

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**İKLİM DEĞİŞİKLİĞİNİN SUSURLUK HAVZASI YAĞIŞLARI
ÜZERİNDEKİ ETKİLERİNİN YAPAY SİNİR AĞLARI İLE
ANALİZİ**

YÜKSEK LİSANS TEZİ

Merve ÖZDİN

Enstitü Anabilim Dalı : İNŞAAT MÜHENDİSLİĞİ

Tez Danışmanı : Dr. Öğr. Üyesi Gökmen ÇERİBAŞI

Haziran 2019

**T.C.
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**İKLİM DEĞİŞİKLİĞİNİN SUSURLUK HAVZASI YAĞIŞLARI
ÜZERİNDEKİ ETKİLERİNİN YAPAY SİNİR AĞLARI İLE
ANALİZİ**

YÜKSEK LİSANS TEZİ

Merve ÖZDİN

Enstitü Anabilim Dalı : İNŞAAT MÜHENDİSLİĞİ

**Bu tez 19/06/2019 tarihinde aşağıdaki jüri tarafından
oybirliği/oyçokluğu ile kabul edilmiştir.**

**Doç. Dr.
Metin İPEK
Jüri Başkanı**

**Dr. Öğr. Üyesi
Beytullah EREN
Üye**

**Dr. Öğr. Üyesi
Gökmen ÇERİBAŞI
Üye**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Merve ÖZDİN

19/06/2019

TEŞEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden yararlandığım, herkonuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, aynı titizlikte beni yönlendiren değerli danışman hocam Dr. Öğr. Üyesi Gökmen ÇERİBAŞI'na teşekkürlerimi sunarım.

Tez çalışması boyunca bilgi ve deneyimlerinden yararlandığım sayın hocam Doç. Dr. Umut OKKAN'na teşekkür ederim.

Ayrıca, bu çalışmada maddi ve manevi açıdan desteklerini üzerimden eksik etmeyen, yüksek lisans sürecim boyunca olumlu teşvikleri sayesinde bugüne ulaşmamda etkili olan aileme ve sevdiklerime teşekkür ederim.

İÇİNDEKİLER

İÇİNDEKİLER.....	ii
SİMGELER VE KISALTMALAR LİSTESİ.....	iv
ŞEKİLLER LİSTESİ	vi
TABLolar LİSTESİ	ix
ÖZET.....	xi
SUMMARY.....	xii
BÖLÜM 1.	
GİRİŞ.....	1
BÖLÜM 2.	
LİTERATÜR ÖZETİ	3
BÖLÜM 3.	
MATERYAL VE YÖNTEM.....	10
3.1. Susurluk Havzası	10
3.2. Yapay Sinir Ağları.....	12
3.2.1. Yapay sinir ağlarının yapısı	13
3.2.2. Yapay sinir ağlarının eğitimi	15
3.2.3. Levenberg-Marquardt algoritması.....	16
3.3. Yapay Sinir Ağlarına Dayanan Ölçek İndirgeme Stratejisi.....	19
3.3.1. Emisyon senaryoları, ECHAM5 iklim modeli ve NCEP/NCAR Re-analiz verileri	20
3.3.2. Ölçek indirgeme yöntemi	23
3.4. Ölçek İndirgeme Modeli Uygulaması.....	26
3.4.1. NCEP/NCAR tahminleyicilerinin seçimi.....	26

3.4.2. Ölçek indirgeme modellerinin kurulması.....	28
--	----

BÖLÜM 4.

ARAŞTIRMA BULGULARI	30
4.1. Balıkesir İstasyonu.....	30
4.2. Bandırma İstasyonu	33
4.3. Bursa İstasyonu.....	37
4.4. Dursunbey İstasyonu.....	40
4.5. Erdek İstasyonu.....	44
4.6. Keles İstasyonu	48
4.7. Mustafa Kemal Paşa İstasyonu	52
4.8. Simav İstasyonu	55
4.9. Tavşanlı İstasyonu.....	59
4.10. Uludağ İstasyonu	62

BÖLÜM 5.

TARTIŞMA VE SONUÇ	67
KAYNAKLAR.....	73
ÖZGEÇMİŞ.....	79

SİMGELER VE KISALTMALAR LİSTESİ

A1	: Senaryo grubu
A2	: Senaryo grubu
Air	: Hava sıcaklığı
B1	: Senaryo grubu
B2	: Senaryo grubu
Bj	: Girdi katmanı ile gizli katman arasındaki sabit (bias) terimler
Bm	: Çıktı katmanı ile gizli katman arasındaki sabit (bias) terimler
Bp	: Beklenen sonuçlar
E(W)	: Performans fonksiyonu
ECHAM5	: Küresel iklim modeli
Ep	: Beklenen sonuçlar ile çıktı sonuçları arasındaki fark (hata)
Ep	: Hatalar
f	: Aktivasyon fonksiyonu
$f^{(1)}$	: Girdi katmanı ile gizli katman arasındaki aktivasyon fonksiyonu
$f^{(2)}$	: Çıktı katmanı ile gizli katman arasındaki aktivasyon fonksiyonu
Hgt	: Geopotansiyel yükseklik
HKO	: Hata Kareler Ortalaması
HKOK	: Hata Kareler Ortalaması Karekökü
I	: Birim matrisi
IPCC	: Intergovernmental Panel on Climate Change
j	: Gizli katmana ait hücre sayısı
m	: Çıkış katmanındaki hücre sayısı
M	: Çıktı katmanındaki hücre sayısı
MATLAB	: Matrix Laboratory
n	: Girdi katmanındaki hücre sayısı
NCEP/NCAR	: Re-analiz verileri

net	: Net fonksiyonu
NetCDF	: Network Common Data Form
Pr	: Yağış
Press	: Yüzey basıncı
Q	: Eğitim aşamasında değerlendirilecek örnek büyüklüğü
R	: Korelasyon katsayısı
R ²	: Determinasyon katsayısı
Rhum	: Rölatif nem
S	: Standart sapma
Slp	: Deniz seviyesi basıncı
W	: Ağırlıklar
W _{ij}	: Girdi katmanı ile gizli katman arasındaki ağırlıklar
W _{jm}	: Çıktı katmanı ile gizli katman arasındaki ağırlıklar
X	: Girdiler
x _i	: Ağın girdileri
y	: Çıktılar
Y _p	: Çıktı sonuçları
YSA	: Yapay Sinir Ağları
β	: Bozulma oranı
λ	: Marquardt parametresi
Σ	: Toplam fonksiyonu

ŞEKİLLER LİSTESİ

Şekil 3.1. Susurluk havzasının konumu	11
Şekil 3.2. Bir sinir hücresinin yapısı	13
Şekil 3.3. Yapay sinir hücresinin yapısı.....	13
Şekil 3.4. Çok katmanlı bir yapay sinir ağının yapısı	14
Şekil 3.5. Senaryolar kapsamında küresel yüzey ısınması değişim tahminleri ve değerlendirilen bölümler	22
Şekil 4.1. Balıkesir istasyonu eğitim sonucu grafiği.....	30
Şekil 4.2. Balıkesir istasyonu eğitim dönemi saçılım grafiği.....	30
Şekil 4.3. Balıkesir istasyonu test sonucu grafiği	31
Şekil 4.4. Balıkesir istasyonu test dönemi saçılım grafiği	31
Şekil 4.5. Balıkesir istasyonu düzeltilmiş 20C3M değerleri grafiği	32
Şekil 4.6. Balıkesir istasyonu düzeltilmiş SRES-A1B değerleri grafiği.....	33
Şekil 4.7. Bandırma istasyonu eğitim sonucu grafiği	33
Şekil 4.8. Bandırma istasyonu eğitim dönemi saçılım grafiği	34
Şekil 4.9. Bandırma istasyonu test sonucu grafiği	34
Şekil 4.10. Bandırma istasyonu test dönemi saçılım grafiği.....	35
Şekil 4.11. Bandırma istasyonu düzeltilmiş 20C3M değerleri grafiği.....	36
Şekil 4.12. Bandırma istasyonu düzeltilmiş SRES-A1B değerleri grafiği	36
Şekil 4.13. Bursa istasyonu eğitim sonucu grafiği.....	37
Şekil 4.14. Bursa istasyonu eğitim dönemi saçılım grafiği.....	37
Şekil 4.15. Bursa istasyonu test sonucu grafiği	38
Şekil 4.16. Bursa istasyonu test dönemi saçılım grafiği	38
Şekil 4.17. Bursa istasyonu düzeltilmiş 20C3M değerleri grafiği	39
Şekil 4.18. Bursa istasyonu düzeltilmiş SRES-A1B değerleri grafiği	40
Şekil 4.19. Dursunbey istasyonu eğitim sonucu grafiği.....	41
Şekil 4.20. Dursunbey istasyonu eğitim dönemi saçılım grafiği	41

Şekil 4.21. Dursunbey istasyonu test sonucu grafiği	42
Şekil 4.22. Dursunbey istasyonu eğitim dönemi saçılım grafiği	42
Şekil 4.23. Dursunbey istasyonu düzeltilmiş 20C3M değerleri grafiği	43
Şekil 4.24. Dursunbey istasyonu düzeltilmiş SRES-A1B değerleri grafiği.....	44
Şekil 4.25. Erdek istasyonu eğitim sonucu grafiği.....	45
Şekil 4.26. Erdek istasyonu eğitim dönemi saçılım grafiği	45
Şekil 4.27. Erdek istasyonu test sonucu grafiği	46
Şekil 4.28. Erdek istasyonu test dönemi saçılım grafiği	46
Şekil 4.29. Erdek istasyonu düzeltilmiş 20C3M değerleri grafiği	47
Şekil 4.30. Erdek istasyonu düzeltilmiş SRES-A1B değerleri grafiği.....	47
Şekil 4.31. Keles istasyonu eğitim sonucu grafiği	48
Şekil 4.32. Keles istasyonu eğitim dönemi saçılım grafiği	49
Şekil 4.33. Keles istasyonu test sonucu grafiği.....	49
Şekil 4.34. Keles istasyonu test dönemi saçılım grafiği.....	50
Şekil 4.35. Keles istasyonu düzeltilmiş 20C3M değerleri grafiği	51
Şekil 4.36. Keles istasyonu düzeltilmiş SRES-A1B değerleri grafiği	51
Şekil 4.37. Mustafa Kemal Paşa istasyonu eğitim sonucu grafiği	52
Şekil 4.38. Mustafa Kemal Paşa istasyonu eğitim dönemi saçılım grafiği.....	52
Şekil 4.39. Mustafa Kemal Paşa istasyonu test sonucu grafiği.....	53
Şekil 4.40. Mustafa Kemal Paşa istasyonu test dönemi saçılım grafiği.....	53
Şekil 4.41. Mustafa Kemal Paşa istasyonu düzeltilmiş 20C3M değerleri grafiği	54
Şekil 4.42. Mustafa Kemal Paşa istasyonu düzeltilmiş SRES-A1B değerleri grafiği .	55
Şekil 4.43. Simav istasyonu eğitim sonucu grafiği	55
Şekil 4.44. Simav istasyonu eğitim dönemi saçılım grafiği.....	56
Şekil 4.45. Simav istasyonu test dönemi saçılım grafiği	56
Şekil 4.46. Simav istasyonu test dönemi saçılım grafiği	57
Şekil 4.47. Simav istasyonu düzeltilmiş 20C3M değerleri grafiği	58
Şekil 4.48. Simav istasyonu düzeltilmiş SRES-A1B değerleri grafiği	58
Şekil 4.49. Tavşanlı istasyonu eğitim sonucu grafiği	59
Şekil 4.50. Tavşanlı istasyonu eğitim dönemi saçılım grafiği	59
Şekil 4.51. Tavşanlı istasyonu test sonucu grafiği	60
Şekil 4.52. Tavşanlı istasyonu test dönemi saçılım grafiği.....	60

Şekil 4.53. Tavşanlı istasyonu düzeltilmiş 20C3M değerleri grafiği.....	61
Şekil 4.54. Tavşanlı istasyonu düzeltilmiş SRES-A1B değerleri grafiği	62
Şekil 4.55. Uludağ istasyonu eğitim sonucu grafiği	63
Şekil 4.56. Uludağ istasyonu eğitim dönemi saçılım grafiği	63
Şekil 4.57. Uludağ istasyonu test sonucu grafiği	64
Şekil 4.58. Uludağ istasyonu test dönemi saçılım grafiği.....	64
Şekil 4.59. Uludağ istasyonu düzeltilmiş 20C3M değerleri grafiği.....	65
Şekil 4.60. Uludağ istasyonu düzeltilmiş SRES-A1B değerleri grafiği	65



TABLolar LİSTESİ

Tablo 3.1. Seçilen istasyonlara ait bilgiler	12
Tablo 3.2. YSA ve Sinir Sistemi Elemanlarının Karşılaştırılması.....	12
Tablo 3.3. IPCC senaryolarının nüfus ve ekonomi öngörülerini	20
Tablo 3.4. İklim senaryolarının CO2 salım tahminleri	21
Tablo 3.5. Global sıcaklık ve deniz seviyelerindeki artış tahminleri	21
Tablo 3.6. Uygulama bölgesini temsil eden ECHAM5 iklim modelinin grid koordinatları.....	22
Tablo 3.7. NCEP/NCAR re-analiz veri setinde ve iklim modellerinde ortak bulunan değişkenler	23
Tablo 3.8. DMİ 17150 yağış verileri ile NCEP/NCAR re-analiz verileri arasında elde edilen korelasyon katsayıları (R).....	26
Tablo 3.9. Aylık toplam yağış tahminleyicilerini belirlemek için gerçekleştirilen adimsal regresyon analizi sonuçları	27
Tablo 4.1. Gerekli oran (Balıkesir İstasyonu)	32
Tablo 4.2. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Balıkesir İstasyonu)	32
Tablo 4.3. Mevsimsel sonuçlar tablosu (Balıkesir İstasyonu).....	33
Tablo 4.4. Gerekli oran (Bandırma İstasyonu).....	35
Tablo 4.5. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Bandırma İstasyonu)...	35
Tablo 4.6. Mevsimsel sonuçlar tablosu (Bandırma İstasyonu).....	36
Tablo 4.7. Gerekli oran (Bursa İstasyonu)	39
Tablo 4.8. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Bursa İstasyonu)	39
Tablo 4.9. Mevsimsel sonuçlar tablosu (Bursa İstasyonu).....	40
Tablo 4.10. Gerekli oran (Dursunbey İstasyonu).....	42
Tablo 4.11. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Dursunbey İstasyonu)	43
Tablo 4.12. Mevsimsel sonuçlar tablosu (Dursunbey İstasyonu)	44

Tablo 4.13. Gerekli oran (Erdek İstasyonu).....	46
Tablo 4.14. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Erdek İstasyonu)	47
Tablo 4.15. Mevsimsel sonuçlar tablosu (Erdek İstasyonu)	48
Tablo 4.16. gerekli oran (Keles İstasyonu)	50
Tablo 4.17. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Keles İstasyonu)	50
Tablo 4.18. Mevsimsel sonuçlar tablosu (Keles İstasyonu).....	51
Tablo 4.19. Gerekli oran (Mustafa Kemal Paşa İstasyonu)	54
Tablo 4.20. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Mustafa Kemal Paşa İstasyonu).....	54
Tablo 4.21. Mevsimsel sonuçlar tablosu (Mustafa Kemal Paşa İstasyonu).....	55
Tablo 4.22. Gerekli oran (Simav İstasyonu)	57
Tablo 4.23. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Simav İstasyonu)	57
Tablo 4.24. Mevsimsel sonuçlar tablosu (Simav İstasyonu).....	58
Tablo 4.25. Gerekli oran (Tavşanlı İstasyonu).....	61
Tablo 4.26. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Tavşanlı İstasyonu)...	61
Tablo 4.27. Mevsimsel sonuçlar tablosu (Tavşanlı İstasyonu)	62
Tablo 4.28. Gerekli oran (Uludağ İstasyonu).....	64
Tablo 4.29. Düzeltilmiş 20C3M ve A1B senaryosu sonuçları (Uludağ İstasyonu).....	65
Tablo 4.30. Mevsimsel sonuçlar tablosu (Uludağ İstasyonu)	66
Tablo 5.1. İstasyon için sonuçlar.....	72

İKLİM DEĞİŞİKLİĞİNİN SUSURLUK HAVZASI YAĞIŞLARI ÜZERİNDEKİ ETKİLERİNİN YAPAY SİNİR AĞLARI İLE ANALİZİ

ÖZET

İnsanlık küresel ısınmanın neden olduğu iklim değişikliği sonucu birçok problemle karşı karşıyadır. Kullanılabilir su kaynaklarının hızla tükenmesi, olağandışı hava olayları, sel ve kuraklık gibi doğal felaketler insanlık için karşı karşıya kalınan sorunlardan en önemlileridir. Bu nedenle iklim değişikliği sonucu meydana gelecek değişiklikler ile ilgili ülkemizin kritik alanlarında senaryolar oluşturularak öngörülerde bulunulması, modellemeler oluşturulması son derece önem arz etmektedir. Dolayısıyla ileriye dönük yapılacak senaryo veya modeller bize gelecekle ilgili bilgi vereceği için ayrıca gelecekte karşımıza çıkabilecek olumsuz senaryolar için önlemler erkenden alınmış olacaktır. Bu tez çalışmasında da iklim değişikliğinin Türkiye'nin önemli havzalarından biri olan Susurluk Havzası'nda ne derece etkili olacağı kurulan modelleme ile araştırılacaktır. Araştırmada, Devlet Meteoroloji istasyonu Genel Müdürlüğü'nün Susurluk havzasında bulunan yağış istasyonlarının (Bandırma, Bursa, Dursunbey, Erdek, Keles, Mustafa Kemal Paşa, Simav, Tavşanlı ve Uludağ) aylık toplam yağış verileri kullanılmıştır. Bu verilerle ileriye dönük tahminler, ölçek indirgeme yaklaşımı Yapay Sinir Ağları (YSA) yöntemi ile MATLAB programı kullanılarak yapılmıştır. Verilerle oluşturulan YSA modeliyle 2015-2030 yılları arasındaki aylık toplam yağış miktarları tahmin edilmiştir.

Anahtar kelimeler: Yapay Sinir Ağları (YSA), İklim değişikliği, Ölçek indirgeme, Yağış tahmini

THE ANALYSIS OF THE EFFECTS OF CLIMATE CHANGE ON THE SUSURLUK BASIN PRECIPITATIONS BY ARTIFICIAL NEURAL NETWORKS

SUMMARY

Humanity is faced with many problems as a result of climate change caused by global warming. Natural disasters such as the rapid depletion of available water resources, unusual weather events, floods and droughts are the most important problems facing humanity. For this reason, it is of utmost importance that predictions and models be created by creating scenarios in critical areas of our country regarding the changes that will occur as a result of climate change. Therefore, the future scenarios or models will give us information about the future, and also the measures for the future negative scenarios will be taken early. This thesis studies of climate change in the Susurluk Basin, one of Turkey's most important watersheds will be established to what extent effective will be investigated by modeling. In the study, the monthly total precipitation data of the precipitation stations (Bandırma, Bursa, Dursunbey, Erdek, Keles, Mustafa Kemal Pasha, Simav, Tavsanlı and Uludag) in the Susurluk basin of the General Directorate of State Meteorology Station were used. Forward-looking estimations with this data were made using the scale reduction approach using the Artificial Neural Networks (ANN) method and the MATLAB program. Monthly total precipitation amounts between 2015-2030 were estimated with the ANN model.

Keywords: Artificial Neural Networks (ANN), Climate change, Scale reduction, precipitation

BÖLÜM 1. GİRİŞ

Küresel ısınma sonucunda meydana gelecek iklim değişikliği, iklim farklılaşmalarının yanı sıra insanların olumsuz davranışları sonucu atmosferin yapısının bozulması olarak tanımlanabilir. Sanayileşme faaliyetleri sonucu atmosfere salınan sera gazlarının miktarının artması, arazi kullanımındaki farklılıklar ve fosil yakıtların yakılması insanların iklim değişikliğine doğrudan ya da dolaylı bir şekilde etki eden olumsuz davranışlarından bazılarıdır. Türkiye gerek jeopolitik gerek özel konumu nedeniyle iklim değişikliğinden en yüksek derecede etkilenecek ülkeler arasındadır. Ekosistemde yer alan canlı çeşitliliğindeki azalma, turizm sektöründeki gelirlerin azalması, tarımsal alandaki verim kayıpları ülkemizde iklim değişikliği sonucu insanları bekleyen sorunlardan bazılarıdır. Bunların yanında belki de en önemlisi kullanılabilir su kaynaklarının azalması ve sel ya da kuraklık gibi doğal afetlerle karşı karşıya kalınmasıdır. Su evrendeki istisnasız bütün canlılar için gerekli olan temel bir yaşam ihtiyacıdır. Bu nedenle her geçen gün sayısında azalmalar görülen su kaynakları için bilim adamları ve daha iyi bir gelecek isteyen herkesin alınabilecek önlemler ile ilgili çalışması gerekmektedir. Yurt dışında bu konuyla ilgili çalışmalara ülkemizden çok daha önce başlanmıştır. Ülkemizde de bu konuyla ilgili çalışmaların artması gerekmektedir. Bu nedenle iklim değişikliği sonucu meydana gelecek değişiklikler ile ilgili ülkemizin kritik alanlarında senaryolar oluşturularak öngörülerde bulunulması, modellemeler oluşturulması son derece önem arz etmektedir. Eğer gelecekte olma ihtimali öngörülen ekstrem olaylarla ilgili önlemler alınmazsa insanlık geri dönülemez tablolarla karşı karşıya kalmış olabilir (Okkan ve Karakan, 2015). Dolayısıyla ileriye dönük yapılacak senaryo veya modeller bize gelecekle ilgili bilgi vereceği için ayrıca gelecekte karşımıza çıkabilecek olumsuz senaryolar için önlemler erkenden alınmış olacaktır. Bu nedenle ileriye dönük tahmin senaryoları son derece önem arz etmektedir. En yaygın olarak bilinen ileriye dönük tahmin modellerinden biri yapay sinir ağlarıdır. Bu tez çalışmasında da yapay sinir ağları yöntemi kullanılarak küresel ısınma sonucu ortaya çıkan iklim değişikliği sonucunun

özellikle Susurluk havzasında ne kadar etkili olacağı bu model sayesinde ortaya çıkmış olacaktır. Dolayısıyla bu tez çalışmasında yapay sinir ağları yöntemi ile ileriye dönük tahmin modeli kurularak gelecekteki aylık toplam yağış miktarının tahmin edilmesi amaçlanmaktadır.

Dolayısıyla ileriye dönük yapılacak senaryo veya modeller bize gelecekle ilgili bilgi vereceği için ayrıca gelecekte karşımıza çıkabilecek olumsuz senaryolar için önlemler erkenden alınmış olacaktır. Bu nedenle ileriye dönük tahmin senaryoları son derece önem arz etmektedir. En yaygın olarak bilinen ileriye dönük tahmin modellerinden biri yapay sinir ağlarıdır. Bu tez çalışmasında da yapay sinir ağları yöntemi kullanılarak küresel ısınma sonucu ortaya çıkan iklim değişikliği sonucunun özellikle Susurluk havzasında ne kadar etkili olacağı bu model sayesinde ortaya çıkmış olacaktır. Dolayısıyla bu tez çalışmasında yapay sinir ağları yöntemi ile ileriye dönük tahmin modeli kurularak gelecekteki yağış miktarının tahmin edilmesi amaçlanmaktadır.

BÖLÜM 2. LİTERATÜR ÖZETİ

Aksoy ve Dahamsheh (2018), yarı kurak ve kurak iklimin hâkim olduğu Ürdün bölgesi ele almışlardır. Kurak bölgelerde yağış değişimin yüksek olması yapay sinir ağı modellerinin performansını olumsuz yönde etkilediğini belirtmişlerdir. Araştırmacılar aylık yağış tahmini elde etmek amaçlı yapay sinir ağına markov zinciri eklemişler ve bu şekilde elde ettikleri sonuçların daha verimli olduğunu orataya koymuşlardır. Yapay sinir ağı modelleri deneme yanılma prosedürüne dayandığından söz konusu çalışmadaki yapay sinir ağı modellerinden hiçbirisi en iyi seçenek olarak nitelendirilemeyeceğini öngörmüşlerdir. Çünkü her zaman farklı aktivasyon işlevlerine ve yayılma katsayılarına sahip daha iyi sonuç veren modeller oluşturulabilir (Aksoy & Dahamsheh, 2018).

Nastos ve ark. (2014), Yunanistan Atina'da aşırı yağışların yol açabileceği sel felaketleri için ileriye dönük önlemler alınabilmesi amaçlı yapay sinir ağları ile yağış tahmini elde etmeye çalışmışlardır. 1891-2009 süreci dikkate alınmıştır. 1891-1980 dönemine ait veri setleri eğitime, 1980-2009 dönemi ise geçerlilik veri seti olarak kullanmıştır. Yapılan analizler sonucunda sonuçlar tatmin edici ve cesaret verici bulmuştur. Yapılan analizlerin sonucunda elde edilen değerler, yağış gibi böylesine rastgele bir olay düşünüldüğünde tatmin edici ve daha sonraki araştırmalar için teşvik edici bulmuştur. Anlaşma endeksi ($IA=0,817$), belirleme katsayısı ($R^2=0,482$) bulmuştur (Nastos, Paliatsos, Koukouletsos, Larissi, & Moustris, 2014).

Çevik (2009), Isparta iline ait yapay sinir ağları metodu ile aylık yağış tahmini yapmıştır. Bu ilde yer alan Senirkent, Uluborlu, Eğirdir, Yalvaç, Isparta istasyonlarına ait yağış verileri kullanmıştır. Yapılan çalışmalar sonucunda girdi parametre sayısı çok olan modellerde yapay sinir ağları metodunun, az parametrelili modellerde ise lineer yağış tahmin modellerinin kullanılabileceği sonucuna varmıştır (Çevik, 2009).

Zubaidi ve ark (2018), belediye su alt yapılarının etkin ve sürdürülebilir bir şekilde gelişebilmesi için önemli olan su talebi tahmini üzerinde çalışmışlardır. Bu çalışmada, ön tedavi sinyal tekniği, hibrit parçacık sürüsü optimizasyon algoritması ve yapay sinir ağları kombinasyonu kullanılarak iklim faktörlerinin değerlendirilmesi yoluyla su talebini ölçmede yeni bir yaklaşım kullanmışlardır. Mevsimsel ve stokastik zaman serileri oluşturmak için altı hava değişkenine bağlı su tüketimini ayırtmak ve yeniden yapılandırmak için Tekil Spektrum Analizi (SSA) tekniği kullanmış ve sonuçlar, SSA'nın orijinal zaman serisini trend, salınım davranışları ve gürültü gibi birçok bağımsız bileşene ayırabilen güçlü bir teknik olduğunu ortaya koymuşlardır. Ek olarak, PSO-ANN algoritmasının, uygunluk fonksiyonu (RMSE) açısından hibrit Geri Taramalı Arama Algoritması BSA-ANN'den daha iyi performans gösteren güvenilir bir tahmin modeli olduğu göstermişlerdir. Bu çalışmanın bulguları, su talebinin klimatolojik değişkenler tarafından yönlendirildiği görüşünü desteklemektedir (Zubaidi vd., 2018).

Bisoyi ve ark. (2019), büyük bir tropik nehir olan Narmada nehri için Geri Yayılım Sinir Ağı (BPNN) algoritmasından faydalanarak tortu yüklerinin değişkenliğini yağış ve akış ile ilişkilendirerek günlük sediment tahmini yapmışlardır. Algoritma ve simülasyon MATLAB programı ile gerçekleştirilmiştir. Zaman değişkenleri, yağış ve su miktarının bilinen verilerinin bulunduğu durumlarda sediment miktarını tahmin etmek için yapay bir sinir ağı modeli geliştirmişlerdir. Dokuz farklı yerde onaylanmış ve test edilmiştir. Önerilen model rastgele seçilen verilerle doğrulanmış ve bir muson mevsiminin zaman serisi verileri kullanılarak test etmişlerdir. %75 olumlu bir sonuç ve daha sonra, başka bir dört yıllık veri seti kullanılarak model eğitildikten sonra tüm yerler için %72 olumlu sonuç elde etmişlerdir. Her iki durumda da öngörülen değerler önerilen modelin sağlamlığını belirleyen gerçek değerlere yakın bulmuşlardır. Bu geri yayımlı yapay sinir ağı modelinin performansının sadece alt havuzlar için değil, aynı zamanda genel kullanıma uygun yerler için de tatmin edici olduğunu bulmuşlardır. Sonuçlar ayrıca, yeterli eğitim almış önerilen modelin, farklı hidrolojik değişkenler arasında doğrusal olmayan bir ilişkiye sahip büyük havzalar için bile günlük sediment yükünü doğru bir şekilde tahmin edebildiğini göstermektedir (Bisoyi , Gupta , Padhy, & Chakrapani, 2019).

Gao ve ark. (2018), Kuzey Çin'deki bir metropol olan Jinan kentindeki ozon konsantrasyonunu tahmin etmek için ANN modelini meteorolojik parametrelerle girdi değişkenleri olarak kullanmanın fizibilitesini araştırmıştır. Öncelikle, nöron ağlarının mimarisinin ANN modelinin öngörme kabiliyetini çok az etkilediğini bulmuşlardır. Kirlilik olayları sırasında ısınma başarısı oranı açısından da tahmin edilebilirliği doğrulanmış ve son olarak, Monte Carlo simülasyonlarına (MCS) dayanarak belirsizlik ve duyarlılık analizi de yapmışlardır. YSA'nın ortamdaki ozon seviyesini uygun şekilde tahmin edebileceği sonucuna varmışlardır. Maksimum sıcaklık, atmosferik basınç, güneşlenme süresi ve maksimum rüzgâr hızı, ortamdaki ozon konsantrasyonlarının öngörülmesini önemli ölçüde etkileyen baskın girdi değişkenleri olarak tanımlamışlardır (Gao, Yin, & Ning, 2018).

Farajzadeh ve ark. (2014), dünyanın en büyük ikinci tuz gölü olan İran'ın kuzeyindeki Urmia göl havzası için yapay sinir ağları ile aylık yağış tahmini modelleme çalışması yapmışlardır. Yapılan çalışmada, Urmia göl havzasında aylık yağışları tahmin etmek için İleri Beslemeli Sinir Ağı ve Otokorelasyon Regresif Tümlleşik Hareketli Ortalama (ARIMA) modelleri uygulanmışlardır. Sonuçlar, Feed-forward NN aracılığıyla aylık yağış değerlerinin, 0,62 korelasyon katsayısı ve 6 yıllık test periyodu boyunca 12,43 mm kök ortalama kare hatası ile ARIMA modeline yakın olduğunu göstermiş; daha sonra, 2012'den başlayarak (2012-2017) 6 yıllık bir süre için yağış miktarı öngörmüşlerdir. Havzada yağışların paralel verilerinden hesaplanan ve 39 yıl boyunca akıntı sonucu gerçekleşen akıntı katsayısı rejimi kullanılarak gelecekteki akış, o dönemde öngörülen yağışlarla elde etmişlerdir (Farajzadeh, Fard, & Lotf, 2014).

Uzlu ve ark. (2014), Bu çalışmada, Türkiye'nin 1980-2020 yıllarındaki enerji tüketimi, önerilen üç senaryoda GSYİH, nüfus, ithalat ve ihracat göstergelerine göre modellemişlerdir. Test ve eğitim veri setlerinin hata değerlerine göre, önerilen ANN-TLBO modeli, Türkiye'nin enerji tüketimini tahmin etmek için klasik BP eğitilmiş ANN modelinden daha iyi performans göstermişlerdir. Senaryo analizinde, 2013-2020 döneminde Türkiye'nin enerji tüketimini tahmin etmek için ANN-TLBO tekniğini kullanmışlardır. Tüm senaryolar, ETKB projeksiyonlarından daha düşük enerji tüketimi tahminleri vermiştir. Üç senaryo, Türkiye'nin gelecekteki enerji tüketiminin 2020'de

142,65 ile 158,00 Mtoe arasında deęiřeceęini göstermiřlerdir (Uzlu, Kankal, Akpınar, & Dede, 2014).

L.Ekonomou (2010), Yunanistan'ın uzun vadeli enerji tüketiminin tahmin edilmesi için yapay sinir aęlarını (YSA) ele almıřtır. Çok katmanlı algılayıcı modeli (MLP), bu amaçla, en iyi genelleme yeteneęine sahip olanı seçebilmek için birkaç olası mimariyi test ederek kullanmıřtır. Eęitim, validasyon ve test sürecinde uzun vadeli enerji tüketimini etkileyen geręek kayıtlı girdi ve çıktı verileri kullanmıřtır. Geliřtirilen YSA modeli 2005-2008, 2010, 2012 ve 2015 Yunan enerji tüketiminin tahmini için kullanmıřtır. 2005-2008 yılları arasında elde edilen ANN sonuları, doęrusal bir regresyon yöntemi, bir destek vektör makinesi yöntemi ve büyük bir doęruluk gösteren geręek enerji tüketim kayıtları ile elde edilen sonularla karřılařtırmıřtır (Ekonomou, 2010).

Sözen ve ark. (2016), Bu alıřma da Türkiye’de enerji tüketiminin gelecekteki seviyesini belirlemek için yapay sinir aęı (YSA) teknięini kullanarak net enerji tüketimini (NEC) tahmin etme denklemlerini geliřtirmek istemiřlerdir. řebekede lojistik sigmoid transfer fonksiyonu kullanılmıřlardır. Sinir aęını, popölasyonu ve brüt üretimi eęitmek için, aęın giriř katmanında kurulu kapasite ve yılları kullanmıřlardır. Net enerji tüketimi çıktı katmanındadır. 1965, 1981 ve 1997’deki girdi deęerleri yalnızca bu yöntemi doęrulamak için test verileri olarak kullanmıř. Birden fazla tespit istatistiksel katsayısı (R , 2-deęeri) sırasıyla eęitim ve test verileri için 0,9999 ve 1’e eřittir. Sonulara göre, ANN teknięini kullanan NEC açıka kabul edilebilir hatalar içerisinde tahmin edilmiřlerdir. Gereken süreyi azaltmanın yanı sıra, YSA yaklařımının önemi, enerji uygulamalarını daha uygulanabilir ve dolayısıyla potansiyel kullanıcılar için daha cazip hale getiren özümmler bulmak için mümkündür (Sözen, Akayol, & Arcaklioęlu, 2006).

Vu ve ark. (2016), Bangkok-Tayland alanını ele alarak yaęıř tahmini yapmıřtır. Sonu olarak yapay sinir aęları kullanılabilir görölmüřtür. Korelasyon katsayısı 0,8, verimlilik oranı 0,65 olarak gözlemlenmiřtir (Vu, Aribarg, Supratid, Raghavan, & Liong, 2016).

Chang vd. (2017), alıřma alanı olarak Kuzeydoęu Amerika Birleřik Devletleri’ndeki Adirondack Eyalet Parkı bölgesini ele almıřlardır. Dalgacık teorisi yardımıyla aylık ve

mevsimsel süreçleri baz alarak yapay sinir ağları aracılığıyla yağış tahmini yapmışlardır. 1983-2009 yıllarını kapsayan verisetinin yüzde altmışı eğitim için kullanılmış, yüzde kırkı test için ayrılmıştır. 2010 yılının aylık ve mevsimsel süreçlerdeki yağış tahminine ulaşmışlardır. Yapılan çalışmalar sonucunda mevsim ölçeğindeki sonuçların daha iyi performans gösterdiği ortaya çıkarmışlardır (Chang, Yang, Imen, & Mullon, 2017).

Uzlu ve ark. (2014), Bu çalışmalarındaki temel amaç, Türkiye'nin yıllık hidrolik enerji üretimini tahmin etmek için ANN (yapay sinir ağı) modelini ABC (yapay arı kolonisi) algoritmasıyla uygulamak istemişlerdir. Modelde GEED (brüt elektrik enerjisi talebi), nüfus, AYT (ortalama yıllık sıcaklık) ve enerji tüketimi bağımsız değişkenler olarak seçmişlerdir. Çalışmanın ilk bölümünde ANN-ABC model performansı ile BP (geri yayılım) algoritması ile eğitilmiş klasik ANN modellerinin sonuçları karşılaştırmışlardır. Model doğruluğunu değerlendirmek için ortalama kare ve bağıl hata uygulamışlardır. Test seti hataları, ANN-ABC ve klasik ANN modelleri arasındaki pozitif farklılıkları vurgulamış. Optimal konfigürasyonların belirlenmesinden sonra, Türkiye için gelecekteki hidroelektrik üretim değerlerini öngörmek için üç farklı senaryo geliştirmişlerdir. Sonuçlar, ANN-ABC yönteminin, BP algoritması ile eğitilmiş klasik ANN'den daha iyi hidroelektrik üretimini öngördüğünü göstermişlerdir. Ayrıca, Türkiye'de gelecekteki hidroelektrik üretiminin 2021'de 69,1 ile 76,5 TWh arasında olacağını ve hidroelektrik tedarik oranlarının temsil ettiği yıllık toplam elektrik talebinin %14,8 ile %18,0 arasında olacağını belirtmişlerdir (Uzlu, Akpınar, Öztürk, Nacar, & Kankal, 2014).

Kermanshahi ve Iwamiya (2002), Bu çalışmalarında Japonya'da en yüksek elektrik yüklerinin 2020 yılına kadar tahmini yapay sinir ağları (YSA) kullanılarak ele almışlardır. Bu çalışmada, Japonya'daki dokuz enerji şirketi için mevcut ve gelecekteki eğilimleri yansıtan toplam sistem yükü tahmini yapmışlardır. İki katmanlı, üç katmanlı bir geri yayılım ve tekrarlayan bir sinir ağı olan bu amaç için tasarlanmış ve test etmişlerdir. Sırasıyla 1999, 2000, 2005, 2010, 2015 ve 2020 hedef yılları için tahminler yapmışlardır ve 2010 ve 2020 yıllarının yüklerini tahmin etmek için de test etmişlerdir. Kısa vadeli yük tahmininin aksine, uzun vadeli yük tahminleri çoğunlukla hava koşullarından ziyade ekonomik faktörlerden etkilemiş ve bu çalışma, uzun vadeli elektrik yükü taleplerini

etkiliyor gibi görünen ekonomik verilere odaklanmışlardır. Burada, önerilen YSA'lar için girdi olarak 10 faktör seçmişlerdir: (1) gayri safi milli hasıla, (2) gayri safi yurtiçi hasıla, (3) nüfus, (4) hane sayısı, (5) klima sayısı, (6) CO₂ miktarı kirlilik, (7) sanayi üretim endeksi, (8) petrol fiyatı, (9) enerji tüketimi ve (10) elektrik fiyatı. Kullanılan veriler: yıllık, fiili, önceki yıla göre artan büyüme oranı ve her ikisi birlikte (önceki yıla ait fiili ve artan büyüme hızı). Sonuç olarak, 2010 ve 2020 taleplerinin sırasıyla 225.779 ve 249.617 GW olduğu tahmin etmişlerdir. Yapı reformu ile 2010 ve 2020 taleplerinin 219.259 ve 244.508 GW olacağı tahmin etmişlerdir (Kermanshahi & Iwamiya, 2002).

Azad ve ark. (2019), İran-İsfahan merkezli çalışma alanında çeşitli yöntemler kullanarak yağış tahmini elde etmeye çalışmışlardır. En iyi model ANFIS-ACOR ($R^2 = 0,92$, RMSE = 2,73 mm ve SI = 0,26) iken, tek ANFIS modeli ($R^2 = 0,33$, RMSE = 9,98 mm ve SI = 0,90 ile) en kötü sonucu vermişlerdir. Araştırmacılar yapılan çalışmalar sonucunda, optimizasyon algoritmalarının ANFIS ile birleştirilmesi aylık yağış-zaman serilerinin modellenmesinde performansını arttırabileceği saptamışlardır. Korelasyon katsayısı ve girdi verilerinin hassasiyet analizi sayesinde gereksiz girdi parametreleri ihmal edilerek model doğruluğu artmış ve geçerli bir girdi sistemi meydana getirmişlerdir (Azad, Manoochehri, Kashi, Farzin, & Karami, 2019).

Xu ve ark. (2019), çalışma alanı olarak Çin'de yaptıkları araştırmada, yarı küresel bir yağış ürünü olan IMERG'in saatlik ve günlük yağış tahminlerinde farklı versiyonlarını kıyaslamışlardır. Araştırmacılar, yapılan çalışmalar sonucunda 05B versiyonunun 04A versiyonuna göre daha iyi sonuçlar verdiğini tespit etmişlerdir (Xu, Shen, & Niu, 2019).

Le ve ark. (2017), Kaliforniya bölgesinde kuraklığa önlemler geliştirebilmek için yapay sinir ağları yöntemi ile yağış tahmini yapmışlardır. (Le, El-Askary, Allali, & Struppa, 2017).

Zambrano vd. (2017), Şili'deki kuraklığa çözüm üretebilmek amacıyla uydu verilerinden faydalanarak yağış tahmininde bulmuşlardır. Yapılan çalışmalar sonucunda farklı teknikler de çözüme eklenerek daha iyi modellemelere ulaşılabileceği öngörülmüşlerdir (Zambrano, Wardlow, Tadesse, Saavedra, & Lagos, 2017).

Trejo ve ark. (2017), çalışma alanı olarak Brezilya’da, uydu verileri kullanılarak seçilen 21 adet istasyonda aylık yağış miktarını belirlemek amacıyla araştırma yapmışlardır. Elde edilen bulgulara göre; CHIRPS v.2 veri setinin, yarı yarı NEB dışındaki yağmur ölçer yağış verisinin yerine kullanabileceği sonucuna varmışlardır (Trejo, Barbosa, & Kumar, 2017).

Kökçam ve ark. (2018), Bu çalışmalarında Meriç Nehri üzerinde bulunan İpsala, Plovdiv, Svilengrad ve Kirişhane akım gözlem istasyonlarındaki akımların tahmini için YSA modeli oluşturmuşlardır. Model ile elde edilen tahminleri çeşitli performans metotları yardımıyla gerçek değerlerle karşılaştırdıklarında YSA’nın nehir akımlarının tahmini konusunda başarılı sonuçlar verdiğini görmüşlerdir. Modelden daha iyi sonuçlar elde edebilmek amacıyla eğitim ve test veri oranları, gizli katman sayısı, zaman gecikmesi, değerlendirme ve eğitim fonksiyonları gibi parametreleri ve yaklaşımları farklılaştırılarak denemişlerdir. Verilerin işlenmesi konusunda gerçek değerler ile normalize değerler karşılaştırmış, veriler [0, 1] aralığına normalize edilerek de model çalıştırmış, fakat eşik değerinde iyileşme görülmediği için normalize edilmeden kullanmışlardır (Kökçam, Doğan, & Erden, 2018).

Çeribaşı ve Doğan, Sakarya Nehrinde ölçülen yıllık ortalama akım ve askıda katı madde ve Sakarya iline ait ortalama yıllık yağış verileri trend analizi yöntemiyle, Sakarya Nehrinde ölçülen günlük, haftalık ve aylık ortalama akım ve askıda katı madde ve Sakarya iline ait ortalama günlük, haftalık ve aylık yağış verileri de YSA Modeli ile irdeleyip sonuçları karşılaştırmışlardır. Yapılan çalışmada her iki yöntem ile ileriye dönük askıda katı madde miktarı tahmini yapılmış ve yapılan bu tahminler ile her iki yönteminde benzer sonuç verdiği görüşünü ortaya koymuşlardır (Ceribasi, Doğan, Akkaya, U. & Kocamaz, 2017).


BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Susurluk Havzası

Susurluk havzası, Türkiye'nin 25 havzasından biri olup önemli havzalardan biridir. Türkiye yüzölçümünün yaklaşık %2,9'unu kapsayan Susurluk Havzası 22.399 km² yağış alanına sahiptir. Susurluk havzasının Türkiye haritası üzerindeki konumu Şekil 1'de gösterilmiştir. Susurluk havzası Türkiye'nin batısında, 39°-40° kuzey enlemleri ile 27°-30° doğu boylamları arasında yer almaktadır. Türkiye'nin alan olarak yaklaşık %3,11'ini kapsayan havzanın toplam alanı yaklaşık 24.332 km²'dir. Daha çok doğu-batı yönünde uzanan dağ sisteminin görüldüğü havzada Marmara Bölgesi'ne ait en yüksek dağ olan Uludağ bulunmaktadır. Susurluk Havzası doğusunda Murat, Gümeş, Yirce ve Uludağlar; güneyde Şaphane ve Simav dağları, batıda Madra ve Deliçal Dağları; kuzeyde ise Karadağ ve Mudanya Tepeleri ile Marmara Denizi tarafından sınırlanmıştır (Susurluk Havzası Taşkın Yönetim Planı, 2018).

Aylık toplam yağış miktarının tahmini için veriler Meteoroloji Genel Müdürlüğünden alınmıştır. Yağış verileri kullanılan istasyonlar: Balıkesir, Bandırma, Simav, Bursa, Tavşanlı, Keles, Dursunbey, Erdek, Mustafa Kemal Paşa ve Uludağ istasyonları olarak belirlenmiştir.

TÜRKİYE’NİN AKARSU ve HAVZALARI



Şekil 3.1. Susurluk havzasının konumu

Tablo 3.1. Seçilen istasyonlara ait bilgiler


İstasyon Adı	Numarası	Bulunduğu İl	Enlem-Boylam-Rakım
Balıkesir	17152	Balıkesir	39.6500-27.8666-102
Bandırma	17114	Balıkesir	40.3315-27.9965-63
Dursunbey	17700	Balıkesir	39.5778-28.6322-637
Erdek	17635	Balıkesir	403.9720-277.8850-2
Bursa	17116	Bursa	40.2308-29.0133-100
Keleş	17695	Bursa	39.9150-29.2313-1063
Mustafa Kemal Paşa	699	Bursa	40.0333-28.4000-40
Uludağ	17676	Bursa	40.1075-29.1290-1877
Tavşanlı	17704	Kütahya	39.5384-29.4941-833
Simav	17748	Kütahya	39.0925-28.9786-809

3.2. Yapay Sinir Ağları


Yapay Sinir Ağları (YSA) teknolojisi, insanlığın doğayı taklit etmek istemesi ve bu nedenle araştırmalar yapması sonucu ortaya çıkmıştır. Basit biyolojik sinir sisteminin işleyiş şeklini simüle etmek amacıyla tasarlanan programlara YSA denmektedir. Simüle edilen sinir hücreleri nöronlar içerirler ve bu nöronlar farklı şekillerde birbirlerine bağlanarak ağı meydana getirirler. Bu ağlar veriler arasındaki kapasiteyi ortaya çıkarma, öğrenme yetisine sahiptir. Diğer bir deyişle, YSA'nın amacı, bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini kullanmayı gerektiren problemler için çözüm üretmektir. Bir insan, insan beyninin sahip olduğu yaşayarak veya deneyerek öğrenme yeteneği sayesinde, düşünme ve gözlemleme yeteneklerini gerektiren problemler için çözümler üretebilir. YSA kavramı, beynin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile orta çıkmıştır (Kubat, 2017).

Tablo 3.2. YSA ve Sinir Sistemi Elemanlarının Karşılaştırılması (Kubat, 2017)

Sinir Sistemi Elemanları	YSA Elemanları
Sinir	Yapay Sinir Hücresi
Sinaps	Ağırlıklar
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Eleman Çıkışı




Şekil 3.2. Bir sinir hücresinin yapısı (URL-1)



Şekil 3.3. Yapay sinir hücresinin yapısı (URL-2)

3.2.1. Yapay sinir ağlarının yapısı

Yapay sinir ağları (YSA) biyolojik sinir sisteminden ilham alınarak geliştirilmiş matematiksel araçlardır (Haykin, 1994; Okkan & Karakan, 2015). YSA modelleri biyolojik sinir sistemlerinde görüldüğü gibi hücrelerin birleşmesiyle oluşturulmakta ve genel olarak katmanlar halinde tanımlanmaktadır (Şekil 3.4.).



Şekil 3.4. Çok katmanlı bir yapay sinir ağının yapısı (Okkan & Karakan, 2015)

Çok katmanlı yapay sinir ağları ilk katman giriş katmanı olarak, aradaki diğer katmanlar ara katman ya da gizli katman olarak isimlendirilir. Son katman ise çıkış katmanı olarak adlandırılır. Bir yapay sinir ağındaki gizli katman sayısı birden fazla olabilmesi mümkündür. Bir yapay sinir ağı modelinde her bir gizli katmanda kaç sinir hücresi olması gerektiği ve kaç tane gizli katman kullanılması gerektiği ise bugüne kadar açıklığa kavuşmamıştır. Üzerinde çalışılan probleme göre değişen bu duruma deneme-yanılma yoluyla çözüm bulunabilmektedir (Ham ve Kostanic, 2001; Tayfur, 2012; Okkan & Karakan, 2015). Şekil 3.7. incelendiğinde bir YSA modelinin çok katmanlı yapısı girdiler (x), ağırlıklar (W), net fonksiyonu (net), aktivasyon fonksiyonu (f) ve çıktılar (y) olmak üzere beş temel elemandan oluşmaktadır (Ham ve Kostanic, 2001; Tayfur, 2012; Okkan & Karakan, 2015). Bir yapay sinir ağı modelinde kullanılacak girdiler ve çıktılar yapılacak olan çalışmanın özelliğine göre değişkenlik gösterebilmektedir. Ağırlıklar, tasarlanacak olan bir modelin performansı için önemlidir çünkü girdilerin sistem içindeki etkinlikleri ağırlıklarla belirlenmektedir. Net fonksiyonu ise ağırlıklı girdilerin toplamı olarak bulunur ve bu fonksiyon ile girdilerin hücreler üzerindeki etkileri ifade edilir. Aktivasyon fonksiyonları (f) yardımıyla hücrelere gelen bu net girdiler de çıktılarına dönüştürülmektedir. Hiperbolik tanjant sigmoid, doğrusal, logaritmik sigmoid, gauss gibi fonksiyonlar bunlardan bazılarıdır (Okkan & Karakan, 2015).

3.2.2. Yapay sinir ağlarının eğitimi

Yapay sinir ağlarında işleyişi gereği girdilere karşılık beklenen çıktıları öğrenmesi amaçlanmaktadır. Doğru kabul edilebilecek sonuçlara ulaşılabilmesi için de ağın mantıklı bir şekilde kurulması ve bu aşamada da kullanılacak olan algoritma son derece önemlidir. Yapay sinir ağlarında kullanılması amaçlı geliştirilen birçok algoritma olmasına karşın YSA ile ilgili çalışmalarda yoğunlukla kullanılan algoritmalar ileri beslemeli geriye yayımlı algoritmalarlardır. Algoritma iki aşamada gerçekleştiği için bu ismi almıştır. Bu aşamalar ileriye doğru hesaplama ve geriye doğru hesaplama (Skapura, 1996; Ham ve Kostanic, 2001; Tayfur, 2012; Okkan & Karakan, 2015).

Girdi katmanındaki verilerin ağa aktarılması ile ileri doğru hesaplama aşaması başlamaktadır. Gizli katmandaki hücrelere gelen net girdiler, gizli katmandaki her hücrenin girdi katmanından gelen girdileri ağırlıklar ile almasıyla hesaplanmaktadır. Gizli katman elemanlarının çıktıları, bu net girdi değerlerinin kullanılmaya karar verilen bir aktivasyon fonksiyonunda işlenmesiyle hesaplanabilmektedir. Bu işlem tüm gizli katman ve çıktı katmanı arasında da yinelenmektedir; çıktı katmanının çıktıları ($y \in \mathbb{R}^{m \times 1}$) belirlendiğinde ileri hesaplama aşaması son bulmaktadır (Denklem 3.1.).

$$y_m = f^{(2)}\{\sum_{j=1}^m [f^{(1)}(\sum_{i=1}^n x_i W_{ij} + b_j)] W_{jm} + b_m\} \quad (3.1)$$

Yapay sinir ağının çıktı sonuçları ile istenilen çıktı değerleri kıyaslanmaktadır. Beklenen sonuçlar (bp) ile çıktı sonuçları (yp) arasındaki fark hata (ep) olarak adlandırılmaktadır. Geriye yayılım kısmında ise bu hata değeri azaltılmaya çalışılmaktadır. Bu şekilde başlangıçta rastgele atanmış olan ağın ağırlıkları, hata değeri istenen sınırlara düşürülünceye kadar iteratif olarak değiştirilmektedir. Hata değerinin istenilen sınırlara dönüştürülmesi için yapay sinir ağı modellerinde belli bir Q eğitim seti için en küçük hata kareler yaklaşımına dayalı performans fonksiyonu ile sağlanabilmektedir (Denklem 3.2).

$$E(W) = \frac{1}{2} \sum_{p=1}^P (e_p)^2, (P = mQ) \quad (3.2)$$

İleri beslemeli geri yayımlı YSA algoritmaları, $E(W)$ değerini en küçükleyecek şekilde geliştirilmiştir. Momentum terimli geriye yayılım algoritması, klasik geriye yayılım

algoritması geliştirilen algoritmalarından sadece birkaç tanesidir. Bahsedilen algoritmaların dışında daha sayısal ve hassas optimizasyon tabanlı Levenberg-Marquardt ve Newton algoritmaları da kullanılmaktadır (Ham ve Kostanic, 2001; Okkan & Karakan, 2015).

Tez çalışmasında anlatılan algoritmaların arasından ileri beslemeli geri yayımlı eğitme algoritmasının daha ileri bir versiyonu olan kullanılmıştır. Modelleme çalışmaları yapan birçok kişi tarafından ve hidrolojide yoğunlukla kullanılmakta olan Levenberg-Marquardt algoritmasının performansı diğer algoritmalarla göre daha başarılı bulunmaktadır (Okkan, 2011; Okkan & Karakan, 2015).

YSA çalışmalarında, yapay sinir ağlarının genelleyebilme performansını irdeleyebilmek için girdi ve çıktı verilerinin tümü ağı eğitirken kullanılmamalıdır. Bu nedenle veriler iki bölüme ayrılmalıdır. Ayrılan verilerin belirlenen bir kısmı ağı eğitmek için, geriye kalan kısmı da ağı test performansını ölçülmesi için kullanılır. Üzerinde çalışılan yapay sinir ağının genelleme özelliğini yitirmemesi diğer bir deyişle ağı test aşamasındaki yeteneğinin olumsuz bir şekilde etkilenmemesi için ağı eğitme aşamasında uygun sayıda iterasyon yaptırılmalıdır. Bahsedilen uygun iterasyon sayısını belirleyebilmek için her iterasyon sonucuna bakılarak ağı performans verimine göre iterasyon sayısı değiştirilmelidir (Okkan & Karakan, 2015).

3.2.3. Levenberg-Marquardt algoritması

Newton algoritmasının bir versiyonu olarak geliştirilmiş (Marquardt, 1963; Okkan & Karakan, 2015) olan Levenberg-Marquardt algoritması yapay sinir ağları ile entegre edilerek ileri beslemeli geriye yayılım algoritmaları arasında kullanılmaya başlanmıştır (Hagan ve Menhaj, 1994; Okkan & Karakan, 2015).

Newton algoritmasında, performans fonksiyonunu minimize eden optimum ağırlıkları Denklem 3.3 yardımıyla bulunabilmektedir.

$$W_{k+1} = W_k - H_k^{-1} g_k \quad (3.3)$$

Denklem 3.3'deki simgelerin açıklaması:

Hk: Hessian adı verilen ve performans fonksiyonunun ağırlıklara göre ikinci derece türevlerinden oluşan bir matris

$$g = \frac{1}{2} \begin{bmatrix} \frac{\partial \sum_{p=1}^P e_p^2}{\partial W_1} \\ \frac{\partial \sum_{p=1}^P e_p^2}{\partial W_2} \\ \vdots \\ \frac{\partial \sum_{p=1}^P e_p^2}{\partial W_N} \end{bmatrix} = \begin{bmatrix} \sum_{p=1}^P e_p \frac{\partial e_p}{\partial W_1} \\ \sum_{p=1}^P e_p \frac{\partial e_p}{\partial W_2} \\ \vdots \\ \sum_{p=1}^P e_p \frac{\partial e_p}{\partial W_N} \end{bmatrix} = J^T e \quad (3.4)$$

Gk: Ağın gradyeni olup performans fonksiyonunun ağırlıklara göre birinci derece türevlerinden oluşan bir matrisi

Ağın gradyeni $g = \partial E(W) / \partial W$ Denklem 3.4'teki formuyla ifade edilebilmektedir.

Burada $P \times N \times J \in$ Jakobien matris olarak adlandırılmakta ve ağ hatalarının ağırlıklara göre birinci derece türevlerinden oluşmaktadır (Denklem 3.5).

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial W_1} & \frac{\partial e_1}{\partial W_2} & \dots & \frac{\partial e_1}{\partial W_N} \\ \frac{\partial e_2}{\partial W_1} & \frac{\partial e_2}{\partial W_2} & \dots & \frac{\partial e_2}{\partial W_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_P}{\partial W_1} & \frac{\partial e_P}{\partial W_2} & \dots & \frac{\partial e_P}{\partial W_N} \end{bmatrix} \quad (3.5)$$

Jakobien ifadesi kullanılarak, Hessian matrisi Denklem 3.6.'daki formuyla tekrar düzenlenebilmektedir.

$$\nabla^2 E(W) = J^T J + S \quad (3.6)$$

$$S = \sum_{p=1}^P e_p \nabla^2 e_p \quad (3.7)$$

Performans fonksiyonu minimize edildiğinde, Denklem 3.7'deki S ifadesinin sayısal değeri giderek küçülmekte ve Hessian matrisin yaklaşık değeri Denklem 3.8 yardımıyla hesaplanabilmektedir.

$$H \cong J^T J \quad (3.8)$$

Denklem 3.8 ve Denklem 3.6 kullanılarak Denklem 3.3'te verilen Newton ifadesi düzenlenmekte ve belli bir k iterasyon adımında ağırlıkları Denklem 3.9 yardımıyla hesaplanabilmektedir.

$$W_{k+1} = W_k - [H_k]^{-1} J_k^T e_k, \quad (H_k = J_k^T J_k) \quad (3.9)$$

Ancak Denklem 3.9'da gösterilen iteratif çözüm, Hessian matrisinin tersine gerek duymakta olup çözüm sırasında problem meydana getirebilmektedir. Bahsedilen problem, Hessian matrisinin yaklaşık bir şeklini uygulayan Levenberg-Marquardt algoritması yardımı ile özömlenebilmektedir. Levenberg-Marquardt algoritması ile Hessian matrisi Denklem 3.10'daki gibi ifade edilebilmektedir.

$$H \cong J^T J + \lambda I \quad (3.10)$$

Burada λ Marquardt parametresini, I ise birim matrisi göstermektedir.

Denklem 3.10, Denklem 3.9'da yerine yazıldığında belli bir k iterasyon adımında ağırlıkları Denklem 3.11 ile güncellenmektedir.

$$W_{k+1} = W_k - [J_k^T J_k + \lambda_k I]^{-1} J_k^T e_k \quad (3.11)$$

Yöntemde Marquardt parametresi λ ise belli bir k iterasyon adımımda, $E(W)$ azaldığında belirli bir bozulma oranı (β ; $0 < \beta < 1$) ile çarpılmakta, $E(W)$ yeni bir adımda arttığında ise β değerine bölünmektedir. Böylece ağın performansı her adımda iyileştirilmektedir (Coulibaly ve ark., 2000; Ham ve Kostanic, 2001; Fistikoglu ve Okkan, 2011; Okkan & Karakan, 2015).

3.3. Yapay Sinir Ağlarına Dayanan Ölçek İndirgeme Stratejisi

Standart bir altlık sağlaması açısından iklim normallerinin kullanılması önemlidir. Tez çalışmasında 1960-1990 ve 1971-2000 referans dönemlerini temel alan bu dönemlerin içerisinde kalan ortak 1970-1999 dönemi verileri dikkate alınmıştır. Detayları yukarıda özetlenmiş olan Levenberg-Marquardt algoritması tabanlı yapay sinir ağları, Ocak 1970-Aralık 1999 referans dönemini içeren Susurluk havzasını temsil eden bölgesel atmosferik NCEP/NCAR re-analiz verileri ve istasyon ölççeklerinde gözlemlenen aylık yağış verileri arasında ayrı ayrı kurulmuştur. Üzerinde çalışılan yapay sinir ağı modellerinde bütün veriler belirli oranlarda eğitim (%70) ve test (%30) olmak üzere iki aşamada değerlendirilmiştir. Buradan yola çıkılarak 1970-1990 dönemi eğitim, 1991-1999 dönemi ise test dönemi olarak çalışılmıştır. Her iki dönemin de başlangıç ve bitiş ayları sırasıyla Ocak ve Aralıktır. Ağın çıktısı olan aylık yağış ve NCEP/NCAR re-analiz verileri ağı iletilmeden önce $(x - x_{ort})/S$ bağıntısıyla standart sapması (S) 1, ortalaması (x_{ort}) 0 olan normalize diziler haline dönüştürülmüştür. Diğer yandan ECHAM5 iklim modelinin A1B senaryosuna ilişkin atmosferik değişkenleri, 20C3M (1970-1999) dönemi değişkenlerinin standart sapma ve ortalama istatistikleri kullanılarak standardize edilmiştir.

Bu şekilde standardize edilmiş NCEP/NCAR verileri ile kurulan YSA modellerinin 20C3M dönemi istatistikleri baz alınarak standardize edilmiş senaryo sonuçlarını havza ölçeğine indirgeyebilmesi sağlanmıştır. Simülasyonlar sonlandıktan sonra havzaya indirgenmiş bu standardize değerler, 1970-1999 gözlenmiş dönem istatistikleri kullanılarak ters işlem ile orijinal ölçeğine dönüştürülmüştür.

3.3.1. Emisyon senaryoları, ECHAM5 iklim modeli ve NCEP/NCAR Re-analiz verileri

Yapılan araştırmada emisyon senaryoları olarak, 21. Yüzyıla ait olan IPCC (Intergovernmental Panel on Climate Change) tarafından hazırlanmış olan dört değerlendirme raporunun sonuncusu olan 4 adet senaryodan oluşan (A1, A2, B1, B2) grup esas alınmıştır. Bu senaryo grupları oluşturulurken farklı kabuller yapılmıştır (IPCC, 2007).

Konunun daha iyi anlaşılabilmesi için bahsedilen senaryoları açıklamak gerekmektedir. Bunlardan A1 senaryo grubu, yeni teknolojilerin dünyaya daha hızlı giriş yaptığı ve yüzyılın ortalarında en yüksek noktasına ulaştığını ancak daha sonra küresel nüfusun azaldığını ve gelecekte çok hızlı bir ekonomik büyümenin yaşanacağını öngörmüştür. Bunun yanı sıra A1 senaryo grubu kendi içerisinde A1FI, A1T ve A1B olmak üzere üçe ayrılmıştır. A1FI senaryosu fosil yoğunluğu bakımından teknolojiyi ön plana alır, A1T senaryosu fosil olmayan enerji kaynaklarını ön plana alır, A1B senaryosu ise bütün kaynaklar arasında dengeyi öngörmektedir. A2 senaryo grubuna gelindiğinde hemen hemen her anlamda heterojen bir dünya tasvir etmektedir. Bu senaryo grubunda yaşanan iklim değişikliği ile ilgili ileride alınması gereken önlemlere yer verilmemiştir ve teknolojik gelişmeler ve ekonomik büyüme diğer senaryo gruplarına göre daha yavaş ilerlediği varsayılmıştır. Aynı zamanda bölgesel düşünülmüş bir senaryodur. B1 senaryosu ise A2 senaryosundaki bölgesel durumun aksine küreseldir. Nüfus değişimi ve ekonomi konularında A1 senaryosu ile benzerdir. B1 senaryosunda uygun şartları barındıran teknolojilerde gelişme sağlanabileceği öngörülmektedir. Bu nedenle sürdürülebilirlik ile ilgili konular bu senaryo kapsamında ele alınmıştır. B2 senaryosunda ise sosyal, ekonomik ve çevresel koşulların devamı için bölgesel çözümlere başvurulmaktadır.

Tablo 3.3. IPCC senaryolarının nüfus ve ekonomi öngörülleri (IPCC, 2007)

Senaryo	Nüfus (Milyar Kişi)		Dünya Yıllık GSH (Trilyon ABD Doları)	
	2050	20100	2050	20100
A1	8,7	7,1	164	525

A2	11,3	15,0	82	243
B1	8,7	7,0	136	328
B2	9,3	10,4	110	235


Tablo 3.4. İklim senaryolarının CO₂ salım tahminleri (IPCC, 2007)

Senaryo	Fosil Kaynaklı CO ₂			Arazi Kaynaklı CO ₂				
				(Milyar ton/yıl)				
		1990	2050	2100	1990	2050	2100	1990-2100
A1	A1FI	6	23,1	30,3	1,1	0,8	-2,1	2189
	A1B	6	16,0	13,1	1,1	0,4	0,4	1499
	A1T	6	12,3	4,3	1,1	0,0	0,0	1068
A2		6	16,5	28,9	1,1	0,9	0,2	1862
B1		6	11,7	5,2	1,1	-0,4	-1,0	983
B2		6	11,2	13,8	1,1	-0,2	-0,5	1164

Sera gazları salınımlarına etki eden şimdiye kadar anlatılmış olan iklim modellerinin kendine ait senaryolarından hareketle ekonomik ve nüfus alanlarındaki öngörülerle birlikte gelecekteki deniz seviyelerindeki ve küresel sıcaklıktaki değişimler belirlenmiştir.

Tablo 3.5. Global sıcaklık ve deniz seviyelerindeki artış tahminleri (IPCC,2007)

Senaryolar	1980-1999 Dönemine Göre Değişen Global Sıcaklık (°C)		1980-1999 Dönemine Göre değişen Ortalama Deniz Seviyesi (m)
	Ortalama Tahmin	Olası Aralık	Olası Aralık
A1T	2,4	1,4-3,8	
A1 A1B	2,8	1,7-4,4	
A1F1	4,0	2,4-6,4	
B1	1,8	1,1-2,9	0,18-0,38
A2	3,4	2,0-5,4	0,23-0,51
B2	2,4	1,4-3,8	0,20-0,43



Şekil 3.5. Senaryolar kapsamında küresel yüzey ısınması değişim tahminleri ve değerlendirilen bölümler

Söz konusu çalışmada orta kötümser A1B gelecek dönem senaryosu ve geçmiş dönemdeki iklimi temsil eden 20C3M senaryosu baz alınmıştır. Bu iki senaryoya ait sonuçlar WDCC (World Data Center for Climate) aracılığı ile elde edilmiştir. Çalışma kapsamında iklim modeli olarak ECHAM5 (Max Planck Meteoroloji Enstitüsü) küresel iklim modeli baz alınmıştır. ArcGIS9.3 programı ile WDCC'den alınmış olan bu iklim modelinin NetCDF (Network Common Data Form) formatındaki sonuçları düzenlenmiştir. Tablo 3.4.'te bu iklim modelinin uygulama bölgesine en yakın gridin koordinatları ve çözünürlük bilgileri gösterilmiştir.

Tablo 3.6. Uygulama bölgesini temsil eden ECHAM5 iklim modelinin grid koordinatları

Küresel İklim Modeli	Çözünürlük (Enlem×Boylam)	Kuzey Enlemi (°)	Doğu Boylamı (°)
ECHAM5	1,87×1,88	40,1	28,1

Aynı iklim modeli hücresinde kalmış olsalar dahi yerel iklimi temsil eden meteoroloji istasyonları farklı özellikler taşıyabilmektedir. Bu sebeple, kaba çözünürlüklü tahminleri içeren iklim modeli sonuçlarının yerel ölçekteki değerlere dönüştürülmesi amacıyla bölgesel atmosferik değişkenler ile yağış gibi bazı değişkenler arasında istatistiksel dönüşüm ilişkisi kurulması önerilmektedir (Anandhi, Srinivas, Nanjundiah, & Kumar, 2008; Fıstıkoğlu & Okkan, 2011; Okkan & Fıstıkoğlu, 2012; Okkan & Fıstıkoğlu, 2014; Okkan U. , 2013; Okkan U. , 2014; Okkan & Karakan, 2015). Bu yöntem istatistiksel ölçek indirgeme yöntemi olarak bilinir ve bu yöntemin uygulanabilmesi için küresel kara

gözlem ağı ve meteoroloji uydularından elde edilen, $2.5^{\circ} \times 2.5^{\circ}$ grid çözünürlüğüne sahip olan NCEP/NCAR re-analiz verilerinden faydalınabilmektedir (Kalnay, et al., 1996; Okkan & Karakan, 2015).

NCEP/NCAR re-analiz verilerine NOAA (National Oceanic and Atmospheric Administration)'nın web sitesinden ulaşılmıştır. Havzadaki yağış çıktılarına dönüştürmede kullanılacak olan ölçek indirgeme modellerinin kurulabilmesi için, NCEP/NCAR re-analiz verilerinde kullanılan atmosferik değişkenlerin çalışma kapsamında ele alınan ECHAM5 iklim modelinde de yer alması gerekmektedir. Bu nedenle ECHAM5 iklim modeli senaryolarında (20C3M ve A1B) ve NCEP/NCAR re-analiz veri setlerindeki değişkenler ayrı ayrı kontrol edilerek 12 ortak değişken tespit edilmiştir.

Tablo 3.7. NCEP/NCAR re-analiz veri setinde ve iklim modellerinde ortak bulunan değişkenler

Atmosferik Seviyeler	Değişkenler
200 hPA	air200 (°C)
	hgt200 (m)
500 hPA	air500 (°C)
	hgt500 (m)
	rhum500 (%)
850 hPA	air850 (°C)
	hgt850 (m)
	rhum850 (%)
Yüzey	air (°C)
	press (hPa)
	slp (hPa)
	pr (kg/m ²)

3.3.2. Ölçek indirgeme yöntemi


İklim değişikliğinin bölgesel ölçekteki etkilerinin saptanabilmesi için iklim modellerinin tahminlerini bölgesel ölçeğe indirgeyen yöntemler ortaya konmuştur. İki çeşit ölçek

indirgeme yöntemi vardır. Bunlar: dinamik ölçek indirgeme ve istatistiksel ölçek indirgeme yöntemidir (Wilby ve ark. 2002, Okkan ve Karakan, 2015).

Dinamik ölçek indirgeme yöntemi, yerel ölçekte faaliyet gösteren fiziksel iklim modelleriyle (Regional Climate Model) ilgili çalışmaları kapsamaktadır. Bu modeller, topoğrafya özelliklerinin gösterildiği, yüksek çözünürlüklerle çalışabilen, başlangıç ve sınır şartlarını küresel ölçekli model çıktılarından alan modellerdir (Crane ve Hewitson, 1998; Mearns ve ark., 1999; Okkan ve Karakan, 2015). Böylece olağan dışı süreçler (Fowler ve ark., 2005; Okkan ve Karakan, 2015), orografik yağışlar (Frei ve ark., 2003; Okkan ve Karakan, 2015) ve bölgesel ölçekteki iklimsel anormaller bölgesel iklim modelleri aracılığıyla incelenebilmektedir. Fakat bu modellerde sınır ve başlangıç koşulları olarak küresel ölçekli modellerin çıktıları temel alınması sebebiyle tahminler yanlış olmakta ve belirsizlikler küresel ölçekli modellerden gelen belirsizliklerle daha muğlak bir hale gelmektedir (Okkan ve Fistikoglu, 2012). Bu türden modellerin performanslarının test edilebilmesi, uygulanabilmesi ve kurulumu için uzun ve yorucu çalışmalar gerekirken olup modellerin kısa süreli zaman zarfında bir başka bölgeye uyarlanması kolay değildir. Bu nedenlerden dolayı yerel yüzölçümü değişkenleri ile büyük atmosferik değişkenler arasında istatistiksel bağlantılar geliştirilmesi yaklaşımını temel alan istatistiksel ölçek indirgeme yöntemleri de genellikle kullanılmaktadır.

Üç adet istatistiksel ölçek indirgeme metodu bulunmaktadır. Bunlar: atmosferik üreticiler (weather generators) (Katz, 1996; Katz ve Parlange, 1998; Okkan ve Karakan, 2015), atmosferik sınıflandırma (weather classification) metotları (Wilby, 1994; Okkan ve Karakan, 2015), dönüşüm fonksiyonları (transfer functions). Bu üç metod arasında daha sık kullanılanları ise dönüşüm (transfer) fonksiyonlarıdır. Dönüşüm fonksiyonları, yerel ölçekte gözlenen değişkenler ile yerel iklimi temsil ettiği düşünülen atmosferik değişkenler arasında istatistiksel bağlantıların kurulması temeline dayanmaktadır (Okkan, 2013). Yapay sinir ağları algoritmaları (YSA), çok değişkenli doğrusal-doğrusal olmayan regresyon tipleri, asal bileşen (principal component) analizi, destek vektör makineleri (DVM), gereksizlik (redundancy) indeksi, kanonik korelasyon analizleri (canonical correlation) gibi birçok ölçek indirgeme yöntemi bu kapsamda gerçekleştirilmektedir (von Storch ve ark., 1993; Crane ve Hewitson, 1998; Burger, 1996; Wilby ve ark., 2003;

Anandhi ve ark., 2008; Okkan, 2013; Karamouz ve ark., 2009; Fistikoglu ve Okkan, 2011; Okkan, 2014; Okkan ve İnan, 2014; Okkan ve Karakan, 2015).



Şekil 3.6. Global-yerel çözünürlüklü modeller ve ölçek indirgeme yaklaşımının şematik bir gösterimi

Tez çalışması kapsamında geliştirilen ölçek indirgeme yöntemi bir yapay sinir ağı algoritmasını temel almaktadır. Son dönemlerde birden fazla alanda kullanılan YSA, istatistiksel ölçek indirgeme teknikleri arasında sıklıkla kullanılmakta ve girdilere karşı çıktılar üreten akıllı bir kara kutu modeli olarak tanımlanmaktadır (Murphy, 1999; Tatlı ve ark., 2006; Karamouz ve ark., 2009; Fistikoglu ve Okkan, 2011; Okkan ve Fistikoglu, 2012; Okkan, 2014; Okkan ve Karakan, 2015).

3.4. Ölçek İndirgeme Modeli Uygulaması

3.4.1. NCEP/NCAR tahminleyicilerinin seçimi

Susurluk havzasını ve çevresini temsil eden çalışma alanı olarak seçilmiş on adet istasyonun aylık toplam yağış dizilerinin yerel ölçekteki tahminlerini elde etmek için istatistiksel ölçek indirgeme modellerine sunulacak olan veriler, ECHAM5 iklim modelinde ortak bulunan ve 1970-1999 dönemini kapsayan 12 adet NCEP/NCAR tahminleyicisinden meydana gelmektedir. Çalışmada hem 20C3M geçmiş senaryosu indirgenmiş yağış 1970-1999 referans dönemini yansıtabilmesi iklim projeksiyonlarındaki belirsizlikler hem de uygulama bölgesini temsil etmesi beklenebilmesi açısından optimum NCEP/NCAR değişkeninin kullanılması uygun görülmüştür (Okkan & Karakan, 2015).

Tablo 3.8. DMİ 17150 yağış verileri ile NCEP/NCAR re-analiz verileri arasında elde edilen korelasyon katsayıları(R)

	air850	hgt850	rhum850	air500	hgt500	rhum500	air200	hgt200	air	press	slp	pr	gozlenen
air850	1.0000	0.5915	-0.7927	0.9740	0.9579	-0.8010	0.6572	0.9670	0.9930	-0.5115	-0.6142	-0.4692	-0.5795
hgt850	0.5915	1.0000	-0.6792	0.6381	0.7783	-0.6448	0.1966	0.6716	0.5541	0.3860	0.2685	-0.6763	-0.5697
rhum850	-0.7927	-0.6792	1.0000	-0.7726	-0.8214	0.7898	-0.4624	-0.7890	-0.7595	0.1646	0.2635	0.6262	0.6562
air500	0.9740	0.6381	-0.7726	1.0000	0.9761	-0.8457	0.6596	0.9902	0.9603	-0.4277	-0.5347	-0.5375	-0.5757
hgt500	0.9579	0.7783	-0.8214	0.9761	1.0000	-0.8470	0.5794	0.9785	0.9374	-0.2632	-0.3810	-0.6026	-0.6220
rhum500	-0.8010	-0.6448	0.7898	-0.8457	-0.8470	1.0000	-0.7053	-0.8757	-0.7873	0.2099	0.3075	0.6634	0.6369
air200	0.6572	0.1966	-0.4624	0.6596	0.5794	-0.7053	1.0000	0.7165	0.6856	-0.5329	-0.5828	-0.3468	-0.4328
hgt200	0.9670	0.6716	-0.7890	0.9902	0.9785	-0.8757	0.7165	1.0000	0.9556	-0.3840	-0.4930	-0.5775	-0.5997
air	0.9930	0.5541	-0.7595	0.9603	0.9374	-0.7873	0.6856	0.9556	1.0000	-0.5505	-0.6493	-0.4453	-0.5660
press	-0.5115	0.3860	0.1646	-0.4277	-0.2632	0.2099	-0.5329	-0.3840	-0.5505	1.0000	0.9922	-0.2022	0.0435
slp	-0.6142	0.2685	0.2635	-0.5347	-0.3810	0.3075	-0.5828	-0.4930	-0.6493	0.9922	1.0000	-0.1183	0.1213
pr	-0.4692	-0.6763	0.6262	-0.5375	-0.6026	0.6634	-0.3468	-0.5775	-0.4453	-0.2022	-0.1183	1.0000	0.6725
gozlenen	0.5795	0.5697	0.6562	0.5757	0.6220	0.6369	0.4328	0.5997	0.5660	0.0435	0.1213	0.6725	1.0000

Başlangıç olarak tüm değişkenler kullanılarak korelasyon matrisi elde edilmiştir (Tablo 3.6). Bu işlemin ardından hesaplanan korelasyon katsayıları gözlemlenerek bağımlı değişkene düşük korelasyon veren bağımsız değişkenlerin elenmiştir.

Buna göre, slp, press ve air200 değişkenleri yağışa düşük korelasyon verdiği için potansiyel tahminleyici listesinden elenmiştir. Arda kalan 9 değişken arasından en uygun olanları ise adimsal regresyon analizi ile saptanmıştır (Tablo 3.7). Bu işlem istatistiksel ölçek indirgeme modelinin eğitim dönemi olan 1970-1990 dönemi verileri ile gerçekleştirilmiştir. Kısmi F testine bağlı olarak geriye eleme yaklaşımı ile hgt200, air ve

air500 değişkenlerinin modelden atılması gerektiği görülmüştür. Tablo 3.7. incelendiğinde 6 girdili doğrusal model (Model 4) ile 9 girdili doğrusal model (Model 1) arasında R^2 ve standart hata istatistikleri bakımından büyük bir farkın olmadığı anlaşılmaktadır. Sonuç olarak, NCEP/NCAR veri setinde yer alan 850 mb seviyesindeki rölatif nem (rhum850), yağış (pr), 850 mb seviyesindeki geopotansiyel yükseklik (hgt850), 850 mb seviyesindeki sıcaklık (air850), 500 mb seviyesindeki rölatif nem (rhum500) ve 500 mb seviyesindeki geopotansiyel yükseklik (hgt500) değişkenlerinin aylık toplam yağış tahminleyicileri olarak kullanılması uygun görülmüştür.

Tablo 3.9. Aylık toplam yağış tahminleyicilerini belirlemek için gerçekleştirilen adımsal regresyon analizi sonuçları (Okkan & Karakan, 2015)

Model No.	Tahminleyici	R^2	Adj. R^2	Standart Hata (mm)
1	pr,air,hgt850,rhum850,rhum500, air500,hgt200,air850,hgt500	0,5904	0,5799	30,71
2	pr,hgt850,rhum850,rhum500, hgt200,air850,hgt500	0,5899	0,5806	30,69
3	Pr,hgt850,rhum850,rhum500, Hgt200,air850,hgt500	0,5896	0,5814	30,65
4	Pr,hgt850,rhum850,rhum500, air850,hgt500	0,5879	0,5809	30,67

Anandhi ve ark. (2008) bağımlı ve bağımsız değişkenlerin korelasyon ilişkilerinin araştırılmasının yanı sıra re-analiz verileri arasındaki uyum ile iklim modellerinin geçmiş dönemi temsil eden simülasyon sonuçları (20C3M senaryosu sonuçları) ile de uyumunun kontrol edilmesinin model çalışmalarındaki performans için önemli bulmuşlardır. Kendi çalışmalarında bu işlem için Kendall Tau sıra korelasyon istatistiğinden faydalanmışlardır. Tez çalışması kapsamında da ECHAM5 iklim modelinin NCEP/NCAR tahminleyicileri ile 1970-1999 dönemine ait 20C3M senaryosu tahminleyicileri arasındaki uyum Kendall Tau istatistiği ile ölçülmüştür. Eğer 0.30 değeri düşük bir korelasyon olarak kabul edilirse bütün elde edilen sıra korelasyonlarının 0.30 değerinden büyük olduğu saptanmıştır. Bu durumdan yola çıkılarak, bağımlı değişkenleri temsil eden NCEP/NCAR veri setindeki pr, air850, hgt850, rhum850, rhum500, hgt500

ve air deęişkenlerinin aynı zamanda ECHAM5 modeli 20C3M senaryo sonuçları ile uyumlu ve ölçek indirgeme modellerinin kurulmasında yeterli olduęu belirlenmiştir.

Bu bölümdeki veriler "İklim Deęişikliğinin Balıkesir İli İçmesuyu Potansiyeline Etkilerinin Modellenmesi: İçmesuyu Talebinin 2015-2030 Projeksiyonu" adlı çalışmadan elde edilmiş olup tez çalışmasına uyarlanmıştır.

3.4.2. Ölçek indirgeme modellerinin kurulması

Seçilen tahminleyiciler yağış verileriyle birlikte yapay sinir ağıları tabanlı istatistiksel ölçek indirgeme modellerinin girdileri olarak kullanılmıştır. 1970-1990 dönemini içeren 21 yıllık veri eğitim aşamasında, 1991-1999 dönemini içeren 9 yıllık veri ise test aşamasında kullanılmıştır. Bu aşamada Levenberg-Marquardt optimizasyon algoritmasına dayanan ileri beslemeli geriye yayımlı bir YSA modeli MATLAB ortamında hazırlanmıştır.

Çeşitli denemeler sonucunda modellerde kullanılacak olan aktivasyon fonksiyonu için ilk katmanda ($f(1)$) sigmoid fonksiyonu, son katmanda ($f(2)$) ise doğrusal fonksiyon en iyi performansı göstermiştir. Tüm girdi ve çıktı verileri $(x-x_{ort})/S$ bağıntısıyla ortalaması sıfır, standart sapması bir değerine eşit olan $(x_{ort}=0; S=1)$ olan standardize edilmiş dizi şekline getirilerek kullanılmıştır. Öğrenme işleminin sonuna gelindiğinde standardize veriler ters işlem ile gerçek ölçeğindeki değerlere dönüştürülmüş daha sonra eğitim ve test dönemi model performansları irdelenmiştir. Modellerdeki $k=0$ durumu için bozulma oranı (β) parametresi ve başlangıç Marquardt parametresi (λ_0) sırasıyla 0,1 ve 0,01 olarak belirlenmiştir.

Modellere ait zaman serisi grafikleri ve saçılım diyagramları elde edilen sonuçlar olarak gösterilmiştir. Modellerin performansları, hata kareler ortalaması (HKO), hata kareler ortalamasının karekökü (HKOK), determinasyon katsayısı (R^2), düzeltilmiş determinasyon katsayısı (Adj. R^2) gibi performans ölçütleri baz alınarak değerlendirilmiş ve bu performans ölçütleri her istasyon için tablolaştırılarak sunulmuştur. Daha sonra yapılan çalışmalardan elde edilen bulgular baz alınarak yağış miktarındaki beklenen


mevsimsel deęişmeler incelenmiştir ve ulaşılan deęerler tablolaştırılarak sunulmuştur. Sonuç olarak istatistiksel performans ölçütlerine bakılarak, NCEP/NCAR deęişkenleri ile kurulan modellerin istasyonlara ait yağışları iyi derecede temsil edebildięi saptanmıştır. Buradan istinaden yapay sinir aęlarına dayalı ölçek indirgeme modellerinin senaryo temelli iklim projeksiyonlarının oluşturulmasında yeter doğrulukta kullanılabileceęi kanısına varılmıştır.




BÖLÜM 4. ARAŞTIRMA BULGULARI

4.1. Balıkesir İstasyonu

Elde edilen yapay sinir ağı modeli 17152 numaralı Balıkesir istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağı öğrenmesine ilişkin grafik Şekil 4.1.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:611.870 (mm²) ve determinasyon katsayısı olan R²: 0.669 olarak bulunmuş, eğitim aşamasına ait saçılım diyagramı Şekil 4.2.'de gösterilmiştir.




Şekil 4.1. Balıkesir istasyonu eğitim sonucu grafiği




Şekil 4.2. Balıkesir istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağıları modelinde 17152 numaralı Balıkesir istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.3.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 557.577 (mm²) ve determinasyon katsayısı olan R²: 0.678 olarak bulunmuş, Balıkesir istasyonu test aşamasına ait saçılım diyagramı Şekil 4.4.'de gösterilmiştir.



Şekil 4.3. Balıkesir istasyonu test sonucu grafiği



Şekil 4.4. Balıkesir istasyonu test dönemi saçılım grafiği

17152 numaralı Balıkesir istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.1.'de gösterilmiştir.

Tablo 4.1. 17152 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	51,963
Gözlenen	45,600
Oran	0,878

17152 numaralı Balıkesir istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.2.'de gösterilmiştir.

Tablo 4.2. 17152 numaralı istasyona ait düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	45,600
SRES-A1B düzeltilmiş	42,219
Değişim oranı (%)	-7,41

17152 numaralı Balıkesir istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.5.'te gösterilmiştir.



Şekil 4.5. Balıkesir istasyonu düzeltilmiş 20C3M değerleri grafiği

17152 numaralı Balıkesir istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.6.'da gösterilmiştir.



Şekil 4.6. Balıkesir istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17152 numaralı Balıkesir istasyonuna ait mevsimsel analizler Tablo 4.3.'de gösterilmiştir.

Tablo 4.3. 17152 numaralı istasyona ait mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	259,7623	104,0778	45,42887	137,9311
A1B	225,3865	114,9661	41,91374	124,3606
Yüzdesel Fark	-13,2335	10,46173	-7,73767	-9,83859

4.2. Bandırma İstasyonu

Elde edilen yapay sinir ağları modelinde 17114 numaralı Bandırma istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.7. 'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:1523.579(mm²) ve determinasyon katsayısı olan R²: 0.502 olarak bulunmuş, Bandırma istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.8.'de gösterilmiştir.




Şekil 4.7. Bandırma istasyonu eğitim sonucu grafiği




Şekil 4.8. Bandırma istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17114 Bandırma istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.9.'da gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 1380.935(mm²) ve determinasyon katsayısı olan R²: 0.462 olarak bulunmuş, Bandırma istasyonu test aşamasına ait saçılım diyagramı Şekil 4.10.'da gösterilmiştir.



Şekil 4.9. Bandırma istasyonu test sonucu grafiği



Şekil 4.10. Bandırma istasyonu test dönemi saçılım grafiği

17114 numaralı Bandırma istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.4.'te gösterilmiştir.

Tablo 4.4. 17114 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	64,371
Gözlenen	59,178
Oran	0,919

17114 numaralı Bandırma istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.5.'te gösterilmiştir.

Tablo 4.5. 17114 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	59,178
SRES-A1B düzeltilmiş	53,386
Değişim oranı (%)	-9,79

17114 numaralı Bandırma istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.11.'de gösterilmiştir.



Şekil 4.11. Bandırma istasyonu düzeltilmiş 20C3M değerleri grafiği

17114 numaralı Bandırma istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.12.'de gösterilmiştir.



Şekil 4.12. Bandırma istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17114 numaralı Bandırma istasyonuna ait mevsimsel analizler Tablo 4.6. ile gösterilmiştir.

Tablo 4.6. 17114 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	344,1201	121,873	71,86835	172,2746
A1B	262,9313	131,7741	68,91248	140,1711
Yüzdesel Fark	-23,5932	8,12417	-4,1129	-18,6351

4.3. Bursa İstasyonu

Elde edilen yapay sinir ağları modelinde 17116 numaralı Bursa istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.13.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 762.926 (mm²) ve determinasyon katsayısı olan R²: 0.577 olarak bulunmuş, Bursa istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.14.'te gösterilmiştir.




Şekil 4.13. Bursa istasyonu eğitim sonucu grafiği




Şekil 4.14. Bursa istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağı modeli 17116 Bursa istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.15.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 874.782 (mm²) ve determinasyon katsayısı olan R²: 0.524 olarak bulunmuş, Bursa istasyonu test aşamasına ait saçılım diyagramı Şekil 4.16.'da gösterilmiştir.



Şekil 4.15. Bursa istasyonu test sonucu grafiği



Şekil 4.16. Bursa istasyonu test dönemi saçılım grafiği

17116 numaralı Bursa istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.7. ile gösterilmiştir.

Tablo 4.7. 17116 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	60,670
Gözlenen	56,345
Oran	0,929

17116 numaralı Bursa istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.8. ile gösterilmiştir.

Tablo 4.8. 17116 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	56,345
SRES-A1B düzeltilmiş	51,719
Değişim oranı (%)	-8,21

17116 numaralı Bursa istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.17.'de gösterilmiştir.



Şekil 4.17. Bursa istasyonu düzeltilmiş 20C3M değerleri grafiği

17116 numaralı Bursa istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.18.'de gösterilmiştir.



Şekil 4.18. Bursa istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17116 numaralı Bursa istasyonuna ait mevsimsel analizler Tablo 4.9.'da gösterilmiştir.

Tablo 4.9. 17116 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	285,7472	145,6501	73,04124	171,7048
A1B	251,5182	155,7885	58,52522	154,7999
Yüzdesel Fark	-11,9788	6,96081	-19,8737	-9,84533

4.4. Dursunbey İstasyonu

Elde edilen yapay sinir ağları modelinde 17700 numaralı Dursunbey istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.19.'da gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:615.979(mm²) ve determinasyon katsayısı olan R²: 0.571 olarak bulunmuş, Dursunbey istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.20.'de gösterilmiştir.




Şekil 4.19. Dursunbey istasyonu eğitim sonucu grafiği




Şekil 4.20. Dursunbey istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17700 numaralı Dursunbey istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.21.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 569.532(mm²) ve determinasyon katsayısı olan R²: 0.592 olarak bulunmuş, Dursunbey istasyonu test aşamasına ait saçılım diyagramı Şekil 4.22.'de gösterilmiştir.



Şekil 4.21. Dursunbey istasyonu test sonucu grafiği



Şekil 4.22. Dursunbey istasyonu eğitim dönemi saçılım grafiği

17700 numaralı Dursunbey istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.10. ile gösterilmiştir.

Tablo 4.10. 17700 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	47,163
Gözlenen	45,757
Oran	0,970

17700 numaralı Dursunbey istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.11. ile gösterilmiştir.

Tablo 4.11. 17700 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	45,757
SRES-A1B düzeltilmiş	42,200
Değişim oranı (%)	-7,78

17700 numaralı Dursunbey istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.23.'te gösterilmiştir.



Şekil 4.23. Dursunbey istasyonu düzeltilmiş 20C3M değerleri grafiği

17700 numaralı Dursunbey istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.24.'te gösterilmiştir.



Şekil 4.24. Dursunbey istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17700 numaralı Dursunbey istasyonuna ait mevsimsel analizler Tablo 4.12.'de gösterilmiştir.

Tablo 4.12. 1700 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	ilkbahar	Yaz	Sonbahar
20C3M	242,7133	116,626	60,76099	128,9864
A1B	207,8613	125,7443	60,17616	112,6126
Yüzdesel Fark	-14,3593	7,818459	-0,96251	-12,6942

4.5. Erdek İstasyonu

Elde edilen yapay sinir ağları modelinde 17635 numaralı Erdek istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.25.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:615.900(mm²) ve determinasyon katsayısı olan R²: 0.555olarak bulunmuş, Erdek istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.26.'da gösterilmiştir.




Şekil 4.25. Erdek istasyonu eğitim sonucu grafiği




Şekil 4.26. Erdek istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17635 numaralı Erdek istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.27.ile gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 1102.471(mm²) ve determinasyon katsayısı olan R²: 0.439 olarak bulunmuş, Erdek istasyonu test aşamasına ait saçılım diyagramı Şekil 4.28.'de gösterilmiştir.



Şekil 4.27. Erdek istasyonu test sonucu grafiği



Şekil 4.28. Erdek istasyonu test dönemi saçılım grafiği

17635 numaralı Erdek istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.13.'te gösterilmiştir.

Tablo 4.13. 17635 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	50,546
Gözlenen	43,741
Oran	0,865

17635 numaralı Erdek istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.14.'te gösterilmiştir.

Tablo 4.14. 17635 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


Ortalama (mm/ay)	
20C3M_düzeltilmiş	43,741
SRES-A1B düzeltilmiş	39,760
Değişim oranı (%)	-9,10

17635 numaralı Erdek istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.29.'da gösterilmiştir.



Şekil 4.29. Erdek istasyonu düzeltilmiş 20C3M değerleri grafiği

17635 numaralı Erdek istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.30.'da gösterilmiştir.



Şekil 4.30. Erdek istasyonu düzeltilmiş SRES-A1B değerleri grafiği


171635 numaralı Erdek istasyonuna ait mevsimsel analizler Tablo 4.15.'te gösterilmiştir.

Tablo 4.15. 17635 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	248,9668	87,08164	45,61375	143,2257
A1B	223,5197	87,95626	38,56556	127,0818
Yüzdesel Fark	-10,2211	1,00437	-15,4519	-11,2717

4.6. Keles İstasyonu

Elde edilen yapay sinir ağları modelinde 17695 numaralı Keles istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.31. ile gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:967.331 (mm²) ve determinasyon katsayısı olan R²: 0.645 olarak bulunmuş, Keles istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.32.'de gösterilmiştir.




Şekil 4.31. Keles istasyonu eğitim sonucu grafiği




Şekil 4.32. Keles istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17695 numaralı Keles istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.33.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 867.166 (mm²) ve determinasyon katsayısı olan R^2 : 0.607 olarak bulunmuş, Keles istasyonu test aşamasına ait saçılım diyagramı Şekil 4.34.'te gösterilmiştir.



Şekil 4.33. Keles istasyonu test sonucu grafiği



Şekil 4.34. Keles istasyonu test dönemi saçılım grafiği

17695 numaralı Keles istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.16.'da gösterilmiştir.

Tablo 4.16. 17695 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	64,221
Gözlenen	61,578
Oran	0,959

17695 numaralı Keles istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.17.'de gösterilmiştir.

Tablo 4.17.17695 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	61,578
SRES-A1B düzeltilmiş	55,651
Değişim oranı (%)	-9,63

17695 numaralı Keles istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.35.'te gösterilmiştir.



Şekil 4.35. Keles istasyonu düzeltilmiş 20C3M değerleri grafiği

17695 numaralı Keles istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.36.'da gösterilmiştir.



Şekil 4.36. Keles istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17695 numaralı Keles istasyonuna ait mevsimsel analizler Tablo 4.18. ile gösterilmiştir.

Tablo 4.18. 17695 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	338,6481	165,8934	74,15723	160,2346
A1B	284,1989	176,0262	72,97983	134,6045
Yüzdesel Fark	-16,0784	6,108004	-1,5877	-15,9954

4.7. Mustafa Kemal Paşa İstasyonu

Elde edilen yapay sinir ağları modelinde 699 numaralı Mustafa Kemal Paşa istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağıın öğrenmesine ilişkin grafik Şekil 4.37.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:1284.038 (mm²) ve determinasyon katsayısı olan R²: 0.487 olarak bulunmuş, Mustafa Kemal Paşa istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.38.'de ile gösterilmiştir.




Şekil 4.37. Mustafa Kemal Paşa istasyonu eğitim sonucu grafiği




Şekil 4.38. Mustafa Kemal Paşa istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağılar modelinde 699 numaralı Mustafa Kemal Paşa istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.39.'da gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 1065.766 (mm²) ve determinasyon katsayısı olan R²: 0.514 olarak bulunmuş, Mustafa Kemal Paşa istasyonu test aşamasına ait saçılım diyagramı Şekil 4.40.'da gösterilmiştir.



Şekil 4.39. Mustafa Kemal Paşa istasyonu test sonucu grafiği



Şekil 4.40. Mustafa Kemal Paşa istasyonu test dönemi saçılım grafiği

699 numaralı Mustafa Kemal Paşa istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.19.'da gösterilmiştir.

Tablo 4.19. 699 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	59,846
Gözlenen	58,654
Oran	0,980

699 numaralı Mustafa Kemal Paşa istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.20.'de gösterilmiştir.

Tablo 4.20. 699 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	58,654
SRES-A1B düzeltilmiş	54,399
Değişim oranı (%)	-7,26

699 numaralı Mustafa Kemal Paşa istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.41.'de gösterilmiştir.



Şekil 4.41. Mustafa Kemal Paşa istasyonu düzeltilmiş 20C3M değerleri grafiği

699 numaralı Mustafa Kemal Paşa istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.42. ile gösterilmiştir.



Şekil 4.42. Mustafa Kemal Paşa istasyonu düzeltilmiş SRES-A1B değerleri grafiği


699 numaralı Mustafa Kemal Paşa istasyonuna ait mevsimsel analizler Tablo 4.21.'de gösterilmiştir.

Tablo 4.21. 699 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	258,5474	138,4177	69,2914	182,8417
A1B	276,6792	148,6595	65,87548	161,5707
Yüzdesel Fark	7,012948	7,399193	-4,92979	-11,6335

4.8. Simav İstasyonu

Elde edilen yapay sinir ağları modelinde Simav istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.43.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:2126.830 (mm²) ve determinasyon katsayısı olan R²: 0.597 olarak bulunmuş, Simav istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.44.'de gösterilmiştir.




Şekil 4.43. Simav istasyonu eğitim sonucu grafiği




Şekil 4.44. Simav istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17748 numaralı Simav istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.45.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 1232.355 (mm²) ve determinasyon katsayısı olan R²: 0.651 olarak bulunmuş, Simav istasyonu test aşamasına ait saçılım diyagramı Şekil 4.46.'da gösterilmiştir.



Şekil 4.45. Simav istasyonu test dönemi saçılım grafiği



Şekil 4.46. Simav istasyonu test dönemi saçılım grafiği

17748 numaralı Simav istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.22. ile gösterilmiştir.

Tablo 4.22. 17748 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	74,304
Gözlenen	66,057
Oran	0,889

17748 numaralı Simav istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.23. ile gösterilmiştir.

Tablo 4.23. 17748 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	66,057
SRES-A1B düzeltilmiş	57,943
Değişim oranı (%)	-12,28

17748 numaralı Simav istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.47.'de gösterilmiştir.



Şekil 4.47. Simav istasyonu düzeltilmiş 20C3M değerleri grafiği

17748 numaralı Simav istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.48.'de gösterilmiştir.



Şekil 4.48. Simav istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17748 numaralı Simav istasyonuna ait mevsimsel analizler Tablo 4.24. ile gösterilmiştir.

Tablo 4.24. 17748 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	417,9141	139,9527	66,90739	167,9072
A1B	329,4909	161,1822	68,45764	136,1841
Yüzdesel Fark	-21,1582	15,16905	2,317011	-18,8932

4.9. Tavşanlı İstasyonu

Elde edilen yapay sinir ağı modeli 17704 numaralı Tavşanlı istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağı öğrenmesine ilişkin grafik Şekil 4.49.'da gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:455.263 (mm²) ve determinasyon katsayısı olan R²: 0.465 olarak bulunmuş, Tavşanlı istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.50.'de gösterilmiştir.




Şekil 4.49. Tavşanlı istasyonu eğitim sonucu grafiği




Şekil 4.50. Tavşanlı istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağırları modelinde 17704 numaralı Tavşanlı istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.51.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 388,441 (mm²) ve determinasyon katsayısı olan R²: 0.467 olarak bulunmuş, Tavşanlı istasyonu test aşamasına ait saçılım diyagramı Şekil 4.52.'de gösterilmiştir.



Şekil 4.51. Tavşanlı istasyonu test sonucu grafiği



Şekil 4.52. Tavşanlı istasyonu test dönemi saçılım grafiği

17704 numaralı Tavşanlı istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.25. ile gösterilmiştir.

Tablo 4.25. 17704 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	43,481
Gözlenen	39,138
Oran	0,900

17704 numaralı Tavşanlı istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.26.'da gösterilmiştir.

Tablo 4.26. 17704 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	39,138
SRES-A1B düzeltilmiş	37,676
Değişim oranı (%)	-3,73

17704 numaralı Tavşanlı istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.53.'de gösterilmiştir.



Şekil 4.53. Tavşanlı istasyonu düzeltilmiş 20C3M değerleri grafiği

17704 numaralı Tavşanlı istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.54.'te gösterilmiştir.



Şekil 4.54. Tavşanlı istasyonu düzeltilmiş SRES-A1B değerleri grafiği


17704 numaralı Tavşanlı istasyonuna ait mevsimsel analizler Tablo 4.27.'de gösterilmiştir.

Tablo 4.27. 17704 numaralı istasyon için mevsimsel sonuçlar tablosu


	Kış	İlkbahar	Yaz	Sonbahar
20C3M	188,1266	94,25961	68,27172	118,9932
A1B	172,8604	99,1086	68,46024	111,6811
Yüzdesel Fark	-8,11484	5,144295	0,276133	-6,145

4.10. Uludağ İstasyonu

Elde edilen yapay sinir ağları modelinde 17676 numaralı Uludağ istasyonuna ait 360 adet verinin %70'ine karşılık gelen 252 adet veri eğitim aşamasında kullanılmıştır ve ağın öğrenmesine ilişkin grafik Şekil 4.55.'te gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO:3957.186(mm²) ve determinasyon katsayısı olan R²: 0.577 olarak bulunmuş, Uludağ istasyonu eğitim aşamasına ait saçılım diyagramı Şekil 4.56.'da gösterilmiştir.




Şekil 4.55. Uludağ istasyonu eğitim sonucu grafiği




Şekil 4.56. Uludağ istasyonu eğitim dönemi saçılım grafiği

Elde edilen yapay sinir ağları modelinde 17676 numaralı Uludağ istasyonuna ait 360 adet verinin %30'una karşılık gelen 108 adet veri test aşamasında kullanılmıştır ve bu bölüme ilişkin grafik Şekil 4.57.'de gösterilmiştir. Analiz sonuçlarına göre hata kareler ortalaması olan HKO: 3625.766 (mm²) ve determinasyon katsayısı olan R²: 0.568 olarak bulunmuş, Uludağ istasyonu test aşamasına ait saçılım diyagramı Şekil 4.58.'de gösterilmiştir.



Şekil 4.57. Uludağ istasyonu test sonucu grafiği



Şekil 4.58. Uludağ istasyonu test dönemi saçılım grafiği

17676 numaralı Uludağ istasyonu senaryo sonuçlarının iyileştirilmesi için gerekli oran Tablo 4.28.'de gösterilmiştir.

Tablo 4.28. 17676 numaralı istasyon sonuçlarının iyileştirilmesi için gerekli oran


	Ortalama (mm/ay)
20C3M	123,612
Gözlenen	122,679
Oran	0,992

17676 numaralı Uludağ istasyonuna ait düzeltilmiş senaryo sonuçları ve değişim oranı Tablo 4.29.'de gösterilmiştir.

Tablo 4.29. 17676 numaralı istasyon için düzeltilmiş 20C3M ve A1B senaryosu sonuçları


	Ortalama (mm/ay)
20C3M_düzeltilmiş	122,679
SRES-A1B düzeltilmiş	114,130
Değişim oranı (%)	-6,97

17676 numaralı Uludağ istasyonuna ait düzeltilmiş 20C3M sonuçları grafiği Şekil 4.59. ile gösterilmiştir.



Şekil 4.59. Uludağ istasyonu düzeltilmiş 20C3M değerleri grafiği

17676 numaralı Uludağ istasyonuna ait düzeltilmiş SRES-A1B senaryo sonuçları grafiği Şekil 4.60.'ta gösterilmiştir.



Şekil 4.60. Uludağ istasyonu düzeltilmiş SRES-A1B değerleri grafiği

17676 numaralı Uludağ istasyonuna ait mevsimsel analizler Tablo 4.30.'da gösterilmiştir.

Tablo 4.30. 17676 numaralı istasyon için mevsimsel sonuçlar tablosu

	Kış	İlkbahar	Yaz	Sonbahar
20C3M	629,6835	329,1299	171,2375	342,0936
A1B	540,0818	354,0412	173,9262	301,5159
Yüzdesel Fark	-14,2296	7,568825	1,570157	-11,8616

BÖLÜM 5. TARTIŞMA VE SONUÇ

İnsanlık küresel ısınmanın neden olduğu iklim değişikliği sonucu birçok problemle karşı karşıyadır. Kullanılabilir su kaynaklarının hızla tükenmesi, olağandışı hava olayları, sel ve kuraklık gibi doğal felaketler insanlık için karşı karşıya kalınan sorunlardan en önemlileridir. Bu nedenle bu konularla ilgili hızla gelişen bilim ve teknolojiye de faydalanılarak önlemler alınması bugünkü yaşam koşullarının iyileşmesi ve gelecek nesiller için yaşanılabilir bir evren için büyük önem arz etmektedir.

İklim değişikliği, Türkiye gibi çoğunlukla yarı kurak ve kurak iklimin hâkim olduğu coğrafyalar için gelecekteki canlı yaşamını birçok farklı açıdan etkilemesi beklenen önemli bir kavramdır. Gelecekteki yağış miktarındaki değişimler, hayatın neredeyse her alanında etkisini gösterecek olması nedeniyle tüm canlı hayatını yakından etkiler. Bu nedenle gelecek yıllara ait yağış tahmin modellemeleri büyük önem arz etmektedir. Dolayısıyla Bu çalışma iklim değişikliğinin Türkiye'nin önemli havzalarından biri olan Susurluk Havzası'nda ne derece etkili olacağı kurulan modelleme ile araştırılmıştır.

Yapılan çalışma sonucunda; Balıkesir istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,66 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,878 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,878 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılmış, yapılan bu işlemle yağış miktarında %7,41 değerinde bir azalma beklendiği ortaya çıkmıştır. Balıkesir istasyonu verilerine göre kış yağışlarında %13,23, yaz yağışlarında %7,74, sonbahar yağışlarında %9,84 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %10,46 miktarında bir artış yaşanacağı öngörülmüştür. 17114 numaralı Bandırma istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda

determinasyon katsayısı olan R^2 : 0,48 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,919 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,919 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %9,79 değerinde bir azalma beklendiği ortaya çıkmıştır. Bandırma istasyonu verilerine göre kış yağışlarında %23,59, yaz yağışlarında %4,11, sonbahar yağışlarında %18,64 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %8,12 miktarında bir artış yaşanacağı öngörülmüştür.

17116 numaralı Bursa istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,56 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,929 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,929 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %8,21 değerinde bir azalma beklendiği ortaya çıkmıştır. Bursa istasyonu verilerine göre kış yağışlarında %11,98, yaz yağışlarında %19,87, sonbahar yağışlarında %9,85 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %6,96 miktarında bir artış yaşanacağı öngörülmüştür.

17700 numaralı Dursunbey istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,57 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,970 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,970 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %7,78 değerinde bir azalma beklendiği ortaya çıkmıştır. Dursunbey istasyonu verilerine göre kış yağışlarında %14,36, yaz yağışlarında %0,96, sonbahar yağışlarında %12,69 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %7,82 miktarında bir artış yaşanacağı öngörülmüştür.

17635 numaralı Erdek istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,51 olarak bulunmuştur.

Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,865 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,865 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %9,10 değerinde bir azalma beklendiği ortaya çıkmıştır. Erdek istasyonu verilerine göre kış yağışlarında %10,22, yaz yağışlarında %15,45, sonbahar yağışlarında %11,27 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %1,00 miktarında bir artış yaşanacağı öngörülmüştür.

17695 numaralı Keles istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,63 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,959 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,959 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %9,63 değerinde bir azalma beklendiği ortaya çıkmıştır. Keles istasyonu verilerine göre kış yağışlarında %16,08, yaz yağışlarında %1,58, sonbahar yağışlarında %15,99 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %6,11 miktarında bir artış yaşanacağı öngörülmüştür.

699 numaralı Mustafa Kemal Paşa istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,49 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,98 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,98 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %7,26 değerinde bir azalma beklendiği ortaya çıkmıştır. Mustafa Kemal Paşa istasyonu verilerine göre kış yağışlarında %7,01, ilkbahar yağışlarında %7,39 miktarında bir artış meydana geleceği; yaz yağışlarında %4,93 ve sonbahar yağışlarında %11,63 miktarında bir düşüş yaşanacağı öngörülmüştür.

17748 numaralı Simav istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,59 olarak bulunmuştur.

Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,889 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0.889 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %12,28 değerinde bir azalma beklendiği ortaya çıkmıştır. Simav istasyonu verilerine göre kış yağışlarında %21,16, sonbahar yağışlarında %18,89 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında %15,17, yaz yağışlarında %2,32 miktarında bir artış yaşanacağı öngörülmüştür.

17704 numaralı Tavşanlı istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,46 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,9 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,9 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %3,73 değerinde bir azalma beklendiği ortaya çıkmıştır. Tavşanlı istasyonu verilerine göre kış yağışlarında %8,11, sonbahar yağışlarında %6,15 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında %5,14, yaz yağışlarında %0,27 miktarında bir artış yaşanacağı öngörülmüştür.

17676 numaralı Uludağ istasyonu için eğitim ve test dönemleri birlikte incelendiğinde oluşturulan model sonucunda determinasyon katsayısı olan R^2 : 0,57 olarak bulunmuştur. Düzeltilmiş 20C3M ve A1B senaryosu sonuçlarını elde etmek amacıyla gözlenen ortalama değerler ortalama 20C3M değerine oranlanmış ve 0,992 bulunmuştur. Ortalama 20C3M ve SRES-A1B değerleri daha önce bulunan 0,992 değerindeki oranla çarpılarak iyileştirilmiş değerlere ulaşılır. Yapılan bu işlemle yağış miktarında %6,97 değerinde bir azalma beklendiği ortaya çıkmıştır. Uludağ istasyonu verilerine göre kış yağışlarında %14,23, sonbahar yağışlarında %11,86 miktarında bir düşüş meydana geleceği; ilkbahar yağışlarında ise %7,57, yaz yağışlarında %1,57 miktarında bir artış yaşanacağı öngörülmüştür.

Modellemeler sonucu elde edilmiş olan tahminlere göre gelecek seneler için önlemler alınabilir ve bu şekilde sel, taşkın, kuraklık vb. doğal afetlerden korunabilir ve su tüketimi daha bilinçli, tüketim planları dahilinde gerçekleştirilebilir.

Yapılan çalışmada, seçilen istasyonlar için ECHAM5 iklim modelinin A1B senaryosu altında 2015-2030 yılları arasındaki yağış tahmini elde edilmiştir. Tahmin edilen tarihlerde bütün istasyon bölgelerindeki yağış miktarlarında düşüşler beklenmektedir. Elde edilen model sonuçlarına bakılacak olursa Bandırma, Tavşanlı ve Mustafa Kemal Paşa istasyonları (R^2) %50'ye yakın oranda iyi sayılabilecek tahmin performansı gösterdiği görülmüştür. Diğer istasyonlarda ise (R^2) %50'nin üzerinde iyi bir tahmin performansı görülmüştür. Bütün istasyonların yağış miktarında %5-%15 aralığında azalmalar yaşanabileceği öngörülmüştür. Mevsimsel olarak incelendiğinde ise, kış mevsimi yağışlarında genellikle %10-%15 aralığında azalmalar, ilkbaharda genellikle %1-%15 aralığında artışlar, yaz mevsiminde genellikle %1-%20 aralığında azalışlar, sonbaharda ise genellikle %6-%20 aralığında yağış miktarının azalması beklenmektedir. Elde edilen sonuçlara genel olarak bakıldığında yapay sinir ağları ile yağış tahmininde umut vaadedici sonuçlara ulaşılmış ve yağış tahminiyle ilgili farklı modelleme çalışmalarında kullanılabileceği kanaatine varılmıştır.

Sonuç olarak, bir kara kutu modeli olarak bilinen yapay sinir ağlarında en iyi sonuca ulaşıp ulaşılamadığı kesin çizgilerle bilinemez çünkü seçilen girdi parametreleri, atanan ağırlıklar, gizli katmandaki nöron sayısı vb. gibi unsurlar ağın performansını önemli ölçüde etkilemekte ve ortaya çıkan sonuçları değiştirmektedir.

Tablo 5.1 İstasyon için sonuçlar

İstasyon Adı	Dönem	HKO (mm ²)	HKOK (mm)	Korelasyon Katsayısı (R)	Determinasyon Katsayısı (R ²)
Balıkesir	Eğitim (Ocak 1970-Aralık 1990)	611,870	24,736	0,818	0,669
	Test (Ocak 1991-Aralık 1999)	557,577	23,613	0,823	0,678
Bandırma	Eğitim (Ocak 1970-Aralık 1990)	1523,579	39,033	0,709	0,502
	Test (Ocak 1991-Aralık 1999)	1380,935	37,161	0,679	0,462
Bursa	Eğitim (Ocak 1970-Aralık 1990)	762,926	27,621	0,760	0,577
	Test (Ocak 1991-Aralık 1999)	874,782	29,577	0,724	0,524
Dursunbey	Eğitim (Ocak 1970-Aralık 1990)	615,979	24,819	0,756	0,571
	Test (Ocak 1991-Aralık 1999)	569,532	23,865	0,770	0,592
Erdek	Eğitim (Ocak 1970-Aralık 1990)	615,900	24,817	0,745	0,555
	Test (Ocak 1991-Aralık 1999)	1102,471	33,203	0,662	0,439
Keles	Eğitim (Ocak 1970-Aralık 1990)	967,331	31,102	0,803	0,645
	Test (Ocak 1991-Aralık 1999)	867,166	29,448	0,779	0,607
Mustafa Kemal Paşa	Eğitim (Ocak 1970-Aralık 1990)	1284,038	35,833	0,698	0,487
	Test (Ocak 1991-Aralık 11999)	1065,766	32,646	0,717	0,514
Simav	Eğitim (Ocak 1970-Aralık 1990)	2126,830	46,118	0,772	0,597
	Test (Ocak 1991-Aralık 1999)	1232,355	35,105	0,807	0,651
Tavşanlı	Eğitim (Ocak 1970-Aralık 1990)	455,263	21,337	0,682	0,465
	Test (Ocak 1991-Aralık 1999)	388,441	19,709	0,683	0,467
Uludağ	Eğitim (Ocak 1970-Aralık 1990)	3957,186	62,906	0,759	0,577
	Test (Ocak 1991-Aralık 1999)	3625,766	60,214	0,754	0,568

KAYNAKLAR

- Aksoy, H., & Dahamsheh, A. (2018). Markov chain-incorporated and synthetic data-supported conditional artificial neural network models for forecasting monthly precipitation in arid regions. *Journal of Hydrology*, 758-779.
- Anandhi, A., Srinivas, V. V., Nanjundiah, S. R., & Kumar, N. D. (2008). Downscaling precipitation to river basin in India for IPCC SRES scenarios using support vector machine. *International Journal of Climatology*, 401-420.
- Ankara: T.C. Orman ve Su İşleri Bakanlığı Su Yönetimi Genel Müdürlüğü. (2018). *Susurluk Havzası Taşkın Yönetim Planı*.
- Azad, A., Manoochehri, M., Kashi, H., Farzin, S., & Karami, H. (2019). Comparative evaluation of intelligent algorithms to improve adaptive neurofuzzy inference system performance in precipitation modelling. *Journal of Hydrology*, 214-224.
- Bisoyi, N., Gupta, H., Padhy, N. P., & Chakrapani, G. J. (2019). Prediction of daily sediment discharge using a back propagation neural network training algorithm: A case study of the Narmada River, India. *International Journal of Sediment Research*, 125-135.
- Burger, G. (1996). Expanded downscaling for generating local weather scenarios. *Climate Research*, 111-128.
- Ceribasi, G., Dogan, E., Akkaya, U. & Kocamaz, U. E., (2017). Application of Trend Analysis and Artificial Neural Networks Methods: The Case of Sakarya River, Scientia Iranica, *International Journal of Science and Technology*, 993-999.
- Chang, N. B., Yang, N. J., Imen, S., & Mullon, L. (2017). Multi-scale quantitative precipitation forecasting using nonlinear and nonstationary teleconnection signals and artificial neural network models. *Journal of Hydrology*, 305-321.
- Coulibaly, P., Anctil, F., & Bobee, B. (2000). Daily reservoir inflow forecasting using temporal neural networks. *Journal of Hydrology*, 244-257.
- Crane, R. G., & Hewitson, B. C. (1998). Doubled CO₂ precipitation changes for the Susquehanna basin: downscaling from the GENESIS general circulation model. *International Journal of Climatology*, 65-76.

- Çevik, E. (2009). *Yapay Sinir Ağları Metodu ile Yağış Tahmini*. (Yüksek Lisans Tezi). Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Isparta.
- Çınar, D. (2007), Haziran. *Hidroelektrik enerji üretiminin hibrid bir model ile tahmini* İstanbul Üniversitesi Fen Bilimleri Enstitüsü (Yüksek Lisans Tezi).
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 512-517.
- Farajzadeh, J., Fard, A. F., & Lotf, S. (2014). Modeling of monthly rainfall and runoff of Urmia lake basin using “feed-forward neural network” and “time series analysis” model. *Water Resources and Industry*, 38-48.
- Ferreira, R. N., Nissenbaum, M. R., & Rickenbach, T. M. (2018). Climate change effects on summertime precipitation organization in the Southeast United States. *Elsevier*, 348-363.
- Fırat, M., & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *İMO Teknik Dergi*, 3267-3282.
- Fıstıkoğlu, O., & Okkan, U. (2011). Statistical downscaling of monthly precipitation using NCEP/NCAR reanalysis data for Tahtali River basin in Turkey. *Journal of Hydrologic Engineering*, 157-164.
- Fowler, H. J., Ekström, M., Kilsby, C. G., & Jones, P. D. (2005). New estimates of future changes in extreme rainfall across the UK using regional climate model integrations 1. Assessment of control climate. *Journal of Hydrology*, 212-233.
- Frei, C., Christensen, J. H., D'equ'e, M., Jacob, D., Jones, R. G., & Vidale, P. L. (2003). Daily precipitation statistics in regional climate models: evaluation and intercomparison for the European Alps. *Journal of Geophysical Research*, 4124.
- Gao, M., Yin, L., & Ning, J. (2018). Artificial neural network model for ozone concentration estimation and Monte Carlo analysis. *Atmospheric Environment*, 129-139.
- Hagan, M. T., & Menjah, M. B. (1994). Training feed forward techniques with the Marquardt algorithm. *IEEE Trans. Neural Networks*, 989-993.
- Ham, F., & Kostanic, I. (2001). *Principles of neurocomputing for science and engineering*. USA: Macgraw-Hill.
- Haykin, S. (1994). *Neural networks: a comprehensive foundation*. New York: McMillan.
- İnallı, K., Işık, E., & Dağtekin, İ. (2014). Karakaya Hes'de verim ve üretim parametrelerinin yapay sinir ağı ile tahmini. *Mühendislik dergisi*, 59-68.

IPCC. (2007). IPCC.

Kalnay, E., Kanamitsu, M., Kistler, R., Collins, W., Deaven, D., & Gandin, L. (1996). The NCEP/NCAR 40-year reanalysis project. *Bulletin of the American Meteorological Society*, 437-471.

Karamouz, M., Fallahi, M., Nazif, S., & Farahani, M. R. (2009). Long lead rainfall prediction using statistical downscaling and artificial neural network modeling. *Scientia Iranica (Transacation A: Civil Engineering)*, 165-172.

Katz, R. W. (1996). Use of conditional stochastic models to generate climate change scenarios. *Climatic Change*, 237-255.

Katz, R. W., & Parlange, M. B. (1998). Overdispersion phenomenon in stochastic modeling of precipitation. *Journal of Climate*, 591-601.

Kermanshahi, B., & Iwamiya, H. (2002). Up to 2020 load forecasting using neural nets. *Electrical power and energy systems*, 789-797.

Kökçam, A., Doğan, E., & Erden, C. (2018), Mayıs. Meriç nehri akımlarının yapay sinir ağları ile tahmini. *ISHAD2018*.

Kubat, C. (2017). *Matlab Yapay Zeka ve Mühendislik Uygulamaları*. İstanbul: Abaküs Kitap.

Le, J. A., El-Askary, H. M., Allali, M., & Struppa, D. C. (2017). Application of recurrent neural networks for drought projections in California. *Atmospheric Research*, 100-106.

Makas, Y., & Karaatlı, M. (2016). Yapay sinir ağlarıyla hidroelektrik enerji üretiminin çok dönemli tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 757-772.

Mearns, L. O., Bogardi, I., Giorgi, F., Matyasovszky, I., & Palecki, M. (1999). Comparison of climate change scenarios generated from regional climate model experiments and statistical downscaling. *Journal of Geophysical Research*, 6603-6621.

Murphy, J. M. (1999). An evaluation of statistical and dynamical techniques for downscaling local climate. *Journal of Climate*, 2256-2284.

Nastos, P. T., Paliatsos, A. G., Koukouletsos, K. V., Larissi, I. K., & Moustris, K. P. (2014). Artificial neural networks modeling for forecasting the maximum daily total precipitation at Athens, Greece. *Elsevier*, 141-150.

Okkan, D., & Karakan, D. (2015), 03 26. İklim Değişikliğinin Balıkesir İli İçme Suyu Potansiyeline Etkilerinin Modellenmesi : İçme Suyu Talebinin 2015-2030 Projeksiyonu. Balıkesir.

- Okkan, U. (2013). *İklim Değişikliğinin Akarsu Akışları Üzerindeki Etkilerinin Değerlendirilmesi*. (Yüksek Lisans) Tezi Dokuz Eylül Üniversitesi. İzmir: Fen Bilimleri Enstitüsü.
- Okkan, U. (2014). Assessing the effects of climate change on monthly precipitation: proposing of a downscaling strategy through a case study in Turkey. *KSCE Journal of Civil Engineering*.
- Okkan, U., & Fıstıkoğlu, O. (2012). Downscaling of precipitation to Tahtali watershed in Turkey for climate change scenarios. *10th International Congress on Advances in Civil Engineering*.
- Okkan, U., & Fıstıkoğlu, O. (2014). Evaluating Climate Change Effects on Runoff by Statistical Downscaling and Hydrological Model GR2M. *Theoretical and Applied Climatology*, 343-361.
- Okkan, U., & İnan, G. (2014). "Bayesian learning and relevance vector machines approach for downscaling of monthly precipitation. " *ASCE Journal of Hydrologic Engineering*, 1943-5584.
- Okkan, U., & Karakan, E. (2015). *İklim değişikliğinin Balıkesir ili içme suyu potansiyeline etkilerinin modellenmesi: İçme suyu talebinin 2015-2030 projeksiyonu*. T.C. Balıkesir Üniversitesi Bilimsel Araştırma Projeleri Birimi.
- Öcal, O. (2007), Temmuz. *Yapay sinir ağları algoritması kullanılarak akarsu havzalarında yağış-akış-katı madde ilişkisinin belirlenmesi* (Yüksek Lisans Tezi). Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.
- Öztürk, K. (2002). Küresel İklim Değişikliği ve Türkiye'ye Etkileri. *G. Ü. Gazi Eğitim Fakültesi Dergisi*, 47-65.
- Skapura, D. M. (1996). *Building Neural Networks*. New York: Addison-Wesley.
- Sözen, A., Akçayol, M., & Arcaklioğlu, E. (2006). Forecasting net energy consumption using artificial neural network. *Energy Sources, Part B*, 147-155.
- Tatlı, H., Dalfes, N. H., & Menteş, S. Ş. (2006). Yeni istatistiksel ölçek küçültme yöntemleri ve Türkiye için uygulamalar. *İTÜ Mühendislik Dergisi*, 269-280.
- Tayfur, G. (2012). *Soft computing methods in water resources engineering*. WIT Press: Southampton, UK.
- Terzi, Ö., & Baykal, T. (2012). Akarsulardaki katı madde miktarının yapay sinir ağları ile tahmini, kızılırmak nehri örneği. *SDU International Technologic Science*, 8-14.
- Terzi, Ö., & Köse, M. (2012). Yapay sinir ağları yöntemi ile göksunehri'nin akım tahmini. *SDU International Technologic Science*, 1-7.

- Trejo, F. J., Barbosa, H. A., & Kumar, T. L. (2017). Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. *Journal of Arid Environments*, 26-40.
- Tripathi, S., Srinivas, V. V., & Nanjundiah, R. S. (2006). Downscaling of precipitation for climate change scenarios: a support vector machine approach. *Journal of Hydrology*, 621-640.
- Uzlu, E., Akpınar, A., Öztürk, H., Nacar, S., & Kankal, M. (2014). Estimates of hydroelectric generation using neural networks with the artificial bee colony algorithm for Turkey. *Energy*, 638-647.
- Uzlu, E., Kankal, M., Akpınar, A., & Dede, T. (2014). Estimates of energy consumption in Turkey using neural networks with the teaching-learning-based optimization algorithm. *Energy*, 295-303.
- von Storch, H., Zorita, E., & Cubasch, U. (1993). Downscaling of global climate change estimates to regional scales: An application to Iberian rainfall in wintertime. *Journal of Climate*, 1161-1171.
- Vu, M. T., Aribarg, T., Supratid, S., Raghavan, S., & Liong, S. Y. (2016). Statistical downscaling rainfall using artificial neural network: significantly wetter Bangkok? *Theor Appl Climatol*, 453-467.
- Wilby, R. L. (1994). Stochastic weather type simulations for regional climate change impact assessment. *Water Resources Research*, 3395-3403.
- Wilby, R. L., Dawson, C. W., & Barrow, E. M. (2002). SDSM – a decision support tool for the assessment of climate change impacts. *Environmental Modeling & Software*, 147-159.
- Wilby, R. L., Tomlinson, O. J., & Dawson, C. W. (2003). Multi-site simulation of precipitation by conditional resampling. *Climate Research*, 183-194.
- Xu, S., Shen, Y., & Niu, Z. (2019). Evaluation of the IMERG version 05B precipitation product and comparison with IMERG version 04A over mainland China at hourly and daily scales. *Advances in Space Research*, 2387-2398.
- Yaşar, M. (2004), Temmuz. *Günlük akışlardaki boşlukların yapay sinir ağları kullanılarak tamamlanması* (Yüksek Lisans Tezi). Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.
- Zambrano, F., Wardlow, B., Tadesse, T., Saavedra, M. L., & Lagos, O. (2017). Evaluating satellite-derived long-term historical precipitation datasets for drought monitoring in Chile. *Atmospheric Research*, 26-42.

Zubaidi, S. L., Dooley, J., Alkhaddar, R. M., Abdellatif, M., Al-Bugharbee, H., & Ortega-Martorell, S. (2018). A Novel approach for predicting monthly water demand by combining. *Journal of Hydrology*, 136-145.

Url-1 <https://auzefalmsstorage.blob.core.windows.net> Eriřim Tarihi: 01.05.2019

Url-2 <http://apelasyon.com/Yazi/927-tarimda-yapay-sinir-ag-uygulamalari> Eriřim Tarihi: 01.05.2019.



ÖZGEÇMİŞ

Merve Özdin, 08.08.1992’de Sakarya’da doğdu. İlk, orta ve lise eğitimini Sakarya’da tamamladı. 2011 yılında başladığı Sakarya Üniversitesi, İnşaat Mühendisliği Bölümü’nü 2016 yılında bitirdi. 2016 yılında Sakarya Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, İnşaat Mühendisliği Anabilim Dalında, Hidrolik Bilim Dalında yüksek lisans eğitimine başladı. Halen yüksek lisans eğitimine devam etmektedir.