T.C.
HATAY MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İKLİM DEĞİŞİKLİĞİNİN KIRIKHAN SULAMA SAHASINDA BİTKİSEL ÜRETİME ETKİSİ

Mustafa ÖZBULDU

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

HATAY
EKİM - 2023

T.C.
HATAY MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İKLİM DEĞİŞİKLİĞİNİN KIRIKHAN SULAMA SAHASINDA BİTKİSEL ÜRETİME ETKİSİ

Mustafa ÖZBULDU
ORCID:0000-0002-5359-8750

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

Danışman
Prof. Dr. Ahmet İRVEM
ORCID: 0000-0002-3838-1924

HATAY
EKİM - 2023

T.C.

HATAY MUSTAFA KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

İKLİM DEĞİŞİKLİĞİNİN KIRIKHAN SULAMA SAHASINDA BİTKİSEL ÜRETİME ETKİSİ

Mustafa ÖZBULDU

BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

DOKTORA TEZİ

Prof. Dr. Ahmet İRVEM danışmanlığında hazırlanan bu tez **00/00/2023** tarihinde aşağıdaki jüri üyeleri tarafından **OYBİRLİĞİ** ile kabul edilmiştir.

Prof. Dr. …….
Başkan

Doç. Dr. ……..
Üye

Doç. Dr. ……..
Üye

Doç. Dr. ……..
Üye

Doç. Dr. ……..
Üye

Kod No:

Doç. Dr. Cengiz KARACA
Enstitü Müdürü

Bu çalışma MKÜ Bilimsel Araştırma Projeleri Komisyonu tarafından desteklenmiştir.
Proje No: ……

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

17/10/2023

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını ve tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu beyan ederim.

Mustafa ÖZBULDU

ÖZET

İKLİM DEĞİŞİKLİĞİNİN KIRIKHAN SULAMA SAHASINDA BİTKİSEL ÜRETİME ETKİSİ

Bu çalışmada küresel iklim modelleri (KİM) kullanılarak iklim değişikliğinin Hatay ilinde farklı senaryolara göre sıcaklık ve yağışa olası etkileri tahmin edilmiş ve bu tahminler kullanılarak Hatay ilinin Kırıkhan ilçesinde iklim değişikliğinin bitkisel üretime olası etkileri değerlendirilmiştir. Çalışmanın birinci bölümünde Hatay ilinde bulunan gözlem istasyonlarına ait veri setleri çok katmanlı yapay sinir ağı modeli oluşturularak uzun yıllık veri setleri haline getirilmiştir. Bu veri setleri kullanılarak yedi farklı KİM arasından çalışma alanına en uygun olanı çok kriterli karar verme yöntemi ile değerlendirilmiş ve EC-EARTH3 modelinin daha iyi sonuç verdiği belirlenmiştir. Bu modelden elde edilen verilerin tahmin doğruluklarının iyileştirilmesi için üç farklı istatistiksel ölçek küçültme yöntemi değerlendirilmiş ve rastgele orman yöntemi daha başarılı olarak belirlenmiştir. Ölçek küçültülmüş KİM'den elde edilen tahminler Hatay ili için iklim değişikliğinin olası etkileri yakın (2020-2060) ve uzak gelecek (2060-2100) dönemler için değerlendirilmiştir. Değerlendirme sonucunda SSP2-4.5 (iyimser) senaryosunda sırasıyla 2.1°C ve 2.9°C, SSP5-8.5 (kötümser) senaryosunda ise sırasıyla 2.4°C ve 5.2°C sıcaklık artışı tahmin edilmiştir. Ayrıca gelecekte her iki senaryo içinde Hatay'ın yıllık yağış miktarında azalma görüleceği tahmin edilmiştir. Özellikle Hatay ilinin batı ve güney bölgelerinde yıllık yağışta iyimser senaryoya göre %10, kötümser senaryoya göre ise yaklaşık %20 oranında azalma öngörülmüştür.

Çalışmanın ikinci bölümünde iklim değişikliğinin Kırıkhan'da yetiştirilen pamuk ve 1. ürün mısır verimine olası etkilerini tahmin etmek için dört farklı arazide çalışmalar gerçekleştirilmiştir. Arazilerden elde edilen 2021-2022 yılı gözlemleri ve analiz sonuçları kullanılarak AquaCrop bitki verim tahmin modeli kalibre edilerek doğrulanmış ve verim tahmin performansı değerlendirilmiştir. Model pamuk bitkisi kütlü verimini %4.99 ve biyokütle verimini ise %5.42'lik sapma, 1. ürün mısır bitkisi dane verimini %3.04 ve biyokütle verimini ise %2.96'lık sapma ile tahmin etmiştir. Doğrulanan AquaCrop modeli ile gerçekleştirilen tahminlere göre, ortalama kütlü pamuk veriminde yakın gelecekte SSP2-4.5 ve SSP5-8.5 senaryoları için sırasıyla %4 ve %8, uzak gelecekte ise %9 ve %19 oranında verim kaybı öngörülmüştür. 1. ürün mısır dane veriminde yakın gelecekte SSP2-4.5 ve SSP5-8.5 senaryoları için sırasıyla %10 ve %16, uzak gelecekte ise %14 ve %30 azalma olabileceği tahmin edilmiştir.

Sonuç olarak; stratejik ve önemli tarım ürünleri olan 1. ürün mısır ve pamuk bitkilerinde yaklaşık 1.55 ve 0.54 ton da^{-1} olan ortalama mevcut üretimin kötümser senaryoya göre bu yüzyılın sonunda yaklaşık olarak 0.36 ve 0.09 ton da^{-1} azalabileceği belirlenmiştir. Bu değerler Kırıkhan ilçesindeki mısır ve pamuk ekili alana göre değerlendirildiğinde ise sırasıyla yaklaşık 21960 ton ve 12870 ton yıllık ürün kaybı olabileceği hesaplanmıştır. Hesaplanan bu ürün kayıpları dikkate alınarak; iklim değişikliğine karşı gerekli önlemlerin alınması ve ilgili eylem planlarının hazırlanması önerilmektedir.

2023, 188 sayfa

Anahtar Kelimeler: İklim değişikliği, AquaCrop, küresel iklim modeli, istatistiksel ölçek küçültme, yapay sinir ağı

ABSTRACT

The EFFECT of CLIMATE CHANGE on PLANT PRODUCTION in KIRIKHAN IRRIGATION SITE

In this study, the possible effects of climate change on temperature and precipitation in Hatay province according to different scenarios were estimated using global climate model (GCM). In addition, the possible effects of climate change on crop production in Kırıkhan district of Hatay were evaluated using the predictions obtained. In the first part of the study, data sets of observation stations in Hatay were converted into long-term data sets by creating a multilayer artificial neural network model. Using these data sets, the most appropriate model for the study area among seven different GCMs was evaluated by multi-criteria decision making method. It was determined that the EC-EARTH3 model gave better results. Three different statistical downscaling methods were evaluated to improve the prediction accuracy of the data obtained from this model and the random forest method was determined to be more successful. The forecasts obtained from downscaled GCM were evaluated for Hatay province for the near (2020-2060) and distant future (2060-2100) periods. As a result of the assessment, a temperature increase of 2.1°C and 2.9°C for SSP2-4.5, 2.4°C and 5.2°C for SSP5-8.5 were forecasted, respectively. In addition, it is forecasted that there will be a decrease in the annual precipitation amount of Hatay in both scenarios in the future. Especially in the western and southern regions of Hatay, this decrease is forecasted to be 10% for SSP2-4.5 and 20% for SSP5-8.5.

In the second part of the study, studies were carried out in four different fields to forecast the possible effects of climate change on cotton and 1st season maize yields cultivated in Kırıkhan. The AquaCrop crop yield predicting model was calibrated and validated using the observations and analyses results obtained from the fields in 2021-2022. The model predicted cotton yield with a deviation of 4.99% and biomass yield with a deviation of 5.42%, 1st crop maize yield with a deviation of 3.04% and biomass yield with a deviation of 2.96%. According to the validated AquaCrop model projections, the average cotton yields for SSP2-4.5 and SSP5-8.5 are forecasted to decrease by 4% and 8% in the near future and by 9% and 19% in the distant future, respectively. Maize yields are forecasted to decrease by 10% and 16% in the near future and by 14% and 30% in the distant future for SSP2-4.5 and SSP5-8.5 scenarios, respectively.

In conclusion, it has been determined that the average current production of 1.55 and 0.54 tonnes da^{-1} in 1st season maize and cotton plants, which are strategic and important agricultural products, may decrease by approximately 0.36 and 0.09 tonnes da^{-1} at the end of this century according to SSP5-8.5 scenario. When these values are evaluated according to the maize and cotton cultivated area in Kırıkhan district, it is calculated that there may be approximately 21960 tonnes and 12870 tonnes of annual crop loss, respectively. Considering these calculated crop losses, it is recommended to take necessary precautions against climate change and to prepare relevant action plans.

2023, 188 pages

Key Words: Climate change, AquaCrop, global climate model, statistical downscaling, artificial neural network

TEŞEKKÜR

Mesleki ve akademik hayatımda önemli kararlar almam gerektiğinde sürekli yanımda olan ve varlığı ile benim için önemli bir rol model oluşturan, gerek doktora tez konumunun belirlenmesinde gerek araştırılması ve yazımı sırasında sahip olduğu bilgi birikimi ve tecrübesi ile çalışmalarıma ışık tutan ve yardımını esirgemeyen danışman hocam Prof. Dr. Ahmet İRVEM'e sonsuz saygı ve teşekkürlerimi sunarım.

Tez izleme komitesinde yer alarak, tez çalışmalarım ile ilgili gelişmeleri takip eden ve değerli yorumlarını esirgemeyen Prof. Dr. Berkant ÖDEMİŞ ve Doç. Dr. Reşat GEÇEN hocalarıma; tez savunma sürecimde sağladıkları katkılar dolayısıyla jüri üyeleri Prof. Dr. Cafer GENÇOĞLAN, Prof. Dr. Fatih TOPALOĞLU ve Prof. Dr. Mustafa ÜNLÜ hocalarıma teşekkürlerimi sunarım.

Çalışma kapsamında, desteklerinden dolayı HMKÜ BAP birimine (Proje no: 20D009); tüm bölüm olanaklarından yararlanmamı sağlayan Biyosistem Mühendisliği Bölüm Başkanlığı'na ve HMKÜ Fen Bilimleri Enstitüsü Müdürlüğü çalışanlarına teşekkürlerimi sunarım.

Tez çalışmalarım süresince yapmış olduğu katkı ve yardımlar için Dr. Öğr. Üyesi Yunus Emre ŞEKERLİ'ye ve arazi çalışmalarımı gerçekleştirmemde sağladıkları imkânlar için Kırıkhan Sulama Birliği çalışanlarına teşekkür ederim.

Bu uzun ve zorlu süreçte arazi ve laboratuvar çalışmalarımda dâhil olmak üzere karşılıksız şekilde destekleyen ve daima yanımda olan kıymetli eşim Neslihan ÖZBULDU'ya sonsuz teşekkür ederim.

Eğitim hayatım boyunca beni maddi ve manevi olarak destekleyen, güvenen ve daima yanımda olan anneme, babama ve ÖZBULDU ailesinin tüm fertlerine sonsuz teşekkürlerimi sunarım.

İÇİNDEKİLER

ÖZET I
ABSTRACT II
TEŞEKKÜR III
İÇİNDEKİLER IV
ÇİZELGELER DİZİNİ VII
ŞEKİLLER DİZİNİ IX
SİMGELER ve KISALTMALAR DİZİNİ XII
1. GİRİŞ 1
2. ÖNCEKİ ÇALIŞMALAR 8
2.1. YSA ile Meteorolojik Verilerin Tahmini ile İlgili Yapılan Çalışmalar 8
2.2. Küresel İklim Modelleri ile İlgili Yapılan Çalışmalar 13
2.3. Ölçek Küçültme Yöntemleri ile İlgili Yapılan Çalışmalar 18
2.4. Bitkisel Üretimin Modellenmesi ile İlgili Yapılan Çalışmalar 22
3. MATERYAL ve YÖNTEM 30
3.1. Materyal 32
3.1.1. Çalışma Alanı ve Özellikleri 32
3.1.1.1. Abalaklı Köyü 35
3.1.1.2. Danaahmetli Köyü 35
3.1.1.3. Mahmutlu Köyü 36
3.1.1.4. Ahrazlı Köyü 37
3.1.2. Meteorolojik Gözlem Verileri 37
3.1.3. Çalışmada Kullanılan Mısır ve Pamuk Bitkilerinin Çeşit Özellikleri 39
3.1.3.1. Pamuk 39
3.1.3.2. Mısır 40
3.1.4. Küresel İklim Modellerinin Özellikleri 42
3.1.5. AquaCrop Bitki Verim Tahmin Modeli 42
3.2. Yöntem 43
3.2.1. Geçmiş Meteorolojik Verilerin Modellenerek Tahmin Edilmesi 43
3.2.1.1. Meteorolojik Gözlem Verilerine Ön İşlem Uygulanması 44
3.2.1.1.1. Kayıp Verilerin Atanması 44
3.2.1.1.2. Değişkenlerin Seçimi 45
3.2.1.1.3. Normalizasyon İşlemi 46
3.2.1.1.4. Eğitim ve Test Veri Setinin Oluşturulması 47
3.2.1.2. Çok Katmanlı Yapay Sinir Ağı 47
3.2.2. Çalışma Alanına En Uygun Küresel İklim Modelinin Seçimi 51
3.2.3. İstatistiksel Ölçek Küçültme Yöntemlerinin Uygulanması ve Karşılaştırılması 53
3.2.3.1. Tahmin Edici Değişken Seçimi (Predictor Selection) 53
3.2.3.2. Rastgele Orman Algoritması 55
3.2.3.3. Destek Vektör Regresyonu Algoritması 58
3.2.3.4. Çok Değişkenli Doğrusal Regresyon 60
3.2.3.5. Yanlılık Düzeltme (Bias Correction) 61
3.2.4. En Uygun Ampirik Referans Evapotranspirasyon Yönteminin Seçilmesi 62
3.2.4.1. Güneş Radyasyonun Belirlenmesi 63
3.2.4.2. Penman Monteith (FAO-56 PM) ET_0 Hesaplama Yöntemi 65

3.2.4.3. Hargreaves-Samani ET_0 Hesaplama Yöntemi 67
3.2.4.4. Priestley-Taylor ET_0 Hesaplama Yöntemi 68
3.2.4.5. Makkink ET_0 Hesaplama Yöntemi 68
3.2.5. Bitki Örneklerinin Alınması ve Hasat Edilmesi 68
3.2.5.1. Pamuk Bitki Örneklerinin Alınması ve Hasat Edilmesi 68
3.2.5.2. Mısır Bitki Örneklerinin Tarladan Alınması ve Hasat Edilmesi 69
3.2.6. AquaCrop Modelinin Girdi Dosyalarının Oluşturulması 70
3.2.6.1. İklim Dosyasının Oluşturulması 71
3.2.6.2. Toprak Dosyasının Oluşturulması 72
3.2.6.2.1. Toprak Örneklerinin Alınması ve Analize Hazırlanması 72
3.2.6.2.2. Kullanılabilir Su Tutma Kapasitesinin Belirlenmesi 74
3.2.6.2.3. Toprak Örneklerinde Hacim Ağırlığının Belirlenmesi 76
3.2.6.2.4. Toprak Bünyesinin Belirlenmesi 76
3.2.6.2.5. Doygun Hidrolik İletkenliğin Belirlenmesi 78
3.2.6.2.6. Toprak Örneklerinde Porozitenin Belirlenmesi 78
3.2.6.3. Bitki Dosyalarının Oluşturulması 79
3.2.6.3.1. Pamuk Bitki Dosyası 79
3.2.6.3.2. Mısır Bitki Dosyası 87
3.2.7. Model Performans Değerlendirilmesi için Kullanılan İstatistiki Ölçütler 92
3.2.7.1. Belirleme Katsayısı 92
3.2.7.2. Kök Ortalama Kareler Hatası 92
3.2.7.3. Normalize Edilmiş Kök Ortalama Kareler Hatası 93
3.2.7.4. Wilmott uyumluluk indeksi 93
3.2.7.5. Yüzde Sapma Değeri 93
3.2.7.6. Nash-Sutcliffe Verimlilik Katsayısı 94
3.2.7.7. Kök Ortalama Kareler Hatası ile Gözlemlerin Standart Sapmasının Oranı 94
3.2.7.8. Performans İndeksi 95
3.2.7.9. Taylor Yetenek Puanı 96
4. ARAŞTIRMA BULGULARI ve TARTIŞMA 97
4.1. Geçmiş Meteorolojik Verilerin Tahmin Sonuçları 97
4.1.1. Modelde Kullanılacak Tahmin Edici Değişkenlerin Seçimi 97
4.1.2. Yapay Sinir Ağı Modellerinin Belirlenen Nöron Sayıları 98
4.1.3. Maksimum ve Minimum Sıcaklıkların Tahmin Sonuçları 98
4.1.4. Yağış Miktarının Tahmin Sonuçları 105
4.1.5. YSA Model Kullanılabilirliğini Değerlendirme Sonuçları 108
4.2. Küresel İklim Modelini Belirleme Sonuçları 110
4.2.1. Maksimum ve Minimum Sıcaklık İçin Değerlendirme Sonuçları 110
4.2.2. Yıllık Yağış Miktarı İçin Değerlendirme Sonuçları 112
4.2.3. Küresel İklim Modellerin Tahmin Performanslarının Sıralama Sonuçları 114
4.3. Küresel İklim Modeline İstatistiksel Ölçek Küçültme Uygulanması Sonuçları 116
4.3.1. Modellerde Kullanılması Belirlenen Tahmin Edici Değişkenler 116
4.3.2. Maksimum ve Minimum Sıcaklık İçin Ölçek Küçültme Modeli Sonuçları 121
4.3.3. Yağış Miktarı İçin Ölçek Küçültme Model Sonuçları 129
4.4. Hatay İli için Farklı Senaryolar Altında Gelecek İklim Değişikliklerini Değerlendirme Sonuçları 134
4.4.1. İklim Değişikliğinin Sıcaklığa Olası Etkilerinin Tahmini ve Değerlendirme Sonuçları 134

4.4.2. İklim Değişikliğinin Yağış Miktarına Olası Etkilerinin Tahmini ve Değerlendirilmesi 138
4.5. Bitkisel Üretim Modelinin Pamuk ve 1. Ürün Mısır Bitkisi İçin Kalibrasyonu ve Doğrulama Sonuçları 140
4.5.1. Güneş Radyasyonu Hesaplama Sonuçları 140
4.5.2. Referans Evapotranspirasyon Hesaplama Sonuçları 141
4.5.3. Toprak Analizi Sonuçları 143
4.5.4. Bitkilerin Maksimum Bitki Örtü Yüzeyi Yüzdelerinin Hesaplama Sonuçları 144
4.5.4.1. Pamuk Bitkisi Sonuçları 144
4.5.4.2. 1. Ürün Mısır Bitkisi Sonuçları 147
4.5.5. AquaCrop Modelinin Kütlü Pamuk Verimi ve Biyokütle Tahmin Performansının Değerlendirilmesi 149
4.5.6. AquaCrop Modelinin 1. Ürün Mısır Dane Verimi ve Biyokütle Tahmin Performansının Değerlendirilmesi 150
4.6. İklim Değişikliğinin Farklı Senaryolar İçin Pamuk ve 1. Ürün Mısır Bitkisine Olası Etkisini Değerlendirme Sonuçları 152
4.6.1. İklim Değişikliğinin Pamuk Bitkisine Etkisi 152
4.6.2. İklim Değişikliğinin 1. Ürün Mısır Bitkisine Etkisi 156
5. SONUÇ ve ÖNERİLER 160
KAYNAKLAR 166
ÖZGEÇMİŞ 188

ÇİZELGELER DİZİNİ

Çizelge 3.1. Hatay ili 1991-2020 meteorolojik gözlem ortalamaları 33
Çizelge 3.2. Abalaklı Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri 35
Çizelge 3.3. Danaahmetli Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri 35
Çizelge 3.4. Mahmutlu Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri 36
Çizelge 3.5. Ahrazlı Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri 37
Çizelge 3.6. Hatay ili MGM gözlem istasyonları ve koordinatları 38
Çizelge 3.7. Kırıkhan İlçesi 2021-2022 yılı meteorolojik gözlemleri 38
Çizelge 3.8. Lima pamuk çeşidinin özellikleri (BUGEM, 2018) 39
Çizelge 3.9. May455 pamuk çeşidinin özellikleri (BUGEM, 2017) 40
Çizelge 3.10. Kebeos mısır çeşidinin özellikleri (BUGEM, 2017) 40
Çizelge 3.11. May-14G44 mısır çeşidinin özellikleri (BUGEM, 2022) 40
Çizelge 3.11. (Devam) May-14G44 mısır çeşidinin özellikleri (BUGEM, 2022) 41
Çizelge 3.12. P1921 mısır çeşidinin özellikleri (BUGEM, 2015) 41
Çizelge 3.13. DKC6980 mısır çeşidinin özellikleri (BUGEM, 2020) 41
Çizelge 3.14. Çalışmada kullanılan küresel iklim modelleri 42
Çizelge 3.15. Meteorolojik istasyonlara ait olan kayıp günlük veri yüzdeleri 45
Çizelge 3.16. Korelasyon katsayısı değerlendirme tablosu 46
Çizelge 3.17. Hatay İli için GEPA aylık ortalama solar radyasyonu 65
Çizelge 3.18. Pamuk bitkisi gelişim bölümü girdilerinin değerleri 84
Çizelge 3.19. Pamuk bitkisi çiçeklenme bölümü girdilerinin değerleri 84
Çizelge 3.20. Pamuk bitkisinin sabit parametre değerleri (Raes ve ark., 2018) 86
Çizelge 3.22. 1. ürün mısır bitkisi çiçeklenme bölümü girdilerinin değerleri 90
Çizelge 3.23. 1. ürün mısır bitkisinin sabit parametre değerleri (Raes ve ark., 2018) 91
Çizelge 3.24. Model tahminlerinin performans değerlendirme tablosu 95
Çizelge 4.1. İklim parametreleri için değişken seçimi 97
Çizelge 4.2. Oluşturulan YSA modellerin gizli katmanlarında belirlenen nöron sayıları 98
Çizelge 4.3. YSA modellerinin günlük maksimum sıcaklık değerleri için eğitim ve test performansları 99
Çizelge 4.4. YSA modellerinin günlük minimum sıcaklık değerleri için eğitim ve test performansları 102
Çizelge 4.5. YSA modellerinin yağış miktarı için eğitim ve test performansları 105
Çizelge 4.6. Çok katmanlı YSA'nın kullanılabilirliğinin değerlendirme sonuçları 109
Çizelge 4.7. KİM'lerin performans metrik değerleri ve sıralamaları 115
Çizelge 4.8. KİM'lerin ortalama CP değerleri ve başarı sıralamaları 115
Çizelge 4.9. LASSO analizi sonucu modellerde kullanılması belirlenen tahmin edici değişkenler 117
Çizelge 4.10. SVR ve RF modellerinin hiperparametre analizi ile belirlenen optimum parametre değerleri 121
Çizelge 4.11. Ölçek küçültme modellerinin maksimum sıcaklık için test dönemi tahmin performansları 127
Çizelge 4.12. Ölçek küçültme modellerinin minimum sıcaklık için test dönemi tahmin performansları 127
Çizelge 4.13. SVR ve RF modellerinin hiperparametre analizi ile belirlenen optimum parametre değerleri 129

Çizelge 4.14. Ölçek küçültme modellerinin yağış miktarı için test dönemi tahmin performansları 130
Çizelge 4.15. Yakın (YG) ve uzak gelecek (UG) dönemler için iki farklı senaryoya göre elde edilen sıcaklık tahmin ortalamaları 135
Çizelge 4.16. Hesaplanan güneş radyasyonu değerlerinin gözlem değerleri ile istatistiksel olarak karşılaştırma sonuçları 141
Çizelge 4.17. Meteorolojik gözlem istasyonunun 2015-2020 verileri ile hesaplanan ET_0 değerleri 142
Çizelge 4.18. Ampirik ET_0 hesaplama yöntemlerinin istatistiksel analiz sonuçları 143
Çizelge 4.19. Çalışma alanlarının analiz edilen toprak özellikleri sonuçları 144
Çizelge 4.20. Pamuk bitki örneklerinden farklı tarihler için hesaplanan yaprak alan indeksleri 146
Çizelge 4.21. Pamuk bitki örneklerinden farklı tarihler için hesaplanan maksimum bitki örtü yüzeyi yüzdesi değerleri 146
Çizelge 4.22. 1. ürün mısır bitki örneklerinden farklı tarihler için hesaplanan yaprak alan indeksleri 148
Çizelge 4.23. 1. ürün mısır bitki örneklerinden farklı tarihler için hesaplanan maksimum bitki örtü yüzeyi yüzdesi değerleri 148
Çizelge 4.24. Kütlü pamuk verimi ve biyokütle veriminin tahmin ve ölçüm sonuçlarının karşılaştırılması 149
Çizelge 4.25. Kütlü pamuk verimi ve biyokütle verim tahmini için AquaCrop modelinin genel tahmin performansı 150
Çizelge 4.26. 1. ürün mısır dane verimi ve biyokütle veriminin tahmin ve ölçüm sonuçlarının karşılaştırılması 151
Çizelge 4.27. 1. ürün mısır dane verimi ve biyokütle verim tahmini için AquaCrop modelinin genel tahmin performansı 151
Çizelge 4.28. Pamuk bitkisi için gelecek iklim senaryolarına göre elde edilen verim tahminleri 152
Çizelge 4.29. 1. ürün mısır bitkisi için gelecek iklim senaryolarına göre elde edilen verim tahminleri 156

ŞEKİLLER DİZİNİ

Şekil 1.1. Türkiye'nin yıllık ortalama sıcaklık sapması 4
Şekil 3.1. İklim değişikliğinin Hatay ili sıcaklık ve yağış miktarına olası etkisinin değerlendirilmesinin iş akış şeması 30
Şekil 3.2. İklim değişikliğinin pamuk ve 1. ürün mısır bitkisi verimine olası etkisinin değerlendirilmesinin iş akış şeması 31
Şekil 3.3. Çalışma alanının sayısal yükseklik modeli 32
Şekil 3.4. Çalışma alanlarının coğrafi konumları A) Abalaklı Köyü B) Danaahmetli Köyü C) Mahmutlu Köyü D) Ahrazlı Köyü 34
Şekil 3.5. Abalaklı Köyü çalışma alanı 35
Şekil 3.6. Danaahmetli Köyü çalışma alanı 36
Şekil 3.7. Mahmutlu Köyü çalışma alanı 36
Şekil 3.8. Ahrazlı Köyü çalışma alanı 37
Şekil 3.9. Kırıkhan meteorolojik gözlem istasyonu 39
Şekil 3.10. YSA hücresinin (nöron) yapısı ve çalışma prensibi 49
Şekil 3.11. YSA modellerinin genel ağ yapısı 49
Şekil 3.12. RF algoritmasının yapısı (Pang ve ark., 2017) 56
Şekil 3.13. SVR algoritmasının genel yapısı 59
Şekil 3.14. Kütlü pamuk veriminin belirlenmesi ve etüvde kurutma işlemi 69
Şekil 3.15. Mısır veriminin belirlenmesi ve tanelenmesi işlemi 70
Şekil 3.16. İklim verileri tanımlama ekranı 71
Şekil 3.17. AquaCrop modeli toprak katmanlarının karakteristikleri ekranı 72
Şekil 3.18. Profil çukurlarının açılması ve toprak örneklerinin alınması 73
Şekil 3.19. Çelik silindirler ile alınmış bozulmamış toprak örnekleri 74
Şekil 3.20. Tarla kapasitesi ve solma noktası tayin cihazı 75
Şekil 3.21. USDA sistemine göre hazırlanmış bünye sınıflarını gösteren eşkenar üçgen 76
Şekil 3.22. Bouyoucos hidrometre yöntemi 77
Şekil 3.23. Toprak örneklerinde hidrolik iletkenliğin belirlenmesi ve hidrolik iletkenlik ölçme cihazı 78
Şekil 3.24. Tarlalarda ekim işlemi 79
Şekil 3.25. Bitki dosyası oluşturulması ekranı 80
Şekil 3.26. CC_o hesaplama bölümü ekranı 81
Şekil 3.27. Bitki gelişim bölümü ekranı 82
Şekil 3.28. Pamuk yapraklarının alınan dijital görüntü örnekleri 83
Şekil 3.29. Çiçeklenme ve verim bölümü ekranı 85
Şekil 3.30. Pamuk bitkisi büyüme dönemleri (Raes ve ark., 2018) 85
Şekil 3.31. Kök derinliği bölümü ekranı 86
Şekil 3.32. Arazilerde ekim işlemi 87
Şekil 3.33. Mısır bitkisinin gelişimi 88
Şekil 3.34. 1. ürün mısır yapraklarının alınan dijital görüntü örnekleri 89
Şekil 3.35. 1. ürün mısır bitkisi büyüme dönemleri (Raes ve ark., 2018) 91
Şekil 4.1. Maksimum sıcaklık parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları 100
Şekil 4.2. Maksimum sıcaklık parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları 101

Şekil 4.3. Minimum sıcaklık parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları 103
Şekil 4.4. Minimum sıcaklık parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları 104
Şekil 4.5. Yağış miktarı parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları 106
Şekil 4.6. Yağış miktarı parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları 107
Şekil 4.7. Gözlem verileri ve KİM'lerin yıllık ortalama maksimum sıcaklık alansal dağılım haritaları (1980-2014) 110
Şekil 4.8. Gözlem verileri ve KİM'lerin yıllık ortalama minimum sıcaklık alansal dağılım haritaları (1980-2014) 112
Şekil 4.9. Gözlem verileri ve KİM'lerin yıllık ortalama yağış miktarı alansal dağılım haritaları (1980-2014) 113
Şekil 4.10. Maksimum sıcaklık ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler 118
Şekil 4.11. Minimum sıcaklık ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler 119
Şekil 4.12. Yağış miktarı ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler 120
Şekil 4.13. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa maksimum sıcaklık tahminleri için saçılım grafikleri 122
Şekil 4.14. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı maksimum sıcaklık tahminleri için saçılım grafikleri 123
Şekil 4.15. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa minimum sıcaklık tahminleri için saçılım grafikleri 125
Şekil 4.16. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı minimum sıcaklık tahminleri için saçılım grafikleri 126
Şekil 4.17. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa yağış miktarı tahminleri için saçılım grafikleri 131
Şekil 4.18. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı yağış miktarı tahminleri için saçılım grafikleri 132
Şekil 4.19. İki farklı senaryoya göre Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa ilçelerinin gelecek yıllar için tahmin edilen sıcaklık grafikleri 136
Şekil 4.20. İki farklı senaryoya göre İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı ilçelerinin gelecek yıllar için tahmin edilen sıcaklık grafikleri 137
Şekil 4.21. Hatay İlinde SSP2-4.5 ve SSP5-8.5 senaryolarına göre yakın (2020-2060) ve uzak (2060-2100) gelecek için yıllık yağış miktarında öngörülen değişim yüzdeleri 138
Şekil 4.22. MGM ölçüm istasyonlarından elde edilen verilerle hesaplanan güneş radyasyonu değerlerinin GEPA verileriyle karşılaştırması 140
Şekil 4.23. Ampirik ET_0 hesaplama yöntemlerinin karşılaştırılması 142
Şekil 4.24. Pamuk bitki örneklerinin yaprak alanlarının ImageJ® görüntü işleme programı ile hesaplanması 145

Şekil 4.25. 1. ürün mısır bitki örneklerinin yaprak alanlarının ImageJ® görüntü işleme programı ile hesaplanması.....147
Şekil 4.26. Pamuk ve biyokütle veriminin yakın ve uzak gelecek için karşılaştırılması 155
Şekil 4.27. Dane ve biyokütle veriminin yakın ve uzak gelecek için karşılaştırılması.157

SİMGELER ve KISALTMALAR DİZİNİ

SİMGELER

°C	: Derece Celsius
C’	: Performans İndeksi
cm	: Santimetre
cm^3	: Santimetreküp
d	: Wilmott Uyumluluk İndeksi
da	: Dekar
ET_0	: Referans Evapotranspirasyon
g	: Gram
ha	: Hektar
hPa	: Hektopaskal
kg	: Kilogram
kPa	: Kilopaskal
m	: Metre
m^2	: Metrekare
MJ	: Megajul
mm	: Milimetre
r	: Korelasyon Katsayısı
R^2	: Belirtme Katsayısı
s	: Saniye
t	: Ton
μ	: Aritmetik Ortalama
σ	: Standart Sapma

KISALTMALAR

ABD	: Amerika Birleşik Devletleri
CC	: Bitki Örtü Yüzeyi (Crop Canopy)
CMIP	: Birleşik Modeller Arası Karşılaştırma Projesi (Coupled Model Intercomparison Project)
CP	: Uzlaşık Programlama (Comprise Programming)
FAO	: Gıda ve Tarım Örgütü (Food and Agriculture Organization of the United Nations)
KİM	: Küresel İklim Modeli (Global Climate Model, GCM)
GEPA	: Güneş Enerjisi Potansiyel Atlası
ICCAP	: Kurak Alanlarda İklim Değişikliklerinin Tarımsal Üretime Etkisi (Impact of Climatic Change on Agricultural Production in Arid Areas)
IPCC	: Hükümetlerarası İklim Değişikliği Paneli (Intergovernmental Panel on Climate Change)

LASSO	: En Küçük Mutlak Daralma ve Seçim Operatörü (Least Absolute Shrinkage And Selection Operatör)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MGM	: Meteoroloji Genel Müdürlüğü
MLR	: Çoklu Doğrusal Regresyon (Multiple Linear Regression)
NRMSE	: Normalize Edilmiş Kök Ortalama Kareler Hatası (Normalized Root Mean-Square Error)
NSE	: Nash-Sutcliffe Verimlilik Katsayısı (Nash–Sutcliffe Efficiency coefficient)
PBIAS	: Yüzde Sapma Değeri (Percent Bias)
RCP	: Temsili Konsantrasyon Yolu (Representative Concentration Pathway
RF	: Rastgele Orman (Random Forest)
RMSE	: Kök Ortalama Kareler Hatası (Root Mean-Square Error)
RSR	: Kök Ortalama Kareler Hatası ile Gözlemlerin Standart Sapmasının Oranı (Ratio of RMSE to the Standard Deviation of the Observations)
SSPs	: Paylaşılan Sosyoekonomik Yollar (Shared Socioeconomic Pathways)
SVR	: Destek Vektör Regresyonu (Support Vector Regression)
TSS	: Taylor Yetenek Puanı (Taylor Skill Score)
UNEP	: Birleşmiş Milletler Çevre Programı (United Nations Environment Programme)
UNFCCC	: Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (United Nations Framework Convention on Climate Change)
USDA	: Amerika Birleşik Devletleri Tarım Bakanlığı (United States Department of Agriculture)
WCRP	: Dünya İklim Araştırma Programı (World Climate Research Programme)
WMO	: Dünya Meteoroloji Örgütü (World Meteorological Organization)
YSA	: Yapay Sinir Ağları

1. GİRİŞ

Günümüzde önemli bir sorun olan iklim değişikliği, özellikle sanayi devriminden sonra antropojenik faaliyetlerin neden olduğu sera gazı salınımındaki üstel artıştan kaynaklanan değişimler olarak kabul edilmektedir. Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesine (UNFCCC) göre iklim değişikliği; referans bir zaman periyodunda gözlenen doğal iklim değişikliğine ek olarak insan etkinlikleri nedeniyle atmosferde sera gazı miktarlarının artmasından dolayı iklimde oluşan değişiklik olarak tanımlanmıştır (Nnadi ve Carter, 2021).

Dünyanın belirli bölgelerinde uzun yıllar boyunca gözlemlenen atmosferik koşulların istatistiksel ortalaması iklim olarak ifade edilmektedir ve meteorolojik değişkenlerin en az 30 yıllık gözlem değerleri ile ilgili eğilimleri dikkate alınarak belirlenmektedir (Türkeş, 2008; Cael ve ark., 2023). Güneş radyasyonunu enerji kaynağı olarak kullanan iklim sistemi; biyosfer, litosfer, kriyosfer, hidrosfer ve atmosfer arasında gerçekleşen etkileşimleri ve çeşitli dış etkilerin neden olduğu değişimleri içeren karmaşık bir sistemdir (Baede ve ark., 2001). Bu dış etkiler; volkanik faaliyetler, güneş patlamaları, dünyanın yörüngesinde gerçekleşen değişimler ve atmosferde insan etkinlikleri nedeniyle meydana gelen değişikliklerdir (Fahey ve ark., 2017).

Atmosfer sistemi çeşitli yoğunluklarda bulunan gazlardan oluşmaktadır. Bu gazlardan en çok ısı tutma özelliğine sahip olanlar ise sera gazları olarak adlandırılmaktadır. Atmosferde bulunan başlıca sera gazları; karbondioksit (CO_2), su buharı (H_2O), nitröz oksit (N_2O), metan (CH_4), ozon (O_3), kloroflorokarbonlar (CFC), hidroflorokarbonlar (HFC) ve perflorokarbonlardır (PFC). Atmosferde belirli oranlarda bulunan bu gazlar, güneşten gelen kısa dalga boyuna sahip ışınımlara karşı geçirgen olup yeryüzünden yansıyan uzun dalga boyuna sahip ışınımlara karşı daha az geçirgen bir yapıya sahiptir. Bu özellikleri ile dünyadan yansıyan ısı enerjisinin atmosfer sistemi içerisinde kalması sağlanarak yeryüzü daha fazla ısınmakta ve su kütlelerinin donması engellenmektedir. Dünya üzerinde canlı ekosisteminin devamlılığı açısından oldukça önemli olan bu olay sera etkisi olarak adlandırılmaktadır (Gündoğan ve ark., 2015).

Atmosferde sera gazlarının olmaması durumunda, dünya yüzeyinin ortalama sıcaklığının 15°C yerine yaklaşık -18°C olacağı tahmin edilmektedir (Steinfeld ve ark., 2006; Birpınar, 2022). Ancak atmosferde sera gazı birikimindeki kontrolsüz artışlar, yeryüzünden yansıyan kızılötesi ışınımları atmosfer sistemi içerisine hapsederek pozitif

radyatif zorlamaya neden olmaktadır. Yerküre ve atmosfer arasındaki enerji dengesine insanlar tarafından yapılan bu pozitif katkı kuvvetlenmiş sera etkisi olarak adlandırılmaktadır (Gündoğan ve ark., 2015; Manabe, 2019). İklim değişikliğine neden olan antropojenik faaliyetler olarak fosil yakıtlarının kullanımının artması, ormanlık alanların yok edilmesi, tarımda sentetik gübre kullanımının artması ve sanayileşme ön plana çıkmaktadır (Canadell ve ark., 2021).

Güneşten dünyaya gelen ışınım ile dünyadan yansıyan ışınım farkı radyatif zorlama olarak adlandırılmaktadır. Radyatif zorlamayla sera etkisini artırarak küresel ısınmaya sebep olan sera gazları arasında en önemlisi atmosferdeki miktarı ve mevcudiyet süresi nedeniyle CO_2'dir. IPCC 6. Değerlendirme Raporunda atmosferdeki CO_2 birikiminin son 2 milyon yıla göre en yüksek değerine ulaştığı bildirilmiştir (IPCC, 2021). Ortalama olarak CO_2 emisyonlarında 1960-2000 arasında yıllık 1.5 ppm'lik artış görülürken, 2000-2010 arasında bu artış 2 ppm değerine ve 2010-2020 arasında ise 2.5 ppm değerine yükselmiştir (Birpınar, 2022). Ayrıca CO_2 ile karşılaştırıldığında 84 kat daha yüksek küresel ısınma potansiyeline sahip CH_4 ve 265 kat daha yüksek küresel ısınma potansiyeline değerine sahip N_2O konsantrasyonlarınında son 800 bin yıllık dönemin en üst seviyelerine çıktığı belirtilmiştir (IPCC, 2021).

Atmosferdeki sera gazlarının bu artışına bağlı olarak son 50 yıldaki küresel ısınma oranının, son 2000 yıldaki herhangi bir dönemden daha fazla olduğu bildirilmiştir (Liang ve ark., 2022). Dünya Meteoroloji Örgütü (WMO) raporlarında 2021 yılında küresel ortalama sıcaklığın sanayi öncesi döneme göre yaklaşık 1.1°C artış gösterdiği belirtilmiştir (WMO, 2022). Sıcaklıktaki bu artış nedeniyle okyanuslar ısınmakta ve buzullar eriyerek su seviyelerini arttırmaktadır. Buzullardaki erimenin en önemli göstergesi olan Arktik deniz buzullarının kapladığı alanın 1979'dan günümüze kadar yaklaşık 2 milyon km^2 azaldığı bildirilmiştir (Docquier ve ark., 2022). Küresel ortalama deniz seviyesinde meydana gelen artışın 1993-2002 yılları arasında 2.1 mm iken, 2013 yılından itibaren yıllık 4.5 mm'ye yükseldiği tespit edilmiştir (WMO, 2022).

Birleşmiş Milletler Çevre Programının (UNEP) sunduğu rapora göre, sera gazı emisyonlarının artış hızının düşürülememesi durumunda 2100 yılında küresel sıcaklığın sanayi öncesi döneme göre 2.7°C artacağı tahmin edilmektedir (UNEP, 2021). İklim değişikliğine bağlı olarak gerçekleşebilecek olan sıcaklık artışı, bağıl nem oranını azaltarak atmosferin nem yükleme kapasitesini arttıracaktır. Böylelikle hava daha yüksek

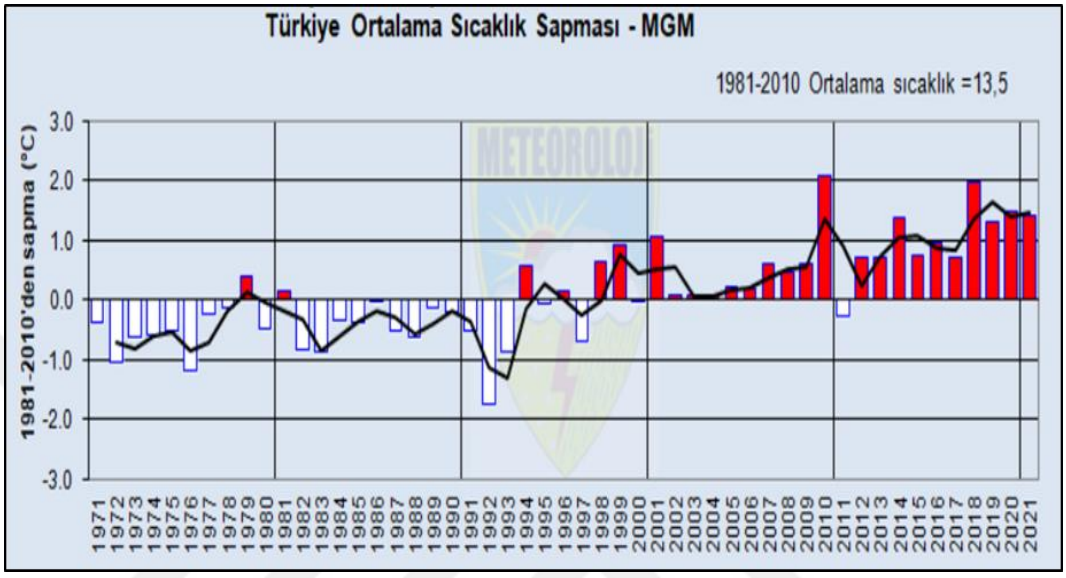
bir doygunluk oranına sahip olacaktır. Bu durum bulut örtüsünün azalmasına ve dolayısıyla yağışın azalmasına yol açacaktır. Böylece yağış daha az sıklıkta ancak daha yoğun bir şekilde, kurak dönemler ise daha uzun ve daha sık meydana gelecektir (Held ve Soden, 2006; Dubrovský ve ark., 2009; O'Gorman ve Schneider, 2009; Kanber ve ark., 2019). Dünya genelinde beklenen olumsuz ve aşırı hava olaylarındaki artışların yanı sıra su kaynaklarında meydana gelecek ciddi azalmalar ile doğrudan veya dolaylı olarak yeryüzünde insan hayatı ve ekolojik sistemlerde birçok açıdan olumsuz etkiler görülecektir (Kenarsari ve ark., 2013; Türkeş, 2020). İklim değişikliğine bağlı olarak yaşanan afetler nedeniyle 2000-2019 yılları arasında 475 binden fazla can kaybı yaşanmış ve yaklaşık 2.56 trilyon ABD doları ekonomik kayıp gerçekleşmiştir (Eckstein ve ark., 2021).

Küresel sıcaklığın 1°C yükselmesi halinde kuzey yarım kürenin güneyinde bulunan kurak iklim kuşaklarının yaklaşık 250 km kadar kuzeye doğru hareket etmesi beklenmektedir. Bu nedenle ülkemizin de içinde bulunduğu Akdeniz Havzası iklim değişikliğinden en çok etkilenecek bölgelerden biri olarak varsayılmaktadır (Giorgi, 2006; IPCC, 2014; Şen, 2022). Yapılan araştırmalara göre, Akdeniz havzasında 2050 yılına kadar sıcaklıklarda 2-3°C artış ve yağış miktarlarında %10-20 arasında azalma beklenmektedir (Bangash ve ark., 2013). Yağıştaki bu azalmaların 21. yy sonlarına doğru ise %20-30 arasında olacağı tahmin edilmektedir (Kanber ve ark., 2019).

Özellikle kurak iklim kuşaklarının kuzeye hareketi sonucunda, ülkemizin güneyinde bulunan bölgelerde kuraklıkların daha da şiddetlenip artacağı tahmin edilmektedir (Şen, 2022). Seyhan Havzasında gerçekleştirilen iklim değişikliğinin tarımsal üretime etkisinin araştırıldığı çalışmada 2070 yılında su kaynaklarının %30 azalacağı bildirilmiştir. Ayrıca yıllık yağış miktarının %25 oranında azalacağı, aylık ortalama sıcaklıkların 3°C ve potansiyel evapotranspirasyonun %15 oranında artacağı tahmin edilmiştir (Kanber ve ark., 2008).

Ülkemizin ortalama sıcaklıkları 1998 yılından günümüze kadar 2011 yılı haricinde sürekli artış göstermiştir. Sıcaklık ortalaması 2020 yılında 14.9°C olarak gözlemlenmiştir. Bu değer 1981-2010 ortalamasının (13.5°C) 1.4°C üzerindedir (Şekil 1.1). Ülkemizin alansal yağış ortalaması ise 2021 yılında 524.8 mm ölçülmüş ve 1981-2010 normalinin (573.4 mm) %9 altında olduğu belirlenmiştir. Sıcaklık artışına bağlı olarak, son yıllarda gözlenen aşırı hava olaylarının sayılarındaki artış eğiliminin de devam

ettiği bildirilmiştir (MGM, 2022). Türkiye genelinde ortalama sıcaklığın 2016-2040 dönemi senaryolarına göre sıcaklık artışının 0.5°C-1.5°C arasında olacağı tahmin edilmektedir. Özellikle yaz mevsiminde Türkiye'nin kuzeyi dışındaki bütün bölgelerde 2°C'ye varan sıcaklık artışlarının olabileceği öngörülmektedir (Anonim, 2021).



Şekil 1.1. Türkiye'nin yıllık ortalama sıcaklık sapması

İklim değişikliğine karşı gerekli olan önlemlerin hızla alınmaması durumunda ülkemizde orman yangınlarının artması, taşkın ve kuraklıkların daha sık görülmesi, kuraklık sıklıklarının artması ile su kaynaklarının azalması ve tarımsal üretimde verim kaybı gibi olumsuz etkilerin gerçekleşmesi beklenmektedir. Özellikle tarım sektörü, sıcaklık ve yağıştan doğrudan etkilenmesi nedeniyle iklim değişikliğinin en çok etkileyeceği sektörlerin başında gelmektedir (Dumrul ve Kılıçaslan, 2017). İklim değişikliği bitkinin gelişimini, sulama ihtiyacını, ekim alanını ve özellikle verimini etkileyebilmektedir (Rahman ve ark., 2018). Yapılan araştırmalarda iklim değişikliğinin küresel çapta 2050 yılına kadar bitkisel üretimde %17'lik bir düşüşe neden olabileceği bildirilmiştir (Nelson ve ark., 2013). İklim değişikliğinin tarım üzerindeki olumsuz etkilerini azaltmak için, iklim değişikliğiyle mücadeleye yönelik politika, strateji, plan ve programların oluşturulması büyük önem taşımaktadır (Dumrul ve Kılıçaslan, 2017).

İklim değişikliği ile küresel mücadele için 2015 yılında imzalanan Paris İklim Anlaşması'na göre sıcaklık artışının sanayi öncesi döneme göre 2°C'nin altında tutulması ve en fazla 1.5°C ile sınırlandırılması hedeflenmektedir (Rogelj ve ark., 2016; Vicedo-

Cabrera ve ark., 2018). Bu amaçla, sera gazı emisyonlarının 2030 yılına kadar %55 oranında azaltılması gerekmekte ve 2050 yılında salınan emisyonların doğal yutak alanlar tarafından tutulan miktara eşit olmasının (karbon nötr) sağlanması gerekmektedir (Rečka ve ark., 2023).

İklim değişikliğiyle mücadele kapsamında uygulanabilecek en önemli stratejiler; sera gazı emisyonlarının azaltılması ve iklim değişikliğinin etkilerine uyum (adaptasyon) sağlanmasıdır. İklim değişikliğinin tüm bu riskleri ve Paris İklim Anlaşması hedefleri göz önünde bulundurularak; yenilenebilir enerji kaynaklarının kullanılması, nüfus planlaması ve iklim değişikliğini dikkate alan kalkınma modellerinin oluşturulması, kurak dönemler için ihtiyaç duyulacak suyu karşılayabilecek kapasitenin belirlenerek gerekli su depolama yapılarının oluşturulması, artan gıda talebini karşılayabilmek için tarımda iklim değişikliğine uyum stratejilerinin geliştirilmesi ve iklim değişimine adaptasyon stratejileri oluşturabilmek için gelecekteki olası iklim değişikliği tahminlerinin doğru bir şekilde elde edilebilmesi gerekmektedir (Zahmatkesh ve ark., 2014).

Küresel iklim modelleri (KİM); atmosfer, okyanus, buz ve kara yüzeyleri arasında gerçekleşen süreçleri dikkate alarak küresel iklim sisteminin artan sera gazına olan tepkisinin benzetimini yapmak amacıyla kullanılmaktadırlar (Tofiq ve Güven, 2014; Hamed ve ark., 2022a). Dünya İklim Araştırma Programı (WCRP), küresel ölçekte olası iklim değişikliklerini daha iyi anlayabilmek için Birleşik Modeller Arası Karşılaştırma Projesini (CMIP) başlatmıştır (Eyring ve ark., 2016). CMIP projesi, CMIP1 ile 1995 yılında başlamış ve günümüzde CMIP6 ile devam etmekte olan iklim değişikliği değerlendirme çalışmaları için en güvenilir uluslararası veri kaynağı olarak kabul edilmektedir (Wang ve ark., 2021; Song ve Yan, 2022). CMIP6 önceki sürümlerinden farklı olarak; sera gazı emisyon artış senaryoları (RCP) ile birlikte sosyoekonomik eğilimleri ve teknolojik gelişmeleri göz önünde bulundurmaktadır. Paylaşılan Sosyoekonomik Yollar (SSP) olarak bilinen bu senaryolar SSPx-y olarak adlandırılmaktadır (Meinshausen ve ark, 2020). SSPx, senaryoların temelini oluşturan sosyo-ekonomik eğilimleri tanımlarken, y radyatif zorlamayı (W m^{-2}) ifade etmektedir. SSP2-4.5 senaryosu mevcut CO_2 emisyonlarının yüzyılın ortasında azalmaya başlayacağını ve yüzyıl sonunda küresel ortalama sıcaklık artışının 2.7°C olacağını öngörmektedir. En kötü senaryo olarak kabul edilen SSP5-8.5 ise, CO_2 emisyonlarının

yüzyılın ortasında neredeyse iki katına çıkacağını ve sıcaklık artışının yaklaşık olarak 4.4°C olmasını öngörmektedir (Hausfather, 2018; IPCC, 2022).

Ancak, bu modellerin kullanımında karşılaşılan birçok problem bulunmaktadır. Bunlardan biri çalışma alanına uygun olan modeli belirleyebilmektir. Genellikle farklı modellerin birleşimi önerilmektedir. Ancak, bu yöntemin çok büyük miktarlarda veri kullanımını gerektirmesi ve çok zaman alması nedeniyle iklim değişkenlerini referans dönemde en düşük hata ile tahmin edebilme performanslarına göre uygun KİM seçimi yaygın olarak kullanılmaktadır (Cannon, 2015; Salman ve ark., 2018; Nashwan ve ark, 2020). KİM'lerin kullanımında karşılaşılan bir diğer problem, yaklaşık 200 km'nin altındaki mekansal ölçeklerde elde edilen tahminlerin referans gözlem veri setleri ile değerlendirildiklerinde genellikle başarısız olmasıdır (Pang ve ark., 2017; Shiru ve ark., 2019). Bu nedenle, küçük bir havzada veya tarım alanı ölçeğinde gerçekleştirilecek çalışmalarda iklim değişikliğinin etkisinin KİM ile değerlendirilebilmesi için ölçek küçültme yöntemleri yaygın olarak kullanılmaktadır (Sa'adi ve ark., 2017; Sachindra ve ark., 2019; Navarro-Racines ve ark., 2020).

Gelecekteki iklim değişikliğinin bitki gelişimi üzerindeki etkisini tahmin etmek ve adaptasyon stratejileri geliştirmek için KİM'ler, bitkisel üretim modelleri ile birlikte kullanılmaktadır (Chen ve ark., 2019; Anwar ve ark., 2020). Bitkisel üretim modelleri; bitkilerin büyümesini, gelişmesini ve verimini tahmin ederek çeşitli senaryolar altında bitkisel üretimde nasıl değişiklikler olabileceğini gösterebilmektedir. Böylelikle daha verimli su kullanımı, ekim zamanının ayarlanması ve hastalık kontrolü gibi iklim değişikliğine karşı gerekli adaptasyon stratejilerinin belirlenmesine yardımcı olabilmektedirler. Ayrıca laboratuvar veya saha araştırması ile karşılaştırıldığında; bu modeller düşük maliyeti, yüksek verimliliği ve kolay kontrol edilebilir olması nedeniyle büyük avantaj sağlamaktadırlar (Moradi ve ark., 2014; Anwar ve ark., 2020).

İklim değişikliği, tarım başta olmak üzere birçok sektördeki olumsuz etkileri nedeniyle günümüzde küresel bir sorun haline gelmiştir. Bu nedenle, sıcaklık ve yağış değişimlerinin bölgesel ve zamansal ölçeklerde değerlendirilmesi oldukça önemlidir. Tarımsal potansiyeli yüksek olan Hatay ilinde sera gazı salınımındaki artışları esas alan senaryolara dayalı olarak geleceğe yönelik tahminler oluşturmak, iklim değişikliğinin olumsuz etkilerine karşı gerekli adaptasyon stratejileri oluşturulabilmesi için büyük avantaj sağlayabilecektir. Bu amaçla Hatay ilinde farklı iklim senaryoları kapsamında

(SSP2-4.5 ve SSP5-8.5) iklim değişikliğinin bitkisel üretime etkilerinin önceden tahmin edilmesi oldukça önem taşımaktadır. Bu çalışmada iklim değişikliği senaryo çıktıları ve arazi koşullarına kalibre edilmiş bitki verim tahmin modeli kullanılarak, iklim değişikliğinin Hatay ilinin Kırıkhan ilçesinde yetiştirilen pamuk ve 1. ürün mısır bitkisinin verimine olası etkileri tahmin edilmiş ve değerlendirilmiştir. Ülkemizde bu senaryolara göre yapılmış pek çok çalışma bulunmasına rağmen, Hatay ilinde bu konuda yapılmış herhangi bir çalışmaya rastlanılmamıştır. Bu nedenle elde edilen bilgiler, bu model ve senaryolar kullanılarak yapılan ilk çalışma olması açısından önemlidir. Dolayısıyla çalışma bulguları iklim değişikliğinin olumsuz etkilerine karşı Hatay ili için gerekli önlem ve stratejilerin oluşturulmasında, gelecekte yapılacak iklim çalışmalarında, yetkili birimlerce oluşturulan kuraklık ve taşkın eylem planlarının geliştirilmesinde ve bitkisel üretim yapan firmalar için önceden alınacak tedbirler açısından önemli bir bilgi kaynağı olacaktır.

Bu çalışmanın amacı, Türkiye'nin güneyinde yer alan ve ülkenin önemli tarım merkezlerinden olan Hatay ilinde iklim değişikliğinin CMIP6 KİM verileri kullanılarak farklı senaryolara (SSP2-4.5 ve SSP5-8.5) göre yakın (2020-2060) ve uzak (2060-2100) gelecek dönemler için sıcaklık ve yağış miktarına olası etkilerinin tahmin edilmesidir. Bununla birlikte, elde edilen bu tahminleri bitkisel üretim modelinde kullanarak iklim değişikliğinin Hatay ilinin Kırıkhan ilçesinde stratejik ve önemli tarım ürünleri olan pamuk ve 1. ürün mısır bitkilerinin verimine olası etkilerinin araştırılmasıdır.

2. ÖNCEKİ ÇALIŞMALAR

2.1. YSA ile Meteorolojik Verilerin Tahmini ile İlgili Yapılan Çalışmalar

Ustaoğlu ve ark. (2008), ileri beslemeli ve geri yayılımlı YSA yöntemini kullanarak günlük ortalama, maksimum ve minimum sıcaklık zaman serilerini tahmin etmek ve bu tahminleri gözlem verileriyle karşılaştırarak kullanılabilirliklerini değerlendirmek amacıyla yürüttükleri çalışmada, Türkiye'nin Marmara bölgesinde bulunan Geyve ve Sakarya meteoroloji gözlem istasyonlarının verilerini kullanmışlardır. Elde edilen model çıktılarını korelasyon katsayısı (r) ve kök ortalama kareler hatası (RMSE) istatistiksel performans kriterleri kullanarak gözlem verileri ile karşılaştırmışlardır. Değerlendirmeler sonucunda maksimum sıcaklık (r=0.91-0.93 ve RMSE=3.49-3.75) ve minimum sıcaklık (r=0.94-0.95 ve RMSE=2.48-2.51) tahminleri için YSA'nın kullanılabileceğini belirtmişlerdir.

Dahamsheh ve Aksoy (2009), kurak bölgeler için ileri beslemeli ve geri yayılımlı YSA ile aylık yağış tahmin performansını araştırmışlardır. Bu amaçla, Ürdün'deki farklı coğrafi bölgelerde bulunan dört meteoroloji istasyonuna ait verileri kullanmışlardır. Çalışma sonucunda YSA tahminlerinin doğrusal regresyon modellerine göre daha iyi tahminler gerçekleştirdiğini belirtmişlerdir. Ayrıca, yağıştaki değişkenliğin fazla olmasının YSA'dan elde edilen tahminlerin performans başarısını azalttığını açıklamışlardır.

Ghanbarzadeh ve ark. (2009), meteorolojik verilere dayalı YSA kullanarak günlük güneş radyasyonunu tahmin etmeyi amaçlamışlardır. Çalışmada girdi verisi olarak İran'ın Dezful şehrinde bulunan Safiabad istasyonunun gözlem verilerini kullanmışlardır. YSA modelini, geri yayılım algoritması kullanılarak eğitmiş ve test veri setleri kullanarak değerlendirmişlerdir. Sonuçlara göre, günlük ortalama sıcaklık, bağıl nem ve güneş ışığı saatlerinin girdi olarak kullanıldığı modelden %8.84 mutlak ortalama yüzde hata ve 0.004 ortalama karesel hata değerleri ile başarılı tahminler elde edildiğini açıklamışlardır.

Kim ve Pachepsky (2010), bir istasyonun eksik günlük yağış verilerini komşu istasyonlardan elde ettiği gözlemleri kullanarak YSA ile tahmin etmişlerdir. Modellerin performansını korelasyon katsayısı ve RMSE kullanarak karşılaştırmışlardır. Çalışma sonucunda elde ettikleri sonuçlara (r=0.572-0.928 ve RMSE=1.84-5.60) dayanarak

gözlem kayıtlarında problem olan istasyon verilerinin yeniden oluşturulmasında YSA yönteminin iyi bir alternatif olduğunu bildirmişlerdir.

Saplıoğlu ve Çimen (2010), günlük yağış miktarını YSA kullanarak tahmin etmişler ve elde edilen sonuçları ağırlıklı ve harmonik ortalama yöntemleri ile karşılaştırmışlardır. Bu amaçla ABD'nin Portland kentinde bulunan dört farklı yağış gözlem istasyonuna ait günlük yağış verilerini kullanmışlardır. Model oluşturulurken 2000-2009 yılları arasında her bir gözlem istasyonundan alınan veriler dikkate alınmıştır. Hesaplamalar sonucunda YSA modelinin en küçük hata değerlerini (NSE=0.907-0.950 ve MSE=21.8-40.1) verdiği açıklanmıştır. Hidrometeorolojik olarak benzer ve birbirine yakın istasyonlarda eksik yağış verilerinin tamamlanması için, YSA modellerinin ağırlıklı ve harmonik ortalama yöntemlerinden daha başarılı olduğunu açıklamışlardır.

Moustris ve ark. (2011), YSA kullanarak aylık maksimum, minimum, ortalama ve kümülatif yağış toplamlarını tahmin etmeye çalışmışlardır. Yağış verileri olarak Yunanistan'da bulunan dört meteoroloji istasyonuna ait gözlemleri kullanmışlardır. İstatistiksel analizlerden elde edilen bulgular, YSA yönteminin kabul edilebilir yağış tahminleri sağladığını (R^2=0.60) ve bu sonuçların klasik regresyon yöntemleri kullanılarak elde edilen tahminlerden daha başarılı olduğunu ortaya koymuşlardır.

Roman ve ark. (2012), komşu istasyonlara ait yağış verilerini kullanarak ölçümleri eksik olan bir gözlem istasyonunun verilerini tahmin etmek için YSA kullanarak bir model oluşturmuşlardır. Çalışma sonucunda YSA ile oluşturulan modelin (r=0.95-0.96, RMSE=4.64-6.68 ve NSE=0.90-0.91) geleneksel yöntemlerden (aritmetik ortalama, normal oran ve ters mesafe) daha başarılı olduğunu açıklamışlardır.

Terzi ve Çevik (2012), Isparta istasyonuna ait aylık yağışların YSA kullanılarak tahmin edilmesi için farklı modeller oluşturmuşlardır. Bu amaçla Isparta istasyonuna komşu Senirkent, Uluborlu, Eğirdir ve Yalvaç meteorolojik gözlem istasyonu verilerini kullanmışlardır. Çalışma sonucunda dört istasyon verileri kullanılarak oluşturulan YSA modelinin tahmin performansının (R^2=0.73-0.83) başarılı olduğunu belirtmişlerdir.

Mehdizadeh (2018), uzun dönemli aylık sıcaklık tahmin için YSA, destek vektör makinesi (SVM) ve çok değişkenli uyarlanabilir regresyon eğrilerine dayalı modellerin performansını araştırmıştır. Bu amaçla İran genelindeki elli istasyonun uzun dönem aylık sıcaklıklarını kullanmıştır. Modellerden elde edilen sonuçlara göre, YSA'nın uzun dönemli aylık minimum (RMSE=0.60-5.00) ve maksimum (RMSE=0.19-6.72)

sıcaklıkları tahmin etmede diğer modellerden daha iyi performans gösterdiğini açıklamıştır.

Süzülmüş (2019), Gaziantep'te aylık ortalama sıcaklıkları tahmin etmek için coğrafi değişkenlere ve meteorolojik verilere dayalı üç farklı yapay sinir ağı modelinin performansını değerlendirmiştir. Elde edilen sonuçlara göre, çok katmanlı algılayıcı modelinin R^2 değerini 0.99, ortalama mutlak yüzde hata değerini ise 2.38 olarak belirlemiş ve bu modelin sıcaklık tahminlerinde güvenle kullanılabileceğini bildirmiştir.

Kumaş ve ark. (2020), Antalya ili için YSA kullanarak ortalama aylık hava sıcaklığını modellemişlerdir. Modelin eğitimi için geri yayılım algoritmasını kullanmışlardır. Çalışma sonucunda aylık ortalama sıcaklık için modellerin R^2 değerini 0.94-0.99 aralığında hesaplamışlardır. Elde ettikleri sonuçlara göre YSA'nın ortalama hava sıcaklığını tahmin etmede oldukça başarılı olduğunu belirtmişlerdir.

Perera ve ark. (2020), Suudi Arabistan'ın Tabuk şehrindeki minimum ve maksimum sıcaklığı tahmin etmek için YSA algoritmalarını değerlendiren bir çalışma yürütmüşlerdir. Çalışma sonucunda minimum sıcaklık için r değerini 0.97 ve maksimum sıcaklık için r değerini ise 0.94 olarak hesaplamışlardır.

Dada ve ark. (2021), yağış tahmini için YSA modellerinin kullanılabilirliğini değerlendirmişlerdir. Değerlendirme sonucunda ileri beslemeli yapay sinir ağı modelinin yıllık RMSE değerini ortalama 7.09 olarak hesaplamışlardır. Sonuçlara göre YSA algoritmalarının yıllık yağış tahmini için kullanımının güvenilir olduğunu bildirmişlerdir.

Hanoon ve ark. (2021), Malezya'nın Terengganu eyaletinde hava sıcaklığı ve bağıl nemi tahmin etmek için farklı makine öğrenimi algoritmalarını değerlendirmişlerdir. Elde ettikleri sonuçlara göre, çok katmanlı yapay sinir ağı modelinin günlük sıcaklık ve bağıl nemi sırasıyla 0.71 ve 0.63 r değeri ve ile iyi performans gösterdiğini belirlemişlerdir. Ayrıca, aylık sıcaklığı (r=0.85) tahmin etmede bu modelin oldukça başarılı olduğunu açıklamışlardır. Ayrıca, oluşturulan modellerin sıcaklık ve bağıl nem için hem günlük hem de aylık tahminler için kullanılabileceğini açıklamışlardır.

Katipoğlu ve Acar (2021), YSA kullanarak eksik hava sıcaklığı verilerini tamamlamayı amaçladıkları çalışmada, eksik verisi bulunan Horasan meteoroloji istasyonuna komşu istasyonlardan elde edilen sıcaklık verilerini model girdileri olarak kullanmışlardır. Çalışma sonucunda istatistiksel değerlendirme ölçütleri olan R^2 değerini 0.99 ve ortalama mutlak hata (MAE) değerini ise 0.03 olarak hesaplamışlardır. Bu

sonuçlara göre YSA ile oluşturulan modellerin sıcaklığı yüksek doğrulukta tahmin edebildiğini açıklamışlardır.

Nguyen ve ark. (2021), günlük ve aylık yağış miktarının tahmini için YSA kullanan bir model geliştirmeyi hedeflemişlerdir. Elde ettikleri sonuçlara göre günlük yağış için r değerini 0.80 olarak hesaplamışlardır. Çalışma sonuçlarına dayanarak YSA'nın yağış tahmininde güvenle kullanılabileceğini bildirmişlerdir.

Sevinç ve Kaya (2021), meteorolojik verilere dayalı sıcaklık tahmini için uzun kısa süreli bellek (LSTM) ve Bütünleşik Otoregresif Hareketli Ortalama (ARIMA) derin öğrenme yöntemlerinin uygulanabilirliğini değerlendirmişlerdir. Bu amaçla Türkiye'nin Diyarbakır ilinin 2014-2020 yıllarına ait sıcaklık verilerini kullanmışlardır. Modellerin tahmin sonuçlarına göre LSTM modelin R^2 değerini 0.96 olarak belirlenmişlerdir Çalışma sonucunda, makine öğrenmesi yöntemleri ile yapılacak sıcaklık tahminlerinin başarıyla kullanılabileceği sonucuna varmışlardır.

Diez ve ark. (2022), İspanya'nın Castilla ve Leon bölgelerindeki gözlem istasyonlarından elde edilen meteorolojik verileri kullanarak ölçümü bulunmayan konumlar için YSA ile maksimum ve minimum sıcaklığın tahmin edilebilirliğini araştırmışlardır. Bu amaçla farklı modeller geliştirmişlerdir. Oluşturdukları modellerden elde edilen tahmin sonuçlarını RMSE ve R^2 istatistiksel ölçütlerini kullanarak değerlendirmişlerdir. En iyi model çıktılarına göre maksimum sıcaklık (RMSE=0.68 ve R^2=0.97) ve minimum sıcaklık (RMSE=0.83 ve R^2=0.89) tahminlerinin oldukça başarılı olduğunu belirtmişlerdir.

Ikpang ve ark. (2022), Nijerya'da aylık yağış tahmini için en uygun modeli belirlemek amacıyla YSA modelleri arasında karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Oluşturulan model için RMSE değerini 0.003 ve MAE değerini 0.029 olarak hesaplamışlardır. Ayrıca bu sonuçlara göre yağış tahmini için yapay sinir ağı modellerinin güvenle kullanılabileceğini bildirmişlerdir.

Karabulut ve Topçu (2022), Türkiye'nin Kars ilinde 2010-2021 yılları arasındaki meteorolojik gözlemler kullanılarak yapay sinir ağı tabanlı LSTM ile ortalama sıcaklığın tahmin edilebilirliğini değerlendirmişlerdir. Performans değerlendirme sonuçlarına göre oluşturdukları modelin günlük (R^2=0.994 ve RMSE =0.498) ve aylık (R^2=0.987 ve RMSE =0.482) sıcaklık tahminlerinin oldukça başarılı olduğunu belirlemişlerdir. Ayrıca bu modellerin su kaynakları yönetimi, kara-atmosfer etkileşimleri ve tarım gibi

uygulamalar için çok önemli olan sıcaklık değerinin tahmini için kullanılabileceğini bildirmişlerdir.

Khastagir ve ark. (2022), Batı Avustralya'da uzun dönem ilkbahar yağışlarının tahmininde YSA ve MLR modellerinin kullanılabilirliklerini değerlendirmişlerdir. Değerlendirme sonucunda YSA modellerinin (d=0.38-0.95), MLR (d=0.26-0.47) gibi doğrusal modelleme tekniklerine kıyasla daha iyi tahmin kabiliyeti gösterdiğini tespit etmişlerdir.

Papailiou ve ark. (2022), eksik yağış verilerini günlük zaman diliminde tahmin etmek amacı ile YSA kullanarak modeller oluşturmuşlardır. Çalışmada komşu istasyonlardan gözlemlenen verileri esas alarak Yunanistan'ın Hanya bölgesi için günlük yağış zaman serileri oluşturmayı amaçlamışlardır. Elde edilen sonuçları çoklu doğrusal regresyon modeli (MLR) ile karşılaştırmış ve YSA (RMSE=1.22-2.42) ile elde edilen tahminlerin daha başarılı olduğunu açıklamışlardır. Ancak modellerin oluşturulma sürelerinin uzun olmasının YSA'nın en büyük dezavantajı olduğunu ifade etmişlerdir.

Pratomo ve ark. (2022), Endonezya'da geçmiş hava durumu verileri ile YSA kullanarak günlük yağış miktarını tahmin etmeyi amaçlamışlardır. YSA modelinden elde edilen tahminleri, gerçek yağış verileri ile karşılaştırarak değerlendirmişlerdir. Değerlendirme sonucunda bir yıl için gerçekleşen ve tahmin edilen yağış miktarı arasındaki ortalama mutlak farkı 3.313 mm olarak hesaplamışlar ve oluşturulan modelden elde edilen tahminlerin kabul edilebilir olduğunu bildirmişlerdir.

Ara ve ark. (2023), Bangladeş'te yaptıkları çalışmada yağış miktarını tahmin etmek için YSA modelinin kullanılabilirliğini değerlendirmişlerdir. Çalışma sonucunda YSA modellerinin (R^2>0.79), yağış miktarını tahmin etmek için doğrusal regresyon ve doğrusal olmayan regresyon gibi diğer modellerden daha üstün olduğu açıklamışlardır.

Hudnurkar ve Rayavarapu (2023), Hindistan'da gerçekleştirdikleri çalışmada YSA kullanarak yağış miktarını doğru bir şekilde tahmin etmeyi amaçlamışlardır. Değerlendirme sonucunda oluşturdukları modelin R^2 değerini 0.66 olarak belirlemişlerdir. Ayrıca YSA kullanılarak yağış tahmin modeli oluşturma yaklaşımının yüksek yağış değişkenliğine sahip bölgeler için kullanılabilir olduğunu açıklamışlardır.

Shrivastava ve ark. (2023), Hindistan Yeni Delhi'de sıcaklık değerlerinin doğru tahmin edilmesinde yapay sinir ağlarının etkinliğini araştırmışlardır. Çalışmanın sonunda, oluşturulan modelin sıcaklık değerlerini (R^2=0.93 ve MSE=1.473) doğru bir

şekilde tahmin edebildiğini belirlemişlerdir. Ayrıca tarım, enerji yönetimi ve afete hazırlık gibi çeşitli sektörler için önemli etkileri olabilecek hava tahmini için makine öğrenimi tekniklerinden yararlanmanın önemli olduğunu açıklamışlardır.

2.2. Küresel İklim Modelleri ile İlgili Yapılan Çalışmalar

Bozkurt ve Sen (2013), Fırat-Dicle Havzasında iklim değişikliğinin gelecekteki olası etkilerini, farklı KİM ve emisyon senaryolarının ölçek küçültme uygulanmış çıktılarını kullanarak araştırmışlardır. Tüm senaryo simülasyonları sonucunda, havza genelinde kış mevsimi yüzey sıcaklığında artışların gerçekleşebileceği belirlenmiş ve bu artışların yüksek bölgelerde daha fazla olabileceğini bildirmişlerdir. Yüzyılın sonunda ise yıllık sıcaklıkta 6.1°C'lik artışın görülebileceğini öngörmüşlerdir.

Dubrovský ve ark. (2014), Akdeniz Havzasında iklim değişikliğinin olası etkilerini KİM kullanarak araştırmışlardır. Akdeniz Havzasının tüm bölgeleri için tüm mevsimlerde sıcaklık artışı beklenebileceğini; en yüksek artışların yaz aylarında ve en düşük artışların ise kış aylarında meydana gelebileceğini tahmin etmişlerdir. Ayrıca yıllık değişim açısından, Akdeniz bölgesinde (kuzeyden güneye) yağışta %5-30'luk bir düşüş beklendiğini açıklamışlardır. Sıcaklık artışları ile birlikte yağışların azalacağı dikkate alındığında, önümüzdeki yıllarda kuraklık riskinde önemli bir artış olabileceğini öngörmüşlerdir.

Görgüner ve ark. (2019), Gediz Havzası için ölçeği küçültülmüş iklim değişkenlerini analiz etmiş ve geçmiş değerlerle karşılaştırarak değerlendirmişlerdir. Çalışmanın sonucunda 2017-2044 yılları için havza sıcaklıklarında önemli ölçüde artan bir sıcaklık eğilimi olduğunu açıklamışlardır. Bununla birlikte, yüzyıl ortası (2045–2072) ve yüzyıl sonu (2073–2100) dönemleri için yıllık ortalama sıcaklıkta sırasıyla 1.1°C ve 2.2°C'lik sıcaklık artışı olabileceğini tahmin etmişlerdir. Ayrıca RCP8.5 senaryolarının, RCP4.5 senaryolarına (0.5°C) kıyasla ortalama olarak havza ölçeğindeki sıcaklıklarda daha büyük bir artış (1.5°C) tahmini ürettiğini bildirmişlerdir.

Danandeh Mehr ve ark. (2019), Türkiye'nin Ankara ilinde üç farklı KİM'in bölgesel olarak küçültülmüş çıktılarını kullanarak meteorolojik kuraklık analizi gerçekleştirmişlerdir. Bu amaçla, RCP4.5 ve RCP8.5 sera gazı senaryoları kapsamında standartlaştırılmış yağış indeksi ve standartlaştırılmış yağış evapotranspirasyon indeksi değerlerini hesaplamışlardır. Tahmin sonuçlarına göre, 2016-2040 yakın gelecek dönemi

için daha az kuraklık olayı olacağını öngörmüşlerdir. RCP4.5 senaryosuna göre, yakın geleceğin ikinci yarısında kuru dönemlerin baskın olacağını ve RCP8.5 senaryosunda ise, kurak dönemlerin tüm yakın gelecek dönem boyunca eşit bir şekilde dağılacağını öngörmüşlerdir.

Homsi ve ark. (2020), Suriye'de iklim değişikliği nedeniyle meydana gelebilecek yağış miktarlarındaki olası değişimleri değerlendirmişlerdir. Sonuçlara göre yağıştaki yıllık değişimlerin; RCP4.5, 6.0 ve 8.5 için %-30-85.2 oranında ve RCP 2.6 için %0.0-%30 oranında azalmalar olabileceğini tahmin etmişlerdir.

Li ve ark. (2020), Moğol Platosu için yaptıkları araştırmada uygulanabilir simülasyon modelini değerlendirmek için 19 KİM'den elde edilen yağış ve sıcaklık verilerini kullanmışlardır. Çalışma sonuçlarına göre, sıcaklık artışlarının hem RCP4.5 hem de RCP8.5 senaryolarında belirgin olduğu ve eğilimlerin kötümser senaryoda daha büyük olacağını açıklamışlardır. Moğol Platosu için hesapladıkları yıllık kuraklık indeksi değerlerinin gelecekte artan kuraklığa işaret ettiğini bildirmişlerdir. RCP4.5'e kıyasla RCP8.5'te kuraklık sıklığının arttığını, bu durumun kuraklığın sera gazı salınımındaki artışla daha şiddetli olacağını öngörmüşlerdir. İki senaryoda da kuraklık sıklığı 21. yy sonunda en yüksek seviyede olacağını ve zamanla artış gösterebileceğini açıklamışlardır. Son olarak kuraklık sıklığının doğudan batıya doğru artış gösterebileceğini bildirmişlerdir.

Bağçaci ve ark. (2021), Türkiye genelinde aylık yağış ve sıcaklık açısından CMIP5 ve CMIP6 senaryolarının çıktılarını karşılaştırmışlardır. Sonuçlara göre, CMIP6 çıktılarının özellikle yağış için istatistiki doğruluğu açısından CMIP5'ten daha iyi performans gösterdiğini belirtmişlerdir. Yazın sıcaklık artışının 6.5°C'ye kadar artış gösterebileceği ve sonbahara doğru yağışlardaki azalmanın %40'a kadar ulaşabileceğini tahmin etmişlerdir.

Iqbal ve ark. (2021), Güneydoğu Asya için 35 CMIP6 KİM'in 1975-2014 geçmiş dönem yağış referans verilerine uyumunu değerlendirmeyi ve çok kriterli karar verme yöntemi ile en başarılı olan modeli belirlemeyi amaçlamışlardır. KİM'lerin başarı sıralaması için dört farklı istatistiksel metriğe dayalı uzlaşık programlama (CP) yöntemini kullanmışlardır. Yağış tahminleri için en uygun performansı veren üç modelin sırasıyla MRI-ESM2-0, EC-EARTH3 ve EC-EARTH3-Veg modelleri olduğunu açıklamışlardır.

Khadka ve ark. (2021), CMIP5 aşamasından 28 ve CMIP6 aşamasından 32 farklı KİM'in yağış ve rüzgâr değerlerini simüle etme yetenekleri açısından değerlendirmişlerdir. Çok kriterli karar verme tekniğini kullanarak model performanslarını gözlem verileriyle karşılaştıran 25 farklı metriğe göre sıralamışlardır. Sonuçlara göre, CMIP5'e kıyasla CMIP6 modelleri tarafından yıllık yağış döngülerinin daha iyi temsil edildiğini göstermişlerdir. Genel olarak CMIP6 modellerinin yağış ve rüzgârı simüle etmede CMIP5 modellerinden daha üstün olduğunu açıklamışlardır.

Sharma ve ark. (2021), Nepal'de gerçekleştirdikleri çalışmada, üç farklı CMIP6 iklim senaryosu çıktıları (SSP1-2.6, SSP2-4.5 ve SSP5-8.5) ile standartlaştırılmış yağış evapotranpirasyon indeksini kullanarak gelecekteki olası kuraklık koşullarını değerlendirmişlerdir. Değerlendirme sonucunda; gelecek dönemde (2020–2100) özellikle SSP5-8.5 için kuraklık süresi ve şiddetinin artacağını öngörmüşlerdir. Ayrıca SSP1-2.6 ve SSP2-4.5 ile karşılaştırıldığında, SSP5-8.5'ten elde edilen tahminlerin gelecekte daha uzun süreli ve şiddetli kuraklıklara işaret ettiğini öngörmüşlerdir.

Supharatid ve Nafung (2021), Güneydoğu Asya için yaptıkları çalışmada SSP2-4.5 ve SSP5-8.5 senaryoları kapsamında gelecekte iklim değişikliği ve kuraklık etkilerini değerlendirmişlerdir. CMIP6 modellerinin kullanıldığı çalışmanın sonucunda 21. yy'da 1.99–4.29°C (%9.62–18.43) sıcaklık artışı öngörmüşlerdir.

Tang ve ark. (2021), CMIP6 aşamasından 40 KİM çıktıları kullanılarak simüle edilen Çinhindi ve Güney Çin bölgesindeki aşırı yağışları beceri puanı ölçütlerine dayalı olarak değerlendirmişlerdir. Genel olarak CMIP6 modellerinin Güney Çin'de, doğuda bulunan Çinhindi ile karşılaştırıldığında daha iyi performans gösterdiğini açıklamışlardır. Ayrıca, değerlendirilen KİM'lerden yalnızca üç modelin (EC-EARTH3, EC-EARTH3-Veg ve NorESM2-MM), çalışma bölgeleri için hem alansal hem de yıllar arası değişkenliği başarıyla tahmin edebildiğini bildirmişlerdir.

Zhu ve ark. (2021), Çin'de üç büyük nehir havzası için CMIP5 ve CMIP6 KİM'lerin yıllık yağış, maksimum sıcaklık ve minimum sıcaklık için geçmiş dönem tahmin performanslarını değerlendirmişlerdir. Bu amaçla iklim parametrelerinin alansal dağılımını değerlendirmek için Taylor Yetenek Puanı (TSS) istatistiksel performans metriğini kullanmışlardır. Çalışma sonucunda meteorolojik değişkenlerin üçü için de EC-EARTH3 modelinin en başarılı CMIP 6 modeli olduğunu belirlemişlerdir.

Abbas ve ark. (2022), Pakistan'da gelecekte meydana gelebilecek olası yağış rejimindeki değişikliklerin önceden tahmin edilebilmesi için kullanılabilecek olan en iyi CMIP6 KİM'i belirlemek amacıyla yürüttükleri çalışmada, KİM'lerden elde edilen geçmiş dönem yağış tahmin performanslarını referans verilerle karşılaştırmışlardır. Performans değerlendirmelerine göre EC-EARTH3 modelinin yağış dağılımını tahmin etmede yüksek potansiyele sahip modellerden biri olduğunu rapor etmişlerdir. Ayrıca, çalışma sonucunda elde edilen bulguların su kaynaklarının ve afet risk yönetiminin sürdürülebilir planlanmasına yönelik uyum ve hafifletme çalışmalarının tasarlanmasında oldukça önemli olacağını bildirmişlerdir.

Çaktu (2022), tez çalışmasında Havran Havzasında iklim değişikliğinin yağış, sıcaklık ve akış üzerindeki etkilerini değerlendirmiştir. Çalışmada CMIP6 KİM'lerden elde edilen verileri, SSP2-4.5 ve SSP5-8.5 senaryoları için yağış ve sıcaklık değişikliklerini belirlemek amacıyla kullanmıştır. Sonuçlara göre, tüm havzanın her iki senaryo için de gelecekteki tüm dönemlerde sıcaklıkta artış eğilimi olduğunu ve yüzyılın sonuna kadar sıcaklık artışının 5°C'ye kadar çıkabileceğin, öngörmüştür. Yağış miktarı için ise, en kötü senaryoda yüzyılın sonuna kadar yağışta 120 mm'lik bir azalma olacağını tahmin etmiştir.

Hamed ve ark. (2022a), Güneydoğu Asya'da CMIP5 (RCP4.5 ve 8.5) ve CMIP6 (SSP2–4.5 ve SSP5–8.5) modellerinin alansal dağılımı ve mevsimler arası değişkenliğini geçmiş ve gelecekteki yağış ve sıcaklık için değerlendirmeyi amaçlamışlardır. Çalışma sonucunda sıcaklık ve yağış değişkenleri için EC-EARTH3 modelinin diğer modellerden daha başarılı olduğunu açıklamışlardır.

Hamed ve ark. (2022b), Irak'ta CMIP6 KİM'lerini kullanarak kuraklığın konumsal ve zamansal değişimini incelemişlerdir. Bu amaçla ölçeği küçültülmüş model çıktılarını kullanarak referans (1975–2014), yakın gelecek (2020–2059) ve uzak gelecek (2060–2099) dönemleri için kuraklığı tahmin etmişlerdir. KİM'ler arasında Irak iklimini tahmin etmede en iyi performansı EC-EARTH3, BCC-CSM2-MR ve ACCESS-CM2 modellerinin gösterdiğini açıklamışlardır.

Majdi ve ark. (2022), çalışmalarında Orta Doğu ve Kuzey Afrika bölgesindeki sıcaklık ve yağış değişimlerinin gelecekteki olası durumunu tahmin etmeyi amaçlamışlardır. Bu amaçla, CMIP6 projesinden 23 KİM'in iki farklı senaryoya göre olan çıktılarını kullanmışlardır. Çalışma sonuçlarına göre, sıcaklığın her iki gelecek

dönemde de (2020-2049 ve 2050-2079) artacağını ve bu artışların 0.8-3.3°C arasında olabileceğini öngörmüşlerdir. Ayrıca yağış değişikliklerindeki azalmanın, ortalama 133 mm'ye kadar ulaşabileceğini tahmin etmişlerdir.

Nishant ve ark. (2022), küresel sıcaklık artışı nedeniyle Avustralya üzerinde meydana gelebilecek aşırı hava olaylarını tahmin etmek için CMIP6 KİM'lerinin performanslarını değerlendirmişlerdir. Yaptıkları değerlendirmelerde modellerin maksimum ve minimum sıcaklığın tahmin edilmesinde yağış tahmininden daha başarılı olduklarını bildirmişlerdir. Ancak, modellerin sıcaklık değerlerini olduğundan düşük ya da yüksek bir şekilde tahmin ettiğini açıklamışlardır.

Salehie ve ark. (2022), Orta Asya'da Amu nehri havzasının kuraklık özelliklerindeki değişiklikleri CMIP6 senaryoları (SSP1-2.6, SSP2-4.5, SSP3-7.0 ve SSP5-8.5) kullanarak değerlendirmişlerdir. Bu amaçla 19 farklı KİM'in yağış, maksimum ve minimum sıcaklık çıktılarını kullanmışlardır. Ayrıca, kuraklıkları tahmin etmek için standartlaştırılmış yağış evapotranpirasyon indeksini kullanmışlardır. Farklı şiddet ve zaman ölçekleri için kuraklıkların sıklığı ve konumsal dağılımındaki değişiklikleri, 1975–2014 temel dönemine göre kıyaslayarak 2020–2059 ve 2060–2099 dönemleri için değerlendirmişlerdir. Sonuçlara göre, yakın gelecekte özellikle orta dereceli kuraklıklar için SSP5-8.5 senaryosuna göre %50 oranında ve uzak gelecekte SSP3-7.0 için kuraklık oluşumunda %30 oranında bir artışa neden olacağı tahmin etmişlerdir.

Das ve ark. (2023), Doğu Afrika'daki Ekstrem Yüksek Sıcaklık (EYS) olaylarının gelecekteki olası eğilimlerini CMIP6 modelleri kullanarak tahmin etmişlerdir. Çalışma sonucunda 21. yüzyılın sonunda (2071-2095) EYS olaylarının artış göstermeye devam edeceğini açıklamışlardır. Gündüz ve gece sıcaklıklarının, SSP2-4.5 ve SSP5-8.5 senaryolarına göre sırasıyla 1.5-3°C ve 1-4°C arasında artış göstereceğini öngörmüşlerdir. Ayrıca uzak gelecekte (2071-2095) SSP5-8.5 ve SSP2-4.5 senaryoları altında sıcak gece frekansında (%23-30 civarı) büyük bir artış tespit etmişlerdir.

Feyissa ve ark. (2023), Etiyopya'daki Omo Nehri Havzasında iklim değişikliğinin olası etkilerini CMIP6 modellerinden elde ettikleri senaryoları kullanarak tahmin etmiş ve değerlendirmişlerdir. Değerlendirme sonucunda maksimum sıcaklığın, yakın gelecek olan 2030-2060 yılları için SSP2-4.5 ve SSP5-8.5 senaryolarına göre yaz aylarında sırasıyla 0.95°C ve 1.78°C artış göstereceğini bildirmişlerdir. Aynı senaryolara göre uzak

gelecek dönemde (2070-2100) ise maksimum sıcaklığın sırasıyla 1.4°C ve 3.88 artış göstereceğini öngörmüşlerdir.

Gümüş ve ark. (2023), iklim değişikliğinin Türkiye'de aşırı iklim olaylarına etkisini belirlemek için CMIP6 modellerinin SSP2-4.5 ve SSP5-8.5 olarak iki farklı gelecek senaryolarını değerlendirmişlerdir. Elde edilen sonuçlara göre, Türkiye için her iki gelecek senaryosuna göre de gelecekte daha kurak koşullar yaşanacağını ayrıca şiddetli yağışlar ve aşırı sıcaklık olaylarının yaşanma sıklığında artış yaşanacağını öngörmüşlerdir. Türkiye'nin Ege ve Akdeniz bölgelerinde toplam yağış miktarında %20'ye varan bir düşüş yaşanacağını tahmin etmişlerdir.

Liu ve ark., (2023), Güneydoğu Asya için CMIP6 modellerinden elde edilen yağış tahminlerinin performanslarını değerlendirmişlerdir. Bu amaçla modellerden elde ettikleri tahminleri, yer tabanlı ölçümler ve uydu gözlemleri de dâhil olmak üzere çeşitli kaynaklardan elde edilen gözlemlenmiş yağış verileriyle karşılaştırmışlardır. Değerlendirme sonucunda, modellerden elde edilen tahminlerin gözlem verilerinden sapmasının yüksek olduğunu açıklamışlardır. Özellikle bol yağış gerçekleşen mevsimlerde, modellerin yağış miktarını genellikle olduğundan fazla tahmin ettiğini tespit etmişlerdir. Ayrıca, bazı CMIP6 modellerinin (EC-EARTH3, EC-EARTH3-Veg ve E3SM-1-0) yağışı tahmin etmede diğerlerinden daha iyi performans gösterdiğini bildirmiş ve gelecekteki iklim çalışmalarında başarılı sonuçlar elde edebilmek için model seçiminin önemli olduğunu açıklamışlardır.

2.3. Ölçek Küçültme Yöntemleri ile İlgili Yapılan Çalışmalar

Tripathi ve ark. (2006), Hindistan'daki farklı bölgelerde aylık yağış ölçeğini azaltmak için SVM tabanlı küçültme modelleri geliştirmişlerdir. SVM tabanlı küçültme modellerinin geleneksel YSA tabanlı ölçek küçültme modelinden daha iyi performans gösterdiğini bildirmişlerdir.

Goyal ve Ojha (2012), Hindistan'ın Pichola Havzası'nda aylık yağış ölçeğini küçültmek için doğrudan, ileri, geri ve adım adım regresyon gibi birkaç doğrusal regresyona dayalı küçültme modeli uygulamışlardır. Doğrudan regresyona dayalı ölçek küçültme modelinin, çalışma alanı için diğer tüm regresyon teknikleri arasında daha iyi performans verdiği sonucuna varmışlardır.

Goly ve ark. (2014), ABD'nin Florida eyaletindeki aylık yağış miktarlarını tahmin etmek için MLR, pozitif katsayılı regresyon, aşamalı regresyon (SR) ve SVM teknikleri kullanan farklı istatistiksel küçültme modellerini uygulamış ve performanslarını karşılaştırmışlardır. Çalışmada ortalama deniz seviyesi basıncı, hava sıcaklığı, özgül nem, bölgesel rüzgâr hızı ve meridiyonal rüzgâr hızı verileri ölçek küçültme modellerinde tahmin edici değişkenler olarak değerlendirilmiştir. Farklı hata ve istatistiksel ölçümler kullanan modellerin performanslarının değerlendirilmesi sonucunda, destek vektör regresyonu (SVR) tabanlı ölçek küçültme modelinin aylık yağışı küçültmede diğer tüm modellerden daha iyi performans gösterdiğini tespit etmişlerdir.

Kundu ve ark. (2017), KİM'in maksimum sıcaklık, minimum sıcaklık ve yağış çıktılarına SVR yaklaşımına dayalı ölçek küçültme yöntemini uygulamışlardır. Oluşturulan modelin performansını R^2, RMSE ve Nash-Sutcliffe Verimlilik Katsayısı (NSE) istatistiksel metriklerle değerlendirmişlerdir. Bu amaçla referans veri olarak Hindistan'ın üç farklı gözlem istasyonundan elde ettikleri meteorolojik gözlem verilerini kullanmışlardır. Değerlendirme sonucunda test dönemi için üç istasyonun ortalama değerleri maksimum sıcaklık (R^2=0.95, RMSE=1.15 ve NSE=0.97), minimum sıcaklık (R^2=0.95, RMSE=1.40 ve NSE=0.96) ve yağış (R^2=0.91, RMSE=20.82 ve NSE=0.95) için başarılı olduğunu açıklamışlardır.

Pang ve ark. (2017), küresel ölçekte oluşturulan iklim modellerini yerel ölçekte kullanabilmek amacıyla istatiksel ölçek küçültme yönteminin kullanılabilirliğini değerlendirmişlerdir. Ayrıca, Çin'de bulunan Pearl Havzası için rastgele orman (RF) regresyonu yaklaşımının kullanılabilirliğini de araştırmışlardır. Veri seti olarak 1961-2005 yılları için 61 farklı gözlem istasyonuna ait günlük sıcaklık değerlerini gözlem verisi olarak kullanmışlardır. Çalışmada RF algoritması ile oluşturulan ölçek küçültme modelinin performans değerlendirmelerini istatistiksel performans metrikleri ile gerçekleştirmişlerdir. Değerlendirme sonucunda oluşturulan modelin hem kalibrasyon (r=0.99 ve RMSE=0.80) hem de doğrulama (r=0.97 ve RMSE=1.46) aşamalarında başarılı olduğunu açıklamışlardır.

Noor ve İsmail (2018), RF algoritmasının ölçek küçültme modeli olarak performansını değerlendirmek amacıyla iklim modellerinden elde edilen yağış çıktılarını kullanmışlardır. RF modeli, Malezya'nın Kelantan eyaletinde yer alan Kota Bahru istasyonundan elde edilen günlük yağış verileri kullanılarak kalibre edilmiş ve

doğrulanmıştır. Sonuçlara göre ölçek küçültülmüş ve gözlenen yağış verileri arasında mükemmel bir uyum olduğunu belirtmişlerdir. Ölçek küçültülmüş günlük ve aylık ortalama değerlerindeki hataların, yılın tüm ayları ve günleri için çok düşük olduğunu tespit etmişlerdir. Son olarak, RF yönteminin yağış verilerinde ölçek küçültme için güvenilir ve etkili bir yöntem olarak kullanılabileceğini bildirmişlerdir.

Alamgir ve ark. (2019), yıllık ve mevsimsel maksimum ve minimum sıcaklık değişikliklerini değerlendirmek ve bu sıcaklık değişikliklerinin mekânsal dağılımını belirlemek amacıyla KİM çıktılarını kullanmışlardır. Bangladeş'te gerçekleştirdikleri çalışmada ölçek küçültme modeli olarak SVR kullanmışlardır. Modelden elde edilen çıktıların sapma hatalarını yanlılık düzeltme yöntemi kullanarak düzeltmişlerdir. Elde edilen sonuçlara göre modeller için hesaplanan RMSE değeri maksimum sıcaklık ve minimum sıcaklık için sırasıyla 0.89 ve 1.54'ten düşük olarak hesaplanmıştır. Ayrıca, hesaplanan performans değerlendirme metriği olan NSE değeri ise ortalama 0.58'in üzerinde hesaplanmıştır. Bu sonuçlara dayanarak SVR modelinin ölçek küçültme yöntemi olarak güvenle kullanılabileceğini bildirmişlerdir.

Beyer ve ark. (2019), günümüzde yaygın olarak kullanılan üç farklı yanlılık düzeltme yöntemini (delta yöntemi, genelleştirilmiş katkı modelleri ve kantil haritalama yöntemi) farklı dönemler için yağış ve sıcaklık veri kayıtlarını kullanarak değerlendirmişlerdir. Genel olarak delta yönteminin hem sıcaklık hem de yağış için en iyi performansı gösterdiğini bildirmişlerdir.

Eekhout ve de Vente (2019), farklı yanlılık düzeltme yöntemleri ile düzeltilmiş iklim modeli çıktılarını Akdeniz havzası için değerlendirmişlerdir. Yaptıkları çalışmalar sonucunda model çıktılarını kullanmadan önce yanlılık düzeltmesinin mutlaka yapılması gerektiğini önermişlerdir.

Ghimire ve ark. (2019), Myanmar'da havza bazında gerçekleştirdikleri çalışmada hidrolojik modelin simülasyon yeteneğini geliştirmek amacıyla yıllık ve aylık zaman ölçeklerinde sekiz farklı yanlılık düzeltme yöntemini karşılaştırmışlardır. Bu amaçla, 1981-1999 yıllarına ait kontrol döneminde model çıktıları için yanlılık düzeltmesi yapılmıştır ve bu düzeltmeleri 2000-2005 yılları için doğrulamışlardır. Yanlılık düzeltme yöntemlerinin uygulanması sonucunda model çıktıları ve gözlenen veriler arasındaki sapmaların azaldığı ve bu azalmadan dolayı hidrolojik modelin gerçekleştirdiği akış simülasyonlarının daha iyi sonuçlar verdiğini belirtmişlerdir.

Ren ve ark. (2019), Çin'de yer alan Yarlung Zangbo Nehri Havzasında bulunan 20 meteorolojik istasyondan elde edilen günlük aşırı sıcaklık (maksimum ve minimum) gözlem verilerini kullanarak ölçek küçültme modelleri oluşturmuşlardır. Ölçek küçültme yöntemi olarak MLR, YSA, SVM ve RF yöntemlerini kullanmışlardır. Bu yöntemlerin performanslarını dört farklı istatistiki performans kriteri kullanarak değerlendirmişlerdir. Değerlendirmeler sonucunda en başarılı yöntem olarak RF modelini belirlemişlerdir.

Soriano ve ark. (2019), İspanya'da havza bazlı olarak yaptıkları çalışmada gelecekte meydana gelebilecek taşkın değişikliklerini doğru bir şekilde tahmin edebilmek için meteorolojik iklim gözlem verileri ile iklim modeli çıktıları arasındaki hataları en aza indiren yanlılık düzeltme yöntemlerini incelemişlerdir. Yaptıkları istatistiksel analizler sonucunda KİM'lerden referans dönem için elde edilen sıcaklık ve yağış çıktı ortalamalarının gözlem verileri ile karşılaştırıldığında önemli ölçüde düşük tahminde bulunduğu görülmüştür. Bu nedenle de KİM çıktılarının gözlem verilerine istatistiksel olarak uyumlu hale getirilmesi için yanlılık düzeltmesinin uygulanmasının gerekli olduğunu belirtmişlerdir.

Noor ve ark. (2020), Batı Malezya'da KİM çıktılarına ölçek küçültme uygulamak amacıyla RF algoritmasının günlük yağış miktarı tahmininde kullanılabilirliğini araştırmışlardır. Gözlem verisi olarak çalışma alanında farklı noktalarda bulunan 19 gözlem istasyonunun verilerini kullanmışlardır. Sonuçlar, modellerin tüm gözlem istasyonlarında yağış miktarını yüksek bir doğrulukla tahmin ettiğini ortaya koymuştur. Modellerin MAE değerlerini 0.39-0.80, normalize edilmiş kök ortalama kareler hatası (NRMSE) değerlerini 7.4-41.7, yüzde sapma değerlerini (PBIAS) -0.3-10.1, NSE değerlerini 0.81-0.99 ve R^2 değerlerini 0.89-0.99 arasında hesaplamışlardır.

Kamruzzaman ve ark. (2021), Bangladeş için CMIP5 ve CMIP6 KİM'lerin yıllık ve mevsimsel olarak yağış ve sıcaklık tahmin performanslarını gözlem verileri ile karşılaştırarak incelemişlerdir. Bu amaçla, 1977-2005 dönemi için 30 farklı meteorolojik gözlem istasyonuna göre KİM'lerin performanslarını çok kriterli karar verme yöntemi kullanarak değerlendirmişlerdir. Sonuç olarak, CMIP6 modellerinin yağışı tahmin etmede sıcaklıktan daha başarılı olduğunu açıklamışlardır. Genel olarak, KİM'lerin bölgesel ölçekte, iklim parametrelerini tahmin etmede yetersiz olduğunu ve bu modellerin kullanılmadan önce ölçek küçültme yöntemlerinin mutlaka uygulanması gerektiğini bildirmişlerdir.

Zhao ve ark. (2021), Çin'de Hennan eyaletinde bulunan 12 farklı istasyon için iklim modellerinde ölçek küçültme yöntemi olarak SVR, RF ve kuantil regresyon yöntemlerini karşılaştırmışlardır. Aylık yağış miktarları için gerçekleştirdikleri çalışmada RF yönteminin R^2 değerini 0.66-0.89 ve RMSE değerini ise 27.68-49.11 arasında hesaplamışlar ve diğer ölçek küçültme yöntemlerinden daha başarılı olduğunu açıklamışlardır.

Güven ve Pala (2022), iklim değişikliğinin yerel ölçekteki hidrolojik etkilerini araştırmak amacıyla KİM çıktılarına ölçek küçültme yöntemi uygulamışlardır. Bu amaçla Türkiye'de bulunan Göksun Nehri Havzası için KİM'in yağış miktarı çıktılarını SVR dâhil üç farklı yöntem kullanarak değerlendirmişlerdir. Değerlendirme sonucunda SVR modelini, R^2 değeri 0.62 ile en başarılı model olarak belirlemişlerdir.

Salman ve ark. (2022), Irak'ta yıllık ve mevsimsel yağış miktarının gelecekteki olası değişimini tahmin etmek amacıyla dört farklı CMIP6 KİM'in çıktılarına istatistiksel ölçek küçültme yöntemi uygulamışlardır. Bu amaçla SVR modelini kullanmışlardır. KİM'lere istatistiksel küçültme uygulanması sonucunda NRMSE değerini 0.56-0.57 ve R^2 değerini 0.85-0.87 olarak hesaplamışlardır. Uyguladıkları istatistiksel performans metriklerinin sonuçlarına dayanarak, KİM çıktılarının yağış tahminlerinin yerel ölçekte iklim değişikliği çalışmalarında kullanılabilmesi için ölçek küçültme yöntemi uygulanmasının oldukça önemli olduğunu açıklamışlardır.

Prathom ve Champrasert (2023), yaptıkları çalışmada Tayland'da KİM'den elde edilen verilerin daha yüksek bir uzamsal çözünürlüğe indirgenmesi için yapay sinir ağlarına dayalı bir ölçek küçültme modeli oluşturmuşlardır. Model elde edilen tahminler istatistiki performans ölçütleri ile değerlendirildiğinde sıcaklık için R^2 değeri 0.73 ve RMSE değeri 0.09 olarak belirlenmiştir. Aynı model yağış tahmini için ise R^2 değerini 0.70 ve RMSE değerini 0.04 olarak hesaplamış ve ölçek küçültme modelinin başarılı olduğunu bildirmişlerdir.

2.4. Bitkisel Üretimin Modellenmesi ile İlgili Yapılan Çalışmalar

Haim ve ark. (2008), İsrail'de gerçekleştirdikleri çalışmada iklim değişikliğinin buğday ve pamuk verimine farklı iklim değişikliği senaryoları (A2 ve B2) altında olası etkilerini araştırmışlardır. KİM'den elde ettikleri çıktıları, 2070-2100 dönemi sıcaklık ve yağış projeksiyonları üretmek için kullanmışlardır. Sonuç olarak, her iki senaryo içinde

pamuk veriminin önemli ölçüde azalacağını (A2 ve B2 senaryolarında sırasıyla %240 ve %173) ve önemli ekonomik kayıpların yaşanacağını bildirmişlerdir.

Farahani ve ark. (2009), Kuzey Suriye'nin yarı kurak iklim ortamında pamuk bitkisi için AquaCrop modelini kalibre ve test etmişlerdir. Modelin kalibrasyonu için 2006 yılı arazi verilerini kullanmışlar ve modelin 2004-2005 yıllarını simüle etme yeteneğini test etmişlerdir. Değerlendirme sonucunda modelin 2004 (R^2=0.78) ve 2005 (R^2=0.96) yılları için verim tahminlerinin başarılı olduğunu belirtmişlerdir.

Heng ve ark. (2009), İspanya'da üç farklı konumda bulunan tarlalarda mısır bitkisinin simülasyonu için AquaCrop modelini test etmişlerdir. Modelin su stresinin olmadığı ya da hafif olduğu koşullarda toprak üstü biyokütleyi ve dane verimini tahmin etmede oldukça başarılı olduğunu açıklamışlardır.

Hsiao ve ark. (2009), AquaCrop'un bitki yoğunluğu ve ekim tarihi bakımından farklılık gösteren dört farklı mısır çeşidinin verimini simüle etme performansını değerlendirmişlerdir. Çalışmanın sonucunda modelin bitki örtü yüzeyini, biyokütle gelişimini ve dane verimini uygun bir şekilde tahmin edebildiğini açıklamışlardır.

García-Vila ve ark. (2009), deneysel verileri kullanarak güney İspanya'da pamuk verimini tahmin etmek için AquaCrop'u kalibre etmek ve doğrulamak amacıyla, 2006-2007 yıllarında İspanya'da iki farklı konumda gerçekleştirilen dört farklı arazi çalışmasının sonuçlarını kullanmışlardır. Çalışmanın sonucunda modelden elde edilen tahminlerin oldukça başarılı olduğunu açıklamışlardır. Ayrıca AquaCrop modelinin; çiftçilere ve sulama bölge yöneticilerine sulama suyu arzının kısıtlanacağı durumlarda karar vermelerinde yardımcı olabilecek güçlü bir araç olduğunu bildirmişlerdir.

Şen (2009), tez çalışmasında Çukurova Yöresi'nde 2071-2100 yılları arasındaki iklim değişikliğinin etkilerini belirlemiş ve bu etkilerin 1. ve 2. ürün mısır verimine etkilerini değerlendirmiştir. Bu amaçla, bölgesel iklim modeli RegCM'den elde ettikleri gelecek tahminlerini WOFOST bitkisel üretim modelinde kullanmıştır. Çalışmada gelecek dönemler için yapılan tahminlere göre, ortalama sıcaklığın yaklaşık 3.0°C-4.5°C artış gösterebileceğini öngörmüştür. Elde edilen sıcaklık tahminlerini bitkisel üretim modelinden kullanmış ve 1. ve 2. ürün mısır veriminde %58 ve %43 oranlarında azalma olabileceğini tahmin etmiştir.

Baydar (2010), yaptığı çalışmada Seyhan Ovası koşullarında iklim değişikliğinin pamuk bitkisine olası etkilerini DSSAT Cropgro bitkisel üretim modeli kullanarak

değerlendirmiştir. Çalışmada 2005-2008 yılları arasında yürütülen DIMAS projesinin 2006 yılı sonuçlarından yararlanmıştır. Gelecek iklim koşullarını belirlemek amacıyla Terch-Rams Bölgesel Atmosferik Model sonuçlarını kullanmıştır. Çalışma sonucunda artan sıcaklıklara bağlı olarak 2070-2079 yılları için pamuk bitkisinin veriminin %5 azalarak 3578 kg ha^{-1} olabileceğini öngörmüştür.

Kapur (2010), tez çalışmasında Çukurova bölgesi için gelecekteki iklim değişikliğinin buğdayın büyüme, gelişme ve verimine olan etkisini incelemiştir. Bu amaçla bölgesel ölçekli TERCH-RAMS iklim modelini kullanarak gelecek iklim değişikliğini öngörmüştür. Değerlendirme sonucuna göre ortalama sıcaklıklarda yaklaşık 3°C'lik bir artış ve yağışlarda ise %25 ile %40 arasında bir azalma olabileceğini tahmin etmiştir. Sıcaklıktaki 1°C artışın çiçeklenmeye kadar geçen süreyi 5 gün, olgunluğa kadar geçen süreyi ise 9 gün kısalttığını gözlemiştir. Dane verimi açısından, CO_2 artışının kısıtlı sulanan normal sıcaklık koşullarında %13, tam sulanan normal sıcaklık koşullarında %17 ve tam sulanan sıcak koşullarda %34 oranında artışa neden olacağını belirlemiştir.

Abedinpour ve ark. (2012), Hindistan'ın yarı kurak iklim ortamında mısır bitkisinin biyokütle ve verim tahmini için AquaCrop modelini incelemişlerdir. Sonuç olarak modelin farklı sulama ve gübreleme uygulamaları ile biyokütleyi %5.91-11.05 ve dane verimini %0.47-4.36 hata yüzdesi ile tahmin ettiğini bildirmişlerdir.

Baydar ve Kanber (2012), Türkiye'nin Aşağı Seyhan Ovası için gerçekleştirdikleri çalışmada gelecek yıllarda meydana gelebilecek olası iklim değişikliği etkilerinin pamuk bitkisinin verim ve fizyolojik özelliklerine olası etkilerini değerlendirmişlerdir. Çalışmada Çukurova Üniversitesi Ziraat Fakültesi Tarımsal Yapılar ve Sulama Bölümü deneme alanında yürütülmüş olan DIMAS projesinin 2006 yılı sonuçlarından yararlanmışlardır. Terch-Rams Bölgesel Atmosferik Model sonuçları kullanılarak gelecek koşullardaki iklim belirlenmiştir. DSSAT Cropgro bitki benzeşim modeli gelecek yıllar için kullanılarak pamuk bitkisinin iklim değişikliklerine karşı olası tepkilerini tahmin etmişlerdir. Sonuç olarak 2070-2079 yılları arasında artan sıcaklık ve CO_2 miktarlarına bağlı olarak pamuk bitkisi veriminin %5 azalarak 3.578 kg ha^{-1} olacağını öngörmüşlerdir. Biyokütlenin ise %8'lik bir artış ile 13.979 kg ha^{-1} olacağını tahmin etmişlerdir. Gelecek koşullarda hasat indeksinin ise %15 azalacağını belirlemişlerdir. Ayrıca, 2070-2079 yılları arasında Aşağı Seyhan Ovası'nın sulanabilir pamuk alanlarında büyüme dönemlerinin uzunluklarında azalmalar olabileceğini açıklamışlardır.

Hebbar ve ark. (2013), iklim değişikliğinin Hindistan'daki pamuk üretimi üzerindeki etkilerini tahmin etmek için, Infocrop-Pamuk simülasyon modelini kullanarak gelecekteki farklı iklim senaryolarına göre pamuk üretimini tahmin etmişlerdir. Simulasyon sonuçlarına göre A2, B2 ve A1B senaryoları için Hindistan'ın pamuk yetiştirme bölgelerinin ortalama sıcaklığında sırasıyla yaklaşık 3.95, 3.20 ve 1.85°C artış olabileceğini tahmin etmişlerdir. Infocrop-Pamuk modelinin tahmin sonuçlarına göre, kütlü pamuk veriminin iyimser senaryoya göre 268 kg ha^{-1} ve kötümser senaryoya göre 477 kg ha^{-1} azalabileceğini öngörmüşlerdir. Ayrıca, yüksek sıcaklıkların serin iklim bölgelerinde CO_2 artışına bağlı olarak verimi arttırabileceğini ancak daha sıcak bölgelerde, özellikle yaz mevsimindeki kritik ürün büyüme döneminde gelişimi hızlandırdığı için verimi azaltacağını açıklamışlardır.

Masanganise ve ark. (2013), Zimbabwe'deki üç farklı mısır çeşidinin 2000-2006 yılları arasındaki verimlerini simüle edebilmek için AquaCrop modelinin başarısını değerlendirmişlerdir. Sonuç olarak, mısır çeşitleri için arazi üzerinde gözlemlenen ve model tarafından simüle edilen verimler arasında yüksek bir korelasyonun olduğu ve tahmin hatalarının oldukça düşük olduğunu açıklamışlardır.

Moradi ve ark. (2014), iklim değişikliğinin mısır bitkisinin gelişimi ve dane verimi üzerindeki etkilerini modelleyerek verimde gerçekleşebilecek olası değişiklikleri değerlendirmek amacıyla yürüttükleri çalışmada, İran'ın Horasan bölgesinde KİM'in üç farklı SRES senaryosuna ait çıktılarını kullanmışlardır. Bitki simülasyon modeli olarak CERES-Mısır modelinden yararlanmışlardır. Modellerden tahmin edilen sonuçlara göre, iklim değişikliği etkilerine yanıt olarak mısır çeşitlerinin çiçeklenmeye kalan gün sayısı ve çiçeklenme periyodunun kısaldığını açıklamışlardır. Mısır çeşitlerinin tahmin edilen dane verimlerinin, mevcut iklim koşullarına kıyasla gelecek 100 yıl boyunca tüm senaryolarda kademeli olarak %6.4-42.2 oranında azalacağını öngörmüşlerdir. Ayrıca, çalışma bulgularına dayanarak erken olgunlaşan mısır çeşitlerinin yetiştirilmesinin, iklimin olumsuz etkilerini azaltmak için etkili bir yaklaşım olarak kabul edilebileceğini açıklamışlardır.

Deveci (2015), yaptığı tez çalışmasında Trakya Bölgesi'nde bulunan Çorlu Pınarbaşı Havzası için iklim değişikliğinin buğday ve ayçiçeği verimine olan etkilerini incelemek amacıyla RegCM3 Bölgesel İklim Modelini kullanmıştır. Çalışmada, 1970-1990 yıllarında ölçülen sıcaklık ve yağış verileri ile model referans verilerini

karşılaştırarak 2016-2025, 2046-2055 ve 2076-2085 yılları için sıcaklık ve yağış değişimini tahmin etmiştir. Buna göre, bu dönemlerde sıcaklıkların sırasıyla 0.12°C, 1.43°C ve 3.05°C artacağı, yağışların ise 2016-2025 yılları arasında %9 artacağı, 2046-2055 ve 2076-2085 yılları arasında ise sırasıyla %14 ve %12 azalacağını tahmin etmiştir. Bitki verimi üzerindeki etkileri tespit etmek için AquaCrop Modeli kullanmıştır. Model tahmin sonuçlarına göre ayçiçeği veriminde önce %9.4'e kadar artış, daha sonra %22'ye kadar azalma olacağını öngörmüştür.

Araya ve ark. (2017), Batı Kansas (ABD) için gerçekleştirdikleri araştırmada gelecekteki iklim değişikliğinin mısır verimi üzerindeki etkisini değerlendirmişlerdir. Bu amaçla, RCP4.5 ve RCP8.5 senaryolarını kullanmışlardır. Sonuçlara göre, 21. yy ortalarında mısır veriminin günümüze göre ortalama olarak RCP4.5 senaryosu altında %18-33 ve RCP8.5 senaryosu altında %37-46 oranında azalacağını öngörmüşlerdir. Verimdeki bu azalmaların, sıcaklıklardaki olası artışlar nedeniyle bitki büyüme döneminin kısalmasından (olgunluğa kalan günlerde %9-18 düşüş) kaynaklandığını bildirmişlerdir.

Rahman ve ark. (2018), Pakistan'ın Punjab Bölgesi'ndeki pamuk üretimine RCP4.5 ve 8.5 senaryoları altında iklim değişikliğinin olası etkilerini değerlendirmişlerdir. Çalışmanın sonucunda, RCP4.5 senaryosunda 2039 yılında %8 ve 2069 yılında %20, RCP 8.5 senaryosunda ise 2039 yılında %12 ve 2069 yılında %30 oranında pamuk üretiminin azalabileceğini bildirmişlerdir.

Tan ve ark. (2018), yaptıkları çalışmada Çin'in güneyindeki Sincan Bölgesi'ndeki iki farklı toprak tipi için AquaCrop model performansını test etmeyi amaçlamışlardır. Test sonuçlarının saha gözlemleriyle oldukça uyumlu olduğunu (R^2>0.77 ve d>0.92) ve pamuk bitkisinin farklı sulama senaryolarına tepkisini tahmin etmek için AquaCrop modelinin uygun bir araç olarak kullanılabileceğini bildirmişlerdir.

Tesfaye ve ark. (2018), mısır için CERES-Mısır bitki büyüme simülasyon modelini kullanarak, iklim değişikliğinin mısır üzerindeki etkisini Kenya, Etiyopya, Zimbabwe ve Hindistan için değerlendirmişlerdir. Çalışma sonucu olarak, iklim değişikliğine bağlı sıcaklıklarda artışların gerçekleşeceğini ve 1, 2 ve 4°C'lik sıcaklık artışlarında sırasıyla %21, %33 ve %50 verim kaybı yaşanabileceğini açıklamışlardır.

Li ve ark. (2019), AquaCrop modelini Kuzey Çin Ovası'ndaki pamuk bitkisini simüle etme performansı açısından değerlendirmişlerdir. AquaCrop modeli 2002–2009

verileri kullanılarak kalibre edilmiş ve 2010–2014 verileri kullanılarak test edilmiştir. Kalibrasyon ve doğrulama veri setlerini saha gözlemleri ile değerlendirmişlerdir. Anılan modelin pamuk bitki verimini simüle etmek için kullanılabileceğini açıklamışlardır.

Tsakmakis ve ark. (2019), Kuzey Yunanistan'da yaptıkları çalışmada pamuk bitki veriminin AquaCrop modeli ile belirlenmesini amaçlamışlardır. AquaCrop modelini 2013-2015 yılları için çiftlik ölçeğinde uygulamışlardır. Sonuçlar, yeşil ve mavi su ayak izlerinde hem sulama teknolojisi hem de sulama stratejisi etkisinin AquaCrop modeli ile oldukça iyi bir şekilde tahmin edildiğini göstermiştir.

Ahmad ve ark. (2020), bitki tahmin modeli olarak CERES-Mısır kullanılarak Pakistan'da iklim değişikliğinin bitkisel üretime olası etkilerini değerlendirmişlerdir. Gelecekteki iklim tahminlerini KİM'lerden RCP8.5 senaryosu için elde etmişlerdir. Model sonuçlarına göre, maksimum sıcaklıkta 3.4°C ve minimum sıcaklıkta 3.8°C artış olacağını bildirmişlerdir. Sıcaklıkta meydana gelmesi öngörülen bu artışın gelecekteki mısır üretimi için yaklaşık %29 oranında bir verim azalmasına neden olacağını öngörmüşlerdir.

Anwar ve ark. (2020), Doğu Avustralya'da iki farklı iklim değişikliği senaryosu (RCP4.5 ve RCP8.5) kullanarak 2040 ve 2080 dönemleri için gelecekte iklim değişikliğinin olası etkilerini değerlendirmişlerdir. Bu amaçla, 32 farklı KİM'den elde edilen istatistiksel olarak ölçeği küçültülmüş meteorolojik çıktıları kullanmışlardır. Elde ettikleri iklim projeksiyonlarına göre özellikle yüksek emisyon senaryosu olan RCP8.5 senaryosu altında bitki büyüme dönemi boyunca sıcaklıklarda ciddi artışların meydana geleceğini açıklamışlardır.

Lv ve ark. (2020), çalışmalarında iklim değişikliğinin mısır verimi üzerindeki etkisini araştırmışlardır. Çalışmanın sonucunda mısırın dane dolum süresinin sıcaklık artışlarına bağlı olarak 6-15 gün kısalabileceğini öngörmüşlerdir. Bu kısalmanın potansiyel mısır verimini 2010–2099 döneminde %2–32 oranında azaltabileceğini bildirmişlerdir.

Masasi ve ark. (2020), AquaCrop modelinin performansını değerlendirmek ve sınırlı su kaynakları ile verimi en üst seviyeye çıkarmak için uygun sulama uygulamasını belirlemeyi amaçlamışlardır. Bunun için, ABD'nin güney bölgesinde iki araziden toplanan verileri kullanarak modeli kalibre etmiş ve doğrulamışlardır. Sonuç olarak, her

iki çalışma alanı içinde yüksek doğrulukta tahminler elde edilmiş ve sonuçları oldukça tatmin edici bulmuşlardır.

Alkan (2021), Porsuk Çayı Havzası'nda iklim değişikliğinin etkilerini incelemeyi amaçlamıştır. Geçmişteki (1970-2018) iklim verileri ile HadGEM2-ES küresel iklim modelinin RCP4.5 ve RCP8.5 senaryolarına göre üretilmiş gelecekteki (2018-2100) iklim verileri kullanılarak Standart Yağış İndisi (SYİ), Standart Akış İndisi (SAİ), Palmer Kuraklık Şiddeti İndisi (PKŞİ) ve WOFOST modeli ile kuraklık analizleri ve buğday verim analizlerini gerçekleştirmiştir. Havzadaki iyimser senaryo sonuçlarına göre, yakın gelecekte (2020-2045) %0.73'lük buğday verim artışı olabileceği öngörmüştür. Bunun dışındaki tüm dönemlerde, buğday verimlerinde (%0.43-1.5 arasında) azalma gerçekleşeceğini tahmin etmiştir.

Karimi (2021), yaptığı tez çalışmasında Altınova Tarım İşletmesinde kuraklığın buğday verimine olası etkilerini belirlemek için Aquacrop bitki simülasyon modelini ve uzaktan algılama verilerini kullanmıştır. Çalışma sonuçlarına göre, Aquacrop bitki büyüme modelinin tahmin ettiği buğday verim değerleri ile gerçek verim değerleri birbirine yakın bulunmuştur (R^2=0.89).

Li ve ark. (2021), iklim değişikliği ve alınabilecek önlemlerin pamuk verimi üzerindeki potansiyel etkilerini daha önce yayınlanmış farklı çalışmaları kullanarak oluşturdukları bir meta veri tabanı ile değerlendirmişlerdir. Çalışmada ortalama sıcaklık, minimum sıcaklık, maksimum sıcaklık, yağış ve CO_2 konsantrasyonunda meydana gelen değişikliklerin pamuk verimine olası etkilerini incelemişlerdir. Çalışma sonucunda, ortalama sıcaklığın her 1°C artması durumunda, pamuk veriminin %1.64 oranında azalacağını bildirmişlerdir.

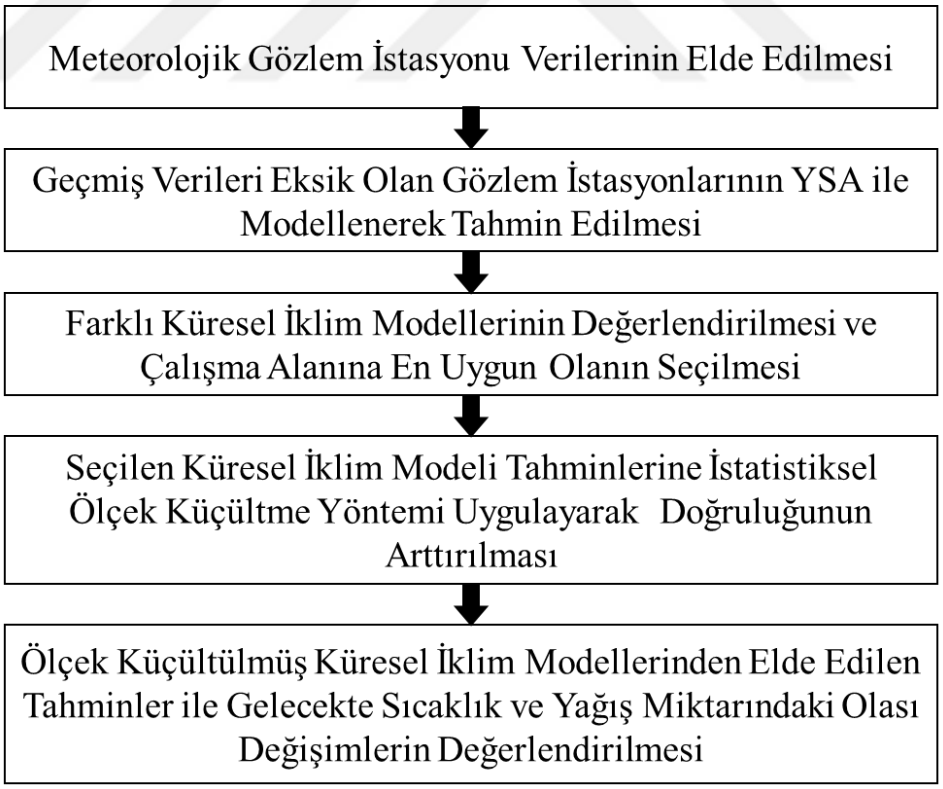
Ahmed ve ark. (2023), Çin'de yaptıkları çalışmada aşırı kurak bir bölgede iklim değişikliğinin gelecek dönemler (2022–2047 ve 2074-2099) için iki farklı senaryo (RCP4.5 ve 8.5) altında pamuk üzerindeki potansiyel etkilerini araştırmışlardır. Sonuçlara göre, tam sulama ile kütlü pamuk veriminin RCP4.5 senaryosu için %13-18 ve RCP8.5 senaryosu için %14-18 oranında azalacağını öngörmüşlerdir. Pamuk verimindeki bu azalmanın gelecek iklimde sıcaklıktaki olası artışlardan kaynaklanabileceğini bildirmişlerdir.

Feleke ve ark. (2023), Etiyopya'da yaptıkları çalışmada sıcaklık değişimlerinin mısır verimine etkisini Aquacrop modeli kullanarak değerlendirmişlerdir. Bu amaçla

KİM modellerinden RCP 8.5 senaryosu için elde edilen gelecek tahminlerini kullanmışlardır. Değerlendirme sonucunda, ortalama mısır veriminin 2030 yılına kadar Ambo ve Melkassa şehirleri için sırasıyla %4 ve %16 oranında azalacağını öngörmüşlerdir.

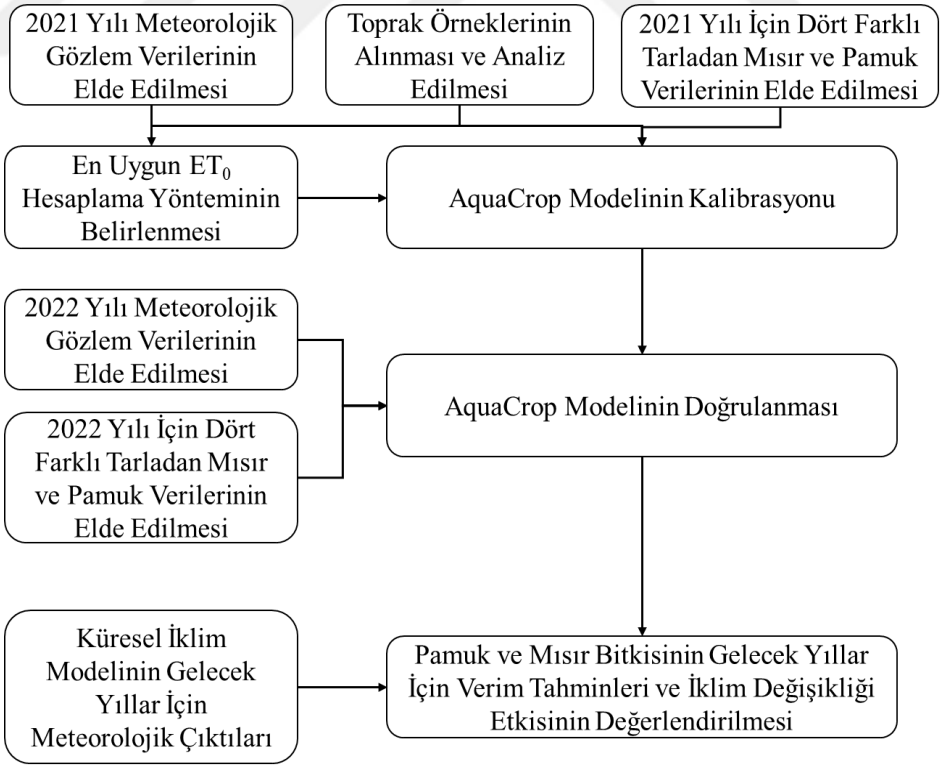
3. MATERYAL ve YÖNTEM

Tez çalışması iki bölümden oluşmaktadır. Birinci bölümde, iklim değişikliğinin Hatay ilinde sıcaklık ve yağış miktarına olası etkileri incelenmiştir. İlk olarak iklim değişikliğinin etkilerinin değerlendirilebilmesi için otuz yıllık gözlem verileri bulunmayan meteoroloji gözlem istasyonları belirlenmiştir. Belirlenen gözlem istasyonları için çok katmanlı YSA tahmin modeli oluşturularak eksik yıllara ait veriler tahmin edilmiş ve bilimsel çalışmalarda kullanılabilecek uzun yıllık veri setleri haline getirilmiştir. Oluşturulan uzun yıllık gözlem verileri KİM çıktılarını doğrulamak için kullanılmıştır. Değerlendirilen KİM'lerden çalışma alanı için en başarılı olanı çok kriterli karar verme yöntemi kullanılarak belirlenmiştir. Kullanılabilirliği doğrulanan modellerden elde edilen gelecek tahminleri farklı ölçek küçültme modelleri kullanılarak yerel ölçeğe indirgenmiştir. Modellerden elde edilen gelecek tahminleri kullanılarak Hatay ilinde, yakın ve uzak gelecekte sıcaklık ve yağışta meydana gelebilecek değişiklikler tahmin edilerek olası etkileri değerlendirilmiştir (Şekil 3.1).



Şekil 3.1. İklim değişikliğinin Hatay ili sıcaklık ve yağış miktarına olası etkisinin değerlendirilmesinin iş akış şeması

İkinci bölümde ise, iklim değişikliğinin bitkisel üretime olası etkilerini değerlendirmek amacıyla 1. ürün mısır ve pamuk bitki verimleri AquaCrop bitki üretim modeli kullanılarak tahmin edilmiştir. AquaCrop bitki üretim modelinin verim tahmini gerçekleştirebilmesi için girdi olarak bazı iklim, toprak ve bitki özelliklerine ihtiyaç duymaktadır. Bu nedenle, ilk olarak Kırıkhan ilçesinde dört farklı konumda bulunan arazilerden toprak örnekleri alınmış ve laboratuvarda analiz edilmiştir. Daha sonra, iklim dosyasının oluşturulabilmesi için gerekli olan referans evapotranspirasyon (ET_0) değerleri Kırıkhan gözlem istasyonundan elde edilen iklim verileri kullanılarak hesaplanmıştır. Son olarak, 2021 yılında farklı tarihlerde arazilerden alınan bitki örneklerinde yapılan gözlemlerle AquaCrop bitki üretim modelinin kalibrasyonu gerçekleştirilmiş ve 2022 yılında elde edilen sonuçlarla model doğrulanmıştır. Hem pamuk hem de 1. ürün mısır bitkisi için doğrulanan modelde gelecek yıllara ait sıcaklık ve yağış tahminleri kullanılarak farklı senaryolar için biyokütle ve ürün verimi tahminleri elde edilmiştir. Son olarak elde edilen model tahmin sonuçları değerlendirilerek iklim değişikliğinin bitkisel üretime olası etkileri öngörülmüştür (Şekil 3.2).

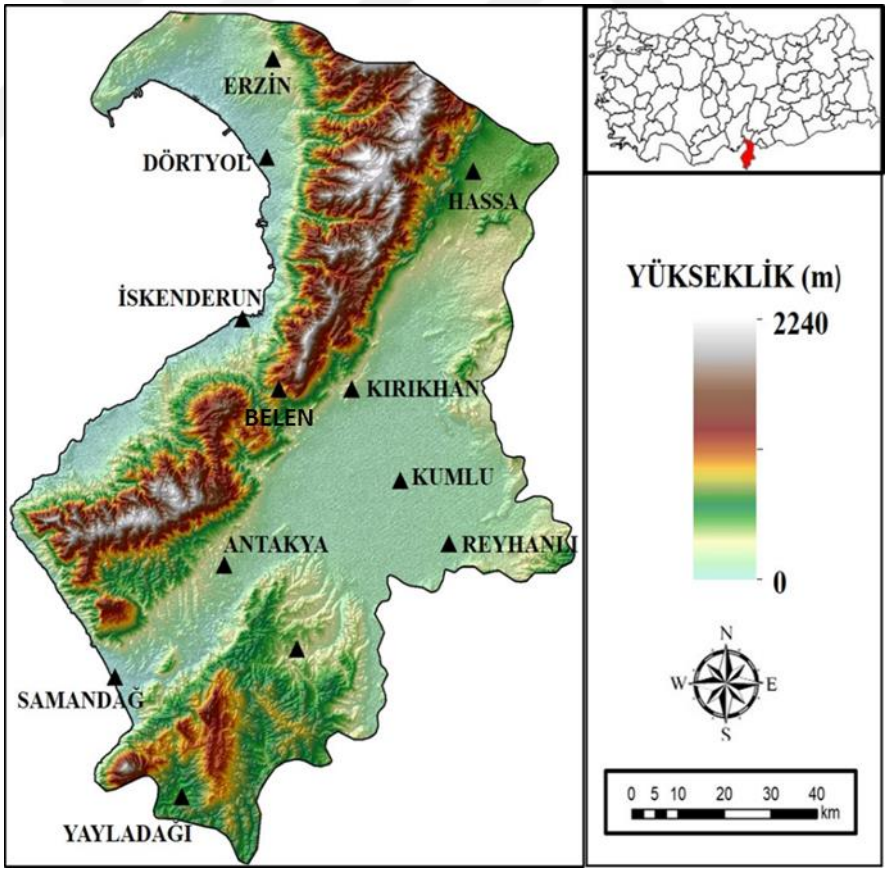


Şekil 3.2. İklim değişikliğinin pamuk ve 1. ürün mısır bitkisi verimine olası etkisinin değerlendirilmesinin iş akış şeması

3.1. Materyal

3.1.1. Çalışma Alanı ve Özellikleri

Hatay, Türkiye'nin güneyinde 35°48'-37°01' kuzey enlemleri ile 35°46'-36°41' doğu boylamları arasında yer almaktadır (Şekil 3.3). Yüzölçümü 5.542 km² olan Hatay; Antakya, Altınözü, Belen, Defne, Dörtyol, Erzin, Hassa, İskenderun, Kırıkhan, Kumlu, Payas, Reyhanlı, Samandağ ve Yayladağı ilçelerinden oluşmaktadır. Hatay coğrafyasının belli başlı jeomorfolojik birimleri; Amanos Dağları, Keldağ (Kılıç Dağı), Kuseyr Platosu, Amik Ovası, Kıyı Ovaları, Asi Nehri, İskenderun Körfezi ve Hatay-Kahramanmaraş grabenidir. İlin en yüksek noktası Hassa'nın batısında bulunan 2240 m yükseklikteki Mığır Tepesidir (Yılmaz, 1984). Türkiye'nin tarım açısından en önemli ovalarından biri olan Amik Ovası'nın uzunluğu 80–90 km, doğu batı genişliği ise 2–35 km ve yükseltisi 80–250 m arasında değişmektedir (Korkmaz, 2009).



Şekil 3.3. Çalışma alanının sayısal yükseklik modeli

Coğrafik konumu nedeniyle deniz etkisine açık olan Hatay'da genel olarak Akdeniz iklimi görülmektedir. Kıyı şeridi boyunca denizellik etkisi görülürken Amanos Dağları nedeniyle iç kesimlerde ılımanlaştırıcı denizellik etkisini kaybetmektedir. Hatay iklimi Köppen iklim sınıflandırmasına göre Csa (kış mevsimi ılık, yaz mevsimi çok sıcak ve kurak) iklim kategorisindedir (Öztürk ve ark., 2017). Metetoroloji Genel Müdürlüğünden elde edilen verilere göre, Hatay'da en düşük aylık ortalama sıcaklık Ocak (8.2°C) ayında ve en yüksek aylık ortalama sıcaklık Ağustos (28.3°C) ayında görülmektedir. Hatay ilinin ortalama yıllık sıcaklığı ise 18.6°C'dir (Çizelge 3.1).

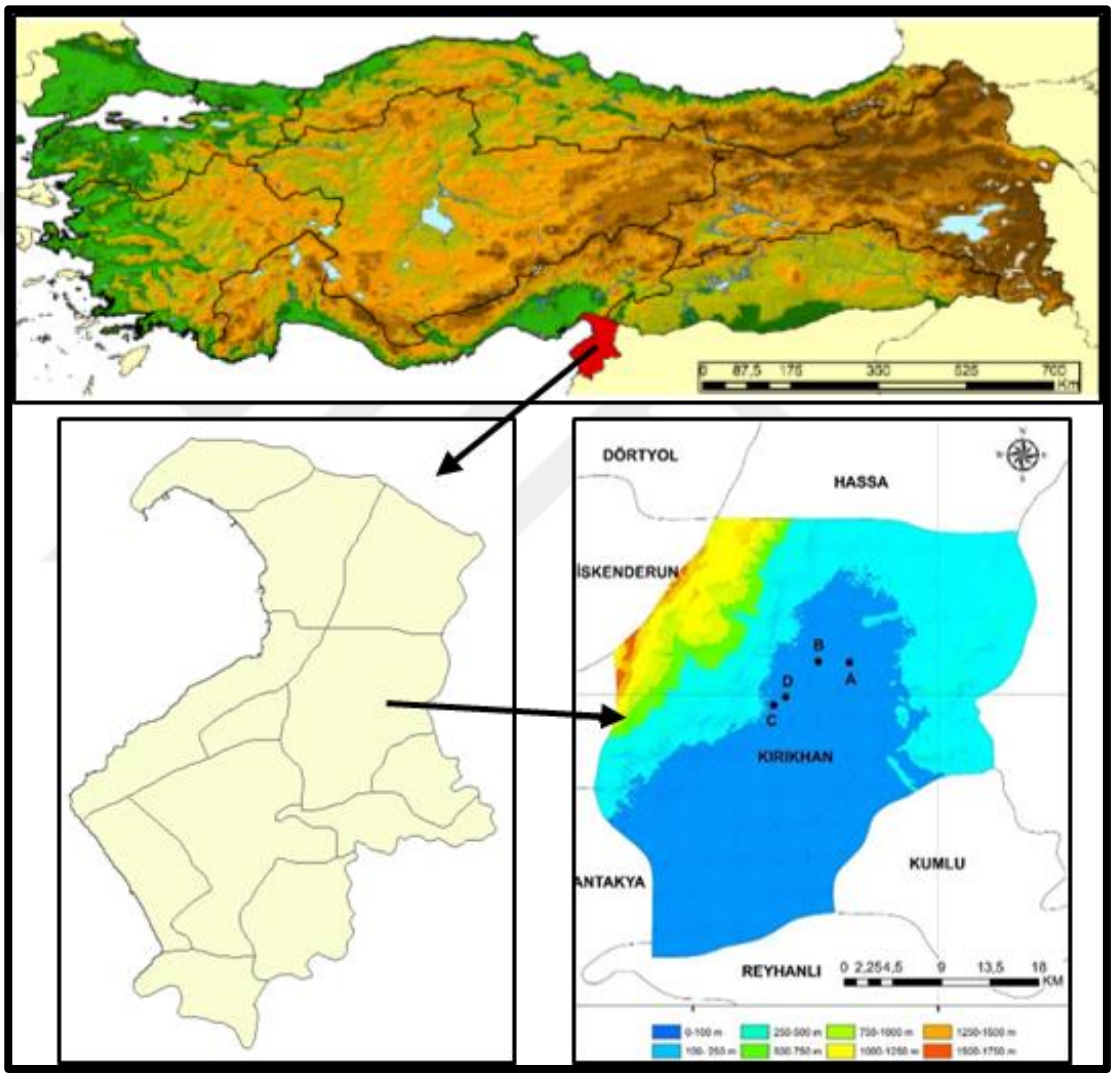
Çizelge 3.1. Hatay ili 1991-2020 meteorolojik gözlem ortalamaları

Aylar	Sıcaklık (°C)	Maksimum Sıcaklık (°C)	Minimum Sıcaklık (°C)	Güneşlenme Süresi (Saat)	Yağışlı Gün Sayısı	Toplam Yağış Miktarı (mm)
Ocak	8.2	12.5	5.0	3.4	13.6	179.5
Şubat	9.9	14.9	5.9	4.6	12.1	162.0
Mart	13.6	19.0	9.1	6.0	11.2	145.1
Nisan	17.4	23.0	12.6	7.3	9.7	108.4
Mayıs	21.6	27.0	16.9	9.1	5.7	89.8
Haziran	25.1	29.7	21.3	10.9	1.8	20.3
Temmuz	27.6	31.6	24.4	11.0	0.8	8.1
Ağustos	28.3	32.5	25.2	10.3	0.8	5.4
Eylül	26.1	31.4	21.7	9.1	4.3	61.7
Ekim	21.5	28.2	16.2	7.0	7.7	56.0
Kasım	14.3	20.3	9.8	5.2	8.0	99.2
Aralık	9.5	13.9	6.2	3.3	11.4	188.7
Yıllık	18.6	23.7	14.5	7.3	87.1	1124.2

Hatay'da yıllık ortalama toplam yağış miktarı 1124.2 mm ve ortalama yağışlı gün sayısı 87.1'dir. Amanos Dağları'nın denizden gelen hava akımlarına karşı dik uzanması ve yükseltinin aniden artış göstermeye başlamasından dolayı genellikle orografik yağışlar görülmektedir. Bu nedenle dağlık alanlarda yağış miktarı daha yüksektir. Meydana gelen yağışların %50'si kış aylarında gerçekleşmektedir. En düşük yağış ortalamasına sahip ay ise 5.4 mm ile Ağustos ayıdır.

Tezin uygulamaya yönelik çalışmaları Hatay ilinin Kırıkhan ilçesindeki sulama sahasında bulunan dört farklı köyde gerçekleştirilmiştir. Kırıkhan ilçesi 36°-37° derece kuzey enlemleri ile 36°-37° doğu boylamları arasında 715 km^2'lik bir alanı kaplamaktadır. Çalışmaların yürütüldüğü arazilerin konumu Şekil 3.4'de verilmiştir.

Amik Ovasının kuzey doğusunda yer alan Kırıkhan Sulama Sahası 1978 yılında kısmen 1988 yılında ise tamamen sulamaya açılmıştır. Sulama suyu ihtiyacı Tahtaköprü Barajı ve Karasu Çayı ile üzerinde bulunan Kamışlar Regülatöründen sağlanmaktadır (Gençoğlu ve Değirmenci, 2019). Kırıkhan ilçesinde 2021 yılında, 42023 ha olan toplam tarım alanında mısır ekili alan 6100 ha ve pamuk ekili alan ise 14300 ha olarak bildirilmiştir (TUİK, 2021).



Şekil 3.4. Çalışma alanlarının coğrafi konumları A) Abalaklı Köyü B) Danaahmetli Köyü C) Mahmutlu Köyü D) Ahrazlı Köyü

3.1.1.1. Abalaklı Köyü

Çalışmanın yürütüldüğü Kırıkhan ilçesine bağlı Abalaklı Köyünde bulunan arazi 36.53° kuzey enlemi ve 36.45° doğu boylamı arasında yer almaktadır. Arazinin uydu görüntüsü Şekil 3.5.'de, arazi ile ilgili ekim bilgileri ise Çizelge 3.2.'de verilmiştir.

Çizelge 3.2. Abalaklı Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri

	Çeşit	Ekim Tarihi	Sıra Arası Mesafe (cm)	Sıra Üzeri Mesafe (cm)
Mısır	KWS-Kebeos	28.02.2021	70	15
Pamuk	Progen-Lima	09.05.2021	70	10



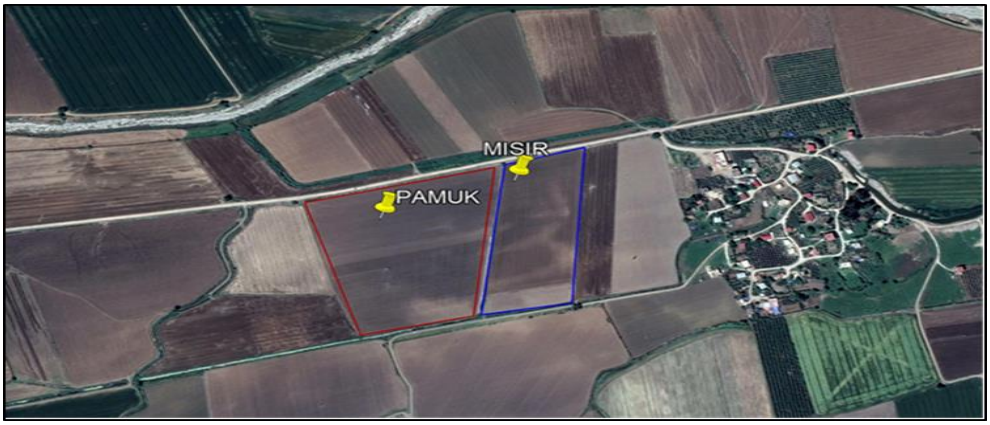
Şekil 3.5. Abalaklı Köyü çalışma alanı

3.1.1.2. Danaahmetli Köyü

Çalışmanın yürütüldüğü Kırıkhan ilçesine bağlı Danaahmetli Köyünde bulunan arazi 36.53° kuzey enlemi ve 36.42° doğu boylamı arasında yer almaktadır. Arazinin uydu görüntüsü Şekil 3.6.'da verilmiştir. Arazi ile ilgili ekim bilgileri ise Çizelge 3.3.'de verilmiştir.

Çizelge 3.3. Danaahmetli Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri

	Çeşit	Ekim Tarihi	Sıra Arası Mesafe (cm)	Sıra Üzeri Mesafe (cm)
Mısır	MAY-14G44	06.03.2021	70	15
Pamuk	MAY-455	24.04.2021	70	10



Şekil 3.6. Danaahmetli Köyü çalışma alanı

3.1.1.3. Mahmutlu Köyü

Çalışmanın yürütüldüğü Kırıkhan ilçesine bağlı Mahmutlu Köyünde bulunan arazi 36.50° kuzey enlemi ve 36.39° doğu boylamı arasında yer almaktadır. Arazinin uydu görüntüsü ise Şekil 3.7.'de verilmiştir. Arazi ile ilgili ekim bilgileri ise Çizelge 3.4.'de verilmiştir.

Çizelge 3.4. Mahmutlu Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri

	Çeşit	Ekim Tarihi	Sıra Arası Mesafe (cm)	Sıra Üzeri Mesafe (cm)
Mısır	Pioneer-1921	01.03.2021	70	15
Pamuk	MAY-455	23.04.2021	70	10



Şekil 3.7. Mahmutlu Köyü çalışma alanı

3.1.1.4. Ahrazlı Köyü

Çalışmanın yürütüldüğü Kırıkhan ilçesine bağlı Ahrazlı Köyünde bulunan arazi 36.50° kuzey enlemi ve 36.40° doğu boylamı arasında yer almaktadır. Arazinin uydu görüntüsü ise Şekil 3.8.'de verilmiştir. Arazi ile ilgili ekim bilgileri ise Çizelge 3.5.'de verilmiştir.

Çizelge 3.5. Ahrazlı Köyü arazisi mısır ve pamuk bitkisi ekim bilgileri

	Çeşit	Ekim Tarihi	Sıra Arası Mesafe (cm)	Sıra Üzeri Mesafe (cm)
Mısır	Dekalb-6980	08.03.2021	70	15
Pamuk	Progen-Lima	22.04.2021	70	10



Şekil 3.8. Ahrazlı Köyü çalışma alanı

3.1.2. Meteorolojik Gözlem Verileri

KİM'den elde edilen verilerin doğrulaması ve gelecek iklim verilerine ölçek küçültme yöntemi uygulanabilmesi için bu çalışmada Hatay ili içerisinde bulunan Meteoroloji İşleri Genel Müdürlüğü (MGM) gözlem istasyonlarına ait veriler kullanılmıştır. Kullanılan istasyonların koordinatları ve ölçüm yılları Çizelge 3.6'da verilmiştir.

Çizelge 3.6. Hatay ili MGM gözlem istasyonları ve koordinatları

İstasyon No	İstasyon Adı	Ölçüm Yılı	Enlem	Boylam
17370	İSKENDERUN	1960-2022	36.5924	36.1582
17372	ANTAKYA	1960-2022	36.2048	36.1513
17645	REYHANLI	2010-2022	36.2657	36.4981
17962	DÖRTYOL	1960-2022	36.8244	36.1981
17986	SAMANDAĞ	1960-2022	36.0814	35.9492
18057	BELEN	2012-2022	36.4889	36.2172
18058	ALTINÖZÜ	2012-2022	36.1200	36.2450
18274	ERZİN	2014-2022	36.9569	36.2086
18275	HASSA	2014-2022	36.7973	36.5392
18276	KIRIKHAN	2014-2022	36.4917	36.3444
18277	KUMLU	2014-2022	36.3639	36.4497
18278	YAYLADAĞI	2014-2022	35.9081	36.0644

Bitki gelişim modelinde kullanılan meteorolojik veriler ise, 18276 nolu Kırıkhan gözlem istasyonundan elde edilmiştir (Şekil 3.9). Gözlem istasyonu otomatik olup, meteorolojik parametrelerdeki değişimlere duyarlı ve bu değişimlerin miktarını ölçen sensörlerden oluşmaktadır. İstasyondan elde edilen 2021 ve 2022 yılı gözlem verileri Çizelge 3.7'de verilmiştir.

Çizelge 3.7. Kırıkhan İlçesi 2021-2022 yılı meteorolojik gözlemleri

Aylar	Maksimum Sıcaklık (°C)		Minimum Sıcaklık (°C)		Yağış Miktarı (mm)	
	2021	2022	2021	2022	2021	2022
Ocak	14.8	11.2	6.8	5.2	188.7	179.8
Şubat	17.1	16.1	7.5	7.6	21.7	24.4
Mart	18.6	14.5	9.0	6.5	37.3	90.0
Nisan	25.1	27.5	13.2	14.2	26.5	2.7
Mayıs	33.1	29.9	18.1	16.9	1.7	14.7
Haziran	33.5	34.0	21.6	21.4	0.8	17.0
Temmuz	38.9	38.0	25.9	24.4	1.2	0.6
Ağustos	38.6	37.0	25.2	25.0	0.4	0.2
Eylül	33.7	34.4	21.9	21.7	2.1	10.6
Ekim	29.2	29.3	17.2	18.1	1.3	5.9
Kasım	22.4	22.8	12.7	13.1	20.5	18.0
Aralık	14.9		7.9		168.1	



Şekil 3.9. Kırıkhan meteorolojik gözlem istasyonu

3.1.3. Çalışmada Kullanılan Mısır ve Pamuk Bitkilerinin Çeşit Özellikleri

3.1.3.1. Pamuk

Çalışmada, ProGen Tohum A.Ş'ye ait Lima ve Doğu Akdeniz Araştırma Enstitüsüne ait May455 çeşidi kullanılmıştır. Çeşitlere ait bazı önemli bilgiler Çizelge 3.8 ve Çizelge 3.9'da verilmiştir.

Çizelge 3.8. Lima pamuk çeşidinin özellikleri (BUGEM, 2018)

Tescil Yılı	2018	
Islah edildiği yer ve yılı	Hatay-2012	
Çeşit sahibi kuruluş	ProGen Tohum A.Ş Hatay	
Islah yöntemi	Melezleme	
Biyolojik özellikler	Koza açma zamanı: Orta	
Tarımsal özellikleri	Ortalama kütlü verim (kg da^{-1})	486.0
	En yüksek kütlü verim (kg da^{-1})	611.0
	Çırçır randımanı (%)	44.3
	Lif verimi (kg da^{-1})	215.6
Önerilen Alanlar	Ege-Akdeniz Bölgesi	

Çizelge 3.9. May455 pamuk çeşidinin özellikleri (BUGEM, 2017)

Tescil Yılı	2017	
Islah edildiği yer ve yılı	Adana-2013	
Çeşit sahibi kuruluş	Doğu Akdeniz TAE-Adana	
Islah yöntemi	Melezleme	
Biyolojik özellikler	Koza açma zamanı: Orta	
Tarımsal özellikleri	Ortalama kütlü verim (kg da^{-1})	524.0
	En yüksek kütlü verim (kg da^{-1})	637.0
	Çırçır randımanı (%)	42.5
	Lif verimi (kg da^{-1})	224.8
Önerilen Alanlar	Ege-Akdeniz Bölgesi	

3.1.3.2. Mısır

Çalışmada, dört farklı mısır çeşidi kullanılmıştır. Abalaklı arazisimde KWS-Kebeos, Danaahmetli arazisimde May-14G44, Mahmutlu arazisimde Pioneer-1921 ve Ahrazlı arazisimde Dekalb-6980 çeşitleri çiftçiler tarafından tercih edilmiştir. Bu çeşitlere ait bazı önemli bilgiler sırasıyla Çizelge 3.10, Çizelge 3.11, Çizelge 3.12 ve Çizelge 3.13'de verilmiştir.

Çizelge 3.10. Kebeos mısır çeşidinin özellikleri (BUGEM, 2017)

Tescil yılı	2016	
Islah edildiği yer ve yılı	İtalya-2012	
Çeşit sahibi kuruluş	KWS Türk Tarım Ticaret A.Ş	
Islah yöntemi	Tek Melez	
Olum müddeti	Ortalama 130-135 gün. FAO olum grubu 700-750 aralığındadır.	
Tane tipi	At dişi	
Tarımsal özellikleri	Tepe Püskülü Gün Sayısı	71.0
	Hasatta rutubet oranı (%)	18.6
	Tane-Koçan oranı (%)	84.0
	Bitki boyu (cm)	278.0
Verim durumu	Ortalama verimi 1632.8 kg da^{-1}	
Denemelerin yapıldığı bölgeler	Akdeniz, Marmara, Karadeniz ve Ege Bölgeleri	

Çizelge 3.11. May-14G44 mısır çeşidinin özellikleri (BUGEM, 2022)

Tescil yılı	2020
Islah edildiği yer ve yılı	İtalya-2013
Çeşit sahibi kuruluş	May Agro Tohumculuk Sanayi ve Ticaret A.Ş
Islah yöntemi	Tek Melez

Çizelge 3.12. (Devam) May-14G44 mısır çeşidinin özellikleri (BUGEM, 2022)

Olum müddeti	Bölgelere göre değişmekle birlikte ortalama 125 gün. FAO olum grubu 650'dir.	
Tane tipi	At dişi	
Tarımsal özellikleri	Çiçeklenme süresi (gün)	55.0
	Hasatta rutubet oranı (%)	21.4
	Tane-Koçan oranı (%)	84.0
	Bitki boyu (cm)	276.0
Verim durumu	Erkenci çeşitler koşullarında ortalama verimi 1227.3 kg da^{-1}	
Denemelerin yapıldığı bölgeler	Akdeniz, Marmara, Güneydoğu Anadolu ve Ege Bölgeleri	

Çizelge 3.13. P1921 mısır çeşidinin özellikleri (BUGEM, 2015)

Tescil yılı	2015	
Islah edildiği yer ve yılı	İtalya-2006	
Çeşit sahibi kuruluş	Pioneer Tohumculuk Dağıtım ve Paz. Ltd. Şti.	
Islah yöntemi	Tek melez	
Olum müddeti	Bölgelere göre değişmekle birlikte ortalama 125-130 gün. FAO 650-700 olum grubundadır.	
Tane tipi	At dişi	
Tarımsal özellikleri	Tepe püskülü çıkarma gün sayısı	65.0
	Hasatta rutubet oranı (%)	17.3
	Tane-Koçan oranı (%)	88.0
	Bitki boyu (cm)	248.0
Verim durumu	Ana ürün koşullarında ortalama verimi 1494.4 kg da^{-1}	
Denemelerin yapıldığı bölgeler	Akdeniz, Marmara, Karadeniz ve Ege Bölgeleri	

Çizelge 3.14. DKC6980 mısır çeşidinin özellikleri (BUGEM, 2020)

Tescil yılı	2020	
Islah edildiği yer ve yılı	İtalya-2016	
Çeşit sahibi kuruluş	Monsanto Gıda ve Tarım Ticaret Ltd. Şti.	
Islah yöntemi	Tek melez	
Olum müddeti	Bölgelere göre değişmekle birlikte ortalama 130 gün. FAO 700 olum grubundadır.	
Tane tipi	At dişi	
Tarımsal özellikleri	Çiçeklenme süresi (gün)	71.0
	Hasatta rutubet oranı (%)	17.8
	Tane-Koçan oranı (%)	87.0
	Bitki boyu (cm)	287.0
Verim durumu	Ana ürün koşullarında ortalama verimi 1779.5 kg da^{-1}	
Denemelerin yapıldığı bölgeler	Akdeniz, Marmara, Karadeniz ve Ege Bölgeleri	

3.1.4. Küresel İklim Modellerinin Özellikleri

Çalışma kapsamında 1980-2014 dönemi için CMIP6 KİM'lerin günlük yağış, minimum ve maksimum sıcaklık çıktılarının Hatay ili için performansları değerlendirilmiştir. KİM'lere ait veriler http://cmip-pcmdi.llnl.gov/cmip6/ adresinden indirilmiştir. Elde edilen ham veriler, Hatay ili gözlem istasyonları için elde edilen referans verileri ile karşılaştırılmıştır. Bu çalışmada değerlendirilen KİM'ler Çizelge 3.14'de listelenmiştir.

Çizelge 3.15. Çalışmada kullanılan küresel iklim modelleri

Model	Enstitü	Ülke
ACCESS-CM2	Avustralya İklim Sistemi Bilim Merkezi ve Araştırma Konseyi	AVUSTRALYA
CMCC-ESM2	Avrupa-Akdeniz İklim Değişikliği Merkezi	İTALYA
EC-EARTH3	Avrupa Topluluğu-Yeryüzü Konsorsiyumu	AVRUPA BİRLİĞİ
GFDL-CM4	A.B.D. Jeofizik Akışkanlar Dinamiği Laboratuvarı	A.B.D
MIROC6	Japonya Deniz-Yer Bilimi ve Teknolojisi Ajansı	JAPONYA
MPI-ESM1-2-HR	Max Planck Meteoroloji Enstitüsü (MPI-M)	ALMANYA
TAIESM1	Tayvan Çevresel Değişiklikler Araştırma Merkezi	TAYVAN

3.1.5. AquaCrop Bitki Verim Tahmin Modeli

AquaCrop, çevre etkilerinin değerlendirilmesi ve ürün verimine yönelik olarak FAO tarafından geliştirilmiş olan bitki simülasyon modelidir. AquaCrop toprak, bitki ve atmosfer arasındaki etkileşimi kullanarak, bitki biyokütlesini ve hasat edilebilir verimi tahmin etmek için kullanılmaktadır (Steduto ve ark., 2009; Raes ve ark., 2021). Model diğer bitki gelişim modellerine kıyasla daha az sayıda parametreye ihtiyaç duyması nedeniyle yaygın olarak kullanılmaktadır (Khafajeh ve ark., 2020). Model, parametre ihtiyacındaki bu azalmayı bitkinin gelişimini etkileyen temel fizyolojik süreçlere ve çevresel faktörlere odaklanarak başarmaktadır. Bu faktörler; sıcaklık, güneş radyasyonu, yağış, toprak özellikleri ve bitkiye özgü özelliklerdir (Heng ve ark., 2009).

AquaCrop modeli; bitki gelişimi, bitki transpirasyonu, toprak üstü biyokütlesi ve ürün verimi olmak üzere bitki verimini dört aşamada tahmin etmektedir. Model yeşil bitki örtü yüzeyinin kapladığı alanla (CC), ekimden hasata kadar olan dönem boyunca yapılan gözlem ve ölçümler arasında ilişki kurarak verimi tahmin etmektedir. AquaCrop modelini diğer modellerden ayıran önemli özelliklerden biri tahmin yaparken diğer modellerin aksine yaprak alan indeksi yerine CC değerini dikkate almasıdır. CC değerleri uzaktan algılama ve görüntü işleme yöntemleri ile basit bir şekilde belirlenerek modele girilebilmektedir (Raes ve ark., 2009).

Modelde bitkinin transpirasyon miktarı, ET_0 değeri ile bitki katsayısının çarpılması ile hesaplanmaktadır. Verimi tahmin edilecek olan bitkinin katsayısı, bitki örtü yüzeyinin (CC) kapladığı alana bağlı olarak hasat zamanına kadar değişkenlik gösterebilmektedir (Raes ve ark., 2009). Bitkinin toprak üstü biyokütlesi, bitkinin transpirasyon miktarlarının kümülatif miktarı (ΣTr) ile oransal olarak model tarafından hesaplanmaktadır. Bu oransal faktör biyokütlenin su verimliliği (WP) olarak nitelendirilmektedir. AquaCrop'ta WP değeri, farklı konum ve mevsimler ile CO_2 konsantrasyonları için geçerli bitkiye özgü bir parametredir. Model tarafından benzetimi yapılan bitkinin verimi, hasat endeksine bağlı olarak hesaplanan toprak üstü biyokütle miktarından tahmin edilmektedir. Hasat indeksinin gerçek değeri, referans hasat indeksinin etkilerini yansıtan bir düzeltme faktörü olarak kullanılmaktadır (Raes ve ark., 2009; Steduto ve ark., 2009).

3.2. Yöntem

3.2.1. Geçmiş Meteorolojik Verilerin Modellenerek Tahmin Edilmesi

Hidrolojik ve meteorolojik çalışmalarda gözlem istasyonlarından elde edilen verilerde karşılaşılan en büyük sorun eksiksiz, sürekli ve uzun kayıtlı olmamalarıdır. Yeterli istasyon ağının kurulmamış olması gibi nedenlerden dolayı uzun yıllık eksiksiz meteorolojik veri setleri bulmak oldukça zordur (Şen, 2004; Teegavarapu ve ark., 2018). Uzun yıllık gözlem kayıtları bulunmayan istasyonlarda, mevcut veriler ile aynı havza içerisindeki diğer gözlem istasyonlarıyla anlamlı ilişki kurularak eksik kayıtlar az bir hata ile tahmin edilebilmektedir. Özellikle, hidrolojik süreçler gibi doğrusal olmayan problemlerin modellenmesinde gösterdiği başarılı performanslar nedeniyle, YSA

meteorolojik verilerin tahmin edilmesi oldukça yaygın olarak kullanılmaktadır (Nayak ve ark., 2013; Teegavarapu ve ark., 2018; Khanzode ve Sarode, 2020).

Hatay ili sınırlarında bulunan meteorolojik istasyonların çoğunda günlük sıcaklık ve yağış miktarının uzun yıllık kayıtlarının bulunmadığı belirlenmiştir (Çizelge 3.2). Bu nedenle uzun yıllık kayıtları bulunmayan istasyonlar (Kırıkhan, Kumlu, Reyhanlı, Altınözü, Yayladağı, Hassa, Belen ve Erzin) için sıcaklık ve yağış verileri çok katmanlı YSA yöntemi ile modellenerek elde edilmiştir. Modellerde tahmin edici değişken olarak 1980-2022 yılları arası (42 yıl) ölçümü bulunan İskenderun, Antakya, Dörtyol ve Samandağ istasyonlarından elde edilen maksimum sıcaklık, minimum sıcaklık ve yağış verileri kullanılmıştır.

3.2.1.1. Meteorolojik Gözlem Verilerine Ön İşlem Uygulanması

Modelleme çalışmaları için verilerin ön işlemden geçirilmesi kullanılacak olan yöntem ve algoritma seçimi kadar önemlidir. Verilerin ön işlemden geçirilmesi modelleme hatalarının azaltılmasına ve doğru sonuca daha hızlı bir şekilde ulaşılabilmesine olanak sağlamaktadır (Yu ve ark., 2005). Gözleme dayalı olarak elde edilen veri setlerinde genellikle eksik ya da gereksiz veriler bulunabilmektedir. Bu verilerin modellemede doğrudan kullanılması tahmin doğruluğunu önemli ölçüde etkileyebilmektedir. Bu nedenle, verilerin modelleme çalışmalarında kullanılmadan önce ön işlemden geçirilerek uygun hale getirilmesi oldukça önem taşımaktadır (Roy ve ark., 2019). Bu çalışmada kullanılan ön işleme uygulamaları; kayıp verilerin atanması, değişken seçimi, normalizasyon ve veri ayrımı işlemleridir.

3.2.1.1.1. Kayıp Verilerin Atanması

Kayıp veri; gözlem sırasında herhangi bir nedenden dolayı verinin ölçülememesi veya kaydedilememesi durumunda değişkenlere ait bilginin veri setinde bulunmaması sorunudur. Bu durum bilgi kaybına yol açabilmekte ve analiz sonuçlarında hatalara neden olabilmektedir. Bu nedenle büyük veri setlerinde kayıp verilerin yerini doldurabilmek büyük önem taşımaktadır (Rahmany ve ark., 2022).

Çalışmamızda kullanılacak gözlem veri setlerindeki kayıp verilerin (Çizelge 3.15) tamamlanması için benzer çalışmalarda daha başarılı bulunan MissForest veri atama

yöntemi tercih edilmiştir (Stekhoven ve Bühlmann, 2012; Mital ve ark., 2020; Alsaber ve ark., 2021). Bu yöntem, her bir kayıp değeri ait olduğu değişkenin diğer değerleriyle ilişkilendirmekte ve birden fazla karar ağacı oluşturmaktadır. Oluşturduğu bu ağaçlardan elde ettiği tahminlerin ortalamasını alarak kayıp veriye atama gerçekleştirmektedir. Bu işlem sürekli güncellenerek yinelemeli olarak çalışmakta ve tahmin performansı değerlendirilmektedir. Bu değerlendirme, önceki atama sonucu ile yeni atama sonucu arasındaki farkta artış görülene kadar devam etmektedir (Stekhoven ve Bühlmann, 2012). Çalışmada kayıp verilerin atanması yöntemi R Studio uygulamasında missForest paketi kullanılarak gerçekleştirilmiştir.

Çizelge 3.16. Meteorolojik istasyonlara ait olan kayıp günlük veri yüzdeleri

İstasyonlar	Gözlem Dönemi	Kayıp Veri Yüzdesi		
		Maksimum Sıcaklık	Minimum Sıcaklık	Yağış
Altınözü	2013-2022	%1.68	%1.68	%1.51
Antakya	1980-2022	%0.12	%0.16	%0.13
Belen	2013-2022	%0.27	%0.27	%0.27
Dörtyol	1980-2022	%0.44	%0.45	%0.40
Erzin	2014-2022	%0.44	%0.44	%0.36
Hassa	2014-2022	%1.65	%1.65	%1.61
İskenderun	1980-2022	%0.00	%0.00	%0.01
Kırıkhan	2014-2022	%3.01	%2.97	%2.49
Kumlu	2014-2022	%0.96	%0.96	%0.68
Reyhanlı	2010-2022	%1.64	%2.24	%1.97
Samandağ	1980-2022	%0.70	%0.71	%0.57
Yayladağı	2014-2022	%0.80	%0.80	%0.52

3.2.1.1.2. Değişkenlerin Seçimi

En uygun modeli oluşturabilmek için veri kümesinde bulunan değişkenler arasındaki ilişkinin analiz edilerek belirlenmesi oldukça önemli bir veri ön işleme adımıdır. Değişken seçimindeki amaç, modellemede aynı performansa daha az sayıda değişken kullanarak daha hızlı bir şekilde ulaşmaktır. Değişkenler arasındaki ilişkiyi analiz edebilmek için pek çok yöntem kullanılmaktadır. Bunlardan en yaygın kullanılanı korelasyon katsayısı yöntemidir (Blessie ve Karthikeyan, 2012; Londhe ve ark., 2015). Korelasyon katsayısı iki değişken arasında bulunan ilişkiyi istatistiksel olarak ölçmek için kullanılmaktadır ve Denklem 3.1 ile hesaplanmaktadır.

$$r = \frac{\sum_{i=1}^{n}(x_i - \bar{x}) \times (y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2} \times \sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}} \quad (3.1)$$

Denklemde x ve y, aralarındaki ilişkinin değerlendirildiği değişkenlerdir. $\bar{x}$ terimi x'in ve $\bar{y}$ terimi y'nin ortalamasını temsil etmektedir. Korelasyon katsayısı değişkenler arasındaki ilişkinin büyüklüğünü ve yönünü belirlemeye olanak sağlamaktadır. Katsayının negatif olması iki değişken arasında zıt, pozitif olması ise aynı yönde doğrusal bir ilişkinin bulunduğunu göstermektedir. Genel olarak kabul edilen katsayı değerlerinin ilişki oranları Çizelge 3.16'da verilmiş ve yüksek korelasyona sahip değişkenler modeller de girdi olarak tercih edilmiştir (De Vaus ve ark., 2002; Napitupulu ve ark., 2018).

Çizelge 3.17. Korelasyon katsayısı değerlendirme tablosu

Korelasyon Katsayısı	İlişki Oranı
0.0-0.2	Çok Zayıf
0.2-0.4	Zayıf
0.4-0.6	Orta
0.6-0.8	Yüksek
0.8-1.0	Çok Yüksek

3.2.1.1.3. Normalizasyon İşlemi

Normalizasyon, YSA uygulamaları için önemli bir veri ön işleme adımıdır. Verilerin normalleştirilmesi, veri setindeki dağılımın düzenli olmasını sağlayarak modelin tahmin doğruluğu ve hızında büyük fark yaratabilmektedir. Özellikle aşırı büyük ve küçük değerlerin bulunduğu veri setleri, ağın yanlış bir şekilde eğitilmesine neden olabilmektedir. Bu nedenle normalizasyon işlemi, bütün verilerin eğitilen ağa eşit ölçüde katkıda bulunmasını sağlayarak ortalamaya aykırı olan değerlerin etkisinin azalmasını sağlamaktadır (Gómez-Escalonilla ve ark., 2022).

Çalışmamızda kullanımı yaygın normalizasyon işlemlerinden biri olan Z-score normalizasyon işlemi kullanılmıştır. Z-score normalizasyon işleminde veriler, ortalama 0 ve varyans 1'e eşit olacak şekilde dönüştürülerek birimsiz hale getirilmektedir. Normalizasyon işlemi Denklem 3.2 kullanılarak gerçekleştirilmiştir. Bu denklemde, Z standartlaştırılmış veriyi, d standartlaştırılmak istenen veriyi, μ aritmetik ortalamayı ve σ standart sapmayı temsil etmektedir.

$$Z = (d - \mu) / \sigma \quad (3.2)$$

3.2.1.1.4. Eğitim ve Test Veri Setinin Oluşturulması

Modelleme çalışmalarında, kullanılan modelin performansının değerlendirilebilmesi için veri setinin eğitim ve test veri seti olarak ayırılması gerekmektedir. Bu ayrım, modelin eğitilmediği veriler ile kullanıldığında ne kadar başarılı olacağının belirlenmesi amacı ile farklı oranlarda gerçekleştirilebilmektedir (Joseph, 2022). Bu çalışmada modelleme çalışmalarındaki başarılı kullanımından dolayı 2/3 eğitim ve 1/3 test veri seti ayrımı tercih edilmiştir (Liu ve Cocea, 2017).

Veri seti ayrımı sonucunda eğitim verileriyle model oluşturulmakta ve test verileri kullanılarak modelin performansı değerlendirilmektedir. Ancak bu ayrılan veri setinde benzer değerlere sahip kayıtların bir arada seçilebilme ihtimali bulunmaktadır ve bu durum model tahmin performansını etkileyebilecek olan aşırı uyum (overfitting) problemine sebep olabilmektedir (Liu ve ark., 2016). Aşırı uyum sorunu, modelin eğitildiği verileri ezberlemesinden dolayı başka veriler ile kullanıldığında tahmin performansının oldukça başarısız olması durumudur. Bu sorunla karşılaşmamak için k katlamalı çapraz doğrulama (k-fold cross validation) yöntemi kullanılmaktadır (Zhang ve ark., 2016).

K katlamalı çapraz doğrulama yöntemi veri setlerini kullanıcı tarafından belirlenen sayıda parçalara ayırmaktadır. Bu ayrımda ilk parça test diğer parçalar ise modelin eğitilmesi için kullanılmakta ve sırayla her parça test ve eğitim şeklinde kullanılarak eğitim gerçekleştirilmektedir. Tüm yinelemeler gerçekleştirildikten sonra en düşük hata oranına sahip olan veri seti ayrımı kullanılmaktadır. Çapraz doğrulama yöntemi uygulandıktan sonra elde edilen tahminlerin daha güvenilir olduğu kabul edilmektedir. Literatürde yaygın olarak 10-katlamalı çapraz doğrulama yöntemi kullanılması nedeniyle bu çalışmada da anılan yöntem tercih edilmiştir (Hadjisolomou ve ark., 2021).

3.2.1.2. Çok Katmanlı Yapay Sinir Ağı

İnsan beyninde öğrenme işleminin gerçekleşmesi sinir ağlarının kullanımı ile meydana gelmektedir. Bu sinir ağları bilgi taşıyan nöronlardan ve bunların arasındaki iletişim ağından sorumlu sinaps bağlantılarından oluşmaktadır. Günümüzde bu öğrenme

sisteminin çalışma prensibini bir sayısal modele dönüştürebilmek amacıyla pek çok çalışma yürütülmektedir. Bu çalışmalarla da birçok YSA modeli geliştirilmiştir (Londhe ve ark., 2015; Mehdizadeh, 2018; Nguyen ve ark., 2021).

Bu ağların en önemli kullanım amacı doğrusal olmayan problemlerin en kısa sürede çözülmesi için elde bulunan verilerle elde edilebilecek bir bilgi ağı oluşturmaktır. YSA'nın bu yeteneği, bilgilerin çok sayıda ağ bağlantısı aracılığı ile paylaşabilmesi sayesinde model çıktılarının, eksik ve gereksiz verilere daha az hassas olarak elde edilmesini sağlamaktadır (Aubakirova ve ark., 2022). Ayrıca YSA'da, girdiler ve çıktı arasındaki fiziksel süreçleri tam olarak öğrenme gereksinimi bulunmamaktadır. Bu avantajlarından dolayı çok sayıda girdi gerektiren karmaşık hidrolojik ve meteorolojik süreçlerin kolaylıkla analiz edilebilmesine olanak sağlamaktadır (Akcakoca ve Apaydın, 2020).

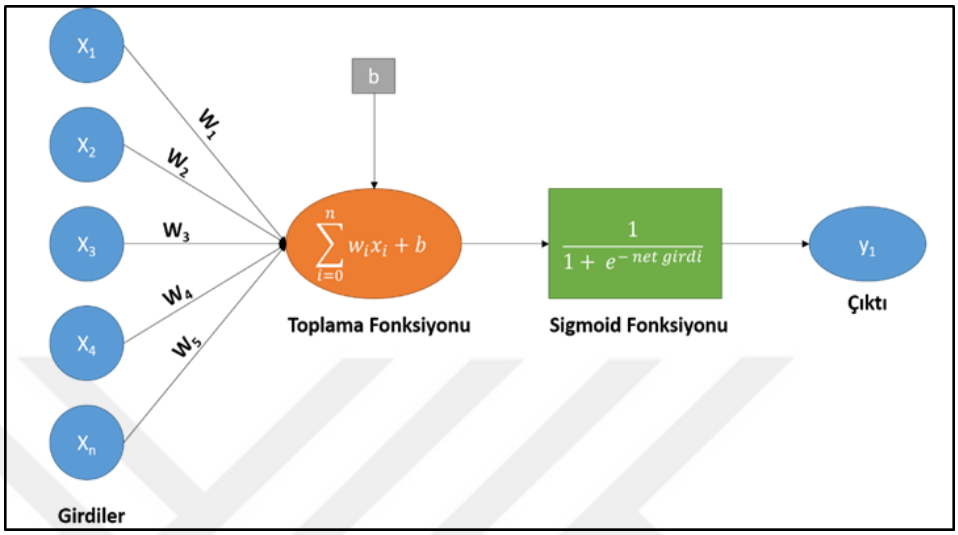
YSA modelleri genellikle girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşmaktadır. Giriş katmanı değişkenlerden alınan bilgiyi gizli katmanlara transfer etmekten sorumludur ve bu katmanda herhangi bir işlem uygulanmamaktadır. Gizli katmanda veriler arasında matematiksel bir ilişki kurulmakta ve bu algoritmayı kullanarak elde edilen bilgiler çıktı katmanına iletilmektedir (Raschka ve ark., 2020). Çıktı katmanında ise girdi katmanında verilen bilgilere karşılık elde edilen çıktılar üretilmektedir. YSA hücrelerinde ilk olarak her bir girdi değişkeni ağırlıklar ile çarpılır ve sapma değeri ile toplanmaktadır. Daha sonra elde edilen tüm değerler toplanarak aktivasyon fonksiyonunda kullanılımakta ve elde edilen sonuç çıktı katmanına aktarılmaktadır (Şekil 3.10 ve Şekil 3.11).

YSA modellerinde herhangi bir nöronun çıktısı aşağıda verilen Denklem 3.3 kullanılarak elde edilmektedir (Kim ve Valdés, 2003).

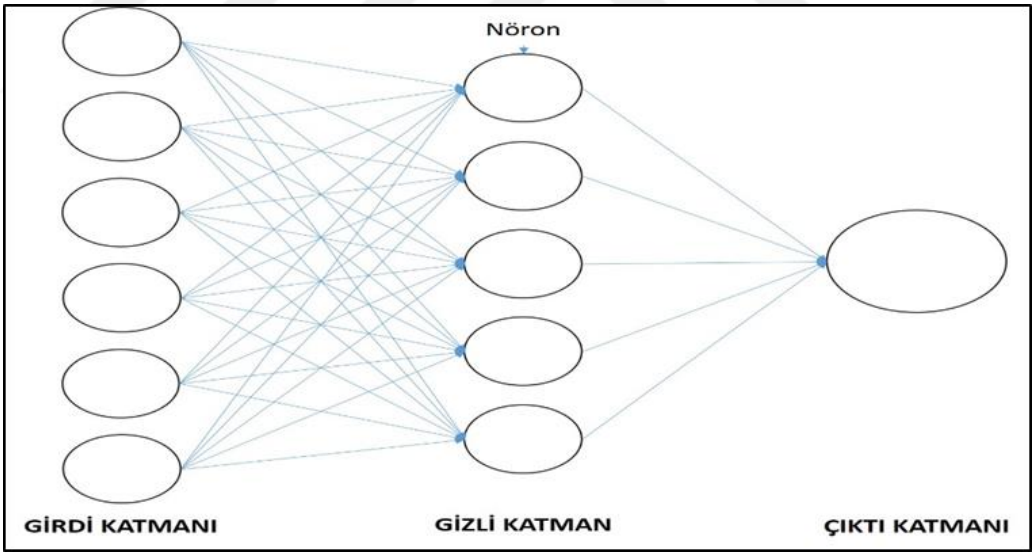
$$y = f(\sum_{i=1}^{n} x_i w_i + b_i) \quad (3.3)$$

Bu denklemde x_i girdi vektörü, w_i ise ağırlık vektörünü, b sapma değeri, f aktivasyon fonksiyonu ve y ise çıktıyı temsil etmektedir. Ağırlıklar modele girilen bilgilerin yapay sinir hücrelerine olan etkisini ve önemini ifade etmektedir. Bu ağırlıklar modelin eğitim süresi boyunca değişkenlik gösterebilmektedirler. Bu değerler eğitim sonunda optimum değeri alarak model içerisinde sabitlenirler. Bu sabit değerler girdi

değerleri ile çarpılır ve sapma değeri ile toplanarak net girdi değerleri elde edilmektedir. Son olarak hücreye gelen net girdi aktivasyon fonksiyonu ile işlenerek hücrenin bu girdiye karşılık üreteceği çıktı belirlenmektedir.



Şekil 3.10. YSA hücresinin (nöron) yapısı ve çalışma prensibi



Şekil 3.11. YSA modellerinin genel ağ yapısı

Aktivasyon fonksiyonu olarak sigmoid, hiperbolik tanjant (tanh), lineer, ve rektefiye edilmiş lineer fonksiyonlar (ReLU) kullanılmaktadır. YSA'da genellikle aktivasyon fonksiyonu olarak Denklem 3.4'te verilen sigmoid fonksiyonu tercih edilmektedir (Dahamsheh ve Aksoy, 2009).

$$f\ (net\ girdi) = \frac{1}{1+ e^{-net\ girdi}} \quad (3.4)$$

Literatürde farklı uygulamalar için birçok YSA türü bulunmaktadır. Bunlar arasında en basit ve yaygın kullanımı olan çok katmanlı sinir ağlarıdır (Hanoon ve ark., 2021). Çok katmanlı sinir ağları ileri beslemeli ağlardır ve öğrenme yöntemi olarak genellikle geri yayılım (back propogation) algoritması kullanılmaktadır (LeCun ve ark., 2015). Bu ağlar denetimli (supervised) öğrenme stratejisine göre çalışmaktadırlar. Buna göre ağın eğitilebilmesi için eğitim veri setine ihtiyaç duyulmaktadır. Eğitim setinde her örnek için hem girdiler hem de girdilere karşılık gelen çıktılar bulunmaktadır (Jiang ve ark., 2020). Eğitim iki aşamadan oluşmaktadır. İleri besleme ile girdiler arasında matematiksel bir ilişki kurmaya çalışılır ve çıktılar oluşturulur. Geriye yayılım işleminde ise farklı bağlantı ağırlıkları değerlendirilmektedir. Bu veriler arasında kabul edilebilir yakınsama değerine sahip bağlantı ağırlıkları elde edilene kadar algoritma kendini tekrar tekrar başlatmaktadır. Model yaptığı bu hatalarla kendini eğiterek hata değerini en aza indirmeye çalışmaktadır (Velo ve ark., 2014).

Bu çalışmada, üç katmanlı ileri beslemeli ve geri yayılımlı sinir ağları kullanılmıştır. Bu amaçla söz konusu ağ R programlama dili ile R Studio uygulamasında oluşturulmuştur. Çalışmada tek bir gizli katman ele alınmıştır. Bunun nedeni ise yeterli nörona sahip tek bir gizli katmanın, çok boyutlu problemleri iyi bir şekilde modellemek için yeterli olmasıdır (Papailiou ve ark., 2022). Girdi katmanı olarak ilgili hedef değişken (Kırıkhan, Kumlu, Reyhanlı, Altınözü, Yayladağı, Hassa, Belen ve Erzin) ile yüksek korelasyona sahip olduğu belirlenen tahmin edici (İskenderun, Antakya, Dörtyol ve Samandağ) istasyonlardan elde edilen günlük veriler kullanılmıştır. Çıktı katmanı ise hedef istasyonun günlük meteorolojik verileri olmuştur. Gizli katmanın transfer fonksiyonu olarak ağın performans hızını arttırdığı için çalışmalarda yaygın kullanımı olan sigmoid fonksiyonu kullanılmıştır.

YSA tahmin modellerinin performansı gizli katmanda kullanılan nöron sayısından etkilenmektedir. Gizli katmanlarda kullanılacak nöron sayısı ile ilgili kesin bir kural olmamakla birlikte genellikle girdi katmanındaki değişken sayısının iki katından az olması gerektiği kabul edilmektedir (Heaton, 2008). Bu nedenle, modelden en düşük hata miktarına sahip tahminleri elde edebilmek için farklı nöron sayıları değerlendirilmiş ve en uygun nöron sayısı deneme yanılma yöntemi ile seçilerek modeller oluşturulmuştur.

3.2.2. Çalışma Alanına En Uygun Küresel İklim Modelinin Seçimi

Gözlemlenen iklim verileri ile benzer çıktılar üretebilen KİM'lerin sıralanması ve uygun olanın seçilmesi için birçok farklı istatistiksel değerlendirme metrikleri kullanılmaktadır (Ahmed ve ark., 2019; Noor ve ark., 2019; Zhu ve ark., 2021). Çalışma kapsamında alansal dağılımı tahmin edebilme performansı için TSS, hata miktarının büyüklüğünü belirlemek için NRMSE ve tahmin performans başarısını değerlendirmek için Wilmott uyumluluk indeksi (d) metrik değerleri hesaplanmıştır. Ancak çalışma alanı için en uygun KİM, modellerin farklı metrikler için farklı sonuçlar verebileceğinden dolayı istatistiksel metriklere dayalı çok kriterli karar verme (MCDM) yöntemi ile belirlenmiştir. Benzer çalışmalarda kullanılmış olduğu için uzlaşık programlama (CP) çok kriterli karar verme yöntemi olarak tercih edilmiştir (Srinivasa Raju ve Nagesh Kumar, 2020; Khadka ve ark., 2021).

CP, modeller arasında tercih yapmada belirlenen ideal değere olan uzaklığı minimize etme esasına dayanmaktadır. Bu amaçla her bir performans kriterinin en iyi olduğu değerler belirlenmekte ve ideal değere en yakın ölçümün elde edilmesi sağlanmaktadır (Zeleny, 2012). Yöntem özet olarak bir performans değerlendirme metriğinin normalize edilmiş değeri ile aynı metriğin ideal değeri arasındaki farkın hesaplanmasına dayanmaktadır (Srinivasa Raju ve Nagesh Kumar, 2020). Bu karar verme yönteminde, dikkate alınan ideal değere olan uzaklığın hesaplanmasında aşağıda verilen adımlar uygulanarak metrik uzaklığı (Lp) hesaplanmaktadır (Srinivasa Raju ve Nagesh Kumar, 2018).

İlk olarak hesaplanan performans metriklerine normalizasyon işlemi (Denklem 3.5) uygulanarak değerlerin ortak bir ölçeğe getirilmesi ve olası yanlılığın azaltılması sağlanmaktadır.

$$k_{aj} = \frac{K_j(a)}{\sum_{a=1}^{T} K_j(a)} \tag{3.5}$$

Bu denklemde k_{aj}; normalize edilmiş değeri, $K_{j(a)}$; KİM için hesaplanan j performans metriğinin değerini, a; KİM'i, J; kullanılan performans metriğini ve T; değerlendirmeye alınan KİM model sayısını temsil etmektedir. Daha sonra normalize edilmiş performans metriklerinin karar problemindeki önemini belirlemek için her bir

performans metriğinin ağırlık değerlerinin hesaplanması gerekmektedir. Bu değerler çalışmamızda entropi yöntemi ile hesaplanmıştır (Denklem 3.6, Denklem 3.7 ve Denklem 3.8) (Srinivasa Raju ve Nagesh Kumar, 2010).

$$En_j = -\frac{1}{\ln(T)}\sum_{a=1}^{T} k_{aj} \ln(k_{aj}) \qquad j = 1, \dots, J \tag{3.6}$$

$$Dd_j = 1 - En_j \tag{3.7}$$

$$r_j = \frac{Ddj}{\sum_{j=1}^{J} Ddj} \tag{3.8}$$

Bu denklemlerde E_{nj}; j. performans metriği için entropi değerini, D_{dj}; farklılaşma derecesini ve r_j; performans metriklerinin ağırlık değerini temsil etmektedir. Son olarak modellerin sıralanması için performans metriklerinin ideal k_j^* ve ideal olmayan (k_{j*}) değerleri dikkate alınarak Denklem 3.9'un kullanımı ile belirlenmektedir. Hesaplanan en düşük Lp değerine sahip model en başarılı olarak kabul edilmektedir (Srinivasa Raju ve Nagesh Kumar, 2010).

$$L_p = \left[\sum_{j=1}^{J} r_j \left|\frac{k_j^* - k_{aj}}{k_j^* - k_{j*}}\right|\right]^{1/2} \tag{3.9}$$

Bu çalışmada Hatay ili için iklim değişikliğinin etkilerini değerlendirmek amacıyla kullanılacak olan KİM'in seçimi için uygulanan işlem adımları şu şekilde özetlenmiştir:

1. Çalışma kapsamında değerlendirilen tüm KİM'ler için elde edilen günlük netCDF formatındaki çıktılar; R Studio programında gtools, raster ve rgdal paketleri kullanılarak meteoroloji gözlem istasyonlarına ait koordinatlara göre ayıklanmış ve MS Excel'e aktarılmıştır.

2. Elde edilen günlük çıktılar kullanılarak MS Excel programında 1980-2014 yılları için uzun yıllık ortalama yağış miktarı, maksimum ve minimum sıcaklık değerleri elde edilmiştir.

3. Elde edilen ortalamalar ArcGIS 10.8 yazılımına aktarılmıştır. ArcGIS yazılımında KİM çıktılarına, ters mesafe ağırlıklandırma (IDW) yöntemi kullanılarak

meteorolojik gözlem istasyonlarının konumuna göre enterpolasyon yapılarak alansal dağılım haritaları elde edilmiştir.

4. Oluşturulan alansal dağılım haritalarından elde edilen piksel değerleri; TSS, d ve NRMSE istatistiksel performans metrikleri kullanılarak karşılaştırılmıştır.

5. İstatistiksel performans metriklerine göre elde edilen sonuçlar, çok kriterli karar verme yöntemi olan Cp yönteminde kullanılarak modellerin genel performansları sıralanmış ve en başarılı model belirlenmiştir.

3.2.3. İstatistiksel Ölçek Küçültme Yöntemlerinin Uygulanması ve Karşılaştırılması

İstatistiksel ölçek küçültme yöntemi; deniz seviyesi basıncı, özgül nem ve rüzgar hızı (tahmin ediciler) gibi büyük ölçekli iklimsel parametreler ile sıcaklık ve yağış gibi yerel parametreler (tahmin edilenler) arasında ampirik bir ilişkiyi kurma esasına dayanmaktadır (Sachindra ve ark., 2014; Güven ve Pala., 2022). İstatistiksel ölçek küçültme; regresyon yöntemleri, hava durumunu esas alan yaklaşımlar, stokastik hava durumu üreteçleri ve sınırlı alan modellemesi olmak üzere dört kategoriye ayrılmaktadır. Bu yaklaşımlardan regresyon yöntemi, uygulanmasının kolay olması ve hesaplama gereksiniminin az olması nedeniyle tercih edilmektedir (Güven ve Pala, 2022).

3.2.3.1. Tahmin Edici Değişken Seçimi (Predictor Selection)

Modellerde değerlendirilecek olan tahmin değişkenleri küresel iklim modelinden 1980-2014 yılları arası için elde edilen yakın yüzey hava sıcaklığı (°C), özgül nem (g kg^{-1}), bölgesel rüzgâr hızı (m s^{-1}), meridiyonal rüzgâr hızı (m s^{-1}) ve deniz seviyesi basıncı (hPa) değerleridir. Bu değerler ölçek küçültme modellerinde yağış miktarı, minimum ve maksimum sıcaklık tahmininde sıklıkla kullanıldığı için tercih edilmiştir (Goyal ve Ojha, 2012, Mondal ve Mujumdar, 2012; Goly ve ark., 2014; Sharma ve ark., 2021).

Yakın yüzey hava sıcaklığı (AIRT), yeryüzüne yakın olan havanın sıcaklığını ifade etmektedir. Dünya yüzeyi ile atmosfer arasındaki enerji alışverişi üzerinde etkileri nedeniyle iklim çalışmaları için oldukça önemli bir değişken olarak kullanılmaktadır (Xu ve ark., 2012). Özgül nem (SHUM), havada bulunan su buharı miktarının ölçümüdür

(Kent ve ark., 2014). Özellikle nem içeriği, bulut oluşumu ve yağışla ilgili çalışmalarda sıklıkla kullanılmaktadır (Sander ve ark., 2019; Henry ve Merlis, 2020).

Bölgesel rüzgâr hızı (UWND); x ekseni doğuya ve y ekseni kuzeye doğru yerel olarak sabitlenmiş bir yatay koordinat sisteminde, bölgesel rüzgâr batıdan eserse pozitif, doğudan eserse negatif bir değer almaktadır. Bu rüzgârlar bulutlu, yağmurlu veya fırtınalı koşullara neden olan alçak basınç sistemleri ile yüksek bir ilişki içerisindedir. Pozitif bir değer alması durumunda iç kesimlerdeki kurak havayı kıyı kesimlere taşırken, negatif bir değer alması durumunda nemli havayı iç kesimlere taşıyarak yağışın oluşmasına neden olabilmektedirler (Hope ve ark., 2014). Meridiyonal rüzgâr hızı (VWND); x ekseni doğuya ve y ekseni kuzeye doğru yerel olarak sabitlenmiş yatay bir koordinat sisteminde meridyen rüzgârı güneyden ise pozitif, kuzeyden esiyor ise negatif bir değer almaktadır. Kuzeyden esen rüzgârlar sıcaklıkların azalmasına neden olabilirken, güneyden esen rüzgârlar hava sıcaklığına pozitif etkide bulunabilmektedirler (Simpson ve ark., 2016).

Deniz seviyesi basıncı (SLP); dünya yüzeyinde belirli bir noktadaki hava basıncının ölçümüdür ve genellikle hektopaskal (hPa) veya milibar olarak ölçülmektedir (Chifurira ve ark., 2016). Deniz seviyesindeki ortalama basınç 1013.25 hPa'dır. Deniz seviyesi referans değer olarak kabul edildiği için bu isimle adlandırılmaktadır. Bu parametre, hava kütlelerinin hareketi ve yağış ihtimali hakkında bilgi vermesi nedeniyle meteorologlar tarafından sıklıkla kullanılmaktadır. Basıncın yüksek olması durumunda genellikle bulutsuz açık bir hava durumu ile karşılaşılırken, düşük olması durumunda bulutluluğun artması ve yağış ihtimalinin yüksek olması beklenmektedir (Ponte, 1994; Diamond ve Bennartz, 2015).

Ölçek küçültme yöntemlerinde en önemli adım tahmin edici değişkenlerin seçilmesidir. Bu işlemin amacı çok sayıda potansiyel bağımsız değişken mevcut olduğunda en iyi performans gösterecek ölçek küçültme modelini oluşturmak ve bağımsız değişken sayısını sınırlamaktır. Bir modelde gereksiz tahmin edici değişkenlerin bulunması, tahmin performansına etkisi olan değişkenin etkisini azaltabilmektedir. Tibshirani (1996) tarafından ortaya atılan En Küçük Mutlak Daralma ve Seçim Operatörü (LASSO) regresyon yaklaşımı değişken seçimi için yaygın olarak kullanılmaktadır (Hammami ve ark., 2012).

LASSO; oluşturulmak istenen modelde bulunan ve anlamsız olan bağımsız değişkenlerin katsayılarını sıfıra küçülterek, anlamlı olan değişkenlerin

belirlenebilmesini sağlayan bir regresyon yöntemidir. Bu yöntemde L1 normunda bir ceza terimi belirlenerek, değişkenlerin katsayılarının küçülmesi sağlanmaktadır. Küçültme işlemi sonucunda katsayısı sıfırlanan değişkenler çıkartılmakta ve kalan bağımsız tahmin edici değişkenlerle modeller oluşturulmaktadır (Zou ve Hastie, 2005; Fonti ve Belitser, 2017; Wubetie, 2019). LASSO tahmini Denklem 3.10 kullanılarak elde edilmektedir.

$$\underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^{n} \left(y_i - \beta_0 - \sum_{j=1}^{p} (X_{ij}\beta_j) \right)^2 + \lambda \sum_{j=1}^{p} |\beta_j| \right\}, \quad i = 1,2,3,\dots,n \;\; j = 0,1,2,\dots,p \qquad (3.10)$$

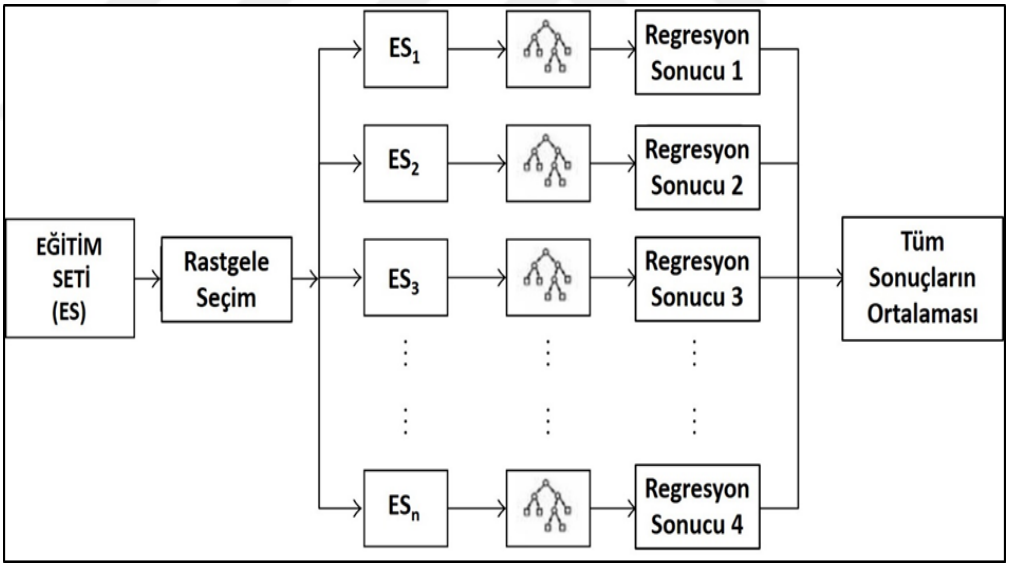
Bu denklemde, n; gözlem sayısını, p; değişken sayısını, y; bağımlı değişkeni, X_i; bağımsız değişkenleri, β; bilinmeyen değişken katsayısını ve $\|\beta\|_1 = \sum_{j=1}^{p} |\beta_j|$ ise L1 norm ceza terimidir. Bu terim β katsayılarının mutlak değerlerinin toplamına eşittir. λ ise katsayıların daralma miktarını ayarlama parametresidir ve sıfırdan büyüktür (Tibshirani, 1996). λ değerinin çok yüksek olması durumunda değişkenlerin kullanıldığı modelde aşırı öğrenmeye sebep olabilmektedir. Bu nedenle ideal λ değerinin belirlenerek değişkenlerin seçilmesi gerekmektedir. Çalışma kapsamında ölçek küçültme modelinde kullanılacak olan değişkenler LASSO regresyon yöntemi ile belirlenmiştir. Bu amaçla R Studio programında bulunan glmnet paketinden faydalanılmıştır. LASSO analizindeki ayarlama parametresi (λ) ise cv.glmnet paketi kullanılarak çapraz doğrulama yöntemi ile belirlenmiştir.

3.2.3.2. Rastgele Orman Algoritması

Leo Breiman tarafından 2001 yılında geliştirilen RF, topluluk öğrenme yöntemini kullanan denetimli bir makine öğrenmesi algoritmasıdır (Gupta ve ark., 2018). RF, en doğru tahmini elde etmek için birden fazla karar ağacının birleşiminden oluşmaktadır. Genellikle veri kümesinden rastgele bir örnekleme (bootstrap) yapılarak oluşturulan bir eğitim veri kümesi kullanılmaktadır. Bu veri kümesinden de rastgele bir şekilde seçilen alt veri kümesi ile her bir karar ağacı eğitilmektedir. Böylece karar ağaçları arasında çeşitlilik sağlanarak her bir ağacın tek başına gerçekleştirdiği tahmin hatasının, diğer ağaçların tahminleri ile karşılaştırılarak en aza indirilmesi sağlanmaktadır. Böylece tek

bir karar ağacı tahmininden daha doğru bir tahmin sonucu elde edilebilmektedir (Breiman, 2001; Xie ve ark., 2009; Cutler ve ark., 2012).

RF regresyonu Şekil 3.12'de gösterildiği gibi birden çok karar ağacından oluşmaktadır. Oluşturulan modelin tahmin doğruluğu bu ağaçların performansına bağlıdır (Breiman, 2001). Karar ağaçları; kök düğümü, iç düğümler ve yapraklardan meydana gelmektedir. Kök düğümü, karar ağacının en tepesinde bulunan ve ardından gelen tüm düğümlerin kaynağı olan başlangıç ayrımıdır. Bu düğümden gelen veriler ağacın diğer bölümlerine doğru bölünür ve bu sayede verilerin anlamlı bir şekilde sınıflandırılması sağlanmaktadır. Böylelikle model, verileri anlamlı bir şekilde yorumlayarak tahmin doğruluğunu arttırabilmektedir. Kök düğümü değişkenlerin önem seviyesine göre algoritma tarafından belirlenmektedir. Her bir iç düğüm ise, kök düğümünden gelen veriyi bölmek için bir test fonksiyonu ile ilişkilendirilmektedir. Bu algoritmanın amacı; düğümlerde olması beklenen varyansı en aza indirebilmektir ve Denklem 3.11 ile belirlenmektedir (Pang ve ark., 2017).



Şekil 3.12. RF algoritmasının yapısı (Pang ve ark., 2017)

$$\underset{x_j \le x_j^R, j=1,2,..,M}{\operatorname{argmin}} \; [\rho_l \operatorname{var}(Y_l) + \rho_\tau \operatorname{var}(Y_\tau)] \tag{3.11}$$

Bu denklemde $\rho_l$ve ρ_τ; sağ ve sol düğümlerdeki örneklerin fraksiyonlarını, $\operatorname{var}(Y_l)$ ve $\operatorname{var}(Y_\tau)$; yanıt vektörleri için sağ ve sol iç düğümleri ve $x_j \le x_j^R,\ j = 1,2,\dots,M$; bölme

için sorulabilecek en uygun soruları temsil etmektedir. RF model eğitim sürecine paralel olarak, bootstrap bölme sırasında seçilmeyen (OOB, Out of Bag) örneklerini de kullanarak kendi içinde ayrıca çapraz doğrulamada gerçekleştirmektedir. Daha sonra Denklem 3.12 kullanılarak her bir ağacın tahmin ettiği değerler ile gerçek değerler arasındaki fark hesaplanarak karar ağaçlarının öğrenme hatası elde edilmektedir.

$$MSE \approx MSE^{OOB} = \frac{1}{n}\sum_{i=1}^{n}\left[\hat{Y}\,(X_i) - Y_i\right]^2 \qquad (3.12)$$

Bu denklemde n; OOB örneklerinin sayısını, $\hat{Y}\,(X_i)$; her bir X_i girdisi için tahmin sonucunu ve Y_i; gözlem değerlerini temsil etmektedir. RF, her değişkenin önemini değerlendirmek için iki yöntem kullanmaktadır. İlk olarak değişkenler rastgele olarak kullanıldığında tahminin ne kadar kötü olabileceğine dayalı olarak değişkenin önemi değerlendirilmektedir. Eğitim süreci sırasında, her ağacın OOB örneklerinin tahmin hataları hesaplanır ($EOOB_1$). Aynı zamanda, OOB örneklerindeki her bir girdi değişkeni tek tek sıralanır. Sıralanmış olan bu veri kümeleri de ağaç tarafından tahmin edilir ($EOOB_2$). Eğitim süreci sonunda, her değişkenin önemi $EOOB_1$ ve $EOOB_2$ arasındaki farkın ortalaması alınarak elde edilir. Sonra bu değer standart sapmaları kullanılarak normalize edilir. İkinci olarak ise düğüm kirliliğinin azaltılması yöntemidir. Bu yöntem, hata farklarının karelerinin toplamının bölme öncesi ve sonrasındaki değişimi değerlendirilerek gerçekleştirilmektedir. Böylelikle gereksiz düğüm oluşumu engellenmektedir (Ai ve ark., 2014; Wang ve ark., 2015).

Hem regresyon hem de sınıflandırma amacı ile kullanılması, diğer yöntemlere göre gerektirdiği parametrelerin sayısının daha az olması, daha hızlı eğitilmesi, tahmin hızının daha yüksek olması gibi avantajlarından dolayı RF son yıllarda kullanımı oldukça popüler olan bir algoritmadır (Hastie ve ark., 2020; Bhusal ve ark., 2022; Liu ve ark., 2022). RF, sınıflandırma amacı için kullanıldığında oluşturulan her bir karar ağacından sınıf oyu alarak, aldığı oyların sonucuna göre sınıflandırma yapmaktadır. Regresyon modellerinde ise elde edilen tahminlerin ortalamasını kullanmaktadır (Dangeti, 2017).

Algoritmanın çalışma prensibi şu şekildedir;

• Veri setinden k tane değişken seçilir.

• Eğitim için gerçek veri setinin 2/3'ünü oluşturacak şekilde eğitim veri seti oluşturulur (inBag)

• Eğitim veri seti içerisinde bulunan değişkenlerden rastgele olacak şekilde m tane özellik belirlenir.

• Belirlenen bu özelliklerden en iyi performansı verecek olanlar belirlenir.

• Kullanılmaya karar verilen ağaç sayısı kadar önceki adımlar tekrarlanır.

• Eğitim için ayrılmayan veriler test amacıyla modele uygulanır.

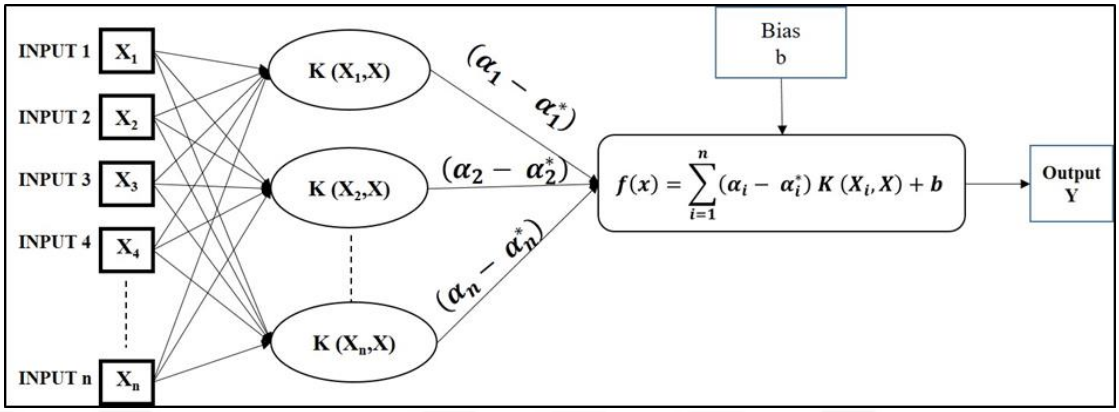
• Elde edilen tahminler ile gözlem değerleri karşılaştırılarak model başarı oranı hesaplanır.

Algoritma için kullanıcı tarafından belirlenmesi gereken önemli parametreler bulunmaktadır. Bu parametrelerden başlıca olanları; oluşturulacak ağaç sayısı (ntree) ve düğümlerde kullanılacak bağımsız değişken sayısıdır (mtry). Bu parametrelerin az olması durumu, modelin eğitim veri setini yeterince iyi öğrenememesine ve dolayısıyla yapılacak tahminlerin doğruluk oranının düşük olmasına neden olabilmektedir. Fazla olması durumu ise, modelin eğitilmesi için gereken sürenin fazla olmasına ve eğitim setine çok fazla uyum göstermesine neden olabilmektedir. Bu nedenlerden dolayı bu parametrelerin optimum olacak şekilde belirlenmesi gerekmektedir. Genel olarak, çalışmalarda oluşturulacak ağaç sayısı 500 olarak kullanılmaktadır (Cutler ve ark., 2012). Bu parametrenin standart kullanımı ile oldukça başarılı sonuçlar elde edilebilmektedir (Fernández-Delgado ve ark., 2014). Ancak model ve veri setine özgün olarak mtry parametresinin ayarlanması ile model performansında az da olsa bir iyileşme gerçekleşebilmektedir (Probst ve ark., 2019). Bu nedenle, çalışma kapsamında mtry parametresi R studio ortamında "caret" paketi (Kuhn, 2008) kullanılarak hiperparametre analizi sonucu belirlenmiştir.

3.2.3.3. Destek Vektör Regresyonu Algoritması

SVM; Vapnik (1999) tarafından geliştirilen, sınıflandırma ve regresyon problemlerinde yaygın olarak uygulanan yapay zeka tabanlı denetimli bir makine öğrenme modelidir (Şekil 3.13). SVM'nin regresyon için uyarlaması Smola ve Schölkopf tarafından ileri sürülmüştür (Smola ve Schölkopf, 2004). Yöntem, YSA gibi yöntemlerden farklı olarak genelleme hatasını azaltan yapısal risk minimizasyonu yaklaşımını benimsemektedir. Bu yaklaşımda amaç, modelin eğitileceği veri setini

kullanarak olduğundan çok daha düşük ya da fazla tahminler üretmeyen bir model oluşturabilmektir (Liu ve ark., 2013; Belayneh ve ark., 2014).



Şekil 3.13. SVR algoritmasının genel yapısı

SVR'deki amaç, çekirdek fonksiyonlarını kullanarak düşük boyutlu verileri yüksek boyutlu bir özellik uzayına eşleyerek doğrusal olmayan regresyon problemlerini çözebilmektir (Raghavendra ve Deka., 2014). Böylelikle, düşük boyutlu girdi uzayındaki doğrusal olmayan bir regresyon probleminden yüksek boyutlu girdi uzayındaki doğrusal bir regresyon problemi elde edilmekte olup çözüm bu uzayda gerçekleştirilmektedir (Misra ve ark., 2009). SVR regresyonunda bağımsız değişkenlerin (x_i) bağımlı değişkene (y) olan etkisi aşağıdaki Denklem 3.13 ile ifade edilmektedir.

$$y = f(x_i) = w\phi(x_i) + b \tag{3.13}$$

Bu denklemde, w; ağırlık vetkörünü, b; yanlılık parametresini ve ϕ; kullanılan çekirdek işlevini temsil etmektedir. SVR bir ε- duyarsız kayıp fonksiyonuyla bir optimizasyon problemini kullanarak f(x) fonksiyonunu tahmin etmektedir (Denklem 3.14).

$$\frac{1}{2}\|w\|^2 + C\sum_{i=1}^{n}(\xi_i^- + \xi_i^+) \quad Kısıt \begin{cases} (w\phi(x_i) + b) - y_i \le \varepsilon + \xi_i^- \\ y_i - (w\phi(x_i) + b) \le \varepsilon + \xi_i^+ \\ \xi_i^-, \xi_i^+ \ge 0 \end{cases} \tag{3.14}$$

Bu denklemde, ξ_i^+ ve ξ_i^- gevşeklik (Slack) olarak adlandırılan parametrelerdir. Bu parametreler, eğitim verisi noktalarının hedef değişkenin gerçek değerinden ε toleransına kadar uzaklıkta olmasına izin verir. Böylelikle modelin hedef değişkenin gerçek değerine en yakın olan tahminleri yapması sağlanmaktadır. Slack değişkenleri, SVR modelinin performansını iyileştirirken aynı zamanda modelin aşırı uyum riskini de azaltmaktadır. Denklemdeki C sabiti ise, sıfırdan büyük bir değer alıp model karmaşıklığı ile ε'dan büyük sapmaların göz ardı edildiği miktar arasındaki ilişkiyi belirlemektedir (Smola ve Schölkopf, 2004; Misra ve ark., 2009). Son olarak bu optimizasyon problemi duali alınarak aşağıda verilen Denklem 3.15 ile ifade edilmektedir.

$$K(x_i, x) = \exp(-\frac{\|x_i, x\|}{2y^2}) \quad (3.15)$$

SVR'de ε değeri, ceza koşulunun büyüklüğü (C) ve radyal esaslı kernel fonksiyonunun parametresi (γ) olan üç parametrenin optimize edilmesi gerekmektedir. Çalışmada model ve bu parametreler R Studio ortamında e1071 paketi ile oluşturularak belirlenmiştir (Meyer ve ark., 2016).

3.2.3.4. Çok Değişkenli Doğrusal Regresyon

MLR, regresyon analizinin yaygın bir şeklidir. MLR, bir bağımlı değişken ile iki veya daha fazla bağımsız değişken arasındaki ilişkiyi doğrusal bir denklem oluşturarak açıklamaya çalışmaktadır (Uyanık ve Güler, 2013). Ölçek küçültme ve etki analizi için iklim çalışmalarında yaygın olarak kullanılmaktadır (Pang ve ark., 2017). Genel olarak, MLR matematiksel olarak Denklem 3.16 ile ifade edilmektedir.

$$Y = b_0 + b_1 x_1 + \cdots + b_n x_n + e \quad (3.16)$$

Bu denklemde, Y; bağımlı değişkeni, x; bağımsız değişkenleri ve e; artık değeri temsil etmektedir. Bu çalışmada MLR regresyonu R STudio prgramında caret paketi kullanılarak oluşturulmuştur.

3.2.3.5. Yanlılık Düzeltme (Bias Correction)

KİM'lerinin çıktıları genellikle aynı dönem için elde edilen gözlem verileri ile istatistiksel olarak benzer özellikler göstermeyebilmektedir (Soriano ve ark., 2019). İklim modelleri ve gözlem verileri arasındaki bu istatistiksel hatalar; yerel iklim etkileri, bitki örtüsü, bulutluluk ve topografik farklılıklardan kaynaklanabilmektedir (Ghimire ve ark., 2019). Yağışların aşırı veya az olarak tahmin edilmesi ve az yağış yoğunluğuna sahip günleri sık tahmin etmesi gibi yanlılık hataları bulunmaktadır (Ines ve Hansen, 2006; Ghimire ve ark., 2019). Bu nedenlerden dolayı, gözlem verileri ve model çıktıları arasındaki istatistiksel farkın azaltılması ile doğruluğu yüksek tahminler elde edebilmek için bu hatalar yanlılık düzeltme yöntemleri ile azaltılmalıdır (Kırdemir ve Okkan, 2019). Yanlılık düzeltme yöntemleri, KİM sonuçlarının gelecek dönemdeki tahminlerine olan güvenilirliği artırmak amacıyla, kontrol döneminde model çıktılarının gözlem verilerine istatistiksel uyumunu arttırmaya çalışmaktadır (Soriano ve ark., 2019). Çalışmamızda hem sıcaklık hem de yağış tahminlerine uygulanabilmesi nedeniyle delta değişimi yanlılık düzeltme yöntemi kullanılmıştır.

Delta değişim yöntemi; geçmiş veriler ile gelecekteki verilerin ortalamaları ve sapma değerleri arasında hesaplanan oranın değişim faktörü olarak kullanılmasına dayanmaktadır. Bu yöntemde, ilk olarak j. ay için gelecek model çıktılarının standart hale getirilmiş bir değeri elde edilir. Bu değeri elde etmek için Denklem 3.17 kullanılmıştır (Lee ve Singh, 2018).

$$z_{m,fut} = \frac{X_{m,fut} - \mu_{m,fut}}{\sigma_{m,fut}} \tag{3.17}$$

Denklemde, $z_{m,fut}$; model çıktılarının standart hale getirilmiş değerini, $X_{m,fut}$; modelin gelecek çıktılarını, $\mu_{m,fut}$; model gelecek çıktılarının ortalamasını ve $\sigma_{m,fut}$; model gelecek çıktılarının standart sapmasını temsil etmektedir. Daha sonra ise, model gelecek çıktıları için ayarlanmış ortalama ve ayarlanmış standart sapma değerleri hesaplanmıştır (Denklem 3.18, Denklem 3.19 ve Denklem 3.20). Denklem 3.19 yağış verileri için, Denklem 3.20 ise sıcaklık verilerinin ortalamaları için kullanılmıştır.

$$\bar{\sigma}_{m,fut} = \frac{\sigma_{obs}}{\sigma_{m,base}} \times \sigma_{m,fut} \tag{3.18}$$

$$\bar{\mu}_{m,fut} = \frac{\mu_{obs}}{\mu_{m,base}} \times \mu_{m,fut} \quad (3.19)$$

$$\bar{\mu}_{m,fut} = \mu_{m,fut} + \left(\mu_{obs} - \mu_{m,base}\right) \quad (3.20)$$

Denklemlerde, $\bar{\sigma}_{m,fut}$; model gelecek çıktılarının ayarlanmış standart sapmasını, σ_{obs}; gözlem verilerinin standart sapmasını, $\sigma_{m,base}$; modelin referans dönemi için olan çıktılarının standart sapmasını, $\bar{\mu}_{m,fut}$; model gelecek çıktılarının ayarlanmış ortalamasını, μ_{obs}; gözlem verilerinin ortalamasını ve $\mu_{m,base}$; modelin referans dönemi için olan çıktılarının ortalamasını temsil etmektedir. Son olarak Denklem 3.21 kullanılarak düzeltilmiş model gelecek çıktıları hesaplanmıştır. Denklemde $\bar{y}_{m,fut}$; modelin düzeltilmiş çıktılarını temsil etmektedir.

$$\bar{y}_{m,fut} = \left(z_{m,fut} \times \bar{\sigma}_{m,fut}\right) + \bar{\mu}_{m,fut} \quad (3.21)$$

3.2.4. En Uygun Ampirik Referans Evapotranspirasyon Yönteminin Seçilmesi

Evapotranspirasyon (ET); suyun buharlaşma yoluyla toprak yüzeyinden ve terleme yoluyla da bitki yüzeyinden kaybolduğu iki ayrı sürecin birleşimidir (Allen ve ark., 1998). Buharlaşma işlemi deniz, toprak ve bitki örtüsü gibi birçok yüzeyde gerçekleşebilmektedir. Buharlaşma işleminde rüzgâr hızı, nem, sıcaklık ve güneş radyasyonu gibi iklim parametreleri etkili olmaktadır (Allen ve ark., 1998). Terleme; bitki dokusunda bulunan suyun stoma aracılığı ile buharlaşması işlemidir. Terleme işlemi güneşlenme süresi, basınç gradyan kuvveti (belirli iki nokta arasındaki basınç değişikliği nedeniyle havanın hareket yönü ve hızına etki eden kuvvet), rüzgâr, güneş radyasyonu, sıcaklık, nem, toprak-su içeriği, topraktaki su miktarı, tuzluluk, bitki özellikleri ve bitki yetiştirme uygulamaları gibi birçok faktöre bağlıdır (Allen ve ark., 1998).

ET, su bütçesi eşitliğinde su kaybına neden olan faktör olduğu için hidrolojik döngünün temel bileşenlerinden biridir (Yuan ve Bai, 2018). Bu nedenle; bitkisel üretimde verim simülasyonu, su kayıplarının optimizasyonu, sulama sistemlerinin yönetimi ve tasarımı, tarımda etkin su kullanımı ve hidrolojik su dengesi gibi birçok araştırma alanında geniş bir öneme sahiptir (Jahanbani ve El-Shafie, 2011; Abdullahi ve

Elkiran, 2017). Ancak, ET miktarını arazi ölçeğinde tahmin etmek oldukça zordur. Günümüzde meteorolojik değişkenler kullanarak oluşturulan pek çok ampirik ET hesaplama yöntemi geliştirilmiştir. Bu çalışmada Kırıkhan ilçesi gözlem istasyonu verileri kullanılarak farklı ET hesaplama yöntemlerinin performansları incelenmiştir. Bu amaçla literatürde çok fazla değişken kullanılarak hesaplanan Penman-Monteith FAO 56 yöntemi ile hesaplanan referans evapotranspirasyon (ET_0) değeri, daha az sayıda değişken kullanılarak hesaplanan diğer yöntemlerle karşılaştırılmış ve en yakın sonuçları veren yöntem ET_0 değerlerinin hesaplanmasında kullanılmıştır.

3.2.4.1. Güneş Radyasyonun Belirlenmesi

Çalışmada bitki gelişme modeli olarak kullanılan AquaCrop modelinin en önemli girdilerinden biri evapotranspirasyondur. Bu değeri hesaplamak için çok sayıda iklim parametresi gerekmektedir. Bu parametrelerden biri olan günlük güneş radyasyonu, ölçüm istasyonlarından elde edilen veriler kullanılarak Hatay ilinin tüm ilçeleri için hesaplanmıştır. Hesaplanan değerlerin doğruluğu Enerji Bakanlığının hazırlamış olduğu Güneş Enerjisi Potansiyeli Atlasından (GEPA) elde edilen bilgilerle kıyaslanmıştır.

Güneş radyasyonu, önemli bir yenilenebilir enerji kaynağı olan güneş enerjisini tahmin etmek için kullanılan önemli bir parametredir (Bandyopadhyay ve ark., 2008). Güneş radyasyonunun mekansal ve zamansal dağılımını hesaplamak sadece güneş enerjisini tahmin etmek için değil aynı zamanda hidrolojik, meteorolojik ve iklimsel çalışmalar için de gereklidir (İrvem ve Özbuldu, 2018). Ancak, güneş radyasyonu ölçüm verileri; ölçüm cihazlarının bakımı, maliyeti ve kalibrasyon gereksinimi gibi sorunlar nedeniyle ülkemiz gibi gelişmekte olan ülkelerde eksik veya erişilemez durumdadır. Bu nedenle güneş radyasyonunun başka iklim parametreleri kullanarak hesaplandığı pek çok yöntem geliştirilmiştir (Chineke, 2008). Bu yöntemlerden biri Hargreaves-Samani eşitliğidir. Hargreaves ve Samani (1982), solar radyasyonun maksimum ve minimum hava sıcaklıkları arasındaki farkın kullanılmasıyla oluşturulan bir denklemden tahmin edilebileceğini öne sürmüşlerdir (Denklem 3.22).

$$R_s = K_r\,(Tmax - Tmin)^{0,5} R_a \qquad (3.22)$$

Bu denklemde, R_s; güneş radyasyonunu (MJ m^{-2}gün^{-1}), T; sıcaklığı (°C), R_a; uzay radyasyonunu (MJ m^{-2} gün^{-1}) ve K_r; ampirik katsayıyı (iç kesimler için 0.16, sahil bölgeleri için 0.19) temsil etmektedir. Uzay radyasyonu ise, enlem ve yılın günlerinin bir fonksiyonu olarak Denklem 3.23 kullanılarak hesaplanmaktadır (Duffie ve Beckmann, 2013);

$$R_a = (1440/\pi).SC.DF.(\cos\varphi.\cos\delta.\sin W_s + W_s.\sin\varphi.\sin\delta) \quad (3.23)$$

$$DF = 1.0 + 0.033.\cos(2.\pi.(\text{Jülyen günü}/365)) \quad (3.24)$$

$$W_s = \cos^{-1}(-\tan\varphi.\tan\delta) \quad (3.25)$$

$$\varphi = latitude(\pi/180) \quad (3.26)$$

$$\delta = 0{,}409.\sin(2\pi(\text{Jülyen günü}/365) - 1.39) \quad (3.27)$$

Denklem 3.22'de R_a; uzay radyasyonunu (MJ m^{-2} gün^{-1}), SC; güneş sabitini (0.082 MJ m^{-2} gün $^{-1}$) temsil etmektedir. DF; dünya ile güneş arasındaki ters bağıl mesafeyi (Denklem 3.24), W_s; gün batımı saat açısını (rad) (Denklem 3.25), φ; enlemi (rad) (Denklem 3.26) ve δ; güneş kırımını (rad) (Denklem 3.27) temsil etmektedir.

Enerji ve Tabii Kaynaklar Bakanlığı tarafından hazırlanmış olan GEPA elde edilen veriler Çizelge 3.17'de verilmiştir (GEPA, 2020). Bu değerler Hatay ili meteoroloji gözlem istasyonlarından elde edilen değerler ile hesaplanan solar radyasyonu değerlerinin doğrulanması için kullanılmıştır.

Çizelge 3.18. Hatay İli için GEPA aylık ortalama solar radyasyonu

Aylar	01	02	03	04	05	06	07	08	09	10	11	12
Altınözü	1.91	2.38	3.92	4.56	5.93	6.52	6.30	5.79	4.63	3.33	2.26	1.70
Antakya	1.99	2.44	4.00	4.84	5.97	6.64	6.34	5.81	4.74	3.54	2.34	1.79
Belen	2.04	2.50	4.05	4.95	6.03	6.72	6.42	5.86	4.82	3.70	2.37	1.82
Dörtyol	2.02	2.47	4.05	4.93	6.01	6.69	6.37	5.86	4.81	3.70	2.35	1.82
Erzin	1.99	2.34	4.01	4.89	5.89	6.60	6.21	5.82	4.75	3.79	2.31	1.80
İskenderun	1.96	2.28	3.99	4.88	5.92	6.64	6.27	5.81	4.72	3.70	2.32	1.79
Hassa	2.06	2.55	4.07	4.95	6.05	6.70	6.40	5.86	4.86	3.70	2.40	1.82
Kırıkhan	2.02	2.41	4.02	4.92	5.94	6.63	6.29	5.83	4.76	3.70	2.40	1.81
Kumlu	2.00	2.37	4.00	4.90	5.90	6.60	6.20	5.80	4.71	3.65	2.40	1.80
Reyhanlı	1.97	2.37	4.00	4.89	5.90	6.61	6.23	5.77	4.72	3.62	2.40	1.80
Samandağ	1.97	2.49	4.00	4.86	5.96	6.62	6.33	5.83	4.74	3.55	2.31	1.79
Yayladağı	1.61	2.34	3.66	3.66	5.95	6.18	6.31	5.75	4.33	2.60	1.84	1.38

3.2.4.2. Penman Monteith (FAO-56 PM) ET_0 Hesaplama Yöntemi

ET_0; mevcut atmosferik koşullar altında, yeterli düzeyde sulanmış, toprağı tamamen gölgeleyen ve aynı boyda olan (12 cm) olan çim bitki örtüsünden gerçekleşen maksimum evapotranspirasyon miktarıdır (Allen ve ark., 1998). Son on yıldan daha uzun süredir farklı bölgelerdeki kısa-yeşil-çim yüzeylerde değerlendirilen FAO-56 PM yöntemi, ölçüm değerlerine en yakın sonuçları tahmin edebilme kapasitesinden dolayı evrensel olarak standart ET hesaplama yöntemi olarak kabul edilmektedir (Şarlak ve Bağçaçı, 2020). Bu yöntem günlük hava sıcaklığı, güneş radyasyonu, ortalama rüzgâr hızı ve bağıl nem verilerine ihtiyaç duymaktadır. Penman-Monteith yöntemi ile ET_0 değeri Denklem 3.28 ile belirlenmektedir (Allen ve ark., 1998).

$$ET_0 = \frac{0.408\Delta(R_n - G) + \frac{900}{T+273}(U_2(e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad (3.28)$$

Denklemde, ET_0; referans evapotranspirasyonu (mm gün^{-1}), Δ; doygun buhar basıncı-sıcaklık eğrisinin eğimini (kPa °C^{-1}), R_n; net radyasyonu (MJ m^{-2} gün^{-1}) ve G; toprak ısı değişimi yoğunluğunu (MJ m^{-2} gün^{-1}) temsil etmektedir. Ayrıca, γ; psikrometrik sabiti (kPa °C^{-1}), U_2; 2 m yükseklikten ölçülen rüzgâr hızını (m s^{-1}), e_s; doygun buhar basıncını (kPa) ve e_a; gerçek buhar basıncını (kPa) temsil etmektedir. ET_0'ın belirlenmesi için doygun buhar basıncı ve sıcaklık arasındaki ilişkinin eğiminin

bilinmesi gerekmektedir. Bu eğim Denklem 3.29 kullanılarak hesaplanmıştır (Allen ve ark., 1998).

$$\Delta = \frac{4098\left[0{,}6108\exp\left(\frac{17{,}27T}{T+273{,}3}\right)\right]}{(T+273.3)^2} \quad (3.29)$$

Dünya yüzeyine gelen net kısa dalga (R_{ns}) ile net yansıtan uzun dalga (R_{nl}) radyasyonu arasındaki fark net radyasyon olarak adlandırılmaktadır ve Denklem 3.30 ile hesaplanmaktadır. Denklem 3.31'de verilen α simgesi albedo değerini temsil etmektedir. Yeşil bitkiler için bu değer 0.23 olarak kabul edilmektedir. Denklem 3.32'de verilen σ simgesi Stefan-Boltzman sabitini temsil etmektedir (σ= 4.903 x10^{-9} MJ K^{-4} m^{-2} $gün^{-1}$). Denklem 3.33'de ise z simgesi ölçülen noktanın deniz seviyesinden yüksekliğini ve Ra ise uzay radyasyonunu temsil etmektedir (Allen ve ark., 1998).

$$R_n = R_{ns} - R_{nl} \quad (3.30)$$

$$R_{ns} = (1-\alpha)Güneş\ radyasyonu \quad (3.31)$$

$$R_{nl} = \sigma\left[\frac{Tmax(K^4)-Tmin(K^4)}{2}\right]\left(0{,}34-0{,}14\sqrt{e_a}\right)\left(1{,}35\frac{Güneş\ Radyasyonu}{Açık\ Hava\ Güneş\ Radyasyonu}\right) \quad (3.32)$$

$$Açık\ Hava\ Güneş\ Radyasyonu = (0{,}75 + 2x10^{-5}z)R_a \quad (3.33)$$

Toprak ısı değişimi, toprağın ısınmasında kullanılan enerjidir ve günlük değişimi oldukça küçük olduğundan 0 olarak kabul edilmektedir. Doygun buhar basıncı, hava sıcaklığı ile ilişkili olduğundan Denklem 3.34 ile hesaplanmaktadır (Allen ve ark., 1998).

$$e_s = \frac{1}{2}\left(0.6108 \times e^{\left(\frac{17.27\times T_{max}}{T_{max}+237.3}\right)} + 0.6108 \times e^{\left(\frac{17.27\times T_{min}}{T_{min}+237.3}\right)}\right) \quad (3.34)$$

Denklemde, e_s; doygun buhar basıncını, T_{max}; maksimum sıcaklığı, T_{min}; minimum sıcaklığı temsil etmektedir. Gerçek buhar basıncı ise, Denklem 3.35 ile

hesaplanmaktadır (Allen ve ark., 1998). Denklemde e_a; gerçek buhar basıncını, RH_{max}; maksimum bağıl nemi ve RH_{min}; minimum bağıl nemi temsil etmektedir.

$$e_a = \frac{1}{2}\left(0.6108 \times e^{\left(\frac{17.27 \times T_{max}}{T_{max}+237.3}\right)} \times \frac{RH_{max}}{100} + 0.6108 \times e^{\left(\frac{17.27 \times T_{min}}{T_{min}+237.3}\right)} \times \frac{RH_{min}}{100}\right) \quad (3.35)$$

Psikrometrik sabit ise, belirli sıcaklık ve basınç koşulları altındaki birim kütledeki hava sıcaklığının 1°C arttırılması için verilmesi gereken enerjidir ve Denklem 3.36 ile hesaplanmaktadır (Allen ve ark., 1998).

$$\gamma = \frac{C_p \; x \; P}{\varepsilon \; x \lambda} \quad (3.36)$$

Denklemde C_p; sabit basınç altında özgül ısıyı ($1.013x10^{-3}$ MJ kg^{-1} $°C^{-1}$), p; atmosferik basıncı (kPa), ε; su buharı/kuru havanın moleküler ağırlık oranını (0.622) ve λ; buharlaşmanın gizli ısısı (2.45 MJ kg^{-1} $°C^{-1}$) değerini temsil etmektedir.

3.2.4.3. Hargreaves-Samani ET_0 Hesaplama Yöntemi

Hargreaves–Samani (HS) yöntemi, sadece hava sıcaklığı verileri mevcut olduğunda ET_0 hesaplaması için önerilmektedir (Allen ve ark. 1998). Bu nedenle, HS denklemi alternatif bir yöntemdir ve ET_0'ı belirlemek için kullanılabilecek en basit denklemlerden biridir (Denklem 3.37) (Hargreaves ve Samani, 1985).

$$ET_0 = 0.0023 \times R_a \, (T_{Max} - T_{Min})^{0.5} \times (T_{Ort} + 17.8) \quad (3.37)$$

Denklemde ET_0; referans evapotranspirasyon (mm $gün^{-1}$), R_a; dünya dışı uzay radyasyonunu (MJ m^{-2} $gün^{-1}$), T_{Max}, T_{Min} ve T_{Ort} maksimum, minimum ve ortalama sıcaklığı temsil etmektedir.

3.2.4.4. Priestley-Taylor ET_0 Hesaplama Yöntemi

Priestley ve Taylor modeli (Priestley ve Taylor, 1972), orijinal 1948 Penman denkleminin kısaltılmış bir versiyonudur (Denklem 3.38) (Tabari, 2010).

$$ET_0 = 1.26 \times \frac{\Delta}{\Delta + \gamma} (R_n - G) \quad (3.38)$$

Denklemde ET_0; referans evapotranspirasyonu (mm gün^{-1}), Δ; doygun buhar basıncı-sıcaklık eğrisinin eğimini (kPa °C^{-1}), R_n; net radyasyonu (MJ m^{-2} gün^{-1}), G; toprak ısı değişimi yoğunluğunu (MJ m^{-2} gün^{-1}) ve γ; psikrometrik sabiti (kPa °C^{-1}) temsil etmektedir.

3.2.4.5. Makkink ET_0 Hesaplama Yöntemi

Makkink modeli, Penman yöntemini lizimetrik ölçüm verileri ile karşılaştırdıktan sonra Penman yönteminin bir modifikasyonu olarak tasarlanmıştır (Denklem 3.39) (Makkink 1957; Tabari 2010).

$$ET_0 = 0.61 \times \frac{\Delta}{\Delta + \gamma} \times \frac{R_n}{58.5} - 0.12 \quad (3.39)$$

Denklemde ET_0; referans evapotranspirasyonu (mm gün^{-1}), Δ; doygun buhar basıncı-sıcaklık eğrisinin eğimini (kPa °C^{-1}), R_n; net radyasyonu (MJ m^{-2} gün^{-1}) ve γ; psikrometrik sabiti (kPa °C^{-1}) temsil etmektedir.

3.2.5. Bitki Örneklerinin Alınması ve Hasat Edilmesi

3.2.5.1. Pamuk Bitki Örneklerinin Alınması ve Hasat Edilmesi

Pamuk bitki örnekleri, her bir arazi için 4.9 m x 2.8 m (13.72 m^2) boyutunda oluşturulmuş olan üç farklı parselin her birinin 1. ve 3. sıralarından rastgele olmak üzere bitkinin çıkışından hasatına kadar toprak üstü biyokütle gelişiminin takibi için her 15 günde bir altı örnek alınmıştır. Ayrıca, maksimum bitki örtü yüzeyi yüzdesinin

hesaplanabilmesi için bitkilerin yaprak alanını değerlerinin belirlenmesi gerekmektedir. Bu amaçla pamuk bitkisinin çiçeklenme dönemi boyunca haftada bir defa olmak üzere altı adet bitki örneği alınmıştır (Farahani ve ark., 2009; Aziz ve ark., 2022).

Toprak seviyesinden kesilen bitki örnekleri laboratuvarda 65°C'de sabit bir ağırlığa gelene kadar etüvde kurutularak toprak üstü biyokütleler belirlenmiş ve biyokütle gelişimi takip edilmiştir (Bronson ve ark., 2003). Yaprak örnekleri ise dijital görüntüleri alınarak ImageJ® görüntü işleme programına aktarılmıştır. Hasat işlemi ise el ile her parselin orta sırasından toplanmış ve tartılarak kütlü pamuk verimi kaydedilmiştir (Şekil 3.14).



Şekil 3.14. Kütlü pamuk veriminin belirlenmesi ve etüvde kurutma işlemi

3.2.5.2. Mısır Bitki Örneklerinin Tarladan Alınması ve Hasat Edilmesi

Mısır bitki örnekleri, her bir arazi için 3.45 m x 2.8 m (9.66 m^2) boyutunda oluşturulmuş olan üç farklı parselin her birinin 1. ve 3. sıralarından rastgele olmak üzere bitkinin çıkışından hasatına kadar toprak üstü biyokütle gelişiminin takibi için 15 günde bir altı örnek alınmıştır. Ayrıca, maksimum bitki örtü yüzeyi yüzdesinin hesaplanabilmesi için bitkilerin yaprak alanı değerlerinin belirlenmesi gerekmektedir. Bu amaçla, tepe püskülü oluşumundan itibaren her üç günde bir altı adet bitki örneği alınmıştır (Abedinpour ve ark., 2012).

Toprak seviyesinden kesilen bitki örnekleri laboratuvarda 65°C'de 48 saat boyunca etüvde kurutularak toprak üstü biyokütleler belirlenmiş ve biyokütle gelişimi takip edilmiştir (Abedinpour ve ark., 2012). Yaprak örnekleri ise, dijital görüntüleri alınarak ImageJ® görüntü işleme programına aktarılmıştır. Hasat işlemi ise el ile her parselin orta sırasından gerçekleştirilmiştir.

Toplanan koçanlar tartıldıktan sonra ortalamaları alınmış ve 1 m^2 alana düşen mısır bitkisi sayısı ile çarpılarak 1 m^2'deki parsel verimi belirlenmiştir. Daha sonra koçanlar danelenerek tartılmış ve dane ağırlıkları belirlenmiştir. Belirlenen dane ağırlıkları koçan ağırlıklarına oranlanarak tane-koçan oranı belirlenmiştir. Son olarak tartılmış mısır daneleri etüvde 70°C'de 24 saat kurutularak nem miktarları belirlenmiştir. Bu veriler Denklem 3.40'da kullanılarak mısır tane nemi hesaplanmıştır (Şekil 3.15) (Anonim, 2010).

$$Birim\ Alan\ Tane\ Verimi = Parsel\ Verimi\ X\ \frac{100-Hasat\ Tane\ Nemi}{85} \times Tane - Koçak\ Oranı \quad (3.40)$$



Şekil 3.15. Mısır veriminin belirlenmesi ve tanelenmesi işlemi

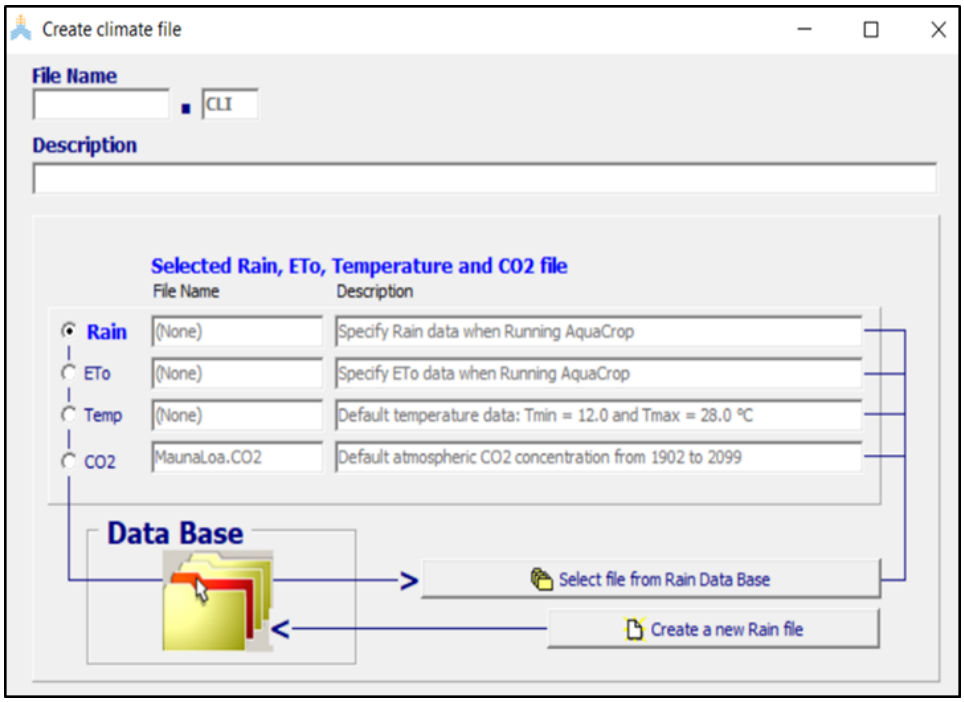
3.2.6. AquaCrop Modelinin Girdi Dosyalarının Oluşturulması

Çalışmamızda önceki çalışmalara dayanarak iklim değişikliğinin pamuk ve 1. ürün mısır bitki verimlerine olan etkisini incelemek amacı ile AquaCrop modeli kullanılmıştır. 2021 ve 2022 yılı için 1. ürün mısır ve pamuk bitkisinin yetiştirildiği dört farklı arazide

gözlemler ve ölçümler gerçekleştirilmiştir. Bu gözlemler kullanılarak AquaCrop modeli kalibre edilmiş ve doğrulanmıştır.

3.2.6.1. İklim Dosyasının Oluşturulması

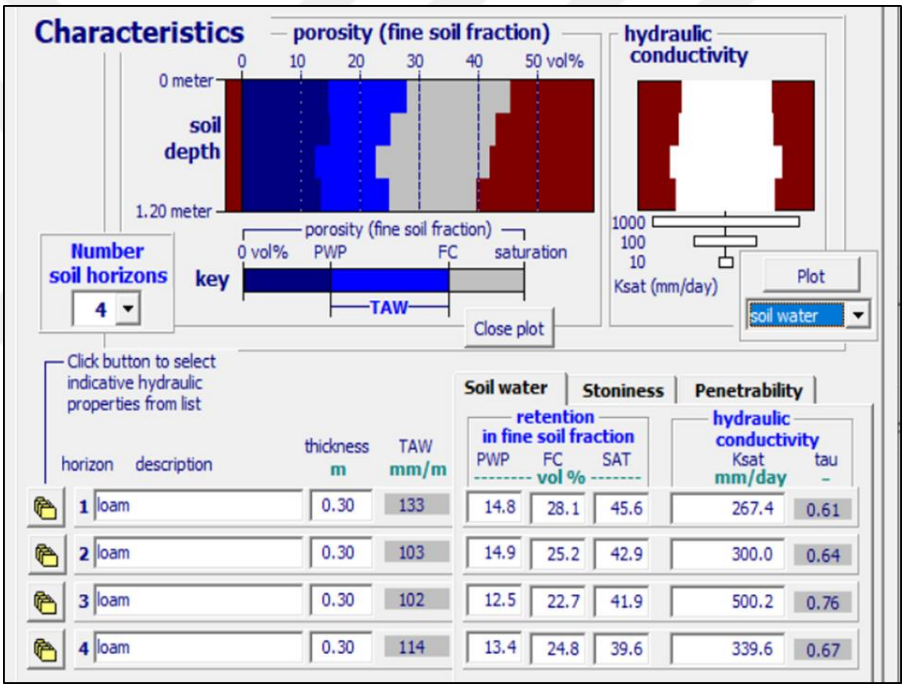
Modelde iklim verileri günlük, 10 günlük ve aylık olarak düzenlenebilmektedir. Modelin çalışmanın gerçekleştirildiği pamuk ve 1. ürün mısır ekili arazilere göre kalibre edilmesi için öncelikle iklim bölümünde "CLI" uzantılı yeni bir iklim dosyası oluşturulması gerekmektedir. Burada dosya adı verildikten ve dosya adı ile ilgili tanımlamalar yapıldıktan sonra yağış, ET_0, sıcaklık ve CO_2 dosyalarının oluşturulup seçilmesi gerekmektedir (Şekil 3.16). Bu dosyanın oluşturulabilmesi için Kırıkhan meteoroloji gözlem istasyonundan 2021 ve 2022 yılları için elde edilen yağış, maksimum ve minimum sıcaklık verileri kullanılmıştır. Günlük ET_0 değerini hesaplamak için önceki bölümlerde çalışma alanı için uygun olduğuna karar verilen ET_0 yöntemi kullanılmıştır. Son olarak ise, CO_2 konsantrasyon miktarı dosyası olarak ise programın içinde yer alan ve tüm Dünyada referans kabul edilen Mauna Loa Gözlemevi verileri seçilmiştir. Tüm dosya seçimlerinin ardından Kırıkhan CLI dosyası oluşturulmuş ve modele girdi olarak kullanılmaya hazır hale getirilmiştir.



Şekil 3.16. İklim verileri tanımlama ekranı

3.2.6.2. Toprak Dosyasının Oluşturulması

Çalışmamızda ürün verimi tahmini için kullanılan AquaCrop modelinin ihtiyaç duyduğu girdilerden biri modelde kullanılacak bitkinin yetiştirileceği toprağa ait bilgileridir (Şekil 3.17). Modelde ihtiyaç duyulan toprak parametreleri farklı derinlikler için; toprağın bünyesi (%), hacim ağırlığı (g cm^{-3}), tarla kapasitesi (%), solma noktası (%), porozite (%) ve doygun hidrolik iletkenlik (mm $gün^{-1}$) değerleridir. Bu parametreleri belirlemek amacıyla çalışma alanı olarak seçilen Abalaklı, Danaahmetli, Mahmutlu ve Ahrazları köylerindeki arazilerden toprak örnekleri alınmış ve laboratuvarda gereken analizler yapılmıştır.



Şekil 3.17. AquaCrop modeli toprak katmanlarının karakteristikleri ekranı

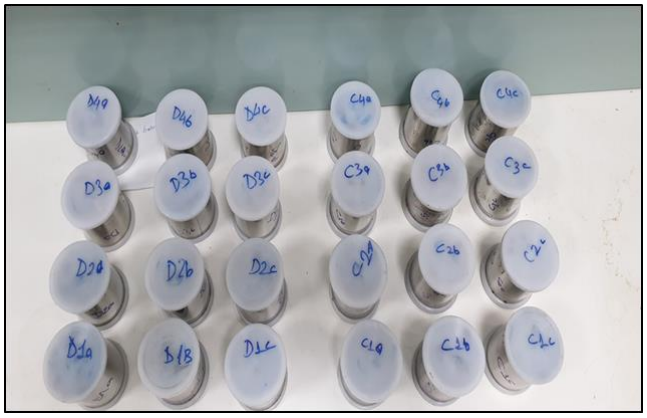
3.2.6.2.1. Toprak Örneklerinin Alınması ve Analize Hazırlanması

Toprağın kimyasal ve fiziksel özelliklerini incelemek amacı ile Kırıkhan ilçesinin Abalaklı, Danaahmetli, Mahmutlu ve Ahrazlı köylerinde bulunan çalışma alanlarından Kırıkhan Sulama Birliğine ait bir kepçe yardımı ile 120 cm derinliğinde profil çukurları açılmıştır (Şekil 3.18). Açılan profil çukurlarının her 30 cm'lik katmanının ortasından üç adet 100 cm^3 hacime sahip çelik silindirlerle bozulmamış ve yine aynı katmanlardan

kürek kullanılarak 1-2 kg kadar bozulmuş toprak örnekleri alınmıştır. Her bir 30 cm'lik katmandan toprak örneği alırken bulaşma olmamasına özen gösterilmiştir. Bu nedenle, üstteki katmanlarda yapılan örnekleme sırasında düşen toprak alttaki katmanlara bulaşabileceğinden örnekleme alt katmanlardan başlayarak üste doğru yapılmıştır. Çelik silindirlerle alınan bozulmamış örnekler ağızları kapatılarak ve bozulmuş örnekler poşete konularak en kısa sürede laboratuvara getirilmiştir (Şekil 3.19).



Şekil 3.18. Profil çukurlarının açılması ve toprak örneklerinin alınması



Şekil 3.19. Çelik silindirler ile alınmış bozulmamış toprak örnekleri

Toprak örnekleri tozdan, kimyasal madde buharından uzak ve oda sıcaklığında olan laboratuvarda hava kuru durumuna gelinceye kadar kurumaya bırakılmıştır. Hava kuru işlemini kolaylaştırmak için büyük topaklar ufalanmış ve zaman zaman karıştırılarak toprak alt üst edilmiştir.

Kurutma işlemi tamamlanan toprak örneklerinde gözle görülebilen taş parçaları ve bitki yumakları ayrıldıktan sonra iri topraklar elle parçalanmıştır. Daha sonra, temiz ve sert bir tahta zemin üzerinde el tokmağı ile toprak hafifçe ezilerek ufalanmıştır. Ufalanan örnekler 2 mm'lik (10 mesh) elekten geçirilmiştir. Eleğin üst kısmında sadece çakıl ve organik materyal kalıncaya kadar bu işleme devam edilmiştir. Elekten geçen toprak iyice karıştırılmış ve saklama kabına konularak analizlerde kullanım için hazır hale getirilmiştir (Kaçar, 2016).

3.2.6.2.2. Kullanılabilir Su Tutma Kapasitesinin Belirlenmesi

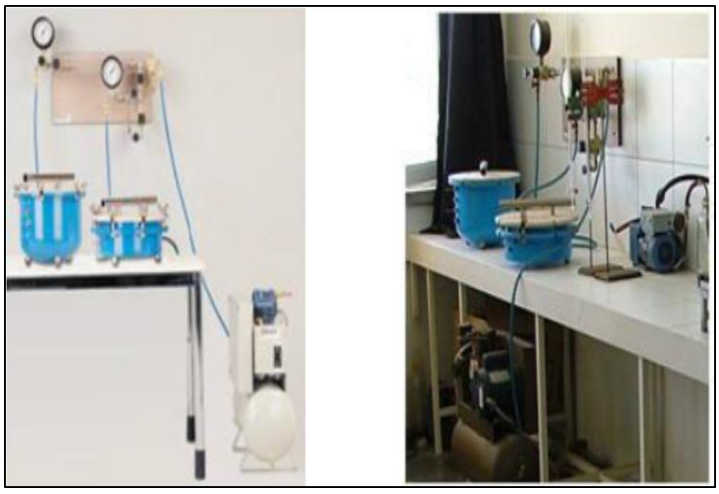
Tarımsal üretimde sulama uygulamaları için belirli basınçlar altında toprak tarafından tutulan nem miktarlarının bilinmesi gerekmektedir. Bu toprak nemi miktarlarına toprak nemi sabiteleri de denilmektedir. Önemli toprak nemi sabiteleri doyma noktası, tarla kapasitesi, solma noktası ve fırın kurudur.

Doyma noktası; toprak gözeneklerinin tamamen su ile dolu olduğu durumda toprakta bulunan nem miktarıdır ve toprak rutubet gerilimi 0 atm'dir. Toprak tanelerinin yerçekimine karşı tuttuğu nem miktarına ise tarla kapasitesi denilmektedir. Tarla kapasitesi, toprağın bünyesine ve yapısına göre farklılık gösterebilmektedir. Ağır bünyeli topraklarda yüksek iken hafif bünyeli topraklarda ise düşük değerlerdedir. Solma noktası;

bitkilerin kökleri aracılığı ile topraktan su alamadıkları ve solmaya başladıkları, toprağa su verilse bile eski durumuna dönemedikleri koşulda toprakta bulunan nem miktarıdır. Fırın kuru ise toprak örneğinin etüvde 105°C'de kurutulduktan sonra toprakta bulunan nem miktarıdır (Güngör ve ark., 2012).

Serbest koşullarda, tarla kapasitesinin üzerindeki nem, yerçekiminin etkisi ile kök bölgesinin altına sızmakta ve bitkiler bu nemden yararlanamamaktadır. Aynı zamanda bitkiler solma noktasının altındaki nemi de kökleri aracılığı ile alamamaktadır. Bu nedenle uygulamalarda, bitkilerin ancak tarla kapasitesi ile solma noktası arasındaki nemden yararlanabildiği kabul edilmektedir. Tarla kapasitesi ve solma noktası arasındaki bu farka kullanılabilir su tutma kapasitesi adı verilmektedir (Güngör ve ark., 2012).

Kullanılabilir su tutma kapasitesinin belirlenebilmesi için öncelikle tarla kapasitesi ve solma noktası değerlerinin belirlenmesi gerekmektedir. Tarla kapasitesi ve solma noktası belirlemek için en yaygın ve güvenilir olarak kullanılan yöntem, toprak örneklerinin 1/3 atm ve 15 atm'de tuttukları nem miktarının belirlenmesi esasına dayanan basınçlı tencere ile belirleme yöntemidir (Şekil 3.20). Bu cihaz Hatay Mustafa Kemal Üniversitesi Teknoloji ve Ar-Ge Uygulama Merkezi (MARGEM) laboratuvarlarında bulunmaktadır. Çalışmamızda tarla kapasitesi ve solma noktası değerleri bu laboratuvarda yaptırılan analizler sonucu elde edilmiştir. Tarla kapasitesi ve solma noktası değerleri arasındaki fark hesaplanarak kullanılabilir su tutma kapasitesi değeri belirlenmiştir.



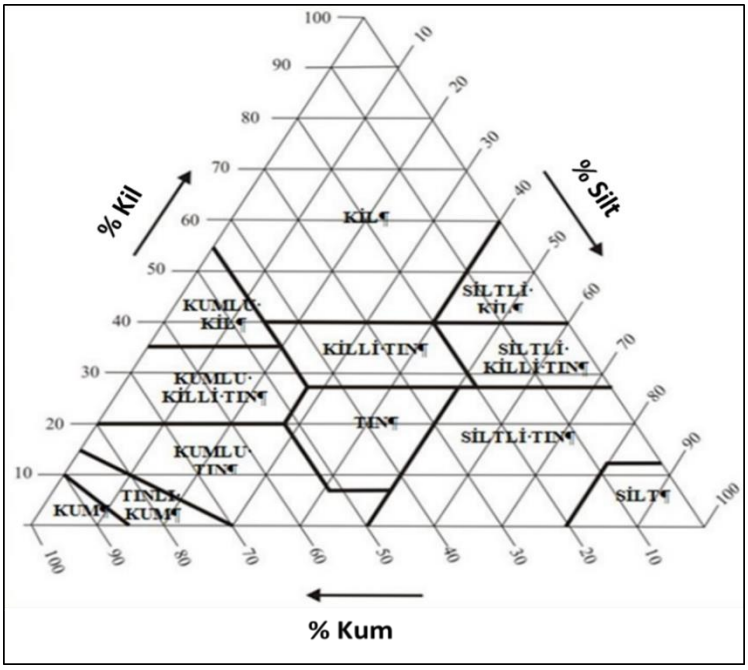
Şekil 3.20. Tarla kapasitesi ve solma noktası tayin cihazı

3.2.6.2.3. Toprak Örneklerinde Hacim Ağırlığının Belirlenmesi

Hacim ağırlığı (kütle yoğunluğu); fırın kuru toprak ağırlığının kütle hacmine bölünmesi ile bulunan değerdir. Hacim ağırlığı, başta infiltrasyon olmak üzere kullanılabilir su, alınabilir bitki besin elementi, mikroorganizma aktiviteleri ve kök gelişimi üzerine etkili olduğundan toprağın önemli fiziksel özelliklerindendir. Günümüzde topraklarda hacim ağırlığının belirlenmesi için yaygın olarak kullanılan yöntem silindir (core) yöntemidir (Kaçar, 2016). Bu yönteme göre, araziden çakma silindirlerle alınan bozulmamış toprak örnekleri laboratuvarda 105°C'de 24 saat kurutulmuş ve tartılmıştır. Tartılan örneklerin hacim ağırlığı, kuru ağırlıklarının çakma silindirlerin hacmine bölünmesi ile belirlenmiştir (Güngör ve ark., 2012).

3.2.6.2.4. Toprak Bünyesinin Belirlenmesi

Toprakların temel yapısını, 2 mm çapından küçük olan ve bağımsız şekilde bulunan inorganik taneler oluşturmaktadır. Kum, silt ve kil olarak adlandırılan bu tanelerin topraktaki dağılım durumu toprak bünyesi olarak ifade edilmektedir. Topraklarda belirlenen yüzde kum, silt ve kil miktarlarına göre anılan tekstür sınıfları Şekil 3.21'de gösterilmiştir.



Şekil 3.21. USDA sistemine göre hazırlanmış bünye sınıflarını gösteren eşkenar üçgen

Büyülüğü 0.002 mm'den az toprak tanelerine kil, 0.002-0.05 mm arasındakilere silt ve 0.05-2 mm arasındakilere ise kum adı verilmektedir. Toprağın katı fazını oluşturan kum, silt ve kilin yüzde değerlerine bağlı olarak 12 toprak bünye sınıfı vardır. Bu sınıflar; kum, tınlı kum, kumlu tın, tın, siltli tın, silt, kumlu killi tın, killi tın, siltli killi tın, kumlu tın, siltli tın ve kildir (Güngör ve ark., 2012).

Çalışmada araziden alınan toprak örneklerinin bünyelerinin belirlenmesi için kullanımı yaygın olan Bouyoucos hidrometresi yöntemi kullanılmıştır (Bouyoucos, 1962; Estefan ve ark., 2014; Karaoğlu ve Şimşek, 2014; Kaçar, 2016). Bu yöntem dikkate alınarak, toprak tanelerinin tamamen serbest hale geçirilmesi için bağ çözücü madde olan kalgon (sodyum hekzametafosfat) kullanılmıştır. Bu arada tanelerin bağlanmasında önemli rol oynayan organik madde, uygulanan hidrojen peroksit ile oksitlenerek etkisizleştirilmiş ve karbonatlar ise uygulanan asit ile giderilmiştir. Bağsız ve bağlantısız hale getirilen ve kuvvetle çalkalanan su sütunundaki toprak tanelerinin belirli zaman aralıklarında değişen yoğunluklarından Bouyoucos hidrometresi ile toprak tanelerinin büyüklüklerinin dağılımı belirlenmiştir (Şekil 3.22).

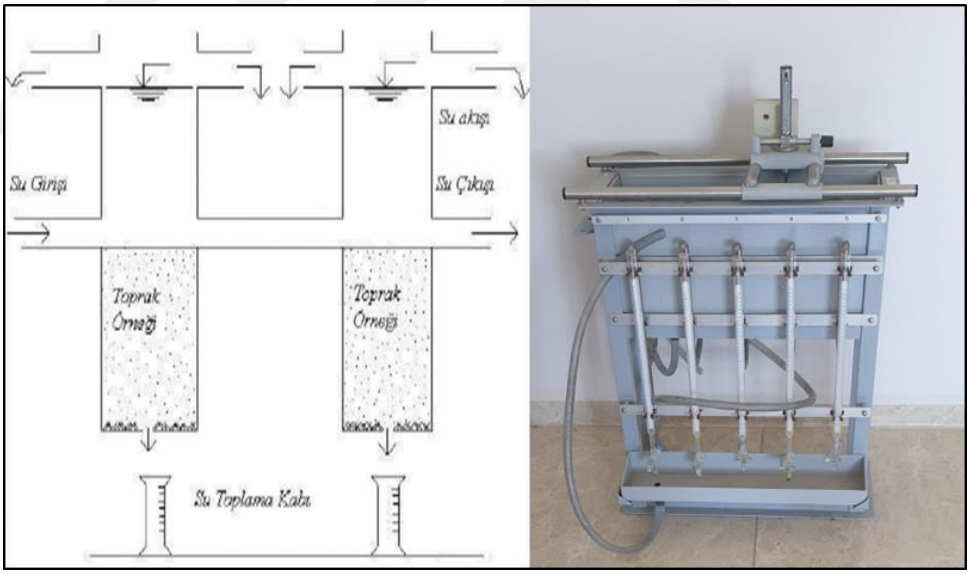


Şekil 3.22. Bouyoucos hidrometre yöntemi

3.2.6.2.5. Doygun Hidrolik İletkenliğin Belirlenmesi

Gözenekli ortamda suyun hareket etme hızı, ortamın geçirgenliğinin bir göstergesidir ve hidrolik iletkenlik olarak adlandırılmaktadır. Bir toprağın hidrolik iletkenliği, su ile dolu gözeneklerin büyüklüğüne, geometrisine ve dağılımına bağlıdır. Hidrolik iletkenlik toprakta suyun devinimini sağlayan güçlerle, engelleyen güçlerin ve dirençlerin bileşkesi olarak da tanımlanmaktadır.

Hidrolik iletkenliğin belirlenmesi yönteminde temel prensip; bir hidrolik yük altında bulunan belirli kalınlıktaki bir toprak sütununun gözeneklerinden birim zamanda hacim olarak geçen suyun ölçülmesidir. Silindir içine konulan toprak üzerinde, Şekil 3.23'de görüldüğü gibi bir su yükü oluşturulur. Fazla su bir boru yardımıyla uzaklaştırılır ve belirli zaman aralıklarında suyun miktarı ölçülür. Toprak örneğinin geçirgenliği Darcy yasası kullanılarak belirlenmektedir. Çalışmamızda Darcy yasasına göre doygun hidrolik iletkenlik üniversitemizin MARGEM laboratuvarında belirlenmiştir.



Şekil 3.23. Toprak örneklerinde hidrolik iletkenliğin belirlenmesi ve hidrolik iletkenlik ölçme cihazı

3.2.6.2.6. Toprak Örneklerinde Porozitenin Belirlenmesi

Porozite; toprak örneğindeki su hacminin boşluk hacmine oranının yüzde cinsinden ifadesidir. Porozite değerleri Denklem 3.41 ile hesaplanmıştır (Güngör ve ark., 2012).

$$n = 100\ \frac{V_e}{V} \qquad (3.41)$$

Denklemde n; poroziteyi (%), V; toprak örneğinin hacmini (cm^3) ve V_e; gözenek hacmini (cm^3) temsil etmektedir.

3.2.6.3. Bitki Dosyalarının Oluşturulması

3.2.6.3.1. Pamuk Bitki Dosyası

Arazilerde pamuk ekimi mibzer kullanılarak; sıra arası mesafe 70 cm, sıra üzeri mesafe ise 10-12 cm olacak şekilde gerçekleştirilmiştir. Abalaklı köyündeki arazide 09.05.2021, Danaahmetli köyündeki arazide 24.04.2021, Mahmutlu köyündeki arazide 22.04.2021 ve Ahrazlı köyündeki arazide 21.04.2021 tarihinde ekim işlemi gerçekleştirilmiştir (Şekil 3.24). Pamuk bitkisinin ekiminden hasatına kadar Abalaklı köyünde 153 gün, Danaahmetli köyünde 143 gün, Mahmutlu köyünde 142 gün ve Ahrazlı köyünde 149 gün geçtiği belirlenmiştir.

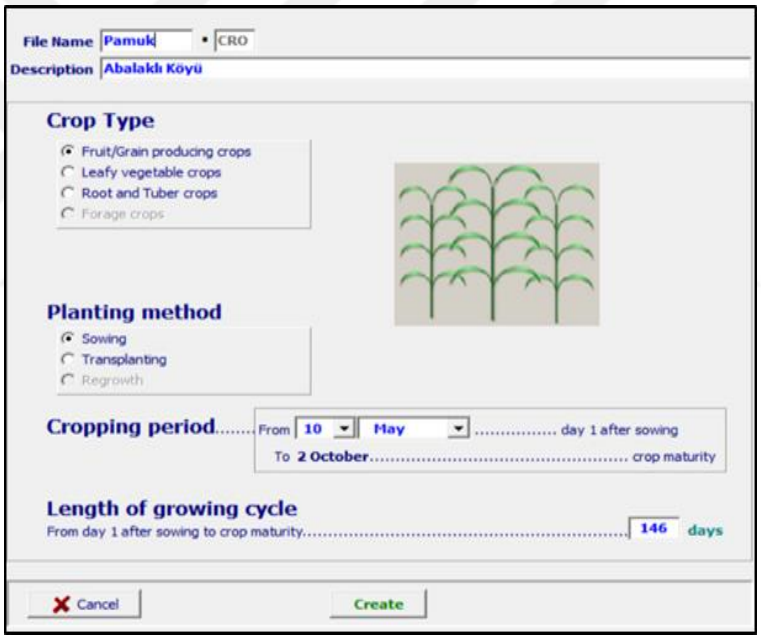


Şekil 3.24. Tarlalarda ekim işlemi

Modelin içerisinde arpa, pamuk, kuru fasulye, mısır, pirinç, patates, sorgum, soya, ayçiçeği, domates ve buğday için oluşturulmuş bitki dosyaları bulunmaktadır. Modelde kullanıcılar bu hazır dosyalardan seçim yapabilmektedir. Ayrıca, kullanıcılar isterse

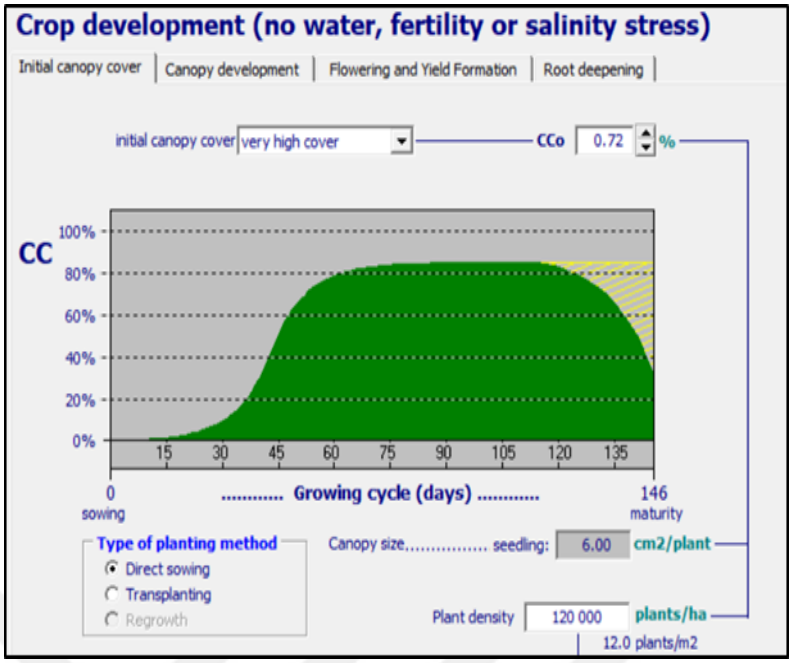
kendi bölge koşullarına uygun olacak yeni bir bitki dosyası oluşturabilmektedir. Bu çalışmada pamuk bitkisinin yetiştirildiği Kırıkhan'da bulunan arazilerden elde edilen gözlem ve ölçüm sonuçları kullanılarak PamukAbalaklı.CRO, PamukDanahmetli.CRO, PamukMahmutlu.CRO ve PamukAhrazlı.CRO dosyaları oluşturulmuştur. FAO tarafından basılmış olan AquaCrop model kullanıcı el kitabında birçok bitki için ek bilgiler verilmiştir. Modelin pamuk bitkisi için kabul ettiği sabit girdi değerleri bu kitapçıktan alınmıştır (Raes ve ark., 2018).

Modelde bitki dosyası için ilk olarak bitkinin tanımlanması gerçekleştirilmiştir. Simülasyonu yapılacak bitki türü olarak farklı bitki tiplerinden meyve veya tahıl üreten bitki seçeneği, bitki gruplarından ise C3 seçilmiştir. Son olarak, ekimden sonraki günün tarihi ve büyüme döngüsü uzunluğu girilmiştir (Şekil 3.25).



Şekil 3.25. Bitki dosyası oluşturulması ekranı

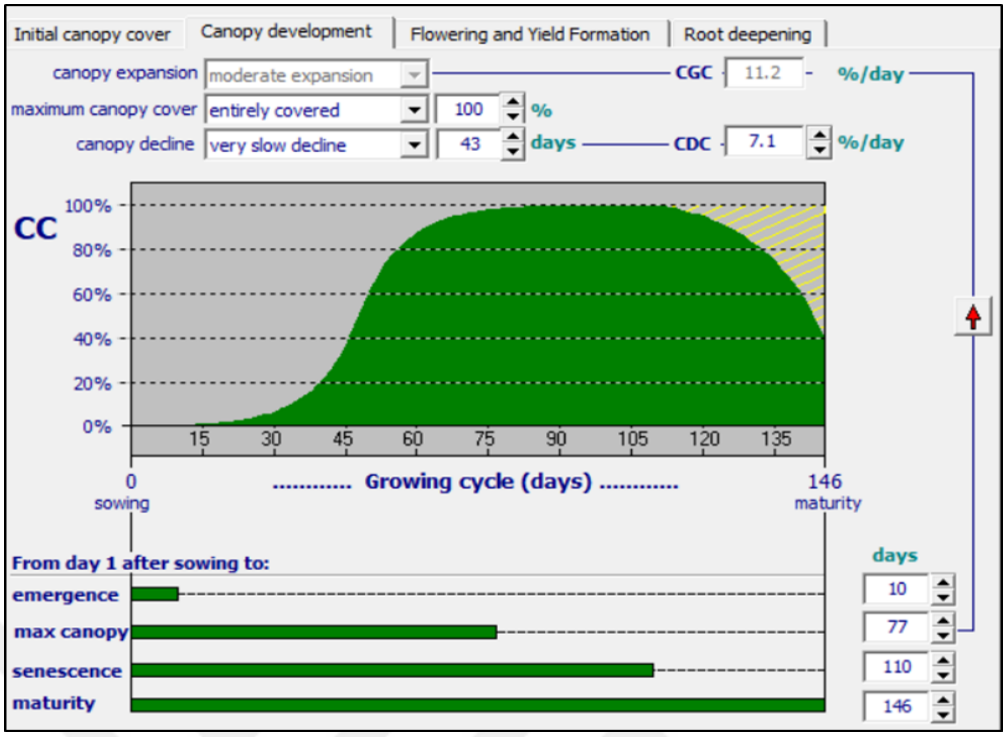
Bitki örtü yüzeyinin gelişimi ve kapladığı alanın başlangıç değerinin (CC_o) hesaplandığı bölümde ise model, girdi olarak ekili alandaki bitki yoğunluğu (bitki ha^{-1}) bilgisini istemektedir. CCo, filizlenmenin %90'ının gerçekleştiği andaki mevcut olan bitki örtü yüzeyini temsil etmektedir. Bu çalışmada, arazilerde metrekare başına düşen bitki sayısı 12 olarak sayılmış ve bu değer hektara çevrilerek modele girilmiştir. Model tarafından CC_o değeri 0.72 olarak hesaplanmıştır. Ekim yöntemi olarak şaşırtma ve doğrudan ekim seçeneklerinden doğrudan ekim seçilmiştir (Şekil 3.26).



Şekil 3.26. CC_o hesaplama bölümü ekranı

Bitki örtü yüzeyi gelişimi bölümünde model tarafından bitkinin gelişim dönemindeki önemli olan tarihlerin girilmesi gerekmektedir. Bu tarihler; ekim zamanından bitkinin çıkışına kadar geçen gün sayısı, bitki örtü yüzeyinin maksimuma ulaşması için geçmesi gereken gün sayısı, bitkinin yapraklarının sararmaya başladığı gün ve hasat olgunluğuna ulaştığı gün bilgileridir (Şekil 3.27). Bitki örtü yüzeyinin kapladığı alanın bitkinin ekiminden sonra maksimuma ulaşması için geçen gün sayısı ve maksimum bitki örtü yüzeyi yüzdesi değerini hesaplayabilmek için ise model bitkinin maksimum yaprak alan indeksi değeri ve bu değere ulaştığı gün sayısını kullanmaktadır.

Bu bölümde tarih bilgileri dışında modelde, arazide yapılan ölçümler sonucunda belirlenen bitki örtü yüzeyinin maksimum genişleme yüzdesi değeri istenmektedir. Bu değerin belirlenmesi için yaprak alan indeksi değerinin hesaplanması gerekmektedir. Yaprak alanı veya yaprak alanı indeksi gibi bitki parametreleri bitkilerde fotosentez ve ürün gelişimine ilişkin fizyolojik ve agronomik çalışmalarda önemli bir rol oynamaktadır. Ürün gelişimi ve çevre arasındaki ilişkilerin daha iyi anlaşılabilmesi için bitki yaprak alanının doğru bir şekilde ölçülmesi oldukça önemlidir (Hajjdiab ve Obaid, 2010; Singh ve ark., 2018).



Şekil 3.27. Bitki gelişim bölümü ekranı

Yaprak alanının ölçülmesi; yaprakların sayısı, boyutu ve şeklindeki değişiklikler nedeniyle zor, işgücü gerektiren ve maliyetli bir işlemdir. Bu yöntemler genellikle yaprakların eskizlerini çizmek ve bir planimetre yardımı ile alanını belirlemek üzerine kuruludur. Ancak, bu çok zaman alıcı ve iş gücü gerektiren bir yöntemdir. Bunun yerine geliştirilen ölçüm cihazları ise çok pahalıdır (Singh ve ark., 2018).

Görüntü analizi gibi alternatif yöntemler, yaprak alanını ölçmek için kullanılabilmektedir (Ali ve ark., 2012). Görüntü analizi; dijital kameralarla elde edilen görüntüleri uygun ticari veya ücretsiz yazılımlar kullanılarak gerçekleştirmektedir. Bu yöntemler son yıllarda eski ve işgücü gerektiren yöntemlerin yerini almıştır (Ahmad ve ark., 2015). Pek çok önceki çalışmada dijital kamera ve farklı görüntü işleme yazılımları kullanılarak yaprak alanı ve yaprak alan indeksi değerleri hesaplanmıştır (Ali ve ark., 2012; Ahmad ve ark., 2015; Aboukarima ve ark., 2017; Koyama, 2023). Bu değerin belirlenmesi amacı ile çalışmamızda her arazi için çiçeklenme dönemi boyunca alınan pamuk örneklerinin yaprakları ayırıldıktan sonra bitki yaprakları beyaz bir zemin üzerine yerleştirilmiş ve dijital görüntüleri elde edilmiştir (Şekil 3.28).



Şekil 3.28. Pamuk yapraklarının alınan dijital görüntü örnekleri

Görüntü işleme uygulaması ile elde edilen toplam yaprak alanlarının ortalamaları Denklem 3.42 ve Denklem 3.43 kullanılarak her arazi için yaprak alan indeksi değerleri belirlenmiştir (Gadédjisso-Tossou ve ark., 2020).

$$Bitki\ yoğunluğu\ (Bitki\ ha^{-1}) = (1/(Sıra\ üzeri\ (m) * Sıra\ arası\ (m))\ 10000 \qquad (3.42)$$

$$LA\dot{I} = \frac{Yaprak\ Alanı\ (m^2/\ Bitki)\ x\ Bitki\ Yoğunluğu\ (Bitki/ha)}{10000\ (m^2/ha)} \qquad (3.43)$$

Model için gerekli girdilerden olan bitkinin tam çiçeklenme dönemi boyunca maksimum bitki örtü yüzeyi yüzdesi değeri çalışmamızda model tarafından kullanılan Denklem 3.44 yardımı ile hesaplanmıştır (Farahani ve ark., 2009). Denklemde x katsayısı 0.77 olarak kabul edilmektedir. (García-Vila ve ark., 2009).

$$CC = 1.00 - e^{(-xLA\dot{I})} \qquad (3.44)$$

Bu bölümde son olarak bitki gelişme katsayısı (CGC) bitki örtü yüzeyinin maksimuma ulaşması için geçmesi gereken gün sayısına göre model tarafından hesaplanmıştır. Bitki zayıflama katsayısı (CDC) ise, bitkinin yaşlanma başlangıcından hasata kadar geçen gün sayısının modele girilmesi ile elde edilmiştir. Tüm araziler için elde edilen bu değerler Çizelge 3.18'de verilmiştir.

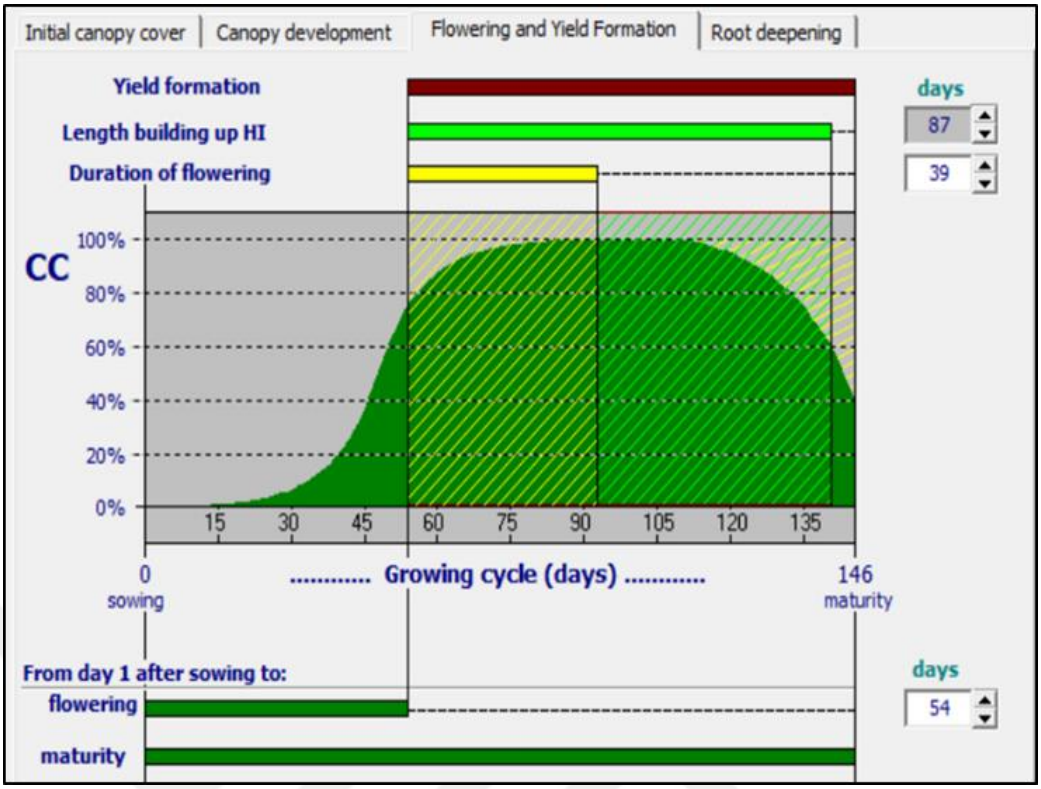
Çizelge 3.19. Pamuk bitkisi gelişim bölümü girdilerinin değerleri

Parametreler	Abalaklı	Danaahmetli	Mahmutlu	Ahrazlı
Bitki çıkışı gün sayısı	10 gün	6 gün	8 gün	6 gün
Yaprakların sararmaya başlama zamanı	110 gün	102 gün	99 gün	92 gün
Fizyolojik olgunluk zamanı	146 gün	136 gün	134 gün	138 gün
Bitki gelişme katsayısı (CGC)	11.2	10.5	12.3	11.6
Bitki zayıflama katsayısı (CDC)	7.1	7.3	7.00	5.30
Bitki örtü yüzeyi nün max olması için gün sayısı	78 gün	78 gün	70 gün	79 gün
Maksimum bitki örtü yüzeyi yüzdesi	0.98	0.97	0.96	0.97

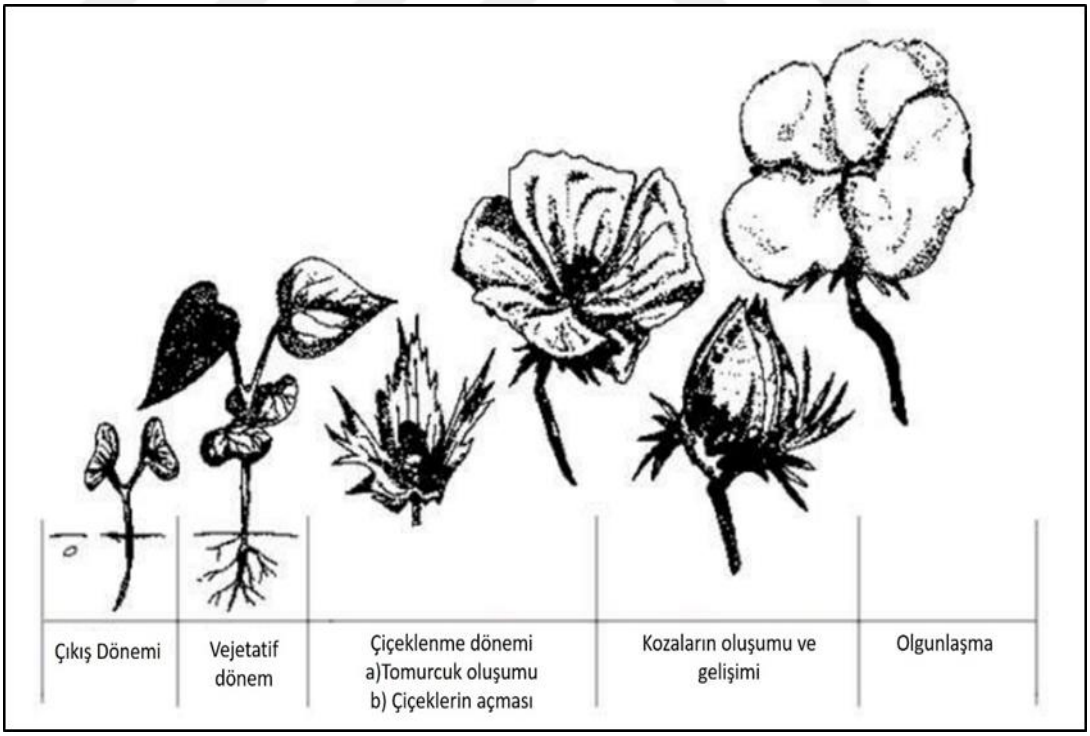
Çiçeklenme verim oluşum bölümü, modelde bitkinin çiçeklenme dönemi ve verim ile ilgili bilgilerin istendiği bölümdür (Şekil 3.29). Çiçeklenme dönemi bitkinin verimi için çok önemlidir. Model, bitkinin çiçeklenme dönemi olarak tomurcuk oluşumu (taraklanma) başlama tarihi ve kozaların oluşma zamanı arasını kabul etmektedir (Şekil 3.30). Model bu bilgileri kullanarak hasat indeksinin gelişmesi için gerekli olan gün sayısını hesaplamaktadır. Çalışma alanları için elde edilen değerler Çizelge 3.19'da verilmiştir.

Çizelge 3.20. Pamuk bitkisi çiçeklenme bölümü girdilerinin değerleri

Parametreler	Abalaklı	Danaahmetli	Mahmutlu	Ahrazlı
Çiçeklenme dönemi başlangıç süresi	54 gün	50 gün	46 gün	46 gün
Çiçeklenme dönemi süresi	39 gün	36 gün	34 gün	33 gün
Hasat indeksinin gelişmesi için gereken süre	87 gün	81 gün	83 gün	87 gün

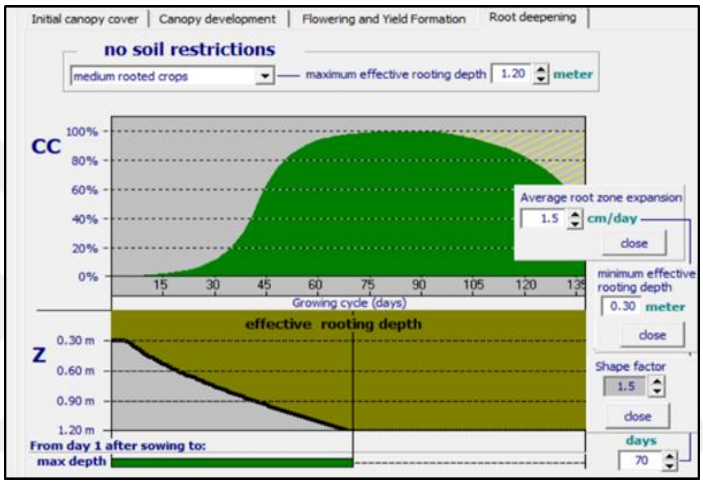


Şekil 3.29. Çiçeklenme ve verim bölümü ekranı



Şekil 3.30. Pamuk bitkisi büyüme dönemleri (Raes ve ark., 2018)

Model köklenme derinliği bölümünde maksimum ve minimum etkili kök derinliği, şekil faktörü ve kök derinliğinin ortalama büyüme değeri bilgilerine ihtiyaç duymaktadır. Çalışmada pamuk bitkisinin maksimum etkili kök derinliği 120 cm olarak kabul edilmiştir (Tülücü, 2003). Pamuk bitkisinin AquaCrop modeli tarafından sabit kabul edilen minimum etkili kök derinliği 0.30 m, şekil faktörü 1.3 ve ortalama büyüme değeri ise 1.5 olarak girilmiştir (Raes ve ark., 2018). Model bu bilgileri kullanarak maksimum etkili kök derinliğine ulaşma gün sayısını 70 gün olarak hesaplamıştır (Şekil 3.31). Son olarak, modelin pamuk bitkisi için belirlediği sabit parametrelerin değerleri Çizelge 3.20'de verilmiştir.



Şekil 3.31. Kök derinliği bölümü ekranı

Çizelge 3.21. Pamuk bitkisinin sabit parametre değerleri (Raes ve ark., 2018)

Parametreler	Değerler
Bitki Transpirasyon Katsayısı, $Kc_{Tr,x}$	1.10
Su Verimlilik Parametresi, WP	15.0 g m^{-2}
Bitki örtü yüzeyi genişlemesi için toprak suyu tükenme üst eşiği	0.20
Bitki örtü yüzeyi genişlemesi için toprak suyu tükenme alt eşiği	0.70
Bitki örtü yüzeyi genişlemesi için toprak su tüketimi şekil faktörü	0.30
Stoma kontrolü için toprak suyu tükenme üst eşiği	0.65
Stoma kontrolü için toprak su tüketimi şekil faktörü	2.50
Bitki örtü yüzeyinin yaşlanması için toprak suyu tükenme üst eşiği	0.75
Bitki örtü yüzeyinin yaşlanması için toprak su tüketimi şekil faktörü	2.50
Havayla temas halinde olan toprağın su stresi	Orta Derece
Çiçeklenmeden önceki su stresinin hasat indeksine pozitif etkisi	Düşük
Çiçeklenmede tozlaşmanın başarısız olması için toprak suyu tükenme üst eşiği	0.85
Çiçeklenmeden sonraki su stresinin hasat indeksine pozitif etkisi	Orta Derece
Çiçeklenmeden sonraki su stresinin hasat indeksine negatif etkisi	Düşük
Referans hasat indeksinin izin verilen maksimum artışı	% 30

3.2.6.3.2. Mısır Bitki Dosyası

Arazilerde mısır ekimi mibzer kullanılarak, sıra arası mesafe 70 cm, sıra üzeri mesafe ise 15-17 cm olacak şekilde gerçekleştirilmiştir. Abalaklı köyündeki arazide 28.02.2021, Danaahmetli köyündeki arazide 06.03.2021, Mahmutlu köyündeki arazide 01.03.2021 ve Ahrazlı köyündeki arazide 08.03.2021 tarihinde ekim işlemi gerçekleştirilmiştir (Şekil 3.32). 1. ürün mısır bitkisinin ekiminden hasatına kadar Abalaklı köyünde 161 gün, Danaahmetli köyünde 156 gün, Mahmutlu köyünde 160 gün ve Ahrazlı köyünde 156 gün geçmiştir. Modelde mısır bitki dosyası, pamuktan farklı olarak C4 bitkisi seçilerek oluşturulmuştur.



Şekil 3.32. Arazilerde ekim işlemi

Pamuk bitkisinin modellenmesinde olduğu gibi 1. ürün mısır bitkisi içinde ilk olarak her arazi için elde edilen gözlem ve ölçüm sonuçları kullanılarak MısırAbalaklı.CRO, MısırDanahmetli.CRO, MısırMahmutlu.CRO ve MısırAhrazlı.CRO dosyaları oluşturulmuştur. Modelin 1. ürün mısır bitkisi için kabul ettiği sabit girdi değerleri AquaCrop model kullanıcı el kitabından alınmıştır (Raes ve ark., 2018). Başlangıç bitki örtü yüzeyinin gelişimi bölümünde, arazilerde metrekare başına düşen bitki sayısı 10 olarak sayılmış ve bu değer hektara çevrilerek modele girilmiştir. Model tarafından CC_o değeri 0.65 olarak hesaplanmıştır. Bitki örtü yüzeyi gelişimi bölümünde

model tarafından bitkinin gelişim dönemindeki önemli olan tarihlerin girilmesi gerekmektedir. Bu tarihler; ekimden bitkinin çıkışına kadar geçen gün sayısı, Bitki örtü yüzeyinin maksimuma ulaşması için geçmesi gerekli olan gün sayısı, bitkinin yapraklarının sararmaya başladığı gün ve hasat olgunluğuna ulaştığı gün bilgileridir (Şekil 3.33).



Şekil 3.33. Mısır bitkisinin gelişimi

Tarih bilgileri dışında model bu bölümde arazide yapılan ölçümler sonucu belirlenen bitki örtü yüzeyinin maksimum genişleme yüzdesi değerini istemektedir. Araziden alınan 1. ürün mısır bitki örneklerinin yaprakları ayırıldıktan sonra bitki yaprakları beyaz bir zemin üzerine yerleştirilmiş ve dijital görüntüleri alınmıştır (Şekil 3.34).



Şekil 3.34. 1. ürün mısır yapraklarının alınan dijital görüntü örnekleri

Görüntü işleme uygulaması ile elde edilen toplam yaprak alanlarının ortalamaları ile Denklem 3.45 ve Denklem 3.46 kullanılarak her arazi için yaprak alan indeksi belirlenmiştir (Gadédjisso-Tossou ve ark., 2020).

$$Bitki\ yoğunluğu\ (Bitki\ ha^{-1}) = (1/(Sıra\ üzeri\ (m) * Sıra\ arası\ (m))\ 1000 \quad (3.45)$$

$$LAİ = \frac{Yaprak\ Alanı\ (m^2/\ Bitki)\ x\ Bitki\ Yoğunluğu\ (Bitki/ha)}{10000\ (m^2/ha)} \quad (3.46)$$

Model için gerekli olan bitkinin tam çiçeklenme dönemi boyunca maksimum bitki örtü yüzeyi yüzdesi değeri çalışmamızda model tarafından kullanılan Denklem 3.47 kullanılarak hesaplanmıştır (Hsiao ve ark., 2009).

$$CC = 1.005\ x\ [1 - \ e^{-0.6LAI}]^{1.2} \quad (3.47)$$

Bu bölümde son olarak ise pamuk bitkisinde olduğu gibi bitki gelişimini simüle etmek için model tarafından istenen önemli günler belirlenerek Çizelge 3.21'de verilmiştir.

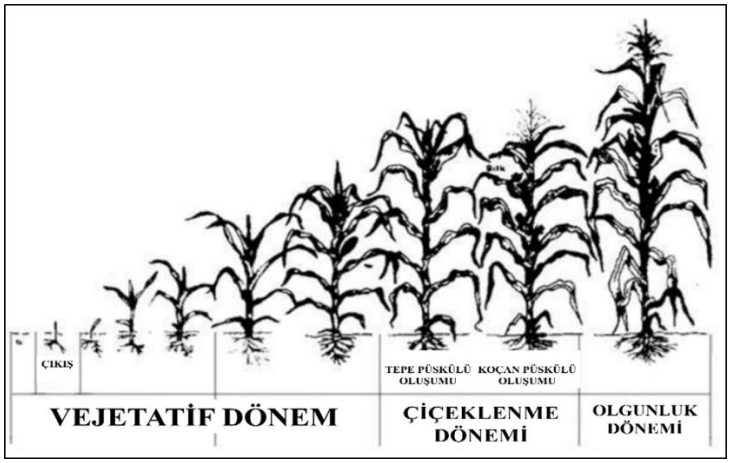
Çizelge 3.21. 1. ürün mısır bitkisi gelişim bölümü girdilerinin değerleri

Parametreler	Abalaklı	Danaahmetli	Mahmutlu	Ahrazlı
Bitki çıkışı gün sayısı	12 gün	12 gün	13 gün	11 gün
Yaprakların sararmaya başlama zamanı	123 gün	113 gün	122 gün	109 gün
Fizyolojik olgunluk zamanı	146 gün	141 gün	147 gün	137 gün
Bitki gelişme katsayısı (CGC)	10.20	10.30	9.30	10.70
Bitki zayıflama katsayısı (CDC)	7.90	7.00	7.90	6.40
Bitki örtü yüzeyinin max olması için gün sayısı	95 gün	88 gün	94 gün	81 gün
Maksimum bitki örtü yüzeyi yüzdesi	0.98	0.97	0.94	0.96

Model, bitkinin çiçeklenme dönemi olarak tepe püskülünün çıkışı ve koçan püskülü teşekkülünün tamamlanma zamanı arasını kabul etmektedir (Şekil 3.35). Model bu bilgileri kullanarak hasat indeksinin gelişmesi için gerekli olan gün sayısını hesaplamaktadır. Çalışma alanları için elde edilen değerler Çizelge 3.22'de verilmiştir.

Çizelge 3.22. 1. ürün mısır bitkisi çiçeklenme bölümü girdilerinin değerleri

Parametreler	Abalaklı	Danaahmetli	Mahmutlu	Ahrazlı
Çiçeklenme dönemi başlangıç süresi	87 gün	78 gün	82 gün	73 gün
Çiçeklenme dönemi süresi	18 gün	15 gün	16 gün	17 gün
Hasat indeksinin gelişmesi için gereken süre	51 gün	57 gün	59 gün	58 gün



Şekil 3.35. 1. ürün mısır bitkisi büyüme dönemleri (Raes ve ark., 2018)

Köklenme derinliği bölümünde pamuk bitkisinde olduğu gibi aynı bilgilere ihtiyaç duymaktadır. Çalışmada 1. ürün mısır bitkisinin maksimum etkili kök derinliği 120 cm olarak kabul edilmiştir (Tülücü, 2003). 1. ürün mısır bitkisinin AquaCrop modeli tarafından sabit kabul edilen minimum etkili kök derinliği 0.30 m, şekil faktörü 1.3 ve ortalama büyüme değeri ise 1.3 olarak girilmiştir (Raes ve ark. 2018). Model bu bilgileri kullanarak maksimum etkili kök derinliğine ulaşma gün sayısını 82 gün olarak hesaplamıştır. Son olarak, modelin 1. ürün mısır bitkisi için belirlediği sabit parametrelerin değerleri Çizelge 3.23'de verilmiştir (Raes ve ark., 2018).

Çizelge 3.23. 1. ürün mısır bitkisinin sabit parametre değerleri (Raes ve ark., 2018)

Parametreler	**Değerler**
Bitki Transpirasyon Katsayısı, $Kc_{Tr,x}$	1,05
Su Verimlilik Parametresi, WP	33.7 g m^{-2}
Bitki örtü yüzeyi genişlemesi için toprak suyu tükenme üst eşiği	0.14
Bitki örtü yüzeyi genişlemesi için toprak suyu tükenme alt eşiği	0.72
Bitki örtü yüzeyi genişlemesi için toprak su tüketimi şekil faktörü	2.90
Stoma kontrolü için toprak suyu tükenme üst eşiği	0.69
Stoma kontrolü için toprak su tüketimi şekil faktörü	6.00
Bitki örtü yüzeyinin yaşlanması için toprak suyu tükenme üst eşiği	0.69
Bitki örtü yüzeyinin yaşlanması için toprak su tüketimi şekil faktörü	2.70
Havayla temas halinde olan toprağın su stresi	Orta Derece
Çiçeklenmeden önceki su stresinin hasat indeksine pozitif etkisi	-
Çiçeklenmede tozlaşmanın başarısız olması için toprak suyu tükenme üst eşiği	0.80
Çiçeklenmeden sonraki su stresinin hasat indeksine pozitif etkisi	Düşük
Çiçeklenmeden sonraki su stresinin hasat indeksine negatif etkisi	Şiddetli
Referans hasat indeksinin izin verilen maksimum artışı	% 30

3.2.7. Model Performans Değerlendirilmesi için Kullanılan İstatistiki Ölçütler

3.2.7.1. Belirleme Katsayısı

Belirleme katsayısı (R^2), gözlemlenen verilerdeki değişimin ne kadarının model tarafından açıklanabildiğinin oranıdır. Ayrıca R^2, bir modelin iyi uyum gösterip göstermediği hakkında bazı bilgiler veren bir istatistiki ölçüttür (Hatmoko ve ark., 2020).

R^2 değeri ne kadar yüksek olursa bu durum açıklanamayan daha az varyasyon olduğunu göstermektedir ve bu nedenle yüksek bir R^2 değeri istenmektedir. Regresyon analizinde R^2, regresyon çizgisinin gerçek verilere ne kadar yaklaştığını gösteren bir istatistiksel ölçümdür (Lamboni ve ark., 2019). R^2 aşağıda verilen Denklem 3.48 ile hesaplanmaktadır.

$$R^2 = \left(\frac{\sum_{i=1}^{n}(O_i - \bar{O}) \times (M_i - \bar{M})}{\sqrt{\sum_{i=1}^{n}(O_i - \bar{O})^2} \times \sqrt{\sum_{i=1}^{n}(M_i - \bar{M})^2}} \right)^2 \tag{3.48}$$

Denklemde, O_i; i.gözlem verisini, $\bar{O}$; gözlem verilerinin ortalamasını, M_i; modelin i.verisini ve $\bar{M}$; model tahminlerinin ortalamasını temsil etmektedir.

3.2.7.2. Kök Ortalama Kareler Hatası

Kök Ortalama Kareler Hatası (RMSE), yaygın olarak kullanılan hata indeksi istatistiklerinden biridir (Singh ve ark., 2005; Moriasi ve ark., 2007). Gözlem verilerine göre model tahminlerinin ortalama standart sapmasını temsil etmektedir. RMSE ne kadar düşükse model performansının o kadar iyi olduğu genel olarak kabul edilmektedir. Denklem 3.49 ile hesaplanmaktadır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^{n}(O_i - M_i)^2}{n}} \tag{3.49}$$

Denklemde, O_i; i.gözlem verisini, n; gözlem sayısını ve M_i; modelin i.verisini temsil etmektedir.

3.2.7.3. Normalize Edilmiş Kök Ortalama Kareler Hatası

NRMSE, bir tahmin modelinin gerçek değerlerden ne kadar sapma gösterdiğini ölçen bir performans metriğidir. NRMSE, kök ortalama kareler hatası gerçek değerlerin aralığıyla normalize edilmesiyle elde edilmektedir (Seo ve Eo, 2019) (Denklem 3.50).

$$NRMSE = \frac{RMSE}{\bar{O}} \tag{3.50}$$

Denklemde, RMSE; kök ortalama kareler hatasını ve $\bar{O}$; gözlem verilerinin ortalamasını temsil etmektedir. NRMSE değeri, genellikle yüzde olarak ifade edilir ve 0 ile 1 arasında bir değer alır. Daha düşük bir NRMSE değeri, modelin daha iyi bir tahmin performansı sergilediğini göstermektedir. NRMSE'nin değeri sıfırın yakınında ise, tahmin modeli gerçek değerlere çok yakın bir uyum sağlamaktadır.

3.2.7.4. Wilmott uyumluluk indeksi

Wilmott uyumluluk indeksi (d), istatistiksel tahmin modellerinin gerçek değerlere ne kadar uyum sağladığını ölçmek için kullanılan bir performans metriğidir. Bu indeks, gerçek değerler ile tahmin edilen değerler arasındaki korelasyonu, veri setinin standart sapmasını ve tahmin edilen değerlerin standart sapmasını dikkate almaktadır. Denklem 3.51 kullanılarak hesaplanmaktadır (Willmott, 1981; Tran ve ark., 2020).

$$d = \frac{\sum_{i=1}^{n}(O_i - M_i)^2}{\sum_{i=1}^{n}\left((M_i - \bar{O}) + (O_i - \bar{O})\right)^2} \tag{3.51}$$

Denklemde, O_i; i.gözlem verisini, $\bar{O}$; gözlem verilerinin ortalamasını ve M_i; modelin i.verisini temsil etmektedir.

3.2.7.5. Yüzde Sapma Değeri

PBIAS, modelin tahmin edilen değerlerinin gözlemlenen değerlerden negatif veya pozitif yönde ne kadar uzakta olduğunu belirlemek için kullanılmaktadır. Pozitif değerler,

gözlemlenen değerlerin simülasyon değerlerinden daha büyük olduğunu gösterirken, negatif değerler ise tam tersi durumu işaret etmektedir (Gupta ve ark., 1999). PBIAS değerleri Denklem 3.52 kullanılarak hesaplanmaktadır ve Çizelge 3.24 kullanılarak değerlendirilmiştir.

$$PBIAS = 100\ (\sum O_i - M_i\ /\ \sum O_i\ ) \tag{3.52}$$

Denklemde, O_i; i.gözlem verisini ve M_i; modelin i.verisini temsil etmektedir.

3.2.7.6. Nash-Sutcliffe Verimlilik Katsayısı

NSE, modelin tahmin kabiliyetini temsil eden bir katsayı değeri vermektedir. Aldığı değerler $-\infty$ ile 1 arasındadır. Aldığı değerin 0-1 arasında olması istenen durumdur ve 1'e yaklaştıkça modelin iyi bir tahmin sonucu verdiğini göstermektedir (Moriasi ve ark., 2007). NSE aşağıda verilen Denklem 3.53 ile hesaplanmaktadır. NSE ve PBIAS değerlendirme tablosu ise, Çizelge 3.24'te verilmiştir.

$$NSE = 1 - \frac{\sum_{i=1}^{n}(O_i - M_i)^2}{\sum_{i=1}^{n}(O_i - \bar{O})^2} \tag{3.53}$$

Denklemde, O_i; i.gözlem verisini, $\bar{O}$; gözlem verilerinin ortalamasını ve M_i; modelin i.verisini temsil etmektedir.

3.2.7.7. Kök Ortalama Kareler Hatası ile Gözlemlerin Standart Sapmasının Oranı

RMSE, yaygın olarak kullanılan hata indeksi istatistiklerinden biridir (Singh ve ark., 2005; Moriasi ve ark., 2007). RMSE ne kadar düşükse model performansının o kadar iyi olduğu genel olarak kabul edilmektedir. Ancak, bu değerin düşüklüğü veri setindeki değerlerin büyüklüğüne göre değişmektedir. Bu nedenle, bu değerleri daha kolay yorumlamamızı sağlayacak model değerlendirme istatistiği olan RSR geliştirilmiştir (Singh ve ark., 2005). RSR, RMSE değerlerini gözlemlerin standart sapma değerlerini kullanarak standart bir değere dönüştürmektedir. Denklem 3.54'te verildiği gibi RMSE

ve gözlem standart sapmalarının oranlanması ile hesaplanır. Çizelge 3.24 kullanılarak elde edilen değerler yorumlanmaktadır.

$$RSR = \frac{\sqrt{\sum_{i=1}^{n}|O_i - M_i|^2}}{\sqrt{\sum_{i=1}^{n}|O_i - \bar{O}|^2}} \tag{3.54}$$

3.2.7.8. Performans İndeksi

Performans indeksi (C'), modelin tahmine dayalı verilerle ilişkisinde doğruluk ve kesinlik kriterlerini birleştirmektedir. Kesinlik kriteri olarak değişkenler arasındaki dağılımın derecesini ve yönünü ölçen pearson lineer korelasyon katsayısı kullanılmaktadır. Willmott'un uyum indeksi, tahmin edilen ve gözlemlenen veriler arasındaki uyum derecesini ölçtüğü için doğruluk kriteri olarak seçilmektedir. Modelin performans indeksi Denklem 3.55 ile hesaplanmış ve Çizelge 3.24 kullanılarak değerlendirilmiştir (Santos ve ark., 2020).

$$C' = \frac{\sum_{i=1}^{n}(O_i - M_i)^2}{\sum_{i=1}^{n}\left((M_i - \bar{O}) + (O_i - \bar{O})\right)^2} * \frac{\sum_{i=1}^{n}(O_i - \bar{O}) \times (M_i - \bar{M})}{\sqrt{\sum_{i=1}^{n}(O_i - \bar{O})^2} \times \sqrt{\sum_{i=1}^{n}(M_i - \bar{M})^2}} \tag{3.55}$$

Denklemde, O_i; i.gözlem verisini, $\bar{O}$; gözlem verilerinin ortalamasını, M_i; modelin i.verisini ve $\bar{M}$; model tahminlerinin ortalamasını temsil etmektedir.

Çizelge 3.24. Model tahminlerinin performans değerlendirme tablosu

Derece	**R^2**	**PBIAS**	**NSE**	**RSR**	**C'**
Çok İyi	0.75-1.00	<±10	0.75-1.00	0.00-0.50	0.75-1.00
İyi	0.65-0.75	±10-±15	0.65-0.75	0.50-0.60	0.65-0.75
Yeterli	0.50-0.65	±15-±25	0.50-0.65	0.60-0.70	0.50-0.65
Yetersiz	≤0.50	>±25	<0.50	>0.70	<0.50

3.2.7.9. Taylor Yetenek Puanı

TSS; çalışmalarda genellikle iklim değişkenlerinin alansal dağılımını değerlendirmek için kullanılmaktadır ve Denklem 3.56 ile hesaplanmaktadır (Taylor, 2001).

$$TSS = 4\,x\,(1+r)^2\,/\,\left[\left(\frac{\sigma_O}{\sigma_M}+\frac{\sigma_M}{\sigma_O}\right)\,x\,4\right] \quad (3.56)$$

Denklemde, r; referans verileri ile modeli çıktı değerleri arasındaki korelasyon katsayısını, σ_O; gözlemlerin standart sapmasını ve σ_M; model tahminlerinin standart sapmasını temsil etmektedir. TSS~1 model ile gözlenen değerler arasındaki mükemmel ilişkiyi gösterirken, TSS=0 kötü model performansını ifade etmektedir (Xin ve ark., 2020; Zhu ve ark., 2020).

4. ARAŞTIRMA BULGULARI ve TARTIŞMA

4.1. Geçmiş Meteorolojik Verilerin Tahmin Sonuçları

4.1.1. Modelde Kullanılacak Tahmin Edici Değişkenlerin Seçimi

Çalışmada değişkenler arası elde edilen r değerleri Çizelge 4.1'de verilmiştir. Çizelgede vurgulanmış olan değişkenler modellerde bağımsız değişken olarak kullanılmıştır.

Çizelge 4.1. İklim parametreleri için değişken seçimi

	Bağımlı	Bağımsız Değişkenler			
	Değişkenler	İskenderun	Antakya	Dörtyol	Samandağ
Maksimum Sıcaklık	Altınözü	**0.9**	**0.9**	**0.9**	**0.9**
	Belen	**0.9**	**0.9**	**0.9**	**0.9**
	Erzin	**0.9**	**0.9**	**0.9**	**0.9**
	Hassa	**0.9**	**0.9**	**0.9**	**0.9**
	Kırıkhan	**0.9**	**0.9**	**0.9**	**0.9**
	Kumlu	**0.9**	**0.9**	**0.9**	**0.9**
	Reyhanlı	**0.9**	**0.9**	**0.9**	**0.9**
	Yayladağı	**0.9**	**0.9**	**0.9**	**0.9**
Minimum Sıcaklık	Altınözü	**0.9**	**0.9**	**0.9**	**0.9**
	Belen	**0.9**	**0.9**	**0.9**	**0.9**
	Erzin	**0.9**	**0.9**	**0.9**	**0.9**
	Hassa	**0.9**	**0.9**	**0.9**	**0.9**
	Kırıkhan	**0.9**	**0.9**	**0.9**	**0.9**
	Kumlu	**0.9**	**0.9**	**0.9**	**0.9**
	Reyhanlı	**0.9**	**0.9**	**0.9**	**0.9**
	Yayladağı	**0.9**	**0.9**	**0.9**	**0.9**
Yağış Miktarı	Altınözü	0.5	**0.7**	0.4	**0.6**
	Belen	**0.7**	**0.7**	0.5	**0.6**
	Erzin	**0.6**	**0.6**	**0.7**	0.5
	Hassa	**0.6**	**0.7**	0.5	**0.6**
	Kırıkhan	**0.6**	**0.7**	0.5	**0.6**
	Kumlu	**0.6**	**0.7**	0.5	**0.6**
	Reyhanlı	**0.6**	**0.8**	0.4	**0.6**
	Yayladağı	**0.6**	**0.7**	0.5	**0.7**

Analiz edilen değişkenlerin arasında hesaplanan korelasyonlar pozitif olarak hesaplanmıştır. İstasyonların sıcaklık verileri arasındaki ilişkinin oldukça yüksek olduğu belirlenmiştir. Gözlem istasyonlarından elde edilen yağış miktarı verileri arasındaki korelasyonun ise sıcaklık değerlerine göre şiddetinin daha düşük olduğu Çizelge 4.1'de

daha düşük olduğu görülmüştür. Bunun nedeni olarak yağışın konumsal değişkenliğinin sıcaklık parametrelerinden daha fazla olmasından kaynaklandığı düşünülmektedir.

4.1.2. Yapay Sinir Ağı Modellerinin Belirlenen Nöron Sayıları

YSA nöronların birbirleriyle olan ilişkilerini kullanarak öğrenme gerçekleştirmekte ve bu öğrenilen bilgileri kullanarak tahminler gerçekleştirebilmektedir. Bu nedenle YSA ile oluşturulacak modelde kullanılacak olan optimum nöron sayısının belirlenmesi ağın tahmin başarısını önemli derecede etkilemektedir. Ancak, nöron sayısının gereğinden fazla olması ağın bilgileri öğrenmek yerine ezberlemesine ve dolayısıyla tahminlerin başarısız olmasına neden olabilecektir (Kadu ve ark., 2012).

Çalışmamızda bu durumla karşılaşmamak için model oluşturulmadan önce optimum nöron sayısı belirlenmiştir. Değerlendirilecek nöron sayılarının modelde girdi değişkeni olarak kullanılan eleman sayısının iki katını geçmeyecek miktarda olması gerektiği literatürde verilmiştir (Heaton, 2008). Bu kural dikkate alınarak yapılan deneme yanılma yöntemi ile elde edilen nöron sayıları Çizelge 4.2'de verilmiştir. Son olarak, veri setleri R Studio programında rastgele olacak şekilde eğitim (2/3) ve test (1/3) veri setleri olarak iki gruba ayrılmıştır. Oluşturulan eğitim veri setleri ile YSA modelleri eğitilmiştir ve oluşturulan modellerin tahmin doğrulukları da test veri seti ile kontrol edilmiştir.

Çizelge 4.2. Oluşturulan YSA modellerin gizli katmanlarında belirlenen nöron sayıları

	Maksimum Sıcaklık	Minimum Sıcaklık	Yağış Miktarı
Altınözü	8	8	3
Belen	8	4	3
Erzin	7	8	5
Hassa	8	8	6
Kırıkhan	8	5	2
Kumlu	8	3	5
Reyhanlı	5	7	3
Yayladağı	7	8	5

4.1.3. Maksimum ve Minimum Sıcaklıkların Tahmin Sonuçları

Maksimum sıcaklık değerlerinin tahmini için oluşturulan modellerin eğitim ve test performansları Çizelge 4.3'de verilmiştir. Eğitim tahminleri için hesaplanan R^2 değerleri

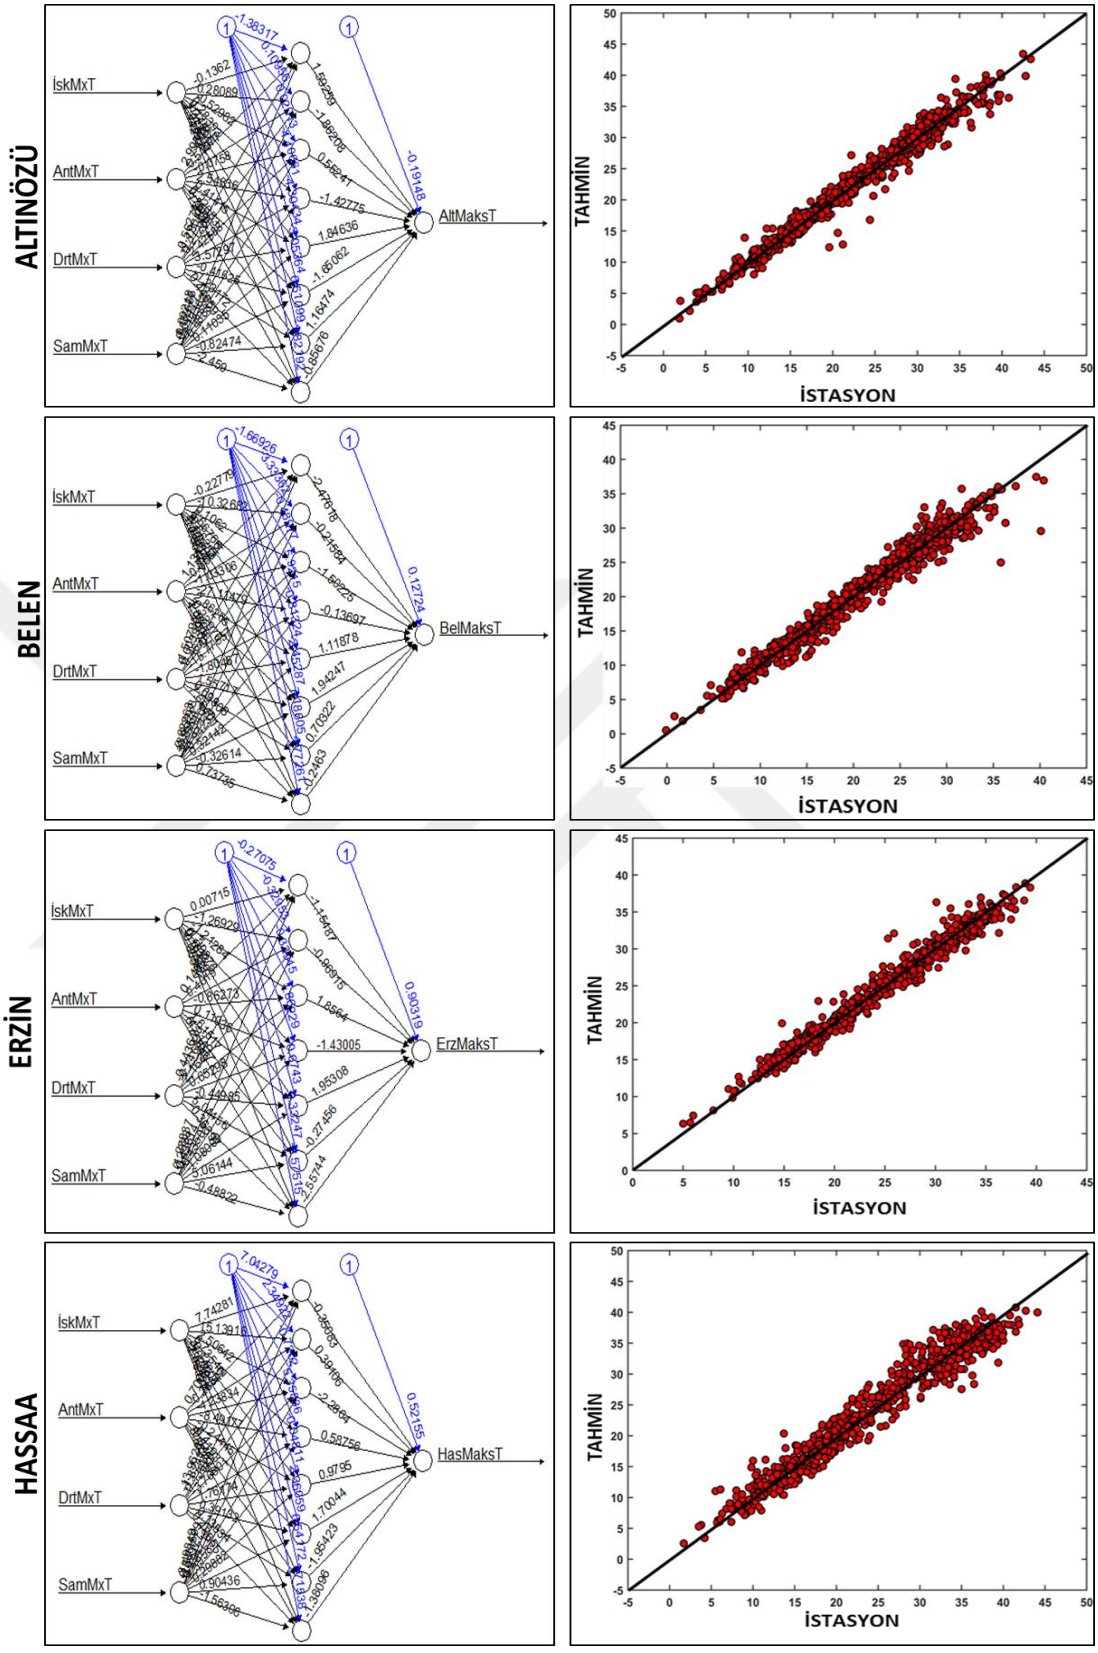
0.95-0.98 ve RMSE değerleri 1.03-2.14 arasında ve test tahminleri için R^2 değerleri 0.94-0.98 ve RMSE değerleri ise 1.12-2.34 arasında hesaplanmıştır.

Çizelge 4.3. YSA modellerinin günlük maksimum sıcaklık değerleri için eğitim ve test performansları

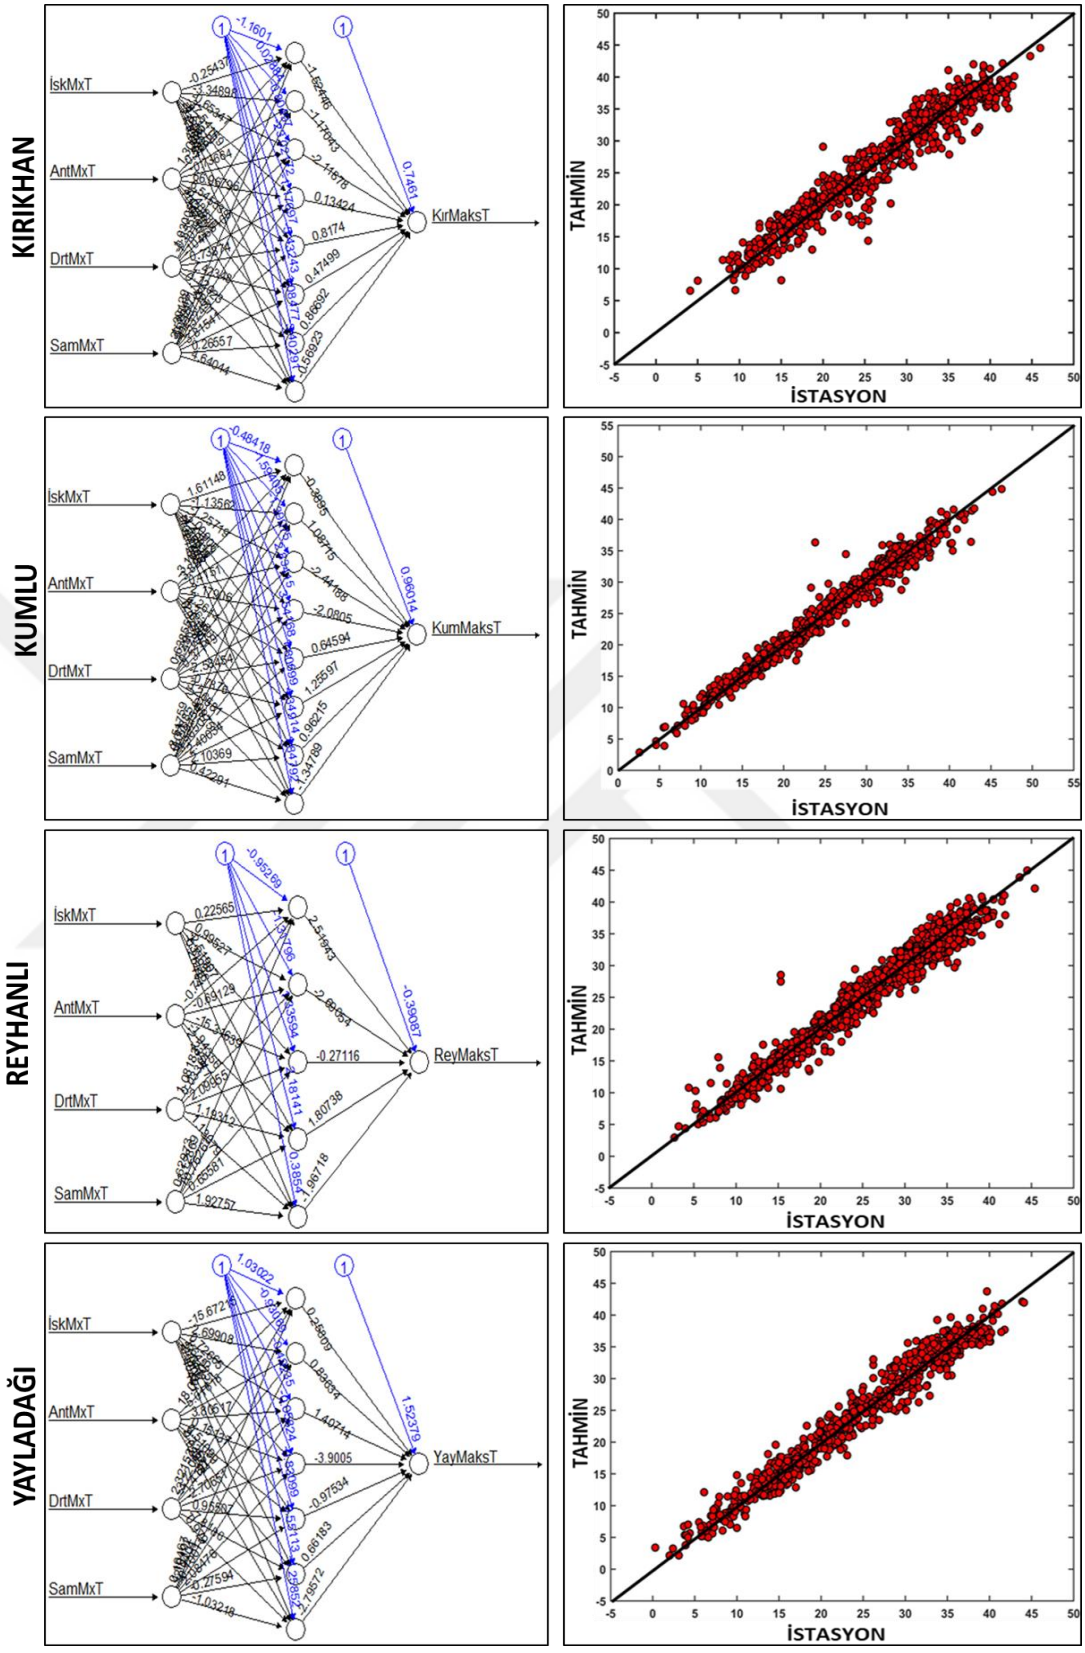
İstasyon	Eğitim		Test	
	R^2	RMSE	R^2	RMSE
Altınözü	0.98	1.23	0.97	1.31
Belen	0.97	1.28	0.97	1.40
Erzin	0.98	1.03	0.98	1.12
Hassa	0.96	1.95	0.96	2.07
Kırıkhan	0.95	2.14	0.94	2.34
Kumlu	0.98	1.27	0.96	1.65
Reyhanlı	0.97	1.52	0.97	1.66
Yayladağı	0.97	1.51	0.97	1.53

Ustaoğlu ve ark. (2008), Sakarya ve Geyve istasyonları için yaptığı çalışmada maksimum sıcaklığı ileri beslemeli ve geri yayılımlı YSA yöntemi kullanarak başarılı bir şekilde tahmin etmişlerdir (r=0.91-0.93 ve RMSE=3.49-3.75). Dombaycı ve Gölcü (2009), YSA ile günlük ortalama sıcaklıkları R^2=0.98-0.99 ile yüksek doğrulukta tahmin etmişlerdir. Mehdizadeh (2018), İran'da farklı istasyonlar için yaptıkları çalışmada aylık maksimum sıcaklık tahminlerinin RMSE değerini 0.19-6.72 hesaplamışlardır. Perera ve ark. (2020), Suudi Arabistan'ın Tabuk şehrinde aylık maksimum sıcaklığı tahmin etmek için yaptıkları çalışmada, r değerini 0.94 olarak hesaplamışlardır. Baczkiewicz ve ark. (2021), Polonya'daki Szczecin şehri için maksimum sıcaklık tahminlerinin RMSE değerini 2.55 ve R^2 değerini ise 0.96 olarak hesaplamışlardır. Katipoğlu ve Acar (2021) YSA kullanarak aylık sıcaklık tahminleri yaptıkları çalışmada, R^2 değerini 0.99 olarak hesaplamışlardır. Diez ve ark. (2022), günlük maksimum sıcaklık tahmini için YSA kullandıkları çalışmada, R^2 değerini 0.92-0.97 ve RMSE değerini 0.68-1.04 arasında hesaplamışlardır. Çalışmamızın sonucunda belirlenen R^2 ve RMSE değerleri literatür ile uyumlu bulunmuştur.

Farklı istasyonlardan elde edilen maksimum sıcaklık değerleri ve YSA tarafından yapılan tahminlerin dağılım grafikleri Şekil 4.1 ve Şekil 4.2'de gösterilmektedir. Bu şekiller incelendiğinde noktaların 1:1 çizgisine olan yüksek uyumu net bir şekilde görülmektedir. Elde edilen sonuçlara göre, çok katmanlı YSA'nın maksimum sıcaklık için tahmin performansının başarılı olduğu görülmüştür.



Şekil 4.1. Maksimum sıcaklık parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları



Şekil 4.2. Maksimum sıcaklık parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları

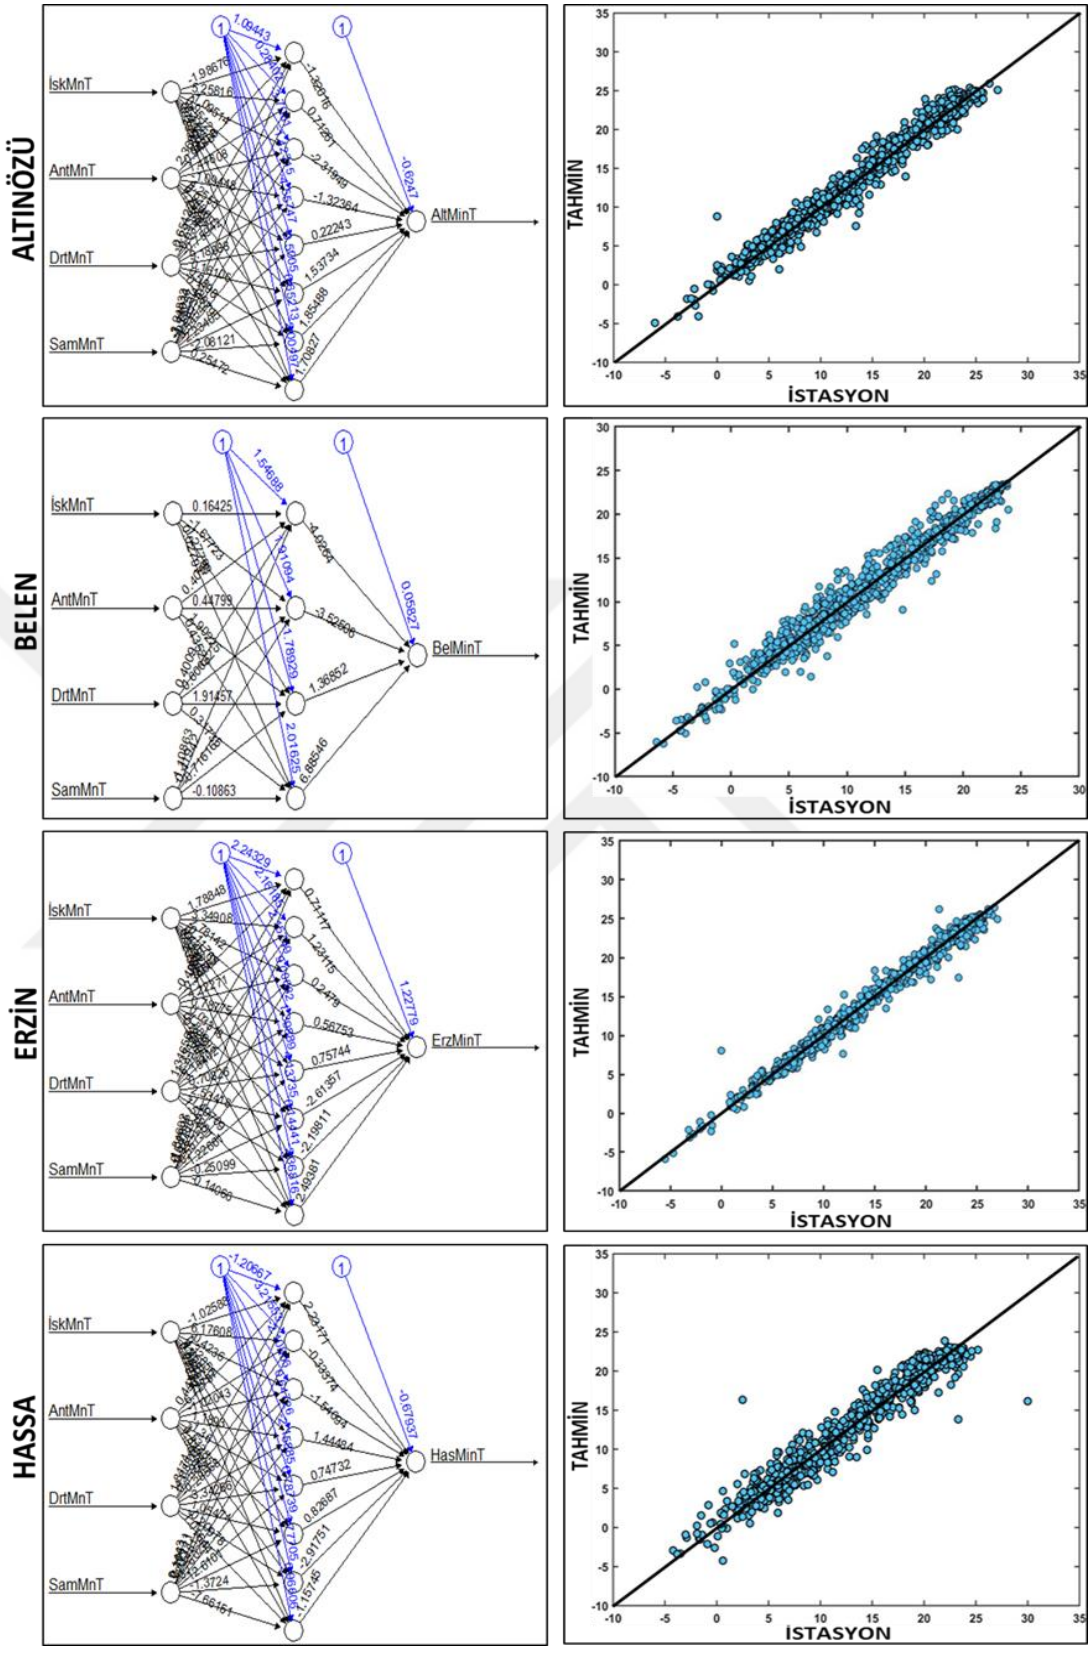
Minimum sıcaklık değerlerinin tahmini için oluşturulan modellerin eğitim ve test performansları Çizelge 4.4'te verilmiştir. Eğitim tahminleri için hesaplanan R^2 değerleri 0.88-0.99 ve RMSE değerleri 0.75-2.23 arasında ve test tahminleri için R^2 değerleri 0.86-0.98 ve RMSE değerleri ise 0.88-2.56 arasında hesaplanmıştır.

Çizelge 4.4. YSA modellerinin günlük minimum sıcaklık değerleri için eğitim ve test performansları

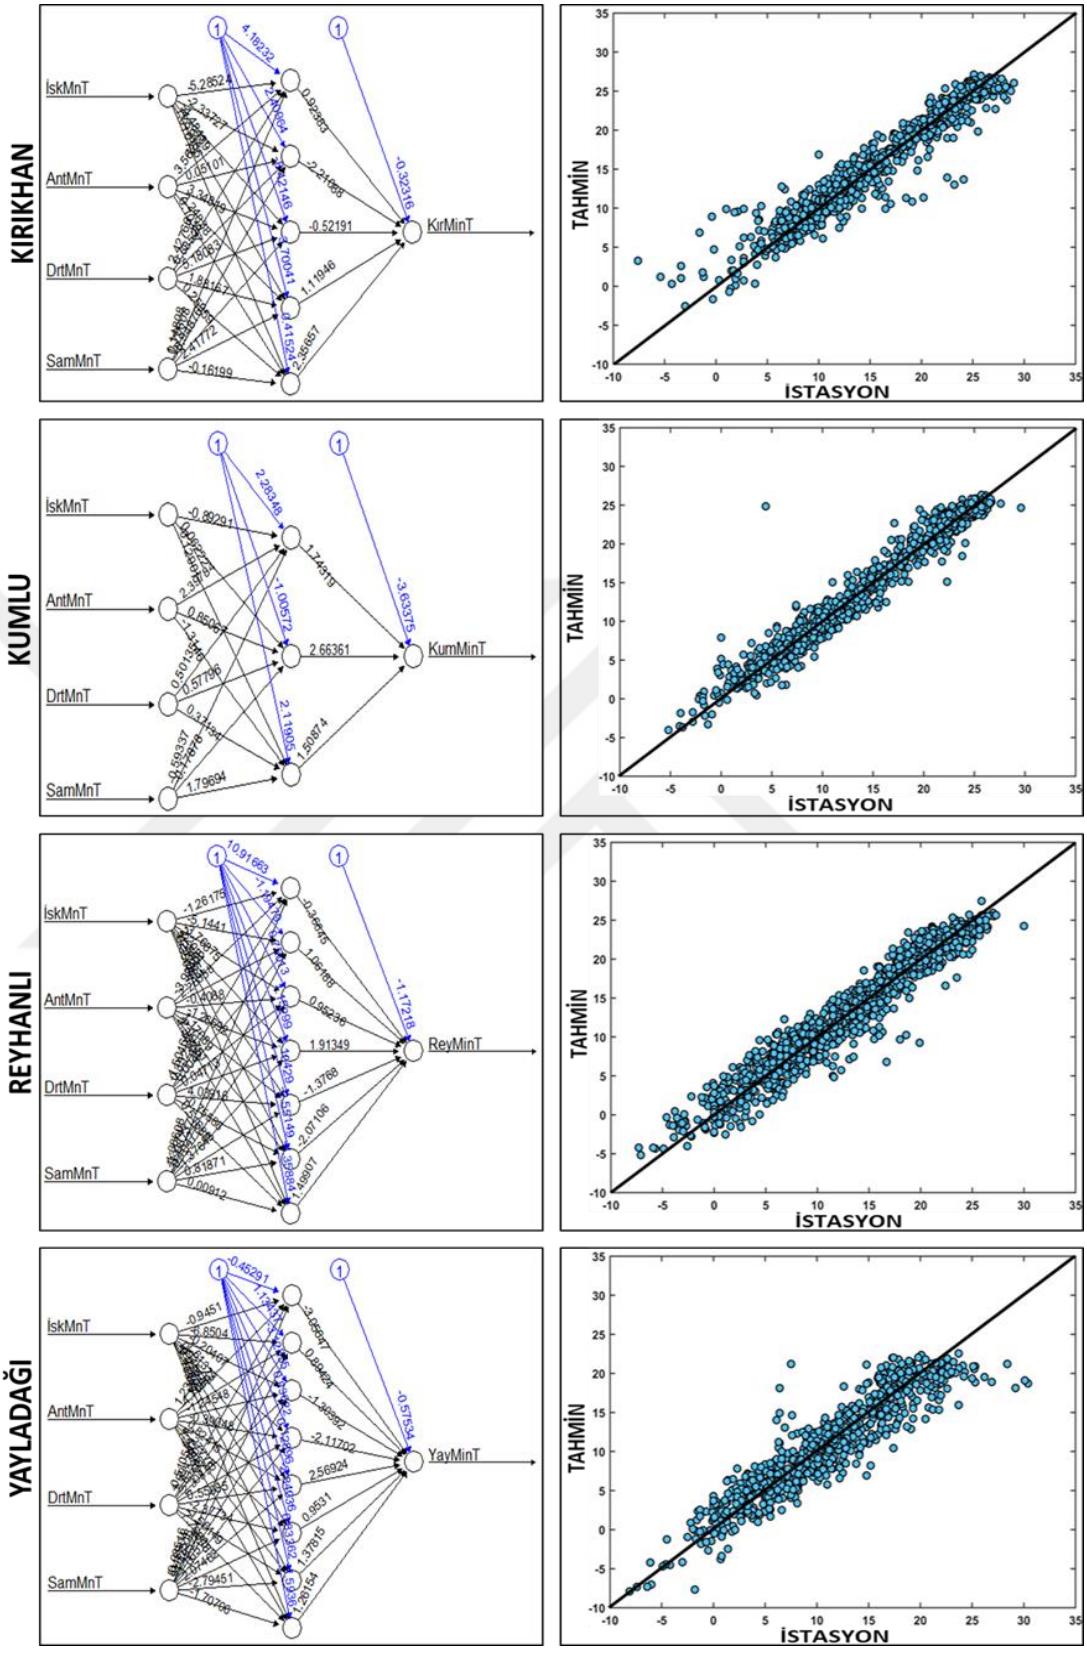
İstasyon	Eğitim		Test	
	R^2	RMSE	R^2	RMSE
Altınözü	0.98	1.12	0.97	1.19
Belen	0.97	1.27	0.95	1.64
Erzin	0.99	0.75	0.98	0.88
Hassa	0.95	1.50	0.94	1.68
Kırıkhan	0.93	1.89	0.92	2.07
Kumlu	0.96	1.45	0.97	1.40
Reyhanlı	0.95	1.79	0.94	1.87
Yayladağı	0.88	2.23	0.86	2.56

Sakarya ve Geyve istasyonlarında yapılan bir çalışmada, minimum sıcaklık, ileri beslemeli ve geri yayılımlı YSA yöntemi kullanılarak r değeri 0.94-0.95 ve RMSE değeri 2.48-2.51 olarak başarılı bir şekilde tahmin edilmiştir (Ustaoğlu ve ark., 2008). Mehdizadeh (2018) İran'da farklı istasyonlar için yaptığı çalışmada, aylık minimum sıcaklık tahminlerinin RMSE değerini 0.60-5.00 hesaplamıştır. Perera ve ark. (2020), Suudi Arabistan'ın Tabuk şehrinde aylık minimum sıcaklığı tahmin etmek için yaptıkları çalışmada, r değerini 0.97 olarak hesaplamışlardır. Baczkiewicz ve ark. (2021), Polonya'daki Szczecin şehri için minimum sıcaklık tahminlerinin RMSE değerini 2.18 ve R^2 değerini ise 0.94 olarak hesaplamışlardır. Diez ve ark. (2022), günlük minimum sıcaklık tahmini için YSA kullandıkları çalışmada, R^2 değerini 0.80-0.89 ve RMSE değerini ise 0.83-1.12 arasında hesaplamışlardır. YSA modellerinden minimum sıcaklık tahmini için elde edilen R^2 ve RMSE değerlerinin literatür ile uyumlu olduğu belirlenmiştir.

Farklı istasyonlardan elde edilen minimum sıcaklık değerleri ve YSA tarafından yapılan tahminlerin dağılım grafikleri Şekil 4.3 ve Şekil 4.4'te gösterilmektedir. Bu şekiller incelendiğinde noktaların 1:1 çizgisine olan yüksek uyumu net bir şekilde görülmektedir. Elde edilen sonuçlara göre, çok katmanlı YSA'nın tahmin performansının başarılı olduğu görülmüştür.



Şekil 4.3. Minimum sıcaklık parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları



Şekil 4.4. Minimum sıcaklık parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları

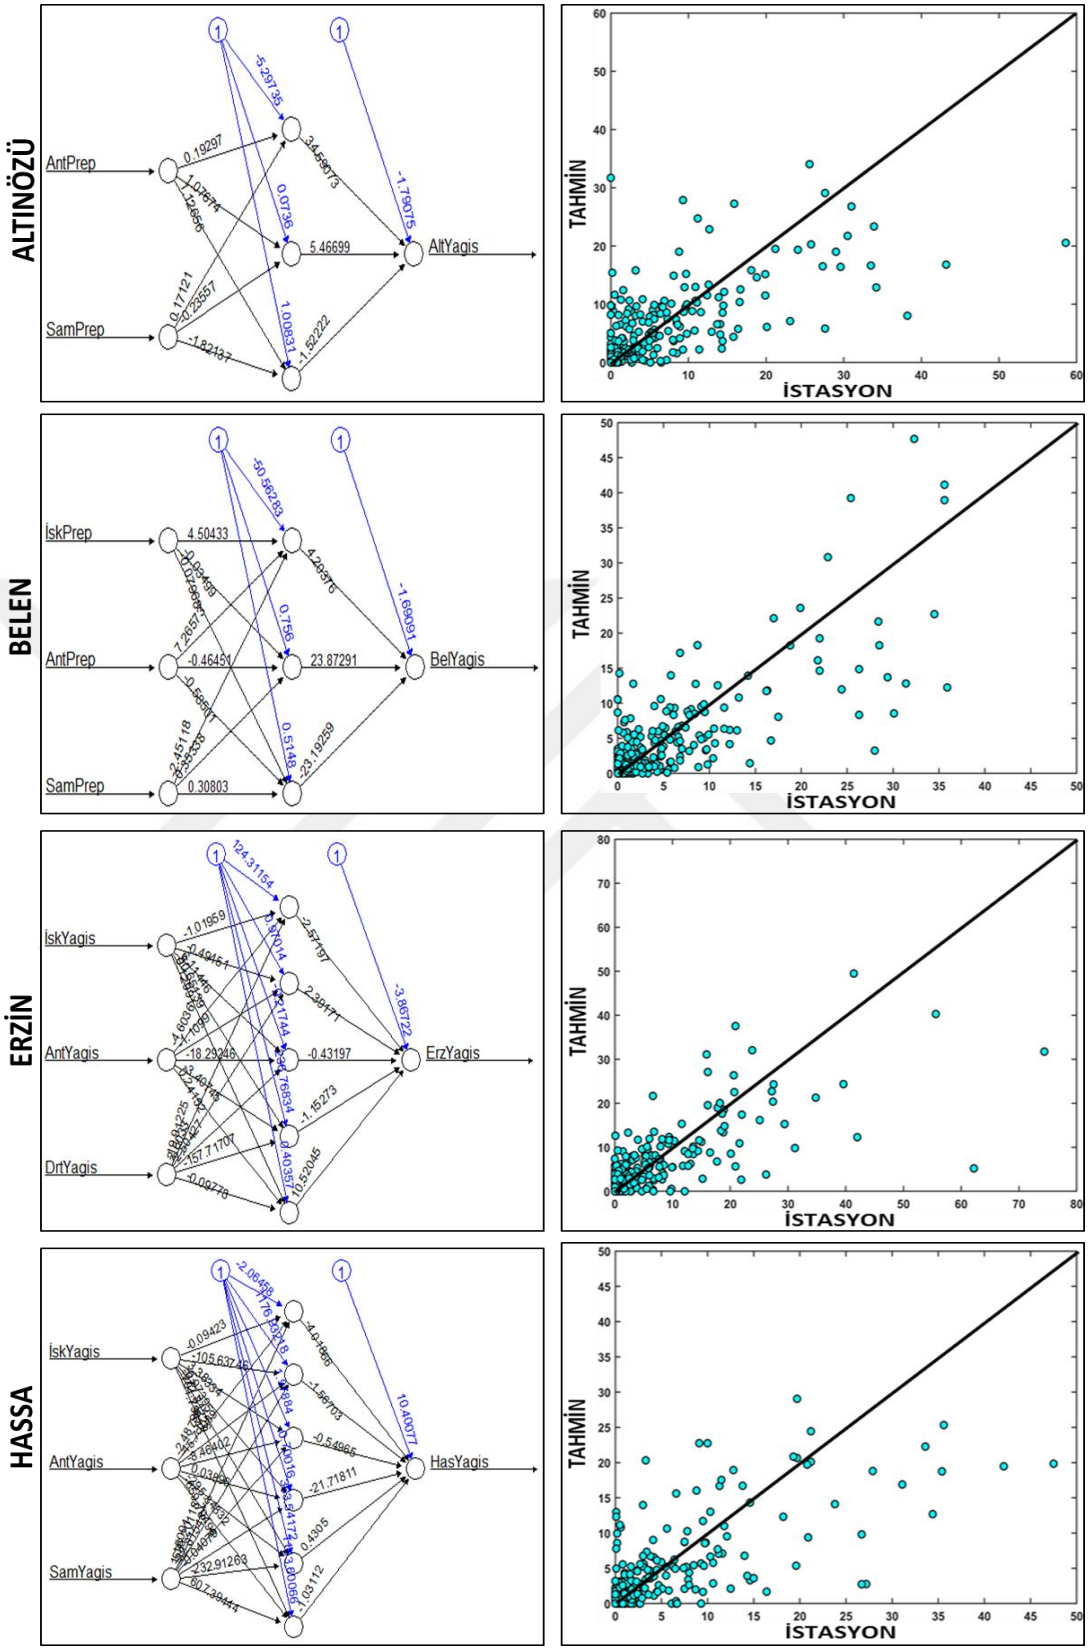
Maksimum ve minimum sıcaklık tahminlerinin çok iyi performans göstermesinin en önemli nedeni sıcaklık zaman serilerinin diğer iklim parametrelerine göre daha düşük değişkenlik göstermesidir. Genellikle istasyonlar arası günlük sıcaklık farkları kış ayları dışında oldukça düşüktür. Bu durumun nedeni ise kış aylarında çeşitli hava kütlelerinin konumsal olarak farklılık gösterebilmesidir (Ustaoğlu ve ark., 2008). Sıcaklık verilerinin bu düşük değişkenliği istasyonlar arası korelasyonun güçlü olmasına ve dolayısıyla oluşturulan modellerin gözlem verilerine daha iyi uyum sağlamasına neden olmaktadır.

4.1.4. Yağış Miktarının Tahmin Sonuçları

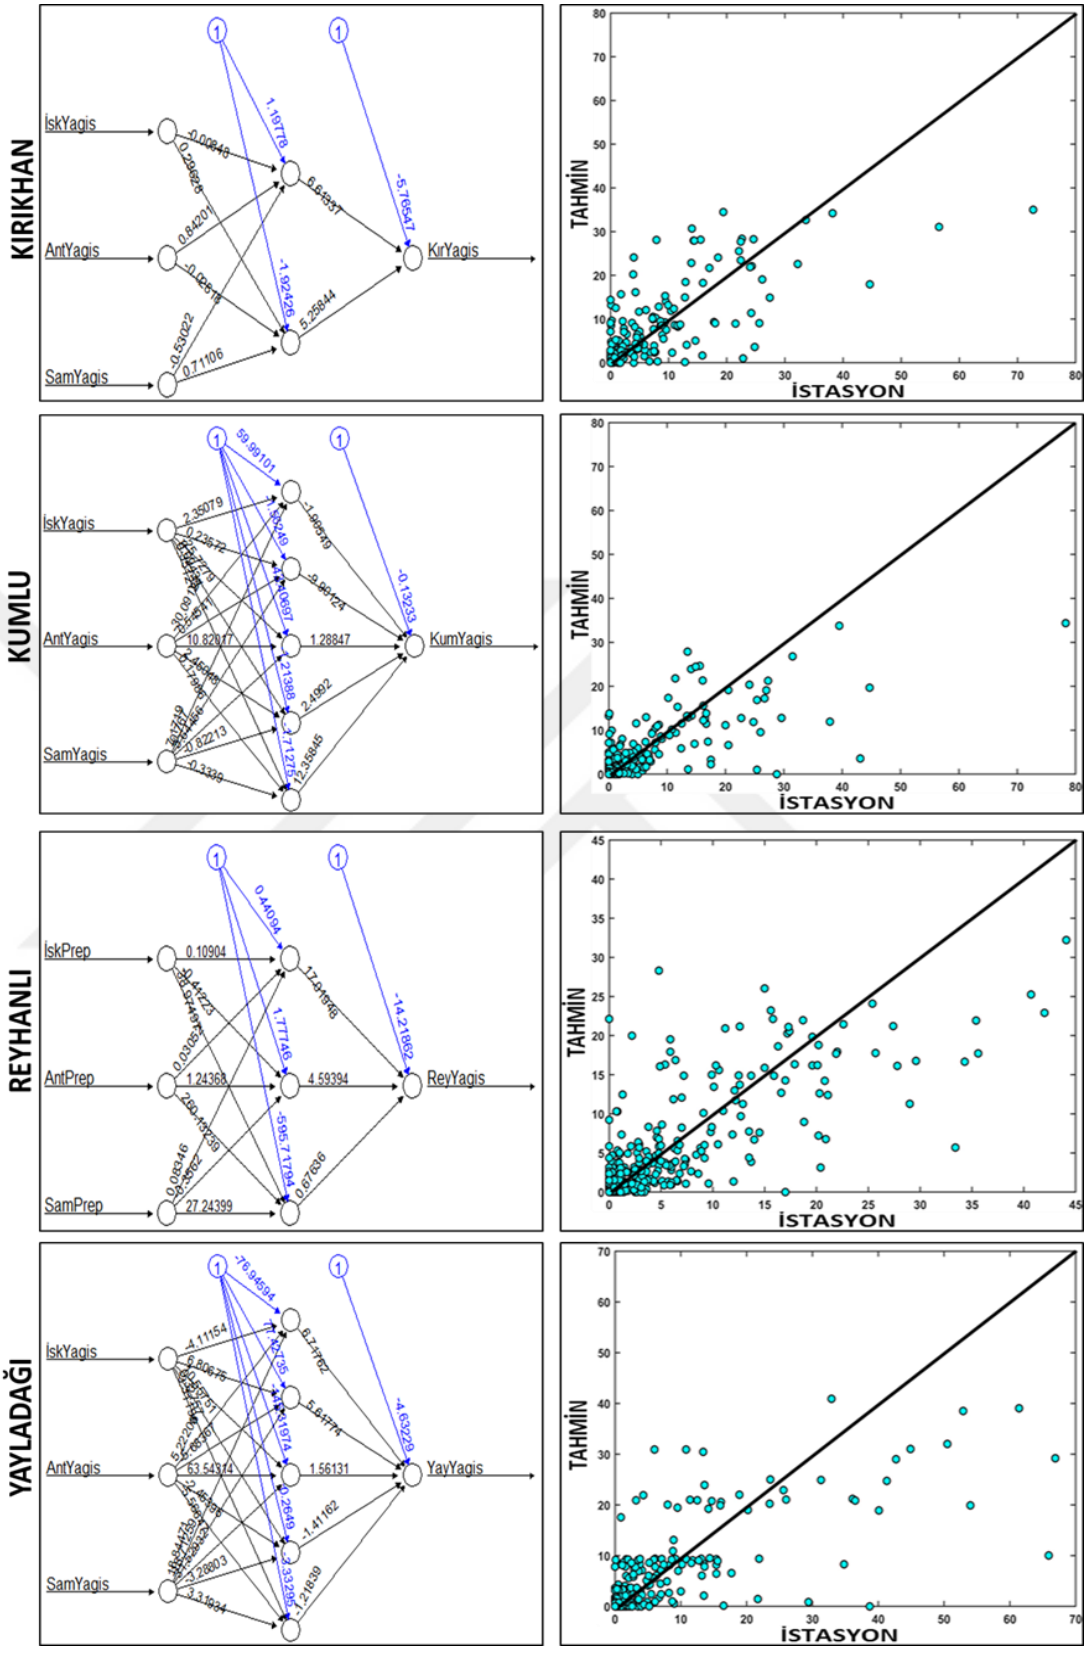
Bir bölgenin su kaynaklarının planlanması, taşkın ve kuraklık analizi için güvenilir modellerin geliştirilebilmesi girdi olarak kullanılan meteorolojik verilerin kalitesine bağlıdır (Canchala-Nastar ve ark., 2019). Ancak, özellikle gelişmekte olan ülkelerde uzun yıllık ve eksiksiz gözlem veri setleri bulmak oldukça zordur. Bu nedenle, yağış verilerini doğru bir şekilde tahmin edebilen modellerin geliştirilmesi çok önemlidir (Papailiou ve ark., 2022). Günümüzde YSA, sadece eğitim veri setinde bulunan bilgileri kullanarak doğrusal olmayan değişkenleri modelleyebilmesi nedeniyle bu soruna alternatif bir çözüm olarak kullanılmaktadır. Modellerin günlük yağış miktarı tahminlerinin eğitim ve test performansları Çizelge 4.5'te verilmiştir. Çalışmada, korelasyon analizi ile belirlenen girdi değişkenleri ve optimum nöron sayısı kullanılarak oluşturulan modeller ve dağılım grafikleri ise Şekil 4.5 ve Şekil 4.6'da verilmiştir.

Çizelge 4.5. YSA modellerinin yağış miktarı için eğitim ve test performansları

İstasyon	Eğitim		Test	
	R^2	RMSE	R^2	RMSE
Altınözü	0.68	3.69	0.58	3.46
Belen	0.77	2.48	0.68	2.69
Erzin	0.70	3.48	0.63	3.95
Hassa	0.65	2.95	0.60	3.21
Kırıkhan	0.67	3.12	0.64	3.55
Kumlu	0.80	2.17	0.62	3.66
Reyhanlı	0.69	2.63	0.68	2.65
Yayladağı	0.76	3.39	0.61	4.62



Şekil 4.5. Yağış miktarı parametresi için oluşturulan Altınözü, Belen, Erzin ve Hassa YSA modelleri ve test tahmin performansları



Şekil 4.6. Yağış miktarı parametresi için oluşturulan Kırıkhan, Kumlu, Reyhanlı ve Yayladağı YSA modelleri ve test tahmin performansları

Eğitim tahminleri için hesaplanan R^2 değerleri 0.65-0.80 ve RMSE değerleri 2.17-3.69 arasında ve test tahminleri için R^2 değerleri 0.58-0.68 ve RMSE değerleri ise 2.65-4.62 arasında hesaplanmıştır. Eğitim ve test sonuçlarının maksimum ve minimum sıcaklık tahminlerinde olduğu kadar başarılı olmadığı Çizelge 4.5'te görülmektedir. Ancak, R^2 değerinin 0.50'den yüksek olması modelden elde edilen tahminlerin kabul edilebilir doğrulukta ve uyumda olduğunu göstermektedir (Moriasi ve ark., 2007).

YSA modelleri girdi ve çıktı değişkenleri arasındaki doğrusal olmayan ilişkiye bağlıdır. Her girdi değişkeni, verilerden belirlenen kendi ağırlık faktörüne sahiptir. Ancak, yağışsız dönemin fazla olması bir dizi sıfır değerinin üzerinden ağırlıkların belirlenmesine ve bu durumda model tarafından daha düşük yağış tahminlerinin yapılmasına neden olmaktadır. Freiwan ve Cigizoğlu (2005) ve Dahamsheh ve Aksoy (2009)'un çalışmalarında belirttikleri gibi, modellerin maksimum yağışların tahmininde başarısız olduğu ve yağışsız gün sayısı arttıkça tahmin performansının düştüğü belirlenmiştir.

YSA kullanarak tahmin edilen günlük yağış miktarları için Kim ve Pachepsky (2010), Saplıoğlu ve Çimen (2010), Roman ve ark. (2012) ve Baczkiewicz ve ark. (2021) çalışmalarında, RMSE değerini sırasıyla 1.84-5.60, 4.67-6.33, 4.64-6.68 ve 3.25 olarak hesaplamışlardır. Çalışmamızda test veri setleri için hesaplanan RMSE sonuçları (2.65-4.62), literatür sonuçlarına benzer olarak hesaplanmış ve tahmin edilen değerler arasındaki sapmanın kabul edilebilir aralıkta olduğu belirlenmiştir. Modellerin test veri seti için R^2 sonuçları da 0.58-0.68 olarak hesaplanmıştır. Daha önce benzer olarak yapılan çalışmalarda R^2 değerlerinin 0.45-0.71 (Coulibaly ve Evora, 2007), 0.60 (Moustris ve ark., 2011), 0.73-0.83 (Terzi ve Çevik, 2012), 0.65 (Nguyen ve ark., 2021) ve 0.52 (Baczkiewicz ve ark., 2021) olarak hesaplandığı bildirilmiştir. Elde ettiğimiz sonuçların yağış tahmini için literatürde bildirilen sonuçlarla benzer ve kabul edilebilir doğrulukta olduğu belirlenmiştir.

4.1.5. YSA Model Kullanılabilirliğini Değerlendirme Sonuçları

Çok katmanlı YSA modelinin kullanılabilirliği NSE, RSR ve C' performans değerlendirme kriterleri kullanılarak incelenmiştir. Elde edilen sonuçlar ve modellerin kullanılabilirlik dereceleri Çizelge 4.6'da verilmiştir. Yapılan analizler sonucunda tüm

istasyonlarda çok katmanlı YSA'nın başarılı sonuçlar verdiği belirlenmiştir. Bu nedenle, geçmiş yıllara ait ölçümleri bulunmayan istasyonların eksik yıllarının tahmin edilmesi için bu modellerin kullanılmasına karar verilmiştir.

Çizelge 4.6. Çok katmanlı YSA'nın kullanılabilirliğinin değerlendirme sonuçları

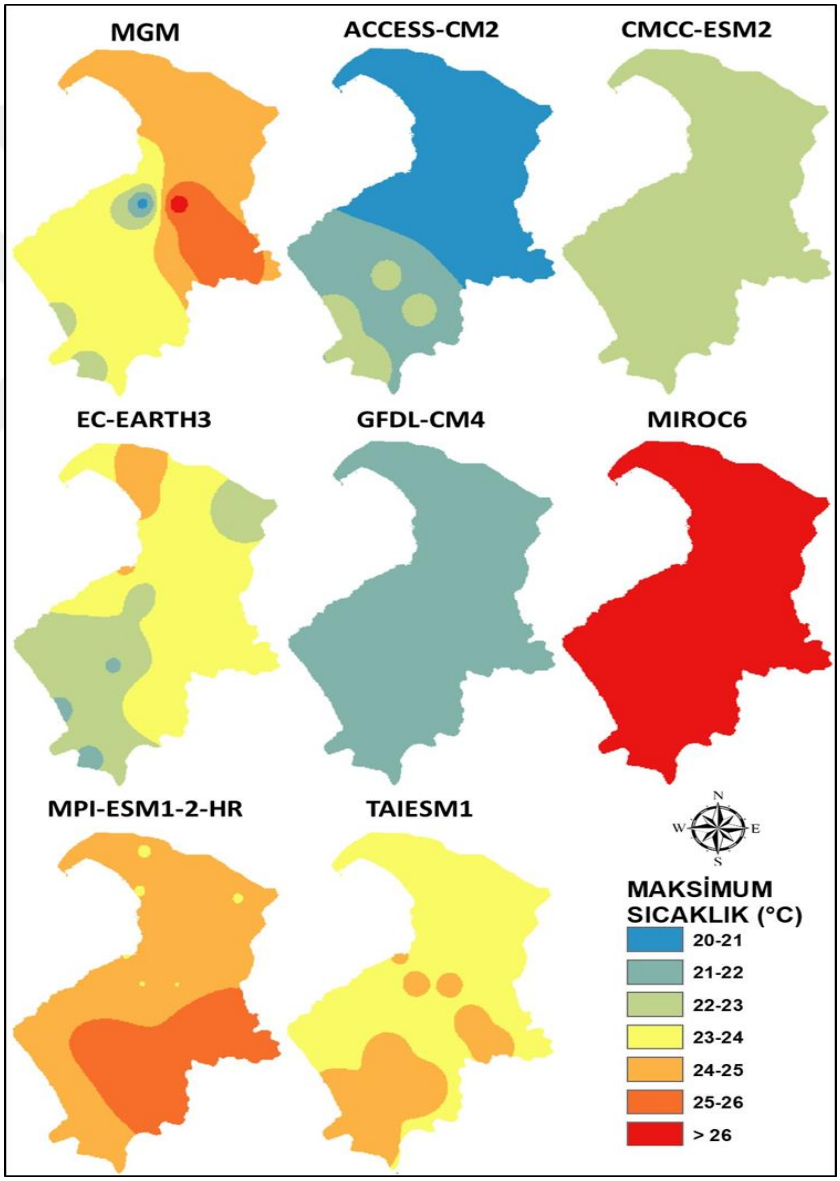
Parametreler	İstasyonlar	NSE		RSR		C'	
		Değer	Derece	Değer	Derece	Değer	Derece
Yağış Miktarı	Altınözü	0.58	Yeterli	0.65	Yeterli	0.65	İyi
	Belen	0.68	İyi	0.57	İyi	0.74	İyi
	Erzin	0.62	Yeterli	0.61	Yeterli	0.69	İyi
	Hassa	0.60	Yeterli	0.63	Yeterli	0.66	İyi
	Kırıkhan	0.63	Yeterli	0.60	İyi	0.71	İyi
	Kumlu	0.61	Yeterli	0.62	Yeterli	0.67	İyi
	Reyhanlı	0.68	İyi	0.57	İyi	0.64	Yeterli
	Yayladağı	0.61	Yeterli	0.63	Yeterli	0.67	İyi
Maksimum Sıcaklık	Altınözü	0.97	Çok İyi	0.16	Çok İyi	0.98	Çok İyi
	Belen	0.97	Çok İyi	0.18	Çok İyi	0.98	Çok İyi
	Erzin	0.98	Çok İyi	0.16	Çok İyi	0.98	Çok İyi
	Hassa	0.96	Çok İyi	0.21	Çok İyi	0.97	Çok İyi
	Kırıkhan	0.94	Çok İyi	0.25	Çok İyi	0.95	Çok İyi
	Kumlu	0.97	Çok İyi	0.16	Çok İyi	0.98	Çok İyi
	Reyhanlı	0.97	Çok İyi	0.19	Çok İyi	0.97	Çok İyi
	Yayladağı	0.97	Çok İyi	0.19	Çok İyi	0.97	Çok İyi
Minimum Sıcaklık	Altınözü	0.97	Çok İyi	0.17	Çok İyi	0.98	Çok İyi
	Belen	0.95	Çok İyi	0.22	Çok İyi	0.96	Çok İyi
	Erzin	0.98	Çok İyi	0.13	Çok İyi	0.99	Çok İyi
	Hassa	0.94	Çok İyi	0.24	Çok İyi	0.96	Çok İyi
	Kırıkhan	0.92	Çok İyi	0.28	Çok İyi	0.98	Çok İyi
	Kumlu	0.96	Çok İyi	0.21	Çok İyi	0.97	Çok İyi
	Reyhanlı	0.94	Çok İyi	0.24	Çok İyi	0.96	Çok İyi
	Yayladağı	0.86	Çok İyi	0.38	Çok İyi	0.89	Çok İyi

Çizelge 4.6'da verilen sonuçlara göre, oluşturulan modellerin maksimum ve minimum sıcaklık değerlerini, yağış tahminlerine göre yüksek doğrulukta tahmin ettiği belirlenmiştir. Yağış tahminlerinin sıcaklık tahminleri kadar başarılı olamamasının en önemli nedenleri modelin girdi değişkenlerinin korelasyonlarının düşük olması ve yağıştaki günlük değişikliğin sıcaklık değerlerine göre daha büyük olmasıdır. Ayrıca, bu çalışmaya özgü olarak Hatay ilinde yağış olmayan günlerin sayısının fazla olması da model performansının düşük olmasında etkili olduğu tahmin edilmektedir. Zaman serilerinde sıfır serilerinin fazla olması modellerin maksimum yağışları tahmin edememesine neden olmaktadır (Dahamsheh ve Aksoy 2009). Ancak, yağış miktarı için model tarafından elde edilen tahminlerin eksik ölçüm yıllarına ait olan kayıtlar için kullanılmasında yeterli doğrulukta performans gösterdiği belirlenmiştir.

4.2. Küresel İklim Modelini Belirleme Sonuçları

4.2.1. Maksimum ve Minimum Sıcaklık İçin Değerlendirme Sonuçları

Gözlemlerden ve CMIP6 KİM'leri tarafından tahmin edilen maksimum sıcaklık verileri kullanılarak çalışma alanındaki yıllık ortalama maksimum sıcaklık değerleri hesaplanmış ve 1980–2014 dönemi için ters ağırlıklı mesafe enterpolasyon yöntemi kullanılarak oluşturulan alansal dağılım haritaları Şekil 4.7'de gösterilmiştir.

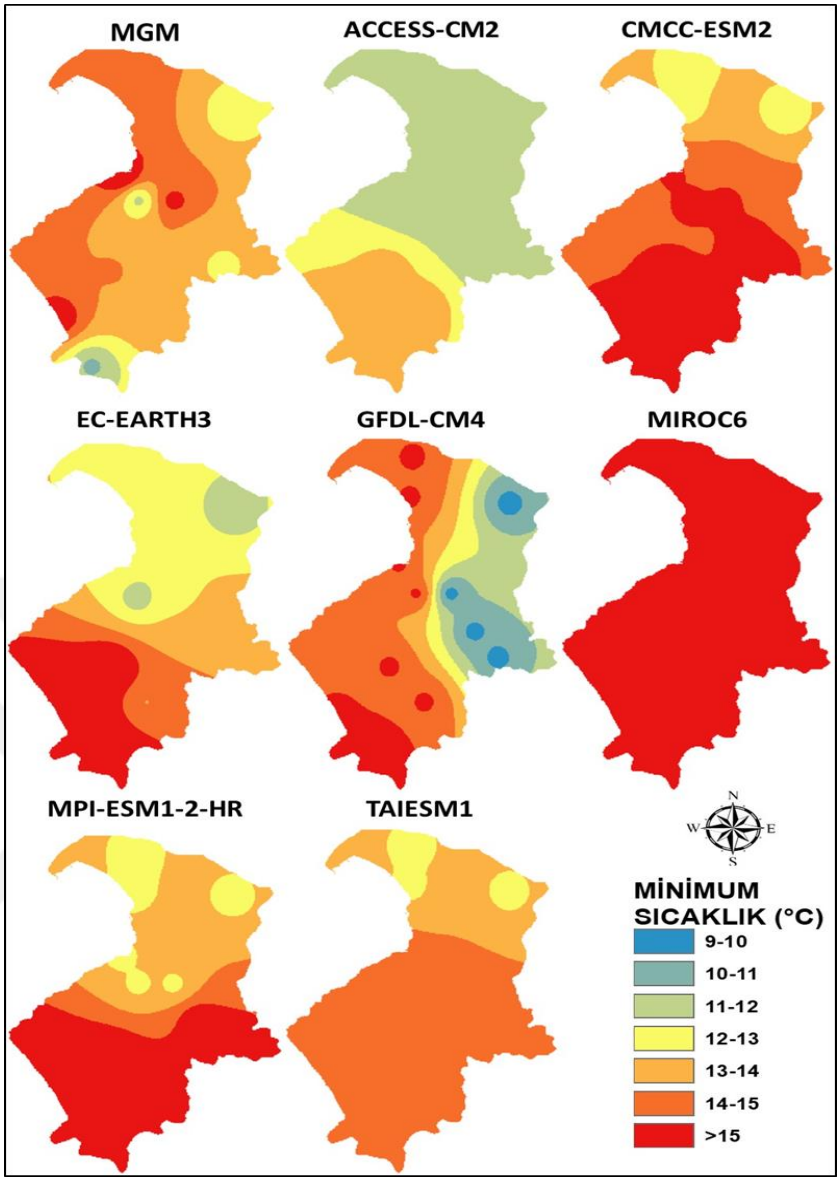


Şekil 4.7. Gözlem verileri ve KİM'lerin yıllık ortalama maksimum sıcaklık alansal dağılım haritaları (1980-2014)

Yıllık ortalama maksimum sıcaklık, gözlem verilerine göre Hatay ili için 21-26°C olarak belirlenmiştir. Maksimum sıcaklık değerlerinin Hatay'ın batı bölgelerinden iç kesimlere doğru alansal artış gösterdiği görülmüştür. Ancak, bu alansal dağılımı KİM'lerin, gözlemlenen dağılıma göre daha düşük tahmin etme eğiliminde olduğu literatür ile benzer şekilde bulunmuştur (Cui ve ark., 2021; Kamruzzaman ve ark., 2021). Çalışma alanının gözlem verileri ile oluşturulan alansal dağılım haritası incelendiğinde (Şekil 4.7), maksimum sıcaklık dağılımının gözlem verilerine benzetimini daha başarılı yapan modellerin EC-EARTH3, CMCC-ESM2 ve MPI-ESM1-2-HR modelleri olduğu görülmüştür.

Gözlemlerden ve CMIP6 KİM'leri tarafından tahmin edilen minimum sıcaklık verileri kullanılarak çalışma alanındaki yıllık ortalama minimum sıcaklık değerleri hesaplanmış ve 1980–2014 dönemi için ters ağırlıklı mesafe enterpolasyon yöntemi kullanılarak oluşturulan alansal dağılım haritaları Şekil 4.8'de gösterilmiştir. Yıllık ortalama minimum sıcaklık, gözlem verilerine göre Hatay ili için 9-15°C olarak belirlenmiştir. En düşük minimum sıcaklık değerlerinin yüksekliğin fazla olduğu bölgelerde görüldüğü Şekil 4.8'de tespit edilmiştir. Minimum sıcaklık dağılımının maksimum sıcaklıkla ters korelasyon gösterdiği ve Hatay'ın batı bölgelerinde en yüksek olduğu, doğu bölgelerine doğru ise azalış gösterdiği alansal dağılım haritalarından belirlenmiştir. Bu alansal dağılımı KİM'lerin maksimum sıcaklıkta olduğu gibi minimum sıcaklık içinde tahmin etmede yeterince başarılı olmadığı görülmüştür. Ayrıca, KİM'lerin minimum sıcaklığı olması gereken değerlerden yüksek olarak tahmin ettiği anlaşılmıştır. Bu sonuca benzer olarak, Nishant ve ark. (2022), CMIP6 KİM'lerden elde edilen minimum sıcaklık tahminlerinin gözlem değerlerine göre olduğundan daha fazla tahmin etme eğiliminde olduğunu açıklamışlardır. Çalışma alanının gözlem verileri ile oluşturulan alansal dağılım haritası incelendiğinde (Şekil 4.8), minimum sıcaklık dağılımının gözlem verilerine benzetimini daha başarılı yapan modellerin CMCC-ESM2, GFDL-CM4 ve TAIESM1 modelleri olduğu görülmüştür.

Genel olarak, KİM'lerin sıcaklık çıktılarının yerel ölçekte karar verme ve politika oluşturma çalışmaları için doğrudan kullanımının riskli olduğu belirlenmiştir. Bu nedenle, önceki çalışmalarda bildirildiği bu modellerin çıktılarının ölçek küçültme yöntemleri uygulandıktan sonra tekrar değerlendirilip ilgili çalışmalarda kullanılması gerekmektedir (Gusain ve ark., 2020).

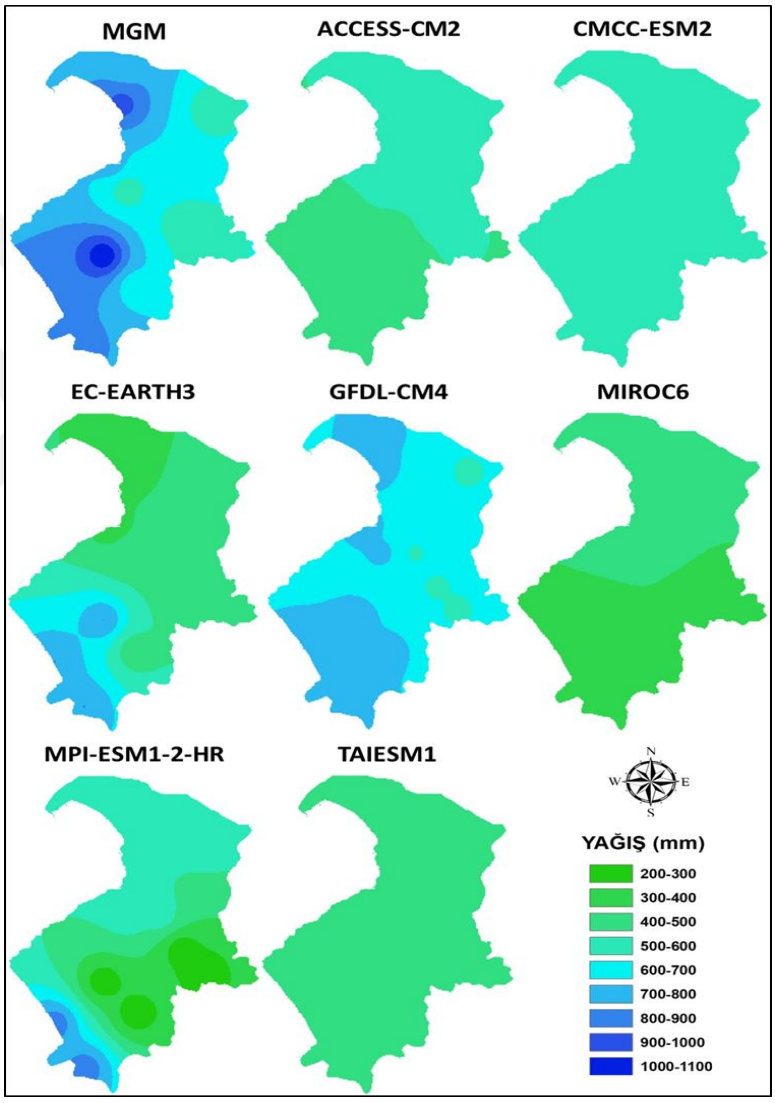


Şekil 4.8. Gözlem verileri ve KİM'lerin yıllık ortalama minimum sıcaklık alansal dağılım haritaları (1980-2014)

4.2.2. Yıllık Yağış Miktarı İçin Değerlendirme Sonuçları

Gözlemlerden ve CMIP6 KİM'leri tarafından tahmin edilen yağış verileri kullanılarak çalışma alanındaki yıllık ortalama yağış miktarları hesaplanmış ve 1980–2014 dönemi için ters ağırlıklı mesafe enterpolasyon yöntemi kullanılarak oluşturulan alansal dağılım haritaları Şekil 4.9'da gösterilmiştir. Yıllık ortalama yağış miktarının, Hatay ilinin farklı konumlarına göre 500–1100 mm aralığında olduğu hesaplanmıştır. Hatay'ın batı bölgelerinde, denize yakın olmaları nedeniyle daha yüksek yağış (>700 mm) meydana geldiği ve yıllık yağış miktarının batı bölgelerinden iç kesimlere doğru

azalma gösterdiği belirlenmiştir. KİM çıktıları ile ilgili olarak, özellikle en yüksek yıllık yağışın gözlemlendiği bölgelerde modellerin çoğu gözlem verilerinden daha düşük tahminler ürettiği belirlenmiştir. Kim ve ark. (2018), bu durumun aşırı yağışların zamansal ve mekânsal olarak yüksek değişkenlik göstermesinden kaynaklandığını ve bu nedenle yerel ölçekte yapılan çalışmalarda en gelişmiş modellerin bile aşırı yağışlı dönemlerin belirlenmesinde sorunlar yaşayabildiğini bildirmiştir.



Şekil 4.9. Gözlem verileri ve KİM'lerin yıllık ortalama yağış miktarı alansal dağılım haritaları (1980-2014)

Çalışma alanının gözlem verileri ile oluşturulan alansal dağılım haritası incelendiğinde (Şekil 4.9), batı bölgelerinden iç kesimlere doğru azalan yağış miktarı dağılımının daha iyi benzetimini yapan modellerin EC-EARTH3, GFDL-CM4 ve MPI-

ESM1-2-HR modelleri olduğu belirlenmiştir. Ancak, genel olarak modellerin kabul edilebilir eşik değerlerinden daha yüksek hata oranı ile tahminler gerçekleştirdikleri belirlenmiştir. Bu durum, KİM'lerin çözünürlüklerinin küresel düzeyde olmasından kaynaklandığı tahmin edilmektedir. Çözünürlüğün düşük olması, KİM'lerin yerel ölçekte topografik etkiler nedeniyle yağış dağılımında meydana gelebilecek alansal değişiklikleri tahmin edememesine neden olmaktadır (Shashikanth ve ark., 2014; Jain ve ark., 2019; Kamruzzaman ve ark., 2021; Li ve ark., 2021). Bu nedenle, sıcaklıkta olduğu gibi yağış verilerinin kullanımında da KİM'lere ölçek küçültme yöntemleri uygulandıktan sonra bölgesel çalışmaların gerçekleştirilmesi gerekmektedir.

4.2.3. Küresel İklim Modellerin Tahmin Performanslarının Sıralama Sonuçları

Tüm KİM'ler için tahmin edilen istatistiksel metriklerin sonuçları ve sıralamaları Çizelge 4.7'de verilmiştir. Bu değerlere göre, maksimum sıcaklık ve yağış miktarı için EC-EARTH3, minimum sıcaklık için ise CMCC-ESM2 en başarılı model olarak belirlenmiştir. Ancak genel olarak değerlendirildiğinde, KİM'lerden elde edilen ham verilerin genel olarak gözlem verileri ile uyumunun oldukça düşük olduğu görülmüştür. Modellerin alansal çözünürlüklerinin düşük olması bu uyum sorununun en büyük nedeni olarak tahmin edilmektedir (Kamruzzaman ve ark., 2021).

Modeller için hesaplanan farklı performans metriklerine göre başarı sıralamalarının değiştiği gözlemlenmiştir. Bu nedenle, tüm istatistiki performans metriklerini dikkate alarak değerlendirme yapabilen çok kriterli karar verme yöntemi olan uzlaşık programlama kullanılmıştır. Yöntem sonucunda elde edilen Lp değerlerinin maksimum sıcaklık, minimum sıcaklık ve yağış için elde edilen ortalamalarına göre oluşturulan başarı sıralaması Çizelge 4.8'de verilmiştir. En yüksek sıralamaya sahip KİM, Lp değeri en düşük olan EC-EARTH3 (0.144) modeli olmuştur. CMCC-ESM2 (0.160) ikinci sırayı alırken, GFDL-CM4 (0.172) üçüncü sırayı almıştır. TAIESM1, performans sıralama listesinde 0.238 Lp değeri ile genel sıralamada sonuncu olmuştur.

Çizelge 4.7. KİM'lerin performans metrik değerleri ve sıralamaları

Parametre	Model	TSS	d	NRMSE	L_p Değeri	Sıra
MAKSİMUM SICAKLIK	ACCESS-CM2	0.27	0.52	0.54	0.343	5
	CMCC-ESM2	0.62	0.46	0.48	0.110	2
	EC-EARTH3	**0.76**	**0.86**	**0.15**	**0.098**	**1**
	GFDL-CM4	0.20	0.49	0.61	0.395	6
	MIROC6	0.39	0.28	0.47	0.270	4
	MPI-ESM1-2-HR	0.56	0.50	0.35	0.155	3
	TAIESM1	0.07	0.12	0.64	0.486	7
MİNİMUM SICAKLIK	ACCESS-CM2	0.57	0.50	0.41	0.180	4
	CMCC-ESM2	**0.84**	**0.77**	**0.27**	**0.075**	**1**
	EC-EARTH3	0.33	0.62	0.33	0.322	5
	GFDL-CM4	0.79	0.80	0.28	0.079	2
	MIROC6	0.16	0.38	0.57	0.424	7
	MPI-ESM1-2-HR	0.29	0.44	0.52	0.344	6
	TAIESM1	0.75	0.83	0.17	0.114	3
YAĞIŞ	ACCESS-CM2	0.15	0.35	0.38	0.333	6
	CMCC-ESM2	0.19	0.46	0.24	0.293	4
	EC-EARTH3	**0.52**	**0.49**	**0.33**	**0.012**	**1**
	GFDL-CM4	0.48	0.66	0.13	0.042	2
	MIROC6	0.14	0.33	0.49	0.341	7
	MPI-ESM1-2-HR	0.38	0.43	0.38	0.121	3
	TAIESM1	0.17	0.40	0.36	0.316	5

Çizelge 4.8. KİM'lerin ortalama CP değerleri ve başarı sıralamaları

Model	Ortalama L_p değeri	Sıra
ACCESS-CM2	0.285	5
CMCC-ESM2	0.160	2
EC-EARTH3	0.144	1
GFDL-CM4	0.172	3
MIROC6	0.345	7
MPI-ESM1-2-HR	0.207	4
TAIESM1	0.305	6

EC-EARTH3 modelinin daha başarılı olma nedeninin mekansal çözünürlüğünün diğer modellerden daha yüksek olmasından kaynaklandığı düşünülmektedir. Li ve ark. (2021), CMIP6 modellerinin Yangtze Nehri Havzası yıllık ortalama yağış için performansını değerlendirdiği çalışmada, EC-EARTH3 modelini en başarılı model

olduğunu belirlemişlerdir. Iqbal ve ark. (2021), KİM'lerin yağış tahmin performansını uzlaşık programlama yöntemini kullanarak değerlendirmişler ve sonuç olarak EC-EARTH3 modelini en başarılı üç modelden biri olarak açıklamışlardır. Zhu ve ark. (2021), CMIP5 ve CMIP 6 modellerinin performanslarını incelemişler ve maksimum sıcaklık, minimum sıcaklık ve yağış tahmini için EC-EARTH3 modelinin en başarılı modellerden biri olduğunu açıklamışlardır. Benzer olarak; Khadka ve ark. (2021), Tang ve ark. (2021), Abbas ve ark. (2022) ve Hamed ve ark. (2022a) farklı bölgelerde yaptıkları çalışmalarda, CMIP6 modelleri arasında maksimum sıcaklık, minimum sıcaklık ve yağış tahminleri için EC-EARTH3 modelinin başarılı olduğunu açıklamışlardır. Sonuç olarak, çalışmada elde edilen sonuçların literatür ile uyumlu olduğu belirlenmiştir.

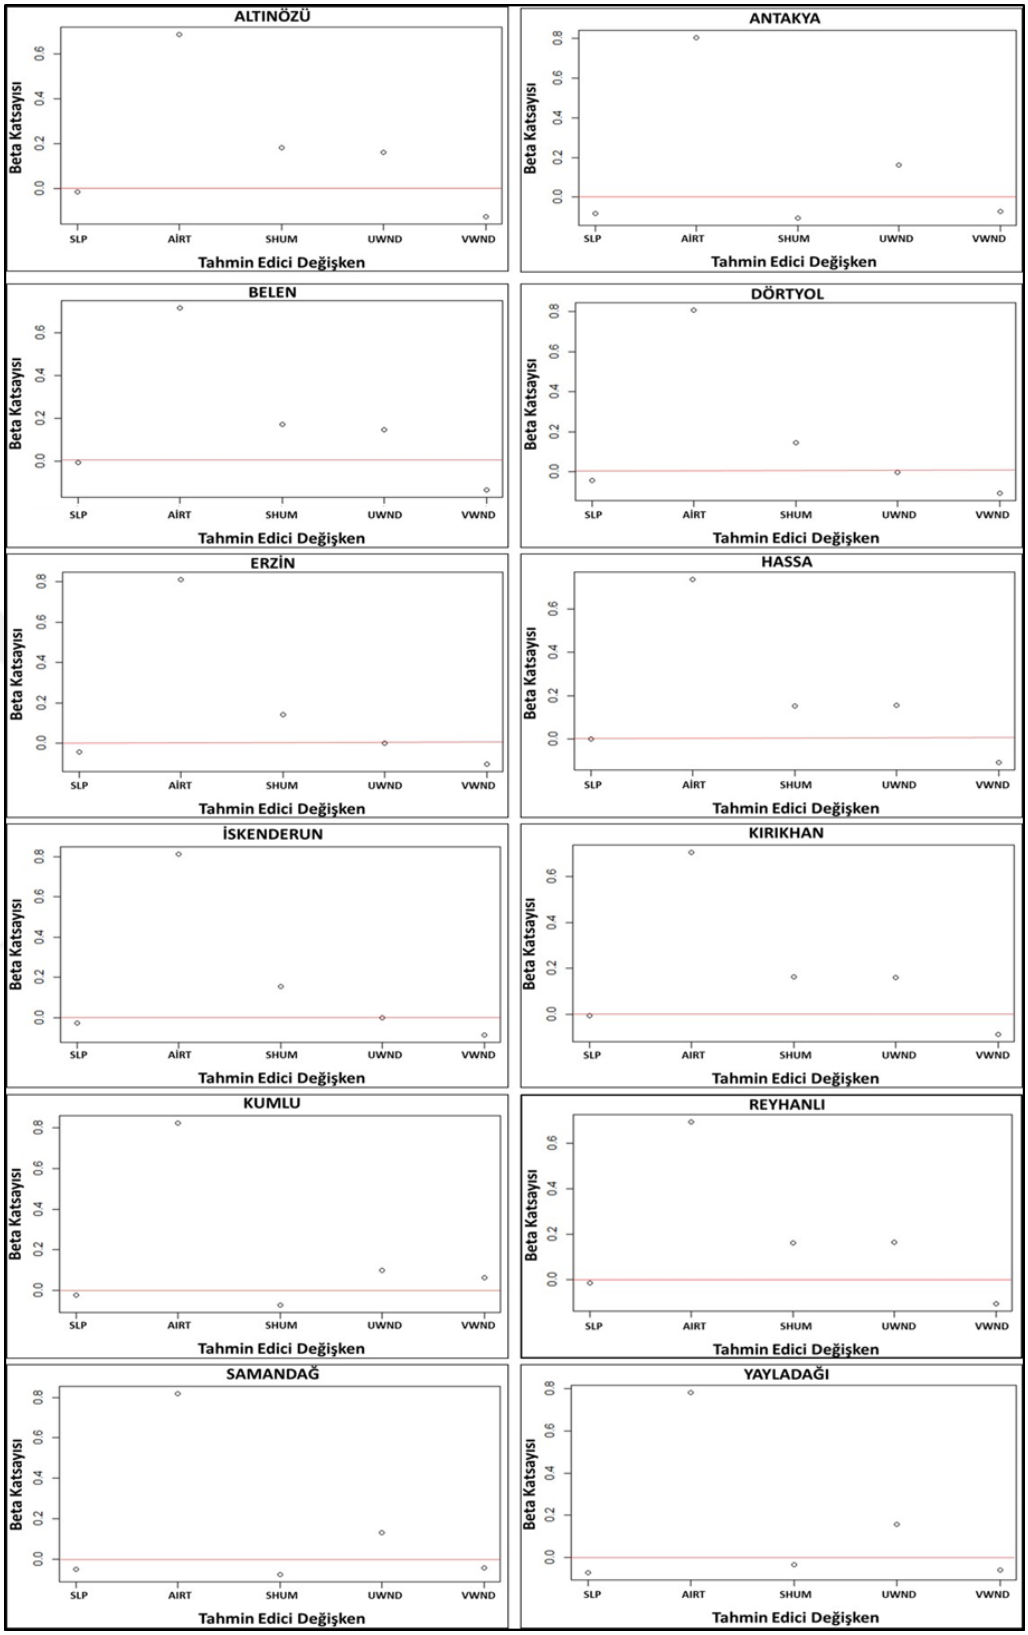
4.3. Küresel İklim Modeline İstatistiksel Ölçek Küçültme Uygulanması Sonuçları

4.3.1. Modellerde Kullanılması Belirlenen Tahmin Edici Değişkenler

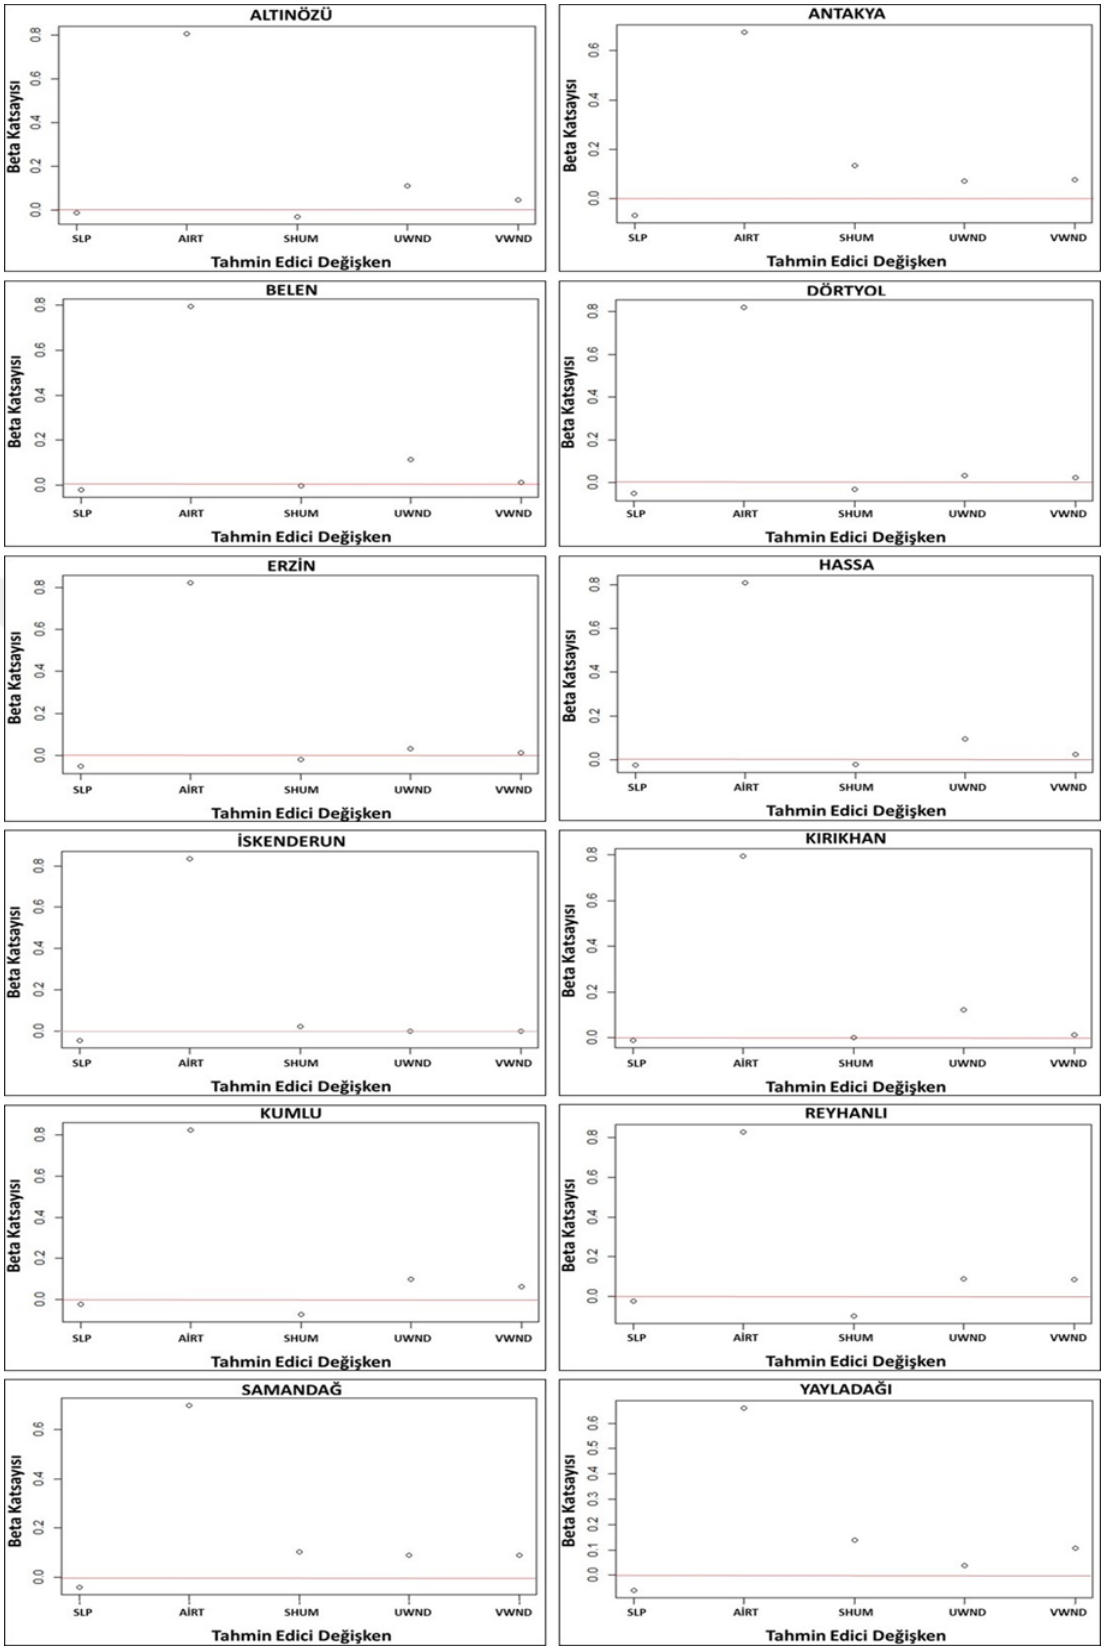
EC-EARTH3 modelinden elde edilen tahminler kullanılarak ölçek küçültme modelinin oluşturulabilmesi için ilk olarak LASSO yöntemi ile bağımsız değişkenlerin belirlenmesi gerekmektedir. Bu amaçla, modelden elde edilen 1980-2014 yıllarına ait yakın yüzey hava sıcaklığı (AIRT, °C), özgül nem (SHUM, g kg^{-1}), bölgesel rüzgâr hızı (UWND, m s^{-1}), meridiyonal rüzgâr hızı (VWND, m s^{-1}) ve deniz seviyesi basıncı (SLP, hPa) parametreleri değerlendirilmiştir. Ölçek küçültme modeli için LASSO analizi ile belirlenen değişkenler Çizelge 4.9'da verilmiştir. Maksimum sıcaklık, minimum sıcaklık ve yağış için elde edilen değişkenlere ait katsayılarının grafikleri sırasıyla Şekil 4.10, Şekil 4.11 ve Şekil 4.12'de verilmiştir. Analiz sonucunda katsayıları sıfıra eşitlenen değişkenler ölçek küçültme modellerinde tahmin edici değişken olarak kullanılmamıştır. Şekillerden görüldüğü gibi maksimum ve minimum sıcaklık tahmini için en etkili değişkenin AIRT ve yağış miktarı için en etkili değişkenin UWND olduğu belirlenmiştir.

Çizelge 4.9. LASSO analizi sonucu modellerde kullanılması belirlenen tahmin edici değişkenler

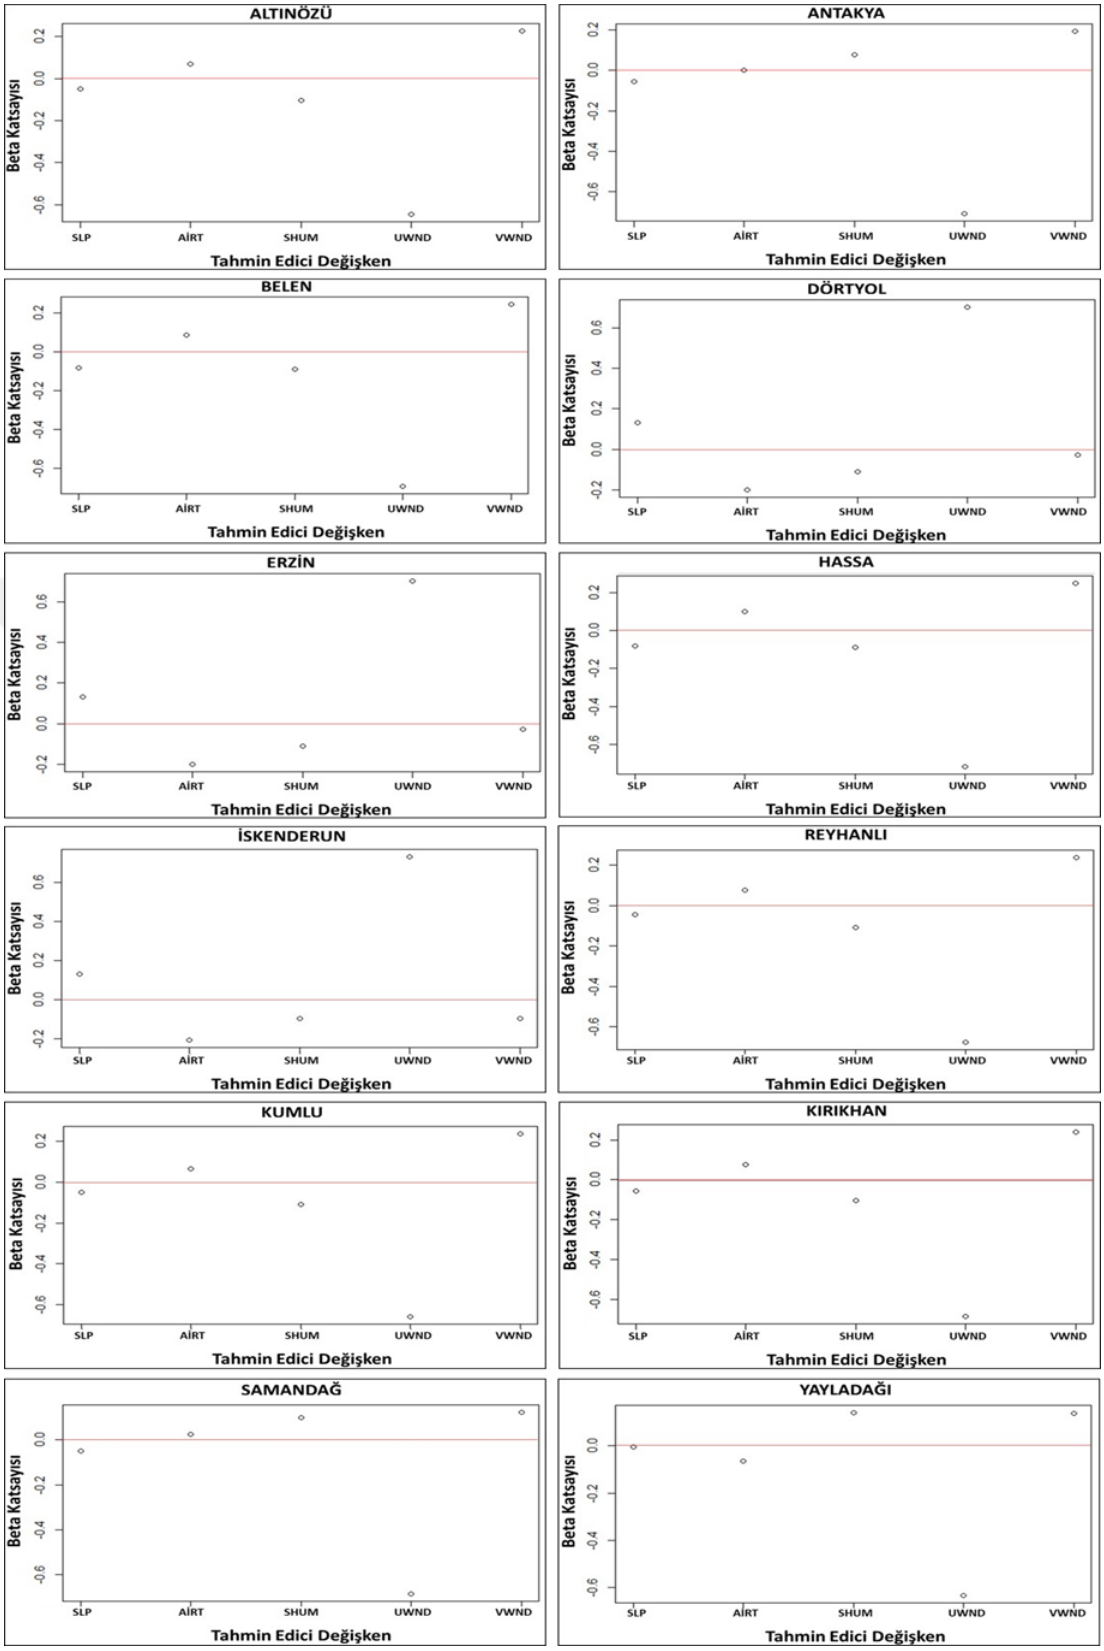
İSTASYONLAR	MAKSİMUM SICAKLIK	MİNİMUM SICAKLIK	YAĞIŞ
Altınözü	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Antakya	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, SHUM, UWND, VWND
Belen	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Dörtyol	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Erzin	SLP, AIRT, SHUM, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Hassa	AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
İskenderun	SLP, AIRT, SHUM, VWND	SLP, AIRT, SHUM	SLP, AIRT, SHUM, UWND, VWND
Kırıkhan	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Kumlu	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Reyhanlı	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Samandağ	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND
Yayladağı	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND	SLP, AIRT, SHUM, UWND, VWND



Şekil 4.10. Maksimum sıcaklık ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler



Şekil 4.11. Minimum sıcaklık ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler



Şekil 4.12. Yağış miktarı ölçek küçültme modeli için LASSO yöntemi ile belirlenen tahmin edici değişkenler

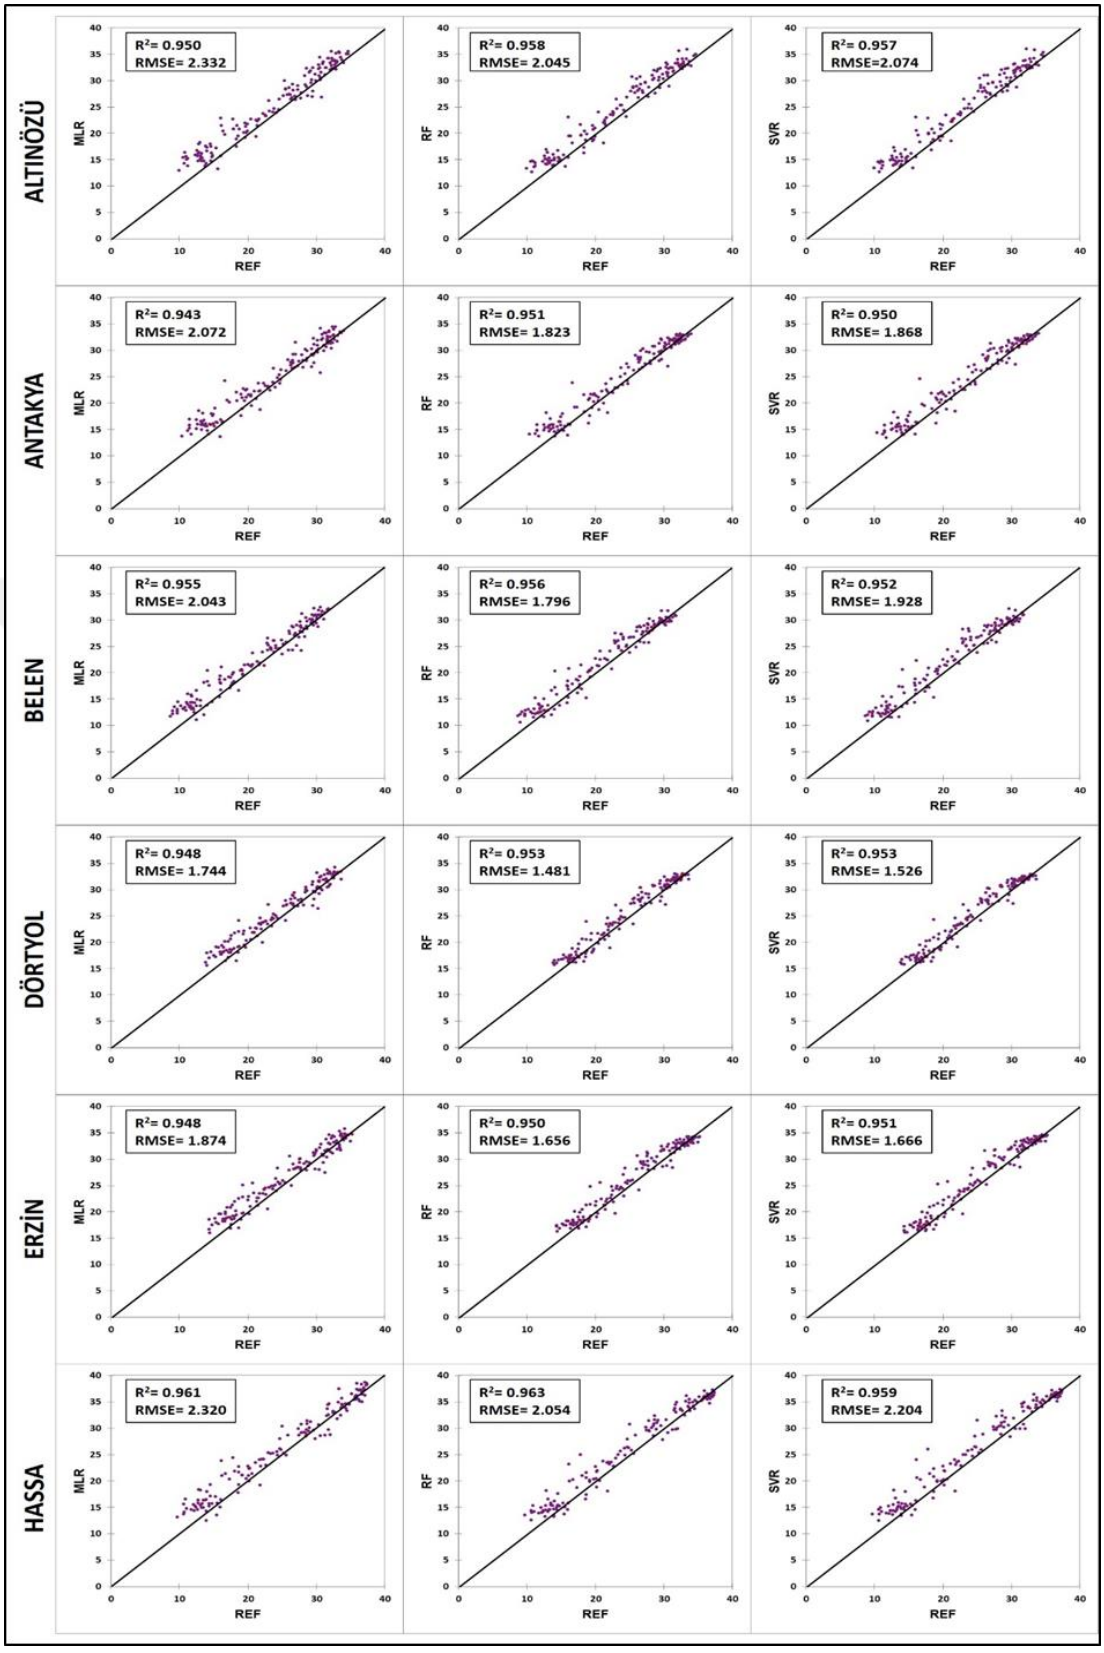
4.3.2. Maksimum ve Minimum Sıcaklık İçin Ölçek Küçültme Modeli Sonuçları

LASSO yöntemi kullanılarak her istasyon için belirlenen tahmin edici değişkenler ile RF, SVR ve MLR yöntemleri kullanılarak ölçek küçültme modelleri oluşturulmuştur. Tahmin edici değişkenler 2/3 eğitim ve 1/3 test veri seti olacak şekilde ayrılmıştır. Oluşturulan modellerden RF ve SVR'ye ait olan hiperparametreler R Studio ortamında çapraz doğrulama yöntemi kullanılarak belirlenmiş ve bu değerler Çizelge 4.10'da verilmiştir.

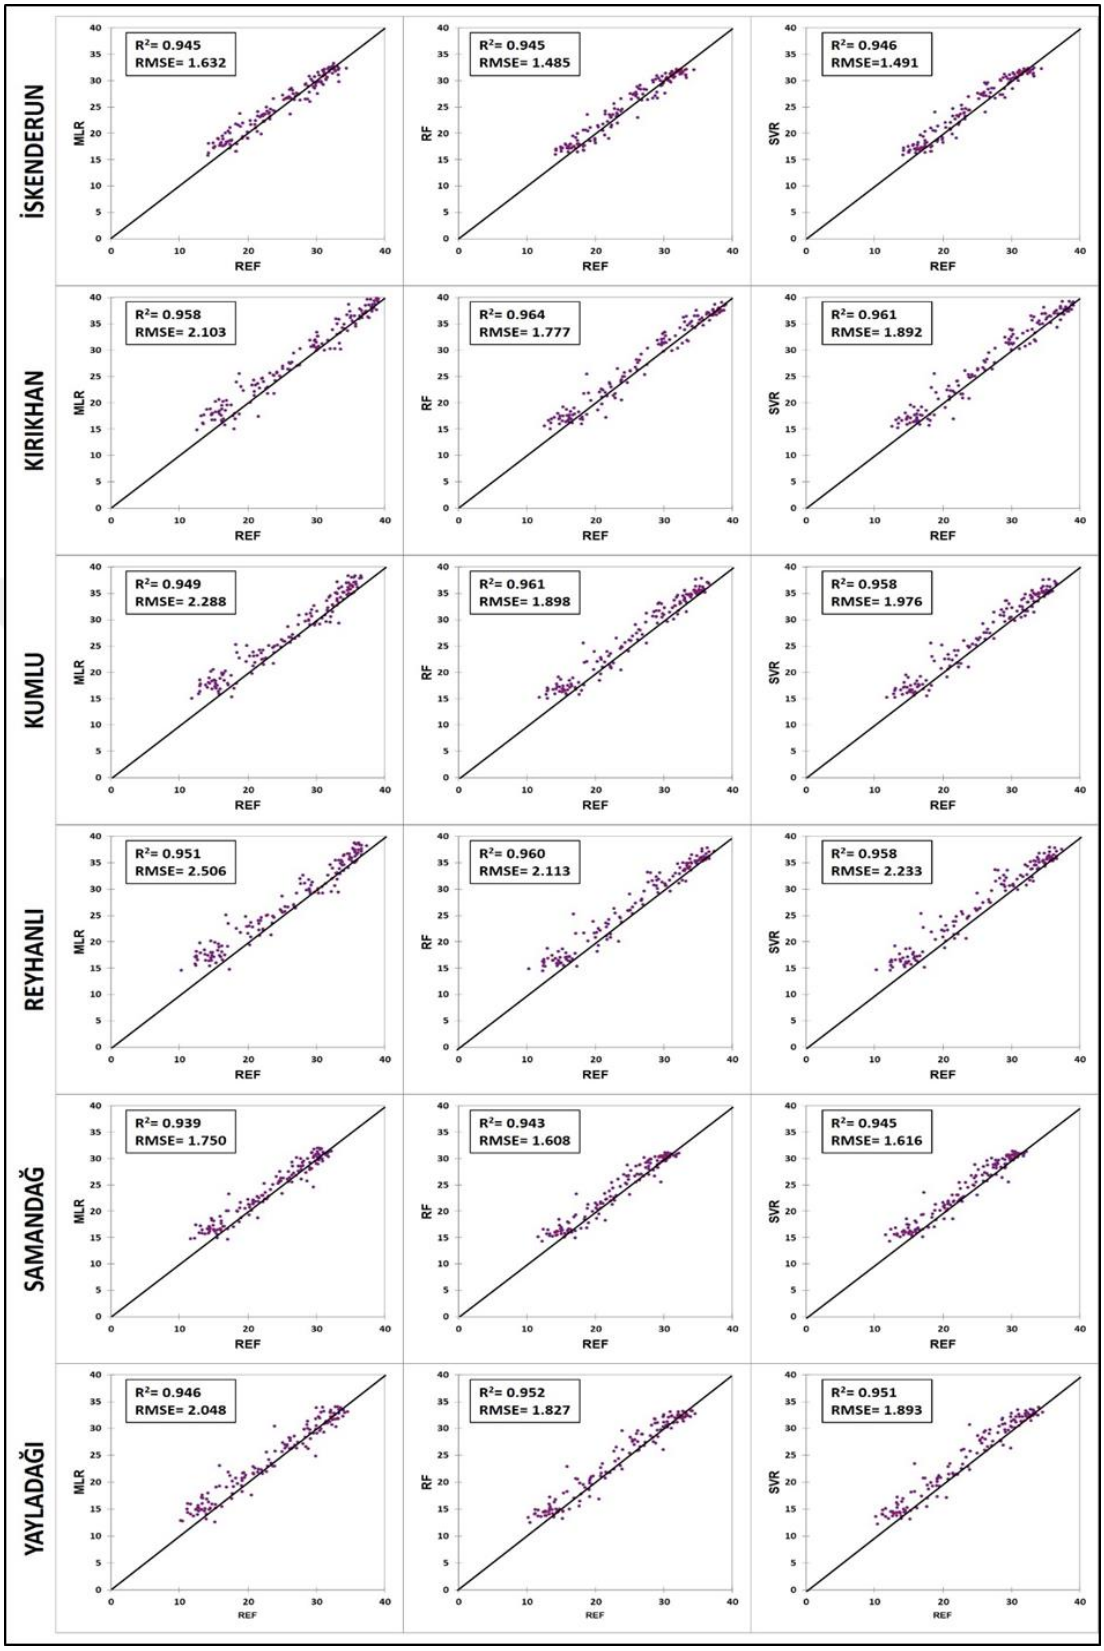
Çizelge 4.10. SVR ve RF modellerinin hiperparametre analizi ile belirlenen optimum parametre değerleri

İSTASYONLAR	Maksimum Sıcaklık					Minimum Sıcaklık				
	SVR			RF		SVR			RF	
	C	γ	ε	ntree	mtry	C	γ	ε	ntree	mtry
Altınözü	2.000	0.125	0.100	500	2	0.500	0.250	0.100	500	2
Antakya	4.000	0.125	0.100	500	2	1.000	0.125	0.100	500	2
Belen	2.000	0.125	0.100	500	2	2.000	0.125	0.100	500	2
Dörtyol	0.500	0.125	0.100	500	2	0.250	0.250	0.100	500	2
Erzin	2.000	0.063	0.100	500	1	0.500	0.250	0.100	500	2
Hassa	2.000	0.125	0.100	500	2	1.000	0.125	0.100	500	2
İskenderun	0.500	0.125	0.100	500	2	0.250	0.500	0.100	500	1
Kırıkhan	1.000	0.125	0.100	500	2	1.000	0.125	0.100	500	2
Kumlu	1.000	0.125	0.100	500	2	0.500	0.250	0.100	500	2
Reyhanlı	4.000	0.063	0.100	500	2	0.500	0.250	0.100	500	2
Samandağ	2.000	0.125	0.100	500	2	0.500	0.125	0.100	500	2
Yayladağı	2.000	0.125	0.100	500	2	1.000	0.125	0.100	500	2

Analiz sonucunda belirlenen parametreler kullanılarak oluşturulmuş olan modellerden elde edilen maksimum sıcaklık tahmin sonuçlarının gözlem verileri ile aylık zaman ölçeğinde karşılaştırılması Şekil 4.13 ve Şekil 4.14'de saçılım grafiği olarak verilmiştir. Maksimum sıcaklık için grafikler incelendiğinde, tüm istasyonlarda modellerin gözlem verileri ile yüksek benzerlik (R^2>0.90) gösterdiği belirlenmiştir. Ayrıca, RMSE değerlerinin de elde edilen tahminlerin gözlem değerlerine oldukça yakın olduğu tespit edilmiştir. Modeller maksimum sıcaklık için karşılaştırıldığında RF (RMSE=1.481-2.113) ve SVR (RMSE=1.491-2.233) model tahminlerinin benzer oldukları görülmektedir. Ancak, geleneksel yöntem olan MLR (RMSE=1.632-2.506) yönteminin makine öğrenmesi yöntemlerine göre maksimum sıcaklıkları tahmin etmede daha başarısız olduğu grafiklerden tespit edilmiştir.



Şekil 4.13. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa maksimum sıcaklık tahminleri için saçılım grafikleri

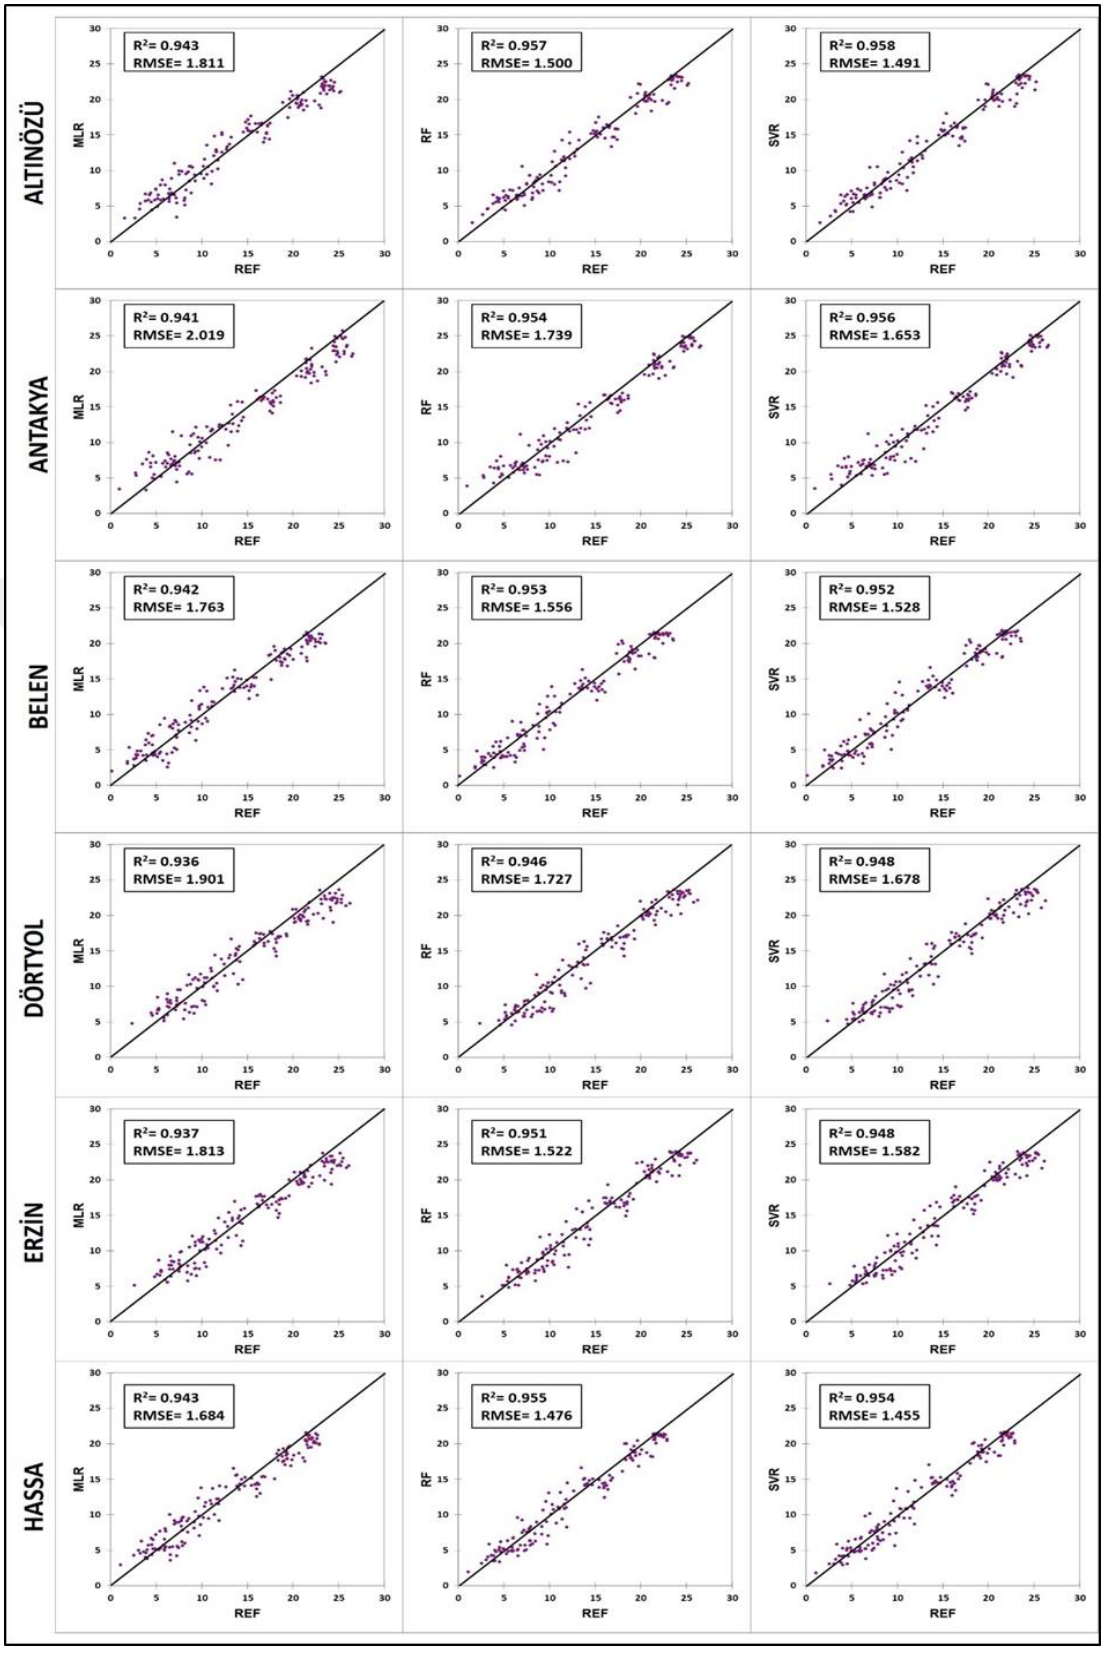


Şekil 4.14. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı maksimum sıcaklık tahminleri için saçılım grafikleri

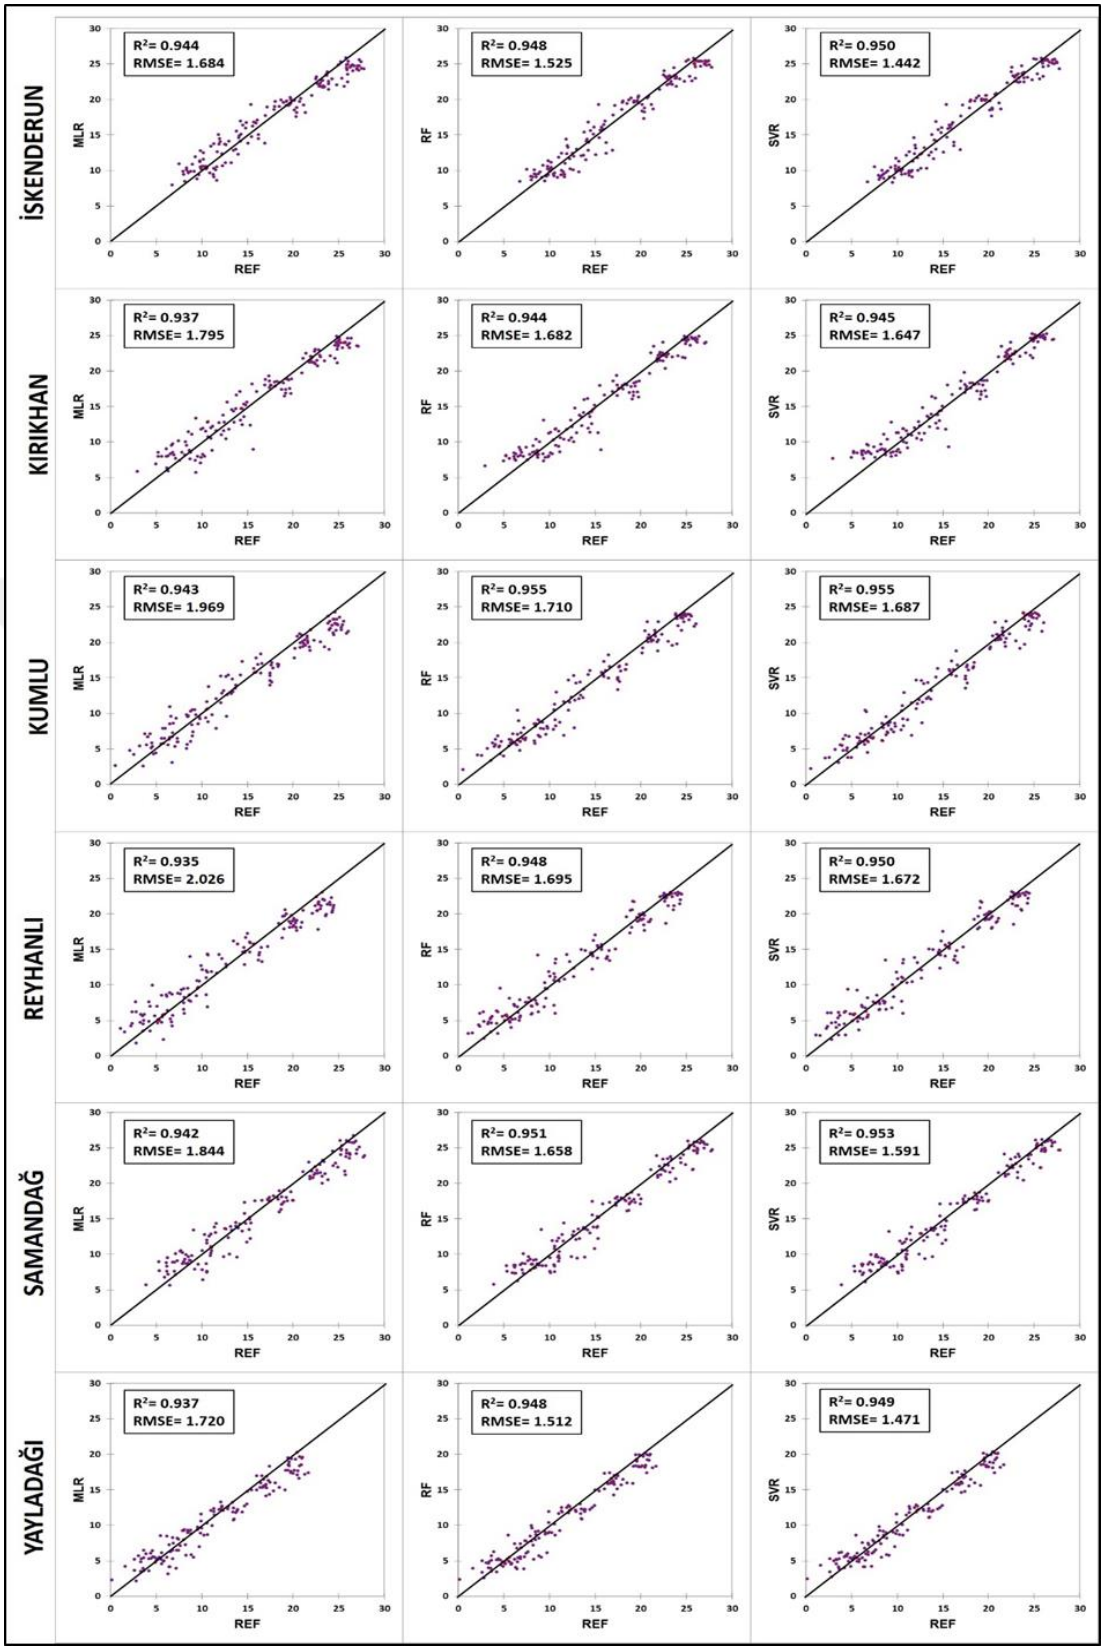
Maksimum sıcaklığa benzer olarak ölçek küçültme modellerinden istasyonlar için elde edilen aylık ortalama minimum sıcaklık tahminlerinin de gözlem değerlerine oldukça yakın olduğu Şekil 4.15 ve Şekil 4.16'da verilen saçılım grafiklerinden tespit edilmiştir (R^2>0.90). Minimum sıcaklık için ölçek küçültme modellerinin tahminlerindeki hata miktarlarının maksimum sıcaklık tahminlerine göre daha düşük olduğu belirlenmiştir. Bunun nedeni maksimum sıcaklıkların kısa süreli hava olaylarından minimum sıcaklığa göre daha çok etkilenmesi ve minimum sıcaklıkların gözlem istasyonlarından genellikle hava olaylarının değişkenlik göstermediği gece saatlerinde ölçülmesinden kaynaklı olduğu düşünülmektedir.

Sıcaklık değerlerinin yüksek doğrulukta tahmin edilmesinin pek çok nedeni bulunmaktadır. Bunlardan en önemlisi; KİM'lerin konveksiyon, kondüksiyon ve radyasyon gibi sıcaklığı kontrol eden fiziksel süreçleri esas alarak oluşturulmalarıdır. Bu sayede enlem, yükseklik ve bulutluluk gibi bölgesel faktörler nedeniyle meydana gelebilecek sıcaklık değişimlerini diğer iklim değişkenlerine kıyasla nispeten daha iyi tahmin edebilmektedir. Ayrıca sıcaklık, diğer iklim parametrelerine göre daha az değişkenlik göstermesi nedeniyle modeller tarafından tahmin doğruluğunu arttırmaktadır (Randall ve ark., 2007).

Modellerin tahminleri karşılaştırıldığında, SVR (RMSE=1.442-1.687) ve RF (RMSE=1.476-1.739) makine öğrenmesi modellerinin maksimum sıcaklıkta olduğu gibi minimum sıcaklıkta da MLR (RMSE=1.684-2.026) modelinden daha başarılı olduğu grafiklerden belirlenmiştir. Makine öğrenmesi yöntemlerinin daha başarılı olmasının birçok nedeni vardır. Bunlardan biri esneklik olarak adlandırılan özelliktir. Geleneksel regresyon yöntemleri sadece doğrusal ilişkileri modelleyebilirken, makine öğrenmesi yöntemleri esneklik özelliği sayesinde değişkenler arasında doğrusal olmayan ilişkileri de modelleyebilmektedir. Ayrıca, makine öğrenmesi modelleri veri setleri içerisindeki aykırı değerlere karşı geleneksel regresyon yöntemlerine göre daha az hassastır. Böylece, regresyon modellerinin göz ardı ettiği değişkenler arasındaki karmaşık ilişkileri de öğrenebilmektedirler (Qiu ve ark., 2014; Khanzode ve Sarode, 2020; Neu ve ark., 2022).



Şekil 4.15. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa minimum sıcaklık tahminleri için saçılım grafikleri



Şekil 4.16. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı minimum sıcaklık tahminleri için saçılım grafikleri

Ölçek küçültme modellerinden elde edilen maksimum ve minimum sıcaklık tahminleri aylık zaman ölçeğinde üç farklı performans değerlendirme metriği (PBIAS, NRMSE ve NSE) kullanılarak karşılaştırılmış ve kullanılabilirlikleri değerlendirilmiştir. Maksimum sıcaklık için elde edilen sonuçlar Çizelge 4.11 ve minimum sıcaklık için elde edilen sonuçlar Çizelge 4.12'de verilmiştir.

Çizelge 4.11. Ölçek küçültme modellerinin maksimum sıcaklık için test dönemi tahmin performansları

İstasyonlar	MLR			RF			SVR		
	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE
Altınözü	-6.70	0.31	0.90	-5.77	0.27	0.93	-5.80	0.27	0.92
Antakya	-4.45	0.29	0.92	-3.53	0.25	0.93	-3.81	0.26	0.93
Belen	-5.89	0.28	0.92	-4.51	0.25	0.94	-5.13	0.27	0.93
Dörtyol	-4.11	0.29	0.92	-2.76	0.24	0.94	-3.15	0.25	0.94
Erzin	-4.13	0.29	0.92	-3.06	0.25	0.93	-3.31	0.26	0.93
Hassa	-5.45	0.26	0.93	-4.07	0.23	0.95	-4.90	0.25	0.94
İskenderun	-2.28	0.27	0.93	-1.36	0.25	0.94	-2.08	0.25	0.94
Kırıkhan	-4.12	0.25	0.94	-2.74	0.21	0.96	-3.34	0.22	0.95
Kumlu	-5.53	0.30	0.91	-4.30	0.25	0.94	-4.53	0.26	0.93
Reyhanlı	-6.23	0.30	0.91	-4.89	0.25	0.93	-5.39	0.27	0.93
Samandağ	-3.47	0.29	0.92	-2.88	0.26	0.93	-3.19	0.27	0.93
Yayladağı	-3.97	0.27	0.93	-3.32	0.24	0.94	-3.90	0.25	0.94

Çizelge 4.12. Ölçek küçültme modellerinin minimum sıcaklık için test dönemi tahmin performansları

İstasyonlar	MLR			RF			SVR		
	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE
Altınözü	1.67	0.26	0.93	2.50	0.22	0.95	2.43	0.21	0.95
Antakya	4.14	0.28	0.92	4.52	0.24	0.94	3.57	0.23	0.95
Belen	1.79	0.26	0.93	3.16	0.23	0.95	1.96	0.22	0.95
Dörtyol	3.89	0.29	0.92	5.20	0.26	0.93	4.60	0.25	0.94
Erzin	3.00	0.28	0.92	3.15	0.23	0.95	3.41	0.24	0.94
Hassa	3.09	0.26	0.93	4.27	0.23	0.95	3.53	0.23	0.95
İskenderun	1.67	0.27	0.93	2.60	0.24	0.94	1.57	0.23	0.95
Kırıkhan	1.48	0.27	0.93	2.34	0.25	0.94	0.74	0.24	0.94
Kumlu	3.74	0.27	0.93	4.54	0.23	0.94	4.29	0.23	0.95
Reyhanlı	1.17	0.28	0.92	1.68	0.23	0.94	1.57	0.23	0.95
Samandağ	2.41	0.26	0.93	2.92	0.24	0.94	2.28	0.23	0.95
Yayladağı	5.45	0.29	0.91	5.53	0.26	0.93	4.17	0.25	0.94

Çizelge 4.11 ve 4.12'de verilen sonuçlar değerlendirildiğinde, modellerin maksimum ve minimum tahminleri için hesaplanan PBIAS sonuçlarına (<±10) göre hesaplanan yanlılıkların ihmal edilebilir düzeyde olduğu görülmüştür. Model tahminlerinin maksimum sıcaklıkları, istasyonlarda gözlenen değerlerden daha yüksek

tahmin etme eğiliminde olduğu hem Şekil 4.13 ve Şekil 4.14'teki saçılım grafiklerinden hem de negatif PBIAS değerlerinin hesaplanmasından anlaşılmaktadır. Buna karşın, minimum sıcaklık değerlerini ise gerçek değerlerden daha düşük tahmin etme eğiliminde olduğu Çizelge 4.12'den anlaşılmaktadır. Modeller maksimum sıcaklık için karşılaştırıldığında; RF (PBIAS=1.36-5.77) modelinin, SVR (PBIAS=2.08-5.80) ve MLR (PBIAS=2.28-6.70) modellerinden daha az yanlılık gösterdiği belirlenmiştir. Minimum sıcaklık için ise, SVR model daha az yanlılık göstererek (PBIAS=0.74-4.60) daha başarılı bulunmuştur.

Model tahminlerinin hata miktarlarının kabul edilebilirliğini değerlendirmek için kullanılan ve istatistiki performans değerlendirme metriklerinden biri olan NRMSE değeri hem maksimum sıcaklık hem de minimum sıcaklık için düşük olarak hesaplanmıştır. RF ve SVR modellerin NRMSE değeri maksimum sıcaklık için sırasıyla ortalama 0.25 ve 0.26, minimum sıcaklık için ise ortalama 0.24 ve 0.23 olarak hesaplanmıştır. Bu değerler literatüre göre 0.50'den küçük olduğu için modellerin tahminlerinin oldukça başarılı olduğu belirlenmiştir (Moriasi ve ark., 2007). Modellerin genel kullanılabilirliğini değerlendiren NSE performans metriği sonuçları ise, diğer performans metriklerinde olduğu gibi başarılı bulunmuştur (NSE>0.90). Bu performans metriği içinde istasyonlar özelinde SVR ve RF model tahminlerinin performansının MLR model performansından daha başarılı olduğu belirlenmiştir. İstatistiki performans değerlendirmeleri ve saçılım grafikleri incelendiğinde elde edilen sonuçlar, Moriasi ve ark. (2007) tarafından oluşturulan değerlendirme tablosuna göre çok iyi olarak kabul edilmektedir. Ayrıca, geleneksel regresyon yöntemlerine göre makine öğrenmesi algoritmalarının kullanılmasının sıcaklık tahminlerindeki hem sapmayı azaltmada hem de doğruluğu arttırmada etkili olduğu görülmüştür.

Hem maksimum hem de minimum sıcaklıklar için elde ettiğimiz bulguların, dünyanın farklı bölgelerinde yapılan benzer çalışmaların sonuçları ile karşılaştırıldığında uyumlu olduğu görülmüştür. Pang ve ark. (2017), çalışmamız da olduğu gibi MLR, SVR ve RF ölçek küçültme modellerini sıcaklık için değerlendirmişlerdir. Çalışma sonucunda test dönemleri için RF modelinin R^2 değerini 0.94 ve RMSE değerini 1.46, SVR modelin R^2 değerini 0.92 ve RMSE değerini 1.66 olarak belirlemişlerdir. Ren ve ark. (2019), maksimum sıcaklık için RF ölçek küçültme modelinin NSE değerini 0.89, RMSE değerini 2.02 ve r değerini 0.95; minimum sıcaklık için ise NSE değerini 0.90, RMSE

değerini 2.46 ve r değerini 0.95 olarak belirlemişlerdir. SVR ölçek küçültme modelinde ise bu değerleri maksimum sıcaklık için sırasıyla 0.86, 2.25 ve 0.93; minimum sıcaklık için ise 0.85, 3.02, 0.93 olarak belirlemişlerdir. Alamgir ve ark. (2019), SVR regresyonu kullanarak maksimum sıcaklık için RMSE değerini 0.54-0.89 ve NSE değerini 0.58-0.71 olarak hesaplamışlardır. Minimum sıcaklık için RMSE değerini 0.60-1.54 ve NSE değerini 0.31-0.68 olarak hesaplamışlardır. Önceki çalışmaların sonuçları ile doğruladığımız model değerlendirme sonuçlarına göre, maksimum ve minimum sıcaklık için ölçek küçültme modeli olarak RF ve SVR'nin kullanılabileceğine karar verilmiştir. Ayrıca, iklim modellerinden elde edilecek gelecek senaryo çıktılarına da bu modeller uygulanmıştır.

4.3.3. Yağış Miktarı İçin Ölçek Küçültme Model Sonuçları

LASSO yöntemi kullanılarak her istasyon için belirlenen tahmin edici değişkenler ile RF, SVR ve MLR yöntemleri kullanılarak ölçek küçültme modelleri oluşturulmuştur. Tahmin edici değişkenler 2/3 eğitim ve 1/3 test veri seti olarak ayrılmıştır. Makine öğrenmesi modelleri olan RF ve SVR'ye ait olan hiperparametreler R Studio ortamında çapraz doğrulama yöntemi kullanılarak belirlenmiş ve bu değerler Çizelge 4.13'te verilmiştir.

Çizelge 4.13. SVR ve RF modellerinin hiperparametre analizi ile belirlenen optimum parametre değerleri

İSTASYONLAR	SVR			RF	
	C	γ	ε	ntree	mtry
Altınözü	2.000	0.500	0.100	500	1
Antakya	8.000	0.063	0.100	500	2
Belen	8.000	0.250	0.100	500	2
Dörtyol	4.000	0.063	0.100	500	2
Erzin	1.000	0.063	0.100	500	2
Hassa	8.000	0.250	0.100	500	2
İskenderun	8.000	0.063	0.100	500	2
Kırıkhan	4.000	0.500	0.100	500	2
Kumlu	8.000	0.500	0.100	500	2
Reyhanlı	4.000	0.500	0.100	500	2
Samandağ	8.000	0.125	0.100	500	1
Yayladağı	2.000	0.250	0.100	500	2

Analiz sonucu belirlenen parametreler kullanılarak yağış miktarı için her istasyona ait ölçek küçültme modelleri oluşturulmuştur. Modellerden elde edilen tahmin sonuçlarının gözlem verileri ile aylık zaman ölçeğinde karşılaştırılması Şekil 4.17 ve Şekil 4.18'de saçılım grafiği olarak verilmiştir. Aylık toplam yağış miktarı için grafikler incelendiğinde tüm istasyonlarda modellerin gözlem verileri ile kabul edilebilir oranda benzerlik (R^2>0.55) gösterdikleri görülmüştür. Ayrıca, hesaplanan RMSE değerleri de elde edilen tahminlerin kabul edilebilir hata miktarı ile gözlem değerlerini tahmin ettiği Şekil 4.17 ve Şekil 4.18'de gösterilmektedir. Modeller yağış miktarı için karşılaştırıldığında, RF'nin (R^2=0.706-0.867 ve RMSE=19.191-45.408) en başarılı ölçek küçültme modeli olduğu görülmüştür. En başarısız tahminler ise, MLR (R^2=0.555-0.805 ve RMSE=25.198-59.164) ölçek küçültme modelinden elde edilmiştir. Sonuç olarak sıcaklıkta olduğu gibi, yağış miktarının tahmini için de makine öğrenmesi yöntemlerinin geleneksel regresyon yöntemine göre çok daha başarılı olduğu görülmüştür.

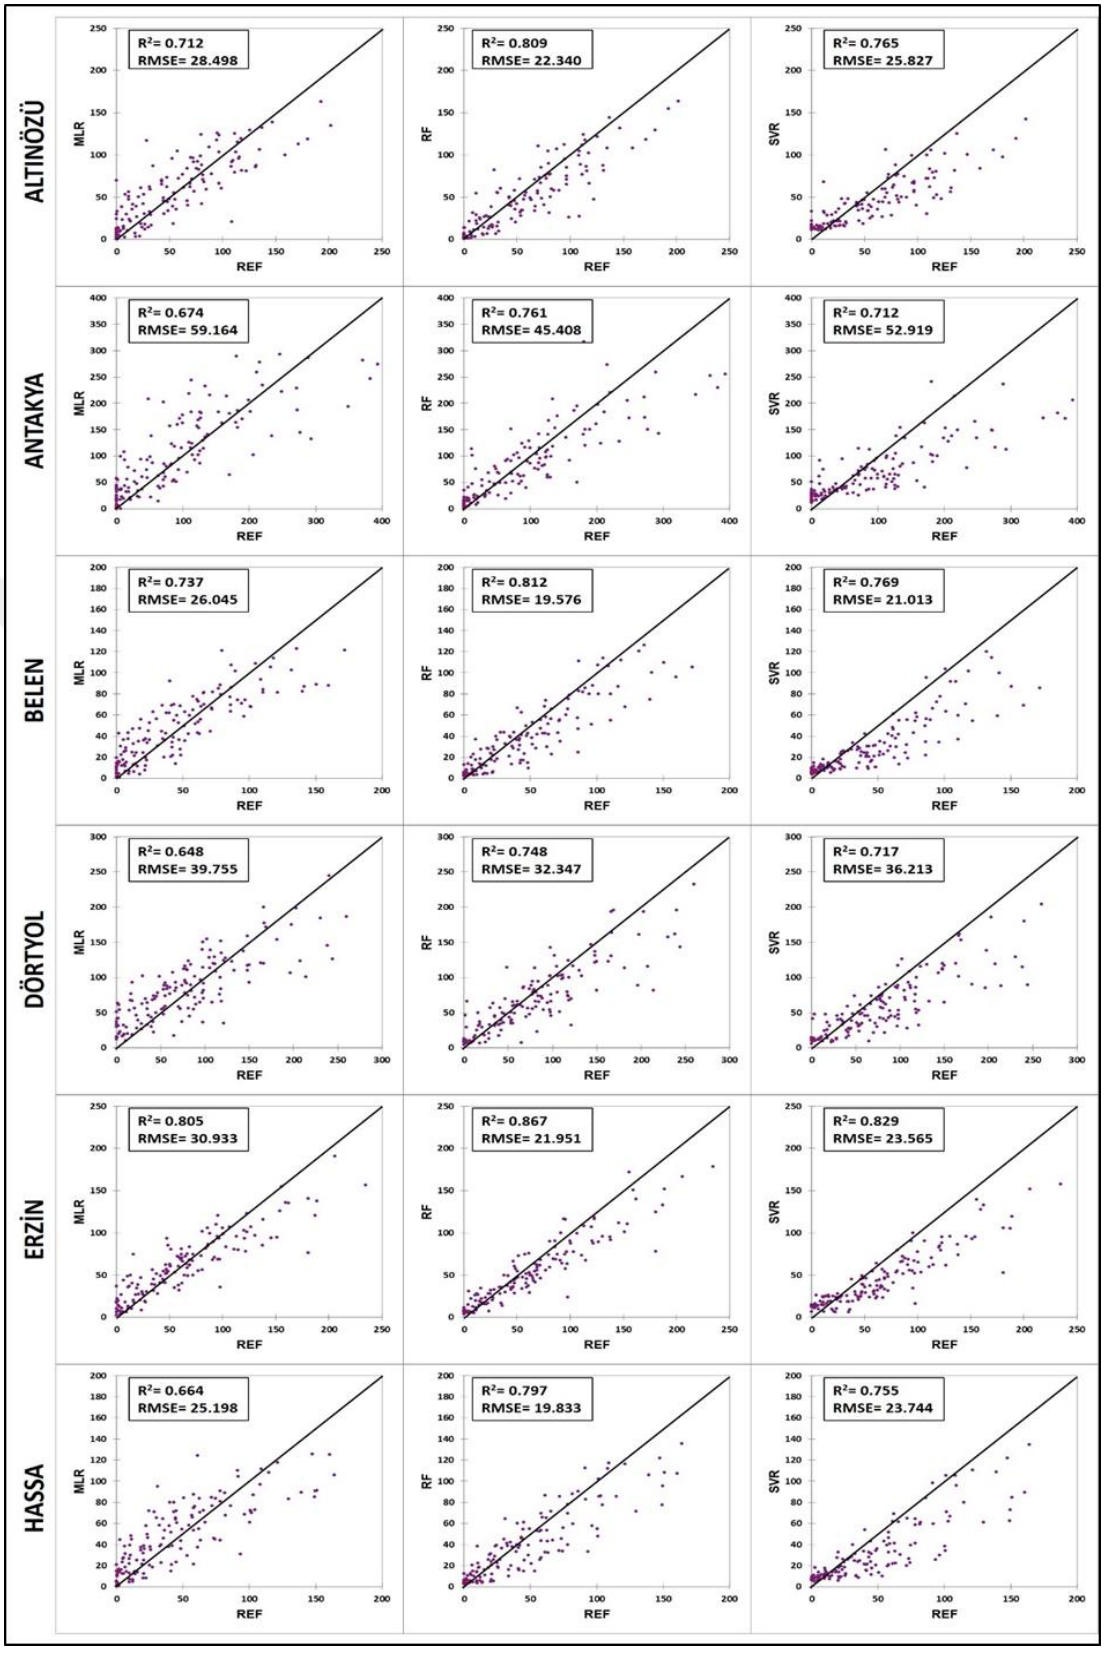
Ölçek küçültme modellerinin tahmin performansı istatistiksel metrikler kullanılarak, gözlem verilerine olan uyumu ve hatalarının büyüklüklerine göre değerlendirilmiş ve sonuçlar Çizelge 4.14'te verilmiştir.

Çizelge 4.14. Ölçek küçültme modellerinin yağış miktarı için test dönemi tahmin performansları

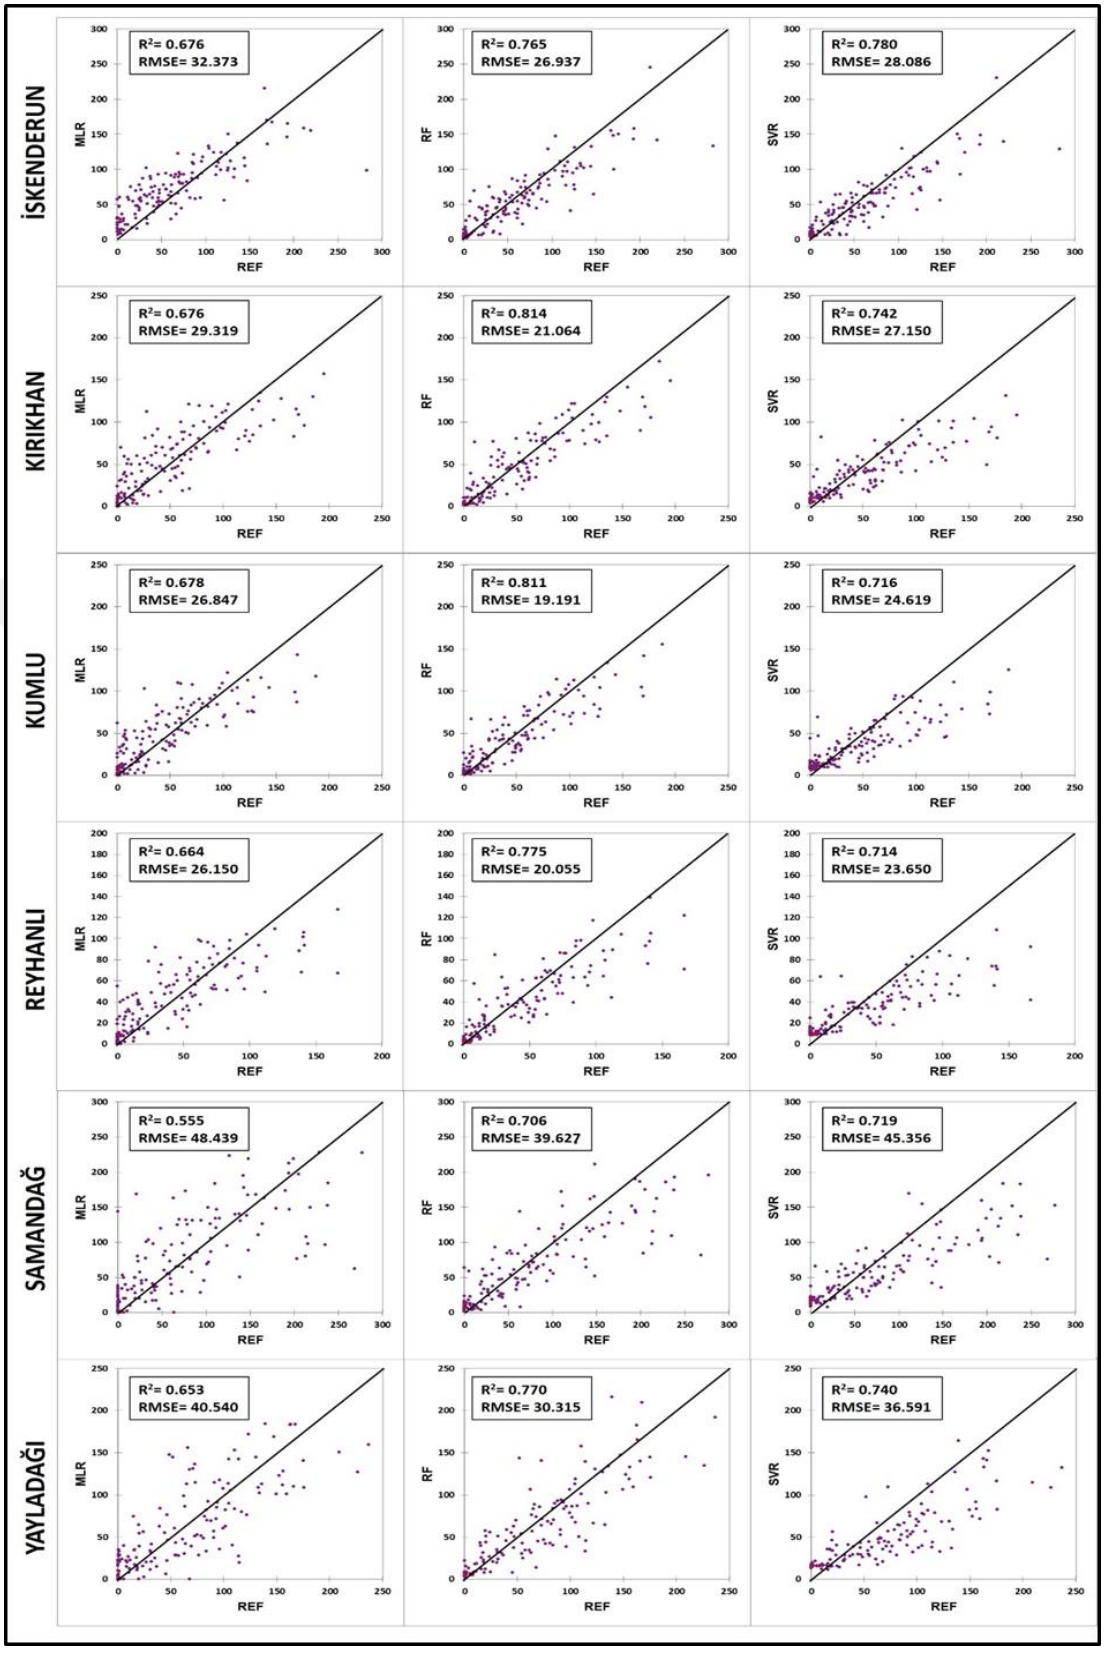
İstasyonlar	MLR			RF			SVR		
	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE	PBIAS	NRMSE	NSE
Altınözü	19.84	0.59	0.65	13.53	0.46	0.78	-4.42	0.54	0.71
Antakya	24.90	0.66	0.57	8.34	0.50	0.75	-13.75	0.59	0.65
Belen	33.85	0.64	0.58	17.02	0.48	0.77	-3.55	0.52	0.73
Dörtyol	27.22	0.66	0.57	13.19	0.53	0.71	-5.92	0.60	0.64
Erzin	29.92	0.61	0.62	14.96	0.44	0.81	3.76	0.47	0.78
Hassa	30.48	0.62	0.62	15.09	0.49	0.76	-6.95	0.58	0.66
İskenderun	-15.76	0.60	0.64	8.31	0.50	0.75	15.36	0.52	0.73
Kırıkhan	23.20	0.62	0.62	7.85	0.44	0.80	-6.10	0.57	0.67
Kumlu	20.51	0.62	0.61	6.82	0.44	0.80	-6.64	0.57	0.67
Reyhanlı	21.08	0.64	0.58	10.59	0.49	0.76	-4.06	0.58	0.66
Samandağ	-6.29	0.68	0.54	11.10	0.56	0.69	23.21	0.64	0.59
Yayladağı	28.79	0.66	0.57	9.69	0.49	0.76	5.05	0.59	0.65

***Yeşil: Çok İyi, Sarı: İyi, Turuncu: Kabul Edilebilir, Kırmızı: Kabul Edilemez**

Çizelge 4.14'ten elde edilen sonuçlara göre ölçek küçültme modellerinin genel olarak kabul edilebilir performans gösterdikleri görülmektedir. Ancak, makine öğrenmesi yöntemlerinin, MLR yöntemine göre çok daha başarılı oldukları belirlenmiştir.



Şekil 4.17. Ölçek küçültme modellerinin Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa yağış miktarı tahminleri için saçılım grafikleri



Şekil 4.18. Ölçek küçültme modellerinin İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı yağış miktarı tahminleri için saçılım grafikleri

Genel olarak, modellerin ortalama NRMSE değerleri RF için 0.49, SVR için 0.56 ve MLR için ise 0.63 olarak belirlenmiştir. Moriasi ve ark. (2007) performans metrikleri değerlendirme tablosuna göre bu değerler, RF ölçek küçültme modellerinin "Çok İyi", SVR ölçek küçültme modelinin "İyi" ve MLR ölçek küçültme modelinin "Kabul Edilebilir" derece ile tahmin performansı gösterdiği belirlenmiştir. NSE performans metriği için de yine NRMSE metriğine benzer olarak; RF modeli ortalama 0.76 ile "Çok İyi", SVR modeli 0.68 ile "İyi" ve MLR modeli 0.60 ile "Kabul Edilebilir" olarak belirlenmiştir. Modellerin tahmin performanslarının yanlılıkları ise PBIAS değerlerine göre RF ve SVR modelinin başarılı (PBIAS<25) olduğu Çizelge 4.14'te görülmektedir. Ancak, MLR ölçek küçültme modelinden elde edilen tahminlerin, izin verilen yanlılık değer aralığından genel olarak fazla olduğu belirlenmiştir. Bu değerlendirme sonuçlarına göre, RF ölçek küçültme modelinin diğer modellere göre daha başarılı olduğu sonucuna varılmıştır. Bu nedenle oluşturulan bu modeller, çalışma kapsamında iklim modellerinden farklı senaryolar için elde edilecek olan gelecek yağış tahminlerine ölçek küçültme uygulanması amacıyla kullanılmasına karar verilmiştir.

Genellikle, yağış tahminleri için oluşturulan ölçek küçültme modelleri sıcaklık tahminlerinde olduğu kadar başarılı performans göstermemektedirler (Ahmed ve ark., 2015). Ölçek küçültme modelleri, özellikle kurak bölgelerde yağış rejiminin düzensiz olmasından dolayı yüksek değerleri olduğundan daha düşük tahmin etmektedir (Ahmed ve ark., 2019). Yaptığımız çalışma sonucunda elde ettiğimiz bulgularda benzer sonuçlar gözlemlenmiştir. Bu nedenle, gözlem istasyonlarından elde edilen veriler ve ölçeği küçültülmüş yağış miktarı arasında sıcaklık tahminlerinde olduğu gibi mükemmel bir eşleşme elde etmek asla mümkün değildir (Nashwan ve ark., 2020; Salman ve ark., 2022).

Goly ve ark. (2014), aylık yağış verilerine uyguladıkları SVR ölçek küçültme modeli ile R^2 değerini 0.61 ve RMSE değerini 56.504 olarak hesaplamışlardır. Noor ve ark. (2020), Batı Malezya'da yaptıkları çalışmada, KİM'lere ölçek küçültme yöntemi uygulamak için RF algoritmasının günlük yağış miktarı tahmininde kullanılabilirliğini değerlendirmişlerdir. Gözlem verisi olarak çalışma alanında farklı noktalarda bulunan 19 gözlem istasyonunun yağış verilerini kullanmışlardır. Sonuçlar, modellerin tüm gözlenen istasyonlarda yağış miktarını yüksek bir doğrulukla tahmin ettiğini ortaya koymaktadır. Modellerin RMSE değeri 7.4 ve 41.7 arasında, PBIAS değeri -0.3 ve 10.1 arasında, NSE değeri 0.81 ve 0.99 arasında ve R^2 değeri 0.89 ve 0.99 arasında bulunmuştur. Zhao ve

ark. (2021), Çin'de 12 farklı istasyon için iklim modellerinin ölçek küçültme yöntemi olarak SVR, RF ve kuantil regresyon yöntemlerini karşılaştırmışlardır. Aylık yağış miktarları için gerçekleştirdikleri çalışmada bizim elde ettiğimiz sonuçlara benzer olarak RF yönteminin R^2 değerini 0.66-0.89 ve RMSE değerini ise 27.68-49.11 arasında hesaplamışlar ve diğer ölçek küçültme yöntemlerinden daha başarılı olduğunu açıklamışlardır. Güven ve Pala (2022), Göksun havzasında gerçekleştirdikleri çalışmada yağış miktarı için SVR ile oluşturdukları modelde R^2 değerini 0.62 olarak belirlemişler ve model tahminlerini kabul edilebilir bulmuşlardır. Ölçek küçültme yöntemi ile yapılan çalışmalar incelenmiş ve çalışmamızda elde ettiğimiz sonuçlarımızın literatür ile uyumlu olduğu belirlenmiştir.

4.4. Hatay İli için Farklı Senaryolar Altında Gelecek İklim Değişikliklerini Değerlendirme Sonuçları

4.4.1. İklim Değişikliğinin Sıcaklığa Olası Etkilerinin Tahmini ve Değerlendirme Sonuçları

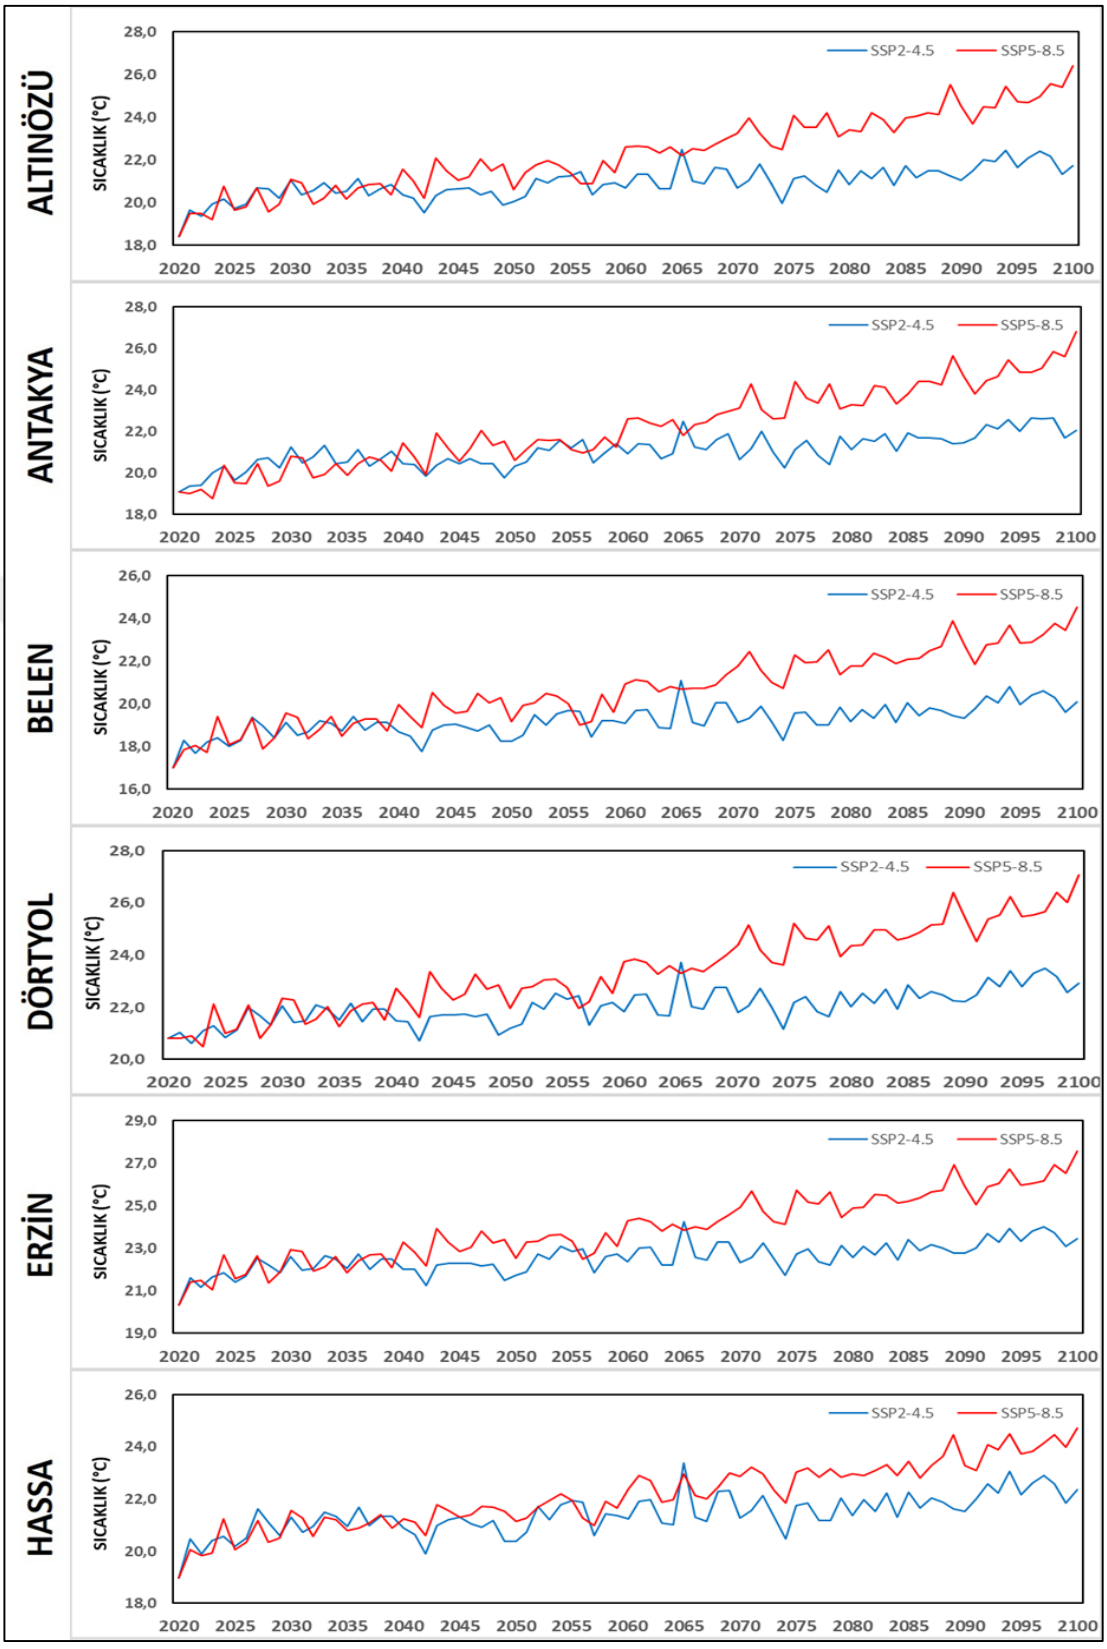
Hatay ili için EC-EARTH3 modelinden SSP2-4.5 ve SSP5-8.5 senaryolarına göre 2020-2100 yılları arası için elde edilen maksimum ve minimum sıcaklık tahminleri Çizelge 4.15'te verilmiştir. Bu sonuçlara göre oluşturulan yıllık ortalama sıcaklık-zaman serisi grafikleri Şekil 4.19 ve Şekil 4.20'de verilmiştir. Sonuçlar, SSP2-4.5 ve SSP5-8.5 senaryoları altında Hatay ilinde yıllık ortalama sıcaklıkta önemli ölçüde artan değişikliklerin olacağını göstermiştir. Ayrıca, her iki senaryo için Hatay genelinde 2060 yılına kadar sıcaklık artış eğiliminde olduğu belirlenirken, sera gazı salınımının sınırlandırıldığı SSP2-4.5 senaryosuna göre 2060 yılından sonra sıcaklıktaki artış hızının azalma gösterdiği belirlenmiştir.

Çizelge 4.15'te verilen sıcaklık ortalamaları incelendiğinde, Hatay ilinde yakın (2020-2060) ve uzak (2060-2100) gelecek dönemlerde SSP2-4.5 senaryosu için sırasıyla 2.1°C ve 2.9°C, SSP5-8.5 senaryosu için ise sırasıyla 2.4°C ve 5.2°C'lik sıcaklık artışı tahmin edilmiştir. Her iki senaryoya göre yapılan tahminlerde en yüksek sıcaklık artışlarının İskenderun, Dörtyol ve Erzin istasyonlarında gerçekleşeceği tahmin edilmiştir. Elde edilen bu sonuçların daha önce yapılmış benzer çalışmalarla uyumlu olduğu görülmüştür (Mesbahzadeh ve ark., 2020; Radmanesh ve ark., 2022).

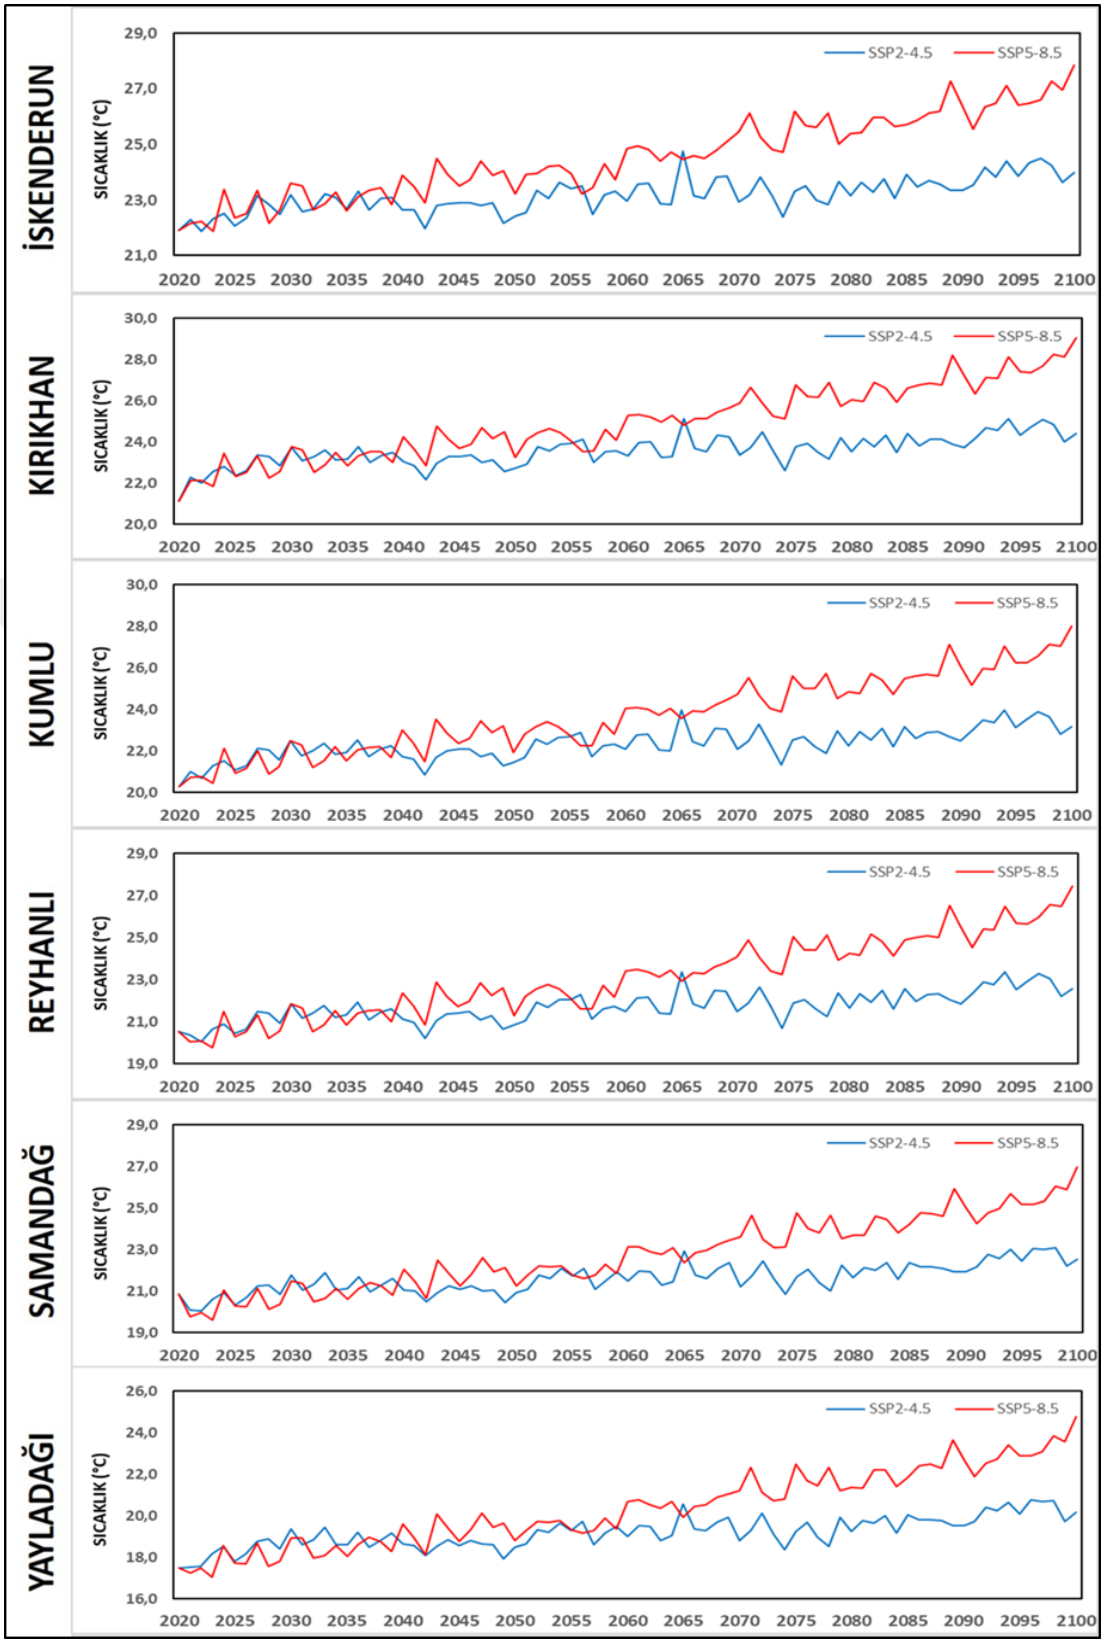
Çizelge 4.15. Yakın (YG) ve uzak gelecek (UG) dönemler için iki farklı senaryoya göre elde edilen sıcaklık tahmin ortalamaları

İstasyon	Geçmiş	SSP2-4.5 YG	SSP2-4.5 UG	SSP5-8.5 YG	SSP5-8.5 UG
Altınözü	18.4	20.5	21.3	20.9	23.8
Antakya	18.9	20.6	21.6	20.7	23.8
Belen	16.4	18.8	19.6	19.3	22.1
Dörtyol	19.5	21.6	22.4	22.1	24.7
Erzin	19.9	22.2	23.0	22.7	25.2
Hassa	18.6	21.0	21.9	21.2	23.2
İskenderun	20.6	22.8	23.5	23.4	25.7
Kırıkhan	21.0	23.2	24.0	23.6	26.4
Kumlu	19.8	21.9	22.8	22.2	25.2
Reyhanlı	19.2	21.3	22.2	21.6	24.6
Samandağ	19.6	21.2	22.1	21.3	24.2
Yayladağı	17.0	18.7	19.7	18.8	21.9
Ortalama	19.1	21.2	22.0	21.5	24.2

IPCC (2007) tarafından Akdeniz bölgesinde sıcaklıkların, 2050 yılına kadar 2-3°C ve 2100 yılına kadar ise 3-5°C arasında artışların beklendiği bildirilmiştir. Çalışmada elde ettiğimiz bulguların IPCC raporunun sonuçları ile uyumlu olduğu görülmüştür. Bozkurt ve Sen (2013), Fırat-Dicle Havzası için yaptıkları benzer çalışmada sıcaklıktaki artışın 2041–2070 için 2.1°C (düşük emisyon senaryosu, SRES B1) ve 4.1°C (yüksek emisyon senaryosu, SRES A1FI), 2071–2099 yılları arası için ise 2.6°C ve 6.1°C arasında değişmesini öngörmüşlerdir. Görgüner ve ark. (2019), Gediz havzası için yüzyıl ortası (2045–2072) ve yüzyıl sonu (2073–2100) dönemleri için yıllık ortalama sıcaklıkta sırasıyla 1.1°C ve 2.2°C bir artış olmasını tahmin etmişlerdir. RCP4.5 ve RCP8.5 senaryoları karşılaştırıldığında ise, RCP8.5 senaryolarının, RCP4.5 senaryolarına göre ortalama olarak havza ölçeğindeki sıcaklıklarda daha büyük bir artış tahmin ettiğini açıklamışlardır. Bağçacı ve ark. (2021), yaz mevsimindeki sıcaklık artışının uzun vadede Türkiye genelinde SSP2-4.5'e göre 2-3.5°C aralığında olacağını ve SSP5–8.5 için ise 6.5°C'ye kadar artış olabileceğini tahmin etmişlerdir. Supharatid ve Nafung (2021) Güneydoğu Asya'da 21. yy'da 1.99–4.29°C (%9.62–18.43) ısınma öngörmüşlerdir. Majdi ve ark. (2022) Orta Doğu ve Kuzey Afrika bölgesi için yaptıkları benzer çalışmada, SSP5-8.5 senaryosuna göre 2020–2049 döneminde sıcaklıkların ortalama 0.8-1.6°C ve 2050-2079 yılları arasında ise yaklaşık 2.1-3.3°C artacağını öngörmüşlerdir. Sonuç olarak, çalışmamızda elde edilen sonuçların literatür ile uyumlu olduğu görülmüştür.



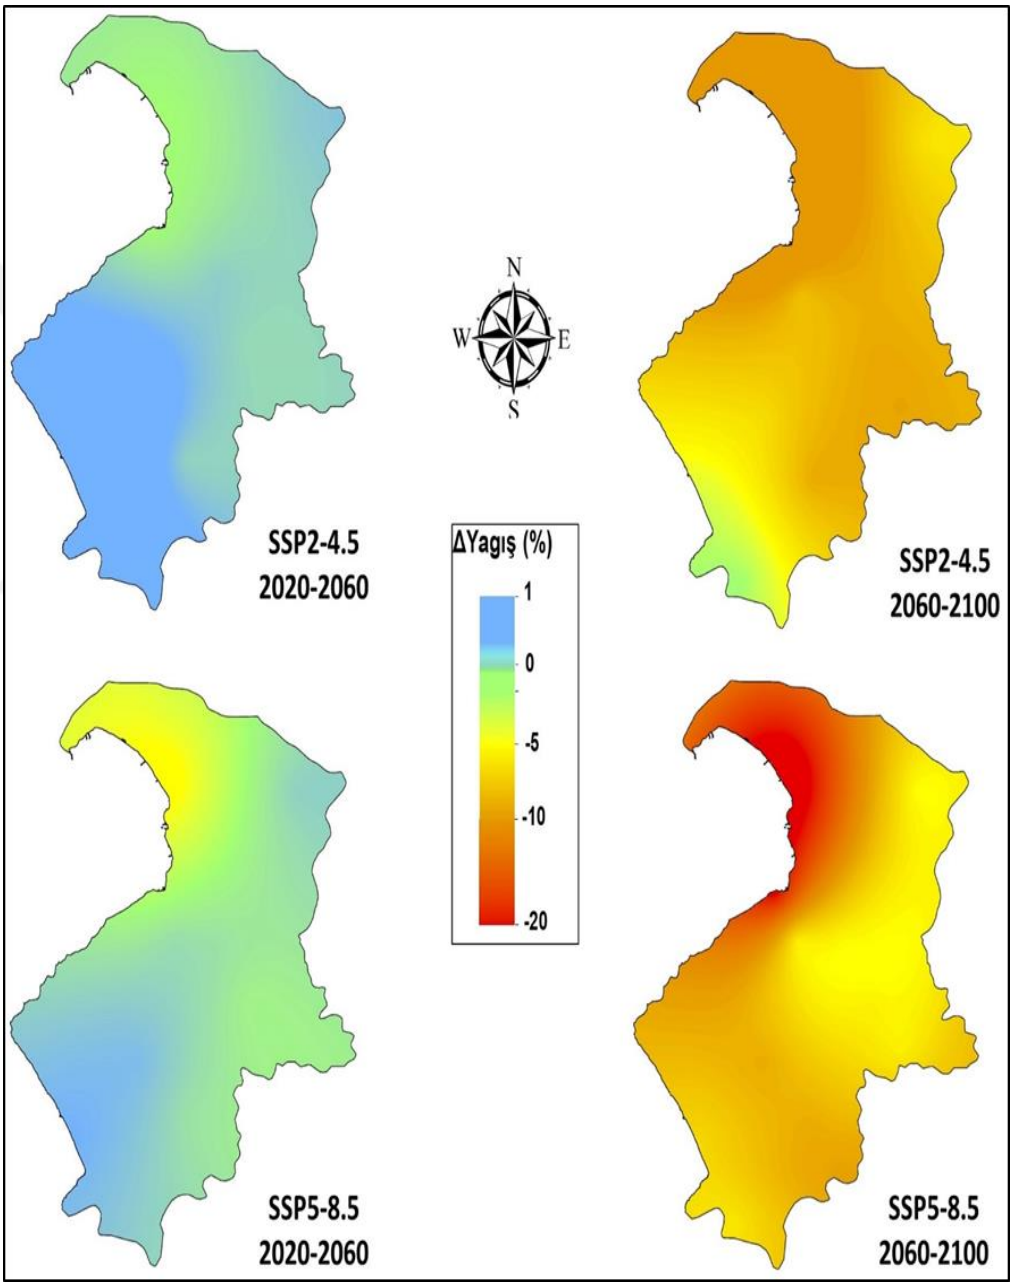
Şekil 4.19. İki farklı senaryoya göre Altınözü, Antakya, Belen, Dörtyol, Erzin ve Hassa ilçelerinin gelecek yıllar için tahmin edilen sıcaklık grafikleri



Şekil 4.20. İki farklı senaryoya göre İskenderun, Kırıkhan, Kumlu, Reyhanlı, Samandağ ve Yayladağı ilçelerinin gelecek yıllar için tahmin edilen sıcaklık grafikleri

4.4.2. İklim Değişikliğinin Yağış Miktarına Olası Etkilerinin Tahmini ve Değerlendirilmesi

Hatay ili için EC-EARTH3 modelinden SSP2-4.5 ve SSP5-8.5 senaryolarına göre yakın (2020-2060) ve uzak gelecek (2060-2100) dönemleri için elde edilen yıllık yağış miktarlarının tahmin edilen yıllık değişim yüzdeleri Şekil 4.21'de verilmiştir.



Şekil 4.21. Hatay İlinde SSP2-4.5 ve SSP5-8.5 senaryolarına göre yakın (2020-2060) ve uzak (2060-2100) gelecek için yıllık yağış miktarında öngörülen değişim yüzdeleri

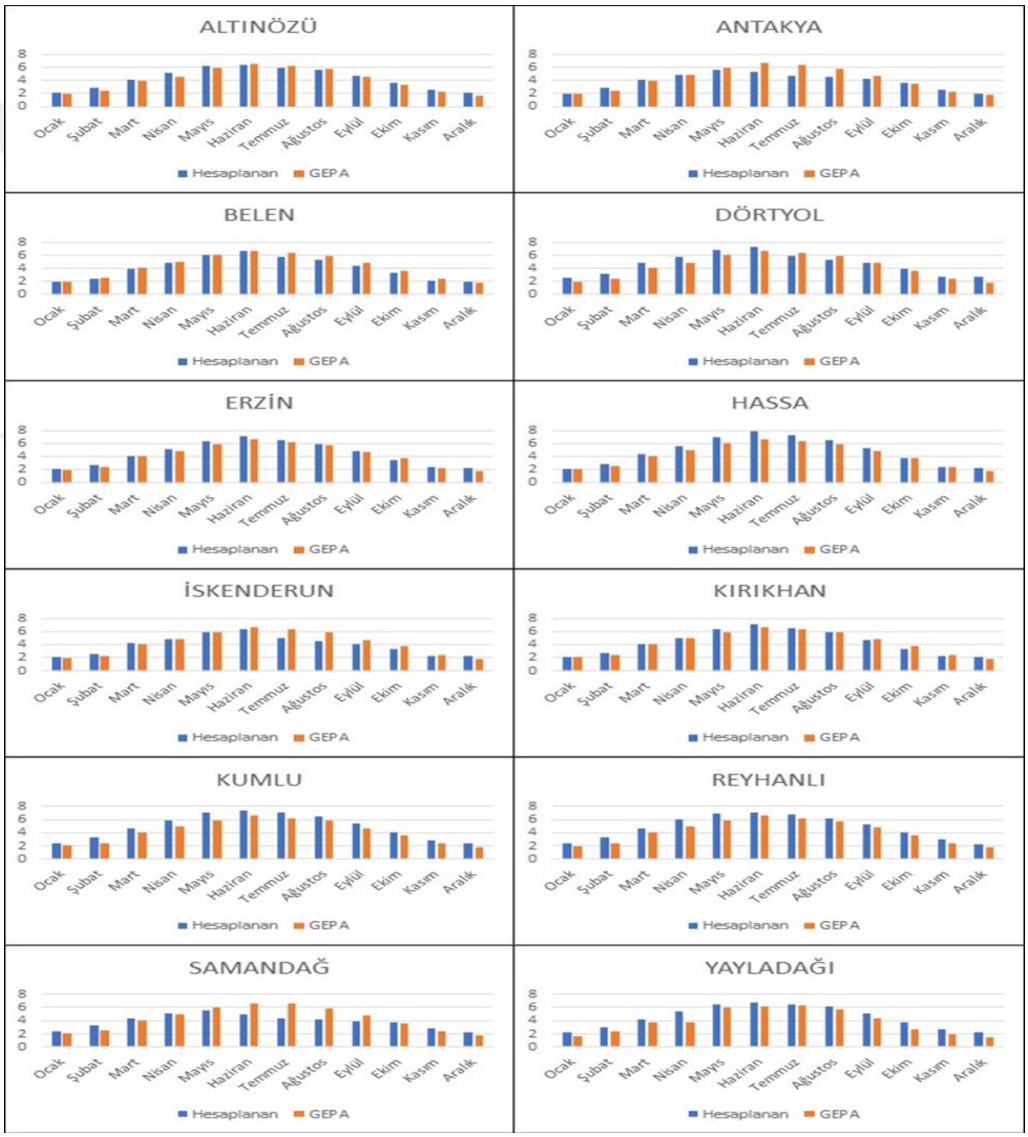
Şekil 4.21'de verilen dağılım haritaları incelendiğinde sera gazı salınım emisyonlarındaki artışın gelecek dönemlerdeki yıllık yağış miktarındaki gözlenecek değişimleri önemli miktarda etkileyebileceği belirlenmiştir. Hatay ilinin güneyi ve batısında her iki senaryo için yakın gelecekte (2020-2060) yağışta artış (%0-1) olacağı öngörülmüştür. Düşük sera gazı salınım emisyonu senaryosunda, bu artışın kötümser senaryoya göre yakın gelecekte daha geniş bir alanda gerçekleşeceği tahmin edilmiştir. Yağışta öngörülen bu artışın, yüksek sıcaklığın yüzeydeki nemi hızla buharlaştırmasından kaynaklanacağı tahmin edilmektedir (Trenberth, 2011). Ancak, Hatay ilinin kuzeyi ve doğusundaki bölgelerde yakın gelecekte yıllık yağış miktarında yaklaşık %5' oranında azalma olabileceği öngörülmüştür. Uzak gelecek (2060-2100) için her iki senaryoya göre elde edilen tahminler ise yıllık yağış miktarında çok şiddetli azalmalar öngörmektedir. Şekil 4.21 incelendiğinde özellikle Hatay ilinin batı ve güney bölgelerinde yıllık yağışta iyimser senaryoya göre yaklaşık %10 ve kötümser senaryoya göre ise yaklaşık %20'lere varan bir azalma olacağı öngörülmektedir.

Dünyanın birçok bölgesi için gerçekleştirilen benzer çalışmalar incelendiğinde de elde ettiğimiz bulguları destekleyecek sonuçlara ulaşıldığı belirlenmiştir. Seyhan Nehri Havzası'nda yapılan ICCAP çalışması 2070 yılında iklim değişikliğinin etkileri nedeniyle su kaynaklarının %30 oranında azalacağını göstermiştir (Kanber ve ark., 2008). Bozkurt ve Sen (2013) Fırat-Dicle Havzası için yaptıkları benzer çalışmada yüksek emisyon senaryosu (SRES-A1FI) için yağış miktarının bu yüzyılın sonuna kadar %33 oranında azalmasını öngörürmüşlerdir. Dubrovský ve ark. (2014), Akdeniz Havzası'nda bulunan bölgelerde yağış miktarındaki yıllık değişim açısından %5-30 arasında bir düşüş beklendiğini açıklamışlardır. Homsi ve ark. (2020), Suriye için yaptıkları çalışmada yıllık yağış miktarlarının en çok kıyı bölgelerinde azalış göstereceğini ve bu azalışların yaklaşık %30-85.2 arasında olacağını öngörmüşlerdir. Türkiye'de Göksun Havzası'nda Güven ve Pala (2022) ve İran'da Radmanesh ve ark. (2022) tarafından gerçekleştirilen benzer çalışmalarda da yağış miktarının 21. yy sonlarına doğru azalma göstereceği bildirilmiştir. Salehie ve ark. (2022) Orta Asya'da bulunan Amu Nehir Havzası için gerçekleştirdikleri çalışmada, yıllık yağışlarda 2060-2100 yılları arasında SSP2-4.5 senaryosu için yaklaşık %9 ve SSP5-8.5 senaryosu için yaklaşık %12 oranında azalma gerçekleşebileceğini öngörmüşlerdir. Ayrıca, sera gazı emisyon miktarındaki artışın yağış miktarındaki azalma oranının şiddetini arttıracağını öngörmüşlerdir.

4.5. Bitkisel Üretim Modelinin Pamuk ve 1. Ürün Mısır Bitkisi İçin Kalibrasyonu ve Doğrulama Sonuçları

4.5.1. Güneş Radyasyonu Hesaplama Sonuçları

Gözlem istasyonlarından elde edilen ölçüm verileri kullanılarak yapılan güneş radyasyonu hesaplama sonuçları ve GEPA verileri ile karşılaştırılması Şekil 4.22'de verilmiştir. Şekil 4.22 incelendiğinde hesaplanan değerler ile GEPA verileri arasındaki uyumun yüksek olduğu görülmüştür.



Şekil 4.22. MGM ölçüm istasyonlarından elde edilen verilerle hesaplanan güneş radyasyonu değerlerinin GEPA verileriyle karşılaştırması

İki veri setinin istatistiksel performans metrikleri ile karşılaştırıldığında aralarındaki ilişki ve doğruluğun çok yüksek olduğu görülmüştür (Çizelge 4.16). Hesaplama yöntemi olarak kullanılan H-S eşitliğinin kullanılabilirliği, GEPA atlasından elde edilen uzun yıllık aylık ortalamaların kıyaslanması ile değerlendirilmiştir. Değerlendirme sonucunda bu eşitliğin kullanımı ile hesaplanan güneş radyasyonu değerlerinin GEPA değerleri ile oldukça benzer olduğu belirlenmiştir.

Çizelge 4.16. Hesaplanan güneş radyasyonu değerlerinin gözlem değerleri ile istatistiksel olarak karşılaştırma sonuçları

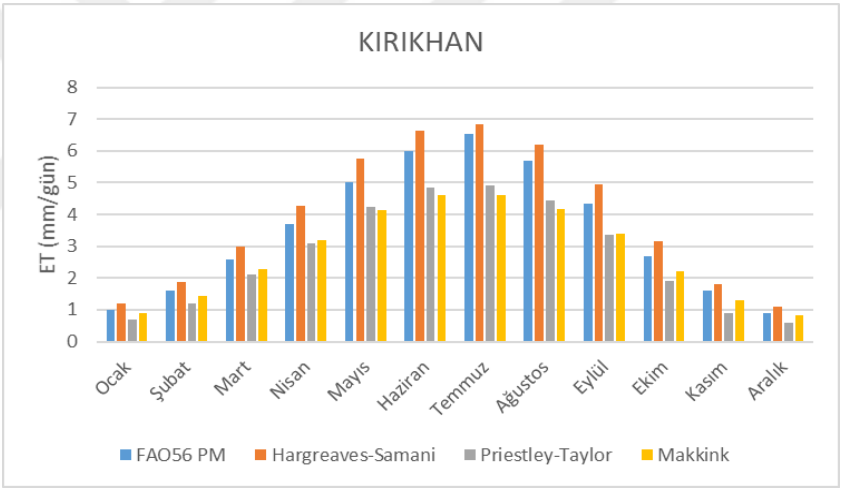
İstasyonlar	**R^2**	**C'**	
Altınözü	0.98	0.98	Çok İyi
Antakya	0.91	0.89	Çok İyi
Belen	0.98	0.98	Çok İyi
Dörtyol	0.93	0.93	Çok İyi
Erzin	0.99	0.99	Çok İyi
Hassa	0.99	0.97	Çok İyi
İskenderun	0.91	0.92	Çok İyi
Kırıkhan	0.99	0.99	Çok İyi
Kumlu	0.99	0.95	Çok İyi
Reyhanlı	0.98	0.95	Çok İyi
Samandağ	0.75	0.74	İyi
Yayladağı	0.96	0.92	Çok İyi

4.5.2. Referans Evapotranspirasyon Hesaplama Sonuçları

Meteoroloji Genel Müdürlüğü Hatay ili Kırıkhan gözlem istasyonundan 2014-2020 yılları için elde edilen günlük meteorolojik veriler kullanılarak hesaplanan aylık ortalama ET_0 değerleri Çizelge 4.17'de ve Şekil 4.23'te verilmiştir. Çizelge 4.17 incelendiğinde, FAO56 PM yöntemi ile elde edilmiş en yüksek ET_0 değeri 6.52 mm ay^{-1} ile Temmuz ayı için elde edilirken, en düşük ET_0 değeri 0.91 mm ay^{-1} ile Aralık ayı için hesaplanmıştır. Tüm yöntemler referans değer olarak kabul edilen FAO56 PM yöntemi sonuçları ile karşılaştırıldığında en yüksek ve en düşük aylık ET_0 değerleri aynı aylar için elde edilmiştir. Çizelge 4.17 ve Şekil 4.23 incelediğinde FAO56 PM yöntemine en yakın sonuçların Hargreaves-Samani yönteminde elde edildiği belirlenmiştir.

Çizelge 4.17. Meteorolojik gözlem istasyonunun 2015-2020 verileri ile hesaplanan ET_0 değerleri

Aylar	FAO56 PM	Hargreaves-Samani	Priestley-Taylor	Makkink
Ocak	1.01	1.20	0.69	0.90
Şubat	1.61	1.87	1.19	1.42
Mart	2.57	3.00	2.10	2.29
Nisan	3.70	4.28	3.10	3.20
Mayıs	5.00	5.76	4.23	4.14
Haziran	5.98	6.62	4.85	4.59
Temmuz	6.52	6.83	4.92	4.62
Ağustos	5.69	6.19	4.43	4.15
Eylül	4.36	4.95	3.37	3.39
Ekim	2.70	3.15	1.90	2.23
Kasım	1.62	1.80	0.91	1.31
Aralık	0.91	1.11	0.59	0.82



Şekil 4.23. Ampirik ET_0 hesaplama yöntemlerinin karşılaştırılması

Ampirik ET_0 hesaplama yöntemlerinin istatistiki analiz sonuçları Çizelge 4.18'de gösterilmiştir. Çizelge 4.18'de verilen istatistiksel analiz sonuçları incelendiğinde üç yönteminde, FAO 56 yöntemi ile yüksek bir uyum içinde olduğu görülmüştür (R^2>0.98). Genel olarak, tüm yöntemler için PBIAS değerlerinin kabul edilebilir düzeyde yüksek veya düşük oranda tahmin etme eğiliminde olduğu görülmektedir. Ancak, H-S eşitliği kullanılarak elde edilen sonuçların diğer ikisine kıyasla daha düşük yanlılık hatası gösterdiği görülmüştür. Tahmin doğruluklarının performansı değerlendirildiğinde ise, üç yönteminde yine çok iyi performans gösterdiği C' ve NSE değerlerinin yüksek değerde

hesaplanmasıyla belirlenmiştir. En yüksek performansı NSE değeri 0.94 ve C' değeri 0.98 ile H-S yöntemi göstermiştir.

Çizelge 4.18. Ampirik ET_0 hesaplama yöntemlerinin istatistiksel analiz sonuçları

Performans Metrikleri	**Hargreaves-Samani**	**Prisetley-Taylor**	**Makkink**
R^2	0.996	0.989	0.984
RMSE	0.129	0.241	0.256
PBIAS	-12.267	22.472	20.622
C'	0.984	0.937	0.918
NSE	0.942	0.797	0.770

Dünyanın birçok bölgesinde yaygın bir şekilde kullanılan ve güvenilir ET_0 tahminleri yaptığı kabul edilen FAO 56 yönteminin çok fazla değişken kullanıyor olması oldukça büyük bir sorundur. Bu nedenle çalışmamızda gelecek dönemlerin ET_0 değerlerini hesaplarken bu yöntemi kullanmak oldukça zordur. Bu sebeple elde edilebilir değişkenler kullanılarak ET_0 hesaplayabilmeye olanak sağlayan yöntemler değerlendirilmiştir. Bu yöntemlerden FAO 56 yönteminin hesaplamalarına istatistiksel olarak en yakın sonuçları veren H-S yöntemi olmuştur. Buna bağlı olarak, çalışmanın ilerleyen aşamalarında gelecek ET_0 değerleri H-S eşitliği kullanılarak hesaplanmıştır.

4.5.3. Toprak Analizi Sonuçları

Tez çalışmamız da ürün veriminin tahmin edilmesi için kullandığımız AquaCrop modelinin ihtiyaç duyduğu toprak özellikleri dosyasını oluşturmak amacıyla, gerekli analizler gerçekleştirilmiş ve Çizelge 4.19'da verilmiştir. Elde edilen sonuçlar kullanılarak her çalışma alanı için farklı toprak dosyaları oluşturulmuş ve çalışma alanlarının toprak özellikleri modele tanıtılmıştır. İlk olarak, arazide açılan toprak profilinin her 30 cm'lik katmanından üç adet alınan bozulmamış toprak örneklerinin hacim ağırlığı belirlenmiştir. Tüm katmanlar için belirlenen hacim ağırlığı değerlerinin 1.55 g cm^{-3}'den düşük olduğu görülmüştür. Analiz sonucunda toprakların herhangi bir şekilde kök gelişmesini olumsuz etkileyecek bir kütle yoğunluğuna sahip olmadığı literatür bilgilerine dayanarak belirlenmiştir (Kaçar, 2016).

Her katmandan kürekle alınan 1-2 kg bozulmuş toprak örnekleri laboratuvarda analize hazırlandıktan sonra Bouyoucos hidrometre yöntemi kullanılarak örneklerin

bünye dağılımı ve tekstür sınıfları belirlenmiştir. Sonuçlar incelendiğinde genel olarak, arazilerin killi tınlı bir bünyeye sahip oldukları görülmüştür. Ayrıca, ağır ve orta bünyeli olan toprak örneklerinde tarla kapasitesi ve solma noktası beklenildiği gibi yüksek çıkmıştır. Toprak örneklerinden elde edilen hidrolik iletkenlik değerleri; killi tınlı topraklarda 64-181 mm gün^{-1}, tınlı topraklarda ise 260-500 mm gün^{-1} olarak belirlenmiştir. Toprak örneklerinden elde edilen bu değerlerinin literatürde belirlenmiş olan sonuçlar arasında olduğu görülmüş ve yapılan analizlerin doğruluğu kabul edilmiştir (Rawls ve ark., 1998; Saxton ve Rawls, 2006).

Çizelge 4.19. Çalışma alanlarının analiz edilen toprak özellikleri sonuçları

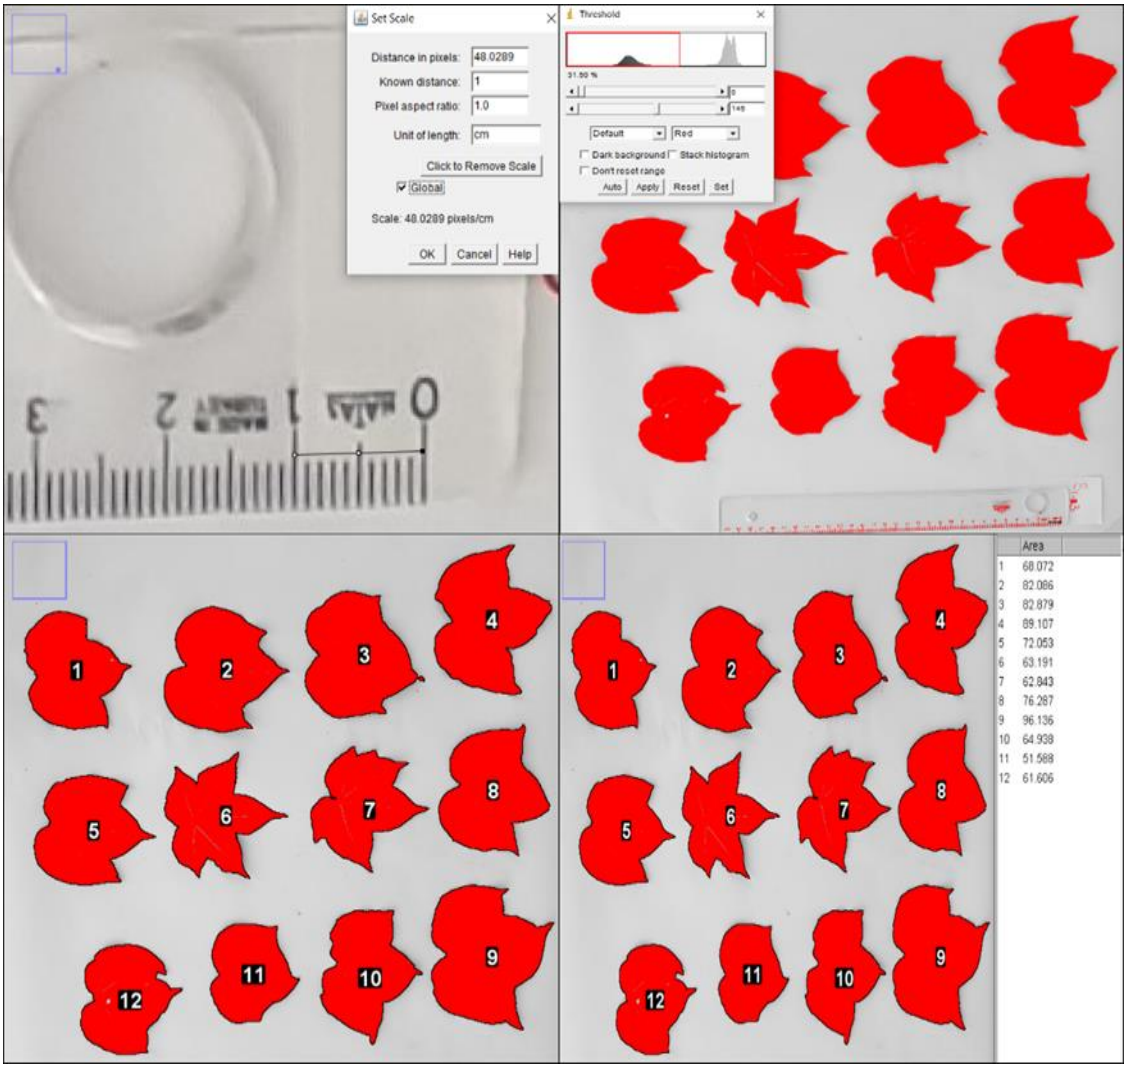
Araziler	D (cm)	As (g cm^{-3})	TK (%)	SN (%)	Por (%)	Kil (%)	Kum (%)	Bünye	k (mm gün^{-1})
Abalaklı Köyü	0-30	1.44 ±0.03	35.20	21.90	45.57	24.32	39.46	Tınlı	267.36
	30-60	1.51 ±0.04	25.20	13.60	42.91	22.87	43.62	Tınlı	300.00
	60-90	1.54 ±0.05	22.70	11.70	41.91	17.65	51.34	Tınlı	500.16
	90-120	1.60 ±0.04	30.30	16.50	39.65	21.23	40.22	Tınlı	339.60
Danaahmetli Köyü	0-30	1.49 ±0.03	28.00	16.90	43.65	29.57	41.94	Killi Tınlı	106.56
	30-60	1.47 ±0.10	29.60	16.70	44.48	29.89	33.15	Killi Tınlı	112.56
	60-90	1.56 ±0.10	28.10	15.80	41.18	28.01	33.89	Killi Tınlı	73.68
	90-120	1.38 ±0.05	32.50	18.30	48.09	33.52	28.49	Killi Tınlı	124.8
Mahmutlu Köyü	0-30	1.38 ±0.08	32.10	18.60	47.92	33.24	33.52	Killi Tınlı	149.52
	30-60	1.42 ±0.03	33.80	20.70	46.43	37.14	28.57	Killi Tınlı	64.32
	60-90	1.30 ±0.03	34.80	20.20	50.98	36.52	26.97	Killi Tınlı	154.08
	90-120	1.32 ±0.03	33.40	18.60	50.25	33.43	27.58	Killi Tınlı	195.84
Ahrazlı Köyü	0-30	1.27 ±0.02	35.40	21.80	52.17	38.89	30.56	Killi Tınlı	161.28
	30-60	1.45 ±0.05	32.50	20.20	45.35	36.21	33.15	Killi Tınlı	65.28
	60-90	1.36 ±0.06	31.70	18.60	48.52	33.52	35.75	Killi Tınlı	181.44
	90-120	1.51 ±0.05	29.20	17.20	43.07	29.73	35.14	Killi Tınlı	93.6

4.5.4. Bitkilerin Maksimum Bitki Örtü Yüzeyi Yüzdelerinin Hesaplama Sonuçları

4.5.4.1. Pamuk Bitkisi Sonuçları

Her arazi için çiçeklenme dönemi boyunca haftada bir olacak şekilde arazilerden rastgele olarak altı bitki örneği alınmıştır. Alınan bu bitki örneklerinin yaprakları ayırıldıktan sonra bitki yaprakları beyaz bir zemin üzerine yerleştirilerek dijital görüntüleri alınmış ve bu görüntüler bilgisayar ortamında ImageJ® görüntü işleme programına aktarılmıştır. Dijital görüntüler yapraklarla birlikte fotoğraflanan cetvel yardımı ile kalibre edilmiştir. Daha sonra, Kırmızı-Yeşil-Mavi (RGB) renk modunda olan

görüntü 8 bit renk moduna çevrilmiş ve yaprakların sınır rengi kırmızı olacak şekilde eşik rengi ayarlanmıştır. Son olarak eşik rengi belirlenmiş olan yapraklar seçilerek yaprak alanları uygulamaya hesaplatılmıştır (Şekil 4.24). Görüntü işleme uygulaması ile elde edilen toplam yaprak alanlarının ortalamaları kullanılarak her arazi için yaprak alan indeksi belirlenmiş ve sonuçlar Çizelge 4.20'de verilmiştir. Elde edilen yaprak alan indeksi sonuçları kullanılarak hesaplanan maksimum bitki örtü yüzeyi yüzdeleri ise Çizelge 4.21.'de verilmiştir.



Şekil 4.24. Pamuk bitki örneklerinin yaprak alanlarının ImageJ® görüntü işleme programı ile hesaplanması

Çizelge 4.20. Pamuk bitki örneklerinden farklı tarihler için hesaplanan yaprak alan indeksleri

Arazi	Yaprak Alan İndeksi					
	Ekimden Sonra Geçen Gün Sayısı					
Abalaklı Köyü	**57 gün**	**64 gün**	**71 gün**	**78 gün**	**86 gün**	**93 gün**
	1.998	3.097	3.902	**5.197**	4.840	4.259
Danaahmetli Köyü	**51 gün**	**62 gün**	**71 gün**	**78 gün**	**84 gün**	**91 gün**
	1.237	2.545	3.808	**4.830**	4.370	3.839
Mahmutlu Köyü	**47 gün**	**54 gün**	**63 gün**	**70 gün**	**77 gün**	**84 gün**
	1.023	1.641	3.332	**4.067**	3.889	3.714
Ahrazlı Köyü	**49 gün**	**56 gün**	**63 gün**	**72 gün**	**79 gün**	**86 gün**
	1.126	1.795	3.076	3.697	**4.692**	4.105

Çizelge 4.21. Pamuk bitki örneklerinden farklı tarihler için hesaplanan maksimum bitki örtü yüzeyi yüzdesi değerleri

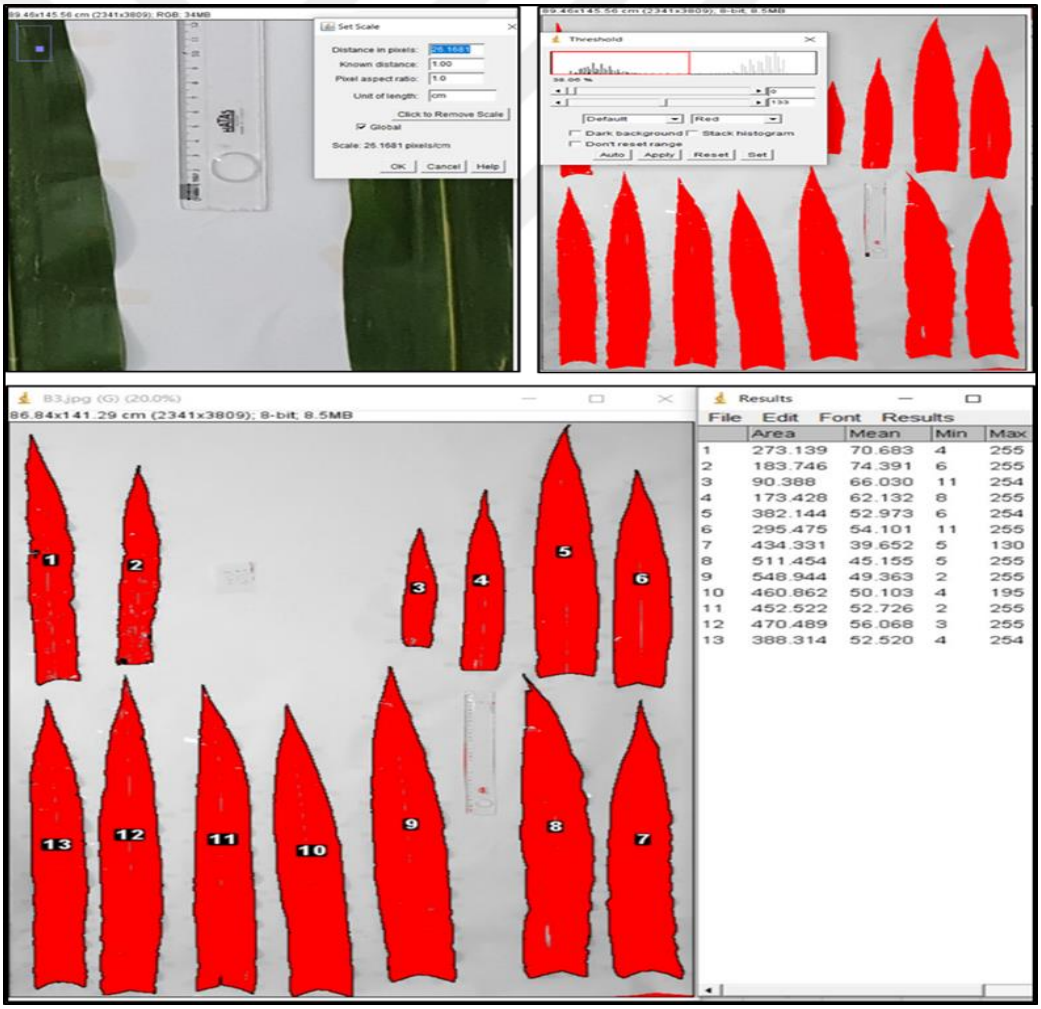
Arazi	Maksimum Bitki Örtü Yüzeyi Yüzdesi (%)					
	Ekimden Sonra Geçen Gün Sayısı					
Abalaklı Köyü	**57 gün**	**64 gün**	**71 gün**	**78 gün**	**86 gün**	**93 gün**
	0.785	0.908	0.950	**0.982**	0.976	0.962
Danaahmetli Köyü	**51 gün**	**62 gün**	**71 gün**	**78 gün**	**84 gün**	**91 gün**
	0.601	0.831	0.930	**0.969**	0.959	0.938
Mahmutlu Köyü	**47 gün**	**54 gün**	**63 gün**	**70 gün**	**77 gün**	**84 gün**
	0.545	0.717	0.923	**0.956**	0.950	0.943
Ahrazlı Köyü	**49 gün**	**56 gün**	**63 gün**	**72 gün**	**79 gün**	**86 gün**
	0.580	0.749	0.906	0.942	**0.973**	0.958

Çalışmamızda hesapladığımız maksimum yaprak alan indeksi değerleri (4.067-5.197), bitkilerin çiçeklenme döneminde elde edilmiş ve sonraki dönemlerde bu değerin azalmaya başladığı belirlenmiştir. Li ve ark. (2022), pamuk bitkileri için genellikle maksimum yaprak alan indeksi aralığının 3.6-5.5 olduğunu ve bu değerlerin bitkinin çiçeklenme döneminde elde edildiğini bildirmişlerdir. Çiçeklenme dönemi, fotosentetik aktivitenin en yüksek olduğu dönemdir. Bu durum yaprakların genişlemesi ve bitkinin genel büyümesinin hızlanmasını sağlamaktadır. Bu nedenle, yaprak alan indeksi maksimum değerini bu dönemde almaktadır. Çiçeklenme sonrası dönemde ise bitki enerji kaynaklarını ürün oluşumu için kullanmaya başlamaktadır. Bu süreçle birlikte, yeni yaprak üretimi azalmakta ve eski yapraklar da dökülmeye başlamaktadır. Böylece fotosentetik aktivite ve yaprak alan indeksi azalmaya başlamaktadır (Fan ve ark., 2023).

Çalışmamızda pamuk bitkisi yaprak alan indeksi için elde edilen değerlerin literatür ile uyumlu olduğu belirlenmiştir.

4.5.4.2. 1. Ürün Mısır Bitkisi Sonuçları

Her arazi için alınan örneklerin dijital görüntüsü alındıktan sonra bu görüntüler bilgisayar ortamında ImageJ® görüntü işleme programına aktarılmış ve görüntüler yapraklarla birlikte fotoğraflanan cetvel yardımı ile kalibre edilmiştir. Daha sonra, RGB renk modunda olan görüntü, 8 bit renk moduna çevrilmiş ve yaprakların sınır rengi kırmızı olacak şekilde eşik rengi ayarlanmıştır. Son olarak ise, eşik rengi belirlenmiş olan yapraklar seçilerek yaprak alanları uygulamaya hesaplatılmıştır (Şekil 4.25).



Şekil 4.25. 1. ürün mısır bitki örneklerinin yaprak alanlarının ImageJ® görüntü işleme programı ile hesaplanması

Görüntü işleme uygulaması ile elde edilen toplam yaprak alanlarının ortalamaları kullanılarak her arazi için yaprak alan indeksi belirlenmiş ve sonuçlar Çizelge 4.22'de verilmiştir. Elde edilen yaprak alan indeksi sonuçları kullanılarak hesaplanan maksimum bitki örtü yüzeyi yüzdeleri ise Çizelge 4.23'te verilmiştir.

Çizelge 4.22. 1. ürün mısır bitki örneklerinden farklı tarihler için hesaplanan yaprak alan indeksleri

Arazi	**Yaprak Alan İndeksi**						
	Ekimden Sonra Geçen Gün Sayısı						
Abalaklı Köyü	**36.gün**	**52.gün**	**80.gün**	**92.gün**	**95.gün**	**98.gün**	**102.gün**
	0.08	0.35	4.90	5.42	**6.24**	6.03	5.77
Danaahmetli Köyü	**27.gün**	**43.gün**	**75.gün**	**88.gün**	**91.gün**	**94.gün**	**97.gün**
	0.05	0.32	4.09	**5.77**	5.48	4.90	4.71
Mahmutlu Köyü	**35.gün**	**51.gün**	**79.gün**	**91.gün**	**94.gün**	**97.gün**	**100.gün**
	0.07	0.43	3.61	4.62	4.90	**4.92**	4.79
Ahrazlı Köyü	**21.gün**	**37.gün**	**71.gün**	**81.gün**	**85.gün**	**88.gün**	**91.gün**
	0.04	0.15	3.50	5.32	**5.54**	5.26	5.16

Çizelge 4.23. 1. ürün mısır bitki örneklerinden farklı tarihler için hesaplanan maksimum bitki örtü yüzeyi yüzdesi değerleri

Arazi	**Maksimum Bitki Örtü Yüzeyi Yüzdesi (%)**						
	Ekimden Sonra Geçen Gün Sayısı						
Abalaklı Köyü	**36.gün**	**52.gün**	**80.gün**	**92.gün**	**95.gün**	**98.gün**	**102.gün**
	0.03	0.14	0.94	0.96	**0.98**	0.97	0.97
Danaahmetli Köyü	**27.gün**	**43.gün**	**75.gün**	**88.gün**	**91.gün**	**94.gün**	**97.gün**
	0.02	0.12	0.90	**0.97**	0.96	0.94	0.93
Mahmutlu Köyü	**35.gün**	**51.gün**	**79.gün**	**91.gün**	**94.gün**	**97.gün**	**100.gün**
	0.02	0.17	0.87	0.93	0.94	**0.94**	0.94
Ahrazlı Köyü	**21.gün**	**37.gün**	**71.gün**	**81.gün**	**85.gün**	**88.gün**	**91.gün**
	0.01	0.05	0.86	0.96	**0.96**	0.95	0.95

Çalışmamızda 1. ürün mısır bitkileri için hesaplanan maksimum yaprak alan indeksi değerlerine (4.92-6.24) ekim tarihinden 88-97 gün sonra ulaşıldığı ve sonraki dönemlerde bu değerin azalmaya başladığı belirlenmiştir. Sharifi ve ark. (2014) yaprak alan indeksi değerinin, ekim tarihinden yaklaşık 90 gün sonra en yüksek değere ulaştığını ve daha sonra bu değerin azalmaya başladığını bildirmişlerdir. Bu azalmanın sebepleri arasında yaprakların yaşlanması ve bitkilerin birbirlerini gölgelemesi gibi faktörlerin etkili olduğunu bildirmişlerdir. Bonelli ve Andrade (2020), mısır bitkisinin optimal yaprak alan indeksi değerinin 3.0-6.5, Ahmed ve ark. (2021) maksimum yaprak alan indeksi değerini

4.0-6.0, Nazeri ve ark. (2021) yaprak alan indeksi değerinin 0.5-5.0 arasında değiştiğini bildirmişlerdir. Çalışmamızda 1. ürün mısır bitkisi yaprak alan indeksi için elde edilen değerlerin literatür ile uyumlu olduğu belirlenmiştir.

4.5.5. AquaCrop Modelinin Kütlü Pamuk Verimi ve Biyokütle Tahmin Performansının Değerlendirilmesi

AquaCrop modelinin pamuk bitkisinin biyokütle ve kütlü verimini tahmin edebilme performansını değerlendirmek için Kırıkhan'da farklı köylerde bulunan arazilerde gözlemler ve ölçümler yapılmıştır. Elde edilen gözlemler ve ölçümlerin sonucunda model arazi koşullarına göre kalibre edilmiş ve araziler için tahminlerde bulunmuştur. Pamuk bitkisi verim değerinin 2021 ve 2022 yılları için ölçülen ve tahmin edilen biyokütle ve kütlü verim değerleri karşılaştırılmış ve sonuçlar Çizelge 4.24'te gösterilmiştir. Kırıkhan'da bulunan arazilerde, arazi koşullarına kalibre edilmiş olan modelin pamuk bitkisi kütlü verimini en fazla %4.99 ve biyokütle verimini ise %5.42'lik bir sapma ile tahmin ettiği görülmüştür. Modelin genel performansının istatistiksel değerlendirilmesi ise Çizelge 4.25'te verilmiştir.

Çizelge 4.24. Kütlü pamuk verimi ve biyokütle veriminin tahmin ve ölçüm sonuçlarının karşılaştırılması

	YIL	Arazi	Ölçüm (t ha^{-1})	Tahmin (t ha^{-1})
Kütlü Verim	2021	Abalaklı	5.49	5.70
		Danaahmetli	5.16	5.22
		Mahmutlu	4.76	4.81
		Ahrazlı	4.80	4.72
	2022	Abalaklı	6.10	5.81
		Danaahmetli	5.88	5.72
		Mahmutlu	5.33	5.13
		Ahrazlı	5.64	5.93
Kuru Biyokütle Verimi	2021	Abalaklı	13.77	13.18
		Danaahmetli	12.78	12.92
		Mahmutlu	12.69	13.26
		Ahrazlı	12.31	11.93
	2022	Abalaklı	15.37	14.58
		Danaahmetli	14.61	14.08
		Mahmutlu	13.38	12.75
		Ahrazlı	14.17	13.46

Çizelge 4.25. Kütlü pamuk verimi ve biyokütle verim tahmini için AquaCrop modelinin genel tahmin performansı

Metrik	Kütlü Pamuk Verimi		Biyokütle	
NRMSE	0.396	İyi	0.547	Yeterli
d	0.952	İyi	0.893	Yeterli
R^2	0.826	İyi	0.811	İyi

Çizelge 4.25 incelendiğinde modelin kütlü verim ve biyokütle için R^2 değerlerinin sırasıyla 0.83 ve 0.81 olduğu görülmektedir. NRMSE değerleri ise sırasıyla 0.40 ve 0.55 olarak hesaplanmıştır. Modelin yüksek R^2 ve düşük NRMSE değerlerine sahip olması oldukça başarılı performansa sahip olduğunu göstermektedir (Moriasi ve ark., 2007; Masasi ve ark., 2020). Modelin başarılı bir şekilde pamuk bitkisinin hem toprak üstü biyokütle gelişimini hem de kütlü pamuk verimini tahmin edebildiği belirlenmiştir.

Qiao ve ark. (2016), kalibrasyon ve doğrulamada R^2 değerini 0.91 ve 0.84, d değerini ise 0.95 ve 0.92 olarak belirlemişlerdir. Hussein ve ark. (2011) çalışma alanımıza yakın olan Suriye'de AquaCrop kullanarak gerçekleştirdiği çalışmada, ölçülen ve tahmin edilen pamuk verimi arasında yüksek korelasyonlar bulmuştur (d=0.99 ve RMSE=0.48). Çalışma sonuçları literatürde bildirilen sonuçlarla karşılaştırıldığında, AquaCrop modelinin birçok farklı bölge ve iklim koşulunda pamuk bitkisini başarıyla tahmin edebildiği gibi Kırıkhan'da bulunan farklı arazilerde de başarılı sonuçlar göstermiştir.

4.5.6. AquaCrop Modelinin 1. Ürün Mısır Dane Verimi ve Biyokütle Tahmin Performansının Değerlendirilmesi

AquaCrop modelinin 1. ürün mısır bitkisinin biyokütle ve dane verimini tahmin edebilme performansını değerlendirmek için Kırıkhan'da farklı köylerde bulunan arazilerde gözlemler ve ölçümler yapılmıştır. Elde edilen gözlemler ve ölçümlerin sonucunda model arazi koşullarına göre kalibre edilmiş ve araziler için tahminlerde bulunmuştur. Tahmin sonuçları arazilerden elde edilen verim ölçümleri ile karşılaştırılarak doğrulanmıştır. 1. ürün mısır bitkisi için 2021-2022 yılları için ölçülen ve tahmin edilen biyokütle ve dane verim değerleri karşılaştırılmış ve sonuçlar Çizelge 4.26'da gösterilmiştir.

Çizelge 4.26. 1. ürün mısır dane verimi ve biyokütle veriminin tahmin ve ölçüm sonuçlarının karşılaştırılması

	YIL	Arazi	Ölçüm (t ha^{-1})	Tahmin (t ha^{-1})
Dane Verimi	2021	Abalaklı	16.53	16.32
		Danaahmetli	15.05	15.23
		Mahmutlu	16.15	16.4
		Ahrazlı	14.67	14.84
	2022	Abalaklı	15.85	16.12
		Danaahmetli	14.76	14.97
		Mahmutlu	15.92	15.45
		Ahrazlı	14.70	14.46
Kuru Biyokütle Verimi	2021	Abalaklı	33.56	32.94
		Danaahmetli	30.89	30.55
		Mahmutlu	32.94	32.52
		Ahrazlı	30.47	30.23
	2022	Abalaklı	32.08	33.06
		Danaahmetli	30.24	30.79
		Mahmutlu	32.66	32.08
		Ahrazlı	29.35	29.86

Kırıkhan'da bulunan arazilerde, arazi koşullarına kalibre edilmiş olan modelin 1. ürün mısır bitkisi dane verimini en fazla %3.04 ve biyokütle verimini ise %2.96'lık bir sapma ile tahmin ettiği belirlenmiştir. Modelin 1. ürün mısır bitkisi için yaptığı tahminlerin, pamuk bitkisine göre daha yüksek başarıya sahip olduğu görülmektedir. Modelin genel performansının istatistiksel değerlendirilmesi ise Çizelge 4.27'de verilmiştir.

Çizelge 4.27. 1. ürün mısır dane verimi ve biyokütle verim tahmini için AquaCrop modelinin genel tahmin performansı

Metrik	1. Ürün Mısır Dane Verimi		Biyokütle	
NRMSE	0.358	İyi	0.381	İyi
d	0.961	İyi	0.950	İyi
R^2	0.858	İyi	0.837	İyi

Çizelge 4.27'de verilen diğer istatistiksel parametreler incelendiğinde modelin 1. ürün mısır dane verimi ve biyokütle için R^2 değerlerinin sırasıyla 0.86 ve 0.84 olduğu görülmektedir. NRMSE değerleri ise sırasıyla 0.36 ve 0.38 olarak hesaplanmıştır. Bu

sonuçlara göre, modelin başarılı bir şekilde 1. ürün mısır bitkisinin hem toprak üstü biyokütle gelişimini hem de dane verimini tahmin edebildiği belirlenmiştir.

Mibulo ve Kiggundu (2018), modelin mısır verimini tahmin etme başarısını değerlendirmiş ve R^2 değerini 0.997 ve RMSE değerini ise 0.11 olarak bulmuşlardır. Ranjbar ve ark. (2019) İran'da AquaCrop kullanarak gerçekleştirdiği çalışmada, ölçülen ve tahmin edilen mısır verimi arasında yüksek korelasyonlar bulmuştur (R^2=0.94 ve RMSE=0.14). Modelden elde edilen istatistiki performans metrikleri literatür sonuçlarına yakın doğrulukta hesaplanmıştır. Hesaplanan değerler çalışma alanımız olan Kırıkhan'da bulunan farklı araziler için modelin tahmin doğruluğunun kabul edilebilir olduğunu göstermiştir.

4.6. İklim Değişikliğinin Farklı Senaryolar İçin Pamuk ve 1. Ürün Mısır Bitkisine Olası Etkisini Değerlendirme Sonuçları

4.6.1. İklim Değişikliğinin Pamuk Bitkisine Etkisi

KİM'den elde edilen SSP2-4.5 ve SSP5-8.5 sera gazı salınım senaryolarına ait çıktılar kullanılarak Kırıkhan'da iklim değişikliğinin pamuk bitkisinin verimine olası etkileri değerlendirilmiştir. Bu amaçla, Kırıkhan'da bulunan dört farklı araziden 2021 yılında elde edilen veriler kullanılarak kalibre edilen AquaCrop bitki verim tahmin modeli kullanılmıştır. Modelden iki farklı senaryo ile elde edilen biyokütle (BK) ve kütlü pamuk verimlerinin (V) yakın gelecek (2020-2060) ve uzak gelecek (2060-2100) dönemleri için tahmin sonuçları Çizelge 4.28'de verilmiştir.

Çizelge 4.28. Pamuk bitkisi için gelecek iklim senaryolarına göre elde edilen verim tahminleri

Çalışma Alanı	SSP2-4.5				SSP5-8.5			
	2020-2060		2060-2100		2020-2060		2060-2100	
	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})
Abalaklı	13.61	5.59	12.92	5.30	13.34	5.23	12.55	4.77
Danaahmetli	13.13	5.39	12.79	5.07	12.63	5.15	11.51	4.29
Mahmutlu	12.78	4.75	12.21	4.54	12.60	4.67	11.46	4.31
Ahrazlı	12.58	5.07	12.53	4.95	12.49	5.00	11.85	4.76

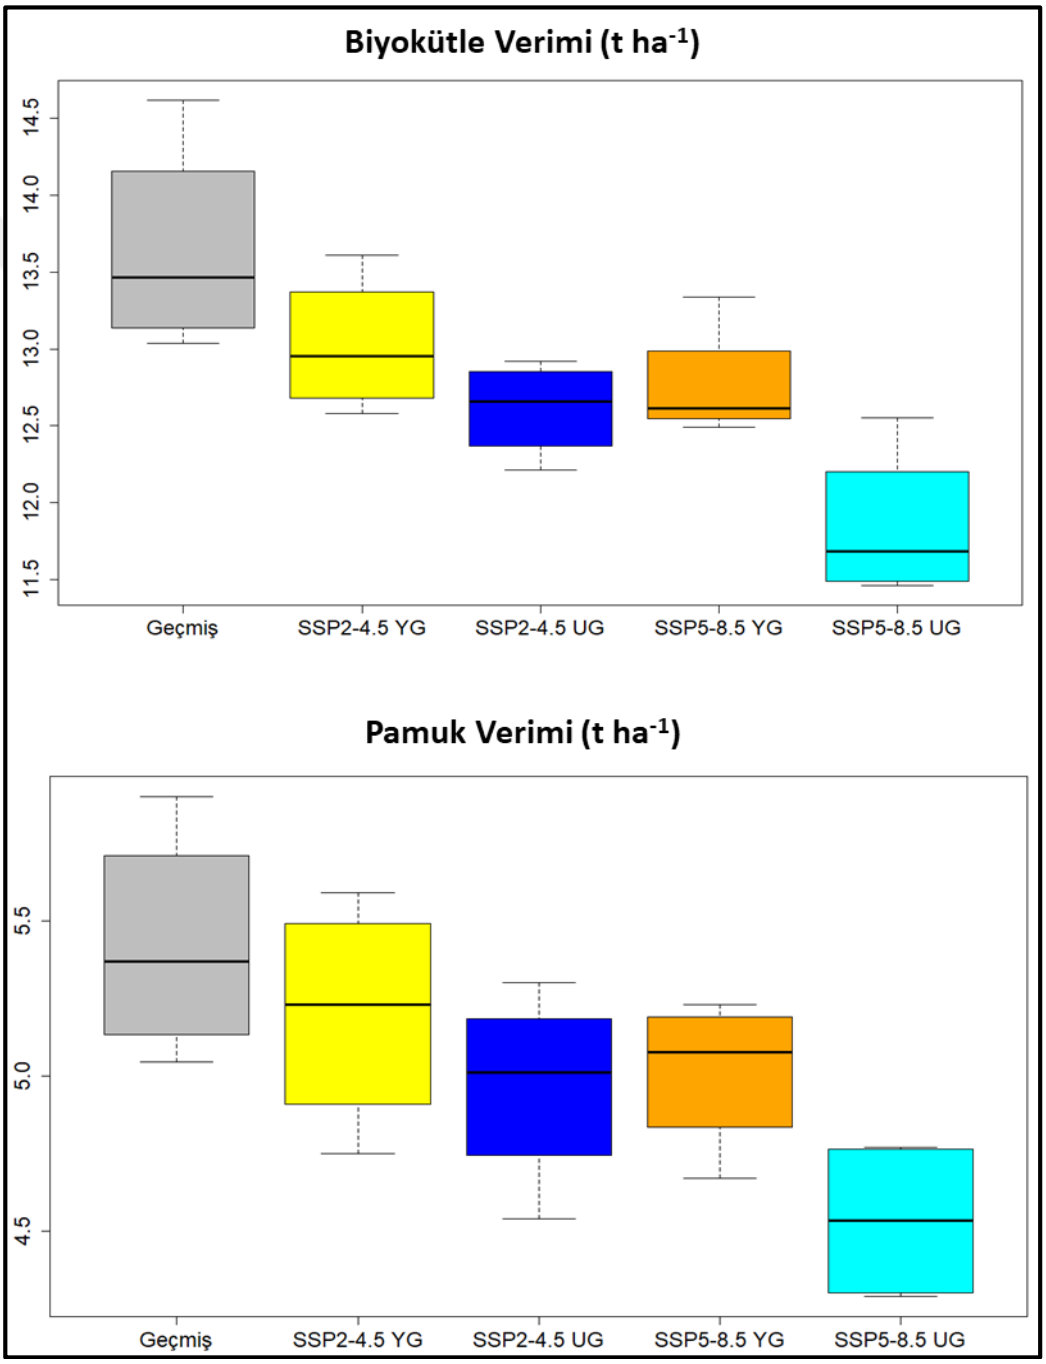
Elde edilen tahminler, arazilerden gözlemlenen 2021 ve 2022 yıllarına ait verim değerleri ortalaması ile karşılaştırılarak değerlendirilmiştir. Biyokütle verimi değerlendirildiğinde yakın gelecekte iyimser senaryo için yaklaşık %5 ve kötümser senaryo için ise %7 oranında azalma olabileceği öngörülmüştür. Uzak gelecekte iyimser senaryoya göre %8 ve kötümser senaryoya göre ise yaklaşık %15 oranında bir verim kaybı öngörülmüştür. Bu sonuçlara göre biyokütle verimindeki azalmanın kütlü pamuk verimindeki kadar olmayacağı öngörülmüştür. Bunun nedeni olarak ise literatürde verilen bilgilere dayanarak sıcaklıktaki artışın pamuk biyokütlesini arttırabilmesine rağmen bitkinin koza tutuşunu önemli ölçüde azaltması nedeniyle düşük koza sayısına sebep olmasından kaynaklandığı tahmin edilmektedir (Bange ve Milroy, 2004; Hatfield ve ark., 2011; Ayankojo ve ark., 2020).

Her iki iklim değişikliği senaryosuna göre pamuk veriminde gelecekte azalma gerçekleşeceği öngörülmüştür. Ortalama kütlü pamuk verimi yakın gelecek için iyimser senaryoya (SSP2-4.5) göre %4, kötümser senaryoya (SSP5-8.5) göre ise %8 oranında azalma göstermiştir. Ortalama kütlü pamuk verimindeki en fazla düşüş ise uzak gelecek dönem için yaklaşık %19 ile kötümser senaryo için tahmin edilmiştir. Aynı dönem için iyimser senaryoda ise %9 azalma görülmüştür.

Pamuk ve biyokütle veriminin, iki farklı senaryodan elde edilen tahminlerle yakın ve uzak gelecek dönemler için karşılaştırılması Şekil 4.26'daki kutu grafiğinde gösterilmiştir. Bu şekil incelendiğinde iyimser senaryo için öngörülen verim kayıplarındaki ortalama düşüş hızının yüzyılın ortasından itibaren kötümser senaryoya göre azaldığı görülmektedir. Bunun nedeni olarak sera gazı salınımındaki artışın, iyimser senaryoda yüzyılın ortasından itibaren azalmaya başlaması ve buna bağlı olarak sıcaklıktaki olası artış hızının da azalmasından kaynaklanacağı varsayılmaktadır (Hausfather, 2018; IPCC, 2022).

Pamuk bitkisi için elde edilen sonuçlar değerlendirildiğinde, gelecekte sıcaklıkta meydana gelmesi beklenen artışların Kırıkhan ilçesinde pamuk bitkisinin gelişimini ve verimliliğini olumsuz yönde etkileyebileceği öngörülmüştür. Benzer çalışmalarda atmosferde bulunan CO_2 konsantrasyonundaki artışın bitki stoma iletkenliğini azaltması ve fotosentezi arttırması nedeniyle pamuk bitkisinde verimi arttırabileceği bildirilmiştir (Adhikari ve ark., 2016; Rahman ve ark., 2018). Ancak, çalışmamızda literatürlerde bildirilen bulgulara benzer şekilde sıcaklıkta öngörülen aşırı artışlara bağlı olarak, bitki

gelişme dönemlerinin kısalacağı ve bu nedenle CO_2 oranındaki artışın verime olası olumlu etkilerinin azalacağı tahmin edilmektedir (Iqbal ve ark., 2016; Nasim ve ark., 2016). Hebbar ve ark. (2013), benzer olarak yüksek sıcaklıkların serin iklim bölgelerinde CO_2 artışına bağlı olarak verimi arttırabileceğini ancak daha sıcak bölgelerde, özellikle yaz mevsimindeki kritik ürün büyüme döneminde gelişimi hızlandırdığı için verimi azaltacağını açıklamışlardır.



Şekil 4.26. Pamuk ve biyokütle veriminin yakın ve uzak gelecek için karşılaştırılması

KİM'den elde ettiğimiz sonuçlara göre pamuk bitkisi büyüme mevsimi boyunca sıcaklık ortalamasının yakın gelecekte (2020-2060) yaklaşık 34°C, 2060 yılından sonra ise ortalama 36°C olacağı tahmin edilmektedir. Bu sonuçlara göre sıcaklıkta olması beklenen bu artışların benzer çalışma bulgularına dayanarak pamuk bitkisinde çiçeklenme ve koza oluşumunda ciddi bir düşüşe neden olabileceği tahmin edilmektedir (Luo, 2011; Ahmed ve ark., 2023). Sıcaklıkta meydana gelen artış, pamuk bitkilerinin metabolik hızı ve karbon kullanım oranını arttırarak büyüme mevsiminde pamuğun daha fazla koza üretmesini sağlayabilmektedir. Ancak aşırı yüksek bir sıcaklık (>29°C) koza dökülme oranını artırmakta ve verimi düşürmektedir (Craufurd ve Wheeler, 2009; Li ve ark., 2021).

Çalışma bulgularına benzer olarak Baydar ve Kanber (2012), 2070-2079 yılları arasında artan sıcaklıklar ve CO_2 miktarlarına bağlı olarak pamuk bitkisinin veriminde %5 oranında azalma olabileceğini bildirmişlerdir. Hebbar ve ark. (2013), Hindistan'da gerçekleştirdikleri çalışmada tahmin edilen sıcaklık artışı ve yağış düzeninin değişimi sonucunda her iki senaryo için kütlü pamuk veriminde azalma olacağını tahmin etmişlerdir. Pamuk veriminin iyimser senaryoya göre 268 kg ha^{-1} ve kötümser senaryoya göre ise 477 kg ha^{-1} azalabileceğini açıklamışlardır. Koukouli ve Georgiou (2018), kuzey Yunanistan'da gelecekteki potansiyel pamuk verimini değerlendirmişler ve sıcaklıklardaki artış nedeniyle 21. yy sonlarına doğru pamuk veriminin yaklaşık %15 oranında azalma olabileceğini tahmin etmişlerdir. Rahman ve ark. (2018), iyimser senaryoda 2039 yılında %8 ve 2069 yılında %20, kötümser senaryoda ise 2039 yılında %12 ve 2069 yılında %30 oranında pamuk veriminin azalacağını öngörmüşlerdir. Chen ve ark. (2019), 2041-2060 ve 2061-2080 yılları için pamuk veriminde sırasıyla %22.4 ve %28.6'lık bir azalma öngörmüşlerdir. Ayankojo ve ark. (2020), ABD Arizona'da yaptıkları çalışmada sıcaklık artışına bağlı olarak gelecekte pamuk bitkisinde yaklaşık %40-51 oranında bir azalma gerçekleşebileceğini bildirmişlerdir. Çalışma sonuçlarına benzer olarak Ahmed ve ark. (2023), Pakistan'da gerçekleştirdikleri çalışmada 2022-2047 ve 2074-2099 yılları arasında iyimser senaryo için pamuk veriminde ortalama %13-16, kötümser senaryoda %16-18'lik verim kaybı olabileceğini tahmin etmişlerdir.

4.6.2. İklim Değişikliğinin 1. Ürün Mısır Bitkisine Etkisi

KİM'den elde edilen SSP2-4.5 ve SSP5-8.5 sera gazı salınım senaryolarına ait çıktılar kullanılarak Kırıkhan'da iklim değişikliğinin 1. ürün mısır bitkisinin verimine olası etkileri değerlendirilmiştir. Bu amaçla Kırıkhan'da bulunan dört farklı araziden 2021 yılında elde edilen veriler kullanılarak kalibre edilen AquaCrop bitki verim tahmin modeli kullanılmıştır. Modelden iki farklı senaryo ile elde edilen biyokütle (BK) ve 1. ürün mısır dane verimlerinin (V) yakın gelecek (2020-2060) ve uzak gelecek (2060-2100) dönemleri için tahmin sonuçları Çizelge 4.29'da verilmiştir.

Çizelge 4.29. 1. ürün mısır bitkisi için gelecek iklim senaryolarına göre elde edilen verim tahminleri

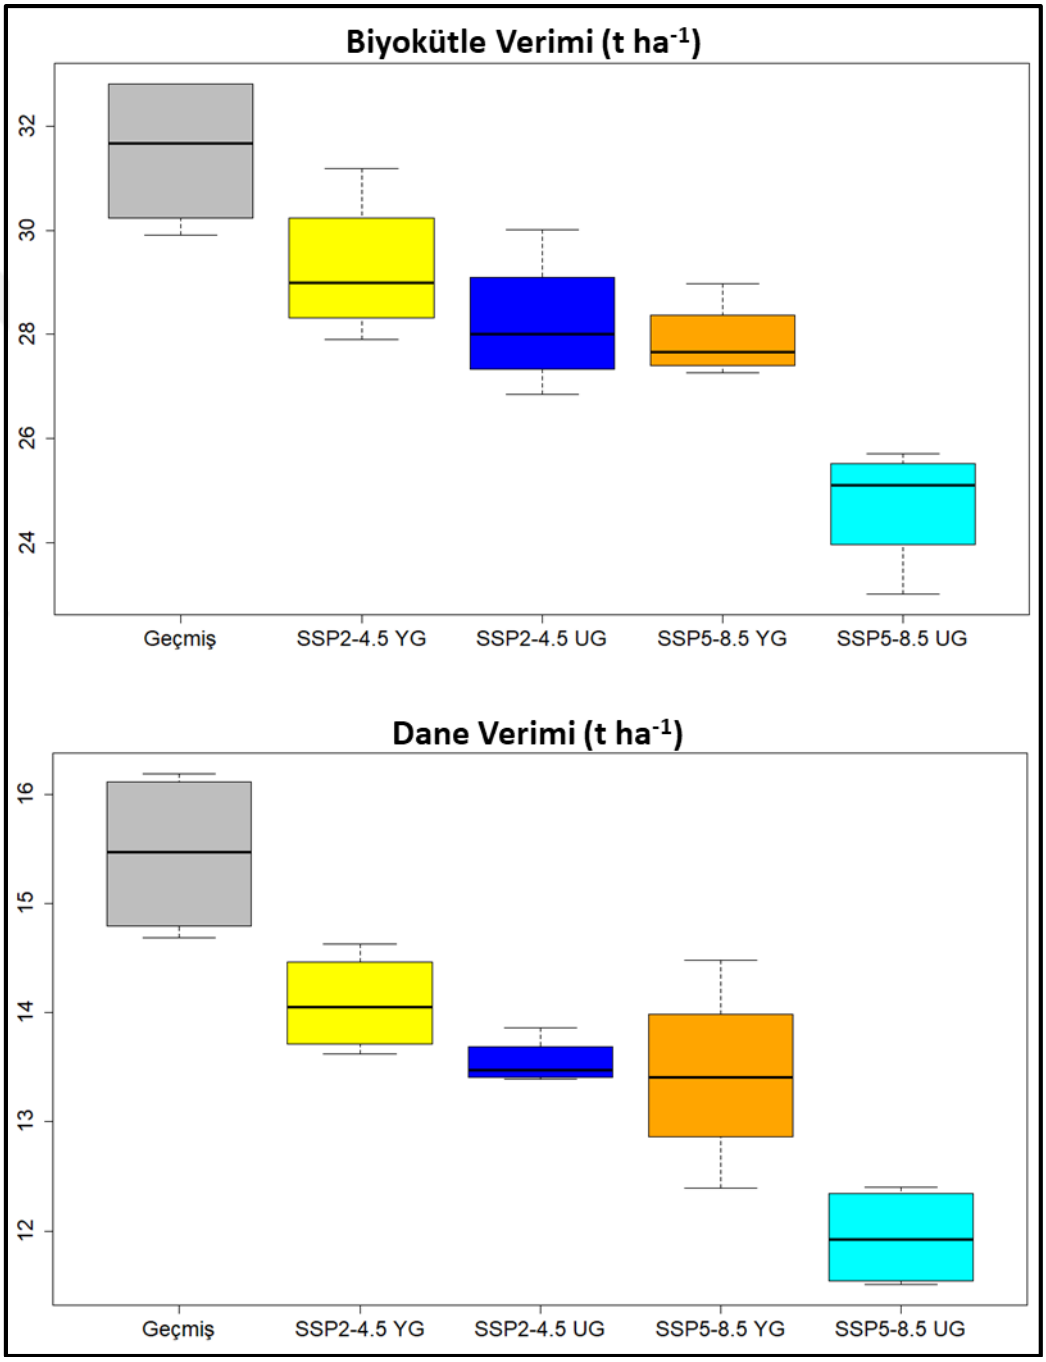
Çalışma Alanı	SSP2-4.5				SSP5-8.5			
	2020-2060		2060-2100		2020-2060		2060-2100	
	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})	BK (t ha^{-1})	V (t ha^{-1})
Abalaklı	29.27	14.30	28.19	13.86	27.52	12.39	25.71	11.57
Danaahmetli	28.72	13.62	27.83	13.39	27.79	13.33	24.90	12.28
Mahmutlu	31.20	14.63	30.01	13.52	28.97	14.48	25.31	12.40
Ahrazlı	27.91	13.81	26.85	13.42	27.27	13.49	23.01	11.51

Elde edilen tahminler, arazilerden gözlemlenen 2021 ve 2022 yıllarına ait verim değerleri ortalaması ile karşılaştırılarak değerlendirilmiştir. Biyokütle verimi değerlendirildiğinde yakın gelecekte iyimser senaryo için %8 ve kötümser senaryo için %13 oranında azalma tahmin edilmiştir. Uzak gelecekte iyimser senaryoya göre %12 ve kötümser senaryoya göre ise yaklaşık %27 oranında bir verim kaybı öngörülmüştür. Çizelge 4.29 incelendiğinde biyokütle verimindeki azalmanın, mısır dane verimi kadar olmayacağı belirlenmiştir. Sıcaklık artışı nedeniyle mısır bitkisinin gelişme süresi azalmakta ve bu nedenle bitkinin CO_2'yi absorbe etmesi için gerekli olan süre kısalmaktadır. Bu durumun mısır bitkisinin biyokütle veriminin azaltmasına neden olduğu düşünülmektedir (Islam ve ark., 2012; Bassu ve ark., 2014).

Her iki iklim değişikliği senaryosuna göre de 1. ürün mısır veriminde gelecekte önemli bir azalma öngörülmüştür. Ortalama 1. ürün mısır dane verimi yakın gelecek için iyimser senaryoya göre %10, kötümser senaryoya göre ise %16 oranında azalma göstermiştir. Ortalama 1. ürün mısır dane verimindeki en fazla düşüş ise uzak gelecek

dönem için yaklaşık %30 ile kötümser senaryo için tahmin edilmiştir. Aynı dönem için iyimser senaryoda ise %14 azalma görülmüştür.

1. ürün mısır dane ve biyokütle veriminin, iki farklı senaryodan elde edilen tahminlerle yakın ve uzak gelecek dönemler için karşılaştırılması Şekil 4.27'deki kutu grafiğinde gösterilmiştir.



Şekil 4.27. Dane ve biyokütle veriminin yakın ve uzak gelecek için karşılaştırılması

Bu şekil incelendiğinde iyimser senaryo için öngörülen verim kayıplarındaki ortalama düşüş hızının yüzyılın ortasından itibaren kötümser senaryoya göre azaldığı görülmektedir. Bunun nedeni olarak sera gazı salınımındaki artışın, iyimser senaryoda yüzyılın ortasından itibaren azalmaya başlaması ve buna bağlı olarak sıcaklıktaki olası artış hızının da azalmasından kaynaklanacağı varsayılmaktadır (Hausfather, 2018; IPCC, 2022).

Bu sonuçlar değerlendirildiğinde, gelecekte sıcaklıkta meydana gelmesi beklenen artışların Kırıkhan ilçesinde 1. ürün mısır bitkisinin gelişimini ve verimliliğini olumsuz yönde etkileyebileceği belirlenmiştir. Mısır bitkisi ile ilgili yapılan farklı çalışmalarda büyüme mevsiminde meydana gelebilecek aşırı sıcaklıkların; dane büyüme hızı, dane boyutu ve dane verimini olumsuz etkilediği bildirilmiştir. Ayrıca, yüksek sıcaklıklar, mısır bitkisinin normal büyümesi ve gelişmesi için gereken sürenin kısalmasına neden olan fenolojik döngülerin hızlanmasına da sebep olmaktadır (Dupuis ve Dumas, 1990; Commuri ve Jones, 2001; Rezaei ve ark., 2015; Tesfaye ve ark., 2018). Büyüme süresinin kısalması, tepe püskülü ve koçan püskülünün daha kısa bir sürede oluşmasına ve dolayısıyla verimin düşmesine neden olacaktır (Abraha ve Savage, 2006; Moradi ve ark., 2014). Ayrıca, bazı çalışmalarda yüksek sıcaklığın bitki yapraklarının yaşlanmasını hızlandırdığı, dane dolum süresini kısalttığı ve polen verimliliğini azaltabileceği de bildirilmiştir (Lobell ve Burke., 2010; Rattalino Edreira ve ark., 2011; Araya ve ark., 2017).

KİM'den elde ettiğimiz sonuçlara göre, 1. ürün mısır bitkisi büyüme mevsimi boyunca sıcaklık ortalamasının yakın gelecekte (2020-2060) yaklaşık 34°C, 2060 yılından sonra ise ortalama 36°C olacağı tahmin edilmektedir. Gelecekteki iklim koşullarında optimum sıcaklık eşiğinin üzerine çıkması nedeniyle mısır verimi düşebilmektedir (Hatfield ve ark., 2011). Çalışmamızda Kırıkhan'da yıllık ortalama yakın gelecekte 2°C, uzak gelecekte ise her iki senaryoya göre 4-5°C'lik sıcaklık artışı olabileceği belirlenmiştir. Lobell ve Burke (2010), mısır bitkisinde verim kaybında sıcaklıkta meydana gelebilecek 2°C'lik bir artışın, yağış miktarında gerçekleşecek %20'lik bir azalmadan daha etkili olabileceğini açıklamışlardır. Rowhani ve ark. (2011), Tanzanya'da gerçekleştirdikleri çalışmada sıcaklıktaki 2°C'lik bir artışın mısır verimini %13 oranında azaltabileceğini tahmin etmişlerdir. Tesfaye ve ark. (2018), mevcut iklim

şartlarına göre, sıcaklıkta meydana gelebilecek 2 ve 4°C'lik artışların mısır veriminde sırasıyla, %33 ve %50 oranlarında azalmaya neden olabileceğini açıklamışlardır.

Moradi ve ark. (2014), İran'da yaptıkları çalışmada tüm SRES iklim değişikliği senaryoları altında gelecekteki koşulların mısır verimini olumsuz etkileyeceğini açıklamışlardır. İklim değişikliğinin mısır dane verimi üzerindeki etkisinin zamanla artış göstereceğini ve en düşük dane verimini 2080 yılında görüleceğini öngörmüşlerdir. Tahminlerine göre 2080 yılında verim kaybının %42.15 olabileceğini açıklamışlardır. Araya ve ark. (2017), yirmi farklı KİM'e dayanarak elde ettikleri iyimser senaryoya göre mısır ortalama veriminde mevcut döneme göre yaklaşık %24 ve kötümser senaryoya göre ise %37 oranında azalma görülebileceğini öngörmüşlerdir. Mısır biyokütlesinde ise iyimser senaryo için %13 ve kötümser senaryo için %22 oranında azalma olabileceğini tahmin etmişlerdir. Lv ve ark. (2020), yazlık mısır için potansiyel verimin 2000'li yıllara kıyasla 2030'larda %15, 2050'lerde %24 ve 2070'lerde yaklaşık %32 oranında azalacağını öngörmüşlerdir.

Her iki senaryo içinde pamuk bitkisinde olduğu gibi 1. ürün mısır bitkisi için de gelecekte meydana gelebilecek yüksek sıcaklıkların negatif etkilerinin, CO_2 artışının pozitif etkilerinden daha fazla olacağı bildirilmiştir (Araya ve ark., 2017). Çalışmamızda gelecek yıllar için 1. ürün mısır bitkisindeki olası verim kaybının pamuk bitkisinden daha fazla olacağı öngörülmüştür. Gelecekte atmosferde gerçekleşebilecek CO_2 artışının C4 bitkilerinde (Mısır), C3 bitkilerinde (Pamuk) olduğu kadar verime pozitif etkisinin olamayacağı benzer önceki çalışmalarda rapor edilmiştir Bunun nedeni olarak yapılan çalışmalarla günümüz CO_2 koşullarında C4 bitkilerinin doygun hale gelmiş olmasından kaynaklanacağı bildirilmiştir (Araya ve ark., 2017).

5. SONUÇ ve ÖNERİLER

Bu tez çalışmasında KİM çıktıları kullanılarak iklim değişikliğinin gelecekte olası farklı senaryolara göre yakın (2020-2060) ve uzak gelecekte (2060-2100) sıcaklık ve yağışa olası etkileri tahmin edilmiştir. Elde edilen tahminler, AquaCrop bitki verim tahmin modelinde kullanılarak iklim değişikliğinin pamuk ve 1. ürün mısır verimine olası etkileri değerlendirilmiştir.

Çalışmada kullanılan geçmiş iklim verileri meteoroloji genel müdürlüğüne ait olan farklı gözlem istasyonlarından elde edilmiştir. İklim değişikliği çalışmalarında gerekli olan uzun yıllık gözlem kayıtları olmayan istasyonlar için kalite kontrolü yapılmış veriler ile eğitilmiş olan çok katmanlı YSA modelleri oluşturulmuştur. Bu modeller, uzun yıllık kayıtları mevcut olan komşu istasyonlara ait gözlemlerden korelasyonları yüksek ($r>0.6$) olan değişkenler seçilerek oluşturulmuştur. Oluşturulan modellerin çıktıları test veri seti ile doğrulanmış ve NSE, RSR ve C' performans değerlendirme kriterleri kullanılarak kullanılabilirlikleri değerlendirilmiştir. Elde edilen sonuçlara göre maksimum sıcaklık ve minimum sıcaklık verileri oldukça başarılı ($NSE>0.90$, $RSR<0.50$ ve $C'>0.75$) olarak belirlenmiştir. Yağış miktarı tahminlerinin ise kullanılabilir doğrulukta ($NSE>0.50$, $RSR<0.70$ ve $C'>0.60$) olduğu kabul edilmiştir. Yağış tahminlerinin, sıcaklık tahminleri kadar başarılı olamamasının en önemli nedenleri olarak modelin girdi değişkenlerinin korelasyonlarının düşük olması ve yağıştaki günlük değişkenliğin sıcaklık değerlerine göre daha fazla olmasından kaynaklandığı kabul edilmiştir. YSA modellerinden elde edilen veriler kullanılarak tüm istasyonların 1980-2020 yılları arası eksiksiz yağış miktarı, maksimum ve minimum sıcaklık veri setleri oluşturulmuştur.

Çalışma alanına en uygun gelecek iklim verilerinin elde edilebilmesi için farklı KİM'lerin (ACCESS-CM2, CMCC-ESM2, EC-EARTH3, GFDL-CM4, MIROC6, MPI-ESM1-2-HR ve TAIESM1) referans dönem çıktıları istatistiksel performans değerlendirme ölçütleri kullanılarak karşılaştırılmıştır. Yağış miktarı, maksimum ve minimum sıcaklık değişkenleri için karşılaştırılan iklim modellerinden elde edilen performans değerlendirme ölçüt sonuçları uzlaşık programlama çok kriterli karar verme yöntemi ile değerlendirilmiştir. Değerlendirme sonuçlarına göre başarılı bulunan EC-EARTH3 modelinden elde edilen SSP2-4.5 ve SSP5-8.5 senaryo çıktıları çalışmada iklim değişikliğinin etkilerini değerlendirmek için kullanılmıştır.

Elde edilen KİM çıktılarının tahmin doğruluklarının iyileştirilmesi için çalışmada istatistiksel ölçek küçültme modelleri kullanılmıştır. Modellerde tahmin edici değişken olarak; 1980-2014 yılları arası için elde edilen yakın yüzey hava sıcaklığı (°C), özgül nem (g kg^{-1}), bölgesel rüzgâr hızı (m s^{-1}), meridiyonal rüzgâr hızı (m s^{-1}) ve deniz seviyesi basıncı (hPa) verileri değerlendirilmiştir. Bu değişkenlerden modellerde kullanılacak olanları LASSO yöntemi ile belirlenmiştir. Belirlenen değişkenler ile RF, SVR ve MLR tabanlı ölçek küçültme modelleri oluşturulmuştur. Oluşturulan modellerden elde edilen sonuçlar, meteorolojik gözlem verileri ile karşılaştırılmış ve test dönemi için RF tabanlı ölçek küçültme modeli en başarılı olarak belirlenmiştir. Son olarak RF tabanlı ölçek küçültme modeli kullanılarak elde edilen SSP2-4.5 ve SSP5-8.5 senaryo çıktılarında olabilecek yanlılık hatalarının düzeltilmesi için gelecek tahminlerine yanlılık düzeltme yöntemi uygulanmıştır. Yanlılık düzeltme sonucunda Hatay ilinde iklim değişikliğinin etkilerini değerlendirmek için kullanılacak olan 2020-2100 yılları arası iki farklı senaryo için yağış miktarı, maksimum ve minimum sıcaklık gelecek tahminleri elde edilmiş ve iklim değişikliğinin olası etkisi değerlendirilmiştir.

Sonuçlara göre, SSP2-4.5 ve SSP5-8.5 senaryoları altında Hatay ilinde yıllık ortalama sıcaklıkta önemli oranda artış olabileceği belirlenmiştir. Ayrıca her iki senaryo için Hatay ili genelinde 2060 yılına kadar sıcaklığın artış eğiliminde olacağı öngörülürken, sera gazı salınımının sınırlandırıldığı SSP2-4.5 senaryosuna göre 2060 yılından sonra sıcaklıktaki olası artış hızının azalma gösterebileceği tahmin edilmiştir. Elde edilen sonuçlara göre Hatay ilinde yakın (2020-2060) ve uzak (2060-2100) gelecek dönemlerde sırasıyla SSP2-4.5 senaryosu için 2.1°C ve 2.9°C, SSP5-8.5 senaryosu için ise 2.4°C ve 5.2°C'lik sıcaklık artışı olabileceği tahmin edilmiştir. Her iki senaryoya göre yapılan tahminlerde en yüksek sıcaklık artışlarının İskenderun, Dörtyol ve Erzin istasyonlarında gerçekleşeceği öngörülmüştür. Yıllık yağış miktarlarının tahmin edilen yıllık değişim yüzdelerine göre ise sera gazı salınım emisyonlarındaki artışın gelecek dönemlerdeki yıllık yağış miktarındaki değişimlere önemli miktarda etki edebileceği belirlenmiştir. Hatay ilinin güneyi ve batısında, her iki farklı senaryo için yakın gelecekte (2020-2060) yağışta bir artış (%0-1) olacağı öngörülmüştür. Yakın gelecekte düşük sera gazı salınım senaryosu için yağıştaki bu artışın kötümser senaryoya göre daha geniş bir alanda gerçekleşeceği tahmin edilmiştir. Yağışta öngörülen bu artışın, yüksek sıcaklığın yüzeydeki nemi hızla buharlaştırmasından kaynaklı olabileceği tahmin edilmiştir. Ancak

Hatay ilinin kuzeyi ve doğusundaki bölgelerde ise yıllık yağış miktarında yaklaşık %5'e kadar bir azalma olacağı tahmin edilmiştir. Uzak gelecek (2060-2100) için her iki senaryoya göre elde edilen tahminlerden yıllık yağış miktarında çok şiddetli azalmalar gerçekleşebileceği öngörülmüştür. Özellikle Hatay ilinin batı ve güney bölgelerinde yıllık yağışta iyimser senaryoya göre yaklaşık %10 ve kötümser senaryoya göre yaklaşık %20'lere varan bir azalma olabileceği belirlenmiştir.

Elde edilen değerlendirme sonuçlarına göre uzak gelecek (2060-2100) döneminde her iki senaryo için de ılıman iklimin yerini kurak bir iklime bırakacağı tahmin edilmektedir. Sonuçlara göre sera gazı salınımının artış gösterdiği senaryo için sera gazı emisyonlarının sınırlandırıldığı senaryoya göre gelecekte daha sıcak ve daha kurak bir iklim tahmin edilmiştir. Bu durum da sera gazı emisyonlarının sınırlandırılması ile gelecekteki olası kuraklık risklerinin azaltılabileceğini göstermektedir. Bu nedenle Paris Anlaşması kapsamında tasarlanmış küresel emisyon azaltma hedeflerinin uygulanmasının küresel düzeyde ısınmayı kontrol etmek için oldukça elzem olduğu anlaşılmaktadır. Küresel sıcaklık artışını 2°C yerine 1.5°C'ye sabitlemenin dünya nüfusunun iklim kaynaklı su kıtlığına maruz kalan kısmını %50 oranında azaltabileceğini bildiren IPCC (2018) raporunun ülkeler tarafından dikkate alınması gerekmektedir.

Atmosferik CO_2 konsantrasyonundaki artıştan kaynaklanan sıcaklık artışları nedeniyle bitkisel üretimde verimin etkilenebileceği tahmin edilmektedir. Bu durumun hızlı bir şekilde artış gösteren nüfusun gelecekte ihtiyaçlarını karşılayabilmede büyük sorun yaşanmasına neden olabileceği düşünülmektedir. Bu nedenle iklim değişikliğinin olası etkilerinin önceden tahmin edilip gerekli adaptasyon önlemlerinin alınması oldukça önemlidir. Bu amaçla ülkemizin önemli tarım merkezlerinden olan Amik Ovasında bulunan Kırıkhan'da yetiştirilen pamuk ve 1. ürün mısır verimine iklim değişikliğinin olası etkilerini tahmin etmek için dört farklı köyde (Abalaklı, Danahmetli, Mahmutlu ve Ahrazlı) çalışmalar gerçekleştirilmiştir. Bu arazilerden 2021 yılında elde edilen gözlemler ve analiz sonuçları kullanılarak AquaCrop bitki verim tahmin modeli kalibre edilmiştir. Daha sonra modelin verim tahminleri, 2022 yılında elde edilen arazi gözlem verileri ile karşılaştırılarak doğrulanmış ve tahmin performansı değerlendirilmiştir.

Değerlendirme sonuçlarına göre arazi koşullarına göre kalibre edilmiş olan modelin pamuk bitkisi kütlü verimini en fazla %4.99 ve biyokütle verimini ise %5.42'lik bir sapma ile tahmin ettiği görülmüştür. İstatistiksel performans ölçütleri incelendiğinde modelin

kütlü verim ve biyokütle için R^2 değerlerinin sırasıyla 0.83 ve 0.81, NRMSE değerleri ise sırasıyla 0.40 ve 0.55 olarak hesaplanmıştır. İstatistiksel performans sonuçlarına göre modelin pamuk bitkisi için başarılı tahminlerde bulunduğu belirlenmiştir.

Kırıkhan'da bulunan arazilerde, arazi koşullarına kalibre edilmiş olan modelin 1. ürün mısır bitkisi dane verimini en fazla %3.04 ve biyokütle verimini ise %2.96'lık bir sapma ile tahmin ettiği belirlenmiştir. Modelin 1. ürün mısır bitkisi için yaptığı tahminlerin, pamuk bitkisine göre daha yüksek başarıya sahip olduğu görülmektedir. Ayrıca modelin 1. ürün mısır bitkisi için yaptığı tahminlerin, pamuk bitkisi tahminleri ile kıyaslandığında daha başarılı performansa sahip olduğu istatistiksel performans ölçütleri (R^2=0.86 ve NRMSE=0.36) ile belirlenmiştir.

Arazi koşullarına göre kalibrasyonu yapılan ve doğrulanan AquaCrop modeli KİM'den iki farklı senaryoya göre elde edilen gelecek iklim tahmin verileri ile kullanılarak verimin olası durumları değerlendirilmiştir. Her iki iklim değişikliği senaryosuna göre de pamuk veriminde gelecekte önemli bir düşüş öngörülmüştür. Ortalama kütlü pamuk verimi yakın gelecek için iyimser senaryoya göre %4, kötümser senaryoya göre ise %8 oranında azalma göstermiştir. Ortalama kütlü pamuk verimindeki en fazla düşüş ise uzak gelecek dönem için yaklaşık %19 ile kötümser senaryo için tahmin edilmiştir. Aynı dönem için iyimser senaryoda ise %9 azalma görülmüştür. Biyokütle verimi değerlendirildiğinde yakın gelecekte iyimser senaryo için yaklaşık %5 ve kötümser senaryo için ise %7 oranında azalma olabileceği öngörülmüştür. Uzak gelecekte iyimser senaryoya göre %8 ve kötümser senaryoya göre ise yaklaşık %15 oranında bir verim kaybı öngörülmüştür. İyimser senaryo için 2060 yılından sonra sera gazı salınımının azaltılması sonucunda, sıcaklık artış hızında yavaşlama meydana gelmesi nedeniyle yakın gelecek döneme (2020-2060) göre verimde artış olacağı öngörülmüştür. Bu sonuçlar değerlendirildiğinde, gelecekte sıcaklıkta meydana gelmesi beklenen artışların Kırıkhan ilçesinde pamuk bitkisinin gelişimini ve verimliliğini olumsuz yönde etkileyebileceği belirlenmiştir.

Çalışmamızda elde edilen ve literatürde bildirilen bulgulara göre, sıcaklıkta öngörülen aşırı artışlara bağlı olarak bitki gelişme dönemlerinin kısalacağı ve buna bağlı olarak CO_2 oranındaki artışın verime olan pozitif etkilerinin azalacağı tahmin edilmektedir. Kırıkhan'da meydana geleceği tahmin edilen aşırı yüksek sıcaklıkların

(>29°C) koza dökülme oranını arttırması ve verimin azalmasına neden olacağı tahmin edilmektedir.

Pamuk bitkisinde olduğu gibi 1. ürün mısır bitkisi içinde her iki iklim değişikliği senaryosuna göre gelecekte önemli bir düşüş öngörülmüştür. Ortalama 1. ürün mısır dane verimi yakın gelecek için iyimser senaryoya göre %10, kötümser senaryoya göre ise %16 oranında azalma göstermiştir. Ortalama 1. ürün mısır dane verimindeki en fazla düşüş ise uzak gelecek döneminde kötümser senaryo için yaklaşık %30 olarak tahmin edilmiştir. Aynı dönem için iyimser senaryoda ise %14 oranında azalma görülmüştür. Biyokütle verimi değerlendirildiğinde yakın gelecekte iyimser senaryo için %8 ve kötümser senaryo için %13 oranında azalma tahmin edilmiştir. Uzak gelecekte iyimser senaryoya göre %12 ve kötümser senaryoya göre ise yaklaşık %27 oranında bir verim kaybı öngörülmüştür. Bu sonuçlar değerlendirildiğinde, gelecekte sıcaklıkta meydana gelmesi beklenen artışların Kırıkhan ilçesinde 1. ürün mısır bitkisinin gelişimini ve verimliliğini olumsuz yönde etkileyebileceği belirlenmiştir. Bu verim kayıplarının nedeni olarak sıcaklıklarda meydana gelebilecek artışların mısır bitkisinin büyüme ve gelişme mevsimlerini kısaltmasından kaynaklanacağı tahmin edilmektedir. Bu durum mısır bitkisinin daha hızlı büyüyerek büyüme süresinin kısalmasına, tepe ve koçan püsküllerinin daha kısa bir sürede oluşmasına dolayısıyla verimin düşmesine neden olacağı tahmin edilmiştir. Her iki senaryo içinde pamuk bitkisinde olduğu gibi 1. ürün mısır bitkisi için de gelecekte meydana gelebilecek yüksek sıcaklıkların olumsuz etkilerinin CO_2 artışının pozitif etkilerinden daha fazla olacağı bildirilmiştir. Ancak gelecek yıllar için mısır bitkisindeki olası verim kaybının pamuk bitkisinden daha fazla olacağı öngörülmüştür. Sonuç olarak; iklim değişikliğinin Hatay ilinin Kırıkhan ilçesinde önemli derecede verim azalmalarına neden olmasından dolayı bitkisel üretimi olumsuz etkileyeceği bu çalışma ile belirlenmiştir. Stratejik ve önemli tarım ürünleri olan 1. ürün mısır ve pamuk bitkilerinde yaklaşık 1.55 ve 0.54 ton da^{-1} olan ortalama mevcut üretimin kötümser senaryoya göre bu yüzyılın sonunda yaklaşık olarak 0.36 ve 0.09 ton da^{-1} azalabileceği belirlenmiştir. Bu değerler Kırıkhan ilçesindeki 1. ürün mısır (61000 da) ve pamuk (143000 da) ekili alana göre değerlendirildiğinde ise sırasıyla yaklaşık 21960 ton ve 12870 ton yıllık ürün kaybı olabileceği hesaplanmıştır.

Hatay'da iklim değişikliği gelecekte kuraklık sıklığındaki değişiklik, su kaynakları mevcudiyetindeki azalma, arazi verimliliğinin bozulması, tarımsal üretimde azalma,

ekosistemlerdeki değişiklikler, biyolojik çeşitlilikte azalma, nadir türlerin yok olması ve sosyo-ekonomik sorunlar üzerinde birçok etki yaratacağı ortadadır. Bu nedenle Hatay ili için ilgili birimlerin kuraklık ve taşkınlarla mücadele eylem planları oluşturması gerekmektedir.

Kuraklık risklerini yönetmesi için hem yerel hem de bölgeler arası su yönetimi politikalarının muhtemelen önümüzdeki yıllarda değiştirilmesi ve uyarlanması gerekmektedir. İklim değişikliğinin gelecekte sıcaklıkları çok arttıracağı ve yağış miktarlarını azaltacağı belirlenmiştir. Bu nedenle iklim değişikliğinin olası etkilerinin hidrometeorolojik afetlere, mevut su kaynaklarının durumuna ve tarım ürünlerine etkisi detaylı bir şekilde araştırılarak değerlendirilmeli ve gerekli eylem planları oluşturulmalıdır.

Hatay ilinde kurak geçmesi beklenen dönemlerin gelecekte artış göstereceği dikkate alınarak çiftçiler için basınçlı sulama sistemlerinin kullanılmasını teşvik edici planlamalar ve destek projeleri oluşturulmalıdır. Hatay ilinde beklenmeyen yoğun yağışların gelecekte daha sık gerçekleşme olasılığı yüksek olduğundan gerekli taşkın koruma önlemlerinin alınması gerekmektedir. Hatay ilçeleri için olası iklim değişikliği etkilerine uygun tarım ürünlerinin, tahmin edilen kurak dönemler dikkate alınarak ekim planlaması yapılmalı ve uygulanmalıdır. Son olarak Hatay ilinde gelecekte kurak dönemlerin artış göstereceği dikkate alınarak atık suların değerlendirilmesi ve su hasadı gibi tekniklerin kullanılmasının yaygınlaştırılması oldukça önem arz etmektedir.

KAYNAKLAR

Abbas, A., Ullah, S., Ullah, W., Waseem, M., Dou, X., Zhao, C., Karim, A., Zhu, J., Hagan, D.F.T., Bhatti, A.S. and Ali, G., 2022. Evaluation and projection of precipitation in Pakistan using the Coupled Model Intercomparison Project Phase 6 model simulations. **International Journal of Climatology**, 42 (13), 6665-6684.

Abdullahi, J. and Elkiran, G., 2017. Prediction of the future impact of climate change on reference evapotranspiration in Cyprus using artificial neural network. **Procedia Computer Science**, 120, 276-283.

Abedinpour, M., Sarangi, A., Rajput, T.B.S., Singh, M., Pathak, H. and Ahmad, T., 2012. Performance evaluation of Aquacrop model for maize crop in a semi-arid environment. **Agricultural Water Management**, 110, 55-66.

Aboukarima A.M., Zayed, M.F., Minyawi, M., Elsoury, H.A., and Tarabye, H.H.H., 2017. Image analysis-based system for estimating cotton leaf area. **Asian Research Journal of Agriculture**, 5 (1), 1-8.

Abraha, M.G. and Savage, M. J., 2006. Potential impacts of climate change on the grain yield of maize for the midlands of Kwazulu-Natal, South Africa. **Agriculture, Ecosystems & Environment**, 115 (1-4), 150-160.

Adhikari, P., Ale, S., Bordovsky, J.P., Thorp, K.R., Modala, N.R., Rajan, N. and Barnes, E.M., 2016. Simulating future climate change impacts on seed cotton yield in the Texas High Plains using the CSM-CROPGRO-Cotton model. **Agricultural Water Management**, 164 (2), 317-330.

Ahmad, I., Ahmad, B., Boote, K. and Hoogenboom, G., 2020. Adaptation strategies for maize production under climate change for semi-arid environments. **European Journal of Agronomy**, 115, 126040.

Ahmad, S., Ali, H., Rehman, A.U., Khan, R.J.Z., Ahmad, W., Fatima, Z., Abbas, G., Irfan, M., Ali, H., Khan, M.A. and Hasanuzzaman, M., 2015. Measuring leaf area of winter cereals by different techniques: A comparison. **Pakistan Journal of Life and Social Sciences**, 13 (2), 117-125.

Ahmed, A., Din, A.M.U., Aftab, S., Titriku, J.K., Ahmed, S., Nizamani, M., Jamali, Z.H., Tei, X., Yang, F. and Yang, W., 2021. Physiological and nutritional significance of potassium application under sole and intercropped maize (*Zea mays* L.). **Italian Journal of Agronomy**, 16 (1), 1737.

Ahmed, K., Sachindra, D.A., Shahid, S., Demirel, M.C. and Chung, E.S., 2019. Selection of multi-model ensemble of general circulation models for the simulation of precipitation and maximum and minimum temperature based on spatial assessment metrics. **Hydrology and Earth System Sciences**, 23 (11), 4803-4824.

Ahmed, K., Shahid, S., Haroon, S. B. and Xiao-Jun, W., 2015. Multilayer perceptron neural network for downscaling rainfall in arid region: A case study of Baluchistan, Pakistan. **Journal of Earth System Science**, 124, 1325-1341.

Ahmed, Z., Gui, D., Ali, S., Chen, X. and Qi, Z., 2023. Evaluating climate change impacts on cotton phenology and yield under full and deficit irrigation conditions in an extremely arid oasis. **International Journal of Plant Production**, 17, 49-63.

Ai, F-f., Bin, J., Zhang, Z-m., Huang, J-h., Wang, J-b., Liang, Y-z., Yu, L. and Yang, Z-y., 2014. Application of random forests to select premium quality vegetable oils by their fatty acid composition. **Food Chemistry**, 143, 472-478.

Akcakoca, F. and Apaydın, H., 2020. Modelling of Bektas Creek Daily Streamflow with Generalized Regression Neural Network Method. **International Journal of Advances in Scientific Research and Engineering**, 6 (2), 97-103.

Alamgir, M., Ahmed, K., Homsi, R., Dewan, A., Wang, J.-J. and Shahid, S., 2019. Downscaling and projection of spatiotemporal changes in temperature of Bangladesh. **Earth Systems and Environment**, 3, 381-398.

Ali, M.M, Al-Ani, A., Eamus, D. and Tan, D.K.Y., 2012. A new image-processing based technique for measuring leaf dimensions. **American-Eurasian Journal of Agricultural & Environmental Sciences**, 12,1588-1594.

Alkan, Ç., 2021. Porsuk Çayı Havzasında İklim Değişikliğinin Kuraklığa ve Buğday Verimine Etkisinin Belirlenmesi. **Tekirdağ Namık Kemal Üniversitesi. Fen Bilimleri Enstitüsü**, Biyosistem Mühendisliği Anabilim Dalı, Doktora Tezi, Tekirdağ, 165 sayfa.

Allen, R.G., Pereira, L.S., Raes, D. and Smith, M., 1998. **Crop evapotranspiration-guidelines for computing crop water requirements.** FAO Irrigation and Drainage Paper 56. FAO, Rome, Italy 300, D05109. ISBN 92-5-104219-5.

Alsaber, A.R., Pan, J. and Al-Hurban, A., 2021. Handling complex missing data using random forest approach for an air quality monitoring dataset: a case study of Kuwait environmental data (2012 to 2018). **International Journal of Environmental Research and Public Health**, 18 (3), 1333.

Anonim, 2010. Tarımsal Değerleri Ölçme Denemeleri Teknik Talimatı. T.C. Tarım Ve Köyişleri Bakanlığı Tarımsal Üretim ve Geliştirme Genel Müdürlüğü Tohumluk Tescil ve Sertifikasyon Merkezi Müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Tescil/Teknik%20Talimatlar/S%C4%B1cak%20%C4%B0klim%20Tah%C4%B1llar%C4%B1/m%C4%B1s%C4%B1r.pdf. (Erişim Tarihi: 21.10.2021).

Anonim, 2021. TBMM İklim Raporu. https://www5.tbmm.gov.tr/sirasayi/donem27/yil01/ss300.pdf. (Erişim tarihi: 15.06.2022).

Anwar, M.R., Wang, B., Li Liu, D. and Waters, C., 2020. Late planting has great potential to mitigate the effects of future climate change on Australian rain-fed cotton. **Science of The Total Environment,** 714, 136806.

Ara, M., Zannat, N. and Saha, S., 2023. Artificial neural network for forecasting monsoon rainfall of south-west region in Bangladesh. **American Journal of Environment and Climate**, 2 (1), 11-23.

Araya, A., Kisekka, I., Lin, X., Vara Prasad, P.V., Gowda, P.H., Rice, C. and Andales, A., 2017. Evaluating the impact of future climate change on irrigated maize production in Kansas. **Climate Risk Management**, 17, 139-154.

Aubakirova, G., Ivel, V., Gerassimova, Y., Moldakhmetov, S. and Petrov, P., 2022. Application of artificial neural network for wheat yield forecasting. **Eastern-European Journal of Enterprise Technologies**, 117 (4), 31-39.

Ayankojo, I.T., Thorp, K.R., Morgan, K., Kothari, K. and Ale, S., 2020. Assessing the impacts of future climate on cotton production in the Arizona low desert. **Transaction of ASABE**, 63 (4), 1087-1098.

Aziz, M., Rizvi, S.A., Sultan, M., Bazmi, M.S.A., Shamshiri, R.R., Ibrahim, S.M. and Imran, M.A., 2022. Simulating cotton growth and productivity using aquacrop model under deficit irrigation in a semi-arid climate. **Agriculture**, 12 (2), 242.

Baczkiewicz, A., Wątróbski, J., Sałabun, W. and Kołodziejczyk, J., 2021. An ANN Model Trained on Regional Data in the Prediction of Particular Weather Conditions. **Applied Sciences**, 11 (11), 4757.

Baede, A.P.M., Ahlonsou, R., Ding, Y. and Schimel, D., 2001. The climate system: An overview. In: **Climate Change 2001**. Cambridge University Press. ISBN: 0521 80767-0.

Bağçaci, S.Ç., Yucel, I., Duzenli, E. and Yilmaz, M.T., 2021. Intercomparison of the expected change in the temperature and the precipitation retrieved from CMIP6 and CMIP5 climate projections: a Mediterranean hot spot case, Turkey. **Atmospheric Research**, 256, 105576.

Bandyopadhyay, A., Bhadra, A., Raghuwanshi, N.S. and Singh, R., 2008. Estimation of monthly solar radiation from measured air temperature extreme. **Agricaltural and Forest Meteorology**, 148 (11), 1707-1718.

Bangash, R.F., Passuello, A., Sanchez-Canales, M., Terrado, M., López, A., Elorza, F.J., Ziv, G., Acuña, V. and Schuhmacher, M., 2013. Ecosystem services in Mediterranean river basin: climate change impact on water provisioning and erosion control. **Science of the Total Environment**, 458-460, 246-255.

Bange, M.P. and Milroy, S.P., 2004. Growth and dry matter partitioning of diverse cotton genotypes. **Field Crops Research**, 87 (1), 73-87.

Bassu, S., Brisson, N., Durand, J.-L., Boote, K., Lizaso, J., Jones, J.W., Rosenzweig, C., Ruane, A.C., Adam, M., Baron, C., Basso, B., Biernath, C., Boogaard, H., Conijn, S., Corbeels, M., Deryng, D., De Sanctis, G., Gayler, S., Grassini, P., Hatfield, J., Hoek, S., Izaurralde, C., Jongschaap, R., Kemanian, A.R., Kersebaum, K.C., Kim, S.-H., Kumar, N.S., Makowski, D., Müller, C., Nendel, C., Priesack, E., Pravia, M.V., Sau, F., Shcherbak, I., Tao, F., Teixeira, E., Timlin, D. and Waha, K., 2014. How do various maize crop models vary in their responses to climate change factors? **Global Change Biology**, 20 (7), 2301-2320.

Baydar, A., 2010. Seyhan Ovası koşullarında iklim değişikliklerinin pamuk bitkisi üzerindeki olası etkilerinin incelenmesi. **Çukurova Ünivesitesi. Fen Bilimleri Enstitüsü,** Tarımsal Yapılar ve Sulama Anabilim Dalı, Yüksek Lisans Tezi, Adana, 57 sayfa.

Baydar, A. ve Kanber, R. 2012. İklimsel değişikliklerin pamuk üretimine etkilerinin incelenmesi. **Toprak Su Dergisi**, 1 (1), 47-53.

Belayneh, A., Adamowski, J., Khalil, B. and Ozga-Zielinski, B., 2014. Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. **Journal of Hydrology**, 508, 418-429.

Beyer, R., Krapp, M. and Manica, A., 2019. A systematic comparison of bias correction methods for paleoclimate simulations. **Climate Past Discussion**, 1-23.

Bhusal, A., Parajuli, U., Regmi, S. and Kalra, A., 2022. Application of machine learning and process-based models for rainfall-runoff simulation in Dupage River basin, Illinois. **Hydrology**, 9 (7), 117.

Birpınar, M.E., 2022. Küresel sorun iklim değişikliği: gelişimi, uluslararası müzakereler ve Türkiye. **Çevre, Şehir ve İklim Dergisi**. 1 (1), 20-36.

Blessie, E.C. and Karthikeyan, E., 2012. Sigmis: A feature selection algorithm using correlation based method. **Journal of Algorithms & Computational Technology**, 6 (3), 385-394.

Bonelli, L.E. and Andrade, F.H., 2020. Maize radiation use-efficiency response to optimally distributed foliar-nitrogen-content depends on canopy leaf-area index. **Field Crops Research**, 247, 107557.

Bouyoucos, G.J., 1962. Hydrometer method improved for making particle size analyses of soils. **Agronomy Journal**, 54 (5), 464-465.

Bozkurt, D. and Sen, O.L., 2013. Climate change impacts in the Euphrates–Tigris Basin based on different model and scenario simulations. **Journal of Hydrology**, 480, 149-161.

Breiman, L., 2001. Random Forests. **Machine Learning**, 45, 5-32.

Bronson, K.F., Chua, T.T., Booker, J.D., Keeling, J.W., ve Lascano, R.J., 2003. In-season nitrogen status sensing in ırrigated cotton: II. Leaf nitrogen and biomass. **Soil Science Society of America Journal**, 67 (5), 1439-1448.

BUGEM, 2016. Çeşit Kataloğu. T.C. tarım ve orman bakanlığı bitkisel üretim genel müdürlüğü tohumluk tescil ve sertifikasyon merkez müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Yay%C4%B1nlar/%C3%87E%C5%9E%C4%B0T%20KATALO%C4%9EU-2016.pdf. (Erişim tarihi: 01.11.2022).

BUGEM, 2017. Çeşit Kataloğu. T.C. tarım ve orman bakanlığı bitkisel üretim genel müdürlüğü tohumluk tescil ve sertifikasyon merkez müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Yay%C4%B1nlar/%C3%87e%C5%9Fit%20Katalo%C4%9Fu%202017.pdf. (Erişim tarihi: 01.11.2022).

BUGEM, 2018. Çeşit Kataloğu. T.C. tarım ve orman bakanlığı bitkisel üretim genel müdürlüğü tohumluk tescil ve sertifikasyon merkez müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Yay%C4%B1nlar/%C3%87e%C5%9Fit%20Katalo%C4%9Fu%202018.pdf. (Erişim tarihi: 01.11.2022).

BUGEM, 2020. Çeşit Kataloğu. T.C. tarım ve orman bakanlığı bitkisel üretim genel müdürlüğü tohumluk tescil ve sertifikasyon merkez müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Yay%C4%B1nlar/%C3%87e%C5%9Fit%20Katologlar%C4%B1/2020/2020%20YILI%20SICAK%20%C4%B0KL%C4%B0M%20TAHILLARI%20%C3%87E%C5%9E%C4%B0T%20KATALO%C4%9EU.pdf. (Erişim tarihi: 01.11.2022).

BUGEM, 2022. Çeşit Kataloğu. T.C. tarım ve orman bakanlığı bitkisel üretim genel müdürlüğü tohumluk tescil ve sertifikasyon merkez müdürlüğü. https://www.tarimorman.gov.tr/BUGEM/TTSM/Belgeler/Yay%C4%B1nlar/%C3%87e%C5%9Fit%20Katologlar%C4%B1/2022/Tarla%20Bitkileri%20T%C3%BCrleri/SICAK%20%C4%B0KL%C4%B0M%20TAHILLARI.pdf. (Erişim tarihi: 01.11.2022).

Cael, B.B., Bisson, K., Boss, E., Dutkiewicz, S. and Henson, S., 2023. Global climate change trends detected in indicators of ocean ecology. **Nature**, 619, 551–554.

Canadell, J.G., Monteiro, P.M.S., Costa, M.H., Cotrim da Cunha, L., Cox, P.M., Eliseev, A.V., Henson, S., Ishii, M., Jaccard, S., Koven, C., Lohila, A., Patra, P.K., Piao, S., Rogelj, J., Syampungani, S., Zaehle, S. and Zickfeld, K., 2021. Global Carbon and other Biogeochemical Cycles and Feedbacks. In: **Climate Change 2021: The Physical Science Basis, Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press, Cambridge, UK. ISBN:9781009157896.

Canchala-Nastar, T., Carvajal-Escobar, Y., Alfonso-Morales, W., Loaiza Cerón, W. and Caicedo, E., 2019. Estimation of missing data of monthly rainfall in southwestern Colombia using artificial neural networks. **Data in Brief**, 26, 104517.

Cannon, A.J., 2015. Selecting GCM scenarios that span the range of changes in a multimodel ensemble: Application to CMIP5 climate extremes indices. **Journal of Climate**, 28 (3), 1260-1267.

Chen, X., Qi, Z., Gui, D., Gu, Z., Ma, L., Zeng, F. and Li, L., 2019. Simulating impacts of climate change on cotton yield and water requirement using RZWQM2. **Agricultural Water Management**, 222, 231-241.

Chifurira, R., Chikobvu, D. and Dubihlela, D., 2016. Rainfall prediction for sustainable economic growth. **Environmental Economics**, 7 (4), 120-129.

Chineke, T.C., 2008. Equations for estimating global solar radiation in data sparse regions. **Renewable Energy**, 33 (4), 827-831.

Commuri, P.D. and Jones, R.J., 2001. High temperatures during endosperm cell division in maize. **Crop Science**, 41 (4),1122-1130.

Coulibaly, P. and Evora, N.D., 2007. Comparison of neural network methods for infilling missing daily weather records. **Journal of Hydrology**, 341 (1-2), 27-41.

Craufurd, P.Q. and Wheeler, T.R., 2009. Climate change and the flowering time of annual crops. **Journal of Experimental Botany**, 60 (9), 2529-2539.

Cui, T., Li, C. and Tian, F., 2021. Evaluation of temperature and precipitation simulations in CMIP6 models over the Tibetan Plateau. **Earth and Space Science**, 8 (7), 1-20.

Cutler, A., Cutler, D.R. and Stevens, J.R., 2012. Random Forests. In: **Ensemble Machine Learning**. Springer. ISBN: 978-1-4419-9325-0.

Çaktu, Y., 2022. Identifying Impacts of Climate Change on Water Resources Using CMIP6 Simulations: Havran Basin Case. **Orta Doğu Teknik Üniversitesi**. **Fen Bilimleri Enstitüsü**, Yer Sistem Bilimi Anabilim Dalı, Yüksek Lisans Tezi, Ankara, 200 sayfa.

Dada, E.G., Yakubu, H.J. and Oyewola, D.O., 2021. Artificial Neural Network Models For Rainfall Prediction. **European Journal of Electrical Engineering and Computer Science**, 5 (2), 30-35.

Dahamsheh, A., and Aksoy, H., 2009. Artificial neural network models for forecasting intermittent monthly precipitation in arid regions. **Meteorological Applications**, 16 (3), 325-337.

Danandeh Mehr, A., Sorman, A.U., Kahya, E., and Hesami Afshar, M., 2019. Climate change impacts on meteorological drought using SPI and SPEI: case study of Ankara, Turkey. **Hydrological Sciences Journal**, 65:2, 254-268.

Dangeti, P., 2017. **Statistics for Machine Learning**. Birmingham Packt Publishing. ISBN: 9781788295758.

Das, P., Zhang, Z., Ghosh, S., Lu, J., Ayugi, B., Ojara, M.A. and Guo, X., 2023. Historical and projected changes in Extreme High Temperature events over East Africa and associated with meteorological conditions using CMIP6 models. **Global and Planetary Change**, 222 (15), 104068.

De Vaus, D., 2002. **Analyzing social science data. 50 key problems in data analysis**. Sage Publications. ISBN: 0761959378.

Deveci, H., 2015. Trakya Bölgesi'nde İklim Değişikliğinin Yüzey Su Kaynakları, Toprak Nemi ve Bitki Verimine Etkisinin Modellenmesi. **Namık Kemal Üniversitesi. Fen Bilimleri Enstitüsü**, Biyosistem Mühendisliği Anabilim Dalı, Doktora Tezi, Tekirdağ, 234 sayfa.

Diamond, M.S. and Bennartz, R., 2015. Occurrence and trends of eastern and central Pacific El Niño in different reconstructed SST data sets. **Geophysical Research Letters**, 42 (23), 10375-10381.

Diez, F.J., Boukharta, O.F., Navas-Gracia, L.M., Chico-Santamarta, L., Martínez-Rodríguez, A. and Correa-Guimaraes, A., 2022. Daily estimation of global solar irradiation and temperatures using artificial neural networks through the virtual weather station concept in Castilla and León, Spain. **Sensors**, 22 (20), 7772.

Docquier, D., Vannitsem, S., Ragone, F., Wyser, K. and Liang, X.S., 2022. Causal links between Arctic sea ice and its potential drivers based on the rate of information transfer. **Geophysical Research Letters**, 49 (9), e2021GL095892.

Dombaycı, Ö.A. and Gölcü, M., 2009. Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. **Renewable Energy**, 34 (4), 1158-1161.

Dubrovský, M., Svoboda, M.D., Trnka, M., Hayes, M.J., Wilhite, D.A., Zalud, Z. and Hlavinka, P., 2009. Application of relative drought indices in assessing climate change impacts on drought conditions in Czechia. **Theoretical and Applied Climatology**, 96, 155-171.

Dubrovský, M., Hayes, M., Duce, P., Trnka, M., Svoboda, M. and Zara, P., 2014 Multi-GCM projections of future drought and climate variability indicators for the Mediterranean region. **Regional Environmental Change**, 14, 1907-1919.

Duffie, J.A. and Beckman, W.A., 2013. **Solar engineering of thermal processes**. John Wiley & Sons. ISBN: 978-0470873663.

Dumrul, Y. and Kılıçaslan, Z., 2017. Economic impacts of climate change on agriculture: Empirical evidence from ARDL approach for Turkey. **Journal of Business, Economics and Finance**, 6 (4), 336-347.

Dupuis, I., and Dumas, C., 1990. Influence of temperature stress on in vitro fertilization and heat shock protein synthesis in maize (*Zea mays* L.) reproductive tissues. **Plant Physiology**, 94 (2), 665-670.

Eckstein, D., Künzel, V. and Schäfer, L., 2021. **Global climate risk index 2021**. Bonn: Germanwatch. ISBN: 978-3-943704-84-6.

Eekhout, J.P.C. and de Vente, J., 2019. The implications of bias correction methods and climate model ensembles on soil erosion projections under climate change. **Earth Surface Processes and Landforms**, 44 (5), 1137-1147.

Estefan, G., Sommer, R. and Ryan, J., 2014. **Analytical methods for soil-plant and water in the dry areas. A Manual of Relevance to the West Asia and North Africa Region**. 3rd Edition, International Center for Agricultural Research in the Dry Areas Published.

Eyring, V., Bony, S., Meehl, G.A., Senior, C.A., Stevens, B., Stouffer, R.J. and Taylor, K.E., 2016. Overview of the coupled model intercomparison project phase 6 (CMIP6) experimental design and organization. **Geoscientific Model Development**, 9 (5), 1937-1958.

Fahey, D.W., Doherty, S.J., Hibbard, K.E., Romanou, A. and Taylor, P.C., 2017. Physical drivers of climate change. In: **Climate Science Special Report: Fourth National Climate Assessment**. Global Change Research Program. Washington DC, USA.

Fan, X., Lv, X., Gao, P., Zhang, L., Zhang, Z., Zhang, Q., Ma, Y., Yi, X., Yin, C. and Ma, L., 2023. Establishment of a monitoring model for the cotton leaf area index based on the canopy reflectance spectrum. **Land**, 12 (1), 78.

Farahani, H.J., Izzi, G. and Oweis, T.Y., 2009. Parameterization and evaluation of the Aquacrop model for full and deficit ırrigated cotton. **Agronomy Journal**, 101 (3), 469-476.

Feleke, H.G., Savage, M.J., Fantaye, K.T. and Rettie, F.M., 2023. The role of crop management practices and adaptation options to minimize the ımpact of climate change on maize (*Zea Mays* L.) production for Ethiopia. **Atmosphere**, 14 (3), 497.

Fernández-Delgado, M., Cernadas, E., Barro, S. and Amorim, D., 2014. Do we need hundreds of classifiers to solve real world classification problems? **The Journal of Machine Learning Research**, 15, 3133-3181.

Feyissa, T.A., Demissie, T.A., Saathoff, F. and Gebissa, A., 2023. evaluation of general circulation models cmıp6 performance and future climate change over the Omo River Basin, Ethiopia. **Sustainability**, 15 (8), 6507.

Fonti, V. and Belitser, E., 2017. **Feature selection using LASSO**. Amsterdam: VU Amsterdam Research Paper in Business Analytics.

Freiwan, M. and Cigizoglu, H.K., 2005. Prediction of total monthly rainfall in Jordan using feed forward backpropagation method. **Fresenius Environmental Bulletin**, 14 (2), 142-151.

Gadédjisso-Tossou, A., Avellán, T. and Schütze, N., 2020. Impact of irrigation strategies on maize (*Zea mays* L.) production in the savannah region of northern Togo (West Africa). **Water SA**, 46 (1), 141-152.

García-Vila, M., Fereres, E., Mateos, L., Orgaz, F. and Steduto, P., 2009. Deficit irrigation optimization of cotton with Aquacrop. **Agronomy Journal**. 101 (3), 477-487.

Gençoğlu, M. ve Değirmenci, H., 2019. Sulama performansının değerlendirilmesi: Kırıkhan sulama birliği örneği. **Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi**, 22 (3), 436-443.

GEPA, 2020. Güneş enerjisi potansiyeli atlası. Enerji İşleri Genel Müdürlüğü. https://gepa.enerji.gov.tr/MyCalculator/pages/31.aspx. (Erişim Tarihi: 03.11.2020).

Ghanbarzadeh, A., Noghrehabadi, A.R., Assareh, E. and Behrang, M.A., 2009. Solar radiation forecasting based on meteorological data using artificial neural networks. **7th IEEE International Conference on Industrial Informatics** 23-26 June, Cardiff, Wales, UK, s:227-231.

Ghimire, U., Srinivasan, G. and Agarwal, A., 2019. Assessment of rainfall bias correction techniques for improved hydrological simulation. **International Journal of Climatology**, 39 (4), 2386-2399.

Giorgi, F., 2006. Climate change hot-spots. **Geophysical Research Letters**, 33 (8), 1-4.

Goly, A., Teegavarapu, R.S.V. and Mondal, A., 2014. Development and evaluation of statistical downscaling models for monthly precipitation. **Earth Interactions**, 18 (18), 1-28.

Gómez-Escalonilla, V., Martínez-Santos, P. and Martín-Loeches, M., 2022. Preprocessing approaches in machine-learning-based groundwater potential mapping: an application to the Koulikoro and Bamako regions, Mali. **Hydrology and Earth System Sciences**, 26 (2), 221-243.

Goyal, M.K. and Ojha, C.S.P., 2012. Downscaling of precipitation on a lake basin: evaluation of rule and decision tree induction algorithms. **Hydrology Research**, 43 (3), 215-230.

Görgüner, M., Kavvas, M.L. and Ishida, K. 2019 Assessing the impacts of future climate change on the hydroclimatology of the Gediz Basin in Turkey by using dynamically downscaled CMIP5 projections. **Science of The Total Environment**, 648, 481-499.

Gupta, B., Awasthi, S., Gupta, R., Ram, L., Kumar, P., Rohit Prasad, B. and Agarwal, S., 2018. Taxi travel time prediction using ensemble-based random forest and gradient boosting model. **Advances in Big Data and Cloud Computing**, 63-78.

Gupta, H.V., Sorooshian, S. and Yapo, P.O., 1999. Status of automatic calibration for hydrologic models: comparison with multilevel expert calibration. **Journal of Hydrologic Engineering**, 4 (2), 135-143.

Gusain, A., Ghosh, S. and Karmakar, S., 2020. Added value of CMIP6 over CMIP5 models in simulating Indian summer monsoon rainfall. **Atmospheric Research**, 232, 104680.

Gümüş, B., Oruc, S., Yucel, I. and Yilmaz, M.T., 2023. Impacts of climate change on extreme climate indices in Türkiye driven by high-resolution downscaled CMIP6 climate models. **Sustainability**, 15 (9), 7202.

Gündoğan, A.C., Baş, D. ve Sayman, R.Ü., 2015. **A'dan Z'ye iklim değişikliği başucu rehberi**. Bölgesel Çevre Merkezi REC Türkiye. ISBN: 978-975-6180-43-3.

Güngör, Y., Erözel, A.Z. ve Yıldırım, O., 2012. Sulama. Ankara Üniversitesi Ziraat Fak. Yayınları No: 1592.

Güven, A., and Pala, A., 2022. Comparison of different statistical downscaling models and future projection of areal mean precipitation of a river basin under climate change effect. **Water Supply**, 22 (3), 2424-2439.

Hadjisolomou, E., Stefanidis, K., Herodotou, H., Michaelides, M., Papatheodorou, G. and Papastergiadou, E., 2021. Modelling freshwater eutrophication with limited limnological data using artificial neural networks. **Water**, 13 (11), 1590.

Haim, D., Shechter, M. and Berliner, P., 2008. Assessing the impact of climate change on representative field crops in Israeli agriculture: a case study of wheat and cotton. **Climatic Change**, 86, 425-440.

Hajjdiab, H. and Obaid, A., 2010. A vision-based approach for nondestructive leaf area estimation. **The 2nd Conference on Environmental Science and Information Application Technology**, 17-18 July Wuhan, s: 53-56.

Hamed, M.M., Nashwan, M.S., Shahid, S., bin Ismail, T., Wang, X.-j., Dewan, A. and Asaduzzaman, M., 2022a. Inconsistency in historical simulations and future projections of temperature and rainfall: A comparison of CMIP5 and CMIP6 models over Southeast Asia. **Atmospheric Research**. 265, 105927.

Hamed, M.M., Sammen, S.S., Nashwan, M.S. and Shahid, S., 2022b. Spatiotemporal variation of drought in Iraq for shared socioeconomicpathways. **Stochastic Environmental Research and Risk Assessment**, 37, 1321-1331.

Hammami, D., Lee, T.S., Ouarda, T.B.M.J. and Lee, J., 2012. Predictor Selection for downscaling GCM data with LASSO. **Journal of Geophysical Research: Atmospheres**, 117 (D17), 1-11.

Hanoon, M.S., Ahmed, A.N., Zaini, N., Razzaq, A., Kumar, P., Sherif, M., and El-Shafie, A., 2021. Developing machine learning algorithms for meteorological temperature and humidity forecasting at Terengganu state in Malaysia. **Scientific Reports**, 11, 18935.

Hargreaves, G.H. and Samani, Z.A., 1982. Estimating potential evapotranspiration. **Journal of the Irrigation and Drainage Division**, 108 (3), 225-230.

Hargreaves, G.H. and Samani, Z.A., 1985. Reference crop evapotranspiration from temperature. **Applied Engineering in Agriculture**, 1 (2), 96-99.

Hastie, T., Tibshirani, R. and Tibshirani, R.J., 2020. Best subset, forward stepwise or Lasso? Analysis and recommendations based on extensive comparisons. **Statistical Science**, 35 (4), 579-592.

Hatfield, J.L., Boote, K.J., Kimball, B.A., Ziska, L.H., Izaurralde, R.C., Ort, D., Thomson, A.M. and Wolfe, D., 2011. Climate impacts on agriculture: implications for crop production. **Agronomy Journal**, 103 (2), 351-370.

Hatmoko, W., Levina, and Diaz, B., 2020. Comparison of rainfall-runoff models for climate change projection–case study of Citarum River Basin, Indonesia. **The 4th International Conference on Climate Change** 18–19 November, Indonesia, s: 1-8.

Hausfather, Z., 2018. Explainer: How 'Shared Socioeconomic Pathways' explore future climate change'. Carbon Brief 19. https://www.carbonbrief.org/explainer-how-shared-socioeconomic-pathways-explore-future-climate-change/ (Erişim tarihi: 25.06.2021).

Heaton, J., 2008. **Introduction to Neural Networks with Java**. Heaton Research. ISBN: 1604390085.

Hebbar, K.B., Venugopalan, M.V., Prakash, A.H. and Aggarwal, P.K., 2013. Simulating the impacts of climate change on cotton production in India. **Climatic Change**, 118, 701-713.

Held, I.M. and Soden, B.J., 2006. Robust responses of the hydrological cycle to global warming. **Journal of Climate**, 19, 5686-5699.

Heng, L.K., Hsiao, T., Evett, S., Howell, T. and Steduto, P., 2009. Validating the FAO Aquacrop model for irrigated and water deficient field maize. **Agronomy Journal**, 101 (3), 488-498.

Henry, M. and Merlis, T.M., 2020. Forcing dependence of atmospheric lapse rate changes dominates residual polar warming in solar radiation management climate scenarios. **Geophysical Research Letters**, 47 (15), 1-8.

Homsi, R., Shiru, M.S., Shahid, S., Ismail, T., Harun, S.B., Al-Ansari, N., Chau, K.W. and Yaseen, Z.M., 2020. Precipitation projection using a CMIP5 GCM ensemble model: a regional investigation of Syria. **Engineering Applications of Computational Fluid Mechanics**, 14 (1), 90-106.

Hope, P., Keay, K., Pook, M., Catto, J., Simmonds, I., Mills, G. and Berry, G., 2014. A comparison of automated methods of front recognition for climate studies: A case study in Southwest Western Australia. **Monthly Weather Review**, 142 (1), 343-363.

Hsiao, T.C., Heng, L., Steduto, P., Rojas-Lara, B., Raes, D. and Fereres, E., 2009. Aquacrop-The FAO crop model to simulate yield response to water: III. parameterization and testing for maize. **Agronomy Journal**. 101 (3), 448-459.

Hudnurkar, S. and Rayavarapu, N., 2023. On the Performance Analysis Of Rainfall Prediction Using Mutual Information With Artificial Neural Network. **International Journal of Electrical and Computer Engineering**, 13 (2), 2101-2113.

Hussein, F., Janat, M. and Yakoub, A., 2011. Simulating cotton yield response to deficit irrigation with the FAO AquaCrop model. **Spanish Journal of Agricultural Research**, 9 (4), 1319-1330.

Ikpang, I.N., Okon, E. J. and George, E.U., 2022. Modeling average rainfall in Nigeria with artificial neural network (ANN) models and seasonal autoregressive integrated moving average (SARIMA) models. **International Journal of Statistics and Probability**, 11 (4), 53-62.

Ines, A.V.M. and Hansen, J.W., 2006. Bias correction of daily GCM Rainfall for crop simulation studies. **Agricultural and Forest Meteorology**, 138 (1-4), 44-53.

IPCC, 2007. **Climate Change 2007: Impacts, adaptation, and vulnerability**. Cambridge University Press. ISBN: 978052188010-7.

IPCC, 2014. **Climate Change 2014 Synthesis Report**. IPCC. ISBN: 978-92-9169-143-2.

IPCC, 2021. **AR6 climate change 2021: The physical science basis**. Cambridge University Press. ISBN: 9781009157896.

IPCC, 2022. **Climate change 2022: Impacts, adaptation, and vulnerability**. Cambridge University Press. ISBN: 9781009325844.

Iqbal, M.A., Ping, Q., Abid, M., Kazmi, S.M.M. and Rizwan, M., 2016. Assessing risk perceptions and attitude among cotton farmers: a case of Punjab province, Pakistan **International Journal of Disaster Risk Reduction**, 16, 68-74.

Iqbal, Z., Shahid, S., Ahmed, K., Ismail, T., Ziarh, G.F., Chung, E.-S. and Wang, X., 2021. Evaluation of CMIP6 GCM rainfall in mainland Southeast Asia. **Atmospheric Research**, 254, 105525.

İrvem, A. and Özbuldu, M., 2018. Accuracy of satellite-based solar data to estimate solar energy potential for Hatay province, Turkey. **Bitlis Eren Üniversitesi Fen Bilimleri Dergisi**, 7 (2), 361-369.

Islam, A., Ahuja, L.R., Garcia, L.A., Ma, L. and Saseendran, A.S., 2012. Modeling the effect of elevated CO_2 and climate change on potential evapotranspiration in the semi-arid Central Great Plains. **American Society of Agricultural and Biological Engineers**, 55 (6), 2135-2146.

Jahanbani, H. and El-Shafie, A.H., 2011. Application of artificial neural network in Estimating monthly time series reference evapotranspiration with minimum and maximum temperatures. **Paddy and Water Environment**, 9, 207-220.

Jain, S., Salunke, P., Mishra, S.K. and Sahany, S., 2019. Performance of CMIP5 models in the simulation of Indian summer monsoon. **Theoretical and Applied Climatology**, 137, 1429-1447.

Jiang, T., Gradus, J.L. and Rosellini, A.J., 2020. Supervised machine learning: a brief primer. **Behavior Therapy**, 51 (5), 675-687.

Joseph, V.R., 2022. Optimal ratio for data splitting. **Statistical Analysis and Data Mining: The ASA Data Science Journal**, 15 (4), 531-538.

Kaçar, B., 2016. **Fiziksel ve Kimyasal Toprak Analizleri**. Nobel Basımevi. ISBN: 9786053204305.

Kadu, P.P. Wagh, K.P. and Chatur, P.N., 2012. Temperature prediction system using back propagation neural network: An approach. **International Journal of Computer Science & Communication Networks**, 2 (1), 61-64.

Kamruzzaman, M., Shahid, S., Islam, A.R.M.T., Hwang, S., Cho, J., Zaman, A.U., Ahmed, M., Rahman, M. and Hossain, B., 2021. Comparison of CMIP6 and CMIP5 model performance in simulating historical precipitation and temperature in Bangladesh: a preliminary study. **Theoretical and Applied Climatology**, 145, 1385-1406.

Kanber, R., Kapur, B., Ünlü, M., Tekin, S. ve Koç, L.D., 2008. İklim değişiminin tarımsal üretim sistemleri üzerine etkisinin değerlendirilmesine yönelik yeni bir yaklaşım ICCAP Projesi. **TMMOB 2. Su Politikaları Kongresi** 20-22 Mart Ankara, s: 83-94.

Kanber, R., Ünlü, M., Kapur, B., Özekici, B. and Donma, S., 2019. Adaptation of contemporary ırrigation systems to face the challenges of future climate changes in the Mediterranean region: A case study of the lower Seyhan ırrigation system. In: **Climate Change Impacts on Basin Agro-ecosystems**. Springer, Switzerland. ISBN: 978-3-030-01035-5.

Karabulut, M.A. ve Topçu, E., 2022. Derin öğrenme teknikleri kullanılarak Kars ilinin hava sıcaklık tahmini. **Mühendislik Bilimleri ve Tasarım Dergisi**, 10 (4), 1174-1181.

Karaoğlu, M. ve Şimşek, U., 2014. **Toprak Fiziği Uygulamaları**. Nobel Akademik Yayıncılık. ISBN. 978-605-133-726-5.

Karimi, M.A. 2021. Altınova tarım işletmesinde kuraklığın buğday verimine etkisi. **Ankara Üniversitesi**. **Fen Bilimleri Enstitüsü**, Tarımsal Yapılar ve Sulama Anabilim Dalı, Yüksek Lisan Tezi, Ankara, 68 sayfa.

Kapur, B., 2010. Artan CO_2 ve küresel iklim değişikliğinin çukurova bölgesinde buğday verimliliği üzerine etkileri. **Çukurova Üniversitesi**, **Fen Bilimleri Enstitüsü**, Tarımsal Yapılar ve Sulama Anabilim Dalı, Doktora Tezi, Adana, 179 sayfa.

Katipoğlu, O.K. and Acar, R., 2021. Estimation of missing temperature data by Artificial Neural Network (ANN). **Dicle University Journal of Engineering**, 12 (2), 431-438.

Kenarsari, S.D., Yang, D., Jiang, G., Zhang, S., Wang, J., Russell, A. G., Wei, Q. and Fan, M., 2013. Review of recent advances in carbon dioxide separation and capture. **RSC Advances**. 3 (45), 22739–22773.

Kent, E.C., Berry D.I, Prytherch, J. and Roberts J.B., 2014. A comparison of global marine surface-specific humidity datasets from *in situ* observations and atmospheric reanalysis. **International journal of climatology**, 34 (2), 355-376.

Khadka, D., Babel, M.S., Abatan, A.A. and Collins, M., 2021. An evaluation of CMIP5 and CMIP6 climate models in simulating summer rainfall in the Southeast Asian monsoon domain. **International Journal of Climatology**, 42(2), 1181-1202.

Khafajeh, H., Banakar, A., Minaei, S. and Delavar, M., 2020. Evaluation of Aquacrop model of cucumber under greenhouse cultivation. **The Journal of Agricultural Science**, 158 (10), 845-854.

Khanzode, K.C.A. and Sarode, R.D., 2020. Advantages and disadvantages of artificial intelligence and machine learning: A literature review. **International Journal of Library & Information Science**, 9 (1), 30-36.

Khastagir, A., Hossain, I. and Anwar, A.H.M.F., 2022. Efficacy of linear multiple regression and artificial neural network for long-term rainfall forecasting in Western Australia. **Meteorology and Atmospheric Physics**, 134, 1-11.

Kırdemir, U. ve Okkan, U., 2019. Farklı yanlılık düzeltme yöntemlerinin istatistiksel ölçeğe indirgenmiş yağış projeksiyonlarına uygulanması. **Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 21 (2), 868-881.

Kim, I.-W., Oh, J., Woo, S. and Kripalani, R.H., 2018. Evaluation of precipitation extremes over the Asian domain: observation and modelling studies. **Climate Dynamics**, 52, 1317-1342.

Kim, J.W. and Pachepsky, Y.A., 2010. Reconstructing missing daily precipitation data using regression trees and artificial neural networks for SWAT streamflow simulation. **Journal of Hydrology**, 394 (3-4), 305-314.

Kim, T.W. and Valdés, J.B., 2003. Nonlinear Model for Drought Forecasting Based on a Conjunction of Wavelet Transforms and Neural Networks. **Journal of Hydrologic Engineering**, 8 (6), 319-328.

Korkmaz, H., 2009. Amik Ovası'nda kurak devre ile buğday, pamuk ve mısır tarımı arasındaki ilişki. **Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi**, 6 (11): 56-88.

Koukouli, P. and Georgiou P., 2018. Evaluation of climatechange impacts on cotton yield using cropsyst and regression models. **Journal of Advances in Agriculture**, 8 (1), 1433-1451.

Koyama, K., 2023. Leaf area estimation by photographing leaves sandwiched between transparent clear file folder sheets. **Horticulturae**, 9 (6), 709.

Kuhn, M., 2008. Building predictive models in R using the caret package. **Journal of Statistical Software**, 28 (5), 1-26.

Kumaş, K., Ayan, M., Akyüz, A.Ö. ve Güngör, A. 2020. Antalya ili meteorolojik verileri yardımıyla hava sıcaklığının yapay sinir ağları metodu ile tahmini. **Gümüşhane Üniversitesi Fen Bilimleri Dergisi**, 10 (1), 146-154.

Kundu, S., Khare, D. and Mondal, A., 2017. Future changes in rainfall, temperature and reference evapotranspiration in the central India by least square support vector machine. **Geoscience Frontiers**, 8 (3), 583-596.

Lamboni, B., Emmanuel, L.A., Manirakiza, C. and Djibib, Z.M., 2019. Variability of future rainfall over the Mono River Basin of West-Africa. **American Journal of Climate Change**, 8 (1), 137-155.

LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. **Nature**, 521, 436-444.

Lee, T. and Singh, V.P., 2018. **Statistical downscaling for hydrological and environmental applications**. CRC Press. ISBN: 9780429459580.

Li, F., Yu, D. and Zhao, Y., 2019. Irrigation scheduling optimization for cotton based on the Aquacrop model. **Water Resources Management**, 33, 39-55.

Li, H., Liu, Z., Zhang, X., Chen, D. and Chen, Y., 2022. A positive correlation between seed cotton yield and high-efficiency leaf area index in directly seeded short-season cotton after wheat. **Field Crops Research**, 285, 108594.

Li, N., Li, Y., Biswas, A., Wang, J., Dong, H., Chen, J. and Fan, X., 2021. Impact of climate change and crop management on cotton phenology based on statistical analysis in the main-cotton-planting areas of China. **Journal of Cleaner Production**, 298, 126750.

Li, S.-Y., Miao, L.-J., Jiang, Z.-H., Wang, G.-J., Gnyawali, K.R., Zhang, J., Zhang, H., Fang, K., He, Y. and Li, C., 2020. Projected drought conditions in Northwest China with CMIP6 models under combined SSPs and RCPs for 2015–2099. **Advances in Climate Change Research**, 11 (3), 210-217.

Liang, P., Yan, Z.-W. and Li, Z., 2022. Climatic warming in Shanghai during 1873–2019 based on homogenised temperature records. **Advances in Climate Change Research**, 13 (4), 496-506.

Liu, H. and Cocea, M., 2017. Semi-random partitioning of data into training and test sets in granular computing context. **Granular Computing**, 2, 357-386.

Liu, S., Tai, H., Ding, Q., Li, D., Xu, L. and Wei, Y., 2013. A hybrid approach of support vector regression with genetic algorithm optimization for aquaculture water quality prediction. **Mathematical and Computer Modelling**, 58 (3-4), 458-465.

Liu, S., Raghavan, S.V., Ona, B.J. and Nguyen, N.S., 2023. Bias evaluation in rainfall over Southeast Asia in CMIP6 models. **Journal of Hydrology**, 621, 129593.

Liu, X., Zhang, X., Kong, X. and Shen, Y.J., 2022. Random Forest Model Has the Potential For Runoff Simulation And Attribution. **Water**, 14 (13), 2053.

Liu, Y., Sang, Y.F., Li, X., Hu, J. and Liang, K., 2016. Long-term streamflow forecasting based on relevance vector machine model. **Water**, 9 (1), 9.

Lobell, D.B. and Burke, M., 2010. **Climate change and food security: adapting agriculture to a warmer world.** Springer Dordrecht. 978-90-481-2952-2.

Londhe, S., Dixit, P., Shah, S. and Narkhede, S., 2015. Infilling of missing daily rainfall records using artificial neural network. **ISH Journal of Hydraulic Engineering**, 21 (3), 255-264.

Luo, Q., 2011. Temperature thresholds and crop production: a review. **Climate Change**, 109, 583-598.

Lv, Z., Li, F. and Lu, G. 2020 Adjusting sowing date and cultivar shift improve maize adaption to climate change in China. **Mitigation and Adaptation Strategies for Global Change**, 25, 87-106.

Majdi, F., Hosseini, S.A, Karbalaee, A., Kaseri, M. and Marjanian, S. 2022. Future projection of precipitation and temperature changes in the Middle East and North Africa (MENA) region based on CMIP6. **Theoretical and Applied Climatology**, 147, 1249-1262.

Makkink, G.F., 1957. Testing the Penman formula by means of lysimeters. **Journal of the Institution of Water Engineerrs**, 11 (3), 277-288.

Manabe, S., 2019. Role of greenhouse gas in climate change. **Tellus A: Dynamic Meteorology and Oceanography**, 71 (1), 1-13.

Masanganise, J., Basira, K., Chipindu, B., Mashonjowa, E. and Mhizha, T., 2013. Testing the utility of a crop growth simulation model in predicting maize yield in a changing climate in Zimbabwe. **International Journal of Agricultural and Food Science**, 3 (4), 157-163.

Masasi, B., Taghvaeian, S., Gowda, P.H., Marek, G. and Boman, R., 2020. Validation and application of Aquacrop for irrigated cotton in the Southern Great Plains of US. **Irrigation Science**, 38 (5-6), 593-607.

Mehdizadeh, S., 2018. Assessing the potential of data-driven models for estimation of long-term monthly temperatures. **Computers and Electronics in Agriculture**, 144, 114-125.

Meinshausen, M., Nicholls, Z.R.J., Lewis, J., Gidden, M.J., Vogel, E., Freund, M., Beyerle, U., Gessner, C., Nauels, A., Bauer, N., Canadell, J.G., Daniel, J.S., John, A., Krummel, P.B., Luderer, G., Meinshausen, N., Montzka, S.A., Rayner, P.J., Reimann, S., Smith, S.J., Berg, M., Velders, G.J.M., Vollmer, M.K. and Wang, R.H.J., 2020. The shared socio-economic pathway (SSP) greenhouse gas concentrations and their extensions to 2500. **Geoscientific Model Development**, 13 (8), 3571-3605.

Mesbahzadeh, T., Mirakbari, M., Mohseni Saravi, M., Soleimani Sardoo, F. and Miglietta, M.M., 2020. Meteorological drought analysis using copula theory and drought indicators under climate change scenarios (RCP). **Meteorological Applications**, 27 (1), 1-20.

Meyer, H., Katurji, M., Appelhans, T., Müller, M.U., Nauss, T., Roudier, P. and Zawar-Reza, P., 2016. Mapping daily air temperature for Antarctica based on MODIS LST. **Remote Sensing**, 8 (9), 732.

MGM, 2022. 2021 Yılı İklim Değerlendirmesi. T.C. Çevre, şehircilik ve iklim değişikliği bakanlığı meteoroloji genel müdürlüğü. https://www.mgm.gov.tr/FILES/iklim/yillikiklim/2021-iklim-raporu.pdf. (Erişim tarihi: 18.01.2023)

Mibulo, T. and Kiggundu, N., 2018. Evaluation of FAO AquaCrop model for simulating rainfed maize growth and yields in Uganda. **Agronomy**, 8 (11), 238.

Misra, D., Oommen, T., Agarwal, A., Mishra, S.K. and Thompson, A.M., 2009. Application and analysis of support vector machine based simulation for runoff and sediment yield. **Biosystems Engineering**, 103 (4), 527–535.

Mital, U., Dwivedi, D., Brown, J.B., Faybishenko, B., Painter, S.L. and Steefel, C.I., 2020. Sequential Imputation of Missing Spatio-Temporal Precipitation Data Using Random Forests. **Frontiers in Water**, 2, 1-15.

Mondal, A. and Mujumdar, P.P., 2012. On the basin-scale detection and attribution of human-induced climate change in monsoon precipitation and streamflow. **Water Resources Research**, 48 (10), 1-18.

Moradi, R., Koocheki, A. and Nassiri Mahallati, M., 2014. Adaptation of maize to climate change impacts in Iran. **Mitigation and Adaptation Strategies for Global Change**, 19, 1223-1238.

Moriasi, D.N., Arnold, J.G., Van Liew, M.W., Bingner, R.L., Harmel, R.D. and Veith, T.L., 2007. Model evaluation guidelines for systematic quantification of accuracy in watershed simulations. **American Society of Agricultural and Biological Engineers**, 50 (3), 885-900.

Moustris, K.P., Larissi, I.K., Nastos, P.T. and Paliatsos, A.G., 2011. Precipitation forecast using artificial neural networks in specific regions of Greece. **Water Resources Management**. 8 (25), 1979-1993.

Napitupulu, D., Rahim, R., Abdullah, D., Setiawan M.I., Abdillah, L.A., Ahmar, A.S., Simarmata, J., Hidayat, R., Nurdiyanto, H. and Pranolo, A., 2018. Analysis of Student Satisfaction Toward Quality of Service Facility. **Journal of Physics: Conference Series**, 954, 012019.

Nashwan, M.S., Shahid, S. and Chung, E.S., 2020. High-resolution climate projections for a densely populated mediterranean region. **Sustainability**, 12 (9), 3684.

Nasim, W., Ahmad, A., Belhouchette, H., Fahad, S. and Hoogenboom, G., 2016. Evaluation of the OILCROP-SUN model for sunflower hybrids under different agro-meteorological conditions of Punjab-Pakistan. **Field Crops Research**, 188, 17-30.

Navarro-Racines, C., Tarapues, J., Thornton, P., Jarvis, A. and Ramirez-Villegas, J., 2020. High-resolution and bias-corrected CMIP5 projections for climate change impact assessments. **Scientific Data**. 7 (1), 1-14.

Nayak, D.R., Mahapatra, A. and Mishra, P., 2013. A Survey on rainfall prediction using artificial neural network. **International journal of computer applications**, 72 (16), 32-40.

Nazeri, B., Crawford, M.M. and Tuinstra, M.R., 2021. Estimating leaf area ındex in row crops using wheel-based and airborne discrete return light detection and ranging data, **Frontiers in Plant Science**, 12, 1-14.

Nelson, G.C., Valin, H., Sands, R.D., Havlik, P., Ahammad, H., Deryng, D., Elliott, J., Fujimori, S., Hasegawa, T., Heyhoe, E., Kyle, P., Lampe, M.V., Lotze-Campen, H., d'Croz, D.M., van Meijil, H., van der Mensbrugghe, D., Müller, C., Popp, A., Robertson, R., Robinson, S., Schmid, E., Schmitz, C., Tabeau, A. and Willenbockel, D., 2013. Climate change effects on agriculture: Economic responses to biophysical shocks. **Proceedings of the National Academy of Sciences**, 111 (9), 3274-3279.

Neu, D.A., Lahann, J. and Fettke, P., 2022. A systematic literature review on state-of-the-art deep learning methods for process prediction. **Artificial Intelligence Review**, 55, 801-827.

Nguyen, H.N., Nguyen, T.A., Ly, H.B., Tran, V.Q., Nguyen, L.K., Nguyen, M.V. and Ngo, C.T., 2021. Prediction of daily and monthly rainfall using a backpropagation neural network. **Journal of Applied Science and Engineering**, 24 (3), 367-379.

Nishant, N., Di Virgilio, G., Ji, F., Tam, E., Beyer, K. and Riley, M.L., 2022 Evaluation of present-day CMIP6 model simulations of extreme precipitation and temperature over the Australian Continent. **Atmosphere**, 13(9), 1478.

Nnadi, N.E. and Carter, D.A., 2021. Climate change and the emergence of fungal pathogens. **PLoS Pathogens**, 17 (4), e1009503.

Noor, M. and İsmail, T., 2018. Downscalıng of daıly average raınfall of Kota Bharu Kelantan,Malaysia. **Malaysian Journal of Civil Engineering**, 30 (1),13-22.

Noor, M., Ismail, T., Shahid, S., Ahmed, K., Chung, E.S. and Nawaz, N., 2019. Selection of CMIP5 multi-model ensemble for the projection of spatial and temporal variability of rainfall in peninsular Malaysia. **Theoretical and Applied Climatology**, 138(1–2), 999–1012.

Noor, M., Ismail, T., Ullah, S., Iqbal, Z., Nawaz, N., Ahmed, K., 2020. A non-local model output statistics approach for the downscaling of CMIP5 GCMs for the projection of rainfall in Peninsular Malaysia. **Journal of Water and Climate Change**, 11 (4), 944-955.

O'Gorman, P.A. and Schneider, T., 2009. The physical basis for increases in precipitation extremes in simulations of 21st-century climate change. **Proceedings of the National Academy of Sciences**, 106 (35), 14773-14777.

Öztürk, M.Z., Çetinkaya, G. ve Aydın, S., 2017. Köppen-Geiger iklim sınıflandırmasına göre Türkiye'nin iklim tipleri. **Cografya Dergisi**, 35, 17-27.

Pang, B., Yue, J., Zhao, G. and Xu, Z., 2017. Statistical downscaling of temperature with the random forest model. **Advances in Meteorology**, 7265178, 1-11.

Papailiou, I., Spyropoulos, F., Trichakis, I. and Karatzas, G.P., 2022. Artificial neural networks and multiple linear regression for filling in missing daily rainfall data. **Water**, 14 (18), 2892.

Perera, A., Azamathulla, H. and Rathnayake, U., 2020. Comparison of different artificial neural network (ANN) training algorithm to predict atmospheric temperature in Tabuk, Saudi Arabia. **Mausam**, 71 (2), 233-244.

Ponte, R. M., 1994. Understanding the relation between wind- and pressure-driven sea level variability. **Journal of Geophysical Research: Oceans**, 99 (C4), 8033-8038.

Prathom, C. and Champrasert, P., 2023. general circulation model downscaling using ınterpolation-machine learning model combination-case study: Thailand. **Sustainability**, 15 (12), 9668.

Pratomo, A.H., Santosa, B., Tahalea, S.P., Paripurno, E.T., Peasetyo, J.D., Jayadianti, H., and Pitayandanu, M.F., 2022. Rainfall prediction using artificial neural network

with historical weather data as supporting parameters. **Jurnal Informatika**, 16 (2), 63-73.

Priestley, C.H.B. and Taylor, R.J., 1972. On the Assessment of the Surface Heat Flux and Evaporation using Large-Scale Parameters. **Monthly Weather Review**, 100 (2), 81-92.

Probst, P., Wright, M.N. and Boulesteix, A.L., 2019. Hyperparameters and tuning strategies for random forest. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, 9 (3), 1-15.

Qiao, X., Farahani, H.J., Khalilian, A. and Barnes, E.M., 2016. Cotton Water Productivity and Growth Parameters in the Humid Southeast: Experimentation and Modeling. **American Society of Agricultural and Biological Engineers**, 59 (3), 949-962.

Qiu, X., Zhang, L., Ren, Y., Suganthan, P.N. and Amaratunga, G., 2014. Ensemble deep learning for regression and time series forecasting. **2014 IEEE Symposium on Computational Intelligence in Ensemble Learning**, 09-12 December Orlando, pp:1-6.

Radmanesh, F., Esmaeili-Gisavandani, H. and Lotfirad, M., 2022. Climate change impacts on the shrinkage of Lake Urmia. **Journal of Water and Climate Change**, 13 (6): 2255-2277.

Raes, D., Steduto, P., Hsiao, T.C. and Fereres, E., 2009. Aquacrop-the FAO crop model to simulate yield response to water: II. main algorithms and software description. **Agronomy Journal**, 101 (3), 438-447.

Raes, D., Steduto, P., Hsiao, T.C. and Fereres, E., 2018. **Chapter 1: FAO crop-water productivity model to simulate yield response to water AquaCrop:version 6.0-6.1 reference manual**. Rome: FAO, 19p.

Raes, D., Waongo, M., Vanuytrecht, E., Moreno, P.M., 2021. Improved management may alleviate some but not all of the adverse effects of climate change on crop yields in smallholder farms in West Africa. **Agricultural and Forest Meteorology**, 308-309, 108563.

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

Rahman, M.H., Ahmad, A., Wang, X., Wajid, A., Nasim, W., Hussain, M., Ahmad, B., Ahmad, I., Ali, Z., Ishaque, W., Awais, M., Shelia, V., Ahmad, S., Fahd, S., Alam, M., Ullah, H. and Hoogenboom, G., 2018. Multi-model projections of future climate and climate change impacts uncertainty assessment for cotton production in Pakistan. **Agricultural and Forest Meteorology**, 253-254, 94-113.

Rahmany, I., Mahfoudhi, S., Freihat, M. and Moulahi, T., 2022. Missing data recovery ın the e-health context based on machine learning models. **Advances in Artificial Intelligence and Machine Learning,** 2 (4), 516-532.

Randall, D.A., Wood, R.A., Bony, S. Colman, R., Fichefet, T., Fyfe, J., Kattsov, V., Pitman, A., Shukla, J., Srinivasan, J., Stouffer, R.J., Sumi A., and Taylor, K.E., 2007. Cilmate models and their evaluation. In: **Climate Change 2007: The Physical Science Basis**. Cambridge University Press. ISBN: 978-0521705967.

Ranjbar, A., Rahimikhoob, A., Ebrahimian, H., and Varavipour, M., 2019. Assessment of the AquaCrop model for simulating maize response to different nitrogen stresses under semi-arid climate. **Communications in Soil Science and Plant Analysis**, 50 (22), 2899–2912.

Raschka, S., Patterson, J. and Nolet, C., 2020. Machine Learning in Python: Main developments and technology trends in data science, machine learning, and artificial intelligence. **Information**, 11 (4), 193.

Rattalino Edreira, J.I., Budakli Carpici, E., Sammarro, D. and Otegui, M.E., 2011. Heat stress effects around flowering on kernel set of temperate and tropical maize hybrids. **Field Crops Research**, 123 (2), 62–73.

Rawls, W. J., Gimenez, D. and Grossman, R., 1998. Use of soil texture, bulk density, and slope of the water retention curve to predict saturated hydraulic conductivity. **American Society of Agricultural and Biological Engineers**, 41 (4), 983-988.

Rečka, L., Máca, V. and Ščasný, M., 2023. Green deal and carbon neutrality assessment of Czechia. **Energies**, 16 (5), 2152.

Ren, M., Pang, B., Xu, Z. Yue, J. and Zhang, R., 2019. Downscaling of daily extreme temperatures in the Yarlung Zangbo River Basin using machine learning techniques. **Theoretical and Applied Climatology**, 136, 1275-1288.

Rezaei, E.E., Webber, H., Gaiser, T., Naab, J. and Ewert, F., 2015. Heat stress in cereals: mechanisms and modelling. **European Journal of Agronomy**, 64, 98–113.

Rogelj, J., den Elzen, M., Höhne, N., Fransen, T., Fekete, H., Winkler, H. Schaeffer, R., Sha, F., Riahi, K. and Meinshausen, M., 2016. Paris agreement climate proposals need a boost to keep warming well below 2°C. **Nature**, 534, 631-639.

Roman, U.C., Patel P.L. and Porey, P.D., 2012. Prediction of missing rainfall data using conventional and artificial neural network techniques. **ISH Journal of Hydraulic Engineering**, 18 (3), 224-231.

Rowhani, P., Lobell, D.B., Linderman, M. and Ramankutty, N., 2011. Climate variability and crop production in Tanzania. **Agricultural and Forest Meteorology**, 151, 449-460.

Roy, S., Sharma, P., Nath, K., Bhattacharyya, D.K. and Kalita, J.K., 2019. Pre-processing: A Data Preparation Step. In: **Encyclopedia of Bioinformatics and Computational Biology**. Elsevier. ISBN: 978-0-12-811432-2. pp: 463-471.

Sa'adi, Z., Shahid, S., Chung, E.-S. and bin Ismail, T., 2017. Projection of spatial and temporal changes of rainfall in Sarawak of Borneo Island using statistical downscaling of CMIP5 models. **Atmospheric Research**, 197, 446-460.

Sachindra, D.A., Huang, F., Barton, A. and Perera, B.J.C., 2014. Statistical downscaling of general circulation model outputs to precipitation-part 2: bias-correction and future projections. **International Journal of Climatology**, 34 (11), 3282-3303.

Sachindra, D.A., Ahmed, K., Rashid, M.M., Sehgal, V., Shahid, S. and Perera, B.J.C., 2019. Pros and cons of using wavelets in conjunction with genetic programming and generalised linear models in statistical downscaling of precipitation. **Theoretical and Applied Climatology**, 138, 617-638.

Salehie, O., Hamed, M.M., bin Ismail, T. and Shahid, S., 2022. Projection of droughts in Amu river basin for shared socioeconomic pathways CMIP6. **Theoretical and Applied Climatology**, 149, 1009-1027.

Salman, S.A., Shahid, S., Ismail, T., Ahmed, K. and Wang, X.-J., 2018. Selection of climate models for projection of spatiotemporal changes in temperature of Iraq with uncertainties. **Atmospheric Research**, 213, 509–522.

Salman, S.A., Hamed,M.M., Shahid, S., Ahmed, K., Sharafati, A., Asaduzzaman, M., Ziarh, G.F., Ismail, T., Chung, E.-S., Wang, X.-J., and Dewan, A., 2022. Projecting spatiotemporal changes of precipitation and temperature in Iraq for different shared

socioeconomic pathways with selected Coupled Model Intercomparison Project Phase 6. **International Journal of Climatology**, 42 (16), 9032-9050.

Sander, R., Baumgaertner, A., Cabrera-Perez, D., Frank, F., Gromov, S., Grooß, J.-U., harder, Harder, H., Huijnen, V., Jöckel, P., Karydis, V.A., Neimeyer, K.E., Pozzer, A., Riede, H., Schultz, M.G., Taraborrelli, D. and Tauer, S., 2019. The Community Atmospheric Chemistry Box Model CAABA/MECCA-4.0. **Geoscientific Model Development**, 12 (4), 1365-1385.

Santos, J.F.S., Leite, D.C., Severo, F.A.S. and Naval, L.P., 2020. Validating the Mark-HadGEM2-ES and Mark-MIROC5 climate models to simulate rainfall in the last agricultural frontier of the Brazilian North and North-East Savannah. **Advances in Research**, 21 (8), 43-54.

Saplıoğlu, K. ve Çimen, M., 2010. Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. **Mühendislik Bilimleri ve Tasarım Dergisi**, 1 (1), 14-21.

Saxton, K.E. and Rawls, W.J., 2006. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. **Soil science society of America Journal**, 70 (5), 1569-1578.

Seo, D.K. and Eo, Y.D., 2019. Multilayer Perceptron-Based Phenological and Radiometric Normalization for High-Resolution Satellite Imagery. **Applied Sciences**, 9 (21), 4543.

Sevinç, A. ve Kaya, B., 2021. Derin öğrenme yöntemleri ile sıcaklık tahmini: Diyarbakır ili örneği. **Journal of Computer Science**, IDAP 2021 (Special issue), 217-225.

Sharifi, R.S., Raei, Y. and Weisany, W., 2014. Study of physiological growth indices in maize (*Zea mays* L.) hybrids under different plant densities. **International Journal of Biosciences**, 5 (3), 100-109.

Sharma, C., Shukla, A.K. and Zhang, Y., 2021. Climate change detection and attribution in the Ganga-Brahmaputra-Meghna river basins. **Geoscience Frontiers**, 12 (5), 10186.

Sharma, S., Hamal, K., Khadka, N., Ali, M., Subedi, M., Hussain, G., Ehsan, M.A., Saeed, S. and Dawadi, B., 2021. Projected Drought Conditions over Southern Slope of the Central Himalaya Using CMIP6 Models. **Earth Systems and Environment**, 5, 849–859.

Shashikanth, K., Salvi, K., Ghosh, S. and Rajendran, K., 2014. Do CMIP5 simulations of Indian summer monsoon rainfall differ from those of CMIP3? **Atmospheric Science Letters**,15 (1), 79–85.

Shiru, M.S., Shahid, S., Chung, E.S., Alias, N. and Scherer, L., 2019. A MCDM-based framework for selection of general circulation models and projection of spatio-temporal rainfall changes: a case study of Nigeria. **Atmospheric Research**, 225, 1–16.

Shrivastava, V.K., Shrivastava, A., Sharma, N., Mohanty, S.N. and Pattanaik, C.R., 2023. Deep learning model for temperature prediction: a case study in New Delhi. **Journal of Forecasting**. 43 (6), 1445-1460.

Simpson, I.R., Seager, R., Ting, M. and Shaw, T.A., 2016. Causes of change in Northern Hemisphere Winter Meridional Winds and Regional Hydroclimate. **Nature Climate Change**, 6, 65-70.

Singh, J., Knapp, H. V., Arnold, J.G. and Demissie, M., 2005. Hydrologic modeling of the Iroquois River watershed using HSPF and SWAT. **Journal of the American Water Resources Association**, 41 (2), 343-360.

Singh, M.C., Singh, K.G. and Singh, J.P., 2018. Indirect method for measurement of leaf area and leaf area index of soilless cucumber crop. **Advances in Plants and Agriculture Research**, 8 (2), 188-191.

Smola, A.J. and Schölkopf, B., 2004. A tutorial on support vector regression. **Statistics and Computing**, 14 (3), 199-222.

Song, S. and Yan, X., 2022. Evaluation of events of extreme temperature change between neighboring days in CMIP6 models over China. **Theoretical and Applied Climatology**, 1-150, 53-72.

Soriano, E., Mediero, L. and Garijo, C., 2019. Selection of bias correction methods to assess the impact of climate change on flood frequency curves. **Water**, 11 (11), 2266.

Srinivasa Raju, K. and Nagesh Kumar, D., 2010. **Multicriterion analysis in engineering and management.** Prentice Hall of India. ISBN: 978-8120339767.

Srinivasa Raju, K. and Nagesh Kumar, D., 2018. Hydrological modeling. Impact of climate change on water resources. In: **Impact of climate change on water resources-with modeling techniques and case studies**. Springer, pp 137–167. ISBN: 978-981-10-6110-3.

Srinivasa Raju, K. and Nagesh Kumar, D., 2020. Review of approaches for selection and ensembling of GCMs. **Journal of Water and Climate Change**, 11 (3), 577-599.

Steduto, P., Hsiao, T.C., Raes, D. and Fereres, E., 2009. Aquacrop-the FAO crop model to simulate yield response to water: I. concepts and underlying principles. **Agronomy Journal**, 101 (3), 426-437.

Steinfeld, H., Greber, P.T.W., Castel, V., Rosales, M. and de Haan, C., 2006. **Livestock's long shadow - environmental issues and options.** FAO. ISBN: 978-92-5-105571-7.

Stekhoven, D.J. and Bühlmann P., 2012. Missforest-Non parametric missing value imputation for mixed-type data. **Bioinformatics**, 28 (1), 112-118.

Supharatid, S. and Nafung, J., 2021. Projected drought conditions by CMIP6 multimodel ensemble over Southeast Asia. **Journal of Water and Climate Change**, 12 (7), 3330-3354.

Süzülmüş, S., 2019. Prediction of average temperatures using artificial neural network methods: The case of Gaziantep Province, Turkey. **Fresenius Environmental Bulletin**, 28 (2A), 1494-1502.

Şarlak, N. ve Bağçacı, S., 2020. Ampirik potansiyel evapotranspirasyon tahmin yöntemlerinin değerlendirilmesi: Uygulama Konya Kapalı Havzası. Teknik Dergi, 31 (1), 9755-9772.

Şen, Z., 2004. **Yapay sinir ağları ilkeleri**. Su vakfı Yayınları. ISBN: 975-6455-13-6.

Şen, B., 2009. Bölgesel iklim modelleri kullanılarak Çukurova Yöresi'nde iklim değişikliğinin 1. ve 2. ürün mısır verimine olası etkilerinin belirlenmesi. **Çukurova Ünivesitesi. Fen Bilimleri Enstitüsü,** Tarımsal Yapılar ve Sulama Anabilim Dalı, Doktora Tezi, Adana, 308 sayfa.

Şen, Z., 2022. İklim değişikliği ve Türkiye. **Çevre, Şehir ve İklim Dergisi**. 1 (1), 1-19.

Tabari, H., 2010. Evaluation of Reference Crop Evapotranspiration Equations in Various Climates. **Water Resources Management**, 24, 2311–2337.

Tan, S., Wang, Q., Zhang, J., Chen, Y., Shan, Y. and Xu, D., 2018. Performance of Aquacrop model for cotton growth simulation under film-mulched drip irrigation in Southern Xinjiang, China. **Agricultural Water Management**, 196, 99-113.

Tang, B., Hu, W., and Duan, A., 2021. Assessment of extreme precipitation ındices over Indochina and South China in CMIP6 Models. **Journal of Climate**, 34 (18), 7507-7524.

Taylor, K.E., 2001. Summarizing multiple aspects of model per-fomance in a single diagram. **Journal of Geophysical Research: Atmospheres**,106 (D7), 7183–7192.

Teegavarapu, R.S.V., Aly, A., Pathak, C.S., Ahlquist, J., Fuelberg, H. and Hood, J., 2018. Infilling missing precipitation records using variants of spatial interpolation and data-driven methods: use of optimal weighting parameters and nearest neighbour-based corrections. **International Journal of Climatology**, 38 (2), 776–793.

Terzi, Ö. and Çevik, E., 2012. Rainfall estimation using artificial neural network method. **Suleyman Demirel University International Journal of Technologic Sciences**, 4 (1), 10-19.

Tesfaye, K., Kruseman, G., Cairns, J.E., Zaman-Allah, M., Wegary, D., Zaidi, P.H., Boote, K.J., Rahut, D. and Erenstein, O., 2018. Potential benefits of drought and heat tolerance for adapting maize to climate change in tropical environments. **Climate Risk Management**, 19, 106-119.

Tibshirani, R., 1996. Regression shrinkage and selection via the lasso. **Journal of the Royal Statistical Society: Series B (Methodological)**, 58 (1), 267-288.

Tofiq, F.A. and Güven, A., 2014. Prediction of design flood discharge by statistical downscaling and General Circulation Models. **Journal of Hydrology**, 517, 1145–1153.

Tran, A.T.M., Eitzinger, J. and Manschadi, A.M., 2020. Response of maize yield under changing climate and production conditions in Vietnam. **Italian Journal of Agrometeorology**, 1, 73-84.

Trenberth, K.E., 2011. Changes in precipitation with climate change. **Climate Research**, 47 (1-2), 123–138.

Tripathi, S., Srinivas, V.V. and Nanjundiah, R.S., 2006. Downscaling of precipitation for climate change scenarios: a support vector machine approach. **Journal of Hydrology**, 330 (3-4), 621-640.

Tsakmakis, I.D., Kokkos, N.P., Gikas, G. D., Pisinaras, V., Hatzigiannakis, E., Arampatzis, G. and Sylaios, G.K., 2019. Evaluation of Aquacrop model simulations of cotton growth under deficit irrigation with an emphasis on root growth and water extraction patterns. **Agricultural Water Management**, 213, 419-432.

TUİK, 2021. Türkiye İstatistik Kurumu. https://www.tuik.gov.tr/ (Erişim Tarihi:15.05.2022).

Tülücü, K., 2003. **Özel bitkilerin sulanması**. Çukuruva Üniversitesi Yayınları. ISBN: 254.

Türkeş, M., 2008. Küresel iklim değişikliği nedir? Temel kavramlar, nedenleri, gözlenen ve öngörülen değişiklikler. **İklim Değişikliği ve Çevre**, 1 (1), 26-37.

Türkeş, M., 2020. İklim değişikliğinin tarımsal üretim ve gıda güvenliğine etkileri: bilimsel bir değerlendirme. **Ege Coğrafya Dergisi**, 29 (1), 125-149.

UNEP, 2021. **Emissions gap report 2021: the heat is on-a world of climate promises not yet delivered.** United Nations Environment Programme. ISBN: 978-92-807-3890-2.

Ustaoğlu, B., Cigizoglu, H.K. and Karaca, M., 2008. Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods. **Meteorological Applications**, 15, 431–445.

Uyanık, G.K. and Güler, N.A., 2013. Study on multiple linear regression analysis. **Procedia-Social and Behavioral Sciences**, 106, 234–240.

Vapnik, V.N., 1999. An overview of statistical learning theory. **IEEE Transactions on Neural Networks**, 10 (5), 988–999.

Velo, R., López, P. and Maseda, F., 2014. Wind speed estimation using multilayer perceptron. **Energy Conversion and Management**, 81, 1-9.

Vicedo-Cabrera, A.M., Guo, Y., Sera, F., Huber, V., Schleussner, C.-F., Mitchell, D., Tong, S., Coelho, M.S.Z.S., Saldiva, P.H.N., Lavigne, E., Correa, P.M., Ortega, N.V., Kan, H., Osorio, S., Kyselý, J., Urban, A., Jaakkola, J.J.K., Ryte, N.R.I., Pascal, M., Goodman, P.G., Zeka, A., Michelozzi, P., Scortichini, M., Hashizume, M., Honda, Y., Hurtado-Diaz, M., Cruz, J., Seposo, X., Kim, H., Tobias, A., Íñiguez, C., Forsberg, B., Åström, D.O., Ragettli, M.S., Röösli, M., Guo, Y.L., Wu, C., Zanobetti, A., Schwartz, J., Bell, M.L., Dang, T.N., Van, D.D., Heaviside, C., Vardoulakis, S., Hajat, S., Haines, A., Armstrong, B., Ebi, K.L. and Gasparrini, A., 2018. Temperature-related mortality ımpacts under and beyond Paris agreement climate change scenarios. **Climatic Change**, 150 (3-4), 391-402.

Wang, L., Zhang, J., Shu, Z., Wang, Y., Bao, Z., Liu, C., Zhou, X. and Wang, G., 2021. Evaluation of the ability of CMIP6 global climate models to simulate precipitation in the Yellow River Basin, China. **Frontiers in Earth Science**, 9, 751974.

Wang, Z., Lai, C., Chen, X., Yang, B., Zhao, S. and Bai, X., 2015. Flood hazard risk assessment model based on random forest. **Journal of Hydrology**, 527, 1130-1141.

Willmott, C.J., 1981. On the validation of models. **Physical Geography**, 2 (2),184-194.

WMO, 2022. **State of the global climate 2021**. World Meteorological Organization. ISBN: 978-92-63-11290-3.

Wubetie, H.T., 2019. Application of variable selection and dimension reduction on predictors of MSE's development. **Journal of Big Data**, 6, 1-44.

Xie, Y., Li, X., Ngai, E.W.T. and Ying, W., 2009. Customer churn prediction using ımproved balanced random forests. **Expert Systems With Applications**, 36 (3), 5445-5449.

Xin, X., Wu, T., Zhang, J., Yao, J. and Fang, Y., 2020. Comparisonof CMIP6 and CMIP5 simulations of precipitation in China and the East Asian summer monsoon. **International Journal of Climatology**, 40 (15), 6423–6440.

Xu, Y., Qin, Z. and Shen, Y., 2012. Study on the estimation of near-surface air temperature from modis data by statistical methods. **International Journal of Remote Sensing**, 33 (24), 7629-7643.

Yılmaz, Y., 1984. **Amanos Dağları'nın Jeolojisi.** T.P.A.O. Rap. No:1920. Ankara.

Yu, L., Wang, S. and Lai, K.K., 2005. An integrated data preparation scheme for neural network data analysis. **IEEE Transactions on Knowledge and Data Engineering**, 18 (2), 217-230.

Yuan, X. and Bai, J., 2018. Future projected changes in local evapotranspiration coupled with temperature and precipitation variation. **Sustainability**, 10 (9), 3281.

Zahmatkesh, Z., Karamouz, M., Burian, S.J., Tavakol-Davani, H. and Goharian, E., 2014. LID implementation to mitigate climate change ımpacts on urban runoff. **World Environmental and Water Resources Congress 2014: Water Without Borders** 1-5 June Portland. pp. 952–965.

Zeleny, M., 2012. **Multiple criteria decision making Kyoto 1975**. Springer Science &Business Media. ISBN: 978-3-540-07684-1.

Zhang, Y., Wang, T., Liu, K., Xia, Y., Lu, Y., Jing, Q., Yang, Z., Hu, W., and Lu, J., 2016. Developing a time series predictive model for dengue ın Zhongshan, China based on weather and Guangzhou dengue surveillance data. **PLoS Neglected Tropical Diseases**, 10 (2), 1-17.

Zhao, X., Huang, G., Li, Y., Lin, Q., Jin, J., Lu, C. and Guo, J., 2021. Projections of meteorological drought based on CMIP6 multi-model ensemble: A case study of Henan Province, China. **Journal of Contaminant Hydrology**, 243, 103887.

Zhu, H., Jiang, Z., Li, J., Li, W., Sun, C. and Li, L., 2020. Does CMIP6 inspire more confidence in simulating climateextremes over China? **Advances in Atmospheric Sciences**, 37, 1119–1132.

Zhu, X., Ji, Z., Wen, X., Lee, S.-Y., Wei, Z., Zheng, Z., and Dong, W., 2021. Historical and projected climate change over three major river basins in China from Fifth and Sixth Coupled Model Intercomparison Project models. **International Journal of Climatology**, 41(15), 6455–6473.

Zou, H. and Hastie T., 2005. Regularization and variable selection via the elastic net. **Journel o f Royal Statistical Society Series B: Statistical Methodology**, 67 (2), 301-320.

ÖZGEÇMİŞ

Mustafa ÖZBULDU ilk, orta ve lise eğitimini Adana'da tamamladı. Lisans eğitimini 2010-2014 yılları arasında Hatay Mustafa Kemal Üniversitesi Ziraat Fakültesi Biyosistem Mühendisliği Bölümü'nde tamamladı. 2014 yılında aynı üniversitede Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. 2017 yılında aynı üniversitenin Ziraat Fakültesi Biyosistem Mühendisliği Bölümü'nde Araştırma Görevlisi olarak göreve başladı. 2017 yılında yüksek lisans eğitimini tamamlayarak aynı üniversitenin Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen HMKÜ Ziraat Fakültesi Biyosistem Mühendisliği Bölümü'nde Araştırma Görevlisi olarak görev yapmaktadır.