



**T.C.
AKSARAY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI

**APA BARAJI HAVZASINDAKİ HİDROLOJİK
PARAMETRELERİN MAKİNE ÖĞRENMESİ İLE TAHMİNİ**

DOKTORA TEZİ

Türker TUĞRUL

DANIŞMAN

Prof. Dr. Mehmet Ali HINIS

AKSARAY, 2024

Aksaray Üniversitesi Fen Bilimleri Enstitüsü'nün 182357401 numaralı Doktora öğrencisi Türker TUĞRUL tarafından hazırlanan “(APA BARAJI HAVZASINDAKİ HİDROLOJİK PARAMETRELERİN MAKİNE ÖĞRENMESİ İLE TAHMİNİ)” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ/OY ÇOKLUĞU ile İnşaat Mühendisliği Anabilim Dalında DOKTORA TEZİ olarak kabul edilmiştir.

Danışman: Prof. Dr. Mehmet Ali HINIS

AKSARAY ÜNİVERSİTESİ

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Prof. Dr. Ömer KÖSE

AKSARAY ÜNİVERSİTESİ

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Prof. Dr. Meral BÜYÜKYILDIZ

KONYA TEKNİK ÜNİVERSİTESİ

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Prof. Dr. Yurdagül KUMCU

NECMETTİN ERBAKAN ÜNİVERSİTESİ

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.....

Üye: Prof. Dr. Kadri YÜREKLİ

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

Bu tezin, kapsam ve kalite olarak Doktora Tezi olduğunu onaylıyorum/onaylamıyorum.....

Tez Savunma Tarihi: 02/02/2024

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

Prof. Dr. Mehmet Ali HINIS

Fen Bilimleri Enstitüsü Müdürü

DOĞRULUK BEYANI

Doktora tezi olarak sunduđum bu alıřmayı, akademik kurallara ve bilimsel etik, ahlak ve geleneklere aykırı dűşecek bir yol ve yardıma bařvurmaksızın yazdıđımı, yararlandıđım eserlerin kaynakada gűsterilenlerden olduđuunu, alıřmamda kullandıđım verilerin orijinalliđini ve her tűrlű intihalden uzak olduđuunu beyan ederim.

Enstitű tarafından belli bir zamana bađlı olmaksızın, tezimle ilgili yaptıđım bu beyana aykırı bir durumun saptanması durumunda, ortaya ıkacak tűm ahlaki ve hukuki sonulara katlanacađımı bildiririm.

İmza

Tűrker TUĐRUL

TEŞEKKÜR

Yıllar boyunca ciddi bir emek ve özveri ile hazırlamış olduğum doktora temizi bitirmenin heyecanını ve gururunu yaşıyorum. Bu bölümü, tez sürecimde bana yardımcı olan aşağıda isimleri belirtilen kişi ve kurumlara teşekkür etmek için bir fırsat olarak kullanacağım.

Bu çalışmanın yürütülmesi esnasında sadece bilimsel katkıları ile değil aynı zamanda hem maddi hem de manevi desteğini esirgemeyen, danışmanlığımı üstlenen tez konumu seçmemde büyük katkıları olan, doktora öğrencisinin yeterliliğini göstermesine olanak sağlayan, Prof. Dr. Mehmet Ali HINIS'a, aileme, akrabalarım, teşekkür etmeyi borç bilirim.

Tezimin gerçekleşmesinde 2022-010 numaralı proje ile maddi destek sağlayan Aksaray Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi'ne ve çalışma alanıma ait verinin temin edilmesinde bana ücret karşılığında veri temin eden Devlet Su İşleri Genel Müdürlüğü, İşletme ve Bakım Dairesi Başkanlığı, Havza İşletme Şube Müdürlüğü'ne ayrıca teşekkür ederim.

Türker TUĞRUL

AKSARAY, 2024

İÇİNDEKİLER

TEŞEKKÜR	i
İÇİNDEKİLER	ii
ÖZET.....	iv
ABSTRACT	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR	xiv
1. GİRİŞ	1
1.1. Çalışmanın Amacı	10
2. KAYNAK ÖZETLERİ	11
2.1. Kuraklık Tahmin Modelleme Çalışmaları.....	12
2.2. Yağış-Akış Tahmin ve Baraj Göl Seviyesi Tahmin Modelleme Çalışmaları	17
3. MALZEME VE YÖNTEM	23
3.1. Çalışma Alanı ve Veri Seti	23
3.2. Yöntemler	25
3.2.1. Standartlaştırılmış yağış indisi (SYİ).....	25
3.2.2. Akış kuraklık indisi (AKİ).....	27
3.2.3. Rastgele orman (RO)	28
3.2.4. Yapay sinir ağları (YSA)	29
3.2.5. Destek vektör makineleri (DVM)	31
3.2.6. Karar ağaçları (KA)	35
3.2.7. Dalgacık dönüşüm tekniği	36
3.2.8. İstatistiksel olarak performans değerlendirme kriterleri	39
4. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	41
4.1. Kuraklık Analizi	41
4.2. Kuraklık Tahmin Modelleri.....	52
4.2.1. DVM ile analiz sonuçları	55
4.2.2. YSA ile analiz sonuçları	72
4.2.3. RO ile analiz sonuçları	89
4.2.4. KA ile analiz sonuçları	107
4.3. Yağış-akış Tahmin Modelleri.....	125
4.3.1. DVM ile analiz sonuçları	131
4.3.2. YSA ile analiz sonuçları	138
4.3.3. RO ile analiz sonuçları	144
4.3.4. KA ile analiz sonuçları	150
4.4. Baraj Göl Seviyesi Tahmin Modelleri.....	155
4.4.1. DVM ile analiz sonuçları	159
4.4.2. YSA ile analiz sonuçları	166
4.4.3. RO ile analiz sonuçları	173
4.4.4. KA ile analiz sonuçları	180
4.5. Tüm Analiz Sonuçlarının Karşılaştırılması	186
4.5.1. Kuraklık tahmin modelleri karşılaştırılması	186
4.5.2. Yağış-akış tahmin modelleri karşılaştırılması	196
4.5.3. Baraj göl seviyesi tahmin modelleri karşılaştırılması.....	198
5. SONUÇ VE ÖNERİLER.....	201
5.1. Kuraklık Analizleri	201
5.2. Kuraklık Tahmin Modelleri.....	201
5.3. Yağış-akış Tahmin Modelleri.....	217

5.4. Baraj Göl Seviyesi Tahmin Modelleri.....	222
KAYNAKLAR	229
ÖZGEÇMİŞ	237



DOKTORA TEZİ

APA BARAJI HAVZASINDAKİ HİDROLOJİK PARAMETRELERİN MAKİNE ÖĞRENMESİ İLE TAHMİNİ

Türker TUĞRUL

**Aksaray Üniversitesi
Fen Bilimleri Enstitüsü
İnşaat Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Mehmet Ali HİNİS

ÖZET

Son yıllarda, özellikle de sanayi devriminden sonra insanoğlunun suya olan ihtiyacı artmıştır. Canlılar için yaşamsal önemi tartışılmaz olan bu suyun, gelecekteki ve mevcut miktarının korunması tüm insanoğlunu ilgilendiren bir konu haline gelmekten ötesine geçmiş, herkesin bu konu hakkında neler yapılabileceği son günlerde tartışılır hale gelmiştir. Ortalama yağış miktarından belli bir periyod boyunca görülen azalma olarak tanımlanan kuraklık, su kaynaklarına mevcudiyetine etki eden unsurlar arasındadır. Kuraklık doğal afetler arasından en sinsi olanlardan birisidir ve gerçekleştiğinde insanoğlu bunun farkına varmayabilir.

Kuraklık olaylarını izlemek, değerlendirmek için genellikle kuraklık indislerinden yararlanılmaktadır. Bu çalışmada da kuraklık indisi olarak Standartlaştırılmış Yağış İndisi (SYİ) ve Akış Kuraklık İndisinden (AKİ) faydalanılmıştır. Bunların yanı sıra, kuraklıklara etki eden ve hesaplarında kullanılan hidrolojik ve meteorolojik verilerden de istifade edilmiştir. En geniş aralık olan 1955-2022 yıllarını kapsayan aylık toplam yağış, aylık ortalama sıcaklık, aylık maksimum sıcaklık, aylık minimum sıcaklık, aylık ortalama baraj göl seviyesi kotu, aylık ortalama baraj hacim verisi, aylık ortalama akım verisi bu çalışmada kullanılmıştır. Çalışma alanı olarak, Türkiye'nin tahıl ihtiyacının önemli bir kısmını gideren Konya Kapalı Havzası'nın orta kesimlerinde yer alan Apa Barajı Bölgesi seçilmiştir.

Geçmişten günümüze kadar insanoğlu çevresel problemler ile büyük bir mücadele vermektedir. Bu mücadelede, bilim insanları alternatif çözüm yolları aramaktadır. Hemen hemen her problemde olduğu gibi, bir soruna çözüm bulmanın en iyi yöntemlerden birisi, geçmiş deneyimlerimizden yararlanarak geleceğe yönelik tahminlerde bulunmaktır. Hidrolojide de geçmişteki veriden faydalanarak geçmişteki davranışların değişmeyeceği varsayılarak gelecekteki eylemler tahmin edilebilir ve su döngüsü, su kaynaklarının planlanması, havza yönetimi, kuraklık analizi, matematiksel modelleme gibi konularda çalışılmaktadır.

Tüm bunlardan esinlenerek, bu çalışmada Konya Kapalı Havzasında yer alan Apa Barajı bölgesine etki eden hidrolojik parametreleri tahmin edebilmek için çeşitli makine öğrenme yöntemlerinden yararlanılmıştır. Bu çalışmada kullanılan makine öğrenme yöntemleri Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA), Karar Ağaçları (KA), Rastgele Orman (RO)'dir. Yağışı esas olan 3 farklı model

kurulmuştur. Bu modeller kuraklık tahmin modeli, yağış-akış tahmin modeli, baraj göl seviyesi tahmin modelidir. Bu modellerin iyileştirilmesi için dalgacık dönüşümünden faydalanılmıştır. Kurulan modeller hem birbirleri ile hem de makine öğrenme algoritmaları performanslarına göre birbiriyle kıyaslanmıştır. Model performanslarının kıyaslanması için Nash-Sutcliffe (NS), Kök Ortalama Kare Hata (RMSE) ve Korelasyon katsayısından (r) faydalanılmıştır.

Çalışmanın sonucunda; kuraklık tahmin modellerinde DVM'nin genellikle diğer algoritmalara göre daha iyi sonuç verdiği belirlenmiştir. Kuraklık tahmin modellerinde model girdi yapısı hem sadece SYİ hem de aylık toplam yağış verisi ile oluşturulan modellerin diğer modellere göre daha etkili performans gösterdiği tespit edilmiştir. Kuraklık tahmin modellerinde en başarılı model, DVM'nin dalgacık dönüşümünde tespit edilen (NS: 0.9970, RMSE: 0.0498, r: 0.9986 performans değerleri ile) M05'dir. Yağış-akış tahmin modellerinde; dalgacık dönüşümü olmadan yapılan analizlerde DVM ve RO genellikle diğer algoritmalara göre daha iyi sonuç vermiştir. Burada model yapısına veri çeşitliliğinin artırılması model performans parametrelerini olumlu yönde etkilemiştir. Bu çalışmadaki yağış-akış modellemesinde dikkat çeken bulgulardan biri, dalgacık dönüşümü sonrasında, giriş yapısında sadece akış verilerinin kullanılmasının, önceki dalgacık dönüşümü olmayan modellerdeki bulguların aksine, model performanslarını olumlu yönde etkilemesidir. M26 (NS: 0.9781, RMSE: 0.2989, r: 0.9893), bu sınıfta en etkili sonucu vermiştir. Baraj göl seviyesi tahmin modellerinde de; dalgacık dönüşümü olmadan RO ve DVM, diğer algoritmalara göre üstünlük sağlamıştır. Model girdi yapısında baraj hacmi ve baraj göl seviyesi verisinin kullanılması model performanslarını artırmıştır. Dalgacık dönüşümünden sonra ise model girdi yapısında akış verisi ve kot verisinden oluşturulan M18 (NS: 0.9851, RMSE: 0.6942, r: 0.9926), diğer modellere göre üstün performans göstermiştir.

Anahtar Kelimeler: Kuraklık, Kuraklık Modellemesi, Baraj Yönetimi, Akış Modellemesi, Baraj Göl Seviyesi Modellemesi.

Şubat, 2024; 237 sayfa

PhD. THESIS

ESTIMATION OF HYDROLOGICAL PARAMETERS IN APA DAM BASIN BY MEANS OF MACHINE LEARNING

Türker TUĞRUL

**Aksaray University
Graduate School of Natural and Applied Sciences
Department of Civil Engineering**

Supervisor: Prof. Dr. Mehmet Ali HINIS

ABSTRACT

In recent years, especially after the industrial revolution, humankind's need for water has increased. The preservation of the future and current amounts of this water, whose vital importance for living things is indisputable, has gone beyond becoming an issue that concerns all human beings and has become debatable what everyone can do about this issue in recent days. Drought, defined as a decrease in the average rainfall over a certain period, is among the factors that affect the availability of water resources. Drought is one of the most insidious natural disasters. When it occurs, people may not be aware of it.

Drought indices are generally used to monitor and evaluate drought events. In this study, Standardized Precipitation Index (SPI) and Streamflow Drought Index (SFI) were used as drought index. In addition, hydrological and meteorological data affecting droughts and used in their calculations were also utilized. Monthly total precipitation, monthly average temperature, monthly maximum temperature, monthly minimum temperature, monthly average dam lake level elevation, monthly average dam volume data, monthly average flow data covering the widest range of 1955-2022 were used in this study. The Apa Dam Region, located in the middle parts of the Konya Closed Basin which meets a significant part of Turkey's grain needs, was chosen as the study area.

From past to present, human beings have been struggling with environmental problems. In this struggle, scientists are looking for alternative solutions for the drought phenomena. As with almost every problem, one of the best ways to find a solution to a problem is to make future predictions by taking advantage of our past experiences. In hydrology, future actions can be predicted by using past data - assuming that past behavior will not change - and studies are carried out on topics such as water cycle, water resources planning, basin management, drought analysis and mathematical modeling.

Inspired by all these, in this study machine learning algorithms, Support Vector Machines, Artificial Neural Networks, Decision Trees, Random Forest, Multiple Support Vectors were used to predict the hydrological parameters affecting the Apa Dam Region, Konya. Subsequently, 3 different models were established. These models are drought prediction model, rainfall-runoff prediction model, dam lake level

prediction model. Wavelet transform was used to improve these models and increase their predictive power. Both the established models were compared with each other according to their performance, and the machine learning algorithms were compared with each other according to statistical criteria. For this purpose, Nash-Sutcliffe Efficiency(NS), Root Mean Square Error (RMSE), Correlation Coefficient (r) were used to compare model performances.

As a result of the study, it has been determined that SVM generally gives better results than other algorithms in drought prediction models. In drought prediction models, it has been determined that models whose model input structure is created with both SPI and monthly total precipitation data perform more effectively than other models. The most successful model in drought prediction models is M05, which was determined in the wavelet transform of SVM (with performance values of NS:0.9970, RMSE:0.0498, r:0.9986). In rainfall-runoff prediction models; in analyzes performed without wavelet transform, SVM and RO generally gave better results than other algorithms. Here, increasing the data diversity in the model structure positively affected the model performance parameters. One of the striking findings in the rainfall-runoff modeling in this study is that using only flow data in the input structure after wavelet transformation positively affects model performances, unlike the findings in previous models without wavelet transformation. M26 (NS: 0.9781, RMSE: 0.2989, r: 0.9893) gave the most effective result in this class. In dam lake level prediction models; RO and SVM without wavelet transform are superior to other algorithms. Using dam volume and dam lake level data in the model input structure increased model performances. After wavelet transformation, M18 (NS: 0.9851, RMSE: 0.6942, r: 0.9926), which was created from flow data and elevation data in the model input structure, showed superior performance compared to other models.

Keywords: Drought, Drought Modelling, Dam Management, Streamflow Modelling, Dam Lake Level Modelling.

February, 2024; 237 pages

ŞEKİLLER DİZİNİ

Şekil 1.1. Veri madenciliğinin kullanım alanları	6
Şekil 1.2. Tez çalışması zaman çizelgesi.	9
Şekil 3.1. Apa Barajı bölgesi fiziki haritası	24
Şekil 3.2. Çok Katmanlı Algılayıcı Sinir Ağı örnek yapısı	31
Şekil 3.3. İki sınıflı destek vektörleri.....	33
Şekil 3.4. Örnek dalgacıklar.....	37
Şekil 3.5. Dalgacık dönüşümünde yaklaşım ve detaylar	39
Şekil 4.1. Yağış değerlerinin zaman serisi.....	41
Şekil 4.2. SYİ1 indis değerlerinin zaman serisi.....	44
Şekil 4.3. SYİ3 indis değerlerinin zaman serisi.....	46
Şekil 4.4. SYİ6 indis değerlerinin zaman serisi.....	48
Şekil 4.5. SYİ9 indis değerlerinin zaman serisi.....	49
Şekil 4.6. SYİ12 indis değerlerinin zaman serisi.....	51
Şekil 4.7. SYİ24 indis değerlerinin zaman serisi.....	52
Şekil 4.8. Kuraklık modelleri çapraz korelasyon örnekleri a) SYİ, b) Yağış	53
Şekil 4.9. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları.....	57
Şekil 4.10. SYİ24 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	58
Şekil 4.11. SYİ12 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	60
Şekil 4.12. SYİ9 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	62
Şekil 4.13. SYİ6 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	63
Şekil 4.14. SYİ3 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	64
Şekil 4.15. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları.....	65
Şekil 4.16. Dalgacık dönüşümü ile SYİ24 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	67
Şekil 4.17. Dalgacık dönüşümü ile SYİ12 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	68
Şekil 4.18. Dalgacık dönüşümü ile SYİ9 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	70
Şekil 4.19. Dalgacık dönüşümü ile SYİ6 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	71
Şekil 4.20. Dalgacık dönüşümü ile SYİ3 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları	72
Şekil 4.21. Dalgacık dönüşümü öncesi YSA analiz özet sonuçları	73
Şekil 4.22. SYİ24 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	76
Şekil 4.23. SYİ12 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	77
Şekil 4.24. SYİ9 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	78
Şekil 4.25. SYİ6 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	80

Şekil 4.26. SYİ3 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	81
Şekil 4.27. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları	82
Şekil 4.28. Dalgacık dönüşümü ile SYİ24 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	84
Şekil 4.29. Dalgacık dönüşümü ile SYİ12 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	85
Şekil 4.30. Dalgacık dönüşümü ile SYİ9 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	87
Şekil 4.31. Dalgacık dönüşümü ile SYİ6 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	88
Şekil 4.32. Dalgacık dönüşümü ile SYİ3 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	89
Şekil 4.33. Dalgacık dönüşümü öncesi RO analiz özet sonuçları.....	90
Şekil 4.34. SYİ24 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	93
Şekil 4.35. SYİ12 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	94
Şekil 4.36. SYİ9 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	96
Şekil 4.37. SYİ6 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	97
Şekil 4.38. SYİ3 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	99
Şekil 4.39. Dalgacık dönüşümü sonrası RO analiz özet sonuçları	101
Şekil 4.40. Dalgacık dönüşümü ile SYİ24 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	102
Şekil 4.41. Dalgacık dönüşümü ile SYİ12 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	103
Şekil 4.42. Dalgacık dönüşümü ile SYİ9 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	104
Şekil 4.43. Dalgacık dönüşümü ile SYİ6 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	105
Şekil 4.44. Dalgacık dönüşümü ile SYİ3 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları	107
Şekil 4.45. Dalgacık dönüşümü öncesi KA analiz özet sonuçları	109
Şekil 4.46. SYİ24 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	111
Şekil 4.47. SYİ12 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	112
Şekil 4.48. SYİ9 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	114
Şekil 4.49. SYİ6 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	115
Şekil 4.50. SYİ3 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	117
Şekil 4.51. Dalgacık dönüşümü sonrası KA analiz özet sonuçları.....	118
Şekil 4.52. Dalgacık dönüşümü ile SYİ24 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları	120

Şekil 4.53. Dalgacık dönüşümü ile SYİ12 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları	122
Şekil 4.54. Dalgacık dönüşümü ile SYİ9 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları	123
Şekil 4.55. Dalgacık dönüşümü ile SYİ6 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları	124
Şekil 4.56. Dalgacık dönüşümü ile SYİ3 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları	125
Şekil 4.57. AKİ1 indis değerlerinin zaman serisi	126
Şekil 4.58. AKİ3 indis değerlerinin zaman serisi	127
Şekil 4.59. AKİ6 indis değerlerinin zaman serisi	127
Şekil 4.60. AKİ12 indis değerlerinin zaman serisi	128
Şekil 4.61. Yağış akış tahmin modelleri çapraz korelasyon örnekleri a) AKİ, b) Yağış	129
Şekil 4.62. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları.....	132
Şekil 4.63. DVM için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	134
Şekil 4.64. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları.....	137
Şekil 4.65. Dalgacık dönüşümü ile DVM için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	137
Şekil 4.66. YSA analiz özet sonuçları	138
Şekil 4.67. YSA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	140
Şekil 4.68. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları	141
Şekil 4.69. Dalgacık dönüşümü ile YSA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	143
Şekil 4.70. Dalgacık dönüşümü öncesi RO analiz özet sonuçları.....	144
Şekil 4.71. RO için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	146
Şekil 4.72. Dalgacık dönüşümü sonrası RO analiz özet sonuçları	147
Şekil 4.73. Dalgacık dönüşümü ile RO için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı.....	149
Şekil 4.74. Dalgacık dönüşümü öncesi KA analiz özet sonuçları	150
Şekil 4.75. KA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	152
Şekil 4.76. Dalgacık dönüşümü sonrası KA analiz özet sonuçları	153
Şekil 4.77. Dalgacık dönüşümü ile KA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı.....	155
Şekil 4.78. Çapraz korelasyon örnekleri a) hacim, b) akış, c) SYİ12, d) AKİ12	156
Şekil 4.79. Baraj göl seviyesi.....	157
Şekil 4.80. Baraj hacim verisi	157
Şekil 4.81. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları.....	160
Şekil 4.82. DVM için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	163
Şekil 4.83. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları.....	164
Şekil 4.84. Dalgacık dönüşümü ile DVM için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	166
Şekil 4.85. Dalgacık dönüşümü öncesi YSA analiz özet sonuçları	167
Şekil 4.86. YSA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı.....	169

Şekil 4.87. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları	170
Şekil 4.88. Dalgacık dönüşümü ile YSA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	173
Şekil 4.89. Dalgacık dönüşümü öncesi RO analiz özet sonuçları.....	174
Şekil 4.90. RO için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı.....	176
Şekil 4.91. Dalgacık dönüşümü sonrası RO analiz özet sonuçları	177
Şekil 4.92. Dalgacık dönüşümü ile RO için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	179
Şekil 4.93. Dalgacık dönüşümü öncesi KA analiz özet sonuçları	180
Şekil 4.94. KA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı.....	182
Şekil 4.95. Dalgacık dönüşümü sonrası KA analiz özet sonuçları	183
Şekil 4.96. Dalgacık dönüşümü ile KA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı	185
Şekil 4.97. SYİ24 ile en başarılı kuraklık tahmin modellerinin Taylor Diyagramı.	187
Şekil 4.98. SYİ24 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı.....	188
Şekil 4.99. SYİ12 ile en başarılı kuraklık tahmin modellerinin Taylor Diyagramı.	189
Şekil 4.100. SYİ12 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı.....	190
Şekil 4.101. SYİ9 verisi içeren en başarılı kuraklık tahmin modellerinin Taylor Diyagramı.....	191
Şekil 4.102. SYİ9 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı.....	192
Şekil 4.103. SYİ6 verisi içeren en başarılı kuraklık tahmin modellerinin Taylor Diyagramı.....	193
Şekil 4.104. SYİ6 verisi içeren en başarılı kuraklık tahmin modellerinin violin diyagramı.....	194
Şekil 4.105. SYİ3 verisi içeren en başarılı kuraklık tahmin modellerinin Taylor Diyagramı.....	195
Şekil 4.106. SYİ3 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı.....	196
Şekil 4.107. En başarılı yağış-akış tahmin modellerinin Taylor Diyagramı.....	197
Şekil 4.108. En başarılı yağış-akış tahmin modellerinin Violin Diyagramı	198
Şekil 4.109. En başarılı baraj göl seviyesi tahmin modellerinin Taylor Diyagramı	199
Şekil 4.110. En başarılı baraj göl seviyesi tahmin modellerinin Violin Diyagramı	200

ÇİZELGELER DİZİNİ

Çizelge 3.1. Veri özet tablosu	25
Çizelge 3.2. SYİ indis değerlerine göre kuraklık kategorileri (McKee vd., 1993)....	27
Çizelge 4.1 SYİ değerlerinin yüzdesel olarak dağılım histogramı	42
Çizelge 4.2. SYİ1 ile elde edilen indis sonuçları	42
Çizelge 4.2 (devam). SYİ1 ile elde edilen indis sonuçları	43
Çizelge 4.2 (devam). SYİ1 ile elde edilen indis sonuçları	44
Çizelge 4.3. SYİ3 ile elde edilen indis sonuçları	45
Çizelge 4.3 (devam). SYİ3 ile elde edilen indis sonuçları	46
Çizelge 4.4. SYİ6 ile elde edilen indis sonuçları	47
Çizelge 4.5. SYİ9 ile elde edilen indis sonuçları	48
Çizelge 4.5 (devam). SYİ9 ile elde edilen indis sonuçları	49
Çizelge 4.6. SYİ12 ile elde edilen indis sonuçları	50
Çizelge 4.7. SYİ24 ile elde edilen indis sonuçları	51
Çizelge 4.8. Kuraklık tahmininde oluşturulan modeller.....	53
Çizelge 4.8 (devam). Kuraklık tahmininde oluşturulan modeller	54
Çizelge 4.9. DVM ile yapılan analiz sonuçları	55
Çizelge 4.9 (devam). DVM ile yapılan analiz sonuçları	56
Çizelge 4.10. Dalgacık dönüşümü ile DVM analiz sonuçları.....	65
Çizelge 4.10. Dalgacık dönüşümü ile DVM analiz sonuçları.....	66
Çizelge 4.11. YSA ile analiz sonuçları	74
Çizelge 4.12. Dalgacık dönüşümü ile YSA analiz sonuçları	82
Çizelge 4.12 (devam). Dalgacık dönüşümü ile YSA analiz sonuçları	83
Çizelge 4.13. RO ile analiz sonuçları.....	90
Çizelge 4.13 (devam). RO ile analiz sonuçları	91
Çizelge 4.14. Dalgacık dönüşümü ile RO analiz sonuçları	99
Çizelge 4.14 (devam). Dalgacık dönüşümü ile RO analiz sonuçları	100
Çizelge 4.15. KA ile analiz sonuçları	108
Çizelge 4.16. Dalgacık dönüşümü ile KA analiz sonuçları	119
Çizelge 4.17. Yağış-akış tahmininde oluşturulan modeller	129
Çizelge 4.17 (devam). Yağış-akış tahmininde oluşturulan modeller	130
Çizelge 4.18. DVM ile yapılan analiz sonuçları	132
Çizelge 4.18 (devam). DVM ile yapılan analiz sonuçları	133
Çizelge 4.19. Dalgacık dönüşümü ile DVM analiz sonuçları.....	135
Çizelge 4.20. YSA ile yapılan analiz sonuçları	139
Çizelge 4.21. Dalgacık dönüşümü ile YSA analiz sonuçları	142
Çizelge 4.22. RO ile yapılan analiz sonuçları.....	145
Çizelge 4.23. Dalgacık dönüşümü ile RO analiz sonuçları	148
Çizelge 4.24. KA ile analiz sonuçları	151
Çizelge 4.25. Dalgacık dönüşümü ile KA analiz sonuçları	153
Çizelge 4.25 (devam). Dalgacık dönüşümü ile KA analiz sonuçları	154
Çizelge 4.26. Baraj göl seviyesi tahmininde oluşturulan modeller	158
Çizelge 4.26 (devam). Baraj göl seviyesi tahmininde oluşturulan modeller	159
Çizelge 4.27. DVM ile yapılan analiz sonuçları	161
Çizelge 4.27 (devam). DVM ile yapılan analiz sonuçları	162
Çizelge 4.28. Dalgacık dönüşümü ile DVM analiz sonuçları.....	164
Çizelge 4.28 (devam). Dalgacık dönüşümü ile DVM analiz sonuçları.....	165
Çizelge 4.29. YSA analiz sonuçları	168

Çizelge 4.29 (devam). YSA analiz sonuçları	169
Çizelge 4.30. Dalgacık dönüşümü ile YSA analiz sonuçları	171
Çizelge 4.30 (devam). Dalgacık dönüşümü ile YSA analiz sonuçları	172
Çizelge 4.31. RO analiz sonuçları	175
Çizelge 4.31 (devam). RO analiz sonuçları	176
Çizelge 4.32. Dalgacık dönüşümü ile RO analiz sonuçları	178
Çizelge 4.32 (devam). Dalgacık dönüşümü ile RO analiz sonuçları	179
Çizelge 4.33. KA analiz sonuçları	181
Çizelge 4.33 (devam). KA analiz sonuçları	182
Çizelge 4.34. Dalgacık Dönüşümü ile KA analiz sonuçları	184



SİMGELER VE KISALTMALAR

AKİ	Akış Kuraklık İndisi
AMA	Ampirik Mod Ayırımı
ANFIS	Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi
ARIMA	Otoregresif Entegre Hareketli Ortalama
AT	Ağaç Toplulukları
C	Ceza Parametresi
CART	Sınıflandırma ve Regresyon Ağaçları
CG	Conjugate-Gradient
COLT	Computational Learning Theory
DSİ	Devlet Su İşleri Genel Müdürlüğü
DVM	Destek Vektör Makineleri
DVM-RSM	Destek Vektör Makineleri Yanıt Yüzey Yöntemi
DVM-PSO	Destek Vektör Makineleri Parçacık Optimizasyonu
EKİ	Efektif Kurak İndisi
ELM	Aşırı Öğrenme Makinesi
EN	Elastik Net
FD	Fourier Dönüşümü
GBSA	Geri Beslemeli Sinir Ağları
GRNN	Genelleştirilmiş Regresyon Sinir Ağı
GPR	Gauss Süreci Regresyonu
KNN	k-En Yakın Komşu
LM	Levenberg-Marquardt
LR	Linner Regresyon
MAE	Ortalama Mutlak Hata
MARS	Çoklu Adaptif Regresyon Enterpolasyonu
MLP	Çok Katmanlı Algılayıcı Sinir Ağı
MLR	Çoklu Lineer Regresyon
MSE	Ortalama Kare Hata
M5B	Budanmış M5 Regresyon Ağaçları
NS	Nash-Sutcliffe
PKŞİ	Palmer Kuraklık Şiddet İndisi
RA	Rastgele Ağaç
RO	Rastgele Orman
REA	Regresyon Ağaç
RMSE	Kök Ortalama Kare Hata
OOB	Out-of-bag
SYİ	Standartlaştırılmış Yağış İndisi (SPI)
SPEI	Standartlaştırılmış Yağış Buharlaştırma İndisi
TSA	Tekrarlayan Sinir Ağı
YAOEAÖM	Yarasa Algoritması Optimize Edilmiş Aşırı Öğrenme Makinesi
YSA	Yapay Sinir Ağları (ANN)
QN	Quasi-Newton
WANN	Dalgacık Sinir Ağı
Wİ	Wilmott's İndisi
XGBOOST	Aşırı Gradyan Artırma
ξ	Esneklik Değişkeni

1. GİRİŞ

Su, sosyal ve ekonomik kalkınmanın temel unsuru olarak kabul edilen önemli bir doğal kaynaktır. Genel olarak su kaynakları yoğun baskı altındadır veya dünya çapında birçok alanda su arzı ve talebi arasında uyumsuzluk yaşanmaktadır. Son yıllarda, özellikle de sanayi devriminden sonra mevcut suya ulaşım ve var olan suyun kullanımı hakkında insanoğlu sürekli bilinçlenmektedir. Yaşam standartlarının da artmasına bağlı olarak su gibi doğal kaynakların bilinçsiz tüketimi hızlanmış, konusu su ile ilgili olan birçok çalışma bilim dünyasında araştırmacıların vazgeçilmez konularından birisi haline gelmiştir. Küresel anlamda bu konu sadece bilim insanlarının değil, yerküre üzerinde yaşayan tüm insanların ilgisini çekmiştir. Dolayısıyla, suyun varlığı ve korunması ile mücadele etmek, olası tehlikelere karşı önlem almak, yalnızca bilim insanlarının uğraşı olmasından çıkmış, toplumun bütün kesimlerini ilgilendiren karmaşık bir olguya dönüşmüştür. Hatta canlılar için yaşamsal önemi tartışılmaz olan suyun, gelecekteki ve mevcut miktarının korunması tüm insanoğlunu ilgilendiren bir konu haline gelmekten ötesine geçmiş, herkesin bu konu hakkında neler yapılabileceği tartışılır hale gelmiştir. Mevcut kullanılabilir su varlıklarının azalmasıyla beraber bu konuya olan ilgi daha da artmış, var olan problemleri çözmeye yönelik önlemler alınmaya başlanmış, adeta suyun gelecekteki varlığı ve sonraki nesillere nasıl aktarılabilceği tartışma konusu olmuştur (Aktürk, 2017).

Aslında uygun su planlaması ve yönetimi, bu tür su streslerini en aza indirmenin veya su arzı ile talep arasındaki boşluğu gidermenin tek alternatifidir (Abrahart ve See, 2000; Borga ve Vizzaccaro, 1997). Su kaynaklarının planlanmasında ve yönetilmesinde, hidrolojik sisteme etki eden parametreleri net bir şekilde ifade etmek ve nehir ya da baraj havzasında su mevcudiyetine etki eden hidrolojik, meteorolojik parametreleri ortaya çıkarmak amaçlarıyla matematiksel modeller geliştirmek ve uygulamak elzemdir. Günümüzde su kaynaklarının yönetilmesinde fiziksel modellerden ziyade matematiksel modeller kullanılmaktadır. Matematiksel modellerde, hidrolojik parametrelerden olan akış, baraj hacmi vb. verinin yanı sıra meteorolojik parametrelerden olan yağış ve buna bağlı hesaplanan kuraklık indis verisi de kullanılmaktadır. Kullanılan matematiksel modeller, suyun mevcut olduğu bölge üzerindeki su döngüsünde ortaya çıkan değişiklikler ile insan etkilerini anlayabilmek ve güvenilir bir şekilde öngörmek için bir araç olarak uygulanmaktadır. Modeller ile su kalite ve miktarı üzerindeki baskıların azaltılmasına ve su kaynaklarının kalite ve

miktarının iyileştirilmesine yönelik farklı yönetim politikaları ortaya konulabilmektedir. Böylelikle en uygun su yönetim politikasının belirlenmesine olanak sağlanabilmektedir. Modeller sayesinde, su kalitesinin geliştirilmesi için yapılması gereken yatırımların kararı, zamanlaması, sınırlı bilgiye sahip olunan parametrelerin, su kalitesine olan etkilerinin tahmini gibi konularda hızlı cevap alınabilmektedir.

Ortalama yağış miktarından belli bir periyod boyunca görülen azalma olarak tanımlanan kuraklık, su kaynakları mevcudiyetine ve yönetimine etki eden unsurlar arasındadır (Dogan vd., 2012; Hınıs, 2013; Tuğrul ve Hınıs, 2022). Kuraklık, uzun bir zaman dilimindeki su eksikliği veya belirli bir dönem boyunca önemli ölçüde yağış eksikliği olarak da tanımlanabilmektedir (Chen vd., 2009). Literatürde farklı şekillerde tanımlanabilen kuraklık, başladığında farkına varılmayabilir ve etki etmeye çoktan başlamış olabilir. Dolayısıyla doğal afetler arasında en sinsi ve en maliyetli olanlar arasında yer almaktadır (Akkurt Eroğlu ve Apaydin, 2020; Wang vd., 2021; Wilhite, 2000). Kuraklık disipliner bakış açısına göre; genellikle hidrolojik, meteorolojik, tarımsal ve sosyo-ekonomik olmak üzere 4 farklı kategoride karşımıza çıkmaktadır. Hidrolojik Kuraklık; yağışın akışa geçmesi ile bu kaynaklardan beslenen göl, baraj, gölet gibi yüzeysel suların mevcut miktarındaki azalma ya da ihtiyaç duyulan miktarın altına inmesi ile meydana gelen durumları ifade etmektedir. Meteorolojik Kuraklık; yağış eksikliği ile oluşan kuru dönemler için, Tarımsal Kuraklık; mevcut yağışlardaki eksilme ile ortaya çıkan kuraklık analizi zemin nemindeki azalmanın tarım ürün ya da ürünleri üzerindeki etkileri için kullanılmaktadır. Sosyo-ekonomik kuraklık, bunlara bağlı olarak arz ve talep dengesinde oluşan tutarsızlıklar ile oluşmaktadır (Heim, 2002; McKee vd., 1993; Tuğrul ve Hınıs, 2022; White ve Walcott, 2009). Diğer kuraklık kategorileri ile kıyaslandığında, hidrolojik kuraklıkların oluşumu en yavaştır ve süresi diğerlerine göre uzundur. Bu yüzden hidrolojik kuraklıklar, meteorolojik kuraklık tarafından sınırlanır ama tarımsal ve sosyo-ekonomik kuraklıklara da etki eder (Yu vd., 2020). Normalde, bir meteorolojik kuraklığın meydana gelmesini önlemek için çok az şey yapılabilir. Ancak hidrolojik kuraklığın oluşumunu engellemek için önlemler alınabilir. Bu önlemler su kaynaklarının planlanmasına ve su kaynaklarının yönetilmesine (baraj yönetimine) yardımcı olabilir. Literatürde hidrolojik kuraklığın yıkıcı etkilerine daha çok dikkat çekilmektedir (Mishra ve Singh, 2010; Pozzi vd., 2013; Van Loon ve Laaha, 2015).

Kuraklık olaylarını izlemek, deęerlendirmek iin genellikle kuraklık indisleri kullanılmaktadır. Kuraklık indisleri kuraklıkların suresi ve Őiddetleri hakkında bilgiler vermektedir. Aslında, kuraklık indisleri sayısal birer gostergedir. Palmer (1965), kuraklık indisleri ile kapsamlı olarak alıřan nc arařtırmacılarıdır. Toprak nemini, yaęıř ve sıcaklık parametrelerini ieren alıřmasında, Palmer Kuraklık Őiddet İndisi (PKŐİ)'ni geliřtirmiřtir ve poplerlięini uzun bir sure korumuřtur. 1990'lı yıllarda literatrde yayınlanan bařka bir kuraklık indisi de Standartlařtırılmıř Yaęıř İndisi (SYİ)'dir (McKee vd., 1993). SYİ kullanılabilirlięi ve gvenilirlięi ile birok alıřmada yer almıřtır. Keyantash ve Dracup (2002) yapmıř olduęu alıřmada; kuraklıkların tespiti iin SYİ'nin iyi sonular verdięini dile getirmiřtir. Dięer indisler ile kıyaslandığında, SYİ'nin daha az veriye ihtiya duyduęunu, yksek hassasiyet ile tespit ettięini ve herhangi bir zaman adımı iin hesaplama yapılabil-dięini vurgulamıřtır. Kuraklık indislerinin belirlenmesinde yaygın olarak SYİ tercih edilmektedir. PKŐİ ile karřılařtırıldığında SYİ'nin kolay hesaplanabilirlięi ve normalleřtirilmesi nemli karakteristiklerindendir (Bonaccorso vd., 2003). Kuraklıklar sadece meteorolojik veri ile deęil, aynı zamanda hidrolojik veri ile de hesaplanabilmektedir. Nalbantis ve Tsakiris (2009) hidrolojik kuraklık indislerinin hesaplamamasında Akım Kuraklık İndisi (AKİ) adıyla yeni bir metot geliřtirmiřlerdir. Bu metot prensip olarak SYİ ile aynı hesaplama temeliyle alıřmaktadır. Dolayısıyla, SYİ kolaylıkları aısından tercih eden birok arařtırmacı, akıř verisi ile alıřırken AKİ'yi de tercih etmektedir (Al-Juboori, 2023). AKİ, SYİ gibi farklı zaman adımlarında hesaplanabilmekte olup genellikle 3, 6, 9, 12, 24 aylık adımlar tercih edilmektedir. Hesap adımlarındaki kolaylıkları, girdi parametresi olarak tek veri kullanılması da tercih edilebilirlięinin bařka nedenlerindendir (Tigkas vd., 2012).

Son yıllarda insanoęlunun kuraklıklar ile mcadele etmesi her zamandakinden daha fazladır. Fakat kuraklıklar kadar nemli olan aynı zamanda canlı hayatına etki eden mevcut su kaynaklarını besleyen akıřların, miktarlarındaki azalmalar ve dalgalanmalar ile de bir mcadele verilmektedir. Bu zorluklarla bař edebilmenin en etkili yntemlerinden birisi bařarılı ve doęru tahminlemeler yapılmasıdır. Kuraklık ve yaęıřlara baęlı akıřın yani yaęıř-akıř tahminlerinin doęru olması, sadece tařkınlar, kuraklık ile mcadele, hidrolik yapıların ve altyapıların gvenlięi aısından deęil, aynı zamanda ime, tarım amalı ve hidroelektrik enerji retimi planlaması iin mevcut suyun miktarının belirlenmesinde de hayati bir rol oynar. Son yıllarda daha sık ortaya

ıkan su kıtlığı ve buna bağılı olarak oluřan kuraklıklar sebebiyle akıř, mevcut su miktarları gibi parametrelerin doęru tahmin edilmesi hidrologlar iin mevcut su kaynaklarını korumak aısından kritik bir konu haline gelmiřtir. Bu mcadelede, bilim insanları ya da bu sorun ile mcadele eden herkes alternatif özm yolları aramaktadır. Hemen hemen her problemde olduęu gibi, bir soruna özm bulmanın en iyi yöntemlerden birisi, gemiřte bu sorun ilgili veriyi incelemektedir. Bařka bir deęiřle, gemiřteki veriden faydalanarak gelecek hakkında tahminlemelerde bulunmaktadır.

Bir konuda tahminde bulunabilmek iin, o konunun gemiř tarihlerdeki davranıřlarından ya da istatistięinden yararlanabilir. Bu da o konu ile alakalı olarak gemiřteki tüm verinin incelemesi ile mümkün olabilir. Günümüzde birok alanda, gemiře dair veri depolanmaktadır. Bu veri miktarı gün getike de artmaktadır. Verinin bu kadar artması, depolama yönünden gemiřte büyük bir sorun olarak gözükse de, tahminleme yönünden günümüzde bir avantajdır. Bunun nedeni ise, gemiřteki hareket ve karar verme alışkanlıklarımızdan ötürü, bu alışkanlıklarımız ne yapacağımızı ok daha iyi bilmemiz olarak açıklanabilir. Örneęin, sabahları markete gitmek, hi gitmeyen birisi iin farklı olabilir, dahası sürekli olarak sabahları markete gitmek bir alışkanlık haline dönüşebilir, hatta alışveriş listesi bile bir önceki günlere benzeyebilir. Bu bilgiler işlenmedięi ya da istatistiksel olarak analiz edilmedięi sürece gemiřteki düşüncelerimizden farklı olmayabilir. Hayatımızı kolaylařtıracak, yařam standartlarımızı artırabilecek birok bilgi, karar ve eylemlerimizi gemiřteki davranıřlarımızdan elde edilen verileri analiz ederek çıkarabilmemiz mümkün olabilir. İşte bu eylem literatürde veri madencilięi olarak isimlendirilir. Veri madencilięinde veri bir bilgisayar veya depolama aygıtı tarafından dijital ortamda saklanır. Bu yöntem ok yeni olmamakla birlikte bir süredir, matematik, ekonomi ve iletiřim gibi tahmin gerektiren disiplinlerde kullanılmaktadır. Fakat gemiř ile günümüzdeki farklılık ise veri řeklinin sınıflandırılması ya da ön işlemeğe tabi tutulmasıdır. Geliřen teknoloji ile beraber, küresel anlamda veri madencilięi hemen hemen her alanda kullanılmaya başlanmıřtır (řekil 1.1). Veri madencilięi hidrolojide de önemli derecede kullanılmaya başlanmıř, birok arařtırmacı veri madencilięini arařtırma yöntemi olarak tercih etmiřtir. Veri madencilięi temel olarak, gemiřte elde edilen veriden yararlanarak, onları farklı özellikleri ile deęerlendirip analiz ederek sorunları özmeyi amaçlamaktadır. Bu süreç dięer bir deyiřle makine öęrenmesi olarak da adlandırılabilir. Hidrolojide de su döngüsü, su kaynaklarının planlanması,


havza yönetimi, baraj yönetimi, kuraklık analizi, matematiksel modelleme gibi konularda genellikle geçmiş verilerden yararlanılmaktadır. Dolayısıyla, bu disiplinde makine öğrenmesinden yararlanmak bilim insanları için vazgeçilmez bir teknik olarak son yıllarda karşımıza çıkmaktadır.

Su kaynakları, çölleşme, toprağın bozulması ve gıda güvenliği kuraklıktan ciddi şekilde etkilenmektedir. Son zamanlarda aşırı kuraklık olaylarının sıklıkla ve yoğun olarak meydana geldiği rapor edilmektedir. Kuraklığı diğer doğal olaylardan ayıran temel farklılık, kuraklığın yavaş başlaması ve başlangıcının tahmin edilmesinin zor olmasıdır. Bu sebeple çeşitli meteorolojik parametreler ile kuraklık göstergeleri geliştirilmekte, bunlar kullanılarak aylık veya mevsimsel zaman ölçeğinde rutin olarak kuraklıklar takip edilmektedir. Ancak başlangıcının ve gelişiminin öngörülemezliği, yüksek karmaşıklığı ve doğrusal olmaması nedeniyle en az anlaşılan doğal olaylardan biri olmaya devam etmektedir. Bu nedenle, kuraklık etkisi ile meydana gelen sosyal ve çevresel sonuçlar nedeniyle, kuraklığın etkisini azaltım ve kuraklığa uyum önlemlerine duyulan ihtiyaç konusunda erken uyarı verecek tahmin sistemleri oluşturmak çok önemlidir. Çevreyi ve insan varlığını birçok açıdan etkileyen en şiddetli iklim felaketlerinden biri olan kuraklık için etkili planlama ve karar alma, küresel olarak doğru ve güvenilir tahminler hayati önem taşımaktadır. Kuraklıkları tahmin etmek için veriye dayalı modeller yaygın olarak kullanılmasına rağmen, olaya etki eden parametrelerin çeşitliliği, olayın dinamik yapısı ve bölgesel ve küresel değişimler gibi çeşitli sebeplerden kaynaklanan bilgi eksikliği nedeniyle etkili bir tahmin modelinin seçimi hala zordur. Bu nedenle, son yıllarda geliştirilen farklı yöntemler ile kuraklık tahmin çalışmaları artmıştır. Bu çalışmalar arasında makine öğrenme yöntemleri sıklıkla kullanılmaktadır.

Hidrolojik sistemlerin çalışmasının makine öğrenmesi yöntemleri ile belirlenip tahmin edilebilmesi, su kaynaklarının etkin biçimde yönetilebilmesi, planlama çalışmalarının yapılabilmesi, doğal afetlere karşı hazırlık yapılabilmesi ve doğal afetlerden kaynaklanan hasarların azaltılması için çok önemlidir. Bu amaçla yapılan çalışmalar ile hidrolojik bir model, zaman ve mekan içinde yağış, yağış-akış, taşkın, kuraklık, su kaynakları potansiyelleri gibi alanlarda hedef parametreyi, akışı ve hacmi tahmin etmesi nedeniyle suyla ilgili çeşitli doğal afetlerin potansiyel oluşumunu önceden tanımlayabilmektedir. Hidrolojide, makine öğrenimi modelleri ilk olarak kısa vadeli

tahminler için kullanılan basit ileri beslemeli ağlar olarak ortaya çıktı ve hidrolojik deneyimi taklit ederek havzaların statik özelliklerini bile hesaba katabilen karmaşık modellere dönüştü. Son yıllarda makine öğrenimi modellerinin sağlam ve verimli olduğunu ve standart hidrolojik modellerden (hem kavramsal hem de fiziksel temelli) daha iyi performans gösterdiğini ortaya konulmuştur. Günümüzde makine öğrenimi modelleri, diğer modellerde sıklıkla ihtiyaç duyulan fiziksel süreçlere dayalı denklem ve varsayımlara ihtiyaç duymama avantajına sahip oldukları için doğal sistemlerin modellenmesinde oldukça kullanışlıdır (Yaseen vd., 2016).

Makine öğrenmesinde veri analiz edilirken, bazı öğrenme algoritmalarından yararlanılır. Bu algoritmaların, geçmişte elde edilen veriden, bir öğrenme sağlayarak test, doğrulama ve tahmin yapmada faydalı olduğu birçok çalışmada vurgulanmıştır.



Şekil 1.1. Veri madenciliğinin kullanım alanları.

Farklı disiplinlerde, farklı algoritmalar veri tipine bağlı olarak farklı performans sonuçları sergileyebilmektedir. Hidrolojide, özellikle matematiksel modelleme

alışmalarında, makine ğrenmesinde yaygınlıkla kullanılan algoritmalarından birisi Destek Vektör Makineleri (DVM)'dir (Cortes ve Vapnik, 1995). Hidrolojik modelin amacına gre bu algoritmalar deėiřebilmektedir (Pechlivanidis vd., 2011). Hidrolojik veriyi istatistiksel olarak analiz edebilmek iin genellikle en basit, yaygın ve gvenilirliėi yksek olan DVM analizinden faydalanılır. DVM ile hidrolojide birok modelleme alışması mevcuttur. Yirminci yzyılın sonlarından itibaren kullanılmaya bařlayan DVM, hidrolojide hala gncel yntemler arasındadır. Kullanılan veriye baėlı olarak sınıflandırma ve regresyon amacıyla da analiz yapılabilmektedir. Yksek gvenilirliėi ve bařarılı model sonularına baėlı olarak, model sonularını daha da iyileřtirmek adına, hibrit modellerinde oluřturabileceėi birok alışmada belirtilmektedir (Belayneh vd., 2014; Deo vd., 2017; Heddam ve Kisi, 2018; Raghavendra. N ve Deka, 2014). Makine ğrenmesi ile yapılan hidrolojik modelleme alışmalarında kullanılan bařka bir analiz tr de Yapay Sinir Aėları (YSA)'dır. İlk ıktıėında insanoėlunun beynine ve sinir sistemine benzetilen YSA'nın, DVM'de olduėu gibi kullanım alanları hidroloji ile kısıtlı olmamasına raėmen, zellikle geri ve ileri beslemeli, ok katmalı algılayıcı gibi modifikasyonları ile, hidrolojik modellemelerde veri arasındaki doėrusal olmayan iliřkileri ortaya ıkararak makine ğrenmesinde birok arařtırmacının bařarılı sonular elde ettiėi ispatlanmıřtır (Djrbouai ve Souag-Gamane, 2016; Imrie vd., 2000; Maier ve Dandy, 1996; Mao vd., 2021; Raman ve Sunilkumar, 1995). YSA, yksek esnekliėi, kolay hesaplanabilirliėi, fazla karmařık yapıda olmayıřından dolayı, modelleme alışmalarında kullanılabilirliėi olduka artmaktadır (Azadi ve Sepaskhah, 2012). Hidrolojik sreleri modellemek iin fiziksel ve kavramsal temelli modeller yaygın olarak kullanılmaktadır. Ancak fiziksel ve kavramsal temelli modeller, elde edilmesi her zaman mmkn olmayan ok fazla iklimsel girdi verisi gerektirmektedir. 1990'lı yıllardan itibaren geleneksel zaman serisi modelleri bu sreleri arařtırmak iin tercih edilmiřtir. Ancak, sreler doėrusal olmayan ve duraėan olmayan davranıřının, geleneksel zaman serisi modelleri ile yakalanması zor olduėundan elde edilen modellerin performansı ok yksek olmadı. Bu nedenle, son on yılda makine ğrenmesi ile geliřtirilen esnek hesaplama modelleri, veri esnekliėi ve doėrusal olmayan davranıřı yakalama yeteneėi nedeniyle birok hidrolojik modelleme alışmasında popler hale gelmiřtir (Wang vd., 2019). DVM ve YSA (esnek hesaplama) yntemleri son yıllarda hidrolojik modelleme alışmalarında tercih edilmektedir (Fan vd., 2018). Hidrolojik modelleme alışmalarında tahminlerde isabet

oranının yüksekliđi, modelleme gcnn yksek olması gibi sebeplerle sıklıkla tercih edilen YSA ve DVM yntemlerine ilave olarak sınıflandırma ve regresyon alıřmaların yksek hassasiyet gstermesi sebebiyle literatre yirminci yzyılın sonlarında kazandırılan (Quinlan, 1986) Karar Ađaları (KA) yntemi de son yıllarda tercih edilmektedir. Hesaplanmasındaki kolaylıđı, farklı alanlara uygulanabilirliđi, ayırt edici zelliklerin kullanıcı tarafından seilebilmesi gibi avantajlarından tr, literatrde sıklıkla arařtırmacılar tarafından tercih edilmektedir. Breiman (2001) tarafından, Sınıflandırma ve Regresyon Ađaları (CART)'na bađlı olarak geliřtirilen Rastgele Orman (RO) metodu, literatrde yine birok disiplinde hem sınıflandırma hem de regresyon amacıyla kullanılmaktadır (Breiman, 1996). Temeli, birden fazla budanmıř sınıflandırma ile KA arasındaki iliřkiye dayanan RO, modifiye edilerek, KA'nın bir fonksiyonu olarak deđerlendirilmektedir (Breiman, 2001; Svetnik vd., 2003). KA ile ok yakın benzerlikleri olmasına rađmen, hesaplamasındaki kolaylıklar ve avantajlardan tr kullanıcılar tarafından sıklıkla tercih edilmektedir. zellikle hidrolojide, sınıflandırma ve regresyon analizlerinde hata katsayılarını indirmesi, ařırı đrenmeden uzaklařması ve iyi sonular vermesiyle, RO dođrusal olmayan (nonlinear) problemlerin czmlerinde sıklıkla kullanılmaktadır.

Modelleme alıřmalarında kullanılan makine đrenmesi algoritmaları, modellerde kullanılan veriye bađlı olarak analiz sonularında farklı performanslar sergileyebilmektedir. Kullanılan algoritmalar, blgeye, veri setine, đrenme oranına, tarih aralıklarına vb. daha sayılamayacak birok nedene gre birbirlerine stnlk sađlayabilirler. Dolayısıyla, arařtırmacılar kurdukları modellerin daha iyi performans gstermeleri iin birtakım teknikler kullanmaktadırlar. Bu teknikler, veri setinde gecikmeleri artırmak ya da sonuca etki edebilecek farklı veriyi de modele eklemenin yanı sıra dalgacık dnřmleri de uygulayabilmektedirler. Zaman serisi inceleme ve sinyal iřlemedeki en popler metotlardan birisi dalgacık dnřmdr. Grossman ve Morlet (1984) tarafından ilk kez uygulanan bu yntem zaman serilerinde ham frekansları bulmada olduka popler olmuřtur. Hidrolojik zaman serilerinde de bu poplerliđini devam ettirmiř olup gnmzde birok arařtırmacı tarafından kullanılmaya devam etmektedir.



Şekil 1.2. Tez çalışması zaman çizelgesi.

1.1. Çalışmanın Amacı

Başlangıcının tespit edilmesinin zorluğu, kısa zamanda geniş alanlara yayılabilmesi, toplumu hem ekonomik hem sosyolojik olarak etkileyebilmesi gibi olumsuz etkileri ile kuraklık doğal afetler arasındaki en tehlikeli ve sinsi gerçekleşenlerden birisidir. Dolayısıyla, böylesine sinsi bir afete önlem almak, sadece bilim dünyasının değil, evren üzerinde yaşayan herkesin bir sorumluluğu olarak görülmelidir. Tüm bunlardan yola çıkarak, bu çalışmada hedeflenen amaç, çalışma alanı olarak seçilen Konya Kapalı Havzası içerisinde bulunan Apa Barajında, bazı hidrolojik ve meteorolojik veriler kullanılarak kuraklık, yağış-akış ve baraj yönetimi için hidrolojik modelleme yapmak ve model sonuçlarının iyileştirmesi için önerilerde bulunmaktır. Genel olarak bu araştırmanın amacı, bir baraj yönetimine etki eden önemli hidrolojik parametrelerden olan yağış, akış, sıcaklık, kuraklık, baraj su seviyesi ve baraj hacim verisinin hidrolojik prensiplerle modellenip sonuçların karşılaştırılması ve iyileştirme için yöntemler teklif edilmesidir.

Daha detaylı olarak bu çalışmada yapılması planlanan çalışmalar;

- Farklı makine öğrenmesi analizlerini uygulamak ve kurulan farklı model sonuçlarını birbirleriyle kıyaslamak, bu kurulan modellerin tahmin gücünü artırmak için kurulan modellerde iyileştirme yöntemi geliştirmek,
- Su kaynakları yönetiminde karar vericilere yardımcı olmak üzere; eksik olan verileri tamamlayabilen ve olağan dışı dönemleri tahmin edebilen modelleri araştırmaktır.

Modellerin kurulmasında aşağıdaki yöntemler kullanılacaktır.

- Veri madenciliği ve farklı optimizasyon yöntemleri ile hidrolojik parametrelerin modellenmesinde; Destek Vektör Makineleri, Yapay Sinir Ağları, Karar Ağaçları, Rastgele Orman yöntemleridir. Kurulacak tahminleri modelleri;
 - a) Kuraklık tahmin modeli,
 - b) Yağış-akış tahmin modeli,
 - c) Baraj göl seviyesi tahmin modelidir.

2. KAYNAK ÖZETLERİ

Su kaynaklarının ve baraj havzalarının etkili yönetimi için, ayrıca bunlardan doğabilecek olumsuz sonuçlardan insanoğlunun etkilenmemesi yönünde önlem alınması amacıyla, modelleme çalışmaları literatürde sıklıkla yapılmaktadır. Modelleme çalışmaları sayesinde, su kaynaklarının planlanması için yapılması gereken yatırımların kararı, zamanlaması kısacası su politikalarının belirlenmesi ve ileriye yönelik tahminde bulunulması, baraj yönetimi gibi konularda hızlı cevap alınmaktadır. Birçok kurum ve kuruluşun, kaynakların etkin yönetimine katkı sağlaması amacıyla modelleme üzerinde önemle durduğu bilinmektedir. Hidrolojik çevrimin temel parametresi yağıştır. Hidrolojik modeller temelinde yağış esas alınarak geliştirilen modellerdir. Su kaynaklarının yönetimi ve planlanmasında afetlere karşı alınacak olan tedbir ve azaltma çalışmalarında yağışın temel alındığı hidrolojik modeller oluşturulması havzaların yönetiminde karar verici mercilere yardımcı olacak en önemli adımdır. Bu sebeple bu çalışma 3 farklı hidrolojik modelleme üzerinde kurgulanmıştır. Çalışılan modeller;

- a) Yağış eksikliğine bağlı olarak gelişen kuraklık tahmin modeli,
- b) Yağış-akış tahmin modeli,
- c) Baraj göl seviyesi tahmin modelidir.

İlk olarak incelenen kuraklık tahmin modelinde en yaygın olarak kullanılan SYİ kullanılmıştır. 3, 6, 9, 12 ve 24 aylık ardışık yağış toplamaları esas alınarak hesaplanan SYİ'ler için 5 farklı zaman adımında 12 model özelinde toplam 60 model incelenmiştir. İkinci olarak, yağış-akış tahmin modelinde aylık toplam yağış, aylık ortalama akış, SYİ, AKİ verisi kullanılarak modeller araştırılmıştır. Üçüncü olarak, baraj seviyesi tahmin modeli incelenmiştir. Bu incelemede aylık toplam yağış, aylık ortalama akış, SYİ, AKİ, aylık ortalama baraj hacmi, aylık ortalama baraj su seviyesi verisi kullanılmıştır. İncelenen bu modellere göre, geçmişte yapılan çalışmalar bir sonraki bölümde verilmiştir.

2.1. Kuraklık Tahmin Modelleme Çalışmaları

Mishra vd. (2006) SYİ'nin 3, 6, 9, 12 ve 24 aylık yağış toplamaları ile elde edilen SYİ3, SYİ6, SYİ9, SYİ12, SYİ24 zaman adımlarında, Kansabati Nehir havzasında 1965-2001 yılları arasındaki aylık toplam yağış verisiyle bir kuraklık modelleme çalışması yapmışlardır. Model girdilerini, bir önceki aylar bazında geciktirerek oluşturan Mishra vd. (2006), analiz olarak stokastik süreçlerden olan Otoregresif Entegre Hareketli Ortalama (ARIMA) ve YSA'dan faydalanmışlardır. İstatistik değerlendirmelerde ise, Kök Ortalama Kare Hata'yı (RMSE) ve Ortalama Mutlak Hata (MAE)'yı kullanmışlar ve elde ettiği sonuçlarda, SYİ1 ve SYİ3 ile oluşturulan modellerde iyi sonuçlar elde ettiklerinden bahsetmişlerdir.

Uzun vadeli kuraklık analizlerinin ileriye yönelik önlem alma ve su kaynakları politikası belirlemede bir hayli önem arz ettiğini vurgulayan Belayned vd. (2014), zaman serisi analizinde kullanılan ARIMA ve makine öğrenmesinde yaygınlıkla tercih edilen YSA, DVM algoritmalarını yaptıkları veri tabanlı modelleme çalışmasında analiz için kullanmışlar, elde ettikleri bulguları algoritma performansını belirlemek için RMSE, MAE gibi istatistiksel parametreler ile kıyaslamışlardır. Awash Nehir havzasında 1970-2005 yılı arasındaki yağış verisi ile önce SYİ6, SYİ12 ve SYİ24'ü hesaplamışlar, sonrasında bu veri ile modeller oluşturup analizler gerçekleştirmişlerdir. Model iyileştirme yöntemi olarak dalgacık dönüşümünden faydalanan Belayned vd. (2014), çalışma sonuçlarında Korelasyon (r) değerlerinde YSA ve DVM makinelerinin birbirlerine yakın sonuçlar verdiği, dalgacık dönüşümünden sonra r değerlerinin daha da iyileştiğini, özellikle SYİ24'de YSA'nın etkin sonuçlar verdiğini dile getirmişlerdir.

Kuraklık tahmin çalışmaları su kaynakları yönetiminin temelini oluşturduğunu ifade eden Deo vd. (2017), kuraklıkların o bölgede sıklıkla görüldüğü Avustralya'nın doğu kesimlerinde Murray Darling Havzası'nda, 1915-2012 yılları arasındaki aylık yağış toplamalarıyla, M5 Ağaçları, DVM, Çoklu Adaptif Regresyon Enterpalasyonu (MARS)'dan faydalanarak bir çalışma gerçekleştirmişlerdir. M5 Ağaçlarıyla analiz ettiği modellerden, yüksek r değerleri elde ettiklerini çalışmalarında belirtmişlerdir.

Khan vd (2020) Pakistan üzerindeki yaptıkları çalışmada, k-En Yakın Komşu (KNN), DVM, YSA gibi farklı makine öğrenme algoritmalarından faydalanarak,

Standartlaştırılmış Yağış Buharlaşma İndisi (SPEI) ile bölgedeki olası kuraklık senaryoları için modeller oluşturmuşlardır. Son yıllarda yaşanan iklim değişikliğinden Pakistan bölgesinin bir hayli fazla etkilendiğine değinen Khan vd. (2020), çalışmalarında 1946-2016 yılları arasındaki 96 farklı istasyondan elde ettikleri meteorolojik veriyi (toplam yağış ve ortalama sıcaklık) kullanmışlardır. Bölgesel kuraklık ve geçici sıcaklık modellemesinde DVM'nin, istatistiksel değerlendirme parametrelerine göre yüksek değerler verdiğini dile getirmişlerdir.

Kuru bölgeler için kuraklık modelleme çalışmalarının hayati öneme sahip olduğunun altını çizen Alawsi vd. (2022), Al-Kut bölgesinde 1990-2020 yılları arasındaki aylık yağış, rüzgar hızı, basınç ve sıcaklık verisiyle, bahsedilen bölge için kuraklık modelleme çalışması yapmışlardır. Modelleme çalışması için, makine öğrenme algoritmalarından YSA'nın farklı modifikasyonlarından olan Katsayı Tabanlı Parçacık Sürüş Optimizasyonu ve Kaotik Yerçekimi Arama Algoritmasından faydalanarak, bölge için hesapladıkları SYİ'nin 1, 3 ve 6 aylık zaman adımları ile analiz yapmışlardır. Bunlara ilave olarak, Deniz Avcıları Algoritması ve Balık Kalıp Algoritmasını da analizlerinde kullanmışlar ve sonuçlarında, YSA'nın Katsayı Tabanlı Parçacık Sürüş Optimizasyonu ile elde ettikleri sonuçların diğer yöntemlere göre üstünlük sağladığından bahsetmişlerdir. Hibrit modellerdeki elde edilen başarılı sonuçların, çoklu veri seti kullanımı ile model sonuçlarının daha da başarılı olabileceğine çalışmalarında ayrıca yer vermişlerdir.

Sağlık, enerji, ekonomi gibi disiplinleri etkileyen uzun kurak dönemlerin, tespiti için çalışan Azimi vd. (2022), SPEI'nin 1, 6 ve 12 aylık zaman adımlarında, İran'nın kuzeybatısında Ardebil'de bir kuraklık modelleme çalışması yapmışlardır. Çalışmalarında, çapraz korelasyon ile en iyi girdi verisini belirleyip, buna bağlı olarak da kuraklık tahminlemelerinde en iyi sonucu bulmaya çalışmışlardır. DVM, Çok Katmanlı Algılayıcı Sinir Ağı (MLP), Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) gibi makine öğrenme algoritmalarından yararlanmışlar ve elde ettikleri sonuçları iyileştirme adına dalgacık dönüşümü analizinden faydalanmışlardır. Model girdi yapısında kullanılan SPEI için 31 yıllık aylık toplam yağış ve aylık ortalama sıcaklık verisini bölgeden temin etmişlerdir. Model girdi verisini, SPEI, yağış ve sıcaklık verisinin ay bazında geciktirilmiş değerlerinden elde etmişlerdir. Elde ettikleri

bulgulara; diğer algoritmalarla göre, SPEI'nin 1 ve 6 aylık zaman adımlarında en iyi sonuçları MLP'de, SPEI'nin 12 aylık zaman adımında ise DVM'de aldıklarını belirtmişlerdir.

Yaptıkları çalışmayla kuraklık tehlikesine karşı erken önlem almanın önemi üzerinde duran Basak vd. (2022), zaman serisi yöntemlerinin hidrolojide bir süredir sıklıkla kullandığını ve farklı yenilikçi bir yöntem kullanılmasına ihtiyaç olduğunu dile getirmişlerdir. 1960-2019 yılları arasındaki aylık toplam yağış verisiyle Rajasthan bölgesinde SYİ verisini de kullanarak, Çoklu Lineer Regresyon (MLR) ve DVM ile bir modelle çalışması gerçekleştirmişlerdir. Çalışmalarına yeni bir yaklaşım olarak ifade ettikleri Prophet'i de dahil etmişlerdir. Model sonuçlarını istatistiksel değerlendirme yöntemlerinden r , Nash-Sutcliffe (NS) ve RMSE ile değerlendirmişlerdir. Çalışmalarını SYİ'nin bütün adımlarına göre şekillendirmişler ve 38 farklı istasyonu incelemişlerdir. SYİ'nin 12 ve 24 aylık zaman adımlarında, Prophet'in diğer yöntemlere göre daha iyi sonuç verdiğini, 3 ve 6 aylık zaman adımlarında ise istatistik değerlendirme sonuçlarının birbiri ile korelasyonunun düşük olduğunu tespit etmişlerdir.

Kuraklık indisi olarak, SYİ'nin buharlaştırma verisini de hesaba katarak hesaplanan SPEI ile çalışan Danandeh vd. (2022), çalışma bölgesini Nallıhan, Beypazarı olarak seçmiş, analizlerinde hibrit RO ve Genetik Algoritma (GA), Aşırı Makine Öğrenmesi (ELM)'nden faydalanmış, kuraklıkların farklı zaman adımlarından elde ettikleri veriyi girdi yapısında kullanarak analizler gerçekleştirmişlerdir. Sonrasında, analizlerde kullandıkları algoritmaları birbirleri ile kıyaslamışlardır. Bölgedeki istasyonlardan 1972-2016 yılı arasında elde edilen aylık toplam yağış ve sıcaklık verisini kullanan Danandeh vd. (2022), hibrit verili modellerden elde edilen sonuçların diğer modellere göre ortalama %35 daha iyi sonuçlar verdiğini ifade etmişlerdir.

Kuraklıkların ileriye yönelik değerlendirmesinde hibrit tekniklerin etkinliğini yaptıkları çalışmayla ifade etmeye çalışan Hinge vd. (2022), dalgacık dönüşümünden de faydalanarak, MLR ve YSA'yı kuraklık modellemesine analiz algoritması olarak seçmişlerdir. Rajasthan'ı çalışma bölgesi olarak belirleyip, bu bölgedeki istasyonlardan elde ettiği 1901-2015 yılları arasındaki aylık toplam yağış verisiyle SYİ hesaplamışlar, sonrasında SYİ'nin 3, 6 ve 12 aylık zaman adımlarıyla farklı girdi yapısı oluşturup, bu veriyle bir modelleme çalışması yapmışlardır. NS ve RMSE

parametrelerini değerlendirme için kullanan Hinge vd. (2022), YSA'ya göre, MLR'nin dalgacık ayrışmasında sonraki sonuçlarının çok etkili olduğunu vurgulamış ve dalgacık ayrışmasının kuraklık modellemelerindeki performans artışına dikkat çekmeye çalışmışlardır.

Su kıtlığına sebep olan iki ana faktörü, iklim değişikliği ve suya olan talebin artması şeklinde tanımlayan Mirboluki vd. (2022), bu problemlerle mücadele etmenin en iyi yollarından birisinin bilimsel çalışmalar olduğunu yaptıkları çalışmada dile getirmişlerdir. Bu çalışmada makine öğrenme algoritmalarından DVM, ANFIS ve zaman serisi analizde kullanılan ARIMA'dan faydalanmışlardır. İstanbul, Çanakkale ve Tekirdağ istasyonlarından elde ettikleri 1960-2015 yılı arasındaki aylık toplam yağış verisini SYİ hesaplamalarında kullanmışlardır. Yenilikçi yaklaşım olarak makine öğrenmesi modifikasyonlarından Gri Kurt Optimizasyon yöntemini hem ANFIS'e hem de DVM'ye ilave ederek yeni bir hibrit hesaplama yöntemi oluşturmuş, iyileştirme yöntemine gitmişlerdir. Elde ettikleri bulgularında; SYİ'nin tüm zaman adımlarında (SYİ3, SYİ6, SYİ9, SYİ12) Gri Kurt Optimizasyonun r değerine olumlu yönde etki ettiğini dile getirmişlerdir.

Hidrolojik ve meteorolojik kuraklıkların Maharashtra bölgesini oldukça etkilediğini yaptıkları çalışmada belirten Elbeltagi vd. (2023), bölgedeki 2 farklı meteoroloji istasyonundan elde ettiği 2000-2019 yılları arasındaki aylık toplam yağış verisiyle SYİ'nin 6-12 aylık zaman adımlarında kuraklık indislerini hesaplamışlardır. Verinin 2000-2013 yılları arasını öğrenme, kalanını da test amacıyla kullanmışlardır. Makine öğrenme tekniklerinden RO, Rastgele Ağaç (RA) ve Gaussian Process Regresyon'dan faydalanmışlardır. Model performanslarını istatistiksel değerlendirmeye tabi tutmuşlar ve sonuçlarında; RO'da, diğer algoritmalara göre yüksek r değerine ulaşıldığını, RMSE değerinin de yine diğer algoritmalara göre daha düşük olduğunu bulgularında söylemişlerdir. Makine öğrenme tekniklerinin zaman serisi modellerine göre daha kullanışlı, hızlı ve etkili olduğunu yaptıkları çalışmada ayrıca belirtmişlerdir.

Hindistan'ın içilebilir suyunun sağlanmasında önemli rolü olan ve senelik ortalama yağış yüksekliğinin 750 mm civarlarında olduğu Godavari Nehir Havzasında kuraklığın ileriye yönelik tahmin modellemesi hakkında çalışmalar yapan Pande vd. (2023), bölgeden elde edilen veriyle önce SYİ hesaplamışlardır. Diğer çalışmalardan farklı olarak, DVM hesaplamalarında farklı Kernel Fonksiyonlarında farklı sonuçların

elde edilebileceğine değinen Pande vd. (2023), belirledikleri bölgede Poly Kernel, Pearson Universal Kernel, Normalleştirilmiş Poly Kernel, Radyal Basis Fonksiyon adı altında 4 farklı Kernel Fonksiyonunu sonrasında analizlerinde kullanmışlardır. SYİ'nin 3, 6, 12 aylık zaman adımlarından elde edilen indis değerlerinin %75'ini eğitim seti için, %25'ini de test amacıyla kullanmışlardır. İstatistik değerlendirmede ise r , RMSE parametrelerinden yararlanmışlar ve elde ettikleri bulgularda, SYİ'in 3 aylık zaman adımında Poly Kernel fonksiyonunu, 6 ve 12 aylık zaman adımında ise Pearson Universal Kernel fonksiyonun başarılı olduğunu tespit etmişlerdir.

İklim değişikliğinin tetiklediği kuraklıkların, su kaynaklarına olumsuz olarak birçok etkisini dile getiren Piri vd. (2023), YSA, DVM ve bunların modifikasyonları olan DVM-PSO (Destek Vektör Makineleri Parçacık Optimizasyonu) ve DVM-RSM (Destek Vektör Makineleri Yanıt Yüzey Yöntemi) makine öğrenme algoritmaları ile SYİ, Çin Z indeksi ve Efektif Kuraklık İndisi (EKİ)'nden yararlanarak, İran'da bir kuraklık tahmin modelleme çalışması yapmışlardır. Çalışmalarında 1981-2020 arasındaki 11 farklı meteoroloji istasyonundan elde edilmiş rüzgar, sıcaklık, ortalama yağış verisinden faydalanmışlardır. Çalışma sonuçlarında, SYİ'nin bölge için kuraklıkları daha iyi ifade ettiğini ve DVM-RSM'in diğer yöntemlere göre üstün performans gösterdiğini ve bu modelin kısa dönemli kuraklık tahminlemelerde kullanılabileceğini ifade etmişlerdir.

Salim vd. (2023) yaptıkları çalışmada, dalgacık dönüşümünün hidrolojik modelleme çalışmalarında kullanıldığını, model sonuçlarını tatminkar seviyede iyileştirdiğini ifade etmişlerdir. Algerois havzasında, 1936-2008 yılları arasını kapsayan aylık toplam yağış verisiyle önce farklı zaman adımlarında (3, 6, 12) SYİ hesaplamışlar, sonrasında ise YSA yöntemiyle kuraklık modelleri oluşturmuşlardır. Aynı modellere, dalgacık dönüşümünde kullanılan Haar, Meyer, Daubechies, Symlet gibi ayrışmada kullanılan farklı fonksiyonları uygulamışlardır. Elde ettikleri bulgularda, istatistik değerlendirme parametrelerinden NS, RMSE'den faydalanarak, dalgacık ayrışmasında ileriye yönelik tahminlerde bölge için Meyer fonksiyonun diğer fonksiyonlara göre daha iyi sonuç verdiğini açıkça beyan etmişlerdir.

2.2. Yağış-Akış Tahmin ve Baraj Göl Seviyesi Tahmin Modelleme Çalışmaları

Hidroelektrik santrallerinde aylık akış değerlerinin santrallerin etkili bir şekilde yönetilmesinde oldukça önem arz ettiğine değinen Huang vd. (2014), yaptıkları çalışmada, Wei nehir havzasında 1960-2005 yılları arasındaki aylık ortalama akış değerleri ile farklı modeller oluşturarak ileriye yönelik tahmin çalışmasında bulunmuşlardır. Modellerde DVM, YSA, DVM tabanlı Ampirik Mod Ayırışımı (AMA)'yı kullanmışlardır. Model sonuçlarını, RMSE ve MAE gibi parametreler ile karşılaştırmışlar, elde ettikleri bulgulara, ayırışma ile modifiye edilen DVM'nin diğer metotlara göre daha iyi sonuçlar verdiğini yaptıkları çalışmada belirtmişlerdir.

Kırsal ve kentsel yerleşim yerlerinde, dönemsel olarak ulaşılabilir su kaynaklarının etkili kullanılmasının, sürdürülebilirlik açısından önemini çalışmalarında ifade eden Yaseen vd. (2016), modelleme çalışmalarıyla birlikte bu konu kapsamında literatüre katkı sağladıklarını ve yaptıkları çalışmanın sonuçları ile bu konuda çalışan bilim insanlarına katkıda bulunabileceklerini bulgularında belirtmişlerdir. Orta Doğunun en uzun nehirlerinden birisi olan Tigris Nehri üzerinde çalışan Yaseen vd. (2016), bölgeden elde ettikleri 1991-2010 yılları arasındaki akış verisini kullanarak, modeller oluşturmuşlar, akabinde oluşturdukları modelleri ELM, DVM, Genelleştirilmiş Regresyon Sinir Ağı (GRNN) gibi makine öğrenme teknikleri ile analiz etmişlerdir. Elde ettikleri sonuçları, r , RMSE, NS, Wilmott's İndisi (WI) gibi istatistiksel değerlendirme sonuçları ile yorumlamışlar ve bulgularında ELM'nin diğer yöntemlere göre daha başarılı olduğundan bahsetmişlerdir.

Tikhamarine vd. (2020), aylık akış tahminlerinin özellikle taşkın, kuraklık gibi doğal afetlere karşı önlem almada ve su kaynakları yönetiminde etkin bir şekilde kullanılması gerektiğini yaptıkları çalışma ile dile getirmeye çalışmışlardır. Çalışma alanını, dünyanın en uzunlarından birisi olan Nil Nehri'ni seçen Tikhamarine vd. (2020), yaklaşık 130 yıllık (1871-2000) akış verisini model girdi yapısında kullanmışlardır. Makine öğrenme algoritmalarından YSA, DVM ve MLR'den faydalanmışlardır. Bu algoritmaları Gri Kurt Optimizasyonu ile modifiye eden Tikhamarine vd. (2020), model sonuçlarını istatistiksel değerlendirme parametrelerinden olan r , NS ve RMSE ile karşılaştırmışlardır. Sonuçlarında, Gri Kurt Optimizasyon'nun YSA kombinasyonu ile yapılan analiz sonuçlarının diğerine göre daha etkili olduğunu çalışmalarında dile getirmişlerdir.

Hidrolojik döngünün önemli birleşenlerinden birisi olan akışların ve akış modelleme çalışmalarının, zamansal ve mekânsal olarak dağılımlarının tahmin edilmesinin şüphesiz su kaynaklarının etkin kullanılmasında ve planlanmasında oldukça yararlı bir araç olduğuna değinen Difi vd. (2022), detaylı bir literatür araştırmasından sonra MLP, GRNN, DVM, Yarasa Algoritması Optimize Edilmiş Aşırı Öğrenme Makinesi (YAOEAÖM) ve Gauss Süreci Regresyonu (GPR)'nun da içinde olduğu bir dizi makine öğrenmesi algoritmasından faydalanan bir modelleme çalışması yapmışlardır. Çalışma alanı olarak, yıllık yağışları 300-600 mm civarlarında olan Cezayir için tarım açısından oldukça önem arz eden Cheliff havzasını seçmişlerdir. Havza üzerinde bulunan ortalama olarak 1983-1995 yılları arasını kapsayan aylık toplam yağış ve akış verisinden yararlanarak ve bu verinin farklı zamanlardaki geciktirilmiş değerlerini modellerde girdi olarak kullanmalarıyla elde edilen sonuçları değerlendirmişler ve bölge için; YAOEAÖM algoritmasının diğer modellere göre daha iyi sonuçlar verdiğini tespit etmişlerdir.

Elbeltagi vd. (2022), yaptıkları çalışmada, akış tahmin modelleme çalışmalarının Amerika'da kullanılabilir su kaynaklarının planlanmasında etkili bir araç olduğuna değinmişlerdir. Mississippi'nin bir kolu olarak bilinen Des Moines Nehri üzerindeki farklı istasyon üzerinden aldıkları (ortalama 70 yılı kapsayan) akış verisi ile akış modelleri oluşturmuşlardır. Oluşturdıkları modelleri, Rastgele Alt Uzay, Budanmış M5 Regresyon Ağaçları (M5B), RO ve Bagging'den (Breiman, 1996) yararlanarak analiz edip model sonuçlarını r , RMSE, Ortalama Kare Hata (MSE), Mallows Cp gibi istatistiksel parametreler ile yorumlamışlardır. Çalışma bölgesindeki akışları en iyi tahmin edebilen ve ileriye yönelik tahmin konularında diğer algoritmalara göre en başarılı sonuç veren algoritmanın M5B olduğunu tespit etmişlerdir.

Baraj yönetiminin iki önemli unsurunun barajdaki su seviyesinin bilinmesi ve barajda ne kadar su tutulması kararının verilmesi olduğunu dile getiren Ibrahim vd. (2022), DVM, ANFIS, MLP, Aşırı Gradyan Artırma (XGBoost)'dan yararlanarak Klang Gate barajında 19 yılı içeren (2000-2019) bir veri aralığında, barajdan elde edilen su seviyesi, akış ve buharlaşma verisinden yararlanarak bölgede modelleme çalışması yapmışlardır. Meteorolojik ve hidrolojik veriyi belirli zaman periyotlarında geciktirerek model girdilerini oluşturan Ibrahim vd. (2022), NS, r , RMSE, MAE'yi

model sonuçlarını kıyaslamak için kullanmışlardır. Günlük ve aylık olarak farklı tahmin modelleri oluşturan Ibrahim vd. (2022) her iki senaryoda da XGBoost'un diğer yöntemlere göre üstünlük sağlandığını tespit etmişlerdir.

Son zamanlarda, hidrolojide makine öğrenmesinin yapay zeka alanında oldukça popüler bir teknik olduğuna değinen Meng vd. (2022), Shiyang nehir havzasındaki iki istasyondan elde ettikleri 46 yıllık aylık ortalama akış (1972-2018) verisi ile bölgede akış modelleri oluşturmuşlardır. Oluşturdukları modelleri RO, LightGBM, Catboost, Rlc-Lasso gibi algoritmalar ile analiz etmişler, elde ettikleri bulgulara RO yönteminin diğer yöntemlere göre ileriye yönelik aylık tahminlerde daha etkili olduğunu ifade etmişlerdir.

Su kaynaklarındaki deşarj ve rezervuar yönetiminde makine öğrenmesinin önemine vurgu yapan Tounsi vd. (2022), Amerika'daki Hackensack nehri havzasında, 2014-2021 yılları arasındaki çoklu sensörlerden elde edilmiş günlük yağış ve akış verisiyle, Long Short Term Memory modelleme çalışması yapmışlardır. Makine öğrenmesi algoritması olarak YSA'nın farklı bir modifikasyonu olan Tekrarlayan Sinir Ağı (TSA)'nı kullanmışlardır. İstatistik değerlendirme parametresi olarak, NS, r, RMSE ve MAE'yi tercih etmişler ve bulgularında, 12 ile 48 saatlik geciktirilmiş veri ile kurulan modellerin daha başarılı olduğunu belirtmişlerdir.

Su rezervuarlarındaki hidrolojik döngüyü anlamak ve etkin bir su politikası yönetimi için baraj akışlarının izlenmesinin bir hayli önemli olduğunu vurgulayan, bu doğrultuda Amerika'da bulunan Carlyle ve Shelbyville baraj göllerinde bir çalışma yapan Qie vd. (2022), çalışmalarında yağış, sıcaklık, baraj hacmi ve seviyeleri gibi 1990-2019 yıllarını kapsayan meteorolojik ve hidrolojik veriyle farklı makine öğrenme algoritmalarıyla bir modelleme çalışması yapmışlardır. Modelleri farklı kombinasyonlar ile geciktirerek oluşturmuş, model sonuçlarını NS, r, RMSE istatistiksel değerlendirme parametreleri ile kıyaslamıştır. RA, YSA, DVM gibi makine öğrenme algoritmalarını modellere uygulayan Qie vd. (2022), DVM'nin bölge için diğer metotlara göre oldukça iyi sonuç verdiğini çalışmalarında vurgulamışlardır.

Akış tahminleme çalışmalarının taşkın ve su kaynakları yönetimi için yararlı araç olduğunu vurgulayan Xiao vd. (2022), kaynak rezervuar yönetimi, su kaynaklarının planlanması, etkili sulama yönetimine bu çalışmaların katkısının olacağını, Xijiang

Nehrindeki yaptıkları çalışmada detaylıca bahsetmişlerdir. Çalışma bölgesindeki yağış dağılımının eşit bir şekilde olmadığına, özellikle aralıktan şubat ayına kadar oldukça kurak geçtiğine ayrıca değinmişlerdir. Çalışmalarında, günlük yağış, günlük ortalama akış, günlük ortalama hava basıncı, günlük ortalama sıcaklık, günlük ortalama nem gibi birçok meteorolojik ve hidrolojik veriyi kullanmışlardır. Makine öğrenme algoritmalarından ise, YSA, ELM, Geri Beslemeli Sinir Ağları (GBSA), GRNN, Dalgacık Sinir Ağı (WANN)'nı tercih etmişlerdir. Kurulan modellerin genellikle 15, 10 ve 7 günlük geciktirilmiş veri ile oluştuğunu belirtmişlerdir. Elde ettikleri sonuçları, r , RMSE, MAE gibi parametreler ile değerlendirmişler, bölgede en iyi sonuç veren algoritmanın akış tahmini için GBSA, su seviyesi için WANN olduğunu ifade etmişlerdir.

Achite vd. (2023) yaptıkları çalışmada, yağış eksikliklerinin insan ve canlı hayatına olan olumsuz etkilerinden bahsetmişler ve bu eksiklerden kaynaklanan kuraklıkların daha sık görülebileceğine değinmişlerdir. Buradan yola çıkarak, Cezayir Wadi Mina havzasında makine öğrenme algoritmalarından yararlanarak bir akış kuraklık modelleme çalışması yapmışlardır. 5 farklı istasyondan 1974-2009 yılları arasındaki sıcaklık, yağış ve akış verisini temin etmişlerdir. Kuraklık indisi olarak AKİ tercih etmişler ve 1, 3, 6, 9, 12 aylık zaman değerlerini hesaplamışlardır. Makine öğrenme algoritmalarından ELM ve dalgacık dönüşümünü kullanarak modelleri analiz etmişlerdir. Bulgularında, AKİ'nin 12 aylık değerlerinden elde ettikleri sonuçların bölgeyi iyi temsil ettiğini belirtmişlerdir.

Çalışma alanını, erişilebilir suyun eksikliğinden oldukça fazla etkilenen Seyhan Nehir havzasında Göksu-Gökdere Nehri olarak belirleyen Ayana vd. (2023), 1940-2011 yılları arasındaki aylık ortalama akış verisinden yararlanarak akış modelleri oluşturmuş ve bu modelleri farklı makine öğrenme algoritmaları ile analiz etmişlerdir. Analiz metotlarına, literatürde yeni kullanılan Long Short Term Memory'i ekleyerek, modelleme çalışmalarında yaygınlıkla kullanılan DVM, Lineer Regresyon (LR), RO, Geçitli Yinelenen Birimler, Çift Yönlü Kapılı Tekrarlayan Üniteler gibi farklı makine öğrenme yöntemleri ile analiz gerçekleştirmişlerdir. İstatistiksel değerlendirme parametreleri (NS, RMSE, Yüzde Tahmini) ile model sonuçlarını kıyasladığında, çalışma alanı için LR'nin, makine öğrenme algoritmalarına göre daha etkili olduğunu yaptıkları çalışma ile ortaya çıkarmışlardır.

Yeşilirmak havzasında bulunan 3 farklı istasyondan elde ettiği akış verisi ile bölgedeki kuraklıkları Akış Kuraklık İndisi (AKİ) ile hesaplayan Katipoğlu (2023), bu indis ile elde ettiği sonuçlarla girdi yapısı farklı olan modeller oluşturmuştur. Ayrıca, çalışma alanının sulama ve elektrik üretiminde önemli derecede rol oynadığından bahseden Katipoğlu (2023), kurduğu modelleri makine öğrenme algoritmaları ile analiz etmiş, ileriye yönelik tahminlerde bulunmuştur. Makine öğrenme tekniklerinden olan DVM, GPR, Regresyon Ağaç (REA), Ağaç Toplulukları (AT), XGBoost'u analiz için kullanmış, model sonuçlarının iyileşmesi içinde dalgacık dönüşümünden faydalanmıştır. Elde ettiği bulgularda, XGBoost'un diğer yöntemlere göre, istatistiksel değerlendirme kriterleri göz önünde bulundurularak (r , RMSE, MAE) daha iyi sonuç verdiğiinden söz etmiştir.

Hibrit makine öğrenme modelleri üzerine çalışan Martinho vd. (2023), DVM, ELM, Elastik Net (EN), MARS, Gri Kurt, XGBoost gibi algoritmalar ile Zambezi Nehir havzasında bir modelleme çalışması yapmışlardır. 2003-2012 yılları arasındaki günlük akış verisi ile çalışan Martinho vd. (2023), hibrit modellerde daha az veriye ihtiyaç duyulduğunu, XGBoost'un diğer yöntemlere göre daha etkin sonuçlar verdiğini ve bu yöntemin test sonucundaki zirve noktaların yakalanmasında etkili olduğunu söylemişlerdir.

Su tedariğinde, taşkın kontrolünde, sulama ve tarımda su kaynak ve rezervuarlarının önemine yaptıkları çalışmada değinen Özdoğan-Sarıkoç vd. (2023), çalışma alanını Ladik ve Yedikır baraj gölü olarak seçmişlerdir. Barajların bölge için özellikle sulamada bir hayli önem arz ettiğini, yaptıkları çalışmada vurgulamışlar ve barajdan elde ettikleri 1975-2019 yıllarını kapsayan ortalama yağış, ortalama sıcaklık, nemlilik, rüzgar hızı, solar radyasyon ve baraj hacmi verisinden yararlanarak bölgede bir modelleme çalışması yapmışlardır. Makine öğrenme algoritmalarından YSA, DVM'nin yanısıra literatürde yeni sayılabilecek Long Short Term Memory'den (LSTM) yararlanmışlardır. İstatistik değerlendirme yöntemleri olarak NS, r , RMSE kullanmayı tercih etmişler ve bölge için diğer metotlarla kıyaslandığında yeni metot olarak değerlendirilen LSTM'nin etkili sonuçlar verdiğini, özellikle ekstrem dönemleri yakalamada oldukça iyi olduğunu tespit etmişlerdir.

Suyun sürdürülebilir kalkınma ile ilişkili olduğunu, ekonomik kalkınma, ekosistem, biyolojik hayat gibi birçok disiplinde önemli bir rol edindiğini çalışmalarında ifade

eden Sharma vd. (2023), son zamanlarda geleceğe yönelik akış tahmin modelleme çalışmalarının literatürde oldukça dikkat çektiğini ve hidrolojik çalışmalarda çoğunlukla yer aldığını ifade etmişlerdir. Bu doğrultuda, Suvarna, Aghanashini, ve Kunderu nehirlerinde, akış tahminlerini değerlendirmek için farklı makine öğrenme algoritmaları ile bir çalışma yapmışlardır. Çalışmalarında, makine öğrenmesi algoritması olarak; RO, DVM, LTSM, MARS'dan, veri olarak; 1951-2018 yılları arasını kapsayan yağış, maksimum ve minimum sıcaklık ve akış'tan faydalanmışlardır. Diğer literatür çalışmalarında olduğu gibi model girdi verisini çeşitli zaman dilimlerinde geciktirerek model girdilerini oluşturan Sharma vd. (2023), bölge için pik noktaları tahmin edebilen ve diğer algoritmalara göre daha iyi sonuç veren MARS ve RO'nun performanslarını, NS gibi istatistiksel değerlendirme kriterleri ile ortaya çıkarmışlardır.

3. MALZEME VE YÖNTEM

3.1. Çalışma Alanı ve Veri Seti

Sulama ve taşkın koruma amacıyla 1957 yılında inşaatına başlanmış, sonraki ortalama 5 yıllık süreçte işletmeye alınmış, $37^{\circ}52'54''$ kuzey ile $32^{\circ}18'17''$ doğu boylamları koordinatlarında yer alan Apa Barajı, Konya'nın merkezine ortalama 70 km uzaklıkta, Çumra ilçesi sınırları içerisinde yer almaktadır (Şekil 3.1). Maksimum 171 hm^3 kapasiteye sahip ve toprak dolgu tipinde bir baraj olan Apa Barajı'nın sulama kaynağı genel olarak, Beyşehir Gölü ile Suğla Depolaması (Beyşehir Kanalı), Bozkır Çarşamba Kanalı ve Toroslardan Mavi Tünel'dir. Apa kasabası içerisinde konumlanan Çarşamba Suyu üzerinde kurulan bu baraj, rekreasyon alanlarının varlığı, birçok balık türüne ev sahipliği yapması, dolayısıyla hobi balıkçılığına da imkân vermesi gibi faaliyetler ile amacı dışında kullanım ile bölge halkına hizmet etmektedir.

Çarşamba Çayı küçük ve büyük ölçekte birçok dereden oluşmaktadır. Bunların içinde Kuruçay, Söğüt, Kayapınar ve Çökelez Deresi en önemlileridir. Yaz aylarında suların çekilmesi ile beraber, bahsedilen derelerin büyük kısmı kurumaya yüz tutmaktadır. Genel olarak kuzeydoğuya doğru akan Çarşamba Çayı, bulunduğu konum içerisindeki en önemli yerleşim yeri olan Bozkır'dan geçerek, "Suçatı" adı verilen mevkide batıdan Kozdere ile birleşir. Beyşehir ve Suğla Göllerinin fazla gelen sularının aktarıldığı Beyşehir-Suğla Kanalı'nın bağlandığı dere Kozdere'dir. Kozdere ile birleşen Çarşamba Çayı artık dar ve derin bir vadi olan Mavi Boğaz içerisinde doğuya doğru hareket etmektedir. Bu boğazda Konya Ovası Projesi'nin (KOP) önemli bir ayağı olan "Mavi Tünel Projesi" yer almaktadır (Buldur ve Sabahattin, 2012).

Ortalama 13 km^2 'lik yüzey alanı, su altında onlarca canlıya ev sahipliği yapması, Türkiye'nin tarım ambarı olarak nitelendirilen Konya Ovası'na su sağlaması gibi nedenlerden dolayı Apa Barajı, bilim insanlarının araştırma yönünde cazibesini çekmektedir. Ayrıca, baraj gölünde bir zamanlar çalışır vaziyette bulunan meteoroloji istasyonlarının varlığı da bunu destekler niteliktedir. Göl üzerinde Devlet Su İşleri Genel Müdürlüğü (DSİ)'ye ait geçmişte aktif halde bulunan meteoroloji istasyonlarından kesintisiz sayılabilecek nitelikte (1962–2003 yılları arası) yağış verisi temin edilebilmektedir. Fakat DSİ'nin Türkiye genelindeki bazı ölçüm istasyonlarının Meteoroloji Genel Müdürlüğüne aktarılmasıyla, 2003 yılından beri gölden meteorolojik ölçüm yapılamamaktadır.

Çizelge 3.1. Veri özet tablosu

Veri Türü	Veri aralığı	Veri adedi	Veri ortalaması	Minimum veri	Maksimum veri	Çarpıklık
Aylık toplam yağış (mm)	1.1955-12.2020	792.00	25.69	0.00	144.30	1.24
Aylık ortalama akım (m ³ /s)	3.1974-9.2015	499.00	2.18	0.00	18.20	2.54
Aylık ortalama kot (m)	12.1962-12.2020	696.00	1042.64	1033.17	1056.55	3.82
Aylık ortalama hacim (hm ³)	12.1962-12.2020	696.00	57.69	3.72	168.56	0.77
Aylık maksimum sıcaklık (°C)	1.1955-12.2020	792.00	25.66	3.50	39.90	-0.34
Aylık minimum sıcaklık (°C)	1.1955-12.2020	792.00	-1.74	-26.80	14.80	-0.28
Aylık ortalama sıcaklık (°C)	1.1955-12.2020	792.00	11.56	-8.60	26.30	-0.11
SYİ24	12.1956-12.2020	769.00	-0.01	-2.71	2.86	0.07
SYİ12	12.1955-12.2020	781.00	0.00	-2.39	2.39	0.14
SYİ9	9.1955-12.2020	784.00	0.00	-3.03	2.88	0.08
SYİ6	6.1955-12.2020	787.00	0.00	-2.76	2.59	-0.17
SYİ3	3.1955-12.2020	790.00	0.01	-2.80	2.13	-0.56
AKİ12	2.1975-9.2015	488.00	0.00	-1.94	3.62	1.17
AKİ6	8.1974-9.2015	494.00	0.00	-1.72	3.66	0.36
AKİ3	5.1974-9.2015	497.00	-0.01	-1.78	3.09	0.54
AKİ1	3.1974-9.2015	499.00	-0.01	-2.88	3.55	0.85

3.2. Yöntemler

Bir önceki kısımda, çalışmada kullanılacak bölgenin tanıtımı yapılmış olup, barajı temsil edebilecek veri oluşturulmuştur. Akabinde, bu veriden yararlanarak çeşitli makine öğrenmesi algoritmaları ile oluşturulan modellerin analizi yapılmıştır. Oluşturulan model girdi yapıları farklı bölümlerde ayrı ayrı ele alınmıştır. Bu kısımda, analizde kullanılacak olan yöntemlere ait bilgilere yer verilmiştir.

3.2.1. Standartlaştırılmış yağış indisi (SYİ)

SYİ, kuraklıkları tespit ve takip etmede yaygınlıkla kullanılan metotlardan birisidir. Bu metot ile hesaplamalar yapılırken aylık ya da günlük olarak yağış verisinden yararlanılır. Öncelikle veri setinin normal dağılıma uygunluğu kontrol edilir. Normal dağılıma uyuyorsa, hesaplamalar normal dağılım üzerinden devam eder. Normal

dağılıma uymuyorsa, SYİ normal dağılım olmayan yağış verisinin normal dağılıma dönüştürülerek hesaplanması temeline dayanır. Bu proseste ilk başta veri gama dağılımına dönüştürülür. Sonra Gamma Dağılımındaki değerlerin Normal dağılıma geçişi yapılır. Bu dağılımda sıfırın üzerindeki değerler yağışlı periyot, altındaki değerler ise kurak periyot anlamına gelir. Eğer bir yerin indeks değeri sıfırın altında çıkıyorsa o yerde kuraklığın meydana geldiği söylenebilir (McKee vd., 1993). SYİ'nin yaygın olarak kullanımında, farklı zaman adımlarında kuraklık seviyesinin hesaplanabilmesi etkin bir rol oynamıştır. SYİ farklı zaman adımlarını kullanarak ilgili kümülatif aylar ile kuraklığı hesaplayabilir. Ancak genellikle 1, 3, 6, 12, 24 ve 48 aylık zaman adımları kullanılır. SYİ hesabı için en az 30 yıllık veri gereklidir ama genellikle 50 yıllık kayıtlar önerilir (Guttman, 1999). Kullanılan gamma dağılımının olasılık yoğunluk fonksiyonu Denklem 3.1 ile ifade edilir. Bu çalışmada kullanılan yağış verisi normal dağılıma (%95 önem seviyesinde) uymamaktadır. Bu sebeple gama dağılımı dönüşümü yapılmıştır.

$$g(x) = \frac{1}{\beta^{\alpha}\Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta} \quad x > 0 \text{ için} \quad (3.1)$$

Belirli bir veri kümesi için en uygun modelin en yüksek olasılıkla veriyi üreten model olduğunu anlamada kullanılan Maksimum olabilirlik metodundan faydalanılır ve Denklem 3.2'deki gibi α (sekil) ve β (ölçek) parametreleri tahmin edilir.

$$\alpha = \frac{1}{4A} \left(1 + \sqrt{1 + \frac{4A}{3}} \right) \text{ ve } \beta = \frac{\bar{x}}{\alpha} \quad (3.2)$$

Çarpıklık α 'ya bağlı olmakla beraber, α büyüdükçe dağılım normal dağılıma doğru yaklaştığı söylenebilir.

$$A = \ln(\bar{x}) - \frac{\sum \ln}{n} \quad (3.3)$$

Burada Denklem 3.3'teki n gözlem sayısını ifade etmektedir. Elde edilen parametreler Denklem 3.4'deki olasılık dağılım fonksiyonunu oluşturmakta kullanılır.

$$G(x) = \int_0^x g(x)dx = \frac{1}{\beta^{\alpha}\Gamma(\alpha)} \int_0^x x^{\alpha-1} e^{-x/\beta} dx \quad (3.4)$$

Gamma dağılımı x 'in sıfır değerleri için tanımsızdır. Yağış serisi sıfır değerleri içerebileceğinden, sıfır ve sıfırdan farklı yağışlar için kümülatif olasılık değerleri, $H(x)$ (Denklem 3.5);

$$H(x) = q + 1(1 - q)G(x) \quad (3.5)$$

şeklinde hesaplanır. Burada q , sıfır yağışın olması durumudur. Eğer seride bulunan sıfırların sayısına “ m ” ile gösterilirse, $q=m/n$ olarak hesap edilebilir. Elde edilen sonuçlara göre kuraklık kategorisi Çizelge 3.2’ye göre belirlenebilir (McKee vd., 1993).

Çizelge 3.2. SYİ indis değerlerine göre kuraklık kategorileri (McKee vd., 1993)

SPI Değeri	Kategorisi
$\geq (2)$	Aşırı Sulak
(1.50) - (1.99)	Şiddetli Sulak
(1.00) - (1.49)	Orta Sulak
(0) - (0.99)	Az Sulak
(-0.99) - (0)	Az Kurak
(-1.49) - (-1.00)	Orta Kurak
(-1.99) - (-1.50)	Şiddetli Kurak
$\leq (-2)$	Aşırı Kurak

3.2.2. Akış kuraklık indisi (AKİ)

Nalbantis ve Tsakiris (2009) tarafından geliştirilen AKİ, meteorolojik kuraklıkları incelemek ve değerlendirmek için araştırmacılar tarafından tercih edilen SYİ ile hesaplama yönünden benzerlik içermektedir. En büyük kolaylıklarından birisi tek veri yani akış verisini kullanmasıyla kuraklıkların başlangıcı ve süresini hesaplayabilmesidir. Hesaplanması SYİ olduğu gibi öncelikle veri setinin normal dağılıma uygunluğu kontrol edilir. Normal dağılıma uyuyorsa, hesaplamalar normal dağılım üzerinden devam eder (Denklem 3.6). Normal dağılıma uymuyorsa, SYİ’nin normal dağılıma dönüştürülerek hesaplanması temeline dayanır. SYİ’deki hesaplamayöntemi aynı şekilde uygulanır. Bu çalışmada kullanılan akış verisi normal dağılıma (%95 önem seviyesinde) uymamaktadır. Bu sebeple gama dağılımı dönüşümü yapılmıştır.

$$AKİ_{i,k} = \frac{V_{i,k} - \bar{V}_k}{S_k} \quad i = 1, 2, \dots, k = 1, 2, 3, 4, \dots \quad (3.6)$$

Buradaki; k ay i yıl olmak üzere, AKI indis değerini, $V_{i,k}$ akış hacmini, $\overline{V_k}$ akış ortalamasını, S_k çalışma periyodu boyunca akış değerlerinin standart sapmasını ifade etmektedir. Hidrolojik çalışma periyodu ekim ile eylül ayları arasını kapsamaktadır. Bulunan AKI indislerin değerlendirmesinde Çizelge 3.2’de SYİ indis değerleri için verilen kuraklık kategorileri kullanılmaktadır.

3.2.3. Rastgele orman (RO)

RO metodu (Breiman, 2001), pratik uygulamalarda en başarılı makine öğrenmelerinden birisi olarak kabul edilir (Biau ve Scornet, 2016; Tyralis vd., 2019). Son zamanlarda özellikle, makine öğrenme algoritmaları ile kıyaslandığında su kaynakları ve hidrolojik konularda başarılı sonuçlar birçok araştırmacı tarafından dile getirilmiştir (Efron ve Hastie, 2016; Tyralis vd., 2019).

Topluluk öğrenme yöntemi olan RO algoritması, sınıflandırma veya regresyon işlemi esnasında birden fazla karar ağacı üreterek sınıflandırma nihai değerini yükseltmeyi hedefleyen bir algoritmadır. Bireysel olarak rastgele seçilerek karar ağaçları bir araya getirilir ve karar ormanı oluşturur. RO, aslında karar ağaçlarının bir fonksiyonudur. Özellikle ağaç boyutu küçük olduğunda, ağaçlandırma yapılırken, dezavantajlar ortaya çıkabilir (Breiman, 1996). Topluluk ağaçları, tahminlemelerde, rastgele oluşturulan dallarda güvenilirliği artıran bir çözüm yöntemidir. RO topluluk ağaçları arasındaki en popüler olanlardandır. Sağlıktan ekonomiye, ekolojiden spor bilimlerine kadar birçok disiplinde kullanılmaktadır (Goldstein vd., 2010; Granitto vd., 2007). Buradaki karar ağaçları, bağlı olduğu veri setinden rastgele seçilmiş birer alt kümedir.

RO, Leo Breiman (1996) tarafından geliştirilen Bagging yöntemi ve Freund ve Schapire (1996) tarafından geliştirilen hızlandırma yöntemlerine göre daha iyidir. Algoritma olarak RO yöntemi bilinen makine öğrenme yöntemleri içerisinde eşsiz bir tahmin geçerliliği ve model yorumlanabilirliği sağlar. Rastgele örneklemeyi ve topluluk yöntemlerdeki tekniklerin iyileştirilmiş özelliklerini içermesi nedeniyle RO yöntemi daha iyi genellemeler sunar ve geçerli tahminlerde bulunur.

RO algoritmasını başlatmak için kullanıcı tarafından iki parametre tanımlanmalıdır. Bu parametreler, en iyi bölünmeyi belirlemek için her bir düğümde kullanılan değişkenlerin sayısı m ve geliştirilecek ağaçların sayısı N ’dir.

İlk başta eğitim veri setinin yaklaşık 2/3'ünden önyükleme örnekleri oluşturulur. Out-of-bag (OOB) verisi olarak da bilinen, eğitim veri setinin 1/3'lük geri kalan kısmı model performansını ölçmek için test amacıyla kullanılır. Bu oranlar değişiklik gösterebilmektedir. Sonra her önceden yüklenmiş örnekten budamasız ağaç geliştirilir. Her bir düğümde m değişkenleri tüm değişkenler arasından rastgele olarak seçilir ve bu değişkenler arasından en iyi dal belirlenir. Yeterli öngörü gücü ile yeterli miktarda korelasyon sağlayan değişken sayısının seçimi son derece önemlidir. RO ağaç üretmek için Sınıflandırma ve Regresyon Ağacı (CART) algoritmasını kullanır. Her bir düğümde dallar CART algoritmasının kriterine (örn. Denklem 3.7'de verilen GINI indeksine) göre oluşturulur (Hu vd., 2019). GINI indeksi sınıf homojenliğini analiz eder ya da ölçer. Kısacası, Rastgele Orman metodu karar ağaçlarındaki hesaplama yöntemiyle çok benzerlik göstermektedir. Farklarından birisi, en iyi sonucu veren dal ile başlamasıdır.

$$G = 1 - \sum_{i=0}^n (P_i)^2 \quad (3.7)$$


G bir düğümdeki veri setini temsil eder. p_i her bir sınıfın veri setindeki oranını ifade eder.

3.2.4. Yapay sinir ağları (YSA)

Biyolojik sinir sistemini taklit ederek çalışan YSA, eşref-i mahlukat olan insanın beynindeki sinyalleri işlemlerini örnek alarak çalışmaktadır. Sinir sisteminde yer alan nöronlar sayesinde sinir hücreleri iletişim kurmaktadır. Nöronlar birbirlerine bağlanarak çeşitli ağlar oluşturmaktadır. Bu ağlar birden fazla yetiye sahiptir (öğrenme, hafıza alma vb.). Bu ağlar arasında çeşitli bağlantılar vardır. Canlıların birçoğu öğrenme yetisini bu ağlardaki etkileşimin tekrar etmesiyle elde etmektedir. Yaşayarak öğrenme işlemi bir nevi anlatılan şekilde oluşmaktadır. Buradan yola çıkarak; genellikle nihai amacı gerçekleştiren bir hesaplama yöntemi geliştirilmiştir. Tahmin, regresyon, eğri uydurma gibi çoğu amaçla kullanılan YSA, esnek veriye dayalı modelleme araçlarından birisidir. Sağlıktan ekonomiye kadar birçok alanda YSA'dan yararlanılmaktadır (Seo ve Kim, 2016). YSA modelleri geçmiş veri kayıtlarından yararlanarak veriyi öğrenir, sonrasında da sınıflandırma ya da tahmin etmede bu eğitim setini kullanır. Modeli oluşturma aşamasında, veri karakteristiğini, modelin yapısını belirlemek amacıyla kullanılmaktadır (Muluaem ve Liou, 2020).

YSA'nın İleri, Geri Beslemeli, Çok Katmanlı Algılayıcı gibi modifikasyonları literatürde sıklıkla kullanılmaktadır. Bunlar arasından Çok Katmanlı Algılayıcı Sinir Ağı (MLP) hidroloji çalışmalarında genellikle tercih edilmektedir. Bu çalışmada YSA'nın Çok Katmanlı Algılayıcı Sinir Ağı (MLP) tercih edilmiştir. MLP genellikle üç kısımda ifade edilir. Bunlar girdi katmanı, saklı katman ve çıktı katmanıdır. Saklı katman sayısı kullanıcının isteğine ve model performansına göre değişiklik gösterebilir (Şekil 3.2). Birçok araştırmacı YSA'yı matematiksel model olarak kullanmıştır. YSA'nın hidrolojide kullanılmasının avantajı, etkili sonuç vermesidir. Diğer bir avantajı ise girdi ve çıktılar arasındaki varsayılan (hayali) fiziksel matematik formundan bağımsız olmasıdır. YSA'nın bir diğer avantajı ise hesaplama kolaylığıdır. Hesaplanması Denklem 3.8 ile yapılır. Matematiksel olarak; aktivasyon fonksiyonu olarak isimlendirilen f fonksiyonu öncelikle hesaplanır. Bu fonksiyon literatürde farklı türevlerde karşımıza çıkabilir. Örneğin; Lineer Fonksiyon, Nonlineer Fonksiyon, Sigmoid Fonksiyon (Hiperbolik Tanjant Sigmoid, Logaritmik Sigmoid vb.), Hiperbolik Tanjant Fonksiyonu, Rectified Linear Unit Fonksiyonu, Leaky ReLu Fonksiyonu gibi. Hidrolojide modeller ile ileriye yönelik tahminler yapılırken, sigmoid fonksiyonu kullanılan veriye bağlı olarak, sonucu olumlu ya da olumsuz olarak etkileyebilir.

YSA'nın hidrolojideki diğer avantajları ise, hidrolojik sistemler genellikle karmaşıktır ve çeşitli etmenlerin etkileşimleri sonucu oluşur. YSA, bu karmaşıklıkları daha iyi modelleyebilir ve hidrolojik süreçler arasındaki ilişkileri tanımlamak için kullanılabilirliği bir avantajdır. Bir diğeri ise YSA, yağış, akış, su seviyeleri gibi hidrolojik değişkenleri tahmin etmek için kullanılabilir. Eğitim verisiyle beslenerek, gelecekteki hidrolojik olayları öngörebilirler. Bu, sel tahminleri, kuraklık izleme ve su kaynakları yönetimi gibi alanlarda önemli bir avantaj sağlar. Hidrolojik sistemler genellikle doğrusal olmayan ilişkilere sahiptir. YSA, bu tür ilişkileri daha iyi modelleyebilir ve hidrolojik sistemlerin daha doğru bir şekilde simülasyonunu sağlayabilir. İyi eğitilmiş bir YSA, hidrolojik olayları tahmin etme ve hidrolojik süreçleri simüle etme konusunda yüksek hassasiyet ve doğruluk sağlayabilir. Bu, su kaynakları yönetimi ve afet risklerinin azaltılması gibi alanlarda önemli bir avantajdır.



Sekil 3.2. Çok Katmanlı Algılayıcı Sinir Ağı örnek yapısı

Bu çalışmada da diğer fonksiyonlar ile denemeler yapıldıktan sonra, girdi verisine bağlı olarak, Hiperbolik Tanjant Fonksiyonunun etkin sonuç verdiği gözlemlenmiştir. Dolayısıyla, bu fonksiyon YSA analizinde kullanılmıştır.

$$f(t) = \frac{e^x - e^{-x}}{(e^x + e^{-x})} \quad (3.8)$$


Buradaki x değeri girdi değerini, e üstel fonksiyonu temsil etmektedir. Hidrolojik modellerde YSA’da birçok eğitim algoritması kullanılmaktadır. Bu algoritmalarından bazıları; Levenberg-Marquardt (LM), Quasi-Newton (QN) ve Conjugate-Gradient (CG) şeklindedir. Bu çalışmada eğitim algoritması olarak LM’den faydalanılmıştır. Ayrıca, en uygun nöron sayısının belirlenmesi deneme yanılma ile yapılmıştır.

3.2.5. Destek vektör makineleri (DVM)

DVM, sınıflandırma ve regresyon analizinde kullanılan, veriyi analiz eden, analiz ederken öğrenen denetimli bir öğrenme yöntemidir. DVM, ilk kez, Vladimir Vapnik ve çalışma arkadaşları tarafından “Computational Learning Theory” (COLT)

konferansında önerilmiş olup, günümüzde kullanılan şekli Corinna Cortes ve Vladimir Vapnik (1995)'e aittir. DVM, istatistiksel öğrenme ilkelerine dayanan son zamanlarda geliştirilen, multidisiplinlerde yaygınlıkla tercih edilen öğrenme araçlarından biridir (Cortes ve Vapnik, 1995; Vapnik, 1992). DVM ilk kez tanıtıldığında YSA benzer bir şekilde heyecan yarattı ve aktif kullanım alanı birden genişledi. DVM'nin gelişimi kapasite kontrolü veya yapısal risk minimizasyonu'na dayanmaktadır. Bu yapısal risk minimizasyonunda girdi-çıktı eğitim setleri kullanılarak model karmaşıklığı en aza indirilmiştir. Bu anlamda, öğrenme prosesi optimum koşullara dayalıdır. Bu ise, bu proses için gerekli ve yeterli koşulların sağlanmış olabileceği anlamına gelmektedir. Tüm bunlar, DVM'lerin seyreklik ve benzersizlik özelliğini ortaya çıkarmaktadır. Seyreklik özelliği kernel matris çekirdeğinin minimum sayıdaki parçasıyla modelin ilk aşamasını oluşturmamıza imkân sağlar (Şekil 3.3). Yani destek vektörlerin ortaya çıkması sağlanır. Destek vektörler ortaya çıktıktan sonra, tüm veri bu doğrultular arasında toplanmaya çalışılır. Bunlardan dolayı destek vektör makinelerinde aşırı öğrenme veya/ve ezberleme önlemiş olmaktadır. Karmaşıklığa yol açacak girdi parametrelerine de imkan tanınmamaktadır.

DVM ile ilgili ilk çalışmalar sınırlı disiplinlerde olmasına rağmen, daha sonraki çalışmalarda özellikle zaman serilerinin tahmini ve regresyon uygulamalarında kullanılmaya başlanmış ve çok iyi sonuçlar elde edildiği görülmüştür (Metlek ve Kayaalp, 2020). Keşfedilmesinden sonra uzun yıllar boyunca kullanılmaya devam etmiş, popülerliğini hala yitirmemiştir. YSA gibi diğer öğrenme yöntemlerine kıyasla, ampirik riskler yerine, yapısal risk minimizasyonunun kullanılması, DVM'nin en önemli avantajlarından birisi olup, popüler olmasının nedenlerindendir. DVM, lineer olmayan zaman serisi için bir dizi girdi vektörlerinden oluşur. Bu girdi vektörlerine bir nevi öğrenme seti (fonksiyonu) de denilebilmektedir. DVM literatürde hem sınıflandırma hem de regresyon analizinde kullanılmasına rağmen genel olarak sınıflandırma işlemlerinde daha çok tercih edilen bir makine öğrenme yöntemidir. Bu yöntem denetimli bir öğrenme modeline dayanmaktadır. Eğitim setindeki veriye göre, farklı Kernel fonksiyonları kullanabilmektedir.



Şekil 3.3. İki sınıflı destek vektörleri

Bu sayede lineer ya da lineer olmayan sınıflandırma işlemi yapılabilmektedir. Sınıflandırma yapılırken, veri tam ayrışabilir nitelikte ise, tek boyutta hiper düzlemler ile ayrışabilir ya da üç boyutta hiper düzlemler iki boyutlu bir alt uzayı ifade eder ve bu düzlemler yardımıyla da ayrışabilir. Sınıflandırmanın nasıl yapılacağı girdi verisine bağlı olarak değişebilir. Bu nedenle farklı çekirdek fonksiyonları anahtar rolündedir. Çekirdek fonksiyonlarının yanı sıra, sınıflandırma ya da regresyon işlemi hiper düzlemlerde yapılıyorsa, ceza parametresi (C) ve esneklik değişkeni (ξ)'ni de analiz sonucunu etkilemektedir. Bu parametreler, ne kadar iyi ayarlanabilirse, analiz sonucunun o kadar iyi sonuç verdiği söylenebilir (Popov ve Sautin, 2008).

DVM'i literatürde yüz algılama, metin ve köprü metni sınıflandırma, görüntü sınıflandırma, biyoinformatik, protein çaprazlama, uzaktan homoloji tespiti, el yazısı tanıma, jeoloji ve çevre bilimleri genelleştirilmiş tahmine dayalı kontrol uygulamalarında genellikle kullanılmaktadır (Gour, 2019).

Destek vektör makinesinin regresyon uyarlamasına dair işlemler ise aşağıda özetlenmiştir. $D = \{(x_1, y_1), (x_2, y_2), \dots (x_n, y_n)\}$ 'den oluşan bir eğitim seti için; x_i N-boyutlu girdi değişkenlerinin her biri, y_i ise çıktılarıdır.

$f(x) = \langle w, x \rangle + b$ fonksiyonu bulunmak isteniyor. Burada; w normal vektör, x ise girdi vektörü, b bias ve vektörel bir çarpım söz konusudur. DVM'de amacımız, öyle

bir $f(x)$ fonksiyonu bulmaktır ki; gerçek y_i çıktı değerleri en fazla sınır miktarı $(2/\|w\|)$ kadar sapma ile tahmin edilsin ve bulunan bu fonksiyona paralel olan ve eğitim girdilerini kapsayan iki düzlem arasındaki mesafe minimum olsun. Dolayısıyla; ilk önce burada hiper düzlem için sınırlarının belirlenmesi (genişletilmesi) gerekmektedir (Denklem 3.9).

$$\begin{aligned} wx_i + b &\geq +1 & \forall y_i = +1 \text{ için} \\ wx_i + b &\geq -1 & \forall y_i = -1 \text{ için} \end{aligned} \quad (3.9)$$

Bu eşitsizlikler özet olarak Denklem 3.10'daki gibi ifade edilebilir.

$$|wx_i + b| = 1 \forall_i \quad (3.10)$$

Sınır miktarlarının maksimize edilmesi için $\|w\|$ ifadesinin minimize edilmesi gerekmektedir.

$$\min \left(\frac{\|w\|^2}{2} \right), \quad y_i(wx_i + b) - 1 \leq 0 \quad (3.11)$$

Denklem 3.11 Lagrangian optimizasyonu problemidir. Optimum hiper düzlemin ağırlık vektörünü w ve eğilimini b elde etmek için Lagrange çarpanları kullanılarak çözülebilir (Gunn, 1997). $a_i \geq 0 \forall_i$ koşulu ile, a_i Denklem 3.12'de Lagrange çarpanını temsil eder.

$$\begin{aligned} L_p &= \left(\frac{\|w\|^2}{2} \right) - a[y_i(wx_i + b) - \forall_i] \\ &= \left(\frac{\|w\|^2}{2} \right) - \sum_{i=1}^L a_i y_i (x_i w + b) + \sum_{i=1}^L a_i \end{aligned} \quad (3.12)$$

3.13 Denkleminde w ve b 'nin diferansiyelini 0'a eşitleyerek, w ve b 'yi minimize edilir, aynı zamanda a_i maksimize eden değeri bulmak amaçlanır.

$$\begin{aligned} \frac{\partial L_p}{\partial w} = 0 &\rightarrow w = \sum_{i=1}^L a_i y_i x_i \\ \frac{\partial L_p}{\partial b} = 0 &\rightarrow \sum_{i=1}^L a_i y_i = 0 \end{aligned} \quad (3.13)$$

Denklem 3.14 formülasyonunda, L_D biricil L_p 'nin ikili formu olarak ifade edilir. Denklem 3.14'de a_i 'yi maksimum yapan değerler için L_D 'nin maksimizasyonu ya da L_p 'nin minimizasyonu ile çözülür. a_i 'nin hesaplaması yapıldıktan sonra akabinde Denklem 3.12'den w ve b değerleri bulunur. Çözümde $a_i > 0$ olan noktalar destek vektörlerini temsil etmektedir.

$$L_D = \sum_{i=1}^L a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i x_j \quad a_i \geq 0 \quad \forall_i \quad (3.14)$$

Doğrusal olarak ayrılabilen veri için hesaplamalara yukarıda değinilmiştir. Doğrusal olarak belirli bir oranda ayrılabilen veri hesabında ise ξ ve C parametrelerinden yararlanılır (Catalbas ve Kocak, 2019) (Denklem 3.15, 3.16).

$$\begin{aligned} wx_i + b &\geq +1 - \xi_i \quad \forall y_i = +1 \text{ için } \xi_i \geq 0 \\ wx_i + b &\geq -1 + \xi_i \quad \forall y_i = -1 \text{ için } \xi_i \geq 0 \end{aligned} \quad (3.15)$$

$$\min \left(\frac{\|w\|^2}{2} + C \sum_{i=0}^L \xi_i \right), \quad y_i(wx_i + b) - 1 + \xi_i \leq 0 \quad (3.16)$$

$$L_p = \frac{\|w\|^2}{2} + C \sum_{i=1}^L \xi_i - \sum_{i=1}^L a_i \left[y_i(wx_i + b) - 1 + \xi_i \right] - \sum_{i=1}^L \mu_i \xi_i \quad \forall_i \quad (3.17)$$

Denklem 3.17 Lagrange denkleminin w , b , ξ 'göre minimize edilmesi ve $a, \mu \geq 0$ 'a göre maksimize edilmesi gerekmektedir. Akabinde w , b , ξ 'nin diferansiyeli 0'a eşitlenir (Denklem 3.18).

$$L_D = \sum_{i=1}^L a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i x_j \quad 0 \leq a_i \leq C \quad \sum_{i=1}^L a_i y_i = 0 \quad (3.18)$$

3.2.6. Karar ağaçları (KA)

KA fikir olarak, çok dal yapısına sahip eğer-öyleyse-aksi durumunda gibi algoritma yapısıyla çalışan farklı dalları olan büyük bir ağaca benzemektedir. Makine öğrenmesindeki en önemli algoritmalarından birisidir. Bu algoritma sınıflandırma ve regresyon amacıyla literatürde birçok araştırmacı tarafından kullanılmaktadır. Prensip olarak, hedefte olan özelliklere göre büyük veriyi, sürekli alt kümeler oluşturarak, daha küçük hale getirmesi ile çalışır. Son aşamadaki dallarda ya da yapraklarda nihai hedef tam olarak yorumlanabildiğinde bu süreç sonlanır. Son daldaki etiket istenilen özelliği temsil etmektedir.

KA'da sınıflandırma ya da regresyon işlemi yapılırken, hata tahminleri öğrenme ve test aşamasında etkili bir rol oynamaktadır. Etkili bir tahminleme yapılabilmesi için en az oranda hata tahminleri yapılması gerekmektedir. Bu hem hata tahminlerinin azalması hem de istenilen özellik ya da hedefe en etkili bir şekilde ulaşılması amacıyla, C4.5, C5.0 gibi karar ağaçları algoritmaları geliştirilmiştir (Quinlan, 1992). Bu algoritmalar veri setine göre farklı performanslar gösterebilmektedir. Hidrolojik çalışmalarda C5.0 genellikle tercih edilmektedir. Bu çalışmada da C5.0 algoritması veri setine bağlı olarak kullanılmıştır. RO'de olduğu gibi burada da GINI indeksi yardımıyla, hesaplamalar yapılmaktadır.

GINI indeksi sınıf homojenliğini analiz eder ya da ölçer. Kısacası, Rastgele Orman metodu karar ağaçlarındaki hesaplama yöntemiyle çok benzerlik göstermektedir (Denklem 3.7). Farklarından birisi, en iyi sonucu veren dal ile başlamasıdır.


3.2.7. Dalgacık dönüşüm tekniği

Veri kaydı ve bunları analiz edip yorumlamak günümüzde birçok disiplin için önemlidir. Su kaynaklarının planlanmasında da veri kaydının önemi bir hayli fazladır. Bir havzadaki ya da su kaynağındaki ölçümü yapılabilen debi, yağış vb. parametrelerin davranışları ya da karakteristiği hakkında bilgi edinmek için geçmişteki veriden büyük ölçüde yararlanılmaktadır. Ayrıca, ileriye yönelik davranışlarını da tahmin edebilmek ve gerekli önlemleri almak için de yine geçmiş veri kayıtları kullanılmaktadır. Elde edilen bilgiler genellikle zamanın bir fonksiyonu olsa da, kullanılan yöntemlerin çoğu ortaktır. Zaman ve frekans analizleri şeklinde genellikle iki başlık altında toplanan bu yöntemler, yeri geldiğinde ortaklaşa da kullanılmaktadır. Zaman analizleri genellikle filtreleme işlemi olarak literatürde bilinir. Frekans'a yönelik işlemler de ise Fourier Dönüşümü (FD) kullanılır. FD'de incelenen zamana bağlı serinin (zaman serisinin) hangi dominant frekanslardan oluştuğu bulunur. FD sonucunda elde edilen hakim frekanslardır. Bu hakim frekanslara sahip olan sinyallerin hangi zaman aralığı içinde etki ettiği bilinmemektedir. Bir diğer deyişle, FD hakim frekanslar tespit edilmekte, ancak zaman etkisi kaybolmakta ve bu etki eden sinyallerin hangi zaman aralığında etki ettiği bilinmemektedir. Bu aşamada, Dalgacık Analizi yardımı yetiştirilmektedir. Dalgacık analizi ile incelenen sinyallerin, hem hakim frekansları hem de etki ettiği

zaman aralığı bulunabilmektedir. Temeli FD olan frekans analizleri zaman içinde gelişerek yerini Dalgacık Dönüşümlerine bırakmıştır. Dalgacık dönüşümleri hem zaman hem de frekans analizlerinde etkin rol oynamaktadır.

Zaman serileri, bir ya da birden fazla zamana bağlı değişkenin kayıt altına alınması sonucunda ortaya çıkar. Ortaya çıkan matematiksel ifade bir fonksiyon olarak değerlendirilebilir. Literatürdeki en uzun süreli zaman serisi kaydı Nil nehrine aittir. Ortalama 1300 yıllık bir seriyi içermektedir. Eskiden olduğu gibi geçmişten günümüze kadar birçok veri zamana bağlı olarak saklanmaktadır. Hidrolojide de durum böyledir. Belirli zaman aralıkları ile belirli konumda ve ölçekte ölçülen hidrolojik veri (yağış, akış, sıcaklık vb.), matematiksel açıdan hidrolojik zaman serisi olarak incelenebilirler. Bu zaman serilerinin karakteristik yapılarının incelemesinde Dalgacık Dönüşüm Teknikleri kullanılabilir. Dalgacık yöntemleri belirli bir periyodun ya da tüm serinin yapısının ortaya çıkarılmasında etkin rol oynamaktadır. Böylelikle ileriye yönelik tahmin yapılabilme kolaylaşabilir.

Dalgacık, süresi sınırlı titreşim hareketi ya da dalgayı oluşturan küçük bir parça olarak tanımlanabilir (Daubechies, 1996; Partal vd., 2008). Dalgacıklar, veriyi farklı frekans bileşenlerine ayıran ve sonra kendi ölçekleriyle eşleştirilmiş bir çözünürlüğe sahip bileşenler üzerinde çalışan matematiksel fonksiyonlardır. Dalgacıkta kullanılan fonksiyonlar çeşitlilik arz edebilir. En yaygın kullanılanlardan bazıları Haar (A), Daubechies (B), Morlet, sym (C), Meksika şapka tipi (D), Bior 3.1, Demey'dir (Şekil 3.4).



Şekil 3.4. Örnek dalgacıklar


Dalgacık dönüşümü yapılırken, zaman serisinin tamamına ya da belirli bir tarih aralığına dönüşüm uygulanabilir. Belirli bir tarih aralığının seçilmesi, işlem kalabalığını azaltarak, daha net sonuç vermesine imkân sağlar. Bu çalışmada, zaman serisine ayrık dalgacık dönüşümü uygulanmış olup, zaman serisi yekpare halinde alınmıştır. Kesikli dalgacık dönüşümü Denklem 3.20 ve 3.21 gibi ifade edilir.

$$\psi_{m,n}\left(\frac{t-\tau}{s}\right) = s_0^{-\frac{m}{2}} \psi\left(\frac{t-n\tau_0 s_0^m}{s_0^m}\right) \quad (3.20)$$

$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} x_i \psi(2^{-m}i - n) \quad (3.21)$$

Burada m ve n tamsayı olarak dalgacığın sırası ile ölçek ve zaman eksenindeki öteleme parametreleridir. s_0 sabit bir öteleme adımını ifade eder. τ_0 zaman eksenindeki öteleme aralığı değerini vermektedir (Partal vd., 2008).

Ayrık Dalgacık Dönüşümünde ham sinyaller $x(t)$ yaklaşık ve farklı kademelerde detay olarak adlandırılabilen iki ayrı seriye ayrılır. İşaret öncelikle yaklaşıklık ve onunla aynı seviyeden bir detay serisine bölünür. Bölünme işleminden sonra, birisi alçak yani düşük frekanslı geçiren bileşen, diğeri de yüksek yani yüksek frekanslı geçiren frekanslı bileşenler olmak üzere iki filtre geçişleri sağlanır. Filtre sonucunda oluşan iki ayrı sinyalden A ile ifade edilene yaklaşım ya da yaklaşıklık serisi (Approximation) ve D ile temsil edene de detay serisi (Detail) adı verilmektedir. Yaklaşım sinyalleri, orijinal sinyali temsil eder ve sinyalin tanımını verir iken detaylar ise sinyalin karakteristiği hakkında fikir verir. Dalgacık dönüşümünde amaç görüldüğü gibi sinyali yaklaşım ve detaylarına ayırmaktır. Elde edilen yaklaşım tekrar ikinci seviye yaklaşım ve detayına ayrıştırılır, bu işlem istenilen sonuç elde edilene kadar tekrarlanabilir. Bu çalışmanın tamamında, Daubechies45 dalgacık dönüşümünden, 5 detay olacak şekilde faydalanılmıştır. Şekil 3.5’de analiz edilen veri setinden bir örnek sunulmuştur. Burada s ham veriyi, a yaklaşım ya da yaklaşıklık serisini, d ’ler ise detay serilerini göstermektedir. Hedef değere ulaşılabilmesi ve kesin tahminlerin yapılabilmesi için detay sayısı artırılıp azaltılabilir.



Şekil 3.5. Dalgacık dönüşümünde yaklaşım ve detaylar

3.2.8. İstatistiksel olarak performans değerlendirme kriterleri

Literatürde modelleme çalışmalarında, modellerden elde edilen sonuçları değerlendirmek için birçok performans değerlendirme kriterlerinden faydalanılmaktadır. Bunlardan bazıları Ortalama Kare Hata (MSE), Ortalama Mutlak Hata (MAE), Nash-Sutcliffe (NS), Kök Ortalama Kare Hata (RMSE), Korelasyon katsayısı (r)'dır. Bu çalışmada, bunlardan NS, RMSE ve r kullanılmıştır. Modellerden elde edilen sonuçlar belirtilen yöntemler ile ölçülmüş ve birbirleriyle kıyaslanmıştır. Bir modelin diğerlerine göre daha başarılı ya da etkili olabilmesi için, önce NS değeri irdelenmiş, sonrasında ise r , en son ise RMSE değeri göz önünde bulundurulmuştur.

NS katsayısı, hata kareleri ortalamaları ile gerçek değerlerin varyansının bir oranıdır. Bu oran 1'den çıkarılarak bir katsayı elde edilir (Denklem 3.22). Elde edilen katsayı 1 ile eksi sonsuz arasında değişmektedir ve en iyi tahmini temsil eden değer 1'dir. Literatürde kabul gören oranlar ise, 0.5-0.7 arası "kabul edilebilir tahmin", 0.7-0.9 arası "iyi tahmin" ve 0.9-1 arası ise "mükemmel" tahmin olarak adlandırılabilir (Moriasi vd., 2007).

$$NS = 1 - \left[\frac{\sum_{i=1}^N (P_{oi} - P_{pi})^2}{\sum_{i=1}^N (P_{oi} - \bar{P}_o)^2} \right] \quad (3.22)$$

En basit ifadeyle, iki değişken arasındaki doğrusal ilişki olup olmadığını istatistiksel olarak sınanmasını sağlayan korelasyon katsayısı, r , model performanslarını değerlendirmek için kullanılan başka bir yöntemdir. -1 ile 1 arasında değerler alabilen r , Denklem 3.23'ya göre hesaplanır.

$$r = \frac{\sum_{i=1}^N (P_{pi} - \bar{P}_p)(P_{oi} - \bar{P}_o)}{N \sigma_{P_p} \sigma_{P_o}} \quad (3.23)$$

RMSE değeri 0 ile sonsuz arasında değişmekte olup en iyi değer Sıfır (0) olarak kabul edilir. Sıfır değeri tahmin işleminin hatasız yapıldığını göstermektedir ve Denklem 3.24 ile hesaplanır.


$$RMSE = \sqrt{\frac{1}{n} \sum_{k=0}^n (P_{pi} - P_{oi})^2} \quad (3.24)$$

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Çalışmanın bu kısmı; kuraklık analiz sonuçları, kuraklık tahmin modelleri, yağış akış tahmin modelleri, baraj kot seviyesi tahmin modelleri ve tüm analiz sonuçlarının karşılaştırılması olmak üzere 5 farklı bölümden oluşturulmuştur. Her bir kısımda, kullanılan veri, modellerin girdi yapısı ve model çalışması sonucunda elde edilen bulgular, ilgili bölümlerde ayrı ayrı verilmiştir.

4.1. Kuraklık Analizi

Çoğunluğunu Çumra istasyonundan elde edilen aylık toplam yağış verisi ile SYİ'den faydalanılarak yapılan analiz sonuçları indis histogramı Şekil 4.1'de ve aylık toplam yağış verisine ait zaman serisi de Çizelge 4.1'de gösterilmiştir.



Şekil 4.1. Yağış değerlerinin zaman serisi

AKİ ile hesaplanan indis değerlerine bu kısımda yer verilmemiştir. AKİ hesaplamaları yağış-akış modellerinin girdi yapısında kullanılacağından dolayı, ilgili kısımda ayrıca verilmiştir.

Çizelge 4.1'de göre, SYİ1'de toplam indis sayısının (792) yüzdesel olarak en fazla dağılım aralığı %41 değer ile 0 ile 1 arasındadır. SYİ3, SYİ6, SYİ9 ve SYİ24'de de bu durum aynıdır. SYİ12'nin en fazla dağılım aralığı ise %35 değer ile -1 ile 0 arasında gerçekleşmiştir. SYİ1'de -2 ve daha küçük değerlerde bir indis değeri, SYİ3'de ise 2 ve daha büyük değerlerde bir indis değeri hesaplanmamıştır. SYİ'nin diğer zaman adımlarına göre, -2 ve daha küçük kuraklık indis değerlerinin yüzdesi SYİ3 ve

SYİ6'da (%4) daha fazladır. Aynı şekilde, 2 ve daha büyük kuraklık indis değerlerinin yüzdesi SYİ9 ve SYİ24'de (%3) SYİ'nin diğer zaman adımlarına göre daha fazla olduğu Çizelge 4.1'de gösterilmiştir.

Çizelge 4.1 SYİ değerlerinin yüzdesel olarak dağılım histogramı

Aralık	SYİ1	SYİ3	SYİ6	SYİ9	SYİ12	SYİ24
< -2	0	4	4	2	1	3
-2 ile -1.5	6	5	4	5	5	4
-1.5 ile -1	9	7	9	10	10	10
-1 ile 0	26	29	33	34	35	31
0 ile 1	41	41	35	33	31	37
1 ile 1.5	13	11	11	10	9	9
1.5 ile 2	4	4	3	4	6	4
>2	1	0	2	3	2	3
Toplam indis sayısı	792	790	787	784	781	769

Kuraklık indis değerleri hesaplandıktan sonra, farklı zaman adımlarında tarihlere göre tespit edilen kuraklıklara ait bilgiler Çizelgeler halinde ifade edilmiştir. 1 aylık yağış toplamaları ile elde edilen SYİ1 indis değerleri, kuraklık sınıflarına göre oluştuğu tarih aralıkları Çizelge 4.2'de gösterilmiştir. Çizelge 4.2 incelendiğinde, toplamda 326 ay süreyle, 144 farklı kuraklık tespit edilmiştir. Bunların 38'i Şiddetli kurak, 35'i orta kurak, 71'i az kurak kategorisinde gerçekleşmiştir. Aşırı kurak kategorisinde herhangi bir kuraklık belirlenmemiştir.

Çizelge 4.2. SYİ1 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
1-1955	2-1955	2	Az kurak	3-1990	4-1990	2	Az kurak
5-1955	8-1955	4	Orta kurak	6-1990	8-1990	3	Şiddetli kurak
10-1955	10-1955	1	Az kurak	3-1991	3-1991	1	Az kurak
3-1956	4-1956	2	Az kurak	6-1991	10-1991	5	Orta kurak
6-1956	10-1956	5	Şiddetli kurak	1-1992	1-1992	1	Az kurak
1-1957	1-1957	1	Az kurak	3-1992	3-1992	1	Az kurak
7-1957	8-1957	2	Şiddetli kurak	8-1992	10-1992	3	Orta kurak
11-1957	11-1957	1	Az kurak	2-1993	3-1993	2	Az kurak
2-1958	2-1958	1	Az kurak	7-1993	10-1993	4	Şiddetli kurak
7-1958	10-1958	4	Şiddetli kurak	2-1994	2-1994	1	Az kurak
2-1959	3-1959	2	Az kurak	5-1994	9-1994	5	Orta kurak
5-1959	5-1959	1	Az kurak	8-1995	9-1995	2	Az kurak
7-1959	9-1959	3	Orta kurak	12-1995	12-1995	1	Az kurak
12-1959	12-1959	1	Az kurak	2-1996	2-1996	1	Az kurak


Çizelge 4.2 (devam). SYİİ ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
6-1960	11-1960	6	Şiddetli kurak	6-1996	9-1996	4	Orta kurak
1-1961	1-1961	1	Az kurak	11-1996	11-1996	1	Şiddetli kurak
4-1961	4-1961	1	Az kurak	4-1997	4-1997	1	Az kurak
7-1961	9-1961	3	Şiddetli kurak	7-1997	7-1997	1	Az kurak
11-1961	11-1961	1	Az kurak	11-1997	11-1997	1	Az kurak
1-1962	1-1962	1	Az kurak	7-1998	9-1998	3	Şiddetli kurak
3-1962	4-1962	2	Az kurak	5-1999	5-1999	1	Az kurak
6-1962	9-1962	4	Şiddetli kurak	7-1999	12-1999	6	Orta kurak
11-1962	11-1962	1	Az kurak	7-2000	9-2000	3	Şiddetli kurak
7-1963	9-1963	3	Şiddetli kurak	11-2000	11-2000	1	Orta kurak
1-1964	1-1964	1	Az kurak	1-2001	1-2001	1	Orta kurak
4-1964	4-1964	1	Orta kurak	3-2001	3-2001	1	Az kurak
7-1964	10-1964	4	Şiddetli kurak	6-2001	10-2001	5	Şiddetli kurak
4-1965	4-1965	1	Az kurak	2-2002	2-2002	1	Az kurak
6-1965	10-1965	5	Şiddetli kurak	6-2002	6-2002	1	Az kurak
4-1966	4-1966	1	Az kurak	10-2002	10-2002	1	Az kurak
6-1966	10-1966	5	Orta kurak	5-2003	10-2003	6	Şiddetli kurak
2-1967	2-1967	1	Az kurak	3-2004	3-2004	1	Az kurak
6-1967	10-1967	5	Orta kurak	5-2004	10-2004	6	Şiddetli kurak
6-1968	8-1968	3	Orta kurak	12-2004	12-2004	1	Az kurak
6-1969	8-1969	3	Orta kurak	3-2005	3-2005	1	Az kurak
4-1970	4-1970	1	Orta kurak	7-2005	8-2005	2	Orta kurak
7-1970	8-1970	2	Orta kurak	12-2005	12-2005	1	Az kurak
7-1971	7-1971	1	Orta kurak	7-2006	8-2006	2	Az kurak
9-1971	9-1971	1	Orta kurak	12-2006	12-2006	1	Orta kurak
3-1972	3-1972	1	Az kurak	4-2007	5-2007	2	Az kurak
7-1972	9-1972	3	Şiddetli kurak	7-2007	8-2007	2	Orta kurak
12-1972	1-1973	2	Az kurak	10-2007	10-2007	1	Az kurak
6-1973	10-1973	5	Şiddetli kurak	4-2008	4-2008	1	Az kurak
12-1973	12-1973	1	Az kurak	6-2008	8-2008	3	Şiddetli kurak
6-1974	9-1974	4	Şiddetli kurak	6-2009	8-2009	3	Şiddetli kurak
11-1974	11-1974	1	Az kurak	3-2010	3-2010	1	Az kurak
3-1975	3-1975	1	Az kurak	5-2010	5-2010	1	Az kurak
7-1975	9-1975	3	Şiddetli kurak	7-2010	9-2010	3	Şiddetli kurak
7-1976	9-1976	1	Az kurak	11-2010	11-2010	1	Az kurak
7-1977	9-1977	3	Şiddetli kurak	7-2011	9-2011	3	Orta kurak
11-1977	11-1977	1	Şiddetli kurak	3-2012	4-2012	2	Az kurak
5-1978	5-1978	1	Az kurak	6-2012	9-2012	4	Şiddetli kurak
7-1978	9-1978	3	Şiddetli kurak	1-2013	1-2013	1	Az kurak
11-1978	11-1978	1	Orta kurak	3-2013	3-2013	1	Az kurak
2-1979	2-1979	1	Az kurak	5-2013	9-2013	5	Orta kurak
7-1979	9-1979	3	Şiddetli kurak	2-2014	2-2014	1	Az kurak
6-1980	9-1980	4	Orta kurak	4-2014	4-2014	1	Az kurak

Çizelge 4.2 (devam). SYİl ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
12-1980	12-1980	1	Az kurak	7-2014	8-2014	2	Şiddetli kurak
4-1981	4-1981	1	Az kurak	7-2015	9-2015	3	Orta kurak
8-1981	10-1981	3	Şiddetli kurak	11-2015	12-2015	2	Orta kurak
7-1982	9-1982	3	Orta kurak	2-2016	2-2016	1	Az kurak
6-1983	9-1983	4	Orta kurak	4-2016	4-2016	1	Az kurak
2-1984	2-1984	1	Az kurak	7-2016	8-2016	2	Şiddetli kurak
5-1984	10-1984	6	Orta kurak	10-2016	10-2016	1	Şiddetli kurak
7-1985	9-1985	3	Şiddetli kurak	2-2017	2-2017	1	Orta kurak
3-1986	3-1986	1	Az kurak	6-2017	9-2017	4	Şiddetli kurak
6-1986	10-1986	5	Şiddetli kurak	2-2018	2-2018	1	Az kurak
6-1987	9-1987	4	Orta kurak	4-2018	4-2018	1	Az kurak
1-1988	1-1988	1	Az kurak	7-2018	9-2018	3	Orta kurak
6-1988	9-1988	4	Şiddetli kurak	5-2019	5-2019	1	Orta kurak
2-1989	2-1989	1	Az kurak	7-2019	10-2019	4	Az kurak
4-1989	9-1989	6	Orta kurak	5-2020	11-2020	7	Şiddetli kurak

Kuraklık indis değerlerinin zaman içerisindeki değişimi Şekil 4.2'deki gibidir. Şekil 4.2. incelendiğinde sulak kategorisinde, 4-1977 tarihinde indis değerinin sulak kategorisinde seri boyunca zirve yaptığı, kurak kategorisinde ise, zaman serisinin birçok zirve noktası olduğu gözlemlenmiştir.



Şekil 4.2. SYİl indis değerlerinin zaman serisi

Toplam zamanın 349 ayı kurak olarak tespit edilen, 3 aylık yağışların ardışık toplamı ile hesaplanan SYİ3'e ait kurak geçen sürelerin detayları Çizelge 4.3'de gösterilmiştir. Buna göre; toplamda 70 kuraklık tespit edilmiş olup, bunların 26'sı aşırı kurak, 18'si şiddetli kurak, 14'ü orta kurak, 25'i az kuraktır.


Çizelge 4.3. SYİ3 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
3-1955	3-1955	1	Az kurak	4-1989	10-1989	7	Şiddetli kurak
6-1955	12-1955	7	Aşırı kurak	4-1990	10-1990	7	Şiddetli kurak
5-1956	1-1957	9	Aşırı kurak	7-1991	10-1991	4	Şiddetli kurak
7-1957	12-1957	6	Orta kurak	9-1992	11-1992	3	Aşırı kurak
4-1958	4-1958	1	Az kurak	3-1993	4-1993	2	Az kurak
8-1958	12-1958	5	Şiddetli kurak	8-1993	11-1993	4	Aşırı kurak
4-1959	10-1959	7	Şiddetli kurak	7-1994	10-1994	4	Aşırı kurak
2-1960	2-1960	1	Az kurak	8-1995	10-1995	3	Az kurak
7-1960	1-1961	7	Şiddetli kurak	2-1996	2-1996	1	Az kurak
4-1961	11-1961	8	Orta kurak	7-1996	11-1996	5	Şiddetli kurak
3-1962	9-1962	7	Aşırı kurak	4-1997	4-1997	1	Az kurak
8-1963	11-1963	4	Şiddetli kurak	8-1997	9-1997	2	Az kurak
1-1964	2-1964	2	Az kurak	8-1998	11-1998	4	Aşırı kurak
4-1964	5-1964	2	Az kurak	5-1999	12-1999	8	Şiddetli kurak
8-1964	11-1964	4	Aşırı kurak	8-2000	4-2001	9	Aşırı kurak
5-1965	11-1965	7	Aşırı kurak	8-2001	10-2001	3	Orta kurak
4-1966	11-1966	8	Aşırı kurak	7-2002	8-2002	2	Az kurak
8-1967	10-1967	3	Şiddetli kurak	7-2003	11-2003	5	Aşırı kurak
6-1968	9-1968	4	Orta kurak	5-2004	5-2004	1	Az kurak
8-1969	10-1969	3	Orta kurak	7-2004	10-2004	4	Aşırı kurak
4-1970	10-1970	7	Orta kurak	2-2005	5-2005	4	Az kurak
7-1971	11-1971	5	Az kurak	7-2005	10-2005	4	Az kurak
8-1972	2-1973	7	Aşırı kurak	2-2006	2-2006	1	Az kurak
7-1973	2-1974	8	Aşırı kurak	4-2006	4-2006	1	Az kurak
6-1974	11-1974	6	Şiddetli kurak	7-2006	9-2006	3	Az kurak
8-1975	11-1975	4	Orta kurak	12-2006	1-2007	2	Az kurak
8-1976	9-1976	2	Orta kurak	5-2007	10-2007	6	Orta kurak
7-1977	11-1977	5	Şiddetli kurak	6-2008	10-2008	5	Şiddetli kurak
6-1978	9-1978	4	Aşırı kurak	7-2009	10-2009	4	Orta kurak
8-1979	10-1979	3	Orta kurak	7-2010	9-2010	3	Aşırı kurak
8-1980	10-1980	3	Aşırı kurak	8-2011	10-2011	3	Aşırı kurak
8-1981	11-1981	4	Şiddetli kurak	4-2012	10-2012	7	Aşırı kurak
7-1982	11-1982	5	Şiddetli kurak	3-2013	3-2013	1	Az kurak
1-1983	1-1983	1	Az kurak	7-2013	12-2013	6	Aşırı kurak
7-1983	11-1983	5	Orta kurak	4-2014	5-2014	2	Az kurak
7-1984	11-1984	5	Aşırı kurak	7-2014	9-2014	3	Az kurak

Çizelge 4.3 (devam). SYİ3 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
8-1985	9-1985	2	Aşırı kurak	8-2015	5-2016	10	Şiddetli kurak
3-1986	4-1986	2	Az kurak	8-2016	11-2016	4	Az kurak
8-1986	10-1986	3	Aşırı kurak	8-2017	10-2017	3	Aşırı kurak
6-1987	10-1987	5	Şiddetli kurak	9-2018	10-2018	2	Şiddetli kurak
8-1988	9-1988	2	Aşırı kurak	7-2019	11-2019	5	Orta kurak
				6-2020	12-2020	7	Orta kurak

SYİ3 indis değerlerinin zamana göre değişimi Şekil 4.3’de gösterilmiştir. Bu şekilde de görüldüğü üzere, sulak dönemlere ait zirve değerleri 1-1969 ve 4-2003 tarihlerinde, kurak döneme ait zirve değerleri ise, 8-1962, 9-1993 ve 10-2004 tarihlerinde tespit edilmiştir. Kurak dönemlere ait zirve değerlerinin, aşırı kurak kategorisinde (<-2) fazlalığı Şekil 4.3’de dikkat çekmektedir.



Şekil 4.3. SYİ3 indis değerlerinin zaman serisi


Bir başka zaman adımı olan 6 aylık ardışık yağış toplamaları ile hesaplanan SYİ6’ya ait kurak geçen dönemlerin bilgileri Çizelge 4.4’de verilmiştir. SYİ6’da toplam 386 ay kurak geçmiş ve 70 kuraklık tespit edilmiştir. 70 kuraklığın 14’ünü aşırı kurak, 12’sini şiddetli kurak, 14’ünü orta kurak, 30’unu ise az kurak oluşturmaktadır.

Çizelge 4.4. SYİ6 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
6-1955	1-1956	8	Aşırı kurak	9-1988	9-1988	1	Az kurak
3-1956	3-1956	1	Az kurak	5-1989	11-1989	7	Aşırı kurak
6-1956	4-1957	11	Aşırı kurak	6-1990	12-1990	7	Orta kurak
8-1957	4-1958	9	Orta kurak	7-1991	1-1992	7	Şiddetli kurak
7-1958	3-1959	9	Şiddetli kurak	10-1992	3-1993	6	Az kurak
5-1959	2-1960	10	Orta kurak	8-1993	2-1994	7	Şiddetli kurak
7-1960	12-1961	18	Aşırı kurak	7-1994	11-1994	5	Şiddetli kurak
6-1962	12-1962	7	Aşırı kurak	9-1995	10-1995	2	Az kurak
11-1963	5-1964	7	Orta kurak	12-1995	2-1996	3	Az kurak
8-1964	2-1965	7	Orta kurak	9-1996	11-1996	3	Şiddetli kurak
6-1965	12-1965	7	Aşırı kurak	7-1997	9-1997	3	Az kurak
7-1966	2-1967	8	Aşırı kurak	11-1997	11-1997	1	Az kurak
9-1967	12-1967	4	Orta kurak	9-1998	12-1998	4	Az kurak
7-1968	10-1968	4	Orta kurak	6-1999	2-2000	9	Aşırı kurak
9-1969	12-1969	4	Az kurak	11-2000	4-2001	6	Orta kurak
6-1970	11-1970	6	Şiddetli kurak	10-2001	11-2001	2	Az kurak
10-1971	12-1971	3	Az kurak	9-2003	12-2003	4	Şiddetli kurak
9-1972	4-1973	8	Şiddetli kurak	7-2004	3-2005	9	Aşırı kurak
8-1973	4-1974	9	Aşırı kurak	5-2005	10-2005	6	Az kurak
6-1974	11-1974	6	Orta kurak	12-2005	12-2005	1	Az kurak
11-1975	11-1975	1	Az kurak	5-2006	1-2007	9	Az kurak
10-1977	1-1978	4	Az kurak	4-2007	5-2007	2	Az kurak
7-1978	12-1978	6	Şiddetli kurak	7-2007	11-2007	5	Şiddetli kurak
8-1979	10-1979	3	Az kurak	6-2008	12-2008	7	Orta kurak
9-1980	12-1980	4	Orta kurak	8-2009	11-2009	4	Az kurak
8-1981	2-1982	7	Orta kurak	8-2010	11-2010	4	Az kurak
7-1982	2-1983	8	Orta kurak	10-2011	1-2012	4	Az kurak
4-1983	4-1983	1	Az kurak	6-2012	1-2013	8	Aşırı kurak
8-1983	1-1984	6	Orta kurak	6-2013	12-2013	7	Şiddetli kurak
7-1984	2-1985	8	Aşırı kurak	7-2014	9-2014	3	Az kurak
9-1985	9-1985	1	Az kurak	8-2015	11-2016	16	Aşırı kurak
11-1985	12-1985	2	Az kurak	9-2017	12-2017	4	Az kurak
4-1986	4-1986	1	Az kurak	9-2018	9-2018	1	Az kurak
7-1986	12-1986	6	Az kurak	8-2019	11-2019	4	Az kurak
8-1987	11-1987	4	Şiddetli kurak	6-2020	12-2020	7	Aşırı kurak

Zaman bazında SYİ6 değerlerinin değişimi Şekil 4.4’de gösterilmiştir. 11-1956, 10-1984 ve 9-2021 yıllarında indis değerlerinin kuraklık kategorisinde zirve yaptığı, bu senelerin ortak noktalarının genellikle sonbahar olduğu dikkat çekmektedir. Sulak

değerlerde ise, zirve noktalarına 3-1969, 4-1969, 5-1957 tarihlerinde ulaşıldığı Şekil 4.4’de açıkça görülmektedir. Zaman serisinin başlangıç tarihlerinde kurak dönemlerin olduğu Şekil 4.4’de görülmektedir.



Şekil 4.4. SYİ6 indis değerlerinin zaman serisi

Bir başka zaman adımı olarak, 9 aylık ardışık yağış verisinin toplamı ile elde edilen SYİ9’a ait kurak tespit edilen zamanlar, kategorilerine göre Çizelge 4.5’de belirtilmiştir. Çizelge 4.5 incelendiği zaman, 65 kuraklık ve bu bunların 394 aylık bir süre tespit edilmiştir. Daha da detaylandırılırsa, 7 aşırı kurak, 6 şiddetli kurak, 11 orta kurak, 41 az kurak farklı zaman dilimlerinde belirlenmiştir.


Çizelge 4.5. SYİ9 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
9-1955	4-1958	32	Aşırı kurak	7-1989	1-1990	7	Şiddetli kurak
7-1958	3-1960	21	Orta kurak	7-1990	3-1991	9	Orta kurak
7-1960	1-1963	31	Aşırı kurak	9-1991	4-1992	8	Orta kurak
1-1964	5-1964	5	Orta kurak	9-1992	11-1992	3	Az kurak
7-1964	2-1966	20	Şiddetli kurak	2-1993	4-1993	3	Orta kurak
9-1966	9-1966	8	Aşırı kurak	8-1993	4-1994	9	Orta kurak
9-1967	10-1967	2	Az kurak	8-1994	10-1994	3	Az kurak
12-1967	12-1967	1	Az kurak	1-1995	2-1995	2	Az kurak
2-1968	2-1968	1	Az kurak	9-1995	10-1995	2	Az kurak
8-1968	8-1968	1	Az kurak	12-1995	2-1996	3	Az kurak
10-1968	11-1968	2	Az kurak	8-1996	9-1996	2	Az kurak
2-1970	5-1970	4	Az kurak	1-1997	1-1997	1	Az kurak
7-1970	1-1971	7	Orta kurak	9-1997	11-1997	3	Az kurak
1-1972	1-1972	1	Az kurak	9-1998	9-1998	1	Az kurak

Çizelge 4.5 (devam). SYİ9 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
11-1972	11-1974	25	Aşırı kurak	3-1999	3-1999	1	Az kurak
1-1978	3-1978	3	Az kurak	7-1999	4-2000	10	Aşırı kurak
9-1978	3-1979	7	Az kurak	1-2001	4-2001	4	Aşırı kurak
9-1979	10-1979	2	Az kurak	7-2001	10-2001	4	Az kurak
9-1980	9-1980	1	Az kurak	1-2004	3-2004	3	Az kurak
12-1980	12-1980	1	Az kurak	9-2004	3-2006	19	Şiddetli kurak
2-1981	2-1981	1	Az kurak	7-2006	12-2007	18	Orta kurak
10-1981	3-1982	6	Az kurak	8-2008	12-2008	5	Az kurak
9-1982	5-1983	9	Orta kurak	10-2009	11-2009	2	Az kurak
7-1983	3-1984	9	Az kurak	9-2010	9-2010	1	Az kurak
8-1984	3-1985	8	Şiddetli kurak	11-2010	11-2010	1	Az kurak
2-1986	4-1986	3	Az kurak	2-2012	3-2013	14	Aşırı kurak
8-1986	11-1986	4	Orta kurak	8-2013	4-2014	9	Orta kurak
2-1987	2-1987	1	Az kurak	8-2014	8-2014	1	Az kurak
9-1987	10-1987	2	Az kurak	10-2014	10-2014	1	Az kurak
1-1988	2-1988	2	Az kurak	9-2015	11-2016	15	Şiddetli kurak
9-1988	9-1988	1	Az kurak	2-2018	2-2018	1	Az kurak
2-1989	2-1989	1	Az kurak	9-2019	11-2019	3	Az kurak
				9-2020	12-2020	4	Şiddetli kurak

Şekil 4.5’de SYİ9’a ait indis değerlerinin zaman içerisindeki değişimi verilmiştir. 5-1969 ve 5-1977 tarihlerinde sulak zamanlarda indis zamanları zirve yaparken, kurak kategorisinde zirve yapan zamanlar 11-1956, 1-1957 ve 12-1999 olarak bulunmuştur.



Şekil 4.5. SYİ9 indis değerlerinin zaman serisi


SYİ6 olduğu gibi, SYİ9'un da zaman serisinin ilk başlarında genellikle indis değerlerinin negatif, yani kurak dönemlerin olduğu dikkat çekmektedir. 2-1975 ile 6-1978 tarih aralığında ise uzun sulak dönemlerin varlığı dikkat çeken diğer bulgular arasındadır.

400 aylık kurak sürenin bulunduğu SYİ12'de, 2'si aşırı kurak, 3'ü şiddetli kurak, 5'i orta kurak, 25'i az kurak kategorisinde olmak üzere toplam 35 kuraklık tespit edilmiştir. Kuraklıkların kategorilerine göre hangi tarih aralığında tespit edildiği Çizelge 4.6'da verilmiştir.

Çizelge 4.6. SYİ12 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
12-1955	3-1963	88	Aşırı kurak	1-1992	5-1992	5	Az kurak
4-1964	9-1967	42	Orta kurak	12-1992	4-1993	5	Az kurak
12-1967	12-1967	1	Az kurak	6-1993	3-1994	10	Az kurak
5-1968	8-1968	4	Az kurak	5-1994	10-1994	6	Az kurak
4-1970	2-1971	11	Az kurak	1-1996	2-1996	2	Az kurak
12-1972	11-1974	24	Şiddetli kurak	11-1996	11-1996	1	Az kurak
4-1978	9-1978	6	Az kurak	4-1997	5-1997	2	Az kurak
12-1978	5-1979	6	Az kurak	2-1998	2-1998	1	Az kurak
10-1979	10-1979	1	Az kurak	5-1999	4-2000	12	Şiddetli kurak
12-1980	12-1980	1	Az kurak	2-2001	10-2001	9	Orta kurak
2-1982	3-1982	2	Az kurak	4-2004	10-2004	7	Az kurak
5-1982	9-1982	5	Az kurak	12-2004	11-2007	36	Şiddetli kurak
11-1982	4-1985	30	Orta kurak	2-2008	2-2008	1	Az kurak
4-1986	4-1986	1	Az kurak	6-2008	8-2008	3	Az kurak
10-1986	11-1986	2	Az kurak	11-2008	12-2008	2	Az kurak
5-1989	3-1991	23	Az kurak	4-2012	9-2014	30	Orta kurak
9-1991	11-1991	3	Az kurak	11-2015	2-2017	16	Aşırı kurak
				11-2020	12-2020	2	Orta kurak

Detaylarının Çizelge 4.6'da verildiği SYİ12 ait indis değerlerinin, zaman serisine göre dağılımı Şekil 4.6'da belirtilmiştir. Şekil 4.6 incelendiğinde, bundan önceki zaman adımlarında olduğu gibi, SYİ12'de de zaman serisinin başlangıcında ki kurak dönemler dikkat çekmektedir. Ayrıca, kurak dönemlere ait zirve noktası, başlangıç noktasına yakın olarak 2-1957 tarihindedir. Sulak dönemlerde zirve noktalarından birisi 7-1969'da oluşmuştur.




Şekil 4.6. SYİ12 indis değerlerinin zaman serisi

24 aylık yağış toplamaları ile hesaplanan SYİ24 ile tespit edilen kuraklıklara ait tarih ve kategori bilgisi Çizelge 4.7’de gösterilmiştir. 2 aşırı kurak, 1 şiddetli kurak, 7 orta kurak, 12 az kurak olmak üzere toplamda 22 kuraklığın tespit edildiği SYİ24 ile yapılan analizde, toplam kuraklık süresi 365 aydır.

Çizelge 4.7. SYİ24 ile elde edilen indis sonuçları

Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı	Başlangıç	Bitiş	Süre (ay)	Kuraklık Sınıfı
12-1956	4-1963	77	Aşırı kurak	3-1986	4-1986	2	Az kurak
12-1963	2-1964	3	Az kurak	4-1990	5-1992	26	Orta kurak
4-1964	5-1964	2	Az kurak	1-1993	2-1995	26	Orta kurak
10-1964	10-1964	1	Az kurak	5-1995	9-1995	5	Az kurak
1-1965	9-1968	45	Şiddetli kurak	9-1999	4-2000	8	Az kurak
4-1973	4-1975	25	Aşırı kurak	10-2000	10-2001	13	Orta kurak
4-1979	9-1979	6	Az kurak	2-2005	12-2008	47	Orta kurak
3-1980	3-1980	1	Az kurak	1-2013	9-2014	21	Orta kurak
11-1982	11-1982	1	Az kurak	1-2016	4-2017	16	Orta kurak
1-1983	9-1985	33	Orta kurak	6-2017	10-2017	5	Az kurak
1-1986	1-1986	1	Az kurak	12-2020	12-2020	1	Az kurak

SYİ24 ile tespit edilen indis değerlerinin zaman serisi Şekil 4.7’de gösterilmiştir. İndis değerlerine göre; Şekil 4.7’de zaman değerlerinin başlangıç noktasında kurak dönemlerin hakim olduğu, son dönemlerde ise sulak dönemlerin hakim olduğu açıkça gözükmemektedir. 4-1977 tarihinde ise sulak dönemlerde indis değerinin zirve yaptığı, 12-1956 tarihinde ise kurak dönemlerde indis değerinin zirve yaptığı belirlenmiştir.




Şekil 4.7. SYİ24 indis değerlerinin zaman serisi

4.2. Kuraklık Tahmin Modelleri

Çalışmanın bu kısmında, kuraklık tahmin modelleri kurulmuş ve bu modellerin farklı makine öğrenme algoritmaları ile analizleri gerçekleştirilmiştir. SYİ ile hesaplanmış olan indis değerleri, model girdilerinden bir kısmını ve modeldeki hedef parametreyi oluşturmuştur. Matlab programından yararlanılarak hedef indis değerlerini tahmin etmek için ortalama 500 farklı model kurulmuştur. Literatürde yaygın olarak, oluşturulan modeller için tüm verinin %70 ile %80'nin öğrenme amaçlı kullanıldığı ve kalanının ise test için kullanıldığı belirlenmiştir. Dolayısıyla öncelikle verinin ne kadarı test ne kadarı öğrenme amacıyla olduğunun kararı verilmiştir. Bunun içinde, analizlerin hepsi %80 öğrenme oranıyla başlamış, sonrasında aynı modeller %70 öğrenme oranı ile devam etmiştir. Elde edilen sonuçlarda %70 öğrenme oranının model performans değerlerine olumlu olarak yansıdığı tespit edilmiş olup, sonraki kısımlarda %70 öğrenme oranından devam edilmiştir.

Model girdi verisi oluşturulurken model çıkış parametresine göre, model sonucuna en iyi etki edecek olan girdi verisi çapraz korelasyon yardımıyla belirlenmiştir (Şekil 4.8). Şekil 4.8'de çıkış verisine etki yani hedef parametreye etki eden geciktirilmiş ay sayısına sahip veri ilişkin bilgiler verilmiştir.



Şekil 4.8. Kuraklık modelleri çapraz korelasyon örnekleri a) SYİ, b) Yağış

Elde edilen sonuçlar doğrultusunda, model girdi verisi olarak Çizelge 4.8’deki veri, her modelde ifade edildiği şekilde kullanılmıştır. Çoklu zaman aralıklarında oluşturulan SYİ24, SYİ12, SYİ9, SYİ6 ve SYİ3 kuraklık indislerinin her biri için 12 adet model oluşturulmuş ve bunlar model numaraları ile birlikte Çizelge 4.8’de verilmiştir. Örneğin: M01-M12 arası modeller SYİ24’e ait modelleri, M13-M24 arası modeller SYİ12’ye ait modelleri vb. temsil etmektedir.

Çizelge 4.8. Kuraklık tahmininde oluşturulan modeller

Model		Girdiler						Çıktı
SYİ24								
M01	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)				SYİ24 _(t)
M02	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)			SYİ24 _(t)
M03	SYİ24 _(t-6)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M04	OY _(t-1)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M05	OS _(t)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M06	OY _(t)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M07	MIS _(t)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M08	MAS _(t)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t)
M09	SYİ24 _(t-6)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t+1)
M10	OY _(t-1)	SYİ24 _(t-6)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)	SYİ24 _(t+1)
M11	SYİ24 _(t-6)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)		SYİ24 _(t+2)
M12	SYİ24 _(t-7)	SYİ24 _(t-6)	SYİ24 _(t-5)	SYİ24 _(t-4)	SYİ24 _(t-3)	SYİ24 _(t-2)	SYİ24 _(t-1)	SYİ24 _(t+2)
SYİ12								
M13	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)				SYİ12 _(t)
M14	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)			SYİ12 _(t)
M15	SYİ12 _(t-6)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)
M16	OY _(t-1)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)
M17	OS _(t)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)
M18	OY _(t)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)
M19	MIS _(t)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)
M20	MAS _(t)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t)

Çizelge 4.8 (devam). Kuraklık tahmininde oluşturulan modeller

Model	Girdiler							Çıktı
SYİ12								
M21	SYİ12 _(t-6)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t+1)
M22	OY _(t-1)	SYİ12 _(t-6)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)	SYİ12 _(t+1)
M23	SYİ12 _(t-6)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)		SYİ12 _(t+2)
M24	SYİ12 _(t-7)	SYİ12 _(t-6)	SYİ12 _(t-5)	SYİ12 _(t-4)	SYİ12 _(t-3)	SYİ12 _(t-2)	SYİ12 _(t-1)	SYİ12 _(t+2)
SYİ9								
M25	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)				SYİ9 _(t)
M26	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)			SYİ9 _(t)
M27	SYİ9 _(t-6)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M28	OY _(t-1)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M29	OS _(t)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M30	OY _(t)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M31	MIS _(t)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M32	MAS _(t)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t)
M33	SYİ9 _(t-6)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t+1)
M34	OY _(t-1)	SYİ9 _(t-6)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)	SYİ9 _(t+1)
M35	SYİ9 _(t-6)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)		SYİ9 _(t+2)
M36	SYİ9 _(t-7)	SYİ9 _(t-6)	SYİ9 _(t-5)	SYİ9 _(t-4)	SYİ9 _(t-3)	SYİ9 _(t-2)	SYİ9 _(t-1)	SYİ9 _(t+2)
SYİ6								
M37	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)				SYİ6 _(t)
M38	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)			SYİ6 _(t)
M39	SYİ6 _(t-6)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M40	OY _(t-1)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M41	OS _(t)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M42	OY _(t)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M43	MIS _(t)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M44	MAS _(t)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t)
M45	SYİ6 _(t-6)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t+1)
M46	OY _(t-1)	SYİ6 _(t-6)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)	SYİ6 _(t+1)
M47	SYİ6 _(t-6)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)		SYİ6 _(t+2)
M48	SYİ6 _(t-7)	SYİ6 _(t-6)	SYİ6 _(t-5)	SYİ6 _(t-4)	SYİ6 _(t-3)	SYİ6 _(t-2)	SYİ6 _(t-1)	SYİ6 _(t+2)
SYİ3								
M49	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)				SYİ3 _(t)
M50	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)			SYİ3 _(t)
M51	SYİ3 _(t-6)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M52	OY _(t-1)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M53	OS _(t)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M54	OY _(t)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M55	MIS _(t)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M56	MAS _(t)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t)
M57	SYİ3 _(t-6)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t+1)
M58	OY _(t-1)	SYİ3 _(t-6)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)	SYİ3 _(t+1)
M59	SYİ3 _(t-6)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)		SYİ3 _(t+2)
M60	SYİ3 _(t-7)	SYİ3 _(t-6)	SYİ3 _(t-5)	SYİ3 _(t-4)	SYİ3 _(t-3)	SYİ3 _(t-2)	SYİ3 _(t-1)	SYİ3 _(t+2)
OS	; Ortalama sıcaklık;							
OY	; Ortalama yağış							
MIS	; Minimum sıcaklık							
MAS	; Maksimum sıcaklık							

Model girdi verisi belirlendikten sonra, tüm modeller makine öğrenme algoritmaları ile analiz edilmiştir. İlerleyen kısımlarda, öğrenme algoritmalarına göre model performansları incelenmiştir.

Model sonuçları yorumları okunmadan önce, hem daha fazla modelle kıyaslama hem de model çeşitliliğin artırılması amacıyla bazı modellerin girdi yapısında t zamanına ait meteorolojik veri, yani sıcaklık ve yağış verisi kullanıldığı hususu hatırlanmalıdır. Mantıksal çerçevede bu girdi yapısıyla oluşturulan modeller, girdi yapısında t zamanına ait veri içermeyen modellere göre daha iyi performans göstermektedir. Ancak, bu çalışmanın tamamında başarılı modellerden bahsedilirken girdi yapısında t zamanına ait veri içermeyenler kastedildiği unutulmamalıdır.

4.2.1. DVM ile analiz sonuçları

DVM ile sınıflandırma ya da regresyon analizi yapılırken literatürde veriye bağlı olarak en fazla kullanılan fonksiyonlardan birisi kernel lineer fonksiyonudur. Bu çalışmada da kernel lineer fonksiyonu tercih edilmiş ve elde edilen bulgular Çizelge 4.9'da model isimlerine göre belirtilmiştir. Dalgacık dönüşümü uygulanarak elde edilen bulgular her bir bölüm içerisinde farklı şekil ve çizelgelerde gösterilmiştir. Algoritma parametreleri ($\mathcal{E}$, a , β , B gibi), model sonucuna en iyi etkiyi gösterecek şekilde otomatik olarak optimize edilmiştir.

Çizelge 4.9. DVM ile yapılan analiz sonuçları


Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.9267	0.2439	0.9628	M37	0.7620	0.4821	0.8748
M02	0.9328	0.2340	0.9659	M38	0.7646	0.4805	0.8760
M03	0.9303	0.2388	0.9647	M39	0.7384	0.4921	0.8615
M04	0.9299	0.2394	0.9646	M40	0.7492	0.4829	0.8682
M05	0.9328	0.2341	0.9659	M41	0.8021	0.4405	0.8991
M06	0.9550	0.1915	0.9778	M42	0.8969	0.3179	0.9476
M07	0.9301	0.2392	0.9646	M43	0.7677	0.4647	0.8824
M08	0.9303	0.2387	0.9647	M44	0.7818	0.4504	0.8911
M09	0.8592	0.3395	0.9282	M45	0.5265	0.6629	0.7399
M10	0.8593	0.3394	0.9283	M46	0.5561	0.6418	0.7524
M11	0.7972	0.4072	0.8944	M47	0.3459	0.7820	0.6115
M12	0.7981	0.4063	0.8948	M48	0.4457	0.7270	0.6772
SYİ12				SYİ3			
M13	0.8626	0.3679	0.9293	M49	0.5839	0.6207	0.7687
M14	0.8642	0.3657	0.9300	M50	0.5967	0.6107	0.7793
M15	0.8693	0.3609	0.9330	M51	0.5978	0.6042	0.7812
M16	0.8694	0.3610	0.9329	M52	0.6255	0.5831	0.7951

Çizelge 4.9 (devam). DVM ile yapılan analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ12				SYİ3			
M17	0.8645	0.3653	0.9301	M53	0.6739	0.5491	0.8269
M18	0.9122	0.2940	0.9561	M54	0.8409	0.3836	0.9173
M19	0.8690	0.3615	0.9328	M55	0.6273	0.5817	0.7968
M20	0.8703	0.3598	0.9333	M56	0.6551	0.5596	0.8155
M21	0.7381	0.5103	0.8627	M57	0.3077	0.7966	0.5678
M22	0.7391	0.5093	0.8629	M58	0.4144	0.7326	0.6575
M23	0.6355	0.6000	0.8017	M59	0.1284	0.8954	0.3886
M24	0.6374	0.5970	0.8029	M60	0.1398	0.8937	0.3964
SYİ9							
M25	0.8040	0.4355	0.8967				
M26	0.8043	0.4359	0.8969				
M27	0.7945	0.4378	0.8921				
M28	0.7988	0.4384	0.8941				
M29	0.8167	0.4219	0.9038				
M30	0.9046	0.3043	0.9524				
M31	0.8026	0.4342	0.8972				
M32	0.8015	0.4354	0.8958				
M33	0.5304	0.6573	0.7343				
M34	0.5511	0.6426	0.7502				
M35	0.3063	0.8009	0.5676				
M36	0.2988	0.8112	0.5542				

Tüm modellerin analizi neticesinde elde edilen sonuçlara ait özet bilgiler Şekil 4.9’da gösterilmiştir. Şekil 4.9 incelendiği zaman, modellere ait NS değerlerinin 0.11 ile 0.99 arasında, r değerlerinin de 0.33 ile 0.99 arasında değiştiği görülmektedir. Ayrıca, tüm modellere ait sonuçlar kuraklık hesaplamalarındaki zaman (SYİ3, SYİ6, SYİ9, SYİ12, SYİ24) adımlarına göre yorumlanmıştır. Yorumlanırken, bir modelin diğerlerine göre başarılı olabilmesi için de önce NS değeri, sonra r değeri, daha sonrasında ise RMSE değeri göz önünde bulundurulmuştur. Çizelge 4.9 incelendiği zaman, yukarıda da belirtildiği gibi SYİ24 ve diğer hidrolojik/meteorolojik veri ile oluşturulan modellerde, yani M01-M12 arasında, performans değerlendirme parametrelerine göre, en iyi değerler sırasıyla M06 (NS: 0.9550, RMSE: 0.1915, r: 0.9778), M02 (NS: 0.9328, RMSE: 0.2340, r: 0.9659) ve M05 (NS: 0.9328, RMSE: 0.2341, r: 0.9659) olarak tespit edilmiştir. Bu modelleri, 6 aya kadar geciktirilmiş SYİ24 indis değerlerinden oluşan M03 ve 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık maksimum sıcaklık değerlerinden oluşan M08 takip etmektedir. M06’nın girdi yapısına bakıldığında, SYİ24’ün 5 aya kadar geciktirilmiş indis değerleri ve t zamanına ait aylık toplam yağış verisinden oluştuğu dikkat çekmektedir. M05’de ise M06’nın girdi verisinin kısmi olarak aynısı olduğu, sadece aylık toplam yağış yerine aylık ortalama

sıcaklık verisinin farklı olduğu Çizelge 4.8’de gösterilmiştir. M02’nin girdi verisi ise SYİ24’ün 5 aya kadar geciktirilmiş indis değerlerinden oluşturulmuştur. M02’nin girdi yapısında t zamanına ait veri bulunmaması en dikkat çekici sonuçlar arasındadır. Bu sonuç göz önünde bulundurulduğunda, M02 mantıksal olarak en başarılı modellerdendir. M05 ve M06’nın girdi verisi incelendiğinde, tahmin ayına ilişkin veriyi model girdisine eklemenin avantaj sağladığı bulunan diğer sonuçlar arasındadır. M07 ile M08’in girdi yapısı, t zamanına ait sırasıyla minimum ve maksimum aylık sıcaklık verisinin yanı sıra, 5 aya kadar geciktirilmiş SYİ24 indis verisinden oluşturulmuştur.




Şekil 4.9. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları

Tespit edilen başka bir bulgu ise, t zamanına ait veriyi içeren M05, M06, M07 ve M08 modellerinde bir kıyaslama yapıldığında, M05 ve M06’in daha iyi sonuç verdiği, aylık toplam yağış ve aylık ortalama sıcaklık verisinin, aylık maksimum ve minimum sıcaklık verisine göre daha iyi performans sergilediğidir. T-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ24 verisini girdi yapısında içeren M04 ise,

NS: 0.9299, RMSE: 0.2394, r : 0.9646 değerleri ile başarılı modeller arasındadır. M10 ve M09 modellerinin çıktı zamanı $t+1$ 'dir. Bu modellerde sırasıyla NS: 0.8593, RMSE: 0.3394, r : 0.9283 ve NS: 0.8592, RMSE: 0.3395, r : 0.9282 performans değerleri hesaplanmıştır. Girdi yapısı incelendiğinde, M10 6 aya kadar geciktirilmiş SYİ24 indisinden ve $t-1$ zamanına ait aylık toplam yağış verisinden, M09 sadece 6 aya kadar geciktirilmiş SYİ24 indisinden oluşturulmuştur. Bu iki model sonucunun birbirlerine oldukça yakın olduğu tespit edilen bulgular arasındadır.

Şekil 4.10'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M02 ve M03) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.10'da gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.10. SYİ24 verisi için DVM'de en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ12 kullanılarak oluşturulan modellere (M13-M24 arası) bakıldığında; M18 (NS: 0.9122, RMSE: 0.2940, r : 0.9561), M20 (NS: 0.8703, RMSE: 0.3598, r : 0.9333), M16 (NS: 0.8694, RMSE: 0.3610, r : 0.9329) ve M15 (NS: 0.8693, RMSE: 0.3609, r : 0.9330) modellerinin diğer modellere göre daha iyi sonuç verdiği belirlenmiştir. M18 haricindeki, diğer üç model sonuçları birbirlerine oldukça yakındır. M18'in diğerlerine göre daha iyi sonuç değerleri vermesinin sebebi model girdi yapısından

kaynaklanmaktadır. Model girdi yapısında t zamanına ait aylık toplam yağış verisi model sonucunu olumlu yönde etkilemektedir. Başarılı modellerin bir diğeri ise, t zamanına ait aylık maksimum sıcaklık ve 5 aya kadar geciktirilmiş SYİ12 verisiyle girdi yapısı oluşturulmuş olan M20'dir. Burada da t zamanına ait veri kullanıldığından ötürü, model performans değerleri iyi yönde çıkmıştır. Girdi yapılarında t zamanına ait veri kullanılan bu iki modelden ziyade, $t-1$ zamanına ait aylık toplam yağış verisi ve 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuş M16 (NS: 0.8694, RMSE: 0.3610, r : 0.9329) en başarılı modellerden birisi olarak belirlenmiştir.

6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuş M15 de başarılı modeller arasındadır. M21'in bu modelden farkı çıktı verisinin zamanı $t+1$ olmasıdır. NS: 0.7381, RMSE: 0.5103, r : 0.8627 değerleri M21'de tespit edilmiştir. M22 ise bu modelin girdi yapısına çok benzer biçimde oluşturulmuştur. Farklı olarak $t-1$ zamanına ait aylık toplam yağış verisi model girdisinde fazladan kullanılmıştır. NS: 0.7391, RMSE: 0.5093, r : 0.3810 değerleri ile M22, M21'e göre daha iyi performans sergilemiştir. Bu kategoride, t zamanına ait aylık minimum sıcaklık verisi ile oluşturulan M19 (NS: 0.8690 RMSE: 0.3615, r : 0.9328) ve t zamanına ait aylık maksimum sıcaklık verisi ile oluşturulan M20 kıyaslandığında, minimum sıcaklık verisinin maksimuma göre daha etkili sonuç vermiştir. NS: 0.8645, RMSE: 0.3653, r : 0.9301 değerler ile t zamanına ait aylık ortalama sıcaklık verisi ve 5 aya kadar geciktirilmiş SYİ12 verisi ile oluşturulan M17'de performans olarak diğer modellerin ardından gelmektedir. M13 ve M14, SYİ12'nin sırasıyla 4 ve 5 aya kadar geciktirilmiş verisi ile oluşturulmuş olup, yine sırasıyla; NS: 0.8626, MSE: 0.3679, r : 0.9293 ve NS: 0.8642, RMSE: 0.3657, r : 0.9300 performans değerleri analizleri neticesinde bulunmuştur. Bu modeller ile diğer başarılı modellerin sonuçları birbirlerine oldukça yakındır. M23 ve M24 ise $t+2$ zamanına ait tahminlemeleri ile sırasıyla NS: 0.6355, RMSE: 0.6000, r : 0.8017 ve NS: 0.6374, RMSE: 0.597, r : 0.8029 değerleri tespit edilmiştir.

Şekil 4.11'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.11'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.11. SYİ12 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

Model girdi verisinde SYİ9 ve diğer verinin kullanıldığı modellerin sonuçları incelendiğinde, M30’un NS: 0.9046, RMSE: 0.3043 r: 0.9524’lük, M29’un NS: 0.8167, RMSE: 0.4219, r: 0.9038’lik, M26’nın NS: 0.8043, RMSE: 0.4359, r: 0.8969’luk ve M25’in NS: 0.8040, RMSE: 0.4355, r: 0.8967’lik değerle diğer modellere göre daha iyi performans sergilediği belirlenmiştir. Başka tespit edilen sonuçlardan bir tanesi de, SYİ’nin zaman adımının büyüdükçe performans değerlerinde düşüş olduğudur. Bunun da nedeni zaman adımlarında bağlı olarak değişen varyanstır. Diğer zaman adımlarında olduğu gibi t zamanına ait verinin girdi verisi olarak kullanılmasından dolayı, M29 ve M30 etkili performans sergilemiştir. Peşi sıra başarılı model olarak tespit edilen M26 ve M25’in girdi yapısı ise, sırasıyla, 5 aya kadar geciktirilmiş SYİ9 ve 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulan M27 ise NS: 0.7945, RMSE: 0.4378, r: 0.3465 değerler ile M26 ve M25’in performans olarak gerisinde kalmıştır. M27’nin girdi verisi ile aynı olan, tahmin ayı t+1 zamanına ait olan M33’de ise; NS: 0.5304, RMSE: 0.6573, r: 0.5193 performans değerleri analiz neticesinde hesaplanmıştır. M26, M25 ve M27’nin performans değerleri kıyaslandığında ise, SYİ9 verisini girdi olarak 5 aya kadar geciktirmenin model sonucuna olumlu olarak yansıdığı, 5 aydan fazla ya da az olarak geciktirmenin model sonucuna olumsuz olarak yansıdığı bulunan sonuçlar arasındadır. T zamanına ait aylık minimum ve maksimum sıcaklık verisini girdi verisi olarak kullanan M31 ve M32’nin

analiz neticesinde, sırasıyla, NS: 0.8026, RMSE: 0.4342, r: 0.8972 ve NS: 0.8015, RMSE: 0.4354, r: 0.8958 değerleri tespit edilmiş olup, M30 ve M29'un gerisinde kaldığı, bu sebeple, maksimum ve minimum aylık sıcaklık değerlerini modellerde kullanmanın, aylık toplam yağış ve aylık ortalama sıcaklık verisine göre daha dezavantajlı olduğu bulunmuştur. M28'de ise girdi verisi olarak t-1 zamanına ait aylık toplam yağış verisi ve SYİ9'un 5 aya kadar geciktirilmiş değerleri kullanılmış, analiz neticesinde, NS: 0.7988 RMSE: 0.4384 r: 0.8941 değerleri hesaplanmıştır. M28 gibi, M34 de diğer modellerin performans olarak gerisinde kalmıştır (NS: 0.5511, RMSE: 0.6426, r: 0.7502). SYİ9'un 6 ve 7 aya kadar geciktirilmiş değerlerinin model girdisinde kullanıldığı, sırasıyla, M35 ve M36'nın çıktı zamanı t+2'dir. Bu sebepten ötürü, sırasıyla, NS: 0.3063, RMSE: 0.8009, r: 0.5676 ve NS: 0.2988, RMSE: 0.8112, r: 0.5542 değerleri ile diğer modellere göre performansı düşüktür.

Şekil 4.12'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M26 ve M25) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.12'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

SYİ6 ile oluşturulan modellere bakıldığında zaman (M37-M48 arası); M42, M41, M44 ve M43'ün diğer modellere göre daha iyi performans sergilediği belirlenmiştir. M42 (NS: 0.8969, RMSE: 0.3179, r: 0.9476) ve M41 (NS: 0.8021, RMSE: 0.4405, r: 0.8991) diğer zaman adımlarında olduğu gibi, SYİ6'da da, girdi verisindeki t zamanına ait sırasıyla, aylık toplam yağış verisi ve aylık ortalama sıcaklık verisi içermesinden dolayı diğer modellerin performans olarak önündedir. Peşi sıra gelen modeller ise M44 ve M43'tür. Bu modellerin performans değerleri, sırasıyla, NS: 0.7818, RMSE: 0.4504, r: 0.8911 ve NS: 0.7677, RMSE: 0.4647, r: 0.8824'dür. M44 ve M43'ün girdi yapısı, t zamanına ait sırasıyla aylık maksimum sıcaklık, minimum sıcaklık verisinden ve her iki modelde de 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Bu modellerde de t zamanına ait meteorolojik veri bulunduğundan ötürü, SYİ6'nın başarılı modellerindendir. Bahsedilen bu modellerden sonra, performans açısından girdi verisinde sırasıyla 5 ve 4 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuş M38 (NS: 0.7646, RMSE: 0.4805, r: 0.8760) ve M37 (NS: 0.7620, RMSE: 0.4821, r: 0.8748) gelmektedir.




Şekil 4.12. SYİ9 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

M39 modelinin girdi verisinde, SYİ6’nın 6 aya kadar geciktirilmiş verisi kullanılmıştır. Ama bu modelin, performans değerleri NS: 0.7384, RMSE: 0.4921, r: 0.8615 şeklinde hesaplanmıştır. Dolayısıyla, sadece SYİ6 verisiyle oluşturulan model yapısında 6 aya kadar geciktirme verisinin kullanılması model performansını olumsuz yönde etkileyeceği belirlenmiştir. SYİ6 verisinin 5 aydan fazla ve az geciktirilmesiyle oluşturulan modellerin, performans değerlerinin 5 ay ile oluşturulan model göre düşük olduğu belirlenmiştir. M45’de ise M39’dan farklı olarak t+1 zamanı çıktı olarak oluşturulmuş ve NS: 0.5265, RMSE: 0.6629, r: 0.7399 performans değerleri hesaplanmıştır. M40’ın girdi yapısı 5 aya kadar geciktirilmiş SYİ6 ve t-1 zamanına ait aylık toplam yağış verisinden, M46’nın girdi yapısı 6 aya kadar geciktirilmiş SYİ6 verisinden ve t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M46’nın çıktısı verisi t+1 ve M40’ın çıktı verisi t zamanına ait olup, performans değerleri sırasıyla, NS: 0.5561, RMSE: 0.6418, r: 0.7524 ve NS: 0.7492, RMSE: 0.4829, r: 0.8682 şeklinde bulunmuştur. Çıktı verisi farklı olarak t+2 zamanından oluşan M47 ve M48’in, yine sırasıyla NS: 0.3459, RMSE: 0.7820, r: 0.6115 ve NS: 0.4454, RMSE: 0.727, r: 0.6772 değerleri ile SYİ6 kategorisinin en düşük performans değerleri tespit edilmiştir.

Şekil 4.13’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M38 ve M37) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.13’de gösterilmiştir.




Şekil 4.13. SYİ6 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ3 verisinden faydalanılarak oluşturulan modellere bakıldığı zaman (M49-M60 arası), diğer zaman adımlarında da olduğu gibi t zamanına ait aylık toplam yağış ve aylık ortalama sıcaklık verisini girdi yapısında bulunduran modeller sırasıyla M54’ün (NS: 0.8409, RMSE: 0.3836, r: 0.9173) ve M53’ün (NS: 0.6739, RMSE: 0.5491, r: 0.8269) diğer modellere göre daha başarılı olduğu tespit edilmiştir. Ayrıca, t zamanına ait aylık toplam yağış verisinin, aylık ortalama sıcaklık verisinden daha etkili sonuçlarda verdiği tespit edilen diğer bulgulardandır. T zamanına ait aylık maksimum ve minimum sıcaklıkları girdi verisi olarak kullanan, sırasıyla M56 (NS: 0.6551, RMSE: 0.5596, r: 0.8155) ve M55 de (NS: 0.6273, RMSE: 0.5817, r: 0.7968) başarılı modeller arasındandır. Başarılı olarak sayılabilecek olan bu modellerin girdi yapısında t zamanına ait veri bulunmaktadır. Bu modellerin haricinde, diğer başarılı sayılabilecek olan bir diğer model ise M52’dir (NS: 0.6255, RMSE: 0.5831, r: 0.7951).

Şekil 4.14’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M52 ve M51) zaman serisi ve gözlem değerlerine göre saçılma diyagramı


verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.14’de gösterilmiştir.



Şekil 4.14. SYİ3 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

Girdi yapısında SYİ3’ün 5 aya kadar geciktirilmiş verisi ve t-1 zamanına ait aylık toplam yağış verisi bulunmaktadır. SYİ3’de diğer modeller ile kıyaslandığında, girdi verisi olarak 6 aya kadar geciktirilmiş SYİ3 verisi kullanmanın daha etkili olabileceği M51 (NS: 0.5978, RMSE: 0.6042, r: 0.7812) ile tespit edilmiştir. M50 ve M49 bu modeli performans olarak takip eden diğer modellerdendir. Performans değerleri sırasıyla, NS: 0.5967, RMSE: 0.6107, r: 0.77793 ve NS: 0.5839, RMSE: 0.6207, r: 0.7687’dir. Bu iki modelin girdi yapısı sadece (sırasıyla) 5 ve 4 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Dolayısıyla, SYİ3 verisinde geciktirilmiş ay sayısının 6 olması, model sonucuna olumlu yönde etki etmiştir.

Şekil 4.15’de DVM ile yapılan analiz sonuçlarının iyileştirilmesi için dalgacık dönüşümünden faydalanarak elde edilen sonuçların özeti gösterilmiştir. Model sonuçlarına bakıldığında hemen hemen tüm modellerde son derece önemli iyileştirmeler yapıldığı Çizelge 4.10’da açıkça görülmektedir.



Şekil 4.15. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları

Varyansa bağlı olarak, zaman adımlarının azalması ile beraber model sonuçlarının da daha düşük performansta olduğu önceki kısımda dile getirilmiştir. Bu durum, dalgacık dönüşümünden sonra da aynı şekilde devam etmiştir.

Çizelge 4.10. Dalgacık dönüşümü ile DVM analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.9942	0.0684	0.9971	M37	0.9812	0.1355	0.9907
M02	0.9908	0.0867	0.9955	M38	0.9832	0.1282	0.9917
M03	0.9970	0.0498	0.9986	M39	0.9861	0.1136	0.9931
M04	0.9947	0.0659	0.9974	M40	0.9861	0.1138	0.9931
M05	0.9889	0.0951	0.9951	M41	0.9832	0.1284	0.9917
M06	0.9930	0.0756	0.9965	M42	0.9849	0.1217	0.9925
M07	0.9949	0.0648	0.9976	M43	0.9833	0.1246	0.9917
M08	0.9949	0.0644	0.9975	M44	0.9840	0.1220	0.9920
M09	0.9839	0.1148	0.9920	M45	0.9442	0.2276	0.9718
M10	0.9828	0.1186	0.9914	M46	0.7729	0.4595	0.8960
M11	0.9811	0.1243	0.9908	M47	0.9310	0.2540	0.9651
M12	0.9797	0.1289	0.9899	M48	0.9383	0.2425	0.9695

Çizelge 4.10. Dalgacık dönüşümü ile DVM analiz sonuçları


Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ12				SYİ3			
M13	0.9866	0.1147	0.9933	M49	0.9784	0.1414	0.9893
M14	0.9887	0.1053	0.9944	M50	0.9809	0.1330	0.9904
M15	0.9940	0.0771	0.9970	M51	0.9802	0.1342	0.9901
M16	0.9942	0.0764	0.9971	M52	0.9772	0.1438	0.9887
M17	0.9892	0.1034	0.9946	M53	0.9815	0.1308	0.9909
M18	0.9914	0.0919	0.9957	M54	0.9829	0.1257	0.9915
M19	0.9941	0.0766	0.9971	M55	0.9575	0.1963	0.9789
M20	0.9938	0.0787	0.9970	M56	0.9762	0.1469	0.9883
M21	0.9820	0.1340	0.9910	M57	0.9239	0.2641	0.9613
M22	0.9830	0.1300	0.9915	M58	0.9352	0.2436	0.9671
M23	0.9647	0.1867	0.9825	M59	0.9004	0.3027	0.9497
M24	0.9712	0.1681	0.9858	M60	0.9026	0.3007	0.9505
SYİ9							
M25	0.9844	0.1228	0.9922				
M26	0.9915	0.0908	0.9958				
M27	0.9901	0.0960	0.9951				
M28	0.9819	0.1314	0.9914				
M29	0.9918	0.0894	0.9960				
M30	0.9923	0.0865	0.9961				
M31	0.9778	0.1456	0.9895				
M32	0.9786	0.1429	0.9898				
M33	0.9331	0.2480	0.9675				
M34	0.9402	0.2346	0.9707				
M35	0.9499	0.2153	0.9747				
M36	0.8850	0.3286	0.9413				

Model performansları incelendiğinde, dalgacık dönüşümünden sonra, SYİ24 verisi kullanarak oluşturulan hemen hemen tüm modellerin NS ve r değerleri 1'e, RMSE değerleri de 0 (sıfır)'a çok yakındır. Dalgacık iyileştirmesinden sonra, bu sınıfta en başarılı model M03 olarak tespit edilmiştir.

M03'ün performans değerleri NS: 0.9986, RMSE: 0.0498, r: 0.9970'dir. M03'ün girdi yapısı 6 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. Dalgacık dönüşümü olmadan NS: 0.9303, RMSE: 0.2388, r: 0.9647 performans değerlerine sahip olan M03'de, dönüşümden sonra bu değerlerin hepsinde iyileştirme gerçekleşmiştir. Aynı şekilde M04'de de, dönüşümden sonra iyileşmeler meydana gelmiştir. Dönüşümden önce M04'de NS: 0.9399, RMSE: 0.2394, r: 0.9646 performans değerleri hesaplanırken, dönüşümden sonra ise NS: 0.9974, RMSE: 0.0659, r: 0.9947 değerleri hesaplanmıştır. Çıktı verisi t+1 zamanına ait modellerde ise en etkili iyileşme M09'da tespit edilmiştir. M09'da dönüşümden önce NS: 0.8592, RMSE: 0.3395, r: 0.9282 değerleri hesaplanırken, dönüşümden sonra NS: 0.9920, RMSE: 0.1148, r: 0.9839 değerleri hesaplanmıştır. Çıktı verisi t+2 zamanına ait olan

modellerdeki en etkili iyileşme ise M11’de meydana gelmiştir. Dönüşümden önce M11’de NS: 0.7972, RMSE: 0.4072, r: 0.8944 performans değerleri hesaplanırken, dönüşümden sonra ise NS: 0.9908, RMSE: 0.1289, r: 0.9797 değerleri hesaplanmıştır. Bunlardan yola çıkarak, model çıktı verisindeki t zamanı arttıkça iyileşme oransal olarak artmaktadır.

Şekil 4.16’da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M03 ve M04) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.16’da gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.16. Dalgacık dönüşümü ile SYİ24 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

Dalgacık dönüşümünden sonra, SYİ12 ile oluşturulan modellerin performansları incelendiğinde, M16 için, çıktı verisi t zamanına ait olan modellere ve diğer tüm modellere göre en etkili değerler hesaplanmıştır. M16’nın dönüşümden önceki değerleri NS: 0.8694, RMSE: 0.3610, r: 0.9329 şeklindeyken, dönüşümden sonra NS: 0.9942, RMSE: 0.0764, r: 0.9971’dir. M16’nın girdi yapısı, 5 aya kadar geciktirilmiş SYİ12 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Girdi yapısında meteorolojik veriyi içeren modellerin bu sınıfta daha başarılı ve etkili olduğu tespit edilmiştir. Çıktı verisi t+1 zamanına ait olan modellerde ise başarılı olan model

M22'dir. M22'nin dönüşümden önceki değerleri NS: 0.7391, RMSE: 0.5093, r: 0.3810 şeklindeyken, dönüşümden sonra NS: 0.9830, RMSE: 0.1300, r: 0.9915'dir. Çıktı verisi t+2 zamanına ait olan modellerde M24'ün dalgacık ayrışmasından sonra etkili sonuçlar verdiği belirlenmiştir. M24'ün dönüşümden önceki değerleri NS: 0.6374, RMSE: 0.597, r: 0.8029 şeklindeyken, dönüşümden sonra NS: 0.9712, RMSE: 0.1681, r: 0.9858'dir. 5 yerine 6 aya kadar geciktirilmiş SYİ12 verisi kullanılmasına rağmen, M22 ile M16'nın model yapısı birbirilerine çok benzemektedir. Dolayısıyla, t-1 zamanına ait veriyi girdi yapısında içeren modeller daha etkili olmuştur.

Şekil 4.17'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.17'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.17. Dalgacık dönüşümü ile SYİ12 verisi için DVM'de en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ9'da dalgacık dönüşümünden sonra, girdi yapısında meteorolojik veri içeren modellerin diğer modellere göre üstünlük sağladığı tespit edilmiş olup, en başarılı model, girdi yapısı 5 aya kadar geciktirilmiş SYİ9 verisi ile t zamanına ait aylık toplam yağış verisinden oluşturulmuş olan M30'dur. M30'un dönüşümden önceki değerleri NS: 0.9046, RMSE: 0.3043 r: 0.9524 şeklindeyken, dönüşümden sonra NS: 0.9923,

RMSE: 0.0865, r: 0.9961'dir. Çıktı yapısı t+1 zamanına ait modellerde ise, 6 aya kadar geciktirilmiş SYİ9 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulan M34, diğer modellere göre daha etkili olduğu bulunan sonuçlar arasındadır. M34'ün dönüşümden önceki değerleri NS: 0.5511, RMSE: 0.6426, r: 0.7502 şeklindeyken, dönüşümden sonra NS: 0.9402, RMSE: 0.2346, r: 0.9707'dir. 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuş M35'in ise, çıktı verisi t+2 zamanına ait olup, dalgacık dönüşümünden elde edilen performans değerleri, NS: 0.9402, RMSE: 0.2153, r: 0.9747'dir. Bu sınıfta t+2 zamanına ait tahminlemelerin sonuçları, t+1 zamanına göre daha etkili performans göstermiştir. Dolayısıyla, girdi yapısından ötürü, sadece kuraklık indisi ile girdi yapısı oluşturulan modellerin performanslarının etkili olduğu gözlemlenmiştir. Girdi yapısında t zamanına ait veriyi içermeyen modellerde M26 ile M27'nin diğer modellere göre daha etkili performans sergilediği tespit edilmiştir. Bu modellerin sırasıyla performans değerleri, NS: 0.9915, RMSE: 0.0908, r: 0.9958 ve NS: 0.9901, RMSE: 0.0960, r: 0.9951'dir. Burada, sadece kuraklık indisi ile oluşturulan modelin daha iyi sonuç verdiği tespit edilmiştir.

Şekil 4.18'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M26 ve M27) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.18'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

SYİ6 sınıfında ise, en etkili sonuç girdi verisi 6 aya kadar geciktirilmiş SYİ6 verisi ile oluşturulan M39 modelinde elde edilmiştir. M39'un dönüşümden önceki değerleri NS: 0.7384, RMSE: 0.4921, r: 0.8615 şeklindeyken, dönüşümden sonra NS: 0.9861, RMSE: 0.1136, r: 0.9931'dir. M39'un çıktı verisi t zamanına ait olup, girdi verisinden meteorolojik veri bulunduran modellere göre daha iyi performans ortaya koymuştur. Çıktı verisi t+1 zamanına ait model sonuçları incelendiğinde, M45'in M46'ya göre daha iyi performans sergilediği belirlenmiştir. Bu modelin dönüşümden önceki performans değerleri NS: 0.5265, RMSE: 0.6629, r: 0.7399 şeklindeyken, dönüşümden sonra NS: 0.9442, RMSE: 0.2276, r: 0.9718'dir. Çıktı verisi t+2 zamanına ait olan modellerde ise, performans değerleri ile diğerlerine göre etkili olan 7 aya kadar geciktirilmiş SYİ6 veri ile oluşturulan M48'dir. M48'in dönüşümden




Şekil 4.18. Dalgacık dönüşümü ile SYİ9 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

önceki performans değerleri, NS: 0.4454, RMSE: 0.727, r: 0.6772 şeklindeyken, dönüşümden sonra NS: 0.9383, RMSE: 0.2425, r: 0.9695’dir. Girdi yapısında t zamanına ait veri olmayan başka bir başarılı model M40’dır. Dalgacık dönüşümünden sonra bu model performans değerleri NS: 0.9861, RMSE: 0.1138, r: 0.9931’dir. M40’ın girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M39 performans olarak M40 hemen hemen aynı değerlere sahiptir.

Şekil 4.19’da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M39 ve M40) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.19’da gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

SYİ3 verisini girdi olarak kullanılan modellerin dalgacık dönüşümünden sonraki performans değerleri incelendiğinde, en başarılı modelin M50 olduğu belirlenmiştir. M50’in girdi yapısı, 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur.




Şekil 4.19. Dalgacık dönüşümü ile SYİ6 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

M50’un dönüşümden önceki performans değerleri NS: 0.6107, RMSE: 0.6107, r: 0.7793 şeklindeyken, dönüşümden sonra NS: 0.9809, RMSE: 0.1330, r: 0.9904’dür. Girdi yapısı, 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olan M51, NS: 0.9802, RMSE: 0.1342, r: 0.9901 performans değerleri olarak M50’yi takip etmektedir. Çıktı verisi t+1 zamanına ait olan modeller arasında en başarılı olan, 6 aya kadar geciktirilmiş SYİ3 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulan M58’dir. M58’in dönüşümden önceki performans değerleri, NS: 0.4144, RMSE: 0.7326, r: 0.6575 şeklindeyken, dönüşümden sonra NS: 0.9352, RMSE: 0.2436, r: 0.9671’dir.

Şekil 4.20’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M51 ve M50) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.20’de gösterilmiştir.

Genellikle iyileştirmeler tüm modellerde olmasına rağmen, çıktı verisine ait zaman arttıkça (M58 ve M60’da olduğu gibi), iyileşme de oransal olarak artmaktadır. Çıktı verisi t+2 zamanına sahip M59 ve M60 bulunmaktadır. Bunların performansları birbirlerine göre kıyaslandığında, M60’ın M59’a göre biraz daha iyi sonuç verdiği

gözlemlenmiştir. M60'ın dönüşümden önceki performans değerleri, NS: 0.4144, RMSE: 0.7326, r: 0.6575 şeklindeyken, dönüşümden sonra NS: 0.9026, RMSE: 0.3007, r: 0.9505'dir.




Şekil 4.20. Dalgacık dönüşümü ile SYİ3 verisi için DVM’de en başarılı modellerin zaman serisi ve saçılma diyagramları

3, 6, 9, 12 ve 24 aylık yağış toplamlarından elde edilen SYİ indislerinin genel özelliği, kısa zamana ait toplam değerlerden elde edilen indislerin uzun zaman yağış toplamlarından elde edilen indislere göre daha sık sınıflar arası geçişlere sahip olmaları, diğer bir deyişle daha büyük değişime sahip olmalarıdır. Örneğin SYİ3 indisi SYİ24 indisine göre daha fazla sıfır ekseninden geçişe sahip olup daha fazla kurak, sulak zamanlara ve değişime sahiptir. Dalgacık analizlerinde bu değişimler daha iyi tanımlanmış olup, modelleme sonuçlarına bu durum yansımış ve dalgacık analizi sonucu elde edilen modellerden daha iyi performans elde edilmiştir.

4.2.2. YSA ile analiz sonuçları

Hiperbolik Tanjant Fonksiyonunun ve LM eğitim algoritmasının kullanıldığı YSA analizi sonucu dalgacık dönüşümü yapılmadan elde edilen modellere ait sonuçlar Şekil 4.21’de gösterilmiştir. Şekil 4.21 incelendiğinde; DVM’deki durumun tersine, NS ve r değerlerinin çok fazla yüksek değerlere ulaşmadığı, RMSE değerlerinin ise, genellikle 1’in üzerine çıktığı ilk göze çarpan sonuçlardır.



Şekil 4.21. Dalgacık dönüşümü öncesi YSA analiz özet sonuçları

Ayrıca, DVM'nin aksine, bazı modellerin NS değerlerinin eksi bulunduğu Şekil 4.21'de görülmektedir. Çizelge 4.11'de YSA ile yapılan analiz neticesinde modellere ait performans değerleri gösterilmiştir. Burada, DVM'de olduğu gibi model performansları SYİ'nin zaman adımlarına göre, tüm modeller incelenmiştir. NS: 0.9229, RMSE: 0.2506, r: 0.9609 değerleri ile SYİ24'ün en başarılı modeli M06'dır. Peşi sıra M02 (NS: 0.9177, RMSE: 0.2590, r: 0.9585) ve M03 (NS: 0.9147 r: 0.9565, RMSE: 0.2642) gelmektedir. M06'nın girdi verisi incelendiğinde, 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Diğer başarılı modellerden olan SYİ24'ün 6 aya kadar geciktirilmiş verisinden oluşturulmuş M03 ise performans olarak M06'nın gerisinde kalmıştır. Buradan, t zamanına ait olan yağış verisinin model sonucunu iyileştirdiği sonucu çıkarılmıştır. M06'nın benzeri olarak oluşturulan M05'te ise aylık toplam yağış verisi yerine aylık ortalama sıcaklık verisi kullanılmıştır. M05 de NS: 0.9119, RMSE:0.2678, r: 0.9552 değerler ile M06'nın performans olarak gerisi kalmıştır. Ama şu da bir gerçektir ki; ağırlıklı olarak çıktı zamanı t, t+1 ve t+2 olan ait tahmin modelleri oluşturulduğundan ötürü, girdi verisinde t zamanına ait veriden ziyade, t-1 veya daha

fazla geciktirilmiş zamanlara ait veriyle tahmin modelleri oluşturmak daha anlamlıdır. M03 gibi, M02 de (5 aya kadar geciktirilmiş) yalnız SYİ24 girdi verisinden oluşturulmuştur. Her ne kadar performans değerlerinde çok fazla bir farklılık olmamasına rağmen, iki model arasında 1 aylık geciktirilmiş veri farkı olduğundan ötürü, 5 aylık geciktirilmiş veri yerine 6 aylık verinin kullanılması YSA'da daha etkili sonuç vermemiştir.


Çizelge 4.11. YSA ile analiz sonuçları

Model	NS	RMSE	r	Nör. S.	Model	NS	RMSE	r	Nör. S.
SYİ24					SYİ6				
M01	0.8997	0.2854	0.9486	50	M37	0.7438	0.5002	0.8650	38
M02	0.9177	0.2590	0.9585	39	M38	0.7267	0.5177	0.8565	42
M03	0.9147	0.2642	0.9565	46	M39	0.6673	0.5549	0.8297	45
M04	0.8856	0.3059	0.9435	44	M40	0.7323	0.4988	0.8580	42
M05	0.9120	0.2678	0.9552	40	M41	0.7573	0.4879	0.8756	46
M06	0.9229	0.2506	0.9609	39	M42	0.8969	0.3179	0.9482	39
M07	0.8988	0.2876	0.9507	24	M43	0.6917	0.5354	0.8441	29
M08	0.9048	0.2789	0.9523	47	M44	0.5858	0.6205	0.8109	36
M09	0.8004	0.4041	0.9001	46	M45	0.3441	0.7802	0.6634	36
M10	0.8265	0.3767	0.9101	46	M46	0.3263	0.7907	0.6573	50
M11	0.7176	0.4805	0.8578	25	M47	-0.0939	1.0113	0.4787	48
M12	0.7496	0.4524	0.8681	41	M48	-0.2832	0.8266	0.6062	48
SYİ12					SYİ3				
M13	0.8515	0.3824	0.9233	32	M49	0.5860	0.6191	0.7824	35
M14	0.8190	0.4221	0.9097	37	M50	0.5635	0.6353	0.7782	45
M15	0.8466	0.3910	0.9204	39	M51	0.4201	0.7255	0.7358	33
M16	0.7691	0.4768	0.8873	48	M52	0.4954	0.6767	0.7578	49
M17	0.8241	0.4161	0.9103	26	M53	0.5260	0.6621	0.7684	43
M18	0.8712	0.3561	0.9337	32	M54	0.9154	0.2796	0.9568	33
M19	0.8293	0.4125	0.9148	18	M55	0.4958	0.6764	0.7652	39
M20	0.7737	0.4751	0.8897	40	M56	0.4628	0.6983	0.7485	22
M21	0.5213	0.6899	0.7498	48	M57	0.1473	1.0255	0.5079	36
M22	0.6272	0.6087	0.8134	44	M58	-0.0689	0.9898	0.5546	50
M23	0.4885	0.7108	0.7248	49	M59	0.1995	1.0504	0.3385	41
M24	0.4013	0.7671	0.6807	41	M60	0.1665	1.0407	0.3579	31
SYİ9									
M25	0.7407	0.5009	0.8607	46					
M26	0.6962	0.5431	0.8377	32					
M27	0.5805	0.6255	0.8219	45					
M28	0.6712	0.5603	0.8377	45					
M29	0.7321	0.5100	0.8610	49					
M30	0.8699	0.3553	0.9343	41					
M31	0.7007	0.5345	0.8499	48					
M32	0.7091	0.5270	0.8511	43					
M33	0.4640	0.7022	0.7029	29					
M34	-0.2961	1.0919	0.5296	49					
M35	0.0882	0.9182	0.4941	44					
M36	0.1295	0.9039	0.5117	43					

Aylık maksimum ve minimum sıcaklık verisinin yanı sıra, t zamanına ait aylık toplam yağış verisini girdi olarak kullanan M08 ve M07'nin performans değerleri sırasıyla, NS: 0.9048, RMSE: 0.2789, r: 0.9523 ve NS: 0.8988, RMSE: 0.2876, r: 0.9507 şeklinde hesaplanmıştır. Sadece SYİ24'ün 4 aya kadar geciktirilmiş verisi ile girdisi oluşturulan M01 (NS: 0.8997, RMSE: 0.2854, r: 0.9486) performans olarak M08'in gerisinde kalmıştır. 5 aya kadar geciktirilmiş SYİ24 verisi ve t-1 zamanına ait aylık toplam yağış verisi ile oluşturulan M04 (NS: 0.8856, RMSE: 0.3059, r: 0.9435), performans olarak sadece SYİ24 indisleri ile oluşturulan modellerin gerisinde kalmıştır. 6 aya kadar geciktirilmiş SYİ24 verisi ve t-1 zamanına ait aylık toplam yağış verisi ile oluşturulan M10 (NS: 0.8265, RMSE: 0.3767, r: 0.9101), çıktı verisi t+1 zamanına ait olan M09'a (NS: 0.8004, RMSE: 0.4041, r: 0.9001) göre daha etkili sonuç ortaya koymuştur. Bu da, t-1 zamanına ait girdi verisinin modellerde kullanılmasının etkili olduğunun bir göstergesidir. M12 (NS: 0.7496, RMSE: 0.4524, r: 0.8681) ve M11 (NS: 0.7176, RMSE: 0.4805, r: 0.8578) incelendiğinde ise, t+2 zamanına ait tahminlemelerde girdi verisi olarak SYİ24'ün 6 aya kadar geciktirilmiş verisinin kullanılmasının iyi olabileceği tespit edilmiştir.

Şekil 4.22'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M02 ve M03) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.22'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.


SYİ12 verisini girdi olarak kullanan modeller (M13-M24 arası) ile alınan sonuçlara bakıldığı zaman, M18 (NS: 0.8712, RMSE: 0.3561, r: 0.9337), M13 (NS: 0.8515, RMSE: 0.3824, r: 0.9233), M15 (NS: 0.8466, RMSE: 0.3910, r: 0.9204) ve M19 (NS: 0.8293, RMSE: 0.4125, r: 0.9148) modellerinin performans olarak diğer modellerden daha iyi olduğu tespit edilmiştir. M18 modelinin girdi yapısı 5 aya kadar geciktirilmiş SYİ12 verisi ve t zamanına ait aylık toplam yağış verisinden oluşturulmuş ve girdi yapısı M18'e benzeyen (t zamanına ait aylık toplam yağış verisi yerine, t zamanına ait aylık ortalama sıcaklık verisinden oluşturulan) M17'ye göre daha etkili sonuç verdiği belirlenmiştir. Bu ise, model girdi yapısında aylık toplam yağış verisinin kullanımının, aylık ortalama sıcaklık verisine göre daha etkili olduğu sonucunu çıkartmıştır.



Şekil 4.22. SYİ24 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

M17’de ise NS: 0.8241, RMSE: 0.4161, r : 0.9103 performans değerleri hesaplanmıştır. M17’den sonra etkili sonuçlardan birisi de M13’de hesaplanmıştır. Girdi yapısında 4 aya kadar geciktirilmiş SYİ12 verisi kullanılan M13’den sonra, 6 aya kadar geciktirilmiş SYİ12 verisini girdi olarak kullanan M15’in etkili sonuç verdiği belirlenmiştir. Bu sonuç ile SYİ12 girdi verisinin fazla geciktirilerek model girdi yapısına eklenmesi, model sonucuna olumsuz olarak etki etmiştir.

Şekil 4.23’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M13 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.23’de gösterilmiştir. SYİ9 verisi ile oluşturulan (M25-M36 arası) modellerin analiz sonuçları incelendiğinde, performans değerlendirme kriterlerine göre M30, M25, M29, M32, M31, M26 modelleri diğerlerine göre daha etkili performans göstermiştir. Diğer SYİ adımlarında olduğu gibi, M30’da (NS: 0.8699, RMSE: 0.3553, r : 0.9343) da t ayını temsil eden aylık toplam yağış verisi modele girdi olarak eklendiği zaman, model performansı önemli derecede etkilendiği tespit edilmiştir. Sonrasındaki başarılı model ise M25’dir (NS: 0.7404, RMSE: 0.5009, r : 0.8607). Bu modelin girdi yapısı 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur.




Şekil 4.23. SYİ12 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

T zamanına ait verinin modelde girdi olarak kullanılmamasından ötürü en başarılı model olarak M25 ifade edilebilir. Bu modellerin devamında başarılı olarak öne çıkan bir diğer model ise M29’dur. M29’un girdi yapısı 5 aya kadar geciktirilmiş SYİ9 verisi ve t zamanına ait aylık toplam yağış verisinden oluşturulmuştur. NS: 0.7321, RMSE: 0.5100, r: 0.8610 performans değerleri M29’da elde edilmiştir. Daha sonraki modeller incelendiğinde M32 (NS: 0.7091, RMSE: 0.5270, r: 0.8511) ve M31’de (NS: 0.7007, RMSE: 0.5345, r: 0.8499) t zamanına ait meteorolojik verinin modele girdi olarak eklenilmesinden dolayı, model sonucu olumlu yönde etkilenmiştir. Başarılı modeller arasında olan M26 (NS: 0.6962, RMSE: 0.5431, r: 0.8377) ise, 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. M26’da, M25’e göre daha fazla SYİ9’un geciktirilmiş verisi kullanıldığı halde, model sonucunun M25’göre daha kötü olduğu tespit edilmiştir. Bundan dolayı, SYİ9 ile yapılabilecek modelleme çalışmalarda, geciktirilmiş verinin optimum düzeyde tutulması gerektiği sonucuna ulaşılmıştır. NS: 0.6712, RMSE: 0.5603, r: 0.8377 performans değerleri, t-1 zamanına ait aylık toplam yağış verisi ve 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuş olan M28 modelinin analizi sonucunda hesaplanmıştır. M28 de başarılı modeller arasında yerini almıştır. M27 ise 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuş ve analiz sonucunda (NS: 0.5805, RMSE: 0.6255, r: 0.8219) bahsedilen diğer modellere göre daha düşük performans sergilemiştir. M33 ve M34’ün çıktı verisi

$t+1$ zamanına ait olup, girdi verisi sırasıyla, 6 aya kadar geciktirilmiş SYİ9 ve 6 aya kadar geciktirilmiş SYİ9 ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Model performansları NS: 0.4640, RMSE: 0.7022, r : 0.7029 değerleri olan M33, NS: -0.2961, RMSE: 0.6255, r : 1.0919 değerleri olan M34'e göre daha iyi performans sergilemiştir. Çıktı verisi $t+2$ zamanına ait olan M36 ve M35 modellerinin performans değerleri NS: 0.1295, RMSE: 0.9039, r : 0.5117 ve NS: 0.0882, RMSE: 0.9182, r : 0.4941 şeklindedir.

Şekil 4.24'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M26) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.24'de gösterilmiştir.




Şekil 4.24. SYİ9 verisi için YSA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ6 verisinin girdi olarak kullanıldığı modeller incelendiğinde, en başarılı modellerden ikisi NS: 0.8969, RMSE: 0.3179, r : 0.9482 performans değerleri ile M42 ve yine NS: 0.7573, RMSE: 0.4879, r : 0.8756 performans değerleri ile M41'dir. Bu modellerin girdi yapısı sırasıyla 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait aylık toplam yağış verisinden, 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait aylık ortalama sıcaklık verisinden oluşturulmuştur. Performans değerlerinin yüksek

olması t zamanına ait verinin kullanılmasıyla elde edilmiştir. Dolayısıyla, girdi yapısında t zamanına ait veriyi içermeyen M37 (NS: 0.7438, RMSE: 0.4988, r: 0.8650) ve M40 (NS: 0.7323, RMSE: 0.5002, r: 0.85) performans değerleri ile SYİ6'da başarılı modellerden diğerleri olarak belirlenmiştir. M37'nin girdi yapısı 4 aya kadar geciktirilmiş SYİ6 verisinden, M40'ın girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. SYİ6 ile yapılacak bir modelleme çalışmasında bu modellere ait girdi yapıları kullanılabilir. NS: 0.7267, RMSE: 0.5177, r: 0.8565 performans değerleri M38 için tespit edilmiştir. M38'in M37 ile farkı 1 ay fazla geciktirilmiş veriyi girdi yapısında bulunmasıdır. Dolayısıyla, SYİ6 verisini girdi yapısında kullanırken, geciktirilmiş ay sayılarının optimum sayıda olması gerektiği sonucuna varılabilir. Model girdi yapısı birbirlerine yakın olan M43 ile M44'in performans değerleri incelendiğinde, M43'ün M44'e göre daha etkili sonuç verdiği tespit edilmiştir. Model girdi yapısındaki farklılık ise, M43'ün t zamanına ait aylık minimum sıcaklık, M44'ün t zamanına ait aylık maksimum sıcaklık verisinden oluşturulmuş olmasıdır. Bu iki modelin sonuçları M43 için NS: 0.6917, RMSE: 0.5354, r: 0.8441, M44 için NS: 0.5858, RMSE: 0.6205, r: 0.8109 olarak hesaplanmış olup, bu zaman adımıyla modelleme çalışmalarında aylık minimum sıcaklık verisinin kullanımın daha yararlı olabileceği belirlenmiştir. 6 aya kadar geciktirilmiş SYİ6 verisinden oluşturulan M39 için NS: 0.6673, RMSE: 0.5549, r: 0.8297 değerleri hesaplanmıştır. T+1 zamanını çıktı verisi olarak kullanan M45 ve M46'da ise, performans değerleri sırasıyla, NS: 0.3441, RMSE: 0.7802, r: 0.6634 ve NS: 0.3263, RMSE: 0.7907, r: 0.6573'dür. T+2 zamanını çıktı verisi olarak kullanan M47 ve M48'de ise, NS (sırasıyla -0.0939, -0.2832) değeri eksi değer olarak hesaplanmış ve etkili sonuç vermediği tespit edilmiştir.

Şekil 4.25'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M37 ve M40) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.25'de gösterilmiştir.


SYİ3 verisi kullanılarak oluşturulan modeller incelendiğinde (M49-M60 arası), M54, M49, M50 ve M53'ün başarılı performansları dikkat çekmektedir. M54 ve M53'ün



Şekil 4.25. SYİ6 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları


girdi yapıları; sırasıyla, t zamanına ait aylık toplam yağış ve aylık ortalama sıcaklık verisinden oluşturulmuştur. M54, NS: 0.9154, RMSE: 0.2796, r: 0.9568 değerleri ile diğer modellere göre daha etkili performans sergilemesinin nedeni, girdi yapısındaki t zamanına ait aylık toplam yağış verisidir. M54’ü, NS: 0.5860, RMSE: 0.7824, r: 0.6191 değerler ile M49 takip etmektedir. Bu modelin girdi yapısı, 4 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Peşi sıra gelen M50 ise, 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olup, performans değerleri NS: 0.5635, RMSE: 0.6353, r: 0.7782’dir. M55 ile M56 t zamanına ait sırasıyla, aylık minimum sıcaklık ve maksimum sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olup, performans değerleri sırasıyla; NS: 0.4958, RMSE: 0.7652, r: 0.7652 ve NS: 0.4628, RMSE: 0.6983, r: 0.7485’dir. M55 ve M56 t zamanına ait veriyi girdi olarak kullanan M53 ve M54’ün performans olarak gerisinde kaldığı tespit edilmiştir. M57 ve M58 t+1 zamanına ait çıktı verisinden oluşturulmuş olup, sırasıyla, NS: 0.1473, RMSE: 1.0255, r: 0.5079 ve NS: -0.0689, RMSE: 0.9898, r: 0.5546 performans değerleri hesaplanmıştır. 6 aya kadar geciktirilmiş SYİ3 değerlerinden oluşturulmuş olan M57’nin, 6 aya kadar geciktirilmiş SYİ3 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuş olan M58’e göre daha iyi performans sergilediği belirlenmiştir.

Şekil 4.26’da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M49 ve M50) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.26’da gösterilmiştir.



Şekil 4.26. SYİ3 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

YSA’da dalgacık dönüşümü uygulandıktan sonra elde edilen modellere ait özet bilgi Şekil 4.27’de gösterilmiştir. Dalgacık dönüşümü yapıldıktan sonra, model performans parametrelerinden olan NS değerleri, 0.60 ile 0.99 arasında r değerleri de 0.81 ile 0.96 arasında değişmektedir. Dönüşüm olmadan önce YSA ile yapılan analizde, bazı model sonuçlarının (-) negatif değerde bulundukları dile getirilmişti. Bulunan sonuçlar arasından birisi, dönüşümden sonra (-) negatif değer olmaması ve model sonuçlarındaki iyileşmenin oransal olarak fazla olmasıdır. Dalgacık dönüşümünden sonraki tüm modellere ait sonuçlar Çizelge 4.12’de gösterilmiştir. Bu modeller arasından en başarılısı M08’dir. M08’in girdi yapısı, 5 aya kadar geciktirilmiş SYİ24 ile t zamanına ait aylık maksimum sıcaklık verisinden oluşturulmuştur. M08’in dönüşümden önceki performans değerleri, NS: 0.9048, RMSE: 0.2789, r: 0.9523 şeklindeyken, dönüşümden sonra NS: 0.9831, RMSE: 0.1177, r: 0.9918’dir. M08’in girdi yapısında t zamanına ait veri içermesinden dolayı, bu model haricindeki diğer başarılı model olarak kabul edilen modellerden birisi de M04’dür. M04’ün girdi verisi,



Şekil 4.27. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları

5 aya kadar geciktirilmiş SYİ24 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M04'ün dönüşümden önceki performans değerleri, NS: 0.8856, RMSE: 0.3059, r: 0.9435 şeklindeyken, dönüşümden sonra NS: 0.9805, RMSE: 0.1263, r: 0.9905'dir. Yapılacak olan bir dalgacık dönüşümlü bir modelleme çalışmasında, bu modelin girdi verisinden yararlanılabilir. Bu modeli performans olarak M03 takip etmektedir (NS: 0.9783 RMSE: 0.1333, r: 0.9891).

Çizelge 4.12. Dalgacık dönüşümü ile YSA analiz sonuçları

Model	NS	RMSE	r	Nör. S.	Model	NS	RMSE	r	Nör. S.
SYİ24					SYİ6				
M01	0.9568	0.1872	0.9784	46	M37	0.9626	0.1911	0.9832	25
M02	0.9690	0.1590	0.9848	47	M38	0.9520	0.2169	0.9761	44
M03	0.9783	0.1333	0.9891	38	M39	0.9535	0.2074	0.9797	48
M04	0.9805	0.1263	0.9905	26	M40	0.9470	0.2220	0.9741	43


Çizelge 4.12 (devam). Dalgacık dönüşümü ile YSA analiz sonuçları

Model	NS	RMSE	r	Nör. S.	Model	NS	RMSE	r	Nör. S.
SYİ24					SYİ6				
M05	0.9788	0.1314	0.9895	25	M41	0.8976	0.3169	0.9517	45
M06	0.9782	0.1332	0.9893	23	M42	0.9478	0.2262	0.9742	26
M07	0.9751	0.1426	0.9877	33	M43	0.9591	0.1950	0.9794	39
M08	0.9831	0.1177	0.9918	39	M44	0.8973	0.3090	0.9483	29
M09	0.9199	0.2560	0.9628	42	M45	0.8096	0.4204	0.9172	42
M10	0.9324	0.2352	0.9671	36	M46	0.8238	0.4044	0.9166	41
M11	0.8644	0.3330	0.9369	34	M47	0.6486	0.5731	0.8457	50
M12	0.8967	0.2906	0.9504	45	M48	0.7010	0.5339	0.8687	45
SYİ12					SYİ3				
M13	0.9423	0.2384	0.9718	44	M49	0.8723	0.3439	0.9397	42
M14	0.9564	0.2072	0.9780	46	M50	0.9252	0.2629	0.9641	40
M15	0.9683	0.1778	0.9840	42	M51	0.9270	0.2574	0.9644	45
M16	0.9698	0.1735	0.9849	36	M52	0.9290	0.2538	0.9657	47
M17	0.9719	0.1662	0.9863	36	M53	0.8312	0.3951	0.9219	42
M18	0.9698	0.1724	0.9850	34	M54	0.9451	0.2254	0.9744	48
M19	0.9509	0.2214	0.9751	29	M55	0.8520	0.3663	0.9285	44
M20	0.9735	0.1627	0.9871	36	M56	0.9250	0.2609	0.9633	34
M21	0.8657	0.3653	0.9399	49	M57	0.8130	0.4140	0.9119	46
M22	0.8711	0.3580	0.9397	49	M58	0.8061	0.4216	0.9163	50
M23	0.7806	0.4655	0.8922	43	M59	0.6593	0.5598	0.8463	50
M24	0.8387	0.3981	0.9234	34	M60	0.7009	0.5269	0.8567	46
SYİ9									
M25	0.9749	0.1557	0.9879	20					
M26	0.9675	0.1777	0.9836	43					
M27	0.9676	0.1738	0.9839	37					
M28	0.9630	0.1879	0.9831	37					
M29	0.9259	0.2682	0.9653	27					
M30	0.9477	0.2252	0.9743	24					
M31	0.9716	0.1646	0.9857	22					
M32	0.9500	0.2184	0.9785	24					
M33	0.8696	0.3463	0.9375	49					
M34	0.8123	0.4155	0.9147	50					
M35	0.7845	0.4465	0.8938	32					
M36	0.6150	0.6011	0.8232	45					

Çıktı verisi t+1 zamanına ait modellerde, M10'un M09'a göre, daha etkili sonuçlar verdiği tespit edilmiştir. M10'un dönüşümden önceki performans değerleri, NS: 0.8265, RMSE: 0.3767, r: 0.9101 şeklindeyken, dönüşümden sonra NS: 0.9324, RMSE: 0.2352, r: 0.9671'dir.

Şekil 4.28'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M04 ve M03) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.28’de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.28. Dalgacık dönüşümü ile SYİ24 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

Çıktı verisi $t+2$ zamanına ait olan M11 ve M12 incelendiğinde ise, M12’nin M11’e göre daha etkili olduğu belirlenmiştir. M12’nin dönüşümden önceki performans değerleri, NS: 0.7496, RMSE: 0.4524, r : 0.8681 şeklindeyken, dönüşümden sonra NS: 0.8967, RMSE: 0.2906, r : 0.9504’dür. Dalgacık analizi ile $t+2$ zamanına ait çıktıları içeren modellerin performanslarında önemli iyileştirmeler olduğu tespit edilmiştir. Dalgacık dönüşümünde SYİ24’ün kullanıldığı modellerin analizinden sonra, SYİ12’nin girdi verisi olarak kullanıldığı modeller de analiz edilmiştir (M13-M24 arası). Bu modellerde en başarılı sonuçlar M20, M17 ve M16 modellerinde hesap edilmiştir. M20 ve M17’nin girdi yapısı t zamanına ait girdi verisinden oluşturulduğundan dolayı, bu modeller dışında girdi yapısında t zamanına ait veri içermeyen en etkili model M16’dır. M16’nın girdi yapısı ise, 5 aya kadar geciktirilmiş SYİ12 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M16’nın dönüşümden önceki performans değerleri, NS: 0.7691, RMSE: 0.4768, r : 0.8873 şeklindeyken, dönüşümden sonra NS: 0.9735, RMSE: 0.1627, r : 0.9871’dir. M20, M17 ve M16 çıktı verisi t zamanına aittir. Çıktı zamanı $t+1$ olan modeller incelendiğinde ise M22, M21’e göre daha etkili sonuçlar vermiştir. M22’nin

dönüşümden önceki performans değerleri, NS: 0.6272, RMSE: 0.6087, r: 0.8134 şeklindeyken, dönüşümden sonra NS: 0.8711, RMSE: 0.3580, r: 0.9397'dir. M22'deki gibi çıktı verisi t+2 zamanına ait olan modellerde de iyileştirmeler yapılmıştır. M24 ve M23 kıyaslandığında, M24'ün performans değerlerinin M23'ü geride bıraktığı Çizelge 4.12'den görülebilmektedir. M24'ün girdi yapısı 7 aya kadar geciktirilmiş SYİ12 verisinden, M23'ün girdi verisi ise 6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. M24'ün dönüşümden önceki performans değerleri, NS: 0.4013, RMSE: 0.7671, r: 0.6807 şeklindeyken, dönüşümden sonra NS: 0.8387, RMSE: 0.3981, r: 0.9234'dir. Dolayısıyla, SYİ12 verisi ile yapılacak olan dalgacık dönüşümü içeren bir modelleme çalışmasında, çıktı verisi t zamanına ait olan modellemelerde M16, çıktı verisi t+1 zamanına ait olan modellemelerde M22, çıktı verisi t+2 zamanına ait olan modellemelerde M24'ün girdi yapılarından faydalanılabilir.

Şekil 4.29'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.29'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.



Şekil 4.29. Dalgacık dönüşümü ile SYİ12 verisi için YSA'da en başarılı modellerin zaman serisi ve saçılma diyagramları


SYİ9 verisi ile oluşturulan model sonuçları incelendiğinde (M25-M36 arası), çıktı verisi t zamanına ait olan modellerdeki en iyi sonuç, M25'de tespit edilmiştir. Bu

modelin girdi yapısı 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. M25'in dönüşümden önceki performans değerleri NS: 0.7407, RMSE: 0.5009, r: 0.8607 şeklindeyken, dönüşümden sonra NS: 0.9749, RMSE: 0.1557, r: 0.9879'dur. Çıktı yapısı t+1 zamanına ait olan modellerde ise başarılı sonuçlardan birisi girdi yapısı 6 aya kadar geciktirilmiş SYİ9 ile oluşturulmuş M33'de alınmıştır. M33'ün dönüşümden önceki performans değerleri NS: 0.4640, RMSE: 0.7022, r: 0.7029 şeklindeyken, dönüşümden sonra NS: 0.8696, RMSE: 0.3463, r: 0.9375'dir. M33 ise çıktı yapısı t+2 zamanına ait olan modellerde başarılı sonuç verenlerden birisidir. M35'ün girdi yapısı M33 ile aynı olup, 6 aya kadar geciktirilmiş SYİ9 verisi ile oluşturulmuştur. M35'in dönüşümden önceki performans değerleri, NS: 0.0882, RMSE: 0.9182, r: 0.4941 şeklindeyken, dönüşümden sonra NS: 0.7845, RMSE: 0.4465, r: 0.8938'dir. Dönüşümden sonra, nerdeyse sıfıra (0) yakın olan NS değeri, 0.7845'e kadar yükselmiştir. SYİ9 ile yapılacak bir modelleme çalışmasında, dalgacık iyileştirmesinden faydalanılacaksa, bu model girdi yapıları kullanılabilir.

Şekil 4.30'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M27) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.30'da gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

SYİ6 verisinin kullanıldığı modeller incelendiğinde (M37-M48 arası), çıktı verisi t zamanına ait olan modellerde M37'nin diğer modellere göre daha etkili sonuç verdiği belirlenmiştir. Model yapısı, 4 aya kadar geciktirilmiş SYİ6 verisinden oluşturulan M37'nin dönüşümden önceki performans değerleri, NS: 0.7438, RMSE: 0.4988, r: 0.8650 şeklindeyken, dönüşümden sonra NS: 0.9626, RMSE: 0.1911, r: 0.9832'dir.

Bu model haricindeki diğer başarılı modellerden birisi de M43'tür. M43'ün girdi yapısında t zamanına ait aylık minimum sıcaklık kullanılmasından dolayı, yapılacak olan modelleme çalışmasında tercih edilmeyebilir. Çıktı verisi t+1 zamanına ait olan modellerde ise en etkili sonuç M46'da alınmıştır. M46'nın dönüşümden önceki performans değerleri NS: 0.3263, RMSE: 0.7907, r: 0.6573 şeklindeyken, dönüşümden sonra NS: 0.8238, RMSE: 0.4044, r: 0.9166'dir. Model girdi yapısı ise,




Şekil 4.30. Dalgacık dönüşümü ile SYİ9 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

6 aya kadar geciktirilmiş SYİ6 veri ile $t-1$ zamanına aylık toplam yağış verisinden oluşturulmuştur. Sadece SYİ6 verisi ile girdi yapısı oluşturulan M45’e göre daha etkili bir performans sergilemiştir. Çıktı yapısı $t+2$ zamanına ait olan modellerde, en başarılı sonuç M48’de tespit edilmiştir. Bu modelin girdi yapısı 7 aya kadar geciktirilmiş SYİ6 verisinden oluşturmuş olup, dönüşümden önceki performans değerleri, NS: -0.2832, RMSE: 0.6062, r : 0.8266 şeklindeyken, dönüşümden sonra NS: 0.7010, RMSE: 0.5339, r : 0.8687’dir. Bu modelin NS değerlerinde dalgacık dönüşümü ile negatif değerden pozitifte doğru önemli derecede iyileştirme sağlanmıştır.

Şekil 4.31’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M37 ve M39) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.31’de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

Girdi yapısında SYİ3 verisinin kullanıldığı modeller incelendiğinde (M48-M60 arası), çıktı verisi t zamanına ait olan modellerde, M54 ve M52 diğer modellere göre etkili performans sergilemiştir. M54’ün girdi yapısında t zamanına ait meteorolojik veri




Şekil 4.31. Dalgacık dönüşümü ile SYİ6 verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

bulunmasından, ayrıca çıktı yapısının t zamanına ait olmasından ötürü, M52’nin bu modele göre daha başarılı olduğu belirlenmiştir. M52’nin girdi yapısı, 5 aya kadar geciktirilmiş SYİ3 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M52’nin dönüşümden önceki performans değerleri NS: 0.4954, RMSE: 0.7578, r : 0.6767 şeklindeyken, dönüşümden sonra NS: 0.9290, RMSE: 0.2538, r : 0.9657’dir. Peşi sıra bu modelleri takip eden başka bir başarılı model ise M51’dir. M51’in girdi yapısı 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Bu modelin performans değerleri NS: 0.9270, RMSE: 0.2574, r : 0.9644’dür. Çıktı verisi $t+1$ zamanına ait olan modellerde ise, M54’ün M60’a göre üstünlük sağladığı belirlenmiştir. M57’nin dönüşümden önceki performans değerleri, NS: 0.1473, RMSE: 1.0255, r : 0.5079 şeklindeyken, dönüşümden sonra NS: 0.8130, RMSE: 0.4140, r : 0.9119’dır. $T+2$ zamanına ait çıktı yapısı olan modellerden M60’ın etkili performans sağladığı belirlenmiştir. Dönüşümden önceki performans değerleri, NS: 0.1665, RMSE: 1.0407, r : 0.3579 şeklindeyken, dönüşümden sonra NS: 0.7009, RMSE: 0.5269, r : 0.8567’dır.

Şekil 4.32’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M52 ve M51) zaman serisi ve gözlem değerlerine göre saçılma diyagramı


verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.32’de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.



Şekil 4.32. Dalgacık dönüşümü ile SYI3verisi için YSA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

4.2.3. RO ile analiz sonuçları

Optimum ağaç sayısının, otomatik olarak belirlendiği RO metodu ile yapılan analizlere ait sonuçlar Çizelge 4.13’de gösterilmiştir. Elde edilen sonuçlar, diğer algoritmalarda (SVM, ANN’de) olduğu gibi SYİ’nin farklı zaman adımlarına göre değerlendirilmiştir. Ayrıca, model sonuçlarının kolay irdelenebilmesi için elde edilen analiz sonuçlarına ait özet bilgi de Şekil 4.33’de gösterilmiştir. Şekil 4.33 incelendiğinde, NS değerleri 0.15 ile 0.94, r değerleri ise 0.44 ile 0.97 arasında geniş bir ölçekte değişmektedir. Ayrıca, başarılı performans değerleri genellikle sıra sayısına göre ilk modellerde tespit edilmiş ve sarı sütunlar halinde gösterilmiştir. Bu modellerin NS ve r değerlerinin neredeyse 1 değerine yaklaştığı dikkat çeken bulgular arasındadır. Şekil 4.33’de performans değerleri düşük olan modeller ise mavi sütunlar ile gösterilmiştir. Bu renge sahip olan M32, M33, M57 ve M58’in performans değerleri diğer modellerin gerisindedir. Bu modellerin r değerleri 0.30 ile 0.60 arasında, NS değerleri ise 0.10 ile 0.30 arasında değişmektedir. RMSE değerleri ise Şekil 4.33’de gösterilmemiş olup, bu değerlere devamında yer alan Çizelge 4.13’de yer verilmiştir.



Şekil 4.33. Dalgacık dönüşümü öncesi RO analiz özet sonuçları

Diğer öğrenme algoritmalarında olduğu gibi, RO algoritmasında da SYİ'nin zaman periyodu arttıkça varyansa bağlı olarak model performansı da artmıştır. DVM ile kıyaslandığında, performans değerleri genel olarak daha düşüktür. YSA ile kıyaslandığında kimi modellerde daha iyi performans sergilediği, kimi modellerde ise daha kötü performans sergilediği belirlenmiştir. Her ne kadar bazı modellerde DVM'den performans olarak geri kalsa da, dalgacık dönüşümü olmadan yapılan analizlerde, başarılı algoritmalarındandır.

Çizelge 4.13. RO ile analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.9199	0.2550	0.9592	M37	0.7549	0.4892	0.8691
M02	0.9215	0.2529	0.9601	M38	0.7507	0.4944	0.8671
M03	0.9123	0.2678	0.9556	M39	0.7403	0.4903	0.8623
M04	0.9148	0.2640	0.9568	M40	0.7572	0.4751	0.8717
M05	0.9180	0.2585	0.9583	M41	0.7733	0.4692	0.8799
M06	0.9359	0.2286	0.9677	M42	0.8673	0.3607	0.9359
M07	0.9125	0.2676	0.9555	M43	0.7659	0.4666	0.8786

Çizelge 4.13 (devam). RO ile analiz sonuçları


Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M08	0.9122	0.2680	0.9554	M44	0.7769	0.4555	0.8843
M09	0.8421	0.3594	0.9182	M45	0.5268	0.6627	0.7285
M10	0.8424	0.3592	0.9185	M46	0.5510	0.6455	0.7461
M11	0.7600	0.4430	0.8728	M47	0.3520	0.7783	0.5969
M12	0.7752	0.4287	0.8816	M48	0.3967	0.7584	0.6319
SYİ12				SYİ3			
M13	0.8406	0.3962	0.9183	M49	0.5966	0.6112	0.7763
M14	0.8318	0.4069	0.9137	M50	0.5825	0.6214	0.7657
M15	0.8346	0.4060	0.9162	M51	0.5750	0.6211	0.7617
M16	0.8419	0.3971	0.9197	M52	0.6280	0.5811	0.7947
M17	0.8293	0.4100	0.9128	M53	0.6827	0.5417	0.8311
M18	0.8673	0.3615	0.9338	M54	0.8273	0.3997	0.9173
M19	0.8343	0.4065	0.9152	M55	0.6212	0.5856	0.7944
M20	0.8377	0.4024	0.9173	M56	0.6618	0.5541	0.8194
M21	0.6849	0.5597	0.8360	M57	0.3193	0.7899	0.5787
M22	0.6884	0.5566	0.8360	M58	0.4797	0.6906	0.7004
M23	0.5620	0.6577	0.7665	M59	0.1679	0.8749	0.4487
M24	0.5668	0.6525	0.7684	M60	0.1799	0.8726	0.4620
SYİ9							
M25	0.7895	0.4513	0.8894				
M26	0.7823	0.4597	0.8862				
M27	0.7645	0.4687	0.8772				
M28	0.7828	0.4555	0.8868				
M29	0.7711	0.4673	0.8785				
M30	0.8633	0.3644	0.9334				
M31	0.7670	0.4717	0.8783				
M32	0.7813	0.4570	0.8873				
M33	0.4853	0.6881	0.7070				
M34	0.5495	0.6438	0.7497				
M35	0.2218	0.8483	0.5055				
M36	0.2481	0.8338	0.5256				

RO ile yapılan analiz sonucunda model sonuçlarına daha detaylı olarak bakıldığı zaman, SYİ24’de, NS: 0.9359, RMSE: 0.2286, r: 0.9677 değerleri ile M06 modelinin diğer modellere göre daha iyi performans gösterdiği tespit edilmiştir. SYİ24’de başarılı olarak tespit edilen diğer modellere bakıldığında ise M02, M01, M05, M04’ün sırasıyla diğer modellere göre daha başarılı performans göstermiştir. Daha önceki kısımlarda da dile getirildiği gibi, t zamanına ait aylık toplam yağış verisini içeren M06 modeli dışında, SYİ24 zaman adımıyla en başarılı modellerden olan M02 (NS: 0.9215, RMSE: 0.2529, r: 0.9601) ve M01’in (NS: 0.9199, RMSE: 0.2550, r: 0.9592) girdi yapısı sırasıyla 5 ve 4 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. Bundan ötürü SYİ24 ile yapılabilecek bir modelleme çalışmasında sadece SYİ değerleri ile model girdileri oluşturulabilir. Bunun yanı sıra NS: 0.9180, RMSE:

0.2585, r : 0.9583 değerleri ile M05 ve NS: 0.9148, RMSE: 0.2640, r : 0.9568 değerler ile de M04'ün girdi yapısından da faydalanılabilir. M05'in girdi yapısı 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık ortalama sıcaklık verisinden oluşturulduğu için, M05'den ziyade, M04 modeli SYİ24 verisiyle yapılacak olan modelleme çalışmasında kullanılabilir. M04'ün girdi yapısında 5 aya kadar geciktirilmiş SYİ24 verisi ve $t-1$ zamanına ait aylık toplam yağış verisi kullanılmıştır. M07 ve M08 modellerinin girdi yapısı t zamanına ait sırasıyla aylık minimum sıcaklık ve maksimum sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. Bu modellerin hesaplanan performans değerleri yine sırasıyla, NS: 0.9125, RMSE: 0.2676, r : 0.9568 ve NS: 0.9122, RMSE: 0.2680, r : 0.9554'dür. 6 aya kadar geciktirilmiş SYİ24 verisi ile oluşturulan M03 modeli, NS: 0.9123, RMSE: 0.2678, r : 0.9556'lık performans değerleri ile M08 haricinde bahsedilen modellerin gerisinde kalmıştır. Çıktı verisi zamanı $t+1$ olan M10 ve M09 modellerinin performansları da sırasıyla, NS: 0.8424, RMSE: 0.3592, r : 0.9185 ve NS: 0.8421, RMSE: 0.3594, r : 0.9182'dir. Girdi verisinin 6 ay geciktirilerek oluşturulan M11 için NS: 0.7600, RMSE: 0.4430, r : 0.8728 değerleri, 7 ay geciktirilerek oluşturulan M12 için NS: 0.7752, RMSE: 0.4284, r : 0.8816 değerleri hesaplanmıştır. Buradan yola çıkılarak SYİ24 verisi kullanılarak yapılacak bir modelleme çalışmasında M02 ve M01'den yararlanılabilir.

Şekil 4.34'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M02 ve M01) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.34'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.

Çizelge 4.13'de gösterildiği gibi, SYİ12 verisi ile oluşturulan modellerde (M13-M24 arası); başarılı modellerden bazıları M18, M16, M13 olduğu görülmektedir. Her ne kadar en başarılı sonuç M18 (NS: 0.8673, RMSE: 0.3615, r : 0.9338 değerleri ile) olarak gözükse de, model girdi yapısında t zamanına ait aylık toplam yağış verisi olması sebebiyle diğer model sonuçlarına göre daha etkili performans sergilemiştir.




Şekil 4.34. SYİ24 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları

Bu model haricinde, M16 (NS: 0.8419, RMSE: 0.3971, r : 0.9197 değerleri ile) ve M13 (NS: 0.8406, RMSE: 0.3962, r : 0.9183 değerleri ile) de girdi yapıları ile etkili sonuçlar verdiği tespit edilmiştir. M16’nın girdi verisi; $t-1$ zamanına ait aylık toplam yağış verisi ve 5 aya kadar geciktirilmiş SYİ12 verisinden, M13 ise 4 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. T zamanına ait aylık maksimum sıcaklık verisi ve 5 aya kadar geciktirilmiş olan SYİ12 ile girdi verisi oluşturulan M20’nin performans değerleri NS: 0.8377, RMSE: 0.4024, r : 0.9162’dir. Bu model 6 aya kadar geciktirilmiş SYİ12 verisi ile oluşturulan M15’den (NS: 0.8346, RMSE: 0.4060, r : 0.9126 değerleri ile) daha etkili performans göstermiştir. M15 ile aynı girdi verisine sahip olup, $t+1$ zamanına ait çıktı verisine sahip olan M21’de NS: 0.6849, RMSE: 0.5597, r : 0.8360 değerleri hesaplanmıştır. Yine $t+1$ zamanına ait çıktı verisine sahip olan bir diğer model olan M22, NS: 0.6884, RMSE: 0.8360, r : 0.5566 değerleri ile M21’den performans olarak daha etkili olmuştur. 5 aya kadar geciktirilmiş SYİ12 indislerinden oluşturulmuş M14’de ise NS: 0.8318, RMSE: 0.4069, r : 0.9137 değerleri tespit edilmiştir. M23 ve M24’ün çıktı yapısı $t+2$ zamanına göre oluşturulmuş olup, M24 (NS: 0.5668, RMSE: 0.6525, r : 0.7684 performans değerleri ile), M23’den (NS: 0.5620, RMSE: 0.6577, r : 0.7665) daha iyi sonuç vermiştir. Bu sebeple $t+2$ zaman tahminlemelerinde kullanılacak model yapısında 7 aya kadar geciktirilmiş veri kullanılabileceği sonucuna ulaşılmıştır. 5 aya kadar geciktirilmiş SYİ12 verisinden ve

t zamanına ait olan aylık ortalama sıcaklık verisinden faydalanılarak oluşturulan M17 (NS: 0.8293, RMSE: 0.4100, r: 0.9128) modelinin, M14'e göre daha kötü performans sergilediği de tespit edilen bulgular arasındadır.

Şekil 4.35'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M13) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.35'de gösterilmiştir. Saçılma diyagramlarında da bu uyum sağlanmıştır.




Şekil 4.35. SYİ12 verisi için RO'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ9 verisi kullanılarak oluşturulan modeller incelendiği zaman (M25-M36 arası), NS: 0.8633, RMSE: 0.3644, r: 0.9334 performans değerleri ve t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulan M30, SYİ9'da en başarılı model olarak tespit edilmiştir. M30'dan sonra başarılı olan bir diğer model ise M25'tir. Bu modelin girdi yapısı, 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. M30 modelinde t zamanına ait olan meteorolojik veri olduğundan ötürü, bu model haricinde SYİ9'da en başarılı model M25'dir. M25'in performans değerleri NS: 0.7895, RMSE: 0.4513, r: 0.8894 şeklinde hesaplanmıştır. M28, M25'den sonra başarılı bulunan modeldir. Bu modelin performans değerleri NS: 0.7828, RMSE: 0.4555, r: 0.8868'dir. Girdi yapısı, 5 aya kadar geciktirilmiş SYİ9

verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Peşi sıra gelen M26 ise, 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. M26, NS: 0.7823, RMSE: 0.4597, r: 0.8862 performans değerleri ile başarılı olan modellerdendir. M32, M29, M31 modelleri sırasıyla, t zamanına ait aylık maksimum sıcaklık, aylık ortalama sıcaklık, aylık minimum sıcaklık ve hepsi 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Performans değerleri sırasıyla, NS: 0.7813, RMSE: 0.4570, r: 0.8873; NS: 0.7711, RMSE: 0.4673, r: 0.8785; NS: 0.7670, RMSE: 0.4717, r: 0.8783'dür. 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuş M27'nin performans değerleri NS: 0.7645, RMSE: 0.4687, r: 0.8772'dir. SYİ9'da indis verisinin geciktirilerek girdi verisinin fazlalaştırılması model sonuçlarını olumsuz yönde etkilemiştir. M34 ve M33'ün çıktı verisi t+1 zamanına ait olup, bu modellerin performans değerleri sırasıyla, NS: 0.5495, RMSE: 0.6438, r: 0.7497 ve NS: 0.4853, RMSE: 0.6881, r: 0.7070'dir. Model girdi yapısı olarak M34, t-1 zamanına ait aylık toplam yağış verisi ile 6 aya kadar geciktirilmiş SYİ9 verisinden, M33 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. T+1 zamanı için tahminlemelerde M34 modeli daha iyi sonuçlar vermiştir. M36 ve M35'de model çıktı yapısı zamanı t+2'dir. Sırasıyla, 6 ve 7 aya kadar geciktirilmiş SYİ9 verisi ile girdi yapısı oluşturulan M34 (NS: 0.2481, RMSE: 0.8338, r: 0.5256) ve M33 (NS: 0.2218, RMSE: 0.8483, r: 0.5055) performans olarak diğer modellerin gerisindedir.

Şekil 4.36'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M28) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.36'da gösterilmiştir.

6 aylık ardışık yağış toplamaları ile hesaplanan SYİ6'da ise (M37-M48 arası), başarılı performans sergileyen modeller M42, M44, M41, M43, M40'dır. M42, M41, M44, M43 modellerinin girdi yapısı t zamanına ait sırasıyla, aylık toplam yağış verisi, aylık ortalama sıcaklık, aylık maksimum sıcaklık, aylık minimum sıcaklık verisi ve farklı geciktirme zamanlarına ait SYİ6 verisinden oluşturulmuştur. T zamanına ait olan veri




Şekil 4.36. SYİ9 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları

kullanıldığından ötürü, bu modeller haricinde, yüksek performans değerlerine sahip olan (NS: 0.7572, RMSE: 0.4751, r: 0.8717) M40, SYİ6’da başarılı olan modellerdendir. M40’ın girdi yapısı, t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. M37 de M40’dan sonra başarılı olarak tespit edilen modeldir. Bu modelin performans değerleri NS: 0.7549, RMSE: 0.4892, r: 0.8691’dir. Model girdi yapısı 4 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Peşi sıra gelen M38’in girdi yapısı ise 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Performans değerleri NS: 0.7507, RMSE: 0.4944, r: 0.8671 olarak hesaplanmıştır. Yapılacak olan bir modelleme çalışmasında, t zamanına ait tahminlemelerde bu modellerden faydalanılabilir. M39 modelinin girdi yapısında 6 aya kadar geciktirilmiş SYİ6 verisi kullanılmış olup, 5 aya kadar geciktirilmiş olan modellere göre daha kötü bir performans sergilediği belirlenmiştir. Yapılacak olan bir modelleme çalışmasında SYİ6 indis girdi verisinin 5 aya kadar geciktirilmesi daha uygun olabilir. Çıktı verisinde t+1 zamanına ait olan modeller ise M46 ve M45’dir. Bu modellerin performans değerleri sırasıyla, NS: 0.5510, RMSE: 0.6455, r: 0.7461 ve NS: 0.5268, RMSE: 0.6627, r: 0.7285’dir. Performans değerleri incelendiği zaman, girdi yapısında 6 aya kadar geciktirilmiş SYİ6 verisi ile t-1 zamanına ait aylık toplam yağış içeren M46’nın, model girdi yapısında 6 aya kadar geciktirilmiş SYİ6 verisi içeren M45’e göre daha etkili sonuç

vermiştir. M48 ve M47'nin çıktı verisi $t+2$ zamanına ait olup, bu modellerin performans değerleri, sırasıyla, NS: 0.3967, RMSE: 0.7584, r : 0.6319 ve NS: 0.3520, RMSE: 0.7783, r : 0.5969'dur.

Şekil 4.37'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M40 ve M37) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.37'de gösterilmiştir.




Şekil 4.37. SYİ6 verisi için RO'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ3'ün girdi verisi olarak kullanıldığı modeller incelendiği zaman (M48-M60 arası), t zamanına ait girdi verisini içeren M54 ve M53 grubunda en başarılı iki modeldir. Performans değerleri sırasıyla, NS: 0.8273, RMSE: 0.3997, r : 0.9173 ve NS: 0.6827, RMSE: 0.5417, r : 0.8311'dir. Bu modeller haricinde, girdi yapısında t zamanına ait olmayan veri ile oluşturulmuş M52 de (NS: 0.6280, RMSE: 0.6906, r : 0.7004) en başarılı modellerden birisidir. M52'nin girdi yapısı 5 aya kadar geciktirilmiş SYİ3 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M55 (NS: 0.6212, RMSE: 0.5856, r : 0.7944) performans değerleri ile M52'den sonra başarılı bulunan modellerden birisidir. M55'in girdi yapısı 5 aya kadar geciktirilmiş SYİ3 verisi ile t zamanına ait minimum sıcaklık verisinden oluşturulmuştur. Girdi verisi 4

aya kadar geciktirilmiş SYİ3 verisi ile oluşturulan M49, performans olarak M55'den sonra gelmektedir. Fakat M49'un girdi yapısı, t-1 zamanına ait aylık toplam yağış ile 5 aya kadar geciktirilmiş SYİ3 değerlerinden oluşturulduğundan ve de girdi yapısında t zamanına ait veri içermediğinden dolayı, M55'e göre (NS: 0.5966, RMSE: 0.6112, r: 0.7763 performans değerleri ile) daha başarılı olarak kabul edilmiştir. Girdi yapısı M49 ile benzer nitelikte olan M50'nin performans değerleri NS: 0.5825, RMSE: 0.6214, r: 0.7657'dir. Bu iki modelin performans değerleri birbirine yakın olsa da, girdi yapısındaki farklılıklardan dolayı M49'un hesaplanan performans değerlerinin daha etkili olduğu tespit edilmiştir. 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulan M51'in performans değerleri NS: 0.5750, RMSE: 0.6211, r: 0.7617'dir. M51 hesaplanan performans değerleri ile başarılı modeller arasındadır. M58 ve M57'nin çıktı verisi t+1 zamanına ait olan veriden oluşturulmuştur. Bu modellerin performans değerleri sırasıyla, NS: 0.4797, RMSE: 0.6906, r: 0.7004 ve NS: 0.3193, RMSE: 0.7899, r: 0.5787'dir. Performans değerleri incelendiği zaman, girdi yapısında 6 aya kadar geciktirilmiş SYİ6 verisi ile t-1 zamanına ait aylık toplam yağış verisini içeren M58'in, model girdi yapısında 6 aya kadar geciktirilmiş SYİ6 verisi içeren M57'ye göre daha etkili sonuç vermiştir. M60 ve M59'un çıktı verisi t+2 zamanına ait olup, bu modellerin performans değerleri, sırasıyla, NS: 0.1799, RMSE: 0.8726, r: 0.4620 ve NS: 0.1679, RMSE: 0.8749, r: 0.4487'dir.

Şekil 4.38'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M52 ve M49) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.38'de gösterilmiştir.

RO ile yapılan analizlere ait sonuçlara önceki paragraflarda yer verilmiştir. Daha önceki makine öğrenme algoritmalarında olduğu gibi, RO algoritmasında da dalgacık dönüşümü uygulanmıştır. Dönüşümden sonraki modellere ait istatistik parametrelerin özeti Şekil 4.39'da gösterilmiştir. Şekil 4.39 incelendiğinde, dönüşüm öncesindeki bazı model sonuçlarının daha iyi olduğu ilk göze çarpan tespitler arasındadır. Dalgacık dönüşümü öncesi ve sonrası kıyaslandığında ise, dalgacık dönüşümünden sonra genellikle M49 ve sonraki modellerde, NS ve r değerlerinin dönüşüm öncesine göre



Şekil 4.38. SYİ3 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları

daha yüksek olduğu belirlenmiştir. Dikkat çeken başka bir bulgu ise, NS değerinin 0.43 ile 0.87 arasında, r değerinin de 0.65 ile 0.94 arasında olduğudur. Dalgacık dönüşümünden önceki değerlere nazaran daha dar bir aralıktadırlar (Çizelge 4.14).


Çizelge 4.14. Dalgacık dönüşümü ile RO analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.8645	0.3317	0.9312	M37	0.6719	0.5661	0.8304
M02	0.8594	0.3385	0.9272	M38	0.7023	0.5403	0.8516
M03	0.8503	0.3500	0.9245	M39	0.7649	0.4665	0.8821
M04	0.8425	0.3589	0.9245	M40	0.7729	0.4595	0.8960
M05	0.8508	0.3488	0.9228	M41	0.7019	0.5407	0.8542
M06	0.8444	0.3561	0.9225	M42	0.7188	0.5252	0.8693
M07	0.8275	0.3757	0.9129	M43	0.7543	0.4779	0.8779
M08	0.8364	0.3658	0.9182	M44	0.7534	0.4789	0.8782
M09	0.8149	0.3891	0.9032	M45	0.7168	0.5127	0.8538
M10	0.8213	0.3824	0.9097	M46	0.7619	0.4701	0.8904
M11	0.7919	0.4125	0.8903	M47	0.6794	0.5474	0.8321
M12	0.7955	0.4089	0.8921	M48	0.6639	0.5661	0.8237
SYİ12				SYİ3			
M13	0.7763	0.4694	0.8852	M49	0.7351	0.4952	0.8708
M14	0.7828	0.4625	0.8870	M50	0.7379	0.4923	0.8727
M15	0.7746	0.4739	0.8855	M51	0.7066	0.5161	0.8474
M16	0.7887	0.4591	0.8984	M52	0.7877	0.4390	0.8972
M17	0.7807	0.4647	0.8858	M53	0.7002	0.5265	0.8424
M18	0.8001	0.4436	0.9017	M54	0.7307	0.4990	0.8677
M19	0.7517	0.4977	0.8735	M55	0.7393	0.4861	0.8742
M20	0.7557	0.4937	0.8730	M56	0.7370	0.4886	0.8660
M21	0.7007	0.5455	0.8444	M57	0.6682	0.5515	0.8210

Çizelge 4.14 (devam). Dalgacık dönüşümü ile RO analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ12				SYİ3			
M22	0.7385	0.5099	0.8654	M58	0.6848	0.5375	0.8323
M23	0.6377	0.5982	0.8076	M59	0.6476	0.5693	0.8084
M24	0.6338	0.5999	0.8054	M60	0.6459	0.5734	0.8080
SYİ9							
M25	0.6664	0.5681	0.8212				
M26	0.6785	0.5587	0.8318				
M27	0.7135	0.5169	0.8508				
M28	0.7112	0.5251	0.8684				
M29	0.6698	0.5662	0.8325				
M30	0.6888	0.5497	0.8441				
M31	0.7016	0.5338	0.8458				
M32	0.7093	0.5269	0.8486				
M33	0.6644	0.5556	0.8177				
M34	0.6805	0.5421	0.8427				
M35	0.6137	0.5977	0.7848				
M36	0.6112	0.6041	0.7844				

DVM ve YSA’da dalgacık dönüşümleri model performanslarını olumlu yönde etkilerken, RO’da bazı modellerde bunun aksi yönünde sonuçlar alınmıştır. Dalgacık dönüşümünden sonraki model performanslarına daha detaylı bakılırsa, SYİ24 ile oluşturulan modellerde M01 ve M02’nin performans değerleri diğer modellere göre daha başarılı olduğu belirlenmiştir. Girdi yapıları sırasıyla, 4 aya kadar geciktirilmiş SYİ24 ve 5 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. M01’in dalgacık dönüşümünden önceki performans değerleri, NS: 0.9199, RMSE: 0.2550, r: 0.9592 şeklindeyken, dönüşümden sonra NS: 0.8645, RMSE: 0.3317, r: 0.9312’dir. M02’nin performans değerleri ise dalgacık dönüşümünden önce NS: 0.9215, RMSE: 0.2529, r: 0.9601 şeklindeyken, dalgacık dönüşümünden sonra NS: 0.8594, RMSE: 0.3385, r: 0.9272’dir. Her iki modelinde dalgacık dönüşümünden sonra performans değerleri gerilemiştir. Genellikle SYİ24’de dalgacık dönüşümü sonrasında model performans değerlerinde düşüşler meydana gelmiştir. Dalgacık dönüşümünden önce en yüksek performans değerleri M06’da hesaplanırken (NS: 0.9359, RMSE:0.2286, r: 0.9677), dalgacık dönüşümünden sonra M02’de hesaplanmıştır. M06’nın dalgacık dönüşümünden sonraki performans değerleri NS: 0.8444, RMSE: 0.3561, r: 0.9225’dir. Her ne kadar M06’nın girdi yapısında t zamanına ait aylık toplam yağış verisi kullanılsa da, dalgacık dönüşümünden sonra performans değerlerinde düşüşler gerçekleşmiştir. M01 ve M02’nin ise girdi yapısında tek tip veri olmasından ötürü dalgacık dönüşümünden sonra M06’dan daha iyi performans değerleri elde edilmiştir.




Şekil 4.39. Dalgacık dönüşümü sonrası RO analiz özet sonuçları

Dalgacık dönüşümü sonrasındaki en iyi performans M01’de tespit edilmiştir. Çıktı verisi t+1 zamanına ait olan modellerde ise, en etkili sonuç M10’da belirlenmiştir. Model yapısı 5 aya kadar geciktirilmiş SYİ24 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M10’un dalgacık dönüşümünden önceki performans değerleri NS: 0.8424, RMSE: 0.3592, r: 0.9185 şeklindeyken, dönüşümden sonra NS: 0.8213, RMSE: 0.3824, r: 0.9097’dir. Yine bu modelde de dalgacık dönüşümünden sonra, model performansının iyileşmediği belirlenmiştir. Çıktı verisi zamanı t+2 olan modellerde en etkili performans ise, M12’de tespit edilmiş olup, dönüşümden önceki performans değerleri, NS: 0.7752, RMSE: 0.4287, r: 0.8816 şeklindeyken, dönüşümden sonra NS: 0.7955, RMSE: 0.4089, r: 0.8921’dir. Dalgacık dönüşümü ile çıktı yapısı t+2 zamanına ait olan modellerde, iyileşmeler tespit edilmiştir.

Şekil 4.40’da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M01 ve M02) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.40’da gösterilmiştir.




Şekil 4.40. Dalgacık dönüşümü ile SYİ24 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ12’yi girdi yapısında kullanan modellerin performansları incelendiğinde (M13-M24 arası), çıktı verisi t zamanına ait modellerden, diğer modellere göre en etkili olan M18’dir. Yalnız bu modelin girdi yapısı 5 aya kadar geciktirilmiş SYİ12 verisi ile t zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri içermeyen ve bu modelin performans olarak arkasından gelen bir diğer model ise M16’dır. M16 gerek girdi yapısı (5 aya kadar geciktirilmiş SYİ12 ve $t-1$ zamanına ait aylık toplam yağış verisi) ile gerek de (NS: 0.7887, RMSE: 0.4591, r : 0.8984’lik) performans değerleri ile gurubunda ya da sınıfında en etkili modellerden birisidir. Dönüşümden önceki performans değerleri NS: 0.8419, RMSE: 0.3971, r : 0.9197 olan M16’nın dönüşümden sonraki değerlerinde gerileme ya da kötüleşme gerçekleşmiştir. Buna rağmen dalgacık analizi ile yapılacak bir çalışmada girdi yapısından faydalanılabilir. Çıktı yapısı $t+1$ zamana ait olan modellerde ise, en etkili olan M22’dir. M22’nin girdi yapısı, 6 aya kadar geciktirilmiş SYİ12 ile $t-1$ aya ait aylık toplam yağış verisinden oluşturulmuştur. M22’nin dönüşümden önceki performans değerleri NS: 0.6884, RMSE: 0.8360, r : 0.5566 şeklindeyken, dönüşümden sonra NS: 0.7385, RMSE: 0.5099, r : 0.8654’dür. Bu modelde dalgacık

dönüşümünden sonra iyileşme tespit edilmiştir. M14'ün 5 aya kadar geciktirilmiş SYİ12 verisiyle girdi yapısı oluşturulmuş olup, bu sınıfta NS: 0.7828, RMSE: 0.4625, r: 0.8870'lik performans değerleri ile başarılı modeller arasındadır.

Şekil 4.41'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M14) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.41'de gösterilmiştir.




Şekil 4.41. Dalgacık dönüşümü ile SYİ12 verisi için RO'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ9 ile oluşturulan modellerde (M25-M36), diğer modellere göre daha etkili performans gösteren model 6 aya kadar geciktirilmiş SYİ9 verisiyle oluşturulan M27'dir. M29, 4 ve 5 aya kadar geciktirilmiş veri ile oluşturulan sırasıyla M25 ve M26'ya göre daha etkili performans göstermiş olup, M27'nin dönüşümünden önceki performans değerleri NS: 0.7645, RMSE: 0.4687, r: 0.8772 şeklindeyken, dönüşümünden sonra NS: 0.7135, RMSE: 0.5169, r: 0.8508'dür. Bu modelde de performans değerlerinde dalgacık dönüşümünden sonra kötüleşme gerçekleşmiştir. M28, performans olarak M27'nin takipçisi niteliğindedir. Bu modelin performans değerleri NS: 0.7112, RMSE: 0.5251, r: 0.8684'dür. Girdi yapısı t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Çıktı

verisi $t+1$ zamanına ait olan modellerde ise, M34'ün M33'e göre daha iyi performans gösterdiği belirlenmiştir. M34'ün girdi yapısı 6 aya kadar geciktirilmiş SYİ9 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. M34'ün dönüşümden önceki performans değerleri NS: 0.5495, RMSE: 0.6438, r : 0.7497 şeklindeyken, dönüşümden sonra NS: 0.6805, RMSE: 0.5421, r : 0.8427'dür. Çıktı yapısı $t+2$ zamanına olan modellerde M35, M36'ya göre daha etkili sonuçlar vermiştir. M35'in dönüşümden önceki performans değerleri, NS: 0.2218, RMSE: 0.8483, r : 0.5055 şeklindeyken, dönüşümden sonra NS: 0.6137, RMSE: 0.5977, r : 0.7848'dür. Dalgacık dönüşümüyle bu modelde önemli derecede iyileştirmeler gerçekleştirilmiştir.

Şekil 4.42'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M27 ve M8) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.42'de gösterilmiştir.




Şekil 4.42. Dalgacık dönüşümü ile SYİ9 verisi için RO'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ6 verisinin girdi yapısında kullanıldığı modeller incelendiğinde (M37-M48 arası), M40'ın diğer modellere göre daha etkili olduğu tespit edilmiştir. M40'ın hem girdi yapısında t zamanına ait veri bulunmadığından hem de dönüşümden sonra NS: 0.7729, RMSE: 0.4595, r : 0.8960'lık performans değerleri ile bu kategoride en başarılı

modellerden birisidir. Bu modeli performans olarak takip eden diğer bir model ise, M39'dur. M39'un girdi yapısı 6 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Performans değerleri ise, NS: 0.7649, RMSE: 0.4665, r: 0.8821'dir. Bu iki model bu sınıf ya da kategoride en başarılı iki model olarak belirlenmiştir. Çıktı verisi t+1 zamanına ait olan modeller incelendiğinde, M46'nın performans olarak M45'in önünde olduğu belirlenmiştir. M46'nın M45'e göre farkı t-1 zamanına ait aylık toplam yağış verisini girdi olarak bünyesinde barındırmasıdır. M46'nın dönüşümden önceki performans değerleri, NS: 0.2218, RMSE: 0.8483, r: 0.5055 şeklindeyken, dönüşümden sonra NS: 0.7619, RMSE: 0.4701, r: 0.8904'dür. Çıktı verisi t+2 zamanına ait olan modellerde ise M47'nin M48'e göre etkili sonuçlar verdiği tespit edilen sonuçlar arasındadır. M47'nin dönüşümden önceki performans değerleri, NS: 0.3520, RMSE: 0.7783, r: 0.5969 şeklindeyken, dönüşümden sonra NS: 0.6794, RMSE: 0.5474, r: 0.8321'dür.


Şekil 4.43'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M40 ve M39) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.43'de gösterilmiştir.



Şekil 4.43. Dalgacık dönüşümü ile SYİ6 verisi için RO'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ3 verisini girdi yapısında kullanan modeller incelendiğinde (M49-M60 arası), 5 aya kadar geciktirilmiş SYİ3 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulan M52'nin diğer modellere daha etkili olduğu tespit edilmiştir. M52'nin dönüşümden önceki performans değerleri NS: 0.6280, RMSE: 0.5811, r: 0.7947 şeklindeyken, dönüşümden sonra NS: 0.7877, RMSE: 0.4390, r: 0.8972'dir. Dolayısıyla, yapılacak olan bir modelleme çalışmasında, M52'nin model girdi yapısından faydalanılabilir. M52'yi performans olarak M50 takip etmektedir. M50'nin girdi yapısı 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. M50'nin performans değerleri NS: 0.7379, RMSE: 0.4923, r: 0.8727'dir. M50'nin dalgacık dönüşümünden önceki performans değerleri NS: 0.5825, RMSE: 0.6214, r: 0.7657'dir. Dalgacık dönüşümünden sonraki değerlerine bakıldığında, dalgacık dönüşümünün bu modeller üzerine olumlu etki yaptığı belirlenmiştir. Çıktı verisi t+1 zamanına ait olan modellerden M58'in, M57'ye göre performans değerleri yüksektir. M58'in dönüşümden önceki performans değerleri, NS: 0.4797, RMSE: 0.6906, r: 0.7004 şeklindeyken, dönüşümden sonra NS: 0.6848, RMSE: 0.5375, r: 0.8323'dür. Çıktı verisi t+2 zamanına ait olan modellerde ise, M59'un M60'a göre daha etkili olduğu bulunan sonuçlardandır. M59'ın girdi yapısı 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olup, dönüşümden önceki performans değerleri, NS: 0.1679, RMSE: 0.8749, r: 0.4487 şeklindeyken, dönüşümden sonra NS: 0.6476, RMSE: 0.5693, r: 0.8084'dür.

Şekil 4.44'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M52 ve M50) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.44'de gösterilmiştir.



Şekil 4.44. Dalgacık dönüşümü ile SYİ3 verisi için RO’da en başarılı modellerin zaman serisi ve saçılma diyagramları

4.2.4. KA ile analiz sonuçları


Optimum alt ağaç sayısının, otomatik olarak belirlendiği KA metodu ile yapılan analizlere ait sonuçlar Çizelge 4.15’de gösterilmiştir. Elde edilen sonuçlar, diğer algoritmalarda (DVM, ANN, RO’da) olduğu gibi SYİ’nin farklı zaman adımlarına göre değerlendirilmiştir. Başarılı modeller kendi zaman adımlarında koyu renk ile gösterilmiştir. Kuraklıkların her bir zaman adımında, en başarılı iki modelin gözlem değerleri ile kıyaslanabilmesi için zaman serisi ve saçılma diyagramları gösterilmiştir.

Yapılan analiz sonucunda zaman adımına bağlı olarak performans değerlerinde değişiklikler tespit edilmiştir. Bu da zaman adımının azaldıkça, varyans değerlerine bağlı olarak performans değerlerinin azalması ile ilgidir. Bu sebeple, en başarılı sonuçlar yukarıda incelenen diğer algoritmalarda olduğu gibi SYİ24’de elde edilmiştir. KA’nın performans değerleri genel anlamda SVM’den geride, ANN ve RO ile hemen hemen aynı seviyededir. Daha detaylı incelemelere zaman adımına bağlı olarak ilerleyen kısımlarda yer verilmiştir.

Çizelge 4.15. KA ile analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.9175	0.2588	0.9580	M37	0.7335	0.5101	0.8577
M02	0.9210	0.2538	0.9598	M38	0.7331	0.5116	0.8569
M03	0.9170	0.2606	0.9578	M39	0.7178	0.5111	0.8491
M04	0.9169	0.2608	0.9578	M40	0.7202	0.5101	0.8503
M05	0.9210	0.2538	0.9598	M41	0.7387	0.5062	0.8631
M06	0.9378	0.2252	0.9685	M42	0.7960	0.4473	0.8960
M07	0.9157	0.2626	0.9572	M43	0.7189	0.5113	0.8492
M08	0.9169	0.2608	0.9578	M44	0.7058	0.5230	0.8468
M09	0.8329	0.3698	0.9133	M45	0.3654	0.7674	0.6411
M10	0.8329	0.3698	0.9133	M46	0.3783	0.7596	0.6528
M11	0.7542	0.4484	0.8713	M47	0.1551	0.8887	0.4774
M12	0.7456	0.4561	0.8664	M48	0.2152	0.8650	0.5132
SYİ12				SYİ3			
M13	0.8262	0.4138	0.9110	M49	0.4930	0.6852	0.7073
M14	0.8247	0.4155	0.9101	M50	0.4576	0.7082	0.6851
M15	0.8300	0.4115	0.9130	M51	0.4817	0.6859	0.7017
M16	0.8342	0.4067	0.9147	M52	0.4721	0.6923	0.7051
M17	0.8323	0.4064	0.9138	M53	0.5708	0.6300	0.7751
M18	0.8831	0.3392	0.9411	M54	0.7838	0.4471	0.8894
M19	0.8304	0.4113	0.9131	M55	0.4798	0.6872	0.7081
M20	0.8304	0.4113	0.9131	M56	0.4963	0.6762	0.7417
M21	0.6404	0.5979	0.8130	M57	0.2285	0.8409	0.5282
M22	0.6516	0.5885	0.8148	M58	0.3536	0.7697	0.6513
M23	0.5240	0.6857	0.7420	M59	0.1236	0.8979	0.4342
M24	0.5187	0.6878	0.7427	M60	0.0339	0.9471	0.3811
SYİ9							
M25	0.7613	0.4806	0.8749				
M26	0.7518	0.4909	0.8719				
M27	0.7525	0.4804	0.8738				
M28	0.7883	0.4496	0.8893				
M29	0.7574	0.4853	0.8750				
M30	0.8383	0.3963	0.9174				
M31	0.7655	0.4732	0.8774				
M32	0.7518	0.4869	0.8729				
M33	0.4892	0.6855	0.7161				
M34	0.5309	0.6569	0.7406				
M35	0.2062	0.8568	0.5096				
M36	0.1929	0.8703	0.4915				

Şekil 4.45 incelendiğinde, NS değerlerinin 0.03 ile 0.94, r değerlerinin ise 0.38 ile 0.97 arasında geniş bir ölçekte değiştiği görülebilmektedir. Genel olarak KA algoritmasının modelleri tahmin etmedeki performansını, çalışmada kullanılan diğer algoritmaların performansları ile karşılaştırıldığında diğerleri kadar yüksek olmadığı tespit edilen ilk bulgular arasındadır.




Şekil 4.45. Dalgacık dönüşümü öncesi KA analiz özet sonuçları

Model performansları incelendiğinde, SYİ24 ile girdi verisi oluşturulan modellerde (M01-M12 arası), M06, M02, M05, M01'in diğer modellere göre daha iyi sonuçlar verdiği Çizelge 4.15'de gösterilmiştir. M06'nın girdi yapısı, 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık toplam yağış verisinden, M05'in girdi yapısı 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık ortalama sıcaklık verisinden oluşturulmuştur. Bu iki modelin performans değerleri (M06 için; NS: 0.9378, RMSE: 0.2252, r: 0.9685, M05 için; NS: 0.9210, RMSE: 0.2538, r: 0.9598) birbirlerine oldukça yakındır. Modelleme çalışmalarında genellikle, çıktı zamanına ait veriden önceki zamanlara ait veri kullanılması tercih edilir. Dolayısıyla, bu modeller dışında M02 ve M01, KA ağaçları ile yapılacak olan bir modelleme çalışmasında kullanılması daha uygundur. M02'in girdi yapısı 5 aya kadar geciktirilmiş SYİ24 verisinden, M01'in girdi yapısı 4 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. Bu iki modelin performans değerleri sırasıyla; M02 için NS: 0.9210, RMSE: 0.2538, r: 0.9598 ve M01 için NS: 0.9175, RMSE: 0.2588, r: 0.9580'dir. Bir

diğer başarılı olan model ise, girdi yapısı M01 ve M02'ye benzeyen ve 6 aya kadar geciktirilmiş SYİ24 verisinden oluşturulan M03'dür. M03'ün performans değerleri, NS: 0.9170, RMSE: 0.2606, r: 0.9578 olarak hesap edilmiştir. M03, M02, M01 kıyaslandığında ise optimum olarak 5 ay geciktirmenin model sonucunu olumlu yönde etkilediği tespit edilmiştir. 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık maksimum ve minimum sıcaklıkları ile girdi verisi oluşturulan M08 ve M07'ye ait performans değerleri sırasıyla NS: 0.9169, RMSE: 0.2608, r: 0.9578 ve NS: 0.9157, RMSE: 0.2626, r: 0.9572'dir. M04'ün sonuçlarına bakıldığında, sadece SYİ24 verisi ile oluşturulan modellerin performans bakımından gerisinde kalmıştır. Performans değerleri NS: 0.9169, RMSE: 0.2608, r: 0.9578'dir. Bu sebeple, KA ile yapılacak olan bir modelleme çalışmasında, model girdileri oluşturulurken bu modellerin girdi yapılarından faydalanılabilir. M10 ve M09'un çıktı verisinde t+1 zamanına ait olan veri bulunmaktadır. Bu modellerin performans değerleri sırasıyla, NS: 0.8329, RMSE: 0.3698, r: 0.9133 ve NS: 0.8329, RMSE: 0.3698, r: 0.9133'dir. Performans değerleri incelendiği zaman, girdi yapısında 6 aya kadar geciktirilmiş SYİ24 verisi ve t-1 zamanına ait aylık toplam yağış içeren M10 ile model girdi yapısında 6 aya kadar geciktirilmiş SYİ24 verisi içeren M09'un sonuçları neredeyse aynıdır. M12 ve M11'in çıktı verisi t+2 zamanına ait olup, bu modellerin performans değerleri, sırasıyla, NS: 0.7456, RMSE: 0.4561, r: 0.8664 ve NS: 0.7542, RMSE: 0.4484, r: 0.8713'dür.

Şekil 4.46'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M02 ve M01) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, algoritmanın genellikle ezbere düştüğü Şekil 4.46'da gösterilmiştir.

SYİ12 verisinin girdi olarak kullanıldığı modeller incelendiğinde (M13-M24 arası), t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulan M18'in NS: 0.8831, RMSE: 0.3392, r: 0.9411'lik performans değerleri ile diğer modellere göre daha etkili sonuç verdiği tespit edilmiştir. Girdi yapısı t zamanına ait aylık ortalama sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulan M17'nin performansı, M18'e nazaran biraz geride kalmıştır. M17'nin




Şekil 4.46. SYİ24 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

performans değerleri NS: 0.8323, RMSE: 0.4064, r : 0.9138’dir. Bu modeller kadar başarılı olan fakat girdi yapısında t zamanına ait veri içermeyen diğer bir model ise M16’dır. M16’nın girdi yapısı 5 aya kadar geciktirilmiş SYİ12 ile $t-1$ zamanına aylık toplam yağış verisinden oluşturulmuş olup, performans değerleri NS: 0.8342, RMSE: 0.4067, r : 0.9147 olarak hesaplanmıştır. Yapılabilecek olan bir kuraklık modelleme çalışmasında, t zamanına ait verinin kullanılmasından ziyade geçmiş aylara ait verinin kullanılması, dolayısıyla model girdi yapılarında t zamanına ait verinin kullanılmaması daha uygundur. Bu kapsamda M16’nın girdi yapısından faydalanılabilir. Yine, girdi yapısı t zamanına ait minimum sıcaklık verisinden ve 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulan farklı bir model olan M19’un performans değerleri NS: 0.8304, RMSE: 0.4113, r : 0.9131’dir. M15 de, NS: 0.8300, RMSE: 0.4115, r : 0.3091 değerleri ile başarılı olan modellerden biridir. M15’in girdi yapısı 6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. Dolayısıyla, t zamanına ait veri içermediğinden ötürü modelleme çalışmalarında avantajlı olabilir. Peşi sıra gelen M13 ve M14’de, M15’in girdi yapısına benzer olarak oluşturulmuştur. Farkı, geciktirilmiş ay sayısıdır. Sırasıyla, 4 ve 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. Performans değerleri ise, NS: 0.8262, RMSE: 0.4138, r : 0.9110 ve NS: 0.8247, RMSE: 0.4155, r : 0.9101’dir. Girdi yapılarında t zamanına ait veri içermediğinden M23’den sonra başarılı olarak kabul edilen modellerdendir. M22 ve M21’in çıktı verisi zamanı $t+1$ ’dir. Bu modellerin performans değerleri sırasıyla,

NS: 0.6516, RMSE: 0.5885, r : 0.8148 ve NS: 0.6404, RMSE: 0.5979, r : 0.8130'dur. Girdi yapısı 6 aya kadar geciktirilmiş SYİ12 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulan M22'nin sonuçları ile, girdi yapısı 6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulan M21'in sonuçları arasında fazla bir fark bulunmamaktadır. M23 ve M24'ün çıktı verisi $t+2$ zamanına ait olup, bu modellerin performans değerleri, sırasıyla, NS: 0.5240, RMSE: 0.6857, r : 0.7420 ve NS: 0.5187, RMSE: 0.6878, r : 0.7427'dir.

Şekil 4.47'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M16 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, algoritmanın genellikle ezbere düştüğü Şekil 4.47'de gösterilmiştir.

SYİ9 verisinden yararlanılarak oluşturulan modeller incelendiğinde (M25-M36), yine daha önceki zaman adımlarında olduğu gibi, t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuş model olan M30'un diğer modellere göre daha etkili performans sergilediği tespit edilmiştir. Bu modelin performans değerleri NS: 0.8383, RMSE: 0.3963, r : 0.9174'dir. Bu model haricindeki,




Şekil 4.47. SYİ12 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ9 sınıfındaki en etkili model, girdi verisinde t zamanına ait veri içermeyen, t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisi ile oluşturulan M28'dir. M28, hem girdi yapısında t zamanına ait veri içermediğinden dolayı, hem de NS: 0.7883, RMSE: 0.4496, r: 0.8893'lük performans değerleri ile SYİ9'dan faydalanan bir modelleme çalışmasında kullanılabilir. T zamanına ait veri içeren farklı bir model olan M31'in girdi yapısı, t zamanına ait aylık minimum sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ9 şeklindedir. M32 de buna benzer bir girdi yapısı ile oluşturulmuş, t zamanına ait minimum sıcaklık yerine, maksimum sıcaklık kullanılmıştır. Bu iki model performanslarına bakıldığında M31'in performans değerleri; NS: 0.7655, RMSE: 0.4732, r: 0.8784, M32'in performans değerleri; NS: 0.7518, RMSE: 0.4869, r: 0.8729'dur. M31, M32'ye göre daha iyi performans göstermiş, t zamanına ait veri ile oluşturulacak bir modelleme çalışmasında kullanılması daha uygun olacağı sonucuna varılmıştır. M25 ve M26'nın model yapısı da birbirlerine benzer niteliktedir. Sırasıyla, model girdileri 4 ve 5 aya kadar geciktirilmiş olan SYİ9 verisi ile oluşturulmuştur. NS: 0.7613, RMSE: 0.4806, r: 0.8749'luk performans değerleri ile M25'in, NS: 0.7518, RMSE: 0.4909, r: 0.8719'luk değerlere sahip olan M26'ya göre daha etkili olduğu bulunan diğer sonuçlardandır. 6 aya kadar geciktirilmiş veri ile oluşturulan M27'nin ise performans değerleri NS: 0.7525, RMSE: 0.4804, r: 0.8738'dir. Tüm bu sonuçlardan dolayı, geciktirilmiş olan SYİ değerlerinin optimum düzeyde tutulması gerektiği sonucuna varılmıştır.

Şekil 4.48'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M28 ve M25) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, algoritmanın genellikle ezbere düştüğü Şekil 4.48'de gösterilmiştir.

SYİ6 verisi ile oluşturulan modeller incelendiğinde (M37-M48 arası), M42 ve M31 sırasıyla NS: 0.7960 RMSE: 0.4473, r: 0.8960 ve NS: 0.7387 RMSE: 0.5062, r: 0.8631'lık performans değerleriyle bu sınıfta en etkili olan modeller arasındadır. M42'nin girdi yapısı, 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait aylık toplam yağış verisinden, M41'in girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisi ile




Şekil 4.48. SYİ9 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

t zamanına ait aylık ortalama sıcaklık verisinden oluşturulmuştur. Bu modeller haricinde, M37 ve M38’in performans verisinin de etkili olduğu bulunmuştur. Sırasıyla performans değerleri, NS: 0.7335 RMSE: 0.5101, r: 0.8577 ve NS: 0.7331 RMSE: 0.5116, r: 0.8569’dur. Girdi yapısı ise, yine sırasıyla 4 aya kadar geciktirilmiş SYİ6 ve 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Bu modellerin girdi yapısında t zamanına ait veri olmadığından ötürü, yapılacak olan bir modelleme çalışmasında daha kullanışlı olabilir. Bu modellerden sonra, 5 aya kadar geciktirilmiş SYİ6 verisi ve t-1 zamanına ait aylık toplam yağış verisi ile oluşturulmuş olan M40 modelinin diğer modellere göre daha etkili olduğu belirlenmiştir (NS: 0.7202, RMSE: 0.5101, r: 0.8503). M43 ve M44 modellerinin girdi yapısında da t zamanına ait meteorolojik veri kullanılmıştır. Bu girdi yapısı sırasıyla, 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait minimum sıcaklık verisi ve 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait maksimum sıcaklık verisi şeklindedir. Bu iki modelin model performansları sırasıyla, NS: 0.7189 RMSE: 0.5113, r: 0.8492 ve NS: 0.7058 RMSE: 0.5230, r: 0.8486 olarak hesaplanmıştır. M43’ün M44’e göre daha etkili olduğu performans sonuçlarından anlaşılmaktadır. M39 modeli, SYİ6’nın 6 aya kadar geciktirilmesi oluşturulmuş olup, performans değerleri NS: 0.7178 RMSE: 0.5111, r: 0.8491’dir. M41 ve M42 ile kıyaslandığında, bu modellerin performans olarak gerisinde kaldığı hesap edilmiştir. Dolayısıyla, sadece SYİ6 verisi ile oluşturulacak olan bir modelleme çalışmasında, SYİ6 verisinin optimum düzeyde geciktirilmesinin

daha etkili olabileceği tespit edilmiştir. M46 ve M45'in çıktı yapısında t+1 zamanına ait veri kullanılmıştır. İki modelin performans değerleri, M46 için; NS: 0.3783 RMSE: 0.7596, r: 0.6528, M45 için; NS: 0.3654 RMSE: 0.7674, r: 0.8641'dir. Bu sonuçlardan da anlaşılacağı gibi M46, M45'e daha göre daha etkili sonuç vermiştir. Girdi yapılarındaki fark ise M46'nın t-1 zamanına ait aylık toplam yağış verisi içermesidir. Tüm bunlardan yola çıkarak, bu model yapısının, t+1 zamanına ait çıktı verisini içeren modelleme çalışmasında da kullanılabileceği sonucuna ulaşılmıştır.

Şekil 4.49'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M37 ve M38) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, algoritmanın genellikle ezbere düştüğü Şekil 4.49'da gösterilmiştir.

SYİ3'ün girdi verisi olarak kullanıldığı modellerde (M49-M60 arası), M54 ve M53 modelleri, sırasıyla t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ3 ve t zamanına ait aylık ortalama sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Bu modeller t zamanına ait veriyi içermesinden dolayı, diğer zaman adımlarındaki gibi diğer modellere göre daha etkili performans sergilemişlerdir.




Şekil 4.49. SYİ6 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

M54'ün performans değerleri; NS: 0.7838, RMSE: 0.4471, r: 0.8894, M53'ün performans değerleri; NS: 0.5708, RMSE: 0.6300, r: 0.7751'dir. Performans değerlerinden de anlaşılacağı gibi, t zamanına ait aylık ortalama sıcaklık verisinden ziyade, aylık toplam yağış verisi ile oluşturulan modelde daha etkili sonuçlar alınmıştır. M56, model girdi yapısı olarak M54 ve M53 modeline benzemektedir. Farklı olarak, t zamanına ait maksimum sıcaklık verisinden oluşturulmuştur. M54 ve M53'den sonra başarılı modeller arasında olup, performans değerleri NS: 0.4963, RMSE: 0.6762, r: 0.7417'dir. Bu modellerin çıktı yapısında t zamanına ait veri bulunmaktadır. Dolayısıyla, hem girdi yapısında hem de çıktı yapısında t zamanına ait veri bulunmasından ötürü, model sonuçları diğer modellere göre daha etkili çıkmıştır. Bundan farklı olarak, t-1 veya daha fazla geciktirme zamanına ait veriyi girdi yapısında içeren modelleri kullanmak daha anlamlı olmaktadır. Bu kapsamda, M49 ve M50'nin girdi yapısı sırasıyla 4 ve 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olup performans değerleri, NS: 0.4930, RMSE: 0.6852, r: 0.7073 ve NS: 0.4576, RMSE: 0.7082, r: 0.6851'dir. M49 performans değerleri ile M56'nın ardından gelmektedir. Fakat model girdi yapısından ötürü, yapılacak olan bir modelleme çalışmasında M49'un kullanılması daha uygun olacaktır. Ayrıca M49, M50'nin girdi yapısına göre daha az geciktirilmiş veri ile oluşturulmuş olup, M50'ye göre daha etkili sonuç vermiştir. Bu sebeple, SYİ3 geciktirilmiş ay sayısının optimum düzeyde tutulması gerektiği sonucuna varılmıştır. M51 modeli ise 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. NS: 0.4817, RMSE: 0.6859, r: 0.7017'lik performans değerleri ile M49'dan hemen sonra gelmektedir. Tüm bunlardan da anlaşılacağı gibi SYİ3 verisinin 4 aya kadar geciktirilmesi ile en ideal sonuç bulunmuştur. 5 ay kadar geciktirilmesiyle model performans değerleri kötüleşmektedir. 6 aya kadar geciktirilmesi ile biraz iyileşme olmasına rağmen, yine de 4 aylık performans değerleri yakalanamamıştır. M58 ve M57'nin çıktı yapısı t+1 zamanına ait veriden oluşturulmuştur. Bu iki modelin girdi yapısı ise, sırasıyla, 6 aya kadar geciktirilmiş SYİ3 verisi ile t-1 zamanına ait aylık toplam yağış verisi ve 6 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Performans değerleri ise, M58 için NS: 0.3536, RMSE: 0.7697, r: 0.6513, M57 için NS: 0.2285, RMSE: 0.8409, r: 0.5282'dir. Bu iki model kendi arasında kıyaslandığında, M58'in performans değerlerinin M57'ye göre daha iyi olduğu ve M52'den performans olarak geriden

geldiği tespit edilmiştir. M60 ve M59 modellerinin çıktıları ise $t+2$ zamanına aittir. Performans değerleri oldukça düşük olup, sırasıyla, NS: 0.0339, RMSE: 0.9471, r : 0.3811 ve NS: 0.1236, RMSE: 0.8979, r : 0.4342 şeklinde bulunmuştur.

Şekil 4.50’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M49 ve M51) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, algoritmanın genellikle ezbere düştüğü, tahmin değerlerini ardışık olarak aynı tahmin ettiği Şekil 4.50’de gösterilmiştir.


KA ile yapılan analiz neticesinde, tüm model sonuçları incelendiğinde model performans değerlerinin diğer algoritmaların performans değerlerine göre, daha geri kaldığı belirlenmiştir. Bu çalışmanın amaçlarından birisi, iyi olan model performanslarının daha da iyileştirmesi yönünde çözümler bulunmasıydı.



Şekil 4.50. SYİ3 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

Bu kapsamda, KA yapılan analiz sonuçlarında dalgacık dönüşümünden sonra model performans değerlerinde iyileştirmeler tespit edilememiştir. Analiz edilen tüm modellere ait özet niteliğinde görsel Şekil 4.51’de gösterilmiştir. Şekil 4.51 incelendiğinde, NS değerlerinin 0.58 ile 0.79, r değerlerinin ise 0.73 ile 0.90 arasında

geniş bir ölçekte değiştiği görülebilmektedir. Diğer algoritmalar ile kıyaslandığında, DVM, YSA ve RO'dan daha kötü bir performans ortaya koyduğu, tespit edilen ilk bulgulardandır.



Şekil 4.51. Dalgacık dönüşümü sonrası KA analiz özet sonuçları

Çizelge 4.16'da ise KA'nın dalgacık dönüşümü ile yapılan tüm modellere ait analiz sonuçları gösterilmiştir. SYİ24'de diğer modellere göre en başarılı modeller M01 ve M05 olarak tespit edilmiştir. Bu modellerin girdi yapısı sırasıyla 4 aya kadar geciktirilmiş SYİ24 verisinden ve 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık ortalama sıcaklık verisinden oluşturulmuştur. Bu modellerin yine sırasıyla performans değerleri NS: 0.7881, RMSE: 0.4147, r: 0.8990 ve NS: 0.7633, RMSE: 0.4393, r: 0.8759'dur. Bu modelleri performans olarak NS: 0.7523, RMSE: 0.4501, r: 0.8790 ve NS: 0.7464, RMSE: 0.4546, r: 0.8793'lük performans değerleri ile sırasıyla M04 ve M02 takip etmektedir. Bu modellerinde girdi yapısı ise, M04 t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ24 verisinden, M02 5 aya


kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. Başarılı modeller arasından M05'in girdi yapısında t zamanına ait meteorolojik veri kullanımının model sonucunu olumlu yönde etkilediği tespit edilmiştir. Girdi yapısında t zamanına ait veri içermeyen M01 ve M04 ise başarılı bulunan modellerdendir. Bu modeller SYİ24 ile yapılacak olan bir modelleme çalışmasında tercih edilebilir.

Çizelge 4.16. Dalgacık dönüşümü ile KA analiz sonuçları

Model	NS	RMSE	r	Model	NS	RMSE	r
SYİ24				SYİ6			
M01	0.7881	0.4147	0.8990	M37	0.3929	0.7701	0.6526
M02	0.7464	0.4546	0.8793	M38	0.4320	0.7464	0.6967
M03	0.6032	0.5697	0.8180	M39	0.5111	0.6727	0.7693
M04	0.7523	0.4501	0.8790	M40	0.5517	0.6456	0.7500
M05	0.7633	0.4393	0.8759	M41	0.4909	0.7066	0.7283
M06	0.7371	0.4629	0.8604	M42	0.4194	0.7546	0.6714
M07	0.7436	0.4580	0.8716	M43	0.5848	0.6214	0.7933
M08	0.6917	0.5022	0.8438	M44	0.5739	0.6295	0.7884
M09	0.6784	0.5130	0.8462	M45	0.5325	0.6587	0.7593
M10	0.7141	0.4836	0.8505	M46	0.4907	0.6875	0.7363
M11	0.7050	0.4912	0.8581	M47	0.5235	0.6674	0.7448
M12	0.6931	0.5009	0.8473	M48	0.4307	0.7367	0.6919
SYİ12				SYİ3			
M13	0.4890	0.7094	0.7343	M49	0.5074	0.6754	0.7461
M14	0.5725	0.6488	0.8122	M50	0.5208	0.6657	0.7598
M15	0.5725	0.6527	0.8402	M51	0.4924	0.6788	0.7213
M16	0.4882	0.7145	0.7163	M52	0.6394	0.5721	0.8042
M17	0.4188	0.7565	0.7847	M53	0.4880	0.6881	0.7232
M18	0.6173	0.6138	0.8033	M54	0.4579	0.7080	0.6976
M19	0.5755	0.6507	0.7909	M55	0.4153	0.7280	0.6798
M20	0.4336	0.7517	0.6966	M56	0.4515	0.7056	0.7273
M21	0.4290	0.7534	0.7671	M57	0.4142	0.7328	0.7057
M22	0.3851	0.7819	0.7161	M58	0.5293	0.6568	0.7361
M23	0.2137	0.8813	0.6556	M59	0.3839	0.7528	0.6655
M24	0.3720	0.7856	0.7464	M60	0.4795	0.6952	0.7237
SYİ9							
M25	0.4297	0.7429	0.6973				
M26	0.4081	0.7581	0.6754				
M27	0.4474	0.7179	0.7123				
M28	0.2753	0.8320	0.6072				
M29	0.3436	0.7983	0.6480				
M30	0.4060	0.7594	0.6787				
M31	0.3971	0.7588	0.7115				
M32	0.3830	0.7677	0.7356				
M33	0.4548	0.7082	0.7193				
M34	0.3278	0.7863	0.6274				
M35	0.3788	0.7579	0.7042				
M36	0.2655	0.8303	0.6931				

Girdi yapısı t zamanına ait aylık minimum sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ24 verisinden oluşturulan M07'nin performans değerleri NS: 0.7436, RMSE: 0.4580, r : 0.8716'dır. M06 bu modeli performans olarak hemen arkasından gelmektedir. M06'nın performans değerleri NS: 0.7371, RMSE: 0.4629, r : 0.8604'dür. Bu modelin girdi yapısı t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. M06'nın hemen ardından çıktı zamanları $t+1$ ve $t+2$ olan M10 ve M11 modeli gelmektedir. Bu modellerin sırasıyla performans değerleri NS: 0.7141, RMSE: 0.4836, r : 0.8505 ve NS: 0.7050, RMSE: 0.4912, r : 0.8581'dir. Çıktı zamanı $t+2$ olan ve 7 ay kadar geciktirilmiş SYİ24 verisinden oluşturulan M12'nin performans değerleri ise NS: 0.6931, RMSE: 0.5009, r : 0.8473'dür.

SYİ24 verisinin girdi yapısında bulundurulmuş modeller ile yapılan analiz neticesinde en başarılı modeller M01 ve M05 olarak tespit edilmiştir. Fakat M05'in girdi verisinde t zamanına ait veri kullanılmasından ötürü, modelleme çalışmalarında tercih edilmeyebilir. Dolayısıyla, bu model yerine M04'ün tercih edilmesi daha yararlı olacaktır. Bu iki modele ait saçılma grafiği ve zaman serisi Şekil 4.51'de gösterilmiştir.




Şekil 4.52. Dalgacık dönüşümü ile SYİ24 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

Şekil 4.52'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M04 ve M01) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği ve modellerin genellikle ezbere düştüğü Şekil 4.52’de gösterilmiştir.

SYİ12’nin girdi verisi olarak kullanıldığı modeller (M13-M24 arası) incelendiğinde, M18 ile M19’un performans değerleri diğer modellere göre daha etkili olduğu bulunmuştur. Bu modellerin girdi yapıları sırasıyla, t zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden ve t zamanına ait aylık minimum sıcak verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. Bu modeller için performans değerleri ise, M18 için NS: 0.6173, RMSE: 0.6138, r: 0.8033, M19 için NS: 0.5755, RMSE: 0.6507, r: 0.7909 olarak hesaplanmıştır. Bu modelleri performans olarak M14 (NS: 0.5725, RMSE: 0.6488, r: 0.8221) ve M15 (NS: 0.5725, RMSE: 0.6527, r: 0.8402) takip etmektedir. Bu modellerin girdi yapısı sırasıyla, 5 ve 6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. Burada en dikkat çekici sonuçlardan birisi bu iki modelin de girdi yapısında t zamanına ait veri bulunmamasıdır. SYİ12 ile yapılacak olan bir modelleme çalışmasında bu modellerin girdi yapılarından faydalanılabilir. Bu modellerin yine girdi yapısında t zamanına ait veri içermeyen M13 ve M16 takip etmektedir. M13’ün girdi yapısı 4 aya kadar geciktirilmiş SYİ12 verisinden, M16’nın girdi yapısı ise t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. M13 için NS: 0.4890, RMSE: 0.7094, r: 0.7343, M16 için NS: 0.4882, RMSE: 0.7145, r: 0.7163’lük performans değerleri hesap edilmiştir. SYİ12 verisini girdi yapısında bulunduran modeller ile yapılan analiz neticesinde en başarılı modeller M18 ve M19 olarak tespit edilmiştir. Fakat bu iki modelin girdi verisinde t zamanına ait veri kullanılmasından ötürü, modelleme çalışmalarında tercih edilmeyebilir. Dolayısıyla, bu model yerine M14 ile M15’in tercih edilmesi daha yararlı olacaktır. Bu iki modele ait saçılma grafiği ve zaman serisi Şekil 4.52’de gösterilmiştir.


Şekil 4.53’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M14 ve M15) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği ve modellerin genellikle ezbere düştüğü Şekil 4.53’de gösterilmiştir.



Şekil 4.53. Dalgacık dönüşümü ile SYİ12 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

SYİ9’un girdi verisi olarak kullanıldığı modeller incelendiğinde (M25-M36 arası), M33 (NS: 0.4548, RMSE: 0.7082, r : 0.7193) ve M27 (NS: 0.4474, RMSE: 0.7179, r : 0.7123)’un diğer modellere göre performans değerleri yüksektir. Bu modellerinde girdi yapısı 6 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Bu modellerin her ne kadar girdi yapısı aynı olsa da, çıktı yapısındaki zamanları sırasıyla $t+1$ ve t ’dir. M33’ün bu sınıfta yüksek performans gösterdiği bulunan sonuçlar arasında en dikkat çekici olanıdır. Bu modellerin girdi yapısı sırasıyla, 4 ve 5 ayak kadar geciktirilmiş SYİ9 verisinden oluşturulmuş M25 ve M26 takip etmektedir. M25 için NS: 0.4297, RMSE: 0.7429, r : 0.6973 ve M26 için NS: 0.4081, RMSE: 0.7581, r : 0.6754 performans değerleri hesaplanmıştır. SYİ9 verisini girdi yapısında bulundurulmuş modeller ile yapılan analiz neticesinde en başarılı modeller M33 ve M27 olarak tespit edilmiştir. Bu iki modele ait saçılma grafiği ve zaman serisi Şekil 4.53’de gösterilmiştir.

Şekil 4.54’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M33 ve M27) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği ve modellerin genellikle ezbere düştüğü Şekil 4.54’de gösterilmiştir.




Şekil 4.54. Dalgacık dönüşümü ile SYİ9 verisi için KA’da en başarılı modellerin zaman serisi ve saçılma diyagramları

Diğer bir girdi verisi olan SYİ6 ile oluşturulan modeller incelendiğinde (M37-M48 arası), girdi verisi t zamanına ait aylık maksimum sıcaklık ile 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulan M43’ün performansı diğer modellere göre daha etkili olmuştur. Bu modelin performans değerleri NS: 0.5848, RMSE: 0.6214, r: 0.7933’dür. Bu modeli performans olarak M44 takip etmektedir. Girdi verisi olarak M43 ile farklı aylık maksimum sıcaklık yerine minimum sıcaklık verisinden oluşturulmuş olmasıdır. M44’ün performans değerleri ise, NS: 0.5739, RMSE: 0.6295, r: 0.7884’dür. Bu iki modelinde girdi yapısında t zamanına ait meteorolojik veri olmasından ötürü, model performanslarının etkili olduğu belirlenmiştir. M40 ise bu modellerin girdi yapısından biraz farklıdır. Girdi yapısı t-1 zamanına aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Bu modelin performans değerleri ise NS: 0.5517, RMSE: 0.6456, r: 0.7500’dır. SYİ6 verisinin girdi yapısında bulundurulmuş modeller ile yapılan analiz neticesinde en başarılı modeller M43 ve M44 olarak tespit edilmiştir. Fakat, bu modellerin girdi verisinde t zamanına ait veri kullanılmasından ötürü, modelleme çalışmalarında tercih edilmeyebilir. Dolayısıyla, bu model yerine M40 ve M45’in tercih edilmesi daha yararlı olacaktır. Bu iki modele ait saçılma grafiği ve zaman serisi Şekil 4.54’de gösterilmiştir.

Bu sınıfta performans olarak başarılı bulunan bir diğer model ise, M45’dir. Bu modelin girdi yapısı 6 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Bu modeldeki

en önemli farklılık ise, çıktı zamanının $t+1$ olmasıdır. Bu rağmen diğer modellere göre performans değerleri (NS: 05325, RMSE: 06587, r : 0.7593) daha iyidir. Girdi yapısı 6 aya kadar geciktirilmiş SYİ6 verisinden oluşturulan ve çıktı zamanı $t+2$ olan M47 performans olarak M45'i takip etmektedir. Bu modelin performans değerleri NS: 0.5235, RMSE: 6674, r : 07448'dir.




Şekil 4.55. Dalgacık dönüşümü ile SYİ6 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

Şekil 4.55'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M40 ve M45) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği ve modellerin genellikle ezbere düştüğü Şekil 4.55'de gösterilmiştir.

Girdi yapısında SYİ3'ün kullanıldığı modeller incelendiğinde ise (M48 ile M60 arası), bu sınıfta ya da kategoride en etkili performans gösteren modeller M52 ile M58'dir. M52'nin girdi yapısı $t-1$ zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuş olup, performans değerleri NS: 0.6394, RMSE: 0.5721, r : 0.8042 şeklindedir. M58 ise aynı girdi yapısına sahip olup, çıktı yapısının girdi zamanı $t+1$ 'dir. Buna rağmen, çıktı yapısı zamanı t olan diğer modellere göre daha iyi performans sergilemiştir. M58'in performans değerleri NS: 0.5293, RMSE: 0.6568, r : 0.7361'dir. M50 performans olarak M60'ın takipçidir. M50'nin girdi yapısı 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Bu modelin

performans değerleri NS: 0.5208, RMSE: 0.6657, r: 0.7598'dir. Yine girdi yapısı M50 ile benzerlik gösteren M49'da başarılı olarak kabul edilen ve M50'yi performans olarak takip eden modeldir. Bu modelin girdi yapısı 4 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Performans değerleri, NS: 0.5074, RMSE: 0.6754, r: 0.7461'dir. SYİ3 verisinin girdi yapısında bulunduran modeller ile yapılan analiz neticesinde en başarılı modeller M52 ve M58 olarak tespit edilmiştir. Bu iki modele ait saçılma grafiği ve zaman serisi Şekil 4.55'de gösterilmiştir.




Şekil 4.56. Dalgacık dönüşümü ile SYİ3 verisi için KA'da en başarılı modellerin zaman serisi ve saçılma diyagramları

Şekil 4.56'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M52 ve M58) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği ve modellerin genellikle ezbere düştüğü Şekil 4.56'da gösterilmiştir.

4.3. Yağış-akış Tahmin Modelleri

Çalışmanın bu kısmında çıktı verisi akış değeri olan tahmin modelleri kurulmuştur. Farklı zamanlara ait SYİ, AKİ, yağış ve akış değerlerinden yararlanılarak Matlab programı ile aylık ortalama akış değerlerini tahmin etmek için çeşitli modeller oluşturulmuştur. Kuraklık tahmin modellerinde olduğu gibi, literatürde genellikle oluşturulan modeller için tüm verinin %70'i öğrenme, %30'u test amacıyla kullanılmaktadır. Dolayısıyla, çalışmanın bu kısmında öğrenme oranı %70 olarak

belirlenmiştir. AKİ ve SYİ'nin 3 ve 12 aylık zaman periyodunun, sırasıyla, tarımsal ve hidrolojik kuraklığı daha iyi temsil ettiği yapılan çalışmalarda yer almaktadır (Mohammed vd., 2022). Dolayısıyla SYİ3, SYİ12, AKİ3 ve AKİ12 hesaplamalarından elde edilen indis değerleri modellerin girdi yapısında kullanılmıştır. SYİ'e ait kuraklık hesaplamalarına Bölüm 4.1'de değinilmiştir. Bu kısımda AKİ analizleri ve sonuçlarından detaylıca bahsedilmiş olup, kullanılan indis değerlerinin zamana göre değişimi grafikler halinde sunulmuştur.




Şekil 4.57. AKİ1 indis değerlerinin zaman serisi

Akış değerlerinin ardışık 1 aylık toplamaları ile oluşturulan AKİ1 değerlerinin zamana göre dağılımı Şekil 4.57'de gösterilmiştir. Şekil 4.57 incelendiğinde, 10-2001 tarihinde indis değeri kuraklık kategorisinde zirve noktalarından birine, 4-2002 tarihinde de sulak kategorisinde zirve noktalarından birine ulaşmıştır. 5-1974 ile 5-1976 tarihlerinde sulak kategorisinde peşi sıra, zirve noktaları tespit edilmiştir. AKİ1 indis değerleri kuraklık sınıfında en fazla aşırı kurak, sulak sınıfında en fazla aşırı sulak sınıflarına erişmiştir.


Şekil 4.58'de ise, 3 aylık akış değerlerinin ardışık toplamı ile elde edilen AKİ3'ün zamana göre indis değerlerinin değişimi gösterilmiştir. En büyük kuraklık 1-1975 ve 10-2001 tarihlerinde “şiddetli kuraklık” sınıfı olarak tespit edilmiştir. Sulak dönemde ise çeşitli dönemlerde (6-1974, 11-1975, 7-1976 ve 5-2002) “aşırı sulak” sınıfı

görülmüş olup bunlar arasındaki en büyük sulak dönem 5-2002'dir. AKİ3 indis değerleri kuraklık sınıfında en fazla şiddetli kurak, sulak sınıfında en fazla aşırı sulak sınıflarına erişmiştir.



Şekil 4.58. AKİ3 indis değerlerinin zaman serisi


AKİ6 indis sonuçları incelendiğinde ise, 5-1975 ile 12-1976 tarihleri arasında uzun bir sulak dönem yaşandığı, akabinde bu dönem kadar uzun olmasa da başka bir sulak dönemin de 1-2002 ile 10-2002 tarihleri arasında yaşandığı belirlenmiştir. Ayrıca, sulak dönemde zirve değerlerinden birine 6-2002 tarihinde rastlanmıştır. AKİ6'da kurak dönemlerde indis değerinin -2 ve altına (aşırı kurak) inmediği Şekil 4.59'da



Şekil 4.59. AKİ6 indis değerlerinin zaman serisi


görülmektedir. Kuraklık kategorisinde en düşük indis değerine 1-1975, sonraki en düşük değere 10-2001 tarihinde ulaşılmıştır. AKİ6 indis değerleri kuraklık sınıfında en fazla şiddetli kurak, sulak sınıfında en fazla aşırı sulak sınıflarına erişmiştir.

1-1975 ile 6-1976 tarihleri arasında sulak bir dönem tespit edilen AKİ12’de, zirve noktalarından biri bu dönemde (11-1975’de) belirlenmiştir (Şekil 4.60). Farklı olarak 11-2002 tarihinden zirve noktalarından birisi daha tespit edilmiştir. Kurak dönemlerde ise 7-2013 ile 4-2015 tarihleri arasında tespit edilen zirve noktalarının (12-2013, 9-2014,) da içinde bulunduğu uzun kurak bir periyod hesap edilmiştir. AKİ12 indis değerleri kuraklık sınıfında en fazla aşırı kurak, sulak sınıfında en fazla aşırı sulak sınıflarına erişmiştir.



Şekil 4.60. AKİ12 indis değerlerinin zaman serisi

Model girdi verisi oluşturulurken model çıkış parametresine göre, model sonucuna en iyi etki edecek olan girdi verisi çapraz korelasyon ile belirlenmiştir (Şekil 4.61). Ayrıca, girdi yapısı oluşturulurken, çıktı yapısı yani akış değerlerine etki edeceği düşünülerek, bazı unsurlar göz önünde bulundurulmuştur.



Şekil 4.61. Yağış akış tahmin modelleri çapraz korelasyon örnekleri a) AKİ, b) Yağış

Bu unsurlar, yağışların ve geçmiş aylardaki yağış değerlerini tahmin ayındaki akışları etkileyebileceği; yağışların, akışların ve geçmiş aylardaki bu değerlerin tahmin ayındaki akışları etkileyebileceği; tarımsal ve hidrolojik kuraklıkların ve geçmiş aylardaki bu değerlerin tahmin ayındaki akışları etkileyebileceği; bu değerlerin kombinasyonunun tahmin ayındaki akışları etkileyebileceği şeklindedir. Bu unsurlar doğrultusunda, model girdi verisi olarak Çizelge 4.17'deki veri, her modelde ifade edildiği şekilde kullanılarak toplam 38 adet model oluşturulmuştur. Oluşturulan modellerden ilk 29 adedi t zamanına (1 ay sonraya) ait akım verisini tahmin için kullanılırken, sonraki 9 adet model $t+1$ anına (2 ay sonrasına ait) akım verisini tahmin için kullanılmıştır. 2 ay sonrasına ait tahminlemeler yapılan model sayıları algoritma performansına göre değişiklik gösterebilmektedir. Bu sebeple, model toplam sayıları M29'dan sonra farklılık gösterebilir.

Çizelge 4.17. Yağış-akış tahmininde oluşturulan modeller

Modeller		Girdiler					Çıktı
M01	$TY_{(t)}$	$TY_{(t-1)}$					$Q_{(t)}$
M02	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$				$Q_{(t)}$
M03	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$			$Q_{(t)}$
M04	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$TY_{(t-4)}$		$Q_{(t)}$
M05	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$TY_{(t-4)}$	$TY_{(t-5)}$	$Q_{(t)}$
M06	$TY_{(t)}$	$TY_{(t-1)}$	$Q_{(t-1)}$				$Q_{(t)}$
M07	$TY_{(t-1)}$	$Q_{(t-1)}$					$Q_{(t)}$
M08	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t-2)}$		$Q_{(t)}$
M09	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t)}$
M10	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t)}$
>>	$Q_{(t-3)}$						
M11	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t)}$
>>	$Q_{(t-2)}$						
M12	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t)}$

Çizelge 4.17 (devam). Yağış-akış tahmininde oluşturulan modeller

Modeller	Girdiler						Çıktı
>>	$Q_{(t-2)}$	$AKİ12_{(t-1)}$	$AKİ12_{(t-2)}$				
M13	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t)}$
>>	$Q_{(t-3)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$SYİ12_{(t-3)}$			
M14	$TY_{(t)}$	$SYİ3_{(t)}$					$Q_{(t)}$
M15	$TY_{(t)}$	$SYİ3_{(t)}$	$Q_{(t-1)}$				$Q_{(t)}$
M16	$TY_{(t)}$	$SYİ3_{(t)}$	$Q_{(t-1)}$	$AKİ3_{(t-1)}$			$Q_{(t)}$
M17	$TY_{(t-1)}$	$SYİ3_{(t-1)}$	$Q_{(t-1)}$	$AKİ3_{(t-1)}$			$Q_{(t)}$
M18	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-2)}$	$SYİ3_{(t-3)}$	$Q_{(t)}$
M19	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-2)}$	$SYİ3_{(t-3)}$	$Q_{(t)}$
>>	$Q_{(t-1)}$						
M20	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-2)}$	$SYİ3_{(t-3)}$	$Q_{(t)}$
>>	$Q_{(t-1)}$	$Q_{(t-2)}$					
M21	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-2)}$	$SYİ3_{(t-3)}$	$Q_{(t)}$
>>	$Q_{(t-1)}$	$Q_{(t-2)}$	$AKİ3_{(t-1)}$	$AKİ3_{(t-2)}$			
M22	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$TY_{(t-4)}$	$TY_{(t-12)}$	$SYİ3_{(t-1)}$	
>>	$SYİ3_{(t-3)}$	$SYİ3_{(t-12)}$	$SYİ12_{(t-1)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$AKİ3_{(t-1)}$	$Q_{(t)}$
>>	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{(t-1)}$	$AKİ12_{(t-6)}$			
M23	$TY_{(t-12)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-12)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$AKİ3_{(t-1)}$	$Q_{(t)}$
>>	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{(t-1)}$				
M24	$TY_{(t-1)}$	$TY_{(t-12)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-12)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t)}$
>>	$AKİ3_{(t-1)}$	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{(t-1)}$			
M25	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t-4)}$	$Q_{(t-5)}$		$Q_{(t)}$
M26	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t-4)}$	$Q_{(t-5)}$	$Q_{(t-6)}$	$Q_{(t)}$
M27	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$TY_{(t-4)}$	$TY_{(t-5)}$	$Q_{(t)}$
M28	$SYİ3_{(t)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-2)}$	$SYİ3_{(t-3)}$	$SYİ3_{(t-4)}$		$Q_{(t)}$
M29	$SYİ12_{(t)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$SYİ12_{(t-3)}$	$SYİ12_{(t-4)}$		$Q_{(t)}$
M09t1	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t+1)}$
M10t1	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t+1)}$
>>	$Q_{(t-3)}$						
M12t1	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$Q_{(t-1)}$	$Q_{(t+1)}$
>>	$Q_{(t-2)}$	$AKİ12_{(t-1)}$	$AKİ12_{(t-2)}$				
M13t1	$TY_{(t)}$	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	Q_{t-1}	$Q_{(t-2)}$	$Q_{(t+1)}$
>>	$Q_{(t-3)}$	$SYİ12_{(t-1)}$	$SYİ12_{(t-2)}$	$SYİ12_{(t-3)}$			
M22t1	$TY_{(t-1)}$	$TY_{(t-2)}$	$TY_{(t-3)}$	TY_{t-4}	$TY_{(t-12)}$	$SYİ3_{(t-1)}$	
>>	$SYİ3_{(t-3)}$	$SYİ3_{(t-12)}$	$SYİ12_{(t-1)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$AKİ3_{(t-1)}$	$Q_{(t+1)}$
>>	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{t-1}$	$AKİ12_{(t-6)}$			
M23t1	$TY_{(t-12)}$	$SYİ3_{t-1}$	$SYİ3_{(t-12)}$	Q_{t-1}	$Q_{(t-2)}$	$AKİ3_{(t-1)}$	$Q_{(t+1)}$
>>	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{(t-1)}$				
M24t1	TY_{t-1}	$TY_{(t-12)}$	$SYİ3_{(t-1)}$	$SYİ3_{(t-12)}$	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t+1)}$
>>	$AKİ3_{(t-1)}$	$AKİ3_{(t-3)}$	$AKİ3_{(t-6)}$	$AKİ12_{(t-1)}$			
M25t1	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t-4)}$	$Q_{(t-5)}$		$Q_{(t+1)}$
M26t1	$Q_{(t-1)}$	$Q_{(t-2)}$	$Q_{(t-3)}$	$Q_{(t-4)}$	$Q_{(t-5)}$	$Q_{(t-6)}$	$Q_{(t+1)}$
TY : Aylık toplam yağış Q : Aylık ortalama akış							


Model yapısı oluşturulduktan sonra, her bir model farklı öğrenme algoritmaları ile analiz edilmiştir. Analiz sonucunda, diğer modellere göre etkili olan modellerin, çıktı zamanı +1 ay ileriye taşınarak da, bu zamandaki performans değerleri incelenmiştir. Bu modelleri diğer modeller ile ayırt edebilmek amacıyla, girdi yapısındaki adlarının yanlarına “t1” ifadesi eklenmiştir. Model girdi verisi belirlendikten sonra, tüm

modeller makine öğrenme algoritmaları ile analiz edilmiştir. İlerleyen kısımlarda, öğrenme algoritmalarına göre model performansları incelenmiştir. Ayrıca, kuraklık tahmin modellerindeki başarılı modellerden ikisine (M28, M29) bu kısımda da yer verilmiştir.

4.3.1. DVM ile analiz sonuçları

DVM ile analiz yapılırken, algoritma ($\mathcal{E}$, a , β , B gibi) parametreleri, model sonucuna en iyi etkiyi gösterecek şekilde otomatik olarak optimize edilmiştir. Kuraklık tahmin modellerinde olduğu gibi, Kernel parametresi lineer seçilmiş olup, ölçeği 1'dir.

Şekil 4.62'de DVM ile yapılan analiz sonuçlarının özeti sunulmuştur. Burada, NS değerlerinin -0.02 ile 0.57 arasında, r değerlerinin 0.32 ile 0.78 arasında yer aldığı görülmektedir. Çizelge 4.18'de ise, tüm modellerin performans değerlerine yer verilmiştir. Model performansları incelendiğinde NS: 0.5622, RMSE: 1.3341, r : 0.7700 performans değerleri ile M22'nin, diğerlerine göre daha etkili olduğu bulunmuştur. M22'nin girdi yapısı, 4 aya kadar geciktirilmiş aylık toplam yağış verisinden, t-12 zamanına ait aylık toplam yağış verisinden, t-1, t-3, t-12 zamanlarına ait SYİ3 verisinden, t-1 zamanına ait SYİ12 verisinden, 2 aya kadar geciktirilmiş aylık ortalama akış verisinden, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1, t-6 zamanlarına ait AKİ12 verisinden oluşturulmuştur. Bu girdi yapısı diğer modellere göre en fazla veriyi içermektedir. Ayrıca, girdi yapısındaki zamanlar, çıktı yapısındaki zaman ile aynı olmaması, modelleme çalışmalarında bu model yapısı daha da tercih edilebilir kılmaktadır. Başarılı modeller arasında M22'yi M24 takip etmektedir. M24'e ait performans değerleri NS: 0.5525, RMSE: 1.3487, r : 0.7623 şeklinde hesaplanmıştır. M24'ün girdi yapısı t-1, t-12 zamanlarına ait aylık toplam yağış verisi, t-1, t-12 zamanlarına ait SYİ3 verisi, 2 aya kadar geciktirilmiş aylık ortalama akış verisi, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1 zamanına ait AKİ12 verisi şeklindedir.



Şekil 4.62. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları

M22 ile kıyaslandığında M24'ün girdi yapısındaki farklılıklar dikkat çekmektedir. Her ne kadar performans değerleri açısından aralarında çok fazla bir fark olmamasına rağmen, girdi yapılarındaki farklı zaman adımlarına ait veri ve farklı geciktirme değerlerinin bulunması ile model sonuçlarının iyileştirilebildiği tespit edilmiştir.

Çizelge 4.18. DVM ile yapılan analiz sonuçları

Model	NS	RMSE	r
M01	-0.0194	2.0357	0.3229
M02	0.0352	1.9803	0.4078
M03	0.1292	1.8814	0.5028
M04	0.1732	1.8333	0.5451
M05	0.2142	1.7872	0.5823
M06	0.4528	1.4914	0.7103
M07	0.4181	1.5380	0.6882
M08	0.4892	1.4409	0.7330
M09	0.4838	1.4486	0.7332
M10	0.5064	1.4165	0.7454
M11	0.4955	1.4321	0.7366


Çizelge 4.18 (devam). DVM ile yapılan analiz sonuçları

Model	NS	RMSE	r
M12	0.4909	1.4385	0.7366
M13	0.5084	1.4137	0.7460
M14	0.0233	1.9925	0.4084
M15	0.4582	1.4840	0.7117
M16	0.4544	1.4893	0.7175
M17	0.4483	1.4975	0.7202
M18	0.0926	1.9206	0.4961
M19	0.4190	1.5368	0.6941
M20	0.4863	1.4450	0.7326
M21	0.5052	1.4182	0.7417
M22	0.5622	1.3341	0.7700
M23	0.5523	1.3490	0.7623
M24	0.5525	1.3487	0.7623
M25	0.4732	1.4656	0.7183
M26	0.4750	1.4646	0.7193
M27	0.2142	1.7872	0.5823
M28	0.2230	1.7772	0.5778
M29	0.0872	1.9263	0.4749
M12t1	0.1721	1.8345	0.5923
M13t1	0.2011	1.8021	0.5720
M22t1	0.4459	1.5008	0.7065
M23t1	0.3743	1.5948	0.6584
M24t1	0.3695	1.6009	0.6514

M23 bu modellerin performans olarak takipçisi olup, performans değerleri NS: 0.5523, RMSE: 1.3490, r: 0.7623'dür. Girdi yapısı ise, yine diğerlerine benzer şekilde olup, t-12 zamanına ait aylık toplam yağış, t-1, t-12 zamanlarına ait SYİ3, t-1 ve t-2 zamanlarına ait aylık ortalama akış, t-1, t-3, t-6, t-12 zamanlarına ait AKİ değerlerinden oluşturulmuştur. Bahsedilen modellerin girdi yapılarında genellikle, kullanılan verinin karması şeklinde oluşturulmuştur. Bu modellerin ardından performans olarak, girdi yapısı t, t-1, t-2, t-3 zamanlarına ait aylık toplam yağış, t-1, t-2, t-3 zamanlarına ait aylık ortalama akış değerlerinden oluşturulan M10 gelmektedir. M10'un performans değerleri NS: 0.5064, RMSE: 1.4165, r: 0.7454'dür. Girdi yapısında t zamanına ait aylık toplam yağış verisi olmasına rağmen, hesaplanan performans değerleri diğer modellerin gerisinde kalmıştır. Girdi verisi sadece aylık ortalama akış değerlerinden oluşturulan modellerin performansı incelendiğinde, sırasıyla 5 ve 6 aya kadar geciktirilmiş M25 ve M26 modellerinin performansı bahsedilen diğer modellerin gerisinde kalmıştır. M25 için NS: 0.4732, RMSE: 1.4656, r: 0.7183 performans değerleri, M26 için NS: 0.4750, RMSE: 1.4646, r: 0.7193 performans değerleri hesaplanmıştır. M05'in girdi yapısı t zamanına ait ve 5 aya kadar geciktirilmiş aylık toplam yağış verisinden oluşturulmuştur. Model performans

değerleri NS: 0.2142, RMSE: 1.7872, r : 0.5823'dür. Tüm bunlardan yola çıkarak, yağış akış tahmin modelleri ile yapılacak olan bir çalışmada girdi yapısında sadece akış ya da yağış verisinin kullanılması modellerin performans değerlerinden de anlaşılacağı gibi çok etkili olmamaktadır. Girdi yapısının çeşitlendirilmesiyle model performans değerlerinin iyileştiği tespit edilmiştir. Başarılı olan modellerden M22, M23 ve M24'ün çıktı zamanı +1 ötelenerek, bu zamana ait model performansları da incelenmiştir. Bu modellerin isimlerinin yanlarına "t1" ifadesi eklenerek, diğer model isimleri ile karıştırılmaması sağlanmıştır. Bu modellerin performans değerleri incelendiğinde, çıktı verisi t zamanına ait olan bazı modellerden bile daha etkili olduğu saptanmıştır. M22t1 için NS: 0.4459, RMSE: 1.5008, r : 0.7065, M23t1 için NS: 0.3743, RMSE: 1.5948, r : 0.6584 performans değerleri hesaplanmıştır. Ayrıca, kuraklık tahmin modellerinde başarılı olan modellerin girdi yapısıyla analiz edilen modellere (28, M29) ait performans değerleri oldukça düşüktür. M28 için NS: 0.2230, RMSE: 1.7772, r : 0.5778, M29 için NS: 0.0872, RMSE: 1.9263, r : 0.4749'dur.

Şekil 4.63de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M22 ve M24) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği, Şekil 4.63'de gösterilmiştir.



Şekil 4.63. DVM için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Kuraklık tahmin modellerine göre, yağış-akış tahmin modellerinin performans değerleri daha düşük seviyelerdedir. Bu sebeple, model tahminlerinin iyileştirilmesi gerekli görülmüş, iyileştirme için bu çalışmada dalgacık ayrıştırması yöntemi kullanılmıştır. Dolayısıyla dalgacık dönüşümü kullanılarak yapılacak iyileştirmenin önemi yağış-akış tahmin modellerinde daha ön plana çıkmaktadır. Yağış-akış tahmin modellerinde dalgacık iyileştirmesi tüm modellere uygulanmış olup, iyileştirme sonucunda elde edilen performans değerleri Çizelge 4.19’da gösterilmiştir.


Çizelge 4.19. Dalgacık dönüşümü ile DVM analiz sonuçları

Model	NS	RMSE	r
M01	0.3022	1.6841	0.5997
M02	0.3464	1.6300	0.6337
M03	0.4275	1.5256	0.6967
M04	0.4397	1.5092	0.6978
M05	0.4559	1.4872	0.7024
M06	0.6573	1.1802	0.8188
M07	0.6573	1.1802	0.8262
M08	0.8847	0.6845	0.9407
M09	0.9281	0.5407	0.9634
M10	0.9344	0.5164	0.9667
M11	0.8792	0.7008	0.9378
M12	0.9001	0.6372	0.9489
M13	0.9351	0.5135	0.9671
M14	0.3946	1.5687	0.6636
M15	0.6735	1.1520	0.8265
M16	0.7879	0.9286	0.8908
M17	0.7963	0.9100	0.8951
M18	0.4656	1.4738	0.7142
M19	0.6789	1.1425	0.8303
M20	0.8950	0.6533	0.9462
M21	0.9245	0.5541	0.9616
M22	0.9124	0.5967	0.9555
M23	0.9145	0.5896	0.9566
M24	0.9131	0.5943	0.9558
M25	0.9612	0.3975	0.9805
M26	0.9781	0.2989	0.9893
M27	0.4559	1.4872	0.7024
M28	0.4848	1.4471	0.7181
M29	0.1133	1.8986	0.4547
M09t1	0.8073	0.8850	0.8997
M10t1	0.8065	0.8869	0.8988
M13t1	0.8133	0.8711	0.9022
M25t1	0.8504	0.7818	0.9236
M26t1	0.8251	0.8454	0.9125


Model sonuçlarının ait özet bilgilerde Şekil 4.63’de gösterilmiştir. Model performansları incelendiğinde, NS değerlerinin 0.11 ile 0.97 arasında, RMSE

değerlerinin 0.29 ile 1.90 arasında, r değerlerinin de 0.45 ile 0.98 arasında değiştiği Şekil 4.64’de görülmektedir. Tüm modellerin dalgacık dönüşümünden yararlanarak DVM ile analiz sonucunda elde edilen performans değerleri incelendiği zaman, dalgacık dönüşümü uygulanmadan önceki modellere göre model performanslarının dikkat çekici şekilde arttığı ve M26 ve M25’in diğer modellere göre daha etkili olduğu bulunmuştur. M26 ve M25’in başarılı olmasının ana sebeplerinden birisi model girdi yapısıdır. İki modelin girdi yapısı da akış değerlerinin geciktirilmesi ile oluşturulmuştur. Sırasıyla, 6 ve 5 aya kadar geciktirilmiş aylık ortalama akış değerlerinden oluşturulan bu modellerin performansları M26 için NS: 0.9781, RMSE: 0.2989 r: 0.9893 ve M25 için NS: 0.9612, RMSE: 0.3975 r: 0.9805 bulunmuştur. Bu modelleri NS: 0.9351, RMSE: 0.5135, r: 0.9671’lik değerler ile M13 takip etmektedir. Ama M13’ün girdi yapısı t zamanına ait olan aylık toplam yağış verisini de içerdiği için, yapılacak olan bir modelleme çalışmasında tercih edilmeyebilir. Dalgacık dönüşümü uygulanmadan yapılan analiz sonuçlarında M22, M24 ve M23’ün diğer modellere göre daha etkili sonuçlar verdiğinden bahsedilmişti. Bu modellerin dönüşümünden sonraki performans değerleri ise M22 için NS: 0.9124, RMSE: 0.5967, r: 0.9555, M24 için NS: 0.9131, RMSE: 0.5943, r: 0.9558, M23 için NS: 0.9145, RMSE: 0.5896, r: 0.9566 olarak hesaplanmıştır.

Dalgacık dönüşümü sonucunda en etkili modellerin çıktı verisi +1 adım ötelenerek t+1 zamanına göre tahminlemeler de yapılmıştır. Bu modellerin isimlerinin yanına “t1” ibaresi eklenerek diğer modellerden ayrılmıştır. Bu modellerde elde edilen en başarılı sonuçlar ise, M25t1 ve M26t1’de alınmıştır. Sırasıyla performans değerleri, NS: 0.8504, RMSE: 0.7818, r: 0.9236 ve NS: 0.8251, RMSE: 0.8454, r: 0.9125’dir. Bu modellerin girdi yapısı, sırasıyla 5 ve 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Dalgacık dönüşümünden sonra, diğer modellere göre daha etkili performans değerleri sadece akış verisi ile oluşturulan modellerden elde edilmiştir. Tüm verinin girdi yapısında kullanıldığı modellerin performans değerleri, girdi yapısında sadece kuraklık indis verisinin içeren modellerin performans değerlerinin, girdi yapısı sadece yağış verisinden oluşturulan modellerin ve bu modellerin kombinasyonlarından oluşturulan modellerin performans değerlerinin, dalgacık dönüşümünden sonra, akış değerleri ile girdi yapısı oluşturulan modellerin performans değerlerinin gerisinde kalmıştır.



Şekil 4.64. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları




Şekil 4.65. Dalgacık dönüşümü ile DVM için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.65’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M26) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü, Şekil 4.65’de gösterilmiştir.

4.3.2. YSA ile analiz sonuçları

Hiperbolik Tanjant Fonksiyonunun ve LM eğitim algoritmasının kullanıldığı YSA ile analizlerden elde edilen modellere ait özeti bilgiler Şekil 4.66’da gösterilmiştir. Şekil 4.66 incelendiğinde; performans değerlerinin düşüklüğü ilk dikkat çeken sonuçlardandır. NS değerlerinin -3.80 ile 0.52 arasında, r değerlerinin 0.42 ile 0.75 arasında değiştiği tespit edilen diğer sonuçlardan biridir. YSA ile yapılan yağış akış modellemesinde, elde edilen performans değerlerinin düşük olması sebebiyle, t+1 zamanına ait tahminleme çalışmalarına bu kısımda yer verilmemiştir.




Şekil 4.66. YSA analiz özet sonuçları

Gizli katmandaki en uygun nöron sayıları da deneme yanılma bulunmuş olup, bulunan en uygun nöron sayıları Çizelge 4.20’de gösterilmiştir. Çizelge 4.20 incelendiği zaman, diğer modellere göre performans değerlerinin etkili olduğu modeller M26 ve M20’dir. Sırasıyla performans değerleri NS: 0.5169, RMSE: 1.4051, r: 0.7420 ve NS: 0.333, RMSE: 1.6338 r: 0.6366’dır. M26’nın girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama akış değerlerinden, M20’in girdi yapısı t-1, t-2, t-3 zamanlarına ait aylık toplam yağış verisinden, t-1, t-2, t-3 zamanlarına ait SYİ3 verisinden ve t-1, t-2 zamanlarına ait aylık toplam yağış verisinden oluşturulmuştur. M26 ve M20 her ne kadar diğer modellere göre başarılı olarak tespit edilmese de, performans değerleri DVM ile yapılan analizden elde edilen sonuçlara göre düşüktür. Dolayısıyla, çıktı verisi akışa ait olan ya da girdi verisi akışa ait olan bir modelleme çalışmasında, DVM ile yapılabilecek bir çalışmada daha iyi sonuçlar alınabileceği belirlenmiştir.

Çizelge 4.20. YSA ile yapılan analiz sonuçları

Model	NS	RMSE	r	Neuron S.
M01	-1.2599	3.0309	0.1195	61
M02	-1.2420	3.0189	0.3253	79
M03	-0.5201	2.4858	0.3588	62
M04	-0.8951	2.7755	0.3979	38
M05	-0.5125	2.4796	0.4223	87
M06	0.2461	1.7506	0.5891	45
M07	0.1779	1.8280	0.5457	60
M08	-0.6221	2.5678	0.5894	67
M09	0.1532	1.8553	0.6123	74
M10	-0.0809	2.0961	0.5908	97
M11	-3.7158	4.3783	0.4208	65
M12	-1.6397	3.2757	0.2823	50
M13	-0.4290	2.4102	0.3937	74
M14	-0.2553	2.2589	0.3529	65
M15	-0.9736	2.8324	0.4843	94
M16	-0.0637	2.0794	0.5848	44
M17	-0.6623	2.5995	0.3792	50
M18	-0.5669	2.5237	0.4220	89
M19	0.1894	1.8152	0.6371	33
M20	0.3433	1.6338	0.6366	50
M21	-0.5092	2.4768	0.5304	88
M22	-0.9254	2.7976	0.4555	45
M23	-3.2416	4.1524	0.3202	79
M24	-1.4069	3.1279	0.3433	15
M25	0.0255	1.9933	0.5929	79
M26	0.5169	1.4051	0.7420	13
M27	-0.4402	2.4196	0.3855	47
M28	-1.0979	2.9203	0.3089	94
M29	-0.7295	2.6515	0.3936	71

Ama yine de YSA ile bir çalışma gerçekleştirilecek ise, M26'nın girdi verisinden faydalanılabilir. M06 bahsedilen bu modellerin performans olarak takipçisidir. Performans değerleri, NS: 0.2461, RMSE: 1.7506, r: 0.5891 olup, girdi verisi t, t-1 zamanlarına ait aylık toplam yağış verisinden ve t-1 zamanına ait aylık ortalama akış verisinden oluşturulmuştur. Buradan da anlaşılacağı gibi, model performans değerleri model girdi yapısından bir hayli etkilenmektedir. YSA ile yapılan akış modellemesinde, sadece akış değerlerinden faydalanılması gerektiği bulunan sonuçlar arasındadır.




Şekil 4.67. YSA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.67’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M26 ve M20) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.67’de gösterilmiştir.

YSA’da dalgacık dönüşümü olmadan yapılan analiz sonuçlarının çok yüksek bir performans göstermediği tespit edilmiştir. Kuraklık tahmin modellemelerinde, YSA ile yapılan analizlerde, DVM ve RO’dan sonra en etkili sonuçların alındığı yukarıdaki kısımlarda belirtilmişti. Bu etkili performansa yağış-akış tahmin modellerinde rastlanılmamıştır. Bu sebepler ile dalgacık iyileştirmesinin yağış-akış tahmin modellerinde kullanılması gerekli görülmüş olup, dalgacık dönüşümü tüm modellere

uygulanmış elde edilen sonuçların özeti Şekil 4.68’de gösterilmiştir. Buradan da anlaşılacağı gibi, bazı modellerden etkili sonuçlar alınabileceği gibi bazı model sonuçlarından da beklenen performans alınamamıştır. NS değerlerinin -2.73 ile 0.96 gibi büyük bir ölçekte değişmiştir. Aynı durum RMSE ve r değerleri içinde geçerlidir.



Şekil 4.68. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları


Dalgacık dönüşümünden sonra her bir modele ait sonuçlar ise Çizelge 4.21’de verilmiştir. Bu sonuçlar incelendiği zaman, en başarılı sonuçlar M25 ve M26 modellerinde alınmıştır. Bu modellerin girdi verisi sırasıyla, 5 ve 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Dalgacık dönüşümünden önce M25’in performans değerleri NS: 0.0255, RMSE: 1.9933, r: 0.5929 şeklindeyken, dönüşümden sonra NS: 0.9567, RMSE: 0.4199, r: 0.9786 olarak hesaplanmıştır. Bu değerler dalgacık dönüşümünün model performansını artırmaya yönelik etkisinin oldukça başarılı olduğunu göstermektedir.

Çizelge 4.21. Dalgacık dönüşümü ile YSA analiz sonuçları

Model	NS	RMSE	r	Nöron S.
M01	-2.7265	3.8921	0.2420	93
M02	-1.3847	3.1135	0.3874	87
M03	-1.3430	3.0861	0.3341	96
M04	-0.7131	2.6389	0.5096	63
M05	-1.6232	3.2654	0.5139	86
M06	-0.0864	2.1015	0.5880	41
M07	0.2264	1.7733	0.7342	25
M08	0.6530	1.1877	0.8296	30
M09	0.8400	0.8064	0.9289	14
M10	0.8347	0.8198	0.9427	6
M11	0.4269	1.5263	0.8050	32
M12	0.5446	1.3606	0.7913	20
M13	0.7089	1.0879	0.8581	29
M14	-2.1062	3.5534	0.2687	37
M15	0.0374	1.9781	0.6961	34
M16	0.5028	1.4216	0.7782	45
M17	0.6738	1.1515	0.8533	50
M18	-0.5184	2.4844	0.3741	43
M19	0.2452	1.7516	0.6739	26
M20	0.6553	1.1837	0.8503	34
M21	0.6382	1.2128	0.8316	35
M22	0.7122	1.0817	0.9119	7
M23	0.5993	1.2762	0.8109	28
M24	0.7925	0.9185	0.8976	14
M25	0.9567	0.4199	0.9786	22
M26	0.9534	0.4366	0.9772	6
M27	-0.8750	2.7607	0.4319	43
M28	-0.5750	2.5303	0.5122	39
M29	-1.6481	3.2809	0.4649	47
M09t1	0.7069	1.0916	0.8428	9
M10t1	0.3562	1.6178	0.7197	31
M24t1	0.3678	1.6030	0.7183	39
M25t1	0.5449	1.3637	0.8265	38
M26t1	0.4894	1.4444	0.7797	28

Özellikle NS değerinde önemli oranda iyileşme gerçekleşmiştir. M26'nın dalgacık dönüşümünden önce performans değerleri NS: 0.5169, RMSE: 1.4051, r: 0.7420 şeklindeyken, dönüşümden sonra NS: 0.9534, RMSE: 0.4366, r: 0.9772 olarak hesaplanmıştır. Tıpkı M25'de olduğu gibi, M26'da da önemli iyileştirmeler gerçekleşmiştir. Burada en dikkat çekici bulgulardan birisi, M25'deki iyileşme yüzdesidir. NS değeri neredeyse 0 (sıfır)'a yakın bir değerdeyken, dönüşüm sonrasında NS değeri 0.95'i aşmıştır. En yüksek performans değerlerine bu iki modelde ulaşılırken, bu modellerin takipçisi M09 olmuştur. M09'un dalgacık

dönüşümünden önce performans değerleri NS: 0.1532, RMSE: 1.8553, r: 0.6123 şeklindeyken, dönüşümden sonra NS: 0.8400, RMSE: 0.8064, r: 0.9289 olarak hesaplanmıştır.




Şekil 4.69. Dalgacık dönüşümü ile YSA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.69’da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M26) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağladığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüştüğü Şekil 4.69’da gösterilmiştir.

Dalgacık dönüşümü sonucunda en etkili modellerin çıktı verisi +1 adım ötelenerek t+1 zamanına göre tahminlemeler de yapılmıştır. Bu modellerin isimlerinin yanına “t1” ibaresi eklenerek diğer modellerden ayrılmıştır. Bu kısımda elde edilen en başarılı sonuçlar ise, M09t1 ve M25t1’de alınmıştır. Sırasıyla performans değerleri, NS: 0.7069, RMSE: 1.0916, r: 0.8428 ve NS: 0.5449, RMSE: 1.3637, r: 0.8265’dir. M09t1’in girdi yapısında t zamanına ait aylık toplam yağış verisi olduğundan dolayı, çıktı verisi t+1 zamanına ait olan modellerde en başarılı sonuç M25t1’de alınmıştır. M25t1’in girdi yapısı ise 5 aya kadar geciktirilmiş akış verisinden oluşturulmuştur.

4.3.3. RO ile analiz sonuçları

Optimum ağaç sayısının, otomatik olarak belirlendiği RO metodu ile yapılan analizlere ait sonuçlar Çizelge 4.22’de, elde edilen sonuçlara ait özet niteliğinde grafik görseli de Şekil 4.70’de gösterilmiştir. Şekil 4.70 incelendiğinde, NS değerlerinin 0.02 ile 0.62 ile arasında, r değerlerinin 0.28 ile 0.79 arasında değiştiği görülmektedir.



Şekil 4.70. Dalgacık dönüşümü öncesi RO analiz özet sonuçları


Bu geniş ölçekte yer alan değerlerin, diğerlerine göre daha başarı olanlar genellikle M20 ve sonrasında olduğu Şekil 4.69’den görülebilmektedir. Her modele karşılık RMSE değerleri ise Çizelge 4.22’de belirtilmiştir. Bu değer ise, 1.25 ile 2.00 arasında değişmektedir. Model performansları daha detaylı olarak irdelendiğinde, diğer modellere göre en başarılı sonuçlar M24, M23 ve M22’de alınmıştır.

Çizelge 4.22. RO ile yapılan analiz sonuçları

Model	NS	RMSE	r
M01	0.0200	1.9960	0.2805
M02	0.1450	1.8643	0.4090
M03	0.2746	1.7172	0.5325
M04	0.3281	1.6526	0.5787
M05	0.3699	1.6005	0.6128
M06	0.4243	1.5298	0.6525
M07	0.3986	1.5636	0.6358
M08	0.5044	1.4194	0.7126
M09	0.5181	1.3997	0.7226
M10	0.5100	1.4114	0.7162
M11	0.5163	1.4023	0.7224
M12	0.4896	1.4404	0.7067
M13	0.5162	1.4023	0.7223
M14	0.1463	1.8628	0.4140
M15	0.4283	1.5244	0.6585
M16	0.4866	1.4446	0.7029
M17	0.4914	1.4378	0.7025
M18	0.3145	1.6693	0.5636
M19	0.4745	1.4616	0.6897
M20	0.5553	1.3446	0.7482
M21	0.5677	1.3257	0.7552
M22	0.6057	1.2660	0.7810
M23	0.6152	1.2506	0.7861
M24	0.6196	1.2435	0.7886
M25	0.5779	1.3118	0.7624
M26	0.5898	1.2946	0.7700
M27	0.3706	1.5996	0.6141
M28	0.3048	1.6810	0.5624
M29	0.0668	1.9477	0.3653
M22t1	0.3732	1.5962	0.6134
M23t1	0.3409	1.6368	0.5864
M24t1	0.3517	1.6233	0.5952
M25t1	0.3813	1.5900	0.6337
M26t1	0.4393	1.5137	0.6763

M24'ün performans değerleri NS: 0.6196, RMSE: 1.2435, r: 0.7886 olup, girdi yapısı t-1, t-12 aylarına ait aylık toplam yağış verisinden, t-1, t-12, zamanlarına ait SYİ3 verisinden, t-1, t-2 zamanlarına ait aylık ortalama akış verisinden, t-1, t-3, t-6 zamanlarına ait AKİ3 verisinden, t-1 zamanına ait AKİ12 verisinden oluşturulmuştur. Tarımsal ve hidrolojik kuraklığı açıklayan kuraklık indisleri ve aylık toplam yağış ve akış verisinin kombinasyonundan oluşturulan modellerin diğer modellere etkili performans sergilediği belirlenmiştir. Performans olarak M23, M24'ün hemen ardından gelmektedir. M23'ün performans değerleri NS: 0.6152, RMSE: 1.2506, r: 0.7861'dir. Girdi yapısındaki tek farklılık t-1 zamanına ait aylık toplam yağış verisinin bulunmamasıdır. Bundan dolayı, yağış-akış tahmin modellerinde RO ile yapılacak bir

analizde yağış verisinin, model sonucunu etkileyeceği sonucuna ulaşılmıştır. M22 modeli, NS: 0.6057, RMSE: 1.2660, r: 0.7810 performans değerleri ile başarılı olan modellerden bir diğeridir. Girdi yapısı, 4 aya kadar geciktirilmiş aylık toplam yağış verisi, t-12 zamanına ait aylık toplam yağış verisi, t-1, t-3, t-12 zamanlarına ait SYİ3 verisi, t-1 zamanına ait SYİ12 verisi, 2 aya kadar geciktirilmiş aylık ortalama akış verisi, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1, t-6 zamanlarına ait AKİ12 verisinden oluşturulmuştur. M23'den daha kapsamlı bir girdi yapısı olmasına rağmen, model performans değerleri M23'ün gerisinde kalmıştır. Bu da hidrolojik ve tarımsal kuraklık indisleri de dahil olmak üzere, girdi yapısındaki verinin optimum düzeyde ve optimum geciktirme zamanının önemini göstermektedir. Analiz sonucunda etkili modellerin çıktığı verisi +1 adım ötelenerek t+1 zamanına göre tahminlemeler de yapılmıştır. Önceki kısımlarda olduğu gibi, bu modellerin isimlerinin yanına "t1" ibaresi eklenerek diğer modellerden ayrılmıştır. Bu kısımda elde edilen en başarılı sonuçlar ise M24t1 ve M23t1'den alınmıştır. Sırasıyla performans değerleri, NS: 0.3517, RMSE: 1.6233, r: 0.5952 ve NS: 0.3409, RMSE: 1.6368, r: 0.5864'dir.




Şekil 4.71. RO için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.71'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M23 ve M24) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.71’de gösterilmiştir.

RO ile yapılan analiz sonucunda, analiz performanslarının iyileştirilmesi için, dalgacık dönüşümünden faydalanılmıştır. Dönüşüm sonrasındaki, modellere ait özet bilgiler Şekil 4.72’de gösterilmiştir. Şekil 4.72 incelendiğinde, NS değerlerinin maksimum olarak 0.84 değerlerine kadar ulaştığı, r değerlerinin de 0.92’ye kadar ulaştığı görülmektedir. Başarılı performans değerlerine genellikle M20 ve sonrasındaki modellerde ulaşılmıştır. RMSE değerlerinin Çizelge 4.23’de belirtildiği model sonuçları incelendiğinde, M26 ve M25’in diğer modellere göre daha etkili performans sergilediği tespit edilmiştir. M26 için NS: 0.8359, RMSE: 0.8188, r: 0.9193 performans değerleri, M25 için NS: 0.8187, RMSE: 0.8598, r: 0.9133 performans değerleri hesaplanmıştır.



Şekil 4.72. Dalgacık dönüşümü sonrası RO analiz özet sonuçları


Dönüşümden önce bu değerler M26 için NS: 0.5898, RMSE: 1.2946, r: 0.7700, M25 için NS: 0.5779, RMSE: 1.3118, r: 0.7624'dür. Bu modellerin girdi yapısı sırasıyla, 6 ve 5 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur.

Çizelge 4.23. Dalgacık dönüşümü ile RO analiz sonuçları

Model	NS	RMSE	r
M01	0.2729	1.7191	0.5265
M02	0.4004	1.5611	0.6352
M03	0.4479	1.4980	0.6711
M04	0.4684	1.4700	0.6863
M05	0.4793	1.4548	0.6956
M06	0.7286	1.0503	0.8785
M07	0.7347	1.0385	0.8861
M08	0.7135	1.0792	0.8658
M09	0.7593	0.9891	0.8927
M10	0.7317	1.0444	0.8755
M11	0.7028	1.0991	0.8593
M12	0.7149	1.0765	0.8637
M13	0.7235	1.0602	0.8724
M14	0.3704	1.5997	0.6229
M15	0.7353	1.0372	0.8781
M16	0.7602	0.9873	0.8911
M17	0.7509	1.0062	0.8821
M18	0.4940	1.4341	0.7049
M19	0.6509	1.1913	0.8113
M20	0.6796	1.1413	0.8336
M21	0.7143	1.0776	0.8583
M22	0.7477	1.0126	0.8817
M23	0.7812	0.9432	0.8984
M24	0.7777	0.9507	0.8961
M25	0.8187	0.8598	0.9133
M26	0.8359	0.8188	0.9193
M27	0.4765	1.4588	0.6924
M28	0.5117	1.4089	0.7189
M29	0.3731	1.5963	0.7056
M22t1	0.7070	1.0913	0.8600
M23t1	0.7414	1.0253	0.8770
M24t1	0.7330	1.0419	0.8756
M09t1	0.7042	1.0966	0.8639
M25t1	0.7976	0.9094	0.8981
M26t1	0.7981	0.9083	0.9019

Dalgacık dönüşümünden sonraki performans değerlerinde, dönüşüm öncesine göre bir iyileşme olduğu tespit edilmiştir. Bu modelleri performans olarak M23 izlemektedir. M23'ün dalgacık dönüşümünden önceki performans değerleri NS: 0.6152, RMSE: 1.2506, r: 0.7861 şeklindeyken, dönüşümden sonra, NS: 0.7812, RMSE: 0.9432, r: 0.8984 şeklindedir. M23'ün girdi yapısı, t-12 zamanına ait aylık toplam yağış, t-1, t-12 zamanlarına ait SYİ3, t-1, t-2 zamanlarına ait aylık ortalama akış, t-1, t-3, t-6

zamanlarına ait AKİ3, t-1 zamanına ait AKİ12 verisi gibi zengin bir girdiden oluşturulmuş olmasına rağmen, sadece akış değerleri ile oluşturulan modellerin performans olarak gerisinden kalmıştır. M24'ün girdi yapısı, M23'ün girdi yapısı ile neredeyse aynı özellikte olup, tek farkı t-1 zamanına ait aylık toplam yağış verisini bulundurmasıdır. M23'e göre daha fazla girdi verisi içermesine rağmen, NS: 0.7777, RMSE: 0.9507, r: 0.8961'luk performans değerleri ile M24, M23'ün performans olarak gerisinde kalmıştır. Analiz sonucunda, etkili modellerin çıktı verisi +1 adım ötelenerek t+1 zamanına göre tahminlemeler de yapılmıştır. Önceki kısımlarda olduğu gibi, bu modellerin isimlerinin yanına "t1" ibaresi eklenerek diğer modellerden ayrılmıştır. Bu kısımda elde edilen en başarılı sonuçlar ise M26t1 ve M25t1'de alınmıştır. Sırasıyla performans değerleri NS: 0.7981, RMSE: 0.9083, r: 0.9019 ve NS: 0.7976, RMSE: 0.9094, r: 0.8981'dir. Bu modellerin çıktı değerleri, çıktı yapısı t zamanına ait olan bazı modellerden bile daha iyi olduğu tespit edilmiştir.




Şekil 4.73. Dalgacık dönüşümü ile RO için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.73'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M26) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.73'de gösterilmiştir.

4.3.4. KA ile analiz sonuçları

Optimum ağaç sayısının, otomatik olarak belirlendiği KA metodu ile yapılan analizlere ait sonuçların özeti Şekil 4.74’de gösterilmiştir. Şekil 4.74 incelendiğinde, NS değerlerinin -0.36 0.90 ile arasında, r değerlerinin -0.02 ile 0.60 arasında değiştiği görülmektedir.



Şekil 4.74. Dalgacık dönüşümü öncesi KA analiz özet sonuçları

Çizelge 4.24’de tüm modellere ait sonuçlar verilmiştir. Bu çizelge incelendiğinde, M07 ve M06’nın diğer modellere göre daha etkili bir performans gösterdiği belirlenmiştir. Performans değerleri sırasıyla, NS: 0.3537, RMSE: 1.6209, r: 0.5978 ve NS: 0.3360, RMSE: 1.6429, r: 0.5925’dir. M07’nin girdi yapısı t-1 zamanına ait aylık toplam yağış ile t-1 zamanına ait aylık ortalama akış verisinden, M06’nın girdi yapısı t, t-1 zamanlarına ait aylık toplam yağış ile t-1 zamanına ait aylık ortalama akış verisinden oluşturulmuştur. Buradan yola çıkarak, M06’nın girdi yapısında t zamanına

ait veri olmasından ötürü M07'nin performans olarak gerisinde kalmıştır. Bu modellerin performans olarak takipçisi M09'dur. Performans değerleri NS: 0.3360, RMSE: 1.6429, r: 0.5925'dir.


Çizelge 4.24. KA ile analiz sonuçları

Model	NS	RMSE	r
M01	-0.0743	2.0897	0.1765
M02	-0.0091	2.0253	-0.0231
M03	0.0050	2.0111	0.3000
M04	-0.0743	2.0897	0.1765
M05	-0.0091	2.0253	-0.0231
M06	0.3360	1.6429	0.5925
M07	0.3537	1.6209	0.5978
M08	0.0695	1.9449	0.5478
M09	0.3360	1.6429	0.5925
M10	0.3360	1.6429	0.5925
M11	0.3360	1.6429	0.5925
M12	0.3325	1.6473	0.5935
M13	0.3024	1.6839	0.5671
M14	0.1094	1.9026	0.3703
M15	0.2131	1.7885	0.5295
M16	0.3024	1.6839	0.5671
M17	0.3024	1.6839	0.5671
M18	-0.0091	2.0253	-0.0231
M19	0.3360	1.6429	0.5925
M20	0.3024	1.6839	0.5671
M21	0.3024	1.6839	0.5671
M22	-0.3618	2.3528	0.5225
M23	0.3024	1.6839	0.5671
M24	0.2718	1.7205	0.5924
M25	0.3294	1.6535	0.5878
M26	0.3265	1.6589	0.5859
M27	-0.0091	2.0253	-0.0231
M28	0.1046	1.9079	0.4647
M29	-0.8310	2.7282	0.1355
M09t1	-0.0084	2.0247	-0.0231
M10t1	-0.0084	2.0247	-0.0231

M09'un girdi yapısı, t, t-1, t-2 zamanlarına ait aylık toplam yağış verisinden, t-1, t-2, t-3 zamanlarına ait aylık ortalama akış verisinden oluşturulmuştur. Çizelge 4.24'den de anlaşılabileceği gibi birçok model sonuçları birbirinin aynısı olarak hesaplanmıştır. Bunu sebeplerinden bir tanesi, model öğrenmesinin ezbere düşmesidir. Genellikle NS değerlerinin 0.35'in altında kalması ve r değerlerinin de 0.60'ı geçememesi KA'nın modelleme çalışmalarında kullanılmasını ve tercih edilmesini azaltmaktadır.


Şekil 4.75'de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M06 ve M07) zaman serisi ve gözlem değerlerine göre saçılma diyagramı

verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği algoritmanın genellikle ezbere Şekil 4.75’de gösterilmiştir.



Şekil 4.75. KA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

KA ile yapılan analiz sonuçlarında performans değerlendirme kriterlerinin diğer algoritmalara göre, düşük kaldığı belirlenmiştir. Hatta model sonuçlarının bir kısmı NS ve korelasyon değerlerinde negatif hesaplanmıştır. Bu modellerin analiz sonuçlarının iyileştirilmesi için dalgacık dönüşümünden yararlanılmıştır. Dönüşüm sonrasındaki, modellere ait özet bilgiler Şekil 4.76’da gösterilmiştir. Şekil 4.76’da M25 ve M26’nın diğer modellerin performans olarak önünde olduğu görülmektedir. Çizelge 4.25’de görüldüğü gibi, M25 için NS: 0.6819, RMSE: 1.1389, r: 0.8297 performans değerleri, M26 için NS: 0.5919, RMSE: 1.2913, r: 0.7911 performans değerleri hesaplanmıştır. M25’in model girdi yapısı 5 aya kadar geciktirilmiş aylık ortalama akış verisinden, M26’nın model girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Ayrıca Şekil 4.76’da performans değerleri başarılı olan modeller sarı renk ile gösterilirken, performans değerleri kötü olan modeller mavi renk ile ifade edilmiştir. Model performanslarına göre bu iki renk arasında geçişler de mevcuttur.



Şekil 4.76. Dalgacık dönüşümü sonrası KA analiz özet sonuçları

En başarılı modellerin girdi yapısı bu şekilde oluşturulmuşken, bu modelleri takip eden M09'un girdi yapısı ise t , $t-1$, $t-2$ zamanlarına ait yağış, $t-1$, $t-2$, $t-3$ zamanlarına ait aylık ortalama akış verisinden oluşturulmuştur. Bu modelin performans değerleri ise, NS: 0.5702, RMSE: 1.3218, r : 0.7778 olarak hesaplanmıştır. Dalgacık dönüşümünden sonra, bahsedilen modelleri performans olarak takip eden diğer bir model ise M06'dır. M06'nın girdi yapısı t , $t-1$ zamanlarına ait aylık toplam yağış, $t-1$ zamanına ait aylık ortalama akış verisinden oluşturulmuştur. Performans değerleri ise, NS: 0.5629, RMSE: 1.3329, r : 0.7513 şeklindedir.

Çizelge 4.25. Dalgacık dönüşümü ile KA analiz sonuçları


Model	NS	RMSE	r
M01	0.1683	1.8386	0.4343
M02	0.3728	1.5967	0.6130
M03	0.0213	1.9946	0.4215
M04	0.3728	1.5967	0.6130
M05	-0.5203	2.4859	0.4160

Çizelge 4.25 (devam). Dalgacık dönüşümü ile KA analiz sonuçları

Model	NS	RMSE	r
M06	0.5629	1.3329	0.7513
M07	0.5384	1.3698	0.7499
M08	0.3095	1.6754	0.5853
M09	0.5702	1.3218	0.7778
M10	0.5303	1.3818	0.7439
M11	0.2758	1.7158	0.5661
M12	0.3869	1.5787	0.6390
M13	0.5304	1.3816	0.7385
M14	-0.0078	2.0240	0.4405
M15	0.3820	1.5850	0.6877
M16	0.5101	1.4111	0.7250
M17	0.4188	1.5371	0.6633
M18	-0.1214	2.1351	0.3990
M19	0.3750	1.5939	0.6347
M20	0.3854	1.5806	0.6445
M21	0.5255	1.3888	0.7428
M22	0.4136	1.5440	0.6581
M23	0.4397	1.5092	0.6648
M24	0.4971	1.4298	0.7385
M25	0.6819	1.1389	0.8297
M26	0.5919	1.2913	0.7911
M27	-0.5288	2.4929	0.4073
M28	0.2859	1.7037	0.5487
M29	-0.0007	2.0169	-0.0231
M06t1	0.3387	1.6395	0.6310
M09t1	0.4568	1.4859	0.6841
M10t1	0.4702	1.4675	0.6935
M25t1	0.4829	1.4535	0.7071
M26t1	0.4455	1.5053	0.6731

Analiz sonucunda, etkili modellerin çıktısı verisi +1 adım ötelenerek t+1 zamanına göre tahminlemeler de yapılmıştır. Önceki kısımlarda olduğu gibi, bu modellerin isimlerinin yanına “t1” ibaresi eklenerek diğer modellerden ayrılmıştır. Bu kısımda elde edilen en başarılı sonuçlar M25t1’de alınmıştır.


Şekil 4.77’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M25 ve M26) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği algoritmanın genellikle ezbere düştüğü Şekil 4.77’de gösterilmiştir.



Şekil 4.77. Dalgacık dönüşümü ile KA için yağış-akış en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

4.4. Baraj Göl Seviyesi Tahmin Modelleri


Çalışmanın bu kısmında çıktı verisi baraj göl seviyesi olan tahmin modelleri oluşturulmuştur. Farklı zamanlara ait SYİ, AKİ, aylık toplam yağış, aylık ortalama akış, hacim verisi değerlerinin yanı sıra baraj göl seviyesinin (kot değerinin) ve diğer verinin farklı geciktirilmiş zamanları da model girdilerine eklenmiştir. Matlab programı ile aylık baraj seviye değerlerini tahmin etmek için çeşitli modeller oluşturulmuştur. Kuraklık tahmin modelleri ve yağış akış tahmin modellerinde olduğu gibi literatürde yaygın olarak modeller için tüm verinin %70'nin öğrenme amaçlı kullanıldığı ve kalanının ise test için kullanıldığı tespit edilmiştir. Dolayısıyla, çalışmanın bu kısmında öğrenme oranı olarak %70 belirlenmiştir. Model girdileri, model çıktı sonucunu olumlu yönde etkileyecek şekilde çapraz korelasyon yöntemiyle belirlenmiş olup çapraz korelasyon örnekleri Şekil 4.78'de gösterilmiştir. Şekil 4.78'de a) şıkında baraj göl seviyesi ile geciktirilmiş hacim değerlerinin ilişkisi, b) şıkında baraj göl seviyesi ile geciktirilmiş akış değerlerinin ilişkisi, c) şıkında baraj göl seviyesi ile geciktirilmiş SYİ12 değerlerinin ilişkisi, d) şıkında baraj göl seviyesi ile geciktirilmiş AKİ12 değerlerinin ilişkisi ortaya konmuştur. Bu değerlerden de yararlanılarak model girdi yapıları oluşturulmuş ve ilerleyen kısımda oluşturulan model bilgileri verilmiştir.




Şekil 4.78. Çapraz korelasyon örnekleri a) hacim, b) akış, c) SYİ12, d) AKİ12

Çalışmanın bu kısmında ağırlıklı olarak çıktı verisi olan 12-1969-12-2020 yıllarına ait baraj göl seviyesi (kot) verisi ile baraj hacim verisinden faydalanılmıştır. Bunlara ait zaman serileri Şekil 4.79 ve Şekil 4.80’de verilmiştir. Baraj kot seviyesi ve baraj hacim verisine ait özet istatistikler Çizelge 3.1’de verilmiştir. Şekil 4.79’de baraj göl seviyesinin zaman serisi verilmiş olup, 4-1974 tarihinde serinin en yüksek kotuna (1056.55) ulaştığı, akabinde, 6-1969 ve 5-1971 tarihlerinde de farklı zirve noktalarına eriştiği belirlenmiştir. Barajda ölçülen en düşük kot değeri (1033.59) 9-2001 tarihinde tespit edilmiştir. Şekil 4.80’de ise baraja ait hacim değerinin zaman serisi verilmiştir.

Baraj hacim değerlerinin 3.8 ile 170 hm³ arasında değiştiği Şekil 4.80’de gösterilmiştir. Bu aralıkta en yüksek değerine (168.5 değer ile) 5-1977 tarihinde, en küçük değerine (3.9) ise 11-2001 tarihinde ulaşmıştır. Baraj göl seviyesi tahmini için oluşturulan modellerde; aylık ortalama hacim, aylık ortalama akım, toplam yağış, aylık ortalama baraj göl seviyeleri, SYİ ve AKİ kuraklık indislerinden oluşan parametreler kullanılmış ve bu parametrelerin önceki aylara ait değerleri birbirleri ile



Şekil 4.79. Baraj göl seviyesi



Şekil 4.80. Baraj hacim verisi

harmanlanması ile elde edilen çeşitli kombinasyonlardan oluşmuş 50 adet çekirdek model kurulmuştur. Her bir yöntem için en iyi modeller belirlendikten sonra bu en iyi modeller kullanılarak bir sonraki aya (t+1) ayına ait değerler de tahmin edilmiştir. Böylece her bir yöntemde kullanılan model sayısı 50'den fazla olmuştur. Kurulan çekirdek modeller Çizelge 4.26'da sunulmuştur.

Çizelge 4.26. Baraj göl seviyesi tahmininde oluşturulan modeller

Model	Girdiler						Çıktı
M01	TYt-5	TYt-4	TYt-3	TYt-2	TYt-1		Zt
M02	TYt-6	TYt-5	TYt-4	TYt-3	TYt-2	TYt-1	Zt
M03	Qt-5	Qt-4	Qt-3	Qt-2	Qt-1		Zt
M04	Qt-6	Qt-5	Qt-4	Qt-3	Qt-2	Qt-1	Zt
M05	Vt-5	Vt-4	Vt-3	Vt-2	Vt-1		Zt
M06	Vt-6	Vt-5	Vt-4	Vt-3	Vt-2	Vt-1	Zt
M07	Zt-6	Zt-5	Zt-4	Zt-3	Zt-2	Zt-1	Zt
M08	Zt-3	Zt-2	Zt-1				Zt
M09	Zt-4	Zt-3	Zt-2	Zt-1			Zt
M10	Zt-5	Zt-4	Zt-3	Zt-2	Zt-1		Zt
M11	Vt-2	VT-1	Vt				Zt
M12	Vt-3	Vt-2	Vt-1	Vt			Zt
M13	Vt-4	Vt-3	Vt-2	Vt-1	Vt		Zt
M14	Vt-4	Vt-3	Vt-2	Vt-1			Zt
M15	Vt-5	Vt-4	Vt-3	Vt-2	Vt-1		Zt
M16	Vt-12	Vt-6	Vt-5	Vt-4	Vt-1		Zt
M17	Vt-12	Vt-6	Vt-5	Vt-4	Vt-1	Zt-1	Zt
M18	Vt-12	Vt-6	Vt-5	Vt-4	Vt-1	Zt-2	Zt
>>	Zt-1						Zt
M19	Qt-12	Qt-11	Qt-6	Qt-5	Q t-4	Qt-1	Zt
M20	Qt-12	Qt-11	Qt-6	Qt-5	Q t-4	Qt-1	Zt
>>	Zt-1						Zt
M21	Qt-12	Qt-11	Qt-6	Qt-5	Q t-4	Qt-1	Zt
>>	Zt-2	Zt-1					Zt
M22	Qt-3	Qt-2	Qt-1	TYt-3	TYt-2	TYt-1	Zt
M23	Vt-3	Vt-2	Vt-1	Qt-3	Qt-2	Qt-1	Zt
>>	TYt-3	TYt-2	TYt-1				Zt
M24	AKİ1t-4	AKİ1t-3	AKİ1t-2	AKİ1t-1	AKİ1		Zt
M25	AKİ1t-5	AKİ1t-4	AKİ1t-3	AKİ1t-2	AKİ1 t-1	AKİ1t	Zt
M26	AKİ1t-4	AKİ1t-3	AKİ1t-2	AKİ1t-1			Zt
M27	AKİ1t-5	AKİ1t-4	AKİ1t-3	AKİ1t-2	AKİ1t-1		Zt
M28	AKİ3t-3	AKİ3t-2	AKİ3t-1	AKİ3t			Zt
M29	AKİ3t-4	AKİ3t-3	AKİ3t-2	AKİ3t-1			Zt
M30	AKİ3t-5	AKİ3t-4	AKİ3t-3	AKİ3t-2	AKİ3t-1		Zt
M31	AKİ6t-5	AKİ6t-4	AKİ6t-3	AKİ6t-2	AKİ6t-1		Zt
M32	AKİ12t-15	AKİ12t-14	AKİ12t-13	AKİ12t-12			Zt
M33	AKİ3t-2	AKİ3t-1	Vt-2	Vt-1			Zt
M34	AKİ3t-3	AKİ3t-2	AKİ3t-1	Vt-2	Vt-1		Zt
M35	Vt-2	Vt-1	AKİ1t-2	AKİ1t-1			Zt
M36	V-3	V-2	V-1	AKİ1t-3	AKİ1t-2	AKİ1t-1	Zt
M37	SYİ3t-12	SYİ3t-11	SYİ3t-10	SYİ3t-5	SYİ3t-4	Zt-2	Zt
>>	Zt-1						Zt
M38	SYİ3t-12	SYİ3t-11	SYİ3t-10	SYİ3t-5	SYİ3t-4	Zt-3	Zt
>>	Zt-2	Zt-1					Zt
M39	AKİ6t-5	AKİ6t-4	AKİ6t-3	AKİ6t-2	AKİ6t-1	Qt-2	Zt
>>	Qt-1						Zt
M40	AKİ12t-15	AKİ12t-14	AKİ12t-13	AKİ12t-12	Zt-2	Zt-1	Zt
M41	AKİ12t-15	AKİ12t-14	AKİ12t-13	AKİ12t-12	Zt-3	Zt-2	Zt
>>	Zt-1						Zt
M42	AKİ6t-5	AKİ6t-4	AKİ6t-3	AKİ6t-2	AKİ6t-1		Zt
>>	Q t-2	Q t-1	TYt-2	TYt-1			Zt
M43	SYİ6t-2	SYİ6t-1	SYİ3t-2	SYİ3t-1	AKİ3t-2	AKİ3t-1	Zt
>>	AKİ6t-2	AKİ6t-1					Zt
M44	SYİ6t-2	SYİ6t-1	SYİ3t-2	SYİ3t-1	AKİ3t-2		Zt
>>	AKİ3t-1	AKİ6t-2	AKİ6t-1	Qt-2	Qt-1		Zt
M45	SYİ6t-2	SYİ6t-1	SYİ3t-2	SYİ3t-1	AKİ3t-2		Zt
>>	AKİ3t-1	AKİ6t-2	AKİ6t-1	TYt-2	TYt-1		Zt
M46	V-3	V-2	V-1	Q-3	Q-2	Q-1	

Çizelge 4.26 (devam). Baraj göl seviyesi tahmininde oluşturulan modeller


Model	Girdiler						Çıktı
>>	TY-3	TY-2	TY-1	AKİ3t-3	AKİ3t-2	AKİ3t-1	
Z>>	AKİ1t-3	AKİ1t-2	AKİ1t-1	AKİ6t-3	AKİ6t-2	AKİ6t-1	Zt
M47	Qt-5	Qt-4	Qt-3	Qt-2	Qt-1		Zt
M48	Qt-6	Qt-5	Qt-4	Qt-3	Qt-2	Qt-1	Zt
M49	Qt-3	Qt-2	Qt-1	TYt-2	TYt-1	TYt	Zt
M50	TYt-3	TYt-2	TYt-1	TYt	Qt-3	Qt-2	
>>	Qt-1						Zt
V : Aylık ortalama hacim				TY : Aylık toplam yağış			
Q : Aylık ortalama akış				Z : Aylık ortalama baraj göl seviyesi (kot)			

Çalışmanın bu kısmında çıktı verisi t zamanına ait aylık ortalama baraj göl seviye verisi olan modeller oluşturulmuş olup; bu modellerin DVM, YSA, RO, KA öğrenme algoritmaları ile analizleri yapılmıştır. Elde edilen bulgular NS, RMSE ve r istatistik kriterlerine göre yorumlanmıştır. Modeller oluşturulurken; öncelikle kot verisine yağışların etki ettiği düşünülmüştür. Akış, hacim, verisinden yararlanılarak, çapraz korelasyon sonuçları da dikkate alınarak, tahmin ayına ve önceki aylara ilişkin yağış verisi de eklenerek modeller oluşturularak model çeşitliliği artırılmıştır. Bunlara ilave olarak kuraklıkların da kot verisine etki edeceği düşünülerek, SYİ ve AKİ kuraklık indis sonuçları modellere girdi olarak eklenilmiştir. Dahası, yağış akış modellerinde en başarılı olan modellerden bazılarının girdi yapısı bu kısımda kullanılarak yağış akış modelleri ile arasındaki ilişki de incelenmiştir (M47-M50). Her algoritmaya göre tespit edilen bulgular farklı başlıklar altında irdelenmiştir. Analiz sonucunda, diğer modellere göre etkili olan modellerin, çıktı yapısındaki zamanı bazılarında 1, bazılarında 2, bazılarında da 3 ay ileriye taşınarak, bu zamandaki performans değerleri incelenmiştir. Daha uzun döneme ait tahminleri içeren bu modelleri diğer modeller ile ayırt edebilmek amacıyla, girdi yapısındaki adlarının yanlarına “t1”, “t2”, “t3” ifadesi eklenmiştir.

4.4.1. DVM ile analiz sonuçları

DVM ile analiz yapılırken, (ϵ , a , β , B gibi) algoritma parametreleri, model sonucuna en iyi etkiyi gösterecek şekilde otomatik olarak optimize edilmiştir. Hem kuraklık tahmin modellerinde hem de yağış akış tahmin modellerinde olduğu gibi, Kernel parametresi lineer seçilmiş olup, ölçeği 1’dir.

Şekil 4.81’de DVM ile yapılan analiz sonuçlarının özeti gösterilmiştir. Burada, NS değerlerinin -0,01 ile 0,98 arasında, r değerlerinin 0,02 ile 0,99 arasında yer aldığı görülmektedir.



Şekil 4.81. Dalgacık dönüşümü öncesi DVM analiz özet sonuçları

Çizelge 4.27’de ise, tüm modellere ait DVM ile yapılan analiz sonucunda performans değerleri verilmiştir. Çizelge 4.27 detaylı olarak incelendiğinde, M12 ve M11’in performans değerleri diğer modellere göre daha fazla etkili bulunmuştur. M12’nin performans değerleri NS: 0.9741, RMSE: 0.9123, r: 0.9904, M11’in performans değerleri NS: 0.9735, RMSE: 0.9241, r: 0.9904’dür. M12’nin girdi yapısı t, t-1, t-2, t-3 zamanlarına ait aylık ortalama hacim verisinden, M11’in girdi yapısı t, t-1, t-2 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Bu modellerin girdi yapılarında t zamanına ait veri olduğundan ötürü, bu modelleri performans olarak takip eden ve girdi yapısında t zamanına ait veri içermeyen modellerden olan M21 ve M20 de başarılı olan modeller arasındadır. M21’in performans değerleri, NS: 0.7868, RMSE: 2.6788, r: 0.8876 olarak hesaplanmıştır. M21’in girdi yapısı t-1, t-4, t-5, t-6, t-

11, t-12 zamanlarına ait aylık ortalama akış değerleri ile t-1, t-2 zamanlarına ait aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M20'nin performans değerleri NS: 0.7821, RMSE: 2.7079, r: 0.8863 olarak hesap edilmiştir.

Çizelge 4.27. DVM ile yapılan analiz sonuçları


Model	NS	RMSE	r
M01	0.3271	4.6411	0.5854
M02	0.3496	4.5739	0.5959
M03	0.3942	4.5266	0.6340
M04	0.3719	4.5830	0.6179
M05	0.6608	3.3030	0.8343
M06	0.6631	3.2918	0.8345
M07	0.7278	2.9591	0.8615
M08	0.7164	3.0204	0.8548
M09	0.7236	2.9819	0.8602
M10	0.7248	2.9751	0.8612
M11	0.9735	0.9241	0.9904
M12	0.9741	0.9123	0.9904
M13	0.9725	0.9401	0.9901
M14	0.6586	3.3139	0.8319
M15	0.6608	3.3030	0.8343
M16	0.7292	2.9572	0.8683
M17	0.7737	2.7030	0.8839
M18	0.7760	2.6894	0.8860
M19	0.3950	4.5121	0.6292
M20	0.7821	2.7079	0.8863
M21	0.7868	2.6788	0.8876
M22	0.3690	4.5810	0.6146
M23	0.7315	2.9879	0.8553
M24	0.4526	4.3026	0.6824
M25	0.4434	4.3387	0.6759
M26	0.4688	4.2384	0.6882
M27	0.4394	4.3543	0.6658
M28	0.4232	4.3916	0.6558
M29	0.4000	4.4793	0.6338
M30	0.4165	4.4171	0.6542
M31	0.3423	4.7045	0.6100
M32	-0.0025	5.8709	0.0234
M33	0.7292	3.0091	0.8566
M34	0.7222	3.0477	0.8527
M35	0.7296	3.0243	0.8545
M36	0.7197	3.0790	0.8510
M37	0.7230	2.9960	0.8524
M38	0.7368	2.9199	0.8607
M39	0.3738	4.5904	0.6324
M40	0.7423	2.9769	0.8628
M41	0.7477	2.9454	0.8694
M42	0.3482	4.6834	0.6220
M43	0.3670	4.6154	0.6346
M44	0.3766	4.5801	0.6403
M45	0.3668	4.6163	0.6336

Çizelge 4.27 (devam). DVM ile yapılan analiz sonuçları

Model	NS	RMSE	r
M46	0.7493	2.9048	0.8701
M47	0.3713	4.6347	0.6171
M48	0.3822	4.5997	0.6234
M49	0.3613	4.6625	0.6014
M50	0.3551	4.6851	0.6028
M21t1	0.5859	3.7412	0.7723
M20t1	0.5835	3.7523	0.7720
M18t1	0.5600	3.7744	0.7543

M20 modelinin girdi yapısı t-1, t-4, t-5, t-6, t-11, t-12 zamanlarına ait aylık ortalama akış değerleri ile t-1 zamanına ait aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M20 ve M21 modellerinin girdi yapısı birbirlerine çok benzer nitelikte olup, tek farklı M20’de t-2 zamanına ait aylık ortalama baraj göl seviyesi verisinin bulunmamasıdır. Buradan da anlaşılabacağı gibi, akış değerleri ve baraj göl seviyesi verisi ile etkili model sonuçlarının alınabilmektedir. Ayrıca, sadece baraj göl seviyesi ya da akış verisi kullanılarak oluşturulan (M04, M05, M19, M20 gibi) modeller performans olarak bu modellerin gerisinde kalmıştır. Başarılı olarak değerlendirilen M21 ve M20’nin t+1 çıkış zamanındaki sonuçlarına bakıldığında, M21t1 için performans değerleri NS: 0.5859, RMSE: 3.7421, r: 0.7723 ve M20t1 için performans değerleri NS: 0.5859, RMSE: 3.7421, r: 0.7723’dür. Çıktı verisi t zamanına ait birçok modelden daha etkili performans sergilemiştir. Ayrıca yağış-akış modellerinde başarılı sonuçlar alınan M47 ile M50 performanslarına bakıldığında çok iyi sonuçlar tespit edilememiştir.


Şekil 4.82’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M21 ve M20) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.82’de gösterilmiştir.



Şekil 4.82. DVM için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

DVM ile yapılan analiz sonucunda performans değerlerinin düşük olduğu gözlemlenmiştir. Kuraklık tahmin ve yağış akış tahmin modellerinde olduğu gibi, çalışmanın bu kısmında da dalgacık dönüşümünden yararlanılarak, performans değerleri iyileştirilmiştir. Dalgacık dönüşümleri sonucunda, model girdi yapılarına göre model sonuçlarında farklı performans iyileştirme oranları gözlemlenmiştir. Şekil 4.83’de tüm modellere ait dalgacık dönüşümünden sonraki performans değerleri gösterilmiştir. Şekil 4.83’de NS değerleri -0.03 ile 0.99 arasında, r değerleri -0.03 ile 0.61 arasında değişmiş ve modellerin yarısından daha fazlasının NS değerinin 0.85’den daha yüksek olmuştur. Bu sonuç, dalgacık dönüşümü ile model performanslarının ciddi ölçüde artırıldığını göstermektedir.

Daha detaylandırıldığında, diğer modellere göre daha başarılı modellerin zirvesinde M18 ve M09 vardır. Çizelge 4.28’de de belirtildiği üzere, M18’in performans değerleri NS: 0.9851, RMSE: 0.6942, r : 0.9926’dır. Girdi yapısı, $t-1$, $t-4$, $t-5$, $t-6$, $t-12$ zamanlarına ait aylık ortalama hacim değerleri ile 2 aya kadar geciktirilmiş baraj göl seviyesi verisinden oluşturulmuştur. Başarılı olan bir diğer model ise M09’dur. M09’ın performans değerleri NS: 0.9806, RMSE: 0.7894, r : 0.9903’dür. Model girdi yapısı 4 aya kadar geciktirilmiş baraj göl seviyesi verisinden oluşturulmuştur.



Şekil 4.83. Dalgacık dönüşümü sonrası DVM analiz özet sonuçları

Çizelge 4.28. Dalgacık dönüşümü ile DVM analiz sonuçları


Model	NS	RMSE	r
M01	0.2278	4.9719	0.6046
M02	0.2980	4.7517	0.6313
M03	0.3585	4.6578	0.6436
M04	0.3344	4.7175	0.6216
M05	0.9457	1.3211	0.9784
M06	0.9474	1.3009	0.9790
M07	0.9801	0.8006	0.9900
M08	0.9770	0.8598	0.9885
M09	0.9806	0.7894	0.9903
M10	0.9794	0.8147	0.9896
M11	0.9664	1.0389	0.9888
M12	0.9623	1.1016	0.9866
M13	0.9629	1.0922	0.9869
M14	0.9461	1.3167	0.9783
M15	0.9457	1.3211	0.9784
M16	0.8784	1.9814	0.9399
M17	0.9201	1.6065	0.9592
M18	0.9851	0.6942	0.9926
M19	0.2424	5.0494	0.5774

Çizelge 4.28 (devam). Dalgacık dönüşümü ile DVM analiz sonuçları

Model	NS	RMSE	r
M20	0.8626	2.1500	0.9315
M21	0.9568	1.2050	0.9786
M22	0.3804	4.5392	0.6554
M23	0.9562	1.2069	0.9779
M24	0.3401	4.7241	0.6372
M25	0.3154	4.8118	0.6237
M26	0.3174	4.8047	0.6164
M27	0.3165	4.8078	0.6171
M28	0.3846	4.5363	0.6585
M29	0.3439	4.6839	0.6281
M30	0.3424	4.6891	0.6261
M31	0.3202	4.7828	0.6171
M32	-0.3433	6.7959	-0.0244
M33	0.9585	1.1782	0.9792
M34	0.9583	1.1803	0.9792
M35	0.9412	1.4104	0.9705
M36	0.9470	1.3387	0.9741
M37	0.9697	0.9915	0.9850
M38	0.9796	0.8125	0.9898
M39	0.3040	4.8395	0.6120
M40	0.9666	1.0720	0.9833
M41	0.9668	1.0677	0.9835
M42	0.3855	4.5476	0.6512
M43	0.3340	4.7343	0.6251
M44	0.2976	4.8619	0.6102
M45	0.2452	5.0398	0.5766
M46	0.9496	1.3025	0.9746
M47	0.3975	4.5371	0.6470
M48	0.3303	4.7889	0.6100
M49	0.3687	4.6355	0.6327
M50	0.3574	4.6767	0.6278
M18t1	0.9477	1.3008	0.9736
M09t1	0.9434	1.3493	0.9714
M07t1	0.9279	1.5248	0.9635
M18t2	0.9304	1.5010	0.9647
M09t2	0.9049	1.7510	0.9515
M07t2	0.9121	1.6838	0.9553
M18t3	0.8717	2.0383	0.9339
M09t3	0.8898	1.8852	0.9436
M07t3	0.8943	1.8465	0.9464

Başarılı modellerden olan M18 ve M09'un çıktı verisi 1 ay ötelenerek oluşturulan M18t1 ve M09t1'in performans değerleri sırasıyla, NS: 0.9477, RMSE: 1.3008, r: 0.9736 ve NS: 0.9434, RMSE: 1.3493, r: 0.9714'dür. Bu modellerin sonuçları incelendiğinde, çıktı verisi t zamanına ait birçok modelden bile daha iyi sonuç vermiştir. Dolayısıyla, çıktı verisi 2 ay ötelenerek, hatta 3 ay ötelenerek tekrar model oluşturulmuş model performans değerleri tekrar hesaplanmıştır.

Şekil 4.84’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M18 ve M09) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.84’de gösterilmiştir. M18t2’nin performans değerleri NS: 0.9304, RMSE: 1.5010, r: 0.9515, M09t2’nin performans değerleri NS: 0.9049, RMSE: 1.7510, r: 0.9515’dir. M18t3’ün performans değerleri NS: 0.8717, RMSE: 2.0383, r: 0.9339, M09t3’ün performans değerleri NS: 0.8898, RMSE: 1.8852, r: 0.9436’dır. Yağış-akış tahmin modellerinde etkili sonuç veren modellerinde dalgacık dönüşümü yapılmış olup elde edilen değerlerin tatminkar seviyede olmadığı bulunan sonuçlardır.




Şekil 4.84. Dalgacık dönüşümü ile DVM için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

4.4.2. YSA ile analiz sonuçları

Baraj göl seviyesi tahmininde Hiperbolik Tanjant Fonksiyonunun ve LM eğitim algoritmasının kullanıldığı YSA ile analizlerden elde edilen özet bilgiler ve modellere ait sonuçlar Şekil 4.85 ve Çizelge 4.29’da gösterilmiştir. Gizli katmandaki nöron sayıları da deneme yanılma ile bulunmuş olup, en uygun sayılar Çizelge 4.29’da gösterilmiştir. Şekil 4.85 incelendiğinde; performans değerlerinin düşüklüğü baraj göl seviyesi tahmin modellerinde de ilk dikkat çeken sonuçlar arasındadır. DVM ile kıyaslandığında, genellikle NS ve r değerleri düşüktür. Dahası, modellerin 2/3’lük

kısımından daha fazlasının NS değeri 0.50'nin altındadır. Detaylı olarak incelendiğinde ise en başarılı performans değeri M13'de alınmıştır. Çizelge 4.29'dan da anlaşılacağı gibi, bu model için NS: 0.9469, RMSE: 1.3073, r: 0.9754 performans değerleri hesaplanmıştır. M13'ün girdi yapısı, t zamanına ait aylık ortalama hacim verisi ile yine aynı verinin 4 aya kadar geciktirilmesi ile oluşturulmuştur. Model girdi verisindeki t zamanına ait verinin bulunmasından dolayı performans değeri yükselmiştir.



Şekil 4.85. Dalgacık dönüşümü öncesi YSA analiz özet sonuçları

Bu modelin performans olarak takipçileri olan M12 ve M11'in de model girdi yapısında t zamanına ait veri bulunmaktadır. Dolayısıyla, her ne kadar bu modeller de başarılı sayılsa da, peşi sıra gelen, girdi yapısında t zamanına ait veri bulundurmayan M20'nin de başarılı olduğu belirlenmiştir. M20'nin girdi yapısı t-1, t-4, t-5, t-6, t-11, t-12 zamanlarına ait aylık ortalama akış verisi ile t-1 zamanına ait aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M20'nin performans değerleri, NS: 0.7113, RMSE: 3.1168, r: 0.8440 olarak hesap edilmiştir.


Çizelge 4.29. YSA analiz sonuçları

Model	NS	RMSE	r	Nör. S.
M01	-1.0483	8.0976	0.3126	94
M02	-0.0060	5.6884	0.4977	74
M03	0.0878	5.5545	0.5485	79
M04	0.2144	5.1251	0.5774	44
M05	0.2163	5.0209	0.6900	60
M06	0.1494	5.2306	0.6570	74
M07	0.1140	5.3384	0.6747	78
M08	-0.5662	7.0978	0.6451	97
M09	0.5402	3.8457	0.7643	90
M10	0.3087	4.7156	0.6984	96
M11	0.8122	2.4577	0.9173	94
M12	0.8652	2.0824	0.9374	92
M13	0.9469	1.3073	0.9754	37
M14	-0.0099	5.6996	0.6406	96
M15	-0.3801	6.6628	0.5520	91
M16	0.0144	5.6415	0.6268	83
M17	0.0204	5.6245	0.6913	74
M18	0.3418	4.6102	0.7448	70
M19	0.1693	5.2871	0.5013	54
M20	0.7113	3.1168	0.8440	63
M21	0.6764	3.2999	0.8365	51
M22	0.3705	4.5753	0.6881	67
M23	0.6408	3.4563	0.8152	30
M24	0.2743	4.9540	0.6400	67
M25	-0.1370	6.2011	0.4681	98
M26	0.1387	5.3971	0.5726	60
M27	0.0892	5.5502	0.5592	88
M28	0.3113	4.7988	0.6193	50
M29	0.1326	5.3856	0.5325	98
M30	-0.0051	5.7972	0.5026	92
M31	0.0237	5.7319	0.5478	76
M32	-1.8909	9.9696	0.2596	96
M33	-0.6213	7.3629	0.5223	68
M34	0.3212	4.7640	0.7061	79
M35	0.5481	3.9096	0.7888	96
M36	0.1898	5.2346	0.6780	98
M37	-0.3617	6.6423	0.5239	90
M38	0.5399	3.8609	0.7622	65
M39	0.1848	5.2378	0.5490	65
M40	0.5558	3.9081	0.7616	86
M41	0.5808	3.7966	0.7898	31
M42	0.1981	5.1949	0.5646	64
M43	-0.0507	5.9465	0.5213	50
M44	0.1883	5.2266	0.5447	84
M45	0.3179	4.7912	0.6314	50
M46	0.5260	3.9940	0.7913	95
M47	0.2947	4.9089	0.6132	57
M48	0.1333	5.4481	0.5651	51
M49	0.2288	5.1232	0.6592	83
M50	0.1677	5.3223	0.5898	95
M20t1	0.5104	4.0680	0.7318	81

Çizelge 4.29 (devam). YSA analiz sonuçları


Model	NS	RMSE	r	Nör. S.
M21t1	0.4620	4.2647	0.7034	97
M23t1	0.0791	5.5341	0.5417	48
M20t2	0.2661	4.9809	0.6739	100

M20'yi performans olarak takip eden, girdi yapısı çoğunlukla aynı olan M21'dir. M21'in performans değerleri NS: 0.6764, RMSE: 3.2999, r: 0.8365'dir. M20 ile girdi yapısındaki farklılık ise, model performans değerini olumsuz yönde etkileyen, t-2 zamanına ait olan aylık ortalama baraj göl seviyesi verisidir. Başarılı olan modellerin, ayrıca, çıktı zamanı +1 ve +2 ay ötelenmiş olup bu modellerinde performans değerleri hesaplanmıştır. Önceki bölümlerde olduğu gibi bu kısımda da daha uzun dönem tahminlerine ait olan bu modellerin sonuna "t1" ve "t2" ibaresi eklenmiştir. M20t1'in performans değerleri NS: 0.5104, RMSE: 4.0680, r: 0.7318, M21t1'in performans değerleri NS: 0.4620, RMSE: 4.2647, r: 0.7034'dür.



Şekil 4.86. YSA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.86'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M20 ve M21) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.86'da gösterilmiştir.



Şekil 4.87. Dalgacık dönüşümü sonrası YSA analiz özet sonuçları

YSA ile yapılan analiz sonucunda performans değerlerinin düşük olduğu gözlemlenmiştir. Bir önceki bölümde olduğu gibi, çalışmanın bu kısmında da dalgacık dönüşümünden yararlanılarak, performans değerleri iyileştirilmiştir. Dalgacık dönüşümleri sonucunda, model girdi yapılarına göre model sonuçlarında farklı performans iyileştirme oranları gözlemlenmiştir. YSA’da dalgacık dönüşümü ile yapılan iyileştirme sonucunda elde edilen performans değerlerinin özeti Şekil 4.87’de gösterilmiştir.

Dalgacık dönüşümünden sonra model sonuçlarının bazılarında NS değerleri negatiftir. Tüm model sonuçlarının performans değerleri Çizelge 4.30’da gösterilmiştir. Çizelge 4.30’da M07 ve M10 performans değerleri dikkat çekmektedir. Diğer modeller ile kıyaslandığında, bu modeller daha etkili olmuştur. Bu modellerin girdi yapısı sadece baraj göl seviyesi verisinden oluşturulmuştur. Dalgacık dönüşümü aynı tip veri ile

oluşturulan modellerde daha etkili olduğu tespit edilmiştir. M07'nin performans değerleri NS: 0.9581, RMSE: 1.1605, r: 0.9792, M10'un performans değerleri, NS: 0.9578, RMSE: 1.1657, r: 0.9794'dür.

Çizelge 4.30. Dalgacık dönüşümü ile YSA analiz sonuçları


Model	NS	RMSE	r
M01	-1.3324	8.6409	0.2978
M02	-0.2406	6.3171	0.5311
M03	-0.9975	8.2193	0.3663
M04	-0.9094	7.9903	0.3849
M05	0.8101	2.4713	0.9193
M06	0.8695	2.0487	0.9370
M07	0.9581	1.1605	0.9792
M08	0.9270	1.5325	0.9639
M09	0.9478	1.2957	0.9752
M10	0.9578	1.1657	0.9794
M11	0.6998	3.1073	0.8803
M12	0.8919	1.8646	0.9475
M13	0.7973	2.5532	0.9106
M14	0.7398	2.8928	0.8881
M15	0.8157	2.4345	0.9187
M16	0.6249	3.4803	0.8532
M17	0.8390	2.2805	0.9224
M18	0.9487	1.2873	0.9755
M19	-0.9551	8.1114	0.3201
M20	0.7441	2.9345	0.8658
M21	0.8634	2.1437	0.9369
M22	-0.2786	6.5209	0.4648
M23	0.8544	2.2002	0.9345
M24	-0.2509	6.5042	0.4667
M25	-0.4172	6.9232	0.3850
M26	-0.4572	7.0203	0.4304
M27	-0.6346	7.4353	0.3300
M28	-0.7688	7.6906	0.2881
M29	-0.5577	7.2171	0.4529
M30	-0.3652	6.7565	0.4504
M31	-0.1832	6.3102	0.5010
M32	-2.5623	11.0669	0.1713
M33	0.7552	2.8609	0.8793
M34	0.6756	3.2934	0.8308
M35	0.8157	2.4968	0.9148
M36	0.8359	2.3561	0.9285
M37	0.8833	1.9448	0.9444
M38	0.9207	1.6024	0.9604
M39	-0.1805	6.3029	0.5238
M40	0.7404	2.9877	0.8681
M41	0.8677	2.1324	0.9320
M42	-0.0818	6.0337	0.5177
M43	-0.4100	6.8885	0.3579
M44	-0.4416	6.9651	0.3696
M45	-0.3046	6.6260	0.3778

Çizelge 4.30 (devam). Dalgacık dönüşümü ile YSA analiz sonuçları

Model	NS	RMSE	r
M46	0.8728	2.0690	0.9355
M47	-1.2666	8.7999	0.3082
M48	-0.7389	7.7168	0.4793
M49	-0.3410	6.7560	0.4203
M50	-0.0790	6.0601	0.4565
M07t1	0.8031	2.5196	0.9095
M10t1	0.8840	1.9318	0.9455
M18t1	0.8120	2.4674	0.9119
M09t1	0.7994	2.5405	0.9009
M07t2	0.7795	2.6665	0.8923
M10t2	0.7496	2.8415	0.8836
M18t2	0.7720	2.7170	0.8945
M09t2	0.7519	2.8287	0.8777
M07t3	0.7639	2.7595	0.8858
M10t3	0.6891	3.1665	0.8645
M18t3	0.6317	3.4530	0.8261
M09t3	0.6014	3.5853	0.8236

Bu modelleri performans olarak M18 ve M09 takip etmektedir. Bu modellerin girdi yapısı ise sırasıyla, t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim değerleri ile 2 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden ve 4 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M18 için performans değerleri NS: 0.9487, RMSE: 1.1605, r: 0.9755, M09 için performans değerleri NS: 0.9478, RMSE: 1.2957, r: 0.9752 olarak hesaplanmıştır. Tüm bunlardan yola çıkarak, baraj göl seviyesi verisini girdi yapısında bulunduran modellerde önemli derece iyileştirmeler gerçekleştirilmiştir. Başarılı olan modellerin çıktı verisine ait zamanları 1, 2 ve 3 ay ötelenerek yeni modeller oluşturulmuş ve performans analiz değerleri hesap edilmiştir. Önceki kısımlarda olduğu gibi diğer modellerden ayırt etmek için, model adının yanına “t1”, “t2” ve “t3” ibareleri eklenmiştir. Bu modeller incelendiğinde ise çıktı zamanı t+1 olan modeller arasında, en başarılı sonuç, M10t1 ve M07t1’de alınmış, sırasıyla performans değerleri NS: 0.8840, RMSE: 1.9318, r: 0.9455 ve NS: 0.8031, RMSE: 2.5196, r: 0.9095’dir. Bu modeller arasında, M10t1’in M07t1’e göre daha iyi performans sergilediği belirlenmiştir. Dolayısıyla, çıktı zamanı t+1 olan modellerde, 6 yerine 5 ay aylık ortalama hacim verisinin geciktirilmesiyle, daha iyi sonuçlar alınabilmektedir. M09t1’nin performans değerleri NS: 0.7994, RMSE: 2.5405, r: 0.9009’dur. Modele geciktirilmiş aylık ortalama hacim verisinin eklenmesi ile model performansı artırılmıştır. Çıktı verisi zamanı t+2 ve t+3 olan modeller için aynı durum söz değildir. Girdi verisinin fazla geciktirilmesi model

sonucuna olumlu olarak yansımıştır. M10t2 ve M07t2’de alınmış, sırasıyla performans değerleri NS: 0.7496, RMSE: 2.8415, r: 0.8836 ve NS: 0.7795, RMSE: 2.6665, r: 0.8923’dür. M09t2’nin performans değerleri M10t2 ile neredeyse aynı olup, M07t2’nin gerisinde kalmıştır.




Şekil 4.88. Dalgacık dönüşümü ile YSA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.88’de girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M20 ve M21) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.88’de gösterilmiştir.

4.4.3. RO ile analiz sonuçları

Optimum ağaç sayısının, otomatik olarak belirlendiği RO ile yapılan analizlere ait sonuçların özeti Şekil 4.89’de gösterilmiştir. Şekil 4.89 incelendiğinde, bir değer haricinde (-0.0284) NS değerlerinin 0.28 ile 0.68 arasında, r değerlerinin 0.01 ile 0.99 arasında değiştiği görülmektedir. Her modele karşılık RMSE değerleri 0.90 ile 5.00 arasında değişmektedir.



Şekil 4.89. Dalgacık dönüşümü öncesi RO analiz özet sonuçları

Çizelge 4.31’de RO analiz sonuçları verilmiştir. Bu sonuçlara göre M12 ve M13 diğer modellere göre daha etkili olmuştur. M12 için performans değerleri NS: 0.9735, RMSE: 0.9233, r: 0.9921, M13 için performans değerleri NS: 0.9675, RMSE: 1.0221, r: 0.9890 olarak hesaplanmıştır. M12’nin girdi yapısı, t, t-1, t-2, t-3 zamanlarına ait aylık ortalama hacim verisinden, M13’ün girdi yapısı t, t-1, t-2, t-3, t-4 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Her iki modelde t zamanına ait girdi verisi bulunmaktadır. Bu modelleri performans olarak M35 ve M36 takip etmektedir. M35 için performans değerleri NS: 0.8002, RMSE: 2.5998, r: 0.9014, M36 için performans değerleri NS: 0.7815, RMSE: 2.7184, r: 0.8949 şeklinde hesaplanmıştır. M35’in girdi yapısı 2 aya kadar geciktirilmiş AKİİ verisi ile 2 aya kadar geciktirilmiş aylık ortalama hacim verisinden, M36’ın girdi yapısı ise 3 aya kadar geciktirilmiş AKİİ verisi ile 3 aya kadar geciktirilmiş aylık ortalama hacim verisinden oluşturulmuştur.

Çizelge 4.31. RO analiz sonuçları


Model	NS	RMSE	r
M01	0.3608	4.5236	0.6287
M02	0.3719	4.4950	0.6376
M03	0.5116	4.0641	0.7159
M04	0.4814	4.1641	0.6965
M05	0.7150	3.0275	0.8517
M06	0.7087	3.0610	0.8495
M07	0.7166	3.0193	0.8500
M08	0.7139	3.0338	0.8465
M09	0.7378	2.9039	0.8609
M10	0.7264	2.9665	0.8550
M11	0.9496	1.2737	0.9808
M12	0.9735	0.9233	0.9921
M13	0.9675	1.0221	0.9890
M14	0.7180	3.0117	0.8543
M15	0.7146	3.0297	0.8522
M16	0.7434	2.8787	0.8687
M17	0.7526	2.8263	0.8713
M18	0.7532	2.8230	0.8710
M19	0.4803	4.1820	0.6992
M20	0.7356	2.9830	0.8657
M21	0.7388	2.9650	0.8710
M22	0.4966	4.0917	0.7095
M23	0.7734	2.7450	0.8961
M24	0.5107	4.0678	0.7149
M25	0.5015	4.1062	0.7088
M26	0.5225	4.0185	0.7231
M27	0.5032	4.0990	0.7100
M28	0.4103	4.4405	0.6542
M29	0.3434	4.6855	0.6109
M30	0.3458	4.6772	0.6144
M31	0.2851	4.9050	0.5793
M32	-0.0284	5.9462	0.0141
M33	0.7212	3.0531	0.8516
M34	0.7188	3.0666	0.8540
M35	0.8002	2.5998	0.9014
M36	0.7815	2.7184	0.8949
M37	0.7016	3.1095	0.8389
M38	0.7121	3.0543	0.8462
M39	0.4221	4.4099	0.6688
M40	0.5366	3.9914	0.8089
M41	0.6945	3.2410	0.8550
M42	0.4130	4.4444	0.6640
M43	0.4260	4.3951	0.6554
M44	0.5017	4.0949	0.7094
M45	0.4242	4.4020	0.6545
M46	0.7300	3.0142	0.8684
M47	0.5314	4.0014	0.7302
M48	0.5103	4.0953	0.7165
M49	0.5296	4.0014	0.7338
M50	0.5250	4.0210	0.7312
M35t1	0.5937	3.7078	0.7858

Çizelge 4.31 (devam). RO analiz sonuçları

Model	NS	RMSE	r
M36t1	0.5877	3.7129	0.7821
M23t1	0.5588	3.8307	0.7664


Burada AKİl değerleri ile hacim verisinin kullanılmasıyla oluşturulan modellerde diğer modellere göre daha etkili sonuç alındığı, ayrıca geciktirme değerlerinin de optimum düzeyde tutulması gerektiği tespit edilmiştir. Bu iki modelin çıktı verisinin zamanı 1 ay ötelenerek performans değerleri tekrar hesaplanmıştır. M35t1 için NS: 0.5937, RMSE: 3.7078, r: 0.7858, M36t1 için NS: 0.5877, RMSE: 3.7129, r: 0.7821 performans değerleri hesap edilmiştir. RO algoritmasında sadece baraj göl seviyesi, hacim, yağış, akış gibi verinin kullanılmasıyla iyi sonuçlar elde edilemediği bulunan diğer sonuçlardandır.

Şekil 4.90'da girdi yapısında t zamanına ait olmayan veri ile oluşturulan en başarılı modellerin (M35 ve M36) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.90'da gösterilmiştir.



Şekil 4.90. RO için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Önceki bölümlerde olduğu gibi, çalışmanın bu kısmında da RO algoritması ile elde edilen sonuçların iyileştirmesi için dalgacık dönüşümünden faydalanılmıştır. Dalgacık dönüşümünden elde edilen model sonuçları Şekil 4.91’de gösterilmiştir. Şekil 4.91 incelendiğinde, bir model haricinde (M32) tüm modellerin NS değerlerinin 0.39’un üzerinde olduğu, NS değerlerinin M32 haricinde 0.39 ile 0.84 arasında olduğu, r değerlerinin de 0.65 ile 0.94 arasında olduğu belirlenmiştir. Tüm sonuçlara ait performans değerleri Çizelge 4.32’de verilmiştir. Çizelge 4.32’de, her ne kadar performans değerleri ile M13, M11 ve M12 öne çıkmış ise de, M07 ve M10 RO’nun dalgacık dönüşümüyle başarılı modelleri arasındadır. M13, M11 ve M12’nin girdi yapısında t zamanına hacim verisi içerdiğinden dolayı modelleme çalışmalarında pek tercih edilmeyebilir.



Şekil 4.91. Dalgacık dönüşümü sonrası RO analiz özet sonuçları

Dolayısıyla, M07’nin girdi yapısı incelendiğinde 6 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluştuğu ifade edilmişti. Performans değerleri

ise NS: 0.8165, RMSE: 5.4293, r: 0.9123 şeklinde hesaplanmıştır. M10'un girdi yapısı ise 5 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Geciktirme zamanı 1 ay artırılarak etkili sonuçlar alınabildiği bu kısımda tespit edilmiştir.


Çizelge 4.32. Dalgacık dönüşümü ile RO analiz sonuçları

Model	NS	RMSE	r
M01	0.4021	4.3748	0.6578
M02	0.3933	4.4175	0.6551
M03	0.4461	4.3282	0.6823
M04	0.4452	4.3071	0.6834
M05	0.7768	2.6795	0.9113
M06	0.7824	2.6455	0.9084
M07	0.8165	2.4293	0.9123
M08	0.7418	2.8818	0.8795
M09	0.7901	2.5986	0.9036
M10	0.8127	2.4543	0.9139
M11	0.8317	2.3270	0.9385
M12	0.8229	2.3870	0.9332
M13	0.8324	2.3218	0.9384
M14	0.7686	2.7280	0.9139
M15	0.7841	2.6354	0.9167
M16	0.7777	2.6793	0.8957
M17	0.8015	2.5318	0.9061
M18	0.7997	2.5430	0.9043
M19	0.4718	4.2159	0.6965
M20	0.6128	3.6098	0.7930
M21	0.6465	3.4490	0.8156
M22	0.5070	4.0492	0.7216
M23	0.7087	3.1124	0.8572
M24	0.4416	4.3457	0.6743
M25	0.4362	4.3669	0.6713
M26	0.4807	4.1907	0.7025
M27	0.4559	4.2897	0.6884
M28	0.4986	4.0946	0.7203
M29	0.4718	4.2024	0.7016
M30	0.4512	4.2839	0.6862
M31	0.4502	4.3013	0.6872
M32	-0.1329	6.2411	-0.0029
M33	0.7046	3.1429	0.8755
M34	0.7189	3.0658	0.8825
M35	0.7381	2.9760	0.8824
M36	0.7226	3.0632	0.8679
M37	0.7058	3.0873	0.8748
M38	0.7416	2.8933	0.8859
M39	0.4582	4.2701	0.6945
M40	0.6152	3.6372	0.8234
M41	0.6852	3.2901	0.8676
M42	0.4752	4.2026	0.7039
M43	0.4679	4.2318	0.6963
M44	0.4993	4.1049	0.7197

Çizelge 4.32 (devam). Dalgacık dönüşümü ile RO analiz sonuçları

Model	NS	RMSE	r
M45	0.4482	4.3093	0.6819
M46	0.6469	3.4472	0.8172
M47	0.4476	4.3443	0.6826
M48	0.4405	4.3773	0.6802
M49	0.4654	4.2655	0.6919
M50	0.4450	4.3464	0.6791
M07t1	0.7963	2.5630	0.9011
M10t1	0.8032	2.5163	0.9067
M17t1	0.7716	2.7192	0.8900
M07t2	0.7826	2.6476	0.8955
M10t2	0.7897	2.6041	0.8980
M17t2	0.7541	2.8217	0.8795
M07t3	0.7762	2.6865	0.8916
M10t3	0.7739	2.7000	0.8905
M17t3	0.7187	3.0181	0.8615

Başarılı olarak değerlendirilen M07 ve M10'un çıktı yapısındaki verinin zamanı 1 ay ötelenerek M07t1 ve M10t1 oluşturulmuştur. Bu modellerin performans değerleri sırasıyla, NS: 0.7963, RMSE: 2.5630, r: 0.9011 ve NS: 0.8032, RMSE: 2.5163, r: 0.9067'dir. Çıktı yapısındaki verinin zamanı 1 ay ötelenerek elde edilen sonuçlar etkili




Şekil 4.92. Dalgacık dönüşümü ile RO için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

olduğundan dolayı, çıktı zamanı 1 ve 2 ay daha ötelenmiş olup, M07t2, M10t2, M07t3, M10t3 modelleri de oluşturulmuştur. Bu modellerin performans değerleri Çizelge 4.32’de gösterilmiştir.

4.4.4. KA ile analiz sonuçları

Optimum ağaç sayısının, otomatik olarak belirlendiği KA metodu ile yapılan analizlerin özeti Şekil 4.93’de gösterilmiştir.



Şekil 4.93. Dalgacık dönüşümü öncesi KA analiz özet sonuçları

Şekil 4.93 incelendiğinde, NS değerlerinin -0.75 ile 0.96 ile arasında, r değerlerinin -0.13 ile 0.99 arasında değiştiği görülmektedir. Çizelge 4.33’de ise tüm modellere ait analiz sonuçları verilmiştir. Çizelge 4.33’de M11, M12 ve M13 performans olarak diğer modellere göre daha etkili olduğu görülmektedir. Fakat bu modellerin girdi yapısında t zamanına ait veri olmasından ötürü yüksek performans değerleri elde edilmiştir. Bunun aksine girdi yapısında t zamanına ait veri içermeyen ve bu modellerin takipçisi olan M41 ve M17’nin de KA algoritmasında etkili sonuçlar


verdiği belirlenmiştir. M41'in girdi yapısı 3 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisi ile t-12, t-13, t-14, t-15 zamanlarına ait AKİ12 değerinden oluşturulmuştur. M41'in performans değerleri NS: 0.7090, RMSE: 3.1629, r: 0.8424'dür. M17 modelinin girdi yapısı, t-1 zamanına ait aylık ortalama baraj göl seviyesi verisi ile t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. M17'nin performans değerleri ise, NS: 0.6911, RMSE: 3.1584, r: 0.8401'dir.

Çizelge 4.33. KA analiz sonuçları

Model	NS	RMSE	r
M01	0.2373	4.9411	0.5454
M02	0.1479	5.2354	0.4477
M03	0.4980	4.1203	0.7123
M04	0.4106	4.4392	0.6600
M05	0.6125	3.5306	0.8079
M06	0.6148	3.5200	0.8080
M07	0.6569	3.3219	0.8217
M08	0.6654	3.2808	0.8276
M09	0.6314	3.4431	0.8079
M10	0.6431	3.3883	0.8134
M11	0.9569	1.1777	0.9883
M12	0.9569	1.1777	0.9883
M13	0.9569	1.1777	0.9883
M14	0.5807	3.6726	0.7899
M15	0.6062	3.5590	0.8072
M16	0.6540	3.3425	0.8206
M17	0.6911	3.1584	0.8401
M18	0.6730	3.2498	0.8314
M19	0.3434	4.7008	0.6173
M20	0.5749	3.7821	0.7628
M21	0.5771	3.7725	0.7633
M22	0.4350	4.3347	0.6659
M23	0.6778	3.2733	0.8277
M24	0.4980	4.1203	0.7123
M25	0.3390	4.7281	0.6322
M26	0.3980	4.5121	0.6468
M27	0.3857	4.5582	0.6478
M28	0.4061	4.4564	0.6522
M29	0.2325	5.0659	0.5543
M30	0.2970	4.8483	0.5917
M31	0.0932	5.5243	0.4762
M32	-0.7434	7.7422	-0.1218
M33	0.5604	3.8339	0.7584
M34	0.6146	3.5900	0.7843
M35	0.6123	3.6211	0.7931
M36	0.6434	3.4731	0.8150
M37	0.6576	3.3309	0.8260
M38	0.6537	3.3495	0.8169
M39	0.3084	4.8244	0.6015

Çizelge 4.33 (devam). KA analiz sonuçları

Model	NS	RMSE	r
M40	0.6864	3.2834	0.8308
M41	0.7090	3.1629	0.8424
M42	0.3659	4.6196	0.6338
M43	0.2067	5.1668	0.5514
M44	0.4246	4.4005	0.6638
M45	0.2701	4.9560	0.5669
M46	0.5859	3.7328	0.7706
M47	0.4891	4.1778	0.7049
M48	0.4285	4.4239	0.6659
M49	0.4012	4.5146	0.6436
M50	0.4012	4.5146	0.6436
M41t1	0.7102	3.1567	0.8432
M17t1	0.4031	4.3960	0.6647
M40t1	0.6230	3.6003	0.7945




Şekil 4.94. KA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

Şekil 4.94’de girdi yapısında t zamanına ait olmayan en başarılı modellerin (M41 ve M17) zaman serisi ve gözlem değerlerine göre saçılma diyagramı verilmiştir. Gözlem değerleri ile her iki modelin uyum sağlamadığı ve gözlem değerlerindeki zirve noktalarının tahmin değerlerindeki zirve noktaları ile örtüşmediği Şekil 4.94’de gösterilmiştir.

KA ile yapılan analiz sonuçlarında performans değerlerinin, diğer algoritmalar ile elde edilen performans değerlerine göre biraz daha geridedir. Ayrıca, başarılı modellerin

girdi yapısında AKİ değerlerinin olması dikkat çeken sonuçlardan birisidir. Başarılı olarak tespit edilen modellerin çıktı verisinin zamanı 1 ay ötelenerek, M41t1 ile M17t1 modelleri oluşturulmuştur. M41t1'in performans değerleri, NS: 0.7102, RMSE: 3.1567, r: 0.8432, M17t1'in performans değerleri, NS: 0.4031, RMSE: 4.3960, r: 0.6647'dir.



Şekil 4.95. Dalgacık dönüşümü sonrası KA analiz özet sonuçları


Önceki kısımlarda olduğu gibi KA algoritmasında da model sonuçlarının iyileştirilmesi için, dalgacık dönüşümünden yararlanılmıştır. Şekil 4.95'de KA'nın dalgacık dönüşümünden sonra elde edilen modellere ait performans değerlerinin özet bilgisi yer almaktadır. Burada NS değerlerinin -0.85 ile 0.73 arasında, r değerlerinin -0.04 ile 0.87 arasında değiştiği görülmektedir. Dalgacık dönüşümden sonra model sonuçlarının bazılarında iyileştirme gerçekleşmediği, hatta aksine performans değerlerinde gerileme tespit edilmiştir.

Çizelge 4.34. Dalgacık Dönüşümü ile KA analiz sonuçları

Model	NS	RMSE	r
M01	0.2415	4.9277	0.5801
M02	0.1668	5.1769	0.5088
M03	0.3278	4.7682	0.6132
M04	0.4161	4.4185	0.6744
M05	0.4875	4.0600	0.7576
M06	0.5907	3.6285	0.8075
M07	0.6460	3.3746	0.8174
M08	0.7066	3.0720	0.8446
M09	0.6997	3.1078	0.8472
M10	0.7263	2.9669	0.8628
M11	0.7168	3.0181	0.8597
M12	0.7104	3.0521	0.8618
M13	0.7157	3.0240	0.8660
M14	0.5240	3.9128	0.7535
M15	0.5244	3.9113	0.7817
M16	0.7098	3.0612	0.8492
M17	0.7052	3.0856	0.8439
M18	0.6922	3.1529	0.8436
M19	0.4037	4.4795	0.6600
M20	0.4634	4.2495	0.7200
M21	0.4356	4.3583	0.7070
M22	0.4332	4.3415	0.6695
M23	0.5212	3.9902	0.7515
M24	0.3991	4.5083	0.6443
M25	0.1945	5.2195	0.5325
M26	0.3976	4.5138	0.6691
M27	0.3665	4.6287	0.6514
M28	0.4961	4.1048	0.7226
M29	0.2548	4.9919	0.5901
M30	0.3639	4.6120	0.6514
M31	0.1172	5.4506	0.5477
M32	-0.8574	7.9913	-0.0304
M33	0.5935	3.6869	0.7832
M34	0.5297	3.9656	0.7367
M35	0.4856	4.1712	0.7500
M36	0.5089	4.0753	0.7341
M37	0.5623	3.7657	0.7686
M38	0.5780	3.6977	0.7918
M39	0.1911	5.2174	0.5565
M40	0.3360	4.7780	0.6796
M41	0.3083	4.8767	0.6493
M42	0.2093	5.1583	0.5716
M43	0.2464	5.0359	0.5835
M44	0.2910	4.8848	0.5959
M45	0.1179	5.4484	0.5275
M46	0.5723	3.7939	0.7932
M47	0.3095	4.8569	0.6444
M48	0.4002	4.5322	0.6621
M49	0.3765	4.6065	0.6478
M50	0.3765	4.6065	0.6478

Çizelge 4.34 incelendiğinde en etkili sonuç M10'da tespit edilmiştir. M10'un performans değerleri NS: 0.7263, RMSE: 2.9669, r: 0.8628'dir. Girdi yapısı 5 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M11, M12, M13 girdi yapısında t zamanına ait veri bulundurmasından dolayı, bu modelleri performans olarak takip eden ve girdi yapısında t zamanına ait veri içermeyen M16, bir diğer başarılı modeldir. M16'nın performans değerleri NS: 0.7098, RMSE: 3.0612, r: 0.8492'dir. Girdi yapısı t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Dalgacık iyileştirmesi model sonuçlarına olumsuz etki yapmasından dolayı başarılı olan modellerin çıktı verisinin zamanlarında öteleme yapılmamıştır.

Şekil 4.96'da başarılı modellerden olan M16 ve M10'a ait model sonuçları ile gerçek değerlerin zaman serisinde karşılıkları verilmiştir. Şekil 4.96'dan da anlaşılabacağı gibi elde edilen iki model sonuçlarının gerçek değer ile uyum sağlamadığı belirlenmiştir.



Şekil 4.96. Dalgacık dönüşümü ile KA için baraj göl seviyesi en iyi model sonuçlarına ait zaman serisi ve saçılma diyagramı

4.5. Tüm Analiz Sonuçlarının Karşılaştırılması


Çalışmanın bu kısmında kuraklık tahmin modelleri, yağış-akış tahmin modelleri ve baraj göl seviyesi tahmin modelleri olmak üzere üç farklı grupta, kendi grubu içerisindeki algoritma bazında en iyi performans gösteren modeller kıyaslanmıştır. Bu çalışmada, performans kriterleri olarak NS, RMSE ve r'den yararlanılmıştır. Önceki bölümlerde bir modelin başarılı sayılabilmesi için, önce NS değerleri, sonra r değerleri en son da RMSE değerleri yorumlanmıştı. Bu bölümde de, değerlendirme aynı sırada yapılmış olup, sonuçların birbirleri ile daha kapsamlı değerlendirilip karşılaştırılması için aynı zamanda Taylor ve Violin Diyagramlarından da yararlanılmıştır. Kıyaslama yapılırken her algoritmada en başarılı olan bir model yani sınıfında en iyi olan modeller Taylor ve Violin Diyagramı'nda gösterilmiştir. Taylor diyagramı gözlenmiş değere en yakın olan modeli tespitinde yardım ederken, Violin Diyagramı modellerdeki elde edilen tahminlerin dağılımını gözlenmiş olan verilerin dağılımı ile kıyaslamakta ve gerek dağılım olarak gerekse en uç değerlerin tahminindeki isabet miktarlarını göstererek tahminlerin güvenilirliğini ortaya koymaktadır.

4.5.1. Kuraklık tahmin modelleri karşılaştırılması

Kuraklık tahmin modelleri, SYİ'nin farklı zaman adımlarına göre analiz edilip, her bir model kendi kategorisi içinde yorumlanmıştır. SYİ'nin aynı zaman adımlarının birbiri ile kıyaslanmasının daha doğru sonuç vereceği düşünülmüş, tüm karşılaştırmalar da aynı zaman adımını içeren model sonuçlarına göre yapılmıştır. Dolayısıyla, ilk karşılaştırma M01 ile M12 arasında yapılmıştır. Şekil 4.97'de SYİ24 verisi içeren modellerin, farklı algoritmalar ile analiz edilip elde edilen tahmin sonuçlarının Taylor Diyagramı'na göre birbiri ile karşılaştırılmıştır.


SYİ24 verisi ile oluşturulan algoritma bazında en başarılı performans değerleri, DVM algoritması ile M06'da, kısaltmasıyla DVMM06'da, DVM'nin dalgacık dönüşümü ile M03'de, kısaltmasıyla DVMDM03'de, YSA algoritması ile M06'da, kısaltmasıyla YSAM06'da, YSA'nın dalgacık dönüşümü ile M08'de, kısaltmasıyla YSADM08'de, RO algoritması ile M06'da, kısaltmasıyla ROM06'da, RO'nun dalgacık dönüşümü ile M01'de, kısaltmasıyla RODM01'de, KA algoritması ile M06'da, kısaltmasıyla KAM06'da, KA'nın dalgacık dönüşümü ile M01'de, kısaltmasıyla KADM01'de belirlenmiştir. Bu modeller arasında en başarılı sonuç, performans değerlendirme kriterlerine (NS: 0.9970, RMSE: 0.0498, r: 0.9986) göre DVMDM03'dür. Peşi sıra

gelen YSADM08'in performans değerleri de NS: 0.9831, RMSE: 0.1177, r: 0.9918'dir. Taylor Diyagramı'na göre de, gözlem değerine en yakın modeller DVMDM06 ve YSADM08'dir.



Şekil 4.97. SYİ24 ile en başarılı kuraklık tahmin modellerinin Taylor Diyagramı


DVMM06, bahsedilen modellerden sonra gözlem değerine en yakın olan modeldir. DVMM06'nın performans değerleri NS: 0.9550, RMSE: 0.1915, r: 0.9778 idi. Performans sonuçlarına göre, en başarılı olan modeller ile Taylor Diyagramı'ndaki en başarılı olan modeller birbiriyle örtüşmektedir. Bu modellere ait farklı yorumlamalar Violin Diyagramı ile de yapılmış olup Şekil 4.98'de gösterilmiştir. Şekil 4.98 incelendiğinde ise, gözlem değerine en yakın şekil veren modellerin DVMM06 ve DVMDM03 ve YSADM08 olduğu görülmüştür.



Şekil 4.98. SYİ24 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı

Bunlar arasında YSADM08 sonuçlarının %99'luk kısmında farklılıklar olduğu, gözlem şekliyle kısmen benzediği tespit edilmiştir. Nitekim DVMM06 ve DVMDM03'in gözlem değerine şekil olarak en çok benzeyen model olduğu bulunan sonuçlar arasındadır. Taylor diyagramından da görüldüğü gibi dalgacık dönüşümü yapılmamış modeller arasında en iyi sonucu veren DVMM06 olmuştur. Bu sonucu Violin diyagramı da teyit etmekte olup, gözlenmiş verilere en yakın dağılım ve en uç noktalardaki (ekstrem) değer tahmininde DVMM06 modeli oldukça iyi performans göstermekte olup YSADM08'den daha iyi uç değer tahmini yaptığı görülmektedir.

Kuraklık tahmin modellerinde girdi verisi olarak kullanılan başka bir veri de SYİ12'dir. Girdi yapısında bu veriyi içeren en başarılı kuraklık tahmin modelleri Şekil 4.99'da Taylor Diyagramında gösterilmiştir. Bu diyagramda bahsedilen; DVMM18 DVM algoritması ile M18'i, DVMDM16 DVM'nin dalgacık dönüşümü ile M16'yı, YSAM18 YSA algoritması ile M18'i, YSADM20 YSA'nın dalgacık dönüşümü ile M20'yi, ROM18 RO algoritması ile M18'i, RODM18 RO'nun dalgacık dönüşümü ile M18'i, KAM18 KA algoritması ile M18'i, KADM18 KA'nın dalgacık dönüşümü ile M18'i ifade etmektedir. DVMDM16'nın performans değerleri, NS: 0.9942, RMSE: 0.0764, r: 0.9971, YSADM20'nin performans değerleri, NS: 0.9735, RMSE: 0.1627, r: 0.9871 şeklinde idi. Performans değerleri ile diğer algoritmalar göre daha etkili olan bu modeller Taylor Diyagramında da gözlem değerine en yakın modeller olup en başarılı modeller olarak gösterilmektedir.




Şekil 4.99. SYİ12 ile en başarılı kuraklık tahmin modellerinin Taylor Diyagramı

KADM18 ve DVMM18 modelleri gözlem değerlerine en başarılı modellerden biraz daha uzak mesafededir. Bu iki model, Taylor Diyagramı'nda performans olarak DVMDM16 ve YSADM20 modellerinden sonra gelmektedir. Şekil 4.99'da verilen Taylor Diyagramının gösterdiği bir başka sonuç ise RODM18 modeli dalgacık dönüşümü sonrası performans olarak dalgacık dönüşümü öncesi modellerinin gerisine düşmüştür.

Şekil 4.100'de ise, bu modellere ait Violin Diyagramı verilmiştir. Şekil 4.100'de DVMDM16 gözlem değeri ile hemen hemen aynı olduğu görülmektedir. YSADM20 de gözlem değeri ile şekil olarak benzese de, DVMDM16'nın en uç noktadaki değerleri tahin etmede DVMDM16'ya göre geride kalmaktadır. YSADM20 en düşük değeri yakalayamamış ve en büyük değerden biraz fazla tahminde bulunmuş olmasına rağmen genel olarak dağılımına bakıldığında gözlem değerlerin dağılımına yakın bir

dağılım ile tahmin sonuçları üretmiştir. KADM18 modeli Taylor diyagramında en iyi üçüncü model olmasına rağmen Violin diyagramında en uç değerleri tahminde performansını düşüğü görülmektedir. En uç değerler haricinde gözlem değerlerine yakın sonuç vermiştir. Bunlar göz önünde bulundurulursa, Violin Diyagramına göre en başarılı model DVMDM16'dır.




Şekil 4.100. SYİ12 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı

RODM18, ise Violin Diyagramı'nda gözlem değeri ile en uyumsuz olan modellerden birisi olarak tespit edilmiştir. Bu model Taylor Diyagramı'nda da gözlem değerine en uzak olan modellerden birisidir. Maksimum ve minimum değerleri de tahmin etmede yetersiz kalmıştır.

Şekil 4.101'de girdi yapısında SYİ9 verisini kullanan en başarılı kuraklık tahmin modelleri Taylor Diyagramı'nda gösterilmiştir. Bu modeller M25 ile M36 arasında isimlendirilmiştir. Şekil 4.101'de bahsedilen; DVMM30 DVM algoritması ile M30'u, DVMDM30 DVM'nin dalgacık dönüşümü ile M30'u, YSAM30 YSA algoritması ile M30'u, YSADM25 YSA'nın dalgacık dönüşümü ile M25'i, ROM30 RO algoritması ile M30'u, RODM27 RO'nun dalgacık dönüşümü ile M27'yi, KAM30 KA algoritması ile M30'u, KADM33 KA'nın dalgacık dönüşümü ile M33'ü ifade etmektedir.

SYİ9 için oluşturulan modeller arasında performans değerleri diğerlerine göre en iyi olan DVMDM30'dur. Bu modelin performans değerleri NS: 0.9923, RMSE: 0.0865, r: 0.9961'dir. Bu modeli YSADM25 takip etmekte olup performans değerleri NS: 0.9749, RMSE: 0.1557, r: 0.9879'dur.




Şekil 4.101. SYİ9 verisi içeren en başarılı kuraklık tahmin modellerinin Taylor Diyagramı

Şekil 4.101'deki Taylor Diyagramı'na göre gözlem değerine en yakın olduğu için en iyi model seçilen DVMDM30 ve YSADM25 modellerini, DVMM25 ve YSAM30 modelleri izlemektedir. Sırasıyla bu en iyi modellerin performans değerleri ise, NS: 0.8040, RMSE: 0.4355, r: 0.8967 ve NS: 0.8699, RMSE: 0.3553, r: 0.9343'dür. SYİ9 için belirlenen en iyi modeller arasında Taylor Diyagramında diğer modellere göre en kötü performansı dalgacık dönüşümü uygulanmasına rağmen RODM27 sergilemiştir. RODM27'nin performans değerleri (NS: 0.7135, RMSE: 0.5169, r: 0.8508) de bunu destekler niteliktedir.

Taylor Diyagramı'nda ifade edilen modeller Violin Diyagramı'nda da gösterilmiştir (Şekil 4.102). Şekil 4.102 incelendiğinde, gözlem değeri dağılımına en benzer

sonuçlar DVMDM30 ve YSADM25 modellerinden alınmıştır. Bu modeller maksimum ve minimum değerleri tahmin etmede Şekil 102’de görüldüğü gibi oldukça iyidir. ROM30 ve KAM30 gözlem değeri ile kısmi olarak uyum sağladığı Şekil 4.102’de gösterilmiştir. ROM30 modeli en düşük değerleri iyi tahmin edememiştir.




Şekil 4.102. SYİ9 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı

DVMDM30, YSADM30 Violin Diyagramı’na göre gözlem değeri ile birbirine en çok uyum sağlayan (şekil olarak benzeyen) modellerdir.


Kuraklık tahmin modellerinde kullanılan başka model SYİ6 verisi ile yapılmıştır. Bu veri seti ile oluşturulan modeller M37 ile M48 arasındadır. Şekil 4.103’de girdi yapısında SYİ6 verisini kullanan en başarılı kuraklık tahmin modellerine ait Taylor Diyagramı gösterilmiştir. Şekil 4.103’de gösterilen; DVMM42 DVM algoritması ile M42’yi, DVMDM39, DVM’nin dalgacık dönüşümü ile M39’u, YSAM42 YSA algoritması ile M42’yi, YSADM37 YSA’nın dalgacık dönüşümü ile M37’yi, ROM42 RO algoritması ile M42’yi, RODM40 RO’nun dalgacık dönüşümü ile M40’ı, KAM42 KA algoritması ile M42’yi, KADM43 KA’nın dalgacık dönüşümü ile M43’ü ifade etmektedir. Bu modeller arasında performans değerleri diğerlerine göre en yüksek olan model DVMDM39’dur (NS: 0.9861, RMSE: 0.1136, r: 0.9931). Bu modeli NS: 0.9626, RMSE: 0.1911, r: 0.9832 performans değerleri ile YSADM37 takip etmektedir. Bu iki model Taylor Diyagramında diğer modellere göre gözlem değerine daha yakın olduğu için en iyi model olarak görülmektedir. Şekil 4.103 incelendiğinde,

gözlem değerlerine en yakın olarak tespit edilen bu iki modelin diyagram üzerindeki yerleri birbirine yakın mesafededir. Dolayısıyla, bu modeller hem performans değerleri ile hem de Taylor Diyagramı'na göre diğer algoritma ve modeller arasında en başarılı modeller olarak belirlenmiştir. Diyagram üzerinde performans olarak bu modelleri DVMM42 takip etmektedir. Performans değerleri ise NS: 0.8969, RMSE: 0.3179, r: 0.9476'dır.




Şekil 4.103. SYİ6 verisi içeren en başarılı kuraklık tahmin modellerinin Taylor Diyagramı

Şekil 4.103'de gösterilen diyagram üzerindeki modeller arasında gözlem değerine en uzak değer KAM42'dir. Bu modelin performans değerleri NS: 0.7960, RMSE: 0.4473, r: 0.8960'dır. Tüm bahsedilen modeller Taylor Diyagramı'nın yanı sıra Violin Diyagramı'nda da (Şekil 4.104'de) gösterilmiştir. Şekil 4.104 incelendiğinde, gözlem değerine en uyum sağlayan model ve algoritmanın DVMDM39 olduğu görülmektedir. Bu modeli peşi sıra takip eden farklı bir modelde YSADM37'dir. Bu model DVMDM39 ile diğer modellere göre, gözlem değeri ile en fazla benzerlik gösteren modellerdir. DVMDM39 maksimum ve minimum değerleri iyi bir şekilde tahmin ettiği Şekil 4.104'de görülmektedir.



Şekil 4.104. SYİ6 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı


Şekil 4.104’de ise KAD43 gözlem değeri ile en uyumsuz model olarak belirlenmiştir. Bu model Taylor Diyagramı’nda da gözlem değerine en uzak mesafede olan modellerdendir. RODM40’a dalgacık dönüşümü uygulanmasına rağmen, minimum ve maksimum değerleri doğru tahmin etmede yetersiz kalmıştır. SYİ3 verisi, kuraklık modellerinde kullanılan diğer veri arasındadır. Bu veri kullanılarak, farklı algoritmalar ile yapılan analizler sonucunda elde edilmiş en başarılı modeller Şekil 4.105’de Taylor Diyagramı’nda gösterilmiştir. Bu diyagramda bahsedilen; DVMM54 DVM algoritması ile M54’ü, DVMDM54, DVM’nin dalgacık dönüşümü ile M54’ü, YSAM54 YSA algoritması ile M54’ü, YSADM54 YSA’nın dalgacık dönüşümü ile M54’ü, ROM54 RO algoritması ile M54’ü, RODM52 RO’nun dalgacık dönüşümü ile M52’yi, KAM54 KA algoritması ile M54’ü, KADM52 KA’nın dalgacık dönüşümü ile M52’yi ifade etmektedir. Şekil 4.105 incelendiğinde gözlem değerine en yakın olan model ve algoritma DVMDM54’dür. Bu modelin performans değerleri ise NS: 0.9829 RMSE: 0.1257, r: 0.9915’dir.



Şekil 4.106. SYİ3 verisi içeren en başarılı kuraklık tahmin modellerinin Violin Diyagramı

4.5.2. Yağış-akış tahmin modelleri karşılaştırılması


Yağış-akış tahmin modellerinde en başarılı performans değerleri, DVM algoritması ile M22 kısaltmasıyla DVMM22’de, DVM’nin dalgacık dönüşümü ile M26 kısaltmasıyla DVMDM26’da, YSA algoritması ile M26’da kısaltmasıyla YSAM26, YSA’nın dalgacık dönüşümü ile M25’de kısaltmasıyla YSADM25’de, RO algoritması ile M24’de kısaltmasıyla ROM24, RO’nun dalgacık dönüşümü ile M26’da kısaltmasıyla RODM26, KA algoritması ile M07’de kısaltmasıyla KAM07’de, KA’nın dalgacık dönüşümü ile KADM25’de tespit edilmiştir. Performans değerlerine bakıldığında; bahsedilen modeller arasında en yüksek NS değeri DVMDM26’da (NS: 0.9781, RMSE: 0.2989, r: 0.9893) hesaplanmıştır. Dolayısıyla, yağış-akış tahmin modellerinde yapılacak bir modelleme çalışmasında, bu model girdileri ve algortmadan faydalanılabilir. Bu modeller arasında daha kolay kıyas yapılabilmesine için tüm modeller Şekil 4.107’de Taylor diyagramında gösterilmiştir. NS değerinden bağımsız olarak; standart sapma, RMSE, r değerlerine göre diyagramdan da anlaşılacağı gibi, gözlem değerine en yakın performans gösteren model DVMDM26’dır. Şekil 4.107 incelendiğinde, model girdi verisi 6 aya kadar geciktirilmiş aylık ortalama akış değerlerinden oluşturulan DVMDM26’yı performans olarak, YSADM25 takip etmektedir.



Şekil 4.107. En başarılı yağış-akış tahmin modellerinin Taylor Diyagramı

YSADM25'nin performans değerleri NS: 0.9567, RMSE: 0.4199, r : 0.9786 olup, girdi verisi 5 kadar geciktirilmiş aylık ortalama akış verisidir. Bu modelden farklı olarak, girdi verisi 1 ay daha geciktirilerek oluşturulan YSADM26, performans olarak YSADM25'nin gerisinde kalmıştır. YSADM26'ya bu diyagramda yer verilmiştir. YSADM26'nın performans değerleri NS: 0.9534, RMSE: 0.4366, r : 0.9772'dir. Geciktirilmiş ay sayısının fazlalığı burada model sonucu olumsuz yönde etkilemiştir. Genellikle başarılı modellerin girdi yapısında sadece akış değerlerinin kullanılması, bulunan diğer sonuçlar arasındadır. Şekil 4.107'de en KADM25 gözlem değerine en uzak değerlerden birisidir. Bu modelin performans değerleri NS: 0.6819, RMSE: 1.1389 r : 0.8297 şeklinde hesaplanmıştır. Hem performans değerlerinden hem de Taylor Diyagramı'ndaki bulgular örtüşmektedir. Şekil 4.108'de ise, yine başarılı olan modellerin Violin diyagramı çizilmiştir. Şekil 4.108'e göre, referans değeri olan gözlem değerlerinin, mod, medyan, standart sapma, ortalama, 1. ve 3. Çeyrek

değerlerine en yakın değer, yine taylor diyagramında da ifade edildiği gibi DVMDM26'dır. DVMDM26'nın maksimum ve minimum değerleri tahmin etmede de iyi olduğu Şekil 4.108'de görülmektedir.




Şekil 4.108. En başarılı yağış-akış tahmin modellerinin Violin Diyagramı

Dolayısıyla, hem performans değerlerine hem de Taylor ve Violin Diyagramlarına göre yağış-akış tahmin modellerinde diğer modeller ve yöntemlere göre en etkili sonuç DVMDM26'da alınmıştır.

4.5.3. Baraj göl seviyesi tahmin modelleri karşılaştırılması

Bu bölümde baraj göl seviyesi tahmin modellerinde başarılı olan modeller performans değerleri ile açıklanmış, Taylor ve Violin Diyagramlarına göre Şekil 4.109 ve Şekil 4.110'da gösterilmiştir. Bölüm 4.4'den elde edilen analiz sonuçlarına göre, en başarılı modeller diyagramlarda ifade edilmiş ve birbiri ile kıyaslanmıştır. Bu modeller, DVM'nin M12'si DVMM12 kısaltmasıyla, DVM'nin dalgacık dönüşümü ile M18 DVMDM18 kısaltmasıyla, YSA'nın M13'ü YSAM13 kısaltmasıyla, YSA'nın dalgacık dönüşümü ile M07 YSADM07 kısaltmasıyla, RO'nun M12'si ROM12 kısaltmasıyla, RO'nun dalgacık dönüşümü ile M13 RODM13 kısaltmasıyla, KA'nın M11'i KAM11 kısaltmasıyla, KA'nın dalgacık dönüşümü ile M10 KADM10 kısaltmasıyla grafikler üzerinde gösterilmiştir. DVM'de dalgacık dönüşümünden faydalanılarak elde edilen M18'in performans değerleri NS: 0.9851, RMSE: 0.6942, r: 0.9926 şeklindeydi. Bu değerler ile özellikle NS değerinin yüksek olmasıyla, yukarıda belirtilen diğer modellerin performans değerlerinden daha etkili olduğu


belirlenmiştir. Model girdi yapısı ise 2 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisi ile t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisi şeklindedir. Bu modeli NS: 0.9806, RMSE: 0.7894, r: 0.9903 performans değerleri ile DVMDM09 takip etmektedir. Bu model grafikler üzerinde gösterilmemesine rağmen başarılı olan modellerdendir. DVMDM09'un girdi yapısı 4 aya geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Model girdi yapısı M09'a göre daha fazla veri ile oluşturulan M18, en etkin performansı göstermiştir. Dolayısıyla yapılacak olan bir modelleme çalışmasında tercih edilebilir.



Şekil 4.109. En başarılı baraj göl seviyesi tahmin modellerinin Taylor Diyagramı

YSASDM07 modelinin performans değerleri NS: 0.9581, RMSE: 1.1605, r: 0.9792 şeklindeydi. Bu modelin performans değerleri DVMDM18 ve DVMDM09'un gerisinde olmasına rağmen Şekil 4.110 gösterilen Taylor Diyagramında gözlem değerine en yakın sonuçlardan birisidir. M07'in girdi yapısı 6 aya kadar geciktirilmiş

aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M09 ile model girdi yapısı kısmen aynı olması rağmen, performans değerlerine göre YSASDM07, DVMDM09'un gerisinde kalmıştır. Taylor Diyagramı'na göre ise gözlem değerine DVMDM09'den daha yakın olduğu, dolayısıyla daha iyi performans gösterdiği belirlenmiştir. Taylor Diyagramı'na göre, DVMDM18, ROM12 hemen hemen aynı performansı sergilemiştir. Violin Diyagramı'nda ise ROM12'nin gözlem şeklinden biraz daha farklı olduğu açıkça görülebilmektedir. Bahsedilen modellerin tamamı Violin Diyagramı'nda (Şekil 4.110) da gösterilmiştir. Şekil 4.110 incelendiğinde, Gözlem değeri ile en uyumlu olanlar DVMDM18, YSADM07 ve YSAM13'tür. YSAM13'ün en küçük ve en büyük değerleri (%1. ve %99'luk dilimleri) tahmininde ve kernel yoğunluğunda her ne kadar küçük farklılar olsa da, Violin Diyagramına göre en başarılı modeller DVMDM18, YSAM13, YSADM07 şekilde tespit edilmiştir. Bu modellerin maksimum ve minimum değerleri tahmin etmede de iyi olduğu Şekil 4.110'da görülmektedir.



Şekil 4.110. En başarılı baraj göl seviyesi tahmin modellerinin Violin Diyagramı

Taylor Diyagramı'nda da olduğu gibi, Violin Diyagramı'nda da KADM10 en kötü kötü performans sergileyen modellerden birisidir. Gözlem şekli ile çok fazla uyum sağlamadığı belirlenmiştir.

5. SONUÇ VE ÖNERİLER

Bu çalışmada Konya Kapalı Havzası içinde bulunan Apa Barajı alt havzası çalışma alanı olarak seçilmiştir. Bu çalışma alanında hidrolojik çevrimin en önemli parametresi olan yağışı esas alan 3 hidrolojik model incelenmiştir. İncelenen hidrolojik modeller;

- a- Kuraklık tahmin modeli,
- b- Yağış-akış tahmin modeli,
- c- Baraj göl seviyesi tahmin modelidir.

Hidrolojik modellerin incelenmesinde en yaygın 4 makine öğrenmesi yöntemi kullanılmıştır. Bu yöntemler DVM, YSA, RO ve KA'dır. İncelenen bu hidrolojik modellerin analizinde kullanılan makine öğrenmesi yöntemlerine göre kurulan modellerin sonuçlarının iyileştirilmesi için veri dalgacık dönüşümü ile dönüştürülüp, hibrit makine öğrenme yöntemleri kurulmuştur. Makine öğrenmesi ve hibrit makine öğrenmesi sonuçları karşılaştırarak incelenen konuyu açıklayan en iyi hidrolojik model araştırılmıştır.

5.1. Kuraklık Analizleri

SYİ1'de 326, SYİ3'de 349, SYİ6'da 386, SYİ9'da 394, SYİ12'de 400 ve SYİ24'de 365 kurak ay tespit edilmiştir. SYİ24 haricinde, zaman adımının artmasıyla kurak geçen ayların (sürenin) fazlaştığı belirlenmiştir.

SYİ1'de aşırı kurak kategorisinden herhangi bir sonuç elde edilememiştir. SYİ6, SYİ9, SYİ12, SYİ24 zaman adımlarında veri setinin başlangıçlarında genellikle kurak zamanların olduğu kuraklık analizlerinde tespit edilen bulgular arasındadır.

5.2. Kuraklık Tahmin Modelleri

DVM SYİ24 sonuçları

M06 için NS: 0.9550, RMSE: 0.1915, r: 0.9778, M02 için NS: 0.9328, RMSE: 0.2340, r: 0.9659, M05 için NS: 0.9328, RMSE: 0.2341, r: 0.9659, M03 için NS: 0.9147, RMSE: 0.2642, r: 0.9565 olarak hesaplanmıştır.

Bu zaman adımında diğerlerine göre daha başarılı olan modeller sırasıyla, M06, M02, M03, M05'dir. Girdi verisi göz önünde bulundurulduğunda, t zamanına ait veriyi

içermeyen modellerde, sadece SYİ24 indisleri ile oluşturulan modellerin diğer modellere göre daha başarılı olduğu (M02), ayrıca modele girdi verisi olarak geciktirilmiş indis verisini artırmanın model sonucunu olumsuz yönde etkilediği (M03), optimum geciktirilmiş ay sayısının 5 ay olduğu, model girdi verisi olarak minimum ve maksimum sıcaklık yerine aylık ortalama sıcaklık ve aylık toplam yağış meteorolojik verisinin kullanılmasının daha etkili olduğu tespit edilen bulgular arasındadır. Dalgacık dönüşümünden sonra da başarılı modellerden olan M03'ün performans değerleri NS: 0.9970, RMSE: 0.0498 r: 0.9970'dir. Diğer başarılı modellerde de önemli derecede iyileştirmeler yapılmıştır. Dalgacık dönüşümünden sonra diğer başarılı modellerden birisi de M04'dür. Bu modele ait performans değerleri NS: 0.9947, RMSE: 0.0659, r: 0.9974'dür. Girdi yapısı ise 5 aya kadar geciktirilmiş SYİ24 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Sadece SYİ indis verisi ile oluşturulan modeller dalgacık analizinde daha başarılı olmuşlardır.

DVM SYİ12 sonuçları

M18 için NS: 0.9122, RMSE: 0.2940, r: 0.9561; M20 için NS: 0.8703, RMSE: 0.3598, r: 0.9333; M16 için NS: 0.8694, RMSE: 0.3610, r: 0.9329; M15 için NS: 0.8693, RMSE: 0.3609, r: 0.9330 ve M17 için NS: 0.8241, RMSE: 0.4161, r: 0.9103 olarak hesaplanmıştır.

T zamanına ait girdi verisi ile oluşturulan modeller dışında, sadece kuraklık indisi ile oluşturulan M16'da diğer modellere göre etkin sonuçlar elde edilmiştir. M16 ve M15'de olduğu üzere, modellere girdi verisi olarak t-1 zamanına ait aylık toplam yağış verisinin eklenmesi model sonucuna olumlu yönde etki etmemiştir. SYİ24'de olduğu gibi, model girdi verisi olarak minimum ve maksimum sıcaklık yerine aylık ortalama sıcaklık ve aylık toplam yağış meteorolojik verisinin kullanılmasının daha etkili olduğu tespit edilen bulgular arasındadır. Girdi verisinde aylık minimum sıcaklık verisi kullanılan M19, girdi yapısı birbirine çok yakın olan ve girdi yapısında aylık minimum sıcaklık yerine aylık maksimum sıcaklık verisini içeren M20 ile kıyaslandığında, minimum sıcaklık verisinin kullanılması, maksimum sıcaklığın kullanılmasına göre daha avantaj sağladığı belirlenmiştir. Tespit edilen unsurlardan bir başkası da, SYİ'nin zaman adımının büyüdükçe performans değerlendirme kriterlerinde düşüş olduğudur. Bununda sebebi SYİ'deki zaman adımının

küçülmesiyle varyans değerlerinin artmasıdır. Dalgacık dönüşümünden sonra da M16 ve M15'in diğer modellere göre daha etkili bir performans sergilediği bulunan sonuçlar arasındadır. M16'nın dalgacık dönüşümünden sonra performans değerleri NS: 0.9942, RMSE: 0.0764, r: 0.9971 ve M15'in dalgacık dönüşümünden sonra performans değerleri NS: 0.9940, RMSE: 0.0771, r: 0.9970'dir.

DVM SYİ9 sonuçları

M26 için NS: 0.8043, RMSE: 0.4359, r: 0.869; M25 için NS: 0.8040, RMSE: 0.4355, r: 0.8967; M30 için NS: 0.9046, RMSE: 0.3043, r: 0.9524, M29 için NS: 0.8167, RMSE: 0.4219, r: 0.9038 olarak hesaplanmıştır.

Tahmin ayına ait (t zamanına ait) aylık toplam yağış ve aylık ortalama sıcaklıkların modellere girdi olarak eklenmesiyle elde edilen sonuçlar dışında, 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulan M26, bu kategoride en başarılı modellerden birisi olarak tespit edilmiştir. 5 aydan fazla ya da az olarak geciktirmenin model sonucuna olumsuz olarak yansıdığı, geciktirilmiş ay sayısının optimum düzeyde tutulması gerektiği bulunan diğer tespitler arasındadır (M25). Tespit edilen başka bir sonuç ise, zaman adımının azalmasıyla performans değerlerini kötüleştirdir. Bir önceki kısımda söylenildiği gibi SYİ'de zaman adımının azalmasıyla varyans değerlerinin artmasına bağlı olarak performans değerleri de kötüleşmektedir. Dalgacık dönüşümünden sonra ise, M26 ve M27'nin performansları diğer modellere göre daha etkilidir. Sırasıyla performans değerleri, NS: 0.9915, RMSE: 0.0908, r: 0.9958 ve NS: 0.9901, RMSE: 0.0960, r: 0.9951'dir. Dolayısıyla, sadece kuraklık indisi ile oluşturulan modeller, diğer modellere göre daha başarılı olduğu sonucuna ulaşılmıştır.

DVM SYİ6 sonuçları

M42 için NS: 0.8969, RMSE: 0.3179, r: 0.9476; M41 için NS: 0.8021, RMSE: 0.4405, r: 0.8991; M38 için NS: 0.7646, RMSE: 0.4805, r: 0.8760 olarak hesaplanmıştır. T zamanına ait meteorolojik veri ile oluşturulan modeller haricindeki, başarılı model girdileri sadece SYİ6 verisi ile oluşturulanlardır. M38'in girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Performans değerleri ile bu kategori ya da grupta en başarılı modeldir. Dolayısıyla SYİ6 ile yapılacak bir çalışmada, sadece SYİ6 indis verisi kullanılmalıdır. M42 ve M41'de t zamanına ait meteorolojik veri

girdi yapısında kullanılmasından ötürü iyi performans değerleri verdiği tespit edilmiştir. Dalgacık dönüşümünden sonra, girdi yapısında t zamanına ait olmayan veri ile oluşturulan tüm modeller arasından, en etkili performanslar M39 ve M40'da tespit edilmiştir. Dönüşüm sonrasında M39 için NS: 0.9861, RMSE: 0.1136, r: 0.9931 ve M40 için NS: 0.9861, RMSE: 0.1138, r: 0.9931 performans değerleri hesaplanmıştır. Bu modeller kendi arasında kıyaslandığında ise, iki modelin performanslar değerleri birbirlerine oldukça yakın bulunmuştur. Yine dönüşüm öncesinde olduğu gibi dönüşüm sonrasında da sadece SYİ verisi ile girdi yapısı oluşturulan modellerin performans değerleri daha yüksektir.

DVM SYİ3 sonuçları

M54 için NS: 0.8409, RMSE: 0.3836, r: 0.9173; M53 için NS: 0.6739, RMSE: 0.5491, r: 0.8269; M56 için NS: 0.6551, RMSE: 0.5596, r: 0.8155; M55 için NS: 0.6273, RMSE: 0.5817, r: 0.7968; M51 için NS: 0.5978, RMSE: 0.6042, r: 0.7812; M52 için NS: 0.6255, RMSE: 0.5831, r: 0.7951 olarak hesaplanmıştır.

Oluşturulan modellerin performansları incelendiğinde, t zamanına ait aylık toplam yağış verisinin girdi verisi olarak modele dahil edilmesi ile, aylık ortalama sıcaklık verisinden daha etkili sonuçlar verdiği tespit edilmiştir (M54, M53, M56, M55). Girdi yapısında t zamanına ait veri içermeyen modeller arasında en başarılı model olan M52 da olduğu gibi, t-1 zamanına ait aylık toplam yağış verisinin model girdisine eklenmesinin, sadece indis verisi ile oluşturulan modellere ile kıyaslandığında, daha etkili olabileceği tespit edilen sonuçlar arasındadır. Dalgacık dönüşümünden sonra, girdi yapısında t zamanına ait olmayan veri ile oluşturulan modellerden M50 ve M51 modellerinin performans değerleri diğer modellere kıyasla daha iyi olduğu sonucuna ulaşılmıştır. Sırasıyla performans değerleri, NS: 0.9809, RMSE: 0.1330, r: 0.9904 ve NS: 0.9809, RMSE: 0.1330, r: 0.9904'dür.

YSA SYİ24 sonuçları

M06 için NS: 0.9229, RMSE: 0.2506, r: 0.9609; M05 için NS: 0.9120, RMSE: 0.2678, r: 0.9552; M02 için NS: 0.9177, RMSE: 0.2590, r: 0.9585; M03 için NS: 0.9147, RMSE: 0.2642, r: 0.9565 olarak hesaplanmıştır.

T zamanına ait meteorolojik veri ile girdi yapısı oluşturulan modeller incelendiğinde; girdi verisinde aylık toplam yağış verisi ve aylık ortalama sıcaklık verisi kullanmanın, aylık minimum sıcaklık ve aylık maksimum sıcaklık verisi kullanmaktan daha etkili olduğu tespit edilmiştir (M06, M05). T zamanına ait olmayan veri ile oluşturulan modellere ait sonuçlar incelendiğinde, 5 aya kadar geciktirilmiş SYİ24 verisi ile oluşturulan model olan M02'nin diğer modellere göre daha iyi sonuç verdiği, ve bu geciktirme zamanının optimum süresinin 5 ay olduğu, daha az ya da daha fazla olmasının model sonucunu olumsuz yönde etkilediği tespit edilmiştir. M03'de olduğu gibi, geciktirme ayı 1 ay ötelendiğinde model sonucu, olumsuz olarak etkilenmiştir. Dalgacık dönüşümünden sonra, tüm modeller arasından en başarılı olan iki model M08 ve M04'dür. Bu modellere ait performans değerleri, sırasıyla, NS: 0.9831, RMSE: 0.1177, r: 0.9918 ve NS: 0.9805, RMSE: 0.1263, r: 0.9905'dir. Girdi yapılarına bakıldığında ise, M08; 5 aya kadar geciktirilmiş SYİ24 ile t zamanına ait aylık maksimum sıcaklık verisinden, M04 5 aya kadar geciktirilmiş SYİ24 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. T zamanına ait veri kullanımının dalgacık dönüşümünde de etkili olduğu gözlemlenmiştir. Bunun dışında ise, t-1 zamanına ait yağış verisinin model sonucuna olumlu yönde etki yapmıştır. Girdi yapısında t zamanına ait veri içermeyen M04'den sonraki başarılı başka bir model ise M03'dür. Bu modelin performans değerleri, NS: 0.9783, RMSE: 0.1333, r: 0.9891'dir. Bu modelin girdi yapısı ise 6 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur.

YSA SYİ12 sonuçları

M18 için NS: 0.8515, RMSE: 0.3824, r: 0.9233; M13 için NS: 0.9177, RMSE: 0.2590, r: 0.9585; M15 için NS: 0.9147, RMSE: 0.2642, r: 0.9565; M17 için NS: 0.8241, RMSE: 0.9103, r: 0.4161, M14 için NS: 0.8190, RMSE: 0.9097, r: 0.4221 olarak hesaplanmıştır.

Model girdi yapısında t zamanına ait aylık toplam yağış verisinin kullanımının, aylık ortalama sıcaklık verisine göre daha etkili olduğu sonucu çıkartılmıştır (M18, M17). M13'ün performans değerlerinin, M14 ve M15'e göre daha etkili olduğu tespit edilmiş olup, SYİ12 verisinin girdi olarak kullanılmasında 6 ya da 5 aydan ziyade 4 aya kadar geciktirmenin daha etkili olabileceği sonucuna varılmıştır. Dalgacık dönüşümünden sonra, diğer modeller ile kıyaslandığında en başarılı modeller M20, M17 ve M16

olarak tespit edilmiştir. Bu modellerden M20 ve M17'nin girdi yapısında t zamanına ait veri kullanılmasından ötürü performans değerleri yüksektir. Sırasıyla performans değerleri, NS: 0.9735, RMSE: 0.1627, r: 0.9871 ve NS: 0.9719, RMSE: 0.1662, r: 0.9863'dür. Girdi yapısında t zamanına ait veri bulundurmayan ve t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuş olan M16'nın performans değerleri, NS: 0.9698, RMSE: 0.1735, r: 0.9849'dur. SYİ24'de olduğu gibi SYİ12'de de dalgacık dönüşümünde t-1 zamanına ait aylık toplam yağış verisinin modele girdi olarak eklenilmesi model sonucunu olumlu yönde etkilemiştir.

YSA SYİ9 sonuçları

M25 için NS: 0.7404, RMSE: 0.5009, r: 0.8607; M26 için NS: 0.6962, RMSE: 0.5431, r: 0.8377; M30 için NS: 0.8699, RMSE: 0.3553, r: 0.9343 ve M29 için NS: 0.7321, RMSE: 0.5100, r: 0.8610 olarak hesaplanmıştır.

M25'in girdi yapısında 4 aylık geciktirilmiş SYİ9 verisi kullanılırken, M26'da bu geciktirilmiş ay sayısı 5'dir. SYİ9 ile yapılabilecek modelleme çalışmalarında meteorolojik veri kullanılmadan, sadece SYİ9 ile model oluşturma daha faydalı ve optimum düzeyde tutulması, mümkünse 4 aylık geciktirme verisinin kullanılması gerektiği tespit edilmiştir. M30 ve M29 olduğu gibi, t zamanına ait meteorolojik verinin, yani aylık toplam yağış ve aylık ortalama sıcaklık verisinin modellere girdi olarak eklenmesi model sonucuna olumlu yönde etki etmiştir. Dalgacık dönüşümünden sonra, en başarılı modeller sırasıyla; M25, M31, M27 ve M26 olarak tespit edilmiştir. Bu modeller arasında M31'in girdi yapısında t zamanına ait veri kullanılmıştır. Dolayısıyla bu verinin girdi yapısında kullanılmasından ötürü performans değerlerinin yüksek çıktığı tespit edilmiştir. Bunların haricinde M25 sadece 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Bu modelin performans değerleri NS: 0.9749, RMSE: 0.1557, r: 0.9879'dur. Dalgacık dönüşümü öncesi ile kıyaslandığında, dalgacık dönüşümünden sonra model performans değerleri iyileşmiştir. Bu modeli performans olarak takip eden M31'in performans değerleri ise NS: 0.9716, RMSE: 0.2184, r: 0.9857'dir. Peşi sıra gelen M27'nin girdi yapısında 6 aya kadar geciktirilmiş SYİ9 verisi kullanılmıştır. Bu modelin performans değerleri NS: 0.9676, RMSE: 0.1738, r: 0.9839'dur. Sadece SYİ9 verisi ile kullanılarak oluşturulan modellerin bu zaman adımı dalgacık dönüşümünde etkili olduğu

sonucuna varılmıştır. Dikkat çeken başka bir sonuç ise çıktı verisi zamanları $t+1$ ve $t+2$ olan M33 ve M35’de almıştır. Bu iki modele ait performans değerleri dalgacık dönüşümünden önce, sırasıyla, NS: 0.4640, RMSE: 0.7022, r: 0.7029 ve NS: 0.0882, RMSE: 0.9182, r: 0.4941’iken, dönüşümden sonra, yine sırasıyla, NS: 0.8696, RMSE: 0.3463, r: 0.9375 ve NS: 0.7845, RMSE: 0.4465, r: 0.8938’dır. Özellikle M35’de önemli derece iyileştirme yapılmıştır.

YSA SYİ6 sonuçları

M42 için NS: 0.8969, RMSE: 0.3179, r: 0.9482; M41 için NS: 0.7573, RMSE: 0.4879, r: 0.8756; M37 için NS: 0.7438, RMSE: 0.5002, r: 0.8650; M40 için NS: 0.7323, RMSE: 0.4988, r: 0.8580 olarak hesaplanmıştır.

M37’nin girdi yapısı 4 aya kadar geciktirilmiş SYİ6 verisinden, M47’nin girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisi ile $t-1$ zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Her iki modelde başarılı performans değerlerinden ötürü, SYİ6 ile yapılacak bir modelleme çalışmasında bu modellere ait girdi yapıları kullanılabilir. M42 ve M41’in girdi yapısında t zamanına ait aylık toplam yağış ve aylık ortalama sıcaklık verisi eklenildiğinden ötürü, model sonucunu olumlu yönde etkilenmiştir. Dalgacık dönüşümünden sonra M37, M43, M39 ve M38 modelleri diğer modellere göre daha etkili sonuç verdiği gözlemlenmiştir. M37’nin girdi yapısı 4 aya kadar geciktirilmiş SYİ6 verisinden, M43’ün girdi yapısı 5 aya kadar geciktirilmiş SYİ6 verisi ile t zamanına ait aylık minimum sıcaklık verisinden oluşturulmuştur. Hem girdi yapısında t zamanına ait veri olmadığından dolayı hem de NS: 0.9626, RMSE: 0.1911, r: 0.9832’lik performans değerleri ile M37’nin, diğer modellere göre daha etkili olduğu tespit edilmiştir. M39 ve M38’in performans değerleri sırasıyla, NS: 0.9535, RMSE: 0.2074, r: 0.9797 ve NS: 0.9520, RMSE: 0.2169, r: 0.9761’dır.

YSA SYİ3 sonuçları

M54 için NS: 0.9154, RMSE: 0.2796, r: 0.9568; M49 için NS: 0.5860, RMSE: 0.6191, r: 0.7824; M50 için NS: 0.5635, RMSE: 0.6353, r: 0.7782; M53 için NS: 0.5260, RMSE: 0.6621, r: 0.7684 olarak hesaplanmıştır.

Önceki zaman adımlarında olduğu gibi, t zamanına ait veriyi girdi yapısında kullanan modeller haricinde (M54 ve M53), sadece SYİ3 ile girdi yapısı oluşturulan modellerin

performans deęerleri dięer modellerin performans deęerlerine gre daha etkili olduęu tespit edilmiřtir (M49). M49’da geciktirilmiř ay sayısı 4 olup, bu rakam M50’de 5’dir. Dolayısıyla SYİ3 verisi geciktirilirken, optimum dzeyde tutulması gerektięi tespit edilmiřtir. Dalgacık dnřmnden sonra, girdi yapısında t zamanına ait veri bulundurmayan M52 ve M51’deki performans deęerleri dikkat ekmektedir. Bu deęerler sırasıyla, NS: 0.9290, RMSE: 0.2538, r: 0.9657 ve NS: 0.9270, RMSE: 0.2574, r: 0.9644’dr. Bu modellerin performans deęerleri dięer modellere gre daha etkilidir.

RO SYİ24 sonuları

M06 iin NS: 0.9359, RMSE: 0.2286, r: 0.9677; M02 iin NS: 0.9215, RMSE: 0.2529, r: 0.9601; M01 iin NS: 0.9199, RMSE: 0.2550, r: 0.9592; M05 iin NS: 0.9180, RMSE: 0.2585, r: 0.9583 olarak hesaplanmıřtır.

SYİ24 verisi kullanılarak yapılacak bir modelleme alıřmasında girdi verisinde kullanılan geciktirilmiř ay sayısının optimum dzeyde tutulması yapılan hesaplamalar sonucunda ortaya ıkarılmıřtır. SYİ24 ile oluřturulan modellerde M06, M02, M01 ve M05’in yksek performans deęerlerine ulařtıęı belirlenmiřtir. M06 ve M05’in girdi yapılarında t zamanına ait veri kullanıldıęından tr, girdi yapısında t zamanına ait veri kullanılmayan modellerden M02 ve M01 bu sınıfta daha etkili performans gstermiřtir. Bu modellerin performans deęerleri sırasıyla, NS: 0.9215, RMSE: 0.2529, r: 0.9601 ve NS: 0.9199, RMSE: 0.2550, r: 0.9592’dır. M02’in girdi yapısında 5, M01’in girdi yapısında 4 aya kadar geciktirilmiř SYİ24 verisi kullanılmıřtır. Dnřm sonrasında, performans deęerlerinde bu modeller iin gerileme tespit edilmiřtir. Dalgacık dnřmnden sonra, her ne kadar performans deęerlerinde gerilemeler tespit edildiyse de, M01 ve M02’nin performans deęerleri dięer modellere gre daha etkili sonular vermiřtir. Bu deęerler sırasıyla, NS: 0.8645, RMSE: 0.3317, r: 0.9312 ve NS: 0.8594, RMSE: 0.3385, r: 0.9272’dır. Bu sınıfta dalgacık dnřm model performanslarını genellikle olumsuz ynde etkilemiřtir.

RO SYİ12 sonuçları

M18 için NS: 0.8673, RMSE: 0.3615, r: 0.9338; M16 için NS: 0.8419, RMSE: 0.3962, r: 0.9183; M13 için NS: 0.8406, RMSE: 0.3962, r: 0.9183; M13 için NS: 0.8406, RMSE: 0.2585, r: 0.9583; M20 için NS: 0.8377, RMSE: 0.4024, r: 0.9162 olarak hesaplanmıştır.

Girdi yapısında t zamanına ait olan aylık toplam yağış verisi kullanılan M18 ve girdi yapısında t zamanına ait olan aylık maksimum sıcaklık verisi kullanılan M20 ve girdi verisinde t zamanına ait meteorolojik veri kullanılan diğer modeller ile kıyaslandığında, aylık toplam yağış verisinin kullanıldığı modeller daha etkili performans göstermiştir. Bahsedilen bu modellerin girdi yapısı hemen hemen aynı niteliktedir. Bunlardan ayrı olarak performans sonuçlarına göre, girdi yapısında t zamanına ait veri kullanılamayan ve girdi yapısı 5 aya kadar geciktirilmiş SYİ12 indis verisi ile t-1 zamanına ait aylık toplam yağış verisi ile oluşturulan M16, yine girdi yapısı 5 aya kadar geciktirilmiş SYİ12 indisleri ile oluşturulan M13 modellerinin, bu kategoride yapılacak olan bir modelleme çalışmasında kullanılması diğer modellere göre daha etkili olabileceği sonucuna varılmıştır. Ayrıca çıktı verisi t+1 zamanına ait olan M21 ve M22'nin performansları kıyaslandığında, (M21 için NS: 0.6849, RMSE: 0.5597, r: 0.8360; M22 için NS: 0.6884, RMSE: 0.8360, r: 0.5566) 6 aya kadar geciktirilmiş SYİ12 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuş olan M22, 6 aya kadar geciktirilmiş SYİ12 verisi ile oluşturulan M21'e göre daha etkili bir performans göstermiştir. Dalgacık dönüşümünden sonra, en başarılı modellerden birisi NS: 0.8001, RMSE: 0.4436, r: 0.9017'lik performans değerleri ile M18'dir. M18'in girdi yapısı 5 aya kadar geciktirilmiş SYİ12 verisi ile t zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri içermeyen modellerden olan M16 ve M14 başarılı olan diğer modellerdendir. M16 için: 0.7887, RMSE: 0.4591, r: 0.8984 performans değerleri ve M14 için NS: 0.7828, RMSE: 0.4625, r: 0.8870 performans değerleri hesaplanmıştır. Dalgacık dönüşümünden sonra performans değerlerinin dönüşüm öncesine göre gerilediği ya da azaldığı bulunan diğer sonuçlardandır.

RO SYİ9 sonuçları

M30 için NS: 0.8633, RMSE: 0.3644, r: 0.9334; M25 için NS: 0.7895, RMSE: 0.4513, r: 0.8894; M28 için NS: 0.7828, RMSE: 0.4555, r: 0.8868; M26 için NS: 0.7823, RMSE: 0.4597, r: 0.8862; olarak hesaplanmıştır.

SYİ9'da t zamanına ait meteorolojik veriyi girdi olarak kullanan modeller haricinde (M30, M29), girdi yapısı 4 aya kadar geciktirilmiş SYİ9 verisiyle oluşturulan M25, bu kategoride en başarılı modellerden birisidir. SYİ9'da indis verisinin geciktirilerek fazlaştırılması model sonuçlarını olumsuz yönde etkilemiştir (M26). M25'in performans değerlerinden sonra M28'in performans değerleri de dikkat çekmiştir. Bu modelin girdi yapısı 5 aya kadar geciktirilmiş SYİ9 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. SYİ verisine ilave olarak aylık toplam yağış verisinin modele girdi olarak eklenilmesi model sonucunu olumlu yönde etkilemiştir. Bu sonuç çıktı zamanı t+1'e ait olan M34 ve M33 modellerinin sonuçlarında da aynı şekildedir. Dalgacık dönüşümünden sonra, girdi verisinde t zamanına ait veri içermeyen ve diğer modellere göre daha etkili performans gösteren model 6 aya kadar geciktirilmiş SYİ9 verisiyle oluşturulan M29'dur. M29, 4 ve 5 aya kadar geciktirilmiş veri ile oluşturulan M25 ve M26'ya göre daha etkili performans göstermiş olup, M27'nin dönüşümden önceki performans değerleri, NS: 0.7645, RMSE: 0.4687, r: 0.8772 şeklindeyken, dönüşümden sonra NS: 0.7135, RMSE: 0.5169, r: 0.8508'dür. M25 ve M26'nın performans değerleri sırasıyla, NS: 0.6664, RMSE: 0.5681, r: 0.8212 ve NS: 0.6785, RMSE: 0.5587, r: 0.8318'dir. Dolayısıyla, bu değerlerden de anlaşılacağı gibi dalgacık dönüşümü sonrasında model performans değerlerinde bir gerileme olduğu belirlenmiştir. Girdi yapısında t zamanına ait veri içermeyen başka bir model ise M28'dir. Bu modelin performans değerleri NS: 0.7112, RMSE: 0.5251, r: 0.8684'dür. Girdi yapısı t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Yine bu kategoride de dalgacık dönüşümünden sonra performans değerlerinde gerileme tespit edilmiştir.

RO SYİ6 sonuçları

M42 için NS: 0.8673, RMSE: 0.3607, r: 0.9359; M44 için NS: 0.7769, RMSE: 0.4555, r: 0.8843; M41 için NS: 0.7733, RMSE: 0.4692, r: 0.8799; M43 için NS: 0.7823, RMSE: 0.4597, r: 0.8862; M40 için NS: 0.7572, RMSE: 0.4751, r: 0.8717; M37 için NS: 0.7549, RMSE: 0.4892, r: 0.8691 olarak hesaplanmıştır.

M42, M41, M44 ve M43 modelleri girdi yapısında sırasıyla, t zamanlarına ait aylık toplam yağış verisi, aylık ortalama sıcaklık, aylık maksimum sıcaklık, aylık minimum sıcaklık verisini içermektedir. SYİ6'da t zamanına ait meteorolojik veriyi girdi olarak kullanan modeller haricinde, 5 aya kadar geciktirilmiş SYİ6 verisi ve t-1 zamanına ait olan aylık toplam yağış verisinden oluşturulan M40'ın performans değerleri diğer modellere göre daha etkili olmuştur. Bu modeli performans olarak M37 takip etmektedir. Bu modelin girdi yapısı 4 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. SYİ6'da en etkili performanslar bu iki modelde tespit edilmiştir. Dalgacık dönüşümünden sonra, M40 ve M39 modellerinde diğer modellere göre daha etkili sonuçlar bulunmuştur. M40'ın girdi yapısı t-1 zamanına ait aylık toplam yağış verisi ve 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. M40'ın performans değerleri NS: 0.7729, RMSE: 0.4595, r: 0.8960'dır. Bu modeli performans olarak M39 takip etmektedir. M39'un performans değerleri NS: 0.7649, RMSE: 0.4665, r: 0.8821'dir. Bu modelin girdi yapısı 6 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri bulundurmeyen bu modeller bu sınıfın etkili sonuç veren en iyi modelleri olarak dikkat çekmektedir. M42 ve M44 için performans değerleri NS: 0.7188, RMSE: 0.5252, r: 0.8693 ve NS: 0.7534, RMSE: 0.4789, r: 0.8782'dir. M42 ve M44 de olduğu gibi, bu sınıfta da dalgacık dönüşümü bazı modellerin performans değerlerini olumsuz yönde etkilemiştir.

RO SYİ3 sonuçları

M54 için NS: 0.8273, RMSE: 0.3997, r: 0.9173; M53 için NS: 0.6827, RMSE: 0.5417, r: 0.8311; M52 için NS: 0.6212, RMSE: 0.5856, r: 0.7944; M55 için NS: 0.6212, RMSE: 0.5856, r: 0.7944; M49 için NS: 0.5966, RMSE: 0.6112, r: 0.7763 olarak hesaplanmıştır.

SYİ3'ün girdi verisi olarak kullanıldığı modeller incelendiğinde M54, M53, M52, M55 ve M49'un diğer modellere göre model performansının daha etkili olduğu belirlenmiştir. M54 ve M53'ün girdi verisinde t zamanına ait veri bulunmasından ötürü, en başarılı bu iki modelin yanında girdi verisinde t zamanına ait veri içermeyen M52 ve M49 da başarılı olarak kabul edilen modellerdendir. M52 t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ3 verisinden, M49 ise 4 aya kadar geciktirilmiş SYİ3 verisinden oluşturulmuştur. Bu modellerin performans değerleri bu sınıfta dikkat çekmektedir. Dalgacık dönüşümünden sonra, SYİ3 verisini girdi yapısında kullanan ve girdi yapısında t zamanına ait meteorolojik veri içermeyen modeller incelendiğinde, 5 aya kadar geciktirilmiş SYİ3 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulan M52'nin diğer modellere daha etkili olduğu belirlenmiştir. Bu modelin performans değerleri NS: 0.7877, RMSE: 0.4390, r: 0.8972 şeklindedir. Bu sınıfta bir diğer başarılı model ise M50'dir. Bu modelin girdi yapısı 5 aya kadar geciktirilmiş SYİ3 ile oluşturulmuş ve performans değerleri NS: 0.7379, RMSE: 0.4923, r: 0.8727'dir. Bu algoritmada, diğer SYİ adımlarının aksine bu kategoride dalgacık dönüşümünün model performansına olumlu yönde etki ettiği belirlenmiştir.

KA SYİ24 sonuçları

M06 için NS: 0.9378, RMSE: 0.2252, r: 0.9685; M02 için NS: 0.9210, RMSE: 0.2538, r: 0.9598; M05 için; NS: 0.9210, RMSE: 0.2538, r: 0.9598; M01 için NS: 0.9175, RMSE: 0.2588, r: 0.9580; M03 için NS: 0.9170, RMSE: 0.2606, r: 0.9578 olarak hesaplanmıştır.

KA ile yapılan analiz neticesinde elde edilen sonuçlarda M06, M02, M05 ve M01'in performans değerlerinin diğer modellere göre daha etkili olduğu belirlenmiştir. M06 ile M05'in girdi yapısı sırasıyla, 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık toplam yağış verisinden ve 5 aya kadar geciktirilmiş SYİ24 verisi ile t zamanına ait aylık ortalama sıcaklık verisinden oluşturulmuştur. Modelleme çalışmalarında genellikle t zamanına ait veri tercih edilmemesinden dolayı bu iki modeli dışında, girdi yapısında t zamanına ait veri içermeyen M02 ve M01 bu sınıfta performans değerleri ile başarılı olan diğer modellerdendir. M02'nin girdi yapısı, 5 aya kadar geciktirilmiş SYİ24 verisinden, M01'in girdi yapısı 4 aya kadar geciktirilmiş SYİ24 verisinden oluşturulmuştur. 6 aya kadar geciktirilmiş olan M03 ise bu

modellerin performans olarak gerisinde kalmıştır. Dolayısıyla geciktirme sayısının optimum düzeyde (5 ay) tutulması gerekmektedir. Dalgacık dönüşümünden sonra, SYİ24 verisini girdi yapısında kullanan ve girdi yapısında t zamanına ait meteorolojik veri içermeyen modeller incelendiğinde, 4 aya kadar geciktirilmiş SYİ24 verisi oluşturulan M01'in diğer modellere daha etkili olduğu belirlenmiştir. Bu modelin performans değerleri NS: 0.7881, RMSE: 0.4147, r: 0.8990 şeklindedir. Dalgacık dönüşümünden sonra performans değerlerinde gerileme olduğu belirlenmiştir. Bundan ötürü, SYİ24'ün girdi verisi olarak kullanıldığı analizlerde, KA algoritmasında dalgacık dönüşümü yapılmamalıdır. Bu sınıfta bir diğer başarılı model ise M04'dür. Bu modelin girdi yapısı 5 aya kadar geciktirilmiş SYİ24 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuş ve performans değerleri NS: 0.7523, RMSE: 0.4501, r: 0.8790'dır. M01'de olduğu gibi, M04'de de dalgacık dönüşümü model performansını olumsuz yönde etkilemiştir.

KA SYİ12 sonuçları

M18 için NS: 0.8831, RMSE: 0.3392, r: 0.9411; M17 için NS: 0.8323, RMSE: 0.4064, r: 0.9138; M16 için NS: 0.8342, RMSE: 0.4067, r: 0.9147; M15 için NS: 0.8300, RMSE: 0.4115, r: 0.9130; M13 için; NS: 0.8262, RMSE: 0.4138, r: 0.9110; M14 için; NS: 0.8247, RMSE: 0.4155, r: 0.9101 olarak hesaplanmıştır.

Model girdi yapısında t zamanına ait veri içeren modeller haricinde (M18, M17), başarılı olan modellerden birisi M16'dır. M16'nın girdi yapısı 5 aya kadar geciktirilmiş SYİ12 verisi ile t-1 zamanına ait aylık toplam yağış verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri içermeyen başka bir model de M15'dir. Bu model performans olarak M16'nın hemen ardından gelmektedir. M15, 6 aya kadar geciktirilmiş SYİ12 verisinden oluşturulmuştur. Bahsedilen bu iki model, bu sınıfta en başarılı modellerdendir. Bu model sonuçlarından da anlaşılacağı gibi, model girdi yapısında meteorolojik verinin olması, model performans değerlerine olumlu yansımıştır. Ayrıca, sadece SYİ12 verisi ile oluşturulan modeller incelendiğinde (M15, M13, M14), M15'in diğer modellere göre daha etkili olmuştur. Buradan da anlaşılacağı gibi, model girdi yapısında ki geciktirilmiş ay sayısının (6 ay kadar) fazla olması model sonucuna olumlu yönde etki etmiştir. Dalgacık dönüşümünden sonra en başarılı modeller girdi yapısında t zamanına ait veri içermeyen sırasıyla M15 ve M14 olarak belirlenmiştir. Bu modellerin performans

değerleri yine sırasıyla NS: 0.5725, RMSE: 0.6527, r: 0.8402, NS: 0.5725, RMSE: 0.6488, r: 0.8122'dir. Bu modellerin dalgacık dönüşümünden sonraki performans değerlerinde gerileme olmuştur. Bu nedenle, modelleme çalışmalarında KA'da önceki SYİ24 olduğu gibi dalgacık dönüşümünden yararlanılmamalıdır.

KA SYİ9 sonuçları

M30 için NS: 0.8383, RMSE: 0.3963, r: 0.9174; M28 için NS: 0.7883, RMSE: 0.4496, r: 0.8893; M31 için NS: 0.7655, RMSE: 0.4732, r: 0.8784; M32 için NS: 0.7518, RMSE: 0.4869, r: 0.8729; M25 için NS: 0.7518, RMSE: 0.4909, r: 0.8719 olarak hesaplanmıştır.

SYİ9'un girdi verisi olarak kullanıldığı bu sınıfta, etkili model sonuçları M30, M28, M31 ve M25'de alınmıştır. Her ne kadar performans değerleri diğerlerine göre daha iyi olsa da, M30'un girdi yapısında t zamanına ait aylık toplam yağış verisi kullanılmasından dolayı, performans değerleri diğer modellere göre yüksek çıkmıştır. Bunun dışında da, M28'in performans sonuçları daha dikkat çekmektedir. Çünkü, M28'in girdi yapısı t-1 zamanına ait aylık toplam yağış verisi ile 5 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Bu modeli performans olarak girdi yapısında t zamanına ait aylık minimum sıcaklık bulunan M31 takip etmektedir. Bir diğer dikkat çeken model ise M25'dir. Bu modelin girdi yapısı 4 aya kadar geciktirilmiş SYİ9 verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri kullanılmadığından ötürü başarılı modeller arasındadır. Dalgacık dönüşümünden sonra girdi yapısında t zamanına ait veri içermeyen modellerden M27 diğer modellere göre daha iyi performans sergilemiştir. Bu modelin dönüşümden sonraki performans değerleri NS: 0.4474, RMSE: 0.7179, r: 0.7123'dür. Dönüşümden önceki değerlerine göre (NS: 0.7525, RMSE: 0.4804, r: 0.8738) gerilemeler olmuştur. Buradan, dalgacık dönüşümünün bu sınıfta kullanılmaması model performansları açısından önemlidir.

KA SYİ6 sonuçları

M42 için NS: 0.7960 RMSE: 0.4473, r: 0.8960; M41 için NS: 0.7387 RMSE: 0.5062, r: 0.8631; M37 için NS: 0.7335 RMSE: 0.5101, r: 0.8577; M38 için NS: 0.7331 RMSE: 0.5116, r: 0.8569; M40 için NS: 0.7202, RMSE: 0.5101, r: 0.8503 olarak hesaplanmıştır.

Bu sınıfta M42 ve M41 performans değerleri ile etkili sonuçlar ortaya koymasına rağmen, girdi yapısında t zamanına ait aylık toplam yağış ve aylık ortalama sıcaklık verisi kullanılmıştır. Bunlarında dışında girdi yapısında t zamanına ait veri kullanılmayan, M37 ve M38 performans değerleri ile başarılı olan modeller arasındadır. Bu modellerin girdi yapısı sırasıyla, 4 ve 5 aya kadar geciktirilmiş SYİ6 verisinden oluşturulmuştur. Ayrıca M40 da farklı girdi yapısı (5 aya kadar geciktirilmiş SYİ6 verisi ve t-1 zamanına ait aylık toplam yağış verisi) ile bu sınıfta etkili performans gösteren modeller arasındadır. Dalgacık dönüşümünde sonra girdi yapısında t zamanına ait veri içermeyen modellerden en başarılı sonuç M37’de alınmıştır. Bu modele ait performans değerleri NS: 0.7335, RMSE: 0.5101, r: 0.8577’dir. Peşi sıra gelen model ise M38’dir. Bu modelin performans değerleri de NS: 0.7331, RMSE: 0.5116, r: 0.8569’dur. İki model arasındaki girdi yapısındaki fark M38’in 1 ay kadar daha fazla geciktirilmesidir. Dolayısıyla, fazla sayıdaki geciktirmiş ay sayısı model sonucunu olumsuz yönde etkilemektedir. Dalgacık dönüşümünden sonra model performanslarındaki düşüş sebebiyle, bu sınıfta dalgacık dönüşümünün yapılmaması daha faydalı olacaktır.

KA SYİ3 sonuçları

M54 için NS: 0.7838, RMSE: 0.4471, r: 0.8894; M53 için NS: 0.5708, RMSE: 0.6300, r: 0.7751; M56 için NS: 0.4963, RMSE: 0.6762, r: 0.7417; M49 için NS: 0.4930, RMSE: 0.6852, r: 0.7073; M51 için NS: 0.4817, RMSE: 0.6859, r: 0.7017 olarak hesaplanmıştır.

Girdi yapısında t zamanına ait aylık toplam yağış ve aylık ortalama sıcaklık verisi kullanan M54 ve M53 modelleri bu kategoride etkili sonuçlar vermiştir. Bu modelleri, girdi yapısı t zamanına ait aylık maksimum sıcaklık verisi ile 5 aya kadar geciktirilmiş SYİ3 verisinden oluşturulan M56 takip etmektedir. Peşi sıra gelen ve girdi yapısında t zamanına ait veri içermeyen ve 4 aya kadar geciktirilmiş SYİ3 verisinde oluşturulan M49 da başarılı olan modellerdendir. Girdi yapısı 6 aya kadar geciktirilen M51’de performans olarak M49’dan sonra gelmektedir. Dalgacık dönüşümünden sonra, girdi yapısında t zamanına ait veri içermeyen modellerden en başarılı sonuç M49’da tespit edilmiştir. Bu modelin performans değerleri NS: 0.5074, RMSE: 0.6754, r: 0.7461’dir. Yukarıdaki kısımların aksine burada da dalgacık dönüşümünden sonra model

performans değerlerinde iyileşme olmuştur. Dolayısıyla, SYİ3'ün girdi verisi olarak kullanıldığı bir modelleme çalışmasında KA'nın dalgacık dönüşümünden yararlanmak model sonuçlarını güçlendirir.

3,6,9,12 ve 24 aylık yağış toplamlarından elde edilen SYİ indislerinin genel özelliği, kısa zamana ait toplam değerlerden elde edilen indislerin uzun zaman yağış toplamlarından elde edilen indislere göre daha sık sınıflar arası geçişlere sahip olmaları, diğer bir deyişle daha büyük değişime sahip olmalarıdır. Örneğin SYİ3 indisi SYİ24 indisine göre daha fazla sıfır ekseninden geçişe sahip olup daha fazla kurak ve sulak zamanlara sahiptir ve daha fazla değişime sahiptir. Dalgacık dönüşümü ile kurulan modellerin analizlerinde bu değişimler daha iyi tanımlanmış olup, modelleme sonuçlarına bu durum yansımış ve dalgacık analizi sonucu elde edilen modellerden daha iyi performans elde edilmiştir.

Kuraklık tahmin modelleri DVM, YSA, RO, KA, oluşan 4 farklı makine öğrenme algoritması ile analiz edilip, hem modellerin birbirleri ile hem de algoritmalar arasında kıyaslamalar yapılmış, model sonuçlarının iyileştirmesi için dalgacık dönüşümünden faydalanılmıştır. Bu kıyaslamalar sonucunda, genellikle hem dalgacık dönüşümünde hem de dalgacık dönüşümü olmadan en başarılı performans sergileyen algoritmanın DVM olduğu, model girdi yapısının kuraklık indisine bağlı olarak değişebileceği, yani meteorolojik verinin de model girdi yapısına eklenmesi model sonuçlarını iyileştirebileceği, model girdi yapısındaki geciktirilmiş veri sayısının kuraklık zaman adımlarında farklılık gösterdiği, varyans değerlerinin azalmasına bağlı olarak kuraklık zaman adımının artmasıyla model performanslarının iyileştiği tespit edilmiştir. Bunlara ilave olarak dalgacık dönüşümünün tek tip veriyle oluşturulan modellerde, yani sadece kuraklık indisi ile oluşturulan modellerde daha etkili olduğu belirlenmiştir. Kuraklık tahmin modelleme çalışmaları yapılırken, başarılı bir sonuç elde edilmek istenirse, SYİ zaman adımlarının yüksek seçilmesi ve zaman adımına uygun olarak bir algoritma seçilmesi gerekir. Bunlara ilave olarak dalgacık dönüşümü ile iyileştirme yapılacaksa, tek tip veri ile model girdi yapıları oluşturulması önerilir.

5.3. Yağış-akış Tahmin Modelleri

DVM sonuçları

M22 için NS: 0.5622, RMSE: 1.3341, r: 0.7700; M24 için NS: 0.5525, RMSE: 1.3487, r: 0.7623; M23 için NS: 0.5523, RMSE: 1.3490, r: 0.7623; M10 için NS: 0.5064, RMSE: 1.4165, r: 0.7454; M25 için NS: 0.4732, RMSE: 1.4656, r: 0.7183, r: 0.6094; M26 için NS: 0.4750, RMSE: 1.4646, r: 0.7193 olarak hesaplanmıştır.

Yağış-akış tahmin modellerinde DVM ile yapılan analiz neticesinde, girdi verisi 4 aya kadar geciktirilmiş aylık toplam yağış verisinden, t-12 zamanına ait aylık toplam yağış verisinden, t-1, t-3, t-12 zamanlarına ait SYİ3 verisinden, t-1 zamanına ait SYİ12 verisinden, 2 aya kadar geciktirilmiş aylık ortalama akış verisinden, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1, t-6 zamanlarına ait AKİ12 verisinden oluşturulan M22'nin diğer modellere göre daha etkili sonuç verdiği tespit edilmiştir. Bu model diğer modellere göre en fazla veriyi içermektedir. Bu modelin performans olarak takipçisi M24'dür. M24'ün girdi yapısı ise t-1, t-12 zamanlarına ait aylık toplam yağış verisinden, t-1, t-12 zamanlarına ait SYİ3 verisinden, 2 aya kadar geciktirilmiş aylık ortalama akış verisinden, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1 zamanına ait AKİ12 verisinden oluşturulmuştur. M22 ve M24'de kullanılan veri çeşitliliği aynı olmasına rağmen, geciktirilmiş ay sayısı M22'de daha fazladır. Her ne kadar performans sonuçları birbirine yakın olsa da, M22'de kullanılan kuraklık verisinin, akış verisinin ve yağış verisinin farklı geciktirilmiş ayları model sonucuna olumlu yönde etki etmiştir. Bu modelleri performans olarak takip eden model M23'tür. M23'ün girdi yapısı M24 ile neredeyse aynıdır. M23'de farklı olarak t-1 zamanına ait aylık toplam yağış verisi bulunmaktadır. Bu da model performans değerlerini etkilemektedir. Bahsedilen bu modellerin ortak yanı girdi yapısında t zamanına ait veri olmamasıdır. Girdi yapısında t zamanına ait veriyi bulunduran modeller arasında en etkili performansı M10 sergilemiştir. M10'un girdi yapısı t, t-1, t-2, t-3 zamanlarına ait aylık toplam yağış, t-1, t-2, t-3 zamanlarına ait aylık ortalama akış değerlerinden oluşturulmuştur. Girdi yapısında t zamanına ait aylık toplam yağış verisi olmasına rağmen, hesaplanan performans değerleri bahsedilen modellerin gerisinde kalmıştır. M25 ve M26 ise sadece akış verisi kullanılarak girdi yapısı oluşturulmuştur. Bu

modeller performans olarak, bahsedilen modellerin gerisinde kalmıştır. Dolayısıyla bulunan sonuçlardan bir diğeri ise, yağış-akış tahmin modellerinde veri çeşitliliğinin olması model sonucuna olumlu yönde etki ettiği şeklindedir.

Kuraklık modelleri ile kıyaslandığında yağış akış tahmin modellerinin performans değerleri düşük seviyededir. Hem bu sebeple hem de olanı iyileştirmek amacıyla çalışmanın bu kısmında da dalgacık dönüşümünden yararlanılmıştır. Dalgacık dönüşümünden sonra ise, M26 ve M25'in performans değerlerinin (sırasıyla, NS: 0.9781, RMSE: 0.2989 r: 0.9893 ve NS: 0.9612, RMSE: 0.3975 r: 0.9805) diğer modellere göre daha etkili olduğu tespit edilmiştir. Bu modellerin girdi yapısı sadece akış verisinden oluşturulmuştur. Dalgacık dönüşümünden önce sadece akış verisi ile oluşturulan modellerin performansı düşük olmasına rağmen, dönüşümden sonraki performans değerleri diğer modelleri göre oldukça iyi seviyedir. Bu modelleri NS: 0.9351, RMSE: 0.5135, r: 0.9671'lik değerler ile M13 takip etmektedir. Ama, M13'ün girdi yapısı t zamanına ait olan aylık toplam yağış verisini de içerdiği unutulmamalıdır. Dalgacık dönüşümünden önce M22, M24 ve M23'ün diğer modellere göre daha etkili sonuçlar verdiğiinden bahsedilmişti. Bu modellerin dönüşümden sonraki performans değerleri ise M22 için NS: 0.9124, RMSE: 0.5967, r: 0.9555, M24 için NS: 0.9131, RMSE: 0.5943, r: 0.9558, M23 için NS: 0.9145, RMSE: 0.5896, r: 0.9566 olarak hesaplanmıştır. Dönüşümden sonra en başarılı modeller M25 ile M26 olduğundan dolayı, bu modellerin çıktı zamanı t+1 olan analizleri de yapılmış, M25t1 ve M26t1 olarak adlandırılmıştır. Sırasıyla performans değerleri, NS: 0.8504, RMSE: 0.7818, r: 0.9236 ve NS: 0.8251, RMSE: 0.8454, r: 0.9125'dir.

YSA sonuçları

M26 için NS: 0.5169, RMSE: 1.4051, r: 0.7420; M20 için NS: 0.3433, RMSE: 1.6338 r: 0.6366; M06 için NS: 0.2461, RMSE: 1.7506, r: 0.5891; M09 için NS: 0.1532, RMSE: 1.8553, r: 0.6123 olarak hesaplanmıştır.

Yağış-akış tahmin modellerinde YSA ile yapılan analiz neticesinde M26'nın diğer modellere göre oldukça iyi performans sergilediği dikkat çeken ilk sonuçlar arasındadır. M26'nın girdi yapısı, 6 aya kadar geciktirilmiş aylık ortalama akış değerlerinden oluşturulmuştur. Sadece akış verisi kullanılarak etkili sonuçlar alınması, YSA ile yapılan analizlerden elde edilen en önemli sonuçlardan birisidir. Bu modeli

performans olarak M20 takip etmektedir. M20'in girdi yapısı t-1, t-2, t-3 zamanlarına ait aylık toplam yağış verisinden, t-1, t-2, t-3 zamanlarına ait SYİ3 verisinden ve t-1, t-2 zamanlarına ait aylık toplam yağış verisinden oluşturulmuştur. M26 ile kıyaslandığında performans değerleri arasında neredeyse yarı yarıya fark vardır. Bu başarılı iki modellerin performanslarından sonra, model performansları DVM ile kıyaslandığında oldukça düşük seviyelerdedir. M06 ise bu modellerin performans olarak hemen gerisinden gelmektedir ve girdi verisi t, t-1 zamanlarına ait aylık toplam yağış verisinden ve t-1 zamanına ait aylık ortalama akış verisinden oluşturulmuştur. M06'da t zamanına ait aylık toplam yağış verisi kullanılmasında rağmen, yine de tahmin ayı ve verisine göre iyi sonuçlar elde edilememiştir.

YSA'da dalgacık dönüşümü olmadan yapılan analiz sonuçlarının fazla etkili bir performans göstermediği geçmiş bölümlerde bahsedilmişti. Dalgacık dönüşümünden sonra, diğer modeller ile kıyaslandığında en etkili sonuç M25'de alınmıştır. Bu modelin Dalgacık dönüşümünden önce performans değerleri NS: 0.0255, RMSE: 1.9933, r: 0.5929 şeklindeyken, dönüşümden sonra NS: 0.9567, RMSE: 0.4199, r: 0.9786'dır. Buradaki önemli derecedeki iyileşme oranı bulunan en dikkat çekici sonuçlardan birisidir. Bu modeli performans olarak M26 takip etmektedir. M26'nın dalgacık dönüşümünden önce performans değerleri NS: 0.5169, RMSE: 1.4051, r: 0.7420 şeklindeyken, dönüşümden sonra NS: 0.9534, RMSE: 0.4366, r: 0.9772'dir. M26'da da önemli derecede iyileştirmeler yapılmıştır. Bu modellerin girdi verisi sırasıyla, 5 ve 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. En yüksek performans değerlerine bu iki modelde ulaşılrken, bu modellerin takipçisi M09 olmuştur. Performans değerleri NS: 0.8400, RMSE: 0.8064, r: 0.9289'dur. YSA ile yapılan analiz sonuçları dönüşümden önceki değerleri çoğunlukla negatif iken, dönüşüm sonrasında tüm değerlerin pozitif olması bulunan sonuçlar arasındadır.

RO sonuçları

M24 için NS: 0.6196, RMSE: 1.2435, r: 0.7886; M23 için NS: 0.6152, RMSE: 1.2506, r: 0.7861; M22 için NS: 0.6057, RMSE: 1.2660, r: 0.7810 olarak hesaplanmıştır.

Yağış-akış tahmin modellerinde RO ile yapılan analiz sonucunda, M24 diğer modeller ile kıyaslandığında, en etkili sonuç veren model olmuştur. M24'ün girdi yapısı t-1, t-12 aylarına ait aylık toplam yağış verisinden, t-1, t-12, zamanlarına ait SYİ3

verisinden, t-1, t-2 zamanlarına ait aylık ortalama akış verisinden, t-1, t-3, t-6 zamanlarına ait AKİ3 verisinden, t-1 zamanına ait AKİ12 verisinden oluşturulmuştur. Tarımsal ve hidrolojik kuraklıkları ifade eden kuraklık indislerinden, aylık toplam yağış ve akış verisinin kombinasyonlarından oluşturulan M24, zengin veri çeşitliliği ile en çarpıcı performans gösteren modellerdendir. Bu modeli performans olarak M23 takip etmektedir. M23'ün girdi yapısı ise, M24 ile neredeyse aynıdır. Model girdi yapılarındaki tek farklılık, M23'ün girdi yapısında t-1 zamanına ait aylık toplam yağış verisinin bulunmamasıdır. Bu da gösteriyor ki, yağış akış tahmin modellemelerinde RO ile yapılan analiz neticesinde girdi yapısında yağış verisinin olması, sonuçlara olumlu olarak etki etmektedir. M22 de başarılı olan modellerden bir diğeridir. Girdi yapısı, 4 aya kadar geciktirilmiş aylık toplam yağış verisi, t-12 zamanına ait aylık toplam yağış verisi, t-1, t-3, t-12 zamanlarına ait SYİ3 verisi, t-1 zamanına ait SYİ12 verisi, 2 aya kadar geciktirilmiş aylık ortalama akış verisi, t-1, t-3, t-6 zamanlarına ait AKİ3 verisi ile t-1, t-6 zamanlarına ait AKİ12 verisinden oluşturulmuştur. Model girdi verisi ve çeşitliliği yönünden kapsamlı olmasına rağmen performans olarak en etkili model olamamıştır. Dolayısıyla, model girdi yapısındaki veri çeşitliliği optimum düzeyde tutulması sonucuna ulaşılmıştır.

Tüm algoritmalarda olduğu gibi KA algoritmasında da, dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümünden sonra, en etkili performans sunan model M26 olmuştur. M26'nın girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Bu modeli performans olarak M25 takip etmiştir. Onunda girdi yapısı 5 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Buradan yola çıkarak, dalgacık dönüşümünden sonraki modellerin girdi yapısında sadece akış verisinin kullanılması, model sonucunu olumlu yönde etkilemektedir. Sırasıyla performans değerleri, NS: 0.8359, RMSE: 0.8188, r: 0.9193 ve NS: 0.8187, RMSE: 0.8598, r: 0.9133'dür. Bu modelleri performans olarak M23 izlemektedir. M23'ün dönüşümden sonraki performans değerleri NS: 0.7812, RMSE: 0.9432, r: 0.8984 şeklindedir. M23'ün girdi yapısı, t-12 zamanına ait aylık toplam yağış, t-1, t-12 zamanlarına ait SYİ3, t-1, t-2 zamanlarına ait aylık ortalama akış, t-1, t-3, t-6 zamanlarına ait AKİ3, t-1 zamanına ait AKİ12 verisi gibi zengin bir girdi verisinden oluşturulmuştur. Buna rağmen tek tip verinin kullanıldığı M25 ve M26'nın performans olarak gerisinde kalmıştır.

KA sonuçları

M07 için NS: 0.3537, RMSE: 1.6209, r: 0.5978; M06 için NS: 0.3360, RMSE: 1.6429, r: 0.5925; M09 için NS: 0.3360, RMSE: 1.6429, r: 0.5925 olarak hesaplanmıştır.

Girdi yapısı t-1 zamanına ait aylık toplam yağış ile t-1 zamanına ait aylık ortalama akış verisinden oluşturulan M07 ve girdi yapısı t, t-1 zamanlarına ait aylık toplam yağış ile t-1 zamanına ait aylık ortalama akış verisinden oluşturulan M06, diğer modeller ile kıyaslandığında bu algorithmada en etkili sonuçları vermişlerdir. Genel olarak KA ile yapılan analiz sonuçları diğer algoritmalar ile yapılan analiz sonuçlarına göre geride kaldığı tespit edilmiştir. Bazı model sonuçlarında NS ve r değerleri negatif olarak hesaplanmıştır. Nitekim en başarılı model sonuçlarının da, tatminkar seviyede olmadığı bulunmuştur. KA'da özellikle zaman serisi ve saçılma diyagramlarından da fark edilebileceği gibi genellikle öğrenmeler ezbere düşmüştür. Bundan dolayı birçok modelde aynı performans değerleri hesaplanmıştır. Genellikle NS ve r değerlerinin düşük olması, diğer algoritmalara göre KA'nın modelleme çalışmalarında kullanılmasını ve tercih edilmesini azaltmaktadır.

Tüm bunlardan yola çıkarak KA ile yapılan analiz sonuçlarının iyileştirilmesi adına dalgacık dönüşümü tüm modellere uygulanmıştır. Dalgacık dönüşümünden sonra, M25 için NS: 0.6819, RMSE: 1.1389, r: 0.8297 performans değerleri, M26 için NS: 0.5919, RMSE: 1.2913, r: 0.7911 performans değerleri hesaplanmış ve bu iki model performans değerleri öne çıkmıştır. M25'in model girdi yapısı 5 aya kadar geciktirilmiş aylık ortalama akış verisinden, M26'nın model girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama akış verisinden oluşturulmuştur. Diğer algoritmalarda da olduğu üzere, dalgacık dönüşümünde en etkili sonuçlar, girdi yapısının tek tip veri ile oluşturulmasından elde edilen modellerde alınmıştır.

Yağış-akış tahmin modelleri DVM, YSA, RO, KA makine öğrenme algoritması ile analiz edilmiştir. Bu analizden elde edilen sonuçlarda DVM'nin diğer algoritmalara göre üstün performans sergilediği belirlenmiştir. YSA, KA algoritmaları yağış-akış tahmin modellerinde performansı en düşük algoritmalarındandır. DVM ile RO'nun performans değerleri ile başarılı oldukları modeller hemen hemen aynıdır. Başarılı oldukları model yapısı, kuraklık indis değerleri, yağış değerleri, akış değerleri ve bunların geciktirilmiş değerleri sonucunda oluşturulan kombinasyonlardan

oluşturulmuştur. Tüm modellerin performans değerlerinin iyileştirilmesi adına dalgacık dönüşüm tekniği uygulanmıştır. Dalgacık dönüşümünden sonra, bu iki makine öğrenme algoritmasının performans değerleri daha da iyileşmiştir. DVM'deki elde edilen iyileşme oranı RO'ya göre daha fazladır. Dolayısıyla, bu da yağış-akış tahmin modellerinde bu algoritmayı en başarılı algoritma yapmıştır. Elde edilen en dikkat çekici sonuç ise, dalgacık dönüşümünden önce çoğu modelin performans değerlerini negatif hesaplayan YSA algoritması, dalgacık dönüşümünden sonra bu modellerin sonucunda nerdeyse DVM ile aynı seviyeye getirmiştir. Bu sonuç, dalgacık dönüşümünden YSA'yı en başarılı modellerden birisi yapmıştır. Her ne kadar YSA'nın performans değerleri iyileşse de, hem dalgacık dönüşümünden önce hem de sonra DVM'nin performans değerlerinin gerisinde kalmıştır. Yağış-akış modelleme çalışmalarında, DVM ile RO algoritması ile daha etkili sonuçlar alındığından ötürü, bu algoritmalar tercih edilmelidir. Model girdi yapısında da veri çeşitliliği (yağış, akış, kuraklık indisleri vb.) de zengin tutulmalıdır. Dalgacık dönüşümünde, model girdi yapısında tek tip veri, algoritma olarak da DVM ve YSA kullanılmalıdır.

5.4. Baraj Göl Seviyesi Tahmin Modelleri

DVM sonuçları

M12 için NS: 0.9741, RMSE: 0.9123, r: 0.9904; M11 için NS: 0.9735, RMSE: 0.9241, r: 0.9904; M21 için NS: 0.7868, RMSE: 2.6788, r: 0.8876; M20 için NS: 0.7821, RMSE: 2.7079, r: 0.8863 olarak hesaplanmıştır.

Baraj göl seviyesi tahmin modellerinde DVM ile yapılan analiz neticesinde, M12'de alınan performans değerlerinin diğer model performans değerlerine göre, daha etkili olduğu tespit edilen ilk bulgulardandır. Bu modelin girdi yapısı t, t-1, t-2, t-3 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri olmasından dolayı, performans değerlerinin etkili olduğu belirlenmiştir. Bu modeli performans olarak M11 takip etmektedir. M11'in girdi yapısı ise; t, t-1, t-2 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. M12'de olduğu gibi bu modelin girdi yapısında da t zamanına ait veri bulunmaktadır. Bunların aksine girdi yapısında t zamanına ait veri içermeyen ve bu modellerin performans olarak takipçisi olan bir diğer başarılı model ise M21'dir. M21'in girdi yapısı t-1, t-4, t-5, t-6, t-11, t-12 zamanlarına ait aylık ortalama akış değerleri ile t-1, t-2 zamanlarına

ait aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Burada olduğu gibi, girdi yapısında t zamanına ait veri bulundurmeyen başarılı olarak analiz edilen modellerde, baraj hacmi verisi içermemesi tespit edilen diğer bulgular arasındadır. Girdi yapısında t zamanına ait veri içermeyen ve bu modellerin performans olarak takip eden başka bir başarılı model ise M20'dir. Bu modelin girdi yapısı t-1, t-4, t-5, t-6, t-11, t-12 zamanlarına ait aylık ortalama akış değerleri ile t-1 zamanına ait aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Girdi yapısında M20'nin M21'den tek farkı, M20'de t-2 zamanına ait baraj göl seviyesi verisinin bulunmamasıdır. Dolayısıyla, tespit edilen bir diğer bulgu da, geciktirilmiş baraj göl seviyesi verisinin (kot verisinin) girdi yapısında eklenmesi model sonucuna olumlu yönde etki yapmış olduğudur. Ayrıca, sadece baraj göl seviyesi ya da akış verisi kullanılarak oluşturulan (M04, M05, M19, M20 gibi) modeller performans olarak bu modellerin gerisinde kalmıştır. Buradan da anlaşılabileceği gibi, t zamanına ait veri içermeyen modellerin girdi yapısında tek çeşit veri kullanılması model sonucunu olumsuz yönde etkilemiştir.

Diğer modellerde olduğu gibi baraj göl seviyesi tahmin modellerinde de dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümünden sonra, en başarılı modeller sırasıyla M18 ve M09 olarak tespit edilmiştir. M18'in performans değeri NS: 0.9851, RMSE: 0.6942, r: 0.9926'dır. Girdi yapısı, t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim değerleri ile 2 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M09'ın performans değerleri NS: 0.9806, RMSE: 0.7894, r: 0.9903'tür. Model girdi yapısı 4 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Baraj hacim verisi ile baraj kot seviyesi verisinin birlikte girdi yapısında yer alması model sonucuna olumlu yönde etki etmiştir. Dalgacık dönüşümü ile önceki bölümlerde, tek tip verinin kullanılmasıyla modellerde daha çok verim alınmaktaydı. Fakat buradaki M18'in girdi yapısında iki ayrı verinin kullanılması daha önceki kısımlarda tespit edilen bu bulgunun aksi yönündedir. Buda bu kısımdaki en dikkat çekici sonuçlardan birisidir. M07'de bu modelleri performans olarak takip etmektedir. Performans değerleri NS: 0.9801, RMSE: 0.7894, r: 0.9900'dür. Model girdi yapısı ise, 6 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur.

YSA sonuçları

M13 için NS: 0.9469, RMSE: 1.3073, r: 0.9754; M12 için NS: 0.8652, RMSE: 2.0824, r: 0.9374; M20 için NS: 0.7113, RMSE: 3.1168, r: 0.8440; M21 için NS: 0.4620, RMSE: 4.2647, r: 0.7034 olarak hesaplanmıştır.

Baraj göl seviyesi tahmin modellerinde YSA ile yapılan analiz sonucunda, girdi yapısı t zamanına ait aylık ortalama hacim verisi ile yine aynı verinin 4 aya kadar geciktirilmesi ile oluşturulan M13, diğer modellere göre daha etkili performans sergilemiştir. Bu modeli performans olarak M12 takip etmektedir. M13 ile M12 modellerinin girdi yapısı birbirine oldukça benzemektedir. Aralarındaki tek farklılık M12'nin 1 ay daha az geciktirilmiş olmasıdır. Girdi yapısında t zamanına ait veri içermeyen ve girdi yapısı t-1, t-4, t-5, t-6, t-11, t-12 zamanlarına ait aylık ortalama akış verisi ile t-1 zamanına ait aylık ortalama baraj göl seviyesi verisinden oluşturulan M20, M12'yi performans olarak takip etmektedir. İki modelin performans değerleri incelendiğinde, özellikle NS değerleri arasında fark dikkat çekmektedir. Bu fark M12'nin t zamanına ait hacim verisini içermesinden dolayı oluşmuştur. Ayrıca t zamanına ait veriyi içeren modellerde hacim verisinin bir ay fazla geciktirilmesi model sonucuna olumlu olarak yansımıştır. Dahası, girdi yapısında t zamanına ait veri içermeyen ve başarılı olarak nitelendirilen bir diğer model ise M21'dir. M21'in girdi yapısı da M20'ye çok benzemektedir. Aralarında tek fark M21'in girdi yapısında kot verisinin 1 ay fazla geciktirilmesidir. Bundan dolayı da performans değerlerinde bir düşüş olmuştur. Girdi yapısındaki baraj göl seviyesi verisinin bir ay fazla geciktirilmesi model sonucuna olumsuz yönde etki ettiği belirlenmiştir.

Önceki bölümlerde olduğu gibi baraj göl seviyesi modellerine de model performans değerlerinin iyileştirilmesi için dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümünden sonra, model sonuçlarının bazılarında önemli derecede iyileştirmeler yapılmıştır. İyileşen performans değerleri olduğu gibi negatif değerler de bazı modellerde tespite edilmiştir. M07, M10, M18, M09 modelleri iyileştirme elde edilen modeller arasından en iyileridir. M07'nin performans değerleri NS: 0.9581, RMSE: 1.1605, r: 0.9792, M10'un performans değerleri NS: 0.9578, RMSE: 1.1657, r: 0.9794'dür. En başarılı model olarak tespit edilen M07'nin girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M10 da 5 aya kadar geciktirilmiş baraj göl seviyesi verisinden oluşturulmuştur. M18 ise 2 aya

kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisi ile t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Dalgacık dönüşümlerinin genelde girdi yapısı tek tip veri ile oluşturulan modellerde daha iyi sonuç verdiğini önceki kısımlar dile getirilmiştir. Bu bölümde bahsedilen bu bulgu değişmemiştir. Akabinde, bu modelleri performans olarak M09'un takip ettiği görülmektedir. M09'un girdi yapısı 4 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. M09'un performans değerleri NS: 0.9478, RMSE: 1.2957, r: 0.9752'dir. Burada, baraj göl seviyesi verisinin optimum düzeyde tutulması gerektiği sonucuna ulaşılmıştır. Bir ay fazla ya da az geciktirmenin model sonucuna olumsuz yönde etki ettiği belirlenmiştir.

RO sonuçları

M12 için NS: 0.9735, RMSE: 0.9233, r: 0.9921; M13 için NS: 0.9675, RMSE: 1.0221, r: 0.9890; M35 için NS: 0.8002, RMSE: 2.5998, r: 0.9014; M36 için NS: 0.7815, RMSE: 2.7184, r: 0.8949 olarak hesaplanmıştır.

RO kullanılarak baraj göl seviyesi modellemesinde yapılan analizler neticesinde, diğer modeller ile kıyaslandığında M12 ve M13'ün performans değerlerinin daha etkili olduğu tespit edilmiştir. M12'nin girdi yapısı t, t-1, t-2, t-3 zamanlarına ait aylık ortalama hacim verisinden, M13'ün girdi yapısı t, t-1, t-2, t-3, t-4 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Başarılı bulunan bu iki modelinde girdi yapısında t zamanına ait veri kullanılmıştır. Bu sebeple, girdi yapısında t zamanına ait veri içermeyen M35 ve M36 bu sınıfta başarılı olan diğer modellerdir. M35'in girdi yapısı 2 aya kadar geciktirilmiş AKİ1 verisi ile 2 aya kadar geciktirilmiş aylık ortalama hacim verisinden, M36'nın girdi yapısı ise 3 aya kadar geciktirilmiş AKİ1 verisi ile 3 aya kadar geciktirilmiş aylık ortalama hacim verisinden oluşturulmuştur. Girdi yapısında kuraklık indislerinin kullanılmasının model sonucuna olumlu yönde etki ettiği belirlenmiştir. Diğer algoritmalar ile yapılan analiz sonuçlarında, kuraklık indisi ile oluşturulan modellerde etkin sonuçlar alınamamıştır. RO ile yapılan analizlerde kuraklık indislerinin model sonucuna olumlu yönde etki etmektedir. AKİ1 değerleri ile hacim verisinin kullanılmasıyla oluşturulan modellerde diğer modellere göre daha etkili sonuç alındığı, ayrıca geciktirme değerlerinin de optimum düzeyde tutulması gerektiği bulunan diğer sonuçlardandır.

RO ile yapılan analizde dalgacık dönüşümünden sonra, diğer modellere göre M13, M11, M12, M07, M10 modellerinin performans değerleri daha etkilidir. M13, M11 ve M12'nin girdi yapısı t zamanına ait aylık ortalama hacim verisi içerdiğinden dolayı performans değerleri yüksek bulunmuştur. Bu modellerin performans değerleri sırasıyla NS: 0.8324, RMSE: 2.3218, r: 0.9384; NS: 0.8317, RMSE: 2.3270, r: 0.9385 ve NS: 0.8229, RMSE: 2.3870, r: 0.9332'dir. Girdi yapısında t zamanına ait veri içermeyen modellerden olan M10'un girdi yapısı ise 5 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden, M07'nin girdi yapısı 6 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Bu modellerin sırasıyla performans değerleri NS: 0.8127, RMSE: 2.4543, r: 0.9139 ve NS: 0.8165, RMSE: 5.4293, r: 0.9123'dür. Girdi yapısındaki farklılıklara bakıldığında M07'nin 1 ay daha fazla geciktirilmiş ay içerdiği, buna bağlı olarak da, performans değerlerinin M10'a göre daha iyi olduğu analizler sonucunda ortaya çıkmıştır.

KA sonuçları

M11 için NS: 0.9569, RMSE: 1.1777, r: 0.9883; M12 için 0.9569, RMSE: 1.1777, r: 0.9883; M13 için 0.9569, RMSE: 1.1777, r: 0.9883; M41 için NS: 0.7090, RMSE: 3.1629, r: 0.8424; M17 için NS: 0.6911, RMSE: 3.1584, r: 0.8401 olarak hesaplanmıştır.

KA kullanılarak baraj göl seviyesi modellemesinde yapılan analizler neticesinde M11, M12, M13 modellerinin performans değerleri aynı olup, diğer modellere göre daha etkili olduğu belirlenmiştir. Bu üç modelin girdi yapısında t zamanına ait aylık ortalama hacim olduğundan ötürü performans değerleri yüksek çıkmıştır. M13'ün girdi yapısı t zamanına ait aylık ortalama hacim verisi ile 4 aya kadar geciktirilmiş hacim verisinden, M12'nin girdi yapısı t zamanına ait aylık ortalama hacim verisi ile 3 aya kadar geciktirilmiş aylık ortalama hacim verisinden, M11'in girdi yapısı t zamanına ait aylık ortalama hacim verisi ile 2 aya kadar geciktirilmiş aylık ortalama hacim verisinden oluşturulmuştur. Girdi yapısında t zamanına ait veri içermeyen modellerden en etkili sonuç M41'de alınmıştır. Bu modelin performans değerleri NS: 0.7090, RMSE: 3.1629, r: 0.8424'dür. M41'in girdi yapısı 3 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisi ile t-12, t-13, t-14, t-15 zamanlarına ait AKİ12 değerlerinden oluşturulmuştur. Bu modeli performans olarak M17 takip etmektedir. M17'nin performans değerleri NS: 0.6911, RMSE: 3.1584, r: 0.8401'dir. M17

modelinin girdi yapısı, t-1 zamanına ait aylık ortalama baraj göl seviyesi verisi ile t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Ayrıca, başarılı modellerin girdi yapısında AKİ değerlerinin olması dikkat çeken sonuçlardan birisidir.

Tüm makine öğrenme algoritmalarında olduğu gibi KA'da da dalgacık dönüşümünden yararlanılmıştır. Dalgacık dönüşümünden sonra, diğer modellere göre en etkili sonuç M10'da alınmıştır. M10'un performans değerleri NS: 0.7263, RMSE: 2.9669, r: 0.8628'dir. Girdi yapısı 5 aya kadar geciktirilmiş aylık ortalama baraj göl seviyesi verisinden oluşturulmuştur. Bu modeli performans olarak M11 ve M13 takip etmektedir. M11 ve M13'ün girdi yapısında t zamanına ait aylık ortalama hacim verisi olduğundan ötürü, model performans değerlerinin iyi derece olduğu belirlenmiştir. Bu modelleri girdi yapısında t zamanına ait veri içermeyen M16 takip etmektedir. M16'nın performans değerleri NS: 0.7098, RMSE: 3.0612, r: 0.8492'dir. Girdi yapısı t-1, t-4, t-5, t-6, t-12 zamanlarına ait aylık ortalama hacim verisinden oluşturulmuştur. Tek tip veri ile gerçekleştirilen analiz sonucunda dalgacık dönüşümü bu algoritmada da başarılı olmuştur.

Baraj göl seviyesi tahmin modelleri DVM, YSA, RO, KA makine öğrenme algoritması ile analiz edilmiştir. Bu 4 farklı algoritmanın her ne kadar model performansları birbirlerine yakın olsa da, RO'nun diğer algoritmalara göre üstün performans sergilediği belirlenmiştir. RO'nun başarı gösterdiği modelin yapısı, hacim verisi ile kuraklık indisi ve bunların farklı aylardaki geciktirilmiş değerlerinden oluşturulmuştur. Diğer kısımlarda olduğu gibi baraj göl seviyesi tahmin modellerine de model performanslarını iyileştirmesine adına dalgacık dönüşümü uygulanmıştır. Dalgacık dönüşümünden sonra, RO ve KA'nın model performans değerleri kötüleşirken, DVM ve YSA'nın performans değerleri iyileşmiştir. Dönüşümden sonra en başarılı algoritma DVM olarak dikkat çekmektedir. Başarılı modelin girdi yapısı, baraj hacim ile baraj göl seviyesi verisinden ve bunların farklı aylardaki geciktirilmiş değerlerinden oluşturulmuştur. DVM kadar olmasa da, YSA ile yapılan analizlerin sonuçları da dikkat çekmektedir. YSA'da en başarılı modelin girdi yapısı, sadece baraj hacim verisi ve bunun farklı aylardaki geciktirilmiş değerlerinden oluşturulmuştur. Dolayısıyla, kullanılan algoritmaya göre model yapısının değiştiği belirlenmiştir. Yapılacak olan baraj göl seviyesi tahmin modellerinde elde edilen veriye göre farklı

öğrenme algoritmaları kullanılabilir. Sonuç olarak, baraj göl seviyesi tahmin modellerinde, DVM ve RO algoritmaları bir modelleme çalışmasında etkin sonuç vermesinden ötürü araştırmacılar tarafından tercih edilmeli ve model girdi yapısı hacim ve baraj kot seviyesinden oluşturulmalıdır. Dalgacık dönüşümü uygulanacaksa, yine DVM ve YSA algoritmaları ile tek tip (hacim, kot verisi) veri tercih edilmelidir.



KAYNAKLAR

- Abrahart, R. J. ve See, L., 2000. Comparing neural network and autoregressive moving average techniques for the provision of continuous river flow forecasts in two contrasting catchments. *Hydrological processes*, 14(11-12), 2157-2172.
- Achite, M., Katipoğlu, O. M., Jehanzaib, M., Elshaboury, N., Kartal, V. ve Ali, S., 2023. Hydrological drought prediction based on hybrid extreme learning machine: Wadi Mina Basin Case Study, Algeria. *Atmosphere*, 14(9), 1447.
- Akkurt Eroğlu, T. ve Apaydin, H., 2020. Estimation of Drought by Streamflow Drought Index (SDI) and Artificial Neural Networks (ANNs) in Ankara-Nallihan Region. *Turkish Journal of Agriculture - Food Science and Technology*, 8(2), 348-357. <https://doi.org/10.24925/turjaf.v8i2.348-357.3045>
- Aktürk, G. 2017. Türkiye’de Farklı Özelliklere Sahip Havzalarda Yağış Eksikliğinin Çeşitli Hidrolojik Sistemler Üzerine Etkilerinin Araştırılması, Doktora Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- Al-Juboory, A. M., 2023. Prediction of Hydrological Drought in Semi-arid Regions Using a Novel Hybrid Model. *Water Resources Management*, 1-13.
- Alawsi, M. A., Zubaidi, S. L., Al-Ansari, N., Al-Bugharbee, H. ve Ridha, H. M., 2022. Tuning ANN Hyperparameters by CPSOCSA, MPA, and SMA for Short-Term SPI Drought Forecasting. *Atmosphere*, 13(9), 1436.
- Ayana, Ö., Kanbak, D. F., Kaya Keleş, M. ve Turhan, E., 2023. Monthly streamflow prediction and performance comparison of machine learning and deep learning methods. *Acta Geophysica*, 1-18.
- Azadi, S. ve Sepaskhah, A. R., 2012. Annual precipitation forecast for west, southwest, and south provinces of Iran using artificial neural networks. *Theoretical and applied climatology*, 109, 175-189.
- Azimi, S. M. E., Sadatinejad, S. J., Malekian, A. ve Jahangir, M. H., 2022. Application of artificial intelligence hybrid models for meteorological drought prediction. *Natural Hazards*, 1-25.
- Basak, A., Rahman, A. S., Das, J., Hosono, T. ve Kisi, O., 2022. Drought forecasting using the Prophet model in a semi-arid climate region of western India. *Hydrological Sciences Journal*, 67(9), 1397-1417.
- Belayneh, A., Adamowski, J., Khalil, B. ve Ozga-Zielinski, B., 2014. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology*, 508, 418-429. <https://doi.org/https://doi.org/10.1016/j.jhydrol.2013.10.052>
- Biau, G. ve Scornet, E., 2016. A random forest guided tour. *Test*, 25, 197-227.

- Bonaccorso, B., Bordi, I., Cancelliere, A., Rossi, G. ve Sutera, A., 2003. Spatial variability of drought: An analysis of the SPI in Sicily. *Water Resources Management*, 17(4), 273-296. <https://doi.org/10.1023/A:1024716530289>
- Borga, M. ve Vizzaccaro, A., 1997. On the interpolation of hydrologic variables: formal equivalence of multiquadratic surface fitting and kriging. *Journal of Hydrology*, 195(1-4), 160-171.
- Breiman, L., 1996. Bagging predictors. *Machine learning*, 24, 123-140.
- Breiman, L., 2001. Random Forests. *Machine learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Buldur, A. ve Sabahattin, S., 2012. Çarşamba Çayı'nın 15 Aralık 2010 Tarihli Taşkını Ve Bozkir'daki (Konya) Etkisi. *Marmara Coğrafya Dergisi*(25), 81-107.
- Catalbas, E. ve Kocak, K. 2019. Rüzgar hız ve enerji verilerinin tahmini için kaotik yaklaşımla birlikte destek vektör regresyonunun kullanımı, *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü*.
- Chen, S.-T., Kuo, C.-C. ve Yu, P.-S., 2009. Historical trends and variability of meteorological droughts in Taiwan / Tendances historiques et variabilité des sécheresses météorologiques à Taiwan. *Hydrological Sciences Journal*, 54(3), 430-441. <https://doi.org/10.1623/hysj.54.3.430>
- Cortes, C. ve Vapnik, V., 1995. Support-vector networks. *Machine learning*, 20, 273-297.
- Danandeh Mehr, A., Torabi Haghighi, A., Jabarnejad, M., Safari, M. J. S. ve Nourani, V., 2022. A New Evolutionary Hybrid Random Forest Model for SPEI Forecasting. *Water*, 14(5), 755. <https://www.mdpi.com/2073-4441/14/5/755>
- Daubechies, I., 1996. Where do wavelets come from? - A personal point of view. *Proceedings of the Ieee*, 84(4), 510-513. <https://doi.org/10.1109/5.488696>
- Deo, R. C., Kisi, O. ve Singh, V. P., 2017. Drought forecasting in eastern Australia using multivariate adaptive regression spline, least square support vector machine and M5Tree model. *Atmospheric Research*, 184, 149-175. <https://doi.org/10.1016/j.atmosres.2016.10.004>
- Difi, S., Elmeddahi, Y., Hebal, A., Singh, V. P., Heddami, S., Kim, S. ve Kisi, O., 2022. Monthly streamflow prediction using hybrid extreme learning machine optimized by bat algorithm: a case study of Cheliff watershed, Algeria. *Hydrological Sciences Journal*, 1-20.
- Djerbouai, S. ve Souag-Gamane, D., 2016. Drought forecasting using neural networks, wavelet neural networks, and stochastic models: case of the Algerois Basin in North Algeria. *Water Resources Management*, 30, 2445-2464.

- Dogan, S., Berktaş, A. ve Singh, V. P., 2012. Comparison of multi-monthly rainfall-based drought severity indices, with application to semi-arid Konya closed basin, Turkey. *Journal of Hydrology*, 470-471, 255-268. <https://doi.org/10.1016/j.jhydrol.2012.09.003>
- Efron, B. ve Hastie, T. 2016. *Computer Age Statistical Inference*. Institute of Mathematical Statistics Monographs. In: Cambridge University Press.
- Elbeltagi, A., Di Nunno, F., Kushwaha, N. L., de Marinis, G. ve Granata, F., 2022. River flow rate prediction in the Des Moines watershed (Iowa, USA): A machine learning approach. *Stochastic Environmental Research and Risk Assessment*, 36(11), 3835-3855.
- Elbeltagi, A., Pande, C. B., Kumar, M., Tolche, A. D., Singh, S. K., Kumar, A. ve Vishwakarma, D. K., 2023. Prediction of meteorological drought and standardized precipitation index based on the random forest (RF), random tree (RT), and Gaussian process regression (GPR) models. *Environmental Science and Pollution Research*, 1-20.
- Fan, J., Yue, W., Wu, L., Zhang, F., Cai, H., Wang, X., Lu, X. ve Xiang, Y., 2018. Evaluation of SVM, ELM and four tree-based ensemble models for predicting daily reference evapotranspiration using limited meteorological data in different climates of China. *Agricultural and forest meteorology*, 263, 225-241.
- Freund, Y. ve Schapire, R. E., 1996. Experiments with a new boosting algorithm. *icml*, United States.
- Goldstein, B. A., Hubbard, A. E., Cutler, A. ve Barcellos, L. F., 2010. An application of Random Forests to a genome-wide association dataset: methodological considerations & new findings. *Bmc Genetics*, 11(1), 1-13.
- Gour, R., 2019. Unique Real-Life Applications of SVM. from <https://medium.com/@rinu.gour123/8-unique-real-life-applications-ofsvm-8a96ca43313>, Retrieved October 24, 2020.
- Granitto, P. M., Gasperi, F., Biasioli, F., Trainotti, E. ve Furlanello, C., 2007. Modern data mining tools in descriptive sensory analysis: A case study with a Random forest approach. *Food Quality and Preference*, 18(4), 681-689. <https://doi.org/10.1016/j.foodqual.2006.11.001>
- Grossmann, A. ve Morlet, J., 1984. Decomposition of Hardy functions into square integrable wavelets of constant shape. *SIAM journal on mathematical analysis*, 15(4), 723-736.
- Gunn, S. R., 1997. *Support Vector Machines for Classification and Regression* (Image Speech & Intelligent Systems Group, University of Southampton). ISIS tech report. 10 May 1998.

- Guttman, N. B., 1999. Accepting the standardized precipitation index: a calculation algorithm 1. JAWRA Journal of the American Water Resources Association, 35(2), 311-322.
- Heddam, S. ve Kisi, O., 2018. Modelling daily dissolved oxygen concentration using least square support vector machine, multivariate adaptive regression splines and M5 model tree. Journal of Hydrology, 559, 499-509. <https://doi.org/10.1016/j.jhydrol.2018.02.061>
- Heim, R., 2002. A Review of Twentieth-Century Drought Indices Used in the United States. Bulletin of the American Meteorological Society, 83. [https://doi.org/10.1175/1520-0477\(2002\)083<1149:AROTDI>2.3.CO;2](https://doi.org/10.1175/1520-0477(2002)083<1149:AROTDI>2.3.CO;2)
- Hinge, G., Piplodiya, J., Sharma, A., Hamouda, M. A. ve Mohamed, M. M., 2022. Evaluation of Hybrid Wavelet Models for Regional Drought Forecasting. Remote Sensing, 14(24), 6381.
- Hinis, M., 2013. Hydrometeorological drought analysis in aksaray by aggregate drought index. Journal of the Faculty of Engineering and Architecture of Gazi University, 28, 711-721.
- Hu, J., Liu, B. ve Peng, S., 2019. Forecasting salinity time series using RF and ELM approaches coupled with decomposition techniques. Stochastic Environmental Research and Risk Assessment, 33, 1117-1135.
- Huang, S., Chang, J., Huang, Q. ve Chen, Y., 2014. Monthly streamflow prediction using modified EMD-based support vector machine. Journal of Hydrology, 511, 764-775.
- Ibrahim, K. S. M. H., Huang, Y. F., Ahmed, A. N., Koo, C. H. ve El-Shafie, A., 2022. Forecasting multi-step-ahead reservoir monthly and daily inflow using machine learning models based on different scenarios. Applied Intelligence, 1-24.
- Imrie, C., Durucan, S. ve Korre, A., 2000. River flow prediction using artificial neural networks: Generalisation beyond the calibration range. Journal of Hydrology, 233, 138-153. [https://doi.org/10.1016/S0022-1694\(00\)00228-6](https://doi.org/10.1016/S0022-1694(00)00228-6)
- Katipoğlu, O. M., 2023. Prediction of streamflow drought index for short-term hydrological drought in the semi-arid Yesilirmak Basin using Wavelet transform and artificial intelligence techniques. Sustainability, 15(2), 1109.
- Keyantash, J. ve Dracup, J. A., 2002. The quantification of drought: An evaluation of drought indices. Bulletin of the American Meteorological Society, 83(8), 1167-1180.
- Khan, N., Sachindra, D. A., Shahid, S., Ahmed, K., Shiru, M. S. ve Nawaz, N., 2020. Prediction of droughts over Pakistan using machine learning algorithms. Advances in Water Resources, 139, 103562. <https://doi.org/10.1016/j.advwatres.2020.103562>

- Maier, H. R. ve Dandy, G. C., 1996. The use of artificial neural networks for the prediction of water quality parameters. *Water resources research*, 32(4), 1013-1022.
- Mao, G., Wang, M., Liu, J., Wang, Z., Wang, K., Meng, Y., Zhong, R., Wang, H. ve Li, Y., 2021. Comprehensive comparison of artificial neural networks and long short-term memory networks for rainfall-runoff simulation. *Physics and Chemistry of the Earth, Parts A/B/C*, 123, 103026.
- Martinho, A. D., Saporetti, C. M. ve Goliatt, L., 2023. Approaches for the short-term prediction of natural daily streamflows using hybrid machine learning enhanced with grey wolf optimization. *Hydrological Sciences Journal*, 68(1), 16-33.
- McKee, T., B., Doesken, N., J. ve Kleist, J., 1993. The relationship of drought frequency and duration to time scales, Preprints 8th Conference on Applied Climatology, Anaheim, CA, Amer. Meteor. Soc.
- Meng, J., Dong, Z., Shao, Y., Zhu, S. ve Wu, S., 2022. Monthly Runoff Forecasting Based on Interval Sliding Window and Ensemble Learning. *Sustainability*, 15(1), 100.
- Metlek, S. ve Kayaalp, K., 2020. Makine Öğrenmesinde, Teoriden Örnek MATLAB Uygulamalarına Kadar Destek Vektör Makineleri. *İksad Yayınevi*.
- Mirboluki, A., Mehraein, M. ve Kisi, O., 2022. Improving accuracy of neuro fuzzy and support vector regression for drought modelling using grey wolf optimization. *Hydrological Sciences Journal*, 67(10), 1582-1597.
- Mishra, A. K. ve Desai, V. R., 2006. Drought forecasting using feed-forward recursive neural network. *Ecological Modelling*, 198(1), 127-138. <https://doi.org/10.1016/j.ecolmodel.2006.04.017>
- Mishra, A. K. ve Singh, V. P., 2010. A review of drought concepts. *Journal of Hydrology*, 391(1), 202-216. <https://doi.org/10.1016/j.jhydrol.2010.07.012>
- Mohammed, S., Elbeltagi, A., Bashir, B., Alsafadi, K., Alsilibe, F., Alsalman, A., Zeraatpisheh, M., Széles, A. ve Harsányi, E., 2022. A comparative analysis of data mining techniques for agricultural and hydrological drought prediction in the eastern Mediterranean. *Computers and Electronics in Agriculture*, 197, 106925.
- Moriasi, D. N., Arnold, J. G., Liew, M. W. V., Bingner, R. L., Harmel, R. D. ve Veith, T. L., 2007. Model Evaluation Guidelines for Systematic Quantification of Accuracy in Watershed Simulations. *Transactions of the ASABE*, 50(3), 885-900. <https://doi.org/10.13031/2013.23153>
- Muluaalem, G. M. ve Liou, Y.-A., 2020. Application of artificial neural networks in forecasting a standardized precipitation evapotranspiration index for the Upper Blue Nile basin. *Water*, 12(3), 643.

- Nalbantis, I. ve Tsakiris, G., 2009. Assessment of hydrological drought revisited. *Water Resources Management*, 23, 881-897.
- Özdoğan-Sarıkoç, G., Sarıkoç, M., Celik, M. ve Dadaser-Celik, F., 2023. Reservoir volume forecasting using artificial intelligence-based models: Artificial Neural Networks, Support Vector Regression, and Long Short-Term Memory. *Journal of Hydrology*, 616, 128766.
- Palmer, W. C., 1965. Meteorological Drought. US Department of Commerce, Weather Bureau, Technical Paper 45, p. 58.
- Pande, C. B., Kushwaha, N., Orimoloye, I. R., Kumar, R., Abdo, H. G., Tolche, A. D. ve Elbeltagi, A., 2023. Comparative assessment of improved SVM method under different kernel functions for predicting multi-scale drought index. *Water Resources Management*, 37(3), 1367-1399.
- Partal, T., Kahya, E. ve Cigizoglu, K., 2008. Yağış verilerinin yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. *itüdergisi/d mühendislik*, 7(3), 73-85.
- Pechlivanidis, I. G., Jackson, B. M., McIntyre, N. R. ve Wheeler, H. S., 2011. Catchment scale hydrological modelling: A review of model types, calibration approaches and uncertainty analysis methods in the context of recent developments in technology and applications [Review]. *Global Nest Journal*, 13(3), 193-214. <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84856696488&partnerID=40&md5=2c5f62fcac517b5350c126c64fe8d4f0>
- Piri, J., Abdolahi-pour, M. ve Keshtegar, B., 2023. Advanced machine learning model for prediction of drought indices using hybrid SVR-RSM. *Water Resources Management*, 37(2), 683-712.
- Popov, A. ve Sautin, A., 2008. Selection of support vector machines parameters for regression using nested grids. 2008 Third International Forum on Strategic Technologies,
- Pozzi, W., Sheffield, J., Stefanski, R., Cripe, D., Pulwarty, R., Vogt, J. V., . . . Lawford, R., 2013. Toward Global Drought Early Warning Capability: Expanding International Cooperation for the Development of a Framework for Monitoring and Forecasting. *Bulletin of the American Meteorological Society*, 94(6), 776-785. <https://doi.org/10.1175/BAMS-D-11-00176.1>
- Qie, G., Zhang, Z., Getahun, E. ve Mamer, E. A., 2022. Comparison of machine learning models performance on simulating reservoir outflow: A case study of two reservoirs in Illinois, USA. *JAWRA Journal of the American Water Resources Association*.
- Quinlan, J. R., 1986. Induction of decision trees. *Machine learning*, 1, 81-106.
- Quinlan, J. R., 1992. Learning with continuous classes. 5th Australian joint conference on artificial intelligence,

- Raghavendra. N, S. ve Deka, P. C., 2014. Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing*, 19, 372-386. <https://doi.org/10.1016/j.asoc.2014.02.002>
- Raman, H. ve Sunilkumar, N., 1995. Multivariate modelling of water resources time series using artificial neural networks. *Hydrological Sciences Journal*, 40(2), 145-163.
- Salim, D., Doudja, S.-G., Ahmed, F., Omar, D., Mostafa, D., Oussama, B. ve Mahmoud, H., 2023. Comparative Study of Different Discrete Wavelet Based Neural Network Models for long term Drought Forecasting. *Water Resources Management*, 37(3), 1401-1420.
- Seo, Y. ve Kim, S., 2016. River Stage Forecasting Using Wavelet Packet Decomposition and Data-driven Models. *Procedia Engineering*, 154, 1225-1230. <https://doi.org/10.1016/j.proeng.2016.07.439>
- Sharma, R. K., Kumar, S., Padmalal, D. ve Roy, A., 2023. Streamflow prediction using machine learning models in selected rivers of Southern India. *International Journal of River Basin Management*(just-accepted), 1-57.
- Svetnik, V., Liaw, A., Tong, C., Culberson, J. C., Sheridan, R. P. ve Feuston, B. P., 2003. Random Forest: A Classification and Regression Tool for Compound Classification and QSAR Modeling. *Journal of Chemical Information and Computer Sciences*, 43(6), 1947-1958. <https://doi.org/10.1021/ci034160g>
- Tigkas, D., Vangelis, H. ve Tsakiris, G., 2012. Drought and climatic change impact on streamflow in small watersheds. *Science of the Total Environment*, 440, 33-41.
- Tikhamarine, Y., Souag-Gamane, D., Ahmed, A. N., Kisi, O. ve El-Shafie, A., 2020. Improving artificial intelligence models accuracy for monthly streamflow forecasting using grey Wolf optimization (GWO) algorithm. *Journal of Hydrology*, 582, 124435.
- Tounsi, A., Temimi, M. ve Gourley, J. J., 2022. On the use of machine learning to account for reservoir management rules and predict streamflow. *Neural Computing and Applications*, 34(21), 18917-18931.
- Tuğrul, T. ve Hınıs, M., A., 2022. Apa Barajında Kuraklık Analizi [Araştırma Makaleleri]. *Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi*, 4(2). <https://doi.org/10.55213/kmujens.1210753>
- Tyralis, H., Papacharalampous, G. ve Langousis, A., 2019. A brief review of random forests for water scientists and practitioners and their recent history in water resources. *Water*, 11(5), 910.
- Van Loon, A. F. ve Laaha, G., 2015. Hydrological drought severity explained by climate and catchment characteristics. *Journal of Hydrology*, 526, 3-14. <https://doi.org/10.1016/j.jhydrol.2014.10.059>

- Vapnik, V. 1992. Principles of risk minimization for learning theory, Advances in Neural Information Processing NIPS 4 (pp. 831±838). In: San Mateo, CA: Morgan Kaufmann.
- Wang, J., Wang, W., Cheng, H., Wang, H. ve Zhu, Y., 2021. Propagation from Meteorological to Hydrological Drought and Its Influencing Factors in the Huaihe River Basin. Water, 13, 1985. <https://doi.org/10.3390/w13141985>
- Wang, X., Kinsland, G., Poudel, D. ve Fenech, A., 2019. Urban flood prediction under heavy precipitation. Journal of Hydrology, 577, 123984.
- White, D. ve Walcott, J., 2009. The role of seasonal indices in monitoring and assessing agricultural and other droughts: A review. Crop and Pasture Science, 60. <https://doi.org/10.1071/CP08378>
- Wilhite, D., 2000. Drought as a Natural Hazard: Concepts and Definitions. Drought, a Global Assessment, 1.
- Xiao, L., Zhong, M. ve Zha, D., 2022. Runoff forecasting using machine-learning methods: case study in the middle reaches of Xijiang River. Frontiers in big Data, 4, 125.
- Yaseen, Z. M., Jaafar, O., Deo, R. C., Kisi, O., Adamowski, J., Quilty, J. ve El-Shafie, A., 2016. Stream-flow forecasting using extreme learning machines: a case study in a semi-arid region in Iraq. Journal of Hydrology, 542, 603-614.
- Yu, M., Liu, X. ve Li, Q., 2020. Responses of meteorological drought-hydrological drought propagation to watershed scales in the upper Huaihe River basin, China. Environmental Science and Pollution Research, 27(15), 17561-17570. <https://doi.org/10.1007/s11356-019-06413-2>

ÖZGEÇMİŞ

Adı ve Soyadı : Türker TUĞRUL

EĞİTİM BİLGİLERİ (Kurum ve Yıl)

Lisans : Selçuk Üniversitesi, İnşaat Mühendisliği Bölümü,
2011-2015

Yüksek Lisans : Selçuk Üniversitesi, Çevre Mühendisliği Anabilim
Dalı, 2014-2017

MESLEKİ DENEYİM VE ÖDÜLLERİ

1. İtikat GmBH / Doktora stajı

TEZDEN ÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER

Uluslararası Hakemli Dergilerde Yayımlanan Makaleler

1. Tuğrul, T. ve Hınıs, M., A. 2023. Konya Apa Barajı Havzasında Meteorolojik ve Hidrolojik Kuraklık Trend Analizi. Karaelmas Fen ve Mühendislik Dergisi,13(1). DOI:10.7212/karaelmasfen.1203887
2. Tuğrul, T. ve Hınıs, M., A. 2022. Apa Barajında Kuraklık Analizi. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi,4(2). <https://doi.org/https://dergipark.org.tr/tr/pub/kmujens/issue/74108/1210753>