

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



**DİNAMİK SU BÜTÇESİ MODELİNE MAKİNE ÖĞRENMESİ**  
**ENTEGRASYONU İLE AYLIK AKIŞ TAHMİNLERİNİN**  
**İYİLEŞTİRİLMESİ**

**ZEYNEP BERİL ERSOY**

**YÜKSEK LİSANS TEZİ**

**Jüri Üyeleri :**    **Doç. Dr. Umut OKKAN**  
                          **Doç. Dr. Okan FISTIKOĞLU**  
                          **Dr. Öğr. Üyesi Ahmet Ali KUMANLIOĞLU**

**BALIKESİR, AĞUSTOS - 2021**

## **ETİK BEYAN**

Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak tarafımda hazırlanan “**Dinamik Su Bütçesi Modeline Makine Öğrenmesi Entegrasyonu ile Aylık Akış Tahminlerinin İyileştirilmesi**” 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.

**Zeynep Beril ERSOY**

## ÖZET

### DİNAMİK SU BÜTÇESİ MODELİNE MAKİNE ÖĞRENMESİ ENTEGRASYONU İLE AYLIK AKIŞ TAHMİNLERİNİN İYİLEŞTİRİLMESİ

YÜKSEK LİSANS TEZİ

ZEYNEP BERİL ERSOY

BALIKESİR ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: DOÇ. DR. UMUT OKKAN)

BALIKESİR, AĞUSTOS - 2021

Yağış-akış modellemesinde en yaygın hibridizasyon uygulaması, makine öğrenimi yaklaşımlarının eğitimi için kavramsal yağış-akış modellerinin belirli çıktılarının kullanılmasına dayanmaktadır. Bu paralel hibridizasyonda, kavramsal ve makine öğrenimi modellerinin parametre tahminleri peş peşe gerçekleştirilmektedir. Ancak hem kavramsal hem de makine öğrenimi modellerinin parametreleri arasındaki karşılıklı etkileşimin dikkate alınmaması bu hibritleme yönteminin önemli dezavantajlarından biri olarak değerlendirilmektedir. Ayrıca ardışık kalibrasyonlar, hesap yoğunluğunu aşırı artırabilmektedir. Bu tez çalışmasında, bahsi geçen dezavantajların üstesinden gelmek için, iki yapay zekâ modeli (yapay sinir ağları ve destek vektör regresyonu), toplu bir kavramsal model olan dinamik su bütçesi modeli (dynwbm) ile seri hibritleme yaklaşımı kullanılarak hibritlenmiştir. Daha sonra önerilen hibrit modellerde tanımlanan tüm potansiyel parametreler eş zamanlı olarak kalibre edilmiştir. Bu iç içe yapının makine öğrenimi katmanı, aylık akış serilerini daha iyi simüle etmek için kavramsal parametrelerden elde edilen farklı çıktı kombinasyonlarını kullanmaktadır. Hibrit parçacık sürü optimizasyon algoritması ile eğitilen bu yeni hibrit modeller Gediz Havzası'nda bulunan dokuz adet akım gözlem istasyonunda sınanmıştır. Performans indislerine göre, seri hibrit modeller tekil modellerden ve paralel hibrit tiplerden daha iyi performans sergilemişlerdir. Netice itibari ile kavramsal bir modelin ve makine öğrenimi algoritmalarının öncül özelliklerini harmanlayan yeni bir modelleme yaklaşımının tutarlılığı ve uygulanabilirliği detaylı bir şekilde kanıtlanmıştır.

**ANAHTAR KELİMELEER:** Yağış-Akış Modellemesi, Kavramsal Model, Makine Öğrenmesi, Hibrit Modeller, Gediz Havzası

## **ABSTRACT**

### **EMBEDDING MACHINE LEARNING INTO DYNAMIC WATER BUDGET MODEL TO IMPROVE MONTHLY RUNOFF PREDICTION**

**MSC THESIS**

**ZEYNEP BERIL ERSOY**

**BALIKESIR UNIVERSITY INSTITUTE OF SCIENCE**

**CIVIL ENGINEERING**

**(SUPERVISOR: ASSOC. PROF. DR. UMUT OKKAN )**

**BALIKESİR, AUGUST - 2021**

The most common hybridization practice in rainfall-runoff modeling is implemented by using the certain outputs of conceptual rainfall-runoff models for the training of machine learning approaches. In that parallel coupling hybridization, the parameter estimations of the conceptual and machine learning models are consecutively carried out. However, this application has a crucial drawback since the mutual interaction between the parameters operating both conceptual and machine learning models is not taken into consideration. Moreover, the cascade calibrations can unnecessarily increase the computational complexity. In this thesis study, to overcome these disadvantages, two artificial intelligence models (artificial neural networks and support vector regression) were integrated with the dynamic water budget model (dynwbm) that is a lumped conceptual model. Then, all potential parameters defined in proposed serial hybrid models were simultaneously calibrated. The machine learning layer of this intertwined structure uses different output combinations obtained from the conceptual parameters in order to better simulate monthly runoff series. These new hybrid models trained through hybrid particle swarm optimization algorithm were performed at the Gediz River Basin. The performance indices pointed out that the serial hybrid models outperformed the solo models and coupled parallel types. Consequently, both the robustness and applicability of this new modeling framework, which makes use of the prominent skills of a conceptual model and machine learning algorithms, has been comprehensively provided.

**KEYWORDS:** Rainfall-Runoff Modelling, Conceptual Models, Machine Learning, Nested Hybrid Models, Gediz River Basin

# İÇİNDEKİLER

## Sayfa

<b>ÖZET</b> .....	<b>i</b>
<b>ABSTRACT</b> .....	<b>ii</b>
<b>İÇİNDEKİLER</b> .....	<b>iii</b>
<b>ŞEKİL LİSTESİ</b> .....	<b>iv</b>
<b>TABLO LİSTESİ</b> .....	<b>v</b>
<b>ÖNSÖZ</b> .....	<b>vi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
1.1 Genel Literatür .....	1
1.2 Paralel Hibrit Modeller .....	4
1.3 Yeni Bir Yöntem Olarak Seri Hibrit Modeller .....	6
<b>2. YÖNTEM</b> .....	<b>8</b>
2.1 Dinamik Su Bütçesi Modeli (dynwbm) .....	8
2.2 Yapay Sinir Ağları .....	11
2.3 Destek Vektör Regresyonu .....	12
2.4 Önerilen Seri Hibrit Yağış-Akış Modelleri.....	13
2.4.1 dynNN1 ve dynNN2 Modellerinin İşleyişi .....	14
2.4.2 dynSVR1 ve dynSVR2 Modellerinin İşleyişi .....	15
2.5 Kullanılan Paralel Hibrit Yağış-Akış Modelleri .....	18
2.6 Modellerin Parametrelerinin Kalibrasyonu.....	19
2.7 Performans Kriterleri .....	22
<b>3. ÇALIŞMA ALANI VE KULLANILAN VERİLER</b> .....	<b>23</b>
<b>4. BULGULAR</b> .....	<b>26</b>
4.1 dynwbm'nin Parametre Hassasiyet Analizi.....	26
4.2 Seri Hibrit Model Kurulması .....	27
4.3 Modellerin Karşılaştırılması .....	30
<b>5. SONUÇLAR</b> .....	<b>61</b>
<b>6. KAYNAKLAR</b> .....	<b>63</b>
<b>ÖZGEÇMİŞ</b> .....	<b>74</b>

## ŞEKİL LİSTESİ

### Sayfa

Şekil 2.1: Dinamik su bütçesi modelinin akış şeması .....	9
Şekil 2.2: Dinamik su bütçesi modelinde Budyko eğrilerinin yüzey akışı, gerçek evapotranspirasyon ve derine sızma sürecinde uygulanışı. ....	10
Şekil 2.3: Seri hibrit modelleme stratejisi .....	13
Şekil 2.4: (a) Tipik katmanlı ANN yapısı, (b) SVR işleyişinin özeti .....	17
Şekil 2.5: İki ardışık kalibrasyon işleminden oluşan paralel birleştirilmiş model stratejisi.	18
Şekil 3.1: Çalışma alanı, istasyonların yerleri ve ilgili alt havzalar.....	24
Şekil 3.2: Akım Gözlem istasyonları ile ilgili bilgiler ve gözlenmiş ortalama yıllık yağış, PET, akım ve sıcaklık değerleri.....	25
Şekil 4.1: (a) dynwbm parametrelerinin kombinasyonları için zincir diyagramı gösterimi, (b) ana kaynaklar ve toplam etkileşim için varyans fraksiyonları ve (c) d parametresi ile ilgili birinci mertebeden etkileşimlerin varyans fraksiyonları.....	27
Şekil 4.2: Tüm istasyonlar için elde edilen korelasyon katsayıları ile oluşturulan kutu grafiği .....	28
Şekil 4.3: İlk iki PC için varyansın açıklanabilme mertebeleri.....	29
Şekil 4.4: Tüm akım koşullarında NS performansına ilişkin derecelendirmelerin modellere göre değişimi. ....	30
Şekil 4.5: $r^2$ istatistiklerinin model ve AGİ özelinde yorumlanması. ....	33
Şekil 4.6: Modellerin validasyon dönemi NS performanslarının tüm akım koşulları için havza genelinde kıyaslanması.....	35
Şekil 4.7: Modellerin validasyon dönemi NS performanslarının yüksek akım koşulları için havza genelinde kıyaslanması.....	36
Şekil 4.8: Yüksek akım koşullarında NS performansına ilişkin derecelendirmelerin modellere göre değişimi. ....	37
Şekil 4.9: NS performanslarına göre modellerin sınıflandırılması. ....	38
Şekil 4.10: Acısu alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri.....	41-45
Şekil 4.11: Topuzdamları alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri...46-50	
Şekil 4.12: Borlu alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri .....	51-55
Şekil 4.13: Dereköy alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri .....	56-60

## TABLO LİSTESİ

### Sayfa

- Tablo 4.1:** Validasyon dönemi için her bir akım gözlem istasyonunda model performanslarının karşılaştırması: a) RMSE istatistikleri b) NS indisleri ..... 31
- Tablo 4.2:** Validasyon dönemi pik akımları için her bir akım gözlem istasyonunda model performanslarının karşılaştırması: a) RMSE istatistikleri b) NS indisleri..... 39

## ÖNSÖZ

Yağış-akış modelleri uluslararası ve ulusal hidroloji literatüründe yapılan arařtırmalar neticesinde sürekli olarak gelişme göstermektedir. Bu tez çalışması kapsamında ise, bu modellerin entegrasyonu hususunda farklı bir bakış açısı geliştirilmiş ve modellerin simülasyon performansında iyileşme sağlanması amaçlanmıştır.

Tez çalışmamın planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren, güler yüzünü ve samimiyetini benden esirgemeyen kıymetli hocam Doç. Dr. Umut OKKAN'a sonsuz teşekkürlerimi sunarım.

Aynı zamanda beni bu günlere sevgi ve saygı kelimelerinin anlamlarını bilecek şekilde yetiştirerek getiren, benden hiçbir zaman desteğini esirgemeyen bu hayattaki en büyük şansım olan aileme ve desteklerini her zaman hissettiğim arkadaşlarıma sonsuz teşekkür ederim.

**Bahkesir, 2021**

**Zeynep Beril Ersoy**



# 1. GİRİŞ

## 1.1 Genel Literatür

Yağış rejimi ve havzanın jeomorfolojik özellikleri ile kontrol edilen yağış-akış ilişkisinin irdelenmesi genel olarak hidrolojik çalışmaların temel konusu olmuştur. Yağışın havza üzerinde akışa dönüşme mekanizması, hidrolojik bileşenlerin havzada homojen dağılması ve bu bileşenlerin zamansal-mekânsal değişkenliklerinden dolayı karmaşık ve doğrusal olmayan bir süreçtir (Chen ve Adams, 2006a, 2006b; Song vd., 2012). Bu kapsamda geliştirilen yağış-akış modelleri, taşkın kontrolü, baraj haznelerinin işletilmesi ve biriktirme sistemlerinden optimum su temini gibi su kaynakları planlama çalışmalarına esas teşkil edecek güvenilir akış tahminleri sağlamak için kullanılmaktadır.

Geliştirilen yağış-akış modelleri farklı karmaşıklık derecelerine sahip olmakla birlikte yapısal çeşitliliğine bakılmaksızın fiziksel tabanlı modeller, parametrik kavramsal modeller ve sıklıkla yapay zekâ uygulamalarını içeren kapalı (kara) kutu modelleri olmak üzere üç temel grupta değerlendirilir (Chen ve Adams, 2006a, 2006b; Dooge, 1977; Song vd., 2012).

Bunlar arasında, fiziksel tabanlı modellerde zemin özellikleri, topoğrafya ve bitki örtüsü gibi fiziksel parametrelerin alansal yayılı olarak kullanılması ile tüm hidrolojik sürecin detaylı ele alınması mümkün olmaktadır. Bu bakımdan fiziksel modelleri parametrize etmek ve doğrulamak için hem yüksek kalitede veri toplamak hem de yoğun bir hesaplama çalışması gerekmektedir (Seyfried ve Wilcox, 1995).

Öte yandan, daha az veri veya parametre seti ile yeter derecede simülasyon doğruluğu hedeflendiğinde, kavramsal tipte yağış-akış (conceptual rainfall-runoff: CRR) modelleri ve kapalı (kara) kutu modelleri de araştırmacılar tarafından pratikte uygulanabilmektedir (Humphrey vd., 2016; Noori ve Mano, 2007; Okkan, 2015; Okkan ve Kirdemir, 2020). Bunlar arasında, tüm havzanın genellikle homojen kabul edildiği CRR modelleri araştırma çalışmalarında yaygın olarak kullanılmaktadır. Bu modeller kavramsal zemin nemi ve yeraltı suyu depolaması elemanları ile hidrolojik süreçler arasındaki ilişkileri basitleştirilmiş matematiksel ifadelerle temsil etmeye çalışmaktadır (Chen ve Adams, 2006b; Noori ve Kalın, 2016; Okkan ve Kirdemir, 2020). Kavramsal yağış-akış

modellerinde yağışın havza üzerine homojen düştüğü ve süreç parametrelerinin (zemin nemi depolaması üst değeri, dolaysız akış katsayısı vb.) alansal dağılımındaki değişkenliklere karşı topaklanmış (lumped) halde olduğu varsayılmaktadır. (Song vd., 2012). Ayrıca kavramsal yağış-akış modellerinin etkinliği ve simülasyon hassasiyeti, parametrelerin tutarlı tanımlanmasına ve bunların kalibrasyonunun ne ölçüde yapıldığına da bağlıdır (Arsenault vd., 2014; Goswami ve O'Connor, 2007; Okkan ve Kirdemir, 2020; Tigkas vd., 2016; Qin vd., 2018). Parametrelerin deneme-yanılma veya tecrübeler ile seçilmesi zor olup, kalibrasyonun otomatik biçimde yapılması ve bunun kaliteli bir optimizasyon algoritması ile işletilmesi güvenilir bir simülasyon için oldukça önemlidir. Kavramsal yağış-akış modelleri hakkında detaylı bilgi içeren birçok eser bulunmaktadır (Chiew, 2010; Singh, 1995; Singh ve Woolhiser, 2002; Singh ve Frevert, 2002; Todini, 1988).

Diğer bir tür olan kapalı kutu modelleri ise çeşitli hidro-meteorolojik değişkenleri girdi seti kabul ederek hedef değişken olan akış çıktılarını benzeştiren ve geleneksel regresyon yöntemlerinden farklı komplekslik derecesindeki makine öğrenimi (machine learning: ML) algoritmalarına kadar uzanan çeşitli istatistiksel teknikleri kapsamaktadır. Hidrolojik süreç hakkında detaylı bilgiye ihtiyaç duymayan bu modellerin kavramsal yağış-akış modellerine iyi alternatifler olabileceği ilgili literatürde belirtilmiştir (Nourani ve Mano, 2007; Ren vd., 2018). Birçok kapalı kutu modeli arasından yapay sinir ağlarının (artificial neural network: ANN) yağış-akış modellemesinde kullanımı 1990'lı yılların ortasından bu yana popülerliğini kaybetmemiştir (Hsu vd., 1995; Minns ve Hall, 1996; Tokar ve Johnson, 1999; Tokar ve Markus 2000; Rajurkar vd., 2002, 2004; Zhang ve Govindaraju, 2003). Hidrolojik süreci çeşitli gözlemlerle taklit edebilme, doğrusal olmayan haritalama ile nispeten daha esnek tahmin sunabilme ve zaman serisindeki eksik gözlemleri tolere edebilme yapay sinir ağlarının temel avantajlı yönleri olarak bilinmektedir (Zhang ve Govindaraju, 2003).

Yağış-akış modellemesi kapsamında ANN ve CRR modellerinin doğrudan karşılaştırılmasına yönelik çalışmalar incelendiğinde, bulguların zaman ölçeğine (günlük, aylık vb.), girdi katmanına sunulan veri niteliği-niceliğine ve drenaj alanına bağlı olarak değişkenlik sergilediği tespit edilmiştir. Örneğin, Hsu vd. (1995), Tokar ve Markus (2000), ve Daliakopoulos ve Tsanis (2016) tarafından hazırlanan çalışmalarda ANN ile Sacramento kavramsal modellerinin kıyaslanması sağlanmış ve üç çalışmada da ANN'nin

kavramsal modelden aşırı üstün olmadığı vurgulanmıştır. Benzer şekilde, Dibike ve Solomatine (2001) ve Jeong ve Kim (2005) tarafından yürütülen çalışmalarda ANN tekniğinin Sugawara'nın TANK modelinden farklı uygulama alanlarında üstün olduğu belirtilmiştir. ANN'nin esnek modelleme becerisine rağmen, Daliakopoulos ve Tsanis (2016) ve Gaume ve Gosset (2003) gibi araştırmacılar ise, CRR modellerini senaryo üretme aşamasında ekstrapolasyon yetileri bakımından daha güvenilir bulmuşlardır. Ayrıca bu modellerin ANN gibi aşırı öğrenme eğiliminde olmamaları önemli avantajlardan biri olarak belirtilmiştir.

ANN'nin literatürde değinilen çeşitli avantajlarına rağmen, modellerde gizli katmandaki hücre sayısının denenerek belirlenmesi ve kalibrasyonu (eğitimi) gereken çok sayıda ağırlığın aşırı öğrenme durumunu yaratması çeşitli dezavantajlar doğurmaktadır. İlgili literatürde, ANN'nin yukarıda bahsi geçen zayıflıklarının üstesinden gelebilecek çeşitli alternatif arayışlarına başvurulmuştur. Örneğin Destek Vektör Regresyonu (support vector regression: SVR) yöntemi bunlardan biridir (Lin vd., 2006; Wang vd., 2009; Maity vd., 2010; Okkan ve Serbes, 2012; Granata vd., 2016). ANN ve SVR, birçok su kaynakları uygulamasında farklı makine öğrenmesi modellerine (çok değişkenli uyarlanabilir regresyon eğrileri, genetik programlama ve uyarlanabilir sinir tabanlı bulanık çıkarım sistemi) nispeten sağlam sonuçlar verdikleri için tercih edilebilir (Tongal ve Booji, 2018; Okkan vd., 2021). Bu nedenle tez çalışmasında doğrusal olmayan ilişkileri kurulması safhalarında, her iki tekniğin de kullanılmasına karar verilmiştir.

Literatür bulguları incelendiğinde, ANN ve SVR gibi yöntemlerin de içinde yer aldığı kapalı kutu modellerinin çoğunlukla önceki zamana ait yağış ( $P_{t-1}, P_{t-2}, \dots, P_{t-k}$ ) ve akış miktarı ( $Q_{t-1}, Q_{t-2}, \dots, Q_{t-k}$ ) kullanılmadan CRR modelleriyle rekabet edemediği gözlenmiştir. Modelleme kabiliyetinin artırılması zemin nemi ve yeraltı suyu depolamasının başlangıç koşullarının yansıtılması ile mümkün olduğu deneyimlendiğinden, uygulamalarda girdi setine  $t$ . zamana ait gözlemlere ilaveten önceki gözlemler de eklenmektedir (Anctil vd., 2004; Okkan ve Serbes, 2012; Robertson vd., 2013; Humphrey vd., 2016; Kumanlioglu ve Fistikoglu, 2019). Bununla birlikte, bu tür gecikmeli akım verisi ile eğitilen modeller, iklim değişikliği senaryoları altında akarsu akışı projeksiyon çalışmaları (küresel iklim modellerinin çıktılarının akış değerlerine indirgenmesi ile ilgili çalışmalar) için engel teşkil etmektedir. Bunun temel sebebi bu tür bir girdi serisinin gelecekteki iklim koşulları için küresel iklim modeli veri setlerinde servis

edilmemesidir (Okkan ve Inan, 2015a; Kumanlioglu ve Fistikoglu, 2019). Ek olarak, Robertson vd., (2013) ařađıda verilen iki nedenden ötürü gecikmeli akıř ve yađıř gözlemlerini kullanmanın havza dinamiklerinin temsil edilebilirliđini kısıtladıđını vurgulamıřtır.

- Zemin nemi ve yeraltı suyu depolama seviyeleri tam kapasitedeyken, akıřlar havzanın sađlayabileceđi potansiyel mertebelerin üzerinde artıř eđilimi sergileyebilmektedir. Bu nedenle, gecikmeli akıř girdisinde ekstrem gözlemler olması halinde, eđitilen model fiziksel olarak anlamsız aykırılıkta ıktılar üretebilmektedir.
- Bir havza zemin nemi dođgunluđuna eriřirken, gecikmeli akıř yađıřa hemen tepki vermemektedir. Bu durumda da gecikmeli akıř deđerleri gerekteki zemin nemi kořullarını temsil edememekte ve model nispeten düřük akım tahminleri üretebilmektedir.

## 1.2 Paralel Hibrit Modeller

Makine öđrenmesi modellerinin sistem iinde meydana gelen fiziksel süreçleri detaylı ele almadan, bir dizi ölçülen hidro-meteorolojik veriye bađlı dođrusal olmayan akım karakterizasyonu sađlaması ve geleneksel CRR modellerinin de havzaların fiziksel özelliklerini temsil edebilme yetileri arařtırmacıları bu iki tekniđi birlikte uygulamaya teřvik etmiřtir. Hibrit modelleme olarak anılan bu uygulamalarda, hibritlenecek model elemanlarının birbiriyle uyumlu olup olmadıđını kontrol etmek ve modelleme sürecinin zayıf yönlerini (bařlangı kořullarına duyarlılık ve ařırı parametrisasyon) ortadan kaldırmak önem arz etmektedir. Literatürde CRR modellerinin ve ML tekniklerinin güçlü yönlerini birleřtirmeyi esas alan hibrit modelleme alıřmaları genel olarak üç grupta deđerlendirilebilir (Ersoy vd., 2021; Okkan vd., 2021).

Birinci grupta deđerlendirilebilecek hibrit modeller, farklı CRR model ıktılarının kalibrasyon sonrasında ML modelleri ile istatistiksel iřlemden geirilmesine dayanmaktadır. Genel olarak bu uygulamaların oklu model topluluk stratejilerini kapsadıđı söylenebilir (Shamseldin vd., 1997; Shamseldin ve O'Connor, 2001; Anctil vd., 2003; Kim vd., 2006). Bu alıřmalarda, tek bir yađıř-akıř modelinden türetilen ıktılara odaklanmak yerine, daha güvenilir akıř tahminleri elde etme ve bireysel modellerin

belirsizliklerini en aza indirme öngörüsü ile birden fazla yağış-akış modelinin modellenmiş çıktılarının doğrusal olmayan bir şekilde ağırlıklandırılması sağlanmaktadır (Humphrey vd., 2016). Ayrıca istatistiksel bir model aracılığıyla tek bir CRR modelinden elde edilen akış serilerinin güncellenmesine dayanan hata (yanlılık) düzeltme (error correction: EC) tarzı modeller de bu gruba dahil edilebilmektedir (Ghaith vd., 2020; Shamseldin ve O'Conner, 2001).

İkinci gruptaki modeller, bir havzayı oluşturan alt havzalar için kavramsal olarak üretilen akış bileşenlerinin ML tabanlı modeller ile ötelenmesini ve ana havza çıkışındaki toplam akışın benzeştirilmesini esas almaktadır. Diğer bir deyişle, bu uygulamalarda, CRR modelleri vasıtasıyla alt havzalarda modellenmiş akış serilerinin türetilmesinin ardından, toplam akışa her bir alt havzadan gelen katkı doğrusal bir süperpozisyon yerine ML tabanlı modellerle işletilmektedir. Örneğin, Chen ve Adams (2006a) tarafından yürütülen çalışmada, Çin'deki Bei Nehri'nde bulunan bir havzanın tamamı üç alt havzaya bölünmüştür. Bu çalışmada, TANK modelinin yarı dağıtılmış versiyonu kullanılarak alt havzalardan modellenmiş akış değerleri elde edildikten sonra, ana havza çıkışı akımları ML tabanlı modeller ile ötelenmiştir. Aynı araştırmacıların daha fazla kavramsal model kullanarak (TANK, SMAR ve Xinanjiang) gerçekleştirdikleri diğer bir çalışmada (Chen ve Adams, 2006b) ise, ML tabanlı öteleme işlemi ile daha iyi akım performansı elde edilebileceği bir kez daha doğrulanmıştır. Benzer entegrasyon başka çalışmalarda da ortaya konulmuştur (Meng vd., 2016; Song vd., 2012).

Öte yandan, nispeten karmaşık olan üçüncü gruptaki modellerde, ML modelleri için tahmin setini güçlendirme amacıyla CRR modellerinden elde edilen çıktılar (hidrolojik süreç bileşenleri ile ilişkili çeşitli simüle edilmiş veriler) kullanılmaktadır (Humphrey vd., 2016). Bu konudaki ilk dikkate değer çalışma, Anctil vd. (2004) tarafından bir şekilde ele alınmıştır. Çalışmalarında, kısa vadeli akış tahminini iyileştirmek amacıyla önceden tanımlanmış parametrelerle GR4J modelinden elde edilen simüle edilmiş zemin nem indeksi değerlerini ANN'lere girdi olarak sunmuşlardır. Simüle edilmiş zemin nemini kullanma girişimleri kayda değer sonuçlar sağlasa da gecikmeli yağış indeksinin kullanılmasının ANN performansında önemli bir etki yaratmadığı sonucuna varmışlardır. Anctil vd. (2004) çalışmasından ilham alan diğer araştırmalar da benzer uygulamalar içermektedir. Örneğin Humphrey vd. (2016), çeşitli Güney Avustralya havzalarında aylık akış tahmini için Bayesian tipteki ANN modelindeki başlangıç dinamik havza koşullarını

temsil etmek için GR4J modelinden simüle edilmiş zemin nemini kullanırken, Kumanlioglu ve Fistikoglu, (2019) Türkiye'nin batısında yer alan Gediz Nehri Havzası'ndaki belirli akım gözlem istasyonları için günlük akış tahmininde ANN'nin performansını güçlendirmek için aynı kavramsal modelin üretim depolama çıktılarını (örneğin: net evapotranspirasyon açığı, perkolasyon ve artık yağış) değerlendirmiştir. Aynı kavramsal modelin Elman tipindeki ANN ile entegrasyonu Tian vd. (2018) tarafından gerçekleştirilmiştir. Benzer şekilde Nilsson vd. (2006) ve Ren vd. (2018), aylık akış değerlerinin benzeşiminde, ANN girdisi olarak zemin nemi ve kar erimesi gibi HBV modeli çıktılarını kullanmıştır. Noori ve Kalin (2016) ve Essenfelder ve Giupponi (2020) ise aynı işleyişi SWAT modelinden elde edilen çıktıları esas alarak gerçekleştirmiştir. Kavramsal süreç modelleri dışında, tekil süreç modellerinde tercih edilen SCS eğri numarası (Isik vd., 2013) ve dijital filtre (Tongal ve Booji, 2018) gibi yaklaşımlarla taban akışı ve dolaysız akış gibi akım bileşenlerinin ayrıştırılarak ML modellerinin tahmin başarısının artırıldığı çalışmalar da bulunmaktadır.

### **1.3 Yeni Bir Yöntem Olarak Seri Hibrit Modelleme**

Üçüncü grupta atfedilen tüm bu çalışmalarda, CRR modelleri önce kalibre edilmekte ve daha sonra bunların belirli çıktıları ML modellerine yeni işlenmiş girdi seti olarak sunulmaktadır. Yani, her iki kalibrasyon süreci de ardışık olarak çalıştırılmakta ve ML tabanlı kısım, CRR modeli kalibrasyonu tamamlanmadan devreye girmemektedir. Bu gruba ait çalışmalarda bu tarz bir yaklaşımın avantajları belirtilse bile, eğitim aşamasında CRR model parametreleri ile ML model parametreleri arasındaki dinamik etkileşim, tanımlanmış tüm parametrelerin aynı iterasyon adımlarında birlikte optimize edilememesinden dolayı kısıtlanmaktadır. Anctil vd. (2004) ve Noori ve Kalin (2016) bu çalışmaların paralel hibridizasyon veya birleşik modelleme olarak da adlandırılabilceğini belirtmişlerdir. Anctil vd. (2004) çalışmalarında paralel hibridizasyonu tanıtan ilk araştırmacılardan olmasına rağmen, her iki yaklaşımın tek bir şemada iç içe geçtiği seri hibrit modellemenin hidrolojik olarak daha anlamlı olacağını da vurgulamışlardır. Diğer yandan, hesap yoğunluğu da iki ardışık modelleme süreci ile artmış olacaktır.

Yukarıda değinilen eksikliklerin üstesinden gelme amacıyla, tez çalışmasında ve tez aşamasında üretilen araştırma çalışmalarında (bkz. Ersoy vd., 2021; Okkan vd., 2021), iç içe geçmiş seri hibridizasyonun uygulanabilirliği test edilmiştir. Bu aşamada, iki farklı ML tekniği dinamik su bütçesi modeli (*dynwbn*) adı verilen kavramsal bir modelin içerisine

yerleştirilmiş ve tüm tanımlı parametreler (*dynwbm* parametreleri ve ilgili ML parametreleri) eşzamanlı olarak kalibre edilmiştir. Bu kapsamda, ilk hibritleme uygulaması bilindik çok katmanlı ANN ile gerçekleştirilmiştir. Bu işlem sonrası, seri tipteki hibrit modelin serbestlik derecesinin gizlik katmandaki hücre sayısına bağlı olarak artma eğiliminde olmasından ve ANN ile işletilen kısma ait parametrelerin toplam varyans belirsizliği üzerindeki anlamlı etkisinden dolayı, ANN'ye bir alternatif olarak, iki kontrol parametresi ile çalışan en küçük kareler destek vektör regresyonu (SVR) da çalışmaya dahil edilmiştir. Bu sayede hem aşırı parametrisasyondan kaçınılabilecek hem de daha cimri bir model yapısı ortaya atılmış olacaktır. Tekil biçimde kullanılan CRR ya da ML modellerine güçlü bir alternatif olarak tez çalışmasında önerilen ve uluslararası literatürde henüz bir örneği gerçekleştirilmemiş seri hibrit modelleme stratejileri, havza dinamiklerini daha iyi yakalama potansiyeli açısından kurumsal çalışmalara ışık tutabilme niteliğindedir.

Sunulan çalışmada, önerilen hibridizasyonun avantajlarını teşhis etmek için, Türkiye'nin batısındaki Gediz Havzası'nda bulunan dokuz adet akım gözlem istasyonundaki aylık akımlarda detaylı bir uygulama hazırlanmıştır. Karşılaştırma adımı, tekil modellerin (yalnız ANN, SVR ve *dynwbm*) ve paralel hibrit modellerin (basit yanlılık düzeltme (EC) varyantları ve birleştirilmiş model (coupled models: CM) varyantları) akış simülasyon performansları önerilen modellere karşı analiz edilmiştir. Tez çalışmasının diğer bölümleri aşağıdaki şekilde düzenlenmiştir. Uygulanan modelleme stratejileri ve karşılaştırma indisleri ile ilgili ayrıntılar Bölüm 2'de sunulurken, Çalışma alanı ve kullanılan veriler Bölüm 3'te, modellerden elde edilen bulgu ve analizler de Bölüm 4'te verilmiştir. Son bölüm ise tez çalışmanın tartışma ve sonuç çıkarımlarını kapsamaktadır.

## 2. YÖNTEM

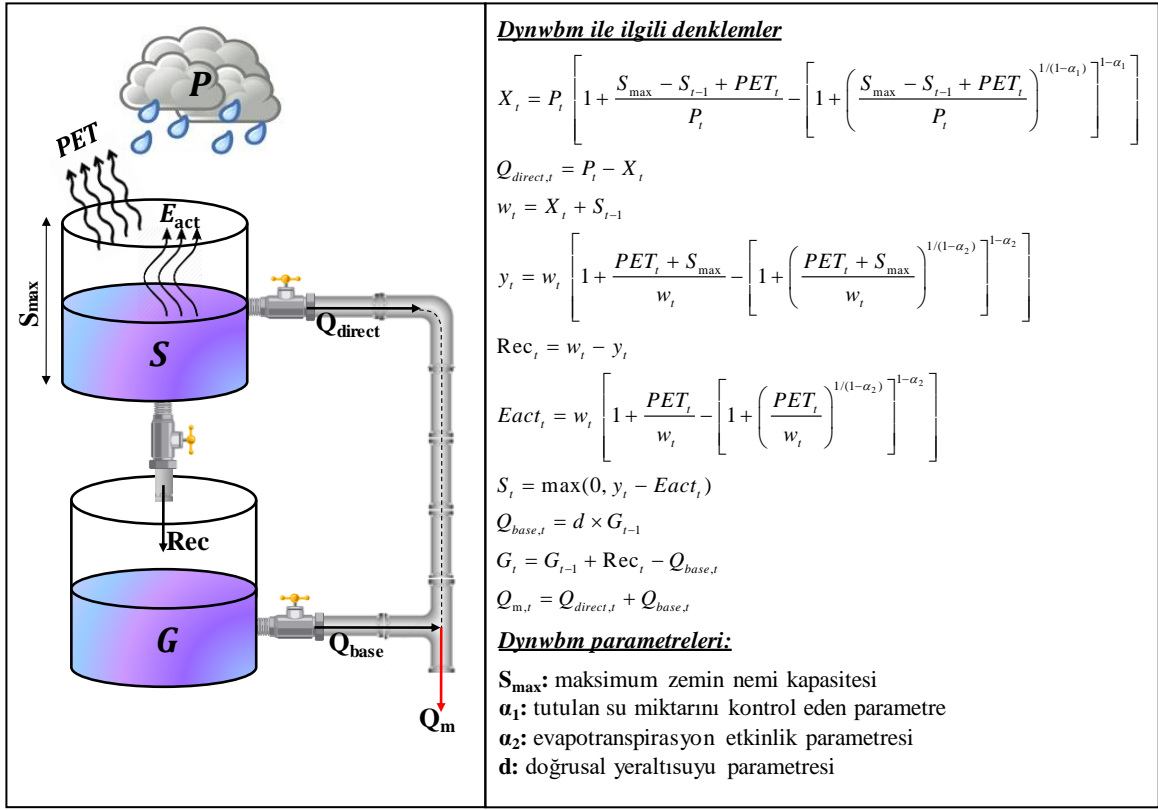
İlk bölümde bahsedildiği üzere, seri hibrit modellerin, daha güvenilir akış simülasyonları elde etmek için hali hazırda kullanılan yağış-akış modelleme yaklaşımlarının (kavramsal ve kapalı kutu modellerinin) güçlü yönlerinden faydalanması beklenmektedir. Bu bölümde ise hibridizasyon aşamasında değerlendirilecek *dynwbm* kavramsal modelinin detayları verilmiş ve iki adet, literatürde sık kullanılan ML tekniği (ANN ve SVR) kısaca tanıtılmıştır. Sonraki alt bölümlerde ise, seri hibrit modellerin nasıl uygulandığı ile ilgili detaylar sunulmuştur. Ayrıca iki ayrı yaklaşımın birleşiminden oluşan (iki ardışık eğitim süreci ile uygulanan modeller) ve seri hibrit modellerle kıyaslanan paralel tipteki bazı hibrit modeller ile ilgili işleyiş de burada verilmiştir. Son olarak ise sırasıyla tüm modellerin kalibrasyonunda tercih edilen optimizasyon algoritması ve performans değerlendirmesinde kullanılan kriterler hakkında bilgiler sunulmuştur.

### 2.1 Dinamik Su Bütçesi Modeli (*dynwbm*)

Çok parametrelili CRR modellerinden türetilen modellenmiş akış çıktıları kalibrasyon periyodu akım gözlemlerini hassas bir şekilde temsil edebilirken, bu tarz modeller doğrulama (validasyon) periyodunda genelleme yetilerini kaybedebilmektedir (Beven, 1989; Fıstıkoğlu, 1999; Fıstıkoğlu ve Okkan, 2010). Bu sebeple parametre adedi bakımından ekonomik olarak atfedilen modeller çok daha pratik bulunmaktadır (Okkan ve Fıstıkoğlu, 2014; Mouelhi vd., 2006; Perrin vd., 2003) Literatürde birçok makul sayıda parametresi olan CRR modeli bulunmasına rağmen, tez çalışmasında Zhang vd. (2008) tarafından önerilen dinamik su bütçesi modeli (*dynwbm*) tercih edilmiştir. Bu model hem dört parametrelili oluşu hem de farklı iklim koşullarında uygun performans göstermesi nedeniyle çalışma kapsamına alınmıştır. Modelin literatürde birçok uygulaması bulunmaktadır (Li vd., 2016; Okkan ve Kirdemir, 2018; 2020; Tekleab vd., 2011; Zuo vd., 2014). Bu model aylık akışı simüle etmek için girdi seti olarak yalnızca aylık toplam yağış (P) ve potansiyel evapotranspirasyon (PET) verilerini kullanmaktadır. Bu seçimin gerekçelerinden biri de modelin Budyko (1958) tarafından önerilen atmosferik talep-limit yaklaşımının kapsamlı bir analogu olmasıdır. Modelde gerçek evapotranspirasyon (actual evapotranspiration:  $E_{act}$ ) her zaman PET'ten daha az değerler vermekte ve zemin nemi doygun olmadığında bile derine sızma (perkolasyon) olayı meydana gelmektedir (Li vd., 2016). Modelin şematik bir diyagramı ve ilgili işlem adımları Şekil 2.1'de gösterilirken, iki



farklı parametre ile kontrol edilen Budyko eğrilerinin ve limitler yaklaşımının özeti Şekil 2.2’de verilmektedir.




Şekil 2.1: Dinamik su bütçesi modelinin akış şeması (Ersoy vd., 2021; Okkan vd., 2021).

Havzaya  $t$ . ayda düşen yağış ( $P_t$ ), dolaysız akışa ( $Q_{direct,t}$ ) ve havza tarafından tutulan su miktarına ( $X_t$ ) paylaştırılmaktadır. Dolaysız akış bileşeni dışındaki diğer hidrolojik çevrim elemanları için alıkonulan su miktarının kontrolünü sağlayan model parametresi veya dolaysız akış parametresi olarak da anılan  $\alpha_1$  ve maksimum zemin nemi depolama parametresi olan  $S_{\max}$  ile  $X_t$  değeri hesaplanmasının akabinde dolaysız akış miktarı tahmin edilmektedir (Denklem 2.1 ve Denklem 2.2).  $S_{\max}$  parametresinin sabit bir değeri için  $\alpha_1$  parametresindeki bir artış dolaysız akış miktarında azalma yaratırken, daha fazla yağış tutulmasını sağlamaktadır.

$$X_t = P_t \left[ 1 + \frac{S_{\max} - S_{t-1} + PET_t}{P_t} - \left[ 1 + \left( \frac{S_{\max} - S_{t-1} + PET_t}{P_t} \right)^{1/(1-\alpha_1)} \right]^{1-\alpha_1} \right] \quad (2.1)$$

$$Q_{direct,t} = P_t - X_t \quad (2.2)$$



**Şekil 2.2:** Dinamik su bütçesi modelinde Budyko eğrilerinin yüzey akışı, gerçek evapotranspirasyon ve derine sızma sürecinde uygulanışı

Modelde, veri periyodunda  $t$ . zaman adımındaki mevcut su içeriği  $w_t$  ise önceki zaman adımından kalan zemin nemi değeri ( $S_{t-1}$ ) ve  $X_t$  toplamına eşit kabul edilmektedir (Denklem 2.3)

$$w_t = X_t + S_{t-1} \quad (2.3)$$

Burada  $X_t$ , gerçek evapotranspirasyon ( $Eact_t$ ), zemin nemindeki değişim ( $S_t - S_{t-1}$ ) ve yeraltı suyu depolamasına sızan su ( $Rec_t$ ) bileşenlerinin toplamı olduğuna göre mevcut su içeriği Denklem 2.4'te belirtildiği gibi ifade edilebilmektedir.

$$w_t = S_t + Eact_t + Rec_t \quad (2.4)$$

Denklem 2.4'te yer alan ilk iki terimin toplamı hidroloji literatüründe evapotranspirasyon fırsatı olarak da bilinmekte olup (Sankarasubramanian ve Vogel, 2002) ve *dynwbm* modelinde  $\alpha_2$  evapotranspirasyon etkinlik parametresine bağlı olarak tahmin edilmektedir (Denklem 2.5)

$$y_t = w_t \left[ 1 + \frac{PET_t + S_{max}}{w_t} - \left[ 1 + \left( \frac{PET_t + S_{max}}{w_t} \right)^{1/(1-\alpha_2)} \right]^{1-\alpha_2} \right] \quad (2.5)$$

Bu işlem sonrasında yeraltı suyu depolamasına sızan su miktarı da Denklem 2.6 ile hesaplanmaktadır.

$$Rec_t = w_t - y_t \quad (2.6)$$

Denklem 2.4'te yer alan terimlerden olan zemin nemi değeri için ise öncelikle  $Eact_t$  bileşeninin bulunması gerekmektedir.  $y_t$  bileşenini kontrol eden evapotranspirasyon parametresi  $\alpha_2$ , gerçek evapotranspirasyon tahmininde de kullanılmaktadır (Ersoy vd., 2021; Okkan vd., 2021) (Denklem 2.7).

$$Eact_t = w_t \left[ 1 + \frac{PET_t}{w_t} - \left[ 1 + \left( \frac{PET_t}{w_t} \right)^{1/(1-\alpha_2)} \right]^{1-\alpha_2} \right] \quad (2.7)$$

Son aşamada, yeraltı suyu depolamasının lineer hazne kabulü ile ele alınması sebebi ile ve taban akışı ( $Q_{base,t}$ ) bir önceki ayın aktif yer altı suyu depolama miktarına ( $G_{t-1}$ ) ve doğrusal yeraltı suyu haznesi parametresine ( $d$ ) bağlı olarak hesaplanmaktadır (Denklem 2.8).

$$Q_{base,t} = d \times G_{t-1} \quad (2.8)$$

Taban akışı tahmininden sonra ise yeraltı suyu depolaması Denklem 2.9'a göre güncellenmektedir.

$$G_t = G_{t-1} + Rec_t - Q_{base,t} \quad (2.9)$$

Su bütçesi elemanlarının tanımlanmasının akabinde modellenen toplam akış Denklem 2.10 vasıtasıyla hesaplanmaktadır.

$$Q_{model,t} = Q_{direct,t} + Q_{base,t} \quad (2.10)$$

## 2.2 Yapay Sinir Ağları

Literatürde kullanılan birçok ANN mimarisine rağmen, en yaygın tür çok katmanlı algılayıcı olarak adlandırılan ileri beslemeli sinir ağlarıdır (Lohani vd., 2011). Çalışmada ele alınan ANN modeli, sırasıyla giriş katmanı, gizli katman ve çıkış katmanında düzenlenen yapay nöronları (hücreleri) içeren üç katmandan oluşmaktadır. ANN'nin hesaplama karmaşıklığı sadece girdi katmanına sunulan tahminleyici sayısına değil gizli katmandaki hücre sayısına ( $nnh$ ) da bağlıdır. Burada, girdiler istatistiksel bir ön analiz veya tecrübenin bir sonucu olarak atanırken, uygun  $nnh$ 'yi bulurken genellikle deneme-yenilme yaklaşımı tercih edilmektedir (Ersoy vd., 2021; Fıstıkoğlu ve Okkan, 2011; Noori ve Kalin, 2016; Okkan vd., 2021).

Çok katmanlı ANN'lerde işletim prosedürü ileri hesaplama ve eğitim olmak üzere iki aşamadan oluşmaktadır. İleri hesaplama adımı Fıstıkoğlu ve Okkan (2011) çalışmasında

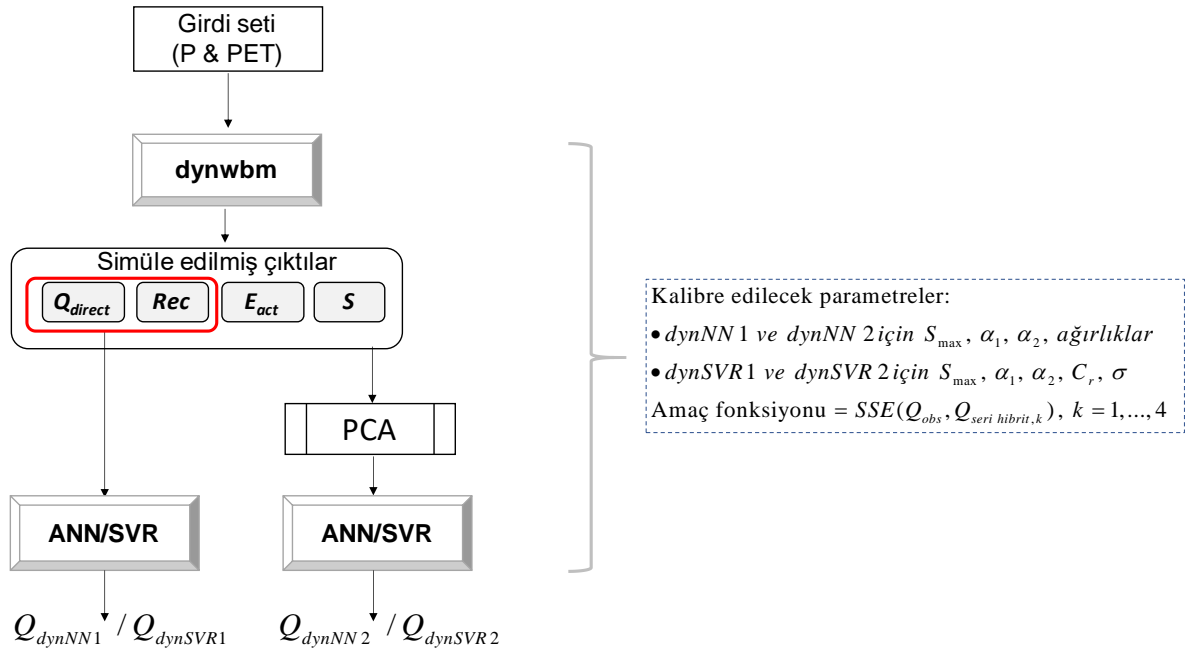
detaylı olarak açıklanmıştır. Eğitim aşaması ise ağırlıkların ve sabit (bias) terimlerin iteratif bir algoritma ile tahmin edilmesine dayanmaktadır. Çalışmada CRR modellerini kalibre etmek için de kullanılabilen otomatik optimizasyon algoritması ANN eğitiminde de değerlendirilmiştir. Hem tekil ANN modellerinde hem de ANN içeren hibrit modellerde, tüm değişkenler [0,1] kapalı aralığında olacak şekilde ölçeklenmiştir. Bunun için, log-sigmoid transfer fonksiyonu tüm katmanlarda uygun sonuçlar vermiştir. Eğitimden sonra, model çıktıları da ölçeklenmiş biçimde elde edildiğinden, çıktılar ters ölçekleme ile orijinal birimlerine (mm/ay) dönüştürülmüştür.

### 2.3 Destek Vektör Regresyonu

Destek vektör regresyonu, yağış-akış modellemesi ve akış simülasyonunda yaygın olarak kullanılan başka bir ML tekniğidir (Behzad vd., 2009; Lin vd., 2006; Maity vd., 2010; Okkan ve Serbes, 2012; Tongal ve Booij, 2018). ANN'de  $nnh$  adedine bağlı olarak eğitilmesi gereken ağırlıkların fazlalaşabilmesi ve bundan dolayı aşırı öğrenme sorunsalı SVR'yi çoğu durumda daha pratik ve güvenilir kılmaktadır (Okkan vd., 2021). Tez çalışmasında SVR'nin en küçük kareler versiyonu, daha kodlanabilir bir algoritmaya sahip olması ve orijinal SVR'deki karesel (kuadratik) programlamaya ihtiyaç duymaması nedeniyle tercih edilmiştir. SVR'nin ana önermesi, girdi verilerini doğrusal olmayan bir şekilde daha yüksek boyutlu özellik uzayına haritalayan bir kernel (çekirdek) fonksiyonunun kullanımına dayanmaktadır (Maity vd., 2010; Okkan vd., 2021; Sachindra vd., 2013). SVR kapsamında çeşitli kernel fonksiyonları kullanılsa da radyal tabanlı kernel fonksiyonunun diğer türlere göre daha iyi performans gösterdiği gözlemlenmiştir (Tongal ve Booji, 2018; Okkan ve Inan, 2015a). Ayrıca, SVR'deki veri ölçeklemesi ANN'deki gibi uygulanabilmektedir. SVR'den iyi sonuç elde etmek için, regülarizasyon parametresi ( $C$ ) ve radyal tabanlı kernel fonksiyonunun genişlik parametresi ( $\sigma$ ) olan iki kontrol parametresinin kalibre edilmesi gerekmektedir. Bu ML tekniğinin diğer detayları için ilgili literatür çalışmaları incelenebilir (Anandhi vd., 2008; Okkan ve Inan, 2015a, 2015b; Okkan ve Serbes, 2012; Sachindra vd., 2013). Bu çalışmada, tekil ANN ve SVR modelleri ilk olarak iki girdi (P ve PET) ile eğitilmiştir. Daha sonra, model performanslarını arttırmak için girdi setine 1 ay gecikmeli yağış verileri de dahil edilmiştir. Bu iki ve üç girdi seti içeren ML modelleri sırasıyla ANN1/SVR1 ve ANN2/SVR2 olarak adlandırılmıştır.

## 2.4 Önerilen Seri Hibrit Yağış-Akış Modelleri

Seri hibrit modeller, Bölüm 2.1, Bölüm 2.2 ve Bölüm 2.3'te verilen yaklaşımların entegre edilmesi ile oluşturulmuştur. Şekil 2.3'te gösterildiği gibi, seri hibrit modeller ardışık olarak CRR ve ML bölümlerinden oluşmaktadır. P, PET ve başlangıç zemin nemi içeriği ( $S_0$ ) bilgisi istenen kavramsal kısımda Şekil 2.1'de belirtilen ifadeler üç kavramsal parametre ile yürütülmüş ve ardından, çeşitli simüle edilmiş çıktılar ML kısmına iletilmiştir (Şekil 2.3). Hibrit modellerde kalibre edilecek parametrelerin özeti de aynı şekil üstünde vurgulanmıştır.



Şekil 2.3: Seri hibrit modelleme stratejisi (Okkan vd., 2021).

İlk stratejide, gözlemlenen akış serileri ile yüksek korelasyon sağlayan iki kavramsal çıktı ( $Q_{direct}$  ve  $Rec$ ), hibrit modelin ML kısmında (ANN ve SVR teknikleri) tekrar işleme maruz bırakılmıştır. Bu çıktıların seçilmesine zemin oluşturan ilgili korelasyon katsayısı istatistikleri Bölüm 4.2'de sunulmuştur. Burada ML kısmı, yeraltı suyu depolamasının lineer  $d$  parametresi ile yönetilen kavramsal taban akışı hesabının yerini almakta ve iki adet kavramsal çıktıyı ( $Q_{direct}$  ve  $Rec$ ) akışa dönüştürmektedir. Kavramsal modelin taban akış bileşeninin seri şema içinde elimine edilmesinin nedeni Bölüm 4.1'de açıklanmıştır. Hangi ML türünün (ANN ve SVR) hibritleme aşamasında kullanıldığına bağlı olarak, bu modeller sırasıyla  $dynNN1$  ve  $dynSVR1$  olarak adlandırılmıştır.

İkinci seri hibridizasyon işleminde,  $Q_{direct}$  ve  $Rec$  kavramsal çıktılarına ilaveten  $A_{ncil}$  vd. (2004) ve Kumanlioglu ve Fistikoglu (2019) çalışmalarında da kullanılan zemin nemi ( $S$ ) ve gerçek evapotranspirasyon ( $E_{act}$ ) da destekleyici veri olarak ML kısmında değerlendirilmiştir. Farklı olarak bu çalışmada seri şema içerisinde ve optimal sayıda asal (temel) bileşenle bu işlem yürütülmüştür. Temel bileşenler analizinde (principal component analysis: PCA), birinci temel bileşen (principal component: PC) varyans üstündeki en önemli katkıyı sağlarken, genellikle ikinci bileşenden sonra varyans üzerindeki katkının düzeyi istatistiksel açıdan anlamlı durmamaktadır (Hu vd., 2007; Okkan vd., 2021). PC'lerdeki katsayıların ve kovaryans matrisi tabanlı özvektörlerin hesap detayları için, Rencher (1998) ve Yılmaz ve Ozelik (2018) çalışmaları incelenebilir. Çalışmada PCA'yı boyut küçültme aracı olarak kullanan seri hibrit modeller  $dynNN2$  ve  $dynSVR2$  olarak adlandırılmıştır.

Şekil 2.3'te görüldüğü gibi, hem kavramsal kısmı yöneten üç parametrenin ( $S_{max}$ ,  $\alpha_1$  ve  $\alpha_2$ ), hem de ANN bölümünde katmanlar arası bağlantıyı sağlayan ağırlıkların ve bias terimlerin  $dynNN1$  ve  $dynNN2$  modelleri kapsamında belirlenmesi gerekmektedir. Bu modellerde eğitilmesi gereken serbest parametre sayısının ise  $4 \times nnh + 4$  olduğu söylenmektedir. Benzer şekilde  $dynSVR1$  ve  $dynSVR2$  hibrit modellerinde SVR kısmını yöneten iki parametre ve aynı kavramsal üç parametre ile beraber toplamda 5 adet kalibre edilebilir parametre olduğu görülebilmektedir. Tez çalışmasında önerilen  $dynNN/dynNN2$  ve  $dynSVR1/dynSVR2$  modellerinin işleyişi sırasıyla 2.4.1 ve 2.4.2 bölümlerinde detaylandırılmıştır. Ayrıca tüm bu seri hibrit modellerin otomatik kalibrasyonunda yararlanılacak optimizasyon algoritması ise Bölüm 2.6'da açıklanmıştır.

#### 2.4.1 $dynNN1$ ve $dynNN2$ Modellerinin İşleyişi

Seri hibrit modellerde kavramsal işleyişin tamamlanmasını takiben yardımcı tahminleyiciler ( $dynNN1$ 'de  $Rec$  ve  $Q_{direct}$ ,  $dynNN2$ 'de ise ilk iki asal bileşen)  $[0,1]$  aralığında ölçeklenmektedir. Ölçeklenmemiş kavramsal çıktıların  $L \times 2$  boyutlu ANN girdi matrisi ( $Inp$ ) gizli katman ile girdi katmanı arasındaki ağırlıklar ve bias terimleri vasıtası ile gizli katman çıktısına dönüştürülmektedir (Denklem 2.11 ve Denklem 2.12).

$$[\mathbf{net}^{(1)}]_{L \times nnh} = [\mathbf{Inp}]_{L \times 2} \begin{bmatrix} W_{1,1}^{(1)} & W_{1,2}^{(1)} & \dots & W_{1,nnh}^{(1)} \\ W_{2,1}^{(1)} & W_{2,2}^{(1)} & \dots & W_{2,nnh}^{(1)} \end{bmatrix}_{2 \times nnh} + \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{L \times 1} [b_1^{(1)} \ b_2^{(1)} \ \dots \ b_{nnh}^{(1)}]_{1 \times nnh} \quad (2.11)$$

$$[\mathbf{gk\check{c}}]_{L \times nnh} = f^{(1)}([\mathbf{net}^{(1)}]) \quad (2.12)$$

Burada  $L$  kalibrasyon veya validasyondaki veri uzunluğunu,  $W_{i,j}^{(1)}$  ve  $b_j^{(1)}$  girdi katmanı ve bias terimlerini ( $i=1,2; j=1,\dots,nnh$ ),  $net^{(1)}$  ara katmandaki toplam fonksiyonu,  $f^{(1)}$  ise ilk uygulanan aktivasyon fonksiyonunu (log-sigmoid) göstermektedir.

Daha sonra, ara katman çıktıları Denklem 2.13 ve Denklem 2.14 ile çıktı katmanının çıktılarına dönüştürülmektedir.

$$[\mathbf{net}^{(2)}]_{L \times 1} = [\mathbf{gk\check{c}}]_{L \times nnh} \begin{bmatrix} W_1^{(2)} \\ W_2^{(2)} \\ \vdots \\ W_{nnh}^{(2)} \end{bmatrix}_{nnh \times 1} + \begin{bmatrix} b^{(2)} \\ b^{(2)} \\ \vdots \\ b^{(2)} \end{bmatrix}_{L \times 1} \quad (2.13)$$

$$[\mathbf{Q}_{m,s}]_{L \times 1} = f^{(2)}([\mathbf{net}^{(2)}]) \quad (2.14)$$

Burada  $W_j^{(2)}$  ara katman ile çıktı katmanı arasındaki ağırlığı ( $j=1,\dots,nnh$ ),  $b^{(2)}$  çıktı düğümüne bağlanan son bias terimini,  $f^{(2)}$  son katmandaki toplam fonksiyonu  $net^{(2)}$ 'yi ölçeklenmiş ağ çıktısına dönüştüren aktivasyon fonksiyonunu temsil etmektedir. ANN içeren sistemin ileri hesaplama işleyişi Şekil 2.4a'da verilmektedir.

#### 2.4.2 dynSVR1 ve dynSVR2 Modellerinin İşleyişi

İlgili makine öğrenmesi tekniğinin işleyiş şeması Şekil 2.4b'de özetlenen bu hibrit modellerde de  $L \times 2$  boyutlu girdi matrisinin (Inp) derlenmesini takiben  $\sigma$  parametresine bağlı olarak kernel fonksiyonu matrisi oluşturulmaktadır. Radyal tabanlı kernel fonksiyonun öklid uzaklığı terimi (D) eğitim ve test veri setleri için Denklem 2.15 ve Denklem 2.16 eşitlikleri ile hesaplanabilmektedir.

$$D = \text{diag}(X_{tr} \ X_{tr}^T) [1 \dots 1]_{1 \times L_{tr}} + \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{L_{tr} \times 1} \left[ \text{diag}(X_{tr} \ X_{tr}^T) \right]^T - 2 X_{tr} X_{tr}^T \quad (2.15)$$

$$D = \text{diag}(X_{tr} \ X_{tr}^T) [1 \dots 1]_{1 \times L_{test}} + \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{L_{tr} \times 1} \left[ \text{diag}(X_{test} \ X_{test}^T) \right]^T - 2 X_{tr} X_{test}^T \quad (2.16)$$

Burada  $L_{tr}$  ve  $L_{test}$  sırasıyla eğitim ve test verisinin uzunluğu,  $X_{tr}$  ve  $X_{test}$  ise  $Inp$  matrisi içerisinde sırasıyla eğitim ve test (validasyon) için ayrılan kısımları ifade etmektedir.  $D$  matrisi eğitim ve test dönemleri için elde edildikten sonra, kernel matrisine Denklem 2.17 ile erişilmektedir ( $D$  ve  $K$  eğitim dönemi için  $L_{tr} \times L_{tr}$  boyutlu iken test döneminde  $L_{tr} \times L_{test}$  boyutuna sahiptir).

$$K = \exp\left(-\frac{D}{2\sigma^2}\right) \quad (2.17)$$

Burada  $\sigma$  radyal tabanlı fonksiyonun genişlik parametresidir.

Modelin  $Cr$  regülarizasyon terimine (penaltı terimi) bağlı olarak Lagrange çarpanları ( $\alpha$ ) ve bias terimi ( $b$ ) Denklem 2.18'de verilen ifadenin çözümü ile elde edilmektedir.

$$\begin{bmatrix} 0 & \vec{1}^T \\ \vec{1} & K + Cr^{-1}I \end{bmatrix}_{(L_{tr}+1) \times (L_{tr}+1)} \begin{bmatrix} b \\ \alpha \end{bmatrix}_{(L_{tr}+1) \times 1} = \begin{bmatrix} 0 \\ \mathbf{y}_{tr} \end{bmatrix}_{(L_{tr}+1) \times 1} \quad (2.18)$$

Burada  $\vec{1} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix}_{L_{tr} \times 1}$  ;  $I = \begin{bmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \cdots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix}_{L_{tr} \times L_{tr}}$  şeklinde tanımlanmaktadır.

$y_{tr}$  gözlenmiş akımları temsil etmekte olup  $\alpha$  ile aynı boyuta ( $L_{tr} \times 1$ ) sahiptir. Elde edilen  $\alpha$  ve  $b$  değerlerine göre eğitim ve test dönemi çıktıları sırasıyla Denklem 2.19 ve Denklem 2.20 olarak elde edilmektedir.


$$[\mathbf{Q}_{m,s}]_{1 \times L_{tr}} = \alpha^T x[K]_{L_{tr} \times L_{tr}} + b x[1 \cdots 1]_{1 \times L_{tr}} \quad (2.19)$$

$$[\mathbf{Q}_{m,s}]_{1 \times L_{test}} = \alpha^T x[K]_{L_{tr} \times L_{test}} + b x[1 \cdots 1]_{1 \times L_{test}} \quad (2.20)$$

Hibrit modelin son aşamasında, ters ölçekleme (Denklem 2.21) ile normalleştirilmiş model çıktıları ( $Q_{m,s}$ ) orijinal hedeflerle aynı birime sahip olan akış tahminlerine ( $Q_{model}$ ) geri dönüştürülür.

$$Q_{model,t} = \mathbf{Q}_{m,s,t} \times (Q_{obs,max} - Q_{obs,min}) + Q_{obs,min}, \quad t = 1, 2, \dots, L \quad (2.21)$$

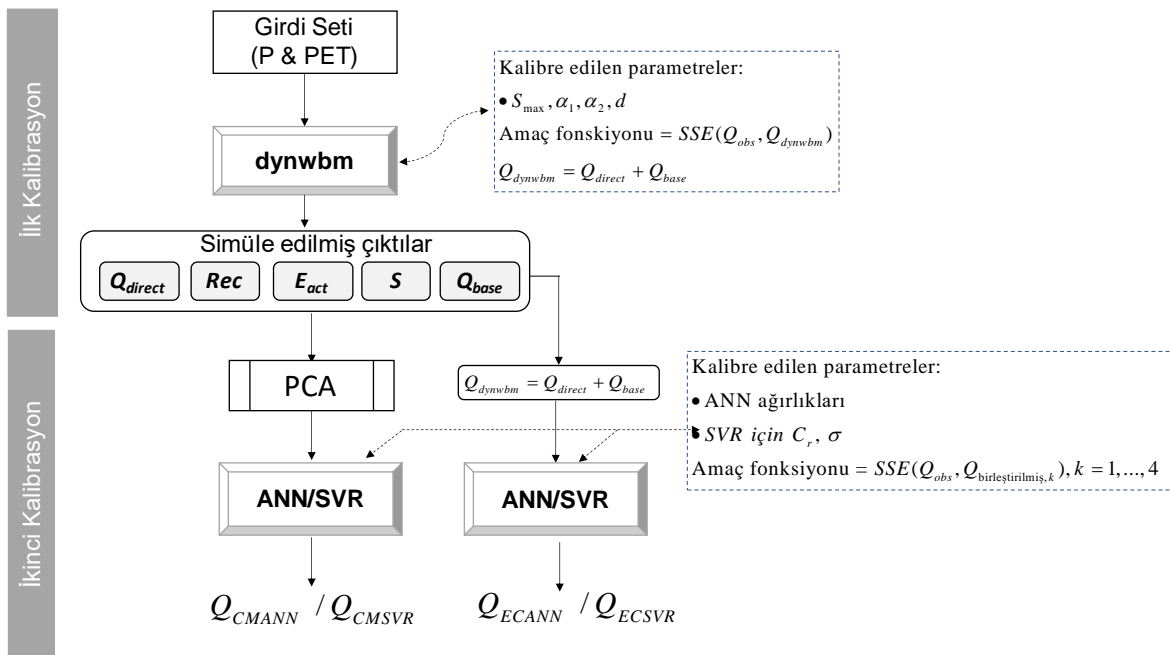




Şekil 2.4: (a) Tipik katmanlı ANN yapısı, (b) SVR işleyişinin özeti

## 2.5 Kullanılan Paralel Hibrit Yağış-Akış Modelleri

Tez çalışmasında, kavramsal model çıktılarının ML teknikleri (ANN ve SVR) ile birleştirilmesi tek bir kalibrasyonla işletilen dört seri hibrit modelleme stratejisine (dynNN1, dynSVR1, dynNN2 ve dynSVR2) karşı test edilmiştir. Seri modellerde uygulananın aksine, kalibre edilmiş kavramsal çıktıların ML ile kombinlenmesi öncesi PCA'nın bu çıktılardaki gerekli boyut küçültmesini sağlayacağı ve aşırı lineerliği azaltacağı düşünülmüş ve modellerin yeraltı suyu bileşeni de kavramsal çıktılar arasında değerlendirilmiştir. Seri hibrit modelleme kapsamında da değerlendirilen PCA, *dynwbm*'den türetilen 5 çıktı ( $Q_{direct}$ , Rec, Eact, S ve  $Q_{base}$ ) arasındaki lineer bağımlılığı da esas alarak ilk iki asal bileşenle iki adet çıktının ML'nin ilk katmanına sunulmasını sağlamıştır. Şekil 2.5'te görüldüğü gibi *dynwbm* kalibrasyonu sonrasında PCA ile boyutu küçülen çıktılar ilgili ML ile yeni bir eğitim sürecinden geçmektedir.



**Şekil 2.5:** İki ardışık kalibrasyon işleminden oluşan paralel birleştirilmiş model stratejisi (Okkan vd., 2021).

Kullanılan paralel hibrit şemalar, ANN ve SVR içermesi durumunda sırasıyla CMANN ve CMSVR olarak adlandırılmıştır. Ayrıca, daha önce Shamseldin ve O'Connor (2001) tarafından deneyimlenen basit hata düzeltme (error correction: EC) yaklaşımli paralel hibrit modellerin de önerilen seri modellerle kıyaslanması sağlanmıştır. EC uygulamasında da ANN ve SVR, *dynwbm*'den türetilen simüle edilmiş toplam akış serisi ( $Q_{direct}+Q_{base}$ )

üzerinde klasik çıktı güncelleme teknikleri olarak irdelenmişlerdir. Dolayısı ile, tek girdili serilerle çalıştırılan bu EC tabanlı paralel tarz modeller de ANN ve SVR içerme koşuluna göre sırası ile ECANN ve ECSVR olarak çalışmada anılmaktadır (Şekil 2.5).

## 2.6 Modellerin Parametrelerinin Kalibrasyonu

Çalışmada değerlendirilen tüm yağış-akış modellerinde (kavramsal tipteki modeller, ANN/SVR modelleri ve karma hibrit modeller) olası çoklu yerel minimum varlığı, küresel çözümün aranmasını karmaşık hale getirebileceğinden, kalibrasyon aşamasında kullanılacak otomatik arama algoritmasının seçimi yapılırken dikkat edilmesi gerekmektedir. Bu bakımdan, gradyan tabanlı algoritmalar (Gauss-Newton, Levenberg-Marquardt) hızlı yakınsamalarına rağmen yerel minimumda takılma olasılığı dahil olmak üzere çeşitli sorunlar barındırmaktadır (Zhang vd., 2007). Gradyan tabanlı yerel arama algoritmalarının bu dezavantajları, hidrologları kavramsal yağış-akış modellerinin otomatik kalibrasyonunda (Arsenault vd., 2014) ve makine öğrenimi modellerinin eğitimi (Chen vd., 2015) için meta-sezgisel tabanlı global arama algoritmalarına yönlendirmiştir. Ayrıca meta-sezgisel yöntemlere daha hızlı yakınsama yeteneği getiren bazı modifikasyonlar da mevcuttur. Bu konu ile ilgili olarak, Okkan ve Kirdemir (2020), Parçacık Sürü Optimizasyonu (PSO) ve Levenberg-Marquardt (LM) algoritmalarının hibridizasyonundan oluşan bir optimizasyon algoritması önermişlerdir. Bu çalışmalarındaki çeşitli indisler açısından, hibrit parçacık sürü optimizasyonu (HPSO) olarak adlandırılan hibrit algoritmanın, kavramsal yağış-akış model kalibrasyonunda bilinen meta-sezgisel algoritmalarla göre daha başarılı bir performans sergilediği kanıtlanmıştır. Çalışmada HPSO olarak anılan bu algoritma karşılaştırılan tüm modellerin eğitiminde kullanılmıştır.

HPSO algoritmasının ilk aşamasında değerlendirilen PSO algoritması Kennedy ve Eberhart (1995) tarafından kuş/balık sürülerinin yiyecek arama davranışlarından esinlenerek önerilmiş popülasyon temelli bir algoritmadır. Algoritma sürünün (parçacıkların) yiyecek aramak için çözüm uzayına rassal hareket etmesiyle başlamaktadır. Parçacıklar, Denklem 2.22'de ifade edilen  $v$  hız vektörü vasıtasıyla yiyeceğin uzaydaki  $x$  koordinatlarını belirlemeye çalışırlar. Başlangıç anında tüm parçacıklar için  $v(t=0)=0$  varsayılabilir. İteratif hesap adımlarında hız vektörü önceki adımda hafızaya alınan konum vektörüne eklenerek parçacıkların yeni konumları belirlenmektedir.

$$v_{i,j}(t+1) = \omega_{inertia} * v_{i,j}(t) + r * c * (pbest_{i,j}(t) - x_{i,j}(t)) + r * c * (gbest_j(t) - x_{i,j}(t)) \quad (2.22)$$

Burada,  $t$  iterasyon adımıdır.  $pbest$ ,  $i$  numaralı parçacığın o adıma kadar eriştiği en iyi koordinat bilgisini,  $gbest$  tüm parçacıklar içindeki en iyi koordinat değerini ifade etmektedir.  $c$  ise ivmelenme katsayısı olup genelde 2 değerini almaktadır (Tayfur, 2017).

$t=0$  adımı için  $pbest$  matrisi Denklem 2.23 ile rassal atanan başlangıç matrisine eşit alınmaktadır.

$$x_{i,j} = x_j^{\min} + r * [x_j^{\max} - x_j^{\min}], \quad i = 1, 2, \dots, N_{pop}, \quad j = 1, 2, \dots, N_{par} \quad (2.23)$$

Burada,  $N_{pop}$  popülasyon büyüklüğünü,  $N_{par}$  ise kalibre edilmesi gereken parametre adedini,  $r$   $[0, 1]$  aralığında rastgele türetilen sayıyı temsil etmektedir.  $x_{min}$  ve  $x_{max}$  ise sırasıyla  $j$  numaralı parametre için seçilen alt ve üst limit değerlerdir.

Popülasyondaki bir  $i$  satırında konum güncellemesi sonrası elde edilen çözüme ait uygunluk fonksiyonu (UF) değeri bir önceki adımdakine kıyasla iyileşmiş ise  $pbest$ 'nin ilgili satırı da yeni konum ile değiştirilir.  $N_{pop} \times N_{par}$  boyutuna sahip  $pbest$  matrisi içindeki en iyi çözüm de önceki adımdaki en iyi çözüme kıyasla daha uygun ise  $gbest$  vektörü bu çözüm ile yer değiştirir. Bu işlemler maksimum iterasyon adedine erişilene kadar sürmektedir (Tayfur, 2017). Çalışmada Denklem 2.22'deki hız terimini iteratif olarak kontrol eden  $\omega_{inertia}$  atalet ağırlıkları için kaotik atalet ağırlığı yaklaşımı seçilmiştir. HPSO yaklaşımı ise PSO'nun bilindik şekilde işletilmesi ile belirlenen  $gbest$  vektörünün her bir iterasyonda LM algoritmasına girdi olarak sunulmasına dayanmaktadır (Okkan ve Kirdemir, 2020). HPSO'da, LM kısmı Jakobien matris olarak adlandırılan, model hatalarının,  $gbest$  vektöründeki her bir elemana göre birinci derece kısmi türevlerinden oluşan Denklem 2.24'teki matrise ihtiyaç duymaktadır ( $L_{tr}$ =kalibrasyondaki veri uzunluğudur).

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial x_1} & \frac{\partial e_1}{\partial x_2} & \dots & \frac{\partial e_1}{\partial x_j} \\ \frac{\partial e_2}{\partial x_1} & \frac{\partial e_2}{\partial x_2} & \dots & \frac{\partial e_2}{\partial x_j} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_{L_{tr}}}{\partial x_1} & \frac{\partial e_{L_{tr}}}{\partial x_2} & \dots & \frac{\partial e_{L_{tr}}}{\partial x_j} \end{bmatrix}_{L_{tr} \times N_{par}}, \quad j = 1, 2, \dots, N_{par} \quad (2.24)$$

Her bir iterasyon adımında sonlu farklar yaklaşımı (tercihen ileri fark) ile  $J$  matrisi oluşturulduktan sonra,  $gbest$  güncellemesi Hessian matrisin yaklaşık bir çözümüne dayanan Denklem 2.25 ile gerçekleştirilmektedir.

$$gbest_{t+1} = gbest_t - [J_t^T J_t + \lambda_t I]^{-1} J_t^T e_t, \quad t = 1, 2, \dots, iter_{max} \quad (2.25)$$

Burada  $e_t$ ,  $L_{tr} \times 1$  boyutundaki hata vektörünü,  $gbest_t$ , PSO vasıtasıyla türetilen global en iyi çözümü,  $gbest_{t+1}$  LM ile güncellenen yeni çözümü temsil etmektedir. Ayrıca, Marquardt parametresi  $\lambda$  ise belli bir  $t$  iterasyon adımında, fitness azaldığında belirli bir bozulma oranı ( $\beta$ ;  $0 < \beta < 1$ ) ile çarpılmakta, fitness yeni bir adımda arttığında ise  $\beta$  değerine bölünmektedir. Böylece modelin performansı her adımda adaptif bir biçimde iyileştirilmeye çalışılmaktadır (Tercihen  $\lambda_0=0.01$ ,  $\beta=0.1$  ve  $\lambda_{max}=10^{10}$  alınabilir). Algoritma ile ilgili daha detaylı bilgiye Okkan ve Kirdemir (2020) çalışmasından ulaşılabilir.

Çalışmada, akım gözlem istasyonları için derlenen veriler kalibrasyon ve validasyon olmak üzere iki eşit parçaya bölünmüştür. HPSO'da popülasyon boyutunun 50 olarak ayarlanması bütün denemeler için yeterliyken, iterasyon sayısı durum ve model tipine bağlı olarak değişmiştir. Amaç (uygunluk) fonksiyonu olarak hata kareler toplamı (sum of squared errors: SSE) tercih edilmiştir.

Kavramsal parametrelerin optimal çözümlerinin arandığı sınırlar da çeşitli denemelerden sonra belirlenmiştir. Buna göre  $S_{max}$  parametresinin alt-üst sınırı 50 - 1000 mm iken,  $\alpha_1$  ve  $\alpha_2$ 'nin sınırları 0.1 - 0.90 olarak ayarlanmıştır. Ayrıca  $d$  parametresi için de 0.01 - 1.0 sınırları kullanılmıştır. HPSO algoritması koşturulurken iteratif çözümlerin bu kapalı aralıklar arasında tutulması sağlanmıştır.

Ayrıca, ANN ve ANN ile hibritlenmiş modellerin serbest parametreleri olan ağırlıkların ve bias terimlerin başlangıç değerleri ise  $[-1, 1]$  üniform aralığında rastgele atanmıştır. Ancak bu modellerin eğitiminde iterasyonlar sırasında çözümlerin herhangi bir aralıkta tutulması yoluna gidilmemiştir. Yalnız ANN modeli ve ANN içeren herhangi bir hibrit model HPSO algoritması vasıtasıyla kalibrasyon veri seti kullanılarak hassas bir şekilde eğitilmiş ve bu aşamada gizli katmandaki hücre sayısına ( $nnh$ ) çeşitli denemeler neticesinde karar verilmiştir. 2 ila 20 aralığındaki  $nnh$  denemelerinin her biri HPSO ile 5 kez koşturulmuş olup netice itibari ile 95 adet simülasyonun yer aldığı deneme havuzu içerisinde validasyon döneminde en küçük karesel hata değerini veren parametre kombinasyonu

tercih edilmiştir. Diğer yandan, SVR ve SVR içeren hibrit modellerin Cr ve  $\sigma$  parametreleri için rasgele başlangıç çözümü [0.1,10] aralığında başlatılmış fakat HPSO ile yapılan iterasyonlar sırasında SVR parametrelerinin çözüm uzayında serbest hareket etmesi sağlanmıştır. ANN içerikli uygulamalardaki gibi, SVR'li herhangi bir modelin kalibrasyon veri seti ile Lagrange çarpanlarının belirlenmesi sağlanmış fakat optimum parametre setlerinin tespitinde validasyon döneminde en küçük karesel hata değerini arz eden kombinasyonlar değerlendirilmiştir.

## 2.7 Performans Kriterleri

Kalibrasyon ve validasyon dönemlerinde irdelenen hata kareler toplamı (SSE) veya hata kareler ortalamasının karekökü (RMSE) gibi ölçütlere ilaveten tez çalışmasında Nash-Sutcliffe katsayısı (NS) değerleri de sorgulanmıştır. NS (Nash ve Sutcliffe, 1970), hidrolojik modellerin performanslarının değerlendirilmesinde yaygın olarak tercih edilmekte ve Moriasi vd. (2007) tarafından vurgulandığı gibi, bir hidrografın genel uyumunu yansıtmada tutarlı bir ölçüttür. Modeller, NS performansları açısından aşağıdaki gibi derecelendirilmektedir (Moriasi vd., 2007; Noori vd., 2020):

Çok iyi:  $0.75 < NS \leq 1$

İyi:  $0.65 < NS \leq 0.75$

Yeterli:  $0.50 < NS \leq 0.65$

Yetersiz:  $NS \leq 0.50$


Çalışmada, Nash ve Sutcliffe (1970) tarafından önerilen NS tabanlı  $r^2$  istatistikleri ile *dynwbm*'ye alternatif olarak uygulanan modellerin *dynwbm*'den ne ölçüde farklılık arz ettiği de sorgulanmıştır. Bu karşılaştırma ölçütü Denklem 2.26 ile ifade edilebilmektedir.

$$r^2 = \frac{NS_2 - NS_1}{1 - NS_1} \quad (2.26)$$

Burada  $NS_1$  ve  $NS_2$ , sırasıyla *dynwbm* ve uygulanan herhangi bir modelden elde edilen NS katsayılarıdır. Senbeta vd. (1999),  $r^2$ 'nin %10'dan büyük olması halinde önerilen modelin karşılaştırılan referans modele kıyasla anlamlı iyileşme öngördüğü söylenebilmektedir.

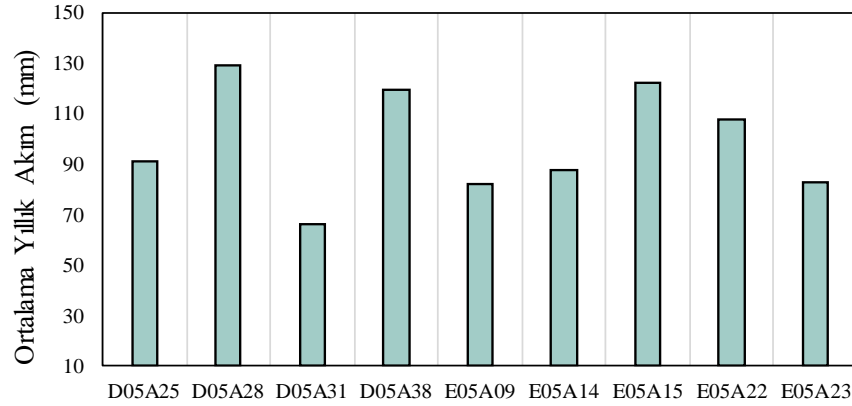

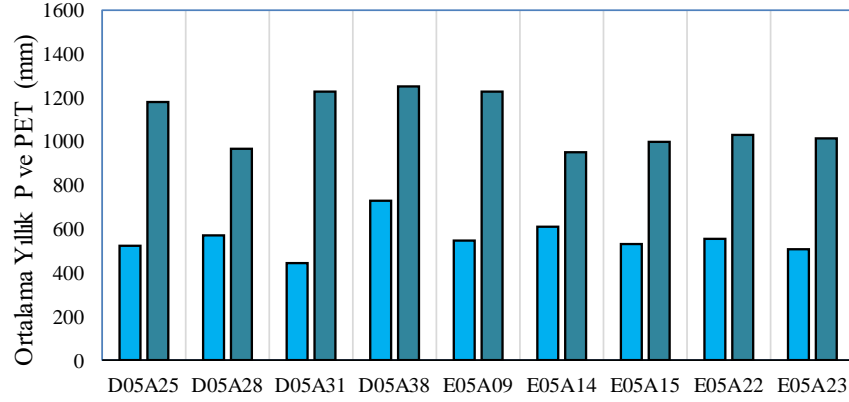
### 3. ÇALIŞMA ALANI VE KULLANILAN VERİLER

Tez çalışması kapsamında Ege Bölgesi'nin tarımsal su talebini yüksek oranda karşılayan Gediz Havzası çalışma alanı olarak seçilmiştir. Su kullanım rekabetlerinin yoğun yaşandığı havzadaki kentsel alanların 2030 yılına kadar %11 oranında genişleyeceği tahmin edilmektedir (De Voogt vd., 2000). Ülkemizde tarımsal su talepleri aylık iklim verileri ile belirlendiğinden, aylık zaman ölçekli akış serilerinin doğru simülasyonu, sulama birliklerine su temininin planlanması ve tarımla işletilen baraj rezervuarlarındaki su kaynağının yeterliliğinin sorgulanması için esas teşkil etmektedir. Bu doğrultuda, tez çalışmasında aylık zaman ölçekli verilerle çalışan modellerin analiz edilmesine karar verilmiştir. Havza üzerindeki aylık yağış, sıcaklık ve bağıl nem verilerini ölçen meteoroloji istasyonları Meteoroloji Genel Müdürlüğü tarafından işletilmektedir. Düzenli olarak ölçülemeyen rüzgâr hızı ve solar radyasyon verileri ampirik Penman-Monteith denklemine dayalı PET hesaplamasının temelini oluşturduğundan, erişilemeyen veriler ERA-Interim re-analiz veri setinden karşılanmıştır. Uygulamalar Devlet Su İşleri Genel Müdürlüğü tarafından işletilen dokuz adet akım gözlem istasyonu üzerinde yapılmıştır. Bunlar içerisinde, Dereköy, Topuzdamları, Borlu ve Acısu istasyonları havzanın kuzeydoğusundaki Demirköprü Baraj rezervuarını besleyen kollar üzerindedir. Havzanın merkezinde yer alan bu rezervuar ile birlikte Marmara Gölü üzüm, pamuk, mısır, çeşitli sebze ve meyveler gibi ürünlerin su ihtiyacını büyük ölçüde karşılamaktadır. Gördes akarsularının beslediği Gördes Barajı da İzmir iline tatlı su sağlanması açısından önemlidir. İstasyonların havza üzerindeki konumları Şekil 3.1'de gösterilmiştir. En büyük drenaj alanına sahip Muradiye istasyonu dışında, ana kol üzerinde yer alan çeşitli alt havzalar da söz konusu şekilde belirtilmiştir. Belirtilen bu alt havzalar tez çalışmasında istasyonların adıyla anılmaktadır. Her bir akım gözlem istasyonunun drenaj alanı için milimetre cinsinden aylık akış, Thiessen ağırlıklı yağış verileri (P) ve alansal ortalama PET verileri, mevcut referans iklim dönemi olan 1981-2010 su yılı dönemleri için derlenmiştir. Bu dönemde tüm havza için ortalama yıllık P ve PET rejimi sırasıyla 525 mm ve 1200 mm civarındadır. Ayrıca, akım gözlem istasyonlarının temsili drenaj alanları için yarı kurak ve kurak-yarı nemli iklim bölgelerinin baskın olduğu tespit edilmiştir. İstasyonların kod, drenaj alanı vb. bilgilerinin de yer aldığı Şekil 3.2'ye göre, alt havzalarda gözlenen yağış rejimi benzer bir eğilim gösterse de yıllık ortalama sıcaklık, PET ve akışa ilişkin değişkenlikler daha belirgin durmaktadır (Okkan vd., 2021).



Şekil 3.1: Çalışma alanı, istasyonların yerleri ve ilgili alt havzalar (Okkan vd., 2021).





AGİ	AGİ No.	Nehri/Çayı	Drenaj alanı (km <sup>2</sup> )
Muradiye	D05A25	Gediz	15,849.0
Hacıhıdır	D05A28	Gördes	808.2
Taytan	D05A31	Alaşehir	2,513.0
Hacıhaliller	D05A38	Nif	854.0
Kayaloğlu	E05A09	Medar	901.6
Dereköy	E05A14	Selendi	689.6
Topuzdamları	E05A15	Deliniş	739.6
Borlu	E05A22	Demirci	818.8
Acısu	E05A23	Gediz	3,272.4

**Şekil 3.2:** Akım gözlem istasyonları ile ilgili bilgiler ve gözlenmiş ortalama yıllık yağış, PET, akım ve sıcaklık değerleri.

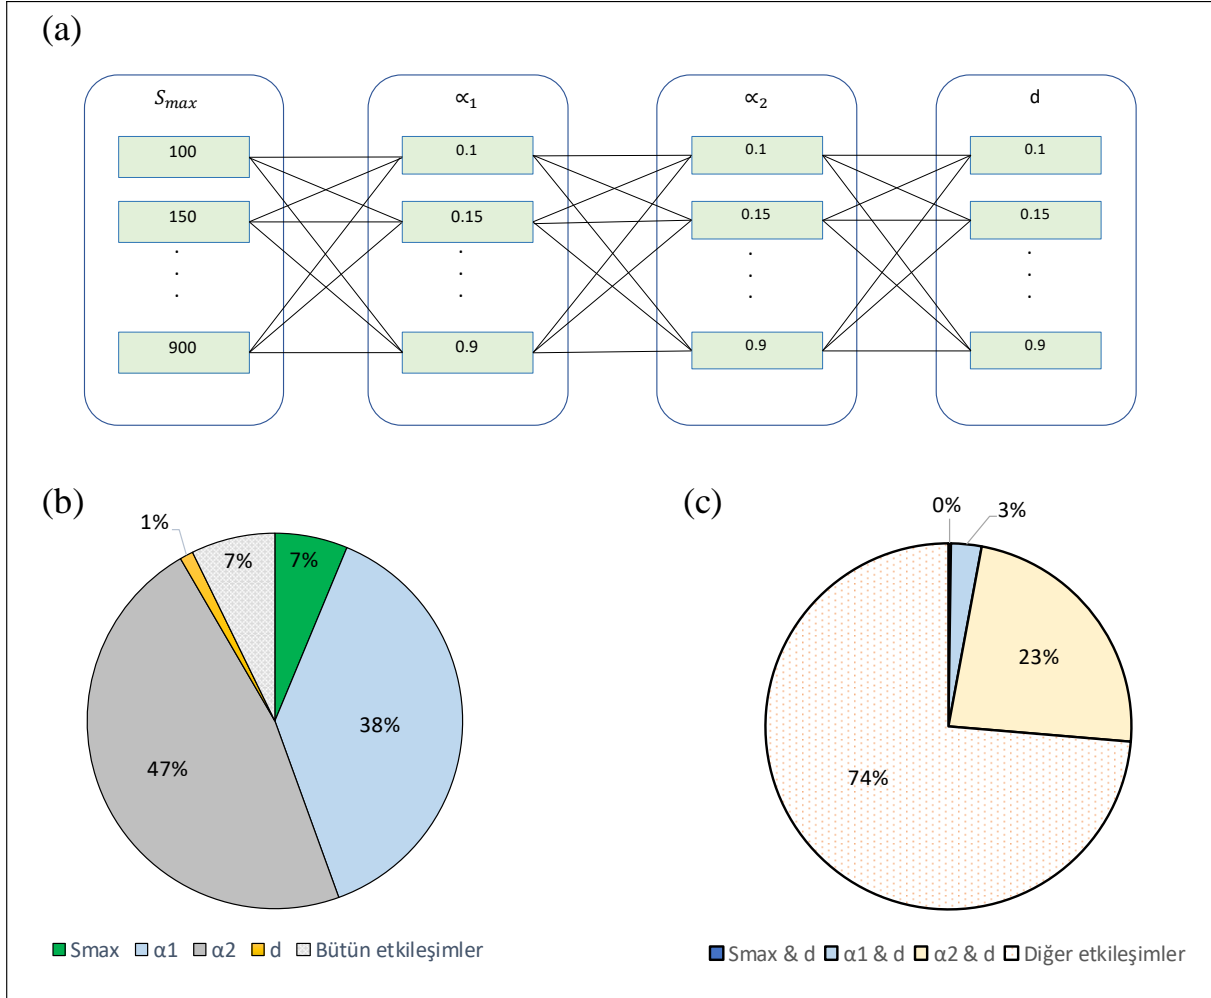
## 4. BULGULAR

Tez çalışması kapsamında tüm modeller herhangi bir paket yazılım kullanılmadan MATLAB ortamında kodlanmış ve bahsedilen dokuz adet akım gözlem istasyonuna uygulanmıştır (Ersoy vd., 2021; Okkan vd., 2021). Daha önceden değinildiği gibi seri hibridizasyonların simülasyon performansındaki etkinliğini değerlendirebilmek için tekil modeller ve farklı paralel tipte hibrit modeller kullanılmıştır. Fakat öncesinde, seri hibrit modeller içindeki kavramsal kısımda taban akışı bileşeninin ortadan kaldırılması önerildiğinden bunu desteklemek için bir hassasiyet analizi Bölüm 4.1’de sunulmuştur. Akabinde, seri hibrit modellerin nasıl kurulacağı Bölüm 4.2’de detaylandırılmış ve tüm modellerin simülasyon performanslarının karşılaştırılması Bölüm 4.3’te verilmiştir.

### 4.1 *dynwbm*’nin Parametre Hassasiyet Analizi

*dynwbm*’nin kalibrasyon ve validasyonunun ardından, model parametrelerinin akış simülasyon performansı üzerindeki bireysel ve etkileşimli etkilerini dinamik olarak ölçmek için ANOVA (varyans analizi) olarak adlandırılan hassasiyet analizine bağlı bir belirsizlik ayrıştırma yöntemi kullanılmıştır. Qi vd., (2016) çalışmasında bir optimizasyon algoritmasının kontrol parametrelerinin dinamik hassasiyetini ölçmek için üç yönlü bir ANOVA çerçevesi önermiş ve bir hidrolojik modelin kalibrasyon problemi üzerindeki parametre etkilerini araştırmıştır. Bu tez çalışmasında ise dört parametrelili *dynwbm*’ye uygulanan hassasiyet analizi dört yönlü ANOVA olarak tanımlanmıştır. ANOVA’yı parametre hassasiyet analizine uyarlamadan önce Şekil 4.1a’da gösterilen parametre kombinasyonları oluşturulmuş ve *dynwbm* toplamda  $17^4 = 83521$  kez çalıştırılmıştır. Bu çalışmalardan derlenen SSE varyasyonları daha sonra *dynwbm*’nin dört parametresine karşılık gelen dört ana etkiye bölünmüştür. Ayrıca, altı adet birinci mertebeden etkileşim terimi (yani  $S_{max} * \alpha_1$ ,  $S_{max} * \alpha_2$ ,  $S_{max} * d$ ,  $\alpha_1 * \alpha_2$ ,  $\alpha_1 * d$  ve  $\alpha_2 * d$ ), dört adet ikinci mertebeden etkileşim terimi (yani,  $S_{max} * \alpha_1 * \alpha_2$ ,  $S_{max} * \alpha_1 * d$ ,  $S_{max} * \alpha_2 * d$  ve  $\alpha_1 * \alpha_2 * d$ ) ve bir adet üçüncü mertebeden etkileşim terimi (yani,  $S_{max} * \alpha_1 * \alpha_2 * d$ ) bulunmaktadır. Dört yönlü ANOVA ile kısmi varyanslar ayrıştırıldıktan sonra, her bir durum için ana kaynaklara ve etkileşim terimlerine ilişkin katkı sağlayan varyans fraksiyonları elde edilmiş olup havza genelindeki ortalamaları Şekil 4.1b’de sunulmuştur. Şekil 4.1b incelendiğinde  $\alpha_1$  ve  $\alpha_2$  parametrelerinin *dynwbm* performansı üzerindeki hassasiyetinin daha baskın olduğu, taban akışı kontrol eden  $d$  parametresinin model üzerinde önemli bir etkisinin olmadığı görülmektedir.  $d$  parametresine bağlı birinci

mertebeden etkileşim terimlerinin toplam etkileşimdeki katkıları da Şekil 4.1c’de çıkarılmıştır. Buna göre,  $S_{max}*d$ ,  $\alpha_1*d$  ve  $\alpha_2*d$  olarak adlandırılan bu etkileşim terimlerinin toplam etkileşim içindeki katkıları nispeten etkisizdir. Ayrıca ikinci ve üçüncü dereceden etkileşim katkıları da oldukça zayıftır.

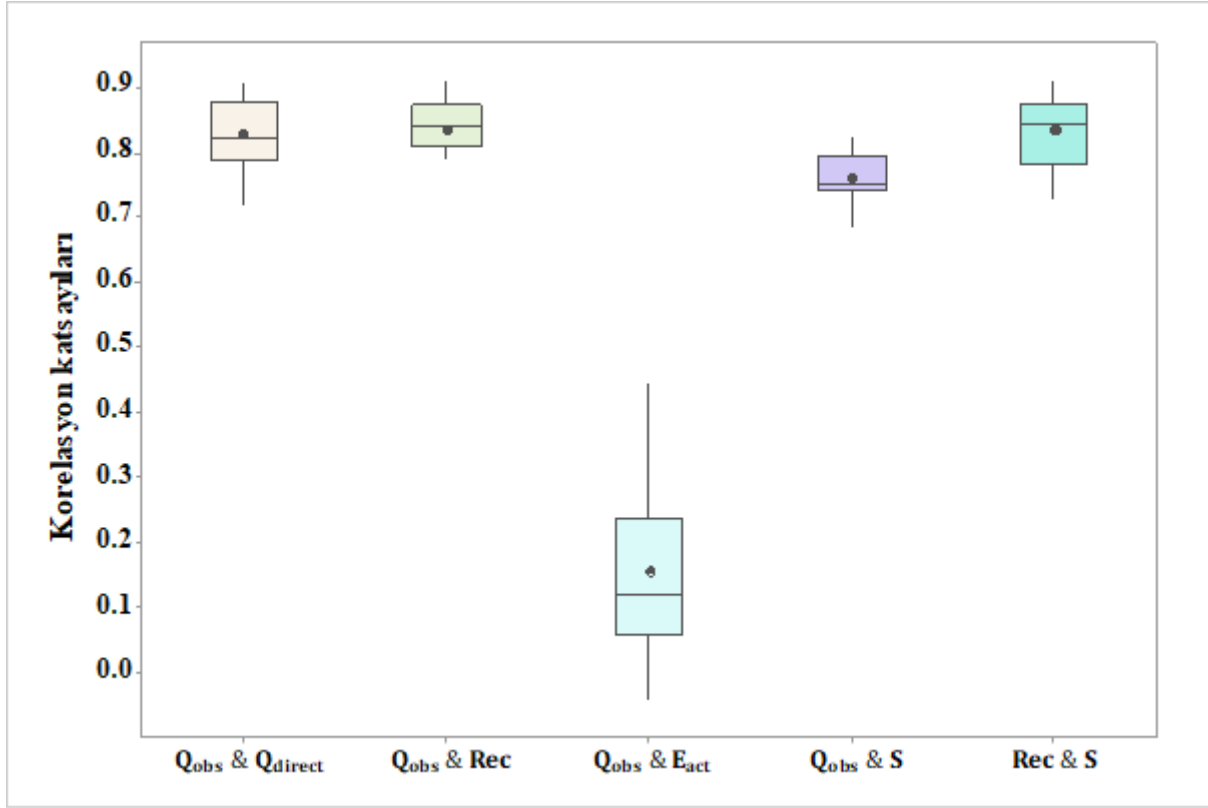


**Şekil 4.1:** (a) *dynwbm* parametrelerinin kombinasyonları için zincir diyagramı gösterimi ( $S_{max}$  mm cinsinden verilmiştir.), (b) ana kaynaklar ve toplam etkileşim için varyans fraksiyonları ve (c)  $d$  parametresi ile ilgili birinci mertebeden etkileşimlerin varyans fraksiyonları.

#### 4.2 Seri Hibrit Modellerin Kurulması

Bölüm 4.1’de belirtilen tüm bulgular, taban akış bileşeninin mevcut modelde açıklayıcı olmadığını ve ilgili sürecin geliştirilmesi gerektiğini göstermektedir. Bu amaçla öncelikle Gan ve Luo (2013) tarafından önerilen lineer olmayan akifer depolaması-debi ilişkisi dikkate alınarak lineer taban akış formu iki parametrelili bir üssel fonksiyona dönüştürülmüştür. Ancak bu değişiklik validasyon süresi boyunca yeterli sonuç vermemiştir (bkz. Ersoy vd., 2021). Bu


nedenle Bölüm 2.4'te belirtildiği gibi, *dynwbm*'nin yeraltı suyu depolama elemanının yerini alabilecek ANN/SVR gibi makine öğrenmesi hibridizasyonunun daha makul simülasyonlar verip vermediği sorgulanmıştır. Modelin nasıl hibritleştirileceği hakkında fikir sahibi olmak için kalibre edilmiş *dynwbm*'nin simüle edilmiş çıktılarına bazı istatistiksel analizler uygulanmıştır. Örneğin, kavramsal modelin içsel değişkenleri ile gözlemlenen akışlar arasında hesaplanan korelasyon katsayıları ( $R$ ) Şekil 4.2'de türetilmiştir.



**Şekil 4.2:** Tüm istasyonlar için elde edilen korelasyon katsayıları ile oluşturulan kutu grafiği (Kutuların ortasındaki çizgiler ve daireler sırasıyla medyan ve ortalama değeri temsil etmektedir. Kutunun kenarları ise 25. ve 75. yüzdeleri göstermektedir).

Tüm istasyonlar için elde edilen  $R$  istatistiklerine ait kutu grafiklerine göre  $Rec$  ve  $Q_{direct}$ , sırasıyla  $Q_{obs}$  ile en yüksek korelasyonu sunmaktadır. Zemin nemi içeriği ( $S$ ),  $Q_{obs}$  ile en yüksek korelasyon sağlayan başka bir değişken olsa da  $Rec$  ile oldukça ilişkili olduğu için bu kavramsal çıktının hibrit şema içindeki ML kısmına yönlendirilmesi gereksiz bulunmuştur. Bu göstergeler ışığında, ilk seri yaklaşımda, ML bölümü yalnızca üç parametre ile yönetilen kavramsal bölümün  $Rec$  ve  $Q_{direct}$  çıktıları ile çalıştırılmıştır. Bu şemada sırasıyla ML teknikleri olarak ANN ve SVR kullanılmış ve bu seri hibrit modeller de sırasıyla  $dynNN1$  ve  $dynSVR1$  olarak atfedilmiştir.


Diğer seri hibritleme yönteminde, kavramsal modelin sadece  $Q_{direct}$  ve Rec çıktıları değil, aynı zamanda S ve  $E_{act}$  çıktıları da ML kısmı içinde yardımcı değişken olarak değerlendirilmiştir. Bununla birlikte Şekil 4.2’de gösterilen denemeler, gözlenmiş akımlar ile bazı kavramsal çıktılar arasında güçlü korelasyonların mevcut olduğu kanıtlamaktadır. Ancak tüm olası değişkenlerin kullanımı sonrası doğabilecek çoklu lineerlik ML bölümünün zayıf genelleme performansına da neden olabilecektir. Diğer yandan, ML operatöründeki giriş katmanına gereğinden fazla girdi yönlendirilmesi de kalibrasyon işlemini zorlaştırmaktadır. Bu aşamada ilişkili kavramsal çıktıları aşırı lineerlikten arındıran ve aşırı bilgi kaybetmeden bunların boyutluluğunu azaltabilen bir veri ön işleme tekniğine ihtiyaç duyulmuştur. Tez çalışması kapsamında ve Okkan vd. (2021) çalışmasında, Şekil 2.3’te belirtilen dört adet kavramsal çıktının ML kısmına yönlendirilmeden önce PCA’ya tabi tutulması uygun bulunmuştur. dynNN2 ve dynSVR2 olarak adlandırılan bu modellerde, Şekil 4.3’te görüldüğü üzere, ilk iki PC her durum için varyansın büyük kısmını açıklamış ve ML bölümünün giriş katmanına yönlendirilen değişken sayısı iki olarak belirlenmiştir.



**Şekil 4.3:** İlk iki PC için varyansın açıklanabilme mertebeleri

### 4.3 Modellerin Karşılaştırılması

Çalışmada kalibrasyon periyodu bulguları hibrit modellerde parametre sayısındaki artışın simülasyon hassasiyetine de yansıdığını göstermiştir. Bu nedenle tüm aday modellerin göreceli performanslarının sadece validasyon periyodu simülasyonları açısından takdim edilmesinin daha tutarlı olacağı düşünülmüştür. Bu nedenle eğitim dönemi performansları tez çalışmasına eklenmemiştir. 1981-1995 su yılı verileri ile eğitilen modellerin 1996-2010 validasyon dönemi performansları Tablo 4.1'de sunulmaktadır. Tablo 4.1b'de belirtilen NS indisleri Moriasi vd. (2007) tarafından önerilen performans derecelendirmesi açısından irdelenmiş ve her bir model özelinde ilgili kategoriye (Çok iyi, İyi, Yeterli, Yetersiz) giren istasyon adedi Şekil 4.4'te de özetlenmiştir.



(Çok iyi:  $0.75 < NS \leq 1$ ; İyi:  $0.65 < NS \leq 0.75$ ; Yeterli:  $0.50 < NS \leq 0.65$ ; Yetersiz:  $NS \leq 0.50$ )

**Şekil 4.4:** Tüm akım koşullarında NS performansına ilişkin derecelendirmelerin modellere göre değişimi.

**Tablo 4.1:** Validasyon dönemi için her bir akım gözlem istasyonunda model performanslarının karşılaştırması:

a) RMSE istatistikleri (mm biriminde) b) NS indisleri (1996-2010 su dönemindeki 180 adet veri noktası ile hesaplama yapılmıştır).

a)

İstasyonlar	<i>dynwbm</i>	<i>ANN1</i>	<i>SVR1</i>	<i>ANN2</i>	<i>SVR2</i>	<i>ECANN</i>	<i>ECSVR</i>	<i>CMANN</i>	<i>CMSVR</i>	<i>dynNN1</i>	<i>dynSVR1</i>	<i>dynNN2</i>	<i>dynSVR2</i>
Muradiye	4.64	6.20	6.28	4.59	4.53	4.31	4.04	3.27	3.37	3.07	2.70	2.80	<b>2.64</b>
Hacıhıdır	8.34	14.42	14.89	9.34	9.69	8.04	8.05	9.21	8.53	<b>7.03</b>	7.35	7.14	7.21
Taytan	3.40	5.38	5.37	3.95	3.95	3.42	3.35	3.37	3.14	3.03	<b>2.91</b>	3.07	2.94
Hacıhaliller	8.19	8.95	9.24	6.26	6.50	7.61	7.62	6.90	7.08	5.34	4.95	5.06	<b>4.63</b>
Kayalıoğlu	7.43	8.84	9.17	5.89	6.99	6.63	6.43	6.39	6.53	4.93	4.82	4.74	<b>4.59</b>
Dereköy	5.82	7.63	7.46	6.20	5.73	5.79	5.44	5.21	5.26	4.18	<b>3.56</b>	4.88	3.93
Topuzdamları	7.71	12.49	12.37	10.74	10.43	7.28	6.61	7.19	6.59	7.04	<b>5.90</b>	7.41	6.09
Borlu	6.24	10.56	10.68	6.99	7.54	6.23	5.91	6.72	6.97	5.11	4.69	4.80	<b>4.37</b>
Acısu	4.83	6.31	6.31	4.71	4.75	4.07	3.98	3.68	3.56	3.50	3.35	3.42	<b>3.31</b>

b)

İstasyonlar	<i>dynwbm</i>	<i>ANN1</i>	<i>SVR1</i>	<i>ANN2</i>	<i>SVR2</i>	<i>ECANN</i>	<i>ECSVR</i>	<i>CMANN</i>	<i>CMSVR</i>	<i>dynNN1</i>	<i>dynSVR1</i>	<i>dynNN2</i>	<i>dynSVR2</i>
Muradiye	0.735	0.526	0.514	0.740	0.748	0.771	0.799	0.868	0.860	0.884	0.910	0.903	<b>0.914</b>
Hacıhıdır	0.837	0.513	0.481	0.796	0.780	0.849	0.848	0.801	0.830	<b>0.884</b>	0.874	0.881	0.878
Taytan	0.798	0.493	0.494	0.726	0.727	0.794	0.803	0.801	0.827	0.839	<b>0.852</b>	0.835	0.849
Hacıhaliller	0.666	0.601	0.575	0.805	0.789	0.712	0.710	0.762	0.750	0.858	0.878	0.872	<b>0.893</b>
Kayalıoğlu	0.654	0.509	0.472	0.782	0.693	0.724	0.740	0.743	0.732	0.847	0.858	0.859	<b>0.868</b>
Dereköy	0.708	0.498	0.521	0.669	0.717	0.711	0.745	0.766	0.762	0.849	<b>0.891</b>	0.795	0.867
Topuzdamları	0.808	0.497	0.506	0.628	0.649	0.829	0.859	0.833	0.860	0.840	<b>0.888</b>	0.823	0.880
Borlu	0.855	0.586	0.576	0.819	0.789	0.856	0.870	0.832	0.820	0.903	0.918	0.914	<b>0.929</b>
Acısu	0.688	0.467	0.468	0.703	0.698	0.778	0.788	0.819	0.830	0.836	0.850	0.844	<b>0.854</b>

Değerlendirilen performans indisleri açısından ilk üç model dolgu ile gösterilirken, en iyi model kalın yazı karakteri ile belirtilmiştir.


Şekil 4.4'ten *dynwbm*'nin NS değerleri bakımından dört istasyonda “çok iyi” simülasyon sağladığı, fakat kalan beş istasyonda sadece “iyi” kategorisine giren sonuçlar ürettiği açıkça anlaşılmaktadır. Diğer yandan, iki girdili ANN ve SVR modellerinin (ANN1/SVR1) NS performansları incelendiğinde, “iyi” ve “çok iyi” derecelendirmelerinden herhangi birine sahip hiçbir istasyonun bulunmadığı ve beş istasyonun “yeterli”, geri kalanların ise “yetersiz” olarak derecelendirildiği tespit edilmiştir. Buna ilaveten, bir önceki yağış girdisinin de eklendiği üç girdili ANN ve SVR modelleri (ANN2/SVR2), iki girdili ML varyantlarına göre çok daha iyi sonuçlar vermiştir. SVR2'den biraz daha iyi olan ANN2'de sekiz istasyonun “çok iyi” veya “iyi” dereceli, bir istasyonun ise “yeterli” derecesinde olduğu görülebilmektedir. Paralel hibrit yapıdaki model varyantları incelendiğinde ise tüm istasyonlardan derlenen performansların “iyi” veya “çok iyi” olarak derecelendirildiği görülmüştür. Özellikle *dynwbm*'de “iyi” derecelendirilmiş performansa sahip iki istasyon ECANN ve ECSVR modellerinde “çok iyi” kategorisine geçmiştir. Ayrıca bu yanlılık düzeltme türlerine göre nispeten tercih edilebilir performanslar veren CMANN ve CMSVR paralel hibrit modelleri birkaç istasyon dışında “çok iyi” olarak sınıflandırılmıştır. Öte yandan, literatürde ilk defa önerilen seri hibrit modellerin her birinin tüm istasyonlarda “çok iyi” kategoride performans sergilediği Şekil 4.4'te bariz bir şekilde görülmektedir.

Gözlenen ve modellenen akış arasındaki hatanın bir ölçüsü olan RMSE istatistikleri de Tablo 4.1a'da görüldüğü gibi her bir istasyon ve model için hesaplanmıştır. Bu istatistiğe ilişkin istasyon bazlı değişkenliklere rağmen, havza genelinde ortalamalar açısından yorumlandığında, seri hibrit modeller *dynwbm*'ye kıyasla RMSE'de %24 ve %30 aralığında azalmalar öngörmektedir. Aynı değerlendirme paralel modellerle (ECANN hariç) yapıldığında, bu azalma miktarı %10 mertebelerindedir. Paralel ve seri hibrit modellerden elde edilen tespitlerden farklı olarak tekil ANN2 ve SVR2 modellerinin kavramsal modelin performansını yansıtabilecek düzeyde olmadığı söylenebilmektedir (ANN1 ve SVR1 modelleri ise tekil modeller içerisinde en kötü RMSE performansı veren modeller olarak nitelendirilebilir).

Çalışmada Tablo 4.1b'deki NS indisleri kullanılarak  $r^2$  istatistikleri hesaplanmış ve *dynwbm*'ye alternatif olarak uygulanan modellerin *dynwbm*'den ne düzeyde farklılık sergilediği Şekil 4.5.'te irdelenmiştir. Şekilde yeşil renk skalası ile verilen değerler hibridizasyonun kayda değer bir gelişme sağladığını (%10'dan büyük değerler) göstermektedir. Buna göre, *dynwbm* ile elde edilen NS performanslarına dayanarak




ANN2/SVR2'nin önemli bir gelişme sağlamadığı ve ilgili indisleri daha iyi bir kategoriye taşıma potansiyeline sahip olmadığı görülmektedir. Buna ek olarak, Topuzdamları istasyonunda dynNN2 tarafından elde edilen %10'un altındaki önemsiz  $r^2$  değeri hariç tutulduğunda, seri hibrit modellerin tüm istasyonlarda  $r^2$  açısından önemli ölçüde iyileşme eğiliminde olduğu açıkça görülmektedir. Paralel hibrit modellerin tamamına yakını ise Hacılıdır, Taytan, Dereköy ve Borlu istasyonlarında anlamlı bir iyileşme göstermemiştir. CMSVR'nin ise birçok istasyon için diğer paralel hibridizasyon varyantları arasında biraz daha öne çıktığı söylenebilmektedir. Ancak Hacılıdır ve Borlu istasyonları için gözlenen  $r^2$ 'nin negatif değerleri bu paralel hibritlemenin validasyon döneminde tutarsız çıktılar üretebileceğini göstermektedir. Bu bağlamda, ECSVR herhangi bir istasyonda negatif  $r^2$  sunmamış ve aynı zamanda türdeşi olan ECANN'ye kıyasla Dereköy ve Borlu istasyonlarında önemli iyileşme sergilemiştir. Tüm hibridizasyon çalışmaları havza bütününde değerlendirildiğinde ise en dikkat çekici iyileştirmeleri sağlayan modellerin sırasıyla 5 parametrelili dynSVR2 ve dynSVR1 seri hibrit modelleri olduğu bariz bir şekilde görülebilmektedir.




Şekil 4.5:  $r^2$  istatistiklerinin model ve AGİ özelinde yorumlanması (Okkan vd., 2021).

Modellerin havza üzerindeki genel NS dağılımları açısından (tüm validasyon serisini içine alacak şekilde 180 adet veri noktasıyla hesaplanan) nasıl performans gösterdiğini görsel olarak özetlemek için Tablo 4.1b'deki indisler kutu grafiği ile yorumlanmıştır (Şekil 4.6). Şekil 4.6'ya göre, seri hibrit modellerden ve iki paralel hibrit modelden (CMANN ve CMSVR) elde edilen performanslara ilişkin kartiller arası mesafenin (IQR) bütünüyle “çok iyi” modelin alt sınırı olan 0.75 değerinin üzerinde yer aldığı görülebilmektedir. Öte yandan, dynSVR1 ve dynSVR2 modellerinden türetilen çizimler oldukça özdeş durmakta ve bu modeller daha dar IQR sergilemektedir. Bu gösterge anılan modellerin istasyonlar arası NS değişkenliklerinin göreceli olarak düşük olduğunu da kanıtlamaktadır. Diğer seri hibrit modeller, tüm tekil varyasyonlar ve tüm paralel hibrit modeller ile karşılaştırıldığında, dynSVR1 ve dynSVR2 modellerinin çalıştırılması havza üzerinde medyan ve üst kartil bakımından daha başarılı sonuçlar üretilmesini sağlamıştır. dynNN2 ile ilişkili ikinci ve üçüncü kartillerdeki göstergeler dynNN1'e kıyasla üstünlük sergilese de dynNN1 özellikle dağılımın alt kartilinde biraz daha güvenilir durmaktadır. Ayrıca Şekil 4.6'dan *dynwbm* ve ECANN, ECSVR ve CMSVR varyasyonlarını kapsayan paralel hibrit modellerin, dynSVR2 ve dynSVR1'den yaklaşık 3-4 kat daha geniş kartiller arası mesafe öngördüğü açıkça anlaşılmaktadır. Bu IQR'lerin ilgili performans dağılımlarının %50'sini temsil ettiği düşünüldüğünde, bu varyantların havza genelinde üniform davranamayabileceği görülmüş ve bu nedenle dynSVR1 ve dynSVR2 seri hibrit modelleri kadar simülasyon güvenilirliği verebilecek bir modelin mevcut olmadığı kanaatine varılmıştır.

Havzanın tarımla işletilen rezervuarları besleyen kollar üzerinde bulunan bazı istasyonlarda (Dereköy, Topuzdamları, Borlu, Acısu ve Taytan) ve İzmir içme suyu sistemine su sağlayan Gördes Baraj Havzası'nı temsil eden Hacıhıdır istasyonunda yüksek akış simülasyonu bilhassa önem taşımaktadır. Bu nedenle, RMSE ve NS indisleri gözlenen akımların üçüncü kartil ve üzerindeki değerlerine karşılık gelen simülasyonlar ile yeniden hesaplanmış ve Tablo 4.2'de sunulmuştur. Bu değerlendirme tüm istasyonlarda aynı 45 veri noktası için yapılmıştır. Bu tablo yorumlandığında, seri hibrit modellerin yine en doğru sonuçları verme eğiliminde olduğu ortaya çıkmaktadır. Tablo 4.1 ve 4.2'deki ilk üç model sıralaması çoğunlukla aynı olmakla birlikte, istasyonların çoğunda dynSVR1 ve dynSVR2 bu ekstrem noktalarda bile “iyi” veya “çok iyi” kategorisine girebilecek sonuçlar üretmiştir.




Şekil 4.6: Modellerin validasyon dönemi NS performanslarının tüm akım koşulları için havza genelinde kıyaslanması.



Şekil 4.7: Modellerin validasyon dönemi NS performanslarının yüksek akım koşulları için havza genelinde kıyaslanması.

Ayrıca yukarıda atfedilen ekstrem noktalarda, *dynwbm*, ANN2 ve SVR2 modellerinin birkaç istisna dışında “iyi” veya “çok iyi” kategorisinde sonuç üretemediği gözlemlenmiştir (Şekil 4.8).




**Şekil 4.8:** Yüksek akım koşullarında NS performansına ilişkin derecelendirmelerin modellere göre değişimi.

Özellikle, *dynwbm*'nin ekstrapolasyon yeteneği iyi olmamakla birlikte, bu modelin CMANN ile hibritlenmesi de yüksek akış simülasyonunda anlamlı katkı sağlayamamıştır. Öte yandan, Muradiye, Hacıhıdır ve Topuzdamları istasyonlarında diğer paralel hibrit yöntemler (ECSVR, CMSVR ve ECANN) gözlemlenen yüksek akımları *dynwbm*'ye kıyasla daha iyi benzeştirmişlerdir. Bununla birlikte, paralel tipteki tüm hibrit modeller, tüm zaman serisinde de en iyi sonucu veren *dynSVR1* ve *dynSVR2* modellerinin aksine Hacıhaliller, Kayalıoğlu ve Dereköy istasyonlarında pik akımlarda herhangi bir performans iyileştirmesi göstermemiştir. Ayrıca modellerin validasyon dönemi NS performanslarının yüksek akım koşulları için havza genelinde kıyaslanması Şekil 4.7'de kutu grafikler ile gösterilmiştir. Şekil 4.6'da gösterilen ve tüm akım koşulları için çizdirilen kutu grafikleri ile Şekil 4.7 karşılaştırıldığında, yüksek akış performansları açısından havza genelinde bazı dağılım bazlı değişikliklerin (kartillerdeki değişkenlikler) olduğu açıktır. Örneğin, burada paralel hibrit modeller havza genelinde tüm akımlar ile hesaplanan NS performanslarına

kıyasla 0.25-0.30 daha düşük medyan değerlerini işaret etmektedir. Söz konusu medyadaki azalış eğilimi, seri hibrit modellerde 0.17 mertebesinde olup, bu modeller aracılığıyla pik akım koşullarında belirlenen IQR'lerdeki değişimin aynı koşullarda diğer modellere nazaran daha az olduğu tespit edilmiştir.

Çalışmanın son aşamasında, modelleri performansları bakımından sınıflandırabilmek ve benzeşim mertebelerini tespit edebilmek için Şekil 4.9'da gösterildiği üzere hiyerarşik bir kümeleme işlemi yapılmıştır. Şekil 4.9'da gösterilen ağaç şemasında farklı denemeler neticesinde üç adet kümenin kullanılmasında karar kılınmış ve burada her bir dalın model benzerlik yüzdelere bağlı olarak otomatik gruplanması sağlanmıştır. Bu aşamada MINITAB paket yazılımından yararlanılmıştır. Bulgulara göre, üçüncü küme (şeklin sağ tarafı), üç girdili ML modelleri, *dynwbm* ve paralel hibrit modeller de dahil olmak üzere yedi modelden oluşmaktadır. Paralel hibritleme *dynwbm* üzerinde bazı iyileştirmeler göstermiş olduğu için *dynwbm* üçüncü kümede ayrı bir dal olarak gözükmektedir. Öte yandan, ikinci küme tüm seri hibrit modellerini kapsamaktadır. Bu kümede, tercih edilen ML tekniğine bağlı olarak iki alt grup ortaya çıkmıştır. İki girdili ML modellerini içeren ilk kümenin ise hiyerarşik şema bütünü içerisinde en ayırık duran küme olduğu görülebilmektedir.



**Şekil 4.9:** NS performanslarına göre modellerin sınıflandırılması.

**Tablo 4.2.** Validasyon dönemi pik akımları için her bir akım gözlem istasyonunda model performanslarının karşılaştırması:

a) RMSE istatistikleri (mm birimde) b) NS indisleri (1996-2010 su dönemindeki 45 adet veri noktası ile hesaplama yapılmıştır).

a)

İstasyonlar	<i>dynwbm</i>	<i>ANN1</i>	<i>SVR1</i>	<i>ANN2</i>	<i>SVR2</i>	<i>ECANN</i>	<i>ECSVR</i>	<i>CMANN</i>	<i>CMSVR</i>	<i>dynNN1</i>	<i>dynSVR1</i>	<i>dynNN2</i>	<i>dynSVR2</i>
Muradiye	7.02	8.71	9.23	7.59	6.93	6.55	5.79	5.24	5.45	4.86	<b>3.61</b>	4.43	3.65
Hacıhıdır	15.67	25.5	27.04	16.29	16.56	14.71	14.79	17.3	15.06	<b>13.1</b>	13.85	13.28	13.62
Taytan	5.06	8.34	8.4	6.56	6.12	5.18	5.06	5.57	4.99	4.98	4.67	5.3	<b>4.61</b>
Hacıhaliller	14.08	14.47	15.69	10.45	11.46	13.14	13.27	12.69	12.95	9.75	9.22	9.08	<b>8.54</b>
Kayalıoğlu	14.25	14.69	15.92	9.8	12.37	12.18	12.07	12.32	12.59	9.23	8.85	8.86	<b>8.39</b>
Dereköy	10.41	11.73	10.58	10.84	8.83	10.4	9.39	8.98	8.1	7.23	<b>5.61</b>	8.84	6.27
Topuzdamları	13.16	21.03	20.35	18.87	17.01	12.67	11	13.4	11.83	12.84	<b>10.01</b>	13.12	10.23
Borlu	11.56	16.77	18.11	11.93	12.92	11.49	10.82	12.86	13.52	9.48	8.7	8.88	<b>7.85</b>
Acısu	7.96	9.2	9.42	7.43	6.73	6.61	5.87	6.14	6.12	5.85	4.88	5.61	<b>5.08</b>

b)


İstasyonlar	<i>dynwbm</i>	<i>ANN1</i>	<i>SVR1</i>	<i>ANN2</i>	<i>SVR2</i>	<i>ECANN</i>	<i>ECSVR</i>	<i>CMANN</i>	<i>CMSVR</i>	<i>dynNN1</i>	<i>dynSVR1</i>	<i>dynNN2</i>	<i>dynSVR2</i>
Muradiye	0.549	0.304	0.219	0.472	0.56	0.606	0.693	0.748	0.727	0.784	<b>0.88</b>	0.82	0.878
Hacıhıdır	0.628	0.014	-0.109	0.597	0.584	0.672	0.668	0.546	0.656	<b>0.74</b>	0.709	0.733	0.719
Taytan	0.573	-0.163	-0.18	0.28	0.374	0.551	0.571	0.482	0.583	0.585	0.635	0.53	<b>0.644</b>
Hacıhaliller	0.325	0.286	0.161	0.628	0.552	0.412	0.4	0.451	0.429	0.676	0.71	0.719	<b>0.751</b>
Kayalıoğlu	0.17	0.118	-0.036	0.608	0.375	0.393	0.405	0.38	0.353	0.652	0.68	0.68	<b>0.713</b>
Dereköy	0.14	-0.091	0.113	0.069	0.382	0.142	0.3	0.361	0.48	0.586	<b>0.75</b>	0.38	0.688
Topuzdamları	0.649	0.104	0.161	0.279	0.414	0.675	0.755	0.636	0.717	0.666	<b>0.797</b>	0.651	0.788
Borlu	0.674	0.315	0.201	0.653	0.593	0.678	0.715	0.597	0.554	0.781	0.815	0.808	<b>0.85</b>
Acısu	0.168	-0.111	-0.165	0.275	0.406	0.427	0.547	0.506	0.509	0.551	0.687	0.587	<b>0.661</b>

Değerlendirilen performans indisleri açısından ilk üç model dolu ile gösterilirken, en iyi model kalın yazı karakteri ile belirtilmiştir.

Elde edilen bu bulgulara ek olarak Demirköprü baraj haznesini besleyen kollarda bulunan dört AGİ için *dynwbm* ve seri hibrit modellerin gidişler ve saçılım grafikleri de örnek olarak Şekil 4.10- Şekil 4.13 aralığında takdim edilmiştir.



Sonuç itibariyle, örnek bir havza üzerinde yağış-akış modelleme çalışmalarında ne tür bir hibridizasyondan yararlanılacağına dair pek çok gösterge niteliğinde bulgu elde edilmiştir. Güncel literatürde benzer versiyonları değerlendirilen paralel hibrit modellerden elde edilen simülasyonların, tez çalışmasında önerilen seri modellerden üretilenler ile eşleşip eşleşmediği derinlemesine incelenmiştir. Elde edilen bulgulardan ne paralel hibridizasyon denemelerinin (çalışmadaki CMANN, CMSVR, ECANN ve ECSVR varyantları) ne de diğer tekil modellerin seri hibrit modellerin yerini alamayacağı doğrulanmıştır.





**Şekil 4.10:** Acısu alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri.



Acısu - dynNN1



42

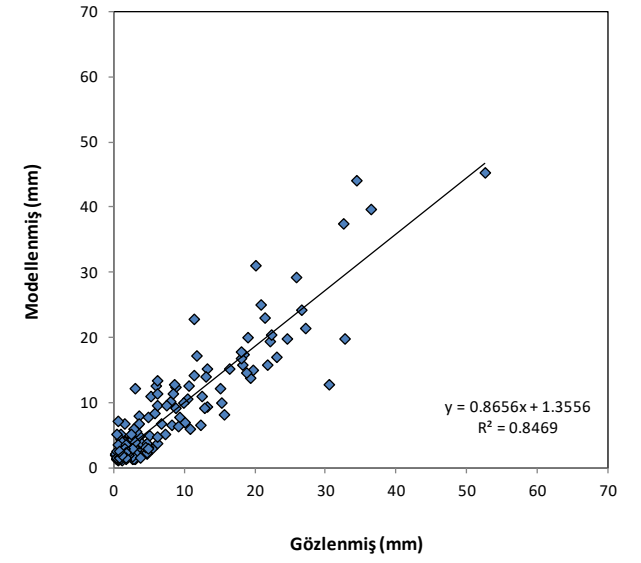

Şekil 4.10 devam

Acısu - dynSVR1


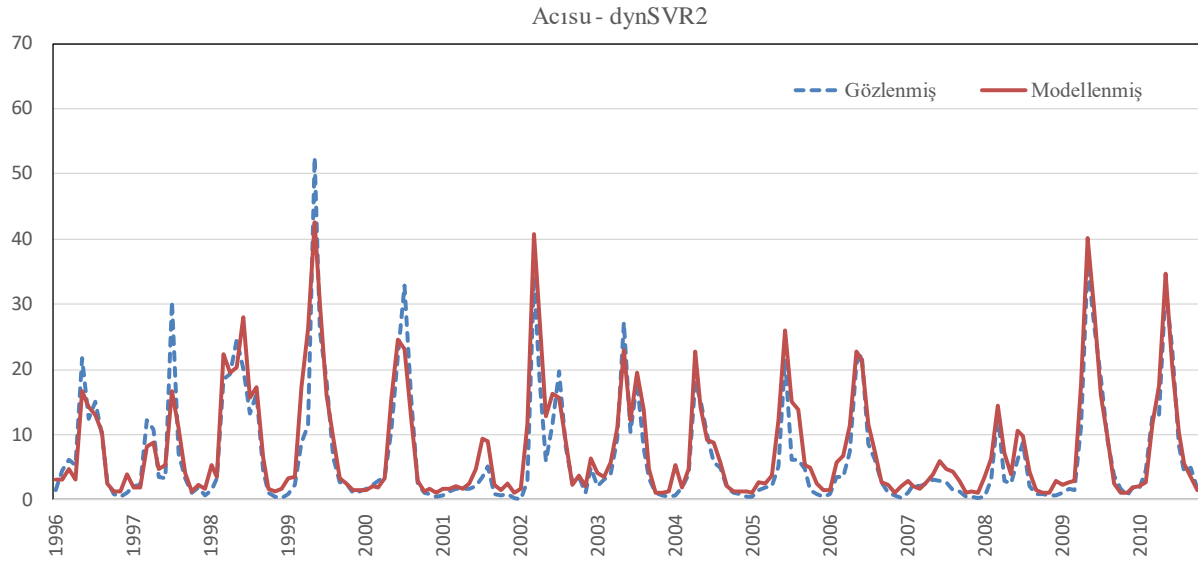


Şekil 4.10 devam


Acısu - dynNN2





Şekil 4.10 devam



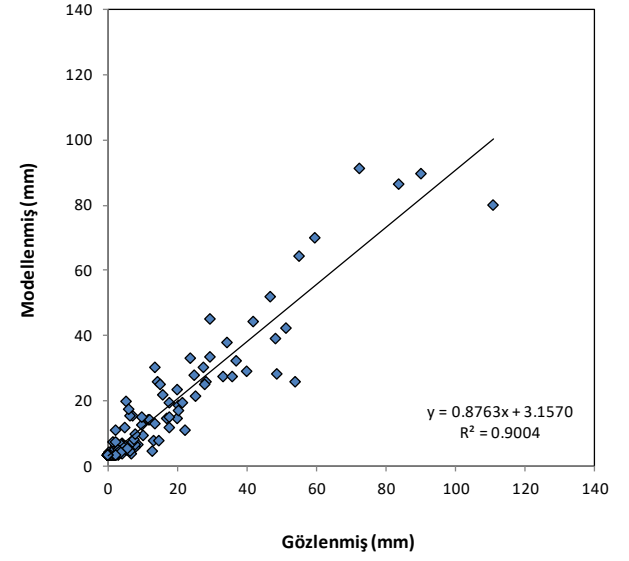
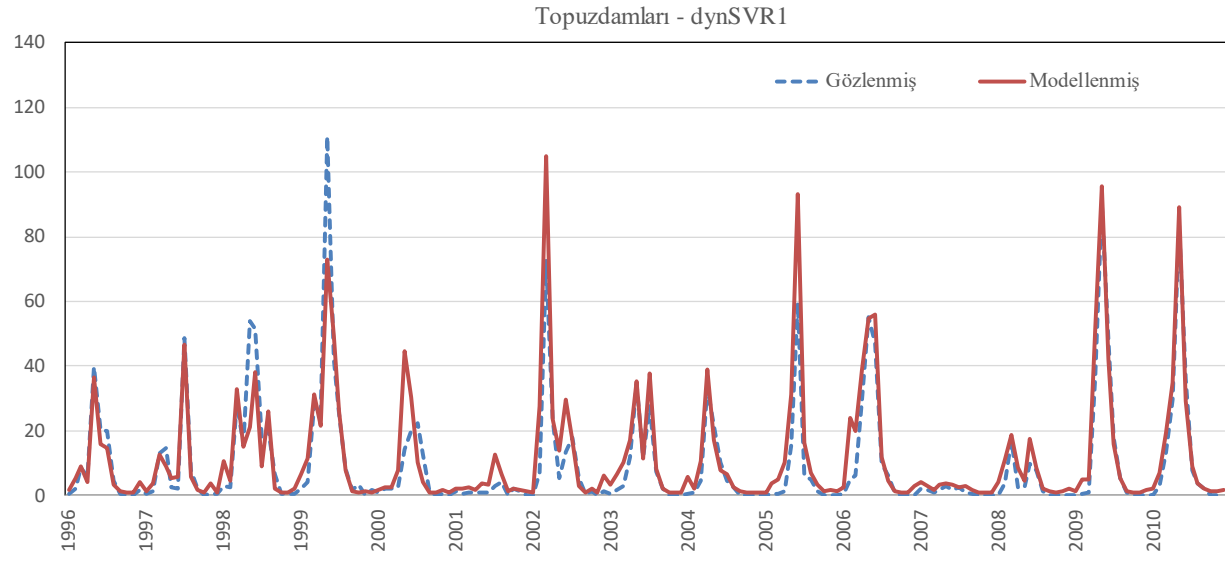
Şekil 4.10 devam



**Şekil 4.11:** Topuzdamları alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri.

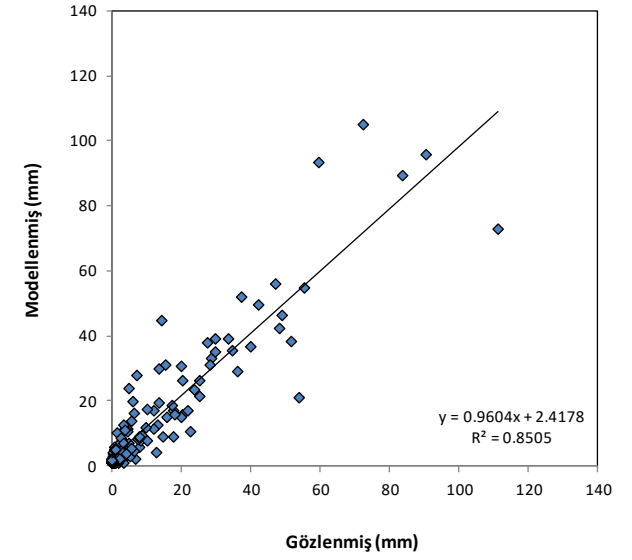



Şekil 4.11 devam





Şekil 4.11 devam








Şekil 4.11 devam




Şekil 4.11 devam




**Şekil 4.12:** Borlu alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri.





Şekil 4.12 devam




Şekil 4.12 devam



Şekil 4.12 devam





Şekil 4.12 devam



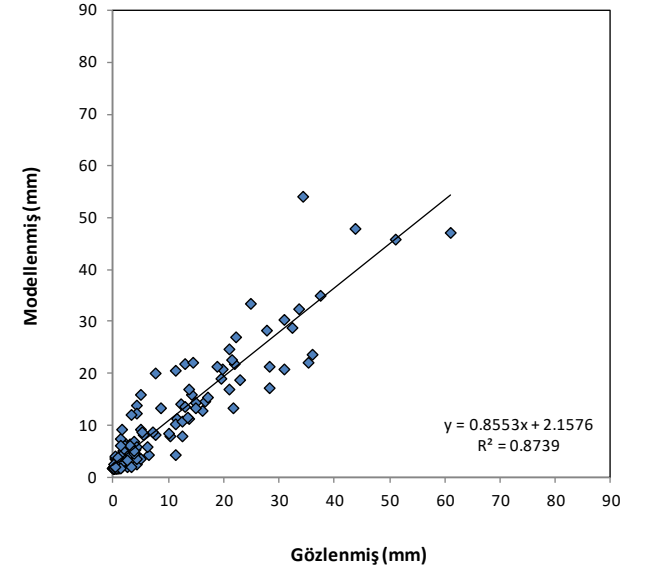

**Şekil 4.13:** Dereköy alt havzası için dynwbm, dynNN1, dynSVR1, dynNN2 ve dynSVR2 modellerinden üretilen akımlara ait gidiş ve saçılım grafikleri.







Şekil 4.13 devam

Dereköy - dynSVR1





Şekil 4.13 devam



Şekil 4.13 devam

Dereköy - dynSVR2



Şekil 4.13 devam

## 5. SONUÇLAR

Hem literatürde hem de tez çalışmasında ortaya konulduğu üzere kavramsal yağış-akış modelleri fiziksel süreci ve havza dinamiğini çeşitli parametreler vasıtasıyla benzeştirip makine öğrenmesi tabanlı modellere kıyasla daha güvenilir akım tahminleri üretebilmektedir. Ancak, çalışmadan tespit edilen bulgulardan biri de bu tarz kavramsal modellerden elde edilen akım çıktılarında bazı sistematik yanlışlıkların mevcut olmasıdır. Bu yanlışlıkların ortalananmış parametre bakış açısından veya basitleştirilmiş kavramsallaştırmadan kaynaklanması olası durmaktadır. Literatürdeki belli başlı paralel hibritleme çalışmaları söz konusu çıktılarını sapmalardan arındırmaya odaklanmış ve genel itibari ile hedeflerine ulaşmış olsalar bile (örneğin Anctil vd., 2004; Humphrey vd., 2016), hiçbir çalışma iki farklı model yapısını kontrol eden parametrelerin birlikte optimizasyonunun nasıl bir etki sağlayabileceğini sorgulamamıştır. Bu sorunun cevabını aramak adına gerek sunulan tez çalışmasında gerekse bu çalışmanın iskeletini oluşturan makale çalışmalarında (Ersoy vd., 2021; Okkan vd., 2021), kavramsal yapıda bir modelin lineer ve hassas çalışmayan yeraltı suyu depolama elemanı iptal edilerek ANN/ SVR tekniklerinin seri bir işleyiş içerisinde zemin nemi depolama elemanına ait spesifik çıktılarını akarsu akımlarına dönüştürmesi sağlanmıştır. Herhangi bir benzerine rastlanılmayan bu uygulamalar bütünleşik yapıları bakımından gerçek bir hibritleme niteliği taşımaktadır. Yöntem ve bulgular bölümünde detaylandırıldığı üzere dynNN1, dynNN2, dynSVR1 ve dynSVR2 olmak üzere dört adet seri hibrit yapı önerilmiştir. RMSE ve NS gibi klasik performans ölçütleri ile yapılan sınamalara göre hem tüm akımlar hem de pik akımlar bakımından dynSVR2 ve dynSVR1 modellerinin birçok modele nazaran daha üstün sonuç sunduğu tespit edilmiştir. Tez çalışmasında önerilen yaklaşıma ilişkin tespitler ve tartışma dahiline alınabilecek bazı hususlar aşağıda listelenmiştir.

- 1) Yağış-akış modellemesi aşamasında uygun bir bireysel modeli (salt kavramsal model veya salt yapay zekâ modeli) arama yoluna gitmek veya bunların çıktılarının paralel hibritleme yaklaşımlarıyla güncellenmesini sağlamak model kullanıcılarını karar verme sürecinde zorlayabilmektedir. Bu bağlamda, önerilen seri (iç içe) şema ile işletilen modellerin hem yüksek simülasyon performansı sunmaları hem de standart paralel hibritlemedeki gibi iki ardışık kalibrasyon sürecine ihtiyaç duymamaları teşvik edici unsurlar olarak değerlendirilmiştir.

- 2) Önerilen seri hibrit modellerin herhangi bir gecikmeli yağış ve akış girdisine ihtiyaç duymamaları (içsel bağımlı yapıda olmamaları) bunları iklim değişikliği senaryoları altında hazne işletme çalışmaları ve hidrolojik projeksiyon hazırlanması gibi uygulamalarda da güvenle kullanılabilir kılmaktadır.
- 3) Paralel tarzda hibritlemeden farklı olarak seri hibritlemede kavramsal modelin genel yapısının korunması da önemli bir detaydır. Örneğin çalışmada *dynwbm* modelinin yeraltı suyu depolama elemanları dışındaki birçok kavramsal çıktısı aynı iterasyon adımıyla yaptırılan iç içe otomatik kalibrasyonun sonucu olarak değişken parametre varyasyonlarına tepki verebilmektedir. Böylelikle kalibrasyon ve doğrulama sonrasında modelin ürettiği zemin nemi içeriği ve gerçek evapotranspirasyon gibi çıktılar (akım bileşenleri hariç) kuraklık analizi vb. uygulamalara girdi niteliği taşıyabilecektir.
- 4) Diğer yandan, önerilen modellerin uygulanabilmesi için kapsamlı bir kodlama ve uzmanlık bilgisine ve kaliteli bir bilgisayar donanımına gereksinim duyulmaktadır. Bu bağlamda da önerilen modeller klasik su bütçesi modellerine kıyasla pratiklikten uzak durmaktadır.
- 5) Seri hibritlemenin ANN ile yapılması kalibre edilebilir çok fazla serbest parametrenin oluşmasına neden olabilmektedir. Özellikle gizli katmandaki hücre sayısının değişkenliği bu durumu tetiklemektedir. Tez çalışmasında ve Okkan vd. (2021) çalışmasında, anılan bu aşırı parametrisasyonun azaltılması adına seri şema içinde ANN yerine iki kontrol parametrelili SVR'nin kullanılması uygun bulunmuştur. Fakat bu varyantta da kavramsal modele SVR entegrasyonunun tüm parametreleri aşırı hassas konuma taşıdığı görülmüştür. Bu nedenle bu tarz modellerin eğitimi aşamasında kullanılacak optimizasyon algoritmasının nitelikli olması ve güvenilir parametre tahminleri elde etmek için seçilen algoritmanın birçok kez koşturulması gerekmektedir.

## 6. KAYNAKLAR

- Anandhi, A., Srinivas, V.V., Nanjundiah, R.S., and Nagesh Kumar, D., (2008). Downscaling precipitation to river basin in India for IPCC SRES scenarios using support vector machine, *International Journal of Climatology*, 28(3), 401-420.
- Ancil, F., Michel, C., Perrin, C., and Andréassian, V., (2004). A soil moisture index as an auxiliary ANN input for stream flow forecasting, *Journal of Hydrology*, 286 (1-4), 155–167.
- Ancil, F., Perrin, C., and Andréassian, V., (2003). ANN output updating of lumped conceptual rainfall/runoff forecasting models, *Journal of the American Water Resources Association*, 39(5), 1269–1279.
- Arsenault, R., Poulin, A., Côté, P., and Brissette, F., (2014). Comparison of stochastic optimization algorithms in hydrological model calibration. *Journal of Hydrologic Engineering*, 19 (7), 1374–1384.
- Behzad, M., Asghari, K., Eazi, M., and Palhang, M., (2009). Generalization performance of support vector machines and neural networks in runoff modeling, *Expert Systems With Applications*, 36(4), 7624-7629.
- Beven, K., (1989). Changing ideas in hydrology – the case of physically-based models, *Journal of Hydrology*, 105(1-2),157-172.
- Budyko, M.I., (1958). The heat balance of the earth's surface. Trs. Nina. A. Stepanova. U.S. Dept. Of Commerce, Washington.
- Chen, J., and Adams, B.J., (2006a). Semidistributed form of the Tank model coupled with artificial neural networks, *Journal of Hydrologic Engineering*, 11(5), 408–417.

- Chen, J., and Adams, B.J., (2006b). Integration of artificial neural networks with conceptual models in rainfall-runoff modeling, *Journal of Hydrology*, 318 (1-4), 232–249.
- Chen, X.Y., Chau, K.W., and Busari, A.O., (2015). A comparative study of population-based optimization algorithms for downstream river flow forecasting by a hybrid neural network model, *Engineering Applications of Artificial Intelligence*, 46, 258–268.
- Chiew, F. H., (2010). Lumped conceptual rainfall-runoff models and simple water balance methods: Overview and applications in ungauged and data limited regions, *Geography Compass*, 4(3), 206-225.
- Daliakopoulos, I.N., and Tsanis, I.K., (2016). Comparison of an artificial neural network and a conceptual rainfall–runoff model in the simulation of ephemeral streamflow, *Hydrological Sciences Journal*, 61(15), 2763–2774.
- De Voogt, K., Kite, G., Droogers, P., and Murray-Rust, H., (2000). Modeling water allocation between a wetland and irrigated agriculture in the Gediz Basin, Turkey, *International Journal of Water Resources Development*, 16(4), 639-650.
- Dibike, Y.B., and Solomatine, D.P., (2001). River flow forecasting using artificial neural networks, *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, 26(1), 1–7.
- Dooge, J.C.I., (1977). Problems and methods of rainfall-runoff modeling. In: Ciriani, T.A., Maione, U., Wallis, J.R. (Eds.), *Mathematical Models for Surface Water Hydrology: the Workshop Held at the IBM Scientific Center, Pisa*. Wiley, London, 71–108



- Ersoy, Z.B., Okkan, U., and Fistikoglu, O. (2021). Hybridizing a Conceptual Hydrological Model with Neural Networks to Enhance Runoff Prediction, *Manchester Journal of Artificial Intelligence and Applied Sciences*, 02, 176-178. [Tezden türetilmiştir]
- Essenfelder, A. H., and Giupponi, C. (2020). A coupled hydrologic-machine learning modelling framework to support hydrologic modelling in river basins under Interbasin Water Transfer regimes, *Environmental Modelling & Software*, 131, 104779.
- Fıstıkoğlu, O., (1999). Hidrolojik modeller. *Türkiye İnşaat Mühendisliği 15. Teknik Kongre ve Sergisi Bildiriler Kitabı* içinde (799-809). Ankara.
- Fıstıkoğlu, O., ve Okkan, U., (2010). Tahtalı havzası için aylık su bütçesi modeli, *VI. Ulusal Hidroloji Kongresi*, Denizli, 546-554.
- Fistikoglu, O., and Okkan, U., (2011). Statistical downscaling of monthly precipitation using NCEP/NCAR reanalysis data for Tahtali River Basin in Turkey, *Journal of Hydrologic Engineering*, 16(2), 157-164.
- Gan, R., and Luo, Y., (2013). Using the nonlinear aquifer storage–discharge relationship to simulate the baseflow of glacier and snowmelt dominated basins in Northwest China, *Hydrology and Earth System Sciences Discussions*, 10(4), 5535–5561.
- Gaume, E., and Gosset, R., (2003). Over-parameterisation, a major obstacle to the use of artificial neural networks in hydrology?, *Hydrology and Earth System Sciences* 7(5), 693–706.
- Ghaith, M., Siam, A., Li, Z., and El-Dakhkhni, W., (2020). Hybrid Hydrological Data-Driven Approach for Daily Streamflow Forecasting. *Journal of Hydrologic Engineering*, 25(2), 04019063.

- Goswami, M., O'Connor, K.M., and Bhattarai, K.P., (2007). Development of regionalisation procedures using a multi-model approach for flow simulation in an ungauged catchment. *Journal of Hydrology*, 333(2-4), 517-531.
- Granata, F., Gargano, R., and De Marinis, G., (2016). Support vector regression for rainfall-runoff modeling in urban drainage: A comparison with the EPA's storm water management model, *Water*, 8(3), 69.
- Hsu, K.L., Gupta, H.V. and Sorooshian, S., (1995). Artificial neural network modeling of the rainfall-runoff process, *Water resources research*, 31(10), 2517-2530.
- Hu, T., Wu, F., and Zhang, X. (2007). Rainfall-runoff modeling using principal component analysis and neural network, *Hydrology Research*, 38(3), 235-248.
- 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.
- Isik, S., Kalin, L., Schoonover, J. E., Srivastava, P., and Lockaby, B. G. (2013). Modeling effects of changing land use/cover on daily streamflow: an artificial neural network and curve number based hybrid approach. *Journal of Hydrology*, 485, 103-112.
- Jeong, D. Il, and Kim, Y.O., (2005). Rainfall-runoff models using artificial neural networks for ensemble streamflow prediction. *Hydrological Processes*, 19(19), 3819–3835.
- Kennedy, J., and Eberhart, R., (1995). Particle swarm optimization, *In Proceedings of ICNN'95-international conference on neural networks*, 4, 1942-1948.

- Kim, Y.O., Jeong, D. Il, and Ko, I.H., (2006). Combining rainfall-runoff model outputs for improving ensemble streamflow prediction, *Journal of Hydrologic Engineering*, 11 (6), 578–588.
- Kumanlioglu, A.A., and Fistikoglu, O., (2019). Performance enhancement of a conceptual hydrological model by integrating artificial intelligence, *Journal of Hydrologic Engineering*, 24 (11), 04019047.
- Li, S., Xiong, L., Li, H.Y., Leung, L.R., and Demissie, Y., (2016). Attributing runoff changes to climate variability and human activities: uncertainty analysis using four monthly water balance models, *Stochastic Environmental Research and Risk Assessment*, 30(1), 251–269.
- Lin, J.Y., Cheng, C.T. and Chau, K.W., (2006). Using support vector machines for long-term discharge prediction, *Hydrological Sciences Journal*, 51(4), 599-612.
- Lohani, A.K., Goel, N.K., and Bhatia, K.K.S., (2011). Comparative study of neural network, fuzzy logic and linear transfer function techniques in daily rainfall-runoff modelling under different input domains, *Hydrological Processes*, 25(2), 175-193.
- Maity, R., Bhagwat, P.P., and Bhatnagar, A., (2010). Potential of support vector regression for prediction of monthly streamflow using endogenous property, *Hydrological Processes*, 24(7), 917-923.
- Meng, C., Zhou, J., Tayyab, M., Zhu, S., and Zhang, H., (2016). Integrating artificial neural networks into the VIC model for rainfall-runoff modeling, *Water*, 8(9), 407.
- Minns, A. W., and Hall, M. J., (1996). Artificial neural networks as rainfall-runoff models. *Hydrological Sciences Journal*, 41(3), 399-417.

- Moriassi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D., and Veith, T.L., (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations, *Transactions of the ASABE*, 50(3), 885-900.
- Mouelhi, S., Michel, C., Perrin, C., and Andréassian, V., (2006). Stepwise development of a two-parameter monthly water balance model, *Journal of Hydrology* 318(1-4), 200–214.
- Nash, J.E., and Sutcliffe, J.V., (1970). River flow forecasting through conceptual models part I- A discussion of principles, *Journal of Hydrology*, 10(3), 282-290.
- Nilsson, P., Uvo, C.B., and Berndtsson, R., (2006). Monthly runoff simulation: Comparing and combining conceptual and neural network models, *Journal of Hydrology*, 321(1-4), 344–363.
- Noori, N., and Kalin, L., (2016). Coupling SWAT and ANN models for enhanced daily streamflow prediction, *Journal of Hydrology*, 533, 141–151.
- Noori, N., Kalin, L., and Isik, S. (2020). Water quality prediction using SWAT-ANN coupled approach, *Journal of Hydrology*, 590, 125220.
- Nourani, V., and Mano, A. (2007). Semi-distributed flood runoff model at the subcontinental scale for southwestern Iran, *Hydrological Processes*, 21(23), 3173-3180.
- Okkan, U., Ersoy, Z.B., Kumanlioglu A.A., and Fistikoglu, 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. [**Tezden türetilmiştir**]

- Okkan, U., and Fistikoglu, O., (2014). Evaluating climate change effects on runoff by statistical downscaling and hydrological model GR2M, *Theoretical and Applied Climatology* 117(1-2), 343–361.
- Okkan, U., and Inan, G., (2015a). Bayesian learning and relevance vector machines approach for downscaling of monthly precipitation, *ASCE Journal of Hydrologic Engineering*, 20(4), 04014051(1-13).
- Okkan, U., and Inan, G., (2015b). 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.
- Okkan, U., and Kirdemir, U. (2020). Towards a hybrid algorithm for the robust calibration of rainfall–runoff models, *Journal of Hydroinformatics*, 22(4), 876-899.
- Okkan, U., and Serbes, Z.A., (2012). Rainfall-runoff modeling using least squares support vector machines, *Environmetrics*, 23(6), 549–564.
- Perrin, C., Michel, C., and Andréassian, V., (2003). Improvement of a parsimonious model for streamflow simulation, *Journal of Hydrology*, 279(1-4), 275–289.
- Qi, W., Zhang, C., Fu, G., and Zhou, H., (2016). Quantifying dynamic sensitivity of optimization algorithm parameters to improve hydrological model calibration, *Journal of Hydrology*, 533, 213-223.
- Qin, Y., Kavetski, D., and Kuczera, G., (2018). A Robust Gauss-Newton Algorithm for the Optimization of Hydrological Models: From Standard Gauss-Newton to Robust Gauss-Newton, *Water Resources Research*, 54(11), 9655–9683.
- Rajurkar, M.P., Kothyari, U.C., and Chaube, U.C., (2002). Artificial neural networks for daily rainfall—runoff modelling, *Hydrological Sciences Journal*, 47(6), 865-877.

- Rajurkar, M.P., Kothyari, U.C., and Chaube, U.C., (2004). Modeling of the daily rainfall-runoff relationship with artificial neural network., *Journal of Hydrology*, 285(1-4), 96-113.
- Ren, W.W., Yang, T., Huang, C.S., Xu, C.Y., and Shao, Q.X., (2018). Improving monthly streamflow prediction in Alpine regions: integrating HBV model with Bayesian neural network, *Stochastic Environmental Research and Risk Assessment*, 32(12), 3381–3396.
- Rencher, A.C. (1998). *Multivariate Statistical Inference and Applications*, 338, Wiley-Interscience, New York.
- 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(1), 579–593.
- Sachindra, D.A., Huang, F., Barton, A., and Perera, B.J.C., (2013). Least square support vector and multi-linear regression for statistically downscaling general circulation model outputs to catchment streamflows, *International Journal of Climatology*, 33(5), 1087-1106.
- Sankarasubramanian, A., and Vogel, R.M., (2002). Comment on the paper:“Basin hydrologic response relations to distributed physiographic descriptors and climate” by Karen Plaut Berger, Dara Entekhabi, 2001, *Journal of Hydrology* 247, 169–182. *Journal of Hydrology*, 263(1-4), 257-261.
- Senbeta, D.A., Shamseldin, A.Y., and O’Connor, K.M., (1999). Modification of the probability-distributed interacting storage capacity model, *Journal of Hydrology*, 224(3-4), 149–168.

- Seyfried, M.S., and Wilcox, B.P., (1995). Scale and the Nature of Spatial Variability: Field Examples Having Implications for Hydrologic Modeling, *Water Resources Research*, 31(1), 173–184.
- Shamseldin, A.Y., and O'Connor, K.M., (2001). A non-linear neural network technique for updating of river flow forecasts, *Hydrology and Earth System Sciences*, 5(4), 577–598.
- 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(1-4), 203–229.
- Singh, V. P., (1995). Computer models of watershed hydrology, *Water Resources Publications*.
- Singh, V.P., and Frevert, D.K. (Eds.), (2002). Mathematical Models of Large Watershed Hydrology, *Water Resources Publications*, LLC, Highlands Ranch, CO, USA, 41.
- Singh, V. P., and Woolhiser, D. A. (2002). Mathematical modeling of watershed hydrology, *Journal of Hydrologic Engineering*, 7(4), 270-292.
- Song, X.M., Kong, F.Z., Zhan, C.S., and Han, J.W., (2012). Hybrid optimization rainfall-runoff simulation based on Xinanjiang model and artificial neural network, *Journal of Hydrologic Engineering*, 17(9), 1033–1041.
- Tayfur, G. (2017). Modern optimization methods in water resources planning, engineering and management, *Water Resources Management*, 31(10), 3205-3233.
- Tekleab, S., Uhlenbrook, S., Mohamed, Y., Savenije, H.H.G., Temesgen, M., and Wenninger, J., (2011). Water balance modeling of Upper Blue Nile catchments using a top-down approach, *Hydrology and Earth System Sciences*, 15(7), 2179–2193.

- Tian, Y., Xu, Y. P., Yang, Z., Wang, G., and Zhu, Q. (2018). Integration of a parsimonious hydrological model with recurrent neural networks for improved streamflow forecasting, *Water*, 10(11), 1655.
- Tigkas, D., Christelis, V., and Tsakiris, G., (2016). Comparative study of evolutionary algorithms for the automatic calibration of the Medbasin-D conceptual hydrological model, *Environmental Processes*, 3(3), 629-644.
- Todini, E., (1988). Rainfall-runoff modeling—Past, present and future, *Journal of hydrology*, 100(1-3), 341-352.
- Tokar, A. S., and Johnson, P. A., (1999). Rainfall-runoff modeling using artificial neural networks, *Journal of Hydrologic Engineering*, 4(3), 232-239.
- Tokar, A.S., and Markus, M., (2000). Precipitation-runoff modeling using artificial neural networks and conceptual models, *Journal of Hydrologic Engineering*, 5 (2), 156–161.
- Tongal, H., and Booij, M.J., (2018). Simulation and forecasting of streamflows using machine learning models coupled with base flow separation, *Journal of Hydrology*, 564(2018), 266-282.
- Wang, W.C., Chau, K.W., Cheng, C.T., and Qiu, L., (2009). A comparison of performance of several artificial intelligence methods for forecasting monthly discharge time series, *Journal of Hydrology*, 374(3-4), 294-306.
- Yilmaz, B., and Ozcelik, C., (2018). Evaluation of Water Quality Monitoring Networks Using Principal Component Analysis: A case of Gediz River Basin, *Celal Bayar University Journal of Science*, 14(1), 65-75.



- Zhang, B., and Govindaraju, R.S., (2003). Geomorphology-based artificial neural networks (GANNs) for estimation of direct runoff over watersheds, *Journal of Hydrology* 273(1-4), 18–34.
- Zhang, J.R., Zhang, J., Lok, T.M., and Lyu, M.R., (2007). A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training, *Applied Mathematics and Computation* 185(2), 1026–1037.
- Zhang, L., Potter, N., Hickel, K., Zhang, Y., and 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.
- Zuo, D., Xu, Z., Wu, W., Zhao, J., and Zhao, F., (2014). Identification of streamflow response to climate change and human activities in the Wei River Basin, China, *Water Resources Management*, 28(3), 833–851.

# ÖZGEÇMİŞ

## Kişisel Bilgiler

Adı Soyadı : Zeynep Beril ERSOY  
Doğum tarihi ve yeri : 12.10.1993 - SELÇUKLU  
e-posta :zeynepberilersoy@gmail.com

## Öğrenim Bilgileri

Derece	Okul/Program	Yıl
Y. Lisans	Balıkesir Üniversitesi/İnşaat Mühendisliği	2021
Lisans	İzmir Yüksek Teknoloji Enstitüsü/İnşaat Mühendisliği	2018
Lise	75. Yıl Lisesi	2011

## Yayın Listesi

Ersoy, Z.B., Okkan, U., and Fistikoglu, O., (2021), Hybridizing a Conceptual Hydrological Model with Neural Networks to Enhance Runoff Prediction, *Manchester Journal of Artificial Intelligence and Applied Sciences*, 2, 176-178. **[Tezden türetilmiştir]**

Okkan, U., Ersoy, Z.B., Kumanlioglu A.A., and Fistikoglu, 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. **[Tezden türetilmiştir]**