
GAZİ ÜNİVERSİTESİ
Gazi
1926

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HAVZA ÇIKIŞ DEBİSİ TAHMİNİ

Kerem KAYA

YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

HAZİRAN 2022

ETİK BEYAN

Gazi Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Kerem KAYA
21/06/2022

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE HAVZA ÇIKIŞ DEBİSİ TAHMİNİ

(Yüksek Lisans Tezi)

Kerem KAYA

GAZİ ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

Haziran 2022

ÖZET

Meteorolojik kaynaklı afetlerden taşkınların verdiği zararlar hem ülkemizde hem de dünyada her geçen yıl artarak devam etmektedir. İklim değişimi, plansız şehirleşme vb. etkiler taşkınların görülme sıklığını ve verdiği zararları etkileyen en önemli parametrelerdir. Özellikle iklim değişimine bağlı olarak yağış rejimleri değişebilmektedir. Yağış rejimlerinin değişimi ise yağış şiddetleri, yağış miktarı ve mevsimsel rejimi etkilemektedir. Mühendislik hizmetleri, tasarlanacak sanat yapıları ve şehirleşme planlarını doğrudan etkileyen bu parametrelerin zamansal ve mekânsal değişimlerinin incelenmesi önemlidir. Literatürde yapılan çalışmalar incelendiğinde meteorolojik verilerin analizinin oldukça önemli olduğu görülmektedir. Bu nedenle yağış–akış ilişkisinin birlikte değerlendirildiği istatistiksel yöntemlerin yanı sıra Coğrafi Bilgi Sistemlerindeki alt yapı çalışmalarının kişisel bilgisayarlarda kullanıma uygun hale gelmesi ile birlikte makine öğrenme yöntemleri tahmin modellerinin geliştirilmesi ve kullanımı da artmıştır. Bu tez çalışması kapsamında sıkça taşkınların yaşandığı, can ve mal kayıplarına neden olan Batı Karadeniz Bölgesinde yer alan Bartın havzası çalışma alanı olarak seçilmiştir. Çalışmanın amacı, meteorolojik veriler ile akış debileri arasındaki ilişkileri makine öğrenme yöntemlerinden Yapay Sinir Ağları, K-Means Kümeleme Yöntemi ve Destek Vektör Regresyon yöntemlerini kullanarak araştırmaktır. Çalışmada Makine Öğrenme yöntemlerinin dışında Moulheli (2003) tarafından geliştirilen GR2M modeli de kurulmuştur. Elde edilen analiz sonuçları ve mevcut akım gözlem istasyon verileri, Kök Ortalama Kare Hata (RMSE), Nash-Sutcliffe Etkinlik Katsayısı (NSE) ve Determinasyon Katsayısı (r^2) ile birlikte değerlendirilmiştir. Çalışmada kullanılan yöntemlerin hem tekil olarak çalıştırılmış sonuçları hem de birlikte kullanımları durumunda elde edilen sonuçlar değerlendirilmiştir. Özellikle Yapay Sinir Ağları ve K-Means Kümeleme yöntemlerinin birlikte kullanımı ile edilen tahmin sonuçları diğer model tahmin sonuçlarına göre daha az hata üretmiştir.

Kodu	:	91106
Anahtar Kelimeler	:	Yapay sinir ağları, coğrafi bilgi sistemleri, Batı Karadeniz havzası, istatistiksel hidroloji
Sayfa Adedi	:	73
Danışman	:	Dr. Öğr. Üyesi Önder KOÇYİĞİT

DETERMINATION OF OUTLET DISCHARGE IN BASIN
WITH MACHINE LEARNING METHODS
(M. Sc. Thesis)

Kerem KAYA

GAZİ UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

June 2022

ABSTRACT

Floods, one of the meteorological disasters are steadily increasing each year both in Turkey and in the World due to variety of reasons such as climate change, unplanned urbanization etc. Frequency and damage magnitudes of the floods are directly related those emphasized subjects. Especially, precipitation regimes may alter due to climate change. Variation in the seasonal storms also affects precipitation intensities as well as amount of total precipitation and seasonal regimes. Therefore, academic studies need to be carried out in order to understand what kind of relations exist between discharges at basin outlet versus the temporal and the spatial variations of hydrological parameters. As can be seen from the literature review, studies that focus on investigating the relationship between precipitation and runoff are largely dependent on the analysis of meteorological data. In addition to the most common conventional statistical approaches in which the precipitation-flow relationship is evaluated together, due to its strong ability to compress information and extract features from large data quantities, machine learning methods with the use of the Geographical Information System have had more application areas on Hydrology. Within the scope of this thesis, the Bartın basin, which is located in the Western Black Sea Region, where flood problem is encountered often causes loss of life and property, has been chosen as the case study area. In this study, of the machine learning methods such as Artificial Neural Networks, K-Means Clustering Method and Support Vector Regression were used in order to correlate meteorological parameters versus the discharge of the river. Apart from machine learning methods, the GR2M model developed by Moulheli (2003) was also tested for the same purpose. The results obtained by model analysis and available observation station data were evaluated together with the Root Mean Square Error (RMSE), the Nash-Sutcliffe Efficiency Coefficient (NSE) and Coefficient of Determination (r^2). In addition to the individual results of any methods used in the study, combination use of the methods were also tested. It has been concluded that the results particularly obtained with the combine use of Artificial Neural Networks and K-Means Clustering methods have better estimation than other outcomes. Detailed analysis of other the results are presented in the thesis.

Science Code	:	91106
Key Words	:	Artificial neural network, geographical information system, the Western Black Sea basin, statistical hydrology
Page Number	:	73
Supervisor	:	Assist. Prof. Dr. Önder KOÇYİĞİT

TEŞEKKÜR

Çalışmalarım süresince yakın ilgileri ve destek veren sözleriyle beni daima olumlu etkileyerek yoluma ışık olan sevgili aileme; gerek ders döneminde, gerek tez aşamasında değerli bilgilerinden, tecrübelerinden, mesleki kişiliğinden ve en önemlisi insani yönünden çok şey öğrendiğim danışman hocam sayın Dr. Öğr. Üyesi Önder KOÇYİĞİT'e teşekkürlerimi bir borç bilirim.

İÇİNDEKİLER

Sayfa

ÖZET…….. iv

ABSTRACT……... v

TEŞEKKÜR……... vi

İÇİNDEKİLER…….. vii

ÇİZELGELERİN LİSTESİ…… ix

ŞEKİLLERİN LİSTESİ ……..….. x

HARİTALARIN LİSTESİ……...….. xii

SİMGELER VE KISALTMALAR …….. xiii

1. GİRİŞ……..……..... 1

2. LİTERATÜR ARAŞTIRMASI……..... 3

3. ÇALIŞMA ALANI.……..... 11

4. METODOLOJİ……..... 21

4.1. Makine Öğrenme Yöntemeri…….…….... 21

4.1.1. Yapay Sinir Ağları…….....…….…..... 22

4.1.2. Destek Vektör Makinesi ve Destek Vektör Regresyonu…..……..... 25

4.1.3. K-Means kümeleme yöntemi……..……..... 28

4.2. GR2M Modeli……..……...…….…... 29

4.2.1. Thornthwaite ve Mather potansiyel buharlaşma – terleme yöntemi..... 32

4.3. Performans Ölçüm Yöntemleri……...……..... 33

4.3.1. Kök ortalama kare hata (RMSE)..…..……..... 33

4.3.2. Nash – Sutcliffe etkinlik katsayısı (NSE)……..... 33

4.3.3. Determinasyon katsayısı (r^2)..…..……..... 34

5. BULGULAR……..……..... 35

Sayfa

5.1. Lineer Regresyon……..……..... 35

5.2. Yapay Sinir Ağları……..……..……..... 35

5.3. Destek Vektör Regresyonu…..…….....……..... 47

5.4. K-Means Kümeleme Yöntemi....……...……..... 48

5.4.1. K-Means ve YSA...…….....…….……..... 53

5.4.2. K-Means ve DVR.……...……..……..... 54

5.5. GR2M Modeli…….....……...……..... 54

6. TARTIŞMA.…….…….……..... 57

7. SONUÇ VE ÖNERİLER…….……... 67

KAYNAKLAR……... 69

ÖZGEÇMİŞ……..... 73

ÇİZELGELERİN LİSTESİ

Çizelge **Sayfa**

Çizelge 3.1. Bartın ilinde yer alan meteoroloji gözlem istasyonları……..... 15

Çizelge 3.2. Bartın iline ait meteorolojik istatistikler……..... 16

Çizelge 3.3. Aylık ortalama akım verileri……..... 18

Çizelge 3.4. Bartın ilinde meydana gelen taşkın olayları…….…..... 19

Çizelge 4.1. Enlem düzeltme katsayısı (G)..……..…….…..... 33

Çizelge 5.1. K-Means kümeleme ile oluşturulan kümelerin sentroid noktaları…….... 51

Çizelge 5.2. Birinci grup ortalama aylık yağış ve debi değerleri…….……..... 52

Çizelge 5.3. İkinci grup ortalama aylık yağış ve debi değerleri…….……..... 53

Çizelge 5.4. Aylık ortalama sıcaklık ve potansiyel evapotranspirasyon…….……..... 55

Çizelge 6.1. Yapay Sinir Ağları ile elde edilen sonuçlar…….……..... 57

Çizelge 6.2. K-Means kümelemeden sonra YSA ve DVR kullanılması ile elde edilen sonuçlar.....……..... 58

Çizelge 6.3. Makine öğrenme yöntemlerinden elde edilen sonuçlar……..…..... 58

Çizelge 6.4. Makine Öğrenme yöntemleri öğrenme ve test verilerinin performansları. 58

Çizelge 6.5. İstatistiksel yöntemlerden elde edilen tekerrür debileri…….……..... 62

Çizelge 6.6. K-S testinden elde edilen fark değerleri……...…….…….……..... 63

Çizelge 6.7. AGİ'de ölçülen maksimum debiye göre istatistiksel yöntemlerden elde edilen yıllar….....……..... 63

Çizelge 6.8. GR2M ve YSA model performansları…...……...…….…….……..... 64

ŞEKİLLERİN LİSTESİ

Şekil **Sayfa**

Şekil 4.1. Makine öğrenme yöntemleri……..……...…….……..... 22

Şekil 4.2. Tek gizli katmana sahip bir Yapay Sinir Ağı modeli..…….……..... 23

Şekil 4.3. Bir sinir ağı hücresinin şematik gösterimi……..…….……..... 24

Şekil 4.4. Destek Vektör Makinesi şematik gösterim..……..…….……..... 26

Şekil 4.5. Bir boyutlu doğrusal Destek Vektör Regresyonu…..…..…….……..... 28

Şekil 4.6. GR2M modeli çalışma şeması……...…..…….……..... 30

Şekil 5.1. Lineer regresyondan elde edilen ölçülen ve modellenen debi grafiği…..... 35

Şekil 5.2. YSA'da girdi olarak M kullanılmasıyla elde edilen debi grafiği……..... 37

Şekil 5.3. YSA'da girdi olarak P kullanılmasıyla elde edilen debi grafiği……..... 37

Şekil 5.4. YSA'da Girdi olarak R kullanılmasıyla elde edilen debi grafiği……..... 38

Şekil 5.5. YSA'da girdi olarak T kullanılmasıyla elde edilen debi grafiği……..... 39

Şekil 5.6. YSA'da girdi olarak M ve P kullanılmasıyla elde edilen debi grafiği….... 39

Şekil 5.7. YSA'da girdi olarak M ve R kullanılmasıyla elde edilen debi grafiği….... 40

Şekil 5.8. YSA'da girdi olarak M ve T kullanılmasıyla elde edilen debi grafiği….... 41

Şekil 5.9. YSA'da girdi olarak P ve R kullanılmasıyla elde edilen debi grafiği….... 42

Şekil 5.10. YSA'da girdi olarak P ve R kullanılmasıyla elde edilen debi grafiği…..... 42

Şekil 5.11. YSA'da girdi olarak R ve T kullanılmasıyla elde edilen debi grafiği.....…. 43

Şekil 5.12. YSA'da girdi olarak M, P ve R kullanılmasıyla elde edilen debi grafiği..... 44

Şekil **Sayfa**

Şekil 5.13. YSA'da girdi olarak M, P ve T kullanılmasıyla elde edilen debi grafiği..... 45

Şekil 5.14. YSA'da girdi olarak P, R ve T kullanılmasıyla elde edilen debi grafiği..... 46

Şekil 5.15. YSA'da girdi olarak M, P, R ve T kullanılmasıyla elde edilen debi grafiği 47

Şekil 5.16. Destek Vektör Regresyonu yöntemi ile elde edilen ölçülen-model debi grafiği..... 48

Şekil 5.17. Aylık yağışa karşılık gelen debi noktaları ……..…... 49

Şekil 5.18. Küme sayısı optimizasyon grafiği……..……..... 50

Şekil 5.19. Debi-yağış verilerinin kümelenme grafiği…….……..... 51

Şekil 5.20. Birinci ve ikinci grup birleştirilmiş model debi ve ölçülen debi grafiği..... 53

Şekil 5.21. Birinci ve ikinci grup birleştirilmiş model debi ve ölçülen debi grafiği..... 54

Şekil 5.22. GR2M modeli ile elde edilen model-ölçülen debi grafiği……..... 56

Şekil 6.1. Yağış, ölçülen debi ve modellenen debi grafiği…….....……..……..... 60

Şekil 6.2. GR2M ve YSA modellerinin karşılaştırılması…..……..……..... 65

HARİTALARIN LİSTESİ

Harita **Sayfa**

Harita 3.1. Bartın ilinin Türkiye'deki konumu……..……..……..... 11

Harita 3.2. Bartın Irmağı'nı oluşturan Kocaçay ve Kocanaz Çayları …..…….……..... 12

Harita 3.3. Kocaçay Çayı yağış alanı sınırları……..…….……..... 13

Harita 3.4. Bartın Havzası Sayısal Yükseklik Modeli…….…….……..... 14

Harita 3.5. Bartın Havzası eğim haritası……..…….…….……..... 14

Harita 3.6. Çalışmada kullanılan meteoroloji gözlem istasyonları…...…….……..... 16

Harita 3.7. Kocaçay Çayı için oluşturulan Thiessen Poligonu…..…...…...….…..... 17

Harita 3.8. D13A031 numaralı AGİ'nin konumu……..…...…….……..... 18

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Simgeler	**Açıklamalar**
E	Potansiyel Evapotranspirasyon
G	Enlem Düzeltme Katsayısı
I	Yıllık Sıcaklık İndisi
km^2	Kilometrekare
m	Metre
m^2	Metrekare
m^3	Metreküp
mm	Milimetre
P	Yağış
R	Tekrarlama Periyodu
Q	Debi
T	Sıcaklık
X_1	Üretim Kapasitesi
X_2	Değişim Parametresi

Kısaltmalar	**Açıklamalar**
AGİ	Akım Gözlem İstasyonu
DVM	Destek Vektör Makinesi
DVR	Destek Vektör Regresyonu
MGM	Meteoroloji Genel Müdürlüğü
NSE	Nash Etkinlik Katsayısı
PET	Potansiyel Evapotranspirasyon
RMSE	Root Mean Square Error
YSA	Yapay Sinir Ağları

1. GİRİŞ

Taşkın, bir akarsuyun çeşitli sebeplerle yatağından taşması veya normal şartlar altında kuru olan bir alanın geçici olarak sularla kaplanması sebebiyle tarım arazilerine, ekonomik aktivite alanlarına, yerleşim yerlerine, altyapı tesislerine ve bölgenin ekolojisine zarar vererek o bölgedeki ekonomik ve sosyal faaliyetleri kesintiye uğratan bir doğa olayıdır. Su Yönetimi Genel Müdürlüğü (2019) raporuna göre taşkın dünyada yaşanan en önemli afetler arasında yer almakta olup ülkemizde de can ve mal kaybı açısından tüm afetler arasında ikinci, meteorolojik afetler arasında da birinci sırada yer almaktadır. Taşkınlar, insan yaşamı üzerindeki olumsuz etkilerine ek olarak, ciddi ekonomik zararlara, çevresel zararlara ve sosyo-kültürel zararlara da yol açmaktadır. Taşkınlar nedeniyle ortaya çıkan bu zararları en aza indirmek için mühendislik alanında çalışmalar yapılmaktadır. Bu çalışmalardan öne çıkanları, hızlı ve güvenilir sonuçlar elde edilmesinden dolayı kullanımı yaygınlaşan, uzaktan algılama yöntemi ve hidrolojik modellemeler üretme tekniğidir.

Meteorolojik kaynaklı afetlerden taşkınların verdiği zararlar hem ülkemizde hem de dünyada her geçen yıl artarak devam etmektedir. İklim değişimi, plansız şehirleşme vb. etkiler taşkınların görülme sıklığını ve verdiği zararları etkileyen en önemli parametrelerdir. Özellikle iklim değişimine bağlı olarak yağış rejimleri değişebilmektedir. Yağış rejimlerinin değişimi ise yağış şiddetleri, yağış miktarı ve mevsimsel rejimi etkilemektedir. Mühendislik hizmetleri, tasarlanacak sanat yapıları ve şehirleşme planlarını doğrudan etkileyen bu parametrelerin zamansal ve mekânsal değişimlerinin incelenmesi oldukça önemlidir. Literatürde yapılan çalışmalar incelendiğinde meteorolojik verilerin analizinin oldukça önemli olduğu görülmektedir. Bu nedenle yağış–akış ilişkisinin birlikte değerlendirildiği istatistiksel yöntemlerin yanı sıra Coğrafi Bilgi Sistemlerindeki alt yapı çalışmalarının kişisel bilgisayarlarda kullanıma uygun hale gelmesi ile birlikte Yapay Sinir Ağları (YSA) tahmin modellerinin geliştirilmesi ve kullanımı da artmaktadır.

Bu tez çalışması kapsamında sıkça taşkınların yaşandığı, can ve mal kayıplarına neden olan Batı Karadeniz Bölgesinde yer alan Bartın havzası çalışma alanı olarak seçilmiştir. Çalışmanın amacı meteorolojik veriler ile akış debileri arasındaki ilişkileri makine öğrenme yöntemlerinden Yapay Sinir Ağları, K-Means Kümeleme Yöntemi ve Destek Vektör Regresyon yöntemleri kullanarak araştırmaktır. Çalışmada Makine Öğrenme yöntemlerinin dışında Moulheli (2003) tarafından geliştirilen GR2M modeli de kurulmuştur. Elde edilen

analiz sonuçları ve mevcut akım gözlem istasyon verileri, Kök Ortalama Kare Hata (RMSE), Nash-Sutcliffe Etkinlik Katsayısı (NSE) ve Determinasyon Katsayısı (r^2) ile birlikte değerlendirilmiştir.

2. LİTERATÜR ARAŞTIRMASI

Bu bölümde tez çalışmasında kullanılan Yapay Sinir Ağları (YSA) yönteminin tarihsel gelişimine ve bu yöntem ile hidroloji alanında yapılan akademik çalışmalara değinilmiştir.

YSA yönteminin gelişimi incelendiğinde, çalışmaların 1940'lı yıllara dayandığı görülmektedir. McCulloh ve Pitts (1943), çalışmalarında en basit yapay sinir ağları tipinin bile aritmetik ve mantıksal fonksiyonları hesaplayabildiğini göstermişlerdir. Bu çalışma geniş bir kitleye ulaşmış ve büyük bir etki bırakmıştır. Başka bir araştırmada Norbert Wiener ve von Neumann, beyin gibi çalışan bilgisayarların tasarımı üzerine yapılan araştırmalar için bazı önerilerde bulunmuşlardır.

Marvin Minsky (1951) tarafından "*Snark*" isimli ilk nöro-bilgisayar üretilmiştir. "*Snark*", teknik açıdan başarılı şekilde çalışmasına rağmen değişik fonksiyonları çalıştırmada yetersiz kalmıştır.

Rosenblatt ve diğerleri (1958) ilk başarılı nöro-bilgisayarı (*Mark I Algılayıcı*) üretmişlerdir. Bu nedenle Rosenblatt, nöro-bilgisayarın kurucusu olarak bilinmektedir. Rosenblatt'ın ayrıca nöron hesaplamaları üzerine "Nörodinamiğin İlkerleri" adlı bir kitabı da bulunmaktadır.

Bernard Widrow, halen yaygın olarak kullanımda olan ADALINE olarak adlandırılan, algılayıcı öğrenme yasası ile çalışan sinir ağlarının aksine daha güçlü bir öğrenme yasası ile donatılmış farklı bir tip sinir ağı işlemcisi geliştirmiştir. Widrow öğrencileriyle beraber geliştirdikleri sistemi birçok oyuncak problemi üzerine başarıyla uygulamışlardır.

1960'lı yılların sonlarında sinir ağları yöntemine aktarılan araştırma fonlarının yapay zekâ alanına yönlendirilmesiyle ile ilgili kampanyalar yürütülmüştür. 1970'li yıllarda sinir ağları yöntemi, yürütülen kampanyalara rağmen uyarlanabilir sinyal işleme, desen tanıma ve biyolojik modellemeler konularında devam etmiştir.

1980'lerin başlarında, birçok Nörobilgisayar araştırmacısı, nöro-bilgisayarların ve sinir ağı uygulamalarının gelişimini keşfetmek için öneriler sunmaya başlamıştır. 1983-1986 yıllarında John Hopfield, sinir ağları üzerine iki makale yazmış ve dünyanın her yerinde

verdiği birçok dersle birlikte, yüzlerce yüksek nitelikli bilim adamı, matematikçi ve teknoloji uzmanının bu alana katılmasını sağlamıştır.

1986'da "PDP kitaplarının (Parallel Distributed Processing, Cilt I ve II, Rumelhart ve McClelland tarafından düzenlenmiştir) yayınlanmasıyla bu alana ilgi çok arttı. 1987'de, modern zamanlarda sinir ağları üzerine ilk açık konferans olan IEEE Uluslararası Sinir Ağları Konferansı San Diego'da yapılmış ve Uluslararası Sinir Ağı Derneği (INNS) kurulmuştur. 1988'de INNS dergisi Neural Networks kurulmuş, bunu 1989'da Neural Computation ve 1990'da IEEE Transactions on Neural Networks izlemiştir (N. Yadav, A. Yadav ve Kumar, 2015).

Aşağıda hidroloji alanında yapılan çalışmalara yer verilmiştir.

Kumar ve diğerleri, yaptıkları çalışmada aylık debi değerlerinin tahmini için YSA'yı kullanmışlardır. Çalışma alanı olarak Hindistan'da bulunan Hemavathi Nehri'ni seçmişlerdir. İki tip YSA yöntemini kullanmışlardır. Bunlar, İleri Yönlü Sinir Ağı ve Tekrarlayan Sinir Ağı'dır. Tekrarlayan Sinir Ağı'nın daha iyi sonuç verdiğini belirtmişlerdir. Sel ve kuraklık gibi olayların etkilerini azaltmak için gerçek zamanlı tahmin modellerinin geliştirilmesinin gerekliliğine vurgu yapmışlardır. Yapılan bu çalışma ile bu amaca katkı sağladıklarını belirtmişlerdir (Kumar, Raju ve Sathish, 2004).

Kentel, çalışma alanı olarak Ankara'da bulunan Güvenç Nehri'ni seçmiştir. Nehrin aylık debi değerlerini tahmin etmek için veri setine uygun olan Yapay Sinir Ağı modelini tespit ederek uygulamıştır. Çalışmada yağış verileri, debi değerleri ve bunlarla ilişkili ay verilerini kullanmıştır. Veri setinin içinde yeterince ekstrem verilerin olmaması nedeniyle YSA'nın iyi sonuçlar vermeyeceğini tespit etmiştir. Bu nedenle verileri, Bulanık C-Ortalama Kümeleme algoritmasını kullanarak normal ve ekstrem olaylar olarak ayırmıştır. Bu sayede ekstrem olaylar karşısında kullanıcılara, YSA'nın güvenilir olmayan sonuçlar üretme riskine karşı bir fikir vermesini amaçlamıştır (Kentel, 2009).

Jahangir ve diğerleri, Tahran, İran' da bulunan Kan Nehri havzasında Coğrafi Bilgi Sistemleri ile YSA'yı birlikte kullanarak nehrin debisini tahmin etmek için çalışmışlardır. Çalışmada bölgenin eğim, eğrilik, normalize edilmiş fark bitki örtüsü indeksi (NDVİ), akım birikimi, jeoloji, toprak grubu, arazi kullanımı haritalarıyla beraber geçmiş yıllara ait yağış

verilerini kullanmışlardır. Olası bir taşkın olayının belirlenmesinde CBS ve YSA'nın birlikte kullanımının en etkili yöntemlerden biri olduğunu belirtmişlerdir (Jahangir, Reineh ve Abolghasemi, 2019).

Joorabchi ve diğerleri, Avustralya'nın en büyük nehir sistemlerinden biri olan, birçok büyük taşkın olaylarının yaşandığı Fitzroy Nehri üzerinde yaptıkları çalışmada günlük debi değerini tahmin etmek için bir YSA tipi olan İleri Yönlü Sinir Ağı'nı kullanmışlardır. Çalışma sonunda yüksek debi değerlerinde güvenilir sonuçlar elde ederken düşük debi değerlerinde gerçek değerin üzerinde sonuçlar elde ettiklerini belirtmişlerdir (Joorabchi, Zhang ve Blumenstein, 2007).

Uysal ve diğerleri, çalışma alanı olarak Türkiye'nin başkenti Ankara şehri için hayati öneme sahip olan Çamlıdere Barajı havzasını seçmişlerdir. YSA tekniğinden yararlanmışlardır ve girdi parametreleri olarak hava sıcaklığı, yağış, buharlaşma ve debi değerlerini kullanarak aylık debi değerini tahmin etmeyi amaçlamışlardır. Elde ettikleri sonuçlara göre girdi vektörlerinin sayısını artırmak yerine veri ön işleme uygulamasının özellikle yüksek debileri yakalamak için etkili olduğuna vurgu yapmışlardır (Uysal ve Şorman, 2017).

Anılan ve diğerleri, YSA tekniğini kullanarak, Türkiye'nin Doğu Karadeniz Bölgesi'ni çalışma alanı olarak seçip, bu bölgede yıllık maksimum debi değerinin tahmini için çalışmışlardır. YSA'nın üç farklı modelini denemişlerdir. Bunlar, Çok Katmanlı Algılayıcı Sinir Ağı, İleri Yönlü Sinir Ağı ve Temel Bileşen Analizli Sinir Ağı'dır. Çalışmada drenaj alanı, yıllık ortalama yağış miktarı, akarsu eğimi, rakım, akarsu yoğunluğu ve tekrarlama periyodunu kullanmışlardır. Çalışmanın, bölgedeki 33 farklı ölçüm istasyonuna uygulandığını ve yıllık maksimum debi değerlerini tahmin etmede en iyi sonucun Temel Bileşen Analizli Sinir Ağı ile elde edildiğini belirtmişlerdir (Anilan, Nacar, Kankal ve Yüksek, 2020).

Kia ve diğerleri, çalışma alanı olarak seçtikleri Malezya'nın Johor Nehri havzasında, CBS ile YSA tekniklerini beraber kullanarak taşkına meyilli olan bölgeleri tespit etmişlerdir. Çalışmada rakım, topografik eğim, akım birikimi, jeoloji, arazi kullanımı, toprak grubu ve yağış miktarı verilerini kullanmışlardır. Sonuçların tahmin edilen ve gerçek değerler arasında tatmin edici bir uyumluluk gösterdiğini ve bu nedenle yöntemin gelecekte planlama

ve taşkın olaylarına karşı korunmada yardımcı olabileceğini göstermişlerdir (Kia ve diğerleri, 2012).

Turhan, çalışma alanı olarak seçtiği Seyhan havzasında yer alan Nergizlik Barajı üzerinde yaptığı çalışmada YSA tekniği ile yağış-akış ilişkisini modellemeyi amaçlamıştır. Çalışmayı, gözlemlenmiş yağış ve debi verileri ile gerçekleştirmiştir. Çalışmayı YSA'nın farklı modelleri olan, İleri Yönlü Sinir Ağları ve Genelleştirilmiş Regresyon Sinir Ağları ile gerçekleştirmiş ve daha sonra sonuçları Çoklu Lineer Regresyon yöntemi ile karşılaştırmıştır. Ayrıca çalışmada en iyi YSA tekniğini saptamak için farklı transfer fonksiyonlarını denemiştir. Sonuç olarak YSA'nın akarsu havzalarında yağış-akış ilişkisinin saptanmasında başarılı bir şekilde model üretebileceğini belirtmiştir (Turhan, 2021).

Mitra ve Nigam, YSA tekniğini kullanarak Hindistan'da yer alan Narmada Nehri için bir akış tahmin modeli oluşturmayı hedeflemiştirler. Veri normalizasyonu sonrası verilerin, 0 ile 1 arasında ölçeklendirilmesi sonrası daha iyi sonuçlar elde edildiğini vurgulamıştırlar. Elde edilen sonuçlara göre YSA'nın, aralarında doğrusal bir ilişki bulunmayan yağış-akış modeli oluşturmada iyi bir tahmin aracı olduğunu belirtmiştirler (Mitra ve Nigam, 2021).

Adnan ve diğerleri, çalışma alanı olarak seçtikleri Pakistan'da yer alan İndus Nehri için debi tahmin modeli oluşturma üzerine çalışmışlardır. Bu çalışmada YSA ve Destek Vektör Makinesi yöntemleri ayrı ayrı uygulanarak hangi yöntemin daha iyi tahmin yaptığını test etmişlerdir. Destek Vektör Makinesi yönteminin, training (öğretme) aşamasında belirli bir planlama gerektirmemesinden dolayı ve makine öğrenme tekniğinin bir prensibi olan yapısal minimizasyon tekniğinin uygulanması sayesinde YSA'dan daha iyi sonuç verdiğini göstermişlerdir (Adnan, Yuan X., Kisi ve Yuan Y., 2017)

Reyes ve diğerleri, çalışma alanı olarak Ekvador'da yer alan Tomebamba akarsu havzasını seçmişlerdir. Çalışmanın amacı YSA tekniğini kullanarak Tomebamba Nehri için bir debi tahmin modeli oluşturmaktır. Çalışma için yağış bilgileri ve nehir üzerindeki ölçüm istasyonlarından elde ettikleri akış bilgilerini kullanmışlardır. YSA tekniklerinden Geri Yayılımlı Sinir Ağı ve çıkış ağırlığı ile gizli katman ağırlığını optimize etmeye yarayan bir hibrit model kullanmışlardır. Hibrit modelin Geri yayılımlı Sinir Ağı'na göre daha fazla hesaplama zamanı gerektirdiğini vurgulamışlardır. Sonuç olarak en iyi sonucun Geri Yayılımlı Sinir Ağı ile elde edildiğini belirtmişlerdir. Ekvador bölgelerinde yeteri kadar veri

olmamasından dolayı bu çalışmayı sürdürmenin başka makine öğrenme tekniklerinden olan Destek Vektör Makinesi ve/veya veri madenciliği teknikleriyle mümkün olabileceğini belirtmiştirler (Reyes, Cisneros ve Vanegas, 2016).

Aichouri ve diğerleri, çalışma alanı olarak Cezayir'de yer alan Seybouse havzasında çalışmışlardır. Çalışmanın amacı YSA tekniğini kullanarak yağış-akış modeli oluşturmaktır. Geliştirilen YSA modeli ile aynı veriler üzerinde çoklu lineer regresyon tekniğinden elde edilen sonuçlar karşılaştırmışlar. Elde edilen sonuçlara göre YSA modeli daha iyi sonuçlar vermiştir. YSA tekniğinin, akış tahmininde yarı kurak iklim ve Akdeniz bölgelerindeki havzalarda gelecek vadeden bir yöntem olduğunu vurgulamıştırlar (Aichouri ve diğerleri, 2015).

Mao ve diğerleri, çalışma alanı olarak Çin'in kuzeybatısında yer alan Heihe akarsu havzasını seçmişlerdir. Havzalarda güvenilir ve etkili akış modellemeler üretmenin su yönetimi için kritik derecede önemli olduğuna vurgulamıştırlar. Bu nedenle çalışmalarında, son yıllarda kullanımı yaygınlaşan makine öğrenme tekniklerinden YSA tekniğini kullanarak yağış-akış ilişkisini modellemeye yönelik çalışmışlardır. Çalışmada hidrolojide histerezis (gecikme) etkisini incelenmiştirler ve histerezis etkisini dikkate alarak ve almayarak YSA tekniğini iki farklı şekilde uygulamışlardır. Elde ettikleri sonuçlara göre histerezis etkisini dikkate almayarak uyguladıkları YSA tekniğinin, aylık ölçekli modellemeler üretmede daha uygun olduğunu ve histerezis etkisini dikkate alarak uyguladıkları YSA tekniğinin, günlük ölçekli modellemeler üretmede daha doğru sonuçlar verdiğini belirtmişlerdir. Bu çalışma ile hidrolojik modellemelerde, makine öğrenme tekniğinin kullanılmasına yeni bir fikir sağladıklarını belirtmişlerdir (Mao ve diğerleri, 2021).

Rauf ve diğerleri, çalışma alanı olarak Pakistan'da yer alan İndus Nehri'nin üst kısmını seçmişlerdir. Çalışmanın amacı debi tahminidir ve yöntem olarak YSA tekniği ve Destek Vektör Regresyon tekniğini kullanmışlardır. Çalışmada 30 yıldan oluşan debi, yağış miktarı ve sıcaklık verilerini kullanmışlardır. Hangi verilerin girdi olarak kullanılmasına korelasyon katsayısı analizi ve bir optimizasyon tekniği olan genetik algoritmalar yöntemini kullanarak belirlemişlerdir. Sonuç olarak uzun vadeli debi tahminini YSA tekniğini kullanarak yapmışlardır ve çalışma bölgesinde debi miktarının azalma trendinde olduğunu saptamışlardır (Rauf, Ghumman, Ahmad, ve Hashmi, 2018).

Okkan ve Serbes, çalışma alanı olarak Türkiye'de bulunan Çağlayan havzası seçmişlerdir. YSA tekniğinin son yıllarda çok yaygın olarak kullanıldığını ve avantajlarının yanında dezavantajlarının olduğunu belirtmişlerdir. Bu nedenle çalışmalarında YSA tekniğinin yanında Destek Vektör Makine ve Uygunluk Vektör Makine tekniğini uygulamışlardır. Çalışmada yağış miktarı, sıcaklık verilerini kullanmışlardır. Elde edilen sonuçlara göre Uygunluk Vektör Makine tekniğinin uzun vadeli tahminlerde diğer iki tekniğe göre daha iyi sonuçlar verdiğini belirtmişlerdir (Okkan ve Serbes, 2014).

Melesse ve diğerleri, çalışma alanı olarak seçtikleri Amerika Birleşik Devletleri'nde bulan Mississippi, Missouri ve Rio Grande nehirleri için askıdaki sediment yükünü tahmin etmek için YSA tekniğini kullanmışlardır. Askıdaki sediment yükünün tahmini için çalışmalarında yağış miktarı, mevcut debi, bir önceki döneme ait debi (t-1) ve bir önceki döneme ait sediment yükü verilerini kullanmışlardır. Elde ettikleri sonuçlara göre günlük tahminlerin haftalık tahminlere göre daha iyi sonuç verdiğini göstermişlerdir. Yapılan bu çalışmanın, hidrolojik verilerin mevcut olduğu sediment ölçümleri için masraflı olan ölçüm sıklığını düşürmede kullanılabileceğini belirtmişlerdir (Melesse, Ahmad, McClain, Wang ve Lim, 2011).

Aziz ve diğerleri, çalışma alanı olarak akım gözlem istasyonlarının çok olduğu ve güvenilir veriler sağladıkları için Avustralya'nın doğusunu seçmişlerdir. Yağış-akış modeli oluşturmada YSA tekniğinin kullanımı oldukça yaygınlaştığını ama Bölgesel Taşkın Frekans Analizi ile YSA tekniğinin beraber kullanıldığı çalışmaların az olduğunu vurgulamışlardır. Bu nedenle çalışmalarında Bölgesel Taşkın Frekans Analizi ile YSA tekniğini beraber kullanarak taşkın tahmin modeli oluşturmayı amaçlamışlardır. Karşılaştırma amaçlı geleneksel yöntemleri de kullanmışlardır. Sonuçlara göre YSA tekniğiyle beraber kullanılan Bölgesel Taşkın Frekans Analizi'nin daha iyi sonuçlar verdiğini belirtmişlerdir (Aziz, Rahman, Fang ve Shrestha, 2014).

Ramirez ve diğerleri, çalışma alanı olarak Brezilya Sao Paulo'yu seçmişlerdir. Çalışmanın amacı, YSA tekniğini kullanarak günlük yağış miktarının tahminine yöneliktir. Geleneksel yöntem ile karşılaştırıldığında YSA'dan elde edilen sonuçların daha üstün olduğunu belirtmişlerdir (Ramirez, Velho ve Ferreira, 2005).

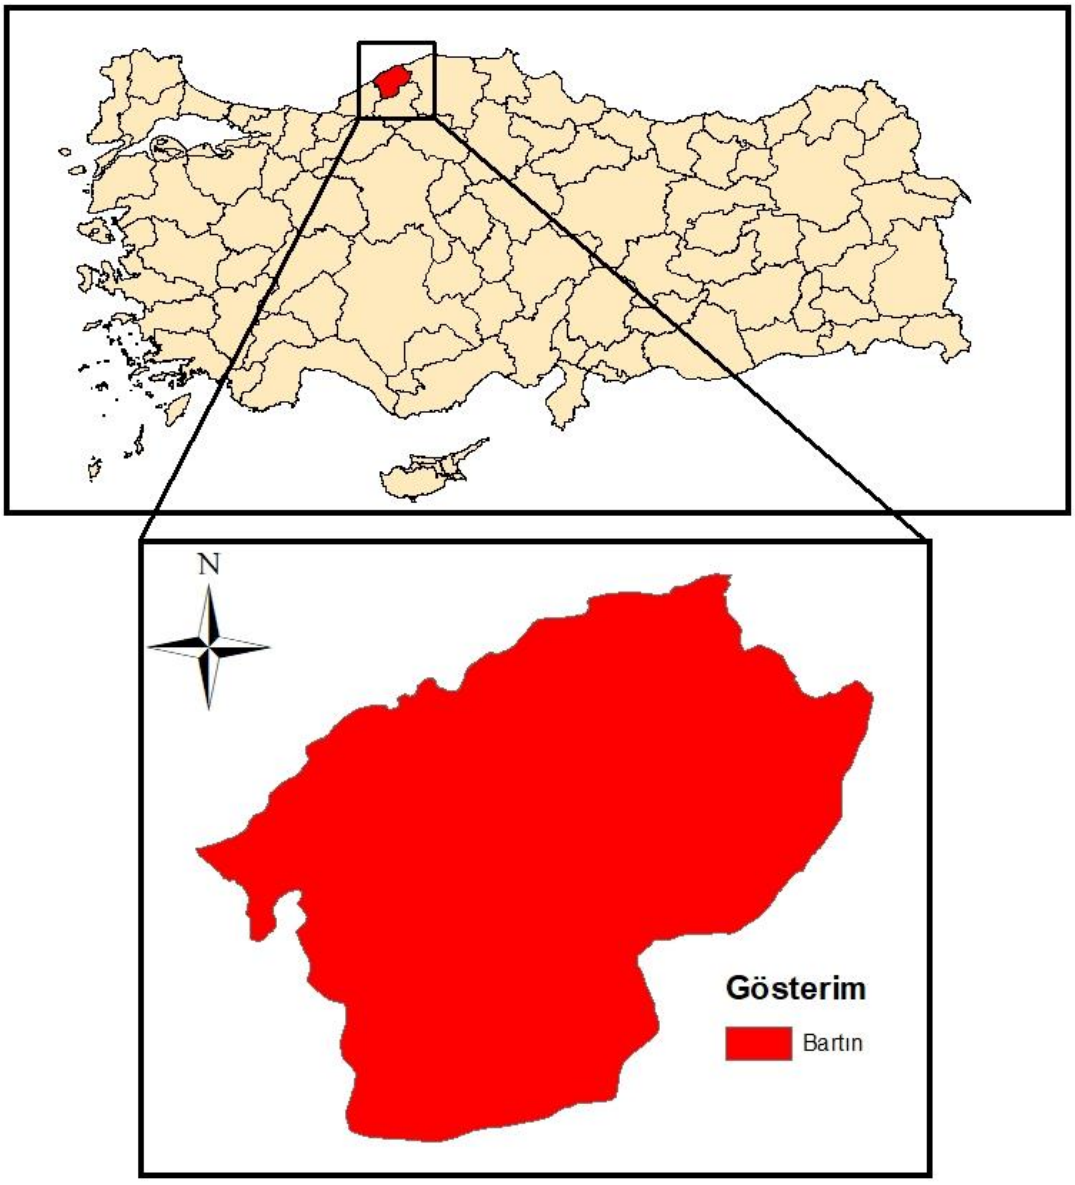
Kişi ve Uncuoğlu, çalışmalarında geri yayılımlı YSA tekniğinin üç farklı tipini, debi tahmini ve kohezyonsuz topraklarda yanal basıncın belirlenmesi konuları üzerinde karşılaştırmayı amaçlamışlardır. Bu üç YSA tekniği; Levenberg-Marquardt, Conjugate Gradient ve Resilient Back-Propagation teknikleridir. Elde ettikleri sonuçlara göre Levenberg-Marquardt yönteminin, öğretme aşamasında daha iyi ve daha hızlı sonuçlar verdiğini ve Resilient Back-Propagation yönteminin test aşamasında en doğru sonuçları verdiğini göstermişlerdir (Kişi ve Uncuoğlu, 2005).

Mehr ve diğerleri, çalışma alanı olarak Doğu Karadeniz Bölgesi'nde yer alan Çoruh Nehri'ni seçmişlerdir. Çalışmanın amacı, YSA tekniğini kullanarak Çoruh Nehri üzerindeki ardışık iki akım gözlem istasyonu için aylık debi miktarını tahmin etmeye yönelik model oluşturmaktır. Çalışmayı iki kısma ayırmışlardır. İlk kısımda nehirde en iyi senaryoyu tespit edebilmek için YSA ile 8 farklı senaryo denenmiştir. İkinci aşamada seçilen en iyi senaryo ile farklı YSA tekniklerini kullanarak aylık debi tahmin modeli oluşturmuşlardır. Elde ettikleri sonuçlara göre, kullandıkları yöntemin ardışık akım gözlem istasyonları için debi tahmininde iyi sonuçlar verdiğini belirtmişlerdir (Mehr, Kahya, Şahin ve Nazemosadat, 2015).

Işık ve diğerleri, çalışma alanı olarak Amerika, Georgia'yı seçmişlerdir. YSA tekniği ile Eğri Numarası yöntemlerini birlikte kullanarak arazi kullanımının, günlük debi değerlerindeki değişimine olan etkisini incelemişlerdir (Isik, Kalin, Schoonover, Srivastava ve Lockaby, 2013).

3. ÇALIŞMA ALANI

Bu bölümde çalışma alanı olarak seçilen Bartın ili hakkında bilgi verilmiştir. Harita 3.1.'de Bartın ilinin Türkiye'deki konumu verilmiştir.



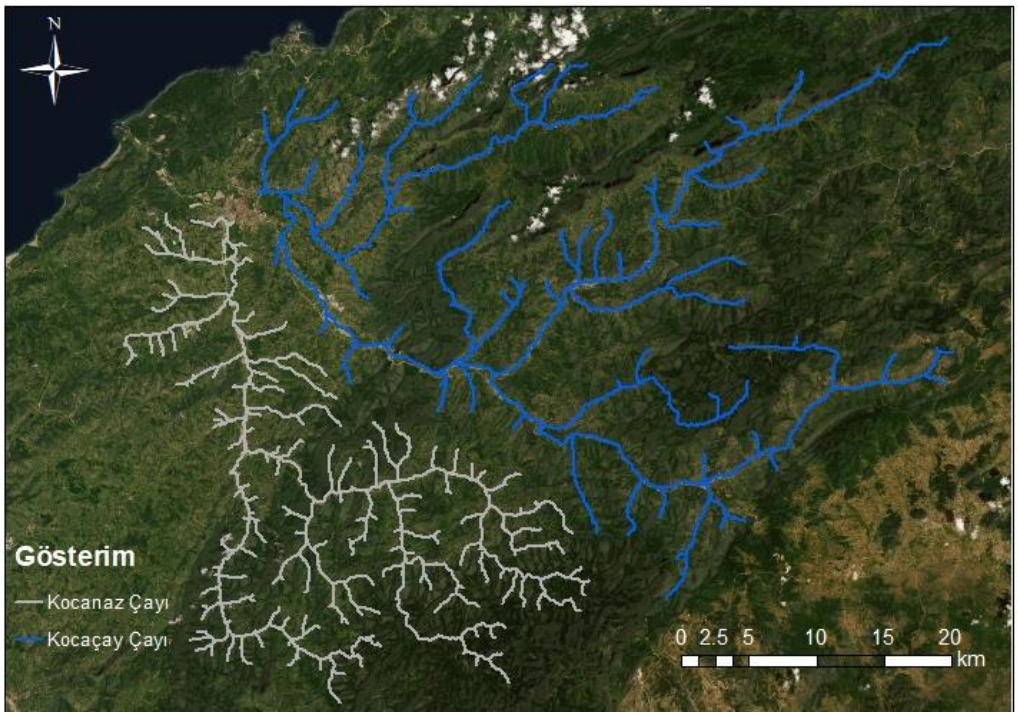
Harita 3.1. Bartın ilinin Türkiye'deki konumu

Bartın ili, Batı Karadeniz bölgesinin, 41°53′ kuzey enlemi ile 32°45′ doğu boylamı arasında yer alır. Kuzeyini 59 km'lik sahil şeridiyle Karadeniz çevrelerken, doğuda Kastamonu, güneydoğuda Karabük, batıda ise Zonguldak illeriyle komşudur. Yüzölçümü 2.330 km^2'dir. İl merkezinin rakımı 25 metredir.

Bartın; doğu, batı ve kuzeyden yüksekliği 2000 metreyi geçmeyen dağlarla çevrilidir. Dağlar, yüksek olmamakla birlikte oldukça dik, sahillere doğru sarp ve kayalıktır. En yüksek nokta Keçikıran Tepesi'dir (1619 m). İlin önemli dağları; Aladağ, Kocadağ, Karadağ, Kayaardı, Karasu ve Arıt Dağları'dır. Kent merkezini batıdan Aladağ, kuzeyden Karasu dağları ve doğudan Arıt Dağları kuşatmaktadır.

Bartın'ın en önemli akarsuyu Bartın Irmağı'dır. Bartın Irmağı'nın iki ana kolunu oluşturan Kocaçay ve Kocanaz Çayı, Bartın merkezinde birleşip 14 km yol kat ederek Karadeniz'e ulaşır (Harita 3.2.).

Kocanaz Çayı güneyden doğup Kozcağız'dan kuzeye doğru akarken, 107 km uzunluğundaki Kocaçay Kastamonu'dan gelip Ulus'tan geçen Göksu ve Eldeş Çayları (Ulus Çayı) ile bunlara katılan derelerden oluşur. Arıt ve Mevren derelerinden oluşan Kozlu Çayı ile birleşen Kışla Deresi, Akpınar ve Karaçay dereleri Kocaçay'ı besleyen akarsulardır. Diğer önemli akarsuları; Kapısuyu ve Tekkeönü dereleri ile Ulus-Uluyayla'yı sulayan Ovaçayı ve İnönü dereleridir (Bartın Valiliği, 2022).



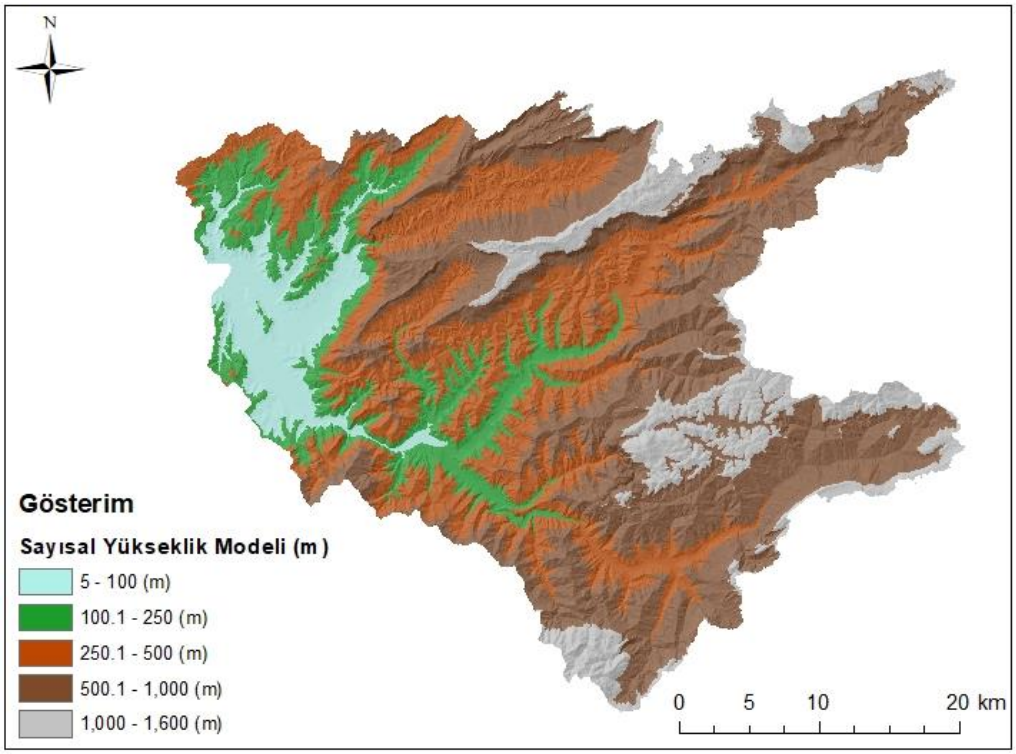
Harita 3.2. Bartın Irmağı'nı oluşturan Kocaçay ve Kocanaz Çayları

Bu tez kapsamında çalışma alanı olarak Bartın Irmağı'nı oluşturan iki koldan biri olan Kocaçay Çay'ı seçilmiştir. Seçilen Kocaçay Çayı'nın yağış alanı Harita 3.3.'te verilmiştir. Yağış alanı CBS teknikleri ile 1375 km^2 olarak hesaplanmıştır.

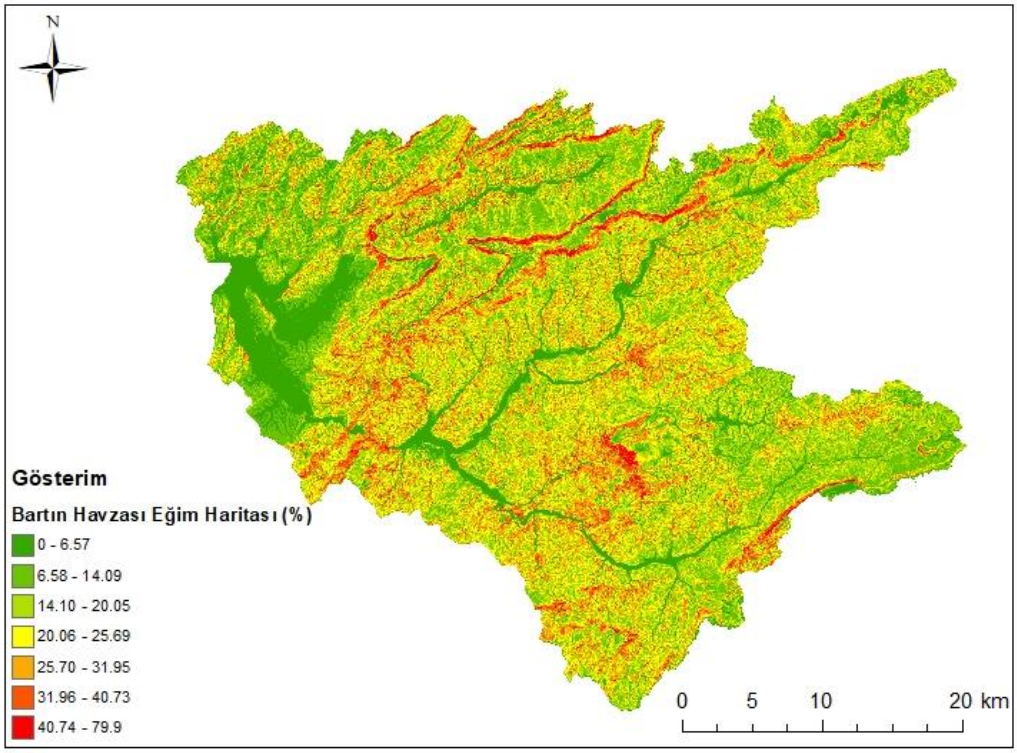


Harita 3.3. Kocaçay Çayı yağış alanı sınırları

Çalışma alanının Sayısal Yükseklik Model haritası Harita 3.4. ile verilmiştir. Bu modele göre arazi yüksekliğinin 5 metre ile 1600 metre arasında olduğu görülmektedir. Çalışma alanının eğim haritası Harita 3.5. ile verilmiştir.



Harita 3.4. Bartın Havzası Sayısal Yükseklik Modeli



Harita 3.5. Bartın Havzası eğim haritası

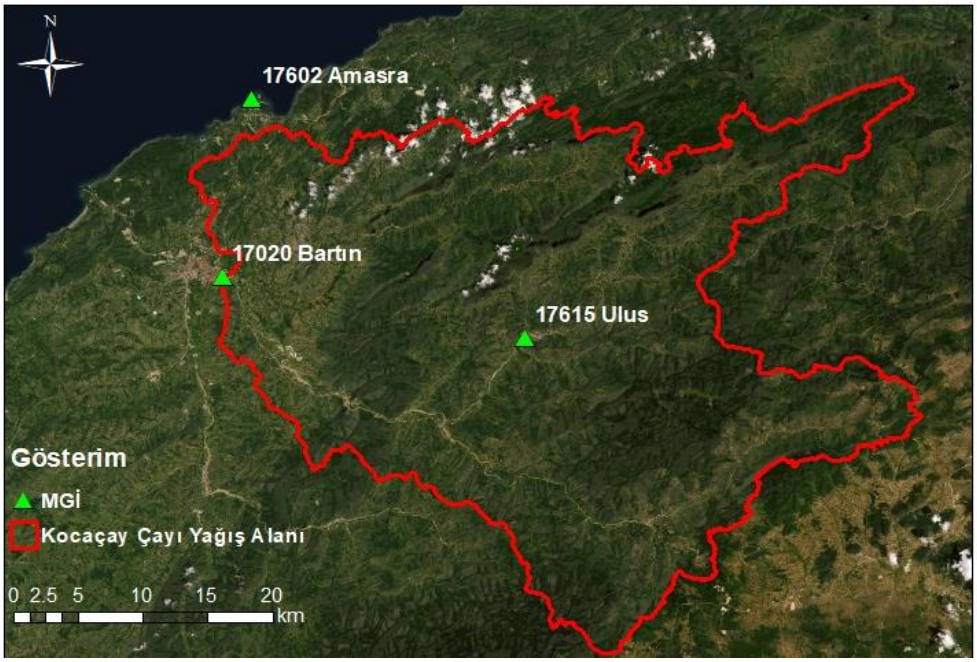
Çizelge 3.1.'de Bartın ilinde yer alan meteoroloji gözlem istasyonları yer almaktadır. Sensörler bölümünde yer alan kısaltmaların açıklaması şu şekildedir:

- R: Rüzgar
- S: Sıcaklık
- N: Nem
- Y: Yağış
- B: Basınç
- KY: Kar Yüksekliği

Çizelge 3.1.'de yer alan istasyonlar arasında, 17020 Bartın, 17615 Ulus ve 17602 Amasra istasyonları bu çalışmada uzun dönem veri kaydı bulundurmalarından dolayı kullanılmıştır. Ayrıca seçilen istasyonların konum Harita 3.6. ile verilmiştir.

Çizelge 3.1. Bartın ilinde yer alan meteoroloji gözlem istasyonları (Meteoroloji Genel Müdürlüğü, 2022)

No	İstasyon Adı	İstasyon No	İlçesi	Sensörler
1	Bartın	17020	Merkez	R,B,TS,Y,
2	Kurucaşile	18245	Kurucaşile	R,N,Y,
3	Ulus	17615	Ulus	R,Y,
4	Bartın/Arıt Beldesi	17721	Merkez	R,Y,
5	Amasra	17602	Amasra	R,B,Y,
6	Bartın Güney Mendirek Feneri	17426	Merkez	B,Y,
7	Bartın/Hasankadı Köyü	18692	Merkez	S,N,Y,KY
8	Kurucaşile/İlyasgeçidi	19207	Kurucaşile	Y,
9	Bartın/Kozcağız Beldesi	19007	Merkez	S,Y,
10	Ulus/Ceyüpler Köyü	19008	Ulus	S,N,Y,KY
11	Ulus/Çubukeli Köyü	19009	Ulus	S,N,Y,KY
12	Amasra Şamandıra	17395	Amasra	



Harita 3.6. Çalışmada kullanılan meteoroloji gözlem istasyonları

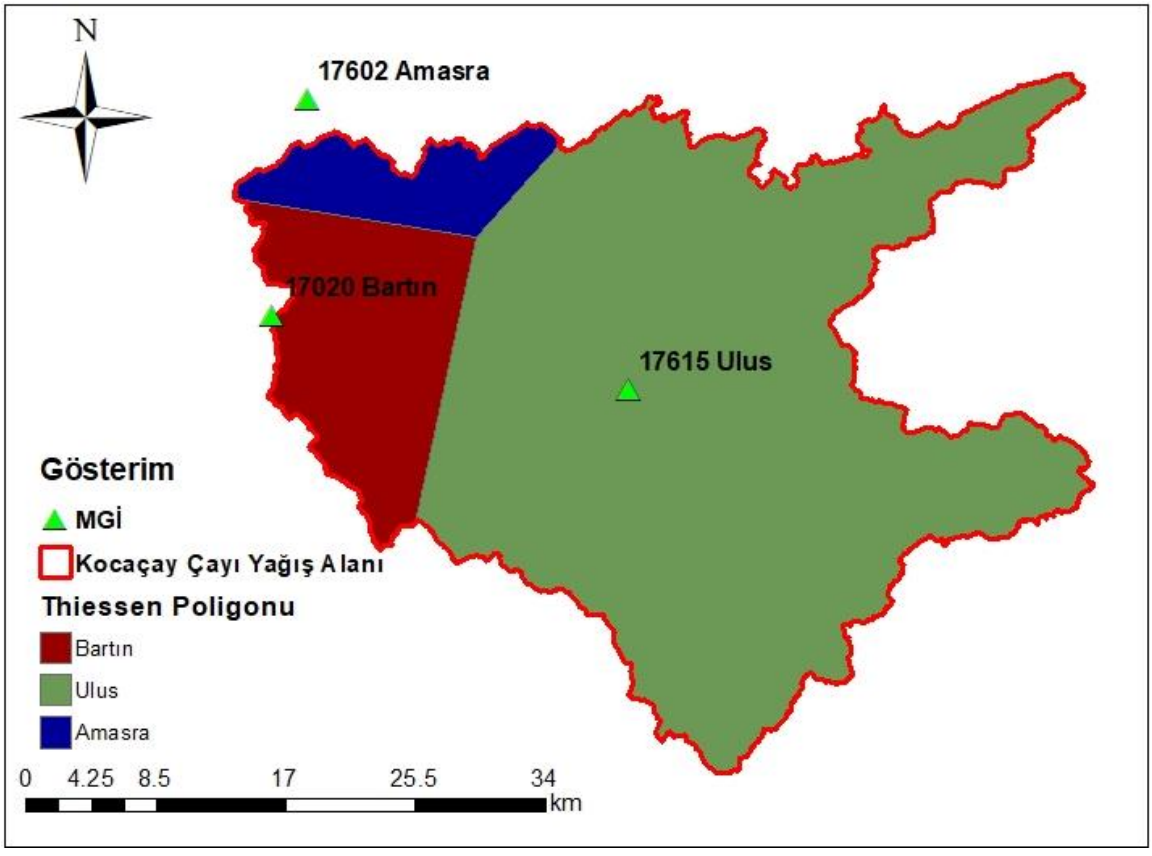
Çizelge 3.2. ile Bartın iline 1961-2020 yıllarına ait ortalama sıcaklık, ortalama en yüksek sıcaklık, ortalama en düşük sıcaklık ortalama güneşlenme süresi, ortalama yağışlı gün sayısı, aylık toplam yağış miktarı ortalaması, en yüksek sıcaklık ve en düşük sıcaklık değerleri verilmiştir. Bu istatistiklere ek olarak günlük en çok yağış miktarı 161,1 mm, günlük en hızlı rüzgar hızı 41,7 m/s ve en yüksek kar kalınlığı 109 cm olarak ölçülmüştür.

Çizelge 3.2. Bartın iline ait meteorolojik istatistikler (Meteoroloji Genel Müdürlüğü, 2020)

Bartın	1	2	3	4	5	6	7	8	9	10	11	12	Yıllık
Ortalama Sıcaklık (°C)	4	4.8	7.3	11.4	15.8	19.8	22	21.8	18	13.8	9.2	5.8	12.8
Ortalama En Yüksek Sıcaklık (°C)	9.2	10.6	13.4	18	22.3	26.1	28.2	28.3	25.1	20.6	15.9	11.2	19.1
Ortalama En Düşük Sıcaklık (°C)	0.4	0.7	2.5	5.9	10	13.6	15.7	15.7	12.2	8.9	4.6	2	7.7
Ortalama Güneşlenme Süresi (saat)	2.2	3.2	4.3	5.9	7.3	8.9	9.8	9.4	7.5	5.2	3.6	2.4	5.8
Ortalama Yağışlı Gün Sayısı	17.4	14.9	14.2	13	11.5	9.6	7.6	7.5	9.3	12	13.8	18.1	148.9
Aylık Toplam Yağış Miktarı Ortalaması (mm)	117.5	86.2	77.2	57.9	54.7	70.7	61.6	77.2	85.5	109.8	113.7	131.8	1043.8
En Yüksek Sıcaklık (°C)	23.2	27.2	31.6	34.1	39.1	38	42.8	41.3	40.5	37.1	29	27.7	42.8
En Düşük Sıcaklık (°C)	-15.4	-18.6	-13.1	-4.5	-1.3	5.3	8	6.7	1.5	-3.2	-5.6	-10.6	-18.6

Meteoroloji Gözlem İstasyonları'ndan elde edilen veriler noktasal ölçümleri temsil etmektedir. Bu noktasal verilerin bölgesel olarak temsil ettiği alanları tespit edebilmek için Thiessen Poligon yöntemi kullanılmıştır. Bu yöntem ile birbirine yakın istasyonlar doğru parçalarıyla birleştirilir ve bu doğru parçalarından orta dikmeler çıkılarak her bir istasyona ait temsili alanlar tespit edilir (Thiessen, 1911). Bu yöntem, alanı 500 ile 5000 km^2 olan bölgeler için iyi sonuçlar vermektedir.

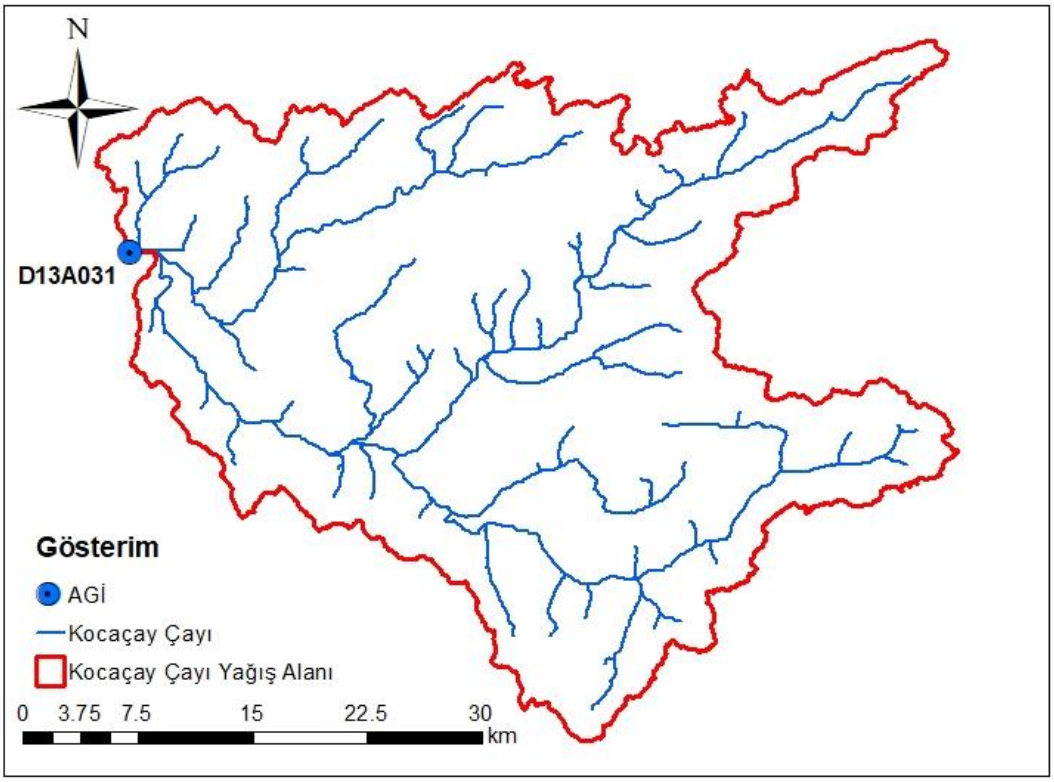
Harita 3.7. ile Kocaçay Çayı için oluşturulan Thiessen Poligonu yer almaktadır. Oluşturulan poligona göre yağış alanına, 17602 Amasra istasyonu %6, 17020 Bartın istasyonu %14, 17616 Ulus istasyonu %80 oranında girmektedir.



Harita 3.7. Kocaçay Çayı için oluşturulan Thiessen Poligonu

Akım Verileri

Çalışma kapsamında kullanılan akım verileri, Devlet Su İşleri Genel Müdürlüğü web sitesinde yayınlanan akım gözlem yıllıklarından elde edilmiştir. Harita 3.8. ile çalışmada kullanılan D13A031 numaralı Akım Gözlem İstasyonu'nun konumu verilmiştir.



Harita 3.8. D13A031 numaralı AGİ ‘nin konumu

Çizelge 3.3. ile çalışmada kullanılan akım verileri için ortalama aylık akım verileri verilmiştir.

Çizelge 3.3. Aylık ortalama akım verileri

Aylar	Ortalama Akım (m^3/s)
Ekim	14,42
Kasım	26,62
Aralık	41,88
Ocak	41,57
Şubat	43,63
Mart	52,24
Nisan	40,10
Mayıs	21,36
Haziran	12,54
Temmuz	10,75
Ağustos	7,14
Eylül	5,72

Bartın İlinde Meydana Gelen Taşkınlar

Çizelge 3.4.'te Bartın ilinde meydana gelen taşkın olayları verilmiştir.

Çizelge 3.4. Bartın ilinde meydana gelen taşkın olayları (Su Yönetimi Genel Müdürlüğü, 2019)

No	İl	İlçe	Yerleşim	Akarsu Adı	Tespit Tarihi
1	Bartın	Kurucaşile	Merkez	İlçe Merkezinden Geçen Dereler	13.08.2016
2	Bartın	Kurucaşile	Ovatekkeönü Köyü	Tekkeköy Deresi	13.08.2016
3	Bartın	Kurucaşile	Uzunköy	Karaçay Deresi	13.08.2016
4	Bartın	Amasra	Çakrazşeyhler Köyü	Büyükdere, Uçurak Deresi, Aliobası Deresi,Ova Deresi	13.08.2016
5	Bartın	Amasra	Göçkündemirci Köyü	Büyükdere, Uçurak Deresi, Yörükler Deresi, Keçicek Deresi	13.08.2016
6	Bartın	Amasra	İnpiri Köyü/Serenli Mahallesi	Çengelmeydanı Deresi ve Kurudere	13.08.2016
7	Bartın	Amasra	Makarcı Köyü	Çengelmeydanı Deresi ve Kurudere	13.08.2016
8	Bartın	Merkez	Gecen Köyü	Aygır Deresi	05.06.2014
9	Bartın	Amasra	Merkez	Bartın Çayı	20.05.1998
10	Bartın	Merkez	Şarköy/Boğaz Mah.		15.07.2009
11	Bartın	Merkez	Kozcağız	Kozcağız Çayı	03.07.2009
12	Bartın	Merkez	Merkez	Bartın Çayı	30.04.1975
					11.08.1975
					21.05.1985
					17.02.1998
					22.05.1998
					24.06.1998
					04.08.1998
13	Bartın	Ulus	Merkez	Bartın Çayı ve Yan Kolları	26.11.1989
					14.09.1993
					13.12.1994

4. METODOLOJİ

Bu bölüm, akım tahmini için mevcut çalışmada kullanılan çeşitli yöntemleri içermektedir. Bu yöntemler bölüm içerisinde incelenmiştir.

4.1. Makine Öğrenme Yöntemleri

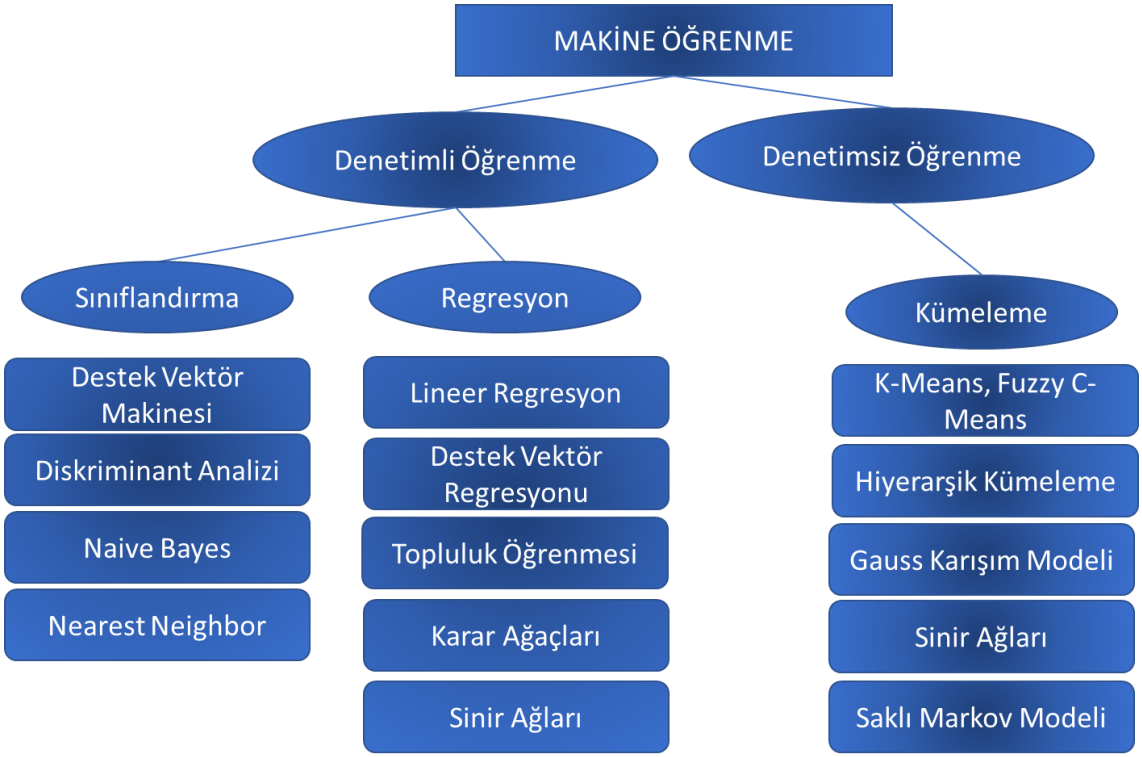
Makine öğrenmesi, insanlar tarafından kolayca anlaşılabilecek kadar basit sınıflandırma ifadeleri üretmeyi amaçlar. Makine öğrenmesi, karar verme sürecini yeterince kavrayabilmesi için insan akıl yürütmesini taklit eder. Bu işlemi yaparken, arka planı geliştirme aşamasında istatistiksel veriler kullanılabilir ancak işlemler insan müdahalesinin olmadan yapıldığı varsayılır (Michie, Spiegelhalter ve Taylor, 1994).

Makine öğrenmesi denetimli öğrenme ve denetimsiz öğrenme olmak üzere ikiye ayrılır. Denetimli öğrenme yöntemi kendi içinde sınıflandırma ve regresyon olmak üzere ikiye ayrılır. Denetimsiz öğrenme yöntemi ise alt başlık olarak kümeleme yönteminden oluşmaktadır.

Denetimli öğrenme, sisteme girdi verileri ve her bir girdi verisine karşılık gelen çıktı verilerinin girilmesiyle oluşur. Amaç girdi ve çıktı verileri arasında bir ilişki öğrenildikten sonra sonucu bilinmeyen girdiler ile yeni çıktı tahmini yapmaktır.

Denetimsiz öğrenme yönteminde denetimli öğrenme yöntemindeki gibi girdi-çıktı ilişkisi aranmaz. Bunun yerine sisteme girdiler verilir ve bu girdiler arasındaki ilişkinin bulunması beklenir.

Şekil 4.1 ile yaygın olarak kullanılan makine öğrenme yöntemleri verilmiştir. Bu çalışmada Sinir Ağları, Destek Vektör Regresyonu ve K-Means Kümeleme yöntemleri kullanılmıştır. Kullanılan yöntemler alt başlıklar halinde verilmiştir.



Şekil 4.1. Makine öğrenme yöntemleri

4.1.1. Yapay Sinir Ağları

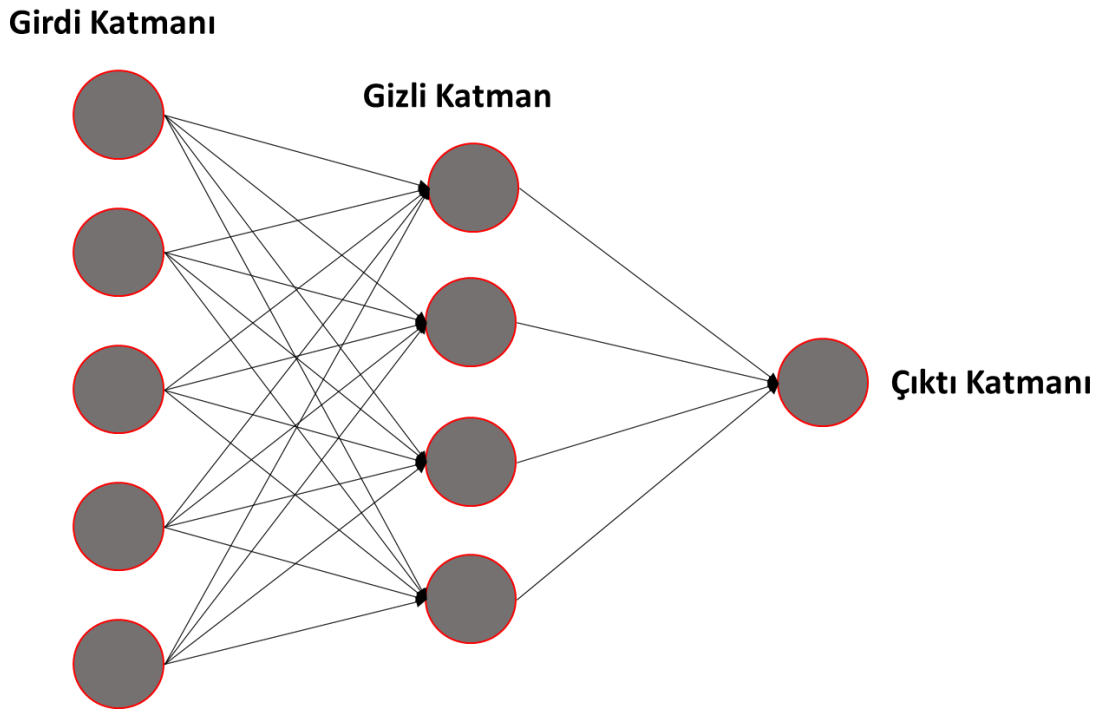
Yapay Sinir Ağları, insan beyninin biyolojik sinir ağlarına benzeyen belirli performans özelliklerine sahip, büyük ölçüde paralel dağıtılmış bir bilgi işleme sistemidir (Haykin, 1994).

YSA, makine öğrenme yöntemlerinden denetimli öğrenme sınıfına girmektedir. YSA, girdi ve çıktı setini içeren veriler arasındaki ilişkiyi öğrenerek yeni girdi seti ile yeni çıktı tahmini yapabilmektedir. Özellikle karmaşık olan ve aralarında doğrusal bir ilişki bulunmayan veriler arasındaki ilişkiyi çözebilen güçlü bir tahmin yöntemidir.

YSA, insan beyninin ya da nöro biyolojinin bir matematiksel genellemesi olarak geliştirilmiştir. YSA'nın yapısı aşağıdaki kurallara dayanmaktadır.

- Bilgi işleme, hücre nöron ya da birim olarak adlandırılan birçok tekil öğede gerçekleşir.
- Sinyaller hücreler arasındaki bağ bağlantıları yoluyla iletilir.
- Her bağın, bağlantı gücünü temsil eden bir ağırlığı vardır.

- Her hücre tipik olarak, çıkış fonksiyonunu belirlemek için ağ girişine aktivasyon fonksiyonu adı verilen doğrusal olmayan bir dönüşüm uygular (ASCE, 2000).



Şekil 4.2. Tek gizli katmana sahip bir Yapay Sinir Ağı modeli

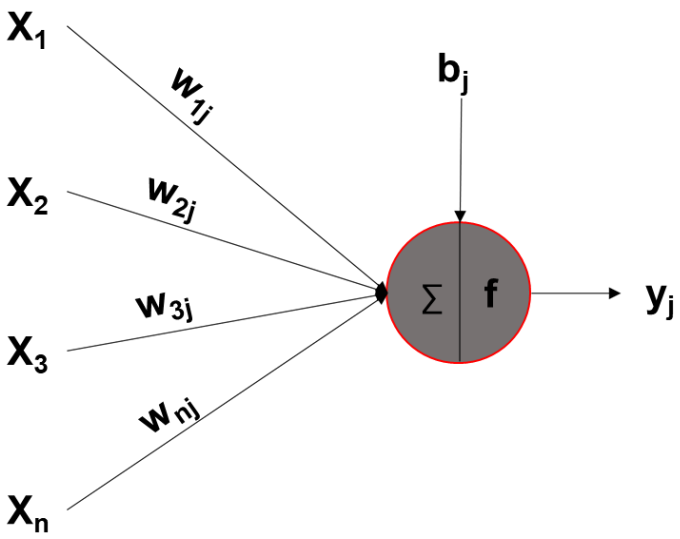
Yapay Sinir Ağları genellikle nöron tipi, bağlantı yapısı ve öğrenim algoritmalarına göre tanımlanır.

Bağlantı yapısı kendi içinde kullanılan katman sayısı, girdi ve çıktı sayılarına göre ayrılmaktadır.

İleri Yönlü Yapay Sinir Ağları Bu tip sinir ağlarında çıktı katmanından girdi katmanına doğru geriye doğru bir bağlantı bulunmamaktadır. Sistem çalıştığında ise nöron önceden hesapladığı çıktı sonucunu hatırlamamaktadır.

Geri Beslemeli Yapay Sinir Ağları Bu tip sinir ağlarında ise çıktı katmanı ile girdi katmanı arasında geriye doğru bir bağlantı vardır. Sistem çalıştığında nöron, önceden hesapladığı sonuçları hafızasında tutar. Hesaplamalarda önceden hesaplanan sonuç ile mevcut durumda elde ettiği sonuç, gelecek durumda hesaplanan çıktıyı belirler.

Öğrenim algoritması ile yapay sinir ağı sistemi eğitilir. Farklı disiplinler arasında problemleri çözmek için çok sayıda araştırma yapılmış ve çok sayıda öğrenim algoritması geliştirilmiştir. Bu tez kapsamında Bayesian Düzenlenmiş Geri Yayılımlı öğrenim algoritması kullanılmıştır.



Şekil 4.3. Bir sinir ağı hücresinin şematik gösterimi

Şekil 4.3.'te şematik olarak bir sinir ağı hücresinin matematiksel olarak gösterimi verilmiştir. $X_{1...n}$ ile ifade edilen parametreler girdileri ya da önceki hücreden gelen çıktıları ifade etmektedir. $w_{1...n}$ ile ifade edilen parametreler, girdi çıktı ilişkisini tahmin etmede her iki uçtaki nöronun göreceli olarak gücünü temsil etmek için her bağlantıya atanan ağırlığı ifade etmektedir. X ile gelen değerler ağırlık ile çarpılarak nöronun içinde toplanır.

X girdi parametreleri ile w ağırlık değerlerinin çarpımlarının toplamından elde edilen değerin sıfır olması durumunda öğrenme gerçekleşmemektedir. Öğrenmenin gerçekleşebilmesi için değeri 1 olan ve Bias olarak adlandırılan b_j değeri eklenerek öğrenmenin gerçekleşmesi sağlanır.

Girdilerin ağırlıklı toplamı ve Bias toplandıktan sonra bu değer Aktivasyon Fonksiyonu adı verilen bir fonksiyona girmektedir. Aktivasyon Fonksiyonu, YSA'nın girdiler ve çıktı arasındaki doğrusal olmayan ilişkiyi bulmasını sağlamaktadır. Aktivasyon fonksiyonunun olmaması halinde girdi ve çıktı arasında doğrusal olmayan bir ilişkini bulunması durumunda

YSA'nın kötü performans göstermesine neden olmaktadır. Aşağıda yaygın olarak kullanılan bazı Aktivasyon Fonksiyon'ları verilmiştir.

Sigmoid Fonksiyon Eş. (4.1. ile Sigmoid fonksiyonunun formülü verilmiştir. Bir nöron için Aktivasyon Fonksiyonu olarak Sigmoid fonksiyon seçildiğinde çıktı sonucu 0 ile 1 arasında olmaktadır.

$$\sigma_x = \frac{1}{1 + e^{-x}} \tag{4.1}$$

Hiperbolik Tanjant Fonksiyon Eş. (4.2. ile Hiperbolik Tanjant fonksiyonunun formülü verilmiştir. Aktivasyon Fonksiyonu olarak Hiperbolik Tanjant fonksiyon seçildiğinde çıktı sonucu -1 ile 1 arasında olmaktadır.

$$\sigma_x = \frac{2}{1 + e^{-2x}} - 1 \tag{4.2}$$

Elliot Sigmoid Fonksiyon Eş.(4.3. ile Elliot Sigmoid fonksiyonunun formülü verilmiştir. Aktivasyon Fonksiyonu olarak Elliot Sigmoid fonksiyon seçildiğinde çıktı sonucu -1 ile 1 arasında olmaktadır.

$$\sigma_x = \frac{x}{1 + |\mathrm{x}|} \tag{4.3}$$

4.1.2. Destek Vektör Makinesi ve Destek Vektör Regresyonu

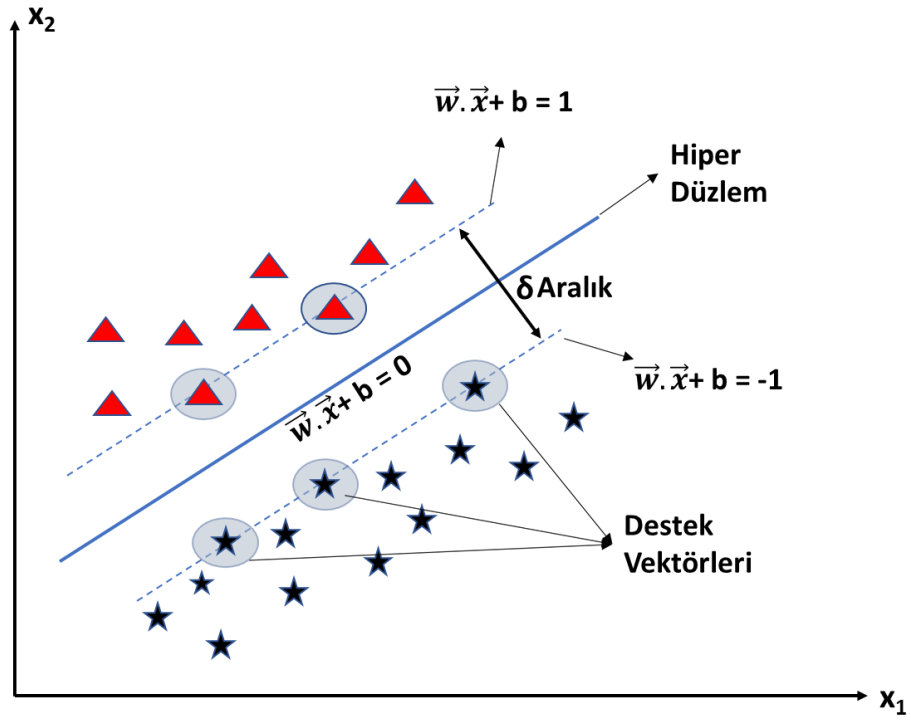
Destek Vektör Makinesi (DVM), istatistiksel öğrenme teorilerinden türetilmiştir ve iyi bir genelleme performansı elde etmek için hem makine öğrenmesinin güven aralığını hem de ampirik riskleri minimize etmek için yapısal risk minimizasyon hipotezinden türetilmiştir (Raghavendra ve Deka, 2014).

DVM, sınıflandırma problemlerinde kullanılan denetimli öğrenme yöntemlerinden biridir. Bu yöntemde düzlem üzerine yerleştirilen noktaları ayırmak amacıyla bir doğru çizilir. Bu doğrunun iki sınıfın noktaları içinde maksimum olması amaçlanır. Şekil 4.4. incelendiğinde, yıldız ve üçgen şeklinden iki sınıf vardır. Sınıflandırma yapabilmek için iki sınıfı ayıran bir doğru çizilir ve bu doğrunun ±1'i arasında kalan bölgeye 'Aralık' adı verilir. 'Aralık' ne kadar geniş ise iki veya daha fazla sınıf o kadar iyi ayrıştırılır.

Formül incelendiğinde,

$$y = \begin{cases} 0 \text{ eğer } w^T.x + b < 0, \\ 1 \text{ eğer } w^T.x + b \geq 0 \end{cases} \quad (4.4)$$

w ağırlık vektörü, x girdi vektörü, b ise sapma değeridir. Yeni bir değer için çıkan sonuç 0'dan küçük ise yıldız noktalarına daha yakın olacaktır. Çıkan sonuç 0'a eşit veya büyük ise üçgen noktalarına daha yakın olacaktır.



Şekil 4.4. Destek Vektör Makinesi şematik gösterim

Şekil 4.4. ile verilen görselde aralarında doğrusal ilişki bulunan veriler ile ilgili bir örnek verilmiştir. Aralarında doğrusal ilişki bulunmayan veriler arasında da sınıflandırma yapmak mümkündür. Bunun için veri setine uygun çekirdek fonksiyonu seçilmesi gerekmektedir. Seçilen çekirdek fonksiyonu verilerin sınıflandırılması için gerekli olan hiper düzlemin veri setine uygun olarak çizilmesinde önemli bir rol oynamaktadır. Aşağıda DVM yönteminde yaygın olarak kullanılan çekirdek fonksiyonları verilmiştir.

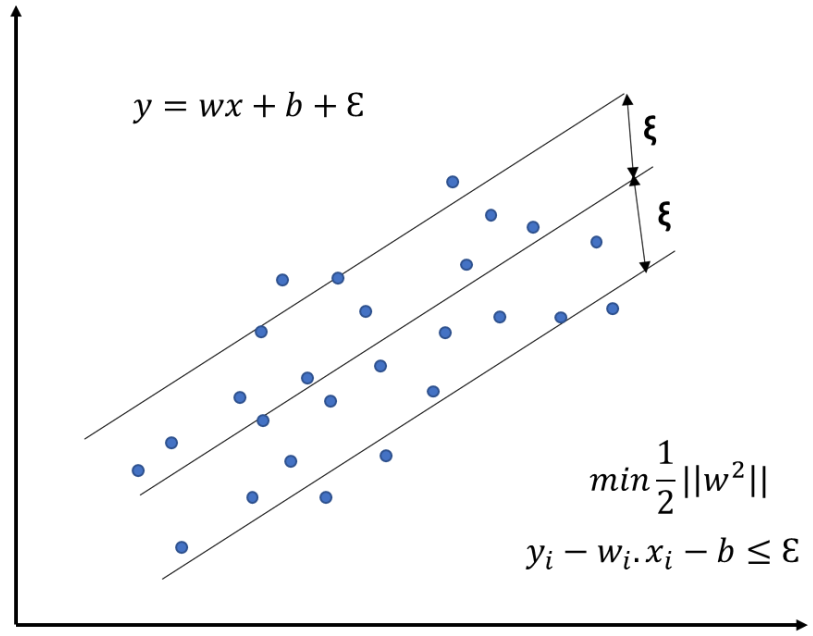
$$\mathrm{K}(\mathrm{x},\mathrm{x}') = \begin{Bmatrix} (X^T.x') & Doğrusal \\ (X^T.x'+1)^d & Polinomal \\ \exp\left(-\gamma\left||x-x'\right|\right|^2\right) & Radyal\ Temelli\ Fonksiyon \\ \tanh(\gamma x.x'+C) & Sigmoidal \end{Bmatrix} \quad (4.5)$$

Destek Vektör Makineleri yönteminde veriler arasında bir sınıflandırma yapılmaktadır. Sınıflandırma yapmanın dışında veriler arasında regresyon da yapılabilir. Bu yöntem Destek Vektör Regresyonu olarak adlandırılmıştır.

Destek Vektör Regresyonu Destek Vektör Regresyonu (DVR), Makine Öğrenme yöntemleri içinde denetimli öğrenme yöntemlerinden regresyon sınıfına girmektedir. DVR ile girdi ve çıktı setini içeren veriler arasındaki ilişki öğrenilerek yeni girdi seti ile yeni çıktı tahmini yapabilmektedir.

DVM yöntemi, iyi bir genelleme ile regresyon problemlerini çözmede uygun hale gelebilmektedir. DVM yönteminin DVR yöntemine genelleştirilmesi, Ɛ-tüpü olarak adlandırılan fonksiyon etrafında Ɛ-duyarsız bölge oluşturulması ile gerçekleştirilir. Bu tüp, model karmaşıklığı ve tahmin hatasını dengelerken fonksiyona en iyi yaklaşan tüpü bulmak için optimizasyon problemini yeniden formüle eder (Awad ve Khanna, 2015).

Şekil 4.5. ile bir boyutlu doğrusal destek vektör regresyonu şematik gösterimi ve formülü verilmiştir.



Şekil 4.5. Bir boyutlu doğrusal Destek Vektör Regresyonu

4.1.3. K-Means kümeleme yöntemi

K-means kümeleme yöntemi makine öğrenme yöntemlerinden denetimsiz öğrenme sınıfına girmektedir. Bu yöntem diğer makine öğretme yöntemlerindeki gibi girdi-çıktı ilişkisinin bulunması esasına değil, girdilerin kendi içerisindeki ilişkinin bulunması esasına dayanmaktadır.

K-means algoritması özellikle veri madenciliği ve istatistik alanlarında en yaygın kullanılan denetimsiz öğrenme tekniklerindendir. K-means algoritmasının amacı, veri noktalarını "k" ile temsil edilen küme sayısı kadar gruplamaktır. Başlangıçta, k değeri k kümelerin ortalaması olarak rastgele seçilir. Bu ortalama değerler sentroid olarak adlandırılır. K kümelerini oluşturmak için seçilen sentroidlerin en yakın veri noktaları bulunur. Daha sonra algoritma bir optimum değere yakınsayana kadar her küme için yeni merkezleri tekrar tekrar hesaplar.

K-means algoritmasının çalışma prensibi aşağıda sıralanmıştır.

1. K noktaları, önceden belirlenmiş k değerine dayalı olarak kümelerin ağırlık merkezi olarak rastgele başlatılır.

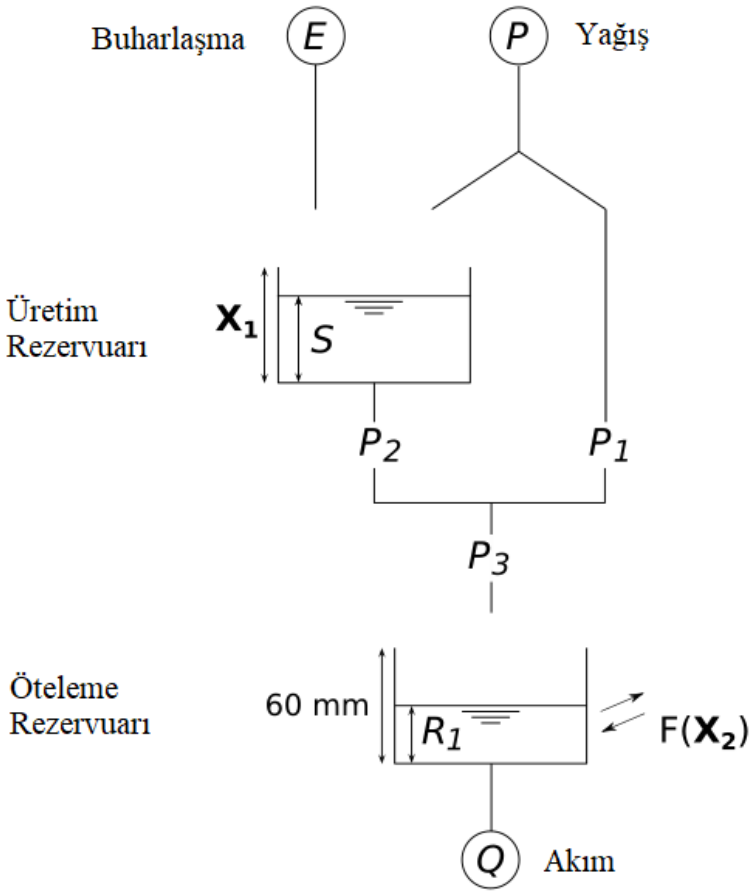
2. K kümelerini oluşturmak için veri kümesinin her veri noktası mesafeye göre en yakın merkeze atanır. Her bir veri noktası ile sentroidler arasındaki mesafenin hesaplanmasında Öklid Bağıntısı kullanılır.
3. Sentroidler, toplam küme içi varyansının azaltılabilmesi için her kümede atanan tüm veri noktalarının ortalaması alınarak yeniden hesaplanır.
4. 2. ve 3. adımlar bazı kriterle karşılanan kadar yinelenir.

Kriterler, sentroid değerlerinde herhangi bir değişiklik olmaması, veri noktaları ile merkez nokta arasındaki mesafelerin toplamı artık değişmediğinde, kümelere atanan veri noktaları önceki atamayla aynı olduğunda veya algoritmaya sabit bir yineleme süresi verilmesi durumunda maksimum yineleme sayısına ulaşılması durumlarıdır (Thewe, Ogawa ve Dung, 2019).

4.2. GR2M Modeli

GR2M modeli, Moulheli (2003) tarafından geliştirilen toprak nemi bazlı üretim fonksiyonu kullanan aylık bazda çalışan bir modeldir.

GR2M, Şekil 4.6.'da görüldüğü üzere X_1 kapasitesine sahip, mevcut seviyesi S olan üretim rezervuarı ve seviyesi 60 mm olarak belirlenmiş, mevcut seviyesi R olan yönlendirme rezervuarı olmak üzere 2 rezervuara sahip aylık olarak çalışan bir hidrolojik modeldir. Modelin girdileri aylık yağış (P) ve potansiyel evapotranspirasyondur (E). Modelden çıktı olarak aylık akım elde edilir (Makhlouf ve Michel, 1994).



Şekil 4.6. GR2M modeli çalışma şeması

Yağış nedeniyle S rezervuarındaki seviye S_1 olarak tanımlanır:

$$S_1 = \frac{S + X_1\varphi}{1 + \varphi\left(\frac{S}{X_1}\right)} \tag{4.6}$$

Burada,

$$\varphi = \tanh\left(\frac{p}{X_1}\right) \text{ 'dir.} \tag{4.7}$$

X_1: Üretim Kapasitesi (mm)

Rezervuar dolduktan sonra, fazla olan yağış (P_1) aşağıdaki gibi hesaplanır.

$$P_1 = P + S - S_1 \tag{4.8}$$

Evapotranspirasyon nedeniyle S_1 seviyesi S_2 ile yeniden hesaplanır.

$$S_2 = \frac{S_1(1-\Psi)}{1+\Psi\left(1-\frac{S_1}{X_1}\right)} \quad (4.9)$$

Burada,

$$\Psi = \tanh\left(\frac{E}{X_1}\right) \quad (4.10)$$

E: Potansiyel evapotranspirasyon

Rezervuar süzülme (P_2) nedeniyle boşalır. P_2 ve S arasındaki ilişki aşağıda gösterilmiştir.

$$P_2 = S_2 - S \quad (4.11)$$

$$S = \frac{S_2}{\left[1+\left(\frac{S_2}{X_1}\right)^3\right]^{\frac{1}{3}}} \quad (4.12)$$

Toplam yağış P_3 yönlendirme rezervuarına aşağıdaki formül ile ulaşır.

$$P_3 = P_1 + P_2 \quad (4.13)$$

Rezervuardaki R seviyesi R_1 olarak tekrar hesaplanır.

$$R_1 = R + P_3 \quad (4.14)$$

Daha sonra bir su değişim terimi hesaplanır.

$$F = (X_2 - 1).R_1 \quad (4.15)$$

X_2 parametresi boyutsuz ve pozitiftir.

Rezervuardaki seviye,

$R_2 = X_2.R_1$ olur. (4.16)

60 mm'ye sahip olan rezervuar ikinci dereceden bir fonksiyona göre boşalır.

Akım şu şekilde elde edilir.

$$Q = \frac{R_2}{R_2 + 60} \quad (4.17)$$

Model optimize edilecek iki parametreye sahiptir. Bunlar,

X_1: Üretim Kapasitesi (mm)

X_2: Değişim Parametresi (mm)'dir.

4.2.1. Thornthwaite ve Mather potansiyel buharlaşma-terleme yöntemi

Suyun sıvı halden gaz haline geçmesine buharlaşma, bitkilerin bünyelerinde bulunan suyun, su buharı şeklinde atmosfere verilmesine terleme (transpirasyon), bu iki olayın her ikisine birden buharlaşma-terleme (evapotranspirasyon) denir.

Yağış ve yeraltı sularınca sürekli olarak ve yeterince beslendiği kabul edilen zemin ve bitki örtüsünün, atmosfere bıraktığı su miktarına potansiyel evapotranspirasyon (PET) denir. Yağış ve zemin suyu, potansiyel evapotranspirasyon için gerekli suyu her zaman karşılamayabilir. Bu durumda zemin bitki örtüsü ve eğer varsa yağışın evapotranspirasyona verebileceği su miktarına gerçek evapotranspirasyon denir.

Potansiyel evapotranspirasyon aşağıdaki formül yardımı ile bulunur.

$$PET = 16 * \left(\frac{10 * t}{I}\right)^{a} * G \tag{4.18}$$

PET: Aylık Potansiyel Evapotranspirasyon (mm)
t: Aylık ortalama sıcaklık (°C)
I: Yıllık sıcaklık indisi
G: Enlem düzeltme katsayısı

$$\mathrm{a} = 6{,}7510 * 10^{-7} - 7{,}7110 * 10^{-5} + 1{,}791210 * 10^{-2} * I + 0{,}49239 \tag{4.19}$$

$$\mathrm{I} = \sum_{1}^{12} i \qquad i = \left(\frac{t}{5}\right)^{1{,}514} \tag{4.20}$$

Aylık evapotranspirasyonun hesaplanmasında kullanılan Enlem düzeltme katsayısı (G), ortalama güneşlenme süresine göre hazırlanmış bir değer olup, Thornthwaite tarafından tablo halinde yayınlanmıştır (Thornthwaite ve Mather, 1957), (Meteoroloji Genel Müdürlüğü, 2016).

Çizelge 4.1. Enlem düzeltme katsayısı (G)

Enlem	1	2	3	4	5	6	7	8	9	10	11	12
0	1,04	0,94	1,04	1,01	1,04	1,01	1,04	1,04	1,01	1,04	1,01	1,04
5	1,02	0,93	1,03	1,02	1,06	1,03	1,06	1,05	1,01	1,03	0,99	1,02
10	1,00	0,91	1,03	1,03	1,08	1,06	1,08	1,07	1,02	1,02	0,98	0,99
15	0,97	0,91	1,03	1,04	1,11	1,08	1,12	1,08	1,02	1,01	0,95	0,97
20	0,95	0,90	1,03	1,05	1,13	1,11	1,14	1,11	1,02	1,00	0,93	0,94
25	0,93	0,89	1,03	1,06	1,15	1,14	1,17	1,12	1,02	0,99	0,91	0,91
30	0,90	0,87	1,03	1,08	1,18	1,17	1,20	1,14	1,03	0,98	0,89	0,88
35	0,87	0,85	1,03	1,09	1,21	1,21	1,23	1,16	1,03	0,97	0,86	0,85
40	0,84	0,83	1,03	1,11	1,24	1,25	1,27	1,18	1,04	0,96	0,83	0,81
45	0,80	0,81	1,02	1,13	1,28	1,29	1,31	1,21	1,04	0,94	0,79	0,75
50	0,74	0,78	1,02	1,15	1,33	1,36	1,37	1,25	1,06	0,92	0,76	0,70

4.3. Performans Ölçüm Yöntemleri

Bu bölümde tez kapsamında kullanılan performans ölçüm yöntemlerine yer verilmiştir.

4.3.1. Kök ortalama kare hata (RMSE)

Kök ortalama kare hatası (RMSE) ile ölçülmüş ve model değerlerinin arasındaki uzaklığın bulunmasını sağlayan ve hatanın büyüklüğünü ölçen bir yöntemdir. RMSE, 0'dan ∞'a kadar değişebilir. Sıfıra yakın RMSE değeri modelin daha iyi sonuçlar verdiğini gösterir. RMSE değerinin sıfır olması modelin hiç hata yapmadığını gösterir. RMSE'nin matematiksel ifadesi aşağıda verilmiştir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}\left(Q_{\text{ölçülmüş}} - Q_{model}\right)^2}{n}} \tag{4.21}$$

4.3.2. Nash-Sutcliffe etkinlik katsayısı (NSE)

Nash-Sutcliffe etkinlik katsayısı (NSE), hidrolojik modellerin performansını değerlendirmede kullanılır. NSE'nin matematiksel ifadesi aşağıda verilmiştir.

$$NSE = 1 - \frac{\sum_{i=1}^{n}\left(Q_{\text{ölçülmüş}} - Q_{model}\right)^2}{\sum_{i=1}^{n}\left(Q_{\text{ölçülmüş}} - \overline{Q}_{\text{ölçülmüş}}\right)^2} \tag{4.22}$$

NSE değerinin 1'e yakın olması modelin iyi sonuçlar verdiğini gösterir (Nash & Sutcliffe, 1970).

4.3.3. Determinasyon katsayısı (r^2)

Determinasyon katsayısı (r^2), model verileri ile ölçülmüş veriler arasındaki ilişkinin gücünü incelemek için kullanılır. r^2 değerinin 1'e yakın olması model ile ölçülmüş veriler arasındaki uyumun yüksek olduğunun göstergesidir. r^2'nin matematiksel ifadesi aşağıda verilmiştir.

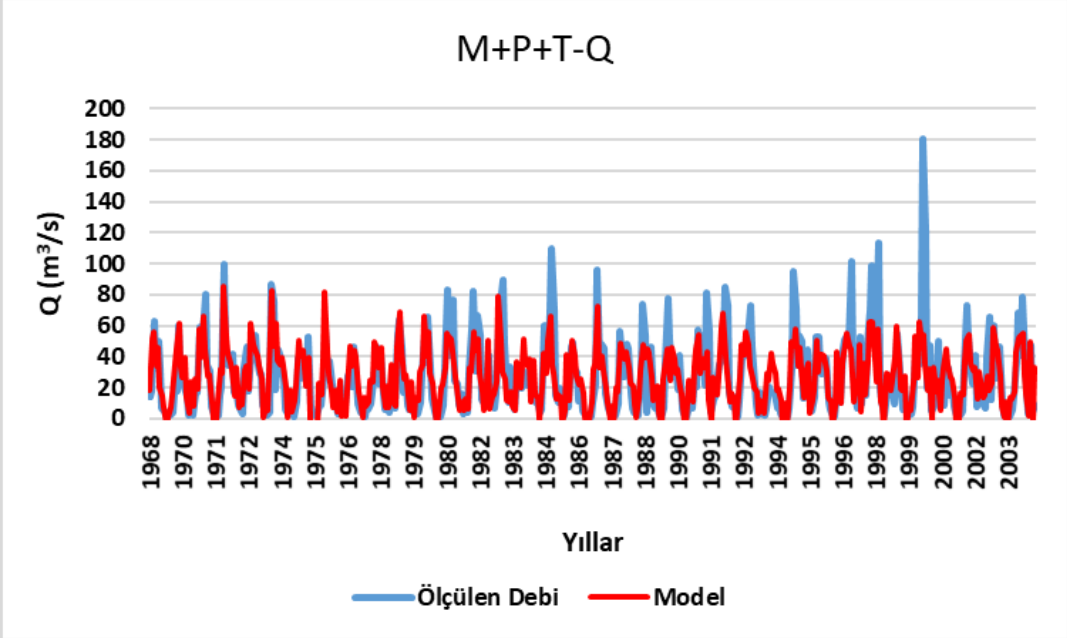
$$r^2 = \left(\frac{\sum_{i=1}^{n}[(Q_{\text{ölçülmüş}} - \bar{Q}_{\text{ölçülmüş}})x(Q_{model} - \bar{Q}_{model})]}{\sqrt{\sum_{i}^{n}[(Q_{\text{ölçülmüş}}\left(Q_{\text{ölçülmüş}} - \bar{Q}_{\text{ölçülmüş}}\right)^2 x\left(Q_{model} - \bar{Q}_{model}\right)]^2}} \right)^2 \qquad (4.23)$$

5. BULGULAR

Bu bölümde Lineer Regresyon, Yapay Sinir Ağları, Destek Vektör Regresyonu ve GR2M yöntemlerinden elde edilen bulgular yer almaktadır.

5.1. Lineer Regresyon

Veriler arasında ölçümün yapıldığı ay verisi (1, 2, 3… 12), aylık toplam yağış, aylık ortalama sıcaklık ve aylık ortalama debi verileri kullanılarak lineer regresyon gerçekleştirilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,55, RMSE değeri 16,51, R^2 değeri 0,55 olarak hesaplanmıştır. Şekil 5.1. ile ölçülen debi ile Lineer regresyondan elde edilen debi grafiği verilmiştir.



Şekil 5.1. Lineer regresyondan elde edilen ölçülen ve modellenen debi grafiği

5.2. Yapay Sinir Ağları

Bu çalışma kapsamında Yapay Sinir Ağları'nı uygulamada MATLAB programı kullanılmıştır. YSA'da girdi olarak ölçümün yapıldığı ay (1, 2, 3, … 12), aylık yağış miktarı (mm), aylık ortalama sıcaklık değeri (°C) ve tekrarlama periyodu seçilmiştir. Çıktı olarak ise aylık debi miktarı (m^3/s) girilmiştir.

Veriler aşağıda belirtilen ifade ile normalize edilerek kullanılmıştır.

$$X_{yeni} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5.1)$$

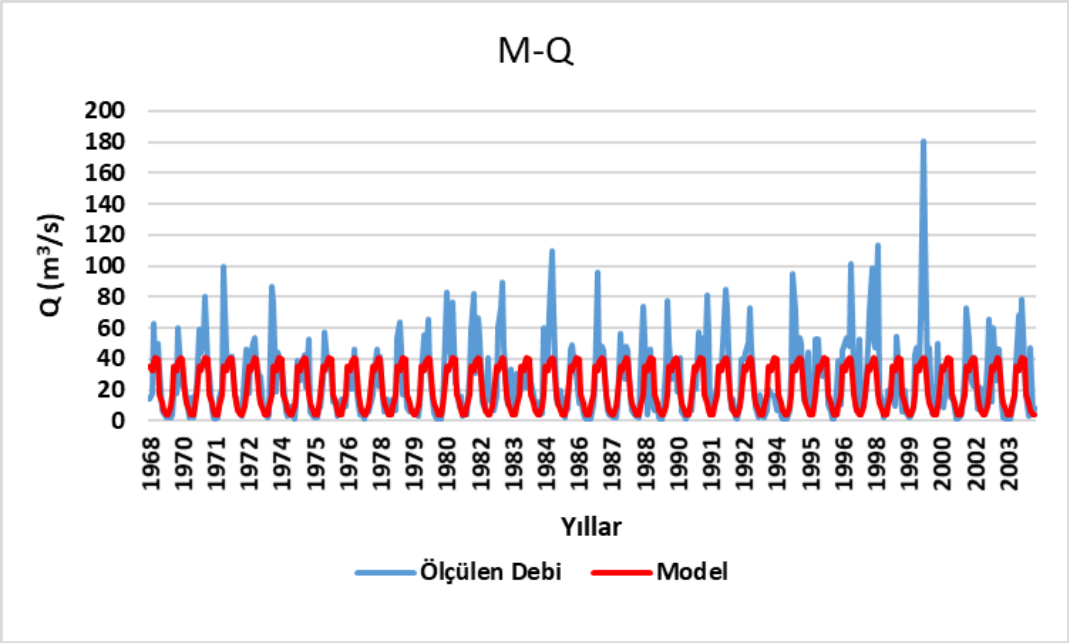
Veri setinin %60 ‘ı öğrenme, geri kalan %40’ı ise test için ayrılmıştır. Seçilen %60’lık kısma öğrenme uygulandıktan sonra kalan %40’lık veri seti ile kurulan ağ yapısının performansı ölçülmektedir. Öğrenme için seçilen %60’lık kısma, öğrenme algoritması olarak Bayesian Düzenlenmiş Geri Yayılımlı algoritma uygulanmıştır. Transfer fonksiyonu olarak Elliot Sigmoid fonksiyonu seçilmiştir.

Yapay Sinir Ağları’nda kurulan ağ sistemleri için genel kurallar bulunmamaktadır. Bu nedenle yukarıda belirtilen parametrelerin yanında ağ yapısının da deneme-yanılma yoluyla irdelenerek sistem için en uygun ağ yapısının belirlenmesi gerekmektedir. Ağ yapısı belirlenirken girdi ve çıktı katmanlarının arasında gizli katman sayısı belirlenmelidir. Gizli katman sayısının 1 veya 1’den fazla olması mümkündür. Seçilen her gizli katman için nöron sayısı da belirlenmelidir. Seçilen katman ve nöron sayısı YSA’nın tahmin performansını önemli derecede etkilemektedir.

YSA sisteminde çıktı olarak seçilen debinin tahmini için girdilerin seçimi önemli bir etkendir. Mevcut olan girdiler, ölçümün yapıldığı ay (M), yağış (P), sıcaklık (T) ve tekrarlama periyodu (R) ‘dur. Tekrarlama periyodu (R), aylık yağış verileri kullanılarak hesaplanmıştır. R, ölçülen aylık toplam yağış miktarının kaç ayda bir oluşabilecek bir değer olduğunu göstermektedir. Bu girdiler ile kurulan YSA sisteminde seçilen girdiler ile debi tahmini yapılmış ve yapılan tahmin ile ölçülen debiler arasında performans ölçümü yapılmıştır. Elde edilen grafik ve performans ölçümleri aşağıda verilmiştir.

Girdi: M-Çıktı-Q

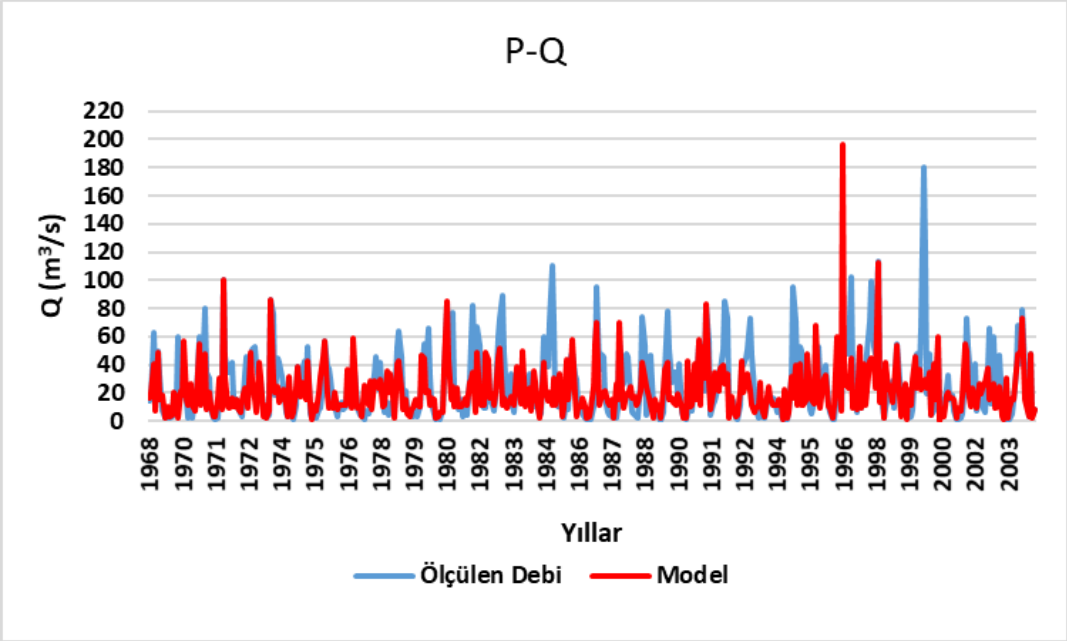
Ölçümün yapıldığı ay verisi (1,2,3 … 12) (M), verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,35, RMSE değeri 19,89 R^2 değeri 0,4 olarak hesaplanmıştır. Şekil 5.2. ile ölçülen debi ile YSA’dan elde edilen debi grafiği verilmiştir.



Şekil 5.2. YSA'da girdi olarak M kullanılmasıyla elde edilen debi grafiği

Girdi: P-Çıktı-Q

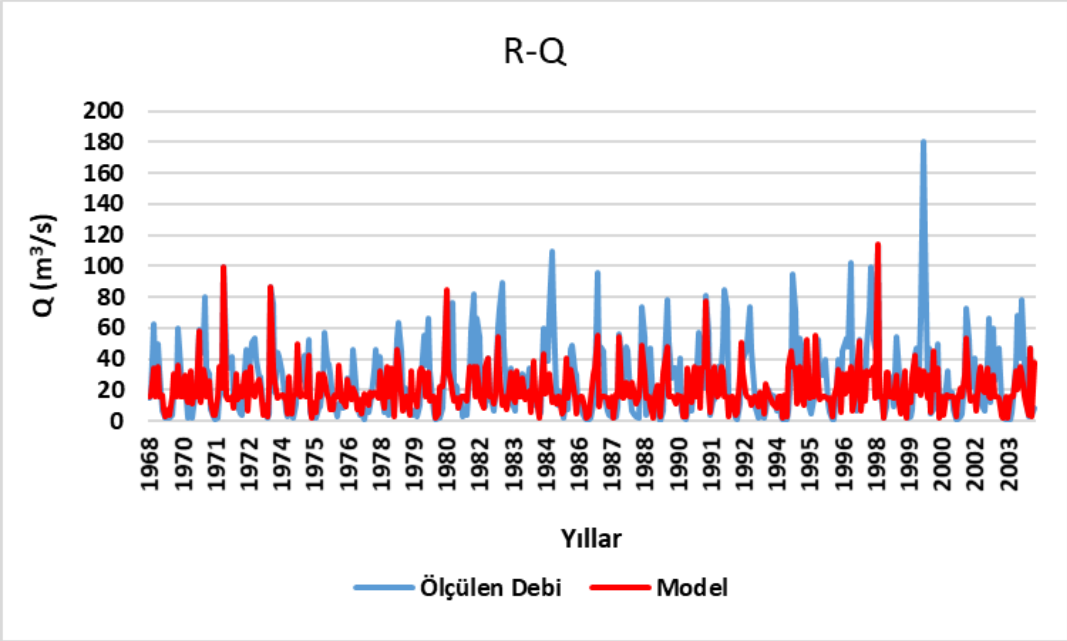
Girdi olarak aylık toplam yağış verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,22, RMSE değeri 21,76, R^2 değeri 0,30 olarak hesaplanmıştır. Şekil 5.3. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.3. YSA'da girdi olarak P kullanılmasıyla elde edilen debi grafiği

Girdi: R-Çıktı-Q

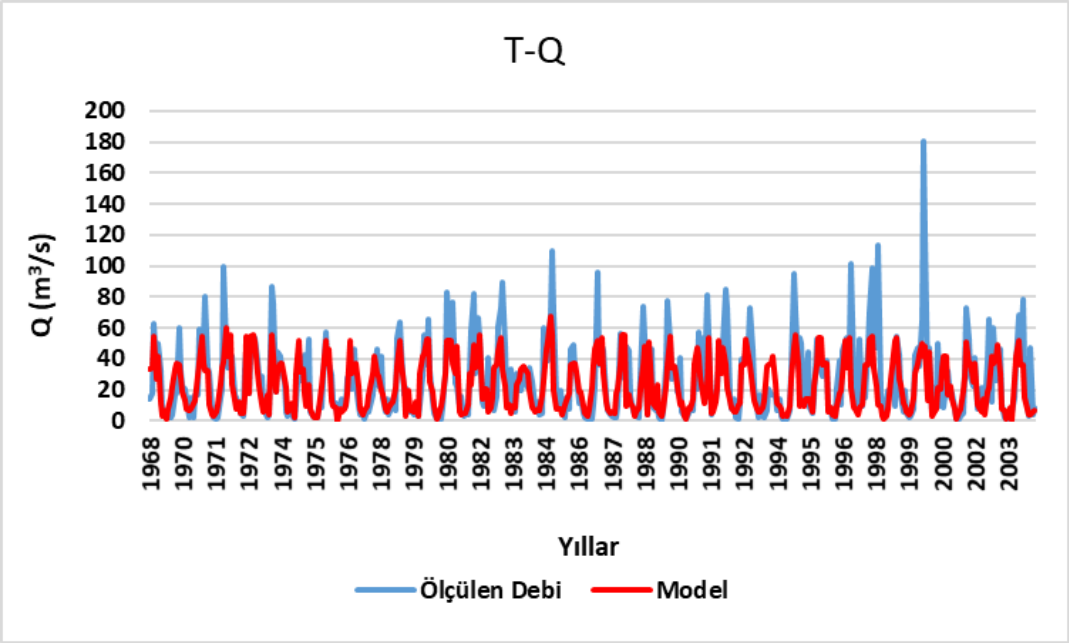
Girdi olarak aylık toplam yağış verilerinden hesaplanan tekrarlama periyodu verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,24, RMSE değeri 21,40, R^2 değeri 0,31 olarak hesaplanmıştır. Şekil 5.4. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.4. YSA'da girdi olarak R kullanılmasıyla elde edilen debi grafiği

Girdi: T-Çıktı-Q

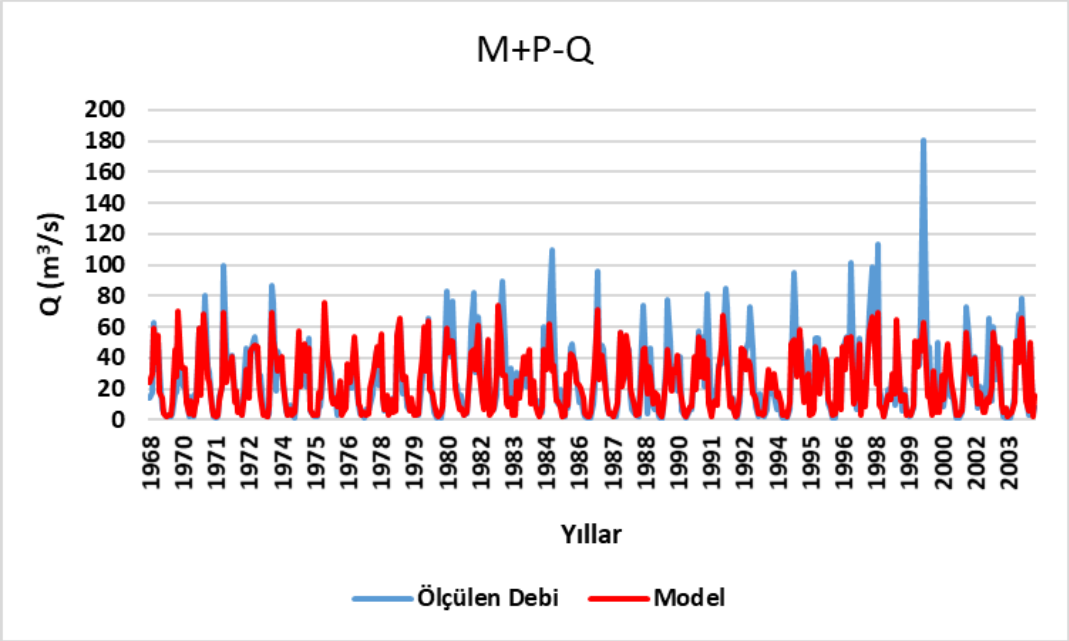
Girdi olarak aylık ortalama sıcaklık verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,41, RMSE değeri 18,83, R^2 değeri 0,44 olarak hesaplanmıştır. Şekil 5.5. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.5. YSA'da girdi olarak T kullanılmasıyla elde edilen debi grafiği

Girdi: M ve P-Çıktı-Q

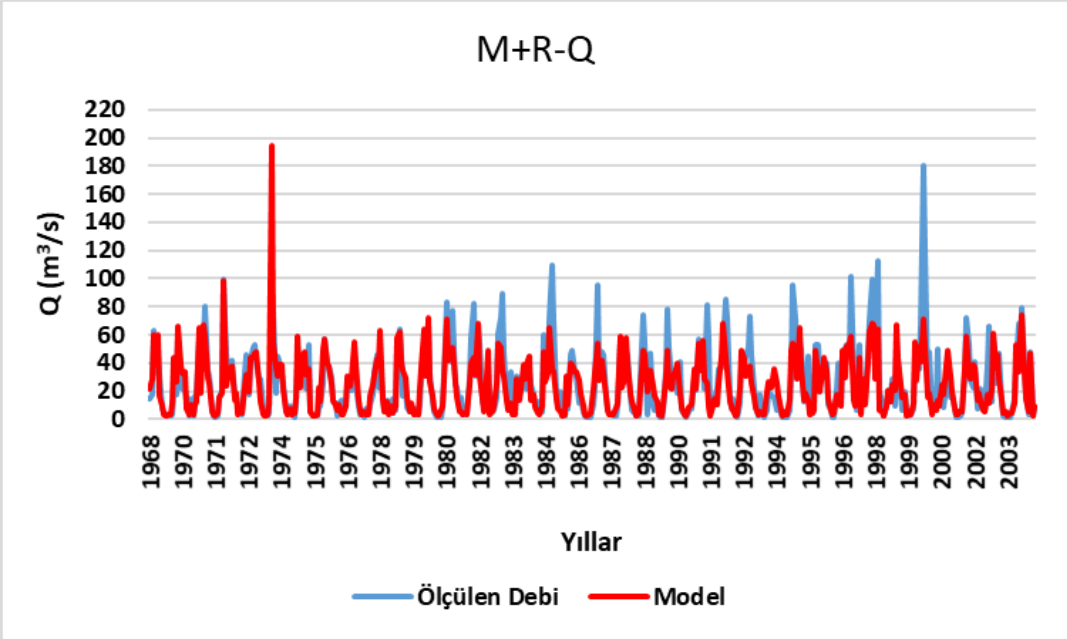
Girdi olarak ölçümün yapıldığı ay verisi (M) ve aylık toplam yağış verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,64, RMSE değeri 14,74, R^2 değeri 0,65 olarak hesaplanmıştır. Şekil 5.6. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.6. YSA'da girdi olarak M ve P kullanılmasıyla elde edilen debi grafiği

Girdi: M ve R-Çıktı-Q

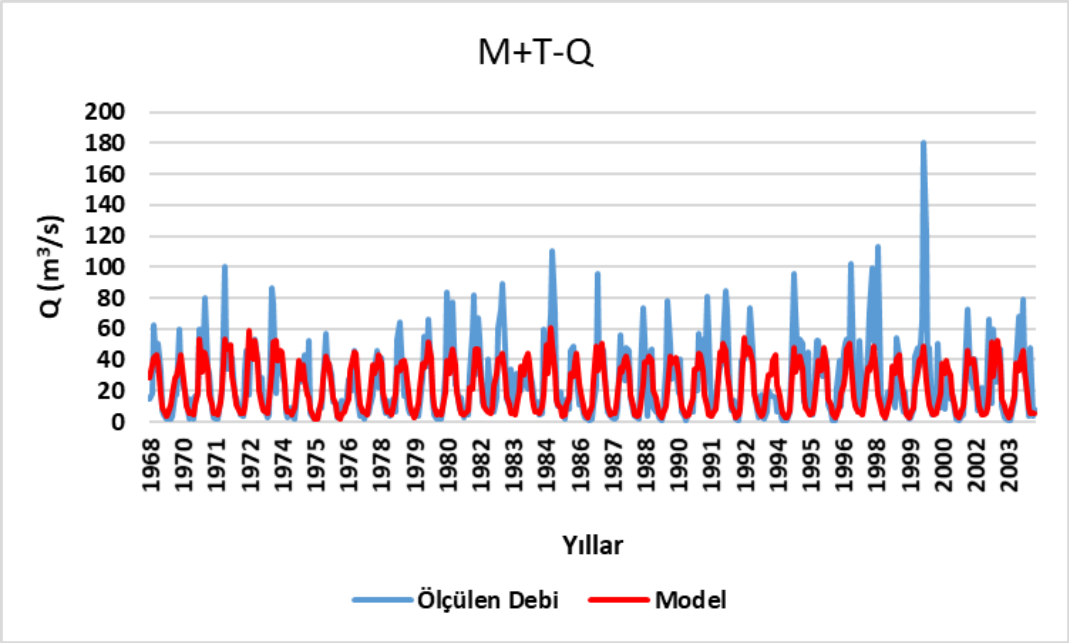
Girdi olarak ölçümün yapıldığı ay verisi (M) ve aylık toplam yağış verilerinden hesaplanan tekrarlama periyodu (R) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,61, RMSE değeri 15,30, R^2 değeri 0,62 olarak hesaplanmıştır. Şekil 5.7. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.7. YSA'da girdi olarak M ve R kullanılmasıyla elde edilen debi grafiği

Girdi: M ve T-Çıktı-Q

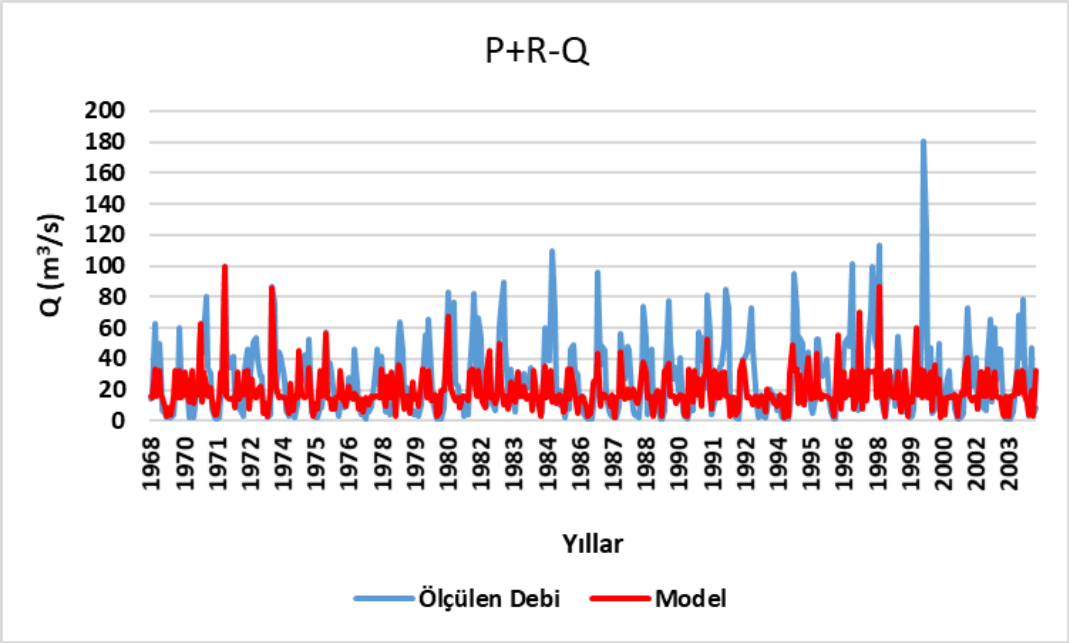
Girdi olarak ölçümün yapıldığı ay verisi (M) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,40, RMSE değeri 19,10, R^2 değeri 0,43 olarak hesaplanmıştır. Şekil 5.8. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.8. YSA'da girdi olarak M ve T kullanılmasıyla elde edilen debi grafiği

Girdi: P ve R-Çıktı-Q

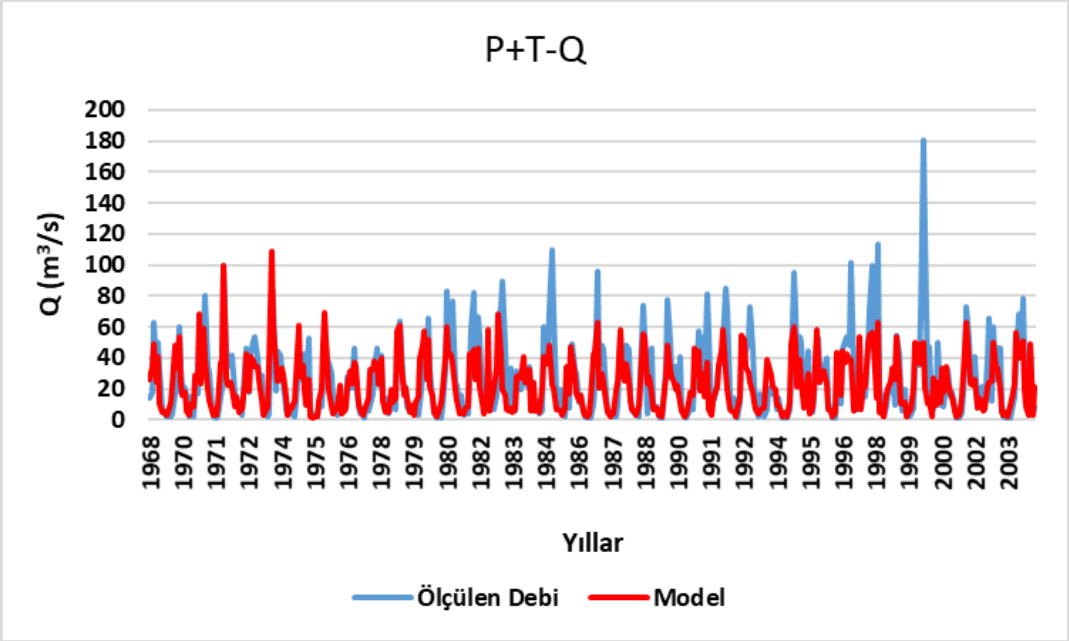
Girdi olarak aylık toplam yağış miktarı (P) ve aylık toplam yağış verilerinden hesaplanan tekrarlama periyodu (R) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,20, RMSE değeri 22,10, R^2 değeri 0,29 olarak hesaplanmıştır. Şekil 5.9. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.9. YSA'da girdi olarak P ve R kullanılmasıyla elde edilen debi grafiği

Girdi: P ve T-Çıktı-Q

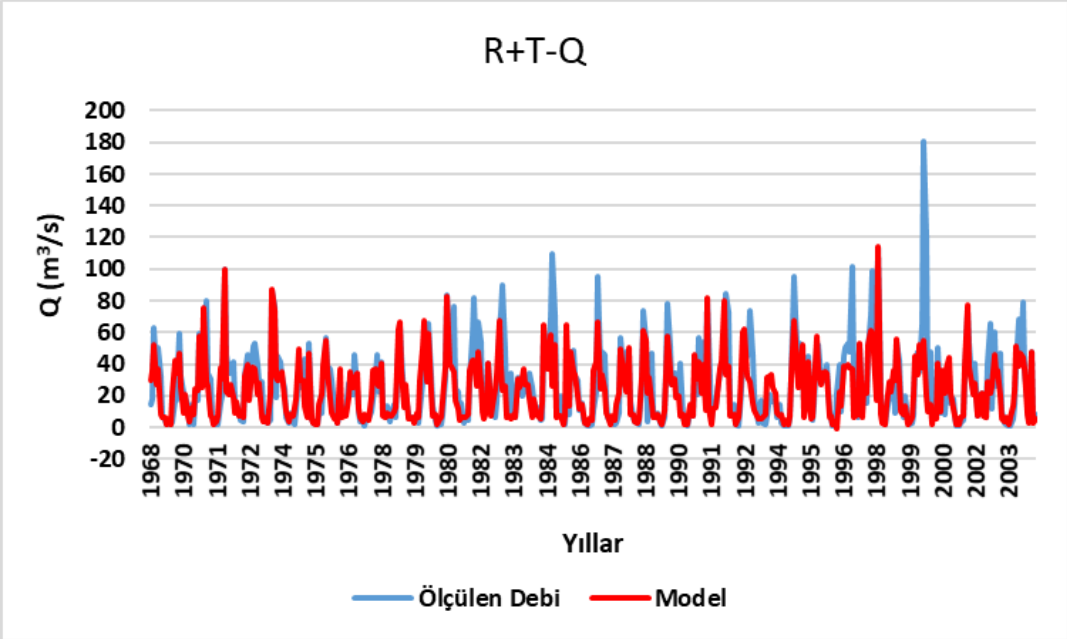
Girdi olarak aylık toplam yağış miktarı (P) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,50, RMSE değeri 17,42, R^2 değeri 0,53 olarak hesaplanmıştır. Şekil 5.10. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.10. YSA'da girdi olarak P ve T kullanılmasıyla elde edilen debi grafiği

Girdi: R ve T-Çıktı-Q

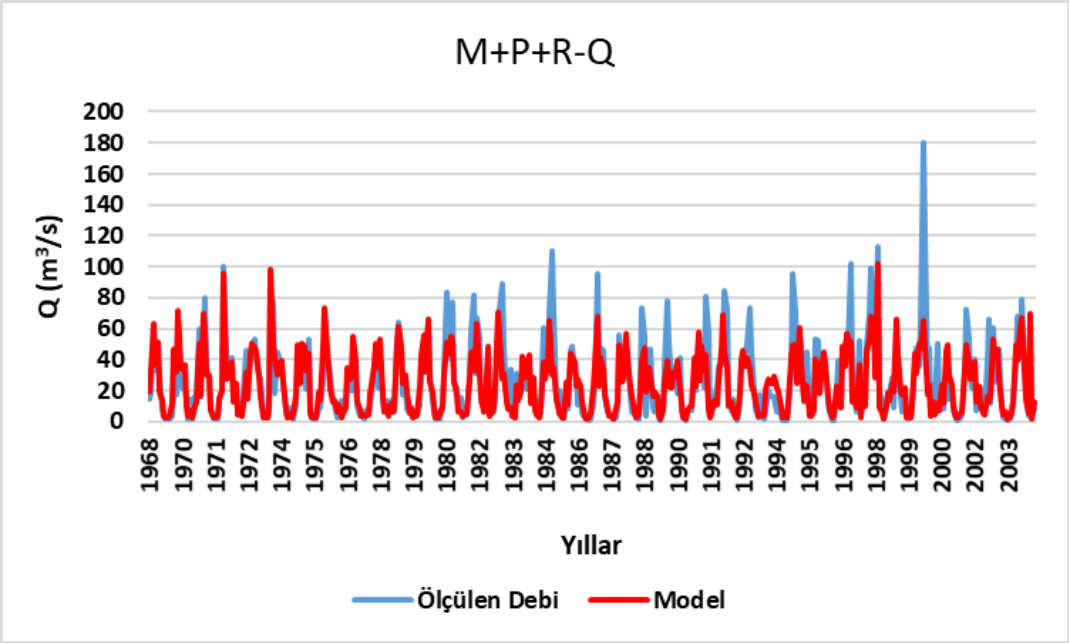
Girdi olarak aylık toplam yağış verilerinden hesaplanan tekrarlama periyodu (R) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,57, RMSE değeri 16,22, R^2 değeri 0,59 olarak hesaplanmıştır. Şekil 5.11. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.11. YSA'da girdi olarak R ve T kullanılmasıyla elde edilen debi grafiği

Girdi: M, P ve R-Çıktı-Q

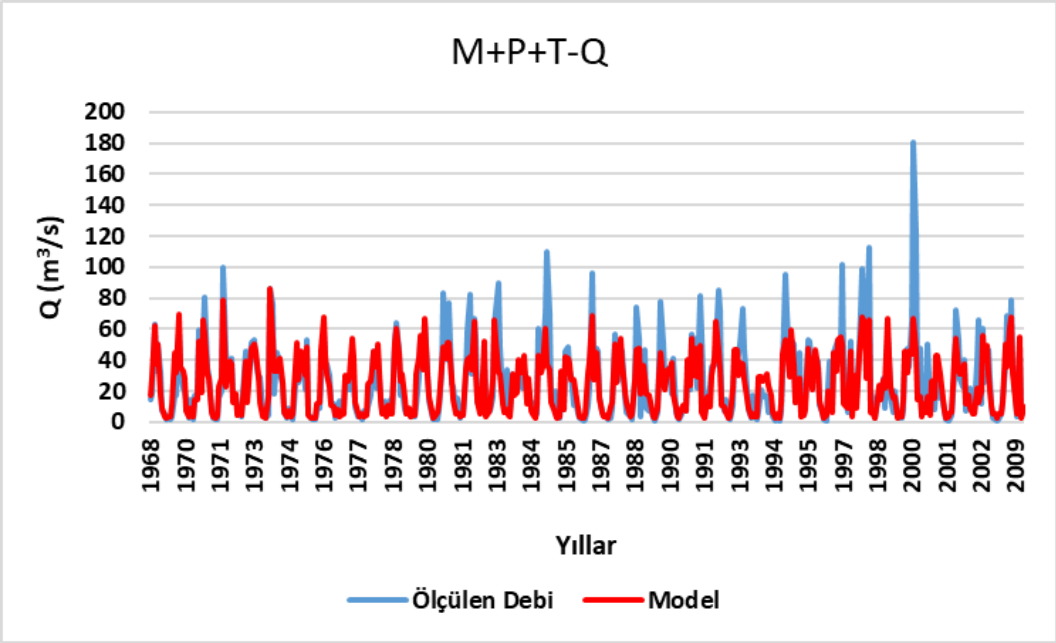
Girdi olarak ölçümün yapıldığı ay (M), aylık toplam yağış (P) ve aylık toplam yağış verilerinden hesaplanan tekrarlama periyodu (R) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,65, RMSE değeri 14,57, R^2 değeri 0,66 olarak hesaplanmıştır. Şekil 5.12. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.12. YSA'da girdi olarak M, P ve R kullanılmasıyla elde edilen debi grafiği

Girdi: M, P ve T-Çıktı-Q

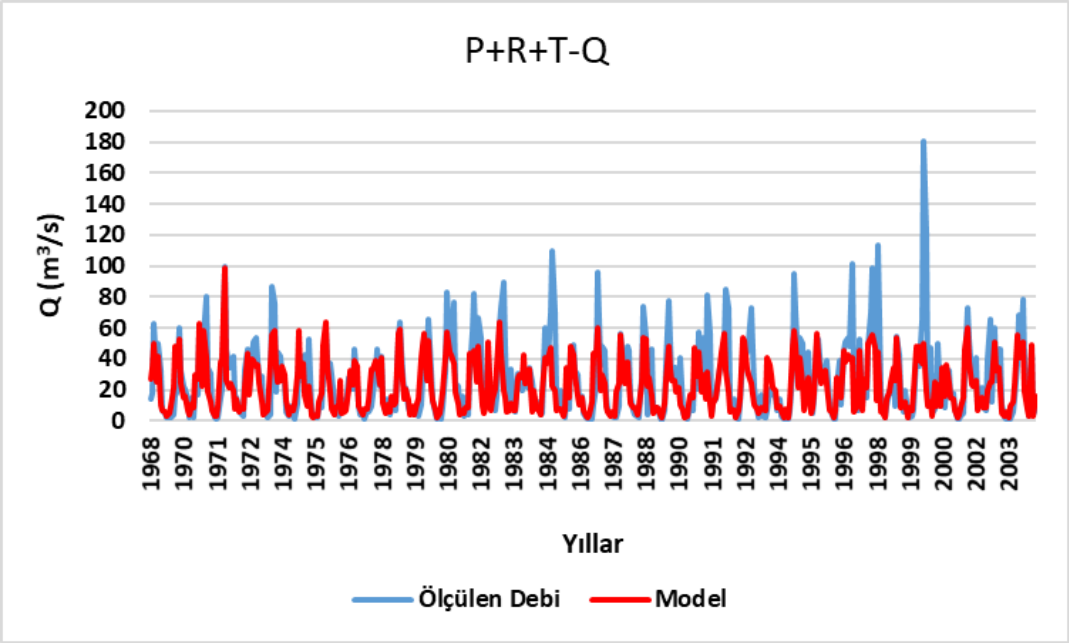
Girdi olarak ölçümün yapıldığı ay (M), aylık toplam yağış (P) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,66, RMSE değeri 14,34, R^2 değeri 0,68 olarak hesaplanmıştır. Şekil 5.13. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.13. YSA'da girdi olarak M, P ve T kullanılmasıyla elde edilen debi grafiği

Girdi: P, R ve T-Çıktı-Q

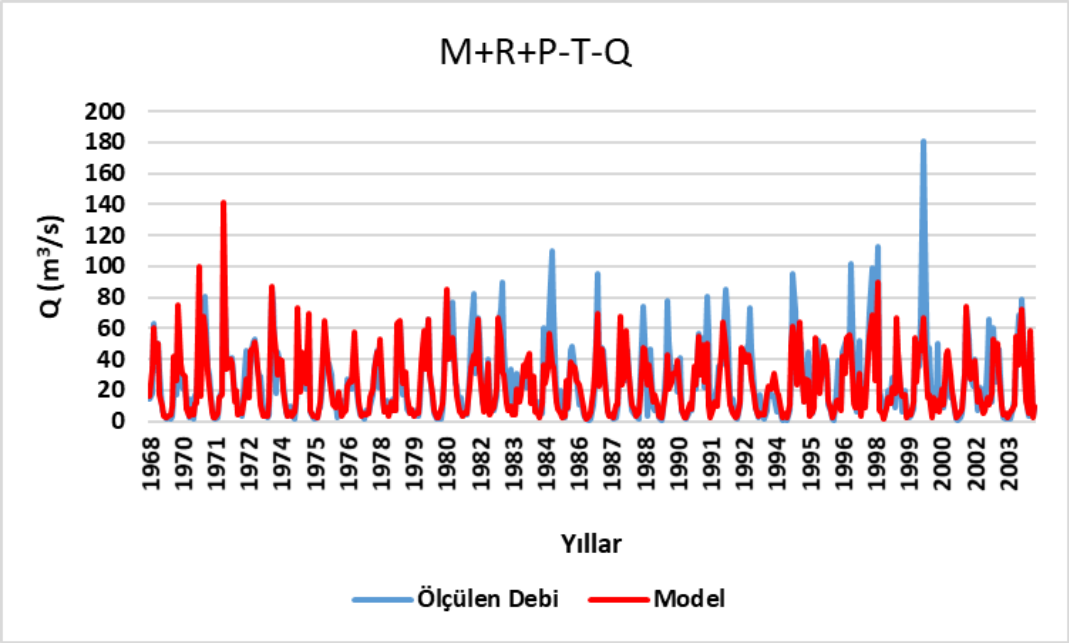
Girdi olarak aylık toplam yağış (P), aylık toplam yağış verilerinden elde edilen tekrarlama periyodu (R) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,49, RMSE değeri 17,61, R^2 değeri 0,52 olarak hesaplanmıştır. Şekil 5.14. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.



Şekil 5.14. YSA'da girdi olarak P, R, T kullanılmasıyla elde edilen debi grafiği

Girdi: M, P, R ve T-Çıktı-Q

Girdi olarak ölçümün yapıldığı ay (M), aylık toplam yağış (P), aylık toplam yağış verilerinden elde edilen tekrarlama periyodu (R) ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,65, RMSE değeri 14,45, R^2 değeri 0,66 olarak hesaplanmıştır. Şekil 5.15. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.

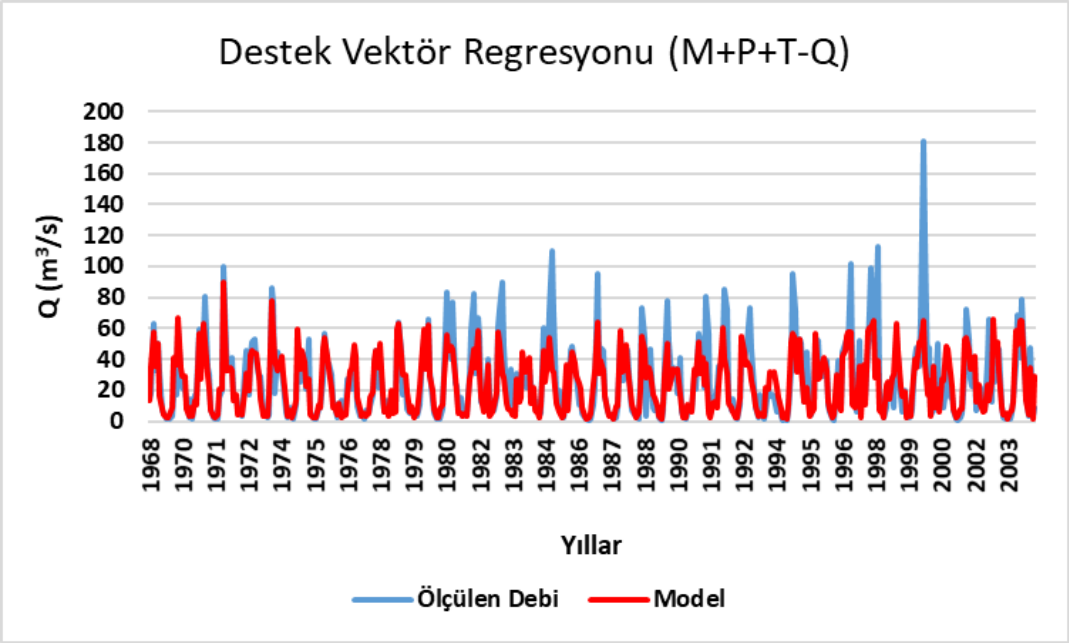


Şekil 5.15. YSA'da girdi olarak M, P, R ve T kullanılmasıyla elde edilen debi grafiği

5.3. Destek Vektör Regresyonu

Destek Vektör Regresyonu ile aylık debi tahmini için girdi olarak ölçümün yapıldığı ay (M), yağış (P) ve sıcaklık (T) verileri kullanılmıştır. Toplamda 430 aylık verinin %60'ı öğrenme için, %40'ı ise test amaçlı kullanılmıştır.

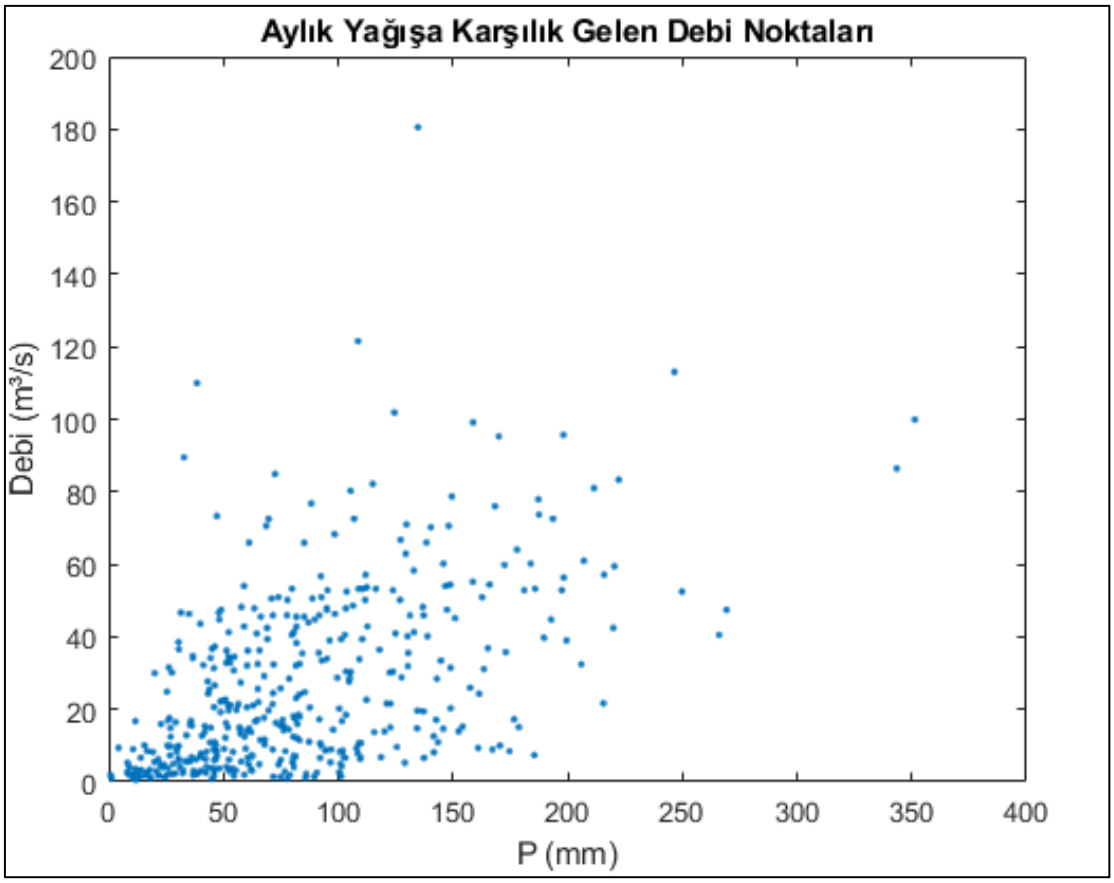
Destek Vektör Regresyonu ile elde edilen aylık debi sonuçları incelendiğinde, NSE değeri 0,62, RMSE değeri 15,10, R^2 değeri 0,63 olarak hesaplanmıştır. Şekil 5.16. ile ölçülen debi ile DVR'den elde edilen debi grafiği verilmiştir.



Şekil 5.16. Destek Vektör Regresyonu yöntemi ile elde edilen ölçülen-model debi grafiği

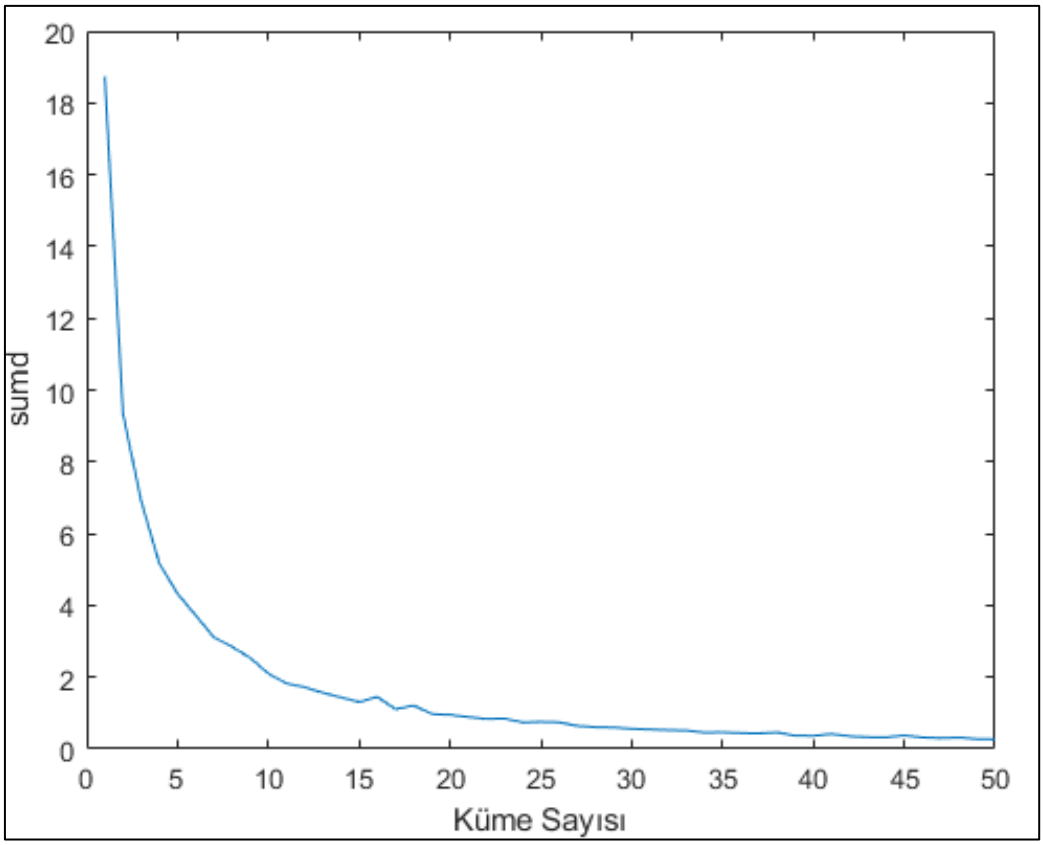
5.4. K-Means Kümeleme Yöntemi

K-Means kümeleme yöntemi kullanılarak veriler, yağış ve debi bakımından gruplandırılmıştır. Daha sonra gruplandırılmış veriler arasından seçilen kümeler 2 gruba ayrılmıştır. Seçilen 2 veri grubu için ayrı ayrı YSA ve DVR uygulanmıştır. Elde edilen sonuçlar performans bakımından incelenmiştir. Şekil 5.17. ile K-Means uygulanmadan önce aylık yağış miktarına karşılık gelen debi noktaları verilmiştir.



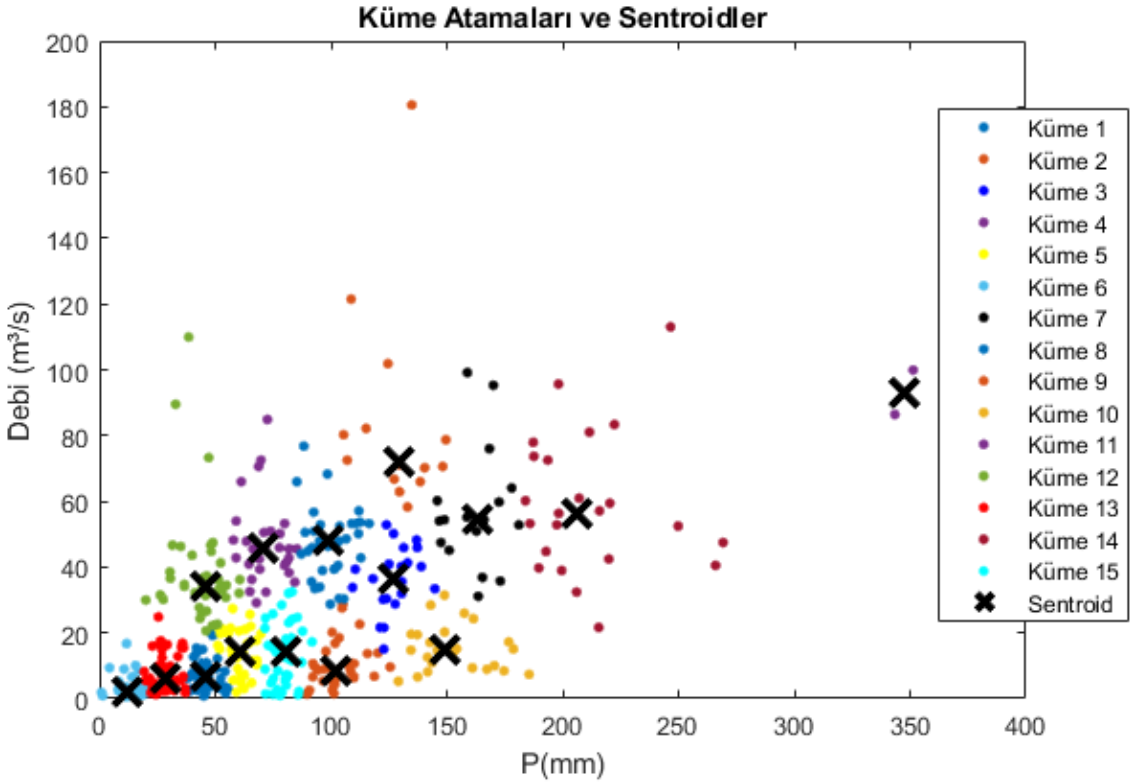
Şekil 5.17. Aylık yağışa karşılık gelen debi noktaları

K-Means kümeleme yönteminde, sentroid değerlerinde herhangi bir değişiklik olmaması, veri noktaları ile merkez nokta arasındaki mesafelerin toplamı artık değişmemesi, kümelere atanan veri noktaları önceki atamayla aynı olması durumunun tespiti için optimum küme sayısının belirlenmesi gerekmektedir. Şekil 5.18. ile küme sayısı optimizasyon grafiği verilmiştir. x ekseni küme sayısı, y ekseni ise küme sentroidlerinin merkeze olan uzaklıklarının toplamını temsil etmektedir. Grafiğin yatayda 1 değerine yakınsamaya başladığı nokta olan 15 değeri optimum küme sayısı olarak seçilmiştir.



Şekil 5.18. Küme sayısı optimizasyon grafiği

Şekil 5.19. ile debi-yağış verilerinin kümelenme grafiği ve her kümenin sentroid noktası verilmiştir. x ekseni yağış, y ekseni ise debiyi temsil etmektedir. Her bir renk 1 kümeyi temsil etmektedir ve toplamda optimizasyon ile karar verilen 15 küme oluşturulmuştur.



Şekil 5.19. Debi-yağış verilerinin kümelenme grafiği

Oluşturulan 15 küme 2 gruba ayrılarak, her 2 grup için ayrı ayrı YSA kurulması amaçlanmıştır. Çizelge 5.1. ile her kümenin Sentroid noktasına karşılık gelen yağış ve debi değerleri verilmiştir. Aylık yağış ve debi değerleri birbiri ile oranlanarak P/Q sütununda verilmiştir. Tabloda görüldüğü üzere tüm kümeler için ortalama alınarak bulunan P/Q oranı 3,29 olarak hesaplanmıştır. Bu oran kullanılarak ortalama P/Q değeri olan 3,29 üzeri değere sahip kümeler bir grupta, 3,29 altında değere sahip olan kümeler başka grupta toplanmıştır. Birinci grupta küme numarası 1, 2, 3, 5, 6, 10, 11, 13, 14, 15 olan kümeler, ikinci grupta ise küme numarası 4, 7, 8, 9, 12 olan kümeler yer almaktadır.

Çizelge 5.1. K-Means kümeleme ile oluşturulan kümelerin sentroid noktaları

Sentroidler	P (mm)	Q (m^3/s)	P/Q
Küme 1	45,95	6,44	7,13
Küme 2	101,94	8,68	11,74
Küme 3	127,03	36,46	3,48
Küme 4	71,00	45,52	1,56
Küme 5	60,69	14,51	4,18
Küme 6	11,83	2,25	5,27
Küme 7	163,55	54,40	3,01
Küme 8	98,55	47,84	2,06
Küme 9	129,72	71,76	1,81
Küme 10	149,03	14,72	10,13

Çizelge 5.1. (devam) K-Means kümeleme ile oluşturulan kümelerin sentroid noktaları

Sentroidler	P (mm)	Q (m^3/s)	P/Q
Küme 11	347,41	93,17	3,73
Küme 12	46,02	34,14	1,35
Küme 13	28,35	6,25	4,54
Küme 14	206,04	56,33	3,66
Küme 15	80,39	14,47	5,56
Ortalama	111,17	33,80	3,29

Ayrıştırılan kümeler ortalama aylık yağış ve debi miktarları bakımından incelenmiştir. Birinci grupta yer alan kümeler incelendiğinde 299 aylık veri bulunmaktadır. Çizelge 5.2. ile yağış ve debinin aylık ortalama değerleri verilmiştir. 299 aylık verinin ortalama yağış miktarı 81,45 mm ve ortalama debi değeri 19,36 m^3/s'dir.

Çizelge 5.2. Birinci grup ortalama aylık yağış ve debi değerleri

Ay	Yağış (mm)	Debi (m^3/s)
Ekim	92,71	12,12
Kasım	107,49	25,55
Aralık	133,58	36,48
Ocak	98,24	29,53
Şubat	79,37	26,64
Mart	64,06	27,89
Nisan	66,14	22,15
Mayıs	60,04	18,62
Haziran	74,68	11,03
Temmuz	62,31	9,44
Ağustos	68,83	7,14
Eylül	69,97	5,72
Ortalama	81,45	19,36

İkinci grupta yer alan kümeler incelendiğinde 131 aylık verisi bulunmaktadır. Çizelge 5.3. ile yağış ve debinin aylık ortalama değerleri verilmiştir. 131 aylık verinin ortalama yağış miktarı 96,34 mm ve ortalama debi değeri 47,07 m^3/s'dir.

Çizelge 5.3. İkinci grup ortalama aylık yağış ve debi değerleri

Ay	Yağış (mm)	Debi (m^3/s)
Ekim	149,50	39,00
Kasım	56,13	44,31
Aralık	125,37	54,16
Ocak	104,84	51,20
Şubat	87,48	45,76
Mart	72,87	56,17
Nisan	70,16	50,25

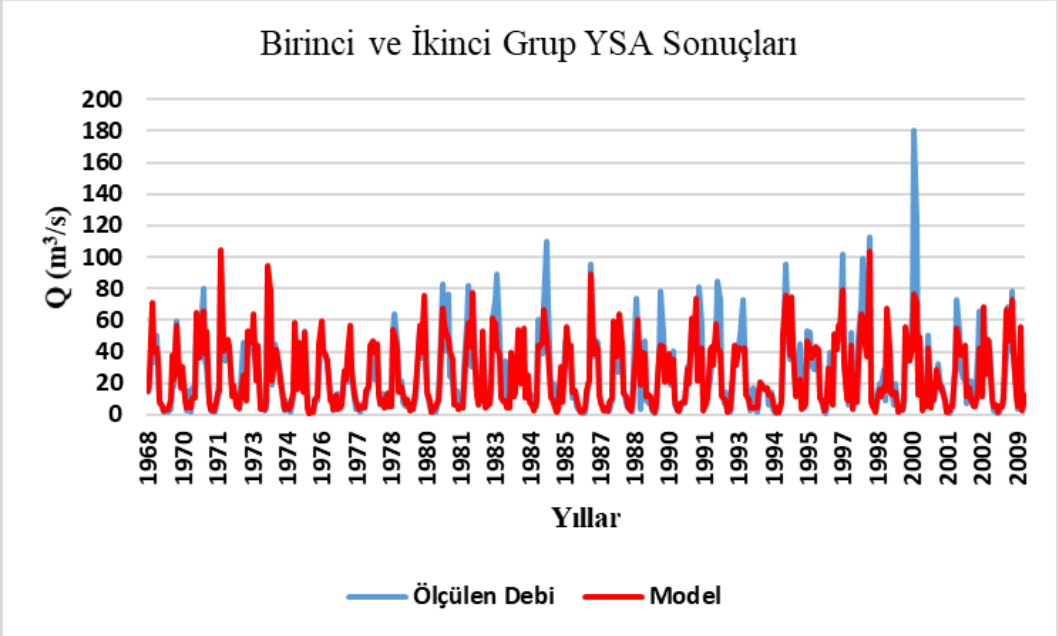
Çizelge 5.3. (devam) İkinci grup ortalama aylık yağış ve debi değerleri

Ay	Yağış (mm)	Debi (m^3/s)
Mayıs	80,94	35,02
Haziran	123,59	38,08
Temmuz	92,52	56,71
Ağustos	-	-
Eylül	-	-
Ortalama	96,34	47,07

5.4.1. K-Means ve YSA

Ayrıştırılan birinci ve ikinci grup verilerine ayrı ayrı YSA uygulanmıştır. K-Means kümeleme yöntemi uygulanmadan önceki YSA sisteminde en iyi sonuç M-P-T (Ay-Yağış-Sıcaklık) ile elde edilmiştir. Bu nedenle birinci ve ikinci grup verilerine de aynı girdiler ile YSA uygulanmıştır. Girdi olarak ölçümün yapıldığı ay (M), aylık toplam yağış (P), aylık toplam yağış ve aylık ortalama sıcaklık (T) verileri kullanılarak YSA yöntemiyle debi verisi elde edilmiştir.

Birinci ve ikinci grup için ayrı ayrı olarak YSA uygulandıktan sonra model sonuçları tekrar birleştirilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,78, RMSE değeri 11,60, R^2 değeri 0,78 olarak hesaplanmıştır. Şekil 5.20. ile ölçülen debi ile YSA'dan elde edilen debi grafiği verilmiştir.

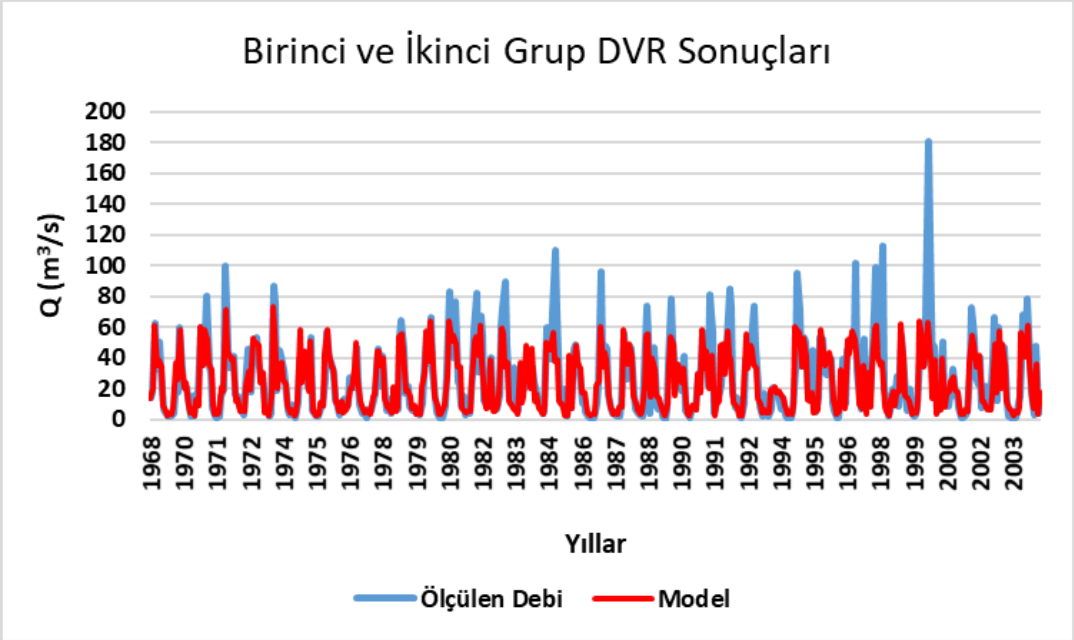


Şekil 5.20. Birinci ve ikinci grup birleştirilmiş model debi ve ölçülen debi grafiği

5.4.2. K-Means ve DVR

Ayrıştırılan birinci ve ikinci grup verilerine ayrı ayrı DVR ve uygulanmıştır. Girdi olarak ölçümün yapıldığı ay (M), aylık toplam yağış (P), aylık toplam yağış ve aylık ortalama sıcaklık (T) verileri kullanılarak DVR yöntemiyle debi verisi elde edilmiştir.

Birinci ve ikinci grup için ayrı ayrı olarak DVR uygulandıktan sonra model sonuçları tekrar birleştirilmiştir. Model ile ölçülen veriler arasındaki performans incelendiğinde, NSE değeri 0,70, RMSE değeri 13,41, R^2 değeri 0,72 olarak hesaplanmıştır Şekil 5.21. ile ölçülen debi ile DVR'den elde edilen debi grafiği verilmiştir.



Şekil 5.21. Birinci ve ikinci grup birleştirilmiş model debi ve ölçülen debi grafiği

5.5. GR2M Modeli

İki parametre ile aylık olarak çalışan GR2M hidrolojik modeli, Moulheli (2003) tarafından geliştirilmiştir. Model için girdi olarak aylık toplam yağış ve potansiyel evapotranspirasyon gerekmektedir. Modelden çıktı olarak debi elde edilmektedir.

Potansiyel evapotranspirasyon, aylık ortalama sıcaklık ile hesaplanan Thornthwaite & Mather (1955) yöntemi kullanılarak elde edilmiştir. Elde edilen potansiyel

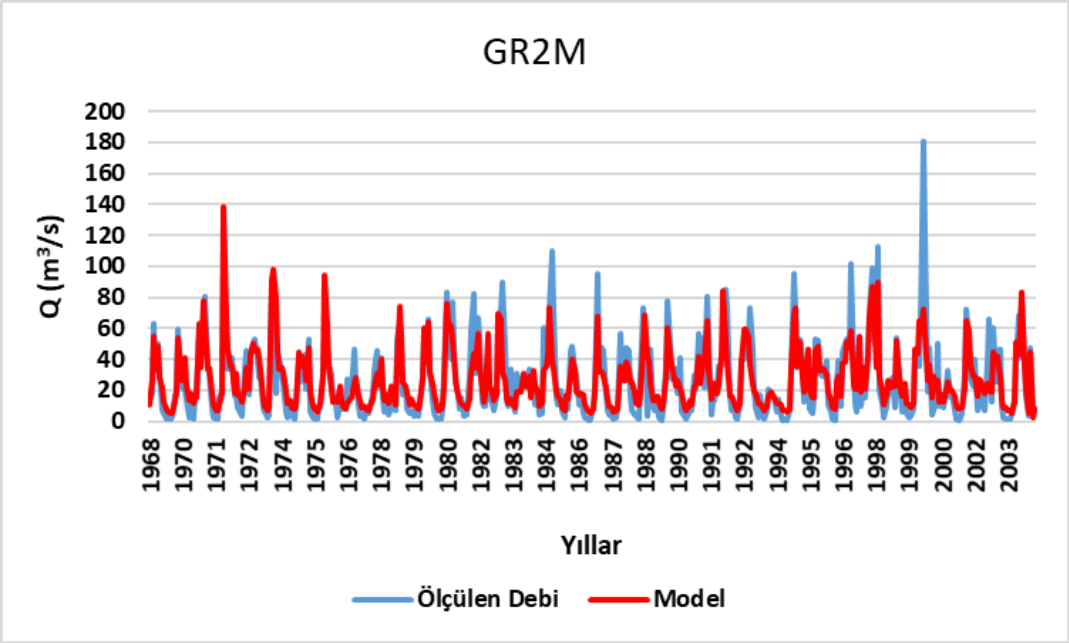
evapotranspirasyon verilerinin aylık ortalama değerleri aylık ortalama sıcaklıkla birlikte Çizelge 5.4.'te verilmiştir.

Çizelge 5.4. Aylık ortalama sıcaklık ve potansiyel evapotranspirasyon

Aylar	Aylık Ortalama Sıcaklık (℃)	Aylık Ortalama PET (mm)
Ekim	13,37	85,91
Kasım	8,51	54,78
Aralık	5,13	37,61
Ocak	3,21	27,57
Şubat	4,30	34,17
Mart	6,92	59,03
Nisan	11,04	87,34
Mayıs	15,43	122,31
Haziran	19,38	143,60
Temmuz	22,01	158,84
Ağustos	21,55	145,57
Eylül	17,55	111,86

GR2M hidrolojik modelinin kalibrasyonu X_1 üretim kapasitesi, X_2 değişim parametreleri ile yapılmaktadır. Optimizasyon yapılarak X_1 parametresi 6,19 mm, X_2 1,38 mm bulunmuştur. Üretim rezervuarındaki ilk dolum seviyesi olan S_0 ve öteleme rezervuarındaki ilk dolum seviyesi olan R_0 parametrelerinin de kalibre edilmesi gerekmektedir. S_0, 243 mm ve R_0, 6,75 mm bulunarak başlangıç ayındaki debi kalibre edilmiştir.

Kalibresi gerçekleştirilmiş GR2M modeli, performans bakımından incelendiğinde, NSE değeri 0,68, RMSE değeri 13,90, R^2 değeri 0,68 olarak hesaplanmıştır. Şekil 5.22. ile ölçülen debi ile GR2M modelinden elde edilen debi grafiği verilmiştir.



Şekil 5.22. GR2M modeli ile elde edilen model-ölçülen aylık debi grafiği

6. TARTIŞMA

Bu bölümde farklı girdiler (M, P, R, T) ve farklı yöntemler (Yapay Sinir Ağları, Lineer Regresyon, Destek Vektör Regresyonu ve GR2M) ile elde edilen debi sonuçlarının ölçülmüş debilere göre performansları karşılaştırılmıştır.

Çizelge 6.1. ile YSA yöntemi kullanılarak girdilere karşılık elde edilen debi sonuçlarının ölçülmüş debilere göre NSE, RMSE ve R^2 sonuçları verilmiştir. Sonuçlar incelendiğinde en iyi sonucun 0,66 NSE, 14,34 RMSE, 0,68 R^2 değerleri ile M-P-T girdisiyle elde edildiği görülmektedir. M-P-R-T ile M-P-T girdisi ile elde edilen sonuçların performansları arasındaki farkın az olduğu görülmektedir. İşlemler yapılırken hesap yükünün daha az olması nedeniyle M-P-T sonuçları üzerinde durulmuştur.

Çizelge 6.1. Yapay Sinir Ağları ile elde edilen sonuçlar

Yapay Sinir Ağları			
Girdi	NSE	RMSE	R^2
M	0,35	19,89	0,40
P	0,22	21,77	0,30
R	0,25	21,40	0,31
T	0,42	18,83	0,44
M-P	0,64	14,74	0,66
M-R	0,62	15,30	0,63
M-T	0,40	19,09	0,44
P-R	0,20	22,07	0,29
P-T	0,50	17,42	0,53
R-T	0,57	16,22	0,59
M-P-R	0,65	14,58	0,66
M-P-T	0,66	14,34	0,68
P-R-T	0,49	17,61	0,52
M-P-R-T	0,65	14,46	0,67

K-Means kümeleme yöntemi ile debi ve yağış verileri kullanılarak veriler birinci ve ikinci grup olmak üzere iki gruba ayrılmıştır. Ayrılan iki gruba da M-P-T girdisi ile YSA ve DVR uygulanmıştır. Daha sonra her iki gruptan elde edilen sonuçlar birleştirilmiştir. Elde edilen sonuç performansları Çizelge 6.2. ile verilmiştir.

Çizelge 6.2. K-Means Kümelemeden sonra YSA ve DVR kullanılması ile elde edilen sonuçlar

Yöntem	Girdi	NSE	RMSE	R^2
YSA & K-Means Kümeleme	M-P-T	0,78	11,60	0,78
DVR & K-Means Kümeleme	M-P-T	0,70	13,41	0,72

Çizelge 6.3. ile çalışmada kullanılan makine öğrenme yöntemlerinden ele edilen sonuçların performansları verilmiştir. Çizelge incelendiğinde üç performans bakımından da en iyi sonuçların K-Means Kümeleme yöntemiyle birlikte kullanılan YSA ve DVR yöntemlerinden elde edildiği görülmektedir.

Çizelge 6.3. Makine öğrenme yöntemlerinden elde edilen sonuçlar

Yöntem	Girdi	NSE	RMSE	R^2
YSA & K-Means Kümeleme	M-P-T	0,78	11,60	0,78
DVR & K-Means Kümeleme	M-P-T	0,70	13,41	0,72
YSA	M-P-T	0,66	14,34	0,68
Destek Vektör Regresyonu	M-P-T	0,62	15,10	0,64
Lineer Regresyon	M-P-T	0,55	16,51	0,55

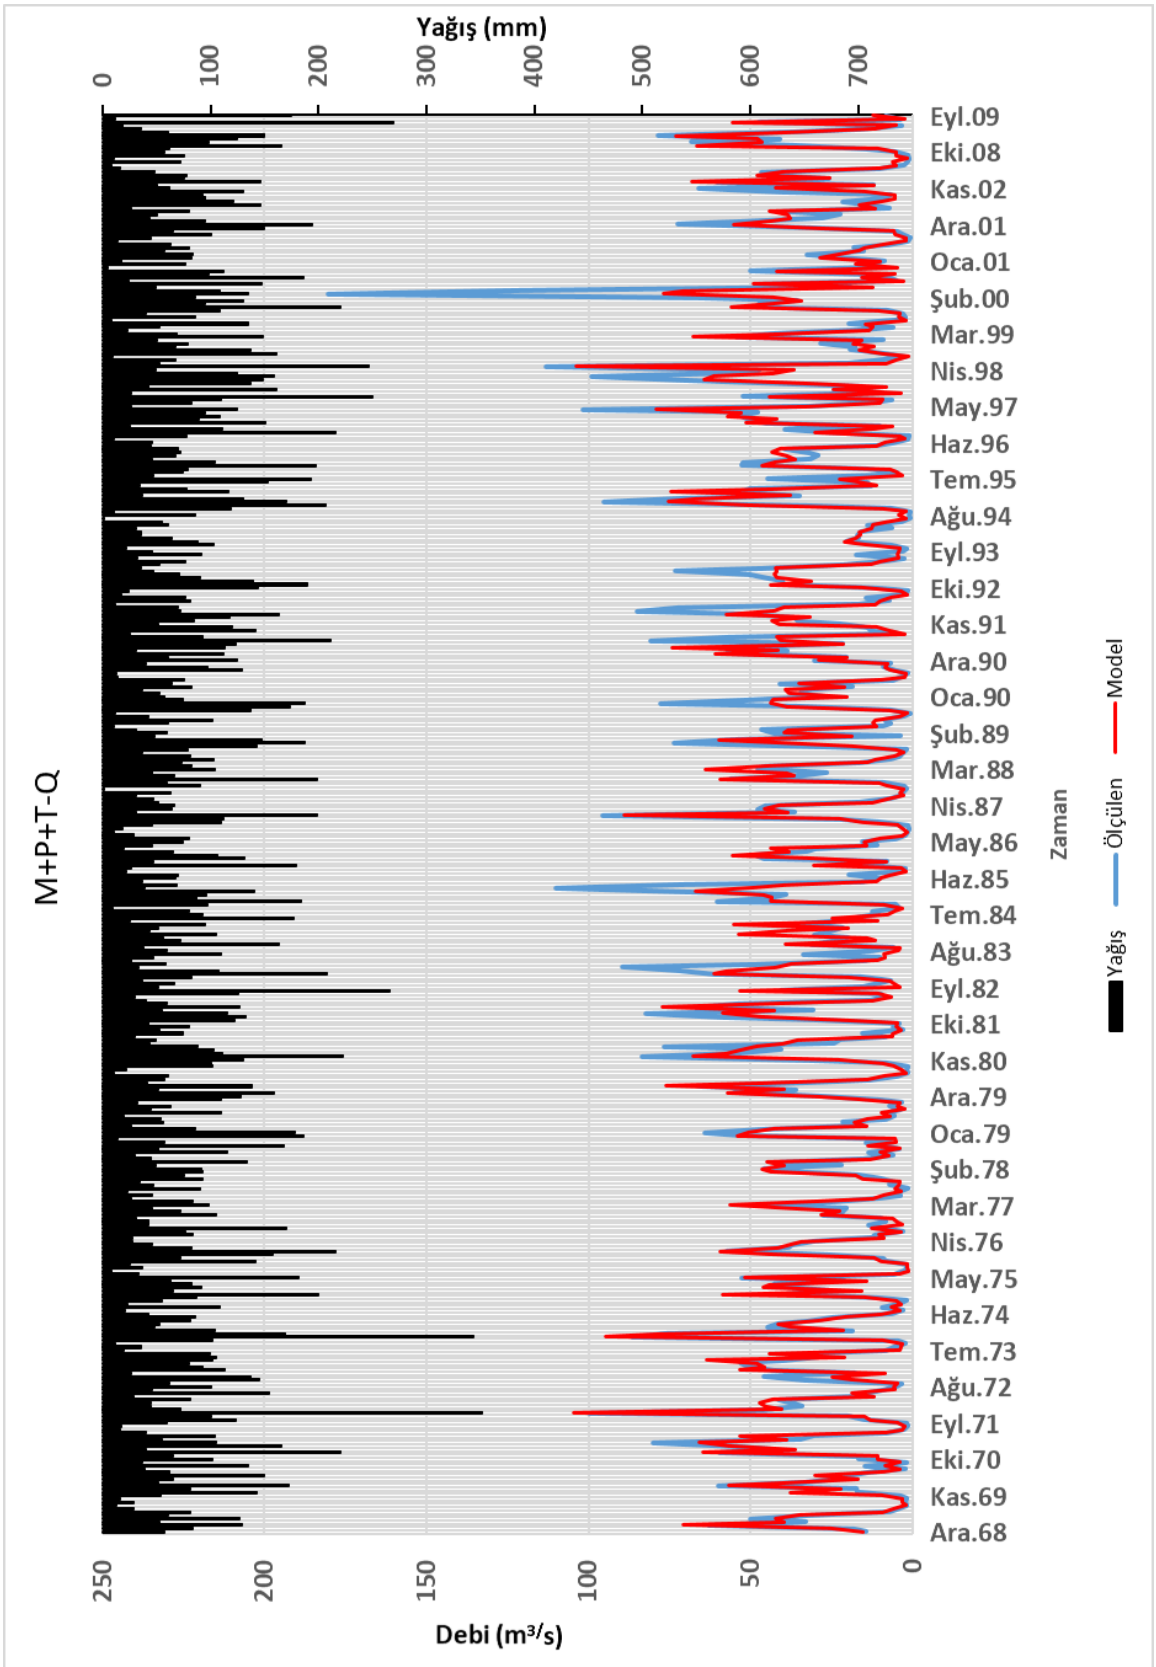
En iyi sonuçların elde edildiği yöntemler olan YSA & K-Means Kümeleme ve DVR & K-Means Kümeleme yöntemlerinin öğrenme ve test veri performanslarının incelenmesi gerekmektedir. Her iki yöntem için de verilerin %60'ı öğrenme için, %40'ı test için ayrılmıştı. Öğrenme ve test için ayrılan verilerin performansı, Kök Ortalama Kare Hata (RMSE) bakımından incelenmiştir. Öğrenme ve test verilerinin RMSE değerleri birbirine yakın olması gerekmektedir. Bu değerlerin birbirine uzak olması makine öğrenme yöntemlerinden elde edilen çıktıların güvenilir sonuçlar vermediğini göstermektedir. Çizelge 6.4. ile makine öğrenme yöntemlerinden elde edilen öğrenme ve test verilerinin RMSE değerleri verilmiştir.

Çizelge 6.4. Makine öğrenme yöntemleri öğrenme ve test verilerinin performansları

Yöntem	Performans Ölçüm Yöntemi	Birinci Grup Öğrenme Verileri	Birinci Grup Test Verileri	İkinci Grup Öğrenme Verileri	İkinci Grup Test Verileri
YSA & K-Means Kümeleme	RMSE	7,36	7,47	17,98	17,02
DVR & K-Means Kümeleme	RMSE	7,43	11,72	14,19	26,00

Çizelge 6.4. incelendiğinde YSA ve K-Means Kümeleme yöntemlerinin birlikte kullanıldığı yöntemde, birinci grup ve ikinci grup öğrenme ve test verilerinin RMSE değerlerinin birbirine yakın olduğu görülmektedir. DVR ve K-Means yöntemlerinin birlikte kullanıldığı yöntemde ise bu değerlerin birbirine uzak olduğu görülmektedir. İki yöntem karşılaştırıldığında, YSA ve K-Means Kümeleme yöntemlerinin birlikte kullanıldığı yöntemde, RMSE değerlerinin yakın sonuçlar vermesinden dolayı bu yöntemin daha güvenilir sonuçlar vereceğini göstermektedir.

Şekil 6.1. ile YSA ve K-Means Kümeleme yönteminin kullanılmasıyla elde edilen debi sonuçları, ölçülen debi ve yağış verilerinin grafiği verilmiştir.



Şekil 6.1. Yağış, ölçülen debi ve modellenen debi grafiği

Çalışma kapsamında kullanılan AGİ verilerine, taşkın debisi tahmini için istatistiksel yöntemlerden olan Normal Dağılım, Log-Normal Dağılım ve Gumbel yöntemleri uygulanmıştır. Bu istatistiksel yöntemler ve elde edilen sonuçlar aşağıda yer almaktadır.

Normal Dağılım

Gauss dağılımı olarakta bilinen Normal Dağılım, hidrolojik değişkenlerin istatistiksel analizinde en yaygın olarak kullanılan dağılımdır. Bunun sebebi çok sayıda değişkenin toplamının dağılımının, temel dağılımdan bağımsız olarak genellikle normal dağılıma yaklaşması olabilir (Benjamin ve Cornell, 1970).

Normal Dağılım'a ait eşitlik aşağıda yer almaktadır.

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \tag{6.1}$$

Formülde yer alan σ standart sapmayı, μ ortalamayı ifade etmektedir.

Log-Normal Dağılım

Hidrolojik değişkenler genellikle pozitif değerlere veya belirli bir alt sınırdan daha büyük değerlere sahip olduklarından normal dağılıma uymazlar. Bu nedenle hidrolojik değişkenler, logaritmaları alınarak normal dağılıma uygun hale getirilebilir (Benjamin ve Cornell, 1970).

Log-Normal Dağılım'a ait eşitlik aşağıda yer almaktadır

$$f(x) = \frac{1}{\sigma_y e^y \sqrt{2\pi}} e^{-\frac{(y-\mu_y)^2}{2\sigma_y^2}} \tag{6.2}$$

Formülde yer alan y, x değerlerinin logaritmasının alınmış halini ifade etmektedir (y=ln x). σ_y, y değerlerinin standart sapmasını ve μ_y y değerlerinin ortalamasını ifade etmektedir.

Gumbel Dağılımı

Ekstren değer dağılımı olarakta bilinen Gumbel dağılımı, n adet değişkenin maksimum ve minimum değerlerin dağılımının modellenmesi olarak tanımlanmaktadır (Gumbel, 1958).

Gumbel dağılımında kullanılan eşitlikler aşağıda verilmiştir.

$$p = 1 - e^{-e^{-y}} \tag{6.3}$$

p hidrolojik değerin gerçekleşme olasılığını ifade etmektedir. y ise aşağıdaki denklem ile hesaplanmaktadır.

$$y = a(x - x_o) \tag{6.4}$$

$$a = \sigma_n/\sigma_x \text{ (Veri sayısı 30'dan küçük ise)}$$
$$a = 1{,}28255/\sigma_x \text{ (Veri sayısı 30'dan büyük ise)} \tag{6.5}$$

$$x_o = \bar{x} - y_n(\sigma_x/\sigma_n) \tag{6.6}$$

$$\bar{x} = \sum x/n \tag{6.7}$$

$$\sigma_x = \sqrt{\sum \frac{(x - \bar{x})^2}{n-1}} \tag{6.8}$$

Burada σ_x standart sapmayı ifade etmektedir.

Çalışma kapsamında kullanılan AGİ verilerine yukarıda tanımlamaları yapılan istatistiksel yöntemler uygulanmıştır. Elde edilen sonuçlar aşağıda verilmiştir.

Çizelge 6.5. İstatistiksel yöntemlerden elde edilen tekerrür debileri

Q_n	Normal Dağılım (m^3/s)	Log-Normal Dağılım (m^3/s)	Gumbel Dağılımı (m^3/s)
Q_2	72,00	67,23	67,85
Q_5	94,72	92,64	94,96
Q_{10}	106,59	109,53	112,91
Q_{25}	119,26	130,96	135,58
Q_{50}	127,44	146,98	152,41
Q_{100}	134,79	163,06	169,11
Q_{250}	143,59	184,59	191,10
Q_{500}	149,69	201,19	207,70
Q_{1000}	155,41	218,11	224,29

Çizelge 6.5 ile istatistiksel yöntemlerden elde edilen tekerrür debileri verilmiştir. Kullanılan istatistik yöntemlerinin en uygun olanını belirlemek için Kolmogorov-Smirnov (k-s) testi uygulanmıştır. Kolmogorov-Smirnov testi gözlenen ve beklenen değerlerin toplam frekansları arasındaki en büyük mutlak fark prensibine dayanmaktadır (Turhan, Değerli ve Duyan Çulha, 2021).

Çizelge 6.6 ile K-S testinden elde edilen gözlenen ve beklenen değerlerin toplam frekansları arasındaki en büyük mutlak fark değerleri verilmiştir. Tabloya göre farkın 0,109 ile en az olduğu Log-Normal dağılımı en uygun istatistiksel yöntem olarak belirlenmiştir.

Çizelge 6.6. K-S testinden elde edilen fark değerleri

K-S Testi	Normal Dağılım	Log-Normal Dağılım	Gumbel Dağılımı
Fark	0,125	0,109	0,112

Çizelge 6.7. ile çalışmada kullanılan AGİ verileri arasında en yüksek değer olan 175 m^3/s debi değerinin istatistiksel yöntemler ile kaç yılda bir tekrarlanacağı hesaplanmıştır. Elde edilen sonuçlara göre 175 m^3/s'lik debi değerinin Normal dağılım yöntemine göre 3640 yılda bir, Log-Normal dağılım yöntemine göre 167 yılda bir, Gumbel dağılımı yöntemine göre 128 yılda bir görülecek bir debi debi değeri olduğu hesaplanmıştır. K-S testine göre en uygun yöntem olan Log-Normal dağılımı en uygun yöntem seçilmişti. Bu nedenle 175 m^3/s'lik debi değerinin 167 yılda bir rastlanılacak bir değer olduğuna karar verilmiştir.

Çizelge 6.7. AGİ'de ölçülen maksimum debiye göre istatistiksel yöntemlerden elde edilen yıllar

Q	Normal Dağılım (Yıl)	Log-Normal Dağılım (Yıl)	Gumbel Dağılımı (Yıl)
Q=175 (m^3/s)	3640	167	128

Çalışmada en iyi sonuç YSA ve K-Means Kümeleme yöntemlerinin birlikte kullanılmasıyla edilmiştir. Şekil 6.1 incelendiğinde ölçülen AGİ değerleri arasında Mart 2000 tarihinde 175 m^3/s'lik debinin iyi modellenemediği görülmektedir. Yukarıda hesaplanan tekerrür debileri arasında 175 m^3/s'lik debi değerinin 167 yılda bir görülecek bir debi değeri olduğu görülmektedir. Makine öğrenme yöntemleri uygulanırken bu tür yüksek debi değerlerinin

veri seti içerisinde az olmasından dolayı modellemelerde bu uç değerler için iyi sonuçlar alınmadığı gözlemlenmiştir.

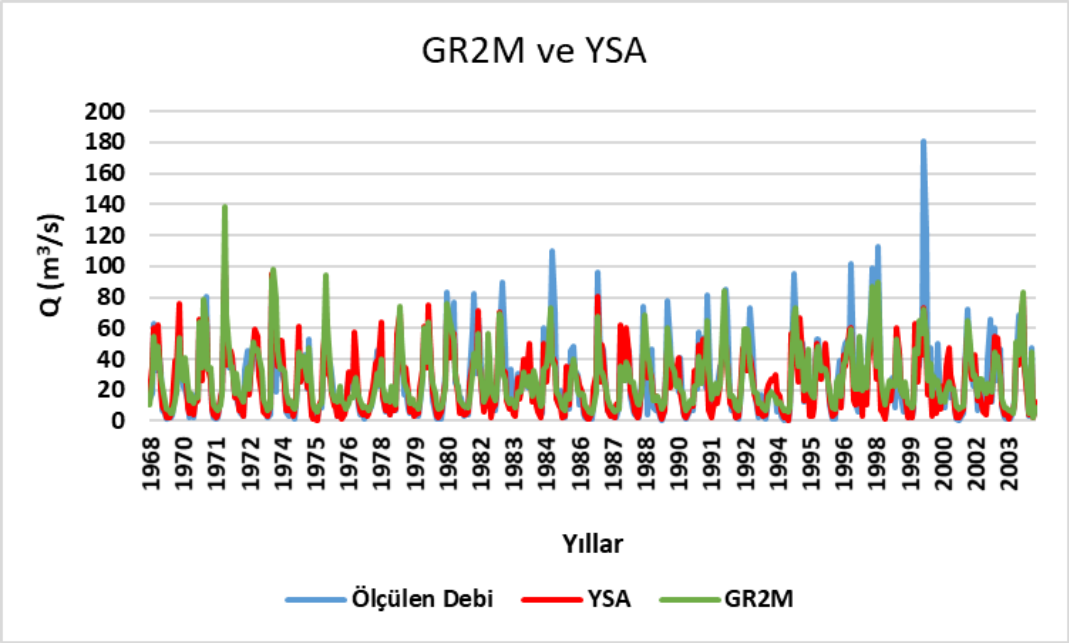
GR2M modeli ile debi hesaplanırken girdi olarak yağış ve potansiyel evapotranspirasyon verilerine ihtiyaç duyulmaktadır. Çalışma kapsamında evapotranspirasyon verileri, aylık ortalama sıcaklık verileri ile Thornthwaite ve Mather yöntemi kullanılarak hesaplanmıştır.

GR2M yöntemi, Microsoft Excel programı kullanılarak, modelin kalibrasyon parametreleri olan X_1, üretim kapasitesi ve X_2, değişim parametresinin optimizasyonu yapılarak kurulmuştur. GR2M ve YSA modellerini kıyaslamak için YSA'da da girdi olarak yağış ve evapotranspirasyon verileri kullanılarak çıktı olarak debi alınmıştır. Her iki modelin performans sonuçları Çizelge 6.8. ile verilmiştir.

Çizelge 6.8. GR2M ve YSA model performansları

Yöntem	Girdi	NSE	RMSE	R^2
GR2M	P-PET	0,68	13,88	0,69
YSA	P-PET	0,66	14,32	0,67

Çizelge 6.8 incelendiğinde GR2M modelinin YSA'ya göre daha iyi performans gösterdiği görülmektedir. YSA yönteminin sadece yağış ve potansiyel evapotranspirasyon ile debi elde etmede iyi performans göstermediği görülmektedir. Şekil 6.2 ile GR2M ve YSA modellerinden elde edilen debileri grafiği birlikte verilmiştir.



Şekil 6.2 GR2M ve YSA modellerinin karşılaştırılması

7. SONUÇ VE ÖNERİLER

Bu tez çalışması için Bartın Irmağı'nı oluşturan akarsulardan Kocaçay Irmağına ait hidrolojik havza çalışma alanı olarak seçilmiştir. Öncelikle Kocaçay Irmağı'nın yağış alanı belirlenmiştir. Belirlenen yağış alanına giren ve yağış alanına yakın bir konumda bulunan meteoroloji gözlem istasyonları tespit edilerek aylık toplam yağış ve aylık ortalama sıcaklık verileriyle birlikte Kocaçay Irmağı'nın aylık ortalama debi değerleri temin edilmiştir.

Meteorolojik veriler ile akım verileri arasında lineer olmayan bir ilişki bulunmaktadır. Aralarında lineer olmayan ilişkilerin tespitinde literatürde birçok çalışma mevcuttur. Bu çalışma kapsamında meteorolojik veriler kullanılarak debi tahmini yapabilmek amacıyla makine öğrenme yöntemlerinden Yapay Sinir Ağları, K-Means Kümeleme Yöntemi ve Destek Vektör Regresyonu kullanılmıştır. Makine öğrenme yöntemlerinin dışında ayrıca Moulheli (2003) tarafından geliştirilen GR2M modeli de kurulmuştur.

Çalışmada kullanılan yöntemler hem tekil olarak çalıştırılmış hem de daha iyi sonuçlar elde etmek amacıyla bazı modeller birlikte kullanılarak değerlendirilmiştir. YSA ve K-Means, DVR ve K-Means modelleri birlikte kullanıma uygun modeller olarak öne çıkmaktadır. Çalışma kapsamında elde edilen tüm performans değerleri dikkate alındığında YSA ve K-Means Kümeleme yöntemlerinin birlikte kullanımı ile elde edilen sonuçların en iyi olduğu, ikinci en iyi sonucun DVR ve K-Means Kümeleme yöntemlerinin birlikte kullanımı ile elde edildiği görülmüştür. Bunu tekil modellerden elde edilen performans değer sonuçları takip etmektedir.

GR2M modelinin uygulanması için yağış ve potansiyel evapotranspirasyon değerlerinin girdi olarak kullanılması zorunludur. GR2M modeli ile YSA'nın performans karşılaştırılması için YSA'da aynı parametreler girdi olarak kullanılmıştır. İki modelin performans değerleri karşılaştırıldığında oldukça yakın değerlere sahiptir. Bununla birlikte iki modelin kurulum, test ve sonuçların elde edilmesi için gerekli süreler dikkate alındığında GR2M modelinin oldukça hızlı olduğu görülmektedir. Bu nedenle sadece "*yağış*" ve "*potansiyel evapotranspirasyon*" verileriyle çalışılması zorunlu olan durumlarda GR2M modelinin kullanılması önerilir. YSA modellerinin kullanılması durumunda girdi parametrelerinin çeşitliliği arttıkça performans sonuçları GR2M modeline göre iyileşmektedir.

Kullanılan yöntemlerin kurulumu bakımından bir değerlendirme yapıldığında en zor kurulumun YSA modelinde olduğu görülmüştür. Çünkü YSA modeli kurulurken, en iyi sonucu elde edebilmek için uygun mimari yapının (gizli katman sayısı, hücre sayısı) belirlenmesine ihtiyaç vardır. Mimari yapının yanında en uygun öğrenme yönteminin de seçilmesi gerekmektedir. En iyi sonucu bulmak için bu parametreler deneme yanılma yoluyla test edilmelidir. Ayrıca YSA'da en iyi sonucu veren gizli katman sayısı, nöron sayısı veya öğrenme algoritması gibi parametreler bir diğer havza verileri ile yapılan çalışmalar için kullanıldığında iyi sonuçlar üretmeyebilir. Her çalışma için en iyi sonucu veren parametrelerin tespit edilmesi gerekmektedir. Bu işlemleri hızlandırmak amacıyla bir optimizasyon tekniğinin kullanılması faydalı olabilir.

KAYNAKLAR

Adnan, R., Yuan, X., Kisi, O. & Yuan, Y. (2017). Streamflow forecasting using artificial neural network and support vector machine models. *American Academic Scientific Research Journal for Engineering, Technology, and Sciences*, *29*(1), 286-294.

Aichouri, I., Hani, A., Bougherira, N., Djabri, L., Chaffai, H. & Lallahem, S. (2015). River flow model using artificial neural networks. *Energy Procedia, 74*, 1007-1014.

Anilan, T., Nacar, S., Kankal, M. & Yuksek, O. (2020). Prediction of maximum annual flood discharges using artificial neural network approaches. *Građevinar, 72*(03), 215-224.

ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial neural networks in hydrology. I: Preliminary concepts. *Journal of Hydrologic Engineering*, *5*(2), 115-123.

ASCE Task Committee on Application of Artificial Neural Networks in Hydrology. (2000). Artificial neural networks in hydrology. II: Hydrologic applications. *Journal of Hydrologic Engineering*, *5*(2), 124-137.

Awad, M. & Khanna, R. (2015). *Efficient learning machines: theories, concepts, and applications for engineers and system designers*. New York: Springer nature, 39-43.

Ayaydın, A. (1992). Regrasyon-Korelasyon Analizi ve Yönetim Muhasebesi. *Marmara İletişim Dergisi, 1*(1), 89-92.

Ayhan, S. & Erdoğmuş, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi, 9*(1), 175-201.

Aziz, K., Rahman, A., Fang, G., & Shrestha, S. (2014). Application of artificial neural networks in regional flood frequency analysis: a case study for Australia. *Stochastic Environmental Research and Risk Assessment*, *28*(3), 541-554.

Benjamin, J. R. & Cornell, C. A. (1970). *Solutions manual to accompany probability, statistics, and decision for civil engineers*. New York: McGraw-Hill, 684.

Botsis, D., Latinapoulas, P., & Diamantaras, K. (2011). *Rainfall-runoff modeling using support vector regression and artificial neural networks.* In 12th International Conference on Environmental Science and Technology (CEST2011), 8-10.

Gumbel, E. J. (1958). *Statistics of Extremes*. Columbia: Columbia university press.

Haykin, S. (1994). *Neural Networks, A Comprehensive Foundation.* New York: Prentice Hall.

İnternet: Bartın Valiliği. (2022). *Bartın Valiliği*. Web: http://www.bartin.gov.tr/bartin-tarihi-ve-cografi-yapisi, Erişim Tarihi:10/01/2022.

İnternet: Meteoroloji Genel Müdürlüğü. (2020). Web: https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=undefined&m=BARTIN, Erişim Tarihi:11/01/2022.

İnternet: Meteoroloji Genel Müdürlüğü. (2022). *Web:* https://mgm.gov.tr/kurumsal/istasyonlarimiz.aspx?il=Bart%C4%B1n, Erişim Tarihi:11/01/2022.

Isik, S., Kalin, L., Schoonover, J. E., Srivastava, P. & Lockaby, B. G. (2013). Modeling effects of changing land use/cover on daily streamflow: an artificial neural network and curve number based hybrid approach. *Journal of Hydrology, 485*, 103-112.

Jahangir, M. H., Reineh, S. M. & Abolghasemi, M. (2019). Spatial predication of flood zonation mapping in Kan River Basin, Iran, using artificial neural network algorithm. *Weather and Climate Extremes, 25, 100215*.

Joorabchi, A., Zhang, H. & Blumenstein, M. (2007). Application of artificial neural networks in flow discharge prediction for the Fitzroy River, Australia. *Journal of Coastal Research*, 287-291.

Kentel, E. (2009). Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. *Journal of hydrology*, *375*(3-4), 481-488.

Kia, M. B., Pirasteh, S., Pradhan, B., Mahmud, A. R., Sulaiman, W. A. & Moradi, A. (2012). An artificial neural network model for flood simulation using GIS: Johor River Basin, Malaysia. *Environmental Earth Sciences, 67*(1), 251-264.

Kişi, Ö. & Uncuoğlu, E. (2005). Comparison of three back-propagation training algorithms for two case studies. *Indian Journal of Engineering, Material Sciences*, 434-442.

Likas, A., Vilassis, N. & Verbeek, J. J. (2003). The global k-means clustering algorithm. *Pattern Recognition, 36*(2), 451-461.

Makhlouf, Z. & Michel, C. (1994). A two-parameter monthly water balance model for French. *Journal of Hydrology, 162*(3-4), 299-318.

Mao, G., Wang, M., Liu, J., Wang, Z., Wang, K., Meng, Y., Li, Y. (2021). Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation. *Physics and Chemistry of the Earth,* Parts A/B/C, 123, 103026.

Mehr, A. D., Kahya, E., Şahin, A. & Nazemosadat, M. J. (2015). Successive-station monthly streamflow prediction using different artificial neural network algorithms. *International Journal of Environmental Science and Technology, 12*(7), 2191-2200.

Melesse, A. M., Ahmad, S., McClain, M. E., Wang, X. & Lim, Y. H. (2011). Suspended sediment load prediction of river systems: An artificial neural network approach. *Agricultural Water Management, 98*(5), 855-866.

Meteoroloji Genel Müdürlüğü. (2016). Thornthwaite iklim sınıflandırmasına göre Türkiye iklimi. Araştırma Dairesi Başkanlığı Klimatoloji Şube Müdürlüğü. *TC Orman ve Su İşleri Bakanlığı Meteoroloji Genel Müdürlüğü*.

Michie, D., Spiegelhalter, D. J., & Taylor, C. C. (1994). *Machine learning, neural and statistical classification.* New York: Ellis Horwood, 11.

Mitra, S. & Nigam, R. (2021). An approach to utilize artificial neural network for runoff prediction: River perspective. *Materials Today: Proceedings*, 52.

Moulheli, S. (2003). *Vers une chaîne cohérente de modèles pluie-débit conceptuels globaux aux pas de temps pluriannuel, annuel, mensuel et journalier*, Doctoral dissertation, Doctorat Géosciences et ressources naturelles, Paris, 25-44

Nagesh Kumar, D., Srinivasa Raju, K. & Sathish, T. (2004). River flow forecasting using recurrent neural networks. *Water Resources Management, 18*(2), 143-161.

Nash, E. J. & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I - A discussion of principles. *Journal of Hydrology, 10*(3), 282-290.

Okkan, U. & Fistikoglu, O. (2014). Evaluating climate change effects on runoff by statistical downscaling and hydrological model GR2M. *Theoretical and Applied Climatology, 117*(1), 343-361.

Okkan, U., Serbes, Z. A. & Samui, P. (2014). Relevance vector machines approach for long-term flow prediction. *Neural Computing and Applications, 25*(6), 1393-1405.

Öztemel, E. (2003). *Yapay Sinir Ağları*. İstanbul:Papatya Yayınclık, 29-45.

Raghavendra. N, S. & Deka, P. C. (2014). Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing, 19*, 372-386.

Ramirez, M. V., Velho, H. F. & Ferreira, N. J. (2005). Artificial neural network technique for rainfall forecasting applied to the Sao Paulo region. *Journal of Hydrology, 301*(1-4), 146-162.

Rauf, A., Ghumman, A. G., Ahmad, S. & Hashmi, H. N. (2018). Performance assessment of artificial neural networks and support vector regression models for stream flow predictions. *Environmental Monitoring and Assessment, 190*(12), 1-20.

Reyes, J. V., Cisneros, F. & Vanegas, P. (2016). Artificial neural networks applied to flow prediction: a use case for the Tomebamba river. *Procedia Engineering, 162*, 153-161.

Saraçlı, S. & Meral, G. (2020). Destek Vektör Makineleri ve Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketimi Üzerine Bir Uygulama. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 24*(2), 411-418.

Su Yönetimi Genel Müdürlüğü. (2019). Batı Karadeniz Havzası Taşkın Yönetim Planı. *TOB.*

Thewe, Y. M., Ogawa, M. & Dung, P. N. (2019). *Applying Clustering Techniques for Refining Large Data Set: Case Study on Malware.* In 2019 International Conference on Advanced Information Technologies (ICAIT). Yangon, 238-243.

Thiessen, A. H. (1911). Precipitation averages for large areas. *Monthly weather review, 39*(7), 1082-1089.

Thornthwaite, C. W. & Mather, J. R. (1957). Instructions and tables for computing potential evapotranspiration and the water balance. *Laboratory of Climatology*, 10, 185-311.

Turhan, E. (2021). A Comparative Evaluation of the Use of Artificial Neural Networks for Modeling the Rainfall-Runoff Relationship in Water Resources Management. *Journal of Ecological Engineering, 22*(5).

Turhan, E., Değerli, S. & Duyan Çulha, B. (2021). Çeşitli Tekerrür Periyotları için Taşkın Debilerinin Tahmininde Farklı Olasılık Dağılımlarının Karşılaştırılması: Ceyhan Nehri Örneği. *Karadeniz Fen Bilimleri Dergisi, 11*(2), 731-742.

Uysal, G. & Şorman, A. Ü. (2017). Monthly streamflow estimation using wavelet-artificial neural network model: a case study on Çamlıdere dam basin, Turkey. *Procedia computer science, 120*, 237-244.

Yadav, N., Yadav, A. & Kumar, M. (2015). *An introduction to neural network methods for differential equations* (Cilt 1). Berlin: Springer, 13-15

Yonaba, H., Anctil, F. & Fortin, V. (2010). Comparing sigmoid transfer functions for neural network multistep ahead streamflow forecasting. *Journal of Hydrologic Engineering*, *15*(4), 275-283.



GAZİ GELECEKTİR..