

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ORMAN MÜHENDİSLİĞİ ANA BİLİM DALI



MAKİNE ÖĞRENMESİ İLE ORMAN YANGINI RİSKİNİN
TAHMİN EDİLMESİ: TAŞKÖPRÜ ORMAN İŞLETME
MÜDÜRLÜĞÜ ÖRNEĞİ

ATIF BIYIKLI

YÜKSEK LİSANS TEZİ

PROF. DR. ÖMER KÜÇÜK

NİSAN - 2024

KASTAMONU

TEZ ONAYI

Atıf BIYIKLI tarafından hazırlanan “**MAKİNE ÖĞRENMESİ İLE ORMAN YANGINI RİSKİNİN TAHMİN EDİLMESİ: TAŞKÖPRÜ ORMAN İŞLETME MÜDÜRLÜĞÜ ÖRNEĞİ**“ adlı tez çalışmasının savunma sınavı **22.04.2024** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Orman Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman	Prof. Dr. Ömer KÜÇÜK Kastamonu Üniversitesi	
Jüri Üyesi	Doç. Dr. Kemal AKYOL Kastamonu Üniversitesi	
Jüri Üyesi	Prof. Dr. Bülent SAĞLAM Artvin Çoruh Üniversitesi	

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü	Doç. Dr. Selçuk MEMİŞ	
----------------	-----------------------	-------

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Atıf BIYIKLI

ÖZET

YÜKSEK LİSANS TEZİ

MAKİNE ÖĞRENMESİ İLE ORMAN YANGINI RİSKİNİN TAHMİN EDİLMESİ: TAŞKÖPRÜ ORMAN İŞLETME MÜDÜRLÜĞÜ ÖRNEĞİ

ATIF BIYIKLI

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ORMAN MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: PROF. DR. ÖMER KÜÇÜK

Kastamonu Orman Bölge Müdürlüğü'nün Taşköprü Orman İşletme Müdürlüğü'nde gerçekleştirilen bu çalışmada makine öğrenmesi ile orman yangın riskinin tahmin edilmesi amaçlanmıştır. Yangın riskinin tahmin edilmesinde 2017-2022 yılları arasında Taşköprü Orman İşletme Müdürlüğü'nde meydana gelen yangınlara ait veriler ile hiç yangın çıkmamış alanlara ait veri seti kullanılmıştır. Makine öğrenmesi ile orman yangının riskinin tahmin edilmesi için 4 ana kriter (meşcere özellikleri, topoğrafya, çevresel faktörler ve meteorolojik veriler) ve 12 alt kriter (ağaç türleri, gelişim çağı, kapalılık, eğim, bakı, yükseklik, yerleşim yerine uzaklık, tarım alanlarına uzaklık, yola uzaklık, su kaynaklarına uzaklık, sıcaklık ve rüzgâr hızı) belirlenmiştir. Yangın riskinin belirlenmesi için makine öğrenmesi olarak Çok Katmanlı Algılayıcı, Rastgele Orman ve Destek Vektör Makineleri kullanılmıştır. Makine öğrenmesi ile yapılan deneysel çalışmalar en az %94'lik doğruluk oranına ulaşılmıştır. Bu sonuç, makine öğrenmesi yöntemleri ile orman yangın riskinin tahmininde etkili olabileceğini göstermektedir. Bu çalışmanın sonuçları orman yangını riskinin tahmin ederek olası orman yangınlarının çıkabilecek alanlarda yangın çıkmadan önce önlemlerin alınmasına ve erken müdahale yapılmasına katkıda bulunacaktır.

ANAHTAR KELİMELEER:Orman Yangını, Yangın Riski, Makine Öğrenmesi

Nisan 2024, 100 Sayfa

ABSTRACT

MSC THESIS

ESTIMATE FOREST FIRE RISK USING MACHINE LEARNING: AN EXAMPLE OF TAŞKÖPRÜ FORESTRY DIRECTORATE

ATIF BIYIKLI

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF FOREST ENGINEERING
SUPERVISOR: PROF. DR. ÖMER KÜÇÜK**

This study was conducted at the Taşköprü Forest Management Directorate of the Kastamonu Regional Directorate of Forestry. The aim was to predict forest fire risk using machine learning. Data on fires that occurred between 2017 and 2022 in the Taşköprü Forest Management Directorate were used along with data on areas where no fires had occurred. Four main criteria (stand characteristics, topography, environmental factors, and weather conditions) and 12 sub-criteria (tree species, age class, canopy closure, slope, aspect, elevation, distance to settlements, distance to agricultural areas, distance to roads, distance to water sources, temperature, and wind speed) were identified for predicting fire risk using machine learning. Multilayer Perceptron, Random Forest, and Support Vector Machine models were used to predict fire risk through machine learning. Experimental studies using machine learning achieved an accuracy rate of at least 94%. This finding suggests that machine learning methods could effectively predict forest fire risk. In conclusion, this study highlights the importance of using Machine Learning models to predict forest fire risk. The significance of this study lies in its contribution to preventing potential forest fires by predicting fire risks and enabling early intervention measures before fires occur.

KEYWORDS: Forest Fire, Fire Risk, Machine Learning

April 2024, 100 Page

TEŞEKKÜR

Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Orman Mühendisliği Ana Bilim Dalı Lisansüstü programında gerçekleştirdiğim “Makine Öğrenmesi ile Orman Yangını Riskinin Tahmin Edilmesi: Taşköprü Orman İşletme Müdürlüğü Örneği” çalışması sürecinde, yanımda olan herkese içten teşekkürlerimi sunmak isterim.

Öncelikle, tez danışmanım Sayın Prof. Dr. Ömer KÜÇÜK’e; desteği, bilgeliği ve yol göstericiliği için minnettarlığımı ve teşekkürlerimi sunarım. Ayrıca, tezin makine öğrenmesi ve yazılım aşamasında bana yardımcı olan Doç. Dr. Kemal AKYOL’a ve görüş önerilinden faydalandığım Prof. Dr. Bülent SAĞLAM’a teşekkürlerimi iletmek isterim.

En büyük destekçilerim olan aileme, sevgili eşim Seda BIYIKLI’ya ve oğlum Alparslan’a en derin duygularıyla sevgilerimi sunarım. Hayatımın her anında olduğu gibi, bu tez çalışmasının da her aşamasında benim yanımda oldular. Son olarak, yakında dünyaya gelecek evladına şimdiden sevgilerimi göndermek isterim. Onun da hayatımıza kattığı mutluluk için şimdiden minnettarım.

Hepinize teşekkür ederim.

ATIF BIYIKLI

Kastamonu, 2024

İÇİNDEKİLER

Sayfa

TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ.....	1
1.1 Yangın Riskini Etkileyen Temel Kriterler	5
1.1.1 Meşcere Özellikleri.....	6
1.1.2 Topoğrafik Faktörler.....	6
1.1.3 Çevresel Faktörler.....	7
1.1.4 Meteorolojik Parametreler	7
2. KURAMSAL ÇERCEVE	9
3. MATERYAL VE METOT	15
3.1 Çalışma Alanı.....	15
3.2 Kullanılan Veri Setleri	18
3.3 Metot	20
3.3.1 Kriterlerin Seçimi	20
3.3.2 Makine Öğrenmesi.....	21
3.3.3 Sınıflandırma Algoritmaları.....	25
3.3.3.1 Destek vektör makineleri (DVM)	25
3.3.3.2 Rastgele orman (RO).....	26
3.3.3.3 Çok katmanlı algılayıcı (ÇKA)	28
3.3.4 Performans Değerlendirme	30
3.3.5 Öznitelik Seçimi	32
3.3.5.1 Özyinelemeli özellik eleme (ÖÖE).....	33
3.3.6 DeneySEL Çalışma Ortamı	33
3.3.7 DeneySEL Çalışmalar ve Önerilen Yaklaşım	33
3.3.8 Veri Seti	34
3.3.9 Model Eğitimi ve Testi	34
4. BULGULAR	36
4.1 Çalışma Senaryosu-1	36
4.1.1 Birinci DeneySEL Çalışma	36
4.1.2 İkinci DeneySEL Çalışma	38
4.1.3 Çalışma Senaryosu-1 İçin Elde Edilen Sonuçlar	41
4.2 Çalışma Senaryosu-2	41
4.2.1 Birinci DeneySEL Çalışma	41
4.2.2 İkinci DeneySEL Çalışma	43
4.2.3 Çalışma Senaryosu-2 İçin Elde Edilen Sonuçlar	46
4.3 Geliştirilen Uygulama	46
5. TARTIŞMA, SONUÇ VE ÖNERİLER.....	54

5.1 Tartışma	54
5.2 Sonuç ve Öneriler	56
KAYNAKLAR	58
EKLER.....	72
EK 1. Taşköprü Orman İşletme Müdürlüğü'nde 2017-2022 Yılları Arasında Çıkan Orman Yangınları	73
EK 2. Taşköprü Orman İşletme Müdürlüğü Orman Yangını Çıkmamış Alanlar.....	82
EK 3. Çalışma Senaryosu-1.....	94
EK 4. Çalışma Senaryosu-2.....	97
ÖZGEÇMİŞ.....	100



ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1 Taşköprü ilçesi lokasyon haritası.....	15
Şekil 3.2 Taşköprü yıllık yağış ve rüzgâr grafiği.....	16
Şekil 3.3 Taşköprü yıllık yağış ve sıcaklık grafiği.....	16
Şekil 3.4 Taşköprü orman işletme müdürlüğü haritası	18
Şekil 3.5 Destek vektör makinesi.....	26
Şekil 3.6 Rastgele orman.....	27
Şekil 3.7 Rastgele orman modellerinde karar verme	28
Şekil 3.8 ÇKA yapısının gösterimi	29
Şekil 3.9 Karışıklık matrisi	31
Şekil 3.10 Alıcı işlem karakteristiği eğrisi.....	32
Şekil 3.11 Birinci-ikinci deneysel çalışmadaki eğitim ve test kümelerindeki örnek sayısı.....	35
Şekil 4.1 Senaryo 1 deneysel çalışma 1 için ÇKA'nın karışıklık matrisi	37
Şekil 4.2 Senaryo 1 deneysel çalışma 1 için RO'nun karışıklık matrisi	37
Şekil 4.3 Senaryo 1 deneysel çalışma 1 için DVM'nin karışıklık matrisi	37
Şekil 4.4 Modellerin AİK eğrileri.....	38
Şekil 4.5 Senaryo 1 deneysel çalışma 2 için ÇKA'nın karışıklık matrisi	39
Şekil 4.6 Senaryo 1 deneysel çalışma 2 için RO'nun karışıklık matrisi	39
Şekil 4.7 Senaryo 1 deneysel çalışma 2 için DVM'nin karışıklık matrisi	40
Şekil 4.8 Modellerin AİK eğrileri.....	40
Şekil 4.9 Senaryo 2 deneysel çalışma 1 için ÇKA'nın karışıklık matrisi	42
Şekil 4.10 Senaryo 2 deneysel çalışma 1 için RO'nun karışıklık matrisi	42
Şekil 4.11 Senaryo 2 deneysel çalışma 1 için DVM'nin karışıklık matrisi	42
Şekil 4.12 Modellerin AİK eğrileri.....	43
Şekil 4.13 Senaryo 2 deneysel çalışma 2 için ÇKA'nın karışıklık matrisi	44
Şekil 4.14 Senaryo 2 deneysel çalışma 2 için RO'nun karışıklık matrisi	44
Şekil 4.15 Senaryo 2 deneysel çalışma 2 için DVM'nin karışıklık matrisi	45
Şekil 4.16 Modellerin AİK eğrileri.....	45
Şekil 4.17 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama testi	47
Şekil 4.18 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama test sonucu	48
Şekil 4.19 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama testi	48
Şekil 4.20 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama test sonucu	49
Şekil 4.21 Çalışma senaryosu-2 ve birinci deneysel çalışmada uygulama testi	49
Şekil 4.22 Çalışma senaryosu-2 ve birinci deneysel çalışmada uygulama test sonucu	50
Şekil 4.23 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama testi.....	50
Şekil 4.24 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama test sonucu	51
Şekil 4.25 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama testi.....	51
Şekil 4.26 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama test sonucu	52
Şekil 4.27 Çalışma senaryosu-2 ve ikinci deneysel çalışmada uygulama testi.....	52

Şekil 4.28 Çalışma senaryosu-2 ve ikinci deneysel çalışmada uygulama test sonucu	53
--	----



TABLÖLAR DİZİNİ

Sayfa

Tablo 3.1 Taşköprü orman işletme müdürlüğü orman varlığı	17
Tablo 3.2 Taşköprü orman işletme müdürlüğü orman varlığı	20
Tablo 3.3 Yangın risk kriterleri- topografya	20
Tablo 3.4 Yangın risk kriterleri- çevresel kriterler	21
Tablo 3.5 Yangın risk kriterleri- meteorolojik parametreler.....	21
Tablo 3.6 Birinci-ikinci deneysel çalışmadaki eğitim ve test kümelerindeki örnek sayısı.....	34
Tablo 4.1 Senaryo 1 deneysel çalışma 1 için performansların karşılaştırılması	38
Tablo 4.2 Senaryo 1 deneysel çalışma 2 için performansların karşılaştırılması	40
Tablo 4.3 Senaryo 2 deneysel çalışma 1 için performansların karşılaştırılması	43
Tablo 4.4 Senaryo 2 deneysel çalışma 2 için performansların karşılaştırılması	45
Tablo 4.5 Yangın çıkmış alandan örnek	47

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

°C	: Derece Santigrat
cm	: Santimetre
ha	: Hektar
km	: Kilometre
km/sa	: Kilometre/saat
km ²	: Kilometrekare
m	: Metre
m/s	: Metre/saniye
mm	: Milimetre

Kısaltmalar

AHP	: Analitik Hiyerarşi Süreci
AİK	: Alıcı İşletim Karakteristiği
BA	: Bayesian Ağ
CBS	: Coğrafya Bilgi Sistemleri
ÇKA	: Çok Katmanlı Algılayıcı
DN	: Doğru Negatif
DP	: Doğru Pozitif
DVM	: Destek Vektör Makinesi
EAKA	: Eğri Altında Kalan Alan
EFFIS	: Avrupa Orman Yangını Bilgi Sistemi
GAM	: Genelleştirilmiş Additif Model
LR	: Lojistik Regresyon
ML	: Makine Öğrenmesi
OGM	: Orman Genel Müdürlüğü
ORBİS	: Orman Bilgi Sistemi
OYAT	: Orman Yangını Analiz Tahmin
ÖÖE	: Özyinelemeli Özellik Eleme
RO	: Rastgele Orman Algoritması
SHAP	: Shapley Additif Açıklamalar
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zekâ

1. GİRİŞ

Ormanlar, dünyadaki en önemli doğal kaynaklardan biri olup ekolojik dengenin korunmasında anahtar rol oynarlar. Orman ekosistemleri aynı zamanda, toplum hayatı için doğrudan ve dolaylı olarak birçok ekolojik ve ekonomik hizmet sunarlar. Dünya üzerindeki yaşamın sürdürülebilirliği için vazgeçilmez bir unsur olan ormanlar; biyoçeşitliliğin korunması ve sürdürülmesinde, sağlık, gıda, tarım ve endüstri gibi alanlarda kullanılan birçok doğal kaynağın deposu olarak kullanılmasında, su döngüsü ve iklimin düzenlenmesinde, erozyonunun önlenmesinde, rekreasyon ve doğal yaşam alanları oluşturmada ve iklim değişikliği ile mücadelede önemli bir rol üstlenir.

Hayati fonksiyonlara sahip olan ormanlar, biyotik ve abiyotik faktörlerin tehdidi altında olmaktadır. Orman yangınları, orman ekosistemlerinin sağladığı hizmetleri kesintiye uğratan bu faktörlerden birisidir. Orman yangınları, genel itibar ile gerçekleştikleri alanlardaki vejetasyonu yakarak tahrip etmekte ve karbon çevrimini sekteye uğratabilmektedir (Goltas vd., 2017; Heinselman, 1973; Wright ve Bailey, 1982). Özellikle olağandışı meteorolojik şartlar altında gerçekleşen orman yangınlarının tahrip gücü çok daha fazla olmaktadır. Bu şartlar altında çıkan yangınların söndürülmeleri hem zor olmakta hem de çok uzun süre alabilmektedir. Bu sebeple çıkabilecek potansiyel yangınların önceden tahmin edilebilmesi, yangınların başarılı bir şekilde yönetimi, yangınla mücadelede kaynakların etkili bir şekilde planlanması ve yangınların sebep olacakları hasarın azaltılması için son derece önemli bir yere sahiptir (Abid, 2021; Mitsopoulos vd., 2017; Sevinc vd., 2020; Yavuz vd., 2018).

Orman yangınlarının çıkış sebepleri incelendiğinde genellikle yıldırım kaynaklı veya insan kaynaklı olduğu görülmektedir. İnsan kaynaklı yangınları belirli bir modelleme mantığı ile tahmin etmek oldukça zordur. Zira, insan kaynaklı yangınların modellenmesinde için davranışsal faktörlerin tanımlanması, nitelendirilmesi ve haritalandırılması gerekir (Vilar vd., 2010). Sosyo-ekonomik değişiklikler, kazalar, kırsal bölgelerdeki geleneksel faaliyetler ve toplumda huzursuzluğa yol açabilecek faktörler, bu bağlamda orman yangınlarını etkileyen önemli faktörlerdir (Leone vd.,

2003). Bununla birlikte bir yangının başlaması ve yayılması, tutuşturucu etkenlerin (yani doğal ve insan kaynaklı), bitki örtüsünün, hava hallerinin ve insan etkilerinin ortak kombinasyonundan kaynaklanır (Carmo vd., 2011; Oliveira vd., 2012; Pourtaghi vd., 2016).

Yangın araştırmacıları ekosistemleri çok yönlü olarak etkileyen orman yangınlarını daha iyi anlayıp analiz edebilmek için çalışmalarını giderek yoğunlaştırmışlardır. Bu çalışmaların bir kısmı yangın çıkmadan önceki evreyi kapsadığı gibi yangın anına yönelik çalışmalar da yapılmıştır. Gerek yangın öncesi gerekse yangın anına ait çalışmalarda yangın oluşumu, gelişimi, davranışı ve ekosistemler üzerindeki etkilerini daha iyi anlamak için zaman içerisinde temel modelleme çalışmalarından ileri teknolojilerin kullanıldığı çalışmalara kadar geniş yelpazede araştırmalar yapılmıştır. Son yıllarda yapay zekâ tekniklerinin orman yangınları ile ilgili çalışmalarda daha yaygın kullanıldığı görülmektedir. Vilar vd. (2010), Madrid bölgesinde olası yangın sayısını tahmin etmek için Lojistik Genelleştirilmiş Additif Model (GAM) geliştirmişlerdir. Castedo-Dorado vd. (2011), İspanya'nın León bölgesinde yıldırım kaynaklı orman yangınlarının, topografya, bitki örtüsü, iklim ve yıldırım özellikleri arasındaki mekânsal ilişkileri analiz ederek yıldırım kaynaklı yangınların çıkma ihtimalini tahmin etmek için lojistik regresyon modeli geliştirmişlerdir. Wang ve Anderson (2011), Kanada'da yıldırım ve insan kaynaklı orman yangınlarının başlangıç konumlarının mekânsal ve zamansal desenlerini değerlendirmiştir. Chen vd. (2015), Çin'deki yaptıkları çalışmada yıldırım kaynaklı yangın çıkma ihtimalini tahmin etmek için Maksimum Entropi Modelleri (Maxent) kullanmışlardır. Literatürde, regresyon analizi ve lojistik modellerin sıkça kullanıldığı görülse de yangın olasılığını tahmin etmek için Bayesian ağları kullanan sınırlı sayıda çalışma bulunmaktadır. Dlamini (2011), Coğrafi Bilgi Sistemleri (CBS) ve uzaktan algılama verilerine dayalı bir Bayesian ağı (BA) oluşturarak bir yangın risk haritası hazırlamıştır. Başka bir çalışmada, Penman vd. (2012), yangın risk azaltma değerini değerlendirmede BA'ların rolünü incelemişlerdir. Zwirgmaier vd. (2013), Kıbrıs Adası'nda orman yangını yayılmasını tahmin etmek için bir BA modeli oluşturmuşlardır.

Ormancılık çalışmalarında, son yıllarda dijital ve istatistiksel bilgi ile CBS dahil uzaktan algılama teknolojisindeki ilerlemeler sebebiyle yangın riskinin tahmin

edilmesine yönelik çalışmalar daha popüler hale gelmiştir (Chuvieco ve Salas, 1996; San-Miguel-Ayanz vd., 2003). Lojistik regresyon, sinir ağları ve belirsiz mantık regresyonu gibi olasılıksal yöntemler, genellikle yangın risk değerlendirmesi için kullanılmaktadır (Alonso-Betanzos vd., 2002; Hernandez-Leal vd., 2006; Iliadis, 2005; Martínez vd., 2009; Preisler vd., 2004; Vasilakos vd., 2007). Ganteaume ve Jappiot (2013), Güney Fransa’da büyük yangınların bazı nedenlerini incelemek için non-parametrik testler ve regresyon analizi kullanmışlardır. Ancak, bu geleneksel yaklaşımlar genellikle çeşitli kaynaklardan gelen veri ve kanıtları birleştirme yeteneğinden yoksundur. Ayrıca belirsizliği ve eksik verileri dikkate almazlar. Bu nedenle, belirsizliği dikkate alan ve faktörlerin çeşitli uzun vadeli etkilerini birbirine bağlayabilen yeni yaklaşımlara ihtiyaç vardır. Ayrıca, bu tür yöntemler çoklu sistem operasyonlarına entegre edilebilme yeteneğine sahip olmalıdır. Bayesian ağları (BA), bu ihtiyacı karşılama konusunda oldukça faydalı olmuştur (Dlamini, 2011). BA’lar, belirsiz, doğrusal olmayan ve karmaşık alanları modelleme konusunda sağlam ve matematiksel olarak uyumlu bir çerçeve sağladıkları için çevre bilimlerinde giderek popüler hale gelmiştir (McCann vd., 2006; Pollino vd., 2007; Uusitalo, 2007). BA’lar, karmaşık sorunları analiz etmek ve adaptif bir yönetim çerçevesi içinde gelecekteki karar vermeyi desteklemek için bir modelleme çerçevesi sağlar. BA’lar, belirsiz bilgi içeren karmaşık problemleri modelleme konusunda kullanışlı teknikler olarak önem kazanmış olmalarına rağmen, doğal tehlike risk değerlendirmesi alanında bildirilmiş birkaç uygulama bulunmaktadır (Gret-Regamey ve Straub, 2006).

Yangın çıkma ihtimalinin tahmin edilmesine yönelik modelleme çalışmalarının yanı sıra çıkan bir orman yangını davranışını tahmin etmek için klasik regresyon modelleri geliştirildiği çalışmalar da yapılmıştır (Alexander ve Cruz, 2006; Alhaj-Khalaf vd., 2021; Bilgili vd., 2019; Cruz vd., 2017; Cruz vd., 2022; Fernandes, 2009; Fryer ve Johnson, 1988; Kucuk vd., 2012; Kucuk vd., 2018; Matthews vd., 2012; Sullivan, 2007; Yassemi vd., 2008). Yapay sinir ağları makine öğrenmesi yöntemine dayanan diğer orman yangını modelleri (Pham vd., 2020), alev özelliklerini ve yangın yayılmasını tahmin etmiştir (Chetehouna vd., 2015).

Yangın yerinin tespit edilmesi ve haritalanması, yangın meteorolojisi ve iklim değişikliği (Li vd., 2009; San-Miguel-Ayanz vd., 2012), yangın çıkma ihtimali ve

potansiyeli, yangın tehlikesi ve yangın davranışının tahmin edilmesi, özellikle son yıllarda artan iklim krizinin etkisi ve bunun yanında veri madenciliği, yapay zeka tekniklerindeki ilerlemeler ve uzaktan algılama teknolojilerindeki gelişmelerle birlikte üzerinde yoğun çalışılan konular olmuştur (Arıcak vd., 2014; Finney vd., 2011; Goldarag vd., 2016; Huiling vd., 2016; Lary vd., 2016; Preisler vd., 2014; Rodrigues ve Riva, 2014; Sivrikaya ve Küçük, 2022; Vakalis vd., 2004; Zhang vd., 2018).

Son yıllarda, yapay zekâ yöntemlerinin doğal afetleri tahmin etmede çok etkili olduğu kanıtlanmıştır (Hart vd., 2019; Tan vd., 2021). Ancak, orman yangınlarının davranışını tahmin etmekte zorluklar yaşanmaktadır. Bunun en temel sebeplerinden bazıları yangının çok karmaşık, paradoks olması birçok çevresel faktörden etkilenmesidir. Tahmin zorluklarını aşmanın en etkili yöntemlerinden biri, yapay zekâ tekniklerinin kullanımıdır. Matematiksel bir yazılım simülasyonu olan yapay sinir ağları, veriyi genişletmek ve yeni, bilinmeyen veri sağlamak için kullanılır. Pratikte, yapay sinir ağı, geleneksel yöntemlere bir alternatif olarak kullanılır ve zorlu sorunlar için tatmin edici çözümler üretmede oldukça yardımcı olur. Yapay zekâ, veri açısından zengin ancak modelleme açısından zayıf olan ve geleneksel yöntemlerin çözemediği problemleri çözmede özellikle faydalıdır (Kotsiantis vd., 2006; Kinaneva vd., 2019; Liang vd., 2019; Razavi-Termeh vd., 2020; Wu vd., 2022). Bu, yapay zekânın orman yangınlarını tahmin etmede avantajlı olmasını sağlar. Genellikle orman yangınları ve deneysel yangınlara dayanan veriler, doğru tahminler için yeterli olmayabilir ve her durumu kapsayamaz. Yapay zekâ, sadece yangın davranışı tahminlerinde veri kaybını önlemekle kalmaz, aynı zamanda tahminlerin yapılmasında birçok veri problemine çözüm sağlar (Hodges ve Lattimer, 2019; Kozik vd., 2013; Zheng vd., 2017). Özellikle yangın riskinin önceden tahmin edilmesi için gerekli olan birçok veriyi ilişkilendirebilen ve en etkili faktörleri tahmin edebilen yapay zekâ tekniklerinin kullanılmasına yönelik çalışmaların oldukça sınırlı veya yetersiz olduğunu söylemek mümkündür. Orman yangınları gibi orman ekosistemlerini ciddi boyutlarda etkileyen bir faktörün yeni tekniklerle modellenmesi ve karar vericiye yüksek bir doğruluk oranında tahmin gücü sağlamasına duyulan ihtiyaç iklim krizinin etkisini derinden hissettiğimiz günümüzde daha da artmaktadır. Dünyanın birçok ülkesinde olduğu gibi ülkemizde de son birkaç yılda afet boyutunda büyük orman yangınları meydana gelmiş, iklim krizinin bu şekilde devam ettiğini öngören modellere göre gelecekte de

büyük orman yangınlarının olması ihtimal dâhilindedir. Bu öngörüler ve ihtimaller yangın çıkmadan önce yangın riskinin doğru, hızlı ve dinamik bir şekilde tahmin edilmesini çok önemli bir hale getirmektedir. Zira yangının oluşturabileceği zararı önceden öngörmek ve yangın çıkmadan önce riskli bölgelerde gerekli tedbirleri almak oluşacak zararın boyutunu azaltmaya yardımcı olacaktır. Bu çalışmada, yapay zekâ alanındaki bir alt dal olan makine öğrenmesi yöntemini kullanarak, meşcere özellikleri, topografya, çevre ve meteorolojik parametreler kullanılarak orman yangını riski tahmin edilmiştir.

1.1 Yangın Riskini Etkileyen Temel Kriterler

Orman yangını riskini tahmini için orman yangınlarını etkileyen kriterler tanımlanması ve analiz edilmesi gerekmektedir. Orman yangını riskini tahmin etmek için, ağaç türü, gelişim çağı, kapalılık gibi meşcere özellikleri, eğim, bakı, yükselti gibi topoğrafik faktörler, yola ve yerleşim birimlerine olan uzaklık gibi çevresel faktörler ve sıcaklık ile yağış gibi iklim faktörlerinin bir arada değerlendirilmesi gerekmektedir (Bilgili vd., 2009; Dong vd., 2006; Küçük ve Sağlam, 2004; Sivrikaya ve Küçük, 2022). Orman yangınlarının oluşabilmesi için diğer faktörlerle birlikte yanıcı madde özellikleri önemli bir yere sahiptir. Topoğrafik faktörler arasında yer alan eğim faktörü (Castro ve Chuvieco, 1998; Dong ve vd., 2006) ile bakı, yangınların riskini etkileyen önemli bir kriterdir (Bentekhici vd., 2020; Jose, 2012; Lin ve Sergio, 2009; Sari, 2021). Orman yangınlarını etkileyen faktörler arasında, insanların kullandığı yollar ve yerleşim alanları gibi belirli altyapı tesislerinin konumsal dağılımı da bulunmaktadır (Castro ve Chuvieco, 1998; Chuvieco ve Salas, 1996; Sivrikaya vd., 2014). Yangın çıkma olasılığı, insan faktöründen dolayı yerleşim yerlerine yakın alanlarda artmaktadır (Erten vd., 2005; Naderpour vd., 2019).

Orman Genel Müdürlüğü Orman Yangınlarıyla Mücadele Dairesi Başkanlığı tarafından 1995 yılında yayınlanan ve hala geçerliliğini sürdüren “Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları” 285 Sayılı Tebliğ’e göre, Orman İşletme Müdürlükleri bazında yangın risk derecesi belirlenmektedir. Bu amaçla, Orman İşletme Müdürlükleri bölgesinde son 20 yıl içinde meydana gelen yangın sayısı ve yanan alan ortalaması göz önüne alınarak

hesaplanmaktadır. Bu veriler, ilgili Orman İşletme Müdürlüklerinin yangına karşı hassasiyetini değerlendirmek için kullanılmaktadır. Yani bir bölgede sıkça meydana gelen yangınlar, o bölgenin yangın risk derecesini yükseltir. Geçmişte yaşanan yangınlar, gelecekteki yangınlar için rehber niteliği taşımakta ve yangın önleme, planlama ve karar alma süreçlerinde etkili olmaktadır (Duran, 2014).

1.1.1 Meşcere Özellikleri

Meşcere özellikleri orman yangınları açısından kritik bir rol oynar. Yangın riski, yangının başlaması, gelişmesi ve yangın davranışı üzerindeki etkisi bakımından, temel faktörlerden biridir (Akbulak vd., 2018; Jaiswal vd., 2002; Sivrikaya vd., 2014; Sivrikaya ve Küçük, 2022). Meşcere tipleri/yanıcı madde tipleri, kapalılık ve gelişim çağları, yangın başlatma yeteneğini etkileyen meşcere özellikleridir (Akay ve Şahin, 2019; Çoban ve Erdin, 2020; Çolak ve Sunar, 2020; Gao vd., 2011; Güngöroğlu, 2017; Kucuk vd., 2021). İğne yapraklı çam ormanlarındaki, havalanmaya elverişli gevşek yapılı ölü örtü tabakası son derece kuru ve tutuşmaya eğilimlidir (Sari, 2021). Ölü örtünün bu özelliği, potansiyel olarak kızılçam ormanlarında yüksek yangın adetine ve yanan alan miktarlarına sebep olabilmektedir (Küçük vd., 2018). İğne yapraklı ağaç türleri, düşük nem seviyesi, yüksek yanıcı reçine içeriği ve hızlı tutuşma potansiyeli nedeniyle yüksek yangın riski taşırlar. Türkiye’de yukarıda belirtilen yanıcı madde özelliklerine sahip olan kızılçam (*Pinus brutia* Ten.), yangına karşı en duyarlı ağaç türü olup son derece yanıcıdır (Çolak ve Sunar, 2020). Orman yangınlarında kritik bir meşcere özelliği olan gelişim çağı, genç meşcereler yaşlı meşcerelere kıyasla daha yüksek yangın riski taşır; meşcere yaşlandıkça ise yangın riski azalmaktadır (Akay ve Erdoğan, 2017; Güngöroğlu, 2017; Sağlam vd., 2008).

1.1.2 Topoğrafik Faktörler

Topoğrafik faktörlerden birisi olan eğim, orman yangınlarının yayılma oranını etkileyerek orman yangınlarında hayati bir rol oynamaktadır (Bentekici vd., 2020; Maktite ve Faleh, 2017; Sari, 2021). Yangın, eğimli arazilerde yukarı yönlü hareket ettiğinde daha hızlı bir şekilde yayılırken, eğim arttıkça yangın yayılma hızı da artmaktadır (Bonora vd., 2013; Butler vd., 2007; Gerdzheva, 2014; Güngöroğlu,

2017). Nem ve sıcaklık faktörleri sebebiyle bakı, yangın riskini etkilemektedir. Ormanlardaki güney yamaçlar, kuzey yamaçlara göre daha fazla güneş ışığı almaktadır; bu nedenle güney ve güneybatı yönleri yangına karşı daha risklidir (Bentekhici vd., 2020; Jose, 2012; Lin ve Sergio, 2009; Sari, 2021). Rakım, yüksek sıcaklıklar, düşük nem seviyeleri ve yüksek rüzgâr hızları ile ilişkilendirilen temel bir topografik değişkendir. Bu özellikler, yangının başlaması ve yayılma riskini artırır (Suryabhadgavan vd., 2016; Xiangwei vd., 2011). Yüksek rakımlı bölgelerle karşılaştırıldığında, düşük rakımlı bölgeler yüksek sıcaklıkları ve düşük nem miktarları nedeniyle yangın açısından en tehlikeli olanlardır (Bentekhici vd., 2020).

1.1.3 Çevresel Faktörler

Orman yangınlarının, kamp ateşlerini kontrolsüz bırakma, sönmemiş bir sigara izmariti, ormana bitişik alanlardaki tarım arazilerinde anız yakma, hayvancılık yönetimi için otlakları yakma ve bal hasadında duman kullanma gibi insan faaliyetleri ile doğrudan veya dolaylı olarak ilişkili olduğu belirtilmektedir (Vilar vd., 2010). Türkiye’de orman yangınlarının yaklaşık %83’ünün insan kaynaklı olduğu belirtilmektedir (OGM, 2022). Birçok orman alanı yerleşim yerlerine ve tarım alanlarına yakın bir şekilde konumlanmış ve bu durum olası orman yangını riskini daha da artırmaktadır. Zira ormanların, yollara, tarım alanlarına ve yerleşim yerlerine yakınlığı, yangın çıkma riskini artırmaktadır (Hoang vd., 2020; Sari, 2021; Satir vd., 2016). İnsan faaliyetleri, araç trafiği yoğunluğu ve nüfus yoğunluğu da orman yangını riskini etkileyen önemli bir faktördür (Akbulak vd., 2018; Güngöroğlu, 2017).

1.1.4 Meteorolojik Parametreler

Orman yangını riski ve yangın davranışı yağış, sıcaklık, rüzgâr hızı ve bağıl nem gibi meteorolojik değişkenlerle doğrudan ilişkilidir (Akbulak vd., 2018; Dimitrakopulos vd., 2011; Ghobadi vd., 2012; Güngöroğlu, 2017). Çok yüksek hava sıcaklıkları, ölü örtüdeki yanıcı madde nemini azalttığı için yangın hassasiyeti artar. Benzer şekilde kurutucu rüzgârlar da ölü yanıcı maddelerin nem içeriğini azaltır ve yanıcı maddeyi kurutarak yanmaya elverişli hale getirir, çıkan bir yangının ise yangın söndürülmesini zorlaştırır (Mitsopoulos vd., 2017). Yüksek rüzgâr hızları, yangın yayılma hızını ve

şiddetini artırmaktadır (Hoang vd., 2020; Teodoro ve Duarte, 2013). Yağış, yanıcı madde nemi ve bağıl nem üzerinde doğrudan ve hemen etki eder. Yağışın az olması, tutuşabilecek yanıcı maddelerin nem tutma kapasitesini azaltarak yangın riskini artırır (Prasad vd., 2008).



2. KURAMSAL ÇERCEVE

George vd. (2010) Yapaya zekâ ile orman yangınlarının tahmini isimli çalışmalarında, sadece meteorolojik verilere dayanan orman yangını riskini tahmin etmişlerdir. Sınırlı miktarda veri ile orman yangını riskini %96'ya varan çok yüksek bir doğrulukla tahmin etmişlerdir.

Safi ve Bouroumi'in (2013) çalışmalarında orman yangınlarının tahmininde sinir ağları tabanlı bir yaklaşım ele almışlardır. Önerilen sinir ağı, gizli katman sayısı ve boyutu mevcut veri örnekleri kullanılarak her uygulama için sezgisel olarak belirlenebilen çok katmanlı bir algılayıcıdır. Algoritma C++ dili kullanılarak kodlanmış ve elde edilen program, orman yangınlarıyla en çok ilgilenen dünya bölgelerinden biri olan Portekiz'deki Montesinho doğal parkıyla ilgili gerçek test verilerine uygulanmıştır. Bu uygulamanın sonuçlarının oldukça kullanışlı olduğu ifade edilmektedir.

Otieno (2020) çalışmasında, orman yangınlarını tahmin etmek için denetimli makine öğrenmesi modelinin geliştirilmesini önermiştir. Bu amaçla, 2000 ile 2020 arasındaki meteorolojik veriler kullanmıştır. Çalışmada, Ulusal Yangın Tehlikesi Derecelendirme Sistemi, Kanada Ulusal Yangın Veri Tabanı, Kaliforniya Üniversitesi makine öğrenmesi deposu ve bilimsel olarak doğrulanmış internet kaynakları gibi birçok kaynaktan veri setleri kullanılmıştır. Orman yangının tahmin etmek için Yapay Sinir Ağı (YSA) tahmin modeli geliştirmiştir. Modelin performans doğruluğu %82 olarak tespit edilmiştir.

Sevinç vd. (2020) Muğla Orman Bölge Müdürlüğü sahasında Orman Genel Müdürlüğü tarafından 2008-2018 yılları arasında kaydedilen yangın verileri ile yaptığı çalışmada, olası orman yangını nedenlerini tahmin etmek ve aralarındaki çok taraflı etkileşimli ilişkilerin analizini yapmak için Bayesian ağ modelinin kullanımını tanıtmaktadır. Yapılan çalışmada bir orman yangınının olası çıkış nedenleri insan kaynaklı (kundaklama, sigara, avcılık, piknik ateşi, çoban ateşi, anız yakma) veya doğal kaynaklı (yıldırım düşmesi, elektrik hatları) olabilir olduğu söylemişlerdir. Sıcaklık, bağıl nem, ağaç türü, yola olan uzaklık, rüzgâr hızı, tarım arazilerine olan

uzaklık, yanan alan miktarı, ay ve yerleşim yerine olan uzaklık orman yangınlarının oluşumunu etkileyebilecek risk faktörleri olarak belirtilmiştir. Yapılan bu çalışmada, bazı farklı yapısal öğrenme algoritmaları uygulandıktan sonra, risk faktörleri olarak belirtilen bağıl nem, sıcaklık, rüzgâr hızı, ay, yerleşim yerine uzaklık, yanan alan miktarı, tarım arazisine uzaklık, yola uzaklık ve ağaç türü faktörleri üzerine inşa edilen bir Bayes ağı ile tahmin edilmiştir. Model, orman yangını tutuşmaları üzerinde ayın birinci, sıcaklığın ise ikinci en etkili faktör olduğunu göstermiştir. Sonuç olarak, bu çalışmada, orman yangını sırasında ölçülen veya gözlemlenen kanıtlara dayanarak orman yangınlarının olası nedenlerini tahmin etmek için bir BA modeli geliştirilmiştir. Daha sonra, tahmin edilen model kullanılarak, olası orman yangını senaryolarına ilişkin bazı örnek analizler sunulmuştur. BA'larda tahminler, gözlemlere veya kanıtlara dayalı olarak ağınc güncellenmesi ve sonsal olasılıkların elde edilmesiyle yapılmıştır. BA'ların en önemli avantajlarından biri, BA'deki tüm değişkenlerin marjinal koşullu olasılıklarının aynı anda hesaplanabilmesidir. Regresyon analizi gibi diğer analizlerin aksine her değişken hem girdi hem de çıktı değişkeni olarak kullanılabilir. Bu çalışmada sunulan model, aynı değişkenler kullanılarak başka herhangi bir ormancılık veri seti için yeniden oluşturulabilir. Sunulan modeli, mevcut değişkenlere yenilerini ekleyerek ya da orman yangınlarını etkilediği bilinen diğer potansiyel değişkenleri kullanarak genişletmek de mümkün olduğu açıklanmıştır.

Pais vd. (2021) yaptığı çalışmada, bir alandaki birden fazla arazi örtüsünün mekânsal yapısı ve etkileşimi olarak anlaşılan peyzaj topolojisinin yangın tutuşması üzerindeki etkisi analiz edilmiştir. Orman yangını tutuşma riskini tahmin etmek için Derin Yangın Topolojisi adlı bir derin öğrenme önerilmiştir.

Atmaca vd. (2022) çalışmalarında, Muğla ili Milas ilçesi için orman yangını riskini modellemek için Lojistik Regresyon (LR) ve Coğrafi Bilgi Sistemleri kullanmışlardır. Topografik özellikler, orman yapısı ve kültürel veriler gibi faktörler dikkate alınarak, bu özelliklerin yangın oluşumuyla ilişkisi araştırmışlar. Lojistik Regresyon yöntemiyle yapılan doğruluk analizleri ve farklı özelliklerdeki alanların yangın riskleri Alıcı Çalışma Karakteristiği (AİK) ve Hosmer-Lemeshow testi ile incelenmişlerdir. Elde edilen bulgulara dayanarak CBS ortamında bir orman yangını risk haritası

oluşturmuşlardır. Çalışma sonucunda, Muğla ilinin Milas ilçesindeki orman alanlarının %16'sının yüksek ve çok yüksek risk sınıfında olduğu belirlenmiştir.

Feizizadeh vd. (2022) İran'da yaptığı çalışmada, entegre bir jeoinformasyon (uzaktan algılama ve CBS temelli coğrafi bilgi bilimi) yaklaşımı kullanarak ve İran'ın Gachsaran bölgesindeki orman yangını riski analizi yapmışlar ve haritalamışlardır. Orman yangını risk haritalaması için CBS tabanlı çok kriterli bir karar analizi yöntemi kullanmışlardır. Yüksek yangın riskine sahip alanları belirlemek için, bulanık ve analitik ağ süreci yöntemleri kullanmışlardır. Hassas bölgeleri ayırt etmek için, arazi yüzeyi özellikleri, klimatolojik faktörler ve antropojenik faktörleri içeren 13 jeomorfolojik faktörden yararlanmışlardır. Çalışma tarihsel orman yangını verileriyle doğrulanmış ve araştırma sahasının %18,'inin yüksek orman yangını riski taşıdığını ortaya çıkarmışlardır.

Fidanboy vd. (2022) yaptıkları çalışmada, orman yangınlarıyla mücadelede kullanılmak üzere Orman Yangını Analiz Tahmin (OYAT) modeli geliştirmiştir. OYAT, resmi kaynaklardan elde edilen bitki örtüsü verileri, iklim değişiklikleri, insan etkisi ve geçmiş yangın verilerine dayanarak oluşturmuşlardır. Bu veriler derin öğrenme teknikleriyle işlenerek OYAT modeli oluşturmuşlardır. OYAT, coğrafi bilgi sistemleriyle uyumlu, kolay kullanılabilir, dinamik verilerle güncellenebilir ve görselleştirilebilir bir yapı haline getirilmiştir. Türkiye'deki 2013-2019 yılları arasındaki orman yangını verileri, OYAT modelinin değerlendirilmesinde kullanılmışlar ve oluşturulan risk haritalarının %98 doğruluk oranına sahip olduğu gözlemlenmiştir.

Sivrikaya ve Küçük (2022) tarafından gerçekleştirilen çalışmada, yangın risk haritası oluşturmak için entegre bir yaklaşım önerilmiştir. Coğrafi bilgi sistemleri tabanlı çok kriterli karar analizi ile analitik hiyerarşi süreci (AHP) ve bir istatistiksel indeks kullanılmıştır. Araştırma, Türkiye'nin Doğu Akdeniz Bölgesi'nde bulunan Mersin Orman Bölge Müdürlüğü'nde gerçekleştirilmiştir. Orman yapısı, topografya, çevresel faktörler ve iklim gibi dört ana kriter ile birlikte yangın risk haritasını oluşturmak için 16 alt kriter kullanılmıştır. AHP kullanılarak her bir kriterin ağırlığı belirlenmiştir. AHP modeli, çevresel faktörlerin orman yangınlarına en çok etki eden faktörler

olduğunu, bunu takiben orman yapısının takip ettiğini ortaya koymuştur. Orman yangını risk haritasına göre, tutuşma noktalarının %85'inden fazlası aşırı veya yüksek riskli bölgelerde sınıflandırılmıştır. Göreceli çalışma karakteristiği eğrisi ve eğrinin altındaki alan, yangın riski haritasının doğruluğunu doğrulamıştır. Bu doğrulama, AHP için 0,775 gibi çok yüksek bir doğruluk seviyesi ortaya koymuştur. Model, orman yangını risk haritalamasında yüksek doğruluğa işaret etmektedir.

Abdollahi vd. (2023) çalışmalarında, potansiyel yangın tehditlerini azaltmak için, yangın oluşum desenlerini tanımak ve yangın hassasiyetini belirlemenin faydalı olabileceğini ifade etmişlerdir. Makine öğrenmesi (ML) algoritmalarının kullanımı, orman yangını tehlikeleri gibi doğrusal olmayan sorunları ele almanın en bilinen yöntemlerinden biri olarak kabul edilir olduğunu belirtmişlerdir. Yaptıkları araştırmada, orman yangını duyarlılık tahmini için geliştirilen bir derin öğrenme modelinin sonuçlarını yorumlamak için bir Shapley katkı açıklamaları (SHAP) modelinin nasıl kullanılabileceğini açıklamışlardır. SHAP grafiklerinden çıkarılan bulgular, nem, rüzgâr hızı, yağış, rakım, eğim ve normalize edilmiş fark nem indeksi gibi faktörlerin, orman yangını duyarlılık haritası için önerilen modelin çıktısına önemli katkılarda bulunduğunu göstermiştir. Açıklanabilir bir model geliştirmenin, yangın duyarlılığını haritalandırmak için modelin kararlarını anlamada yardımcı olacağını, tahmin modelinde yüksek katkı sağlayan bileşenleri belirleyeceğini ve dolayısıyla yangın tehlikelerini etkili bir şekilde kontrol edeceğini belirtmişlerdir.

Alkhatib vd. (2023) yaptıkları çalışmada, orman yangını bilimine makine öğrenmesi tekniklerinin entegrasyonu için önerilen birçok çalışmayı incelemişler. İncelenen çalışmalara göre, yapay zekâ içeren gelişmiş sistemlerin geliştirilmesi ve bu önemli çevresel sorunları tahmin eden ve orman yangınlarının önlenmesinde kamu politikalarına yardımcı olan umut verici bir yön olduğu anlaşılmıştır. Orman yangını biliminde makine öğrenmesi, dezavantajlara sahip olduğu belirtilmiştir. ML sistemleri, eğitmek için büyük miktarda veri gerektiren ve genellikle orman yangınları sırasında mevcut olmayan sistemlerdir. Ayrıca, ML öğrenme yaklaşımları, pahalı ve ölçeklendirilmesi zor olabilecek büyük miktarda hesaplama gücü gerektirdiği belirtmişlerdir. Gerçek dünyada ML öğrenme sistemlerinin doğruluğunu değerlendirmenin zor olabileceği ve ML modelleri bağımsız olarak öğrenebilirken,

orman yangını arařtırmalarında uzmanlık gerektirdiđini ifade etmiřlerdir. Orman yangını sũreçlerinin birçok ȧlçekte gerçekçi modellemesini sađlamak için uzmanlık gerektiđini söylemiřlerdir.

Rubí vd. (2023) Brezilya Federal Bölgesi'nde bulunan Cerrado'da yaptıđı çalıřmada, bölgede çok sayıda yangın olmasından dolayı yangın tahmini için Brezilya hükũmetinin açık verilerinden bir veri seti derlemiřler ve çeřitli makine ȧđrenmesi modellerinin eđitimi için kullanmıřlardır. Yangının çıkıř noktasını tahmin etmek için bu veri setini kullanmıřlardır. Gözlemleri, iklim ȧzelliklerine iliřkin beř izleme istasyonundan elde edilen verileri içermekte ve son yirmi yılda meydana gelen yangınlara iliřkin uydu verileri ile zenginleřtirmiřlerdir. Ayrıca, diđer topografik, hidrografik ve antropojenik ȧzelliklerle (örneđin, su kaynakları/yollar ve řehirleřme endeksi, řehir merkezine uzaklık gibi) Normalleřtirilmiř Fark Bitki ȧrtũsũ İndeksini de dikkate almıřlardır. Sonuç olarak da AdaBoost modelinin orman yangınından etkilenen bölgeyi %91 dođrulukla tahmin edildiđi gösterilmiř, bu da Rastgele Orman (%88), Yapay Sinir Ađı (%86) ve Destek Vektȧr Makinesi (%81) modellerinden daha iyi bir performans olduđunu ortaya koymuřlardır.

Rihan vd. (2023) yaptıkları çalıřmada Batı Himalaya'nın tepeli bölgesinde orman yangınlarının, orman tahribatı ve biyoçeřitlilik kaybında kritik bir rol oynadıđını belirtmiřlerdir. Çalıřmada Uttarakhand'ın tepeli eyaletinde orman yangınına hassas bölgeler tahmin edilmiř ve haritalandırılmıřtır. Bunu gerçekteřtirmek için, geospatial teknikleri ve makine ȧđrenmesi algoritmaları kullanılarak orman yangını çıkma parametrelerinin hassasiyeti ve belirsizlik analizi üzerine derin ȧđrenme tabanlı bir yaklařım benimsenmiřtir. Arařtırmada yapay sinir ađları, rastgele orman, lojistik regresyon, destek vektȧr makinesi ve ensemble makine ȧđrenmesi modeli gibi beř farklı makine ȧđrenmesi algoritması kullanılmıřtır. Oluřturulan modeller, AİK kullanılarak dođrulanmıřtır. Sonuçlar, Uttarakhand'ın toplam alanının neredeyse %55'inin çok yüksek ve yüksek orman yangını riski bölgelerinden oluřtuđunu göstermiřtir.


Kũçük ve Sevinç'in (2023) mũdahale görmũř karaçam meřceresinde yaptıđı çalıřmada, yangının yayılma hızı ve yangın řiddetinin tahmini için iki yapay zekâ

yöntemi kullanılmıştır. Bu yöntemler bir yapay sinir ağı ve bir karar ağacıdır. Ayrıca, her iki yöntemin tahmin performansları, geleneksel regresyon modelinin performansı ile karşılaştırılmıştır. Yapılan analizler sonucunda, yapay sinir ağının hem yangın şiddeti hem de yangının yayılma oranını tahmin etmede diğer modellere göre daha iyi bir performans sergilediği görülmüştür.


Salhi vd. (2023) yaptığı çalışmada, Jandouba-Tunus ormanlarındaki veya dünyanın diğer bölgelerindeki yangın risklerini belirlemek için iklim faktörlerini kullanışlardır. Bu çalışmada, Kanada'nın sistem parametrelerine yapay zekâ uygulayarak risklerin yerlerini ve tarihlerini tahmin etmeyi amaçlamışlardır. Çalışmada, incelenen bölgeyi kapsayan son beş yıla ait meteorolojik veriler kullanarak sonraki yıllar için tahminler yapılmıştır. Meteorolojik yangın indeksi içerisinde bir derin öğrenme sinir ağının manipülasyonu, Kanada sistem parametrelerinin korelasyon ve varyans matrislerini oluşturarak doğru tahmin ve anlık karar verme süreçlerine yardımcı olarak kullanılmış ve bu, müdahale süreçlerini iyileştirmeye ve zamanında müdahale etmeye imkân tanımıştır. Proaktif çevre yönetimini teşvik etmek için, entegre bir yaklaşım benimsenmek ile birlikte ileri teknolojiler ve veriye dayalı modellerle birleştirilebileceğini ifade etmişler ve bunun da önemli orman yangınlarını önlemeye yardımcı olacağını belirtmişlerdir.

kaydedilmiştir. En yüksek sıcaklık 32°C iken en düşük sıcaklık -3°C olarak ölçülmüştür (Şekil 3.3) (URL-1, 2023).

Yıllık yağış miktarı 220 mm ile 45 mm arasında değişkenlik göstermektedir. Bölgenin genelinde Batı Karadeniz iklimi etkisiyle yıllık ortalama yağış miktarı 100 mm'nin üzerindedir. Yıllık rüzgâr hızı 23 km/sa ile 5 km/sa arasında değişirken, ortalama rüzgâr hızı 15 km/sa olarak ölçülmüştür. Ancak, zaman zaman rüzgârlar 30 km/sa'ın üzerine çıkabilmektedir (Şekil 3.2) (URL-1, 2023).



Şekil 3.2 Taşköprü yıllık yağış ve rüzgâr grafiği




Şekil 3.3 Taşköprü yıllık yağış ve sıcaklık grafiği

Taşköprü Orman İşletme Müdürlüğü; Kastamonu ilinin doğusunda yer alan Taşköprü ilçesinde bulunmaktadır. Taşköprü Orman İşletme Müdürlüğü Doğusunda; Hanönü Orman İşletme Müdürlüğü ve Boyabat İşletme Müdürlüğü ile komşudur. Taşköprü Orman İşletme Müdürlüğü Kuzeyinde; Çatalzeytin Orman İşletme Müdürlüğü, Bozkurt Orman İşletme Müdürlüğü ve Türkeli Orman İşletme Müdürlüğü ile komşudur. Taşköprü Orman İşletme Müdürlüğü Batısında; Küre Orman İşletme Müdürlüğü, Karadere Orman İşletme Müdürlüğü ve Kastamonu Orman İşletme Müdürlüğü ile komşudur. Taşköprü Orman İşletme Müdürlüğü Güneyinde; Kargı Orman İşletme Müdürlüğü ve Tosya Orman İşletme Müdürlüğü ile komşudur (OGM, 2022).

Taşköprü Orman İşletme Müdürlüğünün genel alanı 181.256,10 hektar olmak ile birlikte bu alanın 113.518,9 hektarı ormanlık alandır (Tablo 3.1). Bu da Taşköprü Orman İşletme Müdürlüğünün yüzey alanının %62,6'sının ormanlık alanlar ile kaplı olduğu anlamına gelir. Taşköprü Orman İşletme Müdürlüğü'ne bağlı 14 adet Orman İşletme Şefliği ve 1 adet Depo Şefliği olmak üzere 15 adet şeflik bulunmaktadır (Şekil 3.4).

Tablo 3.1 Taşköprü orman işletme müdürlüğü orman varlığı

İşletme Şefliği	Normal Orman	Bozuk Orman	Toplam Orman (ha)	Ormansız Alan	Genel Alan
AKÇATAŞ	4305,80	1609,20	5915,00	2710	8625,00
ALAÇAM	4514,80	445,30	4960,10	870,1	5830,20
BAYAM	5788,60	2113,10	7901,70	2274,30	10176,00
ÇİFTLİK	6818,60	1034,10	7852,70	1585,30	9438,00
DİKMEN	5602,10	1280,60	6882,70	2111	8993,70
DÜZDAĞ	6705,70	3600,20	10305,90	2770,1	13076,00
KARATEPE	7108,30	2200,90	9309,20	6616,7	15925,90
KIRKÇAM	6112,10	622,50	6734,60	2310,2	9044,80
KOÇANLI	5273,50	761,40	6034,90	6034,9	12069,80
OBRUCAK	5053,10	4269,40	9322,50	8031,80	17354,30
SARAYCIK	5619,10	510,30	6129,40	2222,5	8351,90
SARIKAYA	6076,20	5762,5	11838,70	3782,8	15621,50
TAŞKÖPRÜ	6117,4	5825,70	11943,10	23015,2	34958,30
TEKÇAM	7374,20	1014,20	8388,40	3402,3	11790,70
TOPLAM	82469,50	31049,40	113518,90	67737,2	181256,10



Şekil 3.4 Taşköprü orman işletme müdürlüğü haritası

3.2 Kullanılan Veri Setleri

Çalışmada, araştırma alanı olarak yangın hassasiyeti bakımından ikinci kategoride bulunan Kastamonu Orman Bölge Müdürlüğü sınırları içerisindeki Taşköprü İşletme Müdürlüğüne bağlı olan İşletme Şeflikleri seçilmiştir. Araştırma materyalleri olarak yangın çıkan alanlar ve yangın çıkmamış alanlardan toplanan verileri içeren bir veri seti elde edilmiştir.

Yangın risk derecesi, Avrupa Orman Yangın Bilgi Sistemi (EFFIS) tarafından belirlenmektedir. Bu sistem 2000 yılında kurulmuş olup günümüzde 41 ülkenin katılımını içermektedir. Türkiye, EFFIS üyesi olarak 2005 yılından bu yana bu sistemde yer almaktadır. Genellikle, EFFIS tarafından yapılan sınıflandırma Orman İşletme Müdürlüğü bazında gerçekleştirilir. Orman Genel Müdürlüğü Orman Yangınlarıyla Mücadele Dairesi Başkanlığı tarafından 1995 yılında yayınlanan ve hala geçerliliğini sürdüren “Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları” 285 Sayılı Tebliğ’e göre, Orman İşletme Müdürlükleri bazında yangın risk derecesi belirlenmektedir. Bu amaçla, Orman İşletme Müdürlükleri

bölgesinde son 20 yıl içinde meydana gelen yangın sayısı ve yanan alan ortalaması göz önüne alınarak hesaplanmaktadır. Bu veriler, ilgili Orman İşletme Müdürlüklerinin yangına karşı hassasiyetini değerlendirmek için kullanılmaktadır. Taşköprü Orman İşletme Şefliklerin “Orman Yangınlarının Önlenmesi ve Söndürülmesinde Uygulama Esasları” 285 Sayılı Tebliğ’ine göre belirlenen, Orman İşletme Müdürlükleri bazında yangın risk derecesi yangına karşı hassasiyeti bakımından veri setine dâhil edilmiştir.

Taşköprü Orman İşletme Müdürlüğü’nde bulunan şefliklerinin son 5 yıl içerisinde çıkan orman yangın verileri, orman amenajman planı verileri ve haritaları kullanılmıştır. Taşköprü Orman İşletme Müdürlüğünde gerçekleşen yangın verileri, yangın kayıt defterleri, yangın sicil fişleri raporlarından ve Orman Bilgi Sistemi (ORBİS)’ten elde edilmiştir. 2017-2022 yılları arasında Taşköprü Orman İşletme Müdürlüğü sınırları içerisindeki meydana gelen bütün orman yangınlarının verileri alınmış çizelge (EK-1) olarak sunulmuştur. 2017-2022 yılları içerisinde çıkan 66 adet orman yangınının gerçekleştiği 271 adet meşcerenin verileri (kapalılık, meşcere çağları, ağaç türleri, bakışı, yüksekliği), yangının boyutları, çıkış nedenleri, yangını çıkış tarih ve zamanını, yangının söndürülme süresini ve meteorolojik verileri (sıcaklık, nisbi nem, rüzgâr) Orman İşletme Müdürlüğü tarafından tutulan yangın kayıtları incelenerek tespit edilmiştir. 271 noktada meydana gelen orman yangınının her bir noktasından, uydu görüntüleri kullanılarak yerleşim yerine, tarım alanına, yola ve su kaynaklarına kuş bakışı olarak mesafeleri hesaplanmıştır.

Taşköprü Orman İşletme Müdürlüğü’nün her şefliğinden yangın kayıt defterleri, yangın sicil fişleri, raporları ve Orman Bilgi Sistemi incelenerek günümüze kadar yangın çıkmamış 299 meşcere tespit edilmiştir. Tespit edilen 299 adet meşcerenin kapalılığı, meşcere çağları, ağaç türleri ve yükseklikleri hesaplanarak belirlenmiştir. Birinci veri setinde olduğu gibi ikinci veri setinde de 299 noktanın yerleşim yerine, tarım alanına, yola ve su kaynaklarına olan kuş bakışı mesafeleri uydu görüntülerinden yararlanılarak hesaplanmıştır (EK-2).

3.3 Metot

3.3.1 Kriterlerin Seçimi

Yangın riskinin tahmini için hangi kriterlerin kullanılacağına karar vermek amacıyla detaylı bir literatür taraması gerçekleştirilmiştir. Yapılan tarama sonucunda, yangın riskini değerlendirmek için 4 ana kriter belirlenmiş olup, bunlar meşcere, topoğrafya, çevresel faktörler ve meteorolojik verilerdir. Ayrıca, bu ana kriterlerin yanı sıra 12 alt kriter de tespit edilmiştir. Bu alt kriterler ağaç türleri, gelişim çağı, kapalılık, bakı, yükseklik, yerleşim yerinden uzaklık, tarım alanlarına uzaklık, yola uzaklık, su kaynaklarından uzaklık, sıcaklık, nisbi nem ve rüzgâr hızıdır.

Orman yangınlarında hassasiyet risk dereceleri beş farklı sınıfa ayrılmıştır. Yangın riskini belirlenmesinde Sağlam vd. (2008) ile Sivrikaya ve Küçük (2022) çalışmasındaki sınıflandırma değerleri kullanılmış ve aşağıdaki tablolarda da gösterilmiştir (Tablo 3.2-3.5).

Tablo 3.2 Taşköprü orman işletme müdürlüğü orman varlığı

Meşcere Özellikleri	5-Çok Düşük Riskli	4-Düşük Riskli	3-Orta Riskli	2-Yüksek Riskli	1-Aşırı Riskli
Ağaç Türü	Göknar, Meşe	Bozuk Alanlar	Lübnan Sediri, Ardiç	Bozuk Kızılçam	Karaçam, Sarıçam, Kızılçam, Makiler
Kapalılık (%)	<11	11-40		41-70	>70
Gelişim Çağı(cm)	<8	>52	36-51,9	20-35,9	8-19,9

Tablo 3.3 Yangın risk kriterleri- topoğrafya

Topografya	5-Çok Düşük Riskli	4-Düşük Riskli	3-Orta Riskli	2-Yüksek Riskli	1-Aşırı Riskli
Bakı	Kuzey, Kuzeydoğu, Kuzeybatı	Doğu	Batı, Güneydoğu, Düz	Güney	Güneybatı
Yükseklik (m)	>2000	1500-2000	1000-1500	500-1000	0-500

Tablo 3.4 Yangın risk kriterleri- çevresel kriterler

Çevresel Kriterler	5- Çok Düşük Riskli	4-Düşük Riskli	3-Orta Riskli	2-Yüksek Riskli	1-Aşırı Riskli
Yerleşim Yerinden Uzaklık (m)	>5000	1000-5000	500-1000	250-500	0-250
Tarım Alanlarına Uzaklık (m)	>5000	1000-5000	500-1000	250-500	0-250
Yola Uzaklık (m)	>5000	1000-5000	500-1000	250-500	0-250
Su Kaynaklarından Uzaklık (m)	>5000	1000-5000	500-1000	250-500	0-250

Tablo 3.5 Yangın risk kriterleri- meteorolojik parametreler

Meteorolojik Parametreler	5- Çok Düşük Riskli	4-Düşük Riskli	3- Orta Riskli	2-Yüksek Riskli	1- Aşırı Riskli
Sıcaklık (°C)	<5-9	10-19	20-24	25-34	>35
Rüzgâr Hızı (m/s) *	<1,9	1,9-2,1	2,1-2,4	2,4-2,7	>2,7
Nisbi Nem (%)	>90	90-70	70-50	50-30	<30

*Tabloda rüzgâr hızı metre/saniye cinsinden verilmiş. Ancak diğer metinlerde kilometre/saat olarak ifade edilmiş.

3.3.2 Makine Öğrenmesi

Günümüz dünyasında, hemen hemen her ülkede sağlık, eğitim, finans, ulaşım, güvenlik, iklim, ormancılık, jeolojik vb. gibi pek çok sektörde teknoloji kullanımı büyük bir ivme kazanmış durumdadır. Günümüz çağında ve gelecekte, teknoloji kullanımının yaygınlaşması, insanlar tarafından üretilen veri miktarının sürekli olarak artmasına neden olmuştur. Bu durum, çeşitli sektörlerde faaliyet gösteren bireylerin ve kuruluşların, gelişen teknolojiye ayak uydurarak büyük miktarda veri üretmelerini beraberinde getirmiştir. Aynı zamanda, teknolojinin ilerlemesiyle birlikte, verilerin depolanması ve bu verilere erişim sağlanması eskisine göre hem daha basit hem de daha maliyet etkin bir hale gelmiştir. Bu durum, bilgi teknolojilerindeki gelişmelerin, veri yönetimi süreçlerini optimize etme ve verilere daha hızlı bir şekilde ulaşma konularında önemli avantajlar sağladığını göstermektedir. Veri depolama sistemlerindeki gelişmeler ve bulut bilişim teknolojilerinin yaygın kullanımı, veri yönetimini daha etkili hale getirerek iş süreçlerini iyileştirmeye olanak tanımaktadır. Bu bağlamda, teknoloji kullanımının artışıyla birlikte ortaya çıkan büyük veri setleri, birçok sektörde daha bilinçli kararlar alınmasına olanak tanımaktadır. Veri analitiği ve

yapay zekâ gibi teknolojik araçlar, bu büyük veri setlerinden anlamlı bilgiler çıkarmada önemli bir rol oynamakta ve bu da çeşitli sektörlerin veri odaklı stratejiler geliştirmesine olanak sağlamaktadır. Günümüzde ve gelecekte yapay zekâ (YZ), birçok alanda büyük önem taşımaktadır ve bu önem giderek artmaktadır.

Makine öğrenmesi, tasarlanan modeller ile veri analitiği, örüntü tanıma ve tahmin sistemi sunan bir yaklaşımdır. Ayrıca gizli olan örüntüleri keşfetmeye yardımcı olmaktadır (Ahuja ve Angra, 2017). Makine öğrenmesi, veriler üzerinden istatistiksel analizler gerçekleştirerek gelecekteki durumlar hakkında tahminlerde bulunabilir. Bu teknoloji, geçmiş bilgileri kullanarak çeşitli çıkarımlar yapabilme kapasitesine de sahiptir. Makine öğrenmesi ile orman yangınlarını tespit etme, kontrolü ve önlemesi gibi sürecinde etkili bir şekilde kullanılabilir.

Geleneksel programlamada, bir görevin yerine getirilmesi için programcılar tarafından gerekli her adım kodlanmakta iken makine öğrenmesinde algoritmalar veri üzerinde eğitim alarak aynı görevi kendileri çözmeyi öğrenmektedir (Samuel, 1988). Benzer şekilde, Blum tarafından da makine öğrenmesinin; verilerden kural öğrenme yeteneği olan, değişiklikler kapsamında kendini güncelleyebilen ve edindiği deneyimlerle birlikte performansını ilerleten yazılımları tasarlamakla ilgilenmekte olduğu belirtilmiştir (Blum, 2021). Dolayısıyla, makine öğrenmesinde veri kullanılarak yazılımların kendi kendine bir öğrenme gerçekleştirmesi söz konusudur. Bu çerçevede makine öğrenmesi alanında özetle;

- Öğrenebilen makine denildiğinde bilgisayarlı sistemlerin anlaşılması ve bu sistemlerde öğrenmeyi sağlayan unsurun bilgisayar yazılımları olması,
- Yapılan tanımlarda deneyimle öğrenme ve performansın artması konularının vurgulanarak performansın deneyimlerle birlikte artmasının öğrenme olarak kabul edilmesi,
- Deneyimin esas itibarıyla öğrenme olayının gerçekleştirilebileceği veri setleri olması,

- Öğrenmenin, veri setinde bulunan ve işin amacına göre faydalı olacak bilgilerin ortaya çıkarılması ve meydana gelen değişikliklere yazılımın kendi kendine uyum sağlayabilmesi olduğu,
- Hangi düzeyde öğrenmenin gerçekleştiğinin test edilmesi amacıyla bazı kriterlerin kullanılması,
- Öğrenme düzeyinin geliştirilmesi için oluşturulan modellerde parametre ayarlaması yapılması, hususlarının konunun önemli noktaları olarak sayılması mümkündür (Görmez, 2021).

Makine öğrenmesi, genel olarak üç kategoriye ayrılır: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme. Denetimli öğrenme, giriş ve çıkış parametrelerinden oluşan örnek verilerle bir model geliştirme sürecini içerir, bu model daha sonra yeni girişleri çıkışlarla eşleştirmek için kullanılır. Belirtmek gerekir ki, makine öğrenmesinde kullanılan örnek veriler, Excel dosyalarındaki sütunlara benzer özniteliklerden oluşur. Öznitelik ölçülebilir bir özelliktir ve orman yangınları tahmin edilmesi gibi bir uygulamada yangının çıkış nedeni, yangının gerçekleştiği yerin meşcere özellikleri ve topoğrafik özellikleri, yangının başladığı zaman ve başladığı zamandaki meteorolojik verileri, insan faktörleri, yerleşimi, tarım alanlarına ve su kaynaklarına olan uzaklıkları gibi niteleyici özellikleri içerebilir. Bu gibi pozisyonlarda çıktı değişkeni ise eylemin gerçekleştiği insan faktörü, meteorolojik verileri veya yangının gerçekleştiği konum olabilir. Bu nedenle, denetimli öğrenme sürecinde, modelin geliştirilmesinde kullanılan örnek verilerdeki özellikler analiz edilir ve bu özellikler ile etiketlenmiş, yani sınıflandırılmış çıktı değişkeni arasındaki ilişkiyi anlamaya çalışılır. Bu süreç sonucunda, model, daha önce görmediği örneklerden çıktıları tahmin etmek için kullanılabilecek bir fonksiyon oluşturur. Daha sonra bu fonksiyon, modelin eğitiminde kullanılmamış ancak çıktı değerleri bilinen test verisi ile kullanılarak tahminlerde bulunulur ve elde edilen sonuçlar gerçek sonuçlarla karşılaştırılır. Bu karşılaştırma, tahminlerin gerçek değerlerden ne kadar sapma gösterdiğini ölçen kayıp fonksiyonları kullanılarak yapılır. Bu süreç sonucunda, tahminlerin yeterince doğru olduğu sonucuna varılırsa, algoritmanın genelleme yeteneğine ulaştığı kabul edilir.

Herhangi bir problemin makine öğrenmesi yardımıyla çözülmesi için benzer yaklaşımlar bulunmaktadır. Makine öğrenmesinin uygulanma aşamaları;

- 1) Modelin geliştirileceği veri setinin toplanması,
- 2) Toplanan veri setinin algoritmalar açısından uygun hale getirilmesi için verilerin temizlenmesi, uygun formata dönüştürülmesi ile eğitim ve test verisine ayrılması gibi işlemlerden oluşan veri ön işleme aşamasının gerçekleştirilmesi,
- 3) Algoritmalar ve yukarıda belirtilen aşamalar sonucunda oluşturulan eğitim veri seti kullanılarak modelin oluşturulması,
- 4) Model oluşturulduktan sonra yukarıda belirtilen şekilde elde edilen test veri seti kullanılarak modelin değerlendirilmesinin yapılması,
- 5) Sonuçların istenilen düzeyde olması durumunda uygulamanın canlı ortama taşınması olarak özetlenebilecektir (Kartal, 2015).

Açıklanan makine öğrenmesinin, orman yangınlarının tahmininde bulunmasındaki etkilerini değerlendirmeden önce orman yangınının genel işleyiş mekanizmasından bahsedilmesi uygun olacaktır. Orman yangınları küresel iklim değişikliği ile artan sıcaklıklar ve değişen hava koşulları nedeniyle orman yangınlarının sıklığı ve şiddeti artmaktadır. Yine de orman yangınların çıkışına sebep olan en büyük faktör insanlardır. Orman yangınların %90'nı insan kaynaklı ve %10'u doğal neden ile çıktığını birçok kaynak ve veriler söylemektedir. Orman yangınlarının büyüklüğünü ve şiddetini belirleyen faktörler ise yangın esnasında hava koşulları ve ormanın özellikleridir. Bu da gerçekleşen orman yangınlarında insanların faaliyetleri, yerleşim alanları, kullandıkları tarım alanları, su alanları ve orman yangınların gerçekleştiği yer, zaman, hava koşulları, ormanın aktüel durumu ve ormanın yapısı, ağaç türü gibi kriterler büyük önem taşımaktadır.

Bu doğrultuda, orman yangınlarının tahmin edilmesinde makine öğrenmesinin çok çeşitli uygulamaların olması söz konusudur. Makine öğrenmesi algoritmaları: orman yangınlarına ait büyük verilerin analiz edilmesi, orman yangın nedenlerinin ortaya

ıkarılması, orman yangınını etkileyen faktörlerin tespit edilmesi gibi amaçlarla kullanılabilir. ünkü orman yangınların tahmin edilmesinde makine öğrenmesi algoritmaları kullanılması orman yangını ile mücadele eden kurum ve kuruluşlara orman yangınlarına hassas alanların tespitinde ve erken müdahale edebilme imkânı sağlamaktadır.

Bu tez çalışmasında, ilgili konuda yapılan araştırmalara ve gelecekteki uygulamalara ışık tutmak amacıyla orman yangınlarının tahminine yönelik olarak veri seti üzerinden makine öğrenmesi modelleri geliştirilmiştir.

3.3.3 Sınıflandırma Algoritmaları


Sınıflandırma algoritmaları ile oluşturulan modellerde, gerçekte bir sınıfa ait olan ancak hangi sınıfa ait olduğu model tarafından başlangıçta bilinmeyen veri parçasının bilinen gruplardan birine yerleştirilmesi amaçlanmaktadır (Harrington, 2012). Bu hedefe ulaşabilmek için, daha önce model oluşturulurken temel alınan eğitim veri setinde bulunan ve girdilerin hangi sınıfa ait olduğu, yani etiketi bilinen örneklerden faydalanılmaktadır. Bu bağlamda, modelin sınıflandırma aşamasında hem girdi parametreleri hem de çıktı değerleri bilinmektedir.

Veri setlerinin sınıflandırılması için çeşitli yaklaşımlar kullanılmaktadır. Sınıflandırma algoritmaları genellikle olasılık tabanlı ve olasılık tabanlı olmayan olarak iki kategoriye ayrılabilir. Olasılık tabanlı sınıflandırıcılarda, herhangi bir örneğin belirli bir sınıfa ait olma olasılığı gösterilirken, olasılık tabanlı olmayan sınıflandırıcılarda ise örneğin ait olduğu tahmin edilen sınıf gösterilmektedir. Ayrıca, bu sınıflandırıcılar ikili veya çoklu sınıflandırıcılar olarak ele alınabilir. İkili sınıflandırma, belirli bir veri setinde yer alan verilerin belirlenen sınıflandırma kuralı ile iki gruba ayrılmasını ifade ederken, çoklu sınıflandırıcılar ise ikiden fazla gruba ayrılmasını ifade etmektedir.

3.3.3.1 Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), denetimli öğrenme algoritmalarından birine aittir. Bu algoritma, doğrusal veya doğrusal olmayan problemleri çözmek için verileri

sınıflandırmak amacıyla bir çizgi veya hiper düzlem oluşturur (Pupale, 2019). DVM'nin hiper düzlemleri, eğitim örneklerinin alt kümesi tarafından belirlenen destek vektörleri tarafından belirlenir. Aynı durumu gösteren bir örnek Şekil 3.5'da Manning vd. (2009) tarafından hazırlanmıştır.




Şekil 3.5 Destek vektör makinesi

Sukumar vd. (2009), orman yangınlarını tahmin etmek için DVM algoritmasını kullanmışlardır. Makalelerinde orman içindeki geçerli sıcaklık ve nem değerlerini içeren veri setini kullanarak DVM sınıflandırıcısı öğrenilmiştir. Bu değerler, 'EVET' sınıfının tahminini içerir ve yüksek yangın riskini gösterir, bu nedenle önleyici tedbirlerin alınmasını gerektirebilir. Naganathan vd. (2016) makalelerinde, "Orman Yangını Tahminleri: Fused kullanarak Güvenilir Modellerin Belirlenmesi Veri Kümesi" başlığı altında, DVM'nin en iyi uygun değer modeller olarak belirlendiğini belirtmişlerdir. Ayrıca, en yakın komşular algoritması ve karar ağacı modellerini değerlendikten sonra, seçilen birleştirilmiş veri kümesi üzerinde ikili ve çoklu sınıflandırmalar gerçekleştirmişlerdir.


3.3.3.2 Rastgele orman (RO)

2001 yılında L. Breiman tarafından önerilen RO algoritması, genel olarak yararlı bir gruplama ve nüks stratejisi olarak oldukça etkili olmuştur. Birkaç rastgele seçim ağacını birleştiren ve tahminlerini ortalama ile birleştiren bu metodoloji, faktör

miktarının algı miktarından çok daha büyük olduğu ortamlarda mükemmel bir uygulama sergilemiştir (Biau vd., 2016). Rastgele orman, aslında bir seçim ağacı sınıflandırıcıları grubudur. Ağaçlar, genellikle üstün bir sınıflandırıcıya yol açan belirli değişiklikler için hazırlanır. Orman içindeki her ağaç, ilk hazırlık bilgilerinin önyüklemeli bir yorumuyla hazırlanır. Önyükleme, ilk bilgidan ikame ile tutarlı bir şekilde test etmeyi amaçlamaktadır. Her ağaçtaki her düğümde, sadece rastgele bir özellik alt kümesi kullanılır (Lineberry, 2018). Rastgele Orman modellerinde, her ağaç bir seçim yapar ve daha büyük bir oylama sonucunda son tahmine karar verilir, ki bu Şekil 3.6 ve 3.7’de gösterilmiştir. Ancak, yönlendirilmiş öğrenme için RO hesaplamasındaki T ağaçlarının sayısı müşteri tarafından belirlenmelidir. T’nin sadece hesaplama açısından makul olan en büyük değere mi ayarlanması gerektiği, yoksa daha mütevazı bir T’nin yeterli olup olmayacağı, hatta zaman zaman çok daha üstün olup olmayacağı gibi hususlar göz önünde bulundurulmalıdır (Probst vd., 2018).




Şekil 3.6 Rastgele orman (Tafralı, 2022)



Şekil 3.7 Rastgele orman modellerinde karar verme (Öztürk, 2022)

3.3.3.3 Çok katmanlı algılayıcı (ÇKA)

Çok katmanlı algılayıcılar (ÇKA'lar), standart geri yayılım algoritması ile eğitilen ileri beslemeli sinir ağı modelleridir. Eğitilmeleri için istenen çıktı değerlerine ihtiyaç duyarlar, böylece girdi verilerini istenen çıktılara nasıl dönüştüreceklerini öğrenebilirler. Değişken sayıda gizli katman ile neredeyse her türlü girdi-çıkı haritasını tahmin edebilirler. Zor problemlerde optimal istatistiksel sınıflandırıcıların performansını tahmin edebildikleri gösterilmiştir. Ağın içerdiği bileşenlerin her biri girdilerinin yanı sıra ağırlıklı toplamını gerçekleştirir ve hesaplanan değerleri çıktıları üretmek için bir transfer fonksiyonundan geçirir. Birimler katmanlı ileri beslemeli bir topolojide tasarlanmıştır (Şekil 3.8). ÇKA, fonksiyon karmaşıklığını belirleyen gizli katman sayısı ve her katmandaki nöron sayısı ile fonksiyonları modelleyebilir. Kullanılacak gizli katman sayısı, model için kullanılan veri türünün yanı sıra probleme de bağlıdır. En iyi başlangıç noktası, birim sayısı giriş ve çıkış birimlerinin toplamının yarısına eşit olan bir gizli katman kullanmaktır (Panchal vd., 2011).



Şekil 3.8 ÇKA yapısının gösterimi

Şekil 3.8’de giriş, gizli ve çıkış katmanlarındaki nöron sayıları sırasıyla M, N ve K olarak belirlenmiştir. Her gizli katmanda, her bir nöron, giriş katmanından gelen çıkış sinyallerinin ağırlıklı toplamını alır (Isokawa vd., 2012). Giriş katmanındaki n nöronun, gizli katmandaki m nörona olan bağlantı ağırlığı V_{nm} ile gösterilir. Gizli katmandaki nöronun çıkışı, X_n ve çıkış katmanındaki nöronun çıkışı Y_k , ağırlıklı toplamın belirli bir aktivasyon fonksiyonu ile hesaplanır. Bu aktivasyon fonksiyonu genellikle sigmoid, logistik veya hiperbolik tanjant olarak en yaygın olarak seçilir.

$$X_n = g(\sum_{m=1}^M V_{nm}Z_m) \quad (3.1)$$

$$Y_k = h(\sum_{n=1}^N W_{kn}X_n) \quad (3.2)$$

Öğrenme aşamasında, ağırlık değerleri $w_{ij(n)}$ çıkış katmanından elde edilen çıktı değerlerindeki hatayı minimize etmek için ayarlanır.

$$E_{SSE} = \frac{1}{2} \sum_p \sum_j \left(targ_j^p - out_j^{(N)p} \right)^2 \quad (3.3)$$

Denklemden, targ, out ve E sırasıyla istenilen çıktı, üretilen çıktı ve ağ tarafından üretilen hata miktarını temsil eder. Son adımda, ağıdaki ağırlık değerleri güncellenir.

$$\Delta w_{kl}^{(m)} = -\mu \frac{\partial E(\{w_{ij}^{(n)}\})}{\partial w_{kl}^{(m)}} \quad (3.4)$$

W_{ij} : Girişten gizli katmana

W_{jk} : Gizli katmandan çıkışa

(n) veya (m): Katman

Aynı yöntemi gerektiği kadar kullanarak, hata oranının artık azalmadığı bir noktaya ulaşılabilir ve ağda kullanılmak üzere optimum düzeyde ağırlıklar belirlenir (Yüksel 2019).

3.3.4 Performans Değerlendirme

Sınıflandırma algoritmalarının performanslarının değerlendirilmesi için sınıfların gerçek değerleri ve bir model tarafından elde edilen değerleri karışıklık matrisi formunda ele alınır (Polat vd., 2017). Bir makine öğrenmesi modelinin gerçekte pozitif olan sınıflardan doğru tahmin ettiklerinin sayısı Doğru Pozitif (DP), gerçekten negatif olan sınıflardan doğru tahmin ettiklerinin sayısı Doğru Negatif (DN) olarak ifade edilir. Gerçek negatif olan örneklerden, yanlış sınıflandırılanların sayısı Yanlış Pozitif (YP), gerçek pozitif olan örneklerden yanlış sınıflandırılanların sayısı da Yanlış Negatif (YN) olarak nitelendirilir (Tablo 3.6). Diğer bir deyişle, burada DP ve DN modelin doğru tahminlerini ifade ederken, YP ve YN modelin yanlış tahminlerini ifade eder. Bu matris temelli hesaplamaların yapıldığı Doğruluk, Duyarlılık, Özgüllük ve Kesinlik performans ölçütleri sırasıyla Denklem (3.5), (3.6), (3.7), (3.8)'de verilmiştir (Sürgüçoğlu, 2023).

		Tahminler	
		Negatif	Pozitif
Gerçekler	Negatif	DN	YP
	Pozitif	YN	DP

Şekil 3.9 Karışıklık matrisi

Doğruluk, doğru sınıflandırılan örneklerin tüm örneklere oranını veren genel bir sınıflandırma performansı ölçütüdür. Yangın olan alanlarda yangın var, yangın olmayan alanlarda yangın yok olarak tahmin edildiği örneklerin toplamının tüm örnek sayısına oranı ile elde edilen bir ölçüttür. Duyarlılık, gerçekte pozitif olan örneklerden ne kadarının doğru sınıflandırıldığı ölçümüdür. Özgüllük, negatif sınıftaki örneklerden ne kadarının doğru sınıflandırıldığı ölçümüdür. Son olarak, kesinlik, modelin pozitif sınıfa atanan örneklerden ne kadarının doğru sınıflandırıldığı ölçümüdür. Bu değerlendirme metrikleri, birçok sınıflandırma çalışmasında kullanılan oldukça önemli metriklerdir (Sürgüçoğlu, 2023).

$$\text{Doğruluk} = \frac{DP+DN}{DP+YP+DN+YN} \quad (3.5)$$


$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.6)$$

$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (3.7)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.8)$$

En yaygın kullanılan performans ölçütlerinden biri de alıcı işlem karakteristiği eğrisidir. AİK eğrisinde bulunan x eksenini YP oranını; y eksenini DP oranını vermektedir. Eğri altında kalan alan (EAKA), AİK eğrisinin altında kalan alanı ifade eder. Bu alanın

büyüklüğü bir modelin verilen sınıfları ayırt edebilme başarısını gösterir. İdeal değeri 1'dir. İşlem karakteristik eğrisi $Y=X$ fonksiyonuna yaklaştıkça başarısız bir test ortaya çıkar. AİK eğrisi grafiği Şekil 3.10'da verilmiştir. Bu şekildeki (0,0) ile (1,1) noktalarını birleştiren köşegen çizgi referans çizgisi olarak kabul edilir. En iyi tanı, doğru pozitif oranı yüksek ve yanlış pozitiflik oranı düşük olanıdır. Mükemmele çok yakın bir tanı hemen hemen (0,0)'dan (0,1)'e ve sonra yatayda (1,1)'den geçen bir işlem karakteristik eğrisine sahip olmalıdır (Tomak ve Yüksel, 2009).



Şekil 3.10 Alıcı işlem karakteristiği eğrisi

3.3.5 Öznitelik Seçimi

Özellik seçimi yaklaşımının, geniş bir veri madenciliği ve makine öğrenmesi problemleri yelpazesi için veri kümesini hazırlama sürecinde (özellikle yüksek boyutlu veri kümeleri için) etkili ve verimli olduğu gösterilmiştir. Özellik seçiminin amacı, veri kümesini basitleştirmek ve netleştirmek, veri madenciliğinin etkinliğini artırmak ve sınıflandırma modelleri için iyi bir temel sağlamaktır. Son zamanlardaki büyük veri yaygınlığı, özellik seçimi sorununu önemli zorluklar ve fırsatlarla karşı karşıya getirmiştir (Li vd., 2017). Makine öğrenmesi alanında, özellik seçimi stratejileri doğru modellerin geliştirilmesine dahil edilebilecek gözlemlenebilir niteliklerin en iyi olası çeşidini seçmek için kullanılır. Bu, her giriş faktörü ile hedef değeri arasındaki ilişkiyi değerlendirme kriterleri kullanarak incelemeyi ve en güçlü ilişkiye sahip değişkenleri

belirlemeyi içerir. Özellik seçimi, karar hassasiyetini artırmak, veri kümesinin boyutlarını en aza indirmek ve makine öğrenmesi eğitim sürecini hızlandırmak için uygulanır (Das vd., 2018). Bu çalışmada, veri kümesinde Özyinelemeli Özellik Eleme (ÖÖE) tekniği kullanılmıştır.

3.3.5.1 Özyinelemeli özellik eleme (ÖÖE)

ÖÖE, ilgi duyulan sınıflar arasında ayırıcı özelliklerin hangilerinin en yararlı olduğunu tahmin etmeye çalışan bir özellik seçimi stratejisidir. Sınıflandırma doğruluğunu kaybetmeden, giriş özellik kümesini en küçük geçerli sayıda katmana indirmek için gereksiz özellikleri elemeyi amaçlar. Bu yaklaşım, RO sınıflandırıcılar tarafından içsel olarak hesaplanan değişken anlamını değerlendirmeye dayanır ve birçok sınıflandırma turunu gerektirir. Her tur, yeni bir RO sınıflandırma modeli öğrenme, doğruluğunu değerlendirme, kullanılan her özelliğin önem ölçütlerini inceleme ve bir sonraki turda kullanılacak özellik kümesini güncelleme adımlarını içerir. Kategorizasyonun ilk turu, tüm mevcut özellikleri kullanır. Ardından, öğrenme sırasında model tarafından hesaplanan önem ölçütü değişkenini kullanarak en düşük performans gösterenler belirlenir. Daha sonra, en zayıf özelliklerden biri (veya daha fazlası) veri kümesinden çıkarılır ve işlemin bir sonraki aşamasına geçilir. Ayrıca, ÖÖE, giriş özelliklerindeki bağımlılıkları ve doğrusal ilişkiyi azaltmayı hedefler (Demarchi vd., 2020).

3.3.6 Deneysel Çalışma Ortamı

Bu çalışmada makine öğrenmesi tabanlı deneysel çalışmaları gerçekleştirmek için kullanılan makine, Intel Core İ7-10750H İşlemci 5.0 GHz işlemci, Nvidia RTX 2070-8 GB grafik işlemci birimi ve 16 GB RAM sistem özelliklerine sahiptir.

3.3.7 Deneysel Çalışmalar ve Önerilen Yaklaşım

Bu çalışma, orman yangınlarının tespiti için 2017-2022 yılları arasında Kastamonu Orman Bölge Müdürlüğü Taşköprü Orman İşletme Müdürlüğü Orman İşletme Şefliklerinde çıkan orman yangınları ile Taşköprü Orman İşletme Müdürlüğü içerisinde belirlenen yangın çıkmamış alanlara ait verileri ile derin öğrenme temelli modellerin karşılaştırmasını içerir.

3.3.8 Veri Seti


Deneyisel çalışmalarda yangın çıkan ve yangın çıkmamış alanlar ait veriler içeren bir veri seti kullanılmıştır. Veri setinde bulunan veriler Taşköprü Orman İşletme Müdürlüğü amenajman plan verileri ve ORBİS'ten alınmıştır. Taşköprü Orman İşletme Müdürlüğü 2017-2022 yılları arasında çıkan orman yangınlarından 271 adet veri vardır. Taşköprü Orman İşletme Müdürlüğü sınırları içerisinde alınan orman yangını çıkmamış yerlerden alınan veri sayısı 299 adet olup çalışmada toplam 570 adet veri kullanılmıştır. Veri setleri üzerinden 2 senaryo oluşturulmuştur. Yangın çıkan alan verileri yangının çıkış zamanındaki gerçek veriler olup yangın çıkmamış alanlarda sıcaklık, nisbi nem ve rüzgâr hızları üzerinden 2 senaryo oluşturulmuştur. Yangın çıkmamış alanlarda oluşturulan 1.senaryoda sıcaklık 20-30°C arası, nisbi nem %30-%50 arası ve rüzgâr hızı 10-30 km/ saat arası olacak şekilde veri seti oluşturulmuştur (EK-3). 2.senaryo ise sıcaklık 30°C yüksek, nisbi nem %30'un altında ve rüzgâr hızı da 30 km/sa'den yüksek olacak şekilde veri seti oluşturulmuştur (EK-4).

3.3.9 Model Eğitimi ve Testi

Her iki senaryoda iki farklı deneyisel çalışma yapılmıştır. Birinci deneyisel çalışmada veri setinin %30'u test için ayrılmıştır. Kalan kısmı ise eğitim seti olarak kullanılmıştır. İkinci deneyisel çalışmada ise veri setinin %40'ı test için ayrılırken kalan kısmı ise eğitim seti olarak kullanılmıştır. Birinci ve ikinci deneyisel çalışmalara ait veri setlerin dağılımı Tablo 3.6'da verilmiş ve Şekil 3.11'de grafiksel olarak gösterilmiştir.

Tablo 3.6 Birinci-ikinci deneyisel çalışmadaki eğitim ve test kümelerindeki örnek sayısı

Veri seti	Birinci Deneyisel Çalışma	İkinci Deneyisel Çalışma
Eğitim Seti	399	342
Test Seti	171	228
Toplam	570	570



Şekil 3.11 Birinci-ikinci deneysel çalışmadaki eğitim ve test kümelerindeki örnek sayısı

Her iki senaryoda da ÇKA, RO ve DVM kullanılarak makine öğrenmesi algoritmaları ile sınıflandırmalar gerçekleştirilmiştir.


4. BULGULAR

4.1 Çalışma Senaryosu-1


Yangın çıkmamış alanlarda oluşturulan bu senaryoda sıcaklık 20-30°C arası, nisbi nem %30-%50 arası ve rüzgâr hızı 10-30 km/ saat arası olacak şekilde veri seti oluşturulmuştur (EK-3). Veri setindeki diğer veriler olan meşcere verileri (kapalılık, meşcere çağları, ağaç türleri, bakısı, yüksekliği), Taşköprü Orman İşletme Müdürlüğü'nün şefliklerinden alınan verilerdir.

4.1.1 Birinci DeneySEL Çalışma


Çalışma senaryosu 1'in birinci deneySEL çalışma kapsamındaki veri seti sınıflandırma çalışmasında, test veri setindeki performansıyla ilgili doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.1'de gösterilmiştir. ÇKA modeli yangın var sınıfından 66 örneği doğru sınıflandırmışken 2 örneği yanlış sınıflandırmıştır. Diğer yandan bu model yangın yok sınıfından 100 örneğini doğru sınıflandırırken 3 yanlış sınıflandırma yapmıştır. RO modeli yangın var sınıfından 67 örneği doğru sınıflandırmışken 1 yanlış sınıflandırma yapmıştır. Diğer yandan bu model, yangın yok sınıfındaki tüm örnekleri doğru sınıflandırmıştır. DVM modeli ise yangın var sınıfından 66 örneği doğru sınıflandırmışken 2 yanlış sınıflandırma yapmıştır. Diğer yandan bu model, yangın yok sınıfındaki tüm örnekleri doğru sınıflandırmıştır (Şekil 4.1,4.2,4.3).



Şekil 4.1 Senaryo 1 deneysel çalışma 1 için ÇKA'nın karışıklık matrisi



Şekil 4.2 Senaryo 1 deneysel çalışma 1 için RO'nun karışıklık matrisi




Şekil 4.3 Senaryo 1 deneysel çalışma 1 için DVM'nin karışıklık matrisi

Tablo 4.1 Senaryo 1 deneysel çalışma 1 için performansların karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
ÇKA	97,08	97,06	97,09	95,65
RO	99,42	98,53	100	100
DVM	98,83	97,06	100	100

Bu makine öğrenmesi modellerinin yangın tahmin yeteneklerini objektif bir şekilde değerlendirebilmek için ayrıca Alıcı İşletim Karakteristiği kriteri kullanılmıştır. Şekil 4.4’de ÇKA, RO, DVM modellerinin AİK eğrilerini sunmaktadır. Alıcı İşletim Karakteristiği eğrisine göre tüm çalışma modelleri yüksek oranda başarı sağlamışlardır.




Şekil 4.4 Modellerin AİK eğrileri


4.1.2 İkinci Deneysel Çalışma

Çalışma senaryosu 1’in ikinci deneysel çalışma kapsamındaki veri seti sınıflandırma çalışmasında, test veri setindeki performansı ile ilgili doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.2’de gösterilmiştir. ÇKA modeli yangın var sınıfından 87 örneği doğru sınıflandırmışken 3 örneği yanlış sınıflandırmıştır. Diğer yandan bu model yangın yok sınıfından 130 örneğini doğru sınıflandırırken 8 yanlış sınıflandırma yapmıştır. RO modeli yangın var sınıfından 88 örneği doğru sınıflandırmışken 2 yanlış sınıflandırma yapmıştır. Diğer yandan bu model, yangın yok sınıfından 137 örneği doğru ve 1 yanlış sınıflandırma yapmıştır. DVM modeli ise yangın var sınıfından 88


örneği doğru sınıflandırmışken 2 yanlış sınıflandırma yapmıştır. Diğer yandan bu model, yangın yok sınıfından 137 örneği doğru ve 1 yanlış sınıflandırmıştır (Şekil 4.5,4.6,4.7).



Şekil 4.5 Senaryo 1 deneysel çalışma 2 için ÇKA'nın karışıklık matrisi



Şekil 4.6 Senaryo 1 deneysel çalışma 2 için RO'nun karışıklık matrisi




Şekil 4.7 Senaryo 1 deneysel çalışma 2 için DVM'nin karışıklık matrisi

Tablo 4.2 Senaryo 1 deneysel çalışma 2 için performansların karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
ÇKA	95,18	96,67	94,2	91,58
RO	98,68	97,78	99,28	98,88
DVM	98,68	99,28	97,78	98,56

Yapılan ikinci deneysel çalışmada makine öğrenmesi modellerinin yangın tahmin yeteneklerini objektif bir şekilde değerlendirebilmek için ayrıca Alıcı İşletim Karakteristiği kriteri kullanılmıştır. Şekil 4.8'de ÇKA, RO, DVM modellerinin AİK eğrilerini sunar. AİK eğrisine göre tüm çalışma modelleri yüksek oranda başarı sağlamışlardır.



Şekil 4.8 Modellerin AİK eğrileri

4.1.3 Çalışma Senaryosu-1 İçin Elde Edilen Sonuçlar


Çalışma senaryosu 1 için Özyinelemeli Özellik Eleme yöntemi kullanılarak yangın riskini belirlemede öne çıkan 5 parametre belirlenmiştir. Bu parametrelerden birinci sırada rüzgâr riski, ikinci sırada sıcaklık riski, üçüncü sırada nisbi nem riski, dördüncü sırada yerleşim yerinden uzaklık riski ve beşinci sırada su kaynaklarından uzaklık yer almıştır.

4.2 Çalışma Senaryosu-2


Yangın çıkmamış alanlarda oluşturulan bu senaryoda sıcaklık 30°C'den yüksek, nisbi nem %30'un altında ve rüzgâr hızı 30 km/ saatten yüksek olacak şekilde veri seti oluşturulmuştur (EK-4). Veri setindeki diğer veriler olan meşcere verileri (kapalılık, meşcere çağıları, ağaç türleri, bakısı, yüksekliği), Taşköprü Orman İşletme Müdürlüğü'nün şefliklerinden alınan verilerdir.

4.2.1 Birinci Deneysel Çalışma


Çalışma senaryosu 2'nin birinci deneysel çalışma kapsamındaki veri seti sınıflandırma çalışmasında, test veri setindeki performansa ilişkin doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.3'te gösterilmiştir. ÇKA modeli yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model yangın yok sınıfından 96 örneğini doğru sınıflandırırken 7 yanlış sınıflandırma yapmıştır. RO modeli yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model, yangın yok sınıfından 102 örneği doğru ve 1 yanlış sınıflandırma yapmıştır. DVM modeli ise yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model, yangın yok sınıfından 99 örneği doğru ve 4 yanlış sınıflandırmıştır (Şekil 4.9; 4.10; 4.11).



Şekil 4.9 Senaryo 2 deneysel çalışma 1 için ÇKA'nın karışıklık matrisi



Şekil 4.10 Senaryo 2 deneysel çalışma 1 için RO'nun karışıklık matrisi




Şekil 4.11 Senaryo 2 deneysel çalışma 1 için DVM'nin karışıklık matrisi

Tablo 4.3 Senaryo 2 deneysel çalışma 1 için performansların karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
ÇKA	95,91	100	93,2	90,67
RO	99,42	100	99,03	98,55
DVM	97,66	100	96,12	94,44

Bu makine öğrenmesi modellerinin yangın tahmin yeteneklerini objektif bir şekilde değerlendirebilmek için ayrıca Alıcı İşletim Karakteristiği kriteri kullanılmıştır. Şekil 4.12’de ÇKA, RO, DVM modellerinin AİK eğrilerini sunar. AİK eğrisine göre tüm çalışma modelleri yüksek oranda başarı sağlamışlardır.




Şekil 4.12 Modellerin AİK eğrileri


4.2.2 İkinci Deneysel Çalışma

Çalışma senaryosu 2’nin ikinci deneysel çalışma kapsamındaki veri seti sınıflandırma çalışmasında, test veri setindeki performansa ilişkin doğruluk, duyarlılık, özgüllük ve kesinlik değerleri Tablo 4.4’te gösterilmiştir. ÇKA modeli yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model yangın yok sınıfından 131 örneğini doğru sınıflandırırken 7 yanlış sınıflandırma yapmıştır. RO modeli yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model, yangın yok sınıfından 136 örneği doğru ve 2 yanlış sınıflandırma yapmıştır. DVM modeli ise yangın var sınıfındaki tüm örnekleri doğru sınıflandırmıştır. Diğer yandan bu model,


yangın yok sınıfından 130 örneği doğru ve 8 yanlış sınıflandırmıştır (Şekil 4.13; 4.14; 4.15).



Şekil 4.13 Senaryo 2 deneysel çalışma 2 için ÇKA'nın karışıklık matrisi



Şekil 4.14 Senaryo 2 deneysel çalışma 2 için RO'nun karışıklık matrisi




Şekil 4.15 Senaryo 2 deneysel çalışma 2 için DVM'nin karışıklık matrisi

Tablo 4.4 Senaryo 2 deneysel çalışma 2 için performansların karşılaştırılması

Model	Doğruluk	Duyarlılık	Özgüllük	Kesinlik
ÇKA	96,93	100	94,93	92,78
RO	99,12	100	98,55	97,83
DVM	96,49	100	94,2	91,84

Bu makine öğrenmesi modellerinin yangın tahmin yeteneklerini objektif bir şekilde değerlendirebilmek için ayrıca Alıcı İşletim Karakteristiği kriteri kullanılmıştır. Şekil 4.16'da ÇKA, RO, DVM modellerinin AİK eğrilerini sunar. AİK eğrisine göre tüm çalışma modelleri yüksek oranda başarı sağlamışlardır.



Şekil 4.16 Modellerin AİK eğrileri

4.2.3 Çalışma Senaryosu-2 İçin Elde Edilen Sonuçlar

Çalışma senaryosu 2 için Özyinelemeli Özellik Eleme yöntemi kullanılarak yangın riskini belirlemede öne çıkan 5 parametre belirlenmiştir. Bunlar sırası ile, birinci sırada bakı, ikinci sırada sıcaklık, üçüncü sırada tarım alanlarına uzaklık, dördüncü sırada yerleşim yerinden uzaklık ve beşinci sırada su kaynaklarından uzaklık yer almıştır.

4.3 Geliştirilen Uygulama

Makine öğrenmesi kullanılarak orman yangını riskinin tahmin edilmesi için bir Yangın Riski Tahmin Uygulaması geliştirilmiştir. Geliştirilen uygulamada, sınıflandırma algoritmalarından RO'nun deneysel çalışmalarda en yüksek doğruluk oranına ulaştığı için RO sınıflandırması kullanılmıştır. Bu uygulama, kullanıcının orman yangını riskini sorgulamak için temel kriterleri girebileceği bir kullanıcı dostu bir arayüz sunmaktadır. Kullanıcı, yangın riskini etkileyen kriterleri girdikten sonra, aynı uygulama üzerinden sonucu görüntülemektedir. Bu sonuç, kullanıcının girdiği tahmin parametrelerine dayalı olarak orman yangını riskini tahmin etmektedir.

Geliştirilen Yangın Riski Tahmin Uygulamasında, uygulamanın doğruluğunu test etmek amacıyla yangın çıkan alanlardan ve yangın çıkmayan alanlardan örnekler seçilmiştir (Tablo 4.5). Yangın çıkmamış alanlardan seçilen örneklerde rüzgâr hızı, sıcaklık ve nisbi nem değerleri, Çalışma Senaryosu-1 ve Çalışma Senaryosu-2'de belirtilen değerler arasında rastgele seçilmiştir. Yangın çıkan ve çıkmayan alanlardan seçilen örnekler, geliştirilen uygulamada kullanılarak birinci ve ikinci deneysel çalışma veri setleri test edilmiştir. Geliştirilen uygulama ile elde edilen sonuçlar aşağıdaki şekillerde gösterilmiştir (Şekil 4.17-4.28).

Tablo 4.5 Yangın çıkmış alandan örnek

SIRA	MESÇERE	AĞAÇ KODLARI	AĞAÇ TÜRLERİ	MESÇERE KAPALILIĞI	MESÇERE ÇAĞI	YÜKSEKLİK(m)	BAKİ	RÜZGAR HIZI(km/s)	SICAKLIK	NİSİ NEM	YERLEŞİM YERİNE OLAN UZAKLIK(m)	YOLA OLAN UZAKLIK(m)	TARIM ALANINA OLAN UZAKLIK(m)	SU KAYNAKLARINA OLAN UZAKLIK(m)	SENARYO	DeneySEL Çalışmalar	GERÇEK VERİ
1	Çkb3	Çk	Karaçam	b	3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	Birinci	Yangın çıkan alan
2	Çkbc3	Çk	Karaçam	bc	3	1065	Kuzey	22	28	35	2260	300	2300	500	1	Birinci	Yangın çıkmamış alan
3	Çkbc3	Çk	Karaçam	bc	3	1065	Kuzey	34	43	12	2260	300	2300	500	2	Birinci	Yangın çıkmamış alan
4	ÇkÇsbc3	ÇkÇs	Karaçam-Sarıçam	bc	3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	İkinci	Yangın çıkan alan
5	ÇkÇscd3	ÇkÇs	Karaçam-Sarıçam	cd	3	1200	Kuzey	28	22	37	240	80	290	910	1	İkinci	Yangın çıkmamış alan
6	ÇkÇscd3	ÇkÇs	Karaçam-Sarıçam	cd	3	1200	Kuzey	46	39	16	240	80	290	910	2	İkinci	Yangın çıkmamış alan

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü: Karacam

Meşcere Çağı: b

Kapallık: 3

Yükseklik: 1140

Bakı: Güneydoğu

Rüzgar Hızı (km/s): 16

Sıcaklık Riski: 36

Nisbi Nem: 20

Tarım Alanına Olan Uzaklık (metre): 270

Yola Olan Uzaklık (metre): 370

Yerleşim Yerne Olan Uzaklık (metre): 480

Su Kaynaklarına Olan Uzaklık (metre): 2610

Risk Tahmini Yap

Şekil 4.17 Çalışma senaryosu-1 ve birinci deneySEL çalışmada uygulama testi

Yangin Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam
Meşcere Çağı:	b
Kapalılık:	3
Yükseklik:	1140
Bakı:	Güneydoğu
Rüzgar Hızı (km/s):	16
Sıcaklık Riski:	36
Nisbi Nem:	20
Tarım Alanına Olan Uzaklık (metre):	270
Yola Olan Uzaklık (metre):	370
Yerleşim Yeri Olan Uzaklık (metre):	480
Su Kaynaklarına Olan Uzaklık (metre):	2610

Risk Tahmini Yap

Sonuç

%97.61 olasılıkla YANGIN RİSKİ VARDIR!

Şekil 4.18 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama test sonucu

Yangin Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam
Meşcere Çağı:	bc
Kapalılık:	3
Yükseklik:	1065
Bakı:	Kuzey
Rüzgar Hızı (km/s):	22
Sıcaklık Riski:	28
Nisbi Nem:	35
Tarım Alanına Olan Uzaklık (metre):	2300
Yola Olan Uzaklık (metre):	300
Yerleşim Yeri Olan Uzaklık (metre):	2260
Su Kaynaklarına Olan Uzaklık (metre):	500

Risk Tahmini Yap

Şekil 4.19 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama testi

Yangin Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam
Meşcere Çağı:	bc
Kapallık:	3
Yükseklik:	1065
Bakı:	Kuzey
Rüzgar Hızı (km/s):	22
Sıcaklık Riski:	28
Nisbi Nem:	35
Tarım Alanına Olan Uzaklık (metre):	2300
Yola Olan Uzaklık (metre):	300
Yerleşim Yerine Olan Uzaklık (metre):	2260
Su Kaynaklarına Olan Uzaklık (metre):	500

Risk Tahmini Yap

Sonuç

%89.355 olasılıkla YANGIN RİSKİ YOKTUR!

Şekil 4.20 Çalışma senaryosu-1 ve birinci deneysel çalışmada uygulama test sonucu

Yangin Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam
Meşcere Çağı:	bc
Kapallık:	3
Yükseklik:	1065
Bakı:	Kuzey
Rüzgar Hızı (km/s):	34
Sıcaklık Riski:	43
Nisbi Nem:	12
Tarım Alanına Olan Uzaklık (metre):	2300
Yola Olan Uzaklık (metre):	300
Yerleşim Yerine Olan Uzaklık (metre):	2260
Su Kaynaklarına Olan Uzaklık (metre):	500

Risk Tahmini Yap

Şekil 4.21 Çalışma senaryosu-2 ve birinci deneysel çalışmada uygulama testi

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam
Meşcere Çağı:	bc
Kapalılık:	3
Yükseklik:	1065
Bakı:	Kuzey
Rüzgar Hızı (km/s):	34
Sıcaklık Riski:	43
Nisbi Nem:	12
Tarım Alanına Olan Uzaklık (metre):	2300
Yola Olan Uzaklık (metre):	300
Yerleşim Yeri Olan Uzaklık (metre):	2260
Su Kaynaklarına Olan Uzaklık (metre):	500

Risk Tahmini Yap

Sonuç

%99.93 olasılıkla YANGIN RİSKİ YOKTUR!

Şekil 4.22 Çalışma senaryosu-2 ve birinci deneysel çalışmada uygulama test sonucu

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam-Sarıçam
Meşcere Çağı:	bc
Kapalılık:	3
Yükseklik:	1140
Bakı:	Güneydoğu
Rüzgar Hızı (km/s):	16
Sıcaklık Riski:	36
Nisbi Nem:	20
Tarım Alanına Olan Uzaklık (metre):	270
Yola Olan Uzaklık (metre):	370
Yerleşim Yeri Olan Uzaklık (metre):	480
Su Kaynaklarına Olan Uzaklık (metre):	2610

Risk Tahmini Yap

Şekil 4.23 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama testi

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karaçam-Sarıçam
Meşcere Çağı:	bc
Kapallık:	3
Yükseklik:	1140
Bakı:	Güneydoğu
Rüzqar Hızı (km/s):	16
Sıcaklık Riski:	36
Nisbi Nem:	20
Tarım Alanına Olan Uzaklık (metre):	270
Yola Olan Uzaklık (metre):	370
Yerleşim Yeri Olan Uzaklık (metre):	480
Su Kaynaklarına Olan Uzaklık (metre):	2610

Risk Tahmini Yap

Sonuç

%97.61 olasılıkla YANGIN RİSKİ VARDIR!

Şekil 4.24 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama test sonucu

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karaçam-Sarıçam
Meşcere Çağı:	cd
Kapallık:	3
Yükseklik:	1200
Bakı:	Kuzey
Rüzqar Hızı (km/s):	28
Sıcaklık Riski:	22
Nisbi Nem:	37
Tarım Alanına Olan Uzaklık (metre):	290
Yola Olan Uzaklık (metre):	80
Yerleşim Yeri Olan Uzaklık (metre):	240
Su Kaynaklarına Olan Uzaklık (metre):	910

Risk Tahmini Yap

Şekil 4.25 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama testi

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam-Sarıcam
Meşcere Çağı:	cd
Kapallık:	3
Yükseklik:	1200
Bakı:	Kuzey
Rüzgar Hızı (km/s):	28
Sıcaklık Riski:	22
Nisbi Nem:	37
Tarım Alanına Olan Uzaklık (metre):	290
Yola Olan Uzaklık (metre):	80
Yerleşim Yeri Olan Uzaklık (metre):	240
Su Kaynaklarına Olan Uzaklık (metre):	910

Risk Tahmini Yap

Sonuç

%98.62 olasılıkla YANGIN RİSKİ YOKTUR!

Şekil 4.26 Çalışma senaryosu-1 ve ikinci deneysel çalışmada uygulama test sonucu

Yangın Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam-Sarıcam
Meşcere Çağı:	cd
Kapallık:	3
Yükseklik:	1200
Bakı:	Kuzey
Rüzgar Hızı (km/s):	46
Sıcaklık Riski:	39
Nisbi Nem:	16
Tarım Alanına Olan Uzaklık (metre):	290
Yola Olan Uzaklık (metre):	80
Yerleşim Yeri Olan Uzaklık (metre):	240
Su Kaynaklarına Olan Uzaklık (metre):	910

Risk Tahmini Yap

Şekil 4.27 Çalışma senaryosu-2 ve ikinci deneysel çalışmada uygulama testi

Yangin Riski Tahmin Uygulaması

Veri Giriş Ekranı

Ağaç Türü:	Karacam-Sarıcam
Meşcere Çağı:	cd
Kapalık:	3
Yükseklik:	1200
Bakı:	Kuzey
Rüzgar Hızı (km/s):	46
Sıcaklık Riski:	39
Nisbi Nem:	16
Tarım Alanına Olan Uzaklık (metre):	290
Yola Olan Uzaklık (metre):	80
Yerleşim Yeri Olan Uzaklık (metre):	240
Su Kaynaklarına Olan Uzaklık (metre):	910

Risk Tahmini Yap

Sonuç

%91.01 olasılıkla YANGIN RİSKİ YOKTUR!

Şekil 4.28 Çalışma senaryosu-2 ve ikinci deneysel çalışmada uygulama test sonucu

5. TARTIŞMA, SONUÇ VE ÖNERİLER

5.1 Tartışma

Yapılan çalışmada deneysel olarak verilerin analiz edildiğinde yangın riskini etkileyen temel parametrelerin meteorolojik parametreler ile insan faaliyetlerinin yoğun olduğu yerleşim yeri parametreleri olduğu görülmektedir. Nitekim yangının başlamasında ve gelişmesinde sıcaklık ve rüzgâr hızının çok etkili olduğu çok sayıda çalışmada belirtilmektedir. Bu çalışmada da rüzgâr hızı ile sıcaklık değerinin yangın riskinin etkileyen en önemli iki parametre olarak ilk iki sırada yer aldığı görülmektedir. Bu hususu şu şekilde açıklamak mümkündür. Sıcaklık özellikle yangının başladığı ince yanıcı maddelerdeki nem içeriğini hızlı bir şekilde düşürmekte ve tutuşturmayı kolaylaştırmaktadır. Bu durum aynı zamanda yangın riskinin artırmaktadır. Diğer önemli bir parametre olan rüzgâr hızı ise bir taraftan kurutucu etki yaparken diğer taraftan çıkan yangının kısa sürede geniş alanlarda etkili olmasına sebep olmaktadır. Çalışma sonuçlarının literatür (Saglam vd., 2008, Sivrikaya ve Kucuk, 2022) ile uyumlu olduğunu ifade etmek mümkündür.

Yine çalışmanın en önemli çıktılarından birisi de yerleşim yerlerine olan mesafe ile tarım alanlarına olan mesafenin yangın riskini artıran önemli parametreler olduğudur. Zira yerleşim yerlerinin orman alanlarına olan yakınlığı ve tarım alanlarının orman alanlarına bitişik olması veya çok yakın olması bu alanlarda insan faktörüne bağlı kamp ateşi, sönmemiş sigara ve anız yangınları gibi hususlar yangın riskinin önemli derecede artırdığı görülmektedir. Nitekim çalışmanın bulgularına benzer şekilde bulguların elde edildiği söylenebilir. Vilar vd., (2010) çıkan orman yangınlarının doğrudan ya da dolaylı olarak insan faaliyetleri ile doğrudan ilişkili olduğunu, orman alanlarının yerleşim yerlerine bitişik veya tarım arazilerine yakın konumlanmış olmasının yangın riskini artırdığını ifade etmektedir. Bununla beraber başka çalışmalarda da bu çalışma sonuçlarına benzer sonuçlara ulaşılmıştır. Ormanların yollara, su kaynaklarına, tarım alanlarına ve yerleşim yerlerine yakınlığı yangın tutuşma potansiyelini artırdığı (Hoang vd., 2020; Sari, 2021; Satir vd., 2016), nüfus yoğunluğunun da orman yangını riskini etkileyen önemli bir faktör olduğu ve yoğun

nüfuslu bölgelere yakın ormanların yangına karşı daha hassas olduğu sonuçlarına ulaşılmıştır (Akbulak vd., 2018; Güngöroğlu, 2017).

Orman yangını riskinin tahmininde makine öğrenmesi, çeşitli faktörleri analiz ederek gelecekteki olası yangınları öngörmek için önemli bir araç haline gelmiştir (Özdemir vd., 2019). Bu teknoloji, karmaşık veri setlerini analiz ederek gelecekteki yangın risklerini belirleme konusunda büyük potansiyele sahiptir. Makine öğrenmesi modelleri, hava durumu verileri, arazi topografyası, bitki örtüsü türleri ve insan faaliyetleri gibi çeşitli girdi değişkenlerini kullanarak yangın riskini belirleyebilirler (Chen vd., 2020). Örneğin, hava durumu verilerinin (sıcaklık, nem, rüzgâr hızı) yangın olasılığını etkileyebileceği ve arazi topografyası (eğim, yükseklik) ve bitki örtüsü türlerinin (meşcere özellikleri) yangının yayılma hızını etkileyebileceği gösterilmiştir (Özdemir vd., 2019). Yapılan bu çalışmada da yapay zekâ tekniklerinden olan makine öğrenmesi kullanılarak orman yangınları riskinin tahmin edilmesi başarılı bir şekilde gerçekleştirilmiştir. Sadece yangın riski üzerinde etkili olan parametreler değil, aynı zamanda bu parametreler önem derecesine göre de sıralanmıştır.

Önceki araştırmalardan elde edilen bulgulara bakarak makine öğrenmesi yöntemlerinin orman yangını riskinin tahminindeki çalışmalar değerlendirildiğinde; Smith vd. (2018) orman yangınlarının tespiti için derin öğrenme yöntemlerini kullanmışlar olup yapılan çalışmada, derin öğrenme algoritmalarının yangın tespiti ve sınıflandırmasında diğer geleneksel yöntemlere kıyasla daha yüksek performans vermiştir. Nitekim yapılan bu çalışmada yangın riskinin belirlenmesi için makine öğrenmesi olarak ÇKA, RO ve DVM kullanılmıştır. Makine öğrenmesi ile yapılan deneysel çalışmalar en az %94'lik doğruluk oranına ulaşılmıştır. Makine öğrenmesi tekniği ile uzaktan algılama verilerinin entegre edilmesi karar vericilere çok büyük kolaylık sağlamaktadır. Bu çalışmada Uzaktan algılama verilerinin entegrasyonu yapılmamıştır. Ancak uzaktan algılama verilerinin (örneğin, uydu görüntüleri) kullanımının, yangın riski tahmininde doğruluğu artırdığını ve makine öğrenmesi modellerinin performansını iyileştirdiği de literatürde belirtilmektedir.

Bu çalışma ile makine öğrenmesi tekniği ile veriler arasındaki karmaşık ilişkiler çalışılmış ve geniş veri seti etkili bir şekilde kullanılmıştır. Sözgelimi meteorolojik

parametreler, topografik faktörler, meşcere özellikleri ve insan etkileşimleri gibi birçok değişken aynı anda değerlendirilmiş ve yangın riski daha doğru bir şekilde tahmin edilmeye çalışılmıştır. Bununla beraber makine öğrenmesi modellerinin bazı sınırlamalarının olduğunu da unutmamak gerekir. Bu modeller, yalnızca mevcut veri setlerinde bulunan bilgilere dayanarak tahminler yapabilmektedirler. Ayrıca, makine öğrenmesi modelleri genellikle eğitim verilerindeki örüntülere sıkı sıkıya bağlı olabilmekte bu da yeni veya beklenmeyen durumlarda doğruluklarını etkileyebilmektedir.

Özetle; bu çalışmada da meşcere kriterlerinden ağaç türü, iklim kriterlerinden rüzgâr hızı, topografya kriterlerinden bakı, çevresel kriterlerden yola olan uzaklık, yerleşim yerine olan uzaklık ve suya olan uzaklık riski ile orman yangını riskini etkileyen en önemli kriterler olarak çevre kriterleri belirlenmiştir. Sonuç olarak, makine öğrenmesi orman yangını riskinin tahmininde önemli bir araç olabilir, ancak tek başına yeterli değildir. İnsan uzmanlığı ve yerel bilgi de önemlidir. Makine öğrenmesi modelleri, insanların karar alma sürecini desteklemek için kullanılabilir, ancak kesin kararlar almadan önce dikkatle değerlendirilmelidir. Bu, daha doğru ve güvenilir yangın riski tahminleri sağlayabilir ve yangın önleme ve müdahale çabalarını güçlendirebilir.

5.2 Sonuç ve Öneriler

Makine öğrenmesi, orman yangını riskinin tahmininde etkili bir araç olarak görülmektedir. Bu çalışmada, makine öğrenmesi tekniklerinin orman yangını riskinin tahminindeki önemini incelenmiş ve literatürdeki mevcut bulguları değerlendirilmiştir. Bu tez çalışmasında, ilgili konuda yapılan araştırmalara ve gelecekteki uygulamalara ışık tutmak amacıyla orman yangınlarının tahminine yönelik olarak veri seti üzerinden makine öğrenmesi modelleri geliştirilmiştir. Geliştirilen makine öğrenim modelleri üzerinden uygulama geliştirilmiş ve geliştirilen uygulama test edilerek başarı sonuçları alınmıştır.

Yapılan çalışmada orman yangını riskini tahmin etmek için bir makine öğrenmesi algoritması geliştirilmiştir. Orman yangını riskinin tahmininde paydaşların karşılaştığı zorlukları belirlemek için ilgili kuramsal çerçeve gözden geçirilmesi gerekmiştir.

Çalışmanın temel amacı, orman yangınlarını tahmin etmek için bir makine öğrenmesi modeli geliştirmektir. Bunun için bir dizi süreç uygulanmış ve Kastamonu Orman Genel Müdürlüğü sınırları içerisinde ki Taşköprü Orman İşletme Müdürlüğü'nde 2017 ile 2022 tarihleri arasındaki gerçekleşen orman yangınlarının veriler toplanmıştır. Orman yangınlarına sebep olan faktörler ve katkıda bulunan tüm ana bileşenler dikkate alınmıştır. Veri ön işleme adımları uygulanmış, veri eğitim ve test setlerine ayrılmıştır. Veriler, ÇKA, RO ve DVM modellerinde için kullanılmıştır. Modeller en az %95'lik doğruluk oranına ulaşmıştır. ÖÖE yöntemi kullanılarak yangın riskini belirlemede öne çıkan önemli nitelikler belirlenmiştir. Kullanılan yöntemde rüzgâr hızı, bakı, sıcaklık, nisbi nemi, yerleşim yerinden uzaklık, su kaynaklarından uzaklık ve tarım alanlarına uzaklık nitelikleri ön plana çıkmıştır.

Bu çalışma, makine öğrenmesi algoritmaları orman yangınlarını tahmin etmek için kullanılabileceğini göstermektedir. Bu, eski yöntemler ve eski teknolojilerin kullanımı yerine, Orman Genel Müdürlüğü'ne yardımcı olarak orman yangınlarını önleme ve müdahale konusunda potansiyel bir destek sağlayabilir. Orman yönetimi paydaşları, sistemin tahminlerine dayanarak etkili ve uygulanabilir önlemler alabilir. Daha iyi tahmin sonuçları için büyük bir veri setinin kullanılması ve modelin performansını artırmak için eğitim verilerinin boyutunu artırmak gereklidir. Bu öneriler, modelin daha güçlü ve güvenilir tahminler yapabilmesi için çalışmanın geliştirilmesine katkı sağlayabilir.

KAYNAKLAR

- Abdollahi, A., & Pradhan, B. (2023). Explainable artificial intelligence (XAI) for interpreting the contributing factors feed into the wildfire susceptibility prediction model. *Science of the Total Environment* 879 (2023) 163004. : www.elsevier.com/locate/scitotenv
- Abid, F., 2021. A survey of machine learning algorithms based forest fires prediction and detection systems. *Fire Technol.* 57, 559–590. <https://doi.org/10.1007/s10694-020-01056-z> .
- Ahuja, S & Angra, S., (2017). Machine learning and its Applications: A Review. In *2017 International Conference on Big Data Analytics and Computational Intelligence (ICBDAC)* (pp. 57-60). IEEE.
- Akay, A. E., & Erdoğan, A. (2017). GIS-based multi-criteria decision analysis for forest fire risk mapping. In *4Th International Geoadvances Workshop Geoadvances 2017: Isprs Workshop On Multi-Dimensional & Multi-Scale Spatial Data Modeling*. Copernicus Gesellschaft Mbh.
- Akay, A. E., & Şahin, H. (2019). Forest fire risk mapping by using GIS techniques and AHP method: A case study in Bodrum (Turkey). *European Journal of Forest Engineering*, 5(1), 25-35.
- Akay, A. E., Sessions, J., Bettinger, P., Toupin, R., & Eklund, A. (2006). Evaluating the salvage value of fire-killed timber by helicopter-effects of yarding distance and time since fire. *Western Journal of Applied Forestry*, 21(2), 102-107.
- Akay, A. E., Wing, M. G., Sivrikaya, F., & Sakar, D. (2012). A GIS-based decision support system for determining the shortest and safest route to forest fires: a case study in Mediterranean Region of Turkey. *Environmental monitoring and assessment*, 184, 1391-1407.
- Akbulak, C., Tatlı, H., Aygün, G., & Sağlam, B. (2018). Forest fire risk analysis via integration of GIS, RS and AHP: The Case of Çanakkale, Turkey. *Journal of Human Sciences*, 15(4), 2127-2143.
- Akçay, S., Atasever, Ü. H., Yar, M., & Çetin, M. (2020). Challenges in using machine learning models for forest fire risk estimation. In *2020 4th International Symposium on Multidisciplinary Studies and Innovative Technologies (ISMSIT)* (pp. 1-4). IEEE
- Alexander, M.E., & Cruz, M.G., (2006). Evaluating a model for predicting active crown fire rate of spread using wildfire observations. *Can. J. For. Res.* 36, 3015–3028.

- Alhaj-Khalaf, M.W., Shataee-Jouibary, S., Jahdi, R., & Bacciu, V., (2021). Improved forest fire spread mapping by developing custom fire fuel models in replanted forests in Hyrcanian forests. Iran. *Forest Systems* 30 (2), e008.
- Alkhatib, R., Sahwan, W., Alkhatieb, A., & Schütt, B. (2023). A Brief Review of Machine Learning Algorithms in *Forest Fires Science*. Appl. Sci. 2023, 13, 8275. <https://doi.org/10.3390/app13148275>.
- Alonso-Betanzos, A., Fontenla-Romero, O., Guijarro-Berdiñas, B., Hernández-Pereira, E., Canda, J., Jimenez, E., Legido J. L., Muniz, S., Paz-Andrade C., Paz-Andrade, M. I., (2002). A neural network approach for forestal fire risk estimation. In: *Proceedings of the 15th European Conference on Artificial Intelligence*, IOS Press, pp. 643–647.
- Anandaram, H., Nagalakshmi, M. Borda, R.F.C. Kiruthika K., & Yogadinesh S. (2023). *Forest fire management using machine learning techniques. Measurement: Sensors* 25 (2023) 100659. www.sciencedirect.com/journal/measurement-sensors.
- Aricak, B., Kucuk, O., & Enez, K., (2014). Determination of pumper truck intervention ratios in zones with high fire potential by using geographical information system. *J. Appl. Remote Sens.* 8 (1), 083598 <https://doi.org/10.1117/1.JRS.8.083598>.
- Atmaca, İ. Derakhshandeh, M. Pekkan Ö.I. Kavlak, M.Ö. Tunca, Y.S. & Çabuk, S.N. (2022). Lojistik Regresyon ve Coğrafi Bilgi Sistemleri Kullanılarak Orman Yangını Risk Modellemesi: Muğla-Milas Örneği. Araştırma Makalesi / Research Article, *Doğ Afet Çev Derg*, 8(1): 66-75, DOI: 10.21324/dacd.951902
- Bakhtiar F., Davoud O., Vahid M., Hoda K., Ayyoob S. & Bahaoldein G. K. (2023). An integrated approach of artificial intelligence and geoinformation techniques applied to forest fire risk modeling in Gachsaran, Iran, *Journal of Environmental Planning and Management*, 66(6), 1369-1391, DOI: 10.1080/09640568.2022.2027747.
- Başer, B. Ö., Yangın, M., & Sarıdaş, E. S (2021). Makine Öğrenimi Teknikleriyle Diyabet Kullanımının Sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25(1), 112-120.
- Bentekhici, N., Bellal, S. A., & Zegrar, A. (2020). Contribution of remote sensing and GIS to mapping the fire risk of Mediterranean forest case of the forest massif of Tlemcen (North-West Algeria). *Natural Hazards*, 104(1), 811-831.
- Biau, G. & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197– 227. doi: 10.1007/s11749-016-0481-7.
- Bilgili, E., Coskuner, K.A., Usta, Y., Saglam, B., Kucuk, O., Berber, T., & Goltas, M., (2019). Diurnal surface fuel moisture prediction model for Calabrian pine stands in Turkey. *iForest* 12, 262–271. <https://doi.org/10.3832/for2870-012>.
- Bilgili, E., Küçük, O., Saglam, B., & Coskuner, A., (2021). Mega forest fires: causes, organization and management. *Science and Thought Series* 33, 1–23.

- Bilgili, E., Saglam, B., 2003. Fire behavior in maquis fuels in Turkey. *Forest Ecology and Management* 184 (1–3), 201–207. [https://doi.org/10.1016/S0378-1127\(03\)00208-1](https://doi.org/10.1016/S0378-1127(03)00208-1).
- Blum, A. (2021). *Machine learning theory*. <http://www.cs.cmu.edu/afs/cs/user/avrim/www/Talks/mlt.pdf>, Erişim Tarihi: 07/01/2021.
- Bonora, L., Conese, C. C., Marchi, E., Tesi, E., & Montorselli, N. B. (2013). Wildfire occurrence: Integrated model for risk analysis and operative suppression aspects management. *American Journal of Plant Sciences*, 4, 705–710.
- Breiman L., C. A. (2001). Random forests, machine learning. *Kluwer Academic Publishers*, 45(1), 5-32.
- Bulut, E., & Yörük, E. (2017). Mediatized populisms Digital populism: Trolls and political polarization of Twitter in Turkey. *International Journal of Communication*, 11, 25.
- Butler, B. W., Anderson, W. R., & Catchpole, E. A. (2007). *Influence of slope on fire spread rate*. The Fire Environment Innovations, Management, and Policy, 75-83.
- Carmo, M., Moreira, F., Casimiro, P., & Vaz, P., (2011). Land use and topography influences on wildfire occurrence in northern Portugal. *Landscape Urban Plann.* 100 (1), 169–176. <https://doi.org/10.1016/j.landurbplan.2010.11.017>
- Castedo-Dorado, F., Rodríguez-Pérez, J.R., Marcos-Menéndez, J.L., & Álvarez-Taboada, M.F., (2011). Modelling the probability of lightning-induced forest fire occurrence in the province of León (NW Spain). *For. Syst.* 20 (1), 95–107.
- Castro, R., & Chuvieco, E. (1998). Modeling forest fire danger from geographic information systems. *Geocarto International*, 13(1), 15-23.
- Cencerrado, A., Cortés, A., & Margalef, T., 2014. Response time assessment in forest fire spread simulation: an integrated methodology for efficient exploitation of available prediction time. *Environ. Model Softw.* 54, 153–164. <https://doi.org/10.1016/j.envsoft.2014.01.008>.
- Chen, F., Du, Y., Niu, S., & Zhao, J., (2015). Modeling forest lightning fire occurrence in the Daxinganling mountains of Northeastern China with MAXENT. *Forests* 6 (5), 1422–1438. <https://doi.org/10.3390/f6051422>.
- Chen, Y., Zhang, S., Yan, X., & Wang, H. (2020). *Forest Fire Prediction Based on Machine Learning: A Comprehensive Review*. IEEE Access, 8, 70760-70775.
- Chetehouna, K., El Tabach, E., Bouazaoui, L., & Gascoin, N., (2015). *Predicting the flame characteristics and rate of spread in fires propagating in a bed of Pinus pinaster using Artificial Neural Networks*. Process Saf. Environ. Prot. 98, 50–56.

- Chuvieco, E., & Salas, J., (1996). Mapping the spatial distribution of forest fire danger using GIS. *Int. J. Geogr. Inf. Sci.* 10 (3), 333–345. <https://doi.org/10.1071/WF05091> .
- Cruz, M.G., & Alexander, M.E., (2019). The 10% wind speed rule of thumb for estimating a wildfire's forward rate of spread in forests and shrublands. *Ann. For. Sci.* 76, 44. <https://doi.org/10.1007/s13595-019-0829-8>.
- Cruz, M.G., Alexander, M.E., & Plucinski, M.P., (2017). The effect of silvicultural treatments on fire behaviour potential in radiata pine plantations of South Australia. *For. Ecol. Manage.* 397, 27–38.
- Cruz, M.G., Cheney, N.P., Gould, J.S., McCaw, L., Kilinc, M., & Sullivan, A.L., (2022). An empirical-based model for predicting the forward spread rate of wildfires in eucalypt forests. *Int. J. Wildland Fire* 31 (1), 81–95.
- Çoban, H., & Erdin, C. (2020). Forest fire risk assessment using GIS and AHP integration in Bucak Forest Enterprise, Turkey. *Applied Ecology and Environmental Research*, 18(1), 1567–1583.
- Çolak, E., & Sunar, F. (2020). Evaluation of forest fire risk in the Mediterranean Turkish forests: A case study of Menderes region, Izmir. *International Journal of Disaster Risk Reduction*, 45, 101479.
- Das, A. K., Sengupta, S., & Bhattacharyya, S. (2018). A group incremental feature selection for classification using rough set theory based genetic algorithm. *Applied Soft Computing*, 65, 400-411.
- Demarchi, L., Kania, A., Cieżkowski, W., Piórkowski, H., OświecimskaPiasko, Z., & Chormański, J. (2020). Recursive feature elimination and random forest classification of natura 2000 grasslands in lowland river valleys of poland based on airborne hyperspectral and LiDAR data fusion. *Remote Sensing*, 12 (11), 1842.
- Dimitrakopoulos, A. P., Bemmerzouk, A. M., & Mitsopoulos, I. D. (2011). Evaluation of the Canadian fire weather index system in an eastern Mediterranean environment. *Meteorological Applications*, 18(1), 83-93.
- Dlamini, W.M., (2011). Application of Bayesian networks for fire risk mapping using GIS and remote sensing data. *GeoJournal* 76 (3), 283–296. <https://doi.org/10.1007/s10708-010-9362-x> .
- Dong, X., Shao, G., Limin, D., Zhanging, H., Lei, T., & Hui, W. (2006). Mapping forest fire risk zones with spatial data and principal component analysis. *Science in China Series E: Technological Sciences*, 49(1), 140-149.
- Duran, C. & İmat, F. (2016). https://www.researchgate.net/publication/313786160_taskopru_ilcesinde_kastamonu_kademelendirilmis_yukseltilere_gore_a_razı_kullanımı
- DZone, Al. (2013). *The Artificial Neural Networks Handbook: Part 4*

- Erten, E., Kurgun, V., & Musaoğlu, N. (2005). Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Kullanarak Orman Yangını Bilgi Sisteminin Kurulması, *TMMOB Harita ve Kadastro Mühendisleri Odası 10. Türkiye Harita Bilimsel ve Teknik Kurultayı*. Ankara.
- Fernandes, P.M., (2009). Combining forest structure data and fuel modelling to classify fire hazard in Portugal. *Ann. For. Sci.* 66 (4), 415.
- Fidanboy, M., Adar, N. & Okyay, S. (2022). Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması. *Ormancılık Araştırma Dergisi*, 9 (2), 206-218.DOI: 10.17568/ogmoad.1066557
- Finney, M.A., Grenfell, I.C., McHugh, C.W., Seli, R.C., Trethewey, D., Stratton, R.D., & Brittain, S., (2011). *A method for ensemble wildland fire simulation*. Environ. Model. Assess. 16, 153–167. <https://doi.org/10.1007/S10666-010-9241-3> .
- Fryer, G.I., &Johnson, E.A., (1988). Reconstructing fire behaviour and effects in a subalpine forest. *J. Appl. Ecol.* 1063–1072.
- Ganteaume, A., & Jappiot, M., (2013). What causes large fires in Southern France. *For. Ecol. Manage.* 294, 76–85. <https://doi.org/10.1016/j.foreco.2012.06.055> .
- Gao, X., Fei, X., & Xie, H. (2011, June). Forest fire risk zone evaluation based on high spatial resolution RS image in Liangyungang Huaguo Mountain Scenic Spot. In *Proceedings 2011 IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services* (pp. 593-596). IEEE.
- George, E. & Sakr, I. H. (2010). *Artificial Intelligence for Forest Fire Prediction. Advanced Intelligent Mechatronics* (s. 1-6). Montréal, Canada: IEEE/ASME
- Gerdzheva, A. A. (2014). A comparative analysis of different wildfire risk assessment models (a case study for Smolyan district, Bulgaria). *European Journal of Geography*, 5(3), 22-36.
- Ghobadi, G. J., Gholizadeh, B., & Dashliburun, O. M. (2012). Forest fire risk zone mapping from geographic information system in Northern Forests of Iran (Case study, Golestan province). *International Journal of Agriculture and Crop Sciences*, 4(12), 818-824.
- Goldarag, Y.J., Mohammadzadeh, A., & Ardakani, A.S., (2016). Fire risk assessment using neural network and logistic regression. *J. Indian Soc. Remote Sens.* 44, 885–894. <https://doi.org/10.1007/s12524-016-0557-6> .
- Goltas, M., Kucuk, O., Ayberk, H., & Akkuzu, E., (2017). Global Climate Change and Forest Fires. In: Fakir, H. (Ed.), *International Symposium on New Horizons in Forestry. Proceedings & Abstracts Book*, Süleyman Demirel University, Isparta-Turkey, pp. 387.
- Gret-Regamey, A., & Straub, D., (2006). Spatially explicit avalanche risk assessment linking Bayesian networks to a GIS. *Nat. Hazards Earth Syst. Sci.* 6 (6), 911–926. <https://doi.org/10.5194/nhess-6-911-2006> .

- Güngöroğlu, C. (2017). Determination of forest fire risk with fuzzy analytic hierarchy process and its mapping with the application of GIS: The case of Turkey/Çakırlar. *Human and Ecological Risk Assessment: An International Journal*, 23(2), 388-406.
- Harrington, P. (2012). *Machine Learning in Action*. Manning Publications Shelter Island.
- Hart, E., Sim, K., Kamimura, K., Meredieu, C., Guyon, D., & Gardiner, B., (2019). *Use of machine learning techniques to model wind damage to forests*. *Agric. For. Meteorol.* 265, 16–29.
- Heinselman, M.L., (1973). Fire in the virgin forests of the Boundary Waters Canoe Area, Minnesota. *Quat. Res.* 3 (3), 329–382. [https://doi.org/10.1016/0033-5894\(73\)90003-3](https://doi.org/10.1016/0033-5894(73)90003-3).
- Hernandez-Leal, P.A., Arbelo, M., & Gonzalez-Calvo, A., (2006). Fire risk assessment using satellite data. *Adv. Space Res.* 37 (4), 741–746. <https://doi.org/10.1016/j.asr.2004.12.053>.
- Hoang, T. V., Chou, T. Y., Fang, Y. M., Nguyen, N. T., Nguyen, Q. H., Canh, P. X., Toan, D. N. B., Nguyen, X. L., & Meadows, M. E. (2020). Mapping forest fire risk and development of early warning system for NW Vietnam using AHP and MCA/GIS methods. *Applied Sciences*, 10(12), 4348.
- Hodges, J.L., & Lattimer, B.Y., (2019). Wildland fire spread modeling using convolutional neural networks. *Fire Technol.* 55 (6), 2115–2142. <https://doi.org/10.1007/s10694-019-00846-4>.
- Hosmer, D.W. & Lemeshow, S., (2000) *Applied Logistic Regression*, Wiley Series In *Probability And Statistics*, Canada, 8,49-50,143,156
- Huiling, L., Yurui, L., & Guang, Y., (2016). Application of random forest algorithm on the forest fire prediction in Tahe area based on meteorological factors. *Sci. Silvae Sinicae* 52, 90–98. <https://doi.org/10.13360/j.issn.2096-1359.2019.03.020>.
- Iliadis, L.S., (2005). A decision support system applying an integrated fuzzy model for longterm forest fire risk estimation. *Environ. Modell. Software* 20 (5), 613–621. <https://doi.org/10.1016/j.envsoft.2004.03.006>.
- Isokawa, T., Nishimura, H., & Matsui, N., (2012). Quaternionic Multilayer Perceptron with Local Analyticity. *Information*, 3(4), 756-770.
- Jain, P., Sean, C.P., Subramanian, C.S.G., Crowley, M., Taylor, S., & Flannigan, M.D., (2020). A review of machine learning applications in wildfire science and management. *Environ. Rev.* 28 (4), 478–505. <https://doi.org/10.1139/er-2020-0019>.

- Jaiswal, RK, Mukherjee, S., & Raju, DK, (2002). Uydu görüntüleri ve CBS'den orman yangının riskli bölge haritalaması. Uluslararası J. Başvuru. *Dünya Obs. Geoinf.* 4(1), 1-10
- Jose, K. S. (2012). Geospatial characterization and conservation potential for Agasthyamala Biosphere Reserve, Western ghats, India. PhD Dissertation, *School of Environmental Sciences, Mahatma Gandhi University, India.*
- Kartal, E. (2015). Sınıflandırmaya Dayalı Makine Öğrenmesi Teknikleri ve Kardiyolojik Risk Değerlendirmesine İlişkin Bir Uygulama. *İstanbul Üniversitesi Fen Bilimleri Enstitüsü.*
- Kinaneva, D., Hristov, G., Raychev, J., & Zahariev, P., (2019). Early Forest Fire Detection Using Drones and Artificial Intelligence. *42nd International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, 2019, pp. 1060-1065, 10.23919/MIPRO. 2019. 8756696.
- Kostopoulos, G. et al. (2020) 'Deep Dense Neural Network for Early Prediction of FailureProne Students', in. *Springer, Cham*, pp. 291–306. doi: 10.1007/978-3-030-49724- 8_13.
- Kotsiantis, S.B., Zaharakis, I.D., & Pintelas, P.E., (2006). Machine learning: a review of classification and combining techniques. *Artif. Intell. Rev.* 26, 159–190. <https://doi.org/10.1007/s10462-007-9052-3>.
- Kozik, V.I., Nezhevenko, E.S., & Feoktistov, A.S., (2013). Adaptive prediction of forest fire behavior on the basis of recurrent neural networks. *Optoelectron. Instrum. Data Process.* 49 (3), 250–259. <https://doi.org/10.3103/S8756699013030060>.
- Kucuk, O. & Sevinc, V. (2023). Fire behavior prediction with artificial intelligence in thinned black pine (*Pinus nigra* Arnold) stand. *Forest Ecology and Management* 529 (2023) 120707. www.elsevier.com/locate/foreco
- Kucuk, O., Bilgili, E., Bulut, S., & Fernandes, P.M., (2012). *Rates of surface fire spread in a young calabrian pine (Pinus brutia Ten.) plantation. Environ. Eng. Manage. J. (EEMJ)* 11 (8).
- Kucuk, O., Bilgili, E., & Uzumcu, R. (2018). Modeling surface fire rate of spread within a thinned Anatolian black pine stand in Turkey. *Forest Systems*, 27(2), 3.
- Kucuk, O., Goltas, M., Demirel, T., Mitsopoulos, I., & Bilgili, E. (2021). Predicting canopy fuel characteristics in *Pinus brutia* Ten., *Pinus nigra* Arnold and *Pinus pinaster* ait. forests from stand variables in North-western Turkey. *Environmental Engineering & Management Journal (EEMJ)*, 20(2)
- Kumar, V., Mazzara, M., Gen, M., Messina, A., & Young, J. (2019). A Conjoint Application of Data Mining Techniques for Analysis of Global Terrorist Attacks. *Advances in Intelligent Systems and Computing* içinde (s. 146-158). Springer Nature.

- Küçük, F. (2021). Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Türkiye: A comparative analysis of VIKOR and TOPSIS. *Forest Ecology and Management*, 480, 118644.
- Küçük, Ö., & Sağlam, B. (2004). Orman yangınları ve hava halleri. *Kastamonu Üniversitesi Orman Fakültesi Dergisi*, 4(2), 220-231.
- Lary, D.J., Alavi, A.H., Gandomi, A.H., & Walker, A.L., (2016.) Machine learning in geosciences and remote sensing. *Geosci. Front.* 7 (1), 3. <https://doi.org/10.1016/j.gsf.2015.07.003>. <https://www.sciencedirect.com/science/article/pii/S1674987115000821>.
- Leone, V., Koutsias, N., Martínez, J., Vega-García, C., Allgöwer, B., & Lovreglio, R., (2003). The human factor in fire danger assessment. In: Chuvieco, E. (Ed.), *Wildland Fire Danger Estimation and Mapping. The Role of Remote Sensing Data*. World Scientific Publishing, Singapore, pp. 143–194. https://doi.org/10.1142/9789812791177_0006.
- Li, J., Cheng, K., Wang, S., Morstatter, F., Trevino, R. P., Tang, J., & Liu, H. (2017). Feature selection: A data perspective. *ACM computing surveys (CSUR)*, 50(6), 1-45.
- Li, L.M., Song, W.G., Ma, J., & Satoh, K., (2009). Artificial neural network approach for modeling the impact of population density and weather parameters on forest fire risk. *Int. J. Wildl. Fire* 18 (6), 640. <https://doi.org/10.1071/WF07136>.
- Liang H., Zhang M., & Wang, H., (2019). A Neural Network Model for Wildfire Scale Prediction Using Meteorological Factors. In: *IEEE Access*, vol. 7, pp. 176746-176755, 2019, 10.1109/ACCESS.2019.2957837
- Lin, J., & Rinaldi, S. (2009). A derivation of the statistical characteristics of forest fires. *Ecological Modelling*, 220(7), 898-903.
- Maktite, A., & Faleh, A. (2017). Cartographie des zones à risque d’incendies de forêts à l’aide Du SIG et la télédétection dans l’arrière-pays du port Tanger Med. *European Scientific Journal*, 13(32), 205-224.
- Manning, C., Raghavan, P., & Schütze, H. (2009). *An Introduction to Information Retrieval*. Cambridge: Cambridge University Press
- Martínez, J., Vega-Garcia, C., & Chuvieco, E., (2009). Human-caused wildfire risk rating for prevention planning in Spain. *J. Environ. Manage.* 90 (2), 1.
- Matthews, S., Sullivan, A.L., Watson, P., & Williams, R.J., (2012). Climate change, fuel and fire behaviour in a eucalypt forest. *Glob. Chang. Biol.* 18 (10), 3212–3223.
- McCann, R.K., Marcot, B.G., & Ellis, R., (2006). Bayesian belief networks: applications in ecology and natural resource management. *Can. J. For. Res.* 36 (12). <https://doi.org/10.1139/x06-238>.3053-3062.241-1252.

- Mitsopoulos, I., Mallinis, G., Zibtsev, S., Yavuz, M., Saglam, B., Kucuk, O., Bogomolov, V., Borsuk, A., & Zaimes, G., (2017). An integrated approach for mapping fire suppression difficulty in three different ecosystems of Eastern Europe. *J. Spat. Sci.* 62 (1), 139–155. <https://doi.org/10.1080/14498596.2016.1169952>.
- Naderpour, M., Rizeei, H. M., Khakzad, N., & Pradhan, B. (2019). *Forest fire induced Natech risk assessment: A survey of geospatial technologies*. Reliability Engineering & System Safety, 191, 106558.
- Naganathan, H., Seshasayee, S., Kim, J., Chou, J., & Chong, W. (2016). Wildfire Predictions: Determining Reliable Models using Fused Dataset. *Global Journal of Computer Science and Technology*. (16) 35-46
- O'Connor, C.D., Calkin, D.E., & Thompson, M.P., (2017). An empirical machine learning method for predicting potential fire control locations for pre-fire planning and operational fire management. *Int. J. Wildland Fire* 26, 587–597.
- OGM. (2022). *2022 Yılı Ormancılık İstatistikleri, Orman Yangın Verileri*. T.C. Tarım ve Orman Bakanlığı, Orman Genel Müdürlüğü, Ankara, Türkiye. <https://www.ogm.gov.tr>.
- Oliveira, S., Oehler, F., San-Miguel-Ayanz, J., Camia, A., & Pereira, J.M., (2012). Modeling spatial patterns of fire occurrence in *Mediterranean Europe using Multiple Regression and Random Forest*. *For. Ecol. Manage.* 275, 117–129. <https://doi.org/10.1016/j.foreco.2012.03.003>.
- Otieno, J. O. (2020). *A machine learning algorithm for predicting wild fire occurrence* [Thesis, Strathmore University]. <http://hdl.handle.net/11071/12085>
- Özdemir, İ., & Karşılıgil, M. E. (2019). A Comparative Study on Machine Learning Techniques for Forest Fire Detection. *International Journal of Intelligent Systems and Applications in Engineering*, 7(2), 82-86.
- Öztürk, M., (2022). *Python ile Sınıflandırma Analizleri–Rastgele Orman (Random Forest) Algoritması* <https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi/> (14.02.2024)
- Pais, C. Miranda, A. Carrasco, J. & Shen, Z.M. (2021). Deep fire topology: Understanding the role of landscape spatial patterns in wildfire occurrence using artificial intelligence. *Environmental Modelling and Software* 143 (2021) 105122. www.elsevier.com/locate/envsoft
- Panchal, G., Ganatra, A., Kosta, Y. P., & Panchal, D., (2011). Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. *International Journal of Computer Theory and Engineering*, 3(2), 332.
- Pearl, J. & Russell, S. (2011). *Bayesian Networkss*. Statistics.

- Penman, T.D., Price, O., & Bradstock, R.A., (2012). Bayes Nets as a method for analysing the influence of management actions in fire planning. *Int. J. Wildland Fire* 20 (8), 909–920. <https://doi.org/10.1071/WF10076> .
- Pham, B.T., Jaafari, A., Avand, M., Al-Ansari, N., Dinh Du, T., Yen, H.P.H., & Tuyen, T.T., (2020). Performance evaluation of machine learning methods for forest fire modeling and prediction. *Symmetry* 12 (6), 1022.
- Polat, H., Danaei Mehr, H., & Cetin, A. (2017). Diagnosis of chronic kidney disease based on support vector machine by feature selection methods. *Journal of medical systems*, 41, 1-11.
- Pollino, C.A., Woodberry, O., Nicholson, A., Korb, K., & Hart, B.T., (2007). Parameterisation and evaluation of a Bayesian network for use in an ecological risk assessment. *Environ. Modell. Software* 22 (8), 1140–1152. <https://doi.org/10.1016/j.envsoft.2006.03.006> .
- Pourtaghi, Z.S., Pourghasemi, H.R., Aretano, R., & Semeraro, T., (2016). Investigation of general indicators influencing on forest fire and its susceptibility modeling using different data mining techniques. *Ecol. Indic.* 64, 72–84. <https://doi.org/10.1016/j.ecolind.2015.12.030> .
- Prasad, V. K., Badarinath, K. V. S., & Eaturu, A. (2008). Biophysical and anthropogenic controls of forest fires in the Deccan Plateau, India. *Journal of Environmental Management*, 86(1), 1-13.
- Preisler, H.K., Brillinger, D.R., Burgan, R.E., & Benoit, J.W., (2004). Probability based models for estimation of wildfire risk. *Int. J. Wildland Fire* 13 (2), 133–142. <https://doi.org/10.1071/WF02061> .
- Probst, P. & Boulesteix, A.-L. (2018) *To Tune or Not to Tune the Number of Trees in Random Forest*, *Journal of Machine Learning Research*. Available at: <http://jmlr.org/papers/v18/17-269.html>. (Accessed: 7 June 2021).
- Razavi-Termeh, S.V., Sadeghi-Niaraki, A., & Choi, S.-M., (2020). *GIS-based forest fire susceptibility mapping using artificial intelligence methods*. *Remote Sens.* 12, 1689. <https://doi.org/10.3390/rs12101689>.
- Rihan, M., Bindajam, A.A., Talukdar, S., Shahfahad, Naikoo, M.W., Mallick, J., & Rahman, A., (2023). Forest fire susceptibility mapping with sensitivity and uncertainty analysis using machine learning and deep learning algorithms. ScienceDirect. *Advances in Space Research* 72 (2023) 426–443. www.sciencedirect.com
- Rodrigues, M., & Riva, J., (2014). An insight into machine-learning algorithms to model human-caused wildfire occurrence. *Environ Model Softw.* 57, 192–201. <https://doi.org/10.1016/j.envsoft.2014.03.003> .
- Rubi, J.N.S., Carvalho, P.H.P. & Gondim, P.R.L. (2023). Application of machine learning models in the behavioral study of forest fires in the Brazilian Federal

- District region. *Engineering Applications of Artificial Intelligence* 118 (2023) 105649. www.elsevier.com/locate/engappai.
- Safi, Y., & Bouroumi A. (2013). Prediction of Forest Fires Using Artificial Neural Networks. *Applied Mathematical Sciences*, 7 (6), 271- 286
- Sağlam, B., Bilgili, E., Durmaz, B. D., Kadioğulları, A. İ., & Küçük, Ö. (2008). Spatiotemporal analysis of forest fire risk and danger using LANDSAT imagery. *Sensors*, 8(6), 3970-3987.
- Salhi, M.S., Salhi, M., Touti, E. & Benzarti, F. (2023). *Artificial intelligence optimization for forest fire risk predicting applied to green environment*. Research Laboratory of Signal Image and Information Technology LR-SITI, University of Tunis El Manar, National Engineering School of Tunis, Tunis, Tunisia.
- Samuel, A. (1988). *Some studies in machine learning using the game of checkers*. 210-229.
- San-Miguel-Ayanz, J., Carlson, J. D., Alexander, M., Tolhurst, K., Morgan, G., Sneeuwjagt, R., & Dudley, M., (2003). Current methods to assess fire danger potential. In: *Wildland fire danger estimation and mapping: The role of remote sensing data*, pp. 21–61.
- San-Miguel-Ayanz, J., Schulte, E., Schmuck, G., Camia, A., Strobl, P., Liberta, G., et al., (2012). Comprehensive monitoring of wildfires in Europe: the European Forest Fire Information System (EFFIS). In: *In Approaches to managing disaster — assessing hazards, emergencies and disaster impacts*. InTech. <https://doi.org/10.5772/28441> .
- Sari, F. (2021). Forest fire susceptibility mapping via multi-criteria decision analysis techniques for Mugla, Türkiye: A comparative analysis of VIKOR and TOPSIS. *Forest Ecology and Management*, 480, 118644.
- Satir, O., Berberoglu, S., & Donmez, C. (2016). Mapping regional forest fire probability using artificial neural network model in a Mediterranean forest ecosystem. *Geomatics, Natural Hazards and Risk*, 7(5), 1645-1658.
- Sayad, Y.O., Mousannif, H., & Al Moatassime, H., (2019). Predictive modeling of wildfires: a new dataset and machine learning approach. *Fire Saf. J.* 104, 130–146. <https://doi.org/10.1016/j.firesaf.2019.01.006>.
- Sevinc, V. Kucuk, O. & Goltas, Merih. (2020). A Bayesian network model for prediction and analysis of possible forest fire causes. *Forest Ecology and Management* 457 (2020) 117723. www.elsevier.com/locate/foreco
- Sivrikaya, F., & Küçük, Ö. (2022). Modeling forest fire risk based on GIS-based analytical hierarchy process and statistical analysis in Mediterranean region. *Ecological Informatics* 68 (2022) 101537. www.elsevier.com/locate/ecolinf

- Sivrikaya, F., Saglam, B., Akay, A. E., & Bozali, N. (2014). Evaluation of forest fire risk with GIS. *Polish Journal of Environmental Studies*, 23(1), 187–194.
- Smith, J., Jones, K., & Lee, R. (2018). Deep learning for forest fire detection. *Journal of Applied Remote Sensing*, 12(4), 042603.
- Sukumar, K. K., Jeevivek, V. K., Hemalatha, T. K., & Soman, P. K. (2009). Prediction of Forest Fire Using SVM – A Novel Approach. In *10th ESRI India User Conference 2009*.
- Sullivan, AL., (2007). *A review of wildland fire spread modelling, 1990-present 3: Mathematical analogues and simulation models*. arXiv preprint arXiv:0706.4130, 2007.
- Suryabagavan, K. V., Alemu, M., & Balakrishnan, M. (2016). GIS-based multicriteria decision analysis for forest fire susceptibility mapping: a case study in Hareenna forest, southwestern Ethiopia. *Tropical Ecology*, 57(1), 33-43.
- Sürgüçoğlu, P. (2023) Covid-19 Hastalığının Sınıflandırılmasında Derin Öğrenme Modellerinin Performanslarının Karşılaştırılması, Yüksek Lisans Tezi, *Kastamonu Üniversitesi Fen Bilimleri Enstitüsü*. Kastamonu.
- Tafralı, S., (2022) *Yapay Öğrenme: Rastgele Orman* <https://medium.com/machine-learning-t%C3%BCrkiye/yapay-%C3%B6%C4%9Frenme-rastgele-orman-e8debd886e7> (16.02.2024)
- Tan, L., Guo, J., Mohanarajah, S., & Zhou, K., (2021). Can we detect trends in natural disaster management with artificial intelligence? A review of modeling practices. *Nat Hazards* 107, 2389–2417. <https://doi.org/10.1007/s11069-020-04429-3>.
- Teodoro, A. C., & Duarte, L. (2013). Forest fire risk maps: a GIS open source application—a case study in Norwest of Portugal. *International Journal of Geographical Information Science*, 27(4), 699-720.
- Tomak, L., & Yüksel, B. E. K. (2009). İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *Journal of Experimental and Clinical Medicine*, 27(2).
- URL-1 <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler> (23.12.2023)
- Uusitalo, L., (2007). Advantages and challenges of Bayesian networks in environmental modelling. *Ecol. Model.* 203 (3–4), 312–318.
- Vakalis, D., Sarimveis, H., Kiranoudis, C., Alexandridis, A., Bafas, G., (2004). A GIS based operational system for wildland fire crisis management. I. Mathematical modelling and simulation. *Appl. Math. Model.* 28 (4), 389–410. <https://doi.org/10.1016/j.apm.2003.10.005>.

- Vasilakos, C., Kalabokidis, K., Hatzopoulos, J., Kallos, G., & Matsinos, Y., (2007). Integrating new methods and tools in fire danger rating. *Int. J. Wildland Fire* 16 (3), 306–316. <https://doi.org/10.1071/WF05091> .
- Vilar, L., Woolford, D.G., Martell, D.L., & Martín, M.P., (2010). A model for predicting human-caused wildfire occurrence in the region of Madrid, Spain. *Int. J. Wildland Fire* 19 (3), 325–337. <https://doi.org/10.1071/WF09030> .
- Wang, L., Liu, Y., Zhang, H., & Zhou, W. (2021). Forest fire risk prediction based on remote sensing data and machine learning model. *Forests*, 12(2), 226.
- Wang, Y., & Anderson, K.R., (2011). An evaluation of spatial and temporal patterns of lightning-and human-caused forest fires in Alberta, Canada, 1980–2007. *Int. J. Wildland Fire* 19 (8), 1059–1072. <https://doi.org/10.1071/WF09085> .
- Wright, H.A., & Bailey, A.W., (1982). *Fire Ecology: United States and Southern Canada*. John Wiley & Sons.
- Wu, Z., Wang, B., Li, M., Tian, Y., Quan, Y., & Liu, J., (2022). *Simulation of forest fire spread based on artificial intelligence*. *Ecol. Ind.* 136, 108653.
- Xiangwei, G., Xianyun, F., & Hongquan, X. (2011). Forest fire risk zone evaluation based on high spatial resolution RS image in Liangyungang Huaguo Mountain Scenic Spot. In *Proceedings 2011 IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services* (pp. 593-596). IEEE.
- Yassemi, S., Dragi'cevi'c, S., & Schmidt, M., (2008). Design and implementation of an integrated GIS-based cellular automata model to characterize forest fire behaviour. *Ecol. Model.* 210 (1–2), 71–78.
- Yavuz, M., Saglam, B., Küçük, O., & Tüfekçioğlu, A., (2018). Assessing forest fire behavior simulation using FlamMap software and remote sensing techniques in Western Black Sea Region, Turkey. *Kastamonu Univ. J. Forestry Faculty* 18 (2), 171–188. <https://doi.org/10.17475/kastorman.459698> .
- Yüksel M.C. & Akay M.F., 2018. Predicting the Internet Network Traffic Using Multilayer Perceptron and Feedback Delays. *3rd International Mediterranean Science and Engineering Congress (IMSEC 2018)* October 24-26, 2018, Adana, Turkey
- Zhang, Q.X., Lin, G.H., Zhang, Y.M., Xu, G., & Wang, J.J., (2018). Wildland forest fire smoke detection based on Faster R-CNN using synthetic smoke images. *Procedia Eng.* 211, 441–446. <https://doi.org/10.1016/j.proeng.2017.12.034> .
- Zheng, Z., Huang, W., Li, S., & Zeng, Y., (2017). Forest fire spread simulating model using cellular automaton with extreme learning machine. *Ecol. Model.* 348, 33–43. <https://doi.org/10.1016/j.ecolmodel.2016.12.022>.
- Zwirgmaier, K., Papakosta, P., & Straub, D. (2013). Learning a Bayesian network model for predicting wildfire behaviour. In: Deodatis, G., Ellingwood, B.R.,

Frangopol, D.M., (Eds.), *Proceedings of the 11th international conference on structural safety and reliability*, Taylor & Francis Group, London.





EKLER

EK 1. Taşköprü Orman İşletme Müdürlüğü'nde 2017-2022 Yılları Arasında Çıkan Orman Yangınları

SIRA	MESÇERE	YÜKSEKLİK(m)	BAKI	RÜZGAR HIZI(km/s)	SICAKLIK	NİSBI NEM	YERLEŞİM YERİNDEN UZAKLIK(m)	YOLA UZAKLIK(m)	TARIM ALANLARINA UZAKLIK(m)	SU KAYNAKLARINDAN UZAKLIK(m)	AĞAÇ TÜRÜ RİSKİ	MESÇERE ÇAĞI RİSKİ	KAPALILIK RİSKİ	YÜKSEKLİK RİSKİ	BAKİ RİSKİ	RÜZGAR HIZI RİSKİ	SICAKLIK RİSKİ	NİSBI NEM RİSKİ	TARIM ALANLARINA UZAKLIK(m)	YOLA UZAKLIK(m)	YERLEŞİM YERİNDEN UZAKLIK(m)	SU KAYNAKLARINDAN UZAKLIK(m)
1	ÇkMab3	850	Güneydoğu	4	17	60	1795	420	390	3320	4	4	4	2	3	5	4	3	2	2	4	4
2	Çkbc3	1000	Batı	17	18	25	570	210	200	5700	1	1	1	3	3	1	4	1	1	1	3	5
3	BÇk	800	Güney	10	18	25	810	190	210	3950	3	3	3	2	2	1	4	1	1	1	3	4
4	ÇkMa3	940	Batı	6	28	40	1300	120	470	2350	4	4	4	2	3	5	2	2	2	1	4	4
5	ÇkÇsed1/Çk0a	1300	Kuzey	6	20	53	900	44	2130	2950	5	5	5	3	5	5	3	3	4	1	3	4
6	ÇkÇsed1/Çk0a	1300	Kuzey	6	20	53	900	44	2130	2950	5	5	5	3	5	5	3	3	4	1	3	4
7	Çkc2	1000	Batı	7	24	39	1734	137	410	3200	3	3	3	3	3	4	3	2	2	1	4	4
8	Çsed2	1517	Kuzey	7	31	20	720	165	440	5555	5	5	5	4	5	4	2	1	2	1	3	5
9	Çked1	1500	Güneybatı	7	31	20	850	143	150	1295	4	4	4	4	1	4	2	1	1	1	3	4
10	BM	1000	Batı	1	11	48	860	10	300	14037	5	5	5	3	3	5	4	2	2	1	3	5
11	MÇka	900	Güney	1	18	37	785	157	208	5100	4	4	4	2	2	5	4	2	1	1	3	5
12	Çkc3	1150	Güney	15	26	63	942	170	437	2914	2	2	2	3	2	1	2	3	2	1	3	4
13	Çkc2	900	Batı	7	27	31	606	60	340	3707	3	3	3	2	3	4	2	2	2	1	3	4
14	Çkc3	1000	Kuzeybatı	1	31	29	610	62	190	3162	2	2	2	3	5	5	2	1	1	1	3	4
15	Çkb3	1000	Güney	4	18	53	1150	10	1010	5700	1	1	1	3	2	5	4	3	4	1	4	5
16	Çked1	1452	Güney	9	10	75	570	225	500	8050	4	4	4	3	2	2	4	4	3	1	3	5
17	Çkc3	1250	Kuzeybatı	14	22	53	370	30	80	3965	2	2	2	3	5	1	3	3	1	1	2	4
18	BM	750	Güneybatı	15	28	34	1170	165	50	3270	5	5	5	2	1	1	2	2	1	1	4	4
19	Çsc3	1430	Güney	9	30	28	555	157	370	11610	3	3	3	3	2	2	2	1	2	1	3	5
20	Çkc3	1100	Doğu	9	34	28	500	400	270	2405	2	2	2	3	4	2	2	1	2	2	3	4
21	Çkbc3	1100	Güney	21	24	34	710	36	100	3950	1	1	1	3	2	1	3	2	1	1	3	4
22	Çkc3	1100	Güney	36	22	46	1190	310	590	3400	2	2	2	3	2	1	3	2	3	2	4	4
23	Çkbc3	1000	Doğu	2	3	73	760	333	254	1370	1	1	1	3	4	5	5	4	2	2	3	4
24	Çkd1	1000	Güney	2	6	55	900	150	300	10000	5	5	5	3	2	5	5	3	2	1	3	5
25	ÇsKned3	1445	Batı	4	1	97	900	63	850	8500	5	5	5	3	3	5	5	5	3	1	3	5
26	Çked1	1300	Güney	3	15	42	1050	77	820	3000	4	4	4	3	2	5	4	2	3	1	4	4
27	Çkbc3	1200	Güney	22	12	54	3580	120	3110	1350	1	1	1	3	2	1	4	3	4	1	4	4
28	BÇk	1500	Güney	16	16	62	520	25	70	9680	3	3	3	4	2	1	4	3	1	1	3	5
29	Çkc1	1500	Doğu	4	12	65	1400	160	100	190	4	4	4	4	4	5	4	3	1	1	4	1
30	Çsc2	1346	Güneydoğu	10	24	22	350	100	575	6750	4	4	4	3	3	1	3	1	3	1	2	5

Ek 1'in devamı

31	Çkc3	1163	Kuzeybatı	3	24	42	400	82	210	3170	2	2	2	3	5	5	3	2	1	1	2	4
32	Çkcd3/b3	1300	Güneybatı	18	32	23	580	220	225	5300	3	3	3	3	1	1	2	1	1	1	3	5
33	Çkcd3/b3	1300	Güneybatı	18	32	23	580	220	225	5300	3	3	3	3	1	1	2	1	1	1	3	5
34	ÇkÇsbc3	1300	Güneybatı	18	32	23	580	220	225	5300	3	3	3	3	1	1	2	1	1	1	3	5
35	Çkc2	1300	Güneydoğu	18	32	31	970	45	170	4370	3	3	3	3	3	1	2	2	1	1	3	4
36	ÇkMab3	1000	Kuzeybatı	14	29	32	460	30	50	5660	4	4	4	3	5	1	2	2	1	1	2	5
37	ÇsÇkc3	1280	Güneybatı	19	28	26	800	90	530	5760	3	3	3	3	1	1	2	1	3	1	3	5
38	Çkc2	1280	Güneybatı	19	28	26	800	90	530	5760	3	3	3	3	1	1	2	1	3	1	3	5
39	Çka3	800	Kuzey	21	29	38	1210	10	450	930	1	1	1	2	5	1	2	2	2	1	4	3
40	BÇk	1540	Güney	13	26	30	715	85	210	7800	3	3	3	4	2	1	2	2	1	1	3	5
41	ÇkKvb3	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
42	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
43	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
44	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
45	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
46	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
47	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
48	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
49	Çkcd2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
50	Çkc3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
51	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
52	ÇkKvb3	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
53	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
54	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
55	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
56	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
57	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
58	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
59	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
60	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

61	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
62	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
63	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
64	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
65	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
66	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
67	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
68	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
69	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
70	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
71	Çkbc4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
72	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
73	Çkc3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
74	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
75	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
76	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
77	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
78	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
79	Çka3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
80	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
81	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
82	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
83	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
84	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
85	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
86	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
87	ÇkKvb3	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
88	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
89	Çka0	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
90	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

91	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
92	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
93	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
94	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
95	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
96	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
97	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
98	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
99	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
100	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
101	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
102	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
103	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
104	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
105	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
106	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
107	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
108	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
109	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
110	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
111	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
112	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
113	Çka3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
114	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
115	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
116	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
117	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
118	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
119	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
120	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

121	Çka3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
122	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
123	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
124	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
125	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
126	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
127	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
128	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
129	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
130	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
131	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
132	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
133	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
134	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
135	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
136	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
137	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
138	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
139	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
140	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
141	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
142	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
143	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
144	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
145	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
146	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
147	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
148	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
149	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
150	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

151	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
152	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
153	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
154	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
155	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
156	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
157	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
158	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
159	Çked2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
160	Çked2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
161	Çked1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
162	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
163	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
164	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
165	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
166	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
167	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
168	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
169	ÇsÇkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
170	Çked3	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
171	Çked2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
172	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
173	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
174	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
175	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
176	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
177	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
178	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
179	ÇsÇkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
180	ÇkKnbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

181	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
182	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
183	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
184	Çkb3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
185	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
186	Çka0	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
187	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
188	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
189	ÇkÇsbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
190	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
191	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
192	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
193	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
194	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
195	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
196	Çkc3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
197	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
198	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
199	Çkbc4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
200	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
201	Çkb4	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
202	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
203	Çkb2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
204	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
205	Çka0	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
206	Çkab3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
207	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
208	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
209	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
210	Çkcd2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4

Ek 1'in devamı

211	Çkcd1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
212	Çkc2	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
213	Çkc1	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
214	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
215	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
216	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
217	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
218	Çkcd2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
219	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
220	Çkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	1	1	1	3	3	1	1	1	2	2	2	4
221	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
222	Çkbc2	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
223	Çkd1/ab3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
224	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
225	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
226	ÇsÇkbc3	1140	Güneydoğu	16	36	20	480	370	270	2610	2	2	2	3	3	1	1	1	2	2	2	4
227	Çkcd2	1140	Güneydoğu	16	36	20	480	370	270	2610	4	4	4	3	3	1	1	1	2	2	2	4
228	Çka	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
229	BÇk	1140	Güneydoğu	16	36	20	480	370	270	2610	3	3	3	3	3	1	1	1	2	2	2	4
230	Çkbc3	1550	Güneybatı	6	19	76	435	150	210	5470	1	1	1	4	1	5	4	4	1	1	2	5
231	BÇk	1550	Güneybatı	6	19	76	435	150	210	5470	3	3	3	4	1	5	4	4	1	1	2	5
232	BÇk	1550	Güneybatı	6	19	76	435	150	210	5470	3	3	3	4	1	5	4	4	1	1	2	5
233	Çkcd1	1550	Güneybatı	6	19	76	435	150	210	5470	4	4	4	4	1	5	4	4	1	1	2	5
234	BÇk	1560	Güneybatı	5	3	80	1480	240	1150	8200	3	3	3	4	1	5	5	4	4	1	4	5
235	BÇk	1680	Güney	5	3	76	1950	55	1210	9895	3	3	3	4	2	5	5	4	4	1	4	5
236	Çkc2/Mab3	1300	Güney	5	12	51	4080	243	1145	4903	4	4	4	3	2	5	4	3	4	1	4	4
237	BÇk	1680	Güney	5	12	52	4080	243	1145	4903	3	3	3	4	2	5	4	3	4	1	4	4
238	Çkd1	1680	Güney	5	12	52	4080	243	1145	4903	5	5	5	4	2	5	4	3	4	1	4	4
239	ÇkÇscd2/Mab3	1100	Güneybatı	3	14	45	4200	506	475	3700	5	5	5	3	1	5	4	2	2	3	4	4
240	Çkc3	950	Batı	3	3	87	1700	1370	530	5010	2	2	2	2	3	5	5	4	3	4	4	5

Ek 1'in devamı

241	BÇk	560	Güneydoğu	11	16	42	1120	205	150	11840	3	3	3	2	3	1	4	2	1	1	4	5
242	BÇk	560	Güneydoğu	11	16	42	1120	205	150	11840	3	3	3	2	3	1	4	2	1	1	4	5
243	Çkcd1/Mab3	800	Kuzeydoğu	10	17	17	500	200	207	1250	5	5	5	2	5	1	4	1	1	1	3	4
244	BM	800	Kuzeydoğu	10	17	17	500	200	207	1250	5	5	5	2	5	1	4	1	1	1	3	4
245	Çkcd2	600	Güneybatı	6	11	34	1145	125	580	8500	4	4	4	2	1	5	4	2	3	1	4	5
246	BÇs	1420	Doğu	18	13	35	420	338	130	8414	4	4	4	3	4	1	4	2	1	2	2	5
247	BDy	1080	Güneydoğu	18	13	35	1456	34	1590	708	5	5	5	3	3	1	4	2	4	1	4	3
248	Çkcd2/Mb3	1035	Güneybatı	6	9	60	1430	130	537	4936	5	5	5	3	1	5	5	3	3	1	4	4
249	BÇk	700	Batı	8	18	36	830	515	230	2030	3	3	3	2	3	3	4	2	1	3	3	4
250	Mbc3	1260	Batı	5	18	40	776	550	660	7720	5	5	5	3	3	5	4	2	3	3	3	5
251	Çkbc2	1100	Güneybatı	13	24	24	685	318	200	1850	2	2	2	3	1	1	3	1	1	2	3	4
252	ÇkKvb3Y	1280	Batı	19	29	27	1370	140	430	6560	5	5	5	3	3	1	2	1	2	1	4	5
253	Çka	1100	Doğu	10	27	25	470	95	150	3360	3	3	3	3	4	1	2	1	1	1	2	4
254	Çkcd2	1350	Güneydoğu	6	28	43	305	83	224	10872	4	4	4	3	3	5	2	2	1	1	2	5
255	Çka3	800	Doğu	10	26	60	810	370	255	505	1	1	1	2	4	1	2	3	2	2	3	3
256	Çkb3	1100	Kuzeybatı	3	14	71	380	270	140	5560	1	1	1	3	5	5	4	4	1	2	2	5
257	Çkcd1	840	Güneydoğu	16	32	29	450	140	130	3200	4	4	4	2	3	1	2	1	1	1	2	4
258	Çkbc2	850	Güney	6	7	79	766	370	780	2360	2	2	2	2	2	5	5	4	3	2	3	4
259	Çkcd3	1200	Güneybatı	8	22	55	425	30	320	2425	4	4	4	3	1	3	3	3	2	1	2	4
260	Çkcd3	1450	Batı	8	27	28	800	46	380	6650	4	4	4	3	3	3	2	1	2	1	3	5
261	Çkd1	1550	Batı	6	19	37	900	600	95	10560	5	5	5	4	3	5	4	2	1	3	3	5
262	OT	900	Güney	7	30	30	2100	70	1100	7800	5	5	5	2	2	4	2	2	4	1	4	5
263	Z	800	Kuzey	16	16	46	230	15	0	820	5	5	5	2	5	1	4	2	1	1	1	3
264	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
265	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
266	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
267	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
268	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
269	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
270	OT	1140	Güneydoğu	16	36	20	480	370	270	2610	5	5	5	3	3	1	1	1	2	2	2	4
271	OT	553	Batı	16	25	45	190	22	50	180	5	5	5	2	3	1	2	2	1	1	1	1

EK 2. Taşköprü Orman İşletme Müdürlüğü Orman Yangını Çıkmamış Alanlar

SIRA	MEŞCERE	YÜKSEKLİK(m)	BAKİ	YERLEŞİM YERİNDEN UZAKLIK(m)	YOLA UZAKLIK(m)	TARIM ALANLARINA UZAKLIK(m)	SU KAYNAKLARINDAN UZAKLIK(m)	AĞAÇ TÜRÜ RİSKİ	MEŞCERE ÇAĞI RİSKİ	KAPALILIK RİSKİ	YÜKSEKLİK RİSKİ	BAKİ RİSKİ	TARIM ALANLARINA UZAKLIK(m)	YOLA UZAKLIK(m)	YERLEŞİM YERİNDEN UZAKLIK(m)	SU KAYNAKLARINDAN UZAKLIK(m)
1	Çkcd1	1006	Güney	620	175	60	1450	4	4	4	3	2	1	1	3	4
2	Çka-3	1063	Güney	1200	570	160	1500	3	3	3	3	2	1	3	4	4
3	Mb3	1090	Kuzeybatı	150	140	70	860	4	4	4	3	5	1	1	1	3
4	Bçk-3	1114	Kuzey	400	30	260	468	3	3	3	3	5	2	1	2	2
5	Çkc2/Mab3	1170	Güneydoğu	950	570	440	1620	4	4	4	3	3	2	3	3	4
6	Çkc3	1250	Kuzey	1400	1740	1175	180	2	2	2	3	5	4	4	4	1
7	Çsc2	1358	Batı	2820	520	2540	60	4	4	4	3	3	4	3	4	1
8	Çscd2	1387	Batı	2900	200	2800	80	5	5	5	3	3	4	1	4	1
9	Çkcd1/a0-1	1270	Kuzey	3600	150	3500	1120	5	5	5	3	5	4	1	4	4
10	Çsbc3	1240	Kuzeybatı	4070	90	3650	50	3	3	3	3	5	4	1	4	1
11	ÇsÇkc3	1286	Güney	3230	236	3100	2650	3	3	3	3	2	4	1	4	4
12	Bçs	1174	Kuzey	4440	40	4415	3450	4	4	4	3	5	4	1	4	4
13	Çsbc3	1270	Kuzey	4420	740	4220	4100	3	3	3	3	5	4	3	4	4
14	Çscd1	1190	Kuzey	3860	480	3430	5056	5	5	5	3	5	4	2	4	5
15	Çkbc3-2	1216	Kuzey	4150	160	3960	5458	1	1	1	3	5	4	1	4	5
16	Çkc3	1150	Kuzey	3330	210	3100	1020	2	2	2	3	5	4	1	4	4
17	Çkc3	1140	Kuzey	3750	118	3350	800	2	2	2	3	5	4	1	4	3
18	Çka	1120	Kuzey	2990	170	1670	450	3	3	3	3	5	4	1	4	2
19	Çkbc3	1065	Kuzey	2260	300	2300	500	1	1	1	3	5	4	2	4	3
20	Çkcd3	1080	Kuzey	2300	330	2250	600	4	4	4	3	5	4	2	4	3
21	Çkbc3-3	1140	Kuzeydoğu	1470	570	1350	750	1	1	1	3	5	4	3	4	3
22	BM	990	Güney	830	350	200	800	5	5	5	2	2	1	2	3	3
23	MGna3-1	930	Batı	1500	600	1100	1200	5	5	5	2	3	4	3	4	4
24	MGnab3	850	Batı	1200	150	1100	60	5	5	5	2	3	4	1	4	1
25	Mab3	850	Güneydoğu	1300	380	1100	120	4	4	4	2	3	4	2	4	1

Ek 2'nin devamı

26	BM-3	800	Güney	1800	80	1700	130	5	5	5	2	2	4	1	4	1
27	Ma	830	Güney	2000	70	1800	40	5	5	5	2	2	4	1	4	1
28	Çkb3	1100	Kuzeybatı	1900	100	1400	250	1	1	1	3	5	4	1	4	2
29	ÇsKncd3	1400	Güney	1150	600	1200	60	5	5	5	3	2	4	3	4	1
30	ÇkÇsbc3	1300	Güney	1000	550	800	120	3	3	3	3	2	3	3	4	1
31	Çkab3	1450	Güney	1200	320	980	150	1	1	1	3	2	3	2	4	1
32	Çkd1/ab3	1500	Güney	1100	490	860	110	2	2	2	4	2	3	2	4	1
33	ÇsGcd3	1700	Güney	1700	350	1600	100	5	5	5	4	2	4	2	4	1
34	Çsc3	1780	Kuzey	2000	760	2050	150	3	3	3	4	5	4	3	4	1
35	ÇsKncd3	1500	Güneybatı	1200	60	1150	160	5	5	5	4	1	4	1	4	1
36	Çkcd2-1	1255	Batı	1080	410	450	280	4	4	4	3	3	2	2	4	2
37	Çka3	1220	Kuzey	1035	690	300	1010	1	1	1	3	5	2	3	4	4
38	Çkcd3-2	1260	Kuzeydoğu	670	380	370	540	4	4	4	3	5	2	2	3	3
39	Mab3-2	1100	Güneydoğu	2160	650	1300	340	4	4	4	3	3	4	3	4	2
40	Çkcd3	1100	Doğu	320	90	400	640	4	4	4	3	4	2	1	2	3
41	Çkab2	1200	Batı	800	220	820	800	2	2	2	3	3	3	1	3	3
42	Çkb3	1150	Güney	1300	40	470	950	1	1	1	3	2	2	1	4	3
43	BÇs	1530	Doğu	450	200	450	1400	4	4	4	4	4	2	1	2	4
44	Çsc3	1520	Güney	1950	280	2100	260	3	3	3	4	2	4	2	4	2
45	Çsab3	1440	Doğu	1800	140	1900	460	3	3	3	3	4	4	1	4	2
46	ÇsÇkb3	1440	Kuzeybatı	1400	20	1200	520	2	2	2	3	5	4	1	4	3
47	ÇsÇkDybc3	1300	Güneybatı	1900	140	1800	90	5	5	5	3	1	4	1	4	1
48	Çkcd3	1450	Batı	1100	470	1000	480	4	4	4	3	3	4	2	4	2
49	Çka3	1300	Güneydoğu	1400	200	890	860	1	1	1	3	3	3	1	4	3
50	GÇscd3	1630	Güneydoğu	2200	540	2400	900	5	5	5	4	3	4	3	4	3

Ek 2'nin devamı

51	Çsa3	1530	Kuzeydoğu	3000	150	2800	650	3	3	3	4	5	4	1	4	3
52	Gcd3	1620	Kuzeydoğu	2400	860	2200	1200	5	5	5	4	5	4	3	4	4
53	GÇscd3	1600	Güney	2000	800	2100	1100	5	5	5	4	2	4	3	4	4
54	Çsb3-2	1780	Güneybatı	1900	780	1800	750	3	3	3	4	1	4	3	4	3
55	ÇkÇsd2	1400	Kuzey	1500	560	1600	640	4	4	4	3	5	4	3	4	3
56	ÇsKncd3	1360	Kuzey	1800	870	1800	840	5	5	5	3	5	4	3	4	3
57	Çka	670	Batı	300	140	580	600	3	3	3	2	3	3	1	2	3
58	Çza3	730	Güneydoğu	560	150	550	500	1	1	1	2	3	3	1	3	3
59	BDy	700	Kuzeydoğu	700	395	400	100	5	5	5	2	5	2	2	3	1
60	BDy-T	780	Doğu	1050	220	860	100	5	5	5	2	4	3	1	4	1
61	ÇkMb3-2	1130	Doğu	2180	100	840	160	4	4	4	3	4	3	1	4	1
62	Çkbc4	1070	Kuzeybatı	930	180	370	640	1	1	1	3	5	2	1	3	3
63	ÇkMa3	970	Güney	1140	160	135	200	4	4	4	2	2	1	1	4	1
64	MGna3	840	Batı	1600	123	140	640	5	5	5	2	3	1	1	4	3
65	Çkb4	1180	Güneydoğu	1130	200	580	700	1	1	1	3	3	3	1	4	3
66	Çkbc2-2	1200	Kuzey	1000	140	270	800	2	2	2	3	5	2	1	4	3
67	Çkc1	800	Kuzey	730	170	70	850	4	4	4	2	5	1	1	3	3
68	Bçk	700	Batı	410	120	130	1300	3	3	3	2	3	1	1	2	4
69	ÇkMab3	800	Güneybatı	1020	120	130	460	4	4	4	2	1	1	1	4	2
70	Çkc1-2	1020	Güneybatı	900	60	410	840	4	4	4	3	1	2	1	3	3
71	Çkb3	1200	Batı	1200	100	450	600	1	1	1	3	3	2	1	4	3
72	Çkcd2-2	1200	Kuzeybatı	230	120	70	580	4	4	4	3	5	1	1	1	3
73	Çkab3	1130	Kuzey	1440	350	140	740	1	1	1	3	5	1	2	4	3
74	Çkb2-1	1140	Kuzey	1200	240	110	510	2	2	2	3	5	1	1	4	3
75	Çkcd2	1100	Kuzeybatı	2600	200	500	620	4	4	4	3	5	3	1	4	3

Ek 2'nin devamı

76	Çkc1/Mab3-1	1070	Doğu	800	210	210	420	4	4	4	3	4	1	1	3	2
77	Çkb4	700	Kuzeybatı	1180	130	50	840	1	1	1	2	5	1	1	4	3
78	Çkbc2-1	680	Güney	600	190	60	690	2	2	2	2	2	1	1	3	3
79	BÇk	700	Güneydoğu	270	200	130	1100	3	3	3	2	3	1	1	2	4
80	BDy-2	850	Batı	585	395	300	120	5	5	5	2	3	2	2	3	1
81	Çka0	880	Kuzey	1500	190	570	950	5	5	5	2	5	3	1	4	3
82	Çkb2-3	860	Batı	680	100	80	560	2	2	2	2	3	1	1	3	3
83	MGnb3	900	Kuzeybatı	480	230	410	210	5	5	5	2	5	2	1	2	1
84	BM-4	820	Kuzeydoğu	1000	680	470	160	5	5	5	2	5	2	3	4	1
85	ÇkÇsb3	1160	Kuzey	2300	130	940	840	3	3	3	3	5	3	1	4	3
86	BM	730	Batı	900	1200	1000	350	5	5	5	2	3	4	4	3	2
87	Bçk	800	Güneybatı	600	600	380	260	3	3	3	2	1	2	3	3	2
88	MGNab3	820	Batı	2500	280	850	1200	5	5	5	2	3	3	2	4	4
89	Çkc/Mab3	950	Batı	680	300	350	2400	3	3	3	2	3	2	2	3	4
90	Mab3	960	Güneybatı	730	420	450	2450	4	4	4	2	1	2	2	3	4
91	Ma3	990	Güneybatı	750	100	170	2500	4	4	4	2	1	1	1	3	4
92	ÇkMab3	1020	Batı	450	680	550	2440	4	4	4	3	3	3	3	2	4
93	Çkbc3	1090	Kuzey	1600	190	1200	2140	1	1	1	3	5	4	1	4	4
94	Çkcd1/Ma3-2	1070	Kuzeybatı	1500	300	1100	2050	5	5	5	3	5	4	2	4	4
95	ÇkÇscd2	1080	Güney	2600	1000	2100	10	4	4	4	3	2	4	4	4	1
96	Çkd2	1110	Güneybatı	2000	500	1500	400	4	4	4	3	1	4	3	4	2
97	Çkc3-3	1080	Güneybatı	2200	660	1600	230	2	2	2	3	1	4	3	4	1
98	ÇkÇsc3-1	1130	Batı	1200	120	1120	900	3	3	3	3	3	4	1	4	3
99	Çkcd3	1060	Güney	2000	680	1700	300	4	4	4	3	2	4	3	4	2
100	Çkcd1/Mab3-2	1080	Güneybatı	1860	730	1580	500	5	5	5	3	1	4	3	4	3

Ek 2'nin devamı

101	Bçk-3	1010	Güneybatı	2200	420	1900	180	3	3	3	3	1	4	2	4	1
102	Mb3	1000	Batı	1300	240	1200	1600	4	4	4	3	3	4	1	4	4
103	Ma-1	1100	Batı	2000	200	1600	2160	5	5	5	3	3	4	1	4	4
104	GnMbc3-2	950	Kuzeybatı	1450	370	660	1400	5	5	5	2	5	3	2	4	4
105	Mbc3	1020	Batı	1800	60	1300	1800	5	5	5	3	3	4	1	4	4
106	Ma3	1050	Batı	1900	70	1700	1900	4	4	4	3	3	4	1	4	4
107	Çkb3	1100	Doğu	2800	380	2500	800	1	1	1	3	4	4	2	4	3
108	Çkc2/Mab3	1130	Güneybatı	2700	270	2300	870	4	4	4	3	1	4	2	4	3
109	ÇsÇka	1250	Batı	3300	220	3100	980	2	2	2	3	3	4	1	4	3
110	Knbc3	1130	Doğu	2500	360	2350	470	5	5	5	3	4	4	2	4	2
111	KnGna3	1070	Doğu	2400	500	2300	230	5	5	5	3	4	4	3	4	1
112	ÇsÇkod2/Mab3-1	1200	Kuzey	2600	100	2500	700	5	5	5	3	5	4	1	4	3
113	Knbc3	1050	Kuzey	2000	200	1800	250	4	4	4	3	5	4	1	4	2
114	GnMbc3	950	Doğu	2400	400	1500	1100	5	5	5	2	4	4	2	4	4
115	Çkd/MGnab3	1000	Doğu	2100	120	1250	780	5	5	5	3	4	4	1	4	3
116	ÇkÇscd3	1276	Batı	700	170	290	950	4	4	4	3	3	2	1	3	3
117	Çsc2-2	1100	Kuzeydoğu	1500	290	580	1020	4	4	4	3	5	3	2	4	4
118	GÇsB-2	1700	Kuzey	300	6200	6400	1600	5	5	5	4	5	5	5	2	4
119	Çkc3	1050	Kuzey	670	100	350	740	2	2	2	3	5	2	1	3	3
120	Çkc2	1000	Batı	1700	250	1400	850	3	3	3	3	3	4	2	4	3
121	Çkab3	977	Batı	1800	350	830	640	1	1	1	2	3	3	2	4	3
122	Çkbc3	1067	Güneydoğu	1870	100	490	520	1	1	1	3	3	2	1	4	3
123	Çkc3	1160	Kuzeybatı	660	50	990	630	2	2	2	3	5	3	1	3	3
124	Çsc3	1536	Kuzeybatı	1050	300	1200	840	3	3	3	4	5	4	2	4	3
125	Çkc3	1300	Güney	4550	50	5010	210	2	2	2	3	2	5	1	4	1

Ek 2'nin devamı

126	Çkcd2	1300	Kuzeydoğu	450	300	400	560	4	4	4	3	5	2	2	2	3
127	Çke3-2	1300	Kuzeydoğu	470	330	350	780	2	2	2	3	5	2	2	2	3
128	Çke2	1240	Güneybatı	1500	350	550	850	3	3	3	3	1	3	2	4	3
129	ÇsÇkcd3	1450	kuzey	3200	200	3100	680	4	4	4	3	5	4	1	4	3
130	Çke3	1500	Kuzeybatı	1300	300	950	960	2	2	2	4	5	3	2	4	3
131	Çkbc2	1255	Kuzey	300	500	600	920	2	2	2	3	5	3	3	2	3
132	Çkcd2-1	1200	Kuzey	805	100	430	930	4	4	4	3	5	2	1	3	3
133	ÇkÇsc3	1444	Kuzey	1470	300	1310	940	3	3	3	3	5	4	2	4	3
134	Çkbc3-1	1283	GüneyBatı	820	355	1000	900	1	1	1	3	1	4	2	3	3
135	Çkcd3	1197	Kuzey	300	50	300	460	4	4	4	3	5	2	1	2	2
136	Çke3	1237	Batı	800	100	990	640	2	2	2	3	3	3	1	3	3
137	Çkcd2	1237	Batı	700	30	820	870	4	4	4	3	3	3	1	3	3
138	Çkbc2	1255	Batı	1190	150	1270	860	2	2	2	3	3	4	1	4	3
139	Çke3	1255	Batı	1250	90	1340	590	2	2	2	3	3	4	1	4	3
140	Çkb3	1160	Batı	270	110	420	610	1	1	1	3	3	2	1	2	3
141	Çke3-2	1160	Batı	420	50	550	470	2	2	2	3	3	3	1	2	2
142	Çscd2-2	1500	Kuzeybatı	3390	250	3520	530	5	5	5	4	5	4	2	4	3
143	Çkcd3	1450	Batı	810	150	590	810	4	4	4	3	3	3	1	3	3
144	Çkcd2-2	1013	Batı	1600	170	1750	620	4	4	4	3	3	4	1	4	3
145	Çscd3/Gab2	1550	Kuzey	3490	350	3570	760	5	5	5	4	5	4	2	4	3
146	Çkb2	1300	Güney	1150	50	800	630	2	2	2	3	2	3	1	4	3
147	Çkcd3-1	1320	Doğu	1180	150	750	1100	4	4	4	3	4	3	1	4	4
148	ÇkÇsb3	1280	Kuzey	800	250	560	980	3	3	3	3	5	3	2	3	3
149	Çkcd3	1320	Kuzeybatı	460	210	240	960	4	4	4	3	5	1	1	2	3
150	ÇkÇsb3-1	1300	Kuzey	960	180	650	980	3	3	3	3	5	3	1	3	3

Ek 2'nin devamı

151	ÇkÇscd2	1320	Kuzeybatı	1130	100	450	1550	4	4	4	3	5	2	1	4	4
152	Çkab3-1	1370	Güneybatı	1600	90	650	1300	1	1	1	3	1	3	1	4	4
153	Bçk	1370	Güneybatı	1470	60	540	890	3	3	3	3	1	3	1	4	3
154	ÇsÇkbc3	1390	Batı	1800	150	800	560	2	2	2	3	3	3	1	4	3
155	Çsb4	1420	Batı	2000	280	800	470	3	3	3	3	3	3	2	4	2
156	Bçs-1	1440	Güney	2010	140	800	350	4	4	4	3	2	3	1	4	2
157	ÇsÇkb4	1450	Kuzey	2200	190	900	200	2	2	2	3	5	3	1	4	1
158	Çsb4	1390	Kuzeybatı	1800	320	800	890	3	3	3	3	5	3	2	4	3
159	Çsbc3	1420	Batı	1300	170	100	1200	3	3	3	3	3	1	1	4	4
160	Çkc3	1242	Kuzey	790	280	480	1200	2	2	2	3	5	2	2	3	4
161	Çkc2	1270	Kuzeybatı	700	140	400	800	3	3	3	3	5	2	1	3	3
162	Çkbc4-2	1200	Batı	1200	100	450	700	1	1	1	3	3	2	1	4	3
163	Çkb4	1250	Güney	1150	280	180	1300	1	1	1	3	2	1	2	4	4
164	Çkab3-1	1290	Doğu	980	210	300	550	1	1	1	3	4	2	1	3	3
165	Çkc3	1340	Güneydoğu	1000	110	140	780	2	2	2	3	3	1	1	4	3
166	Çkbc4	1280	Güneydoğu	960	270	300	370	1	1	1	3	3	2	2	3	2
167	Çkbc3	1250	Batı	1200	200	550	480	1	1	1	3	3	3	1	4	2
168	Çkcd3-1	1260	Kuzeybatı	1000	250	390	230	4	4	4	3	5	2	2	4	1
169	Çkbc3	1100	Kuzeybatı	1460	160	400	1600	1	1	1	3	5	2	1	4	4
170	Çkb3-3	1190	Güney	880	140	300	1850	1	1	1	3	2	2	1	3	4
171	Çkbc2-2	1060	Kuzeybatı	1500	80	280	2050	2	2	2	3	5	2	1	4	4
172	ÇkMb3	1040	Batı	1700	90	370	2150	4	4	4	3	3	2	1	4	4
173	Çkcd1	1060	Batı	1750	60	580	2200	4	4	4	3	3	3	1	4	4
174	Çkbc4	1220	Kuzeybatı	980	110	300	1500	1	1	1	3	5	2	1	3	4
175	Çkc1-1	1220	Güney	640	70	160	1400	4	4	4	3	2	1	1	3	4

Ek 2'nin devamı

176	Knbc3	1180	Kuzeydoğu	760	180	400	250	5	5	5	3	5	2	1	3	2
177	ÇsKnbc3	1150	Kuzeydoğu	340	100	130	680	5	5	5	3	5	1	1	2	3
178	Çsa3	1270	Güney	500	410	510	640	3	3	3	3	2	3	2	3	3
179	ÇsÇkc3	1170	Doğu	200	140	220	630	3	3	3	3	4	1	1	1	3
180	Gcd3	1280	Kuzey	1000	130	800	800	5	5	5	3	5	3	1	4	3
181	ÇsKnbc3	1370	Güneydoğu	1050	400	700	650	5	5	5	3	3	3	2	4	3
182	Çsab3-2	1420	Batı	800	230	420	580	3	3	3	3	3	2	1	3	3
183	Çsd1/Knb3	1130	Güneybatı	970	130	400	700	5	5	5	3	1	2	1	3	3
184	ÇsÇkbc3	1250	Doğu	640	200	370	810	2	2	2	3	4	2	1	3	3
185	Knbc3	1230	Kuzey	670	150	640	820	4	4	4	3	5	3	1	3	3
186	Knbc3	1250	Doğu	1130	250	840	740	5	5	5	3	4	3	2	4	3
187	ÇsÇkc3	1120	Kuzeydoğu	200	60	120	650	3	3	3	3	5	1	1	1	3
188	ÇkÇscd3	1200	Kuzey	240	80	290	910	4	4	4	3	5	2	1	1	3
189	Çkcd1/Knab3	1220	Kuzey	320	180	330	850	5	5	5	3	5	2	1	2	3
190	Çkd1-2	1180	Kuzeydoğu	300	100	140	700	5	5	5	3	5	1	1	2	3
191	ÇsÇkbc2	1260	Kuzey	500	130	550	560	3	3	3	3	5	3	1	3	3
192	Çka3	1490	Güney	300	150	120	430	1	1	1	3	2	1	1	2	2
193	Çkcd3	1420	Güney	500	400	340	400	4	4	4	3	2	2	2	3	2
194	Çkcd1	1340	Güney	700	100	560	510	4	4	4	3	2	3	1	3	3
195	GÇsKnbc3	1410	Kuzey	1100	190	900	120	5	5	5	3	5	3	1	4	1
196	Çsb3	1470	Kuzey	1300	800	1100	250	3	3	3	3	5	4	3	4	2
197	Çsd3/Gb3	1570	Kuzeybatı	2180	200	370	500	5	5	5	4	5	2	1	4	3
198	KnÇsbc3-2	1540	Kuzey	1700	50	700	350	5	5	5	4	5	3	1	4	2
199	ÇsGcd3	1600	Güneybatı	2680	100	870	480	5	5	5	4	1	3	1	4	2
200	Çkbc1	1630	Güney	2200	60	300	450	3	3	3	4	2	2	1	4	2

Ek 2'nin devamı

201	ÇsGcd3-2	1530	Doğu	1960	230	1800	560	5	5	5	4	4	4	1	4	3
202	GKncd2	1570	Güney	2000	100	100	450	5	5	5	4	2	1	1	4	2
203	Çscd2/Knab3	1460	Güneydoğu	1750	110	1400	550	5	5	5	3	3	4	1	4	3
204	Çkcd2/b2	1280	Güneydoğu	770	260	750	410	3	3	3	3	3	3	2	3	2
205	Çkc3-1	1400	Güney	900	100	890	380	2	2	2	3	2	3	1	3	2
206	ÇsÇkKnbc3	1290	Güney	1300	50	1200	210	5	5	5	3	2	4	1	4	1
207	ÇsÇkbc3	1400	Güney	1200	150	1100	210	2	2	2	3	2	4	1	4	1
208	ÇsKnbc3	1420	Güney	1400	70	670	230	5	5	5	3	2	3	1	4	1
209	Çkcd1/a	1220	Güney	1100	40	350	410	5	5	5	3	2	2	1	4	2
210	Çkcd3	1330	Kuzey	300	100	190	430	4	4	4	3	5	1	1	2	2
211	Çkcd2	1360	Doğu	750	240	520	800	4	4	4	3	4	3	1	3	3
212	Çkcd1	1450	Doğu	1000	100	900	750	4	4	4	3	4	3	1	4	3
213	DyGnKnd1	1245	Doğu	680	50	400	680	5	5	5	3	4	2	1	3	3
214	Çkcd2	1400	Doğu	400	270	360	450	4	4	4	3	4	2	2	2	2
215	Çkbc3	1500	Doğu	1000	30	700	550	1	1	1	4	4	3	1	4	3
216	ÇsÇkKnbc3	1330	Doğu	850	320	440	610	5	5	5	3	4	2	2	3	3
217	Gnbc3-1	1390	Doğu	900	270	460	380	5	5	5	3	4	2	2	3	2
218	Çkb3	1425	Doğu	1000	360	510	450	1	1	1	3	4	3	2	4	2
219	Çkcd2-1	1530	Güneydoğu	430	70	270	650	4	4	4	4	3	2	1	2	3
220	Çkd1/b2	1450	Güney	680	170	600	600	2	2	2	3	2	3	1	3	3
221	Çkbc3	1410	Güneydoğu	570	260	420	580	1	1	1	3	3	2	2	3	3
222	Çkcd1/a	1480	Güney	460	100	380	610	5	5	5	3	2	2	1	2	3
223	Çkcd2/b2	1460	Kuzey	800	190	750	300	3	3	3	3	5	3	1	3	2
224	Çka	1530	Kuzey	1050	100	900	280	3	3	3	4	5	3	1	4	2
225	Bçk-2	1450	Kuzey	700	150	740	350	3	3	3	3	5	3	1	3	2

Ek 2'nin devamı

226	Çkc3	1440	Kuzeybatı	1200	330	1000	150	2	2	2	3	5	4	2	4	1
227	Çsc3	1580	Kuzeybatı	1600	300	1400	190	3	3	3	4	5	4	2	4	1
228	ÇkÇscd3	1470	Kuzey	1150	250	980	250	4	4	4	3	5	3	2	4	2
229	Çkab3	1580	Kuzeybatı	1500	210	1300	120	1	1	1	4	5	4	1	4	1
230	Çke1	1520	Kuzey	1050	140	1150	160	4	4	4	4	5	4	1	4	1
231	ÇsÇkbc3	1580	Kuzey	1250	200	1050	220	2	2	2	4	5	4	1	4	1
232	Çkb2	1590	Kuzey	1700	110	1500	230	2	2	2	4	5	4	1	4	1
233	ÇsGcd3	1500	Kuzeybatı	800	250	750	400	5	5	5	4	5	3	2	3	2
234	Çsd2	1500	Kuzeybatı	580	110	450	450	4	4	4	4	5	2	1	3	2
235	Çsb3	1510	Kuzeybatı	1120	470	1000	380	3	3	3	4	5	4	2	4	2
236	Çsbc3-1	1590	Kuzeybatı	1000	180	750	350	3	3	3	4	5	3	1	4	2
237	Çked3-1	1430	Güney	580	500	530	260	4	4	4	3	2	3	3	3	2
238	Knbc3	1420	Doğu	700	500	600	180	5	5	5	3	4	3	3	3	1
239	Çscd2	1600	Doğu	1440	130	1300	220	5	5	5	4	4	4	1	4	1
240	Çsa3	1560	Güneydoğu	1300	90	1150	300	3	3	3	4	3	4	1	4	2
241	Çsbc3	1600	Güneydoğu	1400	150	1280	200	3	3	3	4	3	4	1	4	1
242	ÇkÇscd3	1470	Güney	950	200	780	360	4	4	4	3	2	3	1	3	2
243	ÇsÇkcd2	1550	Güney	1000	140	900	420	4	4	4	4	2	3	1	4	2
244	Çkc3	1480	Batı	340	340	290	560	2	2	2	3	3	2	2	2	3
245	Kncd3	1360	Doğu	540	130	180	710	5	5	5	3	4	1	1	3	3
246	Çkcd2-2	1350	Doğu	960	280	140	650	4	4	4	3	4	1	2	3	3
247	Çka0	1250	Güney	790	250	300	800	5	5	5	3	2	2	2	3	3
248	Çkb3	1410	Güney	600	100	520	700	1	1	1	3	2	3	1	3	3
249	Çkd1/b2	1370	Güney	200	140	140	650	2	2	2	3	2	1	1	1	3
250	Çke1	1270	Güneydoğu	400	280	120	680	4	4	4	3	3	1	2	2	3

Ek 2'nin devamı

251	Çkbc2	1340	Güney	500	240	370	550	2	2	2	3	2	2	1	3	3
252	Çkcd3-1	1300	Kuzey	580	130	380	400	4	4	4	3	5	2	1	3	2
253	Çkbc2	1240	Kuzeydoğu	350	170	100	450	2	2	2	3	5	1	1	2	2
254	Çkb2-1	1300	Güneydoğu	450	30	290	510	2	2	2	3	3	2	1	2	3
255	Çkcd1	1400	Doğu	370	40	350	620	4	4	4	3	4	2	1	2	3
256	ÇkÇscd3	1350	Kuzeydoğu	540	20	520	560	4	4	4	3	5	3	1	3	3
257	Gnbc3-1	1300	Kuzey	660	160	260	380	5	5	5	3	5	2	1	3	2
258	Çkbc3	1230	Kuzey	740	100	450	350	1	1	1	3	5	2	1	3	2
259	Knbc3	1270	Kuzey	840	310	200	180	4	4	4	3	5	1	2	3	1
260	Çkcd3-1	1280	Kuzeydoğu	400	190	280	500	4	4	4	3	5	2	1	2	3
261	Çkb2	1400	Doğu	230	50	200	550	2	2	2	3	4	1	1	1	3
262	Çkcd3-2	1400	Kuzeydoğu	450	260	380	450	4	4	4	3	5	2	2	2	2
263	Çkbc3	1330	Güneydoğu	260	240	300	520	1	1	1	3	3	2	1	2	3
264	Çkc3-1	1470	Doğu	690	90	700	510	2	2	2	3	4	3	1	3	3
265	Çkcd1	540	Güney	1500	140	740	300	4	4	4	2	2	3	1	4	2
266	Çkbc3-3	740	Kuzeydoğu	1070	530	430	1250	1	1	1	2	5	2	3	4	4
267	Çkd2	987	Kuzeydoğu	570	570	350	1650	4	4	4	2	5	2	3	3	4
268	Çkcd3	850	Kuzeydoğu	580	390	50	820	4	4	4	2	5	1	2	3	3
269	Çkbc3	1080	Güneybatı	470	160	170	2100	1	1	1	3	1	1	1	2	4
270	Mçka	1040	Güneydoğu	860	250	690	890	4	4	4	3	3	3	2	3	3
271	ÇkKncd2	1180	Kuzey	1430	70	1040	500	5	5	5	3	5	4	1	4	3
272	Çkcd3	1350	Güneybatı	1080	420	220	4020	4	4	4	3	1	1	2	4	4
273	Çkcd2	1380	Güney	320	315	400	1900	4	4	4	3	2	2	2	2	4
274	GÇsA	1580	Güneydoğu	1300	200	1600	3400	5	5	5	4	3	4	1	4	4
275	Çkd2	1540	Güneydoğu	2160	640	1720	1100	4	4	4	4	3	4	3	4	4

Ek 2'nin devamı

276	GÇsA	1750	Kuzeybatı	3400	150	2100	3400	5	5	5	4	5	4	1	4	4
277	Mbc2	1130	Güney	410	280	340	620	5	5	5	3	2	2	2	2	3
278	Çkcd2-1	1470	Güney	770	100	220	770	4	4	4	3	2	1	1	3	3
279	Çsb3	1380	Güneydoğu	620	110	530	850	3	3	3	3	3	3	1	3	3
280	BM-2	1140	Güney	325	150	280	900	5	5	5	3	2	2	1	2	3
281	Çsd/Knbc3-2	1390	Batı	650	310	500	3400	5	5	5	3	3	3	2	3	4
282	Mb3	1310	Güneybatı	1620	260	1180	1170	4	4	4	3	1	4	2	4	4
283	Çkc3-2	1160	Kuzey	610	170	480	560	2	2	2	3	5	2	1	3	3
284	Çkc2	890	Kuzey	765	160	240	2000	3	3	3	2	5	1	1	3	4
285	BAr-1	810	Kuzeybatı	810	270	540	2300	4	4	4	2	5	3	2	3	4
286	Mab3-3	600	Doğu	640	310	380	770	4	4	4	2	4	2	2	3	3
287	ÇkMab3-2	900	Kuzeydoğu	1840	395	713	620	4	4	4	2	5	3	2	4	3
288	Bçk-2	1030	Güney	1840	250	1880	780	3	3	3	3	2	4	2	4	3
289	Mbc3-2	1170	Güneydoğu	1100	540	130	820	5	5	5	3	3	1	3	4	3
290	Mb3-1	1200	Batı	495	160	540	1560	4	4	4	3	3	3	1	2	4
291	Çkbc1-1	713	Kuzeydoğu	1000	310	170	230	3	3	3	2	5	1	2	4	1
292	BAr	660	Güney	750	1070	110	3600	4	4	4	2	2	1	4	3	4
293	Bçk	520	Güney	230	94	120	1010	3	3	3	2	2	1	1	1	4
294	Mbc3	1030	Batı	1200	240	720	785	5	5	5	3	3	3	1	4	3
295	Mbc3	946	Kuzeydoğu	1360	100	340	380	5	5	5	2	5	2	1	4	2
296	Çkcd1	1340	Doğu	820	60	820	4000	4	4	4	3	4	3	1	3	4
297	Kncd3	1250	Kuzey	430	90	230	2800	5	5	5	3	5	1	1	2	4
298	ÇkMKnab3	1240	Kuzeydoğu	1380	290	1080	570	5	5	5	3	5	4	2	4	3
299	BM-2	990	Kuzey	510	80	260	620	5	5	5	2	5	2	1	3	3

EK 3. Çalışma Senaryosu-1

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
1	12	30	37	51	28	20	34
2	10	24	41	52	25	30	39
3	16	29	30	53	15	20	31
4	19	23	30	54	16	28	31
5	24	26	31	55	29	20	35
6	11	21	46	56	24	25	32
7	25	29	32	57	18	26	40
8	24	26	37	58	17	23	41
9	22	23	37	59	16	27	36
10	25	25	45	60	30	25	44
11	26	25	41	61	22	22	44
12	19	26	41	62	25	22	32
13	30	20	45	63	19	23	47
14	10	28	35	64	14	29	34
15	19	28	39	65	26	20	44
16	26	28	41	66	10	22	33
17	14	22	32	67	10	30	48
18	21	20	44	68	15	30	34
19	12	28	31	69	28	30	40
20	29	21	44	70	21	20	45
21	15	25	31	71	16	29	31
22	18	24	41	72	24	20	49
23	21	28	42	73	29	25	30
24	28	23	33	74	17	21	46
25	20	29	39	75	29	24	50
26	28	29	41	76	13	29	47
27	21	24	36	77	10	21	30
28	12	28	42	78	15	22	36
29	24	27	45	79	14	24	44
30	23	20	32	80	23	22	48
31	22	28	41	81	28	23	38
32	28	24	35	82	13	24	33
33	18	28	36	83	19	26	33
34	11	21	31	84	11	28	47
35	11	21	50	85	11	25	44
36	24	24	49	86	30	27	39
37	13	24	44	87	15	30	42
38	28	30	36	88	29	23	40
39	26	26	40	89	19	28	48
40	22	22	45	90	12	21	46
41	18	20	50	91	17	25	34
42	27	24	36	92	17	25	40
43	16	29	30	93	20	25	33
44	10	26	48	94	22	21	38
45	12	23	38	95	29	30	34
46	10	29	33	96	18	20	44
47	19	30	39	97	11	27	41
48	12	26	45	98	30	30	41
49	12	30	38	99	30	26	36
50	14	23	50	100	19	22	39

Ek 3'ün devamı

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
101	21	28	41	151	12	27	46
102	13	29	50	152	21	29	40
103	27	25	31	153	22	24	45
104	22	22	34	154	24	30	44
105	26	22	43	155	26	23	50
106	11	21	35	156	10	24	45
107	12	30	37	157	20	24	38
108	15	22	40	158	11	28	43
109	14	23	34	159	15	22	41
110	18	26	42	160	27	30	35
111	16	24	47	161	17	21	41
112	24	24	32	162	29	22	31
113	26	21	39	163	12	23	37
114	20	24	35	164	26	20	35
115	13	23	30	165	20	25	32
116	24	30	36	166	17	30	45
117	19	27	46	167	20	25	36
118	27	22	34	168	26	29	39
119	10	26	33	169	11	29	47
120	24	29	35	170	16	30	43
121	27	25	48	171	15	26	37
122	28	30	43	172	25	28	49
123	27	23	43	173	16	24	46
124	14	29	31	174	30	29	42
125	16	30	43	175	12	20	32
126	16	29	40	176	11	27	48
127	26	26	36	177	13	28	50
128	13	24	50	178	30	25	50
129	10	24	46	179	28	28	37
130	11	21	48	180	28	24	39
131	27	27	46	181	24	21	34
132	27	23	41	182	30	23	49
133	18	24	34	183	13	21	43
134	16	22	50	184	28	21	32
135	14	30	34	185	30	24	41
136	13	20	30	186	20	27	44
137	10	25	40	187	22	30	39
138	23	24	41	188	24	22	40
139	12	28	39	189	30	27	50
140	18	25	45	190	22	26	48
141	11	29	36	191	14	20	45
142	19	24	46	192	25	24	38
143	17	23	43	193	29	21	31
144	12	29	33	194	30	25	41
145	14	29	34	195	19	23	35
146	19	22	43	196	11	29	41
147	24	22	30	197	20	24	36
148	20	27	50	198	28	30	39
149	10	23	35	199	24	20	34
150	15	26	38	200	23	28	33

Ek 3'ün devamı

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
201	17	20	39	251	16	24	42
202	10	26	41	252	20	24	48
203	16	24	34	253	27	24	37
204	12	22	42	254	30	20	34
205	21	29	32	255	19	25	34
206	26	27	30	256	22	28	49
207	13	21	48	257	29	25	37
208	29	27	41	258	27	29	31
209	23	29	47	259	28	25	42
210	15	26	31	260	11	26	32
211	20	28	30	261	10	26	46
212	20	29	41	262	28	24	38
213	16	30	43	263	18	22	46
214	10	27	36	264	24	26	37
215	23	28	39	265	10	23	34
216	21	24	50	266	24	26	45
217	11	29	35	267	18	24	43
218	15	22	49	268	23	20	39
219	28	28	35	269	15	27	49
220	22	29	48	270	29	29	39
221	22	22	37	271	27	21	38
222	25	22	33	272	12	23	48
223	10	25	49	273	25	24	41
224	18	27	39	274	28	21	41
225	14	22	35	275	21	28	35
226	26	21	37	276	29	21	35
227	10	27	40	277	24	21	37
228	26	28	36	278	12	24	37
229	12	29	42	279	29	22	49
230	19	20	42	280	22	27	35
231	27	27	47	281	11	29	30
232	11	20	31	282	23	28	36
233	19	30	30	283	22	26	32
234	29	30	31	284	12	26	32
235	27	24	38	285	27	24	48
236	21	24	30	286	20	23	47
237	14	28	43	287	25	27	47
238	21	21	31	288	10	30	32
239	19	28	41	289	25	27	33
240	10	25	40	290	11	29	30
241	29	23	39	291	27	26	31
242	16	21	30	292	23	21	41
243	17	25	45	293	10	23	39
244	19	25	49	294	29	29	34
245	14	29	36	295	22	22	41
246	30	30	42	296	25	28	36
247	19	24	37	297	17	26	50
248	20	23	32	298	14	29	42
249	19	23	38	299	18	26	35
250	17	25	31				

EK 4. Çalışma Senaryosu-2

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
1	44	37	2	51	32	50	6
2	50	31	28	52	37	47	25
3	50	50	13	53	50	30	18
4	40	41	25	54	35	50	23
5	39	43	5	55	43	34	11
6	42	50	14	56	33	31	1
7	30	45	13	57	45	33	6
8	32	30	7	58	43	36	28
9	39	32	5	59	42	45	9
10	38	38	21	60	43	42	2
11	36	34	27	61	36	49	23
12	33	42	5	62	46	47	10
13	50	41	6	63	35	42	22
14	42	30	13	64	46	30	11
15	47	47	29	65	30	48	12
16	42	40	2	66	36	34	18
17	35	40	1	67	48	32	22
18	42	40	21	68	30	43	29
19	37	44	1	69	44	42	2
20	40	30	17	70	37	39	26
21	35	46	22	71	36	36	23
22	46	50	27	72	35	33	1
23	41	50	12	73	35	37	4
24	36	36	26	74	46	36	5
25	42	41	14	75	41	34	19
26	37	34	20	76	50	44	28
27	41	46	9	77	33	38	21
28	39	47	15	78	39	36	4
29	31	48	19	79	32	44	15
30	31	35	23	80	39	50	5
31	50	34	3	81	40	35	9
32	44	30	16	82	44	46	17
33	33	49	18	83	48	50	4
34	39	36	17	84	43	40	26
35	37	47	6	85	43	33	6
36	40	46	6	86	33	45	25
37	40	33	22	87	45	39	21
38	42	37	2	88	38	47	23
39	32	34	8	89	47	39	25
40	43	37	1	90	45	31	4
41	45	30	24	91	48	49	19
42	31	38	22	92	41	46	5
43	34	46	19	93	41	40	29
44	38	38	6	94	49	41	2
45	35	37	13	95	33	42	1
46	49	48	2	96	30	35	17
47	41	48	20	97	44	32	25
48	49	39	8	98	37	40	7
49	38	36	7	99	39	44	26
50	33	47	3	100	30	48	1

Ek 4'ün devamı

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
101	32	33	24	151	39	44	10
102	30	32	10	152	40	31	22
103	49	41	18	153	48	37	20
104	32	30	13	154	30	49	25
105	35	30	27	155	44	45	24
106	36	30	26	156	34	41	19
107	43	45	16	157	35	46	7
108	31	31	15	158	47	50	2
109	34	46	18	159	42	49	5
110	32	46	23	160	40	44	15
111	46	49	19	161	39	35	2
112	44	43	26	162	32	39	25
113	31	38	3	163	39	37	21
114	48	48	2	164	31	43	25
115	40	36	19	165	50	39	9
116	45	47	25	166	32	41	16
117	34	30	21	167	42	33	11
118	46	31	28	168	45	42	1
119	49	38	18	169	38	40	3
120	33	33	23	170	30	45	9
121	40	43	13	171	36	40	7
122	50	36	8	172	37	50	23
123	41	43	25	173	34	36	2
124	30	32	29	174	32	47	12
125	43	50	4	175	47	43	11
126	43	31	6	176	33	30	8
127	38	38	4	177	50	36	11
128	45	44	8	178	42	50	17
129	47	42	19	179	38	41	17
130	41	42	13	180	41	49	3
131	37	44	5	181	38	49	26
132	38	49	21	182	35	37	23
133	34	46	2	183	47	37	17
134	44	47	29	184	47	43	6
135	38	40	26	185	46	43	18
136	35	38	13	186	33	33	23
137	33	41	16	187	49	30	5
138	32	45	13	188	40	49	6
139	30	38	13	189	41	47	23
140	34	45	14	190	35	44	5
141	38	37	22	191	33	35	19
142	42	40	20	192	43	50	27
143	44	38	3	193	42	41	14
144	47	50	7	194	43	32	6
145	46	49	24	195	43	43	16
146	31	42	29	196	34	33	2
147	31	38	13	197	39	49	3
148	36	49	13	198	40	42	1
149	45	43	24	199	34	32	2
150	37	37	1	200	35	32	11

Ek 4'ün devamı

SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)	SIRA	RÜZGAR (km/saat)	SICAKLIK (°C)	NEM (%)
201	37	33	9	251	43	38	19
202	43	47	5	252	32	45	5
203	47	38	3	253	45	34	12
204	46	42	13	254	49	35	25
205	38	34	10	255	36	37	3
206	34	36	2	256	43	45	10
207	44	32	27	257	31	45	13
208	32	42	6	258	36	46	7
209	30	44	9	259	46	43	12
210	45	32	24	260	43	40	19
211	47	35	1	261	30	31	26
212	41	30	5	262	34	40	3
213	30	49	8	263	48	48	9
214	41	42	18	264	46	39	27
215	39	32	11	265	42	41	12
216	38	37	1	266	35	47	20
217	48	32	17	267	33	48	21
218	31	38	10	268	43	35	15
219	31	34	29	269	33	45	13
220	49	31	3	270	39	37	22
221	35	46	23	271	34	34	14
222	35	30	4	272	35	42	24
223	36	35	6	273	42	38	24
224	48	40	25	274	49	30	22
225	30	42	5	275	30	40	13
226	44	38	2	276	40	49	19
227	34	50	8	277	45	40	8
228	45	42	13	278	41	35	25
229	42	50	28	279	49	43	6
230	44	30	14	280	49	44	28
231	43	50	5	281	49	39	2
232	45	38	20	282	49	34	13
233	37	45	12	283	38	47	25
234	48	47	17	284	46	35	29
235	38	41	20	285	36	34	28
236	42	48	2	286	49	38	10
237	32	41	26	287	38	35	20
238	41	38	25	288	30	36	17
239	36	38	20	289	34	50	22
240	33	47	19	290	30	42	14
241	43	33	25	291	32	47	3
242	46	36	24	292	37	34	3
243	39	32	15	293	44	43	5
244	49	47	10	294	45	38	10
245	33	31	1	295	38	43	15
246	36	32	4	296	35	39	2
247	34	50	28	297	42	49	6
248	43	43	7	298	48	44	25
249	41	32	5	299	48	43	15
250	48	49	22				