

Ahmet Burhan KARAEMİNOĞULLARI

İNŞAAT MÜHENDİSLİĞİ ANA BİLİM DALI

OCAK 2020



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ


**YÜKSEK
LİSANS
TEZİ**

**NEHİRLERDEKİ KATI MADDE
MİKTARININ DESTEK VEKTÖR
MAKİNESİ MODELİ İLE TAHMİNİ**

Ahmet Burhan KARAEMİNOĞULLARI

**İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI**

OCAK 2020





**NEHİRLERDEKİ KATI MADDE MİKTARININ DESTEK VEKTÖR
MAKİNESİ MODELİ İLE TAHMİNİ**

Ahmet Burhan KARAEMİNOĞULLARI

**YÜKSEK LİSANS
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

OCAK 2020

Ahmet Burhan Karaeminoğulları tarafından hazırlanan “**NEHİRLERDEKİ KATI MADDE MİKTARININ DESTEK VEKTÖR MAKİNESİ MODELİ İLE TAHMİNİ**” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Başkan: Prof. Dr. Fatih ÜNEŞ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Doç. Dr. Mustafa DEMİRCİ
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Üye: Dr. Öğr. Üyesi Mehmet Eyyüp KAVŞUT
İnşaat Mühendisliği, Osmaniye Korkut Ata Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi:

29/01/2020

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Tolga DEPCI

Mühendislik ve Fen Bilimleri Enstitüsü Müdürü

ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

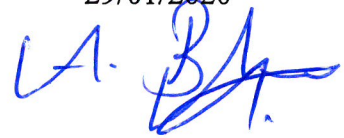
- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada 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.

Ahmet Burhan

KARAEMİNOĞULLARI

29/01/2020



NEHİRLERDEKİ KATI MADDE MİKTARININ DESTEK VEKTÖR MAKİNESİ MODELİ İLE TAHMİNİ

(Yüksek Lisans Tezi)

Ahmet Burhan KARAEMİNOĞULLARI

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Ocak 2020

ÖZET

Akarsu yapılarında katı madde miktarının doğru bir şekilde tahmin edilmesi, su kaynaklarının mühendislik çalışmalarında belirgin bir öneme sahip olup, bu yapıların hassas bir şekilde tasarım ve projelendirilmesine bağlıdır. Katı madde miktarı doğru analizlerle belirlenmediği takdirde su alma yapıları ve barajlar kısa sürede ekonomik ömrünü tamamlayabilir. Bu da verimlilik ve maliyet açısından olumsuz sonuçlar doğurur. Çoğunlukla katı madde miktarı gözlem istasyonlarından yapılan ölçümlerle, katı madde anahtar eğrisi, yapay zekâ modelleme yöntemleri ve kullanılan katı madde denklemlerinden faydalanılarak belirlenmektedir. Bu çalışmada Missouri nehrindeki Nebraska eyaleti Omaha istasyonunda 2011-2017 yılları arasında ölçülen nehir debisi, hava sıcaklığı, yağış gibi hidro-meteorolojik parametreler kullanılarak katı madde miktarı tahmin modellemesi yapılmıştır. Katı madde miktarının tahmini için; katı madde anahtar eğrisi (KMAE) ve literatür de yapay zekâ yöntemleri arasında yer alan radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve geliştirilmiş regresyon yapay sinir ağı (GRYSA) kullanılmıştır. Bu modeller kendi içinde korelasyon katsayısı (R), ortalama karesel hataların karekökü (KKOH), mutlak ortalama hata (MOH) kullanılarak karşılaştırma yapılmıştır. Ölçüm ve model sonuçları karşılaştırıldığında, radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve geliştirilmiş regresyon yapay sinir ağı (GRYSA) modellemeleri nehirlerdeki katı madde miktarının tahmininde uyumlu sonuçlar vermiştir. DVM-RTF, DVM-PÇF ve GRYSA modelleri klasik yöntemlere alternatif olarak sunulabilir.

Anahtar Kelimeler : Tahmin, katı madde, Nebraska, Omaha, destek vektör makinesi
Sayfa Adedi : 71
Danışman : Prof. Dr. Fatih ÜNEŞ

ESTIMATION OF THE SEDIMENT AMOUNT IN THE RIVERS WITH SUPPORT VECTOR MACHINE MODEL

(M.Sc. Thesis)

Ahmet Burhan KARAEMİNOĞULLARI

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

January 2020

ABSTRACT

Accurate estimation of sediments content in river structures has a significant importance in engineering studies of water resources and depends on the precise design and projecting of these structures. If the amount of sediments is not determined by the correct analysis, water intake structures and dams can complete their economic life in a short time. This has negative consequences in terms of productivity and cost. The amount of sediments is mostly determined by measurements from observation stations, sediment key curve, artificial intelligence modeling methods and solids equations used. In this study, the estimation of the sediments content was performed by using hydro-meteorological parameters such as river flow, air temperature and precipitation measured between 2011-2017 years at Omaha Station in Nebraska State, Missouri. For the estimation of sediment amount, sediment rating curve (SRC) and support vector machines- radial basis function (SVM-RBF), support vector machines-polynomial kernel (SVM-PK) and generalized regression neural network (GRNN) which are among the artificial intelligence methods in literature are used. These models were compared by using correlation coefficient (R), root of mean square errors (RMSE) and absolute mean error (MAE). When the measurement and model results were compared, support vector machines- radial basis function (SVM-RBF), support vector machines-polynomial kernel (SVM-PK) and generalized regression neural network (GRNN) models gave consistent results in the estimation of sediments content in rivers. SVM-RBF, SVM-PK and GRNN models can be offered as an alternative to classical methods.

Key Words : Estimation, sediment, Nebraska, support vector machines

Number of Pages : 71

Supervisor : Prof. Dr. Fatih ÜNEŞ

TEŞEKKÜR

Tez çalışmam aşamasında tecrübesi ve bilgi birikimi ile çalışmayı yönlendiren değerli danışman hocam Prof. Dr. Fatih ÜNEŞ 'e teşekkürlerimi sunarım. Ayrıca her daim desteğini hissettiğim Arş. Gör. Bestami TAŞAR' a en içten duygularıyla teşekkürlerimi sunarım. Bana her daim güvenen inanan ve yanımda olan hayatımdaki en fazla teşekkürü hakeden canım anneme, değerli dostlarıma, akrabalarıma, sevgili eşime ve babama sonsuz teşekkürlerimi sunarım.

Rahmetli canım amcam Nejat KARAEMİNOĞULLARI ve canım eniştem Tören YAMAN Anısına.



İÇİNDEKİLER

	Sayfa
ÖZET.....	iv
ABSTRACT.....	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ÇİZELGELERİN LİSTESİ.....	ix
ŞEKİLLERİN LİSTESİ.....	x
SİMGELER VE KISALTMALAR.....	xvi
1. GİRİŞ.....	1
1.1. Suyun Önemi.....	1
1.2. Akarsu Morfolojisi.....	1
1.3. Akarsularda Katı Madde Hareketi.....	2
1.4. Akarsuların Taşıdığı Katı Maddelerin Sınıflandırılması.....	3
2. ÖNCEKİ ÇALIŞMALAR.....	6
3. MATERYAL ve YÖNTEM.....	11
3.1.Çalışma Alanı.....	11
3.2. Kullanılan Modeller.....	16
3.2.1. Katı madde anahtar eğrisi (KMAE).....	16
3.2.2. Destek vektör makinesi (DVM).....	17
3.2.3. Genelleştirilmiş yapay sinir ağı (GRYSA).....	26
4. ARAŞTIRMA BULGULARI ve TARTIŞMA.....	29
4.1. Model Performansında Kullanılan İstatistiksel Parametreler.....	29
4.2. Model Sonuçları.....	30
4.2.1. KMAE sonuçları.....	30
4.2.2. DVM-RTF sonuçları.....	33

4.2.3. DVM-PÇF model sonuçları.....	43
4.2.4. GRYSA model Sonuçları.....	54
5. SONUÇ ve ÖNERİLER.....	66
KAYNAKLAR.....	68
ÖZGEÇMİŞ.....	70



ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Sediment Tahmininde Kullanılan Model Sonuçlarının Karşılaştırılması	64



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Akarsu planı.....	2
Şekil 1.2. Akarsudaki katı maddelerin hareket ve taşınım türleri.....	4
Şekil 1.3. Katı maddenin su derinliğine bağlı dağılımı.....	5
Şekil 3.1. Missouri nehrinin genel görünümü	11
Şekil 3.2. Missouri nehri üzerindeki ölçülen istasyonun yerinin görünümü	12
Şekil 3.3. USGS Missouri nehri üzerindeki Douglos istasyonun detay görünümü.....	12
Şekil 3.4. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında debi miktarı değişimleri.....	14
Şekil 3.5. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında hava sıcaklığı değişimleri.....	14
Şekil 3.6. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında yağış değişimleri.....	15
Şekil 3.7. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında sediment miktarı değişimleri.....	15
Şekil 3.8. S-Q ilişkilerinde doğrusal olmayan bir değişim	17
Şekil 3.9. DVM'nin şematik gösterimi.....	18
Şekil 3.10. Çalışmada kullanılan polinom çekirdek fonksiyonu şeması.....	19
Şekil 3.11. İki boyutlu uzayda örnek veri kümesi.....	20
Şekil 3.12. İki veri kümesini ayıran sonsuz adet düzlemden bir tanesi.....	20
Şekil 3.13. Doğrusal olarak sınıflandırılmayan DVM gösterimi	23
Şekil 3.14. Doğrusal olarak sınıflandırılmayan girdi uzayının bir üst boyuta çekirdek fonksiyonu ile haritalanması.....	24
Şekil 3.15. Çekirdek fonksiyonu gösterimi.....	25
Şekil 3.16. Doğrusal olmayan 2 boyutlu örnek uzay gösterimi.....	25
Şekil 3.17. RTF 'ye ait çekirdek fonksiyonu.....	26

Şekil	Sayfa
Şekil 3.18. Yapay sinir ağına ait şematik gösterim	27
Şekil 3.19. GRYSA' nın genel yapısı	28
Şekil 4.1. Askıdaki sediment miktarı eğitim verileri için KMAE grafiği.....	30
Şekil 4.2. Askıdaki sediment miktarı eğitim verileri için KMAE'ye ait saçılım grafiği.....	31
Şekil 4.3. Askıdaki sediment miktarı eğitim verileri için KMAE'ye ait ölçüm ve dağılım grafiği.....	31
Şekil 4.4. Askıdaki sediment miktarı test verileri için KMAE'ye ait saçılım grafiği.....	32
Şekil 4.5. Askıdaki sediment miktarı test verileri için KMAE'ye ait ölçüm ve dağılım grafiği.....	32
Şekil 4.6. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 1'e ait saçılım grafiği.....	33
Şekil 4.7. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 1'e ait ölçüm ve dağılım grafiği.....	34
Şekil 4.8. Askıdaki sediment miktarı test verileri için DVM-RTF 1'e ait saçılım grafiği.....	34
Şekil 4.9. Askıdaki sediment miktarı test verileri için DVM-RTF 1'e ait ölçüm ve dağılım grafiği.....	35
Şekil 4.10. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 2'ye ait saçılım grafiği.....	35
Şekil 4.11. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 2'ye ait ölçüm ve dağılım grafiği.....	36
Şekil 4.12. Askıdaki sediment miktarı test verileri için DVM-RTF 2'ye ait saçılım grafiği.....	36
Şekil 4.13. Askıdaki sediment miktarı test verileri için DVM-RTF 2'ye ait ölçüm ve dağılım grafiği.....	37
Şekil 4.14. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait saçılım grafiği.....	37
Şekil 4.15. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait ölçüm ve dağılım grafiği.....	38

Şekil	Sayfa
Şekil 4.16. Askıdaki sediment miktarı test verileri için DVM-RTF 3'e ait saçılım grafiği.....	38
Şekil 4.17. Askıdaki sediment miktarı test verileri için DVM-RTF 3'e ait ölçüm ve dağılım grafiği.....	39
Şekil 4.18. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 4'e ait saçılım grafiği.....	39
Şekil 4.19. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 4'e ait ölçüm ve dağılım grafiği.....	40
Şekil 4.20. Askıdaki sediment miktarı test verileri için DVM-RTF 4'e ait saçılım grafiği.....	40
Şekil 4.21. Askıdaki sediment miktarı test verileri için DVM-RTF 4'e ait ölçüm ve dağılım grafiği.....	41
Şekil 4.22. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 5'e ait saçılım grafiği.....	41
Şekil 4.23. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 5'e ait ölçüm ve dağılım grafiği.....	42
Şekil 4.24. Askıdaki sediment miktarı test verileri için DVM-RTF 5'e ait saçılım grafiği.....	42
Şekil 4.25. Askıdaki sediment miktarı test verileri için DVM-RTF 5'e ait ölçüm ve dağılım grafiği.....	43
Şekil 4.26. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 1'e ait saçılım grafiği.....	44
Şekil 4.27. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 1'e ait ölçüm ve dağılım grafiği.....	44
Şekil 4.28. Askıdaki sediment miktarı test verileri için DVM- PÇF 1'e ait saçılım grafiği.....	45
Şekil 4.29. Askıdaki sediment miktarı test verileri için DVM- PÇF 1'e ait ölçüm ve dağılım grafiği.....	45
Şekil 4.30. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 2'ye ait saçılım grafiği.....	46
Şekil 4.31. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 2'ye ait ölçüm ve dağılım grafiği.....	46

Şekil	Sayfa
Şekil 4.32. Askıdaki sediment miktarı test verileri için DVM- PÇF 2'ye ait saçılım grafiği.....	47
Şekil 4.33. Askıdaki sediment miktarı test verileri için DVM- PÇF 2'ye ait ölçüm ve dağılım grafiği.....	47
Şekil 4.34. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 3'e ait saçılım grafiği.....	48
Şekil 4.35. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 3'e ait ölçüm ve dağılım grafiği.....	48
Şekil 4.36. Askıdaki sediment miktarı test verileri için DVM- PÇF 3'e ait saçılım grafiği.....	49
Şekil 4.37. Askıdaki sediment miktarı test verileri için DVM- PÇF 3'e ait ölçüm ve dağılım grafiği.....	49
Şekil 4.38. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 4'e ait saçılım grafiği.....	50
Şekil 4.39. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 4'e ait ölçüm ve dağılım grafiği.....	50
Şekil 4.40. Askıdaki sediment miktarı test verileri için DVM- PÇF 4'e ait saçılım grafiği.....	51
Şekil 4.41. Askıdaki sediment miktarı test verileri için DVM- PÇF 4'e ait ölçüm ve dağılım grafiği.....	51
Şekil 4.42. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 5'e ait saçılım grafiği.....	52
Şekil 4.43. Askıdaki sediment miktarı eğitim verileri için DVM- PÇF 5'e ait ölçüm ve dağılım grafiği.....	52
Şekil 4.44. Askıdaki sediment miktarı test verileri için DVM- PÇF 5'e ait saçılım grafiği.....	53
Şekil 4.45. Askıdaki sediment miktarı test verileri için DVM- PÇF 5'e ait ölçüm ve dağılım grafiği.....	53
Şekil 4.46. Askıdaki sediment miktarı eğitim verileri için GRYSA 1'e ait saçılım grafiği.....	54
Şekil 4.47. Askıdaki sediment miktarı eğitim verileri için GRYSA 1'e ait ölçüm ve dağılım grafiği.....	55

Şekil	Sayfa
Şekil 4.48. Askıdaki sediment miktarı test verileri için GRYS A 1'e ait saçılım grafiği.....	55
Şekil 4.49. Askıdaki sediment miktarı test verileri için GRYS A 1'e ait ölçüm ve dağılım grafiği.....	56
Şekil 4.50. Askıdaki sediment miktarı eğitim verileri için GRYS A 2'ye ait saçılım grafiği.....	56
Şekil 4.51. Askıdaki sediment miktarı eğitim verileri için GRYS A 2'ye ait Ölçüm ve dağılım grafiği.....	57
Şekil 4.52. Askıdaki sediment miktarı test verileri için GRYS A 2'ye ait saçılım grafiği.....	57
Şekil 4.53. Askıdaki sediment miktarı test verileri için GRYS A 2'ye ait ölçüm ve dağılım grafiği.....	58
Şekil 4.54. Askıdaki sediment miktarı eğitim verileri için GRYS A 3'e ait saçılım grafiği.....	58
Şekil 4.55. Askıdaki sediment miktarı eğitim verileri için GRYS A 3'e ait ölçüm ve dağılım grafiği.....	59
Şekil 4.56. Askıdaki sediment miktarı test verileri için GRYS A 3'e ait saçılım grafiği.....	59
Şekil 4.57. Askıdaki sediment miktarı test verileri için GRYS A 3'e ait ölçüm ve dağılım grafiği.....	60
Şekil 4.58. Askıdaki sediment miktarı eğitim verileri için GRYS A 4'e ait saçılım grafiği.....	60
Şekil 4.59. Askıdaki sediment miktarı eğitim verileri için GRYS A 4'e ait ölçüm ve dağılım grafiği.....	61
Şekil 4.60. Askıdaki sediment miktarı test verileri için GRYS A 4'e ait saçılım grafiği.....	61
Şekil 4.61. Askıdaki sediment miktarı test verileri için GRYS A 4'e ait ölçüm ve dağılım grafiği.....	62
Şekil 4.62. Askıdaki sediment miktarı eğitim verileri için GRYS A 5'e ait saçılım grafiği.....	62
Şekil 4.63. Askıdaki sediment miktarı eğitim verileri için GRYS A 5'e ait ölçüm ve dağılım grafiği.....	63

Şekil	Sayfa
Şekil 4.64. Askıdaki sediment miktarı test verileri için GRYSA 5'e ait saçılım grafiği.....	63
Şekil 4.65. Askıdaki sediment miktarı test verileri için GRYSA 5'e ait ölçüm ve dağılım grafiği.....	64



SİMGELER VE KISALTMALAR

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

Simgeler

p	Yağış
q	Debi
r	Korelasyon katsayısı
s	Katı madde miktarı
t	Sıcaklık

Açıklamalar

Kısaltmalar

DVM	Destek vektör makinesi
DVM-PÇF	Polinom çekirdek fonksiyon destek vektör makinesi
DVM-RBF	Radyal taban fonksiyon destek vektör makinesi
GRYSA	Genelleştirilmiş yapay sinir ağı
KKOH	Ortalama karasel hataların karakökü
KMAE	Katı madde anahtar eğrisi
MOH	Mutlak ortalama hata
PPM	Katı madde konsantrasyonu
USGS	United States geological survey
YSA	Yapay sinir ağı

Açıklamalar

1. GİRİŞ

1.1. Suyun Önemi


Su; çok eski çağlardan beri, hem küresel boyutta hem de yaşayan canlılar için en değerli doğal kaynaklardan biridir. Bu yüzden canlıların yaşamlarını devam ettirmesi için büyük öneme sahiptir. İnsan vücudu için de suyun var olması büyük önem taşır. Metabolizmamız suyu depolayamadığı için kaybolan su miktarını sürekli olarak yenilememiz gerekir. İnsan vücudunun üç de ikisi sudur. Vücudumuzda ki su oranı cinsiyet, yaş, fiziksel özellikler ve günlük fiziksel aktivitelerine göre farklılık gösterip, her insanın günde yaklaşık 2 litre suya ihtiyacı vardır. Bu oranlardan da anlaşılacağı üzere hiçbir şey susuz yaşayamaz; su, temel enerji kaynağıdır ve vücudun her hücresinde elektriksel ve manyetik enerji üreterek bize yaşam enerjisi sağlayan temel maddesidir. Ayrıca kimyasal bileşiminde bulundurduğu çok farklı özellikler sayesinde, dünya yüzeyinin ve atmosferinin şekillenmesini sağlamış, yaşamın ortaya çıkıp gelişmesinde ve devamlılığının sürdürülebilmesi açısından da vazgeçilmez bir önemi vardır. Dünya yüzeyinin yüzde 71'i su ile kaplıdır; bunun da yüzde 97'sini okyanuslar ve geri kalanını ise buzullar, kutup buzları, göller, nehirler vb. oluşturur. Nüfusun günden güne artması ile birlikte, buna karşın tatlı su kaynaklarının sabit olması sebebiyle su ihtiyacı her geçen gün artmaktadır. Kişi başına su tüketimi yılda ortalama 800 m³ civarındadır. Dünya nüfusunun yaklaşık % 20'sine karşılık gelen 1,4 milyar insan yeterli içme suyundan mahrum olup, 2,3 milyar kişi sağlıklı suya hasrettir. Bu nedenlerden ötürü su kaynaklarını doğru kullanmak ve bu kaynakları en sağlıklı bir şekilde değerlendirerek gelecek nesle doğru aktarmak hayati bir önem arz etmektedir.

Hayatın temel parçası olan su, bizlerin var olmasındaki en değerli etken, tarih boyunca medeniyetlerin en güçlü silahı, yeri gelince savaş sebebidir. Özetle su; hayattır, yaşamın sürdürülebilmesi için vazgeçilemez temel madde olup, dünya üzerindeki miktarının sabit olması nedeni ile en iyi şekilde değerlendirmeli, korunmalı ve işletilmelidir.

1.2. Akarsu Morfolojisi

Akarsu; yeryüzünde ve yer altında belirli bir yatak içinde yüzey eğimi yönünde sürekli ya da zaman zaman akan suların genel adıdır. Akarsular, yığılma ve taşıma ile yeryüzünün şekillenmesini etkileyen dış etkenlerden biridir. Yer kabuğunun belirli bir alanının sularını

biriktirerek hidrolojik çevrimin önemli bir halkasını oluştururlar. Akarsuyun sularını topladığı alana 'akarsu havzası', bu akarsu havzalarını birbirinden ayıran çizgiye de 'su ayırım çizgisi' denir. Bir akarsuyun hazne veya göl ya da deniz ile birleştiği yere 'ağız' denir. Akarsuların ağız bölümünde katı maddelerin birikmesi sonucu oluşan geniş çaplı birikinti depolarına 'delta' denir. Bir akarsu kesitinin ağız tarafında kalan bölümüne 'mansap bölgesi', kaynak tarafında kalan akarsu bölümüne ise 'mema bölgesi' denir. Aşağıdaki Şekil 1.1.'de bir Akarsu planı gösterilmiştir.



Şekil 1.1. Bir akarsuyun planı

1.3. Akarsularda Katı Madde Hareketi

Katı maddeler, akarsularda su ile birlikte taşınır. Bu katı maddeler ya akarsu yatağındaki aşınmalardan ya da akarsu havzasındaki erozyondan kaynaklanır. Akarsularda taşınan sediment (katı madde) miktarını tespit etmek, su kaynaklarının projelendirilmesi açısından önemlidir. Nehirlerde taşınan katı madde miktarının tahmininde, akarsu yapılarının doğru planlanıp ve projelendirilmesi önemli bir yer teşkil eder.

Katı madde hareketleri sonucu akarsu yatağında oyulma ve yığılmalar meydana gelir. Bu yığılmalar ve oyulmalar sonucunda akarsuyun morfolojik yapısı değişir. Bu problemlerin doğru analizi için katı madde tahminlerine ihtiyaç duyulmaktadır. İnce taneli katı maddeler yüksek hızlarla, su kuvveti tesislerin de aşındırmaya sebep olabilir. Aynı zamanda bu katı maddeler iri kaya şeklinde olursa akarsu üzerinde yapılacak yapılara zarar verebilir. Akım

hızının kritik hızın altına düştüğü yerlerde, akarsuların taşıdığı katı maddeler birikme gözlenir. Bu bölgedeki bu birikmeler, akarsu kesitindeki düzensizliklere sebep olur.

Su rejimi düzensiz akarsularda, eğimin ve hızların büyük olmasıyla orantılı bir şekilde taşınan katı madde de artar. Ayrıca, nehirlerde artan katı maddeler baraj haznelerindeki ölü hacim kapasitesinin artmasına sebep olarak hem maliyeti artırır hem de baraj hazne kapasitesini azaltır ve kapasitenin azalması sonucu tesisin ekonomik ömrünü etkiler. Baraj haznesinde ölü hacim denilen bu pasif hacmin gerçekçi bir şekilde tespit edilebilmesi, katı madde değişiminin doğru bir şekilde tespiti ile mümkündür. Diğer bir değişle barajın verimli ömrü yani hizmet süresi bu hacmin büyüklüğünün doğru tespiti ile direkt bağlıdır. Barajın ekonomik olması ve yapının işlevselliğinin artırılabilmesi için ölü hacminin doğru hesaplanıp, gereğinden ne büyük nede küçük olması gerekir. Ölü hacim gereğinden büyük olduğu takdirde barajın yapım maliyeti artar ve barajdaki diğer bölümlerin verimli ve aktif çalışmasını engelleyebilir. Ölü hacim gereğinden küçük ise, katı madde baraj dışına aktarılamaz ve bunun sonucunda baraj, amacına hizmet etmemiş olur. Bu tip problemlerden dolayı baraj projelendirilmelerinde, katı madde miktarı ve türlerinin doğru tahmin edilmesi gerekir.

Baraj haznesine giren katı maddelerin tamamını engellemek imkânsızdır. Ancak katı maddenin kaynağının doğru tespit edilerek bazı önlemler alınırsa bu miktar azaltılabilir. Bunlar arasında en önemlileri; akarsu havzasında erozyonu azaltıcı tedbirler almak, nehir kesitlerinin ve akımın düzenlenmesi en önde gelen katı maddeyi azaltma yöntemlerinin başında gelir. Akarsularda taşınan katı madde miktarı, suyun ve katı maddenin özelliklerine bağlıdır. Akımın değişken olması zaman içinde değişmesi, katı madde hareketinin kontrol edilmesini daha da zor hale getirmektedir. Bu katı madde hareketi ayrıca akarsuyun su kalitesini de olumsuz yönde etkilemekte ve su kalitesi modellemesini de zorlaştırmaktadır. Bu neden ile su yapılarının projelendirilmesi ve bu yapılara etkilerinin kontrolü için katı madde miktarının değişiminin doğru belirlemek ve katı madde hareketini iyi analiz etmek gerekmektedir.

1.4. Akarsuların Taşıdığı Katı Maddelerin Sınıflandırılması

Akarsuların taşıdığı katı maddeler malzeme kaynağına ve akarsu taşınım şekline göre iki sınıfa ayrılır.


Malzeme kaynağına göre sınıflandırılması

Yatak malzemesi; akarsu yatağında bulunan hareketli tabanı oluşturan malzemedir. Yıkama malzemesi ise yatak malzemesinden daha ince bir malzemeye sahip olup havza erozyonundan gelen malzemedir. Yıkamış malzeme akarsuyun havza büyüklüğüne, topoğrafik özelliklerine ve bölgenin yağış şartlarına bağlıdır (Erkek ve Ağırlioğlu, 1993).

Akarsudaki taşınım şekillerine göre sınıflandırılması

Askı malzemesi; akım şiddeti ile birlikte yataktaki malzeme, akarsu yatağından ayrılıp suyun içinde askı halinde hareket etmeye başlar ve bu şekilde hareket eden malzemeye askı malzemesi denir.


Sürüntü malzemesi ise, akarsuda, akımın etkisinde kayarak ve sürünerek hareket eden malzemedir. Bu şekilde hareket eden katı maddeler yatakla bağlantılı olup, akım şartları ve hızlar arttıkça askı maddesi şeklinde hareket edebilir. Şekil 1.2.'de Askı ve Sürüntü malzemesinin hareket türleri gösterilmiştir.



Şekil 1.2. Akarsudaki katı maddelerin hareket ve taşınım türleri

Askı malzemesi, sürüntü malzemesine göre daha ince çaplıdır. Bu iki malzemeyi birbirinden net bir şekilde ayıran bir tane çapı bulunmamaktadır. Katı madde hareketini etkileyen temel

parametreler akım hızı ve tane çapıdır. Düşük hızlı akımlı bölgede sürüntü halinde olan malzeme, hızlı akımlı bölgede askı haline geçebilir. Şekil 1.3.'de Katı maddenin su derinliğine bağlı dağılımı gösterilmiştir.



Şekil 1.3. Katı maddenin su derinliğine bağlı dağılımı (Erkek ve Ağırlioğlu, 1993)

Genelde, Akarsularda katı madde hareketi incelenirken taşınma şekline göre yapılan sınıflandırma daha çok tercih edilmektedir. Askı maddesiyle birlikte sürüntü maddesinin toplamına 'toplam katı madde' denir.

Hareket eden katı madde miktarı, birim zamanda taşınan kuru ağırlık ya da birim zamanda taşınan kuru hacim olarak ifade edilir. Suyun içindeki askı maddesi miktarının, su ve askı maddesi karışımı oranına 'katı maddesi konsantrasyonu' denilmektedir. Birim olarak milyon metreküpde metreküp ($m^3/10^6 m^3$) veya litrede miligram (mg/l) cinsinden ifade edilir ve ppm olarak gösterilir (Erkek ve Ağırlioğlu, 1993).

Akarsularda katı madde tanesinin harekete başlaması, akım tarafından taşınması sadece akımın değil aynı zamanda tanenin özelliklerinede bağlıdır. Tanenin en önemli özelliğinin tane çapı olduğu ifade edilebilir. Bazı zamanlarda katı madde tanelerini tanımlamak için sadece ortalama çapı kullanmak yetsede, genellikle tanenin özgül ağırlığı, tane biçimi, granülometri gibi başka özelliklerinede dikkata almak gerekir.

2. ÖNCEKİ ÇALIŞMALAR

Akarsulardaki katı madde miktarları, katı madde denklemleri ya da katı madde gözlem istasyonlarından yapılan ölçümlerle belirlenmektedir. Bu gözlemin ölçümlerle yapılması kesin ve en doğru yöntemdir. Fakat bu yöntem maliyetli olup zaman alır. Bazı gözlem istasyonlarında debi ölçülürken, katı madde miktarı ölçümleri yapılmamaktadır.

Hidrolojiyi etkileyen olaylar, birçok parametrelerden oluştuğu için klasik yöntemlerle uygun modeller oluşturulamaz. Bu parametreler arasındaki ilişki genelde doğrusal olmayıp, birbirinden bağımsız olabilmektedir. Bu ilişkinin belirlenmesi zor olacağından, doğrusal olmayan problemler için basit ekonomik ve zaman almayan yöntemler geliştirilmiştir. Katı madde miktarını belirlemek için yapay zeka tekniklerinde içinde olduğu birçok yöntem bulunmaktadır. Tercih edilen yapay zekâ metotları arasında yapay sinir ağları (YSA) ve bulanık mantık (BM) gibi bilimsel yöntemler en başta bulunmaktadır.

Baltacı (2012), Sacramento nehrindeki askı maddesi miktarının tahmini için bulanık modeller (BM) kurmuş ve katı madde anahtar eğrileri (SRC) ile çoklu regresyon (ÇLR) sonuçlarını karşılaştırmıştır. Amerika Birleşik Devletleri'ndeki Kaliforniya Eyaleti'nde bulunan Sacramento nehri üzerindeki freeport istasyonunun günlük gerçek zaman debi, askı malzemesi konsantrasyonu ve ortalama sıcaklık verilerini kullanmıştır. Karşılaştırma yaparken 50 yıllık verileri kullanmış ve son 5 yıllık veri sonuçlarını ayrı inceleyip 50 yıllık verilerle karşılaştırmıştır. Araştırma yaparken korelasyon katsayısı (R), en düşük karesel hata (MSE) ve toplam karesel hata (MAE) istatistiklerini kullanmıştır. Elde ettiği sonuçlara göre bulanık modellerin, diğer modellere karşılaştırdığında daha iyi sonuçlar verdiğini belirtmiştir.

Hipni ve arkadaşları (2013), bu çalışmalarında baraj su seviyesini tahmin etmek için destek vektör makinesi (DVM) modellemesini çalışmışlardır. En doğru modeli belirlemek için 4 kategori tanımlamışlardır; zaman gecikmesi, giriş senaryosu, DVM regresyonunun tipi ve V-katlanma çarpaz doğrulama sayısı. En iyi girdi senaryosunda hem baraj su seviyesi $L(t-i)$ hemde yağış $R(t-i)$ 'i kullanmışlardır. Tip 2 DVM regresyonu en iyi regresyon tipi olarak seçmişlerdir ve 5 kat çarpaz doğrulamanın en doğru sonuçları verdiğini gözlemlemişlerdir.

Sonuçları, yapay sinir ağları (YSA) kullanılarak elde edilen sonuçlarla karşılaştırmışlardır. DVM modellerinin diğer modellere kıyasla daha iyi sonuçlar verdiğini belirtmişlerdir.

Kaya ve arkadaşları (2016), Florida Eyaletindeki ABD meteorolojik istasyonundan aldıkları günlük güneş radyasyonu (GR), hava sıcaklığı (HS), bağıl nem ve rüzgar hızı (U) verilerini, buharlaşma çalışmaları için kullanmışlardır. Model sonuçlarını Turck ampirik formülü ile karşılaştırmışlardır. M5 ağacı veri madenciliği yönteminin Turc ampirik formülünden daha iyi bir performansa sahip olduğunu belirtmişlerdir.

Hidrolojik süreçlerin titizlikle tahmin edilmesi, özellikle akarsu akımları, su bütçesi ve çevre yönetim planlarında önemli bir yere sahiptir. Öte yandan, kurak ve yarı kurak alanlarda temel bir kaynak olan yer altı suyunun korunması, kalkınma planlarında büyük bir öncelik olarak düşünülmelidir. Kişi ve arkadaşları (2016), yapay zeka yöntemlerini kullanarak doğu Azerbeycan Azarshahr ovasında çalışma yaparak yeraltı su seviyesindeki değişimleri incelemişlerdir. Sonuç olarak, yeraltı su seviyesi değişimlerinin incelenmesinde yapay zeka yöntemlerinin başarısını ve bunun önemini ifade etmeye çalışmışlardır.

Zhoua ve arkadaşları (2016), Çin'deki Three Gorges Rezervuarında Bazimen toprak kaymasını öngörmeye destek vektör makinesi (DVM) birleştirme modelini uygulamışlardır. DVM modelini, yağış faktörlerine, rezervuarın değişim aralığına ve önceki dönemlerin yer değiştirmelerine dayanarak periyodik yer değiştirmeyi öngörmek için önermişlerdir. Bazimen heyelanı olarak bilinen Three Gorges rezervuarındaki tipik basamak benzeri heyelanı, tahmin sonuçlarını doğrulamak için örnek bir bölge olarak seçmişlerdir. Çalışmada, önerilen DVM modelini ölçülen değerle ile karşılaştırmışlar bu modelin uygulanabilirliğinin öneminden bahsetmişlerdir.

Hui ve arkadaşları (2017), bu çalışmalarında Yangtze havzası'ndaki altı istasyona ait günlük hava sıcaklığı, güneş radyasyonu, hava basıncı ve rüzgar hızı gibi verileri kullanarak yapay zeka yöntemleriyle elde edilen sonuçları buharlaşma tahmini için karşılaştırmışlardır. Bulanık Mantık modelinin genel olarak, yapay sinir ağları ve M5 model ağacı modelinden, daha iyi sonuçlar verdiğini gözlemlemişlerdir. Sonuçta, buharlaşmayı tahmin ederken bulanık mantık modelinin başarılı bir şekilde kullanılabileceğini göstermişlerdir.

Askıya alınmış katı madde miktarının tahmini, su kaynakları yönetimi ve su kalitesi problemi için önemlidir. Taşar ve arkadaşları (2017), bu çalışmalarında ABD'deki Iowa istasyonundan alınan günlük verilerle; yapay sinir ağları (YSA), M5 ağacı yaklaşımları, çoklu doğrusal regresyon ve sediment değerlendirme eğrileri gibi istatistiksel yaklaşımları birbirleriyle karşılaştırmışlardır. Karşılaştırma kriteri olarak, ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve korelasyon katsayısını seçmişlerdir. Sonuçları karşılaştırdıklarında YSA modelinin diğer modellere göre daha iyi tahminde bulunduğunu belirtmişlerdir.

Ağtaş (2017), bu çalışmasında yapay zeka yöntemlerinin akarsularda taşınan katı madde miktarını tahmin etmek için kullanılabilirliğini araştırmıştır. Model olarak bulanık mantık ve yapay sinir ağlarını seçmiştir. Araştırmasında, Devrek ve Devrekani çaylarına ait akım ve sediment verilerinden faydalanmıştır. Çeşitli yapay zeka yöntemleri ile günlük ve aylık akım verilerinin kullanarak günlük taşınan katı madde tahmin modellerini geliştirmiştir. Ölçülen sonuçlar ile yapılan karşılaştırmaları incelediğinde, yapay zeka modellerinin akarsularda taşınan katı madde miktarı tahmininde başarılı bir şekilde uygulanabileceğini göstermiştir.

Hava durumu tahminleri, özellikle yağış tahmini, karmaşık denklemler ortaya koyar. Çünkü, zaman zaman değişen sıcaklık, nem, rüzgâr hızı ve yönü gibi bağımlı değişkenlerle ilişki içerisindedir. Yan ve arkadaşları (2017), geleneksel yağışta kullanılan doğrusal eşik değerinin yerini alan destek vektör makinesi'ne dayanan yağış tahmini için bir tahmin modeli oluşturmuşlardır. Bu modelin eğitimi için tarihsel verileri kullanarak araştırmalarını yapmışlardır. Diğer modellerle kıyasladıkları zaman, DVM modelinin çok daha iyi bir doğruluğa sahip olduğunu söylemişlerdir.

Üneş ve arkadaşları (2017), bu çalışmalarında, destek vektör makineleri (DVM) kullanarak buharlaşma modellemesi üzerine araştırma yapmışlardır. Bu model için günlük güneş radyasyonu, hava sıcaklığı, rüzgar hızı ve bağıl nem gibi meteorolojik parametreleri kullanarak 2 farklı model olan DVM ve Hargreaves-Samani formülünü karşılaştırıp buharlaşmayı tahmin etmeye çalışmışlardır. Veri kümesi olarak St. Johns, Florida, ABD hava istasyonundan almışlardır. Sonuç olarak DVM yönteminin günlük buharlaşma tahmini için başarılı sonuçlar verdiğini göstermişlerdir.

Yang ve arkadaşları (2019), bu çalışmalarında, Çin'deki üç boğaz rezervuar alanında yaygın olarak ölçülen meteorolojik değişkenleri kullanılarak aylık tava buharlaşması tahmininde destek vektör makinesinin (DVM) performansını araştırmışlardır. DVM modelinin dikkate değer performans gösterdiğini ve ampirik modelden önemli ölçüde daha iyi performans gösterdiğini göstermişlerdir. Sonuç olarak, DVM yönteminin ölçülen meteorolojik değişkenlerden tava buharlaşmasını tahmin etmek için geleneksel yaklaşımlara göre daha başarılı bir alternatif olacağını göstermişlerdir.

Taşar ve arkadaşları (2018), bu çalışmalarında, ABD Massachusetts Cambridge hazne ve havzasında günlük buharlaşma miktarını tahmin etmeye çalışmışlardır. Veri olarak günlük hava sıcaklığı, rüzgar hızı, bağıl nem ve güneşlenme miktarını kullanmışlardır. Turc, Ritchie ve Hargreaves-Samani denklemleri gibi ampirik (geleneksel) yöntemler ile yapay sinir ağları (YSA) yöntemi sonuçlarını karşılaştırmışlardır. Sonuç olarak, YSA modelinin buharlaşma miktarı tahmininde, klasik yöntemlerden daha iyi bir performans verdiğini ortaya koymuşlardır.

Ghose ve arkadaşları (2019), bu çalışmalarında 48 yıllık verileri kullanarak Bolangir, Odisha, Hindistan'daki yağış tahminlerini incelemek için çeşitli yapay zeka yöntemlerini kullanmışlardır. Yapay sinir ağları (YSA) ve destek vektör makinesi (DVM) yaklaşımlarının verimliliğini değerlendirmek için tahmin girdileri olarak geçmiş yağış değerlerinin farklı kombinasyonlarını oluşturmuşlardır. DVM, hem test hem de eğitim aşaması için 0.9526 ve 0.9738 belirleme katsayısı ile daha iyi performans verirken, YSA durumunda 0.9342 ve 0.9488 verdiğini tespit etmişlerdir. Sonuç olarak DVM modelinin YSA modeline göre daha iyi sonuçlar verdiğini belirtmişlerdir.

Moeini ve arkadaşları (2019), bu araştırmalarında Yapay sinir ağı (YSA) ve destek vektör makinesi (DVM) modelleri kullanılarak Zayandehroud baraj rezervuarına girişi tahmin etmek için farklı yeni girdi modelleri önermişlerdir. Baraj rezervuarına girişi öngörmek için, zaman indeksi, zaman gecikmeleri, ve aylık Ghaleh-Shahrokh istasyonunun aylık yağışları göz önüne alındığında, baraj rezervuarına giriş gibi farklı girdi verisi modellerine sahip dokuz farklı model önermişlerdir. DVM modelinin sonuçlarının YSA modelinden daha iyi bir performans gösterdiğini belirtmişlerdir.

Allawi ve arkadaşları (2019), bu çalışmalarında iklim koşullarının bir rezervuardan buharlaşmayı öngörme üzerindeki etkisini farklı yapay zeka yöntemleriyle incelemişlerdir. Radyal temel fonksiyonlu yapay sinir ağının (YSA-RTF) ve destek vektör makinesi (DVM) yöntemlerinin Malezya Lahor rezervuarı, Malezya'daki bir tropik alan için buharlaşma oranı tahmin modeli geliştirme yeteneğini araştırmışlardır. Sonuç olarak DVM Modelinin bu araştırmada doğru bir model olduğunu belirtmişlerdir.

He ve arkadaşları (2019), Hem geleneksel hem de geliştirilmiş önyargı hata kontrol terimi dahil edilerek en az gelişmiş kareler destek vektör makinesi modelleri ile Çin'in Yangtze nehrinin orta kesimlerinde su seviyesinin kısa vadeli tahmininde bulunmaya çalışmışlardır. Her iki modelde de ortalama kare hatası, ortalama mutlak yüzde hatası ve anlaşma endeksi (d) gibi ölçütler kullanılarak değerlendirmeler yapmışlardır. Sonuç olarak, DVM tipi modellerin zaman dizisi problemlerini çözmedeki yeteneklerini ve esnekliklerini göstermişlerdir.

Li ve arkadaşları (2019), bu çalışmalarında, üç farklı havzada simülasyon ve tahmin akışı için destek vektör makinesi (DVM) ve yapay sinir ağı (YSA) modellerini uygulayarak farklı jeo-iklim sistemini temsil edebilecek hidrolojik modeller geliştirmeye çalışmışlardır. Çin'de nemli ve yarı nemli alanlar sık sık sel olaylarından, yarı kurak alanlar ise akışın artmasına katkıda bulunan kentleşme ve iklim değişikliği nedeniyle flaş selinden muzdarip olduğunu ifade etmişlerdir. İki modelide karşılaştırdıklarında, her iki modelin nemli ve yarı nemli sistemler için iyi performans gösterdiğini ve DVM'nin tüm havzaların akış akışı simülasyonunda genellikle YSA'dan daha iyi performans gösterdiğini belirtmişlerdir.

3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı


Bu çalışmada Missouri nehri üzerinde katı madde tahmini için; katı madde anahtar eğrisi (KMAE), destek vektör makinesi (DVM)' ne ait radyal tabanlı destek vektör makinesi fonksiyonu (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makinesi (DVM-PÇF) ve genelleştirilmiş yapay sinir ağı (GRYSA) modelleri incelenmiştir. Çalışma alanı olarak Amerika Birleşik Devletleri'ndeki Nebraska Eyaleti'nde bulunan Dauglos country bölgesi (Hidrolojik Ünite No; 1023000) seçilmiştir. Missouri nehri üzerindeki Omaha istasyonu incelenmiştir (USGS İstasyon No:06610000). Enlem $41^{\circ}15'32''$, Boylam $95^{\circ}55'20''$ (NAD27 Kuzey Amerika Verisi). Bu çalışmada veri olarak, Omaha istasyonuna ait 6 yıla yakın su yılı ölçümleri için uygulama yapılmış ve veriler USGS (United States Geological Survey) ve www.usclimatedata.com web sayfalarından alınmıştır. Missouri nehri Douglos istasyonundan alınan günlük sıcaklık, yağış, akım debisi ve katı madde konsantrasyonu verileri kullanılarak modeller arasında hangisinin daha iyi sonuç verdiği incelenerek karşılaştırma yapılmıştır. Modellerin oluşturulması amacı ile düzenlenen verilerin yaklaşık 6 yıla yakın toplam 2139 günlük verinin 1604'ü eğitim için, son 535 günlük veri de test için kullanılmıştır. Şekil 3.1., Şekil 3.2., ve Şekil 3.3.'de Missouri nehrinin genel görünümü ve seçilen bölgenin görünümü gösterilmiştir.



Şekil 3.1. Missouri nehrinin genel görünümü (Google)



Şekil 3.2. Missouri nehri üzerindeki ölçülen istasyonun yerinin görünümü (USGS)




Şekil 3.3. USGS Missouri nehri üzerindeki Douglos istasyonun detay görünümü (USGS)


Missouri nehri, kuzey Amerika'daki en uzun nehirdir. Batı Montana'daki Rocky dağlarından doğan Missouri, Missouri'deki St. Louis kentinin kuzeyinde Mississippi nehri ile birleşmeden önce doğuya ve güneye doğru 2,315 mil (3,726 km) boyunca hareket etmektedir. Dünyanın dördüncü en uzun nehridir. Missouri nehri, devletin kuzey kesimi boyunca doğuya dönmeden önce ilk önce batı Montana'dan kuzeye ve kuzeydoğuya doğru (Büyük Şelaleler yoluyla) akar. Güney Dakota üzerinden devam eden nehir, daha sonra Güney Dakota - Nebraska sınırı, Nebraska - Iowa sınırı, Nebraska - Missouri sınırı ve Kansas'ın kuzey kesiminin bir bölümünü oluşturur.

Nehrin drenaj havzası, yaklaşık 1.371.100 km² olan büyük ovaları işgal etmekte olup, bunlardan 2.550 km² güney Kanada'dadır. Havzasındaki yükselti aralığı oldukça fazladır: Continental Divide yakınındaki Colorado Rocky'deki deniz seviyesinden 4.300 m yüksekte , Mississippi'ye katıldığı 120 m'dir. Missouri ve yan kollarının çoğunun akışı son derece değişkendir. Korunmasız eğimler ve akıştaki şiddetli dalgalanmalar nedeniyle, erozyon ve taşıdığı katı maddeler, önemli problemlerinden biridir.


Geniş sıcaklık aralıkları ve düzensiz yıllık ve mevsimsel yağışlar Missouri havzasının iklimini karakterize eder. Sıcaklıktaki aşırı uçlara, kuzeybatıdan içeri giren alternatif soğuk hava kütleleri ve Meksika körfezinden gelen sıcak hava kütleleri neden olur. Rüzgar yönleri yaz aylarında güney ve güneybatıdan, kışın ise kuzey ve kuzeybatıdan olma eğilimindedir. Maksimum rüzgar hızları saatte 72 ila 193 km arasındadır. Büyük ovalar genellikle daha yüksek hızları kaydeder. Yüksek sıcaklıklı şiddetli rüzgarlar buharlaşmayı artırır, mahsullere zarar verir ve toz fırtınasına neden olur. Kış mevsiminde yüksek rüzgarlar ve düşük sıcaklıklar kar ve kar fırtınasına neden olur. Yıllık yağış miktarı, şekli ve mevsimsel değişimleri alanın topografyası ile ilgilidir. Ortalama en fazla yağış miktarı: Rocky Dağları ve Ozarks bölgeleri arasındadır. Rocky dağları boyunca kar yağışı yaygındır. Bu alanın kuzeyindeki yıllık yağışlar, yaz yağmurları ve kış karları arasında bölünürken, güney kısmının yıllık yağışları neredeyse tamamen yıl boyunca meydana gelen yağışlardır. Rocky'deki taşkınlar genellikle ılık mevsimde, özellikle daha küçük akarsularda meydana gelen taşkın selleridir. Bu tip hidrolojik düzensizlikler bu nehir üzerinde katı madde problemlerine sebep olmaktadır.




Şekil 3.4. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında debi miktarı değişimleri



Şekil 3.5. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında hava sıcaklığı değişimleri



Şekil 3.6. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında Yağış değişimleri



Şekil 3.7. Missouri nehri üzerindeki Omaha istasyonunun 2011-2017 yılları arasında Sediment miktarı değişimleri

3.2. Kullanılan Modeller

Bu çalışmada Missouri nehrindeki Nebraska eyaleti Omaha istasyonunda 2011-2017 yılları arasında ölçülen nehir debisi, hava sıcaklığı, yağış gibi hidro-meteorolojik parametreler kullanılarak katı madde miktarı tahmin modellemesi yapılmıştır. Katı madde miktarının tahmini için; katı madde anahtar eğrisi (KMAE) ve literatürde yapay zeka yöntemleri arasında yer alan radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) kullanılmıştır.

3.2.1. Katı madde anahtar eğrisi (KMAE)

Katı madde anahtar eğrisi (KMAE), akarsuların herhangi bir kontrol kesitinde ölçülen katı madde miktarı ve akım debisi arasındaki ilişkiyi gösterir. Katı madde konsantrasyonunu S ve akım debisi Q ile gösterilirse, bu ikisi arasındaki bağlantı;

$$S=aQ^b \quad (3.1)$$


şeklinde bir fonksiyonel ilişki ile ifade edilir. Bu ilişkiyi logaritmik tabana döndürdüğümüzde;

$$\log S=a+b\log Q \quad (3.2)$$

ifadesi elde edilir. Bu denklemde $\log Q$ ve $\log S$ arasında lineer regresyon kurularak elde edilen a ve b ise nehir akımı karakteristiğine bağlı katsayıları göstermektedir (Vansickle, 1983; Demiröz, 1989; Crawford, 1991; Salas, 1999). Denklemdeki a ve b değerleri S ve Q arasındaki bağıntıya göre oluşturulan denklemlerden bulunur. Katı madde tahminlerinde kullanılmakta olan bu eğriler ile ortalama aylık ya da yıllık katı madde miktarlarının tahmini yapılabilmektedir.

(3.1) eşitliğinde verilen S-Q ilişkisini inceleyen geniş bir çalışmada (Williams, 1978), tek tip bir ilişkinin olmadığını göstermiştir. Bazı akarsularda S-Q ilişkisi, iki kollu bir değişim izlemektedir. Bu değişim Şekil 3.8.'de gösterilmiştir. Hidrolojik sebeplerden dolayı, akımın farklı zamanlarındaki katı madde miktarı aynı akım debisi değeri için farklı olabilmektedir.

Bazı zamanlarda, bu eğriler kullanılarak doğru katı madde tahmini yapılamamakta ve yetersiz kalmaktadır.



Şekil 3.8. S-Q ilişkilerinde doğrusal olmayan bir değişim


3.2.2. Destek vektör makinesi (DVM)

Sınıflandırma sorunlarının çözümüne ilişkin yapılan araştırmalarda, makine öğrenimi önemli yer tutmaktadır. Özellikle, kimya, sosyal medya, bankacılık, tıp, sigorta ve mühendislik bilim dalı gibi alanlarda sınıflandırma problemleriyle sıkça karşılaşılmaktadır. Bu sebeple, son zamanlarda sınıflandırma problemlerinin çözümü, makine öğrenimine önemli bir şekilde katkı vermiştir. Makine öğrenimi algoritmasının belirlenmesinde dikkat edilmesi gereken en önemli hususlardan biri, algoritmanın genelleme performansıdır. Genelleme başarısı, modelin belirlenmesi, eğitim verisi, bağımsız girdilerin sayısı ve parametre seçimi gibi faktörlere bağlı olarak farklılık gösterir. Algoritmanın genelleme başarısı ne kadar iyi olursa enformasyon da o kadar gerçekçi olacaktır. Son zamanlarda sınıflandırma problemlerinin çözümü için geliştirilen en başarılı algoritmalarından biri Destek Vektör Makineleridir. Bu makine öğrenimi genelleme başarısı yüksek ve birçok sınıflandırma problemlerinin çözümünde başarıyla uygulanmış algoritmalarından biri olarak kaynaklardaki yerini almıştır.

Regresyon ve sınıflandırma formlarını içeren destek vektör makineleri (DVM), Vapnik tarafından sağlam ve önemli bir öğrenme aracı olarak tanıtılmıştır (Vapnik, 1995). O zamandan beri, DVM'lerin uygulamaları ile ilgili zaman geçtikçe artan sayıda araştırmalar


yapılmıştır. Son yıllarda, DVM'ler su kaynakları alanlarında yeni bir öğrenme yaklaşımı olarak kullanılmıştır.. DVM'ler ,yapay sinir ağı (YSA) gibi diğer veri odaklı modellerle karşılaştırıldığında genel olarak üstün performans sunmuştur. Genele bakıldığında, destek vektör makinesi pratikte başarılı sonuçlar vermektedir.. Bu performans, DVM' lerin yüksek genelleme özelliğinden kaynaklanmakla birlikte araştırmacıyı da ilerideki uygulamalar üzerinde çalışmaya motive etmektedir. Esas düşünce, destek vektör makinesi kullanılarak x 'in orijinal verilerini, çoğunlukla bilinmeyen ve doğrusal olmayan haritalama fonksiyonu ile daha yüksek boyutsallığa sahip bir fonksiyona taşımak ve daha devamında özellik uzayında doğrusal regresyona devam etmektir.

Destek vektör makinesini verimli bir şekilde kullanmak için, DVM'nin çalışma sistemini iyi bilmek gerekir. DVM eğitilirken bir çok konuda doğru karar vermek gerekir. Mesela ilk olarak veri nasıl işlenmeli, hangi parametreler kullanılmalı ve hangi tip çekirdek fonksiyonu seçilmeli sorularının cevapları, bu sistemi hazırlayanın kararına ve birikimine bağlıdır. Doğru oluşturulmamış seçimler algoritmanın başarı performansının düşmesine neden olur. Aşağıdaki Şekil 3.9.'da polinom çekirdek fonksiyonlu destek vektör makinesine ait şematik gösterim gösterilmiştir.



Şekil 3.9. DVM'nin şematik gösterimi

Buradaki destek vektör makinesi, girdi katmanı çekirdek iç ürünlerin gizli katmanları ve çıktı tabakasından oluşmaktadır. Aşağıdaki Şekil 3.10.'da polinom çekirdek fonksiyonlu destek vektör makineleri (DVM- PÇF 4) çalışmasına ait bir destek vektör makinesi şeması gösterilmiştir.



Şekil 3.10. Çalışmada kullanılan polinom çekirdek fonksiyonu şeması

Bu çalışmada katı madde miktarı (S_t), günlük yağış (P_t), akım debisi (Q_t) ve sıcaklık (T_t) verileri kullanılarak polinom çekirdek fonksiyonu kullanılarak araştırma yapılmıştır.


Destek vektör makineleri, doğrusal ve doğrusal olmayan şekilde sınıflandırmasına göre 2 durumda inceleme yapılır.

DVM nin temel yapısı Şekil 3.11.'de verilmiştir. Şekil 3.11.'den de görüleceği üzere Veri noktaları, negatif ve pozitif olarak tanımlandıktan sonra sistemin amacı veri noktalarını maksimum marj ile ayıran bir hiper düzlem bulabilmektir. Karar sınırı her iki sınıfın verilerinden mümkün olduğunca uzakta olmalıdır. Örnek, aşağıdaki formatta bir eğitim küme olsun:

$$(x_1, y_1), \dots, (x_n, y_n)$$


Burada x_i hiperdüzlem üzerindeki noktayı verirken, y_i ise x_i verisinin hangi kümeye ait olduğunu ifade eder. y_i , +1 yada -1 değerini alır. Şekil 3.11.'de 2 boyutlu bir uzaydaki veri

kümesinde, kırmızı kareler' $y_i = -1$ ', yeşil yuvarlaklar ise' $y_i = +1$ ' olarak işaretlenmiş verileri gösterir.



Şekil 3.11. 2 Boyutlu uzayda örnek veri kümesi

Bu verileri ayıran sonsuz tane hiper-düzlem üretilebilir. DVM'ler lineer sınıflandırma problemlerinde hiper-düzlemler doğrusal tanımlanır. Üstdeki örnek de olduğu iki boyutlu bir uzayda sonsuz tane ayırım çizgisi tanımlanabilir. Şekil 3.12.'de bu ayırma bir örnek çizim gösterilmiştir.



Şekil 3.12. İki veri kümesini ayıran sonsuz adet düzlemden bir örnek

Bu hiper-düzlemler denklem olarak şu şekilde ifade edilir;

$$\vec{w} * \vec{x}_i + b = 0 \quad (3.3)$$

Bu ifadede w; hiper düzlemin normalini x, düzlemin yerini ve b bias terimini ifade etmektedir.

Doğrusal DVM, sert marjlinli ve esnek marjlinli olmak üzere iki sınıfta değerlendirilir.

DVM'nin eğitilmesini gerçekleştiren algoritmaların kullandığı verilerin tamamı 'eğitim verisi' olarak adlandırılır. Bu eğitim verisi, lineer bir şekilde ayrılabilen Şekil 3.12.'deki gibi doğrusal sınıflandırıcı olarak rahatça kullanılabilir. Bu sınıflandırıcıda $y_i = -1$ değerli bütün veriler hiper-düzlemin bir yanında, $y_i = +1$ değerli veriler ise diğer yanda yer alarak ayrıştırılmaktadır.

Bu marjini maksimize edebilmek için 'w' değerini minimize etmek gerekir. Bu noktada iki tane kısıt vardır. Bu kısıtlamalar için çözülmesi gereken denklemler aşağıda verilmektedir:

$$y_i = +1 \Rightarrow \vec{w} * \vec{x}_i + b \geq +1 \quad (3.4)$$

$$y_i = -1 \Rightarrow \vec{w} * \vec{x}_i - b \leq -1 \quad (3.5)$$

Yukarıdaki iki denklem tek bir denklem haline getirilip, bütün i'ler için problem şu şekilde yazılabilir:

$$y_i(\vec{w} * \vec{x}_i + b) \geq 1, \quad \forall_i, \quad \min_{w,b} \|w\| \quad \text{ifadesini alır.} \quad (3.6)$$

Burada; w hiper düzlemin normalini, x_i düzlemin yerini ve b ise biası (eğilim değerini) yani hiper düzlemin orjinden olan uzaklığı olarak ifade edilir. Her veri noktasının (x_i) belirlenmesi, -1 veya +1 değerini alabilen y_i ile ifade edilir. DVM bu şekilde eğitildikten sonra yeni bir x_c verisinin hangi sınıfa ait olduğu aşağıda gösterilen bir fonksiyonla ifade edilir;

$$x_c \rightarrow \text{sgn}(\vec{w}x_c + b) \quad (3.7)$$

Eğer $\vec{w}x_c + b$ ' nin sonucu negatif ise veri -1 grubuna, pozitifse +1 grubuna aittir.

Bazı hallerde eğitim verisi lineer ayrılabilir durumda olsa da bazı veriler bu kurala uymuyor gibi görünebilir. Bu durumda esnek marjlinli DVM kullanılır. Bu sebeple yanlış tarafta bulunan veriler cezalandırılıp optimizasyon uygulanır. Bu problemi çözümlmek için Hinge kayıp fonksiyonu kullanılabilir. Bu fonksiyon şu şekilde ifade edilir:

$$\max(0, 1 - y_i(\vec{w}x_c + b)) \quad (3.8)$$

Burada , y_i , çıkış değeri; DVM tarafından hesaplanan çıkış değeridir. Daha önceki optimizasyon probleminde bahsetmiş olduğum (3.6) denklemindeki şart sağlanıyorsa, fonksiyonun çıkışı '0' olur. Başka bir ifadeyle, veri doğru tarafta ve marjinin dışında kalıyorsa fonksiyonun bir etkisi olmaz. Eğer veri yanlış tarafta bulunuyorsa, $y_i(\vec{w} * \vec{x}_i + b) \geq 1$ şartı yerine getirilmediği için, fonksiyonun çıkışı verinin yanlış tarafta olduğu oranda artış gösterir. Veri doğru yerde ama marjinin içindeyse çıkış 1'den küçük olur. Düzlemin diğer tarafına geçtiği miktarda 1'den büyük değerler alır.

Kısıtları esnetmek için kullanılan Hinge kayıp fonksiyonu aşağıdaki şekilde gösterilebilir:

$$y_i(\vec{w} * \vec{x}_i + b) \geq 1 - \xi_i \quad \xi_i \geq 0 \quad (3.9)$$

Bu ifade de ξ_i değeri, gevşek değişken olarak adlandırılan, o verinin yaptığı hatayı ifade eden tanımdır.

Daha önce anlattığımız sert marjlinli sınıflandırmada 'w' değeri minimize yapılırken, esnek marjinde bu formüle gevşek değişkeni de eklenir ve bu fonksiyon aşağıdaki şu halini alır:


$$\min_{w,b} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (3.10)$$

C değeri marjin genişliği ile x_i değerinin doğru tarafta yer alması arasında bir tercih yapması için ayarlanır. C sonsuz bir değer aldığıda fonksiyon sert marjinli halini alır veya bu değer küçüldükçe esnek marjinli sınıflandırıcı haline dönüşür.


Bazı sınıflandırma problemleri için doğrusal sınıflandırma yetersiz kalmaktadır. Çok boyutlu problemlerde veri dağılımı doğrusal olmadığından dolayı veri sınıflandırılması için kullanılacak olan hiper-düzlem de doğrusal olmayan yapıya sahip olmalıdır. Doğrusal olmayan sınıflandırıcılar için çekirdek fonksiyonları kullanılır. Bu fonksiyonlarda doğrusal olmayan hiper-düzlem oluşturmayı kolaylaştırır.

Araştırmacılar, ilk başlarda sadece doğrusal sınıflandırma için çalışmalar yaparken ileri yıllarda çekirdek fonksiyonlarını da kullanılarak destek vektör makineleri ile doğrusal olmayan sınıflandırıcı yöntemini kullanıp geliştirmişlerdir.

Burada hedeflenen, girdi uzayında doğrusal olarak tanımlanamayan verinin bir üst boyuta çekirdek fonksiyonu ile haritalanarak doğrusal olarak sınıflandırılmasıdır. Şekil 3.13. ve Şekil 3.14.'te doğrusal olmayan girdi uzayına çekirdek fonksiyonu ile haritalanma işlemini göstermektedir.



Şekil 3.13. Doğrusal olarak sınıflandırılmayan DVM gösterimi



Şekil 3.14. Doğrusal olarak sınıflandırılmayan girdi uzayının bir üst boyuta çekirdek fonksiyonu ile haritalanması

Burada amaç doğrusal olarak çözümlenmeyen bir girdi uzayında bir üst boyut oluşturarak o boyuta çekirdek fonksiyonu ile haritalama işlemini yapmaktır. Bu sayede sistem doğrusal sınıflandırma ile çözüm yapılmaktadır. Bu araştırmada destek vektör makinesi modellerini oluşturmak için tanımlanan , radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) kullanılarak nehirlerdeki katı madde miktarı tahmin edilmiştir. Bu sayede regresyon ve sınıflandırma problemlerinde, bu esnek yapısı nedeniyle daha yüksek performans sonuçları elde edilmektedir.


Polinom çekirdek fonksiyonu

Polinom çekirdek fonksiyonu en basit çekirdek fonksiyonu olup, bir c sabiti ile belirtilir. Bu çekirdek fonksiyonu aşağıdaki formül ile ifade edilir.


$$k(x, y) = (x^T y + c)^d \quad (3.11)$$

Bu ifade de, Ayarlanabilir parametrelerden, c sabit terimi, d polinom derecesini ifade eder. Polinom nöral ağları “kendi kendini organize eden” ağlardır. Ağ sadece giriş nöronları ile

başlar. Eğitim süreci boyunca, nöronlar bir aday havuzundan seçilir ve gizli katmanlara eklenirler. Eğitim verilerinin tümünün normalleştirildiği problemler için çok uygundur. Aşağıdaki Şekil 3.15. ve Şekil 3.16.'da bu fonksiyona ait grafikler gösterilmiştir:



Şekil 3.15. Çekirdek fonksiyonu gösterimi




Şekil 3.16. Doğrusal olmayan 2 boyutlu örnek uzay gösterimi

Radyal tabanlı çekirdek fonksiyonu

Radyal tabanlı sınıflandırma işlemi, doğrusal olmadığından, örneği daha yüksek boyutlu bir uzaya taşıyarak gerçekleştirir. Diğer çekirdek fonksiyonlarından farkı daha sıkıştırılmış bir çekirdek olduğu için, model tasarımında değerli bir özellik olup hesaplamalı eğitim sürecini kısıtlarken, genelleştirme verimliliğini iyileştirmeyi uygun hale getirmede katkı sağlar. Radyal tabanlı fonksiyon şu denklemlerle ifade edilir:

$$K(x, y) = e^{-\gamma \|x - x_i\|^2} \quad (3.12)$$

Aşağıdaki Şekil 3.17.'de Radyal tabanlı çekirdek fonksiyonuna ait haritalama şekli gösterilmiştir




Şekil 3.17. RTF 'ye ait çekirdek fonksiyonu

3.2.3. Genelleştirilmiş regresyon yapay sinir ağı

Yapay sinir ağları (YSA), insan beynindeki nöron sistemini örnek alınarak oluşturulan farklı ağırlıklarla birbirlerine bağlı birçok elamanlardan meydana gelmiş yoğun paralel sistemlerdir. Yapay sinir ağları üç ana katmandan oluşur; giriş, ara ve çıkış katmanlarıdır. Yapay sinir ağları genel anlamda giriş verilerine göre sonuç üreten sistemlerdir. Bu eylem giriş katmanında meydana gelir. bu katmanda veriler herhangi bir işleme maruz kalmaz. giriş katmanında herhangi bir işleme tabi tutulmayan veriler ara katmana gelir. Yapay sinir ağlarında tabaka sayısı modelden modele farklılık gösterebilir. Ara katman sayısı ağdan ağa farklılık gösterebilir. Bu katmandaki nöron sayıları giriş ve çıkış sayısından bağımsızdır. Ara

katmandan gelen veriler son defa çıkış katmanında değerlendirilerek, kullanıma hazır hale getirilir. Şekil 3.18.'de yapay sinir ağlarına ait şekil gösterilmiştir.




Şekil 3.18. Yapay sinir ağına ait şematik gösterim

Radyal tabanlı çalışan ve genellikle tahminleyici olarak çalışan denetimli bir yapay sinir ağı modelidir. Bu algoritmanın güçlü yanlarını oluşturan etkenler, tutarlı ve hızlı sonuçlar üretmesinin yanında kolay modellenmesidir. Bu yapay sinir ağı modelinde eğitim veri setindeki her örnek veri için örüntü katmanında bir tane nöron tutulur. Bundan ötürü, eğitim veri setinin çok fazla olduğu çalışmalarda katman yapısı örnek verilerinin sayısı ile doğru orantıda büyüyüp, yapılan işlem sayısını ve bellek gereksinimini artırmaktadır. Genelleştirilmiş yapay sinir ağının teorik temeli, doğrusal olmayan regresyon analizidir. Y'yi büyük olasılık değeri ile hesaplamak için kullanılan GRYSA aslında, X bağımsız değişkenine göre bağımsız olmayan Y değişkeninin analizidir. Rastgele değişkenin x ve olasılık yoğunluğu fonksiyonun $f(X, y)$ olmasına aşağıdaki denklem 3.13 ile ifade edilir. Burada y, X girişinde y'nin öngörülen çıkışıdır.

$$Y = E\left(\frac{y}{X}\right) = \frac{\int_{-\infty}^{\infty} y f(X, y) dy}{\int_{-\infty}^{\infty} f(X, y) dy} \quad (3.13)$$

Aşağıdaki Şekil 3.19.'da genelleştirilmiş regresyon yapay sinir ağının genel yapısı gösterilmiştir:



Şekil 3.19. GRYSA' nın genel yapısı

Genelleştirilmiş regresyon yapay sinir ağı giriş tabakası, örüntü tabakası, toplama tabakası ve çıkış tabakası olmak üzere 4 tabakadan oluşan ileri beslemeli bir yapay sinir ağı modelidir. Bünyesinde bulunan her bir tabaka farklı sayılarda nöronlardan oluşup, tabakalar sırasıyla bir sonraki tabaka ile bağlantılıdır.

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

Bu bölümde, nehirdeki askı maddesi değişimlerini tahmin etmek amacı ile katı madde anahtar eğrisi (KMAE), radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) modellerinin sonuçları incelenmiştir. Çalışmada kullanılan modellerin karşılaştırılmasında kullanılan istatistiksel parametreler hakkında bilgi verilecek olup, diğer kısımlarda modellere ait sonuçların grafiksel gösterimi, yorumlanması yapılmıştır.

4.1. Model Performansında Kullanılan İstatistiksel Parametreler

Modellerin sonuçlarının değerlendirmesinde Korelasyon katsayısı (R), ortalama karesel hataların karekökü (KKOH) ve mutlak ortalama hata (MOH) hesaplanmıştır.

Korelasyon katsayısı (R), x ve y ikili değerleri arasındaki doğrusal bağıntının gücünü ölçer. Doğrusal ilişkinin 1 olması sonucun doğruya çok yakın olduğunu gösterir. Bu durumda 1'e en yakın değer için yapılacak olan yorumlama en mantıklı ve uygun olanıdır.

$$R = \sqrt{\left(\frac{n\sum xy - (\sum x)(\sum y)}{\sqrt{(n\sum x^2) - (\sum x)^2} \sqrt{(n\sum y^2) - (\sum y)^2}}\right)} \quad (4.1)$$

KKOH ve MOH, hataların ihtimallerini teşhis etmek için kullanılır. KKOH, MOH sıfırdan sonsuza kadar gidebilir. Daha Düşük değerler daha kullanışlı olduğu anlamına gelir.

$$MOH = \frac{1}{n} \sum_{j=1}^n \left| S_{ölçüm} - S_{tah min} \right| \quad (4.2)$$

$$KKOH = \frac{1}{n} \sqrt{\sum_{i=1}^n \left(S_{ölçüm} - S_{tah min} \right)^2} \quad (4.3)$$

Burada, n veri sayılarını ve S günlük askıdaki katı madde/sediment miktarını, konsantrasyonunu (mg/L) miktarını ifade etmektedir.


Sonuçlar, tahmin ve performans açısından karşılaştırmak için kullanılacaktır.

4.2. Model Sonuçları


Çalışmada, katı madde anahtar eğrisi (KMAE), radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve genelleştirilmiş regresyon yapay Sinir Ağı (GRYSA) modellerinin sonuçları incelenmiştir. Bu modellere ait sonuçlar aşağıda verilmiştir.

4.2.1. Katı madde anahtar eğrisi model sonuçları


Katı madde anahtar eğrisi (KMAE) modeli için 2011-2017 yılları arasında 2139 günlük verinin 1604'ü eğitim için, son 535 günlük veri de test için değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. KMAE modelinde girdi olarak ölçülen günlük nehir debisi (m^3/s), kullanılarak çıktı katmanı olarak askıdaki sediment konsantrasyon miktarı (mg/L) alınmıştır. Aşağıdaki Şekil 4.1.'de askıdaki sediment miktarı eğitim verileri için KMAE grafiği, Şekil 4.2. ve Şekil 4.3.'de ise KMAE modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.



Şekil 4.1. Askıdaki sediment miktarı eğitim verileri için KMAE grafiği




Şekil 4.2. Askıdaki sediment miktarı eğitim verileri için KMAE'ye ait saçılım grafiği




Şekil 4.3. Askıdaki sediment miktarı eğitim verileri için KMAE'ye ait ölçüm ve dağılım grafiği

Şekil 4.2. ve Şekil 4.3. incelendiğinde korelasyon katsayısının 0.47 olduğu tespit edilmiştir. KMAE modeli eğitim verilerinin analizi ile elde edilen, KMAE modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.4. ve Şekil 4.5'te verilmiştir.



Şekil 4.4. Askıdaki sediment miktarı test verileri için KMAE'ye ait saçılım grafiği




Şekil 4.5. Askıdaki sediment miktarı test verileri için KMAE'ye ait ölçüm ve dağılım grafiği


Test aşamasında, korelasyon katsayısı $R = 0.57$ olarak elde edilmiştir.

4.2.2. DVM-RTF model sonuçları

DVM-RTF modeli için 2011-2017 yılları arasında 2139 günlük verinin 1604'ü eğitim için, son 535 günlük veri de test için değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. Askıdaki sediment miktarı tahmininde, radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF) içerisinde toplam 5 tane DVM-RTF 1, DVM-RTF 2, DVM-RTF 3, DVM-RTF 4, ve DVM-RTF 5, modelleri kullanılmıştır. DVM-RTF 1 modelinde girdi katmanları olarak ölçülen günlük nehir debisi (m^3/s), hava sıcaklığı($^{\circ}C$), yağış verileri (mm) kullanılarak çıktı katmanı olarak askıdaki sediment konsantrasyon miktarı (mg/L) alınmıştır. Aşağıda Şekil 4.6. ve Şekil 4.7.'de DVM-RTF 1 modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.6. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 1'e ait saçılım grafiği




Şekil 4.7. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 1'e ait ölçüm ve dağılım grafiği

Şekil 4.6. ve Şekil 4.7. incelendiğinde korelasyon katsayısının 0.50 olduğu tespit edilmiştir. DVM-RÇF 1 modeli eğitim verilerinin analizi ile elde edilen, DVM-RÇF 1 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.8. ve Şekil 4.9.'da verilmiştir.




Şekil 4.8. Askıdaki sediment miktarı test verileri için DVM-RTF 1'e ait saçılım grafiği




Şekil 4.9. Askıdaki sediment miktarı test verileri için DVM-RTF 1'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.67$ olarak elde edilmiştir. DVM-RTF 2 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.10., Şekil 4.11., Şekil 4.12., ve Şekil 4.13.'de verilmiştir. Ayrıca DVM-RTF 2 modelinde girdi olarak DVM-RTF 1 modelindeki ilaveten debi zaman serisi eklenmiştir.




Şekil 4.10. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 2'ye ait saçılım grafiği




Şekil 4.11. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 2'ye ait ölçüm ve dağılım grafiği

Şekil 4.10. ve Şekil 4.11. incelendiğinde korelasyon katsayısının 0.49 olduğu tespit edilmiştir. DVM-RÇF 2 modeli eğitim verilerinin analizi ile elde edilen, DVM-RÇF 2 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.12. ve Şekil 4.13.'de verilmiştir.




Şekil 4.12. Askıdaki sediment miktarı test verileri için DVM-RTF 2'ye ait saçılım grafiği




Şekil 4.13. Askıdaki sediment miktarı test verileri için DVM-RTF 2'ye ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.66$ olarak elde edilmiştir. DVM-RTF 3 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.14., Şekil 4.15., Şekil 4.16.,ve Şekil 4.17.'de verilmiştir. Ayrıca DVM-RTF 3 modelinde girdi olarak DVM-RTF 2 modelindekiyle ilaveten yağış zaman serisi eklenmiştir.




Şekil 4.14. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait saçılım grafiği

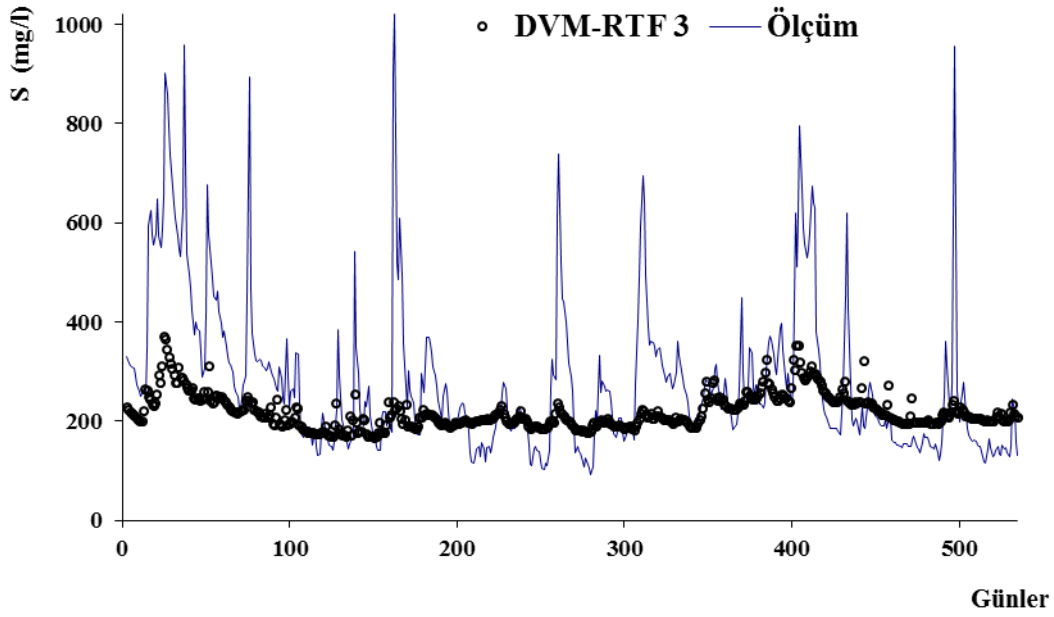


Şekil 4.15. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait ölçüm ve dağılım grafiği

Şekil 4.14. ve Şekil 4.15. incelendiğinde korelasyon katsayısının 0.52 olduğu tespit edilmiştir. DVM-RÇF 3 modeli eğitim verilerinin analizi ile elde edilen, DVM-RÇF 3 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.16. ve Şekil 4.17.'de verilmiştir.




Şekil 4.16. Askıdaki sediment miktarı test verileri için DVM-RTF 3'e ait saçılım grafiği




Şekil 4.17. Askıdaki sediment miktarı test verileri için DVM-RTF 3'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.66$ olarak elde edilmiştir. DVM-RTF 4 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.18., Şekil 4.19., Şekil 4.20., ve Şekil 4.21.'de verilmiştir. Ayrıca DVM-RTF 4 modelinde girdi olarak DVM-RTF 3 modelindeki ilave katı madde zaman serisi eklenmiştir.




Şekil 4.18. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait saçılım grafiği

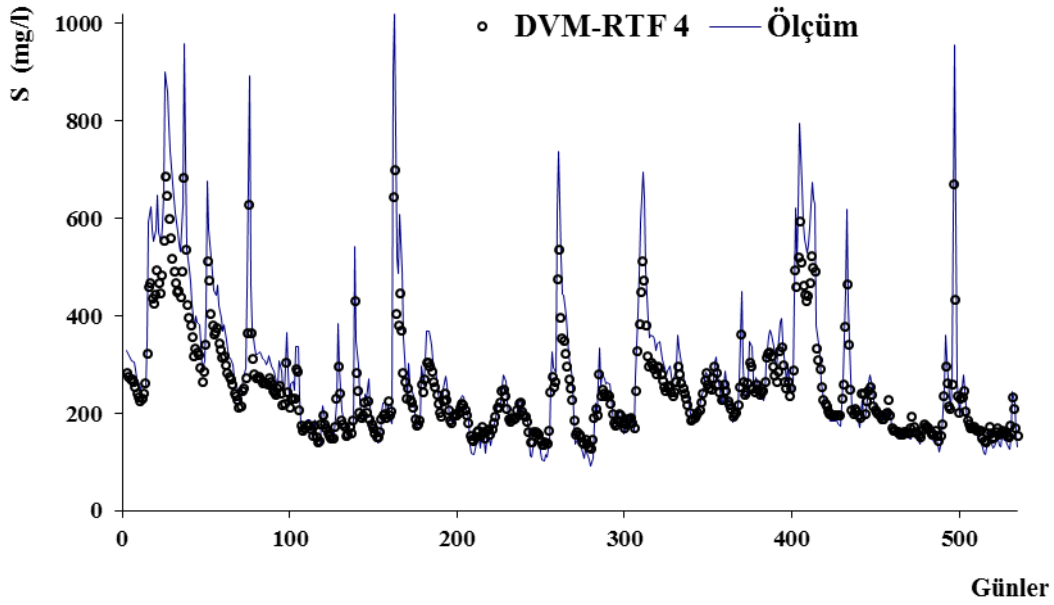


Şekil 4.19. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 3'e ait ölçüm ve dağılım grafiği

Şekil 4.18. ve Şekil 4.19. incelendiğinde korelasyon katsayısının 0.89 olduğu tespit edilmiştir. DVM-RÇF4 modeli eğitim verilerinin analizi ile elde edilen, DVM-RÇF 4 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.20. ve Şekil 4.21.'de verilmiştir.




Şekil 4.20. Askıdaki sediment miktarı test verileri için DVM-RTF 4'e ait saçılım grafiği




Şekil 4.21. Askıdaki sediment miktarı test verileri için DVM-RTF 4'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.87$ olarak elde edilmiştir. DVM-RTF 5 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.22., Şekil 4.23., Şekil 4.24., ve Şekil 4.25.'de verilmiştir. Ayrıca DVM-RTF 5 modelinde girdi olarak DVM-RTF 4 modelindekilere ilaveten ikinci katı madde zaman serisi eklenmiştir.




Şekil 4.22. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 5'e ait saçılım grafiği




Şekil 4.23. Askıdaki sediment miktarı eğitim verileri için DVM-RTF 5'e ait ölçüm ve dağılım grafiği

Şekil 4.22. ve Şekil 4.23. incelendiğinde korelasyon katsayısının 0.86 olduğu tespit edilmiştir. DVM-RÇF 5 modeli eğitim verilerinin analizi ile elde edilen, DVM-RÇF 5 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.24. ve Şekil 4.25. 'de verilmiştir.



Şekil 4.24. Askıdaki sediment miktarı test verileri için DVM-RTF 5'e ait saçılım grafiği




Şekil 4.25. Askıdaki sediment miktarı test verileri için DVM-RTF 5'e ait ölçüm ve dağılım grafiği


Test aşamasında, korelasyon katsayısı $R = 0.85$ olarak elde edilmiştir.

4.2.3. DVM-PÇF model sonuçları

DVM-PÇF modeli için DVM-RTF modelindeki gibi veriler eğitim ve test olarak tanımlanmıştır. Askıdaki sediment miktarı tahmininde, polinom çekirdek fonksiyonlu destek vektör makineleri (DVM- PÇF) içerisinde toplam 5 tane DVM-PÇF 1, DVM- PÇF 2, DVM-PÇF 3, DVM- PÇF 4, ve DVM- PÇF 5, modelleri kullanılmıştır. DVM- PÇF 1 modelinde girdi katmanları olarak ölçülen günlük nehir debisi (m^3/s), hava sıcaklığı($^{\circ}C$), yağış verileri (mm) kullanılarak çıktı katmanı olarak askıdaki sediment konsantrasyon miktarı (mg/L) alınmıştır. Aşağıda Şekil 4.26. ve Şekil 4.27.'de DVM- PÇF 1 modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.26. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 1'e ait saçılım grafiği




Şekil 4.27. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 1'e ait ölçüm ve dağılım grafiği

Şekil 4.26. ve Şekil 4.27. incelendiğinde korelasyon katsayısının 0.50 olduğu tespit edilmiştir. DVM- PÇF 1 modeli eğitim verilerinin analizi ile elde edilen, DVM- PÇF 1 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.28. ve Şekil 4.29.'da verilmiştir.




Şekil 4.28. Askıdaki sediment miktarı test verileri için DVM-PÇF 1'e ait saçılım grafiği




Şekil 4.29. Askıdaki sediment miktarı test verileri için DVM-PÇF 1'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.68$ olarak elde edilmiştir. DVM-PÇF 2 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.30., Şekil 4.31., Şekil 4.32., ve Şekil 4.33.'de verilmiştir. Ayrıca DVM-PÇF 2 modelinde girdi olarak DVM-PÇF 1 modelindekilere ilaveten debi zaman serisi eklenmiştir.




Şekil 4.30. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 2'ye ait saçılım grafiği




Şekil 4.31. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 2'ye ait ölçüm ve dağılım grafiği

Şekil 4.30. ve Şekil 4.31. incelendiğinde korelasyon katsayısının 0.57 olduğu tespit edilmiştir. DVM- PÇF 2 modeli eğitim verilerinin analizi ile elde edilen, DVM- PÇF 2 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.32. ve Şekil 4.33.'de verilmiştir.




Şekil 4.32. Askıdaki sediment miktarı test verileri için DVM-PÇF 2'ye ait saçılım grafiği




Şekil 4.33. Askıdaki sediment miktarı test verileri için DVM-PÇF 2'ye ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.70$ olarak elde edilmiştir. DVM-PÇF 3 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.34, Şekil 4.35, Şekil 4.36., ve Şekil 4.37.'de verilmiştir. Ayrıca DVM-PÇF 3 modelinde girdi olarak DVM-PÇF 2 modelindekilere ilaveten yağış zaman serisi eklenmiştir.




Şekil 4.34. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 3'e ait saçılım grafiği




Şekil 4.35. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 3'e ait ölçüm ve dağılım grafiği

Şekil 4.34. ve Şekil 4.35. incelendiğinde korelasyon katsayısının 0.58 olduğu tespit edilmiştir. DVM- PÇF 3 modeli eğitim verilerinin analizi ile elde edilen, DVM- PÇF 3 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.36. ve Şekil 4.37.'de verilmiştir.




Şekil 4.36. Askıdaki sediment miktarı test verileri için DVM-PÇF 3'e ait saçılım grafiği




Şekil 4.37. Askıdaki sediment miktarı test verileri için DVM-PÇF 3'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.69$ olarak elde edilmiştir. DVM-PÇF 4 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.38., Şekil 4.39., Şekil 4.40., ve Şekil 4.41.'de verilmiştir. Ayrıca DVM-PÇF 4 modelinde girdi olarak DVM-PÇF 3 modelindekilere ilaveten katı madde zaman serisi eklenmiştir.




Şekil 4.38. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 4'e ait saçılım grafiği




Şekil 4.39. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 4'e ait ölçüm ve dağılım grafiği

Şekil 4.38. ve Şekil 4.39. incelendiğinde korelasyon katsayısının 0.91 olduğu tespit edilmiştir. DVM- PÇF 4 modeli eğitim verilerinin analizi ile elde edilen, DVM- PÇF 4 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.40. ve Şekil 4.41.'de verilmiştir.




Şekil 4.40. Askıdaki sediment miktarı test verileri için DVM-PÇF 4'e ait saçılım grafiği




Şekil 4.41. Askıdaki sediment miktarı test verileri için DVM-PÇF 4'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.90$ olarak elde edilmiştir. DVM-PÇF 5 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.42., Şekil 4.43., Şekil 4.44., ve Şekil 4.45.'de verilmiştir. Ayrıca DVM-PÇF 5 modelinde girdi olarak DVM-PÇF 4 modelindekilere ilaveten ikinci katı madde zaman serisi eklenmiştir.




Şekil 4.42. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 5'e ait saçılım grafiği

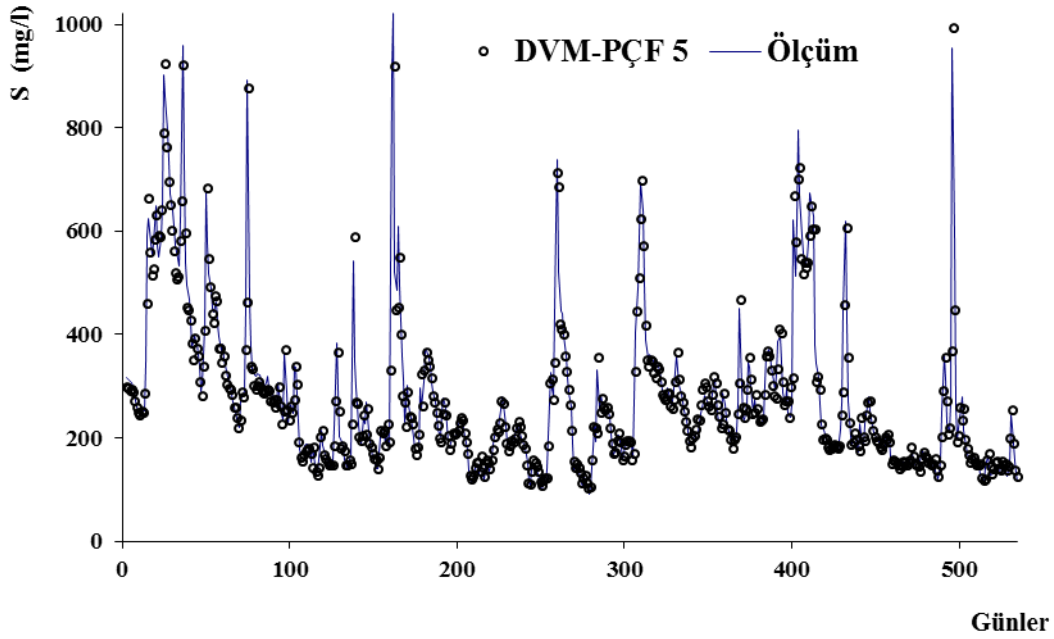


Şekil 4.43. Askıdaki sediment miktarı eğitim verileri için DVM-PÇF 5'e ait ölçüm ve dağılım grafiği

Şekil 4.42. ve Şekil 4.43. incelendiğinde korelasyon katsayısının 0.92 olduğu tespit edilmiştir. DVM- PÇF 5 modeli eğitim verilerinin analizi ile elde edilen, DVM- PÇF 5 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.44. ve Şekil 4.45.'de verilmiştir.



Şekil 4.44. Askıdaki sediment miktarı test verileri için DVM-PÇF 5'e ait saçılım grafiği

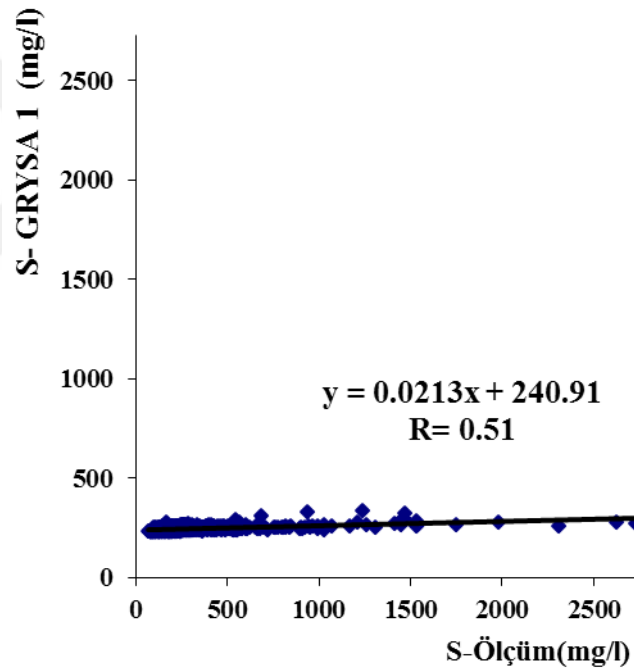


Şekil 4.45. Askıdaki sediment miktarı test verileri için DVM-PÇF 5'e ait ölçüm ve dağılım grafiği


Test aşamasında, korelasyon katsayısı $R = 0.90$ olarak elde edilmiştir.

4.2.4. GRYSA model sonuçları

GRYSA modeli için DVM-PÇF modelindeki gibi veriler eğitim ve test olarak tanımlanmıştır. Askıdaki sediment miktarı tahmininde, genelleştirilmiş regresyon yapay sinir ağı (GRYSA) içerisinde toplam 5 tane GRYSA 1, GRYSA 2, GRYSA 3, GRYSA 4, ve GRYSA 5, modelleri kullanılmıştır. GRYSA 1 modelinde girdi katmanları olarak ölçülen günlük nehir debisi (m^3/s), hava sıcaklığı($^{\circ}C$), yağış verileri (mm) kullanılarak çıktı katmanı olarak askıdaki sediment konsantrasyon miktarı (mg/L) alınmıştır. Aşağıda Şekil 4.46. ve Şekil 4.47.'de GRYSA 1 modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.




Şekil 4.46. Askıdaki sediment miktarı eğitim verileri için GRYSA 1'e ait saçılım grafiği

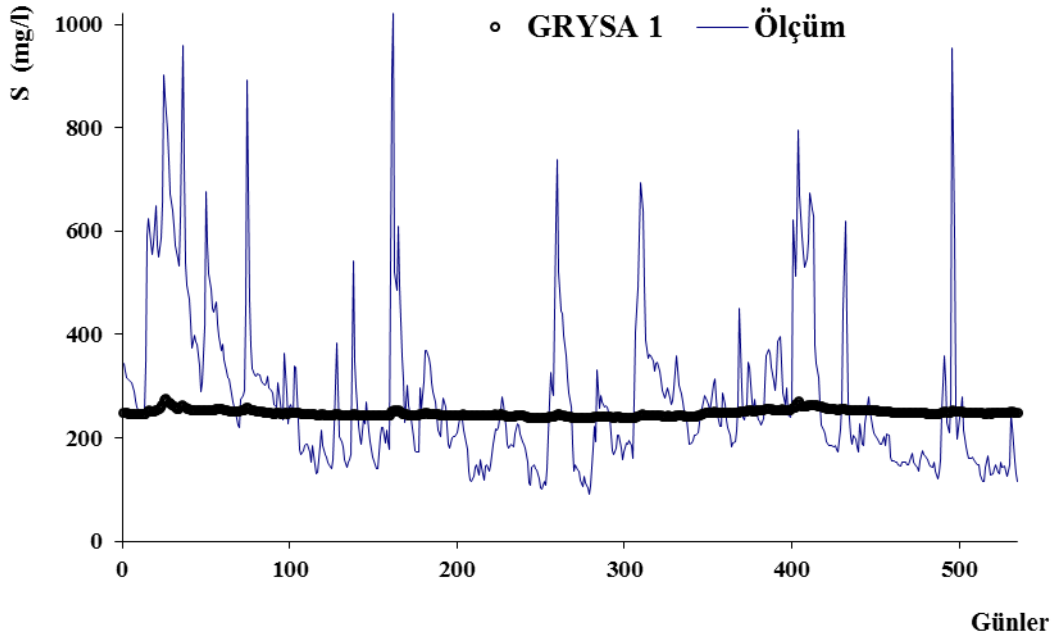


Şekil 4.47. Askıdaki sediment miktarı eğitim verileri için GRYSA 1'e ait ölçüm ve dağılım grafiği

Şekil 4.46. ve Şekil 4.47. incelendiğinde korelasyon katsayısının 0.51 olduğu tespit edilmiştir. GRYSA 1 modeli eğitim verilerinin analizi ile elde edilen, GRYSA 1 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.48. ve Şekil 4.49.'da verilmiştir.




Şekil 4.48. Askıdaki sediment miktarı test verileri için GRYSA 1'e ait saçılım grafiği




Şekil 4.49. Askıdaki sediment miktarı test verileri için GRYSA 1'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.59$ olarak elde edilmiştir. GRYSA 2 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.50., Şekil 4.51., Şekil 4.52., ve Şekil 4.53.'de verilmiştir. Ayrıca GRYSA 2 modelinde girdi olarak GRYSA 1 modelindekilere ilaveten debi zaman serisi eklenmiştir.

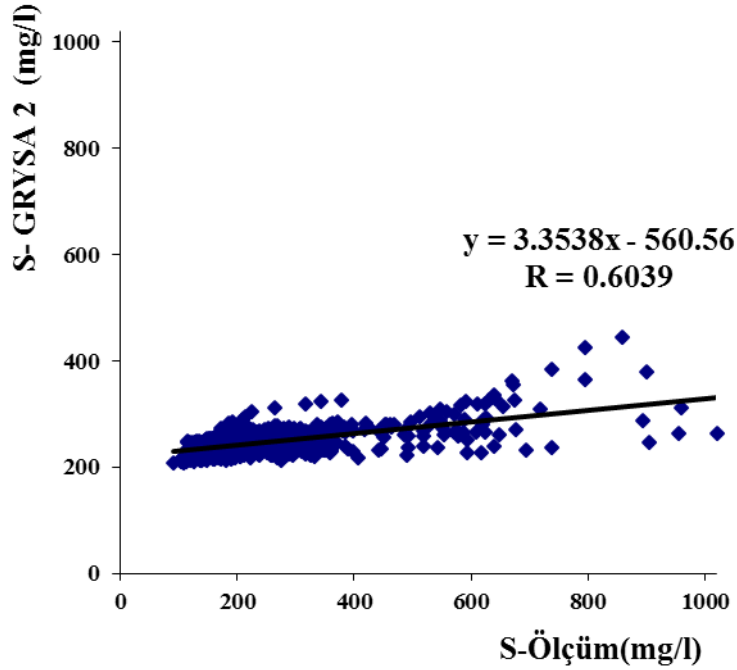


Şekil 4.50. Askıdaki sediment miktarı eğitim verileri için GRYSA 2'ye ait saçılım grafiği




Şekil 4.51. Askıdaki sediment miktarı eğitim verileri için GRYSA 2'ye ait ölçüm ve dağılım grafiği

Şekil 4.50. ve Şekil 4.51. incelendiğinde korelasyon katsayısının 0.47 olduğu tespit edilmiştir. GRYSA 2 modeli eğitim verilerinin analizi ile elde edilen, GRYSA 2 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.52. ve Şekil 4.53.'de verilmiştir.




Şekil 4.52. Askıdaki sediment miktarı test verileri için GRYSA 2'ye ait saçılım grafiği




Şekil 4.53. Askıdaki sediment miktarı test verileri için GRYSA 2'ye ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.60$ olarak elde edilmiştir. GRYSA 3 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.54., Şekil 4.55., Şekil 4.56., ve Şekil 4.57.'de verilmiştir. Ayrıca GRYSA 3 modelinde girdi olarak GRYSA 2 modelindekilere ilaveten yağış zaman serisi eklenmiştir.




Şekil 4.54. Askıdaki sediment miktarı eğitim verileri için GRYSA 3'e ait saçılım grafiği




Şekil 4.55. Askıdaki sediment miktarı eğitim verileri için GRYSA 3'e ait ölçüm ve dağılım grafiği

Şekil 4.54. ve Şekil 4.55. incelendiğinde korelasyon katsayısının 0.49 olduğu tespit edilmiştir. GRYSA 3 modeli eğitim verilerinin analizi ile elde edilen, GRYSA 3 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.56. ve Şekil 4.57.'de verilmiştir




Şekil 4.56. Askıdaki sediment miktarı test verileri için GRYSA 3'e ait saçılım grafiği




Şekil 4.57. Askıdaki sediment miktarı test verileri için GRYSA 3'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.60$ olarak elde edilmiştir. GRYSA 4 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.58., Şekil 4.59., Şekil 4.60., Şekil 4.61.'de verilmiştir. Ayrıca GRYSA 4 modelinde girdi olarak GRYSA 3 modelindekilere ilaveten katı madde zaman serisi eklenmiştir.




Şekil 4.58. Askıdaki sediment miktarı eğitim verileri için GRYSA 4'e ait saçılım grafiği




Şekil 4.59. Askıdaki sediment miktarı eğitim verileri için GRYSA 4'e ait ölçüm ve dağılım grafiği

Şekil 4.58. ve Şekil 4.59. incelendiğinde korelasyon katsayısının 0.99 olduğu tespit edilmiştir. GRYSA 4 modeli eğitim verilerinin analizi ile elde edilen, GRYSA 4 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.60 ve Şekil 4.61 'de verilmiştir.

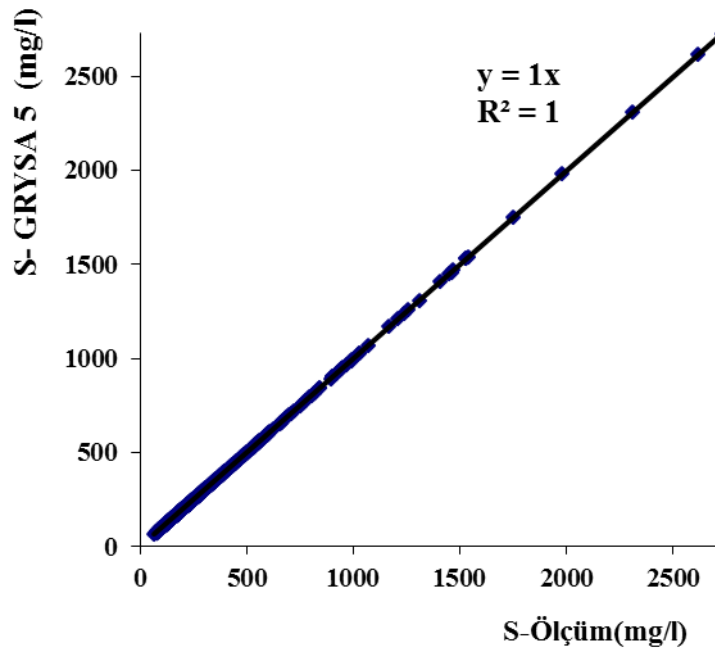


Şekil 4.60. Askıdaki sediment miktarı test verileri için GRYSA 4'e ait saçılım grafiği




Şekil 4.61. Askıdaki sediment miktarı test verileri için GRYSA 4'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.85$ olarak elde edilmiştir. GRYSA 5 modeline ait eğitim ve test aşamasındaki saçılım, dağılım grafikleri sırası ile Şekil 4.62., Şekil 4.63., Şekil 4.64., Şekil 4.65.'de verilmiştir. Ayrıca GRYSA 5 modelinde girdi olarak GRYSA 4 modelindeki ilaveten ikinci katı madde zaman serisi eklenmiştir.




Şekil 4.62. Askıdaki sediment miktarı eğitim verileri için GRYSA 5'e ait saçılım grafiği




Şekil 4.63. Askıdaki sediment miktarı eğitim verileri için GRYSA 5'e ait ölçüm ve dağılım grafiği

Şekil 4.62. ve Şekil 4.63. incelendiğinde korelasyon katsayısının 1 olduğu tespit edilmiştir. GRYSA 5 modeli eğitim verilerinin analizi ile elde edilen, GRYSA 5 modeli test verileri dağılım ve saçılım grafikleri aşağıdaki Şekil 4.64. ve Şekil 4.65.'de verilmiştir.



Şekil 4.64. Askıdaki sediment miktarı test verileri için GRYSA 5'e ait saçılım grafiği



Şekil 4.65. Askıdaki sediment miktarı test verileri için GRYSA 5'e ait ölçüm ve dağılım grafiği

Test aşamasında, korelasyon katsayısı $R = 0.85$ olarak elde edilmiştir. Modellere ait istatistiksel sonuçlar Çizelge 4.1. de verilmiştir.

Çizelge 4.1. Sediment Tahmininde Kullanılan Model Sonuçlarının Karşılaştırılması

Model İsimleri	Model Girdileri	MOH	KKOH	R
KMAE	Q_t	80,67	117,96	0,57
DVM RTF 1	Q_t, P_t, T_t	73,43	118,42	0,68
DVM RTF 2	Q_t, Q_{t-1}, P_t, T_t	73,43	117,51	0,67
DVM RTF 3	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t$	72,23	115,40	0,66
DVM RTF 4	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}$	35,98	69,66	0,87
DVM RTF5	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}, S_{t-2}$	35,32	71,12	0,85
DVM PÇF 1	Q_t, P_t, T_t	71,70	114,25	0,68
DVM PÇF 2	Q_t, Q_{t-1}, P_t, T_t	69,99	110,62	0,70
DVM PÇF 3	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t$	69,24	109,22	0,69
DVM PÇF 4	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}$	24,38	55,61	0,90
DVM PÇF 5	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}, S_{t-2}$	24,47	57,63	0,89
GRYSA 1	Q_t, P_t, T_t	87,03	124,89	0,59
GRYSA 2	Q_t, Q_{t-1}, P_t, T_t	83,10	117,99	0,60
GRYSA 3	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t$	82,71	117,09	0,61
GRYSA 4	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}$	39,80	81,53	0,85
GRYSA 5	$Q_t, Q_{t-1}, P_t, P_{t-1}, T_t, S_{t-1}, S_{t-2}$	41,14	76,98	0,85

KKOH: Ortalama karesel hataların karekökü, **MOH:** Mutlak ortalama hata **R :** Korelasyon katsayısı. **Q(t):** günlük Debi (m^3/s), **P(t):** günlük yağış miktarı (mm), **T(t):** günlük sıcaklık ($^{\circ}C$), **S(t):** günlük Sediment (mg/L)

Geleneksel katı madde anahtar eğrisi (KMAE) model sonucunda MOH: 80,67- KKOH: 117,96- R:0,57 olarak elde edilmiştir. KMAE tahminleri tüm modeller içerisinde en düşük performans göstermiştir.

Radyal tabanlı fonksiyonlu destek vektör makineleri (DVM-RTF) içerisinde toplam 5 tane DVM-RTF 1, DVM-RBF 2, DVM-RBF 3, DVM-RBF 4 ve DVM-RTF 5 modelleri kullanılmıştır. Bu model kendi içinde değerlendirildiğinde DVM-RBF 4 (MOH:35.98- KKOH:69.66- R:0.87) modelinin diğer modellere göre daha iyi performans gösterdiği bulunmuştur.

Polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) içerisinde toplam 5 tane DVM-PÇF 1, DVM-PÇF 2, DVM-PÇF 3, DVM-PÇF 4 ve DVM-PÇF 5 modelleri kullanılmıştır. Bu model kendi içinde değerlendirildiğinde DVM-PÇF 4 (MOH:24.38- KKOH:55.61- R:0.90) modelinin diğer modellere göre daha iyi performans gösterdiği bulunmuştur.

Genelleştirilmiş regresyon yapay sinir ağı (GRYSA) içerisinde toplam 5 tane GRYSA 1, GRYSA 2, GRYSA 3, GRYSA 4 ve GRYSA 5 modelleri kullanılmıştır. Bu model kendi içinde değerlendirildiğinde GRYSA 4 ve GRYSA 5 (MOH:39.80,41.14- KKOH:81.53,76.98- R:0.85,0.85) modellerinin diğer modellere göre daha iyi performans gösterdiği bulunmuştur.

Bu dört model kendi aralarında değerlendirildiğinde DVM-RBF 4, DVM-PÇF 4, GRYSA 4 ve GRYSA 5 modellerinin başarılı sonuçlar verdiği bulunmuş olup kendi içinde de DVM-PÇF 4 modelinin en düşük hata en yüksek korelasyon katsayısıyla en iyi performans gösterdiği gözlemlenmiştir.

5. SONUÇ ve ÖNERİLER

Bu çalışmada, katı madde anahtar eğrisi (KMAE) ve yapay zeka yöntemlerinden radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF), polinom çekirdek fonksiyonlu destek vektör makineleri (DVM-PÇF) ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) kullanılarak, bu yöntemlerin nehirlerdeki katı madde miktarının destek vektör makinesi modeli ile tahmini sırasındaki performansı karşılaştırma yapılarak araştırılmıştır.

Bu çalışmada nehirlerdeki katı madde miktarının tahmini için katı madde anahtar eğrisi (KMAE) ve yapay zeka yöntemlerinden radyal taban fonksiyonlu destek vektör makineleri (DVM-RTF) için 5 farklı model (DVM-RTF 1, DVM-RTF 2, DVM-RTF 3, DVM-RTF 4, DVM-RTF 5), DVM-PÇF modeli için 5 model (DVM-PÇF 1, DVM-PÇF 2, DVM-PÇF 3, DVM-PÇF 4, DVM-PÇF 5) ve GRYSA modeli için 5 model (GRYSA 1, GRYSA 2, GRYSA 3, GRYSA 4, GRYSA 5) uygulanmıştır. Uygulama alanı olarak Amerika Birleşik Devletleri'ndeki Nebraska Eyaleti'nde bulunan Dauglos country bölgesi seçilmiştir ve Missouri nehri üzerindeki Omaha istasyonu incelenmiştir.

Günlük yağış miktarı (P), günlük sıcaklık (T), günlük debi (Q), günlük sediment (S) gibi hidrolojik parametreleri içeren modellerin oluşturulması amacı ile düzenlenen verilerin yaklaşık 6 yıla yakın toplam 2139 günlük verinin 1604'ü eğitim için, son 535 günlük veri nehirlerdeki katı madde miktarını tahmin etmek için girdi verileri olarak kullanılmıştır. İstatistiksel performans değerlendirme ölçütü olarak korelasyon katsayısı (R), ortalama karesel hataların karekökü (KKOH), mutlak ortalama hata (MOH) kullanılmıştır.

Tüm model sonuçları karşılaştırıldığında, KMAE tahminleri en düşük performans göstermiştir.

Çalışma sonucunda üç yapay zeka yönteminin de uygulanabilir olduğu, özellikle DVM-PÇF 4, DVM-PÇF 5, DVM RTF 4, DVM RTF 5 ve GRYSA 4 modelinin problem için uygun olduğu sonucuna varılmıştır. Bu çalışmada kullanılan yöntemler nehirlerdeki katı madde miktarının tahmininde önerilip, katı madde problemlerinde yararlı bir tahmin aracı olabileceğini göstermektedir.

Belirli bir yer için oluşturulan DVM model çalışmalarında, tahminlerin gözlenen değerlere yakınlığı açısından, gerek hata seviyesinin düşük olması gerekse katı madde konsantrasyonu tahmini için diğer yöntemlerden oldukça faydalı bir yöntem olarak kullanılabilir.

DVM olayın doğrusal olmayan boyutunu da göz önüne aldığı için diğer yöntemlere göre avantajlıdır. Bu anlamda, mühendislik dallarında özellikle çözümü zor olan non-lineer problemlerin çözümünde kolaylıkla uygulanabilir.

Modelin oluşturulma safhası ve çözümünde, araştırmacıların yapmış olduğu gözlem ve tecrübelerini de modele katarak gerçeğe daha yakın modeller oluşturulabilmektedir.

Sonuç olarak destek vektör makineleri ve yapay sinir ağları yöntemleri, iklimsel veriler ve nehir verileri kullanılarak nehirlerdeki katı maddelerinin modellenmesinde kullanılmış, DVM'nin YSA'ya göre sonuçların kullanılabilir düzeyde anlamlı olduğu istatistiksel değerlendirme yöntemleri kullanılarak belirlenmiştir.

İleride yapılacak çalışmalarda farklı girdi değişkenleri kullanılarak toplam katı madde konsantrasyonu tahminine yönelik çalışmalar yapılabilir.

Su kaynaklarının doğru yönetimi için, farklı bölgelerdeki nehirlerde katı madde miktarının tahminlerinde yeni yapay zekâ yöntemlerinden destek vektör makinesi tavsiye edilmektedir.

KAYNAKLAR

- Ağtaş, A. (2017). Devrek ve Devrekâni Çaylarında Taşınan Sediment Miktarının Yapay Zekâ Metotlarıyla Tahmini. T.C. Bartın Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi BARTIN.
- Allawi, M. F., Othman, F. B., Afan, H. A., Ahmed, A. N., Hossain, Md. S., Fai, C. M., El-Shafie, A. (2019). Reservoir Evaporation Prediction Modeling Based on Artificial Intelligence Methods. *Water* 11(6).
- Baltacı, A. (2012). Sacramento Nehrindeki Askı Maddesi Miktarının Bulanık Mantık ile Modellemesi. Mustafa Kemal Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı Yüksek Lisans Tezi Eylül Antakya/Hatay.
- Crawford, C.G., (1991). Estimation of Suspended-Sediment Rating Curves and Mean Suspended-Sediment Loads. *J. Hydrology*, 129, pp. 331-348.
- Üneş, F., Demirci, M., Kaya, Y. Z., Taşar, B., Varçin, H. (2017). Evapotranspiration Estimation Using Support Vector Machines and Hargreaves-Samani Equation for St. Johns, FL, USA. “*Environmental Engineering*” 10th International Conference.
- Demiröz, E.. (1989). Sediment Sampling Activities in Turkey. *Fourth International Symposium on River Sedimentation* , Beijing, China, Nov. 1-5.
- Erkek, C., Ağırlioğlu, N., (1993). *Su Kaynakları Mühendisliği*. İstanbul.
- [Google. www.google.com/](http://www.google.com/)
- Ghose, D. K., Sahoo, A., Tripaty, O., Samantaray S. (2019). Rainfall Forecasting Through ANN and SVM in Bolangir Watershed, India. *Smart Intelligent Computing and Applications* pp 767-774.
- He, W., Guo, T., Jiang, Z., Chu, X., Melekian R., Li, Z. (2019). An Improved LSSVM Model for Intelligent Prediction of the Daily Water Level. *Energies*, 12(1), 112.
- Hipni, A., El-sahife, A., Najah, A., Abdulkarim, O., Hussain, A., Mukhlisin A. (2013). Daily Forecasting of Dam Water Levels: Comparing a Support Vector Machine (SVM) Model With Adaptive Neuro Fuzzy Inference System (ANFIS). *Water Resources Management*. Volume 27, Issue 10, pp 3803–3823.
- Hui, L., Bilal, M., Kermani., M. Z., Kişi, Ö., Hu, B., Wang, L. (2017). Evaporation modelling using different machine learning techniques. *International Journal Of Climatology*. Volume37, IssueS1 August 2017 Pages: 1076-1092.
- Kaya, Y. Z., Mamak, M., Üneş, F. (2016). Evapotranspiration Prediction Using M5T Data Mining Method. *International Journal of Advanced Engineering Research and Science (IJAERS)*, Vol-3, Issue-12.

- Kişi, Ö., Moghaddam, A. A., Gorgij, A. D. (2016). Groundwater budget forecasting, using hybrid wavelet ANN-GP modelling: a case study of Azarshahr Plain, East Azerbaijan, Iran. *Hydrology Research* 48 (2): 455-467, Volume 48, Issue 2.
- Li, Z., Bafitlhile, M., T., (2019). Applicability of ε -Support Vector Machine and Artificial Neural Network for Flood Forecasting in Humid, Semi-Humid and Semi-Arid Basins in China. *Water*, 11(1), 85.
- Moeini, R., Babaei, M., Ehsanzadeh, E. (2019). Artificial Neural Network and Support Vector Machine Models for Inflow Prediction of Dam Reservoir (Case Study: Zayandehroud Dam Reservoir). *Water Resources Management* April 2019, Volume 33, Issue 6, pp 2203–2218.
- USGS.gov Science for a changing world [WWW Document], n.d. URL <https://www.usgs.gov/>
- Salas, J. D., Shin, H. S., (1999). Uncertainty analysis of reservoir sedimentation. *Journal of Hydraulic Engineering*, ASCE, 125, 4, April.
- Taşar, B., Üneş, F., Kaya, Y. Z., Varçin, H., Demirci, M. (2017). Forecasting of suspended sediment in rivers using artificial neural networks approach. *International Journal of Advanced Engineering Research and Science (IJAERS)*. Vol-4, Issue-12.
- Taşar, B., Demirci, M., Kaya, Y. Z., Üneş, F. (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *DÜMF Mühendislik Dergisi* 9:1, :543 – 551.
- Vansickle, J., Beschta, R. L., (1983). Supply-based models of suspended sediment transport in streams. *Water Resources Research*, 19, 3.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Newyork: Springer.
- Williams, J. R., (1978). A sediment graph model based on an instantaneous unit sediment graph. *Water Resources Research*, 14, 659-664.
- Yang, H., Chen, J., Lv, M., Xiao, Z., Wu, S., J. (2019). Estimation of monthly pan evaporation using support vector machine in Three Gorges Reservoir Area, China. *Theoretical and Applied Climatology*. October, Volume 138, [Issue 1–2](#), pp 1095–1107
- Yan, W., Yu, Y., Liu, Y., Du, J. (2017). A Prediction of Precipitation Data Based on Support Vector Machine and Particle Swarm Optimization (PSO-SVM) *Algorithms*. *Algorithms*, 10(2), 57.
- Zhoua, C., Yin, K., Caoa, Y., Ahmed, B. (2016). Application of time series analysis and PSO–SVM model in predicting the Bazimen landslide in the Three Gorges Reservoir, China . *Engineering Geology*, Volume 204, 8 April , Pages 108-120.

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : KARAEMİNOĞULLARI
 , Ahmet Burhan
 Uyuğu : T.C.
 Doğum tarihi ve yeri : 10.11.1986, Kırıkhan
 Medeni hali : Evli
 Telefon : 05357249936
 e-mail : burhanes_@hotmail.com
 burhankaraemin@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek Lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2020
Lisans	İskenderun Teknik Üniversitesi / İnşaat Mühendisliği	2011
Lise	Selim Nevzat Şahin Anadolu Lisesi	2004

İş Deneyimi

Yıl	Yer	Görev
2013-Halen	Kırıkhan Belediyesi	Mühendis
2011-2013	Özsafa İnşaat	Mühendis
2011-2012	Ceylanlar İnşaat	Mühendis

Yabancı Dil

İngilizce

Hobiler

Yüzme, Teknoloji, Spor

DİZİN

<hr/> <p>A</p> <p>Akarsu · I, IV, VI, 2, 3, 4, 5, 6, 7, 8</p> <p>Aski · I, IV, VI, VII, VIII, IX, X, 4, 5, 30, 31, 32, 32, 34, 35, 36, 37, 38 39, 40, 41, 42, 43, 44, 45, 46, 47 48, 49, 50, 51, 52, 53, 54, 55, 56 57, 58, 59, 60</p> <hr/> <p>D</p> <p>Destek Vektör Makinesi · I, IV, V, VI, VII, VIII, IX, 7, 8, 9, 10, 11, 17, 18, 19, 20, 21, 22, 23, 24, 29, 30, 31, 32, 33, 34, 35, 36 37, 38, 39, 40, 41, 42, 43, 44, 45 46, 47, 48, 49, 50, 51, 61, 62, 63</p> <hr/> <p>G</p> <p>Genelleştirilmiş yapay sinir ağı · I, IV, V, IX, X, XII, 17, 26 27, 28, 29, 53, 54, 55, 56 57, 58, 59, 60, 61, 62, 63</p> <hr/> <p>M</p> <p>Model · I, V, VI, 7, 8, 9, 10, 11, 17, 26, 29 30, 31, 32, 33, 34, 35, 36, 37, 38 39, 40, 41, 42, 43, 44, 45, 46, 48 49, 50, 51, 52, 53, 54, 55, 56, 57 58, 59, 60, 61, 62, 63</p>	<p>Missouri · I, II, VI, 12, 13, 14, 15, 16, 17, 6 3</p> <hr/> <p>O</p> <p>Ortalama Kareysel Hataların karakökü · I, XII, 9, 11, 29, 61, 62, 63</p> <p>Ortalama Mutlak Hata · I, XII, 9, 11, 29, 61, 62, 63</p> <hr/> <p>K</p> <p>Katı madde · I, IV, VI, 2, 3, 4, 5, 6, 7, 14, 63</p> <hr/> <p>P</p> <p>PÇF · · I, IV, V, VIII, IX, 8, 9, 10, 11, 12 , 17, 19, 24, 29, 40, 41, 42, 43, 44 , 45, 46, 47, 48, 49, 50, 61, 62, 63</p> <hr/> <p>R</p> <p>RBF · I, IV, V, VIII, IX, 12, 17, 24, 25, 26, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 61, 62, 63</p> <hr/> <p>Y</p> <p>Yapay Sinir Ağı · I, IV, XII, 7, 8, 9, 11, 12, 26</p>
--	---



TEKNOVERSİTE





teknoversite **AYRICALIĞINDASINIZ**

İSTE

