havzaya özgü bir değerlendirme yaklaşımı, model kombinasyonlarının daha doğru seçilmesini ve belirsizliklerin daha iyi yönetilmesini sağlayabilir.

Tablo 4.2: İstasyonlara göre katkı oranlarının karşılaştırılması. Her metriğin kalibrasyon ve validasyon dönemlerine ait en yüksek katkı oranı kalın (bold) gösterilmiştir

İstasyon	Katkı	NSE_kal	NSE_val	RMSE_kal	RMSE_val	PBIAS_kal	PBIAS_val	KGE_kal	KGE_val
E311	WD	0,19	0,73	0,20	0,75	0,03	0,17	0,19	0,20
E311	COT	0,16	0,01	0,16	0,01	0,02	0,08	0,15	0,03
E311	DRM	0,00	0,04	0,00	0,03	0,01	0,01	0,00	0,03
E311	DDM	0,21	0,07	0,21	0,06	0,00	0,11	0,03	0,02
E311	TE	0,43	0,16	0,43	0,15	0,94	0,62	0,63	0,73
E314	WD	0,77	0,03	0,76	0,02	0,23	0,15	0,62	0,44
E314	COT	0,04	0,09	0,05	0,10	0,06	0,01	0,01	0,03
E314	DRM	0,00	0,01	0,00	0,01	0,05	0,00	0,01	0,00
E314	DDM	0,01	0,20	0,01	0,21	0,06	0,24	0,09	0,21
E314	TE	0,18	0,68	0,18	0,67	0,60	0,61	0,27	0,32
E316	WD	0,07	0,25	0,07	0,24	0,02	0,01	0,06	0,08
E316	COT	0,16	0,02	0,14	0,02	0,03	0,02	0,01	0,05
E316	DRM	0,02	0,02	0,02	0,02	0,00	0,01	0,00	0,04
E316	DDM	0,00	0,49	0,00	0,50	0,21	0,45	0,36	0,31
E316	TE	0,75	0,22	0,77	0,22	0,74	0,51	0,57	0,52
E321	WD	0,21	0,23	0,22	0,23	0,01	0,00	0,04	0,14
E321	COT	0,25	0,12	0,25	0,12	0,04	0,03	0,13	0,00
E321	DRM	0,07	0,02	0,07	0,02	0,02	0,02	0,02	0,00
E321	DDM	0,11	0,19	0,11	0,19	0,69	0,67	0,00	0,00
E321	TE	0,36	0,44	0,36	0,44	0,24	0,28	0,81	0,85
E328	WD	0,63	0,72	0,21	0,78	0,06	0,06	0,50	0,22
E328	COT	0,06	0,06	0,01	0,05	0,17	0,00	0,05	0,01
E328	DRM	0,00	0,00	0,04	0,00	0,01	0,01	0,00	0,03
E328	DDM	0,00	0,00	0,04	0,00	0,13	0,20	0,23	0,28
E328	TE	0,31	0,17	0,70	0,17	0,63	0,73	0,22	0,45

Uygulanan hibrit model stratejisinin üç ağırlıklandırma yöntemine göre en iyi performansının tekli modelin en iyi performansına göre iyileştirme oranı (IR) her istasyon için Tablo 4.3'te gösterilmiştir.

Tablo 4.3: Tüm istasyonlar için ağırlıklandırma yöntemine göre en iyi tekli model ve en iyi YSA performansı arasında IR (%). Validasyon döneminin en iyi sonuçları kalın olarak gösterilmiştir.

İstasyon	Performans Metriği	w1_HM	w2_HM	w3_HM	w1_YSA	w2_YSA	w3_YSA	w1_HM/w1_YSA	w2_HM/w2_YSA	w3_HM/w3_YSA	w1_HM/w2_YSA	w1_HM/w3_YSA
E311	R2_kal	0,71	0,73	0,76	0,79	0,82	0,82	11,79	11,79	7,46	15,25	15,20
	R2_val	0,71	0,72	0,77	0,67	0,73	0,79	-4,69	1,64	1,83	3,24	11,34
	NS_kal	0,71	0,73	0,76	0,79	0,82	0,82	12,11	12,81	7,64	15,60	15,47
	NS_val	0,68	0,70	0,75	0,66	0,71	0,78	-3,67	1,20	3,84	3,60	14,06
	KGE_kal	0,79	0,81	0,83	0,83	0,87	0,86	5,75	7,36	3,63	9,87	9,74
	KGE_val	0,80	0,81	0,81	0,81	0,81	0,85	1,71	-0,76	5,27	1,62	7,40
E314	R2_kal	0,58	0,72	0,72	0,73	0,82	0,82	26,28	14,17	14,18	41,78	41,80
	R2_val	0,76	0,75	0,75	0,77	0,77	0,78	1,79	2,98	3,34	1,66	2,01
	NS_kal	0,58	0,72	0,72	0,72	0,82	0,82	25,85	14,27	14,28	42,15	42,17
	NS_val	0,76	0,74	0,74	0,77	0,76	0,76	1,19	3,14	3,04	0,30	0,21
	KGE_kal	0,77	0,81	0,83	0,79	0,85	0,86	3,56	4,80	4,27	11,13	12,80
	KGE_val	0,82	0,82	0,86	0,86	0,88	0,82	5,13	6,69	-4,52	7,31	-0,22
E316	R2_kal	0,76	0,80	0,80	0,88	0,86	0,84	15,73	7,59	5,01	12,77	10,88
	R2_val	0,74	0,77	0,75	0,74	0,77	0,80	0,51	-0,79	7,11	3,80	8,56
	NS_kal	0,76	0,79	0,80	0,88	0,86	0,84	15,98	7,77	5,13	12,92	11,11
	NS_val	0,69	0,74	0,72	0,74	0,75	0,79	6,92	0,55	10,85	8,44	15,34
	KGE_kal	0,80	0,83	0,84	0,91	0,89	0,88	13,47	8,01	5,74	11,10	9,98
	KGE_val	0,83	0,83	0,82	0,84	0,83	0,86	1,51	1,15	5,32	1,15	4,72
E321	R2_kal	0,75	0,80	0,77	0,78	0,86	0,84	3,51	7,59	9,07	13,59	10,84
	R2_val	0,74	0,77	0,75	0,75	0,77	0,78	1,63	-0,79	4,75	4,07	6,20
	NS_kal	0,75	0,79	0,76	0,78	0,86	0,81	4,14	7,77	6,49	14,29	7,75
	NS_val	0,67	0,74	0,67	0,71	0,75	0,75	5,51	0,55	11,20	11,35	11,30
	KGE_kal	0,76	0,83	0,77	0,83	0,89	0,86	9,35	8,01	11,92	17,88	13,34
	KGE_val	0,79	0,83	0,78	0,83	0,83	0,85	5,24	1,15	8,55	5,76	7,92
E328	R2_kal	0,68	0,73	0,74	0,74	0,80	0,82	8,31	9,94	10,14	17,14	19,87
	R2_val	0,74	0,78	0,80	0,76	0,80	0,84	3,01	2,82	4,47	8,28	13,39
	NS_kal	0,68	0,72	0,73	0,73	0,78	0,82	7,57	8,56	11,61	15,71	20,77
	NS_val	0,73	0,74	0,79	0,76	0,79	0,82	4,02	6,00	4,43	8,21	13,07
	KGE_kal	0,77	0,81	0,83	0,79	0,85	0,86	3,56	4,80	4,27	11,13	12,80
	KGE_val	0,82	0,82	0,86	0,86	0,88	0,82	5,13	6,69	-4,52	7,31	-0,22

5. SONUÇ VE ÖNERİLER

Bu çalışmada model tahmin tutarlılığını ve genel performansı artırmak amacıyla farklı modeller ve yöntemleri içeren çok yönlü bir strateji geliştirilmiştir. Bu stratejik yaklaşımın sonuçlar üzerindeki etkisi, elde edilen bulgular doğrultusunda değerlendirilmiştir.

Modellerde model performansına ve simülasyonlara etkisi Xu ve Singh (1998) tarafından yapılan derleme çalışmasında önerildiği ve Mirmehdi et al. (2024) tarafından yürütülen uygulamalı karşılaştırma çalışmasında yüksek model doğruluğunun desteklendiği aylık veriler kullanılmıştır.

Kurulan stratejinin ilk adımında CRR modellerine ölçülmüş meteorolojik veriler yerine, Tarek et al. (2020) ve Nacar vd. (2022) çalışmalarında belirtildiği gibi atmosferik koşulları ölçülmüş verilere yakın olan ERA5 yeniden analiz ızgaralı verileri kullanılmıştır.

Piotrowski et al. (2019) tarafından yapılan çalışmada kullanılan yöntemlere benzer veri ağırlıklandırma yöntemleri ve ortak optimizasyon uygulanmış, kalibrasyon döneminde model performansında artış gözlemine paralel sonuçlara ulaşılmıştır. Validasyon döneminde, bu çalışmada ifade edilen aksine model performansında da artış gözlenmiştir. Bunun nedeni yukarıda ifade edilen çalışmada ölçülmüş veriler kullanılırken, çalışmamızda ölçülmüş veriler yerine ERA5 yeniden analiz ızgaralı verilerinin kullanılmasının model performansını olumlu etkilediği görülmüştür. Bu durum bahse konu literatürdeki çalışmadaki validasyon dönemi performans kaybını ortadan kaldırmıştır. Her ne kadar çalışma alanı farklı olsa da bölgesel etki araştırmaya değerlidir. Vaze et al. (2011) çalışmalarında interpolasyon tabanlı yağış yüzeylelerinden elde edilen ortalama yağış değerlerinin hidrolojik model kalibrasyon ve tahminlerinde diğer yöntemlerden daha başarılı sonuçlar verdiği görüşüne paralel olarak, yüksek çözünürlüklü, model tabanlı ve interpolasyonla yeniden analiz ERA5 verilerini kullanılan bu çalışmada Thiessen poligon ağırlıklarından daha başarılı model tahminlerine ulaşılmıştır. Böylece, Thiessen poligonları gibi sınırları keskin bir şekilde belirlenen yağış dağılımı yerine daha yumuşak ve sürekli değişen bir mekânsal yağış dağılımı sağlanmıştır.

Okkan vd. (2021) iç içe hibrit model entegrasyonunda kavramsal yağış-akış model çıktısı ve model iç değişkenlerinden oluşan girdi setlerinin PCA yöntemini ile veri boyutunu

düşürmüşlerdir. Bu çalışmada çoklu model çıktılarından oluşan veri setleri PCA ve LASSO yöntemleri ile benzer şekilde veri boyutu düşürülerek yapay zekâ entegrasyonuna girdi olarak kullanılmıştır. Böylece girdi sayısının fazla olmasının YSA'larda genelleme yeteneğini zayıflatma ihtimali ortadan kaldırılmıştır. COT1, COT2 ve COT3 olarak tanımlanan farklı veri setlerinin bahsedildiği şekilde kullanıldığı yöntemde sonuçlar arasında belirgin bir üstünlük görülmemiştir. Bu durum kullanılan veri boyutunu indirgeme yöntemlerinin veri setlerini etkin şekilde işlediği ve verilerin bilgi taşıma kapasitelerini koruduğunu ortaya koymaktadır.

Shamseldin et al. (2007) çalışmalarında çoklu model tahminlerinde en başarılı yöntemin MLPN olduğu sonucuna ulaşmışlardır. Ancak bu çalışmada çoklu model yaklaşımı ile oluşturulan veri setlerinin FFNN ve RBFN entegrasyonunda elde edilen simülasyonların performansları artarken, yöntemler arasında belirgin bir üstünlük gözlenmemiştir. Veri setinin karmaşıklığına rağmen FFNN ve RBFN çıktılarının performanslarının birbirine yakın ve başarılı olması metotların esnek, güçlü ve dayanıklı yapısını göstermiştir. Uygulanan veri işleme ve ağırlıklandırma yöntemleri ile YSA metotlarının fiziksel tabanlı modellerden elde edilen sonuçlarla genel doğruluğunu ve performansını artırdığı sonucuna ulaşılmıştır.

Hibrit tahmin stratejisinin uygulandığı çalışmada bulgular kavramsal model çıktılarının yapay zekâ yöntemlerine entegre edilmesinin model performansını artırdığını göstermiştir. Bulgular, Slater et al. (2023) çalışmalarında önerdikleri fiziksel tabanlı model tahminlerinin yapay zekâ ile birleştirilmesi tavsiyesini desteklemektedir.

Okkan vd. (2021) uyguladıkları parametre hassasiyet analizi, uygulanan stratejinin adımlarının hassasiyetini belirlemek için Fourway Anova analizi kullanılarak yapılmıştır. Bu analiz dört performans metriğine kalibrasyon ve validasyon dönemlerinde ayrı ayrı uygulanmıştır. Sonuçlar değerlendirildiğinde tüm havza için genel bir hassasiyet belirleme imkanı sunmamaktadır. Sonuçlar genel olarak değerlendirildiğinde WD ve toplam etkileşimin neredeyse tüm metriklerde öne çıktığı görülmektedir. Ancak PBIAS metriğinde DDM etkileşiminin WD'nin model tahminine etkisinin zayıfladığı sonucuna ulaşılmıştır. Bu farklılıkların hidrolojik modelleme sürecinde havzalarda genelleme yapılmasından ziyade seçilen istasyon için model stratejisinin bazı basamaklarının yeniden değerlendirilebileceğine işaret etmektedir.

Çalışmanın sonuçları 5 adet performans değeri için irdelenmiştir. Arsenault et al. (2015) yaptıkları çalışmada ağırlıklı ortalaması alınan birden fazla model simülasyonunun bireysel modellerden daha sağlam ve verimli olduğu sonucuna ulaşmıştır. Paralel olarak bu çalışmada model performansları iyileştikçe, çoklu model performansları da artmıştır. Bu iyileşme Susurluk Havzası özelinde tüm performans kriterlerinde gözlenmiştir. İyileşmenin kısıtlı kalmasının E316 ve E321 istasyonlarında serbest ağırlıklandırma yöntemlerinin neredeyse aynı ızgaraları seçmesinden kaynaklanmıştır. Ayrıca, her iki istasyonun bulunduğu alt havzada göl bulunmasının model performansına etkisinin olabileceği düşünülmektedir. Aşırı yağış olan dönemlerde özellikle E314 istasyonunda kombinasyonların yağışları düşük tahmin etme yönünde eğilimi olduğu gidiş grafiklerinde gözlenebilmektedir. Bu istasyon özelinde kalibrasyon döneminde aşırı yağış daha az ve yağışlar ortalamaya yakınken, validasyon döneminde aşırı yağış piklerinin tahminlerin performansını olumsuz etkilediği düşünülmektedir.

Kumanlıoğlu ve Fıstıkoğlu (2019) ile Okkan vd. (2021) çalışmaları dışında literatürde ulusal hibrit model çalışmalarına rastlanmamıştır. Hibrit modeller ile ilgili yeni gelişmelere katkı sağlamak amacıyla yaptığımız çalışmanın yeni çalışmalara katkı sunması hedeflenmiştir. Uygulama havzası olarak seçilen Susurluk havzası ile ilgili ulusal çalışmaların kısıtlı olduğu görülmüştür. Böylece literatürde gelecek çalışmalara bir basamak oluşturabilmek niyetiyle bu çalışma sunulmuştur.

Bu çalışmada elde edilen sonuçlar örnek havza için bazı genellemelere izin verse bile çalışmanın farklı havzalarda denemesi önemlidir. Çalışma örnek havzadaki seçilen istasyonların belirli bir zaman aralığındaki verileri ile sınırlıdır. Farklı zaman aralığındaki veriler ve farklı bir uygulama alanı farklı sonuçlar ortaya koyabilir.

Slater et al. (2023) çalışmalarında belirttiği gibi gelecekte klasik metotlarla yapay zekâ yöntemlerini birleştiren hibrit sistemlerin oluşturulacak farklı stratejilerle denenmesi umut verici sonuçlara ulaştırabileceğine dikkat çekmiştir. Ancak hibrit modellerin klasik yöntemlerle karşılaştırıldıkları uygulama çalışmalarının eksikliğinden, dikkatli stratejiler geliştirilmesi gereğini de vurgulamıştır. Okkan vd. (2024) çalışmalarında Slater'in bu önerisini dikkate alarak iç içe geçmiş hibrit modellerin benimsenmesini önermiştir.

Gelecek alıřmaların bu nerilerin ışığında, model parametreleri ve grid ağırlıklarının birlikte optimizasyonu ile belirsizliklerin dinamik srece dahil edildiđi, i ie gemiř hibrit modellerin denemesinin geliřimine katkı sunacađı deđerlendirilmektedir. Ayrıca bu alıřmanın hazırlanacak muhtemel iklim deđiřikliđi ve kuraklık stratejilerinin geliřtirilmesi iin gl bir temel oluřturacađı dřnlmektedir.

6. KAYNAKLAR

- Ancil, F., Michel, C., Perrin, C. and Andreassian, V.** (2004). A soil moisture index as an auxiliary ANN input for stream flow forecasting. *Journal of Hydrology*, 286(1-4), 155–167. <https://doi.org/10.1016/j.jhydrol.2003.09.006>.
- Arsenault, R., Gatién, P., Renaud, B., Brissette, F. and Martel, J.-L.** (2015). A comparative analysis of 9 multi-model averaging approaches in hydrological continuous streamflow simulation. *Journal of Hydrology*, 529, 754–767. <https://doi.org/10.1016/j.jhydrol.2015.09.001>.
- Bandara, U., Agarwal, A., Srinivasan, G., Shanmugasundaram, J. and Jayawardena, I. M. S.** (2021). Intercomparison of gridded precipitation datasets for prospective hydrological applications in Sri Lanka. *International Journal of Climatology*, 42(6), 3378–3396. <https://doi.org/10.1002/joc.7421>.
- Broomhead, D. S. and Lowe, D.** (1988). Multivariable functional interpolation and adaptive networks. *Complex Systems*, 2(3), 321–355.
- Budyko, M. I.** (1958). The heat balance of the earth's surface. US Dept. of Commerce, Weather Bureau, Washington, DC, USA.
- Boughton, W.** (2004). The Australian water balance model. *Environmental Modelling & Software*, 19(10), 943–956. <https://doi.org/10.1016/j.envsoft.2003.10.007>.
- Chen, J.m and Adams, B. J.** (2006). Integration of artificial neural networks with conceptual models in rainfall-runoff modeling. *Journal of Hydrology*, 318(1–4), 232–249. <https://doi.org/10.1016/j.jhydrol.2005.06.017>.
- Duan, Q., Ajami, N. K., Gao, X. and Sorooshian, S.** (2007). Multi-model ensemble hydrologic prediction using Bayesian model averaging. *Advances in Water Resources*, 30(5), 1371–1386. <https://doi.org/10.1016/j.advwatres.2006.11.014>.
- ECMWF verileri <https://cds.climate.copernicus.eu/datasets> (Erişim Tarihi 29.03.2024).
- Fıstıkoğlu, O.** (1999). Hidrolojik modeller. *Türkiye İnşaat Mühendisliği Dergisi*, (15), 799–809.
- Fıstıkoğlu, O. ve Harmancıoğlu, N.** (2001). Yukarı Gediz havzasında aylık su bütçesi modeli uygulaması, III. *Ulusal Hidroloji Kongresi*, İzmir.
- Gleixner, S., Demissie, T. and Diro, G. T.** (2020). Did ERA5 improve temperature and precipitation reanalysis over East Africa? *Atmosphere*, 11(9), 996. <https://doi.org/10.3390/atmos11090996>.

KAYNAKLAR DİZİNİ (devam)

- Gupta, H. V., Kling, H., Yilmaz, K. K., & Martinez, G. F.** (2009). Decomposition of the mean squared error and NSE performance criteria: Implications for improving hydrological modelling. *Journal of Hydrology*, 377(1–2), 80–91.
<https://doi.org/10.1016/j.jhydrol.2009.08.003>
- Guo, S.** (1995). Impact of climate change on hydrological balance and water resource systems in the Dongjiang Basin, China. In *Modelling and management of sustainable basin-scale water resource systems: Proceedings of a Boulder Symposium, July 1995* (IAHS Publ. No. 231). International Association of Hydrological Sciences.
- Hafizi, H. and Sorman, A. A.** (2022). Assessment of 13 gridded precipitation datasets for hydrological modeling in a mountainous basin. *Atmosphere*, 13(1), 143.
<https://doi.org/10.3390/atmos13010143>.
- Harris, D. C.** (2015). *Quantitative chemical analysis* (9th ed.). W. H. Freeman and Company.
- Hu, T., Wu, F. and Zhang, X.** (2007). Rainfall–runoff modeling using principal component analysis and neural network. *Nordic Hydrology*, 38(3), 235–248.
<https://doi.org/10.2166/nh.2007.010>.
- Humphrey, G. B., Gibbs, M. S., Dandy, G. C. and Maier, H. R.** (2016). A hybrid approach to monthly streamflow forecasting: Integrating hydrological model outputs into a Bayesian artificial neural network. *Journal of Hydrology*, 540, 623–640.
<https://doi.org/10.1016/j.jhydrol.2016.06.026>.
- Jiao, D., Xu, N., Yang, F., and Xu, K.** (2021). Evaluation of spatial–temporal variation performance of ERA5 precipitation data in China. *Scientific Reports*, 11, Article 17956. <https://doi.org/10.1038/s41598-021-97432-y>.
- Kim, Y., Jeong, D.I. and Ko, I.H.** (2006). Combining rainfall-runoff model outputs for improving ensemble streamflow prediction. *Journal of Hydrologic Engineering*, 11(6), 578. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2006\)11:6\(578\)](https://doi.org/10.1061/(ASCE)1084-0699(2006)11:6(578)).
- Kumanhoğlu, A. A. ve Fıstıkoğlu, O.** (2019). Performance enhancement of a conceptual hydrological model by integrating artificial intelligence. *Journal of Hydrologic Engineering*, 24(11), 04019047. [https://doi.org/10.1061/\(ASCE\)HE.1943-5584.0001850](https://doi.org/10.1061/(ASCE)HE.1943-5584.0001850).

KAYNAKLAR DİZİNİ (devam)

- Mirmehdi, M., Shourian, M. and Sharafati, A.** (2024). Evaluation of SWAT in hydrological modeling and comparison of model accuracy in using of daily and monthly data: Case study of Maroon Basin. *Water Resources Engineering Journal*, 17(62), 29–39. <https://doi.org/10.30495/wej.2024.32618.2399>.
- Moriassi, D. N., Arnold, J. G., Van Liew, M. W., Binger, R. L., Harmel, R. D., & Veith, T. L.** (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. *Transactions of the ASABE*, 50(3), 885–900. <https://doi.org/10.13031/2013.23153>
- Nacar, S., Kankal, M. ve Okkan, U.** (2022). Evaluation of the suitability of NCEP/NCAR, ERA-Interim and ERA5 reanalysis data sets for statistical downscaling in the Eastern Black Sea Basin, Turkey. *Meteorology and Atmospheric Physics*, 134(2), 39–56. <https://doi.org/10.1007/s00703-022-00878-6>.
- Nourani, V., Rouzegari, N., Molajou, A., and Hosseini Baghanam, A.** (2020). An integrated simulation-optimization framework to optimize the reservoir operation adapted to climate change scenarios. *Journal of Hydrology*, 587, 125018. <https://doi.org/10.1016/j.jhydrol.2020.125018>
- Okkan, U.** (2015). Dinamik su bütçesi modeli. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 17(1), 70-82.
- Okkan, U. ve İnan, G.** (2015). Statistical downscaling of monthly reservoir inflows for Kemer Watershed in Turkey: Use of machine learning methods, multiple GCMs and emission scenarios. *International Journal of Climatology*, 35(11), 3274–3295. <https://doi.org/10.1002/joc.4206>.
- Okkan, U. ve Kırdemir, U.** (2020). Towards a hybrid algorithm for the robust calibration of rainfall–runoff models. *Journal of Hydroinformatics*, 22(4), 876–899. <https://doi.org/10.2166/hydro.2020.016>.
- Okkan, U. ve Serbes, Z. A.** (2012). Rainfall-runoff modeling using least squares support vector machines. *Environmetrics*, 23(6), 549–564. <https://doi.org/10.1002/env.2154>.
- Okkan, U., Ersoy, Z. B., Kumanlioğlu, A. A. ve Fıstıkoğlu, O.** (2021). Embedding machine learning techniques into a conceptual model to improve monthly runoff simulation: A nested hybrid rainfall–runoff modeling. *Journal of Hydrology*, 598, 126433. <https://doi.org/10.1016/j.jhydrol.2021.126433>.

KAYNAKLAR DİZİNİ (devam)

- Okkan, U., Ersoy, Z. B., & Fistikoglu, O.** (2024). Internal structure modification of a simple monthly water balance model via incorporation of a machine learning-based nonlinear routing. *Journal of Hydroinformatics*, 26(7), 1648. <https://doi.org/10.2166/hydro.2024.010>.
- Pérez-Sánchez, J., Senent-Aparicio, J., Segura-Méndez, F., Pulido-Velazquez, D. and Srinivasan, R.** (2019). Evaluating hydrological models for deriving water resources in Peninsular Spain. *Sustainability*, 11(10), 2872. <https://doi.org/10.3390/su11102872>.
- Piotrowski, A. P., Osuch, M., and Napiorkowski, J. J.** (2019). Joint optimization of conceptual rainfall–runoff model parameters and weights attributed to meteorological stations. *Water Resources Management*, 33, 4509–4524. <https://doi.org/10.1007/s11269-019-02368-8>.
- Qi, W., Zhang, C., Fu, G., & Zhou, H.** (2016). Quantifying dynamic sensitivity of optimization algorithm parameters to improve hydrological model calibration. *Journal of Hydrology*, 536, 1–16. <https://doi.org/10.1016/j.jhydrol.2015.11.052>.
- Rencher, A. C.** (1998). Multivariate statistical inference and applications. *Wiley-Interscience*.
- Robertson, D. E., Pokhrel, P. and Wang, Q. J.** (2013). Improving statistical forecasts of seasonal streamflows using hydrological model output. *Hydrology and Earth System Sciences*, 17(2), 579–593. <https://doi.org/10.5194/hess-17-579-2013>.
- Shamseldin, A. Y., O'Connor, K. M. and Liang, G. C.** (1997). Methods for combining the outputs of different rainfall–runoff models. *Journal of Hydrology*, 197, 203–229. [https://doi.org/10.1016/S0022-1694\(96\)03259-3](https://doi.org/10.1016/S0022-1694(96)03259-3).
- Shamseldin, A. Y., O'Connor, K. M. and Nasr, A. E.** (2007). A comparative study of three neural network forecast combination methods for simulated river flows of different rainfall–runoff models. *Hydrological Sciences Journal*, 52(5), 896–909. <https://doi.org/10.1623/hysj.52.5.896>.
- Shoaib, M., Shamseldin, A. Y., Khan, S., Khan, M. M., Khan, Z. M. and Melville, B. W.** (2018). A wavelet-based approach for combining the outputs of different rainfall–runoff models. *Stochastic Environmental Research and Risk Assessment*, 32(1), 155–168. <https://doi.org/10.1007/s00477-016-1364-x>.


KAYNAKLAR DİZİNİ (devam)

- Slater, L. J., Arnal, L., Boucher, M.-A., Chang, A. Y.-Y., Moulds, S., Murphy, C., Nearing, G., Shalev, G., Shen, C., Speight, L., Villarini, G., Wilby, R. L., Wood, A. and Zappa, M. (2023). Hybrid forecasting: Blending climate predictions with AI models. *Hydrology and Earth System Sciences*, 27(9), 1865–1889. <https://doi.org/10.5194/hess-27-1865-2023>.
- T.C. Tarım ve Orman Bakanlığı Su Yönetimi Genel Müdürlüğü Taşkın ve Kuraklık Yönetimi Daire Başkanlığı (2023). *Susurluk Havzası Kuraklık Yönetim Planı Cilt I: Havzanın Tanıtılması ve Kuraklık Analizleri*.
- Xu, C.-Y. and Singh, V. P. (1998). A review on monthly water balance models for water resources investigations. *Water Resources Management*, 12(1), 20–50. <https://doi.org/10.1023/A:1007916816469>.
- Xu, W., Chen, J., Corzo, G., Xu, C.-Y., Zhang, X. J., Xiong, L., Liu, D., & Xia, J. (2024). Coupling deep learning and physically based hydrological models for monthly streamflow predictions. *Water Resources Research*, 60(2), e2023WR035618. <https://doi.org/10.1029/2023WR035618>.
- Zhang, J., Kong, D., Li, J., Qiu, J., Zhang, Y., Gu, X. and Guo, M. (2025). Comparison and integration of hydrological models and machine learning models in global monthly streamflow simulation. *Journal of Hydrology*, 650, 132549. <https://doi.org/10.1016/j.jhydrol.2024.132549>.
- Zhang, L., Potter, N., Hickel, K., Zhang, Y., & Shao, Q. (2008). Water balance modeling over variable time scales based on the Budyko framework – *Model development and testing*. *Journal of Hydrology*, 360(1–4), 117–131. <https://doi.org/10.1016/j.jhydrol.2008.07.021>.
- Zuñiga, S. K.F., Santos de la Cruz, E. J., and Hurtado, S. S. (2022). Comparative analysis of GR2M, Temez and HEC HMS hydrological models for runoff estimation in a high Andean basin. In *2022 Congreso Internacional de Innovación y Tendencias en Ingeniería (CONIITI)*. IEEE. <https://doi.org/10.1109/CONIITI57704.2022.9953651>.


EKLER

EKLER


EK A: İstasyonların CRR model ve ağırlıklandırma grafikleri



Şekil A.1: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği




Şekil A.2: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği



E321_model_kal


a)



E321_model_val


b)

Şekil A.3: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği



E328_model_kal

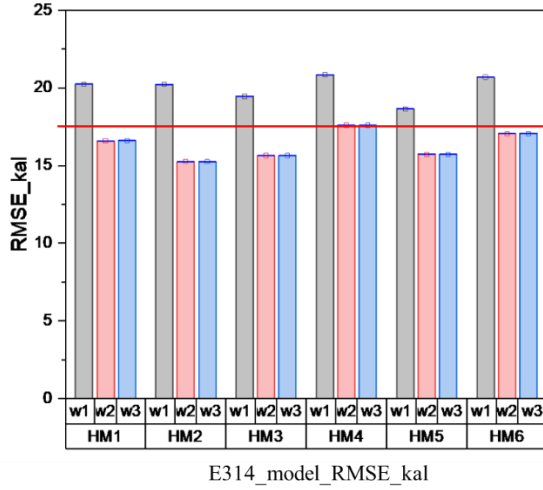
a)




E328_model_val

b)

Şekil A.4: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği

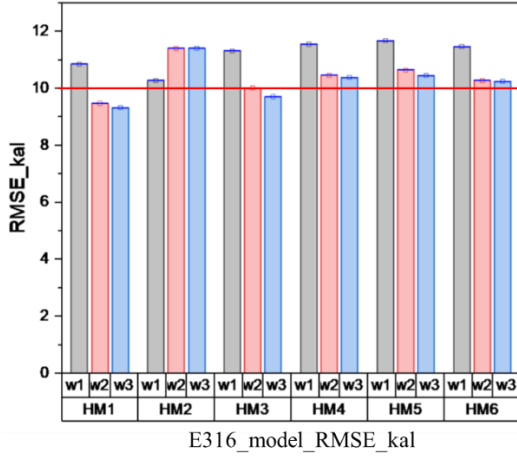


a)




b)

Şekil A.5: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği




a)




b)


Şekil A.6: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği



Şekil A.7: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği




Şekil A.8: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE grafiği



E314_model_R²_kal


a)



E314_model_R²_val


b)

Şekil A.9: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R² grafiği



E316_model_R²_kal



a)



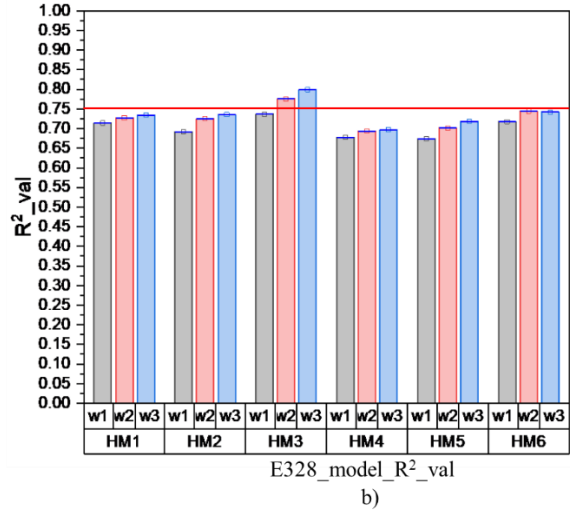

E316_model_R²_val

b)


Şekil A.10: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R² grafiği




Şekil A.11: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R² grafiği




Şekil A.12: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R² grafiği



Şekil A.13: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği




Şekil A.14: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği



E321_model_NSE_kal


a)



E321_model_NSE_val


b)

Şekil A.15: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği



E328_model_NSE_kal


a)




E328_model_NSE_val

b)


Şekil A.16: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE grafiği




Şekil A.17: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği




Şekil A.18: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği




Şekil A.19: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği




Şekil A.20: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS grafiği




Şekil A.21: E314 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği



Şekil A.22: E316 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği




E321_model_KGE_kal
a)




E321_model_KGE_val
b)

Şekil A.23: E321 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği




E328_model_KGE_kal
a)




E328_model_KGE_val
b)

Şekil A.24: E328 istasyonuna ait 6 CRR modelin üç farklı ağırlıklandırma yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE grafiği


EK B: İstasyonların çoklu model tahminlerinin yapay zekâ entegrasyonu grafikleri




Şekil B.1: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği



Şekil B.2: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği




E321_comb_kal
a)




E321_comb_val
b)

Şekil B.3: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği




E328_comb_kal
a)




E328_comb_val
b)



Şekil B.4: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi kutu grafiği





Şekil B.5: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği




Şekil B.6: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği




Şekil B.7: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği




Şekil B.8: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi RMSE performans grafiği




Şekil B.9: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 performans grafiği




Şekil B.10: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 performans grafiği




Şekil B.11: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 performans grafiği




Şekil B. 12: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi R^2 performans grafiği




Şekil B.13: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği




Şekil B.14: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği



Şekil B.15: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği




Şekil B.16: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi NSE performans grafiği



E314_comb_PBIAS_kal


a)



E314_comb_PBIAS_val


b)

Şekil B.17: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği



E316_comb_PBIAS_kal


a)



E316_comb_PBIAS_val


b)

Şekil B.18: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği



E321_comb_PBIAS_kal


a)



E321_comb_PBIAS_val


b)

Şekil B.19: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği



E328_comb_PBIAS_kal


a)




E328_comb_PBIAS_val

b)


Şekil B.20: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi PBIAS performans grafiği




Şekil B.21: E314 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği



Şekil B. 22: E316 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği




Şekil B.23: E321 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği




Şekil B.24: E328 istasyonunun ağırlık yöntemine göre yapay zekâ entegrasyonu yöntemi tahminlerinin a) kalibrasyon dönemi b) validasyon dönemi KGE performans grafiği


EK C: İstasyonların çoklu model tahminlerinin yapay zekâ entegrasyonu gidiş ve saçılım grafikleri




a)



b)




c)




d)


Şekil C.1: E314 Kocaçay- Kayaca İstasyonunun w3 yöntemi ile Q_{1r2} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri




a)



b)




c)




d)


Şekil C.2: E316 Simav Çayı-Yahyaköy İstasyonunun w3 yöntemi ile Q_{lr3} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri




a)



b)




c)




d)


Şekil C.3: E321 Nilüfer Çayı-Geçitköy İstasyonunun w3 yöntemi ile Q_{lr1} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri




a)



b)



c)



d)

Şekil C.4: E328 Emet Çayı-Dereli İstasyonunun w3 yöntemi ile Q_{lr1} model stratejisi performansının a) kalibrasyon dönemi gidiş b) kalibrasyon dönemi saçılım c) validasyon dönemi gidiş d) validasyon dönemi saçılım grafikleri

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı :Hande YALÇIN
Doğum tarihi ve yeri : 23/06/1978-Sakarya
e-posta :hyalcin@balikesir.edu.tr

Öğrenim Bilgileri

Derece	Okul/Program	Yıl
Y. Lisans	Balıkesir Üniversitesi/Çevre Mühendisliği/Bölümü	2005
Lisans	Sakarya Üniversitesi/Çevre Mühendisliği/Bölümü	2000
Lise	Özel Şener Lisesi	1995

Yayın Listesi

- Yalçın, H., Ersoy, Z. B., & Okkan, U.** (2024, Aralık 28–29). Kavramsal model parametreleri ve ERA5 grid ağırlıklarının ortak optimizasyonu. *14. Uluslararası Mühendislik, Mimarlık ve Tasarım Kongresi, İstanbul, Türkiye*, 497–504.[**Tezden türetilmiştir**].
- Yalçın, H., Ersoy, Z. B., & Okkan, U.** (2025, Temmuz12-13). Susurluk Havzası için ölçüm istasyonu tabanlı kavramsal yağış-akış model analizi. *III. Uluslararası Kolezyum Bilimsel Araştırmalar ve İnovasyon Kongresi,İtalya*. [**Tezden türetilmiştir-Basım aşamasında**].