

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DENİZ
YÜZEYİ SICAKLIĞI TAHMİNİ: BARTIN
UYGULAMASI**

YÜKSEK LİSANS TEZİ

Öğrencinin Adı SOYADI : Burçak Şen ÇİDEM

Tezin Enstitüye Verildiği Tarih :

Enstitü Anabilim Dalı : Biyoloji

Tez Danışmanı : Prof. Dr. Tamer AKKAN

Ocak 2025
GİRESUN

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DENİZ
YÜZEYİ SICAKLIĞI TAHMİNİ: BARTIN
UYGULAMASI

YÜKSEK LİSANS TEZİ

Burçak Şen ÇİDEM

Enstitü Anabilim Dalı

:

Biyoloji

Bu tez 17/01/2025 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Prof. Dr.
Tamer AKKAN
Jüri Başkanı

Prof. Dr.
Cengiz MUTLU
Üye

Doç. Dr.
Tanju MUTLU
Üye

Prof. Dr.
Bahadır KOZ
Enstitü Müdürü

BEYAN

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

Burçak Şen ÇİDEM

17/01/2025

TEŞEKKÜR

Yüksek Lisans tez çalışmam boyunca desteğini esirgemeyen değerli danışman hocam Prof. Dr. Tamer AKKAN'a, araştırmama deneyim ve görüşleri ile katkı sunan değerli hocalarım Prof. Dr. Erol EĞRİOĞLU, Prof. Dr. Cengiz MUTLU, Prof. Dr. Eren BAŞ, Doç. Dr. Tanju MUTLU ve Dr. Hakan IŞIK'a,

Bu zorlu süreçte desteğini esirgemeyen sevgili aileme yürekten teşekkürü bir borç bilirim.

İÇİNDEKİLER

TEŞEKKÜR.....	I
İÇİNDEKİLER	II
SİMGELER VE KISALTMALAR LİSTESİ	IV
ŞEKİLLER LİSTESİ	V
TABLolar LİSTESİ.....	VI
ÖZET	VII
SUMMARY	VIII
BÖLÜM 1. GİRİŞ.....	1
BÖLÜM 2. KAYNAK ARAŞTIRMASI.....	2
2.1. Su Sıcaklığının Canlılar İçin Önemi	2
2.1.1. Su sıcaklığının habitatlar üzerindeki rolü	4
2.2. Su Sıcaklığının Deniz Ekosistemine Etkisi.....	5
2.2.1. Deniz biyolojik süreçleri üzerindeki etkileri.....	7
2.3. Su Sıcaklığının Balıkçılık Üzerindeki Etkisi	8
2.3.1. Su sıcaklığı ve balık ilişkisi	9
2.4. Yapay Zeka Kavramı	10
2.5. Yapay Zekanın Kullanım Alanları	11
2.6. Makine Öğrenimi	14
BÖLÜM 3. MATERYAL VE YÖNTEM.....	15
3.1. Çalışma Alanı ile İlgili Genel Bilgiler	15
3.2 Verilerin Eldesi	16
3.3. Veri İşleme Süreci.....	16

3.4. Araştırmada Kullanılan Modeller ve Yaklaşımlar	17
3.4.1. Destek vektör makinesi (SVM).....	19
3.4.2. Gaussian süreç regresyonu (GPR)	19
3.4.3. Karar ağacı (Dt) algoritması.....	20
3.4.4. Yapay sinir ağları (YSA)	21
3.4.5. Regresyon ağaçları topluluğu (RTE)	21
3.4.6. Doğrusal regresyon	22
3.4.7. Kernel fonksiyonları	23
3.5. Modellerin Performans Değerlendirmesi	23
 BÖLÜM 4. ARAŞTIRMA BULGULARI.....	25
4.1. Deniz Yüzey Sıcaklığına Ait Gözlem Sonuçları.....	25
4.2. Deniz Yüzey Sıcaklığının Makine Öğrenimi Algoritmaları ile Tahmini.....	35
4.2.1. Destek vektör makinesi (SVM).....	35
4.2.2. Gaussian süreç regresyonu (GPR)	35
4.2.3. Karar ağacı (Dt) algoritması.....	36
4.2.4. Yapay sinir ağları (YSA)	37
4.2.5. Regresyon ağaçları topluluğu (RTE)	38
4.2.6. Doğrusal regresyon	39
4.2.7. Kernel fonksiyonları	40
4.2.8. Özelleştirilmiş makine öğrenimi modelleri.....	41
 BÖLÜM 5. TARTIŞMA VE SONUÇ.....	48
 KAYNAKLAR	51
ÖZGEÇMİŞ	59

SİMGELER VE KISALTMALAR LİSTESİ

BRTN	: Bartın
DYS	: Deniz Yüzeyi Sıcaklığı
GPR	: Gaussian Süreç Regresyonu
HKOK	: Hata Kareler Ortalaması Karekökü
MSE	: Ortalama Kare Hata
OMH	: Ortalama Mutlak Hata
RTE	: Regresyon Ağaçları Topluluğu
SVM	: Destek Vektör Makinesi
YZ	: Yapay zeka
YSA	: Yapay Sinir Ağı

ŞEKİLLER LİSTESİ

Şekil 4.1. 2014 yılına ait DYS değerlerinin aylık değişimi	25
Şekil 4.2. 2015 yılına ait DYS değerlerinin aylık değişimi	26
Şekil 4.3. 2016 yılına ait DYS değerlerinin aylık değişimi	27
Şekil 4.4. 2017 yılına ait DYS değerlerinin aylık değişimi	28
Şekil 4.5. 2018 yılına ait DYS değerlerinin aylık değişimi	29
Şekil 4.6. 2019 yılına ait DYS değerlerinin aylık değişimi	30
Şekil 4.7. 2020 yılına ait DYS değerlerinin aylık değişimi	31
Şekil 4.8. 2021 yılına ait DYS değerlerinin aylık değişimi	32
Şekil 4.9. 2022 yılına ait DYS değerlerinin aylık değişimi	33
Şekil 4.10. 2023 yılına ait DYS değerlerinin aylık değişimi	34
Şekil 4.11. Çalışmada kullanılan Orta Gauss SVM modelinin tahmin performansı .	46
Şekil 4.12. Dağılım grafiği Model 2.12 (Orta Gauss SVM)	47

TABLÖLAR LİSTESİ

Tablo 3.1. Makine öğrenimi teknikleri ve uygulamaları.....	18
Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları	43
Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları (devamı)	44
Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları (devamı)	45

MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE DENİZ YÜZEYİ SICAKLIĞI TAHMİNİ: BARTIN UYGULAMASI

ÖZET

Deniz yüzeyi sıcaklığı, okyanus ve denizlerdeki değişimleri izlemek ve ekosistemleri değerlendirmek için oldukça önemlidir. Deniz yüzeyi sıcaklığı tahmini, iklim değişikliğinin olası zararlı etkileri başta olmak üzere; balıkçılık yönetimi, deniz taşımacılığı, turizm ve kıyı şeridi yönetimi gibi farklı olgularda karar vericilere yol göstermektedir. Dahası, sürdürülebilir ekosistem yönetimi ve biyoçeşitliliğin korunmasında etkili bir çıktıdır. Günümüzde deniz yüzeyi sıcaklığı yapay zeka yöntemleriyle birlikte çok daha verimli bir şekilde tahmin edilebilmektedir. Bu nedenle bu çalışmada örnek bir uygulama istasyonunda makine öğrenmesi yöntemleriyle deniz yüzeyi sıcaklığının tahmin performansı ve doğrulaması sınanmıştır.

Bu çalışmada, Meteoroloji Genel Müdürlüğü'nden temin edilen 2014-2023 yılları arasına ait Bartın ili deniz yüzeyi sıcaklığına ait değerler veri seti olarak kullanılmıştır. Çalışma süresince kullanılan farklı makine öğrenimi modelleri, performans değerlendirme kriterleri ışığında mukayese edilmiştir. Karşılaştırma ortalama mutlak hata, kök ortalama kare hatası, ortalama yüzde hata ve medyan hata değerleriyle yapılmıştır.

Elde edilen sonuçlar, modellerin hedef değişkenin varyansını açıklama gücünün ve hata oranlarının birbirinden oldukça farklı olduğunu ortaya koymuştur. Özellikle orta Gaussian SVM modeli, yüksek R^2 değeri ve düşük hata metrikleri ile en başarılı model olarak öne çıkmıştır. Sonuç olarak, elde ettiğimiz bulgular benzer araştırmalar ve uygulama alanındaki gelecekteki çalışmalar için önemli çıktılar sunmaktadır.

Anahtar kelimeler: Bartın, Deniz yüzeyi sıcaklığı, Makine öğrenmesi

PREDICTION OF SEA SURFACE TEMPERATURE WITH MACHINE LEARNING METHODS: A CASE STUDY IN BARTIN

SUMMARY

Sea surface temperature is very important for monitoring changes in the oceans and seas and assessing ecosystems. Sea surface temperature prediction guides decision-makers in different phenomena such as fisheries management, maritime transport, tourism and coastline management, especially the possible harmful effects of climate change. Moreover, it is an effective output in sustainable ecosystem management and biodiversity conservation. Today, sea surface temperature can be estimated much more efficiently with artificial intelligence methods. Therefore, in this study, the prediction performance and validation of sea surface temperature with machine learning methods at a sample application station are tested.

In this study, the sea surface temperature values of Bartın province for the years 2014-2023 obtained from the General Directorate of Meteorology were used as a data set. Different machine learning models used during the study were compared in the light of performance evaluation criteria. The comparison is based on mean absolute error, root mean square error, mean percentage error and median error.

The results obtained revealed that the models' ability to explain the variance of the target variable and their error rates are quite different from each other. In particular, the medium Gaussian SVM model stood out as the most successful model with high R^2 value and low error metrics. In conclusion, our findings provide important outputs for similar researches and future studies in the application area.

Keywords: Bartın, Sea surface temperature, Machine learning

BÖLÜM 1. GİRİŞ

Günümüzde deniz yüzeyindeki sıcaklık (DYS) değişimleri bilim ve teknolojinin çeşitli alanlarında önemli bir araştırma konusu haline gelmiştir. Deniz yüzeyi sıcaklığının doğru bir şekilde tahminlenmesi, çeşitli endüstrilerde stratejik karar alma süreçlerini etkileyebilecek bir faktör olması bakımından oldukça önemlidir. DYS trendleri, biyoçeşitlilik, deniz çevresinin korunması ve küresel ısınma da dahil olmak üzere okyanusla ilgili bir dizi sektörde büyük ilgi görmüştür (Xu ve ark., 2023). Okyanus ve atmosfer arasındaki ilişkinin önemli bir fiziksel bileşeni deniz yüzeyi sıcaklığıdır. İklim değişikliği, felaketlerin önlenmesi, afetlerin azaltılması ve deniz biyolojisinin korunması konularını ele almak için DYS'nin zamansal ve coğrafi dağılımını doğru bir şekilde izlemek ve tahmin etmek çok önemlidir (Jia ve ark., 2022).

Kuraklık gibi aşırı çevresel olaylar dünya çapında milyonlarca insanı etkilemektedir. Önlenemeseler de çeşitli zaman dilimlerinde tahmin edilebilir olmaları ve bu da neden oldukları nihai zararların azaltılmasına yardımcı olur. Deniz yüzeyi sıcaklığı kuraklık olaylarının önemli bir göstergelerinden biridir (Salles ve ark., 2016). Ayrıca, ekosistemlerin sürdürülebilirliği ve biyoçeşitliliğin korunmasında da oldukça önemli bir yere sahip olan deniz yüzeyi sıcaklığı, biyosferin geleceğinin şekillenmesinde göz ardı edilemez bir unsurdur.

Bu çalışma güncel makine öğrenimi yöntemlerinden faydalananarak deniz yüzeyi sıcaklığının tahminlenmesindeki etkinliği değerlendirmek ve bu yaklaşımın farklı bilim alanlarında nasıl kullanılabileceğini irdelemektedir. Bu bağlamda hem teorik hem de pratik açıdan bu güncel yaklaşımın getirdiği avantajlar ve sınırlamalar incelenecek, elde edilen sonuçlar doğrultusunda uygulama alanında gelecekte deniz yüzeyi sıcaklığı tahminine yönelik araştırmalara veri kaynağı oluşturularak, öneriler sunulması planlanmaktadır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

2.1. Su Sıcaklığının Canlılar İçin Önemi

Sıcaklık değişimleri, suyun fiziksel ve kimyasal özelliklerini etkileyerek ekosistemlerin dengesini ve biyolojik çeşitliliği doğrudan şekillendirir. Su sıcaklığı, gazların çözünürlüğü üzerinde de belirleyici bir etkiye sahiptir. Özellikle oksijenin suda çözünürlüğü, sıcaklık arttıkça azalır. Bu durum, sucul organizmaların solunum faaliyetlerini ve metabolik süreçlerini doğrudan etkiler. Ayrıca su sıcaklığı, suyun yoğunluğunu ve buna bağlı olarak akıntı sistemlerini de etkiler. Termohalin dolaşım olarak bilinen bu süreçler, okyanus ve denizlerdeki besin maddelerinin dağılımını ve ekosistemlerin işleyişini düzenler. Sıcaklık değişimleri, su hareketlerini değiştirerek sucul yaşamı dolaylı yoldan etkileyebilir (Kadak ve Aras, 2017).

Su sıcaklığı, sucul organizmaların yaşam döngüleri, üreme faaliyetleri ve dağılımları üzerinde doğrudan etkilidir. Birçok tür, belirli bir sıcaklık aralığında optimal yaşam koşullarına sahipken, bu aralığın dışına çıkıldığında stres belirtileri gösterebilir veya popülasyonlarında azalma yaşanabilir. Örneğin, deniz suyu sıcaklıklarındaki artış, bazı balık türlerinin göç yollarını ve üreme alanlarını değiştirebilir. Ayrıca su sıcaklığındaki artışlar, istilacı türlerin yeni bölgelere yayılmasını kolaylaştırabilir. Özellikle Akdeniz ve Ege Denizi'nde, Kızıldeniz'den gelen lesepsiye türlerin sayısında artış gözlenmiştir. Bu türlerin yayılması, yerel ekosistemlerin dengesini bozabilir ve yerli türlerin baskılanmasına neden olabilir (Ömeroğlu ve ark., 2021)

Su sıcaklığındaki değişimler, ekosistemlerin genel sağlığı üzerinde de belirleyici bir rol oynar. Özellikle mercan resifleri gibi hassas ekosistemler, sıcaklık artışlarına karşı duyarlıdır. Tatlı su ekosistemlerinde de benzer şekilde, su sıcaklığındaki artışlar, oksijen seviyelerinin düşmesine ve buna bağlı olarak balık ölümlerine neden olabilir.

Ayrıca, sıcaklık değişimleri, suyun kimyasal bileşimini etkileyerek toksik alg patlamalarına zemin hazırlayabilir

Danovaro ve ark. (2004), derin denizlerdeki sıcaklıkların aşırı stabilitesini vurgulayarak ve iklim değişikliğine karşı potansiyel biyoçeşitlilik tepkilerine odaklanarak, derin deniz biyoçeşitliliğini desteklemek için kararlı deniz suyu sıcaklıklarının önemini vurgulamışlardır. Yasuhara ve Danovaro (2014), derin deniz biyoçeşitliliği üzerinde sıcaklığın etkilerine odaklandı, derin deniz ekosistemlerindeki önemini vurgulayarak, sıcaklığın derin deniz ekosistemlerini şekillendirmedeki kritik rolünü belirttiler. Osman ve ark. (2017), Kuzey Kızıldeniz'de deniz yüzey sıcaklığının (DYS) mercan beyazlaşmasına karşı termal sığınak sağlamadaki önemini gösterdi. Bu çalışma, ısınma eğilimleri ile mercan beyazlaşma kayıtları arasındaki ilişkiyi vurgulayarak deniz suyu sıcaklığının mercan resiflerinin hayatta kalmasındaki kritik rolünü vurgulamıştır. Ayrıca, Jöst ve ark. (2019), derin deniz biyoçeşitliliği için hem sıcaklığın hem de yüzeydeki birincil üretimin önemli faktörler olduğunu bulmuş, deniz suyu sıcaklığının çeşitli deniz canlılarını desteklemedeki önemini daha da vurgulamışlardır. Zheng ve ark. (2019), deniz salyangozlarındaki deniz suyu sıcaklığındaki dramatik mevsimsel değişimleri ve bunların TLR sinyal yolundaki etkilerini tartışarak, sıcaklık stresinin deniz organizmaları üzerinde moleküler düzeydeki etkilerini göstermişlerdir.

Sıcaklık değişimleri, deniz suyunun fiziksel ve kimyasal özelliklerini etkileyerek, ekosistemlerin dengesini ve biyolojik çeşitliliği doğrudan şekillendirir. Deniz suyu sıcaklığındaki değişimler, suyun kimyasal özelliklerini de etkiler. Sıcaklık artışı, suda çözülmüş oksijen miktarını azaltarak, düşük oksijen seviyelerine yol açabilir. Bu durum özellikle oksijen ihtiyacı yüksek olan türler için stres yaratır ve ölümlere neden olabilir. Özellikle son yıllarda iklim değişikliği nedeniyle deniz suyu sıcaklıklarında artışlar gözlemlenmektedir. Türkiye'yi çevreleyen denizlerde, son yirmi yılda deniz suyu sıcaklıklarında yaklaşık 0,4 – 1,4°C artış gerçekleşmiş olup, bu dönemde maksimum artışların yaklaşık 2,3 – 3,5°C arasında olduğu tespit edilmiştir (Demircan, 2022). Deniz suyu sıcaklığındaki artışlar, deniz canlılarının fizyolojik süreçlerini doğrudan etkilemektedir. Balıklar ve diğer sucul organizmalar, yaşam döngülerini

belirli sıcaklık aralıklarında sürdürürler. Sıcaklık artışı, bu organizmaların metabolizma hızlarını, üreme başarılarını ve dağılımlarını değiştirebilir. Örneğin, bazı balık türleri, uygun sıcaklık aralıklarını aramak için göç etmek zorunda kalabilirler. Bu durum, ekosistemlerde tür kompozisyonunun değişmesine ve biyolojik çeşitliliğin azalmasına neden olabilir (Kayhan ve ark., 2015). Ayrıca, deniz suyu sıcaklığındaki artışlar, istilacı türlerin yeni bölgelere yayılmasını kolaylaştırabilir. Özellikle Akdeniz'de, tropikal denizlerden gelen istilacı türlerin sayısında artış gözlenmiştir. Bu türlerin yayılması, yerel ekosistemlerin dengesini bozabilir ve yerli türlerin baskılanmasına neden olabilir (Demircan, 2022).

2.1.1. Su sıcaklığının habitatlar üzerindeki rolü

Küresel iklim değişikliği nedeniyle artan deniz suyu sıcaklıkları, özellikle mercan resifleri, deniz çayırları ve mangrov ormanları gibi hassas habitatları olumsuz yönde etkilemektedir. Örneğin, mercan resifleri, su sıcaklığındaki artışlara karşı oldukça duyarlıdır ve sıcaklık artışı mercan ağarmasına yol açarak bu ekosistemlerin bozulmasına neden olmaktadır (Nacar ve ark., 2024).

Türkiye'yi çevreleyen denizlerde, son yirmi yılda deniz suyu sıcaklıklarındaki artışlar, deniz ekosistemlerinde habitat kaybına ve biyolojik çeşitlilikte azalmaya yol açmaktadır. Özellikle Akdeniz'de, deniz suyu sıcaklıklarının artması, tropikal denizlerden gelen istilacı türlerin bölgeye göç etmesine neden olarak yerel türlerin yaşam alanlarını tehdit etmektedir (Demircan, 2022). Ayrıca, deniz suyu sıcaklıklarındaki artış, deniz seviyesinin yükselmesine ve buna bağlı olarak kıyı habitatlarının tahrip olmasına sebep olmaktadır. Deniz seviyesindeki artış nedeniyle kıyı habitatları tahrip olduğu için deniz kaplumbağalarının üreme alanları daralmaktadır. Birçok deniz memelisi, deniz buzunun azalmasına bağlı olarak yok olma tehlikesiyle karşı karşıya kalmaktadır (Aksay ve ark., 2005).

Su sıcaklığının habitatlar üzerindeki rolü, sucul organizmaların farklı gruplarında farklı şekillerde gözlenebilir. Örneğin, bakteriler, su sıcaklığına bağlı olarak farklı metabolik aktivitelere sahip olabilirler. Bazı bakteriler, düşük sıcaklıklarda daha iyi

büyüyebilirken, bazıları yüksek sıcaklıklarda daha iyi büyüyebilirler. Bazı bakteriler, sıcaklık değişimlerine karşı toleranslı olabilirken, bazıları sıcaklık değişimlerine karşı hassas olabilirler. Bazı bakteriler, sıcaklık artışıyla birlikte patojenik özelliklerini artırabilirken, bazıları sıcaklık artışıyla birlikte patojenik özelliklerini azaltabilirler (Özdemir ve Altındağ, 2009).

Su sıcaklığı, sucul ekosistemlerin sağlığını ve sürdürülebilirliğini belirleyen bir faktördür. Sıcaklık, sucul ekosistemlerin karşılaştığı doğal ve antropojenik tehditlerin etkisini ve bu sucul ekosistemlerin direncini, esnekliğini, dengesini, verimliliğini, stabilitesini ve hizmetlerini etkileyebilir. Sucul ekosistemlerin değerlendirilmesi, izlenmesi, modellenmesi, tahmini, uyarlanması, iyileştirilmesi, restorasyonu, korunması ve planlanması için önemli bir parametre olan su sıcaklığı, sucul ekosistemlerin yasal, politik, ekonomik, sosyal, kültürel, eğitimsel, bilimsel ve teknolojik boyutlarını da etkileyebilir. Bu nedenle, su sıcaklığının habitatlar üzerindeki rolü, sucul ekosistemlerin yönetimi ve korunması için dikkate alınması gereken bir konudur (Kayhan ve ark., 2015).

2.2. Su Sıcaklığının Deniz Ekosistemine Etkisi

İklim değişikliği ile birlikte artan deniz suyu sıcaklıkları, deniz canlılarının yaşam döngülerini, üreme dönemlerini ve dağılımlarını etkileyerek ekosistem dengesini bozabilir. Örneğin, Nacar (2024), Orta Karadeniz bölgesinde deniz suyu sıcaklıklarının iklim değişikliği nedeniyle belirgin bir artış gösterdiğini belirtmiştir. Bu artış, deniz ekosistemindeki türlerin dağılımını ve biyoçeşitliliği etkileyebilir. Ayrıca, deniz suyu sıcaklıklarının yükselmesi, denizlerdeki oksijen seviyelerini azaltarak, özellikle balıklar ve diğer deniz canlıları için yaşam alanlarını tehdit edebilmektedir.

Marmara Bölgesi'nde yapılan bir diğer çalışmada, müsilaj olaylarının deniz suyu sıcaklıkları ile doğrudan ilişkili olduğu tespit edilmiştir. Özellikle Mayıs ayında deniz suyu sıcaklıklarının mevsim normallerinin üzerinde olduğu gözlemlenmiştir. Bu durum, deniz ekosisteminin sağlığını tehdit eden müsilaj gibi olumsuz olayların

artmasına neden olmaktadır. Müsilaj, denizlerdeki besin zincirini bozarak, deniz canlılarının yaşam alanlarını daraltmakta ve ekosistem dengesini sarsmaktadır (Işın, 2024).

Deniz suyu sıcaklıklarının artışı, ayrıca denizlerdeki türlerin göç davranışlarını da etkileyebilir. İklim değişikliği ile birlikte deniz suyu sıcaklıklarının yükselmesi, bazı türlerin daha soğuk sularda yaşamaya başlamasına neden olabilir. Örneğin, Ege Denizi'nde deniz suyu sıcaklıklarının zamanla değişimi incelenmiş ve bu değişimlerin deniz ekosistemindeki türlerin dağılımını etkilediği vurgulanmıştır. Bu tür değişimler, deniz ekosisteminin biyoçeşitliliğini tehdit etmekte ve bazı türlerin yok olmasına yol açabilmektedir (Saracoglu, 2020). Ayrıca, deniz suyu sıcaklıklarının artışı, denizlerdeki besin zincirinin dengesini bozarak, balıkçılık gibi ekonomik faaliyetleri de olumsuz etkileyebilir. İklim değişikliği ile birlikte deniz suyu sıcaklıklarının yükselmesi, balıkların üreme dönemlerini ve dağılımlarını etkileyerek, balıkçılık sektöründe ekonomik kayıplara neden olabilir. Bu durum, kıyı bölgelerinde yaşayan toplulukların geçim kaynaklarını tehdit etmekte ve sosyal sorunlara yol açmaktadır (Sahin, 2020).

Deniz suyu sıcaklıkları ile yağış miktarı arasında pozitif bir ilişki olduğu düşünülmektedir. Yüksek deniz suyu sıcaklıkları, buharlaşmayı artırarak, atmosferdeki nem miktarını etkileyebilir ve dolayısıyla yağış düzenlerini değiştirebilir (Yılmaz, 2021). Bu durum, kıyı ekosistemlerinde su kaynaklarının dengesiz dağılımına yol açarak, tarım ve su temini gibi insan faaliyetlerini de olumsuz etkileyebilir. Kıyı bölgelerinde, deniz suyu sıcaklıklarının artması, deniz seviyesi yükselmesi ile birleştiğinde, kıyı ekosistemlerinin kaybına ve habitat değişikliklerine neden olabilir (Koç, 2024).

Ekosistem hizmetleri açısından, deniz suyu sıcaklıklarının artışı, biyoçeşitliliği tehdit eden faktörlerden biri olarak öne çıkmaktadır. İklim değişikliği, deniz ekosistemlerinde biyoçeşitliliğin azalmasına yol açarak, ekosistem hizmetlerinin devre dışı kalmasına neden olabilir (Aydın ve Kemec, 2023). Örneğin, deniz kaplumbağaları gibi bazı türler, dış ortam sıcaklıklarına bağlı olarak yaşamlarını sürdürmektedirler ve

sıcaklık deęişimleri bu türlerin üreme ve hayatta kalma oranlarını etkileyebilir (Altuę ve ark., 2017).

2.2.1. Deniz biyolojik süreçleri üzerindeki etkileri

Deniz suyu sıcaklığının deniz biyolojik süreçleri üzerindeki etkileri, iklim deęişikliğinin deniz ekosistemleri üzerinde potansiyel etkileri nedeniyle büyük önem taşımaktadır. Deniz suyu sıcaklığındaki deęişiklikler, birincil üretim, metabolik süreçler, tür dağılımı ve ekosistem kompozisyonu dahil olmak üzere çeşitli deniz biyolojik süreçlerini önemli ölçüde etkileyebilir. Deniz biyolojik aktivitesini anlamak için deniz suyu sıcaklığının zamansal ve mekansal varyasyonlarını anlamamanın önemi vurgulanmaktadır. Ayrıca, global ısınma altında deniz ekosistemlerinde önemli deęişikliklere yol açabilecek metabolik süreçlere doğrudan sıcaklık etkileri konusunda deniz birincil üretimin duyarlılığı oldukça önemlidir (Taucher ve Oschlies, 2011).

Venegas ve arkadaşları (2023), Pasifik Okyanusunda deniz ısınmalarının etkilerini vurgulayarak deniz türleri ve ekosistemleri üzerindeki önemli etkilerine dikkat çekmektedir. Dong ve arkadaşları (2022), planktik foraminiferanın deniz suyu pH'sındaki düşüşe biyolojik tepkisine dair içgörüler sunarak deniz organizmalarının deniz suyu koşullarındaki deęişikliklere duyarlılığını göstermektedirler. Ayrıca, Schwier ve arkadaşları (2017), besin zenginleştirme deneylerinde, birincil deniz aerosol bileşimi üzerinde modülasyonları gözlemleyerek biyolojik süreçlerin deniz suyu kimyası üzerindeki etkilerini öne sürmektedirler.

Chiswell (2022), deniz yaşamı üzerindeki deniz yüzeyi ısınmalarının yıkıcı etkilerini vurgulayarak yerel kelpin aşırı deniz suyu sıcaklıklarından dolayı sıcaklık toleransının aşılmasının önemini belirtmektedir. Wåhlström ve arkadaşları (2022), iklim deęişikliğinin deniz ortamlarına ve ekosistemlere getirdiğı ek baskıları vurgulayarak deniz suyu sıcaklığının deniz biyolojik süreçleri üzerindeki etkilerini anlamamanın aciliyetine işaret etmektedir.

Segschneider ve Bendtsen (2013), ısınan bir okyanusta sıcaklığa bağımlı remineralizasyonu tartışarak deniz ekosistem kompozisyonundaki deęişikliklerden

kaynaklanan yüzey pCO₂'deki potansiyel artışa dikkat çekmektedir. Ayrıca, Morris ve arkadaşları tarafından yapılan bir çalışma (2018), deniz suyu sıcaklığı verilerini toplamının tarihçesine dair bir perspektif sunarak deniz suyu sıcaklığını izleme çabalarının uzun vadeli önemini vurgulamaktadır.

2.3. Su Sıcaklığının Balıkçılık Üzerindeki Etkisi

Deniz suyu sıcaklığının balıkçılık üzerindeki etkileri, sadece ekosistem dinamikleri ile sınırlı değildir. Balıkçılık endüstrisi, deniz suyu sıcaklıklarındaki değişimlere bağlı olarak avlanan türlerin dağılımında da değişiklikler yaşamaktadır. Örneğin, sıcaklık artışları bazı türlerin daha yeni habitatlarda yaşamaya başlamasına neden olabilir. Bu durum, balıkçılıkla geçinen toplulukların ekonomik durumlarını da etkileyebilir, çünkü avlanan türlerin yer değiştirmesi, yerel balıkçılık faaliyetlerini zorlaştırabilir (Dilek ve ark., 2019). Ayrıca, deniz suyu sıcaklığındaki artışlar, deniz ürünlerinin kalitesini de etkileyebilir. Balıkların büyüme hızları, sıcaklık değişimlerine bağlı olarak değişiklik gösterebilir. Sıcak su koşullarında, balıkların büyüme oranları artarken, bu durum aynı zamanda besin kalitesinin düşmesine de yol açabilir. Bu nedenle, deniz suyu sıcaklıklarının izlenmesi, balıkçılık yönetimi açısından kritik bir öneme sahiptir (Gündoğdu ve Buyruk, 2021).

Deniz suyu sıcaklığı, balıkçılık üzerinde çok yönlü etkilere sahip bir faktördür. İklim değişikliği ile birlikte artan sıcaklıklar, deniz ekosistemlerinin dengesini bozmakta ve balıkçılık faaliyetlerini tehdit etmektedir. Bu nedenle, deniz suyu sıcaklıklarının düzenli olarak izlenmesi ve bu verilerin balıkçılık yönetiminde kullanılması, sürdürülebilir balıkçılık uygulamaları için hayati öneme sahiptir (Mavruk ve Avşar, 2017). Avcılık bağlamında su sıcaklığı, balık türlerinin yakalanabilirliği ve ölümü ile ilişkilendirilmiştir. Araştırmalar, yüksek su sıcaklıklarının belirli balıkların, örneğin Atlantik somonunun, yakalanabilirliğini azaltabileceğini ve bu nedenle yakalama ve bırakma avcılığı için nehir kapanma sıcaklık eşiklerini etkileyebileceğini göstermiştir. Ayrıca, yakalama ve bırakma sonrası ölüm tahminlerinin su sıcaklığıyla ilişkilendirildiği, bu durumun avcılık uygulamalarının sonuçlarını şekillendirmedeki rolünü vurgulayan çalışmalar bulunmaktadır. Su sıcaklığı ile yakalama dalgalanması

arasındaki ilişki de gösterilmiş, bu da sıcaklığın avcılık başarısı üzerindeki etkisini daha da vurgulamaktadır (Choo, 2021).

Su sıcaklığının etkisi, doğrudan yakalama sonuçlarının ötesine geçerek, balıkların üreme başarısını etkilemektedir. Çalışmalar, akış hızı ve su sıcaklığının balık yüzme davranışı ve gonad gelişimi üzerinde birlikte etkisinin olduğunu vurgulayarak, sıcaklığın ve balıkların üreme süreçleri arasındaki karmaşık ilişkiyi ortaya koymaktadır (Liu ve ark., 2021). Ayrıca, su sıcaklığındaki değişikliklerin balık sosyal davranışı ve refahındaki değişikliklere bağlandığı, nihayetinde balık popülasyonlarının genel refahını etkileyen bir faktör olduğu gösterilmiştir (Gonçalves-de-Freitas ve ark., 2019). Ayrıca, su sıcaklığının balık avı üzerindeki etkisi, iklim değişikliği bağlamında incelenmekte ve çevresel bozulmalar karşısında balıkçılık üretkenliği üzerindeki potansiyel etkileri vurgulayan çalışmalar dikkat çekmektedir (McClanahan ve Abunge, 2014). Balık türlerinin yaşam alanlarında dikey davranışlarının su sıcaklığından etkilendiği bulunmuş, bu da sıcaklığın balık ekolojisi ve dağılımını şekillendirmedeki rolünü daha da vurgulamıştır (Matsumoto ve ark., 2013).

2.3.1. Su sıcaklığı ve balık ilişkisi

Balık göçleri, su sıcaklığı gibi çevresel faktörlerden büyük ölçüde etkilenmektedir. Su sıcaklığı, balıkların üreme, beslenme ve göç davranışlarını doğrudan etkileyen önemli bir parametredir. Özellikle, balıkların üreme dönemlerinde su sıcaklığındaki değişiklikler, göç yollarını ve zamanlamalarını etkileyebilir. Örneğin, İnci kefali (*Alburnus tarichi*) gibi anadrom türler, üreme dönemlerinde alkali Van Gölü'nden tatlı su kaynaklarına göç ederken, su sıcaklığındaki değişiklikler bu göç sürecini etkileyebilir. Su sıcaklığının artması, balıkların metabolizmasını hızlandırarak, göç dönemlerinin zamanlamasında değişikliklere yol açabilir (Oğuz ark., 2019).

Su sıcaklığı, balıkların büyüme oranlarını da etkileyen bir faktördür. Yüksek sıcaklıklar, balıkların büyüme hızını artırabilirken, aşırı sıcaklıklar stres yaratabilir ve bu da balıkların sağlığını olumsuz etkileyebilir (Balta ve Dengiz, 2020). Ayrıca, su

sıcaklığındaki deęişiklikler, balıkların besin kaynaklarına erişimini de etkileyebilir. Örneęin, sıcaklık artışları, fitoplankton ve zooplankton gibi besin kaynaklarının dağılımını etkileyerek, balıkların beslenme alışkanlıklarını deęiştirebilir. Bu durum, balıkların göç yollarını ve zamanlamalarını etkileyebilir, çünkü balıklar genellikle besin kaynaklarının yoğun olduęu alanlara yönelirler (Dalkiran ve ark., 2016).

Su sıcaklığının balık göçleri üzerindeki etkisi, ekosistem saęlığı açısından da önemlidir. Su sıcaklığındaki artış, su kalitesini etkileyerek, balıkların yaşadığı habitatların bozulmasına yol açabilir. Özellikle, yüksek sıcaklıklar, suyun oksijen seviyelerini düşürebilir ve bu da balıkların hayatta kalma şansını azaltabilir (Duran ve ark., 2017).

Su sıcaklığı ile birlikte artan besin maddeleri, sucul ekosistemlerde hipertrofik koşulların oluşmasına neden olabilir. Bu durum, balıkların göç yollarını ve üreme alanlarını olumsuz etkileyebilir (Ariman ve Koyuncu, 2019).

2.4. Yapay Zeka Kavramı

Yapay zeka (YZ), insan zekasının özelliklerini taklit eden sistemler ve teknolojiler olarak tanımlanabilir. İlk olarak 1956 yılında John McCarthy tarafından "zeki makineler yapma bilimi ve mühendisliği" olarak tanımlanan bu kavram, günümüzde çok çeşitli alanlarda uygulanmaktadır (Ekrem ve Daşikan, 2021). Yapay zeka, makine öğrenimi, doğal dil işleme ve robot teknolojileri gibi alt alanları içerir ve bu alanlar, makinelerin insan benzeri düşünme, öğrenme ve problem çözme yeteneklerini geliştirmesine olanak tanır (Çelik ve ark., 2021; Tiftik, 2021).

Yapay zekanın saęlık, tarım, eğitim ve sanayi gibi birçok sektörde önemli uygulamaları bulunmaktadır. Örneęin, saęlık alanında yapay zeka, hastalıkların erken teşhisi, tedavi planlaması ve saęlık hizmetlerinin iyileştirilmesi gibi konularda kullanılmaktadır (Alıcılar ve Çöl, 2021; Yılmaz ve ark., 2021). Tarımda ise, bitki hastalıklarının tespiti ve verimliliğin artırılması amacıyla yapay zeka teknikleri kullanılmaktadır (Aksoy ve ark., 2020). Eğitimde, bireylerin yapay zeka

okuryazarlığını artırmak için müfredatlara entegre edilmesi önerilmektedir (Çetin, 2024). Yapay zeka, insan zekasının çeşitli yönlerini taklit eden ve birçok sektörde devrim niteliğinde değişiklikler yaratan bir teknolojidir. Ancak, bu teknolojinin etik, sosyal ve ekonomik etkilerinin dikkatlice değerlendirilmesi gerekmektedir (Kurçer, 2023; Bebek, 2023). Bununla birlikte, yapay zekanın bazı olumsuz etkileri de bulunmaktadır. Örneğin, iş gücü üzerindeki etkileri, çalışanların motivasyonunu ve performansını olumsuz yönde etkileyebilir (Erkutlu, 2023). Ayrıca, etik ve ahlaki sorunların sorgulanması da yapay zeka uygulamalarının yaygınlaşmasıyla birlikte önem kazanmaktadır (Ergüven ve Ökten, 2022). Dolayısıyla, yapay zekanın potansiyel faydaları ve riskleri arasında dengeli bir yaklaşım geliştirilmesi gerekmektedir.

2.5. Yapay Zekanın Kullanım Alanları

Yapay zeka (YZ), insan beyninin düşünme ve öğrenme işlevlerini taklit eden, topladığı bilgileri yineleyerek kendini geliştirebilen sistemler olarak tanımlanır (Elçiçek, 2024). Son yıllarda YZ teknolojisi, sağlık, otomotiv, eğitim, finans, tarım ve daha birçok alanda devrim niteliğinde uygulamalar bulmuştur (Görentaş, 2023).

Yapay zekanın sağlık alanındaki kullanımı, hastalıkların teşhisinden tedavi süreçlerine kadar geniş bir yelpazeyi kapsamaktadır. Örneğin, görüntü işleme teknolojileri sayesinde biyomedikal görüntülerden hastalık teşhisi yapılmakta ve bu süreçte YZ yöntemleri kullanılmaktadır (Aksoy ve ark., 2021). Ayrıca, sağlık hizmetlerinde YZ uygulamaları, hastaların izlenmesi ve tedavi süreçlerinin optimize edilmesi gibi konularda da önemli bir rol oynamaktadır (Samancı, 2024). Bunun yanı sıra, YZ, ilaç keşfi ve geliştirme süreçlerinde de hız kazandırarak, yeni tedavi yöntemlerinin daha hızlı bir şekilde piyasaya sürülmesine olanak tanımaktadır (Arvas, 2023).

Otomotiv sektöründe, YZ teknolojileri, otonom araçların geliştirilmesinde kritik bir rol oynamaktadır. Bu araçlar, çevrelerini algılayabilen ve bu verileri işleyerek karar verebilen sistemlerdir (Aksoy ve ark., 2021). Otonom sürüş sistemleri, trafik kazalarını azaltma potansiyeline sahipken, aynı zamanda yakıt verimliliğini artırarak çevresel etkileri azaltma konusunda da fayda sağlamaktadır (Ergün, 2023). Ayrıca, YZ,

araçların bakım süreçlerinin optimize edilmesi ve sürücü deneyiminin iyileştirilmesi gibi alanlarda da kullanılmaktadır (Ulupınar, 2023).

Eğitim alanında, YZ uygulamaları, kişiselleştirilmiş öğrenme deneyimleri sunarak öğrencilerin ihtiyaçlarına göre özelleştirilmiş eğitim materyalleri geliştirilmesine olanak tanımaktadır. Öğrencilerin öğrenme stillerine ve hızlarına göre uyarlanmış içerikler, eğitimde daha etkili sonuçlar elde edilmesini sağlamaktadır. Ayrıca, YZ destekli sistemler, öğretmenlerin öğrenci performansını izlemelerine ve gerektiğinde müdahale etmelerine yardımcı olmaktadır (Elçiçek, 2024).

Tarım sektörü, YZ teknolojilerinin en fazla etki gösterdiği alanlardan biridir. YZ, hassas tarım uygulamaları ile birlikte, bitki hastalıklarının tespiti, yabancı otların kontrolü ve mahsul verimliliğinin artırılması gibi konularda önemli avantajlar sunmaktadır. Örneğin, derin öğrenme yöntemleri kullanılarak bitki hastalıklarının tespiti yapılmakta ve bu sayede tarımsal verimlilik artırılmaktadır (Uygun, 2024). Ayrıca, insansız hava araçları (İHA) ile entegre YZ sistemleri, tarım arazilerinin izlenmesi ve analiz edilmesi için kullanılmaktadır (Aksoy ve ark., 2021). Bu tür uygulamalar, çiftçilerin daha bilinçli kararlar almasına ve kaynaklarını daha verimli kullanmasına olanak tanımaktadır (Güman, 2024).

Finans sektöründe de YZ, risk yönetimi, dolandırıcılık tespiti ve müşteri hizmetleri gibi alanlarda kullanılmaktadır. YZ algoritmaları, büyük veri setlerini analiz ederek, finansal piyasalardaki trendleri tahmin etme ve yatırım kararlarını optimize etme konusunda yardımcı olmaktadır. Ayrıca, müşteri hizmetlerinde YZ destekli chatbotlar, kullanıcıların sorularını hızlı bir şekilde yanıtlayarak müşteri memnuniyetini artırmaktadır (Aydınbaş, 2023).

Yapay zeka teknolojisi, sağlık, otomotiv, eğitim, tarım ve finans gibi birçok alanda devrim niteliğinde değişiklikler sağlamaktadır. Bu teknolojinin sunduğu olanaklar, insan hayatını kolaylaştırmakta ve çeşitli sektörlerde verimliliği artırmaktadır. Ancak, YZ uygulamalarının etik sorunları ve potansiyel riskleri de göz önünde bulundurulmalıdır (Güman, 2024).

Yapay zeka (YZ) teknolojisi, hidrobiyoloji alanında da önemli bir dönüşüm yaratmaktadır. Bu dönüşüm, su ekosistemlerinin yönetimi, su kalitesinin izlenmesi ve biyolojik çeşitliliğin korunması gibi birçok alanda kendini göstermektedir. Yapay zeka teknolojilerinin su kalitesinin izlenmesi üzerindeki etkisi dikkate değerdir. YZ, su kalitesi parametrelerinin tahmin edilmesinde kullanılmakta ve bu sayede su kaynaklarının yönetiminde daha bilinçli kararlar alınmasına yardımcı olmaktadır. Örneğin, Palabıyık ve Akkan (2024), su kalitesi indeksini (WQI) tahmin etmek için çeşitli yapay zeka modelleri kullanmıştır. Bu tür modeller, su kalitesinin izlenmesi ve yönetimi için önemli bir araç haline gelmektedir. Dahası, su ekosistemlerinin korunması için gerekli olan bilgilerin toplanmasını ve analiz edilmesini kolaylaştırmaktadır (Ditria ve ark., 2022).

Hidrobiyolojide yapay zeka uygulamalarının bir diğer önemli alanı, su ekosistemlerinin izlenmesi ve yönetiminde otomasyonun sağlanmasıdır. Yapay zeka, ayrıca su ekosistemlerinin biyolojik çeşitliliğinin korunmasında da önemli bir rol oynamaktadır. Örneğin, Deacon ve arkadaşları (2018), yapay rezervuarların doğal göletlerle birlikte kullanıldığında biyoçeşitliliği artırabileceğini kanıtlamışlardır.

YZ tabanlı otomasyon sistemleri, veri toplama, transfer ve işleme süreçlerini hızlandırarak, yöneticilere daha fazla bilgi sunmakta ve bu sayede daha etkili yönetim kararları alınmasına olanak tanımaktadır (Himeur, 2023). Ayrıca, yapay zeka, su ekosistemlerinin yönetiminde sürdürülebilirlik hedeflerine ulaşmak için de kullanılmaktadır. Yapay zeka ve diğer dijital teknolojilerin, Birleşmiş Milletler'in Sürdürülebilir Kalkınma Hedefleri'ne ulaşmada önemli bir rol oynayabileceği vurgulanmaktadır (Alonso ve ark., 2021). Bu bağlamda, yapay zeka uygulamaları, su kaynaklarının daha sürdürülebilir bir şekilde yönetilmesine katkı sağlamaktadır. Örneğin, entegre zincir modelleme ve yapay zeka teknikleri kullanarak su kalitesi ve ekosistem yönetimi üzerine çalışmalar yapmıştır. Bu tür araştırmalar, su kaynaklarının yönetiminde daha bütünsel ve sürdürülebilir yaklaşımlar geliştirilmesine olanak tanımaktadır (Choi, 2023). Dolayısıyla, yapay zeka uygulamalarının hidrobiyolojide de önemli bir dönüşüm yarattığı ifade edilebilmektedir. Su kalitesinin izlenmesi, biyolojik çeşitliliğin korunması ve su ekosistemlerinin yönetimi gibi alanlarda

sağladığı avantajlar, bu teknolojilerin gelecekteki potansiyelini göstermektedir (Elçiçek, 2024).

2.6. Makine Öğrenimi

Makine öğrenimi modellerinin üstün veri yorumlama, daha az hesaplama karmaşıklığı ve doğrusal olmayan verileri başarıyla işleme yeteneğine sahip oldukları kabul edilmektedir (Chen ve ark., 2023). Veriye dayalı makine öğrenimi tahmin modellemesinin doğruluğu, onu son yıllarda güvenilir bir optimizasyon/tahmin yöntemi haline getirmiştir (Arshad ve ark., 2022). Makine öğrenimi, açık bir programlamaya ihtiyaç duymadan, bilgisayarların verilerdeki örüntülerden öğrenmesine ve yeni verilere uygulanabilecek modeller oluşturmaya olanak tanıyan bir yapay zeka uygulamasıdır (Mounce ve ark., 2017).

Yapay zekanın bir alt alanı olan makine öğrenimi (ML), bilgisayarların açık programlama olmadan verileri analiz ederek öğrenmelerini sağlar. Üç ana aşama genellikle bu süreci içerir: veri toplama ve hazırlama, modeli eğitme ve modeli değerlendirme süreçlerini içerir. Başlangıçta, ilgili veri setleri bir dizi değişikliklerle analiz için toplanır ve erişilebilir hale getirilir. Bunu takiben, model, seçilen makine öğrenme yöntemini eğitmek için eğitim verilerini kullanarak girişler ve çıktılar arasındaki bağlantıları öğrenir. Sonuçta, test verileri modelin performansını değerlendirmek için kullanılır ve başarısını ölçmek için doğruluk ve hata oranları gibi ölçütler kullanılır. Model optimize edildikten sonra, yeni verileri kullanarak tahminler oluşturmak için kullanılabilir (Altaş ve Öztürk, 2024).

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı ile İlgili Genel Bilgiler

Bartın'ın Amasra ilçesi, Türkiye'nin Batı Karadeniz Bölgesi'nde yer alan tarihi ve doğal güzellikleriyle öne çıkan bir yerleşim alanıdır. Bu tarihi ve kültürel zenginlikleri ile dikkat çeken Amasra, sürdürülebilir turizm açısından da önemli bir potansiyele sahiptir. Amasra'nın tarihi, Roma dönemine kadar uzanmakta olup, Bizans, Selçuklu ve Osmanlı dönemlerinde de önemli bir yerleşim yeri olmuştur. Bu tarihsel süreç, Amasra'nın mimari yapısına ve kültürel dokusuna yansımaktadır (Özdemir ve Açiksöz, 2016; Cengiz ve ark., 2017).

Amasra'nın doğal güzellikleri, bölgenin turizm potansiyelini artıran bir diğer önemli unsurdur. Özellikle, Amasra'nın kıyı şeridi, zengin biyolojik çeşitliliği ve doğal peyzajı ile dikkat çekmektedir. Yapılan araştırmalar, Amasra ve çevresindeki bitki örtüsünün zenginliğini ortaya koymakta ve bu durumun sürdürülebilir turizm açısından değerlendirilmesi gerektiğini vurgulamaktadır (Nayim, 2017). Amasra'nın doğal alanları, yerel halkın ve turistlerin ilgisini çeken ekoturizm faaliyetleri için de uygun bir zemin sunmaktadır.

Bartın'ın Amasra ilçesi, tarihi ve doğal güzellikleri ile dikkat çeken bir bölge olmasının yanı sıra, balıkçılık faaliyetleri açısından da önemli bir yere sahiptir. Amasra, Karadeniz'in kıyısında yer alması nedeniyle zengin deniz ürünleri çeşitliliğine sahip olup, bu durum yerel ekonominin önemli bir parçasını oluşturmaktadır. Balıkçılık, Amasra'nın tarihsel süreç içinde de önemli bir ekonomik faaliyet olmuştur. Özellikle Bizans döneminde balıkçılık faaliyetleri, bölgenin ekonomik yapısında önemli bir rol oynamıştır (Inanan ve Inanan, 2018). Günümüzde ise, balıkçılık faaliyetleri hem yerel

halk için geçim kaynağı sağlamakta hem de turizm açısından cazibe merkezi oluşturmaktadır (Suluk, 2022).

Amasra'da balıkçılık faaliyetleri, hem geleneksel yöntemlerle hem de modern tekniklerle gerçekleştirilmektedir. Yerel balıkçılar, genellikle küçük ölçekli avcılık yaparak, taze deniz ürünlerini yerel pazarlara sunmaktadır. Bu bağlamda, Amasra'nın deniz ürünleri, hem yerel halk hem de turistler tarafından büyük ilgi görmektedir. Balıkçılığın sürdürülebilirliği, Amasra'nın ekosisteminin korunması açısından da kritik öneme sahiptir. Aşırı avlanma ve çevresel kirlilik gibi sorunlar, balıkçılığın geleceğini tehdit eden unsurlar arasında yer almaktadır (Şahin ve Ceylan, 2023). Bu nedenle, sürdürülebilir balıkçılık yönetimi politikalarının geliştirilmesi gerekmektedir (Suluk, 2022).

Bununla birlikte, Amasra'da balıkçılık faaliyetlerinin karşılaştığı zorluklar da bulunmaktadır. Çevresel faktörler, iklim değişikliği ve deniz kirliliği gibi unsurlar, balıkçılığın sürdürülebilirliğini tehdit etmektedir (Şahin ve Ceylan, 2023). Ayrıca, yerel balıkçıların karşılaştığı ekonomik zorluklar, bu sektördeki istihdamı olumsuz etkileyebilmektedir. Bu nedenle, yerel yönetimlerin ve ilgili kurumların, balıkçılık sektörünü destekleyici politikalar geliştirmesi önem arz etmektedir (Suluk, 2022).

3.2 Verilerin Eldesi

Bu çalışmada kullanılan 2014-2023 yılları arasındaki aylık sıcaklıklara ilişkin meteorolojik veriler T.C. Meteoroloji Genel Müdürlüğü'nden temin edilmiştir. Elde edilen ham veriler, veri işleme teknikleri kullanılarak analize uygun hale dönüştürülmüştür. Bu süreçte, verilerin doğruluğunu sağlamak için eksik veya hatalı gözlemler titizlikle kontrol edilip düzeltilmiştir.

3.3. Veri İşleme Süreci

Modelleme aşamasına geçmeden yapılan çeşitli ön işleme adımları veri seti üzerinde uygulanmıştır. Bu adımlar aşağıdaki gibi özetlenebilir:

- **Eksik Gözlemlerin Düzeltilmesi:** Veri setindeki eksik veya hatalı değerler uygun yöntemler kullanılarak tamamlanmış veya analizden çıkarılmıştır.
- **Veri Ölçekleme ve Normalleştirme:** Değişkenler arasındaki ölçek farklılıklarını ortadan kaldırmak ve model performansını iyileştirmek için veri seti yeniden ölçeklendirilmiştir. Bu süreçte Min.-Max. normalizasyon yöntemi tercih edilmiştir.
- **Eğitim ve Test Verilerine Ayırma:** Modellerin eğitimi ve değerlendirilmesi için veri seti eğitim ve test verisi olarak ikiye ayrılmıştır. Eğitim verileri modellerin öğrenilmesi amacıyla kullanılırken, test verileri performans değerlendirmesi yapmak amacıyla ayrılmıştır. Genel olarak, %70 eğitim ve %30 test oranı belirlenmiştir.

3.4. Araştırmada Kullanılan Modeller ve Yaklaşımlar

Bu çalışmada, farklı makine öğrenimi algoritmaları kullanılarak tahmin gerçekleştirilmiştir. Tablo 3.1’de makine öğrenimi alanında kullanılan temel yöntemler ve bunlara ait algoritmalar ile çekirdek fonksiyonları detaylı bir şekilde sunulmuş olup, bu yapılandırma sayesinde farklı modelleme tekniklerinin özellikleri ve uygulama alanları arasındaki ilişki daha iyi anlaşılabilir hale getirilmiştir.

Tablo 3.1’de makine öğrenimi alanında yaygın bir şekilde uygulanan çeşitli yöntemler ile bunlara karşılık gelen algoritmalar ve çekirdek fonksiyonları sistematik bir biçimde sunulmaktadır. Temel modelleme teknikleri arasında yer alan lineer regresyon, regresyon ağaçları, destek vektör makineleri (SVM), Gaussian süreç regresyonu (GPR) ve sinir ağları gibi yaklaşımlar ve ayrıca bu tekniklerin özelleştirilmiş versiyonları ile topluluk yöntemleri de ele alınarak, her bir metodun kapsamı ve uygulama alanları hakkında derinlemesine bir anlayış geliştirilmesi amaçlanmıştır. DYS tahmini için, MATLAB ortamında bulunan makine öğrenmesi Toolbox 12.4 kullanılarak regresyon öğrenme modeli paketleri ile değerlendirme süreci gerçekleştirilmiştir. Aşırı tahmin riskini minimize etmek amacıyla çapraz geçerlilik

(Cross-Validation) yöntemi uygulanmıştır. Bu kapsamda, veri seti test için beş katmana ayrılmış ve her bir kat, tahmin ve doğrulama açısından ayrı ayrı değerlendirilmiştir. Bu yöntem, modelin genel performansını artırmayı ve aşırı uyumdan kaçınmayı hedeflemektedir.

Tablo 3. 1. Makine öğrenimi teknikleri ve uygulamaları

Yaklaşım	Algoritma/Kernel Fonksiyonu
Doğrusal Regresyon	Lineer Etkileşimler Lineer Robust Lineer Adım Adım Lineer
Karar Ağacı Algoritması	Dar Ağaç Orta Ağaç Kaba Ağaç
Destek Vektör Makineleri (SVM)	Lineer SVM Kuadratik SVM Kübik SVM İnce Gauss SVM Orta Gauss SVM Kaba Gauss SVM
Regresyon Ağaçları Topluluğu (RTE)	Artırılmış Ağaçlar Rastgele Orman (torbalı ağaçlar)
Gaussian Süreç Regresyonu (GPR)	Kare Eksponansiyel Gaussian Süreç Regresyonu (GPR) Matern 5/2 Gaussian Süreç Regresyonu (GPR) Eksponansiyel Gaussian Süreç Regresyonu (GPR) Rasyonel Kuadratik Gaussian Süreç Regresyonu (GPR)
Sinir Ağı	Dar Sinir Ağı Orta Sinir Ağı Geniş Sinir Ağı İki Katmanlı Sinir Ağı Üç Katmanlı Sinir Ağı
Kernel Fonksiyonları	SVM Çekirdek En Küçük Kareler Regresyonu Çekirdeği
Özelleştirilmiş Makine Öğrenimi Modelleri	Özel Ağaç Özel SVM Özel Gaussian Süreç Regresyonu Özel Topluluk Özel Sinir Ağı

3.4.1. Destek vektör makinesi (SVM)

Genelleştirilmiş Doğrusal Sınıflandırıcı ailesinin bir üyesi olan ve Vapnik-Chervonenkis Boyut teorisine dayanan destek vektör makinesi (SVM), ilk olarak 1963 yılında Vladimir N. Vapnik tarafından doğrusal modeller için oluşturulmuştur (Vapnik ve Lerner, 1963). Cortes (1995)'te doğrusal olmayan eğitim verileri için kullanımını genişletmiştir. İstatistiksel makine öğrenimi fikirlerinden biri SVM. Model eğitim sürecinde, model yapısını destekleyen girdi vektörleri seçilir; modelin yapısı önceden belirlenmez (Vapnik, 1998). Destek vektör makineleri, regresyon analizi ve kategorizasyon için kullanılan denetimli öğrenme teknikleridir. SVM'ler aşırı uyumu azaltmak ve genelleme yeteneklerini geliştirmek için destek vektörleri ile regresyon veya karar sınırı arasındaki mesafeyi maksimize etmeyi amaçlar (Hakkoum ve ark., 2024).

SVM, sınıflandırma ve regresyon için bir denetimli öğrenme yöntemidir (Rabbani ve ark., 2017). SVM on veri madenciliği algoritmasından biridir ve popüler seçenekler arasında en güvenilir ve doğru tekniklerden biri olarak kabul edilmektedir (Wu ve ark., 2008). SVM için bir başka sınıflandırma da yeni bir sinir ağı tahmin tekniğidir (Dong ve ark., 2005). Doğrusal olmayan sorunları çözmek için son derece başarılı metodolojisi, hem iş dünyasında hem de araştırmalarda artan bir şekilde başvurulmasını sağlamıştır (Zhao ve Magoulès, 2012).

3.4.2. Gaussian süreç regresyonu (GPR)

Gauss süreci (GP), bir girdi uzayından bir hedef uzaya doğrusal olmayan fonksiyon eşlemelerini simüle etmek için kullanılır. Bir GP, sonlu alt kümelerinden herhangi birinde sonsuz bir rastgele değişken kümesinin ortak Gauss dağılımlarıyla temsilidir. GP, eğitim verilerini açıklayan ve düzgünleştiren fonksiyonları tercih eder. Düzgünleştirici fonksiyon özelliği çok iyi genellemelere olanak sağlar (Heyns ve ark., 2012).

Parametrik olmayan bir olasılıksal çekirdek modeli GPR'dir. Bu makine öğrenimi yaklaşımı son yıllarda literatürde giderek daha popüler hale gelmiştir (Rasmusen ve Williams, 2006). Bu yaklaşım sadece tahmin yapmak için değil, aynı zamanda tahmindeki her nokta için tahminin belirsizlik seviyesini ölçen güven aralığını hesaplamak için de kullanılabilir. Bir Gauss süreci, esasen karşılık gelen olasılık dağılımının genelleştirilmiş halidir. Gauss dağılımı, bir girdi vektörünün olasılığını hesaplamak için bir ortalama ve varyans kullanır. Bir girdi zaman serisi vektörünün olasılığı her zaman adımı için hesaplanır (Sharifzadeh ve ark., 2019).

Bayes öğrenme teorisine göre, parametrik olmayan çekirdek tabanlı bir model olan GPR, denetimli makine öğrenimi yaklaşımının bir bileşenidir (Lázaro-Gredilla ve ark., 2010; Zhou ve ark., 2021). GPR, karmaşık doğrusal olmayan regresyon sorularına yanıt bulmak için çok etkili bir yöntemdir ve küçük veri kümeleriyle çalışabilir. Gauss dağılımı, Gauss süreci olarak genelleştirilen stokastik bir süreçtir (Alghamdi ve ark., 2020; Wu ve ark., 2019).

3.4.3. Karar ağacı (Dt) algoritması

Hem regresyon hem de sınıflandırma konuları için seçilebilecek bir denetimli makine öğrenimi yöntemi karar ağaçlarıdır. Seçimin temel belirleyicilerinden biri yorumlama ve anlama kolaylığıdır. Bir karar ağacı, tabanında bir kök düğümü bulunan bir ağacı andırır. Karar ağaçlarındaki karar düğümleri yapılması gereken seçimleri simgelerken, yaprak düğümleri bu seçimlerin sonuçlarını gösterir (Kotsiantis, 2013; Rokach ve Maimon, 2005). Karar ağacı, Greed Recursive algoritmasındaki kök düğümün tabanından dallanan, gerçekleri elde etmek için en iyi ağırlığa sahip özniteliği kullanan ve bölüm düğümü (hedef öznitelik) dikkate alınana kadar her bölüm adımında Gini katsayısını ve rapor gerçekleri oranını kontrol eden ağaç benzeri bir algoritma içerir (Tahraoui ve ark., 2022).

Bir eğitim veri kümesindeki tüm örnekler veya gözlemler, bazen ağacın kökü olarak da adlandırılan en üstteki düğümde yer alır. Bir girdi tahmincisi üzerindeki bir test her bir iç düğüm tarafından belirtilir ve testin sonucu ağaçtaki her bir dal tarafından temsil

edilir. Bir örneği sınıflandırmak için, ağacın kökünden başlanır ve ardından özniteliklerin değerlerine göre dalları boyunca bir yol izlenir. Yaprakta görülen olayların dağılımı, sonunda ağacın tabanında bir yaprak düğümüne ulaşıldığında bir kategorizasyon belirlemek için kullanılabilir. Günümüzde karar ağacı sınıflandırıcıları oluşturmak için çeşitli yöntemler mevcuttur (Mounce ve ark., 2017).

3.4.4. Yapay sinir ağları (YSA)

YSA ilk olarak insan beyninin sinir sisteminden esinlenen bir veri madenciliği tekniği kullanılarak geliştirilmiştir. Bu, paralel olarak çalışan nöron ağlarının YSA'nın yapısını oluşturduğunu gösterir (Zahiri ve ark., 2015). Genellikle nöral hesaplama olarak bilinen yapay sinir ağları, bu tür sonuçları gerçekleştirmeyi amaçlayan teknolojilerdir. YSA, biyolojik nöronları taklit etmek için insan beyninin işleyişinin çeşitli yönlerini simüle eder. Bir YSA'yı oluşturan işlem birimleri olan nöronlar, bir ağ içinde birbirine bağlıdır (Chui, 1992; Saravanan ve ark., 2010).

Veri setinden gelen veriler, bir YSA'yı eğitmek için sanal ağın birinci katman nöronlarına beslenir. Basitçe düğüm olarak adlandırılan bu nöronların iki temel rolü, impulsu diğer düğümlere aktarmak ve giriş verilerinden adaptif öğrenme yoluyla düğüm ağırlığını değiştirmektir. Her nöron, tüm sistem eğitilirken bir önceki katmandaki nöronlardan girdi alır ve çıktısı ağın bir sonraki katmanındaki nörona girdi olarak iletilir. Ağ öğrendikçe, eğitim sırasında ürettiği sonuçların doğruluğu artar (Chou ve ark., 2018).

3.4.5. Regresyon ağaçları topluluğu (RTE)

Topluluk modelleme, tek bir modelin doğruluğunu artırmak amacıyla tahmin için çeşitli veya aynı ML modellerini sistematik olarak oluşturan ve birleştiren bir tekniktir. RTE, LS-boosting ve bir karar ağacı model grubu adı verilen iki yöntem kullanarak model koleksiyonunu formüle eder ve ilişkilendirir (Pachauri ve Ahn, 2022).

RTE, çok sayıda modelin eğitilmesi yoluyla, topluluk teknikleri son derece hassas sonuçlar veren denetimli öğrenme algoritmalarıdır (Aria ve ark., 2024). Makine öğrenimi tarafından öğrenilen bireysel modellerin hatasını azaltmak için kanıtlanmış bir yöntem olan RTE, genellikle bir orman veya sadece bir topluluk olarak bilinen regresyon ağacı topluluğudur. Tek bir modelin tüm verilere aşırı uyum sağlama konusundaki tehlikesini, tahmin zamanında bir çoğunluk oyu elde ederek ve çeşitli veri alt örnekleri üzerinden çok sayıda model öğrenerek azaltmaktadır (Zhai ve ark., 2022). Topluluk öğrenmesi tipik olarak, sınıflandırma veya regresyon problemlerinde bir tahmin yapmak için birleştirilen birden fazla model üreten yöntemleri ifade eder (Mendes-Moreira ve ark., 2012).

3.4.6. Doğrusal regresyon

Bir tahmin konusunda bağımsız ve bağımlı değişkenlerin birbirleriyle nasıl bir ilişki içinde olduğunu belirlemek için doğrusal regresyon adı verilen bir regresyon modeli oluşturulmuştur (Chou ve ark., 2018). Bu yaklaşımla, bağımlı bir değişken, belirli bir bağımsız değişken veya faktörler topluluğundan tahmin edilebilir. Özellikle bağımlı ve bağımsız değişkenler arasında net bir doğrusal ilişki olduğunda iyi performans gösterir ve tahminlerin anlaşılmasını kolaylaştırır (Tamay ve Türker, 2024).

Bağımsız değişkenler (tahmin edici) ve bağımlı değişkenler (yanıt) arasında fonksiyonel bir bağlantı bulmak regresyon analizi ile mümkündür (Fumo ve Biswas, 2015).

$\{(x_1, y_1), \dots, (x_n, y_n)\}$ verilen örnek olsun. Burada, y_i bağımlı değişken, x_i bağımsız açıklayıcı değişkenler vektörü, β bilinmeyen regresyon parametre vektörü ve ϵ_i rastgele hatayı temsil etmektedir. y_i ve x_i arasında doğrusal bir ilişki olduğu varsayıldığında, regresyon modeli aşağıdaki gibi gösterilmektedir:

$$y_i = x_i^T \beta + \epsilon_i. \quad (3.1)$$

Matris gösterimi, bu regresyon modelini temsil etmenin başka bir yoludur. y bağımlı değişkenlerin bir vektörü, β bilinmeyen regresyon parametrelerinin bir vektörü, ϵ rastgele hataların bir vektörü ve X bağımsız açıklayıcı faktörlerin bir tasarım matrisi olsun. Regresyon modelinin matris gösterimi şu şekildedir:

$$y = X\beta + \epsilon. \quad (3.2)$$

3.4.7. Kernel fonksiyonları

Makine öğreniminde kernel yaklaşımları sıklıkla kullanılmaktadır. Bunlar, SVM'ler gibi algoritmalarda kullanılabilecek doğrusal olmayan karar sınırlarını tanımlamak için uyarlanabilir yöntemlerdir. Benzer uzantılar, birçoğu daha sonraki bölümlerde ele alınacak olan ve yalnızca örnek noktaları arasındaki iç çarpımlara dayanan diğer algoritmalar için de yapılabilir. Bu tekniklerin arkasındaki temel kavram, simetri ve pozitif-tanımlılık gibi belirli teknik kriterler göz önüne alındığında yüksek boyutlu bir uzayda bir iç çarpımı açıkça tanımlayan çekirdeklere veya çekirdek fonksiyonlarına dayanmaktadır. SVM'ler gibi algoritmalar, girdi uzayındaki başlangıç iç çarpımının yerine pozitif tanımlı çekirdeklerin konulmasıyla, bu yüksek boyutlu uzayda doğrusal bir ayırma veya tersine, girdi uzayında doğrusal olmayan bir ayırma anında genişletilebilir (Mohri, 2018).

3.5. Modellerin Performans Değerlendirmesi

Modellerin performansının değerlendirilmesinde aşağıdaki ölçütler kullanılmıştır. Analiz edilen metrikler arasında kök ortalama kare hatası (RMSE), ortalama mutlak hata (MAE), belirleme katsayısı (R^2) ve ortalama mutlak ölçeklendirilmiş hatayı (MASE) yer almaktadır.

$$MAE = \frac{1}{n} \sum_{t=1}^n |\text{output}_t - \text{target}_t| \quad (3.3)$$

$$\text{MASE} = \frac{\text{MAE}}{\frac{1}{n-1} \sum_{t=1}^n |\text{output}_t - \text{target}_t|} \quad (3.4)$$

$$R^2 = 1 - \left(\sum_{t=1}^n (\text{output}_t - \text{target}_t)^2 / (\text{output}_t - \text{target}_t^-)^2 \right) \quad (3.5)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\text{output}_t - \text{target}_t)^2} \quad (3.6)$$




BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu araştırmada zaman serisi olarak Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler kullanılmıştır. Bu veriler, 2014 ile 2023 yılları arasında günlük ortalama DYS değerlerine aittir.


4.1. Deniz Yüzey Sıcaklığına Ait Gözlem Sonuçları

2014 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 7,65 °C, ortalama en yüksek DYS değeri 24,74 °C, yıllık ortalama DYS değeri 15,36 °C olarak kayıt edilmiştir (Şekil 4.1).




Şekil 4.1. 2014 yılına ait DYS değerlerinin aylık değişimi

2015 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 7,15 °C, ortalama en yüksek DYS değeri 23,68 °C, yıllık ortalama DYS değeri 14,97 °C olarak tespit edilmiştir (Şekil 4.2).




Şekil 4.2. 2015 yılına ait DYS değerlerinin aylık değişimi

2016 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 8,25 °C, ortalama en yüksek DYS değeri 24,78 °C, yıllık ortalama DYS değeri 15,22 °C olarak gözlemlenmiştir (Şekil 4.3).




Şekil 4.3. 2016 yılına ait DYS değerlerinin aylık değişimi

2017 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 5,42 °C, ortalama en yüksek DYS değeri 23,82 °C, yıllık ortalama DYS değeri 14,28 °C olarak kayıt edilmiştir (Şekil 4.4).




Şekil 4.4. 2017 yılına ait DYS değerlerinin aylık değişimi

2018 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 7,74 °C, ortalama en yüksek DYS değeri 24,56 °C, yıllık ortalama DYS değeri 15,43 °C olarak tespit edilmiştir (Şekil 4.5).




Şekil 4.5. 2018 yılına ait DYS değerlerinin aylık değişimi

2019 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 7,48 °C, ortalama en yüksek DYS değeri 22,70 °C, yıllık ortalama DYS değeri 15,14 °C olarak rapor edilmiştir (Şekil 4.6).




Şekil 4.6. 2019 yılına ait DYS değerlerinin aylık değişimi

2020 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 8,59 °C, ortalama en yüksek DYS değeri 23,30 °C, yıllık ortalama DYS değeri 15,49 °C olarak gözlemlenmiştir (Şekil 4.7).




Şekil 4.7. 2020 yılına ait DYS değerlerinin aylık değişimi

2021 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 8,75 °C, ortalama en yüksek DYS değeri 25,10 °C, yıllık ortalama DYS değeri 15,60 °C olarak kayıt edilmiştir (Şekil 4.8).




Şekil 4.8. 2021 yılına ait DYS değerlerinin aylık değişimi

2022 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 7,46 °C, ortalama en yüksek DYS değeri 25,46 °C, yıllık ortalama DYS değeri 15,36 °C olarak tespit edilmiştir (Şekil 4.9).



Şekil 4.9. 2022 yılına ait DYS değerlerinin aylık değişimi

2023 yılında Bartın deniz gözlem istasyonunun ait deniz yüzey sıcaklığına ait veriler incelendiğinde aylara göre ortalama en düşük DYS değeri 8,06 °C, ortalama en yüksek DYS değeri 23,07 °C, yıllık ortalama DYS değeri 15,51 °C olarak rapor edilmiştir (Şekil 4.10).



Şekil 4.10. 2023 yılına ait DYS değerlerinin aylık değişimi

4.2. Deniz Yüzey Sıcaklığının Makine Öğrenimi Algoritmaları ile Tahmini

Bu çalışmada kullanılan farklı makine öğrenimi modeli, performans değerlendirme kriterleri ışığında analiz edilmiştir. Modellerin her biri farklı algoritmik yaklaşımlara ve veri işleme yöntemlerine sahiptir. Modellerin teorik temelleri, güçlü ve zayıf yönleri ile birlikte performans sonuçları akademik bir perspektifle detaylı bir şekilde incelenmiştir.

4.2.1. Destek vektör makinesi (SVM)

SVM algoritmasının değişik kernel fonksiyonları ve hiperparametre ayarları ile sağladığı performansı Tablo 4.1’de detaylı bir şekilde incelenmiştir. "Orta Gaussian SVM" modeli, en düşük RMSE (1,1981) ve MSE (1,4356) değerleri ile en yüksek R^2 (0,9577) ve en düşük MAE (0,9526) değerlerine ulaşarak, tahminleme doğruluğunun en yüksek olduğu modeli temsil etmektedir. Bu durum, modelin veri setindeki varyansı etkili bir biçimde açıkladığını ve tahminlerin gerçek değerlere yakınlığını göstermektedir. "Linear SVM" ve "Quadratic SVM" modelleri, sırasıyla RMSE değerleri 1,4021 ve 1,4798 ile oldukça yüksek doğruluk oranları sergilemekte, ancak "Cubic SVM" modelinin performansı belirgin bir düşüş göstermektedir (RMSE: 1,7845). "Fine Gaussian SVM" modeli ise, en yüksek RMSE (2,4682) ve MSE (6,0918) değerleri ile en düşük R^2 (0,8206) değerine sahip olup, bu modelin tahminlerinin güvenilirliğinin azaldığını ortaya koymaktadır. Sonuç olarak, SVM algoritmasının kernel fonksiyonu ve hiperparametre ayarlarının, modelin genel başarısı üzerinde önemli bir etkiye sahip olduğu görülmektedir. Bu bulgular, özellikle model seçiminde dikkatli olunması gerektiğini ve her bir modelin özelliklerinin, belirli veri setleri için optimize edilmesi gerektiğini vurgulamaktadır.

4.2.2. Gaussian süreç regresyonu (GPR)

GPR modeli kullanılarak gerçekleştirilen tahminlerin performansı Tablo 4.1’de incelenmiştir. Farklı GPR türleri ile elde edilen sonuçlar, modelin genel başarısını ve kernel fonksiyonlarının etkisini değerlendirmektedir. Analiz edilen metrikler arasında RMSE, MAE ve R^2 yer almaktadır. İlk olarak, Squared Exponential GPR modeli, en

düşük RMSE (1,2013) ve MSE (1,4431) değerine sahip olup, R^2 (0,9575) ve MAE (0,9423) değerleri ile yüksek bir tahmin doğruluğu sergilemektedir. Bu model, verinin sürekli ve düzgün bir yapıya sahip olduğunu varsayarak etkili bir tahminleme stratejisi sunmaktadır. Bu durum, modelin veri setindeki varyansı yüksek bir oranda açıkladığını ve tahminlerin gerçek değerlere yakın olduğunu göstermektedir. İkinci olarak, Matern 5/2 GPR modeli, RMSE değeri (1,2072) ve MSE (1,4574) ile benzer bir performans sergilemektedir. R^2 değeri (0,9571) oldukça yüksektir ve MAE (0,9407) değeri de tatmin edicidir. Bu model, verinin karmaşık yapısını yakalamada etkili bir yaklaşım sunmakla birlikte, biraz daha yüksek hata oranları göstermektedir. Üçüncü olarak, Exponential GPR modeli, RMSE (1,2123) ve MSE (1,4697) değerleri ile benzer bir performans sergilemektedir. R^2 değeri (0,9567) ve MAE (0,9466) de oldukça yüksektir. Ancak, bu modelin tahmin doğruluğu, diğer iki modelin gerisinde kalmaktadır. Bu durum, modelin verinin karmaşık yapısını yeterince iyi yakalayamadığını gösterebilir. Son olarak, Rational Quadratic GPR modeli, diğerleriyle aynı RMSE ve MSE değerlerine sahip olup, bu da modelin özelliklerinin etkili bir şekilde optimize edildiğini göstermektedir. Genel olarak, tüm GPR modelleri benzer performanslar sergilemekte ve yüksek R^2 değerleri ile veri setindeki varyansı iyi bir şekilde açıklamaktadır.

Sonuç olarak, Gaussian Süreç Regresyonu (GPR) algoritması, farklı kernel fonksiyonları ile yüksek performans göstermektedir. "Squared Exponential GPR" modeli, bu çalışma için iyi performansı sergileyen model olarak öne çıkmakta, ancak diğer modeller de benzer doğruluk seviyeleri sunmaktadır. Bu bulgular, GPR'nin esnekliğini ve farklı veri setlerine uyum sağlama yeteneğini vurgulamaktadır. Ayrıca, hiperparametrelerin optimizasyonu, modelin performansını artırmada önemli bir rol oynamaktadır. Bu çalışma, GPR'nin çeşitli uygulamalarda nasıl etkili bir şekilde kullanılabileceğine dair önemli bilgiler sunmaktadır.

4.2.3. Karar ağacı (Dt) algoritması

Karar ağacı tabanlı model (Tree) kullanılarak gerçekleştirilen tahminlerin performansı Tablo 4.1'de incelemektedir. Farklı ağaç türleri ile elde edilen sonuçlar, modelin genel başarısını ve minimum yaprak boyutunun etkisini değerlendirmektedir. Analiz edilen

metrikler arasında Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE) ve Belirleme Katsayısı (R^2) yer almaktadır. RMSE, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu gösterirken, MAE tahminlerin ortalama mutlak hatasını ölçmektedir. R^2 , modelin verideki varyansı ne kadar açıkladığını belirtmektedir. İyi performansı gösteren model, "Fine Tree" presetine sahip olanıdır. Bu modelin RMSE değeri 1,6710, MSE değeri 2,7924, R^2 değeri 0,9178 ve MAE değeri 1,2679 olarak belirlenmiştir. Bu sonuçlar, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve yüksek bir doğruluk sağladığını göstermektedir. Orta düzeydeki "Medium Tree" modeli, RMSE ve MSE değerlerinde bir artış göstermekte, ancak R^2 değeri hâlâ tatmin edici bir seviyededir (0,9008). Bu modelin MAE değeri de 1,2882 olarak kaydedilmiştir. Son olarak, "Coarse Tree" modeli, en yüksek RMSE (2,6282) ve MSE (6,9075) değerlerine sahip olup, en düşük R^2 (0,7965) ve en yüksek MAE (2,2051) değerlerini göstermektedir. Bu durum, bu modelin tahminlerinin daha az güvenilir olduğunu ve daha fazla hata içerdiğini ortaya koymaktadır.

Sonuç olarak, "Fine Tree" modeli, çalışmada iyi performans sergilemiş ve tahminleme sürecinde yüksek doğruluk oranını sağlamıştır. Diğer iki modelin sonuçları ise, modelin karmaşıklığı arttıkça performansın düştüğünü göstermektedir. Bu bulgular, karar ağaçları ile yapılan tahminleme çalışmalarında model seçiminin önemini vurgulamaktadır.

4.2.4. Yapay sinir ağları (YSA)

Farklı yapay sinir ağı mimarileri kullanılarak gerçekleştirilen tahminlerin performansı Tablo 4.1’de incelenmiştir. Analiz edilen modeller arasında Narrow, Medium, Wide, Bilayered ve Trilayered Neural Network bulunmaktadır. Sonuçlar, Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE) ve Belirleme Katsayısı (R^2) gibi metrikler üzerinden değerlendirilmiştir. İlk olarak, Narrow Neural Network modeli, en yüksek RMSE (2,9560) ve MSE (8,7378) değerlerine sahip olup, R^2 (0,7426) ve MAE (2,2400) değerleri ile düşük bir tahmin doğruluğu sergilemektedir. Bu durum, modelin karmaşık verileri yeterince iyi öğrenemediğini ortaya koymaktadır. Buna karşılık, Medium Neural Network modeli ise iyi performans göstermektedir; RMSE değeri

(1,9714) ve MSE (3,8865) ile oldukça düşük hatalar ortaya koymakta, R^2 (0,8855) değeri ise modelin veri setindeki varyansı yüksek oranda açıkladığını göstermektedir. Ayrıca, MAE (1,5263) değeri, modelin tahminlerinin gerçek değerlere yakın olduğunu vurgulamaktadır. Wide Neural Network modeli, RMSE (2,1065) ve MSE (4,4374) değerleri ile Medium Neural Network'ün gerisinde kalmakla birlikte, R^2 (0,8693) ve MAE (1,5754) değerleri ile yine de tatmin edici sonuçlar sunmaktadır. Bu model, daha fazla nöron kullanarak verinin karmaşık yapısını daha iyi öğrenmeye çalışmaktadır. Bilayered Neural Network ve Trilayered Neural Network modelleri, sırasıyla RMSE (2,8982) ve (2,8472) değerleri ile daha yüksek hata oranları göstermektedir. Bu modellerin R^2 değerleri (0,7526 ve 0,7612) ile daha düşük bir varyans açıklama oranı sunmaları, katman sayısının artmasının her zaman performansı artırmadığını ortaya koymaktadır. Sonuç olarak, bu çalışma sinir ağı modellerinin yapılandırmasının performans üzerindeki etkisini vurgulamaktadır. Medium Neural Network modeli, iyi tahmin doğruluğunu sağlarken, diğer modellerin performansları da dikkate değer sonuçlar sunmaktadır. Bu bulgular, sinir ağlarının farklı yapılandırmalarının veri setine uyum sağlama yeteneğini ve hiperparametrelerin optimize edilmesinin önemini göstermektedir. Sinir ağları, karmaşık verilerle çalışmak için etkili bir araç olarak değerlendirilmektedir.

4.2.5. Regresyon ağaçları topluluğu (RTE)

Regresyon Ağaçları Topluluğu (RTE) kullanarak elde edilen tahminlerin performansı Tablo 4.1'de değerlendirilmiştir. "Bagged Trees" modeli, en düşük RMSE (1,3625) ve MSE (1,8565) değerleri ile en yüksek R^2 (0,9453) ve en düşük MAE (1,0507) değerlerine ulaşmıştır. Bu durum, modelin veri setindeki varyansı etkili bir şekilde açıkladığını ve tahminlerin gerçek değerlere yakınlığını gösterir. Diğer yandan, "Boosted Trees" modeli, RMSE değeri (1,6338) ile daha yüksek bir hata oranı sergilemekte ve MSE (2,6691) ile R^2 (0,9214) değerleri de "Bagged Trees" modelinin gerisinde kalmaktadır. Ancak, "Boosted Trees" modelinin öğrenme oranı (learning rate) ile birlikte daha karmaşık bir yapı sunduğu göz önünde bulundurulmalıdır. Bu durum, modelin aşırı uyum (overfitting) riskini artırabileceği anlamına gelmektedir. Sonuç olarak, regresyon ağaçları topluluğu algoritmalarının, modelin hiperparametre ayarlarının dikkatli bir şekilde optimize edilmesi gerektiği ve bu ayarların tahminleme

başarısını önemli ölçüde etkilediği sonucuna varılabilir. Bu bulgular, makine öğrenimi uygulamalarında model seçiminde dikkatli olunması gerektiğini ve her bir modelin performansını artırmak için uygun hiperparametrelerin belirlenmesinin önemini vurgulamaktadır.

4.2.6. Doğrusal regresyon

Çeşitli Doğrusal Regresyon modellerinin (Linear Regression) performansını değerlendirilmiştir. Dört farklı model arasında yapılan analizde, RMSE (Kök Ortalama Kare Hatası), MSE (Ortalama Kare Hatası), R^2 (Belirleme Katsayısı) ve MAE (Ortalama Mutlak Hata) gibi metrikler kullanılmıştır. Tablo 4.1'deki sonuçlar, farklı doğrusal regresyon modellerinin tahminleme performanslarını karşılaştırmak için önemli bir temel sunmaktadır. İlk olarak, "Doğrusal Regresyon" modeli iyi sonuçlar vermekte olup, düşük RMSE (1,4616) ve MSE (2,1363) değerleri ile yüksek bir R^2 (0,9371) ve MAE (1,1470) sunmaktadır. Bu, modelin veriye mükemmel bir uyum sağladığını ve tahminlerinin güvenilir olduğunu göstermektedir. Bu model, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini oldukça iyi bir şekilde açıklamaktadır. İkinci model olan "Doğrusal Regresyon (Interactions Linear)" ise oldukça yüksek RMSE (8,6323) ve MSE (74,5167) değerlerine sahip, bu da modelin tahminlerinin büyük hatalar içerdiğini ve veriye uygunluğunun zayıf olduğunu göstermektedir. R^2 değeri -1,1949, modelin bağımsız değişkenlerin varyansını açıklamada başarısız olduğunu ortaya koymaktadır. Bu durum, modelin karmaşık etkileşimleri yeterince iyi yakalayamadığını ve bu nedenle başarısız olduğunu gösterir. "Robust Linear" modeli, ilk modelle benzer sonuçlar vermekte olup, RMSE (1,4597) ve MSE (2,1306) değerleri ile iyi bir performans sergilemektedir. Ancak, MAE (1,1533) değeri biraz daha yüksektir, bu da tahminlerin ortalama hata miktarının arttığını göstermektedir. Bu model, verinin dışındaki aşırı değerlerden etkilenmeden daha sağlam tahminler sunmayı hedefler. Son olarak, "Stepwise Linear" modeli, RMSE (1,5423) ve MSE (2,3786) değerleri ile daha yüksek hata oranları göstermektedir. R^2 değeri 0,9299 ile ilk modelin gerisindedir. Bu, modelin karmaşık yapısının tahmin başarısını olumsuz etkilediğini düşündürmektedir. Ayrıca, bu modelin aşırı karmaşık hale gelmesi, tahminlerin güvenilirliğini azaltmış olabilir.

Genel olarak, "Doğrusal Regresyon" modelinin iyi performansı sergilediğini, diğer modellerin ise farklı nedenlerle tahmin başarısının düştüğünü göstermektedir. Model seçiminde dikkatli olunması gerektiği ve karmaşık modellerin her zaman daha iyi sonuçlar vermediği sonucuna ulaşılmaktadır. Bu bulgular, tahminleme çalışmalarında modelin basitliği ile karmaşıklığı arasında bir denge kurmanın önemini vurgulamaktadır.

4.2.7. Kernel fonksiyonları

Çalışmada SVM Kernel ve Least Squares Regression Kernel olmak üzere iki farklı Kernel Fonksiyonu modelinin performansı Tablo 4.1’de değerlendirilmiştir. Her iki model, RMSE (Kök Ortalama Kare Hatası), MSE (Ortalama Kare Hatası), R^2 (Belirleme Katsayısı) ve MAE (Ortalama Mutlak Hata) gibi metrikler kullanılarak analiz edilmiştir. Analiz edilen modeller arasında SVM Kernel ve Least Squares Regression Kernel yer almaktadır. Elde edilen sonuçlar, her iki modelin çeşitli performans metrikleri üzerinden değerlendirilmektedir. İlk olarak, SVM Kernel modeli, RMSE (Root Mean Square Error) değeri 2,4434 ve MSE (Mean Squared Error) değeri 5,9704 ile belirli bir hata oranına sahiptir. R^2 (Determinasyon Katsayısı) değeri 0,8241 olarak hesaplanmış olup, bu, modelin veri setindeki varyansın %82,41’ini açıkladığını göstermektedir. Bu durum, modelin tahminlerinin oldukça doğru olduğunu ifade etmektedir. Ayrıca, MAE (Mean Absolute Error) değeri 2,0873 olarak belirlenmiş, bu da modelin tahminlerinin ortalama olarak gerçek değerlere ne kadar uzak olduğunu ortaya koymaktadır. Öte yandan, Least Squares Regression Kernel modeli, daha iyi bir performans sergilemektedir. Bu modelin RMSE değeri 2,0290 ve MSE değeri 4,1167 olarak hesaplanmış, bu da daha düşük hata oranları sunduğunu göstermektedir. R^2 değeri 0,8787 olarak belirlenmiş olup, bu da modelin veri setindeki varyansı %87,87 oranında açıkladığını göstermektedir. Bu sonuç, modelin tahminlerinin daha yüksek bir doğrulukla gerçekleştirildiğini ortaya koymaktadır. Ayrıca, bu modelin MAE değeri 1,6339 olarak belirlenmiş, bu da tahminlerinin ortalama olarak daha az hata payı ile gerçekleştiğini desteklemektedir.

Sonuç olarak, bu bulgular Kernel Fonksiyonlarının performans üzerindeki etkisini vurgulamaktadır. Least Squares Regression Kernel modeli, daha düşük hata oranları ve yüksek determinasyon katsayısı ile daha başarılı bir tahmin performansı sergilemektedir. Elde edilen bu sonuçlar, Kernel Fonksiyonlarının, özellikle karmaşık veri setlerinde, modelin başarısını artırmada önemli bir rol oynadığını göstermektedir. Kernel tabanlı yaklaşımlar, veri analizi ve tahminleme süreçlerinde etkili araçlar olarak değerlendirilmektedir ve bu çalışma, farklı Kernel Fonksiyonlarının performansını karşılaştırarak, model seçiminde dikkate alınması gereken önemli faktörleri ortaya koymaktadır.

4.2.8. Özelleştirilmiş makine öğrenimi modelleri

Bu çalışma, beş farklı özelleştirilmiş makine öğrenimi modelinin performansı Tablo 4.1’de değerlendirilmiştir. Analiz edilen modeller arasında Karar Ağacı Algoritması, SVM (Destek Vektör Makineleri), Gaussian süreç regresyonu (GPR), Regresyon Ağaçları Topluluğu (RTE) ve Sinir Ağı bulunmaktadır. Her modelin performansı, RMSE (Root Mean Square Error), MSE (Mean Squared Error), R^2 (Determinasyon Katsayısı) ve MAE (Mean Absolute Error) gibi metrikler kullanılarak değerlendirilmiştir. Karar Ağaçları, veri setini özelliklerine göre dallara ayırarak tahminler yapan, oldukça anlaşılır bir model yapısına sahiptir. Bu modelin RMSE değeri 1,5994, MSE değeri 2,5579 ve R^2 değeri 0,9247 olarak hesaplanmıştır. Bu sonuçlar, modelin veri setindeki varyansın %92,47’sini açıkladığını göstermekte ve modelin genel olarak iyi bir performans sergilediğini ortaya koymaktadır. Ancak, karar ağaçları aşırı uyum (overfitting) riski taşımaktadır; bu durum, modelin eğitim verisine çok iyi uyum sağlaması ancak yeni verilerle karşılaştığında kötü performans göstermesi anlamına gelir. Bu nedenle, modelin optimizasyonu sırasında minimum yaprak boyutu gibi hiperparametrelerin dikkatlice ayarlanması önemlidir. SVM, veri noktalarını en iyi ayıran hiper düzlemi bulmayı hedefleyen güçlü bir sınıflandırma algoritmasıdır. Bu modelin RMSE değeri 1,4710 ve MSE değeri 2,1639 olarak belirlenmiştir. R^2 değeri 0,9363 ile yüksek bir doğruluk göstermektedir. SVM’nin başarısı, Kernel Fonksiyonlarının doğru seçimine bağlıdır. Bu çalışma, Lineer Kernel Fonksiyonu fonksiyonu kullanarak iyi sonuçlar elde etmiştir. Ancak, SVM’nin büyük veri setlerinde hesaplama açısından maliyetli olabileceği ve hiperparametre ayarlarının

karmaşık olabileceği unutulmamalıdır. Gaussian süreç regresyonu, istatistiksel bir modeldir ve tahminlerin belirsizliğini de dikkate alır. Bu model, RMSE değeri 1,2072 ve MSE değeri 1,4574 ile en iyi performansı göstermektedir. R^2 değeri 0,9571, modelin veri setindeki varyansın %95,71'ini açıkladığını göstermektedir. GPR, Kernel Fonksiyonları aracılığıyla esnek bir yapı sunar ve bu sayede karmaşık ilişkileri modelleyebilir. Ancak, GPR'nin büyük veri setlerinde hesaplama zorluğu ve bellek kullanımı gibi dezavantajları vardır. RTE, birden fazla regresyon ağacının bir araya getirilmesiyle oluşan bir topluluk modelidir. Bu modelin RMSE değeri 1,4619 ve MSE değeri 2,1373 olarak belirlenmiştir. R^2 değeri 0,9370 ile yüksek bir doğruluk sağlamaktadır. RTE, bireysel ağaçların zayıf performansını dengeleyerek genel tahmin doğruluğunu artırmaktadır. Bununla birlikte, topluluk yöntemlerinin genellikle daha fazla hesaplama gücü gerektirdiği ve modelin yorumlanmasının zorlaşabileceği dikkate alınmalıdır. Sinir ağları, karmaşık veri yapıları için güçlü bir modelleme aracı olarak öne çıkmaktadır. Bu modelin RMSE değeri 1,4573 ve MSE değeri 2,1236 olarak hesaplanmıştır. R^2 değeri 0,9374 ile iyi bir performans göstermektedir. Sinir ağları, katmanlar arası bağlantılar ve aktivasyon fonksiyonları aracılığıyla öğrenme yeteneklerini artırır. Ancak, sinir ağları aşırı uyum riski taşımakta ve hiperparametre ayarları karmaşık olabilmektedir. Sonuç olarak, bu çalışma, özelleştirilmiş makine öğrenimi modellerinin çeşitli performans metrikleri üzerinden değerlendirildiğinde, Gaussian süreç regresyonunun en iyi sonuçları verdiğini göstermektedir. Diğer modeller de yüksek doğruluk oranları sunmakta, ancak her bir modelin kendi güçlü ve zayıf yönleri bulunmaktadır. Özellikle, model seçiminde veri setinin özellikleri, modelin karmaşıklığı ve hesaplama kaynakları göz önünde bulundurulmalıdır. Bu bulgular, özelleştirilmiş makine öğrenimi modellerinin, karmaşık veri setlerinde model başarısını artırmada önemli bir rol oynadığını vurgulamaktadır.

Tablo 4.1'de, farklı yapılandırmalara sahip makine öğrenimi modellerinin performansını incelemektedir. Her bir modelin RMSE, MSE, R^2 ve MAE gibi değerlendirme ölçütlerini sunmaktadır.

Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları

Model No	Model Tipi	RMSE	MSE	R ²	MAE	Ön Ayar	Hiperparametreler
2,1	Doğrusal Regresyon	1,4616	2,1363	0,9371	1,1470	Linear	Terms: Linear; Robust option: Off
2,2	Doğrusal Regresyon	8,6323	74,5167	-1,1949	5,7722	Interactions Linear	Terms: Interactions; Robust option: Off
2,3	Doğrusal Regresyon	1,4597	2,1306	0,9372	1,1533	Robust Linear	Terms: Linear; Robust option: On
2,4	Doğrusal Regresyon	1,5423	2,3786	0,9299	1,2075	Stepwise Linear	Initial terms: Linear; Upper bound on terms: Interactions; Maximum number of steps: 1000
2,5	Karar Ağacı Algoritması	1,6710	2,7924	0,9178	1,2679	Fine Tree	Minimum leaf size: 4; Surrogate decision splits: Off
2,6	Karar Ağacı Algoritması	1,8355	3,3690	0,9008	1,2882	Medium Tree	Minimum leaf size: 12; Surrogate decision splits: Off
2,7	Karar Ağacı Algoritması	2,6282	6,9075	0,7965	2,2051	Coarse Tree	Minimum leaf size: 36; Surrogate decision splits: Off
2,8	Destek Vektör Makineleri (SVM)	1,4021	1,9659	0,9421	1,1230	Linear SVM	Kernel function: Linear; Kernel scale: Automatic; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,9	Destek Vektör Makineleri (SVM)	1,4798	2,1898	0,9355	1,1950	Quadratic SVM	Kernel function: Quadratic; Kernel scale: Automatic; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,1	Destek Vektör Makineleri (SVM)	1,7845	3,1843	0,9062	1,4198	Cubic SVM	Kernel function: Cubic; Kernel scale: Automatic; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,11	Destek Vektör Makineleri (SVM)	2,4682	6,0918	0,8206	1,9646	Fine Gaussian SVM	Kernel function: Gaussian; Kernel scale: 0.87; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,12	Destek Vektör Makineleri (SVM)	1,1981	1,4356	0,9577	0,9526	Medium Gaussian SVM	Kernel function: Gaussian; Kernel scale: 3.5; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,13	Destek Vektör Makineleri (SVM)	1,3692	1,8748	0,9448	1,0707	Coarse Gaussian SVM	Kernel function: Gaussian; Kernel scale: 14; Box constraint: Automatic; Epsilon: Auto; Standardize data: Yes
2,14	Regresyon Ağaçları Topluluğu (RTE)	1,6338	2,6691	0,9214	1,2398	Boosted Trees	Minimum leaf size: 8; Number of learners: 30; Learning rate: 0.1
2,15	Regresyon Ağaçları Topluluğu (RTE)	1,3625	1,8565	0,9453	1,0507	Bagged Trees	Minimum leaf size: 8; Number of learners: 30
2,16	Gaussian Süreç Regresyonu (GPR)	1,2013	1,4431	0,9575	0,9423	Squared Exponential GPR	Basis function: Constant; Kernel function: Squared Exponential; Use isotropic kernel: Yes; Kernel scale: Automatic; Signal standard deviation: Automatic; Sigma: Automatic; Standardize data: Yes; Optimize numeric parameters: Yes
2,17	Gaussian Süreç Regresyonu (GPR)	1,2072	1,4574	0,9571	0,9407	Matern 5/2 GPR	Basis function: Constant; Kernel function: Matern 5/2; Use isotropic kernel: Yes; Kernel scale: Automatic; Signal standard deviation: Automatic; Sigma: Automatic; Standardize data: Yes; Optimize numeric parameters: Yes
2,18	Gaussian Süreç Regresyonu (GPR)	1,2123	1,4697	0,9567	0,9466	Exponential GPR	Basis function: Constant; Kernel function: Exponential; Use isotropic kernel: Yes; Kernel scale: Automatic; Signal standard deviation: Automatic; Sigma: Automatic; Standardize data: Yes; Optimize numeric parameters: Yes

Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları (devamı)


Model No	Model Tipi	RMSE	MSE	R ²	MAE	Ön Ayar	Hiperparametreler
2,19	Gaussian Süreç Regresyonu (GPR)	1,2013	1,4431	0,9575	0,9423	Rational Quadratic GPR	Basis function: Constant; Kernel function: Rational Quadratic; Use isotropic kernel: Yes; Kernel scale: Automatic; Signal standard deviation: Automatic; Sigma: Automatic; Standardize data: Yes; Optimize numeric parameters: Yes
2,2	Sinir Ağı	2,9560	8,7378	0,7426	2,2400	Narrow Neural Network	Number of fully connected layers: 1; First layer size: 10; Activation: ReLU; Iteration limit: 1000; Regularization strength (Lambda): 0; Standardize data: Yes
2,21	Sinir Ağı	1,9714	3,8865	0,8855	1,5263	Medium Neural Network	Number of fully connected layers: 1; First layer size: 25; Activation: ReLU; Iteration limit: 1000; Regularization strength (Lambda): 0; Standardize data: Yes
2,22	Sinir Ağı	2,1065	4,4374	0,8693	1,5754	Wide Neural Network	Number of fully connected layers: 1; First layer size: 100; Activation: ReLU; Iteration limit: 1000; Regularization strength (Lambda): 0; Standardize data: Yes
2,23	Sinir Ağı	2,8982	8,3997	0,7526	2,1813	Bilayered Neural Network	Number of fully connected layers: 2; First layer size: 10; Second layer size: 10; Activation: ReLU; Iteration limit: 1000; Regularization strength (Lambda): 0; Standardize data: Yes
2,24	Sinir Ağı	2,8472	8,1064	0,7612	1,8952	Trilayered Neural Network	Number of fully connected layers: 3; First layer size: 10; Second layer size: 10; Third layer size: 10; Activation: ReLU; Iteration limit: 1000; Regularization strength (Lambda): 0; Standardize data: Yes
2,25	Kernel Fonksiyonları	2,4434	5,9704	0,8241	2,0873	SVM Kernel	Learner: SVM; Number of expansion dimensions: Auto; Regularization strength (Lambda): Auto; Kernel scale: Auto; Epsilon: Auto; Iteration limit: 1000
2,26	Kernel Fonksiyonları	2,0290	4,1167	0,8787	1,6339	Least Squares Regression Kernel	Learner: Least Squares Kernel; Number of expansion dimensions: Auto; Regularization strength (Lambda): Auto; Kernel scale: Auto; Iteration limit: 1000
Özelleştirilmiş Makine Öğrenimi Modelleri	Karar Ağacı Algoritması	1,5994	2,5579	0,9247	1,2363	Custom Tree	Surrogate decision splits: Off; ; Optimized Hyperparameters; Minimum leaf size: 2; ; Hyperparameter Search Range; Minimum leaf size: 1-54
	Destek Vektör Makineleri (SVM)	1,4710	2,1639	0,9363	1,1766	Custom SVM	Kernel scale: 1; ; Optimized Hyperparameters; Kernel function: Linear; Box constraint: 0.068701; Epsilon: 0.27673; Standardize data: No; ; Hyperparameter Search Range; Box constraint: 0.001-1000; Kernel scale: 0.001-1000; Epsilon: 0.0082204-822.0405; Kernel function: Gaussian, Linear, Quadratic, Cubic; Standardize data: true, false

Tablo 4.1. Çalışmada kullanılan farklı makine öğrenimi modellerinin karşılaştırmalı performans sonuçları (devamı)

Model No	Model Tipi	RMSE	MSE	R ²	MAE	Ön Ayar	Hiperparametreler
Özelleştirilmiş Makine Öğrenimi Modelleri	Gaussian Süreç Regresyonu (GPR)	1,2072	1,4574	0,9571	0,9407	Custom Gaussian Process Regression	Signal standard deviation: 4.1323; Optimize numeric parameters: Yes; ; Optimized Hyperparameters; Basis function: Constant; Kernel function: Isotropic Matern 5/2; Kernel scale: 2.0785; Sigma: 2.0929; Standardize data: Yes; ; Hyperparameter Search Range; Sigma: 0.0001-58.4393; Basis function: Constant, Zero, Linear; Kernel function: Nonisotropic Exponential, Nonisotropic Matern 3/2, Nonisotropic Matern 5/2, Nonisotropic Rational Quadratic, Nonisotropic Squared Exponential, Isotropic Exponential, Isotropic Matern 3/2, Isotropic Matern 5/2, Isotropic Rational Quadratic, Isotropic Squared Exponential; Kernel scale: 0.020046-20.0463; Standardize data: true, false
	Regresyon Ağaçları Topluluğu (RTE)	1,4619	2,1373	0,9370	1,0987	Custom Ensemble	;Optimized Hyperparameters; Ensemble method: LSBoost; Minimum leaf size: 1; Number of learners: 494; Learning rate: 0.061297; Number of predictors to sample: 8; ; Hyperparameter Search Range; Ensemble method: Bag, LSBoost; Number of learners: 10-500; Learning rate: 0.001-1; Minimum leaf size: 1-54; Number of predictors to sample: 1-12
	Sinir Ağı	1,4573	2,1236	0,9374	1,1431	Custom Neural Network	Iteration limit: 1000; ; Optimized Hyperparameters; Number of fully connected layers: 2; Activation: None; Regularization strength (Lambda): 6.1957e-05; Standardize data: No; First layer size: 1; Second layer size: 10; ; Hyperparameter Search Range; Number of fully connected layers: 1-3; Activation: ReLU, Tanh, Sigmoid, None; Standardize data: Yes, No; Regularization strength (Lambda): 9.2593e-08-925.9259; First layer size: 1-300; Second layer size: 1-300; Third layer size: 1-300

Orta Gaussian SVM modeli, RMSE (1,1981), MSE (1,4356) ve R^2 (0,9577) değerleri ile diğer modellere göre en iyi performansı sergilemektedir. Bu, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu gösterir. Tablo 4.1'deki veriler ışığında, orta Gaussian SVM modelinin en iyi seçim olduğu sonucuna varılabilir. Özellikle yüksek R^2 değeri, modelin bağımlı değişkenin varyansını iyi bir şekilde açıkladığını gösterir.


Şekil 4.11'de, (2.12) orta Gauss SVM (Destek Vektör Makinesi) modelinin tahmin performansını göstermektedir. Dikey eksen tahmin edilen yanıtı, yatay eksen ise gerçek yanıtı temsil etmektedir. Grafikte, mavi noktalar gözlemleri göstermektedir. Noktaların çizgiye yakınlığı, modelin performansını yansıtmaktadır. Daha yakın noktalar, modelin daha doğru tahminler yaptığını gösterir. Bu model, gerçek yanıtlar arttıkça tahminlerin de doğrusal olarak arttığını göstermektedir. Modelin performansı, verilerin dağılımına ve seçilen hiper parametrelere bağlı olarak değişebilir.



Şekil 4.11. Çalışmada kullanılan Orta Gauss SVM modelinin tahmin performansı

Şekil 4.12’de, makine öğrenmesi modellerinin tahmin performansını değerlendirmek için kullanılan bir dağılım grafiğidir. Grafikte, dikey eksen "Yanıt (sütun_13)" olarak adlandırılan bağımlı değişken, yatay eksen ise "Kayıt numarası" gösterilmektedir.

Grafikteki noktalar, gerçek değerler (Doğru Tahminler) ile model tahminleri (Tahminler) arasındaki ilişkiyi temsil etmektedir. Noktaların dağılımı, Orta Gauss SVM modelinin tahmin performansını yansıtmaktadır. Daha düzenli ve doğrusal bir dağılım, modelin daha iyi performans sergilediğini gösterir.



Şekil 4.112. Dağılım grafiği model 2.12 (Orta Gauss SVM)

BÖLÜM 5. TARTIŞMA VE SONUÇ

Deniz yüzeyi sıcaklığı başta iklim değişimi, biyoçeşitlilik ve ekosistem farklılaşması olmak üzere birçok önemli olayı yorumlamada önemli bir çevresel parametre olup, aynı zamanda sosyoekonomik etkiler başta olmak üzere zincirleme birçok etkileşimi de beraberinde getirmektedir (Akkan ve ark., 2022). Dahası, deniz yüzeyi sıcaklığı sucul ekosistemlerin sürdürülebilirliği, yerel yönetimlerin stratejik pozisyonları ve küresel değişime adaptasyonda oldukça önemli bir değişken olduğu için araştırmalarda da sıkça kullanılmaktadır.

Karadeniz’de Rize istasyonundan 2010-2020 yılları arasında elde edilen aylık ortalama DYS’ye ait zaman serisinin ileri beslemeli yapay sinir ağları ile tahmininde MAPE 0,90 ile en verimli yöntem olarak belirlenmiştir (Akkan ve ark., 2022). Akdeniz’in doğu kesiminde yer alan Türkiye’nin güney kıyılarına ait DYS verileriyle gerçekleştirilen araştırmada Doğrusal Regresyon, K-En Yakın Komşular, Karar Ağaçları, Destek Vektör Makinesi ve üç sinir ağı tabanlı modelin 37 farklı konfigürasyon sonuçlarında LSTM en başarılı model olarak seçilmiştir (Kartal, 2023). Akdeniz’in 16 bölgesinde gerçekleştirilen diğer bir araştırmada kısa vadeli (7 güne kadar) DYS tahminlemede ML yöntemlerinden özellikle LSTM’nin dinamik modellere göre daha verimli model olduğu RMSE değerine göre çıkarımlanmıştır (Bonino ve ark., 2024). Ordu, Samsun ve Sinop istasyonlarını içeren Türkiye’nin Orta Karadeniz kıyı şeridini içeren çalışmada DYS tahmini modeli, tekrarlayan sinir ağı (RNN) uzun ve kısa vadeli hafıza (LSTM) için ortalama kare hatası (MSE) sırasıyla 0,914, 0,815 ve 0,802 olarak rapor edilmiştir (Aydınlı ve ark., 2022). Atlantik’te, önceki dönemlere ait DYS bilgisine dayalı bir yıl öncesi tahmin prosedürü önerilmiş ve Destek Vektör Makineleri (SVM’ler) ile Ortalama Mutlak Yüzde Hata (MAPE) değerleri %2’yi geçmeyen ve tüm Ortalama Mutlak Hatalar (MAE’ler) 0,37 °C’den düşük, oldukça verimli bulgular elde edilmiştir (Lins ve ark., 2013). Kuzey Amerika

doğu kıyısı boyunca kıta sahanlığında 2015 ile 2021 yılları arasında DYS verilerinin toplandığı araştırmada, toplamda 20 farklı modelin karşılaştırıldığı ve bu modeller arasında Cubist yönteminin en iyi performansı gösterdiği vurgulanmıştır. Cubist modelinin, eğitim setinde R^2 değerinin 0,95 ve RMSE değerinin 14,79 μatm olarak elde edildiği belirtilmiştir (Wang ve ark., 2024).

Bu çalışma verilere göre, orta Gaussian SVM modeli, sağladığı düşük hata oranları ve yüksek R^2 değeri ile en iyi model olarak öne çıkmaktadır. Bu model, tahminleme çalışmanızda en güvenilir ve etkili sonuçları elde etmenizi sağlayacaktır. Diğer modellerle karşılaştırıldığında, orta Gaussian SVM'nin kullanılması, genel anlamda daha iyi tahminler yapmanıza olanak tanıyacaktır. Çalışmada kullanılan SVM türleri arasında performans farklılıkları gözlemlenmiştir. Gelecek çalışmalar, farklı veri setleri ve parametre ayarlamaları ile bu modellerin daha da optimize edilmesini sağlayabilir.

Genel olarak, Gaussian Process Regression modelleri arasında performans farklılıkları gözlemlenmiş olup, Squared Exponential GPR ve Rational Quadratic GPR iyi performansı sergilemektedir. Bu sonuçlar, GPR'nin esnekliği ve kernel fonksiyonlarının seçiminin tahmin doğruluğu üzerindeki etkisini vurgulamaktadır.

Karar ağaçları gibi makine öğrenimi modellerinin seçiminde, modelin karmaşıklığı ile tahmin doğruluğu arasındaki dengeyi sağlamanın kritik önem taşıdığını vurgulanmaktadır. Yapay sinir ağlarının mimarisinin tahmin performansını doğrudan etkilediğini ve daha fazla katman ile uygun boyutların kullanılması gerektiğini göstermektedir. Ancak, karmaşıklığın her zaman performansı artırmayabileceği de vurgulanmalıdır.

RTE yöntemlerinin geliştirilmesi, daha doğru ve güvenilir tahminler elde etmek için önemli bir adım olacaktır.

Doğrusal Regresyon yönteminin uygun ayarlarla tahmin performansını artırabileceğini ve aşırı karmaşık modellerin dikkatli bir şekilde değerlendirilmesi gerektiğini

göstermektedir. Gelecek çalışmalar, farklı hiperparametre ayarları ve model yapılandırmaları ile bu modellerin daha da optimize edilmesine olanak tanıyabilir. Kernel Fonksiyonları kullanılarak yapılan tahminlerin, model seçiminde dikkatli olunması gerektiği görülmektedir. Gelecek çalışmalar, farklı Kernel türleri ve hiperparametre ayarları ile bu modellerin daha da optimize edilmesine olanak tanıyabilir. Bu doğrultuda, Kernel Fonksiyonları yöntemlerinin geliştirilmesi, daha doğru ve güvenilir tahminler elde etmek için önemli bir adım olacaktır.

Özelleştirilmiş makine öğrenimi modellerinin, problem çözümünde dikkatli bir şekilde seçilmesi gerektiğini göstermektedir. Gelecek çalışmalar, farklı hiperparametre ayarları ve model kombinasyonları ile bu modellerin daha da optimize edilmesine olanak tanıyabilir. Özellikle, Gaussian Process Regression gibi daha karmaşık modellerin, daha doğru tahminler elde etmek için önemli bir potansiyele sahip olduğu vurgulanmalıdır. Özetle gelecek çalışmalar için farklı parametre ayarları ve model kombinasyonları ile bu modellerin daha da optimize edilmesine olanak tanıyabilir.

Bu çalışma, orta Gaussian SVM modelinin düşük hata oranları ve yüksek R^2 değerleri ile tahmin performansını artırarak, makine öğrenimi literatüründe model seçiminde esneklik ve optimizasyonun önemini vurgulamaktadır. Ayrıca, Gaussian Process Regression gibi karmaşık modellerin esnekliği ve Kernel Fonksiyonlarının seçiminin tahmin doğruluğu üzerindeki etkilerini ortaya koyarak, bu alandaki mevcut bilgi birikimine katkıda bulunmakta ve gelecekteki araştırmalar için yeni bir çerçeve sunmaktadır. Dolayısıyla, elde edilen bulgular, makine öğrenimi uygulamalarında karar ağaçları ve yapay sinir ağları gibi diğer modellerin seçiminde karmaşıklık ve tahmin doğruluğu arasındaki dengeyi sağlama gerekliliğini destekleyerek, bilimsel araştırmaların yönlendirilmesine katkı sağlamaktadır.

KAYNAKLAR

- Aksay, C. S., Ketenoğlu, O., Kurt, L. 2005. Küresel ısınma ve iklim değişikliği. SÜ, Fen-Ed. Fak, Fen Dergisi, 25: 29-41.
- Aksoy, B., Halis, H., Salman, O. 2020. Elma bitkisindeki hastalıkların yapay zekâ yöntemleri ile tespiti ve yapay zekâ yöntemlerinin performanslarının karşılaştırılması. International Journal of Engineering and Innovative Research, 2(3): 194-210.
- Aksoy, B., Korucu, K., Çalışkan, Ö., Osmanbey, Ş., Halis, H. 2021. İnsansız hava aracı ile görüntü işleme ve yapay zekâ teknikleri kullanılarak yangın tespiti: örnek bir uygulama. Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 9(6): 112-122.
- Alghamdi, A. S., Polat, K., Alghoson, A., Alshdadi, A. A., Abd El-Latif, A. A. 2020. Gaussian process regression (GPR) based non-invasive continuous blood pressure prediction method from cuff oscillometric signals. Applied Acoustics, 164: 107256.
- Alıcılar, H. Çöl, M. 2021. Usage of artificial intelligence in public health. Uludağ Üniversitesi Tıp Fakültesi Dergisi, 47(1): 151-158.
- Alonso, S., Montes, R., Molina, D., Palomares, I., Martínez-Cámara, E., Chiachío, M., Herrera, F. 2021. Ordering artificial intelligence based recommendations to tackle the sdgs with a decision-making model based on surveys. Sustainability, 13(11): 6038.
- Altaş, F., Öztürk, M. 2024. Water level predictions at both entrances of a sea strait by using machine learning. Water, 16(16): 2335.
- Altuğ, M., Deveci, M., İşler, C., Yurtal, Z., Alakuş, İ. 2017. Emergency and critical care in sea turtles. Türkiye Klinikleri Journal of Veterinary Sciences, 8(1): 25-41.
- Aria, M., Gnasso, A., Iorio, C., Pandolfo, G. 2024. Explainable ensemble trees. Computational Statistics, 39(1): 3-19.
- Arıman, S., Koyuncu, S. 2019. Monitoring of sensitive areas for water pollution: kızılırmak delta-balık lake. Mühendislik Bilimleri Ve Tasarım Dergisi, 7(4): 705-714.
- Arvas, M. 2023. Topraksız tarım da çilek olgunluğunun yapay zekâ teknikleri kullanılarak tespiti. International Conference on Scientific and Innovative Studies, 1(1): 350-353.

- Aydın, E., Kemec, S. 2023. Wetlands under the pressure of anthropogenic impacts and climate change: van castle and its surroundings natural protected area example. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 28(3): 1139-1154.
- Aydınbaş, G. 2023. İktisadi perspektiften akıllı tarım (tarım 4.0) üzerine bir inceleme. *Biltürk Journal of Economics and Related Studies*, 5(2): 63-86.
- Aydınlı, H.O., Ekincek, A., Aykanat-Atay, M. 2022. Sea surface temperature prediction model for the Black Sea by employing time-series satellite data: a machine learning approach. *Appl Geomat* 14: 669–678.
- Balta, F. Dengiz, Z. 2020. Gökkuşuğu alabalığı (*Oncorhynchus mykiss*) yavrularında görülen gaz kabarcığı hastalığı ve tedavisi üzerine bir araştırma. *Journal of Anatolian Environmental and Animal Sciences*, 5(1): 100-105.
- Bebek, G. 2023. Farmasötik endüstride farma 4.0 yaklaşımı. *Ankara Üniversitesi Eczacılık Fakültesi Dergisi*, 47(3): 1058-1070.
- Bonino, G., Galimberti, G., Masina, S., McAdam, R., Clementi, E. 2024. Machine learning methods to predict sea surface temperature and marine heatwave occurrence: a case study of the Mediterranean Sea. *Ocean Science*, 20(2): 417-432.
- Cengiz, B., Cengiz, C., ve Dağlı, P. 2017. Üniversite öğrencileri açısından kentsel kültürel peyzajlarda karakter ve algı değişimi: Bartın, Amasra, Safranbolu. *Kastamonu University Journal of Forestry Faculty*, 17(1): 45-56.
- Chiswell, S. 2022. Global trends in marine heatwaves ve cold spells: the impacts of fixed versus changing baselines. *Journal of Geophysical Research Oceans*, 127(10).
- Choi, B. 2023. Changes in hydraulics–water quality–bloom–aquatic habitat using an integrated chain modeling and artificial intelligence technique in the yeongsan river. *Sustainability*, 15(23): 16355.
- Choo, H. 2021. Correlation between water temperature ve catch at a set net in yeosu bay, korea. *Fisheries ve Aquatic Sciences*, 24(1): 41-52.
- Chou, J. S., Ho, C. C., Hoang, H. S. 2018. Determining quality of water in reservoir using machine learning. *Ecological informatics*, 44: 57-75.
- Chui, C. K. 1992. *An Introduction To Wavelets*. Academic Press.
- Cortes, C. 1995. Support-Vector Networks. *Machine Learning*. *Machine Learning*, 20: 273-297.
- Çelik, İ., Arslan, F., Tunç, R., Yıldız, I. 2021. İlaç keşfi ve geliştirilmesinde yapay zekâ. *Ankara Üniversitesi Eczacılık Fakültesi Dergisi*, 45(2): 400-427.
- Çetin, M. 2024. Gelişen bir paradigma: yapay zekâ okuryazarlığı. *International Journal of Active Learning*, 8(1): 50-63.
- Dalkiran, N., Karacaoğlu, D., Dere, Ş., Çınar, Ş., Bulut, C., Savaşer, S. 2016. Species composition and spatio-temporal variations of phytoplankton of lake Uluabat. *Journal of Limnology and Freshwater Fisheries Research*, 2(3): 121-135.

- Danovaro, R., Dell'Anno, A., Pusceddu, A. 2004. Biodiversity response to climate change in a warm deep sea. *Ecology Letters*, 7(9): 821-828.
- Deacon, C., Samways, M., Pryke, J. 2018. Artificial reservoirs complement natural ponds to improve pondscape resilience in conservation corridors in a biodiversity hotspot. *Plos One*, 13(9): e0204148.
- Demir, A. 2009. Küresel iklim değişikliğinin biyolojik çeşitlilik ve ekosistem kaynakları üzerine etkisi. *Ankara Üniversitesi Çevrebilimleri Dergisi*, 1(2): 37-54.
- Demircan, M. 2022. İklim değişikliğinin Türkiye denizlerine ve su ürünleri sektörüne etkileri. *Journal of Environmental and Natural Studies (JENAS)*, 4(1): 96-108.
- Dilek, S., Paruğ, Ş., Paruğ, A., Keskingöz, H. 2019. Kastamonu'da su ürünleri tüketim tercihleri ve balık talebi. *Turkish Journal of Agriculture - Food Science and Technology*, 7(11): 1844-1857.
- Ditria, E., Buelow, C., González-Rivero, M., Connolly, R. 2022. Artificial intelligence and automated monitoring for assisting conservation of marine ecosystems: a perspective. *Frontiers in Marine Science*, 9.
- Dong, B., Cao, C., Lee, S. E. 2005. Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5): 545-553.
- Dong, S., Lei, Y., Bi, H., Xu, K., Li, T., Jian, Z. 2022. Biological response of Planktic foraminifera to decline in seawater pH. *Biology*, 11(1): 98.
- Duran, D., Cebeci, D., Şahin, U., Kalyoncu, H., ve Calapoğlu, M. 2017. Su kirliliğinin gökkuşağı alabalığı (*Oncorhynchus mykiss*)'nın biyojen amin seviyeleri üzerine etkileri. *Future Visions Journal*, 1(1): 1-8.
- Ekrem, E. Daşikan, Z. 2021. Perinatal dönemde yapay zekâ teknolojisinin kullanımı. *Eurasian Journal of Health Technology Assessment*, 5(2): 147-162.
- Elçiçek, M. 2024. Öğrencilerin yapay zekâ okuryazarlığı üzerine bir inceleme. *Bilgi ve İletişim Teknolojileri Dergisi*, 6(1): 24-35.
- Ergün, G. 2023. *Machina sapiens*. *Ankara Üniversitesi Hukuk Fakültesi Dergisi*, 72(2): 717-758.
- Ergüven, Ö. Ökten, S. 2022. Yapay zeka'nın mikrobiyolojide kullanımı. *Journal of Artificial Intelligence in Health Sciences*, 2(2): 1-12.
- Erkutlu, H. 2023. Yapay zekâ ve örgütsel davranış. *Nevşehir Hacı Bektaş Veli Üniversitesi Sbe Dergisi*, 13(3): 1403-1417.
- Fumo, N., Biswas, M. R. 2015. Regression analysis for prediction of residential energy consumption. *Renewable and Sustainable Energy Reviews*, 47: 332-343.
- Gonçalves-de-Freitas, E., Bolognesi, M., Gauy, A., Brandão, M., Giaquinto, P., Fernandes-Castilho, M. 2019. Social behavior and welfare in Nile tilapia. *Fishes*, 4(2): 23.
- Görentaş, M. 2023. Makine öğrenmesi yöntemleri kullanılarak mahkeme kararlarının kümelenmesi. *Computer Science*, 8(2): 148-158.

- Güman, Z. 2024. Nesnelerin interneti yardımıyla akıllı tarımda yapay zekâ tabanlı gübre ve mahsul tahmini. *Journal of the Institute of Science and Technology*, 14(3): 958-973.
- Gündoğdu, E. Buyruk, L. 2021. Tüketicilerin deniz ürünleri tercihleri ile restoran menülerinin karşılaştırılması: bandırma örneği. *Gastroia Journal of Gastronomy and Travel Research*, 5(2): 252-276.
- Hakkoum, K. N., Cherif, L. H. 2024. A novel approach for cardiac pathology detection using phonocardiogram signal multifractal detrended fluctuation analysis and support vector machine classification. *Research on Biomedical Engineering*, 40(2): 1-16.
- Heyns, T., De Villiers, J. P. Heyns, P. S. 2012. Consistent haul road condition monitoring by means of vehicle response normalisation with Gaussian processes. *Engineering Applications of Artificial Intelligence*, 25(8): 1752-1760.
- Himeur, Y., Elnour, M., Fadli, F., Meskin, N., Petri, I., Rezgui, Y., Amira, A. 2023. AI-big data analytics for building automation and management systems: a survey, actual challenges and future perspectives. *Artificial Intelligence Review*, 56(6): 4929-5021.
- Inanan, F. İnanan, B. 2018. Bizans döneminde balıkçılık aktiviteleri ve mozaiklerde görülen balık türleri. *Uludağ Üniversitesi Fen-Edebiyat Fakültesi Sosyal Bilimler Dergisi*, 19(35): 527-554.
- Işın, M. 2024. Marmara bölgesi'nde görülen müsilaaj sırasında meteorolojik değişkenlerin analizi., 4(1): 55-63.
- Jia, X., Ji, Q., Han, L., Liu, Y., Han, G., Lin, X. 2022. Prediction of sea surface temperature in the East China Sea based on LSTM neural network. *Remote Sensing*, 14(14): 3300.
- Jöst, A. B., Yasuhara, M., Wei, C. L., Okahashi, H., Ostmann, A., Martínez Arbizu, P., Brix, S. 2019. North Atlantic Gateway: Test bed of deep-sea macroecological patterns. *Journal of Biogeography*, 46(9): 2056-2066.
- Kadak, A. E., Aras, M. S. 2017. Su Sıcaklığının Diğer Su Özelliklerine Olan Etkileri. *Menba Kastamonu Üniversitesi Su Ürünleri Fakültesi Dergisi*, 3(1-2): 30-35.
- Kartal, S. 2023. Assessment of the spatiotemporal prediction capabilities of machine learning algorithms on Sea Surface Temperature data: A comprehensive study. *Engineering Applications of Artificial Intelligence*, 118: 105675.
- Kayhan, F. E., Kaymak, G., Tartar, Ş., Akbulut, C., 2015. Küresel ısınmanın balıklar ve deniz ekosistemleri üzerine etkileri. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*, 31(3): 128-134.
- Koç, C. 2024. Kentsel büyüme ve iklim değişikliğinin Yalova örneğinde değerlendirilmesi. *Dicle Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 13(1): 11-44.
- Kotsiantis, S. B. 2013. Decision trees: a recent overview. *Artificial Intelligence Review*, 39: 261-283.

- Kurçer, D., Civelek, M. 2023. Yapay zeka ve turizm: akıllı sistemler, Turizmde Değişim ve Arayışlar, 191-208.
- Lázaro-Gredilla, M., Quinonero-Candela, J., Rasmussen, C. E., Figueiras-Vidal, A. R. 2010. Sparse spectrum gaussian process regression. The Journal of Machine Learning Research, 11: 1865-1881.
- Liu, H., Yin, X., Qiu, X., Qin, J., Yang, W., Zhang, J. 2021. Coupled influence of flow velocityve water temperature on grass carp swimming behaviourve gonad development. Hydrological Processes, 35(4).
- Matsumoto, T., Kitagawa, T., Kimura, S. 2013. Vertical behavior of bigeye tuna (*Thunnus obesus*) in the northwestern pacific ocean based on archival tag data. Fisheries Oceanography, 22(3): 234-246.
- Mavruk, S. Avşar, D. 2017. Distribution dynamics of ichthyoplankton and recruitment hypotheses. Ege Journal of Fisheries and Aquatic Sciences, 34(3): 355-361.
- McClanahan, T. Abunge, C. 2014. Catch ratesve income are associated with fisheries management restrictionsve not an environmental disturbance, in a heavily exploited tropical fishery. Marine Ecology Progress Series, 513: 201-210.
- Mendes-Moreira, J., Soares, C., Jorge, A. M., Sousa, J. F. D. 2012. Ensemble approaches for regression: A survey. Acm computing surveys (csur), 45(1): 1-40.
- Mohri, M. 2018. Foundations of machine learning. second edition. The MIT Press ISBN: 9780262039406.
- Morris, D. J., Pinnegar, J. K., Maxwell, D. L., Dye, S. R., Fernand, L. J., Flatman, S., Rogers, S. I. 2018. Over 10 million seawater temperature records for the United Kingdom Continental Shelf between 1880 and 2014 from 17 Cefas (United Kingdom government) marine data systems. Earth System Science Data, 10(1): 27-51.
- Mounce, S. R., Ellis, K., Edwards, J. M., Speight, V. L., Jakomis, N., Boxall, J. B. 2017. Ensemble decision tree models using RUSBoost for estimating risk of iron failure in drinking water distribution systems. Water Resources Management, 31: 1575-1589.
- Nacar, S., Mete, B., Tokgöz, B. S., Bayram, A. 2024. İklim değişikliğinin deniz suyu sıcaklıkları üzerindeki olası etkilerinin değerlendirilmesi: Orta Karadeniz örneği. Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi, 16(1): 279-289.
- Nayim, Y. 2017. Mapping of biotopes between Amasra and Inkum (Bartın), Western Black Sea Region of Turkey. Journal of Environmental Biology, 38(5(SI)): 1033-1042.
- Oğuz, A., Özok, N., Omar, A., Alkan, Z., Kiraççakali, A. 2019. Van balığında (*Alburnus tarichi* Guldenstadt, 1814) üreme göçü sırasında oksidatif stresin araştırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 8(1): 90-97.

- Osman, E., Smith, D., Ziegler, M., Kürten, B., Conrad, C., El-Haddad, K. Suggett, D. 2017. Thermal refugia against coral bleaching throughout the northern red sea. *Global Change Biology*, 24(2).
- Ömeroğlu Tapan, B., Morkoyunlu Yüce, A., Sheikh Abdi, M. H., Öncü, F., 2021. İklim değişikliğinin sucul ekosistem üzerindeki etkilerinin değerlendirilmesi. Şehir, Çevre ve Sağlık Kongresi (108-114). Ankara, Turkey
- Özdemir, D. Açiksöz, S. 2016. Koruma-planlama-yaşam kalitesi çerçevesinde mekânsal yönetim planı geliştirilmesi: Bartın-Amasra örneği. *Bartın Orman Fakültesi Dergisi*, 18(2): 82-82.
- Özdemir, E., Altındağ, A. 2009. Küresel ısınmanın sucul yaşam üzerine etkisi. *Ankara Üniversitesi Çevrebilimleri Dergisi*, 1(1).
- Pachauri, N., Ahn, C. W. 2022. Regression tree ensemble learning-based prediction of the heating and cooling loads of residential buildings. In *Building Simulation 15(11): 2003-2017*. Beijing: Tsinghua University Press.
- Palabıyık, S., Akkan, T. 2024. Evaluation of water quality based on artificial intelligence: performance of multilayer perceptron neural networks and multiple linear regression versus water quality indexes. *Environment, Development and Sustainability*.
- Rabbani, Y., Shirvani, M., Hashemabadi, S. H., Keshavarz, M. 2017. Application of artificial neural networks and support vector regression modeling in prediction of magnetorheological fluid rheometry. *Colloids and Surfaces A: Physicochemical and Engineering Aspects*, 520: 268-278.
- Rasmusen, C. E. Williams, C. 2006. Gaussian processes for machine learning. MIT Press, Cambridge, MA, 32, 68.
- Rokach, L., Maimon, O. 2005. Decision trees. *Data mining and knowledge discovery handbook*, 165-192.
- Sahin, C. 2020. Sakarya nehri deltası'nda uzun süreli rüzgar ve dalga iklimi değişimleri. *Deu Mühendislik Fakültesi Fen ve Mühendislik*, 22(65): 353-368.
- Salles, R., Mattos, P., Iorgulescu, A. M. D., Bezerra, E., Lima, L., Ogasawara, E. 2016. Evaluating temporal aggregation for predicting the sea surface temperature of the Atlantic Ocean. *Ecological Informatics*, 36: 94-105.
- Samancı, M. 2024. Sağlık Hizmetlerinde Dijitalleşme. *Journal of Health and Management (Sağlık ve Yönetim Dergisi)*, 4(1): 67-86.
- Saracoglu, F. 2020. Gökçeada sıcaklık ve deniz suyu sıcaklıklarının eğilim analizi. *Haliç Üniversitesi Fen Bilimleri Dergisi*, 3(1): 1-17.
- Saravanan, N., Siddabattuni, V. K., Ramachandran, K. I. 2010. Fault diagnosis of spur bevel gear box using artificial neural network (ANN), and proximal support vector machine (PSVM). *Applied Soft Computing*, 10(1): 344-360.
- Schwier, A. N., Sellegri, K., Mas, S., Charrière, B., Pey, J., Rose, C., d'Anna, B. 2017. Primary marine aerosol physical flux and chemical composition during a nutrient enrichment experiment in mesocosms in the Mediterranean Sea. *Atmospheric Chemistry and Physics*, 17(23): 14645-14660.

- Segschneider, J., Bendtsen, J. 2013. Temperature-dependent remineralization in a warming ocean increases surface pCO₂ through changes in marine ecosystem composition. *Global Biogeochemical Cycles*, 27(4): 1214-1225.
- Sharifzadeh, M., Sikinioti-Lock, A., Shah, N. 2019. Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression. *Renewable and Sustainable Energy Reviews*, 108: 513-538.
- Suluk, S. 2022. Ekonominin renkleri: sürdürülebilir mavi ekonomi bağlamında Türkiye'nin değerlendirilmesi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, (74): 132-150.
- Şahin, C. Ceylan, Y. 2023. Determination of age, growth parameters and first sexual maturity length of horse mackerel (*Trachurus mediterraneus*) steindachner, 1868 in the eastern black sea region.. *Journal of Anatolian Environmental and Animal Sciences*, 8(1): 69-79.
- Tahraoui, H., Amrane, A., Belhadj, A. E., Zhang, J. 2022. Modeling the organic matter of water using the decision tree coupled with bootstrap aggregated and least-squares boosting. *Environmental Technology & Innovation*, 27: 102419.
- Tamay, M., Türker, G. F. 2024. Machine Learning Based Energy Forecasting for Photovoltaic Solar Plants. *Yekarum*, 9(2): 128-146.
- Taucher, J., Oschlies, A. 2011. Can we predict the direction of marine primary production change under global warming?. *Geophysical Research Letters*, 38(2).
- Tiftik, C. 2021. Artificial intelligence technologies and practices in human resources management. *Ibad Sosyal Bilimler Dergisi*, (9): 374-390.
- Ulupınar, S. 2023. Mobil uygulamalar aracılığıyla koşma egzersizleri için performans ölçümü. *Dijital Çağda Spor Araştırmaları* 2: 15.
- Uygun, T. 2024. Derin öğrenme ve nesne algılama yöntemleri kullanılarak bazı bağ zararlılarının oluşturduğu hasarın yolov8x modeli ile tespiti. *Turkish Journal of Agriculture - Food Science and Technology*, 12(3): 386-396.
- Vapnik, V. 1998. Statistical learning theory. John Wiley & Sons google schola, (2): 831-842.
- Vapnik, V. N. 1963. Pattern recognition using generalized portrait method. *Automation and Remote Control*, 24(6): 774-780.
- Venegas, R. M., Acevedo, J., Treml, E. A. 2023. Three decades of ocean warming impacts on marine ecosystems: A review and perspective. *Deep Sea Research Part II: Topical Studies in Oceanography*, 212: 105318.
- Wählström, I., Hammar, L., Hume, D., Pålsson, J., Almroth-Rosell, E., Dieterich, C., Jonsson, P. R. 2022. Projected climate change impact on a coastal sea—As significant as all current pressures combined. *Global Change Biology*, 28(17): 5310-5319.
- Wang, Y., Wu, Z., Lu, W., Yu, S., Li, S., Meng, L., Yan, X. H. 2024. Remote sensing estimations of the seawater partial pressure of CO₂ using sea surface roughness

- derived from Synthetic Aperture Radar. *IEEE Transactions on Geoscience and Remote Sensing*.
- Wu, J., Chen, X. Y., Zhang, H., Xiong, L. D., Lei, H., Deng, S. H. 2019. Hyperparameter optimization for machine learning models based on Bayesian optimization. *Journal of Electronic Science and Technology*, 17(1): 26-40.
- Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., Steinberg, D. 2008. Top 10 algorithms in data mining. *Knowledge and Information Systems*, (14): 1-37.
- Xu, T., Zhou, Z., Li, Y., Wang, C., Liu, Y., Rong, T. 2023. Short-term prediction of global sea surface temperature using deep learning networks. *Journal of Marine Science and Engineering*, 11(7): 1352.
- Yasuhara, M. Danovaro, R. 2014. Temperature impacts on deep-sea biodiversity. *Biological Reviews*, 91(2): 275-287.
- Yılmaz, E. 2021. Yüksek çözünürlüklü ccsm4 model verilerine göre son buzul maksimumunda (sbm) türkiye'nin holdridge ekolojik bölgeleri ve günümüz iklim şartlarıyla karşılaştırılması. *Coğrafi Bilimler Dergisi*, 19(2): 331-367.
- Yılmaz, Y., Yılmaz, D., Yıldırım, D., Korhan, E., Kaya, D. 2021. Yapay zeka ve sağlıkta yapay zekanın kullanımına yönelik sağlık bilimleri fakültesi öğrencilerinin görüşleri. *Süleyman Demirel Üniversitesi Sağlık Bilimleri Dergisi*, 12(3): 297-308.
- Zahiri, A., Dehghani, A. A., Azamathulla, H. M. 2015. Application of gene-expression programming in hydraulic engineering. *Handbook of Genetic Programming Applications*, 71-97.
- Zhai, A., Fan, G., Ding, X., & Huang, G. 2022. Regression tree ensemble rainfall–runoff forecasting model and its application to Xiangxi River, China. *Water*, 14(3): 463.
- Zhao, H. X., Magoulès, F. 2012. A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6): 3586-3592.
- Zheng, Z., Sun, H., Wang, J., Zhou, Z. 2019. Expression analysis of genes involved in tlr signalling pathway under temperature stress in sea cucumber *apostichopus japonicus*. *Aquaculture Research*, 50(9): 2724-2728.
- Zhou, Y., Liu, Y., Wang, D., De, G., Li, Y., Liu, X., Wang, Y. 2021. A novel combined multi-task learning and Gaussian process regression model for the prediction of multi-timescale and multi-component of solar radiation. *Journal of Cleaner Production*, 284: 124710.

ÖZGEÇMİŞ

Burçak ŞEN ÇİDEM ilköğretimini Ankara İstiklal İlköğretim Okulunda tamamladı. 2004 ile 2008 yılları arasında Ankara Batıkent Yabancı Dil Ağırlıklı Lisesini okudu ve mezun oldu. 2008 yılında başladığı Adnan Menderes Üniversitesi Biyoloji Bölümünü 2012 yılında bitirdi. 2022 yılında Giresun Üniversitesi Biyoloji Anabilim Dalında Başladığı yüksek lisans öğretimine halen devam etmektedir