

**Eksik Akış Kayıtlarının Tahmini İçin Tekrarlayan Sinir
Ağlarının Uygulanabilirliği**

Yaman ALSAVAF



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**Eksik Akış Kayıtlarının Tahmini İçin Tekrarlayan Sinir Ağlarının
Uygulanabilirliği**
**Applicability of Recurrent Neural Networks for Prediction of Missing Flow
Records**

Yaman ALSAVAF
0000-0001-5008-8344

Doç. Dr. Arzu TEKSOY
(Danışman)

YÜKSEK LİSANS
ÇEVRE MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2021

Her Hakkı Saklıdır

TEZ ONAYI

Yaman ALSAVAF tarafından hazırlanan “Bazı Yüzeysel Su Parametrelerin Gelecekteki Durumunun Tahmin Edilmesi İçin Yapay Zeka (RNN Yöntemi) Kullanılması” adlı tez çalışması aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Çevre Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman : Doç. Dr. Arzu TEKSOY

- Başkan** : Doç. Dr. Arzu TEKSOY İmza
0000-0002-0467-7188
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Çevre Mühendisliği Anabilim Dalı
- Üye** : Prof. Sabahattin Sıddık CİNDORUK İmza
0000-0001-7536-0332
Bursa Uludağ Üniversitesi,
Mühendislik Fakültesi,
Çevre Mühendisliği Anabilim Dalı
- Üye** : Dr.Öğr.Üyesi Saadet HACISALİHOĞLU İmza
0000-0001-5969-4180
Bursa Teknik Üniversitesi,
Mühendislik Ve Doğabilimleri Fakültesi,
Çevre Bilimleri Anabilim Dalı

Yukarıdaki sonucu onaylarım

Prof. Dr.

Enstitü Müdürü

/ /2021

Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

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

Beyan ederim.

06/12/2021

Yaman ALSAVAF

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Doç. Dr. Arzu TEKSOY
06/12/2021

Yaman ALSAVAF
06/12/2021

İmza

Bu bölüme kişinin kendi el yazısı ile okudum anladım yazmalı ve imzalanmalıdır.

İmza

Bu bölüme kişinin kendi el yazısı ile okudum anladım yazmalı ve imzalanmalıdır.

ÖZET

Yüksek Lisans Tezi

Eksik Akış Kayıtlarının Tahmini İçin Tekrarlayan Sinir Ağlarının Uygulanabilirliği

Yaman ALSAVAF

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Çevre Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Arzu TEKSOY

Nehir akış kayıtlarının saklanması, optimum su kaynağı yönetimi uygulamalarının sağlanması ve ekohidrolojik dengenin korunması için birincil koşuldur. Bazı nehir akış ölçüm istasyonları özellikle ülkenin kırsal ve uzak bölgelerinde çeşitli teknik sorunlar veya beklenmedik problemler nedeniyle kesintili olarak hizmet dışı kalabilmektedir. Böylelikle nehir akış kayıtlarının bir kısmı kaybolabilmektedir. Bu bağlamda yapılan bu tez çalışmasında, Bursa'da Orhaneli Nehri üzerinde bulunan Dağgüney istasyonunun günlük nehir akış verilerinin tahmin edilmesi için destekleyici bir yaklaşım olarak tekrarlayan sinir ağlarının (TSA) uygunluğu araştırılmıştır. Elde edilen bulgular TSA'nın sınırlı sayıda girdi verisi olsa bile belli dönemlerde iyi ve çok iyi tahminler sağlama potansiyelini göstermiştir. Çalışmanın sonucunda $R^2=0,875$ olarak bulunmuştur. Ayrıca, tüm tahmini akışlar ve tüm gerçek kayıtlar için tahmini KOKH değerleri sırasıyla $14,7 \text{ m}^3/\text{s}$ ve $15,59 \text{ m}^3/\text{s}$, tahmin modeli için Nash-Sutcliffe verimliliği NSV değeri ise 0,871 olarak bulunmuştur. Bu sonuçlar TSA'nın umut verici olduğunu ve uzak bölgelerdeki sel ve kuraklıkların olası dönemlerini tahmin etmek ve klasik yaklaşımları kullanmak yerine eksik kayıtları hesaplamak için TSA'nın pratik bir yöntem olarak değerlendirilebileceğini göstermiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Yüzey Akışı, Derin Öğrenme, Nehir, Kayıp Veriler.

2021, ix + 54 sayfa.

ABSTRACT

MSc Thesis

Applicability of Recurrent Neural Networks for Prediction of Missing Flow Records

Yaman ALSAVAF

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

Supervisor: Assoc.Prof. Arzu TEKSOY

Acquiring river flow records is the primary prerequisite for providing optimum water resource management practices and preserving the ecohydrological balance. Some river flow measurement stations may be out of service intermittently due to various technical problems or unexpected difficulties. Consequently, some of the river flow records may be lost especially in rural and remote areas of the country. In this context, the suitability of recurrent neural networks (RNN) as a supportive approach for estimating daily river flow data of Dağgüney station located on the Orhaneli River in Turkey was investigated in this thesis. The findings showed the potential of RNN in providing good and very good predictions in some periods, even with a limited number of input data. As a result of the study, $R^2=0.875$ was found. In addition, RMSE values for all estimated flows and all actual records respectively were found to be 14,7 m³/s and 15.59 m³/s. The Nash-Sutcliffe efficiency NSE value for the forecast model was 0.871. These results suggested that RNN are promising and may be considered as a practical method to predict the likely periods of floods and droughts in remote areas and interpolate missing records instead of using classical approaches.

Key words: Artificial neural networks, Runoff, Orhaneli, River, Missing data.

ÖNSÖZ VE TEŞEKKÜR

Öncelikle bu çalışmanın tamamlanmasına kadar bana güç veren ve yardımcı olan yüce Allah'a hamd, sonsuz şükran ve teşekkürlerimi sunarım.

Bu araştırmayı gerçekleştirmek için rehberlik eden, paha biçilmez motivasyon ve destek sağlayan Doç. Dr Arzu TEKSOY'a minnettarlığımı ve teşekkürlerimi sunarım. Bana verdiği destek her zaman koşulsuzdur. Bağımsız bilimsel araştırma yapabilmem için akademik özgürlüğüme olanak tanınması, çalışmanın her aşamasında ilgi göstermesi ve bana sonsuz güven duyması nedeniyle onur duyuyorum.

Yüksek lisans dahil olmak üzere tüm eğitim ve öğrenim aşamalarında bana katkıda bulunan tüm hocalarıma müteşekkirim.

Ebeveynlerime, kardeşlerime, tüm aile üyelerime ve akrabalarım, ilerlemem için sürekli ilham vermelerinden dolayı yürekten teşekkür etmek istiyorum. Eğitimim ve başarımlarım için yaptıkları fedakârlık ve verdikleri mücadeleler için aileme minnettarım.

Bu çalışmanın her aşamasında beni yönlendiren ve sabırla bilgisini paylaşan, öğrenim hayatım boyunca hep katkıda bulunan Yrd. Doç. Dr. Basil ALSAWAF'a en derin teşekkürlerimi sunarım.

Son olarak, beni cesaretlendiren ve hayatımın bir parçası olan arkadaşlarıma, meslektaşlarıma teşekkür ederim.

Yaman ALSAVAF

.../.../2021

İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	ii
TEŞEKKÜR	iii
KISALTMALAR DİZİNİ	v
ŞEKİLLER DİZİNİ	vi
ÇİZELGELER DİZİNİ	vii
1. GİRİŞ	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI	4
2.1 Yapay Sinir Ağları (YSA)	4
2.1.1 Yapay sinir ağlarının tarihsel gelişimi	4
2.1.2 Yapay sinir ağlarının yapısı	5
2.1.3 Yapay sinir ağı çeşitleri	6
2.1.4 Yapay sinir ağlarının optimizasyonu	8
2.1.5 Tekrarlayan sinir ağları (TSA)	10
2.1.6 İleri beslemeli sinir ağları üzerindeki tekrarlayan sinir ağları avantajları	11
2.1.7 Sinir ağı modellerinin avantajları ve dezavantajları.	11
2.2 Su Kaynakları.	12
2.2.1 Hidrolojik döngü kavramı.	12
2.2.2 Sular kaynakların sınıflandırılması	15
2.2.3 Su kaynaklarının Türkiye'deki durumu.	19
2.3 Yüzey Akışı (Runoff)	21
2.3.1 Yüzey akışı oluşumu.	22
2.3.2 Yüzey akışı türleri.	22
2.3.3 Yüzey akışını (runoff) kontrol eden faktörle.	23
2.3.4 Yüzey akışı etkileri.	24
2.3.5 Yıllık yüzey akış miktarı.	25
2.3.6 Yüzey akışının önemi	25
2.3.7 Yüzey akışı ve su kalitesi.	25
2.4 Hidrolojik Modellemelerde Yapay Sinir Ağlarının (YSA)	26
2.4.1 Hidrolojik Modelleme için yapay sinir ağların Avantaj ve Dezavantajları.	26
2.5 Su Kalitesi Modellemesinde Yapay Snir Ağlarının (YSA) Kullanımı.	29
3. MATERYAL ve YÖNTEM.	31
3.1 Çalışma Alanı	31
3.2 Nehir Akım Kayıtları	32
3.3 Tekrarlayan Sinir Ağları Modeli ve Performans Ölçütleri.	34
4. BULGULAR ve TARTIŞMA	37
5. SONUÇ	44
KAYNAKLAR	45
EKLER.	48
EK 1. Şekil 2.8.	49
EK 2. Şekil 4.1.	50
EK 3. Şekil 4.2.	51
EK 4. Model değerleri 2014 Akış değerleri ile karşılaştırılması	52
EK 5. Model değerleri 2015 Akış değerleri ile karşılaştırılması	53
ÖZGEÇMİŞ	54

KISALTMALAR DİZİNİ

Kısaltmalar	Açıklama
ALK	Alkalinite
ÇKA	Çok Katmanlı Algılayıcı
ÇTK	Toplam Çözünmüş Katı
ÇO	Çözünmüş Oksijen
DSİ	Devlet Su İşleri
EC	Elektrik İletkenliği
GY	Geri Yayılım
İBSA	İleri Beslemeli Sinir Ağı
K-EYK	K-En Yakın Komşu
NSV	Nash-Sutcliffe Verimliliği
KOKH	Kök Ortalama Kare Hatası
OEHO	Otoregresif Entegre Hareketli Ortalama
OMH	Ortalama Mutlak Hata
PCC	Pearson Korelasyon Katsayısı
pH	Power of Hydrogen
RNN	Recurrent Neural Network
T	Sıcaklık
TS	Toplam Sertlik
TSA	Tekrarlayan Sinir Ağı
TÜİK	Türkiye İstatistik Kurumu
UKSH	Uzun Kısa Süreli Hafıza
YSA	Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

	Sayfa	
Şekil 2.1.	Yapay bir nöronun şematik diyagramı	5
Şekil 2.2.	TSA/RNN yapısı ve gizli katmanının yapısı.	8
Şekil 2.3.	Bir TSA ağının temel temsili yuvarlanmış ve açılmış halleri	11
Şekil 2.4.	Hidrolojik döngü şeması	13
Şekil 2.5.	Hidrolojik döngünün Şematik Gösterimi	15
Şekil 2.6.	Su kaynakların Sınıflandırması	15
Şekil 2.7.	Türkiye'nin su havzaları	20
Şekil 2.8.	Susurluk havzası siyasi haritası	20
Şekil. 2.9.	Yüzey akışının meydana gelişi	22
Şekil 3.1.	Orhaneli Nehri konumu ve incelenen nehir boyunca dere akış izleme istasyonlarının konumu, nehir seviyesi ve yağmur ölçüm istasyonları	32
Şekil 3.2.	Python programında kullanılan modulün ekran görüntüsü	33
Şekil 3.3.	a) TSA'nın basit bir tasviri, b) bir nöron yapısının temsili görünümü.	35
Şekil 3.4.	Her bir zaman adımındaki girdi dizisinin yapısı.	37
Şekil 4.1.	Düşük akış dönemlerinde (a, b, c) gerçek (siyah) ve tahmini (kırmızı) akışlar arasındaki karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki görelî fark	38
Şekil 4.2.	Orta akış (a & b) ve yüksek akış (c) dönemlerinde gerçek (siyah) ve tahmini (kırmızı) akışların arasındaki karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki görelî fark.	40
Şekil 4.3	Gerçek ve Tahmini akışlar arasındaki ilişki.	41
Şekil 4.4	Gerçek değerlerin öğrenme değerleri ve e tahmini değerler ile arasındaki ilişki	41

ÇİZELGE DİZİNİ

	Sayfa
Çizelge 2.1 Türkiye su kaynakları potansiyeli	19
Çizelge 2.2 Dört YSA modelinin R^2 verimlilik değerleri	
Çizelge 2.3 Dört veri kümesinde sonraki 6 gün için çeşitli modeller arasında tahmin performan	28
Çizelge 3.1 Orhaneli nehri üzerinde bulunan gözlem istasyonunun listesi	33
Çizelge 3.2 Su yılın kayıtlarının örneği	34
Çizelge 3.3 Çalışmanın TSA modelinin özeti	36
Çizelge 3.4. Çalışmanın TSA modelinin özeti	37
Çizelge 4.1. Çalışmanın sonuçları özet tablosu	42

1. GİRİŞ

İnsanların,tüm canlıların vazgeçilemez temel ihtiyacı olan suya sağlıklı ve güvenilir bir şekilde erişebilmesi, suyun yeterli miktarda ve istenilen kalitede olması, suyun tükenebilecek bir doğal kaynak olduğu gerçeğinin tam olarak anlaşılması su yönetimi açısından büyük önem taşımaktadır.

1980lerden bu yana su kullanımı, nüfus artışı, sosyoekonomik gelişmeler ve değişen tüketim kalıplarının bir kombinasyonuna bağlı olarak, küresel olarak her yıl yaklaşık %1 oranında artmaktadır. Su talebinin 2050 yılına kadar benzer bir oranda artmaya devam etmesi beklenmektedir (UNESCO 2019). Bu nedenle Birleşmiş Milletler'in öne sürdüğü "leaving no one behind" [kimseyi geride bırakmamak] kavramı benimsenerek, gelecek kuşaklar için su kaynaklarının yönetimi ve korunması prensiplerini daha etkin kılmak amacıyla çeşitli çalışmalar başlamıştır.

Yüksek nüfus artış hızı ve su tüketimindeki bazı alışkanlıklar mevcut su kaynakları üzerinde önemli bir stres unsurudur. Buna ilaveten iklim değişikliği de su potansiyeli üzerinde yadsınamaz bir etkiye sahiptir. Özellikle suyun hidrolojik döngüsüne, mekânsal ve zamansal dağılımına olan etkisi her geçen gün daha da belirgin olmaktadır (UNESCO 2019).

Hidrolojik sistemler, sel ve kuraklık gibi farklı şiddetlerde olaylarla sonuçlanan çeşitli bağımlı değişkenler tarafından kontrol edilir (Graeff vd. 2009). Bu nedenle ekohidrolojik sistemlerin davranışları üzerinde etkili olan temel sorunları anlamak için, su kaynakları ve ekohidroloji alanındaki en önemli uygulamalardan biri olan, sel ve kuraklıkların tahminini daha iyi sağlamak amacıyla farklı hidrolojik değişkenler arasındaki güçlü ilişkileri gösteren net hidrolojik modellerin oluşturulması gerekmektedir (Al Sawaf, Kawanisi, ve Xiao 2020). Yapay Sinir Ağları (YSA), doğrusal olmayan modelleri mükemmel bir şekilde tahmin edebilen, veriye dayalı popüler bir model çeşididir (Wu, Chau, ve Li 2009). Çok sayıda araştırmada, gerçek zamanlı nehir akım seviyesi tahmin modeli olarak Tekrarlayan Sinir Ağları (TSA) formunda geliştirilen derin öğrenme yöntemleri kullanılarak dil çevirisi (Ranzato, Chopra, Auli ve Zaremba 2016), resim algılama (Lee 2016), konuşma tanıma (speech

recognition) yağış-akış modellemesi (Kratzert, Klotz, Brenner, Schulz ve Herrnegger 2018) ve gerçek zamanlı nehir akışı tahmini (Hitokoto, Sakuraba, ve SEI 2017) dâhil olmak üzere çeşitli uygulamalarda, Yapay Sinir Ağları'nın verimliliği incelenmiştir. Diğer klasik algoritmalara kıyasla daha fazla doğruluk oranına sahip sonuçlar elde edilmiştir. Ancak, YSA yaklaşımlarının “kara kutu (black box)” gibi bazı sınırlamaları olduğu kabul edilmelidir (Tzeng ve Ma 2005). Bu modelleme yöntemi son yıllarda derin öğrenme verisine dayalı model algoritmalarından biri olarak oldukça fazla ilgi görmüştür (Beck, Flad, ve Munz 2019).

Nehir akışının zamana bağlı tahmininde derin öğrenmenin potansiyeli birçok çalışmada gösterilmiştir (K. Kim, D. Kim, Noh ve M. Kim. 2018). Geçmişteki çalışmalar dikkate alındığında, su krizinin Türkiye'de önemli bir sorun haline geldiği ve öncelikle yetersiz yönetim planlarından ve kapsamlı planlama eksikliğinden etkilendiği görülmektedir. Bu nedenle Türkiye'deki su krizinin üstesinden gelmek için mevcut yönetim kılavuzlarının ve stratejilerinin gözden geçirilip güncellenmesi gerekmektedir (Graeff vd. 2009).

Türkiye'de özellikle merkezden uzak bölgelerde ve bazı beklenmedik teknik sorunlar nedeniyle izleme kapsamından çıkan istasyonlarda akış izleme stratejilerinin güncellenmesi önem arz etmektedir. Bu bölgelerdeki istasyonlarda eksik toplanan nehir akış kayıtlarının tamamlanması, nehir kontrol sistemlerinin altta yatan sorunlarının anlaşılmasına ve gelecekte Türkiye'nin su kaynakları ve ekohidrolojik sistemleri için daha iyi değerlendirme ve yönetim uygulamalarının oluşturulmasına yardımcı olacaktır.

Nehir akış tahmini verimliliğinde kayda değer gelişmeler sağlayan çeşitli tahmin algoritmalarının geliştirilmesi konusunda önemli ilerlemeler mevcut olsa da bu çalışmada nehir akış değerlerini tahmin etmede derin öğrenme algoritmalarının yeterliliğinin belirlenmesi amaçlanmıştır. Bu çalışmanın temel araştırma sorusu, ardışık istasyonlardan temin edilen mevcut nehir akış kayıtlarına dayalı olarak teknik sorunlar nedeniyle devre dışı olmuş bir istasyondaki eksik nehir akış kayıtlarının tahmin edilmesinde derin öğrenmenin yaygın algoritmalarından biri olan Tekrarlayan Sinir Ağlarının (TSA), kullanımının uygun olup olmadığıdır. Bu kapsamda, komşu istasyonlardan elde edilen akış verilerine dayalı olarak herhangi bir istasyondaki eksik

akış kayıtlarının tahmin edilmesinde TSA'nın uygunluğu araştırılacak, ayrıca çökmüş veya devreden çıkmış bir istasyonda günlük nehir akış verilerinin kurtarılması için destekleyici bir yöntem olarak TSA'nın kapasitesi incelenecektir.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1 Yapay Sinir Ağları (YSA)

2.1.1 Yapay sinir ağlarının tarihsel gelişimi


YSA terimi 1943'te, insan beyni işlevlerini gerçekleştiren birbirine bağlı sinir hücresi ağlarına dayalı olarak kavramsallaştırılmasını öneren Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir (Russell, Norvig, Canny, Malik ve Edwards 1995). İlk sinir ağı makinesi 1951'de Minsky ve Edmonds tarafından geliştirilmiştir. Makine, bir farenin labirent boyunca ilerleyişini izlemek için kullanılmıştır. Geliştirilen nöral makine, farenin rolünü üstlenmiştir. Daha sonra 1962'de, Rosenblatt 'perceptron' algılayıcısını geliştirmiştir. Algılayıcı, bir öğrenme algoritması ile birlikte tek katmanda birbirine bağlı yapay nöronların basit bir düzenlemesidir. Sonrasında neredeyse 20 yıl bu konuda herhangi bir gelişme olmamıştır (Russell vd., 1995).

Altmışlı yılların sonlarında, Rosenblatt'ın algılayıcısının çok kompleks fonksiyonları ifade edemediği, Minsky ve Papert'in 1969 yılındaki önemli bir yayınında ortaya konmuştur. YSAların önündeki ana engel, seksenlerin ortalarına kadar aşılamamıştır. Bir çalışmada Çok Katmanlı Algılayıcı'nın (ÇKA) sınırlandırılmış boyutta bir uzaydan diğerine istenilen herhangi bir fonksiyona istenilen herhangi bir doğruluk derecesine kadar yaklaşabileceği matematiksel olarak kanıtlanmıştır. Bu, evrensel bir yaklaşım olarak adlandırılmıştır (Hornik, Stinchcombe, ve White 1989). Yani bu durum YSAların teorik olarak herhangi bir hidrolojik modelleme problemine uygulanabilir olması gerektiği anlamına gelmektedir. Yapay sinir ağlarının kullanımı, çok çeşitli alanlara sıklıkla uygulanan veriye dayalı popüler bir tekniktir. YSA, doğrusal olmama durumlarını simüle edebilir ve yeni bilgilere otomatik olarak uyum sağlayabilir; ancak genel olarak az miktarda veriyle çalışılması halinde matematiksel işlemlere gereksinim duyulabilir (De Vos ve Rientjes 2008).

2.1.2 Yapay sinir ağlarının yapısı

Yapay sinir ağı (YSA), biyolojik sinir sistemlerinden ilham alan bir bilgi işleme paradigmasıdır. Bir sinir ağı, deneysel bilgiyi depolamak ve onu kullanıma hazır hale getirmek için doğal bir eğilime sahip olan, basit işlem birimlerinden oluşan, büyük ölçüde paralel dağıtılmış bir işlemcidir. YSA insan beynine iki şekilde benzer: (i) bir sinir ağı, öğrenme yoluyla bilgi edinir ve (ii) bir sinir ağının bilgisi, sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı güçleri içinde depolanır (Hornik vd. 1989). YSAlar günümüzde hem doğrusal hem de kompleks, doğrusal olmayan ilişkileri temsil etme ve bu ilişkileri modellenen verilerden doğrudan öğrenme yetenekleri nedeniyle evrensel bir işlem yaklaşımı olarak kabul edilmiştir. Gerçek değerli ve belirli modifikasyonlardan sonra ayırık değerli fonksiyonlara yakınsamak için güçlü bir yaklaşım sağlarlar. Günümüzde bu yöntemler kontrol, sınıflandırma, örüntü tanıma, dinamik sistemlerin modellenmesi ve zaman serisi tahmini için birçok alanda başarıyla uygulanmaktadır (ASCE 2000).

YSAlar, nöron veya düğüm adı verilen çok sayıda basit işlem ögesinden oluşur. Her nöron daha sonra doğrudan bağlantı aracılığıyla diğer nöronlara bağlanır; her biri, sorunu çözmek için ağ tarafından kullanılan bilgiyi temsil eden bir ağırlıkla ilişkilendirilir. Sinir ağı genel olarak yapısı (nöronlar arasındaki bağlantı kalıpları), eğitim veya öğrenme algoritması (bağlantılar üzerindeki ağırlıkları belirleme yöntemleri) ve aktivasyon fonksiyonu ile karakterize edilebilir (Shrestha 2010; ASCE 2000). Tek nöronlu tipik bir sinir ağının yapısı Şekil 2.1'de gösterilmektedir. Bu yapı beş temel unsurdan oluşur:



Şekil 2.1. Yapay bir nöronun şematik diyagramı (Shrestha 2010; ASCE 2000)

Burada;

1. x_1, \dots, x_n giriş sinyallerini almak için giriş düğümleri;
2. Her biri bir ağırlık w_{ij} ile karakterize edilen bir dizi bağlantı halkası (genellikle sinaps olarak adlandırılır);
3. Giriş sinyallerini toplamak için toplama işlevi;
4. Nöronun aktivasyon seviyesini hesaplayan aktivasyon fonksiyonu ve
5. Çıkış düğümleri y_1, \dots, y_l

Her nöronun işlenmesi iki adımda gerçekleştirilir:

- (I) ağırlıklı giriş sinyallerinin toplamının elde edilmesi ve
- (ii) bir nöronun çıktısının genliğini sınırlamak için toplam değere aktivasyon fonksiyonunun uygulanması göstermektedir.

Bu süreç, matematiksel olarak aşağıdaki iki denklemle tanımlanabilir:

$$u_j = \sum_{i=1}^p w_{ij} x_i \quad (1-1)$$

$$y_j = f(u_j + b_j) \quad (1-2)$$

Burada w_{ij} , i girişini j nöronuna bağlayan ağırlıktır. Etkili gelen sinyal u_j ve önyargı b_j , çıktı sinyali y_j 'yi üretmek için $f(.)$ aktivasyon fonksiyonundan geçirilir. Yaygın olarak kullanılan nöronlar arasındaki temel fark, aktivasyon fonksiyonunun tipidir. Aktivasyon fonksiyonlarının fonksiyonel formları, bir düğümün toplam giriş sinyaline tepkisini belirler, ancak bu aktivasyon fonksiyonları arasında ortak bir nokta vardır- hepsi giriş sinyallerini belirli sınırlarla kısıtlar. Yaygın olarak kullanılan bazı aktivasyon fonksiyonları doğrusal, ikili, sigmoid ve teğet hiperboliktir (Shrestha 2010).

2.1.3 Yapay sinir ağı çeşitleri

YSA'lar İleri Beslemeli Sinir Ağları (İBSA) ve Tekrarlayan Sinir Ağlarıdır (TSA iki ana türden oluşmaktadır:).

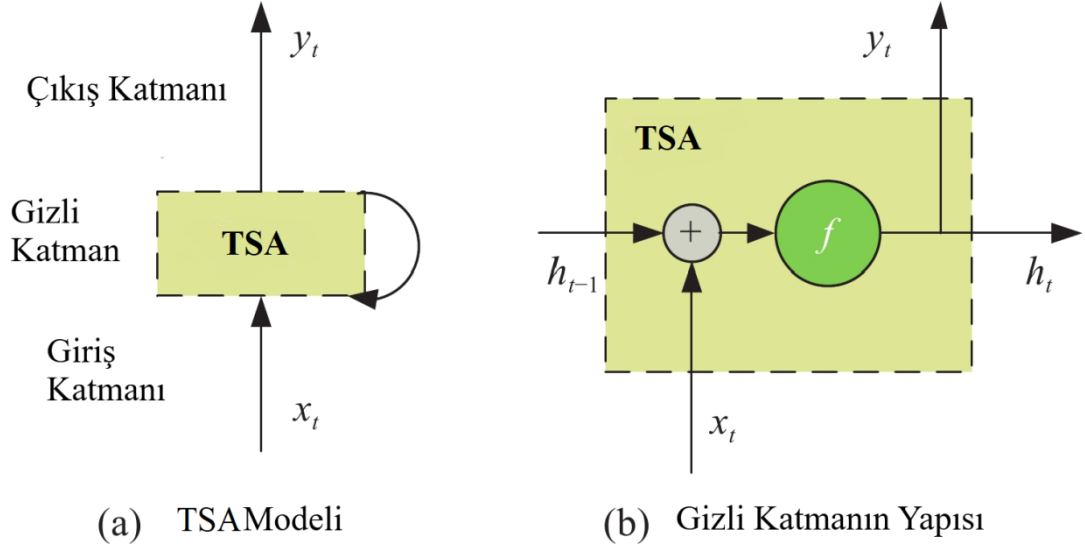
- İleri beslemeli sinir ağıları (İBSA)

İleri beslemeli bir ağı tanımlamanın en basit yolu, tüm bağlantıların girişten çıkış katmanına doğru tek bir yöne ilerlemesini sağlamaktır. Çok katmanlı algılayıcılar (ÇKA), giriş ve çıkış düğümleri arasında bir veya daha fazla katman bulunan ileri beslemeli yapılardır. ÇKAların (bir veya daha fazla gizli katmanlı olmak üzere) avantajı, gizli katmandaki düğüm sayısının, girdi ve çıktı değişkenleri arasındaki ilişkilerin karmaşıklığına uyum sağlayabilecek şekilde değiştirilebilmesidir. İBSA'nın, örnekleme veya ölçüm zaman aralığının 24 saatten daha az veya ona eşit olduğu verilere uygulandığında, bir zaman adımlı tahmin olarak en iyi performansı gösterdiği bulunmuştur (Khaparde, Lohtia, ve Desai 1991).

- Tekrarlayan sinir ağıları (TSA)

Bu tip modeller iki yönlü veri akışına sahiptir. İBSAlar, verileri girdiden çıktıya yayarken, TSAlar verileri 'akıntı yönü' işleme birimlerinden önceki birimlere yayar. Bu nedenle, TSAlar farklı katmanlarda diğer katmanlara veya farklı döngü tiplerinde geri bildirim bağlantılılarına sahiptir. Bu durum ağ çıkışının yalnızca harici girişlere değil, aynı zamanda önceki zaman adımındaki ağı durumuna da bağlı olduğu anlamına gelir (Khaparde vd. 1991) . Şekil 2.2'de gösterildiği gibi model, tüm düğümler arasındaki tam geri bildirim ve ara bağlantıları kullanmaktadır

Aşağıda bulunan şekil Liu ve ark.larına göre a kısmında TSA'nın yapısı ve içerdiği gizli katmanın yapısı görülmektedir (Liu vd. 2021)



Şekil 2.2. TSA yapısı ve gizli katmanının yapısı (Liu vd. 2021)

TSA'nın İBSA'ya göre bazı avantajları vardır. Birincisi, mevcut hesaplamalarda kullanılabilen önceki işlem döngülerinden değerleri muhafaza etme yeteneğine sahip olmasıdır. Bu avantaj, TSAların basit statik girdilere yanıt olarak karmaşık, zamanla değişen çıktılar üretmesine izin verir (Khararde vd. 1991).

Bir TSA, katmanlardan herhangi birinin birimleri arasında bağlantılara sahip olabileceğinden, her birimin çıktısı, zaman adımları cinsinden tanımlanmalıdır. Örneğin, t-1 adımıdaki çıktılar, t adımıdaki girdiler olabilir. Ayrıca bazı TSA yapılarında, bağlam birimleri aracılığıyla önceki bir zaman adımıdaki çıktıların bir kopyasını saklamak da mümkündür. Bağlam birimleri, sonraki eğitim adımlarında girdi olarak yeniden kullanılabilen bu çıktıları saklamaktadır (Khararde vd. 1991).

2.1.4 Yapay sinir ağlarının optimizasyonu

Bir ağ yapısı kurulduktan sonra, bu ağ optimizasyon aşamasına tabi tutulmaktadır. YSA, önceden tanımlanmış bir öğrenme programına uygun olarak kendisine sunulan eğitim örneklerine yanıt olarak bağlantıları adapte ederek işlevi öğrenir. Optimizasyon süreci veri setindeki girdi ve çıktı değerleri arasındaki hataları küçülten önemlilik payını bulmak için kullanılmaktadır. YSAlar, ağ ağırlıklarının matrisini ve nöron yanlılıklarını

ayarlayarak ağ çıkışındaki hatayı azaltmaya çalışan optimizasyon algoritmasının uygulanmasıyla eğitilmektedir (Maier ve Dandy 2000, Wei, Xu, Fan ve Tasi 2002).

Fonksiyon tahminlerinde YSA uygulamasındaki yaygın yaklaşım, denetimli öğrenim algoritmalarının kullanılmasıdır. Denetimli öğrenim algoritmaları, simüle edilecek sistemin örnek giriş ve çıkış verileri ile birlikte kullanılır. Geri yayılım (GY) algoritması, en popüler YSA eğitim algoritması olarak kabul edilmektedir. Aslında, çıktıların sonraki katmanlara gecikmeden gönderildiği ileri beslemeli modelleri eğitmek için uygulanan bir prosedürdür (Nagesh Kumar, Srinivasa Raju, ve Sathish 2004). Belli bir problem için uygun YSA'nın yapısını seçme süreci şu şekilde açıklanmıştır:

- Yapıyı kurmak,
- Ağı eğitmek,
- Ağı test etmek.

GY algoritmasıyla oluşturulmuş sinir ağlarının performansını optimize etmek için, adım boyutunun öğretim üzerindeki etkisinin iyi anlaşılması esastır. Ağırlıkların¹ başlatılması, bir sinir ağını eğitmek için dâhili parametreleri hazırlamanın ilk adımındır. GY algoritması için, ağırlıklar küçük ve sıfıra yakın ortalamalı rastgele değerlerle başlatılmıştır, çalışmalar ayrıca istikrarlı sonuçlar elde edilip edilmediğini görmek için bir dizi farklı rasgele başlangıç değeri kümesinin kullanılması gerektiğini önermiştir (Maier ve Dandy 2000).

Maier ve Dandy (2000), gizli katmanlarda sigmoid transfer fonksiyonlarının ve çıktı katmanında lineer transfer fonksiyonlarının kullanılmasının, eğitim verilerinin aralığının ötesinde ekstrapolasyon yapılması gerektiğinde avantajlı olabileceğini belirtmiştir.

GY algoritması gibi sinir ağı öğretim algoritmalarında yaygın olarak dikkate alınan diğer bir parametre, öğretim sırasında en aza indirilmesi gereken işlev olan hata işlevidir (Maier ve Dandy 2000, Vahed 2011).

Ortalama kareler hatası (OKH) ağı hatasıdır. Burada i , giriş modeli ağı sunulduğunda üretilen hatadır. OKH, yaygın olarak kullanılan bir hata işlevidir.

¹ Bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini göstermektedir.

$$= \frac{1}{N} \sum_{i=1}^N \varepsilon_i^2, \quad (1-3)$$

Eđitim sırasında kolayca hesaplanabilmesi, büyük hataları düzeltebilmesi ve normal dağılımla yakından ilgili olması gibi avantajları vardır.

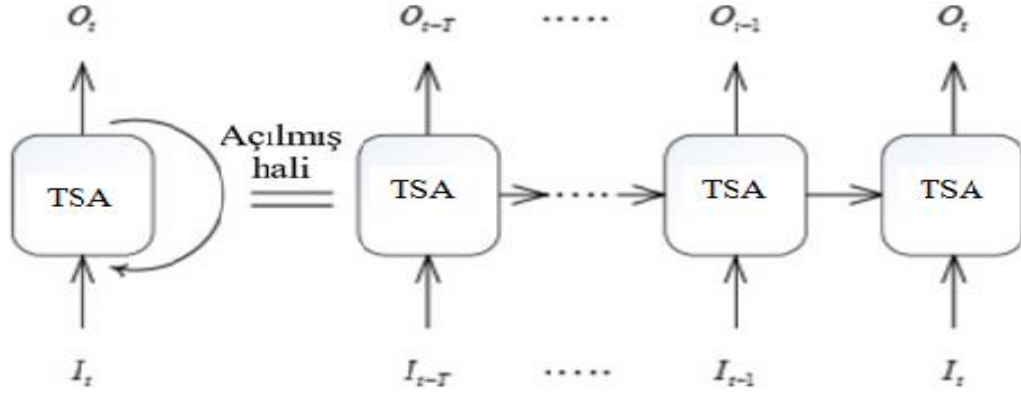
2.1.5 Tekrarlayan sinir ađları (TSA)

Hidrolojik zaman serilerinin tahmini, kalıcılık bileşenlerinin "Hafıza" sayısına bađlı olarak serinin önceki değerlerine dayanmaktadır. TSA bu kolaylığı geri besleme döngülerinin sayısı ile sağlar. Genelleştirilmiş bir TSA, her iki yönde v tüm katmanlara girdi gönderebilir. Bu nedenle, ađın çıkışı yalnızca aldığı harici girişlere deđil, aynı zamanda ađın önceki zaman adımındaki durumuna da bađlıdır. "Hafıza"nın statik nöral ađlara tanıtılmasının üç ana yolu vardır (ASCE 2000). Bunlar (artan karmaşıklık ve yetenek sırasına göre):

Tıklanan gecikme hattı modelleri: Şebeke zaman içinde belirli bir noktada tepkisini belirlemek için açıkça mevcut olan geçmiş girdilere sahiptir (ASCE 2000; Mozer ve Smolensky 1989).

Bađlam modelleri veya kısmi tekrarlayan modeller: Bu modeller, geçmişteki ham girdileri korumak yerine düğümlerin geçmiş çıktılarını korumaktadır (Kothari ve Agyepong 1997) .

Tamamen tekrarlayan modeller: Bu modeller, tüm düğümler arasında tam geri bildirim ve ara bađlantılar kullanır (ASCE 2000).



Şekil 2.3. Bir TSA'nın temel temsili yuvarlanmış ve açılmış halleri (Zhou, Qu, ve Li 2017)

2.1.6 İleri beslemeli yapay sinir ağları üzerindeki tekrarlayan sinir ağların avantajları

TSA'lar önemli özelliklere sahiptir, yani geçmişteki olaylar saklanabilir ve mevcut hesaplamalarda kullanılabilir. Ayrıca, ağına basit statik girdilere yanıt olarak karmaşık, zamanla değişen çıktılar üretmesine de izin verir. Ek olarak, bu etkiye yönelik herhangi bir önlem alınmasa da TSAların nadiren yerel minimuma yerleştiği gözlemlenmiştir (Nagesh Kumar, Srinivasa Raju, ve Sathish 2004; Carling 1995).

2.1.7 Sinir ağı modellerinin avantajları ve dezavantajları

YSA, K- En-Yakın Komşular algoritması (K-EYK) ve Otopregresif Entegre Hareketli Ortalama algoritması (OEHO) yöntemleri gibi herhangi bir açık denklem verilmeksizin, girdilerin çıktılarla nasıl ilişkilendirileceğini öğrenir. YSA modeli için tek gerçek gereklilik, taşkın modelleme olayları örneği için yeterli veri ve kullanılacak uygun sinir ağı parametreleri değerlerinin belirtilmesidir. YSAlar nispeten düşük hesaplama gerektirir ve diğer tekniklerle kolayca entegre edilebilir. Doğrusal bir programın yapamayacağı işlevleri yerine getirirler ve sinir ağının bir unsuru çalışmadığında, oldukça paralel yapıları nedeniyle sorunsuz bir şekilde devam edebilirler (Mather, S. Openshaw ve C. Openshaw 1998; Vahed 2011).

YSAların bir dezavantajı, pek çok ađ tasarım parametresinin optimal biçiminin veya deęerinin her uygulama için farklı olabilmesi ve genelde teorik olarak tanımlanamamasıdır. Ancak, bu deęerler genellikle deneme yanılma yaklaşımları kullanılarak tahmin edilmektedir (Nagesh Kumar vd. 2004). Sinir ađlarının dięer dezavantajı da alıřtırmak için eđitim gerektirmeleridir ve bu durum büyük sinir ađlarının kullanımı için ok fazla iřlem süresi gerektirebilir.

2.2 Su Kaynakları

Yüzeysel sular, atmosfere aık olan ve bir akarsu, nehir, göl veya rezervuar gibi yüzeyden gelen akıřla beslenen sulardır. Bir nehre boşaltılan su, nehir tarafından boşaltılan havzadan gelen yüzey akıřıdır. Yüzey suyu, kamu, sanayi, denizcilik ve tarımsal tedarik gibi amalarla kullanılabilir deęerli bir kaynaktır. Bu nedenle, yüzeysel suların kaynaklarının potansiyeli, kullanımı ve sürdürülebilirlięi, su kaynaęı deęerlendirme ve geliřtirmenin ana anahtarlarıdır. Su havzası seviyesinde su varlıęının deęerlendirilmesi, bir nevi havzada oluřan yüzey akıřının nicelleřtirilmesiyle gerekleřtirilmektedir. Su kaynaklarının deęerlendirmesi ve korunmasını etkin hale getirmek, bir takım nicelik ve nitelik izlemelere ve analizlere dayanmaktadır (Mayo 2015; Daniel 2011).

2.2.1 Hidrolojik döngü kavramı

Su sıvıdan katıya, katıdan sıvıya, sıvıdan buhara, buhardan sıvıya ve buhardan katı hale dönuřmektedir. Güneřin radyasyonu, yerekimine baęlı ivme, suyun akma kabiliyeti ve suyun dięer bazı özellikleri, bu dönuřümü daha etkili ve düzenli hale getirir. Dünyanın su kütlelerinin temel girdisi yaęıřlardan gelir. Sızma ve geirgenlik gibi süreçlerle yaęmur (veya kar) yaęıřı, suyu karadan yeraltı suyu sistemlerine doęru hareket ettirmektedir. Bir miktar su, yüzey akıřı olarak denize doęru akar. Göllerde, göletlerde, bataklıklarda, denizlerde ve okyanuslarda toplanan yüzey suyu buharlařarak atmosfere karıřır. Bitki örtüsü, buharlařan toprak neminden toplanan suyu aıęa ıkarır ve tařınan su buhar olarak atmosfere girer. Toplanan su buharı yoęunlařarak bulutları oluřturur. Bulutlar karaya yaklařır ve yeniden yaęıř bařlar. Bu sonsuz su sirkülasyonu hidrolojik

döngü olarak bilinir (Balasubramanian 2010). Şekil 2.4.'te hidrolojik su döngüsü genel bir ifadeyle açıklanmıştır.



Şekil 2.4. Hidrolojik döngü şeması, (Anonim 2018)

Yüze suyu, kara yüzeyindeki suyu tanımlamak için kullanılan terimdir. Su, akarsularda ve nehirlerde olduğu gibi akıyor olabilir veya göllerde, rezervuarlarda ve göletlerde olduğu gibi durgun olabilir. Yüze suyu, yağışların akışı ve doğal yeraltı suyu sızıntısı ile üretilir; atmosfere açık olan ve yüze akışına maruz kalan tüm su olarak tanımlanmaktadır. Bu tanım, yüze suyunu hem yeraltı suyundan hem de okyanus suyundan ayırmaktadır (Viessman 2010).

Yüze akış modelleri (patterns) yağmuru drene eden ve karı bir nehir veya akarsuda belirli bir noktaya kadar eriten arazi alanları açısından tanımlanmaktadır. Bu kara alanı drenaj alanları, drenaj havzaları, havzalar veya su havzaları olarak adlandırılabilir. Her su havzası, onu diğer havzalardan ayıran, bölücü adı verilen nispeten yüksek bir zemine bağlıdır (Viessman 2010; Balasubramanian 2010; Rao 2005).

Kaynak ve sızıntılardan gelen yeraltı suyu da çoğu akarsuya ve akışa katkıda bulunmaktadır. Bu genellikle temel akış olarak adlandırılır. Bitişik su tablası derenin su yüzeyinden daha yüksek bir seviyede ise, su tablasından gelen su dereye akmaktadır (Şekil 1.6). Su tablası akışın su yüzeyinden daha düşük bir seviyedeysse, dere yeraltı suyunu yeniden yükleyecektir. Akarsuya gidiş ve dönüş akışı, su tablasının mevsimsel

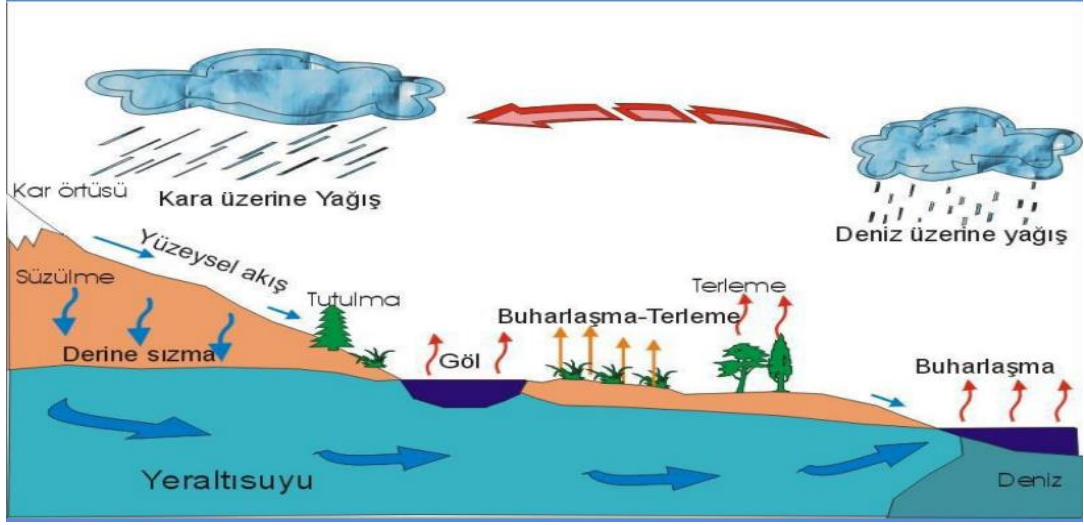
dalgalanmalarına göre deęişebilir. Yeraltı suyu akışı olmasaydı, birçok dere yağmurdan kısa bir süre sonra kurumuş olurdu (Viessman 2010).

Suyolları

Yüzey akışı doğal olarak en az direnç gösteren yol boyunca meydana gelmektedir. Bir su havzası içindeki suyun tamamı, bir kanal veya boru hattı gibi inşa edilmiş yapı tarafından yönlendirilmedięi veya yeraltı suyu potansiyeli olarak zemine akmadığı sürece, birincil olarak doğal suyoluna doğru akmaktadır. Suyolları iki şekilde oluşur, hem doğal şekilde hem de yapay şekilde (Viessman 2010; Rao 2005).

Doęal Suyolları: Tipik doğal suyolları arasında dereler, akarsular ve nehirler bulunmaktadır. Yağış sıklığına, eriyen karların mevcudiyetine ve yeraltı suyunun suyolunun taban akışına katkı oranına baęlı olarak, suyolları sürekli, ara sıra veya aralıklı olarak akabilir. Yılın her döneminde kesintisiz akan doğal suyollarına çok yıllık akarsular denilmektedir. Yalnızca ara sıra akan akışlara geçici akışlar denir. Akışın frekansı uzun süreli ve geçici arasında bir yerde ise bu akışa kesintili akış denmektedir (Viessman 2010; Rao 2005).


Yapay Taşıyıcılar: Bunlar, yüzey suyunun akışını hızlandırmak veya onu doğal koşullar altında akacağı yönden farklı bir yöne yönlendirmek için inşa edilmiş tesislerdir. Kanallar, su kemerleri, borular, tüneller ve boru hatları inşa edilen taşıyıcılara örnektir (Viessman 2010; Rao 2005). Şekil 2.5'te hidrolik döngü ve suyollarının oluşma şekli gösterilmektedir.



Şekil 2.5. Hidrolojik Döngünün Şematik Gösterimi (Soytürk 2014)

2.2.2 Su kaynaklarının sınıflandırılması

Su doğada en bol bulunan bileşiktir. Dünya yüzeyinin %75'ini kaplamaktadır. Suyun yaklaşık %97,3'ü tuzlu olan büyük okyanuslarda bulunur ve %2,14'ü kutuplardaki buzullarda tutulur ve buzullardaki su da kullanılabilir değildir. Geriye kalan %0,56'lık kısım ancak genel geçim ve yaşam için kullanılabilir haldedir. Şekil 2.6'da su kaynaklarının sınıflandırılması açıklanmaktadır.



Şekil:2.6. Su kaynaklarının sınıflandırılması (Rao 2005) değiştirilerek alınmıştır

Yağmur Suyu

Kara ve su yüzeylerinden buharlaşan su, yüksek irtifada bulut şeklinde yoğunlaşıp yağmur veya kar suyu şeklinde düşmeye başlar. Yüksek irtifadan yere düşüşü sırasında su, oksijen, karbondioksit ve diğer gazları, toz, duman, ve bakteri gibi içerikleri

emmektedir. Bu nedenle yağmur suyu, ilk yağmurlarda yüksek miktarda ve sezon sonunda az miktarda kirleticiler içermektedir. Açık araziye, bozulmamış ortamlara veya tarlalara düşen yağmur suyunun kalitesi, şehir veya kasabalara düşeninkinden daha iyidir. Geçen sezonun son yağmur suyunun kalitesi iyidir ve küçük bir arıtmadan sonra kullanılabilir. Oksijene doymuş yağmur suyu yumuşaktır, ancak tadı yavandır ve doğası gereği aşındırıcıdır (Rao 2005; Viessman 2010).

Yağmur, belediye su kaynaklarının temel kaynağı değildir. Yağmur suyunun toplanması, genellikle yeterli yeraltı veya yüzey suyundan yoksun olan yarı kurak bölgelerdeki çiftlikler ve kırsal yerleşimlerle sınırlıdır. Yağmur suyu toplama havzaları ve tankları evlere yakın bulunmaktadır. Bu sistemin elverişliliğini artırmak için uygun çatıların seçilmesi gerekmektedir. Yağmur suyu toplama sistemlerinin diğer su kaynaklarına göre avantajları aşağıdaki şekildedir (Viessman 2010; Vinogradov 2006):

- Yağmur suyunun kalitesi nispeten yüksektir.
- Toplama sistemi şebekeden bağımsızdır.
- Yağmur suyu sistemi yapımında yerel malzeme ve işçilik kullanılabilir.
- Sistemi çalıştırmak için herhangi bir enerji maliyetine gerek yoktur.
- Sahibi/kullanıcısı tarafından bakımı kolaydır.
- Suya erişim kolaydır ve su kalitesi kabul edilebilirdir. Suya erişimde değerli zamanın tasarrufu sağlanır.

Su kaynağı olarak yağmur suyunun dezavantajları şunlardır:

- Yüksek ilk yatırım maliyeti, bir ailenin sistemi satın almasını engelleyebilir.
- Toplanan su, yağış miktarı ve çatı alanı ile sınırlıdır. Uzun kurak mevsimler için gerekli depolama hacmi çok büyük olabilir.
- Mineral içermeyen su yavan bir tada sahiptir.

Göller ve Göletler

Göl veya rezervuarlar durağan iç su kütlesi olarak tanımlanır. Kurak dönemlerde kullanabilmek için genellikle yağışlı dönemlerde suyu depolayabilmeleri avantaj oluşturmaktadır. Göllerde su kalitesi genellikle kötüdür. Bulanıklık ve bakteriler başlıca kirleticilerdir. Dezenfekte edilmeden hiçbir göl veya rezervuar suyu güvenli kabul

edilemez. Genel olarak, bulanıklığın giderilmesi de gereklidir. Derin göller ve rezervuarlar, su kalitesini büyük ölçüde etkileyen termal tabakalaşmaya maruz kalabilmektedir (Viessman 2010; Rao 2005)

Nehir Suyu

Bir akarsu veya nehir, yeryüzünün yüzeyinde yüksek seviyeden alçak seviyeye doğru akan bir su kütesidir. Nehirlerin doğrudan su kaynağı olarak hizmet etme kapasitesi, günlük minimum akış hızıyla orantılıdır. Akarsular genellikle akışta belirgin mevsimsel değişiklikler gösterir ve kirlenmeye karşı hassastır. Kimyasal yapısı kısmen ana kayaya bağlı iken, fiziksel ve bakteriyolojik nitelikleri oldukça değişkendir. Nehirlerin yeraltına uzanan bir su alma yapısı gerektirir ve küçük akarsular durumunda küçük toplama barajlarının inşasını gerektirmektedir (Viessman 2010; Vinogradov 2006).

Rezervuarlar

Rezervuar, bir vadi boyunca bir barajın inşa edilmesiyle oluşan yapay göldür. Depolama rezervuarı, suyu tutmak için bir baraj, fazla suyun akmasına izin vermek için bir savak ve akışı düzenlemek için gerekli valfleri içeren bölme içermektedir.

Yeraltı Suyu

Yeraltı suyu, dünya genelinde önemli bir su temini kaynağıdır. Sulamada, endüstrilerde, belediyelerde ve kırsal alanlarda kullanımı artmaya devam etmektedir. Yeraltı suyu, akiferler olarak bilinen birçok jeolojik oluşumlarda meydana gelir. Akifer, önemli miktarda su elde etmek için yeterli miktarda doymuş geçirgen malzeme içeren bir oluşumdur. Yeraltı su sistemi kuyuları, kaynakları ve sızma galerilerini içermektedir.

Yeraltı suyunun avantajları şunlardır:

- Patojen bakteri içerme ihtimali düşüktür.
- Genel olarak fazla arıtıma ihtiyaç duyulmadan kullanılabilir.
- Kırsal alanların yakın çevresinde bulunabilir.
- Elde edilmesi ve dağıtımı genellikle pratik ve ekonomiktir. Çekilen su taşıyan tabaka genellikle alım noktasında doğal depolama sağlar.

Dezavantajları ise:

- Yeraltı suyunun mineral içeriği genellikle yüksektir.
- Genellikle pompalama gerektirir.

Yeraltı suyunun kalitesi fazla değişim göstermez, bulanıklık ve renk içermez. Genel olarak, yeraltı suları kalsiyum, magnezyum, demir ve manganez gibi katyonların yanı sıra bikarbonat, karbonat ve klorür gibi anyonları da içermektedir (Vinogradov 2006).

Pınar Suyu

Pınar ya da kaynak suyu, sızmayı önleyen geçirimsiz bir taban nedeniyle yerden çıkan yeraltı suyudur. Kaynak suyu genellikle kum veya çakıl su yataklarındaki zeminden (akifer) veya çatlaklı kayalardan beslenir. Kaynak aramak için en iyi yerler, kurak mevsimde yeşil bitki örtüsüne sahip tepelik yamaçlar ve nehir vadisi kum alanlarıdır. Uygun şekilde korunur ve iyi yönetilirse, kaynak suyu küçük toplulukların su kaynağı olma açısından avantajlıdır (Balasubramanian 2010; Viessman 2010)

Pınarlar genellikle Yerçekimi veya Artezyen tiptedir.

– Yerçekimi Pınarları

- Yeraltı suyu, geçirimsiz bir tabaka üzerinden zemin yüzeyine akar.
- Verim, su tablasının konumuna göre değişir.
- Kurak mevsimlerde veya hemen sonrasında kuruyabilir.

– Artezyen Pınarları

- Kapalı sistemleri nedeniyle yüksek kaliteli su.
- Kapalı alanda yüksek basınç nedeniyle yüksek deşarj.
- Verim muhtemelen tek tiptir ve yılın mevsimleri boyunca neredeyse sabittir.

Sızma galerisi

Sızma galerileri, neredeyse tüm uzunlukları boyunca su toplayan yatay kuyulardır. Dere yatakları veya göl kıyıları kumlu ve çakıllı olduğunda, bir kıyı boyunca bir çakıl cebi bulma olanakları yüksektir. Sızma galerisi, doğal olarak filtrelenmiş su elde etmenin basit bir yoludur ve bu amaçla, nehir veya göl kıyısından 15 m veya daha uzağa yerleştirilmelidir. Su taşıyan kuma bir hendek kazılarak, daha sonra suyun pompalandığı merkezi bir depolama alanına giden delikli bir boru veya galeride suyu toplayarak inşa edilmektedir (Viessman 2010).

2.2.3 Türkiye’de su kaynaklarının durumu

Türkiye yarı-kurak, tropik ve aşırı sıcaklık rejimlerinin olduğu bir iklim bölgesinde yer almaktadır. Üç taraftan denizle kaplı olmasına rağmen, Türkiye maalesef su zengini bir ülke değildir. Devlet Su İşleri’ne (DSİ) göre, ülkenin yüzey ölçümünün %11’i göller ve sazlıklar ile kaplıdır. Akarsuların uzunluğu 170.000 km olup 120’den fazla göl bulunmaktadır. Çizelge 2.1.’de Türkiye’deki yıllık su kaynaklarının potansiyeli m³ biriminde ve yağış potansiyeli Mm/yıl biriminde özetlenmiştir.

Çizelge 2.1. Türkiye’deki yıllık su kaynakları ve yağış değerleri (Devlet Su İşleri [DSİ])

Durum	Miktar	Birim
Yıllık ortalama yağış	574	Mm/yıl
Yıllık yağış miktarı	450	Milyar m ³
<i>Yüzey Suyu</i>		
Yıllık yüzey akışı	186	Milyar m ³
Kullanılabilir yüzey suyu	94	Milyar m ³
<i>Yeraltı Suyu</i>		
Yıllık çekilebilir su miktarı	18	Milyar m ³
Toplam kullanılabilir su (net)	112	Milyar m ³
<i>Gelişme durumu</i>		
Sulama Suyu	44	Milyar m ³
İçme-kullanma ve sanayi suyu	13	Milyar m ³
Toplam kullanılan su	57	Milyar m ³

Türkiye İstatistik Kurumu TÜİK’in yaptığı analizlere ve çalışmalara göre, Türkiye’de kişi başına düşen günlük su miktarı 189 ila 236 l arasında değişmekte olup, ortalama 224 l’dir. Tüketilen su genelde göllerden ve nehirlerden sağlanmaktadır. Bunlar diğer yüzeysel sular ile birlikte su toplama havzalarını teşkil etmektedir.


Türkiye 25 su havzasına ayrılmıştır (Şekil 2.7). Bu havzaların durumu, korunması ve yönetimi DSİ ve benzeri yetkili kuruluşlar tarafından kontrol edilmektedir.



Şekil.2.7 Türkiye'nin su havzaları (Kahraman ve Özkul 2018)

Susurluk Havzası:

Marmara Bölgesi'nin güneyinde bulunan Susurluk Havzası Türkiye'nin batısında, 39°-40° kuzey enlemleri ile 27°-30° doğu boylamları arasında yer almaktadır. Toplam alanı yaklaşık 24.332 km² olan havza, ülkenin toplam alanının %3,11'ine tekabül etmektedir. Yalnızca Bursa, Balıkesir ve Kütahya illeri havza alanının %98,23'ünü oluşturmaktadır (Orman ve Su İşleri Bakanlığı 2018).



Şekil 2.8. Susurluk Havzası Siyasi Haritası (Orman ve Su İşleri Bakanlığı 2018)

Toplam yağış alanı 22.399 km² olan Susurluk Havzası'nın ortalama yıllık akışı 5,43 km³'tür. Havzada Marmara Bölgesi'ne ait en yüksek dağ Uludağ'dır. Susurluk Havzası güneyinde Şaphane ve Simav dağları; batıda Madra ve Deliçal Dağları; doğuda Murat, Gümeş, Yirce ve Uludağ, kuzeyde ise Karadağ ve Mudanya Tepeleri ile Marmara Denizi ile çevrilidir (Orman ve Su İşleri Bakanlığı 2018).

Havzada su potansiyeli yılda 6,08 x 10⁹ m³ olarak belirtilmiş olup, Türkiye'nin önemli göllerinden Uluabat ve Manyas Gölleri'ni içerisinde bulundurmaktadır. Nilüfer Çayı, Mustafakemalpaşa Çayı, Simav Çayı, Kocaçay, Orhaneli Çayı gibi akarsulara sahiptir. Havza, bulunduğu yer nedeniyle özel bir iklime sahiptir. Akdeniz ve Karadeniz iklimleri arasında bir iklim mevcut olup, kış dönemleri aşırı soğuk geçmez. Havzada meydana gelmektedir (Orman ve Su İşleri Bakanlığı 2018).

Yağış özelliklerine bakıldığında, yıllık yağış miktarı 40 mm ile 65 mm aralığında olup, kış mevsimlerinde bu miktar artış göstermektedir. Buna karşılık, yaz mevsimlerinde yağışlar çok aşağı seviyelere düşmektedir. Aralık, Ocak ve Şubat aylarında yağış miktarı yükselir. Haziran, Temmuz ve Ağustos aylarında ise azalır. En şiddetli yağış alan yer Simav Bölgesidir. Havzanın yağışları kapsadığı alan 2 milyon hektarı aşmaktadır. Havza içindeki akarsular Marmara Denizi ile Uluabat ve Manyas göllerine dökülmektedir (Orman ve Su İşleri Bakanlığı 2018).

2.3 Yüzey akışı (Runoff)

Yüzey akışı, yağış veya sulama sularının yüzey veya yeraltı akışı şeklinde bir alanı terk eden kısımdır. Toprak yüzeyine ulaşan yağış şiddeti infiltrasyon kapasitesinden az olduğunda, suyun tamamı toprak tarafından emilir. Yağmur devam ettikçe, toprak doymun hale gelir ve sızma kapasitesi azalır. Toprak yüzeyindeki sığ çöküntüler suyla dolmaya başlar, ardından yerüstündeki fazla akış, yüzey akışı olarak devam eder (Vinogradov 2006; Balasubramanian 2010).



Şekil. 2.9. Yüzeysel akışın meydana gelişi (Anonim 2018)

2.3.1 Yüzeysel akışın oluşumu

Yağmur devam ederken, zemin yüzeyine ulaşan su, yağış hızının (yoğunluğunun) toprağın sızma kapasitesini aştığı bir aşamaya gelinceye kadar toprağa sızmaktadır. Bundan sonra, yüzeysel su birikintileri, hendekler ve diğer çukurlar suyla dolar ve yüzeysel akış olarak kara akışını meydana getirir. Akış oluşum süreci, yağış yoğunluğu toprağın gerçek sızma kapasitesini aştığı sürece devam eder, ancak yağış hızı gerçek sızma hızının altına düştüğünde akış durur (Vinogradov 2006; Balasubramanian 2010).

2.3.2 Yüzeysel akış türleri

- Yüzeysel akış: Yağıştan hemen sonra dereye giren yağış miktarıdır. Tüm kayıplar karşılandığında ve yağış devam ederken, yağış oranı (şiddeti) sızma oranından daha büyük olduğunda meydana gelmektedir.
- Yeraltı akışı (runoff): Yağışların ilk önce toprağa sızan ve su tablasına, dereye, nehirlerle veya okyanusa katılmadan yanal olarak hareket eden kısmı, yüzeysel akış olarak bilinir. Genellikle ara akış olarak da adlandırılmaktadır.
- Taban akışı (runoff): Yağışın yere düştükten sonra toprağa sızarak su tablasıyla buluşup derelere, okyanusa vb. akmasını sağlayan kısmı olarak tanımlanan uzun

sürekli akıştır. Suyun buradaki hareketi çok yavaştır. Bu nedenle gecikmeli bir yüzey akışı olarak da adlandırılmaktadır (Vinogradov 2006; Balasubramanian 2010).

2.3.3 Yüzey akışını (runoff) kontrol eden faktörler

Herhangi bir akış iki ana faktör grubu tarafından belirlenir. İlk grup, drenaj havzasının jeomorfolojik faktörleridir. İkinci grup ise iklim değişkenlerine bağlıdır.

– Meteorolojik faktörler:

- Yağış türü (yağmur, kar, sulu kar, vb.)
- Yağış yoğunluğu
- Yağış miktarı
- Yağış süresi
- Yağışların havzalara dağılımı
- Fırtına hareketinin yönü
- Önceki yağış ve bunun sonucunda oluşan toprak nemi
- Sıcaklık, rüzgar, bağıl nem ve mevsim gibi diğer meteorolojik ve iklimsel koşullar evapotranspirasyonu etkiler.

– Fiziksel faktörler:

- Arazi kullanımı
- Bitki örtüsü
- Toprak tipi
- Drenaj bölgesi
- Havza şekli
- Yükseklik
- Eğim
- Topografya
- Yönlendirme yönü
- Drenaj ağı modelleri

- Havzadaki akışın mansapta devam etmesini engelleyen veya değiştiren göletler, göller, rezervuarlar, lavabolar vb.

Jeomorfolojik faktörler arasında arazi kullanımı arazi örtüsü, toprak tipi, alan, şekil, yükseklik, eğim, bir drenaj ağı ve akış için dolaylı etkiler yer almaktadır (Vinogradov 2006).

2.3.4 Yüzey akışının etkileri

Erozyon ve birikme: Akışlar toprak yüzeyinin aşınmasına neden olabilir; aşınmış malzeme oldukça uzakta birikebilir. Su kaynaklı erozyon, yamaçlardaki en önemli jeomorfolojik süreçlerden biridir. Erozyon üç aşamadan oluşur: partikül ayrılması, taşınması ve birikmesi. Oluk erozyonu, bir sıçrama, tabaka yıkama ve delinme-yıkamanın (delikler arası ve rill erozyonu) toplu etkisiyle meydana gelir. Bu erozyon süreçleri hem tortu üretimi hem de tortu taşınması üzerinde büyük bir etkiye sahiptir. Yağış, akış, erozyon ve tortu taşınımı arasındaki ilişki oldukça değişkendir. Aralarındaki ilişki, nihayetinde su ve tortu verimini kontrol edecek olan arazi kullanımı değişiklikleri ve iklim salınımlarından etkilenebilir.

Akışlar taşkınların meydana gelmesine katkıda bulunur. Bir suyolu akıntı yönünde akan akış miktarını iletmediğinde, sel meydana gelir. Seller toplumlara hem faydalı olabilir hem de zarar verebilir.

Akışlarla ilişkili başlıca çevresel sorunlar, su kirleticilerinin bu sistemlere taşınması yoluyla yüzey suyuna, yeraltı suyuna ve toprağa olan etkilerdir.

Tarım Üzerindeki Etkiler: Erozyon tarımsal kimyasalların (Nitratlar, Fosfatlar, Pestisitler, Herbisitler vb.) akış yoluyla taşınması neden olur. Ortaya çıkan kirlenmiş akış, yalnızca tarımsal kimyasalların israfını değil, aynı zamanda aşağı havzadaki ekosistemler için çevresel bir tehdidi de temsil etmektedir (Vinogradov 2006; Balasubramanian 2010; Viessman 2010).

2.3.5 Yıllık yüzey akış miktarı

Bir yıl gibi belirli bir dönemde bir akarsudan beklenebilecek toplam su miktarına akarsu verimi denir. Verimin bir yıllık dönemi yansıması uygundur ve daha sonraki yılın akış

hacmi hakkında fikir verir. Verim terimi, aksi belirtilmedikçe yıllık akış hacmini ifade etmek için de kullanılır. Tüm su kaynaklarının geliştirme çalışmalarında, verimin hesaplanması büyük öneme sahiptir. Verim tahmini için kullanılan çeşitli yöntemler aşağıdaki gibi sıralanabilir (Balasubramanian 2010):

- Akarsu akışı ve yağış korelasyonu,
- Ampirik denklemler,
- Havza simülasyonları.

2.3.6 Yüzey akışının önemi

Karalar ve denizler için doğrudan girdi olarak tanımlanan su kaynakları yağışlardır. Ana çıktı kaynakları ise buharlaşma, terleme, süblimleşme ve durdurmadır. Yeraltı suyu, yüzeysel su kütleleriyle (bulunabildiği tüm formlarda) birlikte bir su dengesi dahlindedir. Bu bileşenler, su dengesi denklemi olarak adlandırılan basit bir kütle dengesi denklemi kullanılarak analiz edilebilir. Bu denklem, tatlı ve tuzlu suyun giriş, çıkış ve depolama rezervuarlarındaki değişiklikleri dikkate almaktadır (Vinogradov 2006; Balasubramanian 2010).

2.2.7 Yüzey akışı ve su kalitesi

Ormanlık havzalardaki yağışın önemli bir kısmı toprak tarafından emilmekte (sızma), yeraltı suyu olarak depolanıp sızıntılar ve pınarlar yoluyla yavaş yavaş akarsulara boşaltılmaktadır. Ayrıca, kanalizasyon rögarları hemen hemen tüm sokaklarda yaygın olarak kullanılmaktadır. Fırtına akıntıları bu drenler tarafından toplanır ve su boruları vasıtasıyla en yakın yüzey suyuna iletilir. Kanalizasyon rögarları fırtına sırasında buldukları sokaklardaki su baskınını önlemeye yardımcı olmaktadır. Tarım arazilerinden (ve hatta kendi bahçelerimizden) gelen akış, azot ve fosfor gibi fazla besin maddelerini derelere, göllere ve yeraltı su kaynaklarına taşıyabilir. Fazla miktarda taşınan bu besin maddeleri su kalitesini düşürme potansiyeline sahiptir (Vinogradov 2006; Balasubramanian 2010; Viessman 2010).

2.4 Hidrolojik Modellemelerde Yapay Sinir Ağlarının (YSA) Kullanılması

Yağış ve yüzey akışı arasındaki ilişkiyi belirlemek, hidrologların ve çevre mühendislerin karşılaştığı en önemli problemlerden biridir. Bu ilişkinin pek doğrusal olmayıp kompleks bir yapıya olduğu bilinmektedir. Hidroloji/Çevre Mühendisliği tasarımı ve yönetimi amaçlarının yerine getirilebilmesi için yağış ve yüzey akışı hakkında bilgi sahibi olunması gereklidir. Yüzey akışı daha önce de belirtildiği gibi yağışa ilaveten toprak nemi, arazi kullanımı, havza jeomorfolojisi, buharlaşma, sızma, dağılım, yağış süresi gibi pek çok faktöre bağlıdır. Her ne kadar birçok su havzasında akış kayıtlarını saklamak için sürekli ölçümler yapılmış olsa da konuyla ilgili çalışan mühendisler çok az veri olması veya hiç olmaması gibi durumlarla da karşı karşıya kalabilmektedir. Bu gibi durumlarda, sanal (*synthetic*) akışlar oluşturmak için simülasyon modelleri sıklıkla kullanılmaktadır (ASCE b 2000).

1999 ile 2007 arasında su kaynakları ile ilgili 210 makale incelenmiştir. Bu incelemede, YSA model geliştirme süreci bileşenlerine ayrılmış, örnek olarak, girdi değişkeni seçme yöntemleri, veri bölme yöntemleri, YSA türü, eğitim algoritması türü vb. açısından çalışmalar ele alınmış, model geliştirmede hangi tür yöntemlerin kullanıldığını belirlemek için sistematik olarak makaleler değerlendirilmiştir. Bu değerlendirmeye göre, 210 araştırmadan 178'inin (veya kabaca %85'inin) bir ÇKA kullandığı bulunmuştur. Kullanılan YSA yöntemleri ve çeşitleri arasında Radyal Temel Fonksiyon Ağları (RTFA), Tekrarlayan Sinir Ağları (TSA lar) ve Kendi Kendini Organize Eden Haritalar (KOE H) bulunmaktadır (Maier, Jain, Dandy ve Sudheer. 2010).

2.4.1 Hidrolojik modellemede yapay sinir ağlarının avantaj ve dezavantajları

YSA lar bilgi işleme yeteneklerinin yanı sıra verilerden öğrenme ve başa çıkmanın kolay olmadığı durumlara genelleme yapma becerilerine de sahiptir. Ek olarak, ağın kolektif gücü çok sayıda ve kompleks görevlerin verimli bir şekilde uygulanmasına izin vermektedir (Napolitano vd. 2010; Reilly ve Cooper 1995). Hidrolojik modellemeye ilişkin YSA ların avantajları ve dezavantajları aşağıdaki şekilde listelenmiştir

– Avantajları

Doğrusal olmama

Girdi / çıktı ilişkilerini modelleyebilme

Uyarlanabilirlik

Hızlı kurulabilmesi

Hesaplama açısından verimli

Modülerlik.

– Dezavantajları

Verilerdeki dalgalanma (daha az duyarlıdır)

Black-Box Yapısı (en büyük dezavantajdır)

Hjelmfelt ve Wang (1993) birim hidrograf teorisine dayanan bir sinir ağı geliştirmiştir. Çalışmada bir su havzası için kompozit akış hidrografi, doğrusal süperpozisyon kullanılarak, birim hidrograf koordinatlarının ve akış fazlalıklarının uygun bir şekilde toplanmasıyla geliştirilmiştir. Bunu bir sinir ağı çerçevesinde uygulamak içingiriş ve gizli katmandaki birim sayıları aynı tutulmuştur. Bağlantılar yalnızca ilk iki katmandaki karşılıklı gelen çiftler arasında mevcut olup, birinci katmandaki *i*. düğüm, ağırlıkların bir değerine ayarlanmasıyla yalnızca ikinci katmandaki *i*. düğüme bağlanmıştır. Gizli katmandaki düğümler, akışı temsil eden tek çıkış düğümü ile tamamen bağlanmıştır. YSA'nın girdileri yağış dizileridir. Eşik fonksiyonu yerine, gizli katman için yağış *f*-indeksine karşılık gelen bir rampa transfer fonksiyonu kullanılmıştır. Gizli katman, yağış verilerinden sızıntı değerlerini çıkarmış olup, elde edilen sonuçlar akış değerleridir. Çıktı katmanı, yağış fazlalıklarının ağırlıklı toplamını hesaplamıştır. YSA'nın öğrenimi ve testi için, Missouri'nin merkezindeki Goodwater Creek havzasından (12,2 km²) 24 şiddetli fırtına olayından elde edilen yağış ve akış verileri seçilmiştir. Ortaya çıkan ağın, birim hidrografi, standart gama fonksiyonu gösterimi ile elde edilenden daha iyi oluşturduğu gösterilmiştir. Daha sonra yapılan başka bir çalışmada, Hjelmfelt ve Wang (1996) bu yöntemi geri yayımlı normal üç katmanlı bir yapay ağ ile karşılaştırmıştır. Araştırmacılar, normal bir ağın birim hidrografının çok iyi

bir şekilde yeniden üretemeyeceği, aynı zamanda yapısının dalgalanmaya birim hidrograf hesaplamaları için uygun olan bir ağdan daha duyarlı olduğu sonucuna varmışlardır (ASCE b 2000; Hjelmfelt ve Wang 1993; Hjelmfelt ve Wang 1996).

Shamseldin (2010) Sudan'da Mavi Nil Nehri'nde 4 yıllık periyottaki yağış-yüzey akışı bilgileri için 4 adet model ve gerçek zamanlı nehir tahmini geliştirmiştir. Çalışmadan elde edilen sonuçlar, sinir ağı modellerinin önemli bir potansiyele sahip olduğunu ve gelişmekte olan ülkelerde nehir akış tahmini için alternatif bir yaklaşım olarak kullanılmasının ümit verici olduğunu göstermiştir. Kullanılan dört modelin ortak özelliği ÇKA yapısına dayalı olmalarıdır. Bu modeller, model tarafından kullanılan harici girişler açısından farklılık göstermiştir. Dört model, yağış endeksini ortak bir harici giriş olarak kullanmaktadır. İlk model (YSA1) yalnızca bu ortak harici girişi kullanmıştır. Modellerden ikisi (YSA2 ve YSA3) ek dış girdi bilgisi olarak ya mevsimsel beklenti yağış endeksini ya da deşarjın mevsimsel beklentisini kullanmıştır. Dördüncü model (YSA4) ek dış girdi bilgisi olarak hem mevsimsel beklenti yağış endeksini hem de deşarjın mevsimsel beklentisini kullanmıştır. Sonuçlar, YSA4 modelinin araştırmacıların çalışmasında geliştirilen dört model arasında en iyi performansa (R^2 değerleri) sahip olduğunu ortaya çıkarmıştır.

Çizelge 2.2 Dört YSA modelinin R^2 verimlilik değerleri (Shamseldin 2010)

	$(R^2 \%)$			
	YSA1	YSA2	YSA3	YSA4
Öğrenme Periyodu	82,98	83,7	91,18	93,64
Analiz Edilen Periyot	72,32	78,04	85,27	87,21

Başka bir çalışmada (Ren, Liu, Niu, Lei ve Zhang. 2020), Çin'de bir Su Yönlendirme Projesi örnek alınarak kademeli kanalların gerçek zamanlı su seviyesi tahmini yapılmıştır. Yüksek tahmin doğruluğu ile 2/4/6 saat ilerideki kademeli kanallar için su seviyesi tahmin modellerinin oluşturulması için, iki tür sinir ağı kullanılmıştır.

İlk olarak, kademeli kanalların ham hidrolojik verileri, yüksek boyutlu özelliklere sahip veri setleri üreten uzamsal ve zamansal pencereler kullanılarak çoğaltılmıştır. Daha

sonra, zamansal boyuttaki çoklu veri kayıtları ve uzaysal boyuttaki çoklu kanallar arasındaki mutlak korelasyonu içeren çoğaltılmış veri yardımı ile, ÇKA ve TSA yöntemleri su seviyesi tahmin modelini kurmak için kullanılmıştır. Oluşturulan modeller deneysel sonuçlar ile Destek Vektör Makinesi'nin (DVM), Kök Ortalama Kare Hatası (KOKH), Ortalama Mutlak Hata (OMH), Pearson Korelasyon Katsayısı (r) ve Nash 'Sutcliffe Verimliliği (NSV) değerlerine göre üstünlüğünü göstermiştir. Tahmin sapmaları 1 cm, 2 cm ve 3 cm'den küçük olan bu modellerin doğrulukları sırasıyla %81,36, %94,09 ve %97,05 gibi yüksek değerlere ulaşabilmektedir.

2.5 Su Kalitesi Modellemesinde Yapay Sinir Ağlarının (YSA) Kullanımı

Son yıllarda YSA'lar su kalitesi modellemesi alanında bir dizi uygulama alanı bulmuştur. Su kalitesi pek çok faktörden ve belirli parametrelerden etkilenir. Bu tür değişkenlerin tahmini genellikle kompleks bir problemdir, parametreler arasında doğrusal bir ilişki bulunmaz; bu durum da YSA uygulamasını uygun kılmaktadır (ASCE 2000; ASCE b 2000).

Bir çalışmada, haliçlerde yüzme suyu kalitesini ve bu kalitenin zaman ve mekândaki değişkenliğini analiz etmek için prosese dayalı modellerin emülatörleri olarak YSA geliştirmiştir. Metodoloji, saha ölçümlerinin, süreç tabanlı modellemenin uzamsal ve zamansal çözünürlüğünü, sonuçların doğruluğunu ve hesaplama maliyetlerindeki düşüşünü entegre ederken, yapay sinir ağları sonuçların doğruluğunu ve güvenilirliğini koruyarak dışkı indikatörü organizmaların konsantrasyonunu tahmin etmektedir. Bu nedenle genel yaklaşım olarak, prosese dayalı model çıktıları tarafından eğitilen yapay sinir ağlarını kullanarak, yüzme alanlarının verileriyle önceden kalibre edilip birleştirilmiş hidrodinamik bakteriyolojik model, düşük dereceli bir emülatöre entegre edilmiştir (García-Alba, Bárcena, Ugarteburu ve García 2019).

Yürütülen çalışmanın İspanya'nın kuzeybatı kıyısında bulunan *Eo Halici*'ne uygulanması, YSA'nın doğrusallıktan oldukça yoksun, prosese dayalı modelin ve oldukça kritik varyantların uygun bir temsili olduğunu göstermiştir. Elde edilen sonuçlar, prosese dayalı model ve sinir ağları ile *Escherichia coli* (*E. Coli*)

konsantrasyonlarının ölçümlerinin uyumlu olduğunu, model için ($R^2 = 0,87$) sinir ağlarından ($R^2 = 0,83$) biraz daha fazla korelasyona sahip olduğunu göstermiştir. Bunun sonunda, her iki tahmin yönteminin model kurulumu sırasında, süreç tabanlı yaklaşımın hesaplama süresinin, YSA yaklaşımından 0,78 kat daha kısa olduğu görülmüştür. Çünkü YSA'nın geliştirilmesi için ek süreye ihtiyaç duyulmaktadır. Tersine, tahmin etmenin hesaplama maliyetleri, prosese dayalı modele kıyasla sinir ağları tarafından önemli ölçüde azaltılır ve 1 saat, 1 gün, 1 ay ve 1 yüzme sezonu tahminlerinde sırasıyla saatte 25, 600, 3900 ve 31633 kez azalma olur (García-Alba vd. 2019).

Salari vd. (2018) yaptıkları çalışmada nehir suyu kalitesi verilerini simüle etmeye çalışmışlardır. Çözünmüş oksijen ($ÇO$), toplam çözünmüş katı ($ÇTK$), toplam sertlik (TS), alkalilik (ALK) ve bulanıklık, elektrik iletkenliği (EC), sıcaklık (T) ve pH. gibi parametreler yardımı ile tahmin edilmiştir. Neredeyse hiçbir maliyet olmadan kolayca ölçüm gerçekleştirilmiştir. Simüle edilmiş su kalitesi parametreleri, matematiksel ve YSA olmak üzere iki modelleme yöntemi ile incelenmiştir. Matematiksel yöntemler, en küçük kareler yöntemi ile polinom yordamaya dayalıdır. YSA modelleme algoritmaları ise ileri beslemeli ağlardır. Sonuçlar, YSA modellemesinin tuzluluk testi için güvenilir bir alternatif olduğunu göstermiştir. Bu yöntem ayrıca eksik verilerin tahmin edilmesi ve ölçüm araçlarının kalibrasyonu için uygun bir yöntemdir. Çalışmada ek olarak bilimsel uygulamalar için model bazında üretilen veriler üzerinde duyarlılık analizleri yapabileme becerisinin olduğu ve deneysel zorlukların olduğu koşullarda bu yöntemin uygun olduğu vurgulanmıştır. Su kalitesi parametrelerini simüle etmek için geliştirilen tüm optimum YSA modelleri, 0,99'a yakın R değeri ile yüksek doğruluk seviyesine sahiptir. YSA modeli, alkaliliği simüle etmek için genişletilmiştir ve R değeri 0,82'ye eşittir (Salari vd. 2018).

3. MATERYAL ve YÖNTEM

3.1 Çalışma Alanı

Çalışma alanı olarak Susurluk Havzası'na bağlı Orhaneli Çayı seçilmiştir. Türkiye'deki 25 havzadan biri olan Susurluk Havzası, Türkiye'nin batısında 27° - 30° doğu boylamları ile 39° - 40° kuzey enlemleri arasında yer almaktadır. Havzanın toplam yüzölçümü, tüm havzaların yaklaşık %3,11'i kadardır ve Türkiye yüzölçümünün 24.332 km²'sine tekabül eder. Susurluk Havzası'nın toplam yağış alanı 22.399 km², yıllık ortalama debisi ise 5,43 km³/yıl'dır. Yıllık ortalama 7,2 L/s/km³ verimle havzada potansiyel yağış oranı %2,9'dur (Orman ve Su İşleri Bakanlığı 2018).

Susurluk Havzası, Akdeniz ve Karadeniz iklimleri arasında bir geçiş iklim tipine sahiptir. Kışların çok sert geçmediği havzada yaz aylarında kuraklık görülebilmektedir. Yıllık toplam yağışın büyük çoğunluğu kışın düşmektedir. Marmara Denizi'nin kıyı kesimlerinde kar yağışı ve don olayı nadir görülmekle birlikte, Uludağ dağı gibi yüksek rakımlı bölgelerde kışlar karlı ve soğuk geçer

Orhaneli Çayı, Kütahya ilinin Gediz ilçesinden doğar ve Mustafakemalpaşa ilçesine 20 km kala Çamandar Köyü'nde Bursa İli içinden geçer. Mustafakemalpaşa Çayı'nın batı kolu olan Emet Çayı'na katılır ve Mustafakemalpaşa Çayı adını alır, ardından Uluabat Gölü'ne dökülür. Bursa İli sınırları içerisinde 104 km uzunluğundadır (Orman ve Su İşleri Bakanlığı 2018).



Şekil 3.1. Orhanlı Nehri ve nehir boyunca dere akışı izleme, nehir seviyesi ve yağmur ölçüm istasyonlarının konumu (Orman ve Su İşleri Bakanlığı 2018)

3.2 Nehir Akış Kayıtları

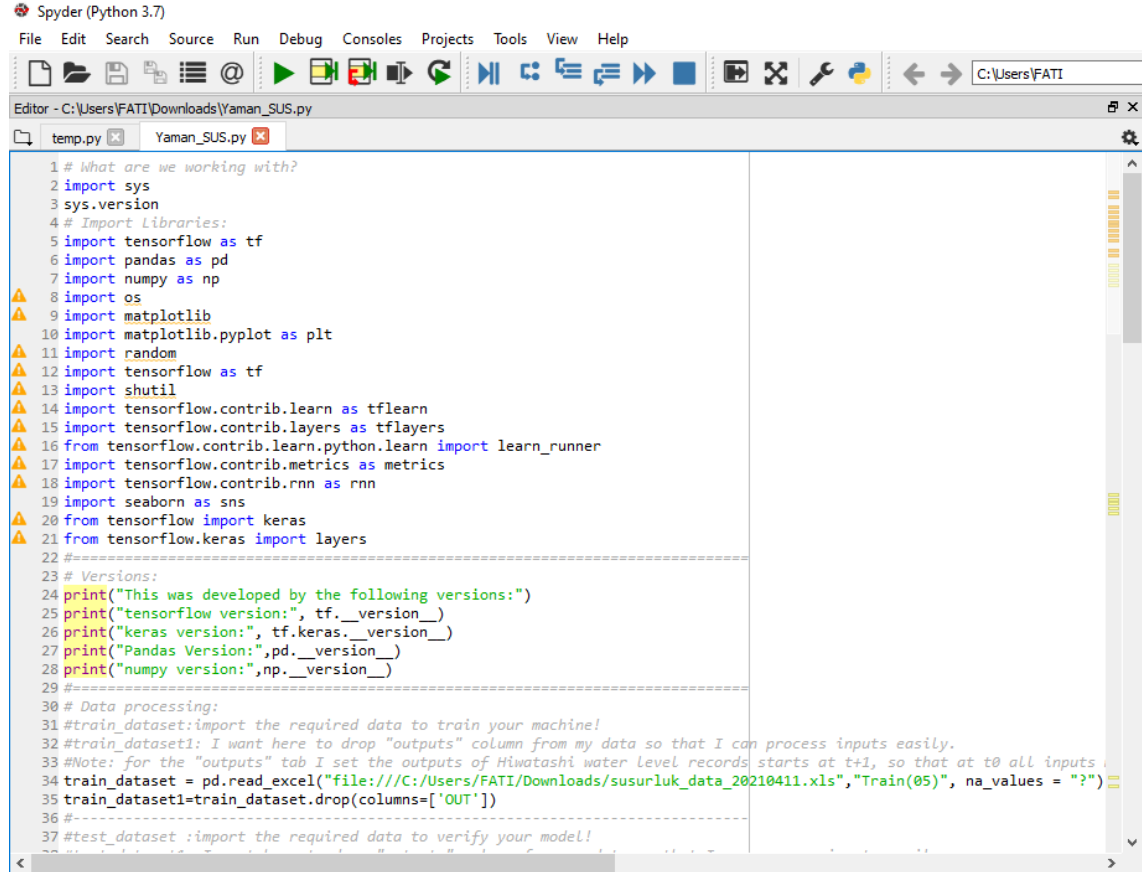
Bu çalışmada Orhanlı Çayı'nın memba konumuna odaklanılmıştır. Şekil 3.1'te belirtildiği üzere akış yönü üzerinde 3 istasyon belirlenmiştir. Bunlar sırasıyla Akçasehir İstasyonu, Esatlar İstasyonu ve Dağgüney İstasyonudur. Nehir akımını tahmin etmek için hedef istasyon olarak Dağgüney ölçüm istasyonu seçilmiştir. Aslında Dağgüney istasyonunun seçimi için pek çok neden var. İstasyon, Çınarcık barajının akış yönünde yer almakta olup en az veri kaydına sahip olan istasyondur. Çizelge 3.1 bu çalışmada ele alınan istasyonları listelenmektedir.

Çizelge 3.1. Orhanlı nehri üzerinde bulunan gözlem istasyonları

Nehir/Çay Adı	İstasyon	İstasyon No
Orhanlı Çayı	Esatlar	12003083
	Akçasehir	12003020
	Dağgüney	32003031

Çalışmada kullanılan veriler 1 Ekim 2012 ile 30 Eylül 2015 yılları arasındaki günlük akış kayıtlardan oluşmaktadır. Listelenen istasyonların günlük akış kayıtları, DSI

kayıtlarının nehir bilgi sistemi (Akım Gözlem Yıllığı) veri tabanından elde edilmiştir. Verileri işlemek için, *Python* programlama & modelleme dilini ve *Mathematica* teknik hesaplama programı kullanılmıştır. Tahmin işlemi yapmak için kullanılan modulün bir parçası Şekil 3.2.'de gösterilmiştir.



```
1 # What are we working with?
2 import sys
3 sys.version
4 # Import Libraries:
5 import tensorflow as tf
6 import pandas as pd
7 import numpy as np
8 import os
9 import matplotlib
10 import matplotlib.pyplot as plt
11 import random
12 import tensorflow as tf
13 import shutil
14 import tensorflow.contrib.learn as tflearn
15 import tensorflow.contrib.layers as tflayers
16 from tensorflow.contrib.learn.python.learn import learn_runner
17 import tensorflow.contrib.metrics as metrics
18 import tensorflow.contrib.rnn as rnn
19 import seaborn as sns
20 from tensorflow import keras
21 from tensorflow.keras import layers
22 #-----
23 # Versions:
24 print("This was developed by the following versions:")
25 print("tensorflow version:", tf.__version__)
26 print("keras version:", tf.keras.__version__)
27 print("Pandas Version:", pd.__version__)
28 print("numpy version:", np.__version__)
29 #-----
30 # Data processing:
31 #train_dataset:import the required data to train your machine!
32 #train_dataset1: I want here to drop "outputs" column from my data so that I can process inputs easily.
33 #Note: for the "outputs" tab I set the outputs of Hiwatashi water level records starts at t+1, so that at t0 all inputs .
34 train_dataset = pd.read_excel("file:///C:/Users/FATI/Downloads/susurluk_data_20210411.xls","Train(05)", na_values = "?")
35 train_dataset1=train_dataset.drop(columns=['OUT'])
36 #-----
37 #test_dataset :import the required data to verify your model!
```

Şekil 3.2. Python programında kullanılan modulün ekran görüntüsü.

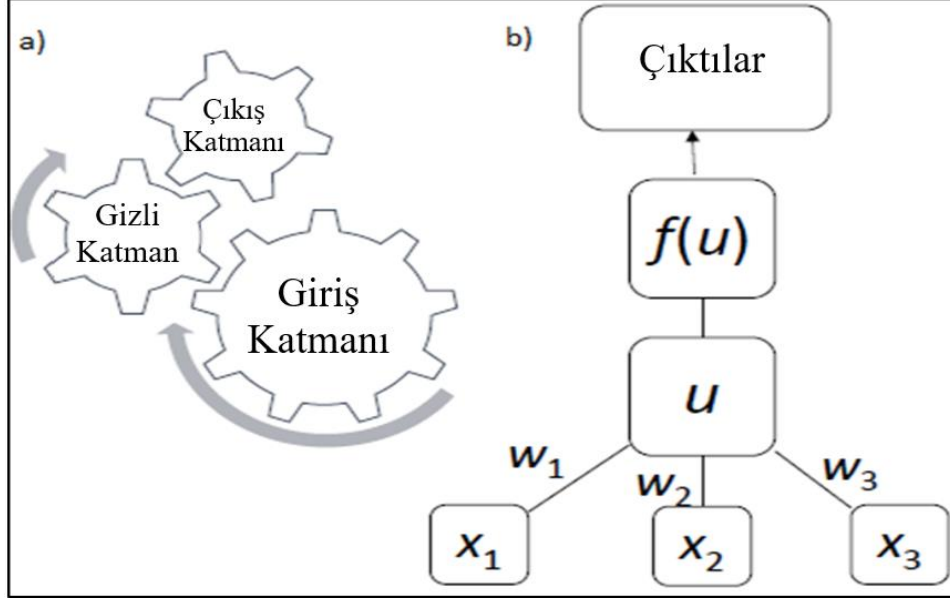
Çizelge 3.2'de Dağgüney istasyonuna ait suyun akış kayıtları göstermektedir. Genel olarak kayıtlar Ekim 'den in 30 Eylül ayına kadardır.

Çizelge 3.2. Su yılın kayıtlarının örneği (DSİ, 2015)

Akımlar 01 Ekim 2014 'den 30 Eylül 2015' a kadar m ³ /sn olarak												
Gün	Ekim	Kasım	Aralık	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül
01	2.52	2.05	1.75	1.75	8.25	4.95	3.22	3.46	4.48	4.38	3.52	2.59
02	2.52	2.05	1.75	1.75	6.29	4.17	3.10	3.22	4.48	4.09	3.66	2.59
03	2.52	2.05	1.75	1.75	19.8	4.05	3.22	3.22	4.48	4.09	3.66	2.59
04	2.52	2.05	1.68	1.68	7.80	4.17	2.98	3.22	4.95	3.81	3.81	2.69
05	2.52	2.05	1.68	1.68	4.95	3.69	2.89	3.22	4.79	3.66	3.52	2.79
06	2.42	1.98	1.68	1.68	3.93	3.34	2.89	3.22	4.64	3.66	3.95	2.39
07	2.42	1.98	1.68	1.83	3.58	3.22	5.73	3.22	4.79	3.52	2.99	2.19
08	2.42	1.98	1.68	2.24	3.22	3.10	8.69	3.69	6.47	3.38	2.79	2.19
09	2.42	1.98	1.62	2.14	3.22	2.89	5.57	3.58	6.13	3.66	2.99	2.19
10	2.42	1.98	1.62	2.33	3.10	2.89	5.73	3.34	5.59	3.66	3.38	2.39
11	2.33	1.98	1.62	2.52	2.89	2.79	5.42	3.34	5.77	3.38	3.23	2.49
12	2.33	1.90	1.62	2.52	2.89	2.79	5.42	3.34	5.59	3.09	2.79	2.49
13	2.33	1.90	1.62	2.52	2.89	2.79	4.95	3.34	5.42	3.23	2.59	2.59
14	2.33	1.90	1.62	2.89	2.89	2.79	4.48	3.34	5.24	3.38	2.59	2.59
15	2.33	1.90	1.62	2.42	2.79	2.89	4.17	3.34	4.70	3.38	3.38	2.59
16	2.24	1.83	1.62	2.24	2.79	2.79	3.93	3.34	4.38	3.38	2.49	2.59
17	2.24	1.83	1.62	2.14	2.70	2.70	3.81	3.46	5.59	3.52	2.49	2.59
18	2.24	1.83	1.62	1.98	2.52	2.61	3.69	3.46	5.24	3.52	2.49	2.59
19	2.24	1.83	1.62	1.90	2.42	2.61	3.58	3.46	5.42	3.52	2.39	2.59
20	2.24	1.90	1.62	1.90	2.42	2.52	3.46	3.58	5.95	3.38	2.39	2.69
21	2.24	1.83	1.62	1.90	2.42	2.61	3.58	3.81	5.42	3.38	2.19	2.69
22	2.14	1.83	1.62	1.90	2.42	2.61	4.64	3.81	5.06	3.38	2.19	2.79
23	2.14	1.83	1.62	1.98	2.42	2.61	5.26	3.81	6.76	3.38	2.19	2.69
24	2.14	1.83	1.62	1.98	4.33	2.52	5.26	3.81	5.77	3.38	2.19	2.59
25	2.14	1.75	1.55	2.14	6.10	2.52	5.11	3.81	4.88	3.52	2.19	2.39
26	2.14	1.75	1.55	2.52	6.29	2.42	5.11	3.81	4.70	3.52	2.29	2.39
27	2.14	1.75	1.55	2.70	5.42	2.52	5.11	4.05	4.88	3.52	2.29	2.29
28	2.05	1.75	1.55	3.93	5.92	3.58	5.11	4.48	7.67	3.66	2.39	2.29
29	2.05	1.75	1.62	4.33	-----	3.93	4.95	4.79	6.76	3.81	2.49	2.39
30	2.05	1.75	1.68	3.81	-----	3.69	4.79	4.95	5.06	3.81	2.59	2.39
31	2.05	-----	1.75	7.21	-----	3.34	-----	4.64	-----	3.52	2.59	-----
Maks.	2.52	2.05	1.75	7.21	19.8	4.95	8.69	4.95	7.67	4.88	4.52	3.81
Min.	2.05	1.75	1.55	1.68	2.42	2.42	2.89	3.22	4.38	3.09	2.19	2.19
Ortalama	2.28	1.89	1.64	2.46	4.52	3.10	4.53	3.65	5.37	3.57	2.80	2.51
LT/SN/Şm2	2.70	2.23	1.94	2.90	5.34	3.66	5.35	4.31	6.34	4.21	3.30	2.96
AKİM mm.	7.23	5.79	5.18	7.78	12.9	8.80	13.9	11.5	16.4	11.3	8.84	7.68
MİL. M3	6.12	4.90	4.39	6.59	10.9	8.30	11.7	9.78	13.9	9.55	7.49	6.51
SU YILI (2015) YILLIK TOPLAM AKİM 100.13 MİLYON M3 118 MM. 3.8 LT/SN/Şm2												

3.3 Tekrarlayan Sinir Ağları Modeli ve Performans Ölçütleri

TSA çeşitli hidrolojik uygulamalarda çok iyi performans gösteren gelişmiş bir YSA türüne verilen isimdir (Kratzert vd. 2018). Şekil 3.2'de TSA'nın basit bir temsili sunulmuştur. Görüldüğü üzere, bir TSA sırasıyla girdi (input), gizli (hidden) ve çıkış (output) katmanlarına sahiptir. Bu çalışmada Hitokoto vd. (2017) tarafından önerilen, aşağıdaki alt bölümlerde gösterilmiş olan notasyon kullanılmıştır



Şekil 3.3. a) TSA'nın basit bir tasviri, b) sinir (nöron) yapısının temsili görünümü

Çalışmada oluşturulan TSA ağı üç katmandan oluşmaktadır:

- i) girdi
- ii) gizli katman
- iii) çıktı katmanı

Şekil 3.3.a'da TSA yapısı Şekil 3.3b'de tek bir nöronun temsili yapısı gösterilmiştir. Her bir sinirde değerlendirilen girdi verisi aşağıdaki şekilde tahmin edilir:

$$u = \sum_{i=1}^{i=k} w_i x_i + \theta_i \quad (3-1)$$

$$z = f(u) \quad (3-2)$$

Burada u bir sinir için tüm girdi verilerinin ağırlıklı toplamı, x girdi vektörü, w ağ ağırlığı, θ yanlılık (bias) ve k girdi verisi sayısıdır. Ayrıca, z bir sinirin çıktı vektörü iken, $f(u)$ aktivasyon fonksiyonudur. Birçok farklı aktivasyon fonksiyonu vardır. Bu çalışmada aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmıştır ve bu fonksiyon şöyle tahmin edilir:

$$f(u) = \frac{1}{1+e^{-u}} \quad (3-3)$$

Sinir ağlarının eğitim sürecinde amaç fonksiyonunun minimum değerinin tahmini için tüm ağ ağırlıklarının yinelemeli optimizasyonu kullanılır. Çalışmada kayıp fonksiyonunu minimize etmek için gradyan iniş algoritması kullanılmıştır. Bu kapsamda, ağırlıklar ve bias'lar eğitim sürecinde değiştirilmiştir. Bu nedenle kayıp

gradyanına göre ağırlıkların ve önyargıların ne dereceye kadar ayarlanması gerektiğini öğrenme oranının belirlediğinden bahsetmek çok önemlidir. Tablo 3.3'de bu çalışmada kullandığımız TSA modelinin ana konfigürasyonu sunulmuştur.

Çizelge 3.3. Bu çalışmanın TSA modelinin özeti

Özellik	Seçilen ayar
Katman sayısı	3 (Girdi, gizli, ve çıktı)
Optimizasyon algoritmaları	Geri Yayılımlı Gradyan İniş
Öğrenme oranı	0,1
Dropout	0,2
Girdi sayısı	32
Çıktı sayısı	1
İterasyon sayısı	50.000
Eğitim yüzdesi	%60
Tahmin yüzdesi	%40
Batch büyüklüğü	30

Şekil 3.4'te modele sağlanan veri setinin sekans girdisi gösterilmiştir. Çalışılan alanda verinin az olması nedeniyle, öğrenme sürecini güçlendirmek amacıyla yukarı akış verileri ustaca kullanılmıştır. Bu kapsamda, bir hedef zamanda, mesela D0'da (ilk gün), girdi veri seti Akçaşehir, Esatlar ve Dağgüney'de gözlemlenen 7 günlük akış okumalarından oluşmuştur. Ayrıca, yukarıda belirtilen istasyonlarda gözlemlenen 7 günlük okumaların maksimum, minimum ve ortalama değerleri tahmin edilmiş ve girdi olarak kullanılmıştır. Benzer şekilde, D1 zamanında (ikinci günde) girdi penceresi bir adım ileri kaydırılmış ve bu durum sonraki zaman adımları için de böyle tekrar etmiştir.

		Akcasehir St.										
		D-7	D-6	D-5	D-4	D-3	D-2	D-1	D0	D1		
...	...	1.25	1.25	1.36	1.25	1.25	1.25	1.36	1.36	8.34
From D-7 to D0: Max, Mean, Min												
From D-6 to D1: Max, Mean, Min												
		Esatlar St.										
		D-7	D-6	D-5	D-4	D-3	D-2	D-1	D0	D1		
...	...	4.64	4.01	9.05	8.82	8.34	8.1	7.87	7.87	1.36
From D-7 to D0: Max, Mean, Min												
From D-6 to D1: Max, Mean, Min												
		Daggüney St.										
		D-7	D-6	D-5	D-4	D-3	D-2	D-1	D0	D1		
...	...	6.73	7.4	7.63	7.85	7.85	7.85	8.33	8.08	8.75
From D-7 to D1: Max, Mean, Min												
From D-6 to D0: Max, Mean, Min												

Şekil 3.4. Her bir zaman adımındaki girdi dizisinin yapısı

TSA modeli tarafından üretilen, tahmin edilen akışların performansı ($F_{orecasted}$) aşağıdaki ölçekler kullanılarak Dağgüney'deki gerçek nehir akış kayıtları (A_{ctual}) ile karşılaştırılmıştır:

- 1) Ortalama KareKök Sapması (OKKS):

$$= \sqrt{\frac{\sum(Q_{Tahmini} - Q_{Gerçek})^2}{n}} \quad (3-4)$$

- 2) Nash–Sutcliffe Verimliliği (NSV) değeri (Nash ve Sutcliffe 1970):

Hidrolojik modellerin tahmin gücünü değerlendirmek için kullanılır. NSV değeri $-\infty$ ile 1 arasında değişir ve 1'e yaklaştıkça doğruluğu artar:

$$NSV = 1 - \frac{\sum_{i=1}^n (Q_{Gerçek} - Q_{Tahmini})^2}{\sum_{i=1}^n (Q_{Gerçek} - \bar{Q}_{Gerçek})^2} \quad (3-5)$$

Günlük, aylık veya yıllık hidrolojik analizlerde (deşarj veya akış) NSV değeri Çizelge 3.4'te verilen değerlendirme kriterleri dikkate alınmaktadır:

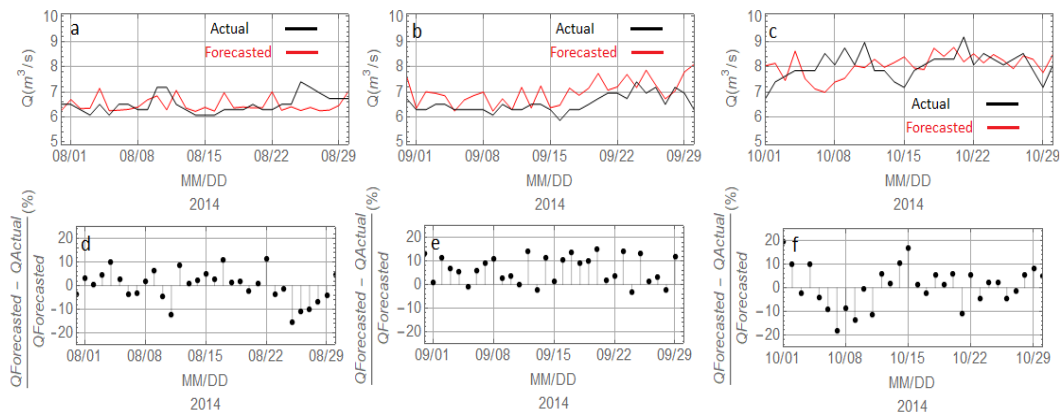
Çizelge 3.4. Nash–Sutcliffe değerlendirme aralıkları

Yetersiz	Yeterli	İyi	Çok iyi
$NSV \leq 0.50$	$0.50 < NSE \leq 0.70$	$0.70 < NSE \leq 0.80$	$NSE > 0.80$

4. BULGULAR ve TARTIŞMA

Seçilen istasyonlardan alınan verilerin TSA tahminlerinin performansının daha iyi anlaşılabilmesi için tahminler i) düşük-akış periyodu, ii) orta-akış periyodu ve iii) yüksek-akış periyodu olmak üzere üç ana periyoda ayrılmıştır.


Şekil 4.1'de (a, b, c), gözlemlenen gerçek deşarj değerlerine (siyah) kıyasla düşük akış sırasındaki tahmin sonuçları (kırmızı) verilmiştir. Her bir kutu, bir ay içindeki günlük akış tahmini değerlerini göstermektedir. Yapılan bu çalışmada oluşturulan model tarafından tahmin edilen değerlerin gözlemlenen gerçek değerlerle genel anlamda uyum içinde olduğu görülmüştür. Şekil 4.1.a'da görüldüğü gibi, Ağustos ayında 01/08 - 15/08 günleri arasında tahmin edilen ve ölçülen gerçek debi değerleri benzerlik gösterirken, diğer haftalarda değerlerde uyum bulunmamaktadır Şekil 4.1.b incelendiğinde, neredeyse tüm debi değerlerinin birbirlerinden farklı olduğu görülmektedir. Şekil 4.1.c'de ise, Ekim ayının 15'ine kadar gerçek ve tahmin değerlerinde farklılık varken, 15'inden sonra değerler yavaşça uyum sağlamaya başlamıştır. Bazı farklılıklar olmakla beraber, genel anlamda tahmini ve ölçülen değerlerin yakın olduğu söylenebilir. Olağanüstü koşullarda meydana gelen olaylar için yapılan tahmini göreceli hatalar, çok iyi olarak kabul edilebilecek bir oranda, yaklaşık %15'lik bir belirsizlik yüzdesiyle son derece düşük bulunmuştur.



Şekil 4.1. Düşük akış dönemlerinde (a, b, c) gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminler gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığında göreceli hatalar

Şekil 4.1. (d,e,f) grafiklerinde görelî hatalar verilmekte olup, görelî hatalar -20 ila 20 aralığında deęişmektedir. Grafiklerde farklı tarihlerde gözlenen zıtlıkların ve tahmini görelî hatalarda oluşan sapmaların modelde sadece akış kayıtlarının kullanılmasından kaynaklandığı, sıcaklık, buharlaşma ve yağış gibi modele etki edebilecek faktörlerin bulunmamasının bu duruma neden olabileceği düşünölmektedir. Ayrıca, kayıtların alındığı dönemdeki meteoroloji raporlarına göre, 2014 yılında yaz ile sonbahar mevsimlerinde neredeyse yurdun genelinde sıcaklığın normalden fazla artış gösterdiği gözlemlenmiştir. Sıcaklık artışıyla orantılı olarak buharlaşma etkisi artmış, bunun sonucunda da su miktarı etkilenmiş olup, beklenen ile gerçekleşen akış miktarları farklı bulunmuştur (Anonim 2015).

Şekil 4.2 (a, b) orta seviyede nehir akış dönemlerindeki tahminleri, Şekil 4.2c ise yüksek seviyede akışlı dönemlerdeki tahmin sonuçlarını göstermektedir. Elde edilen verilere göre, orta ve yüksek akış periyotlarında tahmin deęerlerinin gerçek gözlemlerle karşılaştırılabilir düzeyde olduğu görölmektedir. Ayrıca, ortaya çıkan olayların nispi hatalarının yaklaşık %25-30 olarak tahmin edilebileceği görölmüştür. Yağış, hava durumu deęişkenleri ve havza parametreleri gibi ilgili verilerin azlığı göz önüne alındığında, bu deęerin yine de kabul edilebilir olduğu düşünölmektedir.




Şekil 4.2. Orta akış (a, b) ve yüksek akış (c) dönemlerinde gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminler gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığında görelî fark.

Şekil 4.2. a, b ve c'de görüldüğü gibi, tahmin değerleri ile gerçek değerler arasında genel anlamda bir uyum olmasına rağmen, eğriler karşılaştırıldığında çoğu noktada zıtlıkların olduğu ve eğrilerin uyumlu olmadığı görülmektedir. a ve b grafiklerinde gerçek değerler ve tahmin değerleri 1 Nisan'dan 13 Mayıs'a kadar gösterilmiştir. Elde edilen grafiklere göre, değerler birbirinden farklıdır ve uyum göstermemektedir. Bunun sebebi 2015 yılında yaşanan sıcaklık artışı, özellikle de kış mevsiminde sıcaklıkların normalden 1,7 °C daha yüksek olmasıdır (Anonim 2016).


Grafik c'de 01/03'tan 15/03'a kadar değerlerin çok yakın olduğu ve uyum sağladıkları görülebilir. Daha sonra, 29/03 ve sonrasında (grafiğin gösterdiği gibi), değerler arasındaki fark yavaşça artmaktadır.

Şekil 4.3, tahminler arasında mantıklı ve bütünsel bir bağlantı kurulabilmesi için gerçek akış ile model ile tahmin edilen akış arasındaki doğrusal ilişkiyi göstermektedir. Şekil incelendiğinde, gerçek ve tahmini değerlerin düşük akışlar sırasında birbirleriyle güçlü bir şekilde ilişkili olduğu, yüksek akışlar sırasında ise iyi bir korelasyona sahip olduğu görülmektedir. Lineer regresyon modelinin R^2 'si 0,88 ve P-değeri² 1.370×10^{-12} bulunmuş olup, bunlar oldukça iyi değerlerdir. Dolayısıyla model bu kullanım amacı için tatmin edici görünmektedir. Ayrıca, tüm tahmini akışlar ve tüm gerçek kayıtlar için tahmini KOKH değerleri sırasıyla 14,7 m³/s ve 15,59 m³/s olarak bulunmuştur. Benzer şekilde, tahmin modeli için NSV-değeri 0,871 (NSV: 0~1 arasında) olarak bulunmuştur ve bu değer mükemmel bir değerdir.

² p-değeri: Anlamlılık seviyesi, p-değeri 0.05'ten küçük çıktığında iki değişken arasında anlamlı bir ilişki bulunduğu söylenebilmektedir.



Şekil 4.3. Gerçek ve tahmini akış değerleri arasındaki ilişki.



Şekil 4.4. a. Gerçek ile tahmin değerleri arasındaki ilişki b. Gerçek ile öğrenme değerleri arasındaki ilişki

S. Meshram, Singh, Kisi, Karimi ve C Meshram (2020) toprak sağlığının ve doğal kaynakların korunması için bir çalışma yürütmüşlerdir. Amaç günlük tortu verimini tahmin etmektir. Çalışmayı gerçekleştirilmek için 4 farklı derin öğrenme metodu kullanılmıştır. Kullanılan metotların biri YSA'dır ve 2 havzanın yağış ve deşarj verileri üzerinde uygulanmıştır. Sonuçlara göre, en düşük göreceli mutlak hata "0,360, 0,344", aynı zamanda r değeri = "0,921, 0,883" iken, NSE değeri "0,744, 0,763" olarak belirlenmiştir. Bu çalışmada Şekil 4.2 ve Şekil 4.3'te görüldüğü gibi, göreceli hatanın -0.25 - ~ 0.30 arasında olduğu ve $R^2 = 0,87 \sim (r=0,935)$ olduğu görülmektedir. Meshram vd. tarafından yapılan çalışmayla kıyaslandığında, çalışmaların sonuçları birbirine yakındır. Çizelge 4.1'de çalışma sonuçları özetlenmiştir.

Çizelge 4.1. Çalışmanın sonuçları özet tablosu

Değer	KOKH	R ²	P-değeri	NSE
Gerçek	14,7 m ³ /s	-	-	-
Tahmini	15,59 m ³ /s	-	-	-
Birleşik	-	0,875	1.370 _x 10 ⁻¹²	0,871

Elde edilen bulgular tatmin edici gibi görünse ve bazı durumlarda öyle olsa da sorulabilecek önemli sorulardan biri, oluşturulan modelin neden bazı dönemlerde, özellikle yüksek akış dönemlerinde düşük performansa sahip olduğudur. Aslında burada, çalışmanın asıl amacının beklenmedik bir arıza veya teknik sorun nedeniyle aniden durmuş olan bir istasyon için kullanılabilir veya elverişli tahminler üreterek, TSA'nın bu gibi durumlarda çözüm üretmedeki yeterliliğini araştırmak olduğunu vurgulamak gerekir. Şüphesiz, modelin doğruluğu, yağış kayıtları, su seviyesi, yeraltı suyu tablosu, nem içeriği, meteorolojik veriler gibi değişkenlerin bir birleşiminin bir fonksiyonudur. Ne yazık ki, veri yetersizliği nedeniyle, model yalnızca bitişik ve komşu istasyonlardan gelen akış kayıtlarına dayanarak eksik kayıtları belirleyecek şekilde oluşturulmuştur. Öte yandan, hızlı tahminler oluşturmak için modelde bir gizli katman kullanılmıştır. Hitokoto vd. (2017) tarafından belirtilene göre, çoklu gizli katman kullanmanın model doğruluğu açısından faydalı olabileceği ve bunun da öğrenme sürecini yavaşlatacağı düşünülmüştür. Ayrıca, Kratzert vd. (2018) bir TSA için ana zayıflığın, temel özelliklerin uzun süreli depolanmasına bağlı olduğunu bildirmiştir. Üzerinde durulması gereken bir diğer önemli soru ise Şekil 4.1(d, e, f) ve Şekil 4.2(d, e, f)'de verilen tahmini hata yüzdelerinin performansı ile ilgilidir. Esasen %10-%30'luk doğruluk iyi bir aralık gibi görünmektedir. Çalışmada kullanılan algoritmanın stokastik³ doğası göz önünde bulundurulduğunda, elde edilen sonuçların gerçek kayıtlardan biraz farklı olması gerektiğine de dikkat edilmelidir (Hitokoto vd. 2017).

³ Stokastik bir algoritma, istatistiksel olarak analiz edilebilen ancak kesin olarak tahmin edilemeyen rastgele bir olasılık dağılımına veya modeline sahiptir.

Genel olarak bakıldığında, elde edilen sonuçlar TSA algoritmasının çok iyi olduğunu ve hedeflenen amaca ulaşmak için son derece uygulanabilir bir yöntem olduğunu göstermiştir. Ekstra kayıtların az olması halinde dahi iyi tahminler yapmak mümkündür. Eksik kayıtların enterpolasyonu için klasik yaklaşımlar kullanmaktan ziyade, alternatif olarak TSA kullanılması tavsiye edilebilir. Ayrıca bu yöntem, uzak bölgelerde olası sel ve kuraklık dönemlerini tahmin etmek için uygun bir çözüm olacaktır. Çalışmadan elde edilen sonuçlar aşağıdaki tabloda özetlenmiştir.

5. SONUÇ

Bu çalışmada, Susurluk havzasında bulunan Orhaneli Çayı'na ait bir istasyonun kayıp veya eksik günlük akış verilerinin tekrarlayan sinir ağı (TSA) metodu kullanılarak tahmin edilmesi amaçlanmıştır. Çalışmada Orhaneli Çayı'nın 2012-2015 yılları arasında günlük ortalama akış kayıtlarını kullanarak çayın üzerinde bulunan Dağgüney istasyonunun kayıt altına almadığı değerlerin tahmini yapılmıştır.

Böylelikle, çökmüş veya devreden çıkmış bir istasyonda günlük nehir akış verilerini kurtarmak için destekleyici bir yöntem olarak TSA'nın uygulanabilirliği incelemiştir.

Elde edilen sonuçlar TSAların bazı olaylarda daha az girdi verisiyle bile çok iyi tahminler sağlama yeteneği olduğunu göstermiştir. Bu durum TSAların umut verici olduğunu ve uzak bölgelerdeki olası sel ve kuraklık dönemlerini tahmin etmede geleneksel yöntemler kullanmak yerine eksik kayıtların enterpolasyonunu yapmak için pratik bir yöntem olarak kullanılabilmesini işaret etmektedir. Ancak, gelecekteki araştırmacıların çeşitli hidrolojik kayıtları dâhil etmeleri ve gelişmiş derin öğrenme algoritmaları kullanarak ve çoklu gizli katmanları göz önünde bulundurarak bu konuyu araştırmaları önem arz etmektedir.

Bu yöntemin Devlet Su İşleri ve Bursa Su ve Kanalizasyon İdaresi (DSİ ve BUSKİ) gibi kamu kurumlarında kullanımının yaygınlaştırılmasıyla gelecekte su durumunun daha iyi değerlendirileceği ve TSAların su miktarının tahmin edilmesine yardımcı olabileceği düşünülmektedir. Böylelikle gelecek nesiller için su kaynaklarının korunmasına ve muhafaza edilmesine katkıda bulunulacak ve gelecekte suyun daha etkili ve uygun kararlar ve planlarla yönetilmesine yardımcı olunabilecektir.

KAYNAKLAR

- Anonim. 2015. “2014 Yılı İklim Değerlendirmesi”. *2014 Yılı İklim Değerlendirmesi*.
- Anonim. 2016. “2015 Yılı İklim Değerlendirmesi”.
- Anonim. 2018. “Yüzeysel akış”. [https://avys.omu.edu.tr/storage/app/public/gturan/133010/Yüzeysel Akış.pdf](https://avys.omu.edu.tr/storage/app/public/gturan/133010/Yüzeysel_Akış.pdf).
- ASCE. 2000. “Artificial Neural Networks in Hydrology. I: Preliminary Concepts”. *Journal of Hydrologic Engineering* 5 (2): 115–23. [https://doi.org/10.1061/\(asce\)1084-0699\(2000\)5:2\(115\)](https://doi.org/10.1061/(asce)1084-0699(2000)5:2(115)).
- ASCE b. 2000. “Task Committee on Application of Artificial Neural Networks in Hydrology, Artificial Neural Networks in Hydrology. II:Hydrologic Application”. *Journal of Hydrologic Engineering* 5 (2): 124–36.
- Balasubramanian, A. 2010. “surface water runoff [n]”. İçinde *Encyclopedic Dictionary of Landscape and Urban Planning*, 1004–1004. India. https://doi.org/10.1007/978-3-540-76435-9_14338.
- Beck, Andrea, David Flad, ve Claus Dieter Munz. 2019. “Deep neural networks for data-driven LES closure models”. *Journal of Computational Physics* 398 (Aralık). <https://doi.org/10.1016/j.jcp.2019.108910>.
- Daniel, Edsel B. 2011. “Watershed Modeling and its Applications: A State-of-the-Art Review”. *The Open Hydrology Journal* 5 (1): 26–50. <https://doi.org/10.2174/1874378101105010026>.
- Devlet Su İşleri [DSİ]. y.y. “Toprak Su Kaynakları”. Erişim 28 Kasım 2021. <https://www.dsi.gov.tr/Sayfa/Detay/754>.
- Devlet Su İşleri [DSİ]. 2015. “Akım Gözlem Yıllıkları”. 2015. <https://www.dsi.gov.tr/Sayfa/Detay/744>.
- García-Alba, Javier, Javier F. Bárcena, Carlos Ugarteburu, ve Andrés García. 2019. “Artificial neural networks as emulators of process-based models to analyse bathing water quality in estuaries”. *Water Research* 150 (Mart): 283–95. <https://doi.org/10.1016/j.watres.2018.11.063>.
- Graeff, Thomas, Erwin Zehe, Dominik Reusser, Erika Lück, Boris Schröder, Gerald Wenk, Hermann John, ve Axel Bronstert. 2009. “Process identification through rejection of model structures in a mid-mountainous rural catchment: observations of rainfall-runoff response, geophysical conditions and model inter-comparison”. *HYDROLOGICAL PROCESSES Hydrol. Process* 23 (5): 702–18. <https://doi.org/10.1002/hyp.7171>.
- Hitokoto, Masayuki, Masaaki Sakuraba, ve Yuichi SEI. 2017. “DEVELOPMENT OF THE REAL-TIME RIVER STAGE PREDICTION METHOD USING DEEP LEARNING”. *Journal of JSCE* 5 (1): 422–29. https://doi.org/10.2208/journalofjsce.5.1_422.
- Hjelmfelt, Allen T., ve Menghua Wang. 1993. “Artificial neural networks as unit hydrograph applications”. İçinde *Proceedings of the Symposium on Engineering Hydrology*, 756–59. <https://cedb.asce.org/CEDBsearch/record.jsp?dockey=0083447>.
- Hjelmfelt, Allen T., ve Menghua Wang. 1996. “Predicting Runoff using Artificial Neural Networks”. İçinde , 233–44. https://doi.org/10.1007/978-94-011-0389-3_16.
- Hornik, Kurt, Maxwell Stinchcombe, ve Halbert White. 1989. “Multilayer feedforward networks are universal approximators”. *Neural Networks* 2 (5): 359–66. [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8).
- Kahraman, Ahmet Cihat, ve Mustafa Özkul. 2018. “ERGENE HAVZASI II ARALIK 2018 İSTANBUL Hazırlayanlar”.
- Khparde, S. A., A. Lohtia, ve U. B. Desai. 1991. “Load forecasting using artificial neural network”. İçinde *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, 1:208–12. <https://doi.org/10.1109/TENCON.1991.712548>.
- Kim, Kangil, Dong Kyun Kim, Junhyug Noh, ve Minhyeok Kim. 2018. “Stable Forecasting of Environmental Time Series via Long Short Term Memory Recurrent Neural Network”. *IEEE Access* 6: 75216–28. <https://doi.org/10.1109/ACCESS.2018.2884827>.
- Kothari, Ravi, ve Kwabena Agyepong. 1997. “Induced specialization of context units for temporal pattern recognition and reproduction”. İçinde *Neural Networks for Signal Processing - Proceedings of the IEEE Workshop*, 131–40. <https://doi.org/10.1109/nnspp.1997.622391>.
- Kratzert, Frederik, Daniel Klotz, Claire Brenner, Karsten Schulz, ve Mathew Herrnegger. 2018. “Rainfall–runoff modelling using Long Short-Term Memory (LSTM) networks”. *Hydrology and Earth System Sciences* 22 (11): 6005–22. <https://doi.org/10.5194/hess-22-6005-2018>.
- Lee, Changki. 2016. “Image Caption Generation using Recurrent Neural Network”. *Journal of KIISE* 43


- (8): 878–82. <https://doi.org/10.5626/jok.2016.43.8.878>.
- Liu, Zhao Hua, Xu Dong Meng, Hua Liang Wei, Liang Chen, Bi Liang Lu, Zhen Heng Wang, ve Lei Chen. 2021. “A Regularized LSTM Method for Predicting Remaining Useful Life of Rolling Bearings”. *International Journal of Automation and Computing* 18 (4): 581–93. <https://doi.org/10.1007/s11633-020-1276-6>.
- Maier, Holger R., ve Graeme C. Dandy. 2000. “Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications”. *Environmental Modelling and Software* 15 (1): 101–24. [https://doi.org/10.1016/S1364-8152\(99\)00007-9](https://doi.org/10.1016/S1364-8152(99)00007-9).
- Maier, Holger R., Ashu Jain, Graeme C. Dandy, ve K. P. Sudheer. 2010. “Methods used for the development of neural networks for the prediction of water resource variables in river systems: Current status and future directions”. *Environmental Modelling and Software*. <https://doi.org/10.1016/j.envsoft.2010.02.003>.
- Mather, Paul M., S. Openshaw, ve C. Openshaw. 1998. “Artificial Intelligence in Geography”. *The Geographical Journal* 164 (3): 353. <https://doi.org/10.2307/3060633>.
- Mayo, Malual Deng. 2015. “Assessment of Surface Water Resources and its Allocation: Case Study of Bahr el-Jebel River Sub-Basin, South Sudan”. *Mekelle University, Ethiopia*. https://scholar.google.com/scholar?hl=tr&as_sdt=0%2C5&q=Assessment+of+Surface+Water+Resources+and+its+Allocation%3A+Case+Study+of+Bahr+el-Jebel+River+Sub-Basin%2C+South+Sudan+malual+deng&btnG=.
- Meshram, Sarita Gajbhiye, Vijay P. Singh, Ozgur Kisi, Vahid Karimi, ve Chandrashekar Meshram. 2020. “Application of Artificial Neural Networks, Support Vector Machine and Multiple Model-ANN to Sediment Yield Prediction”. *Water Resources Management* 34 (15): 4561–75. <https://doi.org/10.1007/s11269-020-02672-8>.
- Mozer, Michael C, ve Paul Smolensky. 1989. “Skeletonization: A Technique for Trimming the Fat from a Network via Relevance Assessment”. İçinde *Advances in Neural Information Processing Systems*, 1:107–115. <http://papers.nurips.cc/paper/119-skeletonization-a-technique-for-trimming-the-fat-from-a-network-via-relevance-assessment.pdf>.
- Nagesh Kumar, D., K. Srinivasa Raju, ve T. Sathish. 2004. “River flow forecasting using recurrent neural networks”. *Water Resources Management* 18 (2): 143–61. <https://doi.org/10.1023/B:WARM.0000024727.94701.12>.
- Napolitano, G, L See, B Calvo, F Savi, ve A. Heppenstall. 2010. “A conceptual and neural network model for real-time flood forecasting of the Tiber River in Rome”. *Physics and Chemistry of the Earth* 35 (3–5): 187–94. <https://doi.org/10.1016/j.pce.2009.12.004>.
- Nash, J E, ve J V Sutcliffe. 1970. “River flow forecasting through conceptual models part I - A discussion of principles”. *Journal of Hydrology* 10 (3): 282–90. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6).
- ORMAN VE SU İŞLERİ BAKANLIĞI. 2018. “SUSURLUK HAVZASI TAŞKIN YÖNETİM PLANI”, 1–330. [https://www.tarimorman.gov.tr/SYGM/Belgeler/Taşkın_Yönetim_Planları/4\) SUSURLUK_HAVZASI_TAŞKIN_YONETIM_PLANI.pdf](https://www.tarimorman.gov.tr/SYGM/Belgeler/Taşkın_Yönetim_Planları/4) SUSURLUK_HAVZASI_TAŞKIN_YONETIM_PLANI.pdf).
- Ranzato, Marc’Aurelio, Sumit Chopra, Michael Auli, ve Wojciech Zaremba. 2016. “Sequence level training with recurrent neural networks”. İçinde *4th International Conference on Learning Representations, ICLR 2016 - Conference Track Proceedings*. International Conference on Learning Representations, ICLR.
- Rao, Puli Venkateshwara. 2005. *INTERMEDIATE VOCATIONAL COURSE WATER SUPPLY*. Editör K. SRINIVASA RAO. First. Hyderabad/ İndia: STATE INSTITUTE OF VOCATIONAL EDUCATION DIRECTOR OF INTERMEDIATE EDUCATION GOVT. OF ANDHRA PRADESH.
- Reilly, Douglas L, ve Leon N. Cooper. 1995. “An Overview of Neural Networks: Early Models to Real World Systems”. İçinde , 300–321. https://doi.org/10.1142/9789812795885_0023.
- Ren, Tao, X Liu, Jianwei Niu, Xiaohui Lei, ve Zhao Zhang. 2020. “Real-time water level prediction of cascaded channels based on multilayer perception and recurrent neural network”. *Journal of Hydrology* 585. <https://doi.org/10.1016/j.jhydrol.2020.124783>.
- Russell, Stuart J, Peter Norvig, John F Canny, Jitendra M Malik, ve Douglas D Edwards. 1995. “Artificial Intelligence: A Modern Approach /Russell, Stuart J.”
- Salari, Marjan, Esmaeel Salami, Seied Hosein, Majid Ehteshami, Gea Oliveri, Zahra Derakhshan, ve Solmaz Nikbakht. 2018. “Quality assessment and arti fi cial neural networks modeling for characterization of chemical and physical parameters of potable water”. *Food and Chemical*

- Toxicology* 118 (February): 212–19. <https://doi.org/10.1016/j.fct.2018.04.036>.
- Sawaf, Mohamad Basel Al, Kiyosi Kawanisi, ve Cong Xiao. 2020. “Measuring Low Flowrates of a Shallow Mountainous River Within Restricted Site Conditions and the Characteristics of Acoustic Arrival Times Within Low Flows”. *Water Resources Management* 34 (10): 3059–78. <https://doi.org/10.1007/s11269-020-02557-w>.
- Shamseldin, Asaad Y. 2010. “Artificial neural network model for river flow forecasting in a developing country”. *Journal of Hydroinformatics* 12 (1): 22–35. <https://doi.org/10.2166/hydro.2010.027>.
- Shrestha, Durga Lal. 2010. *Uncertainty analysis in rainfall-runoff modelling-application of machine learning techniques: UNESCO-IHE PhD thesis*. https://www.researchgate.net/publication/41599693_Uncertainty_analysis_in_rainfall-runoff_modelling_application_of_machine_learning_techniques.
- Soytürk, Ozan. 2014. “Su Çerçeve Direktifine Göre Yeraltı Sularının İzlenmesi ve Türkiye İçin Bir Değerlendirme”. *T.C. Orman Ve Sİşleri Bakanlığı, sayı Uzmanlık Tezi*.
- Tzeng, Fan-Yin, ve Kwan-Liu Ma. 2005. “Opening the Black Box-Data Driven Visualization of Neural Networks”. <https://escholarship.org/uc/item/9dd6f376>.
- UNESCO, 2019. 2019. “The United Nations World Water Development Report 2019: Leaving no one behind.” *UNESCO Digital Library*.
- Vahed, Anwar. 2011. “ARTIFICIAL NEURAL NETWORK MODELLING OF FLOOD PREDICTION AND EARLY WARNING BY RAMAPULANA NKOANA”. https://scholar.google.com/scholar?hl=en&as_sdt=0%2C5&q=RAMAPULANA+NKOANA+2011&btnG=.
- Viessman, Warren. 2010. “Water Supply & Urban Drainage Lectures”. İçinde *Addis Ababa University*, 11–37. Addis Ababa University.
- Vinogradov, Yu B. 2006. “SURFACE WATER RUNOFF”. İçinde *HYDROLOGICAL CYCLE – Vol. III*, 34. <https://www.eolss.net/sample-chapters/C07/E2-02-06.pdf>.
- Vos, N. J. De, ve T. H.M. Rientjes. 2008. “Multiobjective training of artificial neural networks for rainfall-runoff modeling”. *Water Resources Research* 44 (8): 8434. <https://doi.org/10.1029/2007WR006734>.
- Wei, Yiming, Weixuan Xu, Ying Fan, ve Hsien Tang Tasi. 2002. “Artificial neural network based predictive method for flood disaster”. İçinde *Computers and Industrial Engineering*, 42:383–90. Pergamon. [https://doi.org/10.1016/S0360-8352\(02\)00047-5](https://doi.org/10.1016/S0360-8352(02)00047-5).
- Wu, C. L., K. W. Chau, ve Y. S. Li. 2009. “Predicting monthly streamflow using data-driven models coupled with data-preprocessing techniques”. *Water Resources Research* 45 (8). <https://doi.org/10.1029/2007WR006737>.
- Zhou, Mofan, Xiaobo Qu, ve Xiaopeng Li. 2017. “A recurrent neural network based microscopic car following model to predict traffic oscillation”. *Transportation Research Part C: Emerging Technologies* 84: 245–64. <https://doi.org/10.1016/j.trc.2017.08.027>.


EKLER DİZİNİ

	Sayfa
EK 1. Şekil 2.8 Susurluk havzası siyasi haritası	49
EK 2. Şekil 4.1 Düşük akış dönemlerinde (a, b, c) gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki görelî hatalar	50
EK 3. Şekil 4.2 Orta akış (a & b) ve yüksek akış (c) dönemlerinde gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki görelî fark	51
EK 4. Model değerleri 2014 Akış değerleri ile karşılaştırılması	52
Ek 5. Model değerleri 2015 Akış değerleri ile karşılaştırılması	53


Ek.1 Şekil 2.8. Susurluk Havzası Siyasi Haritası




Ek.2 Şekil 4.1 Düşük akış dönemlerinde (a, b, c) gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki görelî hatalar.




Ek.3 Şekil 4.2 Orta akış (a & b) ve yüksek akış (c) dönemlerinde gerçek (siyah) ve tahmini (kırmızı) akışların karşılaştırması ve tahminlerin gözlemlenen gerçek kayıtlarla (d, e, f) karşılaştırıldığındaki göreceli fark



EK 4. Model deęerleri 2014 Akış deęerleri ile karşılaştırılması



EK 4 Model deęerleri 2015 Akıř deęerleri ile karřılařtırılması



ÖZGEÇMİŞ

Adı Soyadı : Yaman ALSAVAF
Doğum Yeri ve Tarihi : Riyad-Saudi Arabistan/1993
Yabancı Dil : İngilizce-Arapça

Eğitim Durumu

Lisans : Pamukkale Üniversitesi/ Çevre-MÜH. Böl.
Yüksek Lisans : Uludağ Üniversitesi / Çevre-MÜH. ABD

Çalıştığı Kurum/Kurumlar :

İletişim (e-posta) : ysawaf.999@gmail.com

Yayınları:

- ALSAVAF Y., TEKSOY A. Applicability of recurrent neural networks to retrieve missing runoff records: challenges and opportunities in Turkey/ Environmental Monitoring and Assessment (2022) 194: 28
- ALSAVAF Y. A Comparative Study For Evaluating The Sustainability of Some Textile Wastewater Treatment Units/ 4. İCOCEM kongre / Trabzon-Türkiye.(2014), S:1057-1064