

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HİBRİT DALGACIK-SİNİR AĞI MODELLERİ İLE AYLIK NEHİR
AKIM TAHMİNİ

Mehmet Şamil GÜNEŞ

DOKTORA TEZİ

İstatistik Anabilim Dalı

İstatistik Programı

Danışman

Dr. Öğr. Üyesi Doğan YILDIZ

Mayıs, 2023

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**HİBRİT DALGACIK-SİNİR AĞI MODELLERİ İLE AYLIK NEHİR AKIM
TAHMİNİ**

Mehmet Şamil GÜNEŞ tarafından hazırlanan tez çalışması 15.05.2023 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü İstatistik Anabilim Dalı, İstatistik Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Doğan YILDIZ
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Doğan YILDIZ, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Fatma Noyan TEKELİ, Üye
Yıldız Teknik Üniversitesi

Prof. Dr. Ali Karun NEMLİOĞLU, Üye
İstanbul Üniversitesi

Prof. Dr. Filiz KARAMAN, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Erhan USTAOĞLU, Üye
Marmara Üniversitesi

Danışmanım Dr. Öğr. Üyesi Doğan YILDIZ sorumluluğunda tarafımca hazırlanan Hibrit Dalgacık-Sinir Ağı Modelleri İle Aylık Nehir Akım Tahmini başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Mehmet Şamil GÜNEŞ

İmza

TEŞEKKÜR

Tez çalışmamda planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Dr. Öğr. Üyesi Doğan YILDIZ 'a, tezden üretilmiş yayında önemli katkıları bulunan değerli meslektaşım Arş. Gör. Dr. Coşkun PARİM'e teşekkürü bir borç bilirim ve sonsuz teşekkürlerimi sunarım.

Mehmet Şamil GÜNEŞ

İÇİNDEKİLER

SİMGE LİSTESİ	v
KISALTMA LİSTESİ	vi
ŞEKİL LİSTESİ	vii
TABLO LİSTESİ	ix
ÖZET	xi
ABSTRACT	xii
1 GİRİŞ	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı	5
1.3 Hipotez	6
2 TÜRKİYE'DE SU YÖNETİMİ VE İKLİM DEĞİŞİKLİĞİ.....	7
2.1 Türkiye’de Su Yönetimine Genel Bakış	7
2.2 Türkiye’de İklim Değişikliğinin Etkileri.....	8
3 METOTLAR	10
3.1 Yapay Sinir Ağları (ANN)	10
3.2 Yapay Sinir Ağlarının Tarihçesi.....	10
3.3 Temel Kavramlar.....	11
3.4 Eğitim ve Öğrenme Süreçleri.....	17
3.5 Yapay Sinir Ağları Tipleri	22
3.6 Dalgacık (Wavelet) Dönüşümü	30
3.7 Sürekli Dalgacık (Wavelet) Dönüşümü.....	36
3.8 Kesikli Dalgacık (Wavelet) Dönüşümü	41
3.9 Dalgacık (Wavelet) Tipleri	47
3.10 WT-ANN Hibrit Dönüşümü.....	54
3.11 Model Değerlendirme Kriterleri.....	56
4 UYGULAMA.....	58
4.1 Çalışma Alanı ve Veri	58
4.2 WT-ANN Hibrit Makine Öğrenmesi Modelleri ve Sonuçları.....	63
5 SONUÇ VE ÖNERİLER	74
KAYNAKÇA.....	76
TEZDEN ÜRETİLMİŞ YAYINLAR	90

SİMGE LİSTESİ

e	Ağ Hatası
g, f	Aktivasyon Fonksiyonu
A	Approximation
D	Details
θ	Eşik Değeri
f	Frequency (Frekans)
H	High Pass
J	Jakobiyen Matrisi
L	Low Pass
ψ	<i>Mother Wavelet</i>
η	Öğrenme Oranı
s	Scale (Ölçek)
w	Sinaptik Ağırlıklar
w_l	Window Length

KISALTMA LİSTESİ

AGİ	Akım Gözlem İstasyonu
BP	Back Propagation
CWT	Continuous Wavelet Transform
Db	Daubechies
DWT	Discrete Wavelet Transform
FIR	Finite Impulse Response
FT	Fourier Transform
MKS	Markov Karar Süreci
MAE	Mean Absolute Error
MRA	Multi Resolution Analysis
RMSE	Root Mean Square Error
SOM	Self Organizing Maps
STFT	Short Time Fourier Transform
WA	Wavelet Analysis
WT	Wavelet Transforms
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 3.1	Sinir hücresi örneği.....	12
Şekil 3.2	Basit YSA nöron modeli.....	13
Şekil 3.3	İki farklı transfer fonksiyonu (a:sigmoid, b:tanh)	14
Şekil 3.4	Sigmoid fonksiyonu	15
Şekil 3.5	Hiperbolik tanjant fonksiyonu	15
Şekil 3.6	Radyal tabanlı gaussian aktivasyon fonksiyonu.....	16
Şekil 3.7	Piecewise linear aktivasyon fonksiyonu.....	16
Şekil 3.8	Linear aktivasyon fonksiyonu	17
Şekil 3.9	Denetimli öğrenme akışı	18
Şekil 3.10	Denetimsiz öğrenme akışı	19
Şekil 3.11	Pekiştirmeli öğrenme (reinforcement learning) süreci	19
Şekil 3.12	Online (çevrimiçi) öğrenme süreci	20
Şekil 3.13	Öğrenme (learning) tipleri	22
Şekil 3.14	YSA sınıflandırma şeması	23
Şekil 3.15	Tek katmanlı ileri beslemeli sinir ağı örneği.....	24
Şekil 3.16	Çoklu katman ileri beslemeli sinir ağı modeli örneği 1	24
Şekil 3.17	Çoklu katman ileri beslemeli sinir ağı modeli örneği 2.....	25
Şekil 3.18	Geri beslemeli ağlar modeli	28
Şekil 3.19	Kendini Düzenleyen Haritalar (SOM) modeli	29
Şekil 3.20	Farklı frekans, zaman ölçekleme şekilleri.....	31
Şekil 3.21	Fourier dönüşümü aralığı (the windowed Fourier transform)	34
Şekil 3.22	Fourier ve Dalgacık dönüşümünün karşılaştırmalı görseli	36
Şekil 3.23	Fourier ve Dalgacık dönüşümünün karşılaştırmalı görseli	37
Şekil 3.24	Dalgacığın geçiş (zaman sabiti t 'ye bağlı olarak) ve genişleme (s ölçeklemesi ile) süreçlerinin temsili gösterimi.....	39
Şekil 3.25	Sürekli tipte nabız sinyalinin geçiş (shift, translation) ve genişleme (dilation, stretch) parametreleriyle beraber Daubechies dalgacığı ile olan süreci	40
Şekil 3.26	Düşük ve yüksek bant dalgacık katsayılarının belirlenmesi	41
Şekil 3.27	Düşük ve yüksek bant içeren iki kanallı filtreleme.....	42

Şekil 3.28 Üç seviyeli filtre bank örneği	45
Şekil 3.29 Kesikli dalgacık dönüşümü	46
Şekil 3.30 Haar dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude).....	48
Şekil 3.31 Daubechies (a:db2, b:db4) dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude)	49
Şekil 3.32 Haar dalgacık dönüşümü seviyeleri	50
Şekil 3.33 Coiflets dalgacık dönüşümü seviyeleri	51
Şekil 3.34 Symlet dalgacık dönüşümü seviyeleri	52
Şekil 3.35 Biortogonal 2.4 dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude)	53
Şekil 4.1 Çoruh havzası üzerinde yer alan İspir, Laleli ve Mescitli akım gözlem istasyonları	58
Şekil 4.2 Türkiye su havzaları yağış alanları (km ²) (2020 ve 2013 için)	61
Şekil 4.3 Türkiye su havzaları için ortalama yıllık akımlar (km ³) (2020 ve 2013 için)	61
Şekil 4.4 Çoruh su havzası için 1901-2016 yılları arası ortalama aylık sıcaklık (temperature) (°C) ve yağış (rainfall) (mm).....	62
Şekil 4.5 Hibrit dalgacık sinir ağı (WT-ANN) için akış diyagramı	65
Şekil 4.6 İspir, Mescitli ve Laleli istasyonları için Model 8 eğitim, validasyon ve test dönemlerinin karşılaştırılması	71

TABLO LİSTESİ

Tablo 2.1	Su yönetiminde nüfusa bağlı olarak sorumlu olan kurumlar	8
Tablo 3.1	Dalgacık dönüşümlerinin kullanım alanları.....	32
Tablo 3.2	Kesikli dalgacık dönüşümü frekans içerikleri	46
Tablo 4.1	Havzalara göre yıllık ortalama havza yağış alanı ve ortalama yıllık akımlar (2013 ve 2020)	60
Tablo 4.2	Çoruh havzasında eğitim, validasyon ve test periyodları veri özeti	62
Tablo 4.3	Eğitim, validasyon ve test periyodları için değişkenlerin ortalama ve standart sapma değerleri	63
Tablo 4.4	Girdi Kombinasyonları için Oluşturulan Modeller	64
Tablo 4.5	İspir istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi	66
Tablo 4.6	Laleli istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi	67
Tablo 4.7	Mescitli istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi	68
Tablo 4.8	Eğitim, validasyon ve test periyotları için model performansları	69
Tablo 4.9	Eğitim, validasyon ve test periyotları için model performansları	73

Hibrit Dalgacık-Sinir Ağı Modelleri İle Aylık Nehir Akım Tahmini

Mehmet Şamil GÜNEŞ

İstatistik Anabilim Dalı

Doktora Tezi

Danışman: Dr. Öğr. Üyesi Doğan YILDIZ

Su yönetim planlamasında, özellikle su havzası yönetiminde akımın istatistiksel olarak tutarlı ve performanslı bir şekilde modellenmesi, diğer sıcaklık, yağış gibi diğer klimatolojik etkilerle beraber değerlendirilmesi önem taşımaktadır. Bu nedenle, su yönetimini etkileyen faktörleri değerlendirmek, etkilerini anlamak, gelecekteki kullanımı tahmin etmek ve bu sistemleri doğru bir şekilde geliştirmek için istatistiksel model yaklaşımları kullanılabilir. Bu tez çalışmasında, aylık akımı tahmin etmek için ayrık dalgacık dönüşümlerini (WT'ler) ve yapay sinir ağlarını (YSA'lar) birleştiren hibrit bir model kullanılmıştır. Çalışmada, hava sıcaklığı, yağış, akım ve bunların dalgacık dönüşümlerinin değişken kombinasyonları ile Çoruh nehri havzasındaki üç farklı ölçüm istasyonu için akımın bir ay sonrasındaki değerini tahmin etmek adına Daubechies ana dalgacığı yardımıyla WT-ANN hibrit modeli kullanılmıştır. En yaygın olarak kullanılan hibrit WT-ANN modelleri oluşturulmuş ve geleneksel YSA modelleri ile karşılaştırılmıştır. Veri seti kronolojik olarak eğitim, validasyon ve test verilerine bölünmüştür. Sonuçlar, WT-ANN hibrit modellerinin her üç istasyon için de geleneksel YSA modellerinden daha iyi performans verdiğini göstermiştir. Ayrıca, kronolojik olarak bölünmüş

veri seti, zaman içerisinde hidrolojik verilerdeki deęişikliklerin model performansı üzerindeki etkilerini incelemek için kullanılmıştır. Ek olarak, eğitim için kullanılan dönemdeki model performansın, hidrolojik verilerdeki yapısal deęişiklikler nedeniyle validasyon ve test için kullanılan dönemlerde kötüleştięi görölmektedir.

Anahtar Kelimeler: Akım, yapay sinir aęları (YSA), dalgacık dönüşümü, hava sıcaklığı, yağış



Monthly River Streamflow Prediction with Hybrid Wavelet-Neural Network Models

Mehmet Şamil GÜNEŞ

Department of Statistics

Doctor of Philosophy Thesis

Supervisor: Dr. Öğr. Üyesi Doğan YILDIZ

In water management planning, especially in water basin management, it is important to estimate the flow in a statistically consistent and performance way and to evaluate it together with other climatological effects such as temperature and precipitation. Hence, statistical models can be utilized to assess the aspects effecting water management, understand their conclusions, predict future need, and improve these structures accurately. In this thesis, a hybrid model combining discrete wavelet transforms (WTs) and artificial neural networks (ANNs) is used to estimate the monthly streamflow. The WT-ANN hybrid model was developed using the Daubechies main wavelet to predict the streamflow for three gauging stations on the Çoruh river basin one month in advance, with different combinations of air temperature, precipitation, and streamflow variables, and their wavelet transformations. Most commonly used hybrid WT-ANN models were generated and compared with conventional ANN models. The dataset was chronologically divided into training, validation, and testing data. The results indicated that the WT-ANN hybrid models performed better than the traditional ANN models for all three stations. Furthermore, the chronologically divided

dataset was used to examine the effects of changes in hydrological data over time on model performance. Additionally, model performances in the training period deteriorated during the validation and testing periods due to structural changes in the hydrological data.

Keywords: Streamflow, artificial neural network (ANN), wavelet transform (WT), air temperature, precipitation



1.1 Literatür Özeti

İklim değışiklięi, nüfus artışı, sanayileşme ve çevresel etkiler, bölgesel su kaynaklarının mevcudiyetinde özellikle son dönemlerde mekânsal-zamansal değışikliklerin en önemli nedenlerindendir [1, 2]. Özellikle bu unsurlardan iklim değışiklięinin, hidrolojik döngünün en önemli bileşenlerinden olan akım, sıcaklık, yağış miktarı ve bunların değışkenlięi üzerine olan etkileri yüksek seviyelerdedir [3-5]. Bu değışiřme örnek olarak Jiao ve Wang, yaptıkları çalışmada, son on yılda sıcaklık etkisinin artış eğilimindeyken, akarsu akışı ve yağış etkisinin azalma eğiliminde olduğunu belirtmişlerdir [6]. Akarsu akışının modellenmesi ve ana hatlarının belirlenmesi su yönetimi ve planlamasında çok dikkat edilmesi gereken bir süreçtir ve tutarlı bir akım tahmini, suyun en verimli şekilde kullanılması ve kalite yönetimi açısından hayati bir araçtır [7].

Akarsu akımının tutarlı projeksiyonu, hem su miktarı hem de kalite yönetimi için temel bir bileşendir. Tutarlı akım tahmin çalışmalarında çeşitli yaklaşım çeşitleri vardır. En çok kullanılan yaklaşım ise temel hidrolojik ve klimatolojik etkileri içeren akım modellemeleridir [7, 8]. Bu modelleme tipi akım modellemesi sürecinde, hava koşulları, arazi kullanımı, kuraklık ve bitki örtüsü gibi birçok faktörden etkilenebilir. Bu yaklaşımın dışında ilgili nokta, havza veya nehri daha önceki elde edilen çeşitli bölge verilerine dayanarak modelleme çalışması yapan desen tasarımı (pattern recognition) yöntemlerinden de araştırmacılar yararlanmaktadır [9]. Bu tip modelleme çalışmalarının ana amacı ise akımın mekansal ve zamansal özelliklerini değerlendirerek çıkarım yapmaktır [10].

Literatürde akarsu akımının yağış ve sıcaklıkla ilişkisini inceleyen, değışim ve tahminlerini değerlendiren çalışmalar mevcuttur [11, 12]. Xu vd. [13] akımdaki

periyodik deęişikliklerin sıcaklık ve yağış ile yakından ilişkili olduğunu çalışmalarında vurgulamışlardır. Ayrıca, Duan vd. [14] araştırmalarında sıcaklığın akarsu akımı üzerinde yağıştan daha büyük bir etkiye sahip etkiye olduğunu göstermişlerdir. Bu deęişkenler arasındaki ilişkiyi, uzun dönemli eğilimlerinin deęişimlerini ve bunların tahminini içeren birçok çalışma mevcuttur [15-19]. Son yıllarda yapılan çalışmalardan hareketle sıcaklık ve yağışın yirmibirinci yüzyıl boyunca akarsu akımını önemli ölçüde etkilemeye devam edeceğini görmekteyiz [20, 21].

Su havzaları; evsel su kullanım kaynağı, tarımsal sulama ve endüstriyel kullanım ihtiyacı nedeniyle hayati önem taşıyan noktalardır [22]. Bu kullanımlara ek olarak evsel ve endüstriyel atıksular havzanın akımını ve su kalitesini etkileyen diğer etmenlerdendir [23]. Su havzalarının yönetiminin küresel olarak iklim deęişikliğinden de sürekli olarak etkilendiğı gerçeğı ve bu deęişime adapte olmanın uzun dönemli yönetim planı oluşturmada ciddi bir unsur olarak ele alınması gerekliliğı unutulmamalıdır. Küresel iklim deęişiminin su kaynakları üzerindeki ve yönetimindeki etkisini incelemek ortak disiplinlerarası bir yönetim çalışmasını gerektirmektedir. Daha önceki çalışmalarda iklim deęişikliğinin havza akımları üzerinde olan etkisi açıkça ortaya konulmuştur [24-27].

Türkiye ve global düzeyde geleneksel akım tahmini modellemesi üzerine yapılan çalışmalar genellikle trend analizi, regresyon modelleri ve klasik zaman serileri gibi yöntemleri içermektedir [28-31].

Son dönemlerde akım tahminlerinde yapay zeka (artificial intelligence) tekniklerinden biri olan yapay sinir ağıları (YSA) yöntemleri çevre bilimleri alanında yaygın bir şekilde kullanılmaktadır [32]. Bu ağ sistemi hayvanların beyin sinir sisteminin işleyişinden esinlenilerek oluşturulmuş bir tekniktir ve sinir ağıları üzerinden giriş verileriyle desteklenerek süreci ve öğrenmeyi devam ettirir.

YSA yöntemleri, bilgisayarlı analiz sistemleri ve araştırmalar geliştikçe ilgili alanlara ve kullanım şekillerine göre ilerlemiştir ve bağımlı ve açıklayıcı deęişkenlerin arasındaki ilişkinin bilinmediğı durumlarda tahminleme için kullanılmaktadır. Bu ilerleme, akım tahminleme yöntemleri sürecinde de etkili

olmuştur ve başarılı sonuçlar vermiştir [10, 33-35]. YSA'nın akım tahminlerinde kullanılmasına ilk örneklerinden biri Kang vd.'nin [36] günlük ve saatlik akım tahmin modellemesidir. Özellikle YSA lineer olmayan hidroloji ve klimatoloji verileri üzerinde kullanılmaya çok uygun bir analiz sistemi haline gelmiştir [37-41]. YSA içinde hidroloji alanında en çok kullanılan tekniklerden biri olan feed-forward neural network (FFNN) sürecinin ise akım tahmin modellemesinde olan popülerliği yükselerek artmaktadır [42]. Kişi [43] ve Yaseen vd. [44] YSA modellerinin aylık performanslarını ölçmek amacıyla farklı akım gözlem istasyonlarını karşılaştırmak için FFNN kullanmıştır. Zealand vd. [45] ise bu yöntemi haftalık tahmin modeli oluşturmak için kullanmıştır. Kişi [43] ise aynı tekniği Türkiye'de aylık akım tahmini için kullanmıştır.

Lineer ve lineer olmayan (non-linear) metotlardan biri olan YSA'nın durağan olmayan (non-stationary) verilerle çalışılması durumunda çeşitli kısıtlamaları vardır. Modelde giriş datası için veri düzenleme süreci tutarlı ve verimli yapılmamışsa gereksiz, tamamlanmamış ya da hatalı verilerin var olması gibi çeşitli sorunlar ortaya çıkabilir [46, 47]. Son yıllarda yapılan çalışmalardan hareketle YSA ile beraber durağan olmayan verilerde oluşan bu kısıtlamaların üstesinden gelmede etkili ve pratik yöntem olan wavelet transform (dalgacık dönüşümü-WT) yöntemi kullanılmaktadır [48].

Yapay zeka alanında kullanılan yöntemlerden bir diğeri olan wavelet transform (dalgacık dönüşümü-WT) tekniğinde YSA ile beraber hidroloji alanında tahmin modeli geliştirmede kullanılan önemli bir araçtır [48-50]. Chang vd. dalgacık dönüşümünü akımın periyodik olarak incelenmesinde kullanmıştır [51]. Bu çalışmada dalgacık dönüşümü kullanmanın nedeni, WT'lerin (sürekli ve ayrık) zaman serilerini uygun bir şekilde ayrıştırması ve değişen tahmin seviyelerinde kullanılacak bilgileri ortaya çıkarmasıdır. Dalgacık dönüşümleri, zamansal frekansla ilgili bilgi sağladığı için hidrolojik zaman serilerinde kullanılması uygundur.

Dalgacık dönüşüm yöntemleri temel olarak sürekli (continuous-CWT), kesikli (discrete-DWT) ve durağan (stationary-SWT) dalgacık dönüşümleri olmak üzere

ana üç gruba ayrılabilir. Literatür taramasında Santos vd. [52, 53] sürekli dalgacık dönüşümlerini yağış serilerini tahmin etmede kullanmışlardır. Nalley vd. [54] ve Seo vd. [55] ise dünyanın en büyük su havzalarının aylık akım yapılarının incelenmesi ve tahmininde yapay sinir ağları ve kesikli dalgacık dönüşümlerinin hibrit bir şekilde kullanılmasının daha iyi performanslı sonuçlar verdiğini göstermişlerdir. Bu hibrit dönüşümlere benzer çeşitli tahmine dayalı zaman serisi yapıları da dalgacık dönüşümleri ile kullanılmaktadır [56, 57].

Son yıllarda literatürde yer alan birçok çalışma kesikli dalgacık dönüşümü (DWT) ve yapay sinir ağlarını (ANN) birleştirerek (WT-ANN) akım tahmini yapan hibrit modeller oluşturmaya başlanmış ve performans değerlendirmeleri yapılmıştır. WT-ANN modellerinin kullanımı ve uygulamaları çok fazla olduğu bilinmektedir. Ancak hidroloji ve su havzası akımı tahminlemesinde yapılan çalışmalar daha kısıtlı sayıdadır. Anctil ve Tape [58] WT-ANN modellemesi kullanarak Amerika Birleşik Devletleri ve Fransa için bir sonraki gün akımını tahmin etmişlerdir. Partial [59] Türkiye geneli hibrit aylık akım tahmini modeli oluşturmuş, Kişi [60] ise WT-ANN hibrit modelini Türkiye’de günlük akım tahmini yapmak için kullanmıştır. Wu vd. [61] ise üç gün kadar akım tahmini yapan modeller üzerinde çalışmışlardır. Bu akım tahmin modelleme çalışmalarında hibrit WT-ANN yapılarının klasik ANN (YSA) modellerinden daha iyi performans verdiği görülmektedir.

Türkiye’de Çoruh nehir havzasında yapılan akım tahmin çalışmaları, hidrolojik ve klimatolojik verileri YSA ve diğer metotlarla kullanarak daha iyi sonuçlar almak için kullanmışlardır. Mehr vd. [7] neuro-wavelet dönüşümünü lineer genetic programlama ile beraber kullanarak Çoruh nehir havzası için aylık akım tahmini modeli oluşturmuştur. Benzer olarak Mehr vd. [62] dalgacık dönüşümü (WT) kullanarak Çoruh nehir havzasında sıralı iki akım gözlem istasyonu için aylık tahmin modelleri geliştirmişlerdir. Çalışmalarında modellerin giriş datasının gecikmeli değerlerinin farklı etkilerini incelemişlerdir. Ek olarak Mehr vd. [62] sıralı akım gözlem istasyonlarının aylık akım tahminlemesi için YSA’yı kullanırken, Yücel vd. [63] Çoruh su havzası ve çevresi için eriyen karların akıma olan etkisini modellemiştir. Can vd. [64] ise bölgede günlük akım tahmini için YSA ve

otoregresif hareketli ortalama (auto-regressive moving average) sistemini kullanmışlardır. Büyükyıldız [65] ise Çoruh nehir havzasında aylık akımı incelemek amacıyla YSA, destek-vektör makinesi (support-vector machine) ve adaptif bulanık çıkarım sistemlerini (adaptive fuzzy inference systems-ANFIS) modellemiştir.

Çoruh nehir havzası için yapılan güncel modelleme çalışmalarının çok az sayıda olduğu görülmektedir. Bölgede akımı etkileyen en önemli değişkenlerden olan yağış ve sıcaklık ile arasındaki ilişkiyi inceleyen birkaç klasik yöntemlerin kullanıldığı çalışma dışında başka literatür bulunmamaktadır. Bizim çalışmamızda kullandığımız hibrit WT-ANN modellemeleri ve klasik YSA'ya göre performans değerlendirmeleri Çoruh nehir havzası için ilgili alanda daha önce yapılmamıştır. Çalışmanın bu yönü tez çalışmasının yenilikçi kısmını oluşturmaktadır. Bununla beraber klimatolojik değişkenler olan yağış ve sıcaklığın WT-ANN modelleri ile akıma olan etkilerinin detaylı incelenmesi ve değerlendirilmesi de literatüre katkı sağlayacaktır.

1.2 Tezin Amacı

Bu tez çalışmasının amacı, kesikli dalgacık dönüşümü (DWT) ve yapay sinir ağlarını (ANN) hibrit modelde birleştirerek aylık akım tahmini yapan modeller geliştirmektir. Bu geliştirmeyi yapmak amacıyla Çoruh nehri havzasındaki üç ölçüm istasyonu (Laleli, Mescitli ve İspir akım gözlem istasyonları) ele alınmıştır ve WT-ANN hibrit modeli için Daubechies ana dalgacığı aracılığıyla, hava sıcaklığı, yağış ve akım değişkenlerinin farklı kombinasyonları ve bunların dalgacık dönüşümleri kullanılmıştır. Bu çalışma modelleri bir ay sonraki akımı daha iyi, tutarlı ve performanslı tahmin edecek modellemeler için geliştirilmiştir. Literatürde bölgede yapılan diğer akım tahmin çalışmalarından farklı olarak, periyodik değişimleri daha iyi modellemek amacıyla veriler kronolojik olarak eğitim (training), validation (geçerlilik) ve test olarak bölünmüştür.

1.3 Hipotez

Bu tez çalışması, hidroloji alanında hibrit bir model tipi olan WT-ANN'nin çeşitli algoritmalarının kendi aralarında ve klasik ANN yöntemi karşısında performanslarını ölçmeyi ve değerlendirmeyi amaçlar. Genel olarak tez çalışmasının hipotezlerini şu şekilde sıralayabiliriz. Birinci olarak, hibrit WT-ANN modeli içinde yer alan ve kullandığımız veri yapısına uygun olan Biorthogonal, Coiflets, Daubechies, Haar, Meyer, Mexican Hat, Morlet, ve Symlets algoritmalarının performanslarını karşılaştırmalı olarak ölçmektir. İkinci olarak, literatürde hidroloji alanında yaygın olarak kullanılan klasik veya geleneksel olarak tabir edebileceğimiz yapay sinir ağı yöntemlerinden biri olan feed-forward neural network tekniğini veriye uygulayarak hibrit WT-ANN algoritmaları karşısında performansını değerlendirmektir. Üçüncü olarak ise, daha önce literatürde yapılmış olan birçok çalışmadan farklı olarak akım verisinin periyodik olarak bölünerek performansını hibrit ve klasik yöntemle ölçmektir. Tez çalışmasının çıktılarının su yöneticilerine, yasa yapıcılara ve ilgili alanda çalışma yapmış veya yapacak araştırmacılara karar almada yardımcı olması beklenebilir.

2.1 Türkiye’de Su Yönetimine Genel Bakış

Bütün dünya üzerinde olduğu gibi Türkiye’de de nüfus artışı, sanayileşme ve iklim değişikliği su yönetiminin sağlıklı ve verimli planlamasında oldukça önemli rol oynamaktadır. Su havzalarının entegre bir şekilde yönetilmesi, havza içinde ve havzaya komşu olan her canlı için dikkat edilmesi gereken bir noktadır [66]. Suya olan ihtiyacın birçok sektörde giderek artması, su yönetiminde sürekli olarak kendini yenileyen ve taleplere cevap vermesi gereken bir sistem içinde olması gerekliliğini doğurmuştur. Bu adımlardan en önemlilerinden birkaçı ise mevcut durumun belirlenmesi, istatistiksel tahmin modellerinin değerlendirilmesi ve altyapı durumunu sürekli olarak gözden geçirilmesidir.

Su ve havza yönetiminde sürdürülebilir gelişme hedeflerinin belirlenmesi, bu konuda gerekli adımlar atılması ve hedeflerin sağlanması, ulusal ve uluslararası olarak su yöneticilerinin ve politikacıların en önemli dikkat etmesi gereken unsurlardan bazılarıdır. Özellikle nüfus yoğun alanlarda, tarımsal sulama ihtiyacının fazla olduğu ve sanayinin gelişmiş olduğu bölgelerde su ve havza yönetiminin en iyi şekilde yapılması kaçınılmaz bir durumdur.

Türkiye’de suyun kullanımını genel olarak sınıfladığımızda (çekilen su bazında), yaklaşık %41’lik kısmını belediyeler, %36’lık kısmını termik santraller, %15’lik kısmı endüstriyel ve yaklaşık %8’lik bir kısmı ise köyler tarafından kullanılmaktadır [67]. Bu kullanımlar göz önüne alındığında Türkiye’de su yönetiminin en verimli bir biçimde yapılması gerekliliği önem arz etmektedir.

Su yönetimi konusunda Türkiye bazında çalışmalar 1920’li yıllarda oluşmaya başlamıştır. Daha ufak çaplı sulama bölgeleriyle hayata geçen su yönetimi girişimleri, ilerleyen dönem ihtiyaçları ve amaç doğrultusunda günümüze kadar

gelmiştir [68]. Türkiye'de su yönetimi politikaları, ülkedeki ekonomik ve sosyal kalkınma, su ve gıda güvenliğindeki öncelikler, Avrupa Birliği (AB) kriterleri ve bölgesel gelişmeler dikkate alınarak oluşturulmaktadır. Çeşitli havza ve il bazlı su yönetimi master planları işleme konulmuştur [69]. Su yönetimi ile ilgili Türkiye'de Devlet Su İşleri, Çevre, Şehircilik ve İklim Değişikliği ve Tarım ve orman Bakanlığı gibi resmi kurumlar ve alt birimleri sorumludur. Bunun yanında resmi olmayan çeşitli kuruluşlarda su yönetimi hakkında çeşitli çalışmalar sürdürmektedir [70].

Türkiye'de Su ve Belediyeler Kanunu'na göre belediyeler, nüfusa bağlı olarak kentsel su temin hizmetlerinden sorumludur. Yaşayan kişi sayısı 10000'den az olan alanlar için sorumluluk belediyelerdedir [68]. Su yönetiminde nüfusa bağlı olarak sorumlu olan kurumlar Tablo 2.1'de verilmiştir.

Tablo 2.1 Su yönetiminde nüfusa bağlı olarak sorumlu olan kurumlar

Nüfus	Sorumlu Kurum
10000 ve altı	Belediyeler
10000 ile 50000 arası	Su yönetim ofisleri veya müdürlükleri
50000 ve üzeri	Belediye meclisi

Nüfusu yüksek olan bölgelerde su temini, birden fazla kurumun ve iştiraklerinin meclis onayıyla gelen ortak çalışması şeklinde süreci işletmektedir [71].

2.2 Türkiye'de İklim Değişikliğinin Etkileri

İklim değişikliği, dünyadaki yaşamın tamamını küresel ölçüde etkileyen ve etkileri uzun süre devam edecek olan bir tehdittir. Son yüzyıldaki dünyadaki ortalama yüzey sıcaklığı yaklaşık olarak 0.75 °C artmıştır [72]. Stern ise yayınladığı çalışmasında orta derece kuraklığın 2090 yılına kadar %50'ye çıkacağını, aşırı kuraklığın ise aynı tarihe kadar %30'a çıkacağını vurgulamaktadır [73]. İklim değişikliği etki alanları çeşitli alan veya sektörlerle sınırlı kalmayıp canlı yaşamının her alanına etki etmektedir. Bu etki alanlarının en başında içme suyu, sağlık, tarım ve endüstri gibi alanlar sayılabilir. İklim değişikliğinin çevre ve insan hayatına olan

etkilerini incelemek ve mücadele etmek amacıyla birçok  lke Paris Anlařmasını imzalamıřtır [74].

T rkiye’de iklim deęiřiklięi etkilerinden etkilenecek olan hidrolojik deęiřkenlerin en  nemlilerinden biri akımdır. Yildiz vd. [75], T rkiye’de iklim deęiřiklięinin akıma olan uzun s reli (1960-2000 yılları arası) etkilerinin,  zellikle mevsim d ng s ne ve su dengesine olan etkisini ve deęiřimini incelemiřlerdir. Bu  alıřmada 10’ar yıllık periyodik deęiřimler incelenmiř ve genel yapı ile deęiřimler tartıřılmıřtır. Arnell [76] iklim modelleme ve projeksiyonunda, Avrupa’da ve T rkiye’de iklim deęiřiklięinin b y k  apta etkilerinin 2050 yılıyla bařlayacaęını vurgulamıřtır.

İklim deęiřiklięinin yaęıř ve sıcaklık gibi meteorolojik deęiřkenler  zerine olan etkisi literat rde yaygın olarak  alıřılan  nemli bir alandır. Yaęıř rejimlerinin iklim deęiřimleriyle beraber olan deęiřimi, etkilenen b lgeyi daha kırılgan ve tehditlere a ık hale getirir. T rkiye’nin g ney havza b lgeleri de bu iklim deęiřiklięinin sonucu olan kırılganlık ve tehditlere a ık durumdadır [77]. T rkiye bulunduęu coęrafi konum nedeniyle farklı iklim tiplerine sahiptir ve genel olarak havzalarda azalan yaęıř ve y kselen sıcaklıklar eęilimi vardır [78]. İyig n vd. [78] T rkiye’yi  eřitli klimatik alanlara ayırıp bu b lgelere meteorolojik deęiřkenlerin uzun d nemli etkisini incelemiřtir. Bu etkilerin yanında, kentleřme ve ormanlık alanların azalması da iklim deęiřiklięinin var olan etkilerini arttıran durumlardır. Bu nedenlerle hidroloji alanında iklim deęiřiklięinin  evre  zerine olan etkileri giderek  nemi artan  alıřma alanları haline gelmiřtir [79].

3.1 Yapay Sinir Ağları (ANN)

Yapay sinir ağları, biyolojik olarak insan beyin hücrelerinin işleyişinden esinlenerek modelleme dizaynı yapan bilgisayar programlarıdır. Bu yöntemler bütünü mantıksal ve tümevarımsal bilgi edinme araçlarını, karar verme ve problem çözme yolu için beyin iç sisteminin karar alma yolunu simüle eden süreçlerdir [80]. Yapay sinir ağları desenler ve veri içindeki ilişkileri tecrübe yoluyla işleyen algoritmalarıdır. Yapay zeka yöntemleri içerisinde yaygın olarak kullanılan metotlar bütünüdür.

3.2 Yapay Sinir Ağlarının Tarihçesi

YSA ile ilgili ilk kaynak çalışma, 1943 yılında McCulloch ve Pitts [81] tarafından tek nöronla yaptıkları sinir aktivitesinin modellenmesidir. Bu çalışma birden çok girdinin olduğu ve tek çıktı değerine sahip, sonucu hücre aktivitesinin olmadığı veya olduğu durumu ortaya koymaktaydı. Daha sonra bu modelleme Hebb [82] tarafından sinir ağları arasındaki ilişkiyi güçlendiren bir matematiksel kurallar dizisi ile geliştirilmiştir. Bu kurallar dizisi oluşturulduktan sonra 1958 yılında Rosenblatt [83] bir ağın başladığı başlangıç zamanını belirleyecek olan girdi değişkenlerinin ağırlıklı lineer kombinasyonları olan *perceptron (algılayıcı)* çıktısını oluşturmuştur ve bu alanda yapılan çalışmalar gelişerek devam etmiştir. 1982 yılına kadar çeşitli kısıtlamalar altında gelişemeyen yapay sinir ağları [84], Hopfield [85] tarafından bu kısıtlamaları ortadan kaldıran çalışmasıyla ilerlemesinde ciddi bir hız kazanmıştır. Artık sorun olmaktan çıkan limitasyonların en önemlisi ise nöron üzerinden işleme geçen çıktı ve girdi değerlerinin non-linearlığıydı [86].

YSA'ların bu dönüşüm ve gelişimlerinden sonra yaygın olarak günümüze kadar artarak kullanılmaya devam ettiği görülmüştür. Problem çözme algoritmaları, finans, fizik gibi bilimin nerdeyse tüm alanlarında kullanılmaktadır. Birçok alanda rahatça kullanılmasının sebebi, çok karmaşık olan sınıflama, karar verme problemlerini çözmede işe yarayan non-lineer yaklaşımıdır.

3.3 Temel Kavramlar

Yapay sinir ağlarının çalışma şekli, biyolojik olarak beynin en temel işlevlerinin performanslarından esinlenmiştir. Yapay sinir ağlarının önemli özellikleri, deneyimlerden öğrenme, önceki örnekleri kullanarak yenilerine genelleme ve gereksiz veriler içeren girdilerden anlamlı bilgiler çıkarabilmesidir.

Yapay sinir ağları örneklerle öğrenir. Bu tecrübelerle öğrenme yeteneği sayesinde, bilinmeyen problem veya örnekler üzerinde daha önce kullandığı, tecrübe kazandığı örnekler üzerinden çıkarım yapabilme işlevine sahip olur. YSA sonuç çıkarım durumunu girdi değişkenlerine ve parametrelere göre değiştirebilir. Bir ağ eğitildikten sonra veride var olan az sayıda değişikliklerden etkilenmez. Uygulamalarda bu gibi sorunlu durumlarda (noise ve distortion) verimli bir şekilde tanıma ve çıkarım yapma yeteneği YSA'ları birçok alanda kullanıma uygun hale getirmiştir. YSA bilgiyi çıkarım yapmak amacıyla sinir nöron yapısı gibi dağıtım ve hızlı şekilde işleyebilir.

Yapay sinir ağları çoğunlukla yüksek sayıda veri içeren sistemlerde çözüm aracı olarak kullanılır. Genel olarak YSA uygulamaları kendi içinde tahminleme, sınıflama, veri filtreleme ve optimizasyon gibi adımları içerir.


Yapay sinir ağlarının ilk temel ilkeleri McCulloch ve Pitts [81] tarafından ana 5 varsayım altında şu şekilde toplanmıştır.

- Nöron hareketliliğinin sonucu vardır ya da yoktur (binary).
- Bir nöronun uyarılması için sabit sinapsis sayısı 1'den büyük olmalıdır.
- Sinir sistemi içindeki tek önemli gecikme sinaptik gecikmedir.
- Herhangi bir sinapsın aktivitesi, o sırada nöronun uyarılmasını kesinlikle engeller.

- Birbirine bağı ağ yapısı zamanla değişmez.

Daha sonra çeşitli kısıtlamaları da içeren bu temel varsayımlar değişerek gelişmiştir [87].

Ortalama bir beyni ele aldığımızda yaklaşık olarak 100 milyar nörondan oluşmakta ve bu nöronların birbirleriyle olan bağlantıları 100-10000 arasında değişmektedir [80]. Nöronlar, çekirdek, hücreye bilgi taşıyan basamaklar (threads), dendritler ve sinyali uzağa taşıyan aksonlardan (axon) oluşmaktadır (Şekil 3.1).




Şekil 3.1 Sinir hücresi örneği

Sinir hücreleri (nöronlar) tamamen birbirine bağı alıcı ve gönderici görevi üstlenen impulslarla işlevini sürdürür [80]. Bu yapı öğrenme, sınıflama, tahminleme ve tanıma yetkinliğine sahip, kompleks problemleri çözen verimli bir sistemi oluşturmaktadır.

Temel bir nöron ağ yapısı üç ana farklı katmandan (layer) oluşur. Bu katmanlar Input (giriş), Hidden (gizli) ve Output (çıkı) olmak üzere üçe ayrılır. Hidden layer (gizli katman) ise input verisindeki bütün hesaplamaların yapıldığı nöron grubunu temsil etmektedir. En basit sinir ağı modeli tek hidden layer içerir. YSA modellerinin algoritmaları, geriye yayılım sürecini kullanarak ağırlıkları değiştirerek hedef değer ile tahminler arasındaki artıkları en aza indirmeyi amaçlar.

YSA'nın ana yapısını oluşturan birim nöronlardır. Beyin yapısı çalışma şeklini simüle edecek şekilde oluşturulan bu yapılarda gelen impulslara giriş (*input, x_i*) ismi verilmektedir. Ağırlıklandırılarak (*w_i*) aktivasyon ve transfer fonksiyonu


uygulanır ve çıktı değeri (y) elde edilir. Aktivasyon fonksiyonu amaca ve kullanım alanına yönelik değişebilen yapılardır [88]. Nöron içi transfer yapıları (transfer fonksiyonu) iki seçenekli basit çıktı (binary output) sinyali olacak şekilde, şu formülasyon biçiminde $X_s = (x_{1s}, x_{2s}, \dots, x_{ms})$ olarak yazılır. Basit YSA nöron modeli Şekil 3.2’de verilmiştir.



Şekil 3.2 Basit YSA nöron modeli

Burada bias (b) ise girdi değerleri ve ilgili ağırlıklar arasındaki ürünün toplamına eklenen sabit bir değerdir. x girişi ağırlık değeri w ile çarpıldıktan sonra bir sonraki düğüme doğrusal bir kombinasyon olarak geçilir. Daha sonra, birleştirilmiş değer aktivasyon fonksiyonunun durumuna göre dönüştürülür ve bir sonraki katmana sinyal olarak iletilir. Bu işlemler sonrasında nihai çıktı değeri y elde edilir.

Nöronlar model çalışmalarında ağırlık vektörleri $W_j = (w_{j1}, w_{j2}, \dots, w_{ji}, \dots, w_{jm})$ şeklinde gösterilmektedir. X_s 'in değerleri üzerinden transfer fonksiyonu yardımıyla hesaplanan çıktı değeri a sınırlı aralığında Eşitlik 3.1 ve 3.2’deki gibi formülize edilir ve bu fonksiyonun genellikle iki formu vardır (sigmoid ve tanh).



Şekil 3.3 İki farklı transfer fonksiyonu (a:sigmoid, b:tanh) [89]

Bu iki farklı transfer fonksiyonları aşağıdaki gibidir (sigmoid ve tanh).

$$y_j = \frac{1}{1 + e^{-a_j(Net_j - \theta_j)}} \quad (3.1)$$

$$y_j = \frac{1 - e^{-a_j(Net_j - \theta_j)}}{1 + e^{-a_j(Net_j - \theta_j)}} \quad (3.2)$$

Burada Net_j giriş değişkenlerin doğrusal kombinasyonlarını ifade etmektedir.

$$Net_j = \sum_{i=1}^m w_{ji} x_i \quad (3.3)$$


Transfer fonksiyonu bütün nöronlar için öğrenme sürecinde değişmez. Ama bu öğrenme sürecinde ağırlıklar (eşik değeri olan θ ve eğim değeri olan a_j 'ye bağlı olarak) değişir. Her bir ağırlık miktarı nörona gelen sinyalin oranını temsil etmektedir [89].

Yapay nöronun çıktısı hem sinaptik ağırlıklara (w) hem de aktivasyon fonksiyonuna (f) bağlıdır. En çok kullanılan aktivasyon fonksiyonları sigmoid, hyperbolic tangent, radial basis, piecewise linear ve linear aktivasyon algoritmalarıdır.

Sigmoid fonksiyonu

Sigmoid fonksiyonu formülü ve gösterimi aşağıdaki gibidir.

$$y(x) = f(x) = \frac{1}{1 + e^{-x}} \quad , \quad 0 < y < 1 \quad (3.4)$$




Şekil 3.4 Sigmoid fonksiyonu

Hiperbolik tanjant fonksiyonu

Hiperbolik tanjant fonksiyonu formülü ve gösterimi aşağıdaki gibidir.

$$y(x) = f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad , \quad -1 < y < 1 \quad (3.5)$$




Şekil 3.5 Hiperbolik tanjant fonksiyonu

Radyal tabanlı aktivasyon fonksiyonu

Gaussian fonksiyonu radial tabanlı süreçler içerisinde en yaygın olarak kullanılan yaklaşımdır. Formülü ve gösterimi aşağıdaki gibidir.

$$y(x) = f(x) = \exp\left(\frac{-x^2}{2}\right) , \quad 0 < y < 1 \quad (3.6)$$




Şekil 3.6 Radyal tabanlı gaussian aktivasyon fonksiyonu

Piecewise linear aktivasyon fonksiyonu

Piecewise linear fonksiyonu formülü ve gösterimi aşağıdaki gibidir.

$$f(u(t)) = \begin{cases} +1 & \text{if } gu > 1 \\ gu & \text{if } |gu| < 1 \\ -1 & \text{if } gu < -1 \end{cases} \quad (3.7)$$




Şekil 3.7 Piecewise linear aktivasyon fonksiyonu

Linear aktivasyon fonksiyonu

Linear aktivasyon fonksiyonu formülü ve gösterimi aşağıdaki gibidir.

$$f(u(t)) = gu(t) \quad (3.8)$$




Şekil 3.8 Linear aktivasyon fonksiyonu

Aktivasyon fonksiyonunun seçimi, sinir ağının kullanıldığı uygulamaya ve ayrıca nöronun seviyesine (hangi katmanda) bağlıdır. Sigmoid ve hiperbolik aktivasyon fonksiyonları tahminleme süreçlerinde iyi performans veren algoritmalarlardır. Doğrusal fonksiyon (linear), ileri beslemeli ağlarda çıkış katmanında kullanılabilir. Radyal bazlı fonksiyonlar ise sınıflama, özellik tanıma gibi alanlarda performansı yüksek olan fonksiyonlardır.

3.4 Eğitim ve Öğrenme Süreçleri

Eğitim (training) ve öğrenme (learning) süreçleri YSA'nın en önemli adımlarındandır. YSA modelleri ve algoritmaları ilgili çalışma alanına göre seçilip temel yapı sistemi oluşturulduktan sonra artık model eğitim (training) sürecine geçilir. Bu eğitim süreci denetimli (supervised) ve denetimsiz (unsupervised) eğitim süreci olarak ikiye ayrılır. Denetimli ve denetimsiz öğrenme çoğunlukla YSA'da sınıflama (classification) ve tahminleme (prediction) ihtiyacında kullanılan göreceli olarak yüksek performans veren sistemlerdir.

Denetimli öğrenme giriş veri/verileri üzerinden belirlenen hedef çıktısını tahminlemeyi amaçlar. Bu ağ türü, giriş katmanı, çıkış katmanı ve bunlar arasındaki gizli katmanlar halinde düzenlenmiş, tamamen birbirine bağlı nöronlardan oluşan bir sistemdir [90]. Burada bilgiler ağırlıklarıyla birlikte nöronlar arasında iletilir. Çıktının daha tutarlı sonuçları vermesi için bazı içsel bağlantılar güçlendirilir veya zayıflatılır. Denetimli öğrenmenin genel akışı Şekil 3.9'dan incelenebilir [91].




Şekil 3.9 Denetimli öğrenme akışı

Denetimli öğrenmede en çok kullanılan algoritma tipi geri yayılım (back propagation) algoritmasıdır. Geriye doğru besleme algoritması, var olan ağırlıklandırmaları düzenleyerek tahmindeki hata oranını en aza indirmeyi ve tekrarlamamayı amaçlar. Süreçte, gizli katmandaki işlemlerin sayısı ve işlem hızı belirlenen nöron ve giriş sayısı ile doğrudan ilişkilidir. Az sayıda gizli katman sayısı eğitim sürecini engelleyebileceği gibi, çok fazla sayıda olması da tahminlemeyi yanıltıcı sonuçlar oluşturacaktır [88].


Denetimsiz öğrenme tipinde ise denetimli öğrenmenin aksine çıkış birimleri belli değildir. Giriş verisinin hangi özelliklerini kullanacağına algoritmanın kendisi karar vererek işlemi sürdürür. Bu süreçte nöron kendi aralarında gruplara ayrılır. Grup nöronların tepki gücü çıktının ne olacağı ya da olmayacağı konusunda bilgi sistemini, gizli katmandaki işlemsel gücünü etkiler. Burada eğitim setinin amacı veri içinde yer alan desenleri (pattern) belirleyip belirlenen desenleri iç özelliklerine göre gruplamaktır. Daha sonra grupladığı bilgi aracılığıyla en tutarlı

ve performanslı tahminlemeyi gerçekleştirmektir [87]. Denetimsiz öğrenmenin genel akışı Şekil 3.10'dan incelenebilir [91].



Şekil 3.10 Denetimsiz öğrenme akışı

Öğrenme süreçlerinden bir diğeri de pekiştirmeli öğrenmedir (reinforcement learning). Pekiştirmeli öğrenme, davranışçılıktan esinlenen, öznelere bir ortamda en yüksek ödül miktarına ulaşabilmesi için hangi eylemleri yapması gerektiğiyle ilgilenen bir makine öğrenmesi yaklaşımıdır. Bu problem, genellikle oturma oyunu kuramı, kontrol kuramı, yöneylem araştırması, bilgi kuramı, benzetim tabanlı eniyileme ve istatistik gibi birçok diğer dalda da çalışılmaktadır. Nasıl ki insanlar daha önce edindikleri bilgilerden yararlanarak ya da olağan süreçle karşılaştırmalar yaparak öğrenebiliyorsa, gerçek hayatta da doğduğumuz andan itibaren hem kendimiz hem de çevremizdekiler tarafından, çevre ve çevre ile etkileşime girerek öğreniriz. Bu algoritmanın da işleyiş şekli bunu taklit eder (Şekil 3.11) [91].




Şekil 3.11 Pekiştirmeli öğrenme (reinforcement learning) süreci

Makine öğreniminin bu YSA öğrenme tipini de içeren amacı, genellikle bir öğrenme aracı olarak adlandırılan öğrenme ve değişim süreci aracılığıyla akıllı programlar üretebilmektir. Pekiştirmeli öğrenmede, ortam (environment) genellikle bir Markov Karar Süreci (MKS) olarak modellenir. Pekiştirmeli öğrenme, doğru girdi/çıktı eşleşmelerinin verilmemesi ve optimal olmayan eylemlerin dışarıdan düzeltilmemesi yönleriyle denetimli öğrenmeden ayrışır.

Makine öğrenmesi ve YSA'da veri seti bölümlenmesi genellikle eğitim (training), test ve validasyon (bazı algoritalarda sadece eğitim ve test olarak iki gruba ayrılabilir) olmak üzere üç ayrı gruba ayrılır. Eğitim verisinin en iyi şekilde oluşturulması ve test edilmesi modelin tutarlılığı ve iyi performansla çalışması açısından önem arz etmektedir. Bu bölümleme %70 eğitim, %15 test ve %15 validasyon (ya da %70 eğitim, %30 test) gibi oranlarla ayrılabilir. Bölümleme oranları çoğunlukla araştırma alanına ve araştırmacının kendi kararına bağlıdır.

Yapay sinir ağları ve makine öğrenmesi alanında kullanılan diğer öğrenme tipleri de online (çevrimiçi) ve offline (batch yada çevrimdışı) öğrenmedir.

Online (çevrimiçi) veri akışının modele sürekli olarak devam ettiği ve her gelen veri ile anlık modelin eğitiminin sürdüğü bir öğrenme tipidir. Yapay sinir ağları ve makine öğrenmesi sistemleri için online öğrenme çoğunlukla daha hızlı otonom şekilde çalışan, offline öğrenmeye göre verimi daha yüksek olan öğrenme şeklidir. Sisteme giren her bir yeni veriyle eğitimi gerçekleştirdikten sonra o veriye bir daha ihtiyaç duymadığından zaman, maliyet ve yer kaplama açısından iyi bir alternatiftir. Online öğrenmenin genel akışı Şekil 3.12' den incelenebilir




Şekil 3.12 Online (çevrimiçi) öğrenme süreci

Çevrimiçi öğrenmenin en önemli yönlerinden biri öğrenme oranıdır. Yüksek oranlı öğrenme oranına sahip model elinde var olan bilgileri daha çabuk unutmaya eğilimlidir. Düşük öğrenme oranına sahip modeller ise daha çok offline öğrenme mantığına yakınsar. Buradaki en büyük dezavantajlı nokta ise, eğer model düzenli olmayan, kötü toplanmış bir veri seti ile beslenirse etkisi anlık olarak hissedilecektir. Bu yüzden modele eklenen giriş verilerinin dikkatle incelenmesi gerekir.

Offline (çevrimdışı) öğrenme, veriseti üzerinden oluşturulan eğitim setinin günlük, haftalık, aylık gibi çeşitli aralıklarla modele taşır. Sürekli olarak artan veri sayısı her yeni model değerlendirme süresinde giriş birimleri olarak işlenir. Çevrimdışı girdilerle eğitilmiş modeller oluşturmak, modellerin daha önce yapılmış olan tüm eğitim veri seti ile eğitilmesini gerektirir. Yinelenen verilerin sürekli olarak eğitimi modelin gelişimi için gereklidir. Belirli süre aralıkları ile yenilenen alanlarda çoğunlukla tercih edilen offline öğrenme tipi maliyet ve işlem hızlarının (veri ve model parametrelerine bağlı olarak) uzun sürdüğü bir öğrenme tipidir. Bu modellemede eğitilen verinin ilgili aralıklarla performans göstergeleri (hata oranları) incelenmeli, zaman, kaynak ve maliyet açısından değerlendirilmelidir.

Genel olarak öğrenme tiplerinin amaçlarına yönelik sınıflandırmaları Şekil 3.13’ de verilmiştir.




Şekil 3.13 Öğrenme (learning) tipleri

3.5 Yapay Sinir Ağları Tipleri

Makine öğrenmesi (machine learning), derin öğrenme (deep learning) alanlarında sıklıkla birlikte kullanılan bir yöntemler topluluğu olan yapay sinir ağları genel olarak ileri ve geri beslemeli olarak ikiye ayırabiliriz. Literatürde yapılan YSA sınıflamalarını genel olarak ele aldığımızda ileri beslemeli ağları, tek katmanlı algılayıcılar (single layer perceptron), çok katmanlı algılayıcılar (multi layer perceptron) ve radial tabanlı ağlar (radial basis networks) olmak üzere olmak üç ana gruba ayırabiliriz. Geri beslemeli ağları ise genel olarak iki ana gruba ayırabiliriz. Bunlardan ilki kendini düzenleyen haritalar (self organizing maps-SOM)'dir. İkinci olarak ise basit ve tam tekrarlayan ağlar olarak sınıflayabiliriz.

Yapay sinir ağı modelleri kendi içlerinde bilginin iletim, yönü, dağıtım şekli, nöronların birbirine bağlanma ve gruplanma şekilleri gibi özelliklerine göre gruplara ayrılır. YSA yöntemlerinin genelleştirilmiş sınıflandırma hali Şekil 3.14' de verilmiştir.




Şekil 3.14 YSA sınıflandırma şeması

Direk dağıtım (iletim) ağı üzerinde işleyen YSA'lar daha çok tahminleme ve sınıflama problemlerinde kullanılır. Bu dağıtım zincirinin tersine çalışan algoritmalar (Kohonen ağları vb.) çoğunlukla veri indirgeme ve şıkıştırma gibi işlemlerde kullanılır. Geri beslemeli (recurrent feedback) teknikler sınıflama ve filtrelemede, radial tabanlı yöntemler karar almada, sınıflamada ve tahminleme problemlerinde yer alır. SOM (Self Organizing Maps) algoritmaları kümeleme ve sınıflama ihtiyacı olduğunda işleme alınabilecek bir yapay sinir ağı algoritma çeşididir [92]. Şekil 3.14' te verilen sınıflandırma gruplarının detaylı anlatımı sonraki başlıklarda mevcuttur.

Tek Katmanlı İleri Beslemeli Ağlar (Single Layer Feed-Forward Networks)

Tek katmanlı ileri beslemeli sinir ağları iletim dalları yapısından oluşur. Basit olarak girdi (input) ve çıktı (output) sisteminden oluşur. Bu tip yapay sinir ağının genel akışı Şekil 3.15' de verilmiştir.




Şekil 3.15 Tek katmanlı ileri beslemeli sinir ağı örneği

Bu tip algoritmada, giriş nöronlarının iletim dalları, çıkış nöronlarının bilgiyi dağıtan ve ileten noktalarıyla süreç tamamlanır. Tek katmanlı bir ağda giriş nöronu çıkış nöronuna tek bir iletim ağıyla bağlanabilir.

Multiple Layer Feed-Forward Networks


Literatürde en çok kullanılan sinir ağı tipi ileri beslemeli (feed-forward) sinir ağlarıdır. Bu tipte bilgi akışı giriş biriminden çıkış birimine doğru sadece ileri yönlüdür [93]. Şekil 3.14 ve Şekil 3.17’ de Çoklu katman ileri beslemeli sinir ağı modeli örneği verilmiştir. Çoklu katman bir ileri beslemeli ağda, nöronlar girdi, gizli ve çıktı katmanları olmak üzere üç aşamada düzenlenir.



Şekil 3.16 Çoklu katman ileri beslemeli sinir ağı modeli örneği 1

Çıkış nöronu, girdi verileri üzerinden gelen ve gizli nöronlarda hesaplanan işlemlerinin son halini gösterir. Gizli katman üzerinden hesaplanan birçok

fonksiyonun her bir çıktısı bu nöronlar tarafından oluşturulan lineer olmayan fonksiyonlardır.



Şekil 3.17 Çoklu katman ileri beslemeli sinir ağı modeli örneği 2

Bu tip ağ, N_i tane giriş (input), N_h tane gizli (hidden) ve N_o tane çıktı (output) katmanından oluşur ve aşağıda gibi formülize edilebilir.

$$y_j = g\left(\sum_{k=1}^{N_h} w_{jk} h_k + w_{j0}\right) = g\left\{\sum_{k=1}^{N_h} w_{jk} f\left(\sum_{i=1}^{N_i} w_{ki} x_i + w_{k0} + w_{j0}\right)\right\} \quad (3.9)$$

Burada g ve f aktivasyon fonksiyonunu, h_k k . gizli katmanı, w_{jk} k . gizli katmanın ağırlıklandırmasını ve j . çıktı birimini, w_{ki} ise k . gizli katmanı ve i . girişi temsil eder [86]. Çok katmanlı sinir ağları modellerinde sigmoid ve bipolar sigmoid aktivasyon fonksiyonları kullanılır. Yukarıdaki eşitlikten de görülebileceği gibi çıktı, hem parametreler hem de giriş verileri için lineer olmayan bir fonksiyondur [94-96]. Bu fonksiyon YSA'nın eğitimi (training) için kullanılır ve bu tip öğrenmeye ağ işleyiş şekli belli olduğundan veya tüm noktalarda bilindiğinden denetimli (supervised) öğrenme adını alır [86].

YSA'da eğitim bölümünün amacı, daha önce var olan tecrübelerden yararlanan sinir ağlarında tecrübe edilmiş eski bilgilerle (giriş ve çıkış verileri var olan), var olan veri için en iyi model parametrelerini bulmaktır. Bu da maliyet fonksiyonunun (cost function), yani tahmin değerlerimizle ölçüm değerlerimiz arasındaki farkın minimum olması demektir. Bu maliyet fonksiyonu artıkların hata

kareleri ise, bu eğitim (training) sürecine geri beslemeli (back propagation-BP) denir [97-99]. Eğitim sürecince her bir ağ ağırlığı aşağıdaki formüle değişir.

$$\Delta w_{ji}(t) = -\eta \frac{\partial E}{\partial w_{ji}} + \mu \Delta w_{ji}(t-1) \quad (3.10)$$

ı burada öğrenme oranını, μ momentum temsil eder.

Yapay sinir ağları alanında kullanılan birçok eğitim fonksiyonu (Levenberg–Marquardt, quasi-Newton, bayesyen vb.) vardır. Bu fonksiyonların en önemlilerinden biri Levenberg–Marquardt fonksiyonudur. Birçok YSA türünde de kullanılan bu eğitim fonksiyonu bizim çalışmamızda da ileri beslemeli geleneksel çok katmanlı YSA modeli içinde kullanılmıştır. Bu eğitim fonksiyonu Hessian matrisi hesaplaması yapmadan ikinci dereceden eğitim hızına yaklaşmayı amaçlar. Hata fonksiyonun bir tür kareli toplam olduğu varsayımı altında Hessian matrisine yakınsaması şu şekildedir.

$$H = J^T J \quad (3.11)$$

ve gradyan fonksiyonu ise,

$$g = J^T e \quad (3.12)$$

şeklinde hesaplanır. Burada J Jakobiyen matrisi, e ağ hatasını temsil eder. Jakobiyen matrisi hesaplamak Hessian matrisi hesaplamaktan güç ve hız olarak daha verimlidir. Formülizasyon en son olarak şu hali alır.

$$x_{k+1} = x_k - \left[J^T J + \mu I \right]^{-1} J^T e \quad (3.13)$$


Burada μ algoritmanın davranışını control eden skaldır. $\mu=0$ için yöntem yaklaşık Hessian matrisi kullanan Newton algoritmasına döner. μ yükseldikçe algoritma dereceli azalma (gradient descent) yöntemi halini alır [100].

Radyal Bazlı Ağlar (Radial Basis Networks)

Yapay sinir ağlarının bir alt türü olan radyal bazlı ağlar, orijin noktasına bağlı mesafeyi dikkate alarak (aktivasyon fonksiyonu dahil) katmanlar veya nöronlar arası iletişimi sağlayan YSA türüdür. Literatürde çok sıklıkla tercih edilen bir yöntem olmayıp, hidroloji alanında da (akım tahmininde) az sayıda çalışmaya rastlanmaktadır [101-104]. Moradkhani ve ark. [105] ise Self Organizing Radial Basis (SORB) yöntemini kullanarak günlük akım tahmin modeli oluşturmuşlardır. Bir radyal bazlı ağ en basit anlatımıyla giriş, gizli çıkış katmanları ile beraber radial bazlı aktivasyon fonksiyonunu içerir. Bütün hesaplama işlemleri gizli katmanda öklid uzaklık mesafesi üzerinden yapılır ve giriş değerleri için lineer olmayan dönüşümle beraber radyal bazlı fonksiyona iletilir. Bu algoritmanın kullanılması için katman sayısı, radial aktivasyon fonksiyonu ve eğitim ağı bilinmelidir [62, 106].

Geri Beslemeli Ağlar (Recurrent Feedback Networks)


Geri beslemeli ağlar (Recurrent feedback networks veya recurrent neural networks) genel ileri beslemeli ağlardan farklı olarak en az bir tane geri besleme döngüsüne sahiptir. Burada en az bir hücrenin çıkışı kendi tarafına ya da diğer ağ elemanlarına verilir ve bu iletim katmanlar arasında da meydana gelebilir. Bu tip ağlar sıralı olan bilgiyi en iyi şekilde kullanmayı amaçlar. Klasik sinir ağları mantığında bütün birimler birbirinden bağımsız olarak işlem yapılır ve gelecek tahminlemede çok önemli sorunlara yol açabilir. Geri beslemeli ağlar bütün tahminleme (output) sürecinde kendisinde daha önce yapılan hesaplama ve veri girdisine bağımlıdır. Geri beslemeli YSA, doğrusal olmayan dinamik bir yapıya sahiptir. Bu nedenle, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir. Şekil 3.18’de iki katmanlı ve çıkışlarından giriş katmanına geri beslemeli bir yapay sinir ağı yapısı görülmektedir [107].



Şekil 3.18 Geri beslemeli ağlar modeli

Kendini Düzenleyen Haritalar (Self Organizing Map-SOM)

Kohonen tarafından geliştirilen ve Kohonen algoritması olarak da bilinen bu tekniğin tarihi 1982 yılına dayanmaktadır [108, 109]. Bilimin birçok alanında kullanılmakta olan bu yöntemin hidroloji ve klimatoloji alanında da kullanımı yaygındır [110-113]. Bu uygulamalar genellikle uydu verileri üzerinden elde edilen akım ve yağış gibi değişkenlerin dönemsel trendleri ve tahmin modelleri oluşturmak üzerinedir. SOM ağlarının genel kullanım şekli çok boyutlu (high dimensional) giriş verilerini çeşitli özelliklerine göre gruplayıp çoğunlukla iki boyutlu (two dimensional) hale getirmektir. Bu tekniği kullanmanın iki önemli avantajı vardır. Birinci avantajı bu yöntemin lineer olmayan bir sistem oluşturmasıdır ve ikinci avantajı ise verinin topolojik özelliklerini korumasıdır [114, 115]. Kohonen tarafından geliştirilen bu yöntemin akış diagramına Şekil 3.19'dan ulaşılabilir [116].



Şekil 3.19 Kendini Düzenleyen Haritalar (SOM) modeli

SOM yönteminin uygulama adımlarını ana 3 kategoriye ayırabiliriz [111].


- *Veri toplama ve veri normalizasyonu aşaması* : verileri $[0,1]$ gibi aralığa dönüştürmek [117, 118].
- *Eğitim verisinin oluşturulması* : bu adımda kullanılacak iterasyon sayısının çıktı nöron sayısının en az 500 katı olması önerilir [118, 119].
- *Bilgi çıkarımı*: verinin eğitim süreci tamamlandıktan sonra sonuçlar kümeleme analizi veya birçok görselleştirme araçları yardımı ile çıkarılır.

3.6 Dalgacık (Wavelet) Dönüşümü

Dalgacık dönüşümü (wavelets transform) yöntemi ilk olarak sismik araştırmalarda petrol ve değerli madenlerin keşfinde toprak katmanlarının görüntülerini elde etmede kullanılmıştır. Dalgacık dönüşümleri bilimin birçok alanında kullanımı artmakta ve geliştirilmeye devam etmektedir. Çoğunlukla resim işleme (image processing), veri sıkıştırma (data compression) gibi alanlarda kullanıldığı görülmektedir. Sinyal monitorü (signal monitoring), güç ve enerji araştırmalarında sıklıkla kullanılan dalgacık sistemi özellikle yeryüzünü ilgilendiren deprem ve su araştırmaları gibi alanlarda yüksek öneme sahiptir. Dönüşümler veriyi çeşitli limitasyonlardan (noise vb.) kurtarma amacı ile ayırtıran bir metottur. Wavelet, süreçlerin ve ilişkilerinin zamansal bir tanımını sağlamak için zaman-frekans uzayındaki zaman serilerini çözen zamana bağlı bir spektral analiz yaklaşımıdır [120].

1807 yılında Joseph Fourier dönüşümünü üzerine Paul Levy tarafından inşa edilen Haar fonksiyonu ile beraber, Jean Morlet ve Alex Grossman sinyal izleme sistemini ilk dalgacık dönüşüm mantığına oturtmuşlardır. Bu sistem dalgacık dönüşümlerinin temelini oluşturmuştur [121]. Ingrid Daubechies bu gelişmelerin üzerine 1990 yılında kendi wavelet (dalgacık) fonksiyonlarını tanıtmıştır [122, 123].

Literatürde yer alan ilk sinyal tipi veri araştırmalarında çıkarımlar Fourier dönüşümü kullanılarak yapılmaktaydı [124]. Frekans lokalizasyonu sorunu ortaya çıkan bu dönüşümde, Gabor bu soruna Short-Time Fourier Transform (STFT) çözümünü getirmiştir. Heisenberg 'in belirsizlik ilkesi nedeniyle STFT'nin en iyi zaman veya frekansta ortak dalgacıkları oluşturması mümkün değildi [125, 126]. Dalgacık dönüşümleri bu ve benzeri sorunları herhangi kısıtlamaya uğramadan çözerek hem zaman hem frekans aralığında ölçeklenebilir dönüşümler halini almıştır. Şekil 3.20, STFT ile dalgacık dönüşümünün nasıl grafik olarak farklılık gösterdiğini temsil etmektedir.



Şekil 3.20 Farklı frekans, zaman ölçekleme şekilleri a) Short-Time Fourier Transform ve b) Dalgacık dönüşümü

Fourier dönüşümü fonksiyonları trigonometrik polinomlar ekleyerek genişletirken, dalgacık dönüşümleri fonksiyonları dalgacıklar şeklinde (başlangıç noktası olarak mother wavelet (ana dalgacık) kullanılır) genişletir. Bu dalgacık dönüşümleri en iyi zaman ve frekans lokalizasyonunu L^2 fonksiyonlarında vermektedir. L^2 , Hilbert uzayı olarak da bilinen 3 boyuttan daha fazla boyutun yer aldığı, öklid uzaklığının kullanıldığı uzaydır. Dalgacıklar ölçeklenmeye göre genişleyen fonksiyonlardır [127, 128]. Bu dönüşümlerin (Fourier, Gabor, Wavelet) Belirsizlik İlkesi ile olan ilişkileri literatürde çokça incelenmiş, bu durumu ihmal eden Fourier dönüşüm argümanı ile karşılaşmamıştır [129].

Belirsizlik İlkesi (Uncertainty Principle) 1927 yılında Alman fizikçi Werner Heisenberg tarafından ilk olarak ortaya konulmuştur. Belirsizlik ilkesi, bir parçacığın konumu ne kadar kesin olarak belirlenirse, momentumunun başlangıç koşullarından o kadar az kesinlikte tahmin edilebileceğini belirtir. Bu tersi durumda da geçerlidir [130]. Matematiksel olarak, Heisenberg belirsizlik ilkesine göre Fourier dönüşümü hem zaman hem de frekans aralığında kesin tahmin yapamaz [131]. Bu ilke günümüze kadar geçerliliğini korumuştur. Dönüşüm fonksiyonları Heisenberg'in Belirsizlik İlkesine muhalefet etmeden zaman ve frekans lokalizasyonu belirsizliğini minimuma indirgemeyi amaçlar. İlk olarak Fourier dönüşümü, daha sonra Fourier dönüşüm üzerine inşa edilen Gabor dönüşümü göreceli olarak daha iyi lokalizasyon sonuçları verdiğini literatürden

görebiliriz [120, 123, 132]. Feichtinger ve Grochenig ise belirsizlik ilkesini Gabor dalgacık dönüşümüne sinyalleri kontrol etmek için uygulamıştır [133].

Dalgacık dönüşümü ile yapılan geliştirmelerin temel amacı zaman ve frekans (konum) lokalizasyonundaki belirsizliği en aza indirmektir. Sürekli dalgacık fonksiyonlarını kullanarak belirsizliği minimize eden literatürde birçok çalışma bulunmaktadır [134, 135]. Dalgacık dönüşümü ise bu iki dönüşümden daha iyi ölçekleme sonuçları verdiği bilinmektedir [123].

Dalgacık dönüşümü, sinyalin ayrıntılarını (yüksek frekans) ve yaklaşıklığını veya eğilimini (düşük frekans) aynı anda daha iyi temsil eder. Çünkü dalgacık dönüşümleri (WT) değişken boyutlu bölgelemeyi en uygun aralıkta veya pencerede yapar (Şekil X.20(b)). STFT ise bu aralığı sabit olan bölümlerler şeklinde gerçekleştirir (Şekil X.20(a)).

Dalgacık dönüşümleri literatürde çoklu çözünürlük analizi (multi-resolution analysis) olarak da bilinir. Fizik, mühendislik ve yer bilimleri alanında çoğunlukla desen tanıma (pattern recognition, image processing) gibi alanlarda kullanılmaktadır. Öncelik olarak sinyal analizi ve ayrıştırması üzerine derinleşen dalgacık sistemleri giderek gelişerek günümüze gelen ve hala kullanım alanları çok geniş olan bir yöntemler bütünüdür (Tablo 3.1).

Tablo 3.1 Dalgacık dönüşümlerinin kullanım alanları

Alan Türü	Uygulama Tipi
Matematik	Harmonik analiz
Fizik	Uzay-faz analizleri
Sinyal İşleme	Çoklu hız filtreleme, kare ayna filtreleme, bant genişliği kodlama
Resim İşleme	Görüntü sıkıştırma
Ses İşleme	Etkin temsil ve eşitleme

Dalgacık dönüşümü sinyalleri zamana ve frekansa bağlı olarak gelişen bir sinyal sistemidir. Dalgacık dönüşümünün ana amacı zaman ve frekans lokalizasyonunu sinyal ayrıştırması (signal decomposition) yaparak sağlamaktır [123]. Örnek olarak müzik notaları müzisyene, hangi notayı (frekansı) verilen herhangi bir zamanda çalması için yol gösterir. Bu zaman ve frekans lokalizasyonu için Fourier dönüşümü $f(t)$ ile ilk olarak formülize edilmiştir.

$$f(w) = \frac{1}{\sqrt{2\pi}} \int F(w) e^{-iwt} dt \quad (3.14)$$

Burada f frekansı göstermektedir. Fonksiyon 3.14'te dönüşümün zaman lokalizasyonu içermediğinden Fourier dönüşümüne uygun aralıkta bir f sinyali (windowing the signal f) eklenir [136].


$$(T^{win} f)(w, t) = \int f(s) g(s - t) e^{-iws} ds \quad (3.15)$$

Eklenen aralıklı sinyal girdisinin kesikli olduğu durumlarda t ve w değerlerine aralıklı değerler atanır. Zaman lokalizasyonu eklenen fonksiyon 3.15'te $t = nt_0$, $w = mw_0$ ($t_0, w_0 > 0$ ve Z aralığında) olarak eklenir (n sabit).

$$T_{m,n}^{win}(f) = \int f(s) g(s - nt_0) e^{-imw_0s} ds \quad (3.16)$$

$T_{m,n}^{win}(f)$, $f(\cdot)g(\cdot - nt_0)$ için Fourier dönüşüm katsayılarıdır. Değişen n miktarına bağlı olarak ölçeklemeler t_0 anından itibaren başlar ve bütün f 'ler için fonksiyonları kesikli olarak işleme sokar. Fonksiyon temelindeki sinyal analizlerinde en iyi destek ve düzgünleştirmeyi veren g 'ler için birçok seçenek literatürdeki çalışmalara konu olmuştur [137, 138]. Bu seçenekler aynı anda hem zaman hem de frekans düzeyinde en uygun ve popüler olan Gaussian g 'dir (eğer g ve g' sıfır etrafında yoğunlaşmışsa en iyi zaman ve frekansa yakındır).

İşlemsel olarak ifade edilen bu sürecin görsel olarak temsili aşağıdaki Şekil 3.21'de verilmiştir.



Şekil 3.21 Fourier dönüşümü aralığı (the windowed Fourier transform)

$f(t)$ fonksiyonu aralık fonksiyonu olan $g(t)$ ile çarpılır ve Fourier katsayıları olan $f(t)g(t)$ hesaplanır. Daha sonra aralığın diğer versiyonları olan $g(t-t_0)$, $g(t-2t_0)$, ..., için tekrarlanır [120].

Fourier'den Dalgacık Dönüşümüne Geçiş

Dalgacık dönüşümü zaman frekans lokalizasyonunda Fourier dönüşümü mantığına yakın olmakla beraber bazı farklılıklarla ayrılır. Bu dönüşümün fonksiyonları aşağıda verilmiştir.

Sürekli durumlar için dalgacık dönüşümü:

$$(T^{wav} f)(a, b) = |a|^{-1/2} \int dt f(t) \psi\left(\frac{t-b}{a}\right) \quad (3.17)$$

Kesikli durumlar için dalgacık dönüşümü:

$$T_{m,n}^{wav}(f) = a_0^{-m/2} \int dt f(t) \psi(a_0^{-m} t - nb_0) \quad (3.18)$$

Hem sürekli hem de kesikli durumlar için ψ aşağıdaki durumu sağladığı varsayılır.

$$\int dt \psi(t) = 0 \quad (3.19)$$

Sürekli dalgacık fonksiyonu üzerinden üretilen kesikli fonksiyonda a , b sadece kesikli değerler olmak üzere aşağıda şartları sağlar.

$$a = a_0^m, \quad b = nb_0a_0^m, \quad a_0 > 1, \quad b_0 > 0, \quad \mathbb{Z} \text{ üzerindedir.}$$


Bu fonksiyonlarda $\psi^{a,b}$ dalgacık (wavelet) olarak isimlendirilirken, ψ ana dalgacık (mother wavelet) olarak adlandırılır. Literatürde birçok dalgacık tipi mevcuttur. En çok kullanılan dalgacık tipleri ise Biorthogonal, Coiflets, Daubechies, Haar, Meyer, Mexican Hat, Morlet, ve Symlets dalgacıklarıdır.

Örnek olarak Mexican Hat fonksiyonu, $\Psi(t) = (1-t^2) \exp(-t^2/2)$ olan Gaussian'ın ikinci türevidir. Dalgacık şeklinden dolayı bu ismi alan Mexican Hat fonksiyonu hem zaman hem de frekans durumunda iyi lokalize olan dalgacık türüdür [139].

$$\psi^{a,0}(s) = |a|^{-1/2} \psi(s/a) \quad (3.20)$$

Fonksiyon 3.20 dalgacık fonksiyonunun genel bir ifadesidir.

Burada a frekansı, b ise zamanı temsil eder. Ölçeklemede $|a|$ 'nın yüksek değerleri düşük frekans değerlerine, $|a|$ 'nın düşük değerleri ise yüksek frekans değerlerine karşılık gelmektedir. b parametresi ise zaman lokalizasyonunun hareketini sağlar. $\psi^{a,b}$ için $s=b$ olduğunda lokalize olmuş demektir. Wavelet ve Fourier dönüşümünün farklılığı kendilerini oluşturan fonksiyonların biçiminden kaynaklanır. Dalgacık fonksiyonlarında frekansların zamanla olan adaptasyonu Fourier dönüşümüne göre çok daha fazladır. Sonuç olarak, dalgacık dönüşümü, aralıklı Fourier dönüşümünden kısa süreli yüksek frekanslı olaylarda ve zaman, frekans birlikteliğinde daha iyi bir performansa sahiptir. Fourier ve Dalgacık dönüşümünün karşılaştırmalı görseli Şekil 3.22'de verilmiştir [140].




Şekil 3.22 Fourier ve Dalgacık dönüşümünün karşılaştırmalı görseli

Şekil 3.22’de (a) seçeneği sinyalin Fourier dönüşümdeki biçimini, (b) seçeneği sinyalin dalgacık dönüşümündeki biçimini ve (c) seçeneği ise sinyalin dalgacıklarda düşük veya yüksek ölçekli olmasında alacağı genel biçimi tasvir etmektedir.

3.7 Sürekli Dalgacık (Wavelet) Dönüşümü

Dalgacık dönüşümleri sinyalin karakteristik özelliklerini ortaya çıkaran matematiksel bir araçtır. Dalgacıklar kendinden daha küçük çeşitli salınımlara sahip olan zaman dalgalarından oluşur. Dalgalar genellikle belirli bir düzene ve

şekle sahiptir. Dalgacıklar ise belirli bir süre aralığında herhangi bir sıradışı şekle sahip olabilir [141]. Şekil 3.23’de bu açıklamanın görsel halini temsil etmektedir.



Şekil 3.23 Dalga (a) ve Dalgacık (b) sinyal gösterimi

Dalgalar, zaman değişiminden bağımsız veya durağan veri akışında çoğunlukla deterministik olarak Fourier dönüşümü üzerinden kullanılır. Dalgacıklar ise hem deterministik hem de non-deterministik, zaman değişimine adapte olmuş veya durağan olmayan veri akışlarında ayrıştırma yaparak kullanılır [142].

Sürekli dalgacık dönüşümünün formülize edilmiş hali aşağıdaki gibidir [143, 144].

$$\int_{-\infty}^{\infty} \frac{|\Psi(f)|^2}{(f)} df < \infty \quad (3.21)$$

Burada $\Psi(f)$, dalgacık fonksiyonu olan $\psi(t)$ ’nin Fourier dönüşümüdür. Sürekli dalgacık dönüşümüne geçişte ise kabul edilebilirlik şartı $\psi(t)$ ’nin sıfır frekansa sahip olduğu durumda Fourier fonksiyonunun artık var olmamasıdır. Bu ifadeyi şu formda ifade edebiliriz.

$$|\Psi(f)|^2 \big|_{f=0} = 0 \quad (3.22)$$

Fonksiyon frekansının sıfır durumunda olması demek, aynı esnada dalgacıkların ortalama değerinin zaman noktasının da sıfır olduğu nokta demektir. Zaman noktasının da sıfır olduğu nokta integrali aşağıdaki gibidir.

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (3.23)$$

Dalgacık zaman lokalizasyonunun sıfır olduğu nokta dalgacığın doğada var olduğu durumdur. Dalgacıklar gelen verinin veya sinyalin durumuna göre genişlerler veya çeşitli geçişler yaparlar (Şekil 3.22). Bu ölçekleme ve geçiş aşağıdaki fonksiyon yardımıyla belirlenir:

$$\psi_{s,\tau}(t) = \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right), \quad s > 0, \tau \in R \quad (3.24)$$

Burada $1/\sqrt{s}$, dalgacık koşullarının farklı ölçekleme durumlarında, ölçeklemeden etkilenmeden aynı durumda kalmasını sağlar. Örnek olarak dalgacığın yaydığı enerjinin farklı ölçeklendirme koşullarında bu fonksiyon yardımıyla aynı kaldığı şu şekilde ispatlanır (Eşitlik 3.25 ve 3.26) [141].

Dalgacığın yaydığı
enerji

$$\varepsilon = \int_{-\infty}^{\infty} |\psi(t)|^2 dt \quad (3.25)$$

Enerji, ölçeklendirme
ve geçiş fonksiyonu
uygulandıktan sonra

$$\varepsilon' = \left| \int_{-\infty}^{\infty} \frac{1}{\sqrt{|s|}} \psi\left(\frac{t-\tau}{s}\right) dt \right|^2 = \frac{1}{s} \int_{-\infty}^{\infty} \left| \psi\left(\frac{t}{s}\right) \right|^2 dt = \varepsilon \quad (3.26)$$


Bölümleme sayesinde $\psi(t)$ 'nin (mother wavelet) $\psi_{s,\tau}(t)$ (scaled wavelet) ile olan ilişkisi ayrıştırma Şekil 3.24'te temsili olarak verilmiştir.

Sürekli dalgacık dönüşümünü son haliyle ifade edecek olursak [145]:

$$wt(s, \tau) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^*\left(\frac{t-\tau}{s}\right) dt \quad (3.27)$$


Burada, $\psi^*(.)$ ölçeklendirilmiş (geçiş ve genişleme işlemleri tamamlanmış) ana dalgacıktır.

Fourier dönüşümü ayrıştırmayı tek boyuta indirgerken, dalgacık fonksiyonu ayrıştırmayı zaman ölçeklemesinde 2 boyuta indirger.



Şekil 3.24 Dalgacığın geçiş (zaman sabiti t' 'ye bağılı olarak) ve genişleme (s ölçeklemesi ile) süreçlerinin temsili gösterimi

Dalgacık dönüşümünde genel olarak geçiş (translation) ve genişleme (dilation) kısımlarını daha iyi anlaşılması için bir nabız (impulse) örneğini ele alabiliriz [146]. Bu ses sinyalinin şekilsel olarak dalgacık dönüşümüne doğru hareketi verilmiştir (Şekil 3.24).




Şekil 3.25 Sürekli tipte nabız sinyalinin geçiş (shift, translation) ve genişleme (dilation, stretch) parametreleriyle beraber Daubechies dalgacı ile olan süreci Fugal verdiği bu örnekte literatürde yaygın olarak kullanılan Daubechies (Db20) dalgacığını kullanmıştır. Bu şekilde A kısmı 20 Hz'lik (1/4 sn) bir nabız sinyalini göstermektedir. B ise $t=0$ anından itibaren başlayan Daubechies (Db20) dalgacığını gösterir ve orijinal nabız sinyalinin başlangıç zamanına kadar devam eder. Dalgacık ve sinyalin beraber olduğu an ise bize korelasyon katsayısını verir. B ve D sinyali arasındaki korelasyon şekilden de görüleceği üzere çok düşüktür. Genişleme (stretch veya translation, D evresi) ve geçiş (shift veya dilation, C evresi) evrelerini tamamlayan dalgacık (D), ilk olan nabız sinyaline (A) en yakın frekans ve zaman lokalizasyonunu sağlamıştır. Bu da yüksek derecede bir korelasyon derecesi anlamına gelmektedir.

3.8 Kesikli Dalgacık (Wavelet) Dönüşümü

Dalgacık dönüşümleri veride sıkıştırma (data compression), gürültüyü (noise) engelleme, resim ve sinyal işleme süreçlerinde sıklıkla kullanılan tekniklerdir [147]. Dalgacık dönüşümleri (wavelet transforms-WT) genel olarak sürekli (continuous-CWT) ve kesikli (discrete-DWT) şekilde ana iki gruba ayrılırlar. Bu bölümde kesikli dalgacık dönüşümü ele alınacaktır. Bu tip dönüşüm çoğunlukla zaman serisi tipinde veri alt setinde konum ve ölçeklemeye çok uygun olduğu için tercih edilmektedir [120, 148]. Bu tez çalışmasında da akım gözlem istasyonlarının uzun dönemli zaman serisi veri tipine kesikli dalgacık dönüşümleri uygulanmıştır.

Sürekli dalgacık dönüşümlerinde çeşitli genişleme ve dalgacık fonksiyonları kullanırken, kesikli dalgacık dönüşümlerinde ise çeşitli filtreleme sistemleri (filter bank) ve özelleştirilmiş dalgacık filtreleri kullanır.

Mallat [149] tarafından önerilen kesikli dönüşüm sinyalleri, ilgili veriyi çeşitli aralıklar bandına oturtarak filtrelemektedir ve literatürde filter bank olarak da geçmektedir. Bu filtreleme başlangıç noktası olan original sinyali kullanarak bantlar arası düşük (low-pass) veya yüksek (high-pass) geçirgenliğe göre algoritmik olarak tekrar ederek devam eder. İyi bir kesikli dalgacık dönüşümü yapılması; işlem hızı, veri düzenlemesinin iyi şekilde yapılması, frekans ve zaman parametrelerinin ayarı gibi etkenlere bağlıdır [150]. Şekil 3.26, Mallat tarafından kesikli dalgacık dönüşümü için önerilen düşük ve yüksek bant geçişlerinde dalgacık katsayılarının belirlenmesini gösteren diyagramdır.




Şekil 3.26 Düşük ve yüksek bant dalgacık katsayılarının belirlenmesi

Verideki her bir dalgacık katsayılarının ölçekleme ve lokalizasyonunun hesaplanması çok uzun bir süre ve güç gerektirdiğinden, çeşitli alt kümeler seçilmesi kesikli dalgacık dönüşümlerinde sıklıkla rastlanan bir durumdur [149].

Dalgacık dönüşümü yapıları lineerdir ve zaman değişiminden etkilenmezler [144]. Bu yapılar; kısa süreli sinyal verilerinde (impulse vb.) sinyalin boyutları ve işleme süreçleri bakımından analiz edilecek olursa, kesikli Fast Fourier dönüşümü veya kesikli dalgacık dönüşümü tercih edilebilir. Kesikli dalgacık dönüşümü Kesikli Fourier dönüşümünün aksine dalgacık dönüşümü için birden fazla katsayı verir. Kesikli olarak kullanılan değerler dalgacığın sınırlarını oluşturur ve oluşturulan katsayıları kullanarak birçok dalgacık filtrelemesine de geçişi mümkün kılar. Zaman ve frekans lokalizasyonu bakımından Fourier'den daha detaylı ve performanslı sonuçlar veren bir yaklaşımdır [120, 123, 128].

Kesikli Dalgacık Dönüşümde Filtreler

Kesikli tipte ayrıştırmanın ana ögesi olan filtreler, aldıkları sinyalleri belirlenen frekans bandına yerleştirirler. Bu frekans bantları yüksek veya düşük frekanslı bantlar olabilir [151]. Örnek olarak bunun gibi yüksek (high pass) ve düşük (low pass) frekanslı iki kanalı içeren Şekil 3.28'teki temsili akışlı bir kesikli dalgacık dönüşümünü ele alalım [152].



Şekil 3.27 Düşük ve yüksek bant içeren iki kanallı filtreleme

Kesikli olan $x(k)$ zaman sinyali, giriş sinyalinden gelen toplam frekansları eşit olarak yüksek ve düşük frekanslı olarak dağıtan bir analiz sistemi (analysis bank) tarafından filtrelendir. Burada filtrelerin çıktısı, frekans içeriği (Şekil 3.27'de c simgesi içeriği (content) temsil eder) olarak toplam frekansın yarı miktarını içerir. Eşit olarak yüksek ve düşük bant frekans kanalına giren örneklem sayısı ise aynıdır, yani iki kanala giren örnek sayısı giriş katmanına giren örneklem sayısı ile aynıdır. Bu da aslında Şekil 3.27'de sol tarafta olan bölümde normal olan veri sayısının iki katı (H ve L kanallarında aynı sayıda örnek içermesi) olması demektir. Bu yüzden iki faktörlü, $\downarrow 2$ ile gösterilen downsampling uygulanmıştır [152].

Filtreleme işleminin analizlerinin sonrasında ise ikinci kısma geçilir bu da yüksek ve düşük bant filtrelemesinden geçen orijinal sinyalin yeniden yapılandırılmasıdır (Şekil 3.27'de sağ taraf). Daha sonra burada veri içeriği yüksek ve düşük bant kanallarına $\uparrow 2$ faktörlü upsampling yapılarak orijinal sinyal yapısı (L' ve H' olarak) filtrelenerek $y(k)$ çıktısına ulaşılır [153].

Downsampling yöntemi kesikli dalgacık dönüşümünde gereksiz veri fazlalığını ve işlem süresinin artmasını engellemek amacı ile kullanılır. Bu 2 faktörlü yöntem sadece çift sayılı kanal sisteminin olduğu durumlarda bilgi kaybı olmadan süreci tamamlar [154]. Tek numaralı kanalların olduğu durumlarda veri Shannon örnekleme teorisi şartlarını sağlıyorsa veri kaybına uğramaz [155].

Kesikli dalgacık filtrelemesinin downsampling ve upsampling aşamalarında orijinal sinyalin en iyi şekilde yapılandırılması gerekir. Filtreleme esnasında kanallar arası istenmeyen veri geçişleri yeniden orijinal sinyal sentezinin oluşturulmasında veri kaybına neden olur. Şekil 3.27'de olduğu kanallar arası geçiş duvarları (brick wall filtreleri) ne kadar iyiye sinyalin yeniden yapılandırılması o kadar iyi olur. Teorik olarak bu en iyi yapılandırma mümkünse de, pratikte bantlar arası geçiş vardır ve bu da veride bozulmaya (distortion, aliasing) neden olur [152].

Daha önce verdiğimiz iki kanallı filtreleme örneğinde bu sorunları önlemek için yüksek (H) ve düşük (L) kanallar aşağıdaki durumları sağlamalıdır.

$$L'(z) = H(-z) \quad (3.28)$$

$$H'(z) = -L(-z) \quad (3.29)$$


Bu veri düzenlemesine ek olarak, bozulmayı (distortion) engellemek amacıyla bir ürün filtresi $P_o(z) = L'(z)L(z)$ tanımlanabilir. Bu eklenen filtre ile aşağıdaki eşitlik şartını sağlayarak bozulma engellenir [153].

$$P_o(z) - P_o(-z) = 2z^{-N} \quad (3.30)$$

Burada N filtre bankasındaki genel gecikmedir. En iyi orjinal sinyali yeniden yapılandırma işlemleri ise iki adımda özetlenebilir. Birinci olarak, eşitlik 3.29'u sağlayan P_o düşük bantlı filtre oluşturmaktır. İkincisi ise faktör örnekleme olan P_o 'i $L'(z)L(z)$ içine koymak ve Eşitlik 3.28 ve 3.29' u kullanarak $H(z)$ ve $H'(z)$ 'yi hesaplamaktır [152, 154].

Dalgacık dönüşümlerinde yüksek frekanslı bant aralığında (düşük ölçeklemeyle) daha iyi bir zaman tahmini önemlidir. Düşük frekanslı durumda (yüksek ölçeklemeyle) ise daha iyi bir konum (frekans) elde edilmesi önemlidir. Eğer dalgacık dönüşümü daha önce de belirttiğimiz gibi filtre bankaları (filter bank) kullanıyorsa bu dönüşüm kesikli dalgacık halini almıştır. Eğer sürekli bir dalgacık dönüşümü geçiş ve genişleme parametreleri vasıtasıyla kesikli hale getiriliyorsa bu dönüşüm DWT ile aynı sonucu vermez [120]. Kesikli dönüşümdeki filtrelerden sinyallerin yaklaşımları (approximation) ve detayları (details) elde edilir. Filtreleme işlemlerinin yani kaç seviye filtreleme işleminin yapılacağı araştırmacının ve ilgili alanın literatürünün kendi karar verdiği durumdur.

Örnek olarak analiz ve sentez kısımlarının (analysis ve synthesis bank) temsili olan, üç seviye içeren bir kesikli dalgacık dönüşümünü ele alalım. Şekil 3.28'de bu temsili örnek verilmiştir.




Şekil 3.28 Üç seviyeli filtre bank örneği

$c_1(k)$, giriş katmanından (a) gelen frekansların yarısının en düşük kısmını içerir. İkinci seviyede ise $L(z)$ ve $H(z)$ zaman çözülüm değeri iki katına çıkarken frekans içeriği azaltılır. Her bir seviyeden sonra, yüksek geçiş filtresi bir önceki düşük geçiş filtresinin en yüksek frekanslı içeriğini oluşturur. Bu iletim sistemini geçiş bandı olarak da adlandırabiliriz. Şekil 3.28'den da görüleceği üzere yüksek ve düşük bant filtrelerinin oluşturduğu bu altyapı kesikli dalgacık filtrelemesidir.

Kesikli dalgacık dönüşümünde ayrıştırma işleminin başarısı sinyalin, yani verinin ve seçilen dalgacığın tipine göre değişkenlik gösterir. Yüksek ölçekli veya düzenli dalgacıklar frekanslar arası farklılığı göstermede daha düzgün çalışmaktadır (daha yüksek hesaplama zamanı ile). Daha önceki kesikli dönüşüm şekillerine ek olarak dalgacıkların düşük ve yüksek frekanslı kanallarda nasıl bir yol izlediği ve ayrıştığı aşağıdaki tablo ve şekilde örneklendirilmiştir [122].

Tablo 3.2 Kesikli dalgacık dönüşümü frekans içerikleri

Altbant (subband)	$f_{\text{düşük}}$	$f_{\text{yüksek}}$
c_{lll}	0	62.5
c_{llh}	62.5	125
c_{lh}	125	250
c_h	250	500

**Şekil 3.29** Kesikli dalgacık dönüşümü

Burada $x(t)$ orijinal veri, yani giriş sinyalidir. Şekil 3.27 ve 3.28'de daha önce kesikli veri yüksek ve düşük frekans kanalları ile ölçeklenerek downsampling ve upsampling aşamalarından geçerek ayrıştırmayı tamamlıyordu. Şekil 3.29 ise bu ayrıştırmanın daha detaylı bir gösterimini temsil etmektedir. Dalgacıkların orijinal sinyale yaklaşması veya uzaklaşması, ilk verinin başlangıç ve bitiş verisinin hareketiyle ilişkilidir. Sinyallerin ayrışmasındaki farklılık, ilgili verinin frekansının

büyüklüğü veya küçüklüğü ile alakalıdır. Daha yüksek dereceli olarak belirlenen dalgacık, kendisini çevreleyen alt bantlarda daha az istenmeyen frekans içeriği üretecektir. Örnek olarak 0.2'lik zaman diliminde en yüksek frekanslarla dalgacık oluşmuştur.

Kesikli dönüşümün farklı frekans bantlarındaki dalgacık katsayıları çeşitli şekillerde işlenebilir. Filtreleme sürecinin ikinci kısmı olan sentez bölümünde ayrıştırılan ve yeniden yapılandırılan sinyaller dalgacık katsayılarına yapılacak olan çeşitli ayarlamalarla değiştirilebilirler ve orijinal sinyal ile karşılaştırılabilir. Bu filtreleme mantığı kesikli dalgacık dönüşümünü doğrusal filtrelemekten ayırır. Bu dönüşüm tipi sürekli dalgacık dönüşüm tipine göre hesaplaması daha kolaydır. Bununla beraber elde edilen dalgacık katsayıları, ölçeklemeden frekansa dönüşüm işlemi görmediğinden daha kolay yorumlanabilir [141].

3.9 Dalgacık (Wavelet) Tipleri


Literatürde birçok alanda kesikli dalgacık dönüşümlerinin daha iyi uygulanması amacıyla çeşitli dalgacık fonksiyonları geliştirilmiştir. Yüksek ve düşük frekans yoğunluklarının durumlarına göre geliştirilen dalgacık fonksiyonları orthogonal veya biorthogonal yapıdadır. En çok kullanılan dalgacık tiplerini Daubechies, Biorthogonal, Coiflets, Haar, Meyer, Mexican Hat, Morlet ve Symlets dalgacık tipi olarak sayabiliriz.

Haar

1910 yılında Haar tarafından bulunan ve üzerine birçok çalışma yapılan bu tip dalgacığın tanımlaması aşağıdaki gibidir [156]. Ortogonal ve simetrik yapıya sahiptir.

$$\psi_{Haar}(t) = \begin{cases} 1 & 0 \leq t \leq 1/2 \\ -1 & 1/2 \leq t \leq 1 \\ 0 & \text{diger} \end{cases} \quad (3.31)$$

Simetrik ve orthogonal yapıya sahip olması sinyalin ayrıştırma durumlarında (lineer karakteristiğe sahip) herhangi bir yapı bozulmasına, yani distorsiyona uğramaz. Var olan en basit dalgacık fonksiyonudur. Haar dalgacığının fonksiyon ve frekans yapısı Şekil 3.30’ da verilmiştir [142].



Şekil 3.30 Haar dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude)

Zaman lokalizasyonu konusunda yüksek tutarlılığa sahip olan Haar, dikdörtgen dalgacık şeklinden dolayı düşük frekans çözünürlüğüne (konumsal bilgi) sahiptir [120].

Daubechies

Ingrid Daubechies tarafından kesikli zaman aralığında süreci gerçekleştirebilen ortonormal bir dalgacık tipi olarak oluşturulmuştur [120, 123]. Ortogonal olmasına rağmen asimetrik bir yapıya sahip olan Daubechies dalgacığında distorsiyon faz oranı yüksektir. Bu da sinyal akış bilgilerinin saklanması gereken uygulamalarda kullanımını mümkün kılmaz [120]. Bu tez çalışmasının uygulama kısmında dalgacık tipi olarak Daubechies dalgacığı kullanılmıştır.

Daubechies dalgacığının genişliği $2N-1$ fonksiyonuna sahip ana dalgacık ile ortak harekete sahiptir (N : ana dalgacığın derecesi). $N=1$ olması durumunda ise bir diğer yaygın olarak kullanılan dalgacık olan Haar dalgacığı elde edilir. Bant genişliği arttıkça Daubechies dalgacığının düzgünleştirme giderek daha iyi duruma gelir ve daha iyi frekans lokalizasyonunu sağlar [123].


Dalgacık ve ölçekleme fonksiyonu derecesi 1'den 8'e kadar olan Daubechies dalgacığı için ilk derece (db1) matematiksel fonksiyonu aşağıdaki gibidir.

$$\psi(t) = \begin{cases} 1 & \text{eger } x \in [0 \ 0.5] \\ -1 & \text{eger } x \in [0.5 \ 1] \\ 0 & \text{eger } x \notin [0 \ 1] \end{cases} \quad (3.32)$$

$$\phi(t) = \begin{cases} 1 & \text{eger } x \in [0 \ 1] \\ 0 & \text{eger } x \notin [0 \ 1] \end{cases}$$


Daubechies dalgacığının derecesi arttıkça bu dalgacığı ifade etmek ve hesaplamak giderek zorlaşır. Dereceler dalgacıktaki sifıra eşit olan anları (vanishing moments) temsil eder [120]. Dalgacığın yaptığı salınımlar ile derecelendirmenin ilişkisi zayıf olsa da, bu noktalarda daha iyi frekans lokalizasyonu sağlanır ve farklı ölçeklerdeki dalgacık katsayıları arasındaki bağımlılık artan dalgacık sırası ile azalır [141, 157].

En kolay anlamda Daubechies dalgacığının zaman (ms) ve frekans (Hz) yapısı Şekil 3.31' de verilmiştir.



Şekil 3.31 Daubechies (a:db2, b:db4) dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude)

Daubechies dalgacık tiplerinin her bir seviyesinin daha detaylı biçimsel görünümü ise Şekil 3.32’de verilmiştir [158].




Şekil 3.32 Haar dalgacık dönüşümü seviyeleri

Coiflets

Ortogonal ve simetriğe yakın bir yapısı ile sıfıra eşit noktası fazla olan bir dalgacık türüdür. Bant genişliği $6N-1$ olan kanallar için en çok sıfıra eşit olan noktayı oluşturmak bu dalgacığın ana amacıdır ve Ingrid Daubechies tarafından ortaya konulmuştur [123]. Daubechies dalgacığından daha fazla sıfır noktasına sahiptir.


Coiflets dalgacığı ve ölçek fonksiyonu seviyeleri 1 ile 5 arasındadır ve bu seviyeler aşağıdaki şekildeki biçimler halini alır [120].



Şekil 3.33 Coiflets dalgacık dönüşümü seviyeleri

Symlets


Daubechies tarafından db grubundaki dalgacıklara ek özellikler ekleyerek ortaya çıkarılan ortogonal, simetriğe yakın ve en az asimetriye sahip bir dalgacık türüdür [123]. Db dalgacık grubuyla genel olarak aynı özelliklere sahip olan bu dalgacık türü yaklaşık olarak doğrusal bir yapıdadır ve 2 ile 8 arasında seviyelere sahiptir (Şekil 3.34).



Şekil 3.34 Symlet dalgacık dönüşümü seviyeleri

Biorthogonal

Biortogonal dalgacık tipi ortogonal yapının aksine sinyalin birebir aynı yapısını bozmadan FIR (Finite Impulse Response) filtrelemesi kullanarak fonksiyonları işleme sokan dalgacık türüdür (Haar hariç) [158]. Bu yapının tersi olan ters biortogonal (reverse biortogonal) dalgacık türü ise burada yapılan tersini içerir [159]. Spline yöntemini kullanarak ortaya çıkarılan bu yapının biçimsel yapısı aşağıdaki gibidir [160]. Dalgacık alt kategorileri 4 farklı seviyeye (bior1.1, bior1.3, bior2.2 ve bior2.4) sahiptir. Şekil 3.35 ise bior2.4'ü biçimsel olarak temsil eder.



Şekil 3.35 Biortogonal 2.4 dalgacık dönüşümü genişliği (amplitude) ve büyüklüğü (magnitude)

Literatürde yaygın olarak kullanılan diğer dalgacık tipleri ise Meyer, Mexican Hat ve Morlet dalgacıklarıdır.

3.10 WT-ANN Hibrit Dönüşümü

Dalgacık dönüşümleri veriyi ayrıştırmada, sıkıştırmada, sinyal ve resimleri analiz etmede ve veride genel akışı bozan gürültü (noise) gibi nedenleri ortadan kaldırmada kullanılan çok katmanlı bir çözüm yoludur [147]. Wavelet, yani dalgacık, süreçlerin ve ilişkilerinin zamansal bir tanımını sağlamak için zaman-frekans uzayındaki zaman serilerini çözen zamana bağlı bir spektral analiz yaklaşımıdır [120]. Literatürde tahmin çalışmaları genel olarak ele alındığında hibrit olarak YSA ve dalgacık dönüşümünün sıklıkla kullanıldığı görülmektedir [105, 121, 161].

Genel olarak dalgacık dönüşümlerini sürekli ve kesikli olarak ana iki kategoriye ayırmıştık. Tez çalışmasında zaman serisi verisi ile çalışıldığından, kesikli dalgacık dönüşümü kullanılması daha uygun görülmüştür. Bu Teknik, ölçek ve konumun alt kümelerini kullanarak zaman ve hız konusunda hesaplamalarda büyük avantaj sağladığı için de tercih edilmiştir [148, 162].

Dalgacık dönüşümünün uygulamasında ana dalgacık (mother wavelet) tipinin seçiminin yanında uygun ayrıştırma (decomposition) düzeyinde seçilmesi önemlidir. Bu düzeyler kesikli dalgacık dönüşümünde çeşitli filtreleme yöntemleriyle en uygun zaman ölçeğinin seçilmesi vasıtasıyla olur. Elde var olan ilk veri yüksek ve düşük geçiş filtrelerini kullanarak detaylı bir şekilde dalgacık katsayılarını (wavelet coefficients) ve yaklaşım (approximation) serilerini oluşturacak şekilde sisteme dahil edilir [163]. Dalgacık sisteminde yer alan düşük geçiş filtreleri, içerisinde orijinal verinin trendini ve yaklaşımını (A-approximate) içerir. Yüksek geçiş filtrelemesi ise ihtiyaç olan zaman ölçeğine göre çeşitli düzeylerde detayları (D-details) içerir [164].

Literatürde ayrıştırma (decomposition) düzeylerini Eşitlik 3.32'deki hesaplayan bir çok çalışma mevcuttur [165-167]. Bu çalışmalara ek olarak Aussem [56] vd.' de çalışmasında ayrıştırma düzeyini (l) aynı formül aracılığıyla hesaplamıştır.

$$l = \text{int}[\log(n)] \quad (3.33)$$

Burada l ayrıştırma düzeyini (decomposition level), n zaman serisinde yer alan veri sayısını, int integer (tamsayı) fonksiyon kısmını ve log ise logaritma (10 tabanlı) fonksiyonunu temsil eder.

Tez çalışmasında ayrıştırma düzeyinin belirlenmesinde Çoruh su havzasında yer alan İspir, Mescitli ve Laleli olmak üzere üç ana akım gözlem istasyonuna sırasıyla 588, 564 ve 492 tane giriş değeri kullanılmıştır. Bu değerler toplamının Eşitlik 3.32 yardımıyla hesaplanması sonucunda ayrıştırma düzeyi her bir istasyon için yaklaşık değerle 3 olarak bulunur. Toplam 3 dalgacık ayrıştırması 3 tane de detay (D1, D2, D3) ve 1 tane de yaklaşım (A3) çıktısı oluşturmaktadır. Daha detaylı olarak bu modeller tezde uygulama kısmında incelenecektir.



3.11 Model Değerlendirme Kriterleri

WT-ANN gibi hibrit modellerin karşılaştırılmalı performanslarını ölçmek amacıyla birden fazla istatistiksel kriter mevcuttur. Su havzası akımları araştırmalarında model performansları çoğunlukla *RMSE* (Root Mean Square Error), *MAE* (Mean Absolute Error) ve R^2 (determinasyon katsayısı) kriterleri kullanılarak karşılaştırmalar yapılmıştır [106, 168]. Tez çalışmasında da bu akış izlenerek model performansları karşılaştırılmıştır.

R² (Determinasyon Katsayısı)

İstatistikte determinasyon katsayısı, bağımlı değişkendeki bağımsız değişken(ler)den tahmin edilebilen değişimin oranıdır. Korelasyon (r), bağımsız ve bağımlı bir değişken arasındaki doğrusal ilişkinin gücünü açıklarken, R^2 , bir değişkenin değişiminin ikinci değişkenin değişimini etkileme düzeyini gösterir. Bu değer yüksek olması, ilgili model uyumunun iyi olduğunu gösterir. Bu değer 0 ile 1 arasındadır ve $R^2=1$ olduğu durum mükemmel uyumu işaret eder [168].

$$R^2 = \left[\frac{\frac{1}{N} \sum (O_i - O_m)(M_i - M_m)}{\sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - O_m)^2} \sqrt{\frac{1}{N} \sum_{i=1}^N (M_i - M_m)^2}} \right] \quad (3.34)$$

$$O_m = \frac{1}{n} \sum_{i=1}^n O_i, \quad M_m = \frac{1}{n} \sum_{i=1}^n M_i$$

Burada N örnek sayısını, $O=Observed$ (gözlenen) ve $M=Calculated$ (Hesaplanan) değerleri göstermektedir.

RMSE (Root Mean Square Error)

Ortalama karekök hata (RMSE-root mean square error), tahmin modellerinin performanslarını değerlendirmek için en sık olarak kullanılan ölçülerden biridir. Bu kriter, öklid mesafesini kullanarak tahminlerin ölçülen gerçek değerlerden ne kadar uzak olduğunu gösterir [169].

RMSE'yi hesaplamak için, öncelikle her bir veri noktası için kalıntı (tahmin ile gözlem arasındaki fark) hesaplanır. Daha sonra her veri noktası için kalıntı normu

işlenir. Artıkların ortalaması alınır ve hesaplanan bu ortalamanın karekökü alınarak RMSE bulunur. RMSE formülü Eşitlik 3.34'te verilmiştir.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (O_i - M_i)^2} \quad (3.35)$$

$$O_m = \frac{1}{n} \sum_{i=1}^n O_i, \quad M_m = \frac{1}{n} \sum_{i=1}^n M_i$$

Burada N örnek sayısını, $O=Observed$ (gözlenen) ve $M=Calculated$ (Hesaplanan) değerleri göstermektedir.

RMSE, tahmin edilen her veri noktasında doğru ölçümleri kullandığından ve buna ihtiyaç duyduğundan, denetimli öğrenme uygulamalarında yaygın olarak kullanılır. Veri biliminde çoğunlukla ana iki amaç için kullanılır. Birinci olarak eğitim modellerine sezgisel (heuristic) olarak katkıda bulunmaktır. İkinci olarak ise eğitilmiş modellerinin tutarlılığını değerlendirmektir [43].

MAE (Mean Absolute Error)

MAE çoğunlukla regresyon modelleriyle birlikte kullanılan bir model değerlendirme metriğidir. Bir test setine göre bir modelin ortalama mutlak hatası (MAE), test setindeki tüm örnekler üzerindeki bireysel tahmin hatalarının mutlak değerlerinin ortalamasıdır. Her tahmin hatası, örneğin gerçek değeri ile tahmin edilen değeri arasındaki farktır [170].

$$MAE = \frac{1}{N} \sum_{i=1}^N |M_i - O_i| \quad (3.36)$$


$$O_m = \frac{1}{n} \sum_{i=1}^n O_i, \quad M_m = \frac{1}{n} \sum_{i=1}^n M_i$$

RMSE ve MAE tahmin hatalarını ölçmek için hesaplandıklarından 0'a yakın olmaları istenen bir durumdur. 0 değeri ise mükemmel uyumu gösterir.

4.1 Çalışma Alanı ve Veri

Çalışma Alanı

Tez çalışması için uygulama alanı olarak Çoruh nehir havzasında yer alan, veri sürekliliği ve tutarlılığı en yüksek olan üç ana akım gözlem istasyonu (AGİ) seçilmiştir. Bu üç istasyonun isimleri sırasıyla İspir, Laleli ve Mescitli 'dir. Bu istasyonların Çoruh havzası üzerindeki yerleşimi Şekil 4.1'de verilmiştir.



Şekil 4.1 Çoruh havzası üzerinde yer alan İspir, Laleli ve Mescitli akım gözlem istasyonları

Çoruh nehir havzasının çıkış kaynağı Türkiye'nin kuzeydoğusunda yer alan Mescit dağlarıdır. Mescit dağları Erzurum ilinin kuzeyinde, deniz seviyesinin 3000 metre

üstünde yer alır ve buradan doğan Çoruh havzası Türkiye sınırından yaklaşık 20 km sonra Gürcistan'ın Batum şehri üzerinden Karadeniz'e dökülür.

Havzanın toplam drenaj alanı 21000 km² dir ve bu alanın %91'i Türkiye sınırı boyunca yer alırken %9'u Gürcistan tarafında konumlanır [147]. Çoruh havzasının yıllık akım miktarı toplamı 6.3 milyar km³ olmakla beraber Türkiye sınırları içerisinde erozyondan en çok etkilenen havzadır [171]. Yüksek nem ve sıcaklıklar havzanın kuzey bölgelerinde Karadeniz kıyısına yakın bölgelere hakimdir. Ancak havzanı güney bölgeleri sıcak yaz, soğuk kış ve kar gibi daha çeşitli hava koşullarına sahiptir.

Havzanın kuzey ve güneyinde hakim olan çok farklı iklim koşullarının en önemli nedeni Çoruh havzasının yer aldığı Erzurum platosudur. Bu plato üzerinde yer alan dağlar ve tepeler Karadeniz'den gelen nemli bulutları engelleyerek yıllık yağış ve sıcaklıkta kuzey ve güney bölgeleri arasındaki ciddi iklim koşulları farklılığını yaratır [172].

Veri


Tez çalışması uygulamasında Çoruh su havzasında yer alan üç ana akım gözlem istasyonu (İspir, Mescitli ve Laleli) için akım, sıcaklık ve yağış değişkenleri kullanılmıştır. Akım değişkeni Devlet Su İşleri (DSİ) akım yıllıkları üzerinden elde edilmiştir [173]. Sıcaklık verileri Hollanda Kraliyet Meteoroloji Enstitüsü (Royal Netherlands Meteorological Institute - KNMI) veritabanından alınmıştır [174]. Yağış verileri ise Dünya Bankası (World Bank) webitesi üzerinden elde edilmiştir [175].

Türkiye'de yer alan havzalarının yağış ve akım genel karakteristikleri 2013 ve 2020 yılları için aşağıdaki Tablo 4.1'de, Şekil 4.2 ve 4.3'de özetlenmiştir. Bunun yanında Çoruh su havzası için sıcaklık ve yağışın uzun dönemli karakteristiği Şekil 4.4'de verilmiştir.


Tablo 4.1 Havzalara göre yıllık ortalama havza yağış alanı ve ortalama yıllık akımlar (2013 ve 2020) (*Kaynak: DSİ Yıllıkları*)

	Havza No ve Adı	Havza Yağışalanı (km ²)	2013	Havza Yağışalanı (km ²)	2020
			Ortalama Yıllık Akım (km ³)		Ortalama Yıllık Akım (km ³)
01	Meriç Ergene	14560	1.33	14486	1.65
02	Marmara	24100	8.33	23074	7.44
03	Susurluk	22399	5.43	24319	4.96
04	Kuzey Ege	10003	2.09	9861	1.98
05	Gediz	18000	1.95	17137	1.77
06	Küçük Menderes	6907	1.19	6963	0.62
07	Büyük Menderes	24976	3.03	25960	3.04
08	Batı Akdeniz	20953	8.93	20956	6.49
09	Antalya	19577	11.06	20249	12.94
10	Burdur Göller	6374	0.5	6294	0.23
11	Akarçay	7605	0.49	7995	0.37
12	Sakarya	58160	6.4	63303	6.48
13	Batı Karadeniz	29598	9.93	28855	10.79
14	Yeşilırmak	36114	5.8	39595	7.04
15	Kızılırmak	78180	6.48	82181	7.00
16	Konya Kapalı	53850	4.52	49930	2.40
17	Doğu Akdeniz	22048	11.07	21150	7.55
18	Seyhan	20450	8.01	22035	6.2
19	Asi	7796	1.17	7886	1.78
20	Ceyhan	21982	7.18	21391	7.73
21	Fırat - Dicle	184918	52.94	176143	56.31
22	Doğu Karadeniz	24077	14.9	22846	16.42
23	Çoruh	19872	6.3	20248	6.98
24	Aras	27548	4.63	27775	4.48
25	Van Gölü	19405	2.39	17861	2.60






Şekil 4.2 Türkiye su havzaları yağış alanları (km²) (2020 ve 2013 için)



Şekil 4.3 Türkiye su havzaları için ortalama yıllık akımlar (km³) (2020 ve 2013 için)



Tablo 4.2 Çoruh havzasında eğitim, validasyon ve test periyodları

İstasyon	Eğitim Periyodu (0.7)	Validasyon Periyodu (0.15)	Test Periyodu (0.15)	Hidrolojik Ay Sayısı	Hidrolojik Yıl
<i>İspir</i>	Ekim/1965 - Ocak /1999	Şubat/1999 - Mayıs/2006	Haziran /2006 - Eylül /2013	588	49 (1965 - 2013)
<i>Mescitli</i>	Ekim /1966 - Eylül/1998	Ekim /1998 - Eylül/2005	Ekim /2005 - Eylül /2012	564	47 (1966 - 2012)
<i>Laleli</i>	Ekim /1971 - Mayıs/1999	Haziran/1999 - Temmuz/2005	Ağustos/2005 - Eylül /2011	492	41 (1971 - 2011)

Tablo 4.3, her üç istasyon için eğitim, validasyon ve test periyodları için değişkenlerin ortalama ve standart sapma değerlerini göstermektedir. Her değişken için ölçüm birimleri farklı olduğundan normalleştirme yapılmıştır. Bütün değişkenler için Z skoru normalleştirilmesi (ortalaması sıfır, varyansı bir) kullanılmıştır. Bu normalleştirme sistemi daha önceki yapılmış çalışmalar [176-178] incelenerek Min-Max metodu ile yapılmıştır.

Tablo 4.3 Eğitim, validasyon ve test periyodları için değişkenlerin ortalama ve standart sapma değerleri

İstasyon	Değişken	Eğitim	Validasyon	Test
İspir	Akım (m ³)	102.81, 115.49	105.32, 129.59	108.55, 126.44
	Sıcaklık (°C)	7.24, 8.04	7.62, 8.17	8.44, 8.37
	Yağış (mm)	64.68, 27.36	71.05, 27.44	66.42, 26.68
Laleli	Akım (m ³)	77.5, 87.81	70.92, 84.47	85.01, 96.77
	Sıcaklık (°C)	7.16, 8.08	7.99, 8.27	8.23, 8.37
	Yağış (mm)	64.52, 26.93	70.96, 28.17	68.67, 28.96
Mescitli	Akım (m ³)	15.63, 14.91	13.83, 12.76	16.82, 16.77
	Sıcaklık (°C)	7.29, 8.05	7.84, 8.12	8.01, 8.41
	Yağış (mm)	64.76, 27.18	70.11, 27.88	67.79, 27.82

*(ortalama, standard sapma)

4.2 WT-ANN Hibrit Makine Öğrenmesi Modelleri ve Sonuçları

Modelleme çalışmaları her üç akım istasyonu için bir ay sonraki akım değerinin tahmini için yapılmıştır. Karşılaştırmalı olarak model performansları değerlendirilirken yapay sinir ağları (YSA) modelleri geleneksel metot olarak ele alınmış ve dalgacık dönüşümü kullanılarak oluşturduğumuz hibrit modellerle olan performans değişimi değerlendirilmiştir.

Girdi Kombinasyonları için Oluşturulan Modeller ve Sonuçları

Tezin uygulama bölümünde, bir sonraki ayın akım tahmininde her bir istasyon için 8 ayrı model kullanılmıştır. İlk 4 model geleneksel yapay sinir ağları modellerini gösterirken, 5-8 arası modeller ise dalgacık dönüşümü (WT-ANN)

yapılarak hibritleştirilen kombinasyonları içerir. Her bir modeli ve modelin içindeki değişkenleri içeren bilgiler ise Tablo 4.4 'te verilmiştir.

Tablo 4.4 Girdi Kombinasyonları için Oluşturulan Modeller

Modeller	Girdiler						Çıktı
	S_t	A_t	P_t	$DWT-S_t$	$DWT-A_t$	$DWT-P_t$	
Model 1	✓	—	—	—	—	—	S_{t+1}
Model 2	✓	✓	—	—	—	—	
Model 3	✓	—	✓	—	—	—	
Model 4	✓	✓	✓	—	—	—	
Model 5	—	—	—	✓	—	—	
Model 6	—	—	—	✓	✓	—	
Model 7	—	—	—	✓	—	✓	
Model 8	—	—	—	✓	✓	✓	

S_t , A_t ve P_t : Streamflow (Akım), Air Temperature (Hava sıcaklığı), Precipitation (Yağış), t (zaman birim olarak ay). DWT (Discrete wavelet transform-kesikli dalgacık dönüşümü): Db10(3): A_3 , D_1 , D_2 , D_3 (A- approximates, D-details)


Tablo 4.4 incelendiğinde, S_t aylık akımı (m3), A_t hava sıcaklığını ($^{\circ}\text{C}$), P_t ise yağışı (mm) temsil etmektedir. Tabloda yer alan DWT simgeli değişkenler ise ilgili değişkenin dalgacık dönüşümü uygulanmış halini temsil eder. Bütün girdi değişkenlerinin tek çıktısı olan bir ay sonraki akım tahmini ise S_{t+1} olarak gösterilmektedir. Girdi kombinasyonları için oluşturulan modeller tablosunda ✓ sembolü değişkenin ilgili modelde kullanıldığını, — ise ilgili değişkenin modelde yer almadığını gösterir.

Model 1'in giriş vektörü, bir sonraki ay için akım tahmininde kullanılan mevcut aylık akım verilerini içerir. Mevcut aylık akım değerlerine sırasıyla aylık hava sıcaklığı ve yağış eklenerek Model 2 ve 3 oluşturulmuştur. Son olarak, Model 4 bu üç değişkenin (akım, hava sıcaklığı ve yağış) hepsinin var olduğu sistemi temsil eder.

Model 5-8 için giriş vektörleri, sırasıyla Model 1-4'te kullanılan değişkenlerin kesikli dalgacık dönüştürülmüş alt serisidir. Bu tez çalışmasında litetürde sıklıkla kullanılan Daubechies Db10 (3) dalgacık dönüşümü ana dönüşüm tekniği olarak kullanılmıştır. Kullanılan Daubechies Db10 (3) dalgacık dönüşümü her bir

istasyon için $d1$, $d2$, $d3$ olmak üzere üç detay (detail) ve $a3$ olmak üzere bir yaklaşım (approximation) fonksiyonu oluşturarak dönüşüm gerçekleştirmiştir. Bu oluşan dalgacık dönüşümlerinin detaylı gösterimine Tablo 4.5, 4.6 ve 4.7’de yer verilmiştir.

Tez çalışmasında kullanılan hibrit dalgacık sinir ağı modellerinin genel akış diyagramı Şekil 4.5’de verilmiştir.




Şekil 4.5 Hibrit dalgacık sinir ağı (WT-ANN) için akış diyagramı


Modelleme çalışmaları için analizler MATLAB (R2019a) program üzerinden Deep Learning Toolbox™ 12.1 ve Wavelet Toolbox™ 5.2 kullanılarak gerçekleştirilmiştir. Bütün modeller için gizli katmandaki optimal nöron sayıları 2’den 10’a kadar denenmiş ve en tutarlı sonuç veren nöron sayısı ilgili modelde kullanılmıştır. Bu nöron sayılarındaki farklılığın en büyük nedeni her bir modelde yer alan değişken sayılarının değişmesidir. Örnek olarak Model 1 toplam $1 \times N$ (N =veri sayısı) kadar girdi içerirken, Model 8 ise $12 \times N$ kadar girdi içermektedir. Bütün modellerin eğitim sürecinde Levenberg-Marquardt algoritması kullanılmıştır. Bütün değişkenler analizlerin daha sağlıklı yapılabilmesi açısından normalize edilmiştir.

Eğitim, validasyon ve test periyotları için model performanslarının ise detaylı sonuçları Tablo 4.8’de verilmiştir.


Tablo 4.5 İspir istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi



Tablo 4.6 Laleli istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi



Tablo 4.7 Mescitli istasyonu için her bir değişken bazında oluşturulan dalgacık dönüşümlerinin gösterimi



Genel olarak sonuçlar (Tablo 4.8) incelendiğinde her bir istasyon için geleneksel YSA modellerinde eğitim, validasyon ve test periyotları için model performansları arasındaki farklar birbirine yakın seviyelerdedir. YSA modelleri açısından sonuçları incelediğimizde üç akım gözlem istasyonu içinde çoğunluk olarak Model 4 en iyi sonuçları vermiştir. Model 4 akım, hava sıcaklığı ve yağış olmak üzere bütün değişkenleri içerir. Performans değerleri, bu üç değişkenin akımı bir ay önceden tahmin etmede önemli olduğunu göstermektedir. Bu sonuçlara ek olarak Model 4 için RMSE ve MAE değerleri en düşük seviyelerdedir. Bir diğer önemli nokta ise ilk dört modelin en iyi performansı eğitim dönemlerinde vermesidir.


Tablo 4.8 Eğitim, validasyon ve test periyotları için model performansları

İstasyon	Model	Eğitim			Validasyon			Test		
		R ²	RMSE	MAE	R ²	RMSE	MAE	R ²	RMSE	MAE
İspir	Model1 -ANN	0.841	0.326	0.351	0.802	0.334	0.326	0.777	0.465	0.396
	Model2 -ANN	0.840	0.331	0.365	0.832	0.288	0.313	0.785	0.450	0.399
	Model3 -ANN	0.841	0.326	0.344	0.837	0.281	0.294	0.795	0.432	0.370
	Model4 -ANN	0.878	0.216	0.270	0.840	0.331	0.340	0.809	0.412	0.373
	Model5 -WT-ANN	0.952	0.087	0.185	0.874	0.280	0.323	0.835	0.361	0.352
	Model6 -WT-ANN	0.969	0.058	0.160	0.886	0.264	0.299	0.842	0.381	0.343
	Model7 -WT-ANN	0.968	0.058	0.158	0.861	0.303	0.330	0.817	0.374	0.357
	Model8 -WT-ANN	0.970	0.056	0.162	0.891	0.245	0.338	0.847	0.322	0.352
Mescitli	Model1 -ANN	0.876	0.233	0.293	0.867	0.187	0.293	0.826	0.459	0.367
	Model2 -ANN	0.892	0.204	0.267	0.876	0.175	0.28	0.859	0.347	0.338
	Model3 -ANN	0.893	0.203	0.263	0.885	0.162	0.274	0.875	0.298	0.318
	Model4 -ANN	0.905	0.180	0.244	0.891	0.164	0.291	0.881	0.287	0.302
	Model5 -WT-ANN	0.930	0.135	0.225	0.898	0.147	0.253	0.892	0.286	0.341
	Model6 -WT-ANN	0.947	0.103	0.212	0.921	0.116	0.236	0.900	0.250	0.28
	Model7 -WT-ANN	0.951	0.095	0.215	0.910	0.132	0.297	0.895	0.281	0.355
	Model8 -WT-ANN	0.980	0.039	0.150	0.925	0.112	0.231	0.906	0.246	0.278
Laleli	Model1 -ANN	0.838	0.357	0.379	0.778	0.391	0.374	0.767	0.386	0.397
	Model2 -ANN	0.842	0.384	0.360	0.796	0.342	0.363	0.784	0.381	0.367
	Model3 -ANN	0.862	0.310	0.342	0.816	0.327	0.328	0.762	0.388	0.381
	Model4 -ANN	0.849	0.277	0.329	0.846	0.345	0.382	0.769	0.385	0.388
	Model5 -WT-ANN	0.934	0.126	0.256	0.863	0.233	0.328	0.783	0.493	0.419
	Model6 -WT-ANN	0.947	0.100	0.210	0.876	0.222	0.306	0.808	0.433	0.424
	Model7 -WT-ANN	0.945	0.105	0.214	0.859	0.240	0.320	0.811	0.424	0.410
	Model8 -WT-ANN	0.950	0.084	0.198	0.873	0.251	0.355	0.860	0.315	0.341

Ayrıca modellerin performansı validasyon dönemlerinde eğitim dönemlerine göre biraz daha düşmüş ve model performansı test döneminde en düşük düzeyde olmuştur. Örnek olarak İspir istasyonu Model 4 için eğitim, validasyon ve test periyotları için R^2 değerleri sırasıyla 0.878, 0.840, 0.809 ‘dur. Uygulama verileri için bölümlene kronolojik olarak yapılmıştır ve bu bölümlene eğitim, validasyon ve test periyotları için sırasıyla 1964-1999, 1999-2006 ve 2006-2013 yıllarını kapsamaktadır. Bütün modellerde kullanılan değişkenler için betimleyici istatistikler (ortalama, std. sapma) “*Çalışma Alanı ve Veri*” kısmında verilmiştir. Örnek olarak, validasyon dönemindeki ortalama aylık yağış miktarı, eğitim periyodundakinden daha yüksek iken, test periyodundaki miktar validasyon periyodundakinden daha düşüktür. Bu değişime ek olarak hava sıcaklığı da kademeli olarak artmaktadır. Yıllar bazında yağış ve hava sıcaklığındaki değişim etkisinden kaynaklı olarak bir ay sonraki akım tahmini için eğitilen verilerin performansının validasyon ve test dönemlerinde düşmesi olasıdır. Tahminleme performansının hidrolojik veri yapısında oluşabilecek değişim etkilerinden en az etkilenmesi amacıyla da veri kronolojik olarak bölünmüştür (uzun dönemli akım hareketleri dikkate alınarak).

WT-ANN hibrit modellerini (Model 5-8) değerlendirmeye aldığımızda bütün akım gözlem istasyonları bazında YSA modellerinden daha iyi bir eğitim performansı vermiştir. Tablo 4.8 içerisindeki son dört model (Model 5-8), ilk dört (Model 1-4) YSA modelinin dalgacık dönüşümü uygulanmış hallerini göstermektedir. Tablo 4.8’de yer alan modelleri karşılaştırıldığında, havza su akımını bir ay önceden tahmin etmek için orijinal aylık akımı, hava sıcaklığını, yağış miktarını ve bunların dalgacık dönüşümlerini içerisinde barındıran Model 8’in her üç istasyon için de daha iyi performans verdiğini model değerlendirme kriterleri olan R^2 , $RMSE$ ve MAE yardımıyla belirlenebilir.

Eğitim periyodu performansları dikkate alındığında İspir, Mescitli ve Laleli istasyonları için R^2 değerleri sırasıyla 0.970, 0.980 ve 0.950’dir. Aynı istasyonlar için, test periyodu performansları dikkate alındığında ise R^2 değerleri sırasıyla 0.847, 0.906 ve 0.860 olarak bulunmuştur.



Şekil 4.6 İspir, Mescitli ve Laleli istasyonları için Model 8 eğitim, validasyon ve test dönemlerinin karşılaştırılması.

YSA sonuçlarına benzer şekilde WT-ANN test periyotları performansları her üç istasyon için de daha düşük seviyededir. Test periyotlarında görülen düşük performansların en önemli nedenlerinden biri kronolojik bölümlenme oranlarının oluşturduğu yapısal bölümlenmedir. Bir diğer önemli neden ise, bu dönemdeki akım, hava sıcaklığı ve yağıştaki değişikliklerdir.

Çoruh su havzası için yapılan bütün modelleme çalışmaları için en iyi performansı Model 8 vermiştir. Şekil 4.6, Model 8 için her üç istasyonun gözlemlenen ve tahmin edilen değerlerini aylara göre sunmakta ve modelin başarısını görsel olarak temsil etmektedir. Şekil 4.6, model tahminlerinin daha net bir şekilde görselleştirilmesini sağlamak amacıyla eğitim, validasyon ve test periyotlarını dikey kesikli çizgilerle üç bölüme ayırmıştır.

WT-ANN modelleri, Çoruh nehri havzasında bulunan her üç istasyon için de geleneksel YSA modellerinden daha iyi performans göstermiştir. Bu performans verimliliğinin en önemli nedenlerinden biri, çalışmamızda zaman serisi halinde var olan hidrolojik ve meteorolojik değişkenleri dalgacık dönüşümleri ile ayrıştırarak oluşan hibrit modellere daha fazla bilgi akışının sağlanmasıdır. Yapılan bu çalışma, aynı zamanda havza su akımı tahminlemesinde dalgacık dönüşümleri kullanımının önemini göstermektedir. Tezin uygulama kısmı, literatürde dalgacık dönüşümü kullanılarak yapılan havza su akım araştırmalarına [179-181] ek olarak çalışmaların geliştirilmesine yardımcı olabilir.

Çoruh havzası üzerinde su akımı için yapılan çalışmalar incelendiğinde Mehr ve ark. [7], aylık su akımı tahmini çalışmalarında havzada yer alan iki istasyonu kullanmıştır. Mehr ve ark. [62] daha sonraki çalışmalarında aynı havzada su akımı değişkenin gecikmeli değerlerinin farklı kombinasyonlarını kullanarak aylık tahmini gerçekleştirmiştir. Bu tez çalışmasının literatürdeki ve bölgedeki çalışmalardan farklı taraflarından biri ise, su akımı ile birlikte hava sıcaklığı ve yağışın analize girdi değişkenlerinin dalgacık dönüşümleri ile beraber dahil edilmesidir.

Tez çalışmasında hibrit dalgacık dönüşümü için kullanılan teknik Daubechies (Db10) dalgacıdır. Çoruh havzası İspir istasyonu için su akımı verilerinde

kullanılan temel dalgacık dönüşümü dışında literatürde sıklıkla yer alan Biorthogonal, Haar, Mexican Hat, Morlet ve Symlets dalgacık dönüşümleri uygulanmış ve performansları değerlendirilmiştir (Tablo 4.9).

Tablo 4.9 Eğitim, validasyon ve test periyotları için model performansları

İstasyon	Dalgacık Tipi	Eğitim R ²	Validasyon R ²	Test R ²	MSE
İspir	Haar(3)	0.942	0.922	0.927	0.00214
	Reverse biorthogonal (rbio1.1)	0.922	0.845	0.870	0.00226
	Symlets (sym2)	0.902	0.855	0.890	0.00357
	Fejer-Korovkin (fk4)	0.861	0.849	0.883	0.00508
	Biorthogonal (bior1.1)	0.925	0.893	0.950	0.00244
	Db10 Model8 -WT-ANN	0.970	0.891	0.847	0.00179

İspir istasyonu için kullanılan diğer dalgacık dönüşümlerinde de ana dalgacık modelimiz olan Db10 algoritması daha iyi sonuçlar vermiştir.

5 SONUÇ VE ÖNERİLER

Tez çalışmasının amacı, kesikli dalgacık dönüşümü (DWT) ve yapay sinir ağlarını (ANN) hibrit modelde birleştirerek aylık akım tahmini yapan modeller geliştirmektir. Bu geliştirmeyi yapmak amacıyla Çoruh nehri havzasındaki üç ölçüm istasyonu (Laleli, Mescitli ve İspir akım gözlem istasyonları) ele alınmıştır ve WT-ANN hibrit modeli için Daubechies ana dalgacığı aracılığıyla, hava sıcaklığı, yağış ve akım değişkenlerinin farklı kombinasyonları ve bunların dalgacık dönüşümleri kullanılmıştır. Bu tez çalışmasında ilgili dönüşümlerin bir diğer ana kullanım amacı ise, hidroloji alanında hibrit bir model tipi olan WT-ANN'nin çeşitli algoritmalarının kendi aralarında ve klasik ANN yöntemi karşısında performanslarını ölçmek ve değerlendirmektir.

Model performansları bütünsel olarak ele alındığında WT-ANN modellerinin sonuçları her üç istasyon için de daha iyi performans verdiği gözlemlenmiştir. Su akımı, hava sıcaklığı ve yağış değişkenlerini dönüşümleri ile beraber içeren Model 8, her istasyon için en iyi sonuçları vermiştir. Kronolojik olarak istasyon bazında bölünen veri seti sayesinde, belirli bir zaman periyodunda eğitilen veri setinin performansının başka bir zaman diliminde değişmesi de gözlemlenen ana çıktılardandır. Bu nedenle, zaman içinde iklimde meydana gelen değişiklikler aynı zamanda su akımı, hava sıcaklığı ve yağış gibi değişkenlerinde yapısını değiştirmiştir [182].

Bu tez çalışmasının sonuçları, dalgacık dönüşümleri ve yapay sinir ağları tekniklerinin birleştirilmesinin su havzası akımını tahmin etmede önemli bir araç olarak kullanılabileceğini göstermektedir. Ek olarak, hava sıcaklığı ve yağış miktarının akarsu akımı üzerinde önemli etkileri olduğu görülmüştür ve bu etkiler dalgacık dönüşümleri ile beraber modelde yer aldığı havza için daha tutarlı projeksiyonlar yapmaya olanak tanımıştır. Literatürde hibrit dönüşüm çalışmaları (WT-ANN) su akım değişkenini veri eksikliği ve kalitesi gibi nedenlerle modellerde

çoğunlukla kullanmamıştır. Tutarlı ve uzun süreli hidrolojik ve klimatolojik verilerin varlığı tahminleme çalışmalarının en iyi şekilde yapılması için vazgeçilmez bir durumdur.

Çoruh havzası Türkiye içerisinde bulunduğu bölge elektrik üretimine önemli derecede katkı sağlayan bir nehirdir ve havza üzerinden elde edilen elektrik üretimi Çoruh havzası su akımını etkilemektedir [183, 184]. Özellikle yüksek rakımlı bölgelerde hidroelektrik santraller ve eriyen karlar önemli ölçüde etkilemektedir[176].

Havzalar için yapılan ve yapılacak olan akım tahmin çalışmalarında, su akım değişkeninin karakteristiğini etkileyen diğer faktörlerin de (yeraltı su karakteristikleri, su derinliği ve eğimi vb.) eklenerek, bu yöntemsel metodolojiyi diğer havzalar bazında tekrarlayarak ve değerlendirmeler yaparak daha da ileri seviyelere taşınabilir. Tutarlı ve şeffaf olarak yapılan akım tahmin modellemeleri su yöneticilerine ve araştırmacılara karar almada yardımcı olacaktır.

Tez çalışması ile bölgede yer alan havza yönetim politikalarına ve yöneticilerine yardımcı olmak çalışmanın ana amaçlarından birini oluşturmaktadır. Çoruh havza bölgesi üzerinde yapılan literatür ve uygulama çalışmalarının havza yönetimine bakış açısının çok faktörlü ve disiplinli olması gerekliliğini ortaya koymuştur. Havza içi ve havzalar arası entegre bir su izleme ve yönetim sisteminin oluşturulması veya var olanların iyileştirilmesi ile modelleme çalışmaları havza bazından ülke bazına çıkartılarak değerlendirmeler daha tutarlı yapılabilir.

- [1] R. E. Schulze, "Modelling hydrological responses to land use and climate change: a southern African perspective," *Ambio*, pp. 12-22, 2000.
- [2] X. Zhang, L. Zhang, J. Zhao, P. Rustomji, and P. Hairsine, "Responses of streamflow to changes in climate and land use/cover in the Loess Plateau, China," *Water Resources Research*, vol. 44, no. 7, 2008.
- [3] S. R. Ahn, G. Park, I. K. Jung, K. J. Lim, and S. J. Kim, "Assessing hydrologic response to climate change of a stream watershed using SLURP hydrological model," *KSCE Journal of Civil Engineering*, vol. 15, no. 1, pp. 43-55, 2011.
- [4] W. Lahmer, B. Pfützner, and A. Becker, "Assessment of land use and climate change impacts on the mesoscale," *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, vol. 26, no. 7-8, pp. 565-575, 2001.
- [5] H. Xu, R. Taylor, and Y. Xu, "Quantifying uncertainty in the impacts of climate change on river discharge in sub-catchments of the Yangtze and Yellow River Basins, China," *Hydrology and Earth System Sciences*, vol. 15, no. 1, pp. 333-344, 2011.
- [6] L. Jiao and D. Wang, "Climate change, the evaporation paradox, and their effects on Streamflow in Lijiang Watershed," *Polish Journal of Environmental Studies*, vol. 27, no. 6, pp. 2585-2591, 2018.
- [7] A. D. Mehr, E. Kahya, and E. Olyaie, "Streamflow prediction using linear genetic programming in comparison with a neuro-wavelet technique," *Journal of Hydrology*, vol. 505, pp. 240-249, 2013.
- [8] L. Kuchment, V. Demidov, P. Naden, D. Cooper, and P. Broadhurst, "Rainfall-runoff modelling of the Ouse basin, North Yorkshire: an application of a physically based distributed model," *Journal of Hydrology*, vol. 181, no. 1-4, pp. 323-342, 1996.
- [9] V. Nourani, M. Komasi, and A. Mano, "A multivariate ANN-wavelet approach for rainfall-runoff modeling," *Water resources management*, vol. 23, no. 14, pp. 2877-2894, 2009.
- [10] L. E. Besaw, D. M. Rizzo, P. R. Bierman, and W. R. Hackett, "Advances in ungauged streamflow prediction using artificial neural networks," *Journal of Hydrology*, vol. 386, no. 1-4, pp. 27-37, 2010.
- [11] J. Yu, G. Fu, W. Cai, and T. Cowan, "Impacts of precipitation and temperature changes on annual streamflow in the Murray-Darling Basin," *Water International*, vol. 35, no. 3, pp. 313-323, 2010.
- [12] L. Zhang, R. Karthikeyan, Z. Bai, and J. Wang, "Spatial and temporal variability of temperature, precipitation, and streamflow in upper Sang-kan basin, China," *Hydrological Processes*, vol. 31, no. 2, pp. 279-295, 2017.

- [13] J. Xu, Y. Chen, F. Lu, W. Li, L. Zhang, and Y. Hong, "The nonlinear trend of runoff and its response to climate change in the Aksu River, western China," *International Journal of Climatology*, vol. 31, no. 5, pp. 687-695, 2011.
- [14] K. Duan *et al.*, "Future shift of the relative roles of precipitation and temperature in controlling annual runoff in the conterminous United States," *Hydrology and Earth System Sciences*, vol. 21, no. 11, pp. 5517-5529, 2017.
- [15] R. Graf, "Distribution properties of a measurement series of river water temperature at different time resolution levels (based on the example of the Lowland River Noteć, Poland)," *Water*, vol. 10, no. 2, p. 203, 2018.
- [16] A. H. Nury, K. Hasan, and M. J. B. Alam, "Comparative study of wavelet-ARIMA and wavelet-ANN models for temperature time series data in northeastern Bangladesh," *Journal of King Saud University-Science*, vol. 29, no. 1, pp. 47-61, 2017.
- [17] J. C. Morrill, R. C. Bales, and M. H. Conklin, "Estimating stream temperature from air temperature: implications for future water quality," *Journal of Environmental Engineering*, vol. 131, no. 1, pp. 139-146, 2005.
- [18] M. Van Vliet, F. Ludwig, J. Zwolsman, G. Weedon, and P. Kabat, "Global river temperatures and sensitivity to atmospheric warming and changes in river flow," *Water Resources Research*, vol. 47, no. 2, 2011.
- [19] B. W. Webb and F. Nobilis, "Long-term changes in river temperature and the influence of climatic and hydrological factors," *Hydrological Sciences Journal*, vol. 52, no. 1, pp. 74-85, 2007.
- [20] C. Karul, S. Soyupak, A. F. Çilesiz, N. Akbay, and E. Germen, "Case studies on the use of neural networks in eutrophication modeling," *Ecological modelling*, vol. 134, no. 2-3, pp. 145-152, 2000.
- [21] G. J. McCabe and D. M. Wolock, "Independent effects of temperature and precipitation on modeled runoff in the conterminous United States," *Water Resources Research*, vol. 47, no. 11, 2011.
- [22] H. Razmkhah, A. Abrishamchi, and A. Torkian, "Evaluation of spatial and temporal variation in water quality by pattern recognition techniques: A case study on Jajrood River (Tehran, Iran)," *Journal of environmental management*, vol. 91, no. 4, pp. 852-860, 2010.
- [23] K. P. Singh, A. Malik, D. Mohan, and S. Sinha, "Multivariate statistical techniques for the evaluation of spatial and temporal variations in water quality of Gomti River (India)—a case study," *Water research*, vol. 38, no. 18, pp. 3980-3992, 2004.
- [24] N. W. Arnell, *Hydrology and global environmental change*. Routledge, 2014.

- [25] G. Fu, M. E. Barber, and S. Chen, "Impacts of climate change on regional hydrological regimes in the Spokane River Watershed," *Journal of Hydrologic Engineering*, vol. 12, no. 5, pp. 452-461, 2007.
- [26] A. Sankarasubramanian, R. M. Vogel, and J. F. Limbrunner, "Climate elasticity of streamflow in the United States," *Water Resources Research*, vol. 37, no. 6, pp. 1771-1781, 2001.
- [27] D. N. Yates and K. M. Strzepek, "Modeling the Nile Basin under climatic change," *Journal of Hydrologic Engineering*, vol. 3, no. 2, pp. 98-108, 1998.
- [28] K. Ercan, D. Mehmet C, and B. Osman A, "Hydrologic homogeneous regions using monthly streamflow in Turkey," *Earth sciences research journal*, vol. 12, no. 2, pp. 181-193, 2008.
- [29] C. Gagnon, B. P. Grandjean, and J. Thibault, "Modelling of coagulant dosage in a water treatment plant," *Artificial Intelligence in Engineering*, vol. 11, no. 4, pp. 401-404, 1997.
- [30] E. Kahya, S. Kalaycı, and T. C. Piechota, "Streamflow regionalization: Case study of Turkey," *Journal of Hydrologic Engineering*, vol. 13, no. 4, pp. 205-214, 2008.
- [31] K. Yenigün, V. Gümüş, and H. Bulut, "Trends in streamflow of the Euphrates basin, Turkey," in *Proceedings of the Institution of Civil Engineers-Water Management*, 2008, vol. 161, no. 4: Thomas Telford Ltd, pp. 189-198.
- [32] R. J. Abrahart *et al.*, "Two decades of anarchy? Emerging themes and outstanding challenges for neural network river forecasting," *Progress in Physical Geography*, vol. 36, no. 4, pp. 480-513, 2012.
- [33] M. C. Demirel, A. Venancio, and E. Kahya, "Flow forecast by SWAT model and ANN in Pracana basin, Portugal," *Advances in Engineering Software*, vol. 40, no. 7, pp. 467-473, 2009.
- [34] O. Kisi and H. Kerem Cigizoglu, "Comparison of different ANN techniques in river flow prediction," *Civil Engineering and Environmental Systems*, vol. 24, no. 3, pp. 211-231, 2007.
- [35] Z. F. Toprak *et al.*, "Modeling monthly mean flow in a poorly gauged basin by fuzzy logic," *Clean-Soil, Air, Water*, vol. 37, no. 7, pp. 555-564, 2009.
- [36] K. Kang, J. Kim, C. Park, and K. Ham, "Evaluation of hydrologic forecasting system based on neural network model," in *PROCEEDINGS OF THE CONGRESS-INTERNATIONAL ASSOCIATION FOR HYDRAULIC RESEARCH*, 1993, vol. 2: LOCAL ORGANIZING COMMITTEE OF THE XXV CONGRESS, pp. 257-257.
- [37] T. Mandal and V. Jothiprakash, "Short-term rainfall prediction using ANN and MT techniques," *ISH Journal of Hydraulic Engineering*, vol. 18, no. 1, pp. 20-26, 2012.

- [38] J. Chang, G. Wang, and T. Mao, "Simulation and prediction of supraperafrost groundwater level variation in response to climate change using a neural network model," *Journal of Hydrology*, vol. 529, pp. 1211-1220, 2015.
- [39] R. Prasad, R. C. Deo, Y. Li, and T. Maraseni, "Input selection and performance optimization of ANN-based streamflow forecasts in the drought-prone Murray Darling Basin region using IIS and MODWT algorithm," *Atmospheric Research*, vol. 197, pp. 42-63, 2017.
- [40] A. P. Piotrowski and J. J. Napiorkowski, "Simple modifications of the nonlinear regression stream temperature model for daily data," *Journal of Hydrology*, vol. 572, pp. 308-328, 2019.
- [41] J.-T. Shiau and H.-T. Hsu, "Suitability of ANN-based daily streamflow extension models: a case study of Gaoping River basin, Taiwan," *Water resources management*, vol. 30, no. 4, pp. 1499-1513, 2016.
- [42] M. A. Amiri, C. Conoscenti, and M. S. Mesgari, "Improving the accuracy of rainfall prediction using a regionalization approach and neural networks," *Kuwait Journal of Science*, vol. 45, no. 4, 2018.
- [43] Ö. Kişi, "River flow modeling using artificial neural networks," *Journal of Hydrologic Engineering*, vol. 9, no. 1, pp. 60-63, 2004.
- [44] Z. M. Yaseen, A. El-Shafie, H. A. Afan, M. Hameed, W. H. M. W. Mohtar, and A. Hussain, "RBFNN versus FFNN for daily river flow forecasting at Johor River, Malaysia," *Neural Computing and Applications*, vol. 27, no. 6, pp. 1533-1542, 2016.
- [45] C. M. Zealand, D. H. Burn, and S. P. Simonovic, "Short term streamflow forecasting using artificial neural networks," *Journal of hydrology*, vol. 214, no. 1-4, pp. 32-48, 1999.
- [46] I. A. Gheyas and L. S. Smith, "A neural network-based framework for the reconstruction of incomplete data sets," *Neurocomputing*, vol. 73, no. 16-18, pp. 3039-3065, 2010.
- [47] J. Krenek, K. Kuca, O. Krejcar, P. Maresova, V. Sobeslav, and P. Blazek, "Artificial neural network tools for computerised data modeling and processing," in *2014 IEEE 15th International Symposium on Computational Intelligence and Informatics (CINTI)*, 2014: IEEE, pp. 255-260.
- [48] J. Adamowski and K. Sun, "Development of a coupled wavelet transform and neural network method for flow forecasting of non-perennial rivers in semi-arid watersheds," *Journal of Hydrology*, vol. 390, no. 1-2, pp. 85-91, 2010.
- [49] O. R. Dolling and E. A. Varas, "Artificial neural networks for streamflow prediction," *Journal of hydraulic research*, vol. 40, no. 5, pp. 547-554, 2002.

- [50] P. Whigham and P. Crapper, "Modelling rainfall-runoff using genetic programming," *Mathematical and Computer Modelling*, vol. 33, no. 6-7, pp. 707-721, 2001.
- [51] B. Chang, K. He, R. Li, H. Wang, and J. Wen, "Trends, Abrupt Changes, and Periodicity of Streamflow in Qinghai Province, the Northeastern Tibetan Plateau, China," *Polish Journal of Environmental Studies*, vol. 27, no. 2, 2018.
- [52] C. A. SANTOS, C. d. O. GALVÃO, K. SUZUKI, and R. M. TRIGO, "Matsuyama city rainfall data analysis using wavelet transform," *Proceedings of Hydraulic Engineering*, vol. 45, pp. 211-216, 2001.
- [53] C. A. G. Santos and B. S. de Moraes, "Identification of precipitation zones within São Francisco River basin (Brazil) by global wavelet power spectra," *Hydrological sciences journal*, vol. 58, no. 4, pp. 789-796, 2013.
- [54] D. Nalley, J. Adamowski, and B. Khalil, "Using discrete wavelet transforms to analyze trends in streamflow and precipitation in Quebec and Ontario (1954–2008)," *Journal of hydrology*, vol. 475, pp. 204-228, 2012.
- [55] Y. Seo, S. Kim, O. Kisi, and V. P. Singh, "Daily water level forecasting using wavelet decomposition and artificial intelligence techniques," *Journal of Hydrology*, vol. 520, pp. 224-243, 2015.
- [56] A. Aussem, "Waveletbased feature extraction and decomposition strategies for financial forecasting," *International Journal of Computational Intelligence in Finance*, vol. 6, pp. 5-12, 1998.
- [57] B.-L. Zhang and Z.-Y. Dong, "An adaptive neural-wavelet model for short term load forecasting," *Electric power systems research*, vol. 59, no. 2, pp. 121-129, 2001.
- [58] F. Anctil and D. G. Tape, "An exploration of artificial neural network rainfall-runoff forecasting combined with wavelet decomposition," *Journal of Environmental Engineering and Science*, vol. 3, no. S1, pp. S121-S128, 2004.
- [59] T. Partal, "River flow forecasting using different artificial neural network algorithms and wavelet transform," *Canadian Journal of Civil Engineering*, vol. 36, no. 1, pp. 26-38, 2009.
- [60] Ö. Kişi, "Neural networks and wavelet conjunction model for intermittent streamflow forecasting," *Journal of Hydrologic Engineering*, vol. 14, no. 8, pp. 773-782, 2009.
- [61] C. Wu, K. W. Chau, and Y. S. Li, "Methods to improve neural network performance in daily flows prediction," *Journal of Hydrology*, vol. 372, no. 1-4, pp. 80-93, 2009.
- [62] A. Danandeh Mehr, E. Kahya, A. Şahin, and M. Nazemosadat, "Successive-station monthly streamflow prediction using different artificial neural

- network algorithms," *International Journal of Environmental Science and Technology*, vol. 12, no. 7, pp. 2191-2200, 2015.
- [63] I. Yucel, A. Güventürk, and O. L. Sen, "Climate change impacts on snowmelt runoff for mountainous transboundary basins in eastern Turkey," *International Journal of Climatology*, vol. 35, no. 2, pp. 215-228, 2015.
- [64] İ. Can, F. Tosunoğlu, and E. Kahya, "Daily streamflow modelling using autoregressive moving average and artificial neural networks models: case study of Çoruh basin, Turkey," *Water and Environment Journal*, vol. 26, no. 4, pp. 567-576, 2012.
- [65] M. Buyukyildiz, "Monthly Streamflow Time Series Modelling Of Coruh River," 2014.
- [66] R. I. McDonald *et al.*, "Urban growth, climate change, and freshwater availability," *Proceedings of the National Academy of Sciences*, vol. 108, no. 15, pp. 6312-6317, 2011.
- [67] K. Bakanlığı, "On Birinci Kalkınma Planı (2019-2023) Kamu Harcamalarında Etkinlik Çalışma Grubu Raporu," 2018.
- [68] M. Şamil Güneş, D. Yıldız, and F. Sevinç Kurnaz, "A Comparative Assessment of Municipal Water Use in Turkey," *Journal of Water Resources Planning and Management*, vol. 148, no. 2, p. 05021033, 2022.
- [69] M. E. Bariş and A. A. Karadağ, "Water resources management issues in Turkey and recommendations," *Journal of Applied Sciences*, vol. 7, no. 24, pp. 3900-3908, 2007.
- [70] S. Alpan and K. Opemshaw, "Turkey-Anatolia watershed rehabilitation project," *Regional Environmental Assessment and Environmental Management Framework E*, vol. 695, 2003.
- [71] T. Cinar, "Privatisation of urban water and sewerage services in Turkey: Some trends," *Development in Practice*, vol. 19, no. 3, pp. 350-364, 2009.
- [72] K. E. Trenberth *et al.*, "Observations: surface and atmospheric climate change," in *Climate Change 2007: The Physical Science Basis. Contribution of Working Group 1 to the 4th Assessment Report of the Intergovernmental Panel on Climate Change*: Cambridge University Press, 2007.
- [73] N. Stern, "Stern Review: The economics of climate change," 2006.
- [74] P. Agreement, "Framework convention on climate change. United Nations," ed, 2017.
- [75] D. Yildiz, M. S. Gunes, F. Gokalp Yavuz, and D. Yildiz, "Detecting seasonal cycle shift on streamflow over Turkey by using multivariate statistical methods," *Theoretical and Applied Climatology*, vol. 133, no. 3, pp. 1143-1161, 2018.
- [76] N. W. Arnell, "The effect of climate change on hydrological regimes in Europe: a continental perspective," *Global environmental change*, vol. 9, no. 1, pp. 5-23, 1999.

- [77] E. Sánchez, C. Gallardo, M. Gaertner, A. Arribas, and M. Castro, "Future climate extreme events in the Mediterranean simulated by a regional climate model: a first approach," *Global and Planetary Change*, vol. 44, no. 1-4, pp. 163-180, 2004.
- [78] C. Iyigun *et al.*, "Clustering current climate regions of Turkey by using a multivariate statistical method," *Theoretical and applied climatology*, vol. 114, no. 1, pp. 95-106, 2013.
- [79] D. Zuo, Z. Xu, W. Wu, J. Zhao, and F. Zhao, "Identification of streamflow response to climate change and human activities in the Wei River Basin, China," *Water Resources Management*, vol. 28, no. 3, pp. 833-851, 2014.
- [80] S. Agatonovic-Kustrin and R. Beresford, "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research," *Journal of pharmaceutical and biomedical analysis*, vol. 22, no. 5, pp. 717-727, 2000.
- [81] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115-133, 1943.
- [82] D. O. Hebb, *The organization of behavior: A neuropsychological theory*. Psychology Press, 2005.
- [83] F. Rosenblatt, "The perceptron: a probabilistic model for information storage and organization in the brain," *Psychological review*, vol. 65, no. 6, p. 386, 1958.
- [84] M. Minsky and S. Papert, "An introduction to computational geometry," *Cambridge tiass., HIT*, vol. 479, p. 480, 1969.
- [85] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities," *Proceedings of the national academy of sciences*, vol. 79, no. 8, pp. 2554-2558, 1982.
- [86] F. Marini, R. Bucci, A. L. Magrì, and A. D. Magrì, "Artificial neural networks in chemometrics: History, examples and perspectives," *Microchemical journal*, vol. 88, no. 2, pp. 178-185, 2008.
- [87] D. Graupe, *Principles of artificial neural networks*. World Scientific, 2013.
- [88] J. Bourquin, H. Schmidli, P. van Hoogevest, and H. Leuenberger, "Basic concepts of artificial neural networks (ANN) modeling in the application to pharmaceutical development," *Pharmaceutical development and technology*, vol. 2, no. 2, pp. 95-109, 1997.
- [89] R. Leardi, *Nature-inspired methods in chemometrics: genetic algorithms and artificial neural networks*. Elsevier, 2003.
- [90] B. Ripley, "Pattern Recognition and neural networks cambridge university press cambridge," *UK Google Scholar*, 1996.

- [91] "Makine Öğrenmesi (Machine Learning) Nedir?" <https://blog.turhost.com/makine-ogrenmesi-machine-learning-nedir/> (accessed 2022).
- [92] M. Z. Zgurovsky, V. M. Sineglazov, and I. C. Olena, *Artificial Intelligence Systems Based on Hybrid Neural Networks*. Springer, 2020.
- [93] G. Dreyfus, "Neural networks: an overview," *Neural networks*, pp. 1-83, 2005.
- [94] K. Hornik, M. Stinchcombe, and H. White, "Multilayer feedforward networks are universal approximators," *Neural networks*, vol. 2, no. 5, pp. 359-366, 1989.
- [95] K. Hornik, M. Stinchcombe, and H. White, "Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks," *Neural networks*, vol. 3, no. 5, pp. 551-560, 1990.
- [96] K. Hornik, "Approximation capabilities of multilayer feedforward networks," *Neural networks*, vol. 4, no. 2, pp. 251-257, 1991.
- [97] D. Rumelhart, G. Hinton, and J. Williams, "Learning Internal representations by error backpropagation," in *parallel Distributed Process*: The MIT press, 1986.
- [98] D. E. Rumelhart, R. Durbin, R. Golden, and Y. Chauvin, "Backpropagation: The basic theory," *Backpropagation: Theory, architectures and applications*, pp. 1-34, 1995.
- [99] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *nature*, vol. 323, no. 6088, pp. 533-536, 1986.
- [100] R. Zayani, R. Bouallegue, and D. Roviras, "Adaptive predistortions based on neural networks associated with Levenberg-Marquardt algorithm for satellite down links," *EURASIP Journal on Wireless Communications and Networking*, vol. 2008, pp. 1-15, 2008.
- [101] D. A. K. Fernando and A. Jayawardena, "Runoff forecasting using RBF networks with OLS algorithm," *Journal of hydrologic engineering*, vol. 3, no. 3, pp. 203-209, 1998.
- [102] Y. B. Dibike and D. P. Solomatine, "River flow forecasting using artificial neural networks," *Physics and Chemistry of the Earth, Part B: Hydrology, Oceans and Atmosphere*, vol. 26, no. 1, pp. 1-7, 2001.
- [103] C. Dawson, C. Harpham, R. Wilby, and Y. Chen, "Evaluation of artificial neural network techniques for flow forecasting in the River Yangtze, China," *Hydrology and Earth System Sciences*, vol. 6, no. 4, pp. 619-626, 2002.
- [104] A. Piotrowski, J. Napiorkowski, and P. Rowiński, "Flash-flood forecasting by means of neural networks and nearest neighbour approach—a comparative study," *Nonlinear Processes in Geophysics*, vol. 13, no. 4, pp. 443-448, 2006.

- [105] H. Moradkhani, K.-l. Hsu, H. V. Gupta, and S. Sorooshian, "Improved streamflow forecasting using self-organizing radial basis function artificial neural networks," *Journal of Hydrology*, vol. 295, no. 1-4, pp. 246-262, 2004.
- [106] Ö. Kişi, "Stream flow forecasting using neuro-wavelet technique," *Hydrological Processes: An International Journal*, vol. 22, no. 20, pp. 4142-4152, 2008.
- [107] E. Kabalcı, "Yapay Sinir Ağları," *Ders notları*, 2014.
- [108] T. Kohonen, "Analysis of a simple self-organizing process," *Biological cybernetics*, vol. 44, no. 2, pp. 135-140, 1982.
- [109] T. Kohonen, "Self-organized formation of topologically correct feature maps," *Biological cybernetics*, vol. 43, no. 1, pp. 59-69, 1982.
- [110] F. D. Mwale, A. J. Adeloje, and R. Rustum, "Infilling of missing rainfall and streamflow data in the Shire River basin, Malawi—A self organizing map approach," *Physics and Chemistry of the Earth, Parts A/B/C*, vol. 50, pp. 34-43, 2012.
- [111] A. M. Kalteh, P. Hjorth, and R. Berndtsson, "Review of the self-organizing map (SOM) approach in water resources: Analysis, modelling and application," *Environmental Modelling & Software*, vol. 23, no. 7, pp. 835-845, 2008.
- [112] H. Murao, I. Nishikawa, S. Kitamura, M. Yamada, and P. Xie, "A hybrid neural network system for the rainfall estimation using satellite imagery," in *Proceedings of 1993 International Conference on Neural Networks (IJCNN-93-Nagoya, Japan)*, 1993, vol. 2: IEEE, pp. 1211-1214.
- [113] K. l. Hsu, H. V. Gupta, X. Gao, S. Sorooshian, and B. Imam, "Self-organizing linear output map (SOLO): An artificial neural network suitable for hydrologic modeling and analysis," *Water Resources Research*, vol. 38, no. 12, pp. 38-1-38-17, 2002.
- [114] S. Corne, T. Murray, S. Openshaw, L. See, and I. Turton, "Using computational intelligence techniques to model subglacial water systems," *Journal of Geographical Systems*, vol. 1, no. 1, pp. 37-60, 1999.
- [115] A. T. C. o. A. o. A. N. N. i. Hydrology, "Artificial neural networks in hydrology. I: Preliminary concepts," *Journal of Hydrologic Engineering*, vol. 5, no. 2, pp. 115-123, 2000.
- [116] A. M. Kalteh and R. Berndtsson, "Interpolating monthly precipitation by self-organizing map (SOM) and multilayer perceptron (MLP)," *Hydrological sciences journal*, vol. 52, no. 2, pp. 305-317, 2007.
- [117] J. Vesanto, J. Himberg, E. Alhoniemi, J. Parhankangas, S. Team, and L. Oy, "SOM toolbox for Matlab 5," Citeseer, 2000.
- [118] T. Kohonen, *Self-organizing maps*. Springer Science & Business Media, 2012.

- [119] S. Haykin and N. Network, "A comprehensive foundation," *Neural networks*, vol. 2, no. 2004, p. 41, 2004.
- [120] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis," *IEEE transactions on information theory*, vol. 36, no. 5, pp. 961-1005, 1990.
- [121] T. Şengüler, "Wavelet frames and redundant wavelet transforms for fault detection," 2017.
- [122] R. Merry and M. Steinbuch, "Wavelet theory and applications," *literature study, Eindhoven university of technology, Department of mechanical engineering, Control systems technology group*, 2005.
- [123] I. Daubechies, *Ten lectures on wavelets*. SIAM, 1992.
- [124] S. V. Vaseghi, *Advanced digital signal processing and noise reduction*. John Wiley & Sons, 2008.
- [125] O. Rioul and M. Vetterli, "Wavelets and signal processing IEEE SP Magazine," ed: October, 1991.
- [126] D. Gabor, "Theory of communication. Part 1: The analysis of information," *Journal of the Institution of Electrical Engineers-part III: radio and communication engineering*, vol. 93, no. 26, pp. 429-441, 1946.
- [127] S. Arfaoui, A. B. Mabrouk, and C. Cattani, *Wavelet Analysis: Basic Concepts and Applications*. Chapman and Hall/CRC, 2021.
- [128] S. Mallat, *A wavelet tour of signal processing*. Elsevier, 1999.
- [129] S. Arfaoui, M. G. Alshehri, and A. Ben Mabrouk, "A quantum wavelet uncertainty principle," *Fractal and Fractional*, vol. 6, no. 1, p. 8, 2021.
- [130] W. Heisenberg, "Über den anschaulichen Inhalt der quantentheoretischen Kinematik und Mechanik," in *Original Scientific Papers Wissenschaftliche Originalarbeiten*: Springer, 1985, pp. 478-504.
- [131] P. A. M. Dirac, "The fundamental equations of quantum mechanics," *Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character*, vol. 109, no. 752, pp. 642-653, 1925.
- [132] D. P. Casasent, J. S. Smokelin, and A. Ye, "Wavelet and Gabor transforms for detection," *Optical Engineering*, vol. 31, no. 9, pp. 1893-1898, 1992.
- [133] H. G. Feichtinger and K. Gröchenig, "Gabor wavelets and the Heisenberg group: Gabor expansions and short time Fourier transform from the group theoretical point of view," *Wavelets: a tutorial in theory and applications*, vol. 2, pp. 359-398, 1992.
- [134] L. T. Rachdi and F. Meherzi, "Continuous wavelet transform and uncertainty principle related to the spherical mean operator," *Mediterranean Journal of Mathematics*, vol. 14, no. 1, pp. 1-23, 2017.

- [135] S. Dahlke, G. Kutyniok, P. Maass, C. Sagiv, H.-G. Stark, and G. Teschke, "The uncertainty principle associated with the continuous shearlet transform," *International Journal of Wavelets, Multiresolution and Information Processing*, vol. 6, no. 02, pp. 157-181, 2008.
- [136] M. Antonini, M. Barlaud, and P. Mathieu, "Image coding using lattice vector quantization of wavelet coefficients," in *[Proceedings] ICASSP 91: 1991 International Conference on Acoustics, Speech, and Signal Processing*, 1991: IEEE, pp. 2273-2276.
- [137] M. Wong, "Localization operators on the Weyl-Heisenberg group," *Geometry, analysis and applications (Varanasi, 2000)*, pp. 303-314, 2001.
- [138] J. R. Klauder and B.-S. Skagerstam, *Coherent states: applications in physics and mathematical physics*. World scientific, 1985.
- [139] T. Hou and H. Qin, "Continuous and discrete Mexican hat wavelet transforms on manifolds," *Graphical Models*, vol. 74, no. 4, pp. 221-232, 2012.
- [140] V. Sygouni, C. D. Tsakiroglou, and A. C. Payatakes, "Capillary pressure spectrometry: Toward a new method for the measurement of the fractional wettability of porous media," *Physics of Fluids*, vol. 18, no. 5, p. 053302, 2006.
- [141] R. X. Gao and R. Yan, *Wavelets: Theory and applications for manufacturing*. Springer Science & Business Media, 2010.
- [142] J.-M. Combes, A. Grossmann, and P. Tchamitchian, *Wavelets: Time-Frequency Methods and Phase Space Proceedings of the International Conference, Marseille, France, December 14-18, 1987*. Springer Science & Business Media, 2012.
- [143] C. K. Chui, *An introduction to wavelets*. Academic press, 1992.
- [144] Y. Meyer, "Wavelets: Algorithms and Applications, SIAM, Philadelphia, 1993," *MR 95f*, vol. 94005, 1993.
- [145] O. Rioul and M. Vetterli, "Wavelets and signal processing," *IEEE signal processing magazine*, vol. 8, no. 4, pp. 14-38, 1991.
- [146] D. L. Fugal, *Conceptual wavelets in digital signal processing: an in-depth, practical approach for the non-mathematician*. Space & Signals Technical Pub., 2009.
- [147] M. Güneş, C. Parim, D. Yıldız, and A. Büyüklü, "Predicting monthly streamflow using a hybrid wavelet neural network: case study of the Çoruh River Basin," *Polish Journal of Environmental Studies*, vol. 30, no. 4, 2021.
- [148] R. Maheswaran and R. Khosa, "Comparative study of different wavelets for hydrologic forecasting," *Computers & Geosciences*, vol. 46, pp. 284-295, 2012.

- [149] S. G. Mallat, "A theory for multiresolution signal decomposition: the wavelet representation," *IEEE transactions on pattern analysis and machine intelligence*, vol. 11, no. 7, pp. 674-693, 1989.
- [150] D. Sundararajan, *Discrete wavelet transform: a signal processing approach*. John Wiley & Sons, 2016.
- [151] H. Olkkonen, *Discrete Wavelet Transforms: Biomedical Applications*. BoD–Books on Demand, 2011.
- [152] M. Schneiders, "Wavelets in control engineering," ed: DCT, 2001, p. 38.
- [153] G. Strang and T. Nguyen, *Wavelets and filter banks*. SIAM, 1996.
- [154] M.-Y. Shih and D.-C. Tseng, "A wavelet-based multiresolution edge detection and tracking," *Image and Vision Computing*, vol. 23, no. 4, pp. 441-451, 2005.
- [155] G. G. Walter, "A sampling theorem for wavelet subspaces," *IEEE Transactions on Information Theory*, vol. 38, no. 2, pp. 881-884, 1992.
- [156] A. Haar, *Zur theorie der orthogonalen funktionensysteme*. Georg-August-Universität, Gottingen., 1909.
- [157] P. F. Craigmile and D. B. Percival, "Wavelet-based trend detection and estimation," *Encyclopedia of environmetrics*, vol. 4, pp. 2334-2338, 2002.
- [158] R. Merry, "Wavelet theory and applications: a literature study," *DCT rapporten*, vol. 2005, 2005.
- [159] M. Misiti, Y. Misiti, G. Oppenheim, and J.-M. Poggi, "Wavelet toolbox," *The MathWorks Inc., Natick, MA*, vol. 15, p. 21, 1996.
- [160] A. Cohen, I. Daubechies, and J. C. Feauveau, "Biorthogonal bases of compactly supported wavelets," *Communications on pure and applied mathematics*, vol. 45, no. 5, pp. 485-560, 1992.
- [161] H. T. Nguyen and I. T. Nabney, "Short-term electricity demand and gas price forecasts using wavelet transforms and adaptive models," *Energy*, vol. 35, no. 9, pp. 3674-3685, 2010.
- [162] H. Ebrahimi and T. Rajaei, "Simulation of groundwater level variations using wavelet combined with neural network, linear regression and support vector machine," *Global and Planetary Change*, vol. 148, pp. 181-191, 2017.
- [163] K. Gurley and A. Kareem, "Applications of wavelet transforms in earthquake, wind and ocean engineering," *Engineering structures*, vol. 21, no. 2, pp. 149-167, 1999.
- [164] K. S. Kasiviswanathan, J. He, K. Sudheer, and J.-H. Tay, "Potential application of wavelet neural network ensemble to forecast streamflow for flood management," *Journal of hydrology*, vol. 536, pp. 161-173, 2016.
- [165] A. El Ibrahimy, A. Baali, A. Couscous, T. El Kamel, and N. Hamdani, "Comparative Study of the Three Models (ANN-PMC),(DWT-ANN-PMC)

- and (MLR) for Prediction of the Groundwater Level of the Surface Water Table in the Saïss Plain (North of Morocco)," *Int. J. Intell. Eng. Syst.*, vol. 10, no. 5, 2017.
- [166] A. Kumar, R. Kale, B. M. Babu, U. Sathishkumar, G. Reddy, and P. S. Kulkarni, "A hybrid-wavelet artificial neural network model for monthly water table depth prediction," *Current Science (00113891)*, vol. 117, no. 9, 2019.
 - [167] M. K. Tiwari and J. F. Adamowski, "An ensemble wavelet bootstrap machine learning approach to water demand forecasting: a case study in the city of Calgary, Canada," *Urban Water Journal*, vol. 14, no. 2, pp. 185-201, 2017.
 - [168] P. Sarda and P. Sadgir, "Reservoir Water Quality Modeling for COD using Artificial Neural Network," *International Journal of Engineering and Management Research (IJEMR)*, vol. 5, no. 4, p. 347, 2015.
 - [169] W. Wang and Y. Lu, "Analysis of the mean absolute error (MAE) and the root mean square error (RMSE) in assessing rounding model," in *IOP conference series: materials science and engineering*, 2018, vol. 324, no. 1: IOP Publishing, p. 012049.
 - [170] C. Sammut and G. I. Webb, *Encyclopedia of machine learning*. Springer Science & Business Media, 2011.
 - [171] A. Bilgin and M. U. Konanç, "Evaluation of surface water quality and heavy metal pollution of Coruh River Basin (Turkey) by multivariate statistical methods," *Environmental Earth Sciences*, vol. 75, no. 12, pp. 1-18, 2016.
 - [172] C. Yerdelen, Y. Karimi, and E. Kahya, "Frequency analysis of mean monthly streamflow in Çoruh Basin, Turkey," *Fresenius Environmental Bulletin*, vol. 19, no. 7, pp. 1300-1311, 2010.
 - [173] (2020). *Devlet Su İşleri*. [Online] Available: <http://en.dsi.gov.tr>
 - [174] K. C. Explorer, "Royal Netherlands Meteorological Institute (KNMI)," *URL: https://climexp.knmi.nl/[cited 2016/05/13]*, vol. 1, 2016.
 - [175] W. Bank, "World Bank Data," 2020. [Online]. Available: <https://data.worldbank.org/>.
 - [176] R. Graf, S. Zhu, and B. Sivakumar, "Forecasting river water temperature time series using a wavelet–neural network hybrid modelling approach," *Journal of Hydrology*, vol. 578, p. 124115, 2019.
 - [177] C. Huang, A. J. Newman, M. P. Clark, A. W. Wood, and X. Zheng, "Evaluation of snow data assimilation using the ensemble Kalman filter for seasonal streamflow prediction in the western United States," *Hydrology and Earth System Sciences*, vol. 21, no. 1, pp. 635-650, 2017.
 - [178] D. C. Sohoulade Djebou and V. P. Singh, "Entropy-based index for spatiotemporal analysis of streamflow, precipitation, and land-cover," *Journal of Hydrologic Engineering*, vol. 21, no. 11, p. 05016024, 2016.

- [179] C. A. Guimarães Santos and G. B. L. d. Silva, "Daily streamflow forecasting using a wavelet transform and artificial neural network hybrid models," *Hydrological Sciences Journal*, vol. 59, no. 2, pp. 312-324, 2014.
- [180] O. Kisi and M. Cimen, "A wavelet-support vector machine conjunction model for monthly streamflow forecasting," *Journal of Hydrology*, vol. 399, no. 1-2, pp. 132-140, 2011.
- [181] P. Coulibaly and D. H. Burn, "Wavelet analysis of variability in annual Canadian streamflows," *Water Resources Research*, vol. 40, no. 3, 2004.
- [182] H. Wang and K. He, "Sensitivity Analysis of the Effects of Climate Change on Streamflow Using Climate Elasticity in the Luan River Basin, China," *Polish Journal of Environmental Studies*, vol. 26, no. 2, 2017.
- [183] A. Akpınar, M. İ. Kömürcü, and M. Kankal, "Development of hydropower energy in Turkey: the case of Coruh river basin," *Renewable and Sustainable Energy Reviews*, vol. 15, no. 2, pp. 1201-1209, 2011.
- [184] A. Klaphake and W. Scheumann, "Coruh river basin: hydropower development and transboundary cooperation," *Turkey's Water Policy: National Frameworks and International Cooperation*, pp. 251-261, 2011.

Makale

1. Güneş; M. Ş.; Parim; C.; Yıldız; D. ve Büyüklü; A. H. “Predicting monthly streamflow using a hybrid wavelet neural network: Case study of the Çoruh river basin” Polish Journal of Environmental Studies; cilt 30; 2021. (SCI Expanded)

Bildiri

1. Güneş; M. Ş.; Parim; C.; Yıldız; D. ve Büyüklü; A. H. “Predicting Monthly Streamflow Using a Hybrid Wavelet Neural Network: Case Study of the Çoruh River Basin” 4th International Conference on Data Science and Applications (ICONDATA’21), İstanbul, Türkiye, 4 - 06 Haziran 2021, ss.2