

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



VERİ ANALİZ YÖNTEMLERİNE DAYALI OLARAK ORMAN
YANGINLARININ İNCELENMESİ

YÜKSEK LİSANS TEZİ

Zeynep AYTOLU KÜLAHCI

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

NİSAN, 2023

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



VERİ ANALİZ YÖNTEMLERİNE DAYALI OLARAK ORMAN
YANGINLARININ İNCELENMESİ

YÜKSEK LİSANS TEZİ

Zeynep AYTOLU KÜLAHCI
(Y2013.010011)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Zafer ASLAN

NİSAN, 2023

TEZ SAVUNMA TUTANAĐI

ONUR SÖZÜ

Yüksek Lisans olarak sunduđum “VERİ ANALİZ YÖNTEMLERİNE DAYALI OLARAK ORMAN YANGINLARININ İNCELENMESİ” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça 'da gösterilenlerden oluştuđunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (26/04/2023)

Zeynep AYTOLU KÜLAHCİ

ÖNSÖZ

Eđitim hayatım boyunca bana destek olan ve yardımlarını esirgemeyen bařta sevgili babam Emrah Aytolu ve ailem olmak üzere, bu alıřmanın gerekleřtirildiđi süre boyunca bana yol gösteren, bilgi ve birikimlerini benimle paylařan sevgili danıřman hocam Prof. Dr. Zafer Aslan'a en iten teřekkürlerimi sunarım.

Eđitim hayatım boyunca desteđini ve bilgisini esirgemeyen tüm hocalarıma teřekkür ederim. Sizlerin özverisi ve öğrettikleriniz sayesinde geliřtim ve bu noktaya geldim, bana olan inanlarınız ve sabrınız için teřekkürler.

Bu süreç boyunca beni destekleyen ve her zaman yanımda olan eřime ve her zaman yanımda olan ve desteklerini esirgemeyen sevgili arkadařım Meltem Makaracı'ya teřekkür etmek istiyorum.

Son olarak, desteđiyle yanımda olan herkese teřekkür ederim.

Nisan, 2023

Zeynep AYTOLU KÜLAHCI

VERİ ANALİZ YÖNTEMLERİNE DAYALI OLARAK ORMAN YANGINLARININ İNCELENMESİ

ÖZET

Bu araştırmanın temel amacı, Antalya ve Muğla illerinde 2020-2023 yılları arasında gerçekleşen yangınların enerji miktarını belirleyerek, yangınların şiddetini değerlendirmektir. Çalışmada, MODIS cihazlarıyla kaydedilen veriler kullanılmış olup, Terra ve Aqua EOS uyduları tarafından sağlanan MODIS verileri incelenmiştir. Antalya'da 1742 ve Muğla'da 597 yangın verisi kullanılmıştır. Yangınların çıkardığı enerji miktarını hesaplamak için, uydu görüntülerinden elde edilen parlaklık sıcaklığı ve sıcaklığa olan güven değerleri kullanılmıştır. Bu veriler kullanılarak, her bir yangın olayının toplam enerjisi kilowatt cinsinden hesaplanmıştır. Elde edilen enerji miktarları, yangının büyüklüğünü ve şiddetini yansıtmaktadır. Bu çalışmada, makine öğrenmesi yöntemlerinden Yapay Sinir Ağı (YSA), Destek Vektör Regresyonu (SVR) ve Doğrusal Regresyon (Liner) kullanılarak enerji miktarının tahmini yapılmıştır. SVR ve Liner modelleri üzerinde yapılan analizlerde, yangın şiddeti ile enerji miktarı arasında doğrusal bir ilişki tespit edilememiştir. Ancak, YSA modelinde verilerin normalize edilmesiyle düşük sıcaklıklı yangın olayları için başarılı sonuçlar elde edilmiştir. YSA modeli, düşük sıcaklıklar için daha iyi öğrenme yeteneği gösterir, bu da daha doğru tahminler yapabilmesine olanak sağlar, modelin düşük sıcaklıklar için daha iyi bir öğrenme yeteneğine sahip olduğunu ve bu nedenle daha doğru tahminler yapabildiğini işaret etmektedir. Yangınların enerji miktarını belirlemenin ve yangınların şiddetini analiz etmenin önemli bir adımı olarak değerlendirilebilir. Çalışmanın spesifik sonucu olarak, seçilen iki inceleme bölgesinde orman yangını olasılığının tahmini için en başarılı olan modeller saptanmıştır. Antalya'da ve Muğla'da YSA yöntemine dayalı tahmin çalışmalarının SVM ve LR modellerinden daha başarılı olduğu saptanmıştır. Elde edilen veriler, yangın kontrol ve yönetim stratejilerinin geliştirilmesine ve yangın riskinin azaltılmasına katkı sağlayabilir. SVR modelinin düşük sıcaklıklı yangınlar için daha iyi performans göstermesi, gelecekteki

çalıřmalarda daha fazla optimize edilmiř modellerin geliřtirilebileceđini gstermektedir. Elde edilen bulgular, yangın ynetimi ve mdahale stratejilerinin geliřtirilmesine katkı sađlayabilir ve gelecekteki yangın olaylarının etkilerini daha iyi anlamamıza yardımcı olabilir.

Anahtar Kelimeler: Derin ğrenme, Makine ğrenmesi, Orman Yangınları, MODIS

INVESTIGATION OF FOREST FIRES BASED ON DATA ANALYSIS METHODS

ABSTRACT

The main objective of this research is to determine the energy released by wildfires in the provinces of Antalya and Muğla between 2020 and 2023, in order to assess the severity of the fires. The study utilizes data recorded by MODIS devices and examines MODIS data provided by the Terra and Aqua EOS satellites. A total of 1742 fire incidents in Antalya and 597 fire incidents in Muğla are used in the analysis. To calculate the energy released by the fires, brightness temperature and confidence values derived from satellite imagery are employed. Using this data, the total energy of each fire event is calculated in kilowatts. The obtained energy values reflect the size and intensity of the fires. In this study, machine learning methods such as Artificial Neural Network (ANN), Support Vector Regression (SVR), and Linear Regression (Liner) are employed to predict the energy released by the fires. The analysis conducted on SVR and Liner models did not reveal a linear relationship between fire intensity and energy released. However, the ANN model yielded successful results when the data was normalized, particularly for low-temperature fire incidents. The ANN model demonstrates better learning capabilities for low-temperature fires, enabling more accurate predictions. This suggests that the ANN model has better learning capabilities for low-temperature fires and, therefore, can make more accurate predictions. Determining the energy released by wildfires and analyzing their severity can be considered an important step. As a specific outcome of the study, the most successful models for predicting the probability of forest fires in the selected study areas are identified. It is determined that the ANN method-based prediction studies in Antalya and Muğla outperform the SVM and LR models. The obtained data can contribute to the development of fire control and management strategies and the reduction of fire risks. The better performance of the SVR model for low-temperature fires indicates the potential for developing more optimized models in future research.

The findings can contribute to the improvement of fire management and intervention strategies and help us better understand the impacts of future fire incidents.

Keywords: Deep Learning, Machine Learning, Forest Fires, MODIS

İÇİNDEKİLER

ONUR SÖZÜ	V
ÖNSÖZ.....	vi
ÖZET	vii
ABSTRACT	ix
İÇİNDEKİLER.....	xi
ÇİZELGELER LİSTESİ	xiv
KISALTMALAR LİSTESİ	xv
I. GİRİŞ.....	1
II. LİTERATÜR ARAŞTIRMASI	3
A. Orman Yangınları Araştırma ve Analiz Çalışmaları:.....	3
B. Orman Yangınları Tahmin Çalışmaları:.....	4
III. YÖNTEM	6
A. Veri:.....	6
B. Neural Network (Yapay Sinir Ağları):.....	10
C. Support Vector Machines (Destek Vektör Makinesi):.....	17
1. Destek Vektör Regresyonu (Support Vector Regression -SVR)	17
D. Liner Regresyon	18
IV. ANALİZ	19
A. Yapay Sinir Ağları (Artificial Neural Networks):	19
B. Destek Vektör Regresyon (Support Vector Regression):	27
C. Liner Regresyon	29
D. Flow Diagram	30
V. SONUÇ	31
VI. KAYNAKÇA.....	32

EKLER.....	36
ÖZGEÇMİŞ.....	38

ŞEKİLLER LİSTESİ

Şekil 1 Örnek yer gözlemi	7
Şekil 2 Uyduların Yangın Görüntüleme Örneği	7
Şekil 3 Antalya Harita	8
Şekil 4 Antalya Harita	8
Şekil 5 Yapay Sinir Hücresi	9
Şekil 6 Örnek Çok Katmanlı Sinir Ağı	10
Şekil 7 Eğitim ve Doğrulama Seti Hata Oranları / Antalya	21
Şekil 8 Eğitim ve Doğrulama Seti Hata Oranları / Antalya – Normalize	21
Şekil 9 Eğitim ve Doğrulama Seti Hata Oranları / Muğla	22
Şekil 10 Eğitim ve Doğrulama Seti Hata Oranları / Muğla – Normalize	22
Şekil 11 Eğitim ve Doğrulama Veri Seti Tahmin Sonuçları MAE / Antalya – Normalize	23
Şekil 12 Eğitim ve Doğrulama Veri Seti Tahmin Sonuçları MAE / Muğla – Normalize	24
Şekil 13 Eğitim verilerinden seçilen orijinal veri / Antalya – Normalize	24
Şekil 14 Eğitim sonrası tahmin / Antalya– Normalize	24
Şekil 15 Tahmin ve Gözlem Verisi / Antalya – Normalize	25
Şekil 16 Eğitim verilerinden seçilen orijinal veri / Muğla – Normalize	25
Şekil 17 Eğitim sonrası tahmin / Muğla – Normalize	25
Şekil 18 Tahmin ve Gözlem Verisi / Muğla – Normalize	26
Şekil 19 Doğrulama Veri Seti Tahmin Sonuçları SVM / Antalya	28
Şekil 20 Doğrulama Veri Seti Tahmin Sonuçları SVM / Muğla	29
Şekil 21 Flow Diagram	30

ÇİZELGELER LİSTESİ

Çizelge 1 YSA Eğitim parametreleri ve Sonuçları	19
Çizelge 2 YSA Eğitim parametreleri ve Sonuçları – Normalize	20
Çizelge 3 YSA Hata Oranları – Normalize.....	26
Çizelge 4 SVR Hata Oranları.....	27
Çizelge 5 Liner Regresyon Hata Oranları.....	29

KISALTMALAR LİSTESİ

AUC	: Eğri Altındaki Alan / Area Under Curve
BTEMP	: Olayın tespit edilme anındaki parlaklık sıcaklığını
CONF	: Olayın gerçekleştiği andaki uydudan alınan verinin güvenilirliği
FIRMS	: Kaynak Yönetim Sistemi için Yangın Bilgileri / Fire Information for Resource Management System
FRP	: Olayın gerçekleştiği andaki Mega Watt cinsinden yangının oluşturduğu enerji
LR	: Liner Regresyon / Linear Regression
MAE	: Ortalama Mutlak Hata / Mean Absolute Error
MODIS	: Orta Çözünürlüklü Görüntüleme Spektroradyometresi / Moderate Resolution Imaging Spectroradiometer
MSE	: Ortalama Hata Karesi / Mean Squared Error
NASA	: Ulusal Havacılık ve Uzay Dairesi / National Aeronautics and Space Administration
ReLU	: Doğrultulmuş lineer birim / Rectified Linear Unit
RBF	: Radyo Tabanlı İşlev Sinir Ağları
ROC	: Alıcı işlem karakteristikleri / Receiver Operating Characteristic

RMSProp : Kök Ortalama Kare Yayılımı / Root Mean Square Propagation

SVM : Destek Vektör Makineleri / Support Vector Machine

SVR : Destek Vektör Regresyonu/ Support Vector Regression

YSA : Yapay Sinir Ağı / Artificial Neural Networks

I. GİRİŞ

Orman yangınları, doğal afetler arasında en ciddi olanlardan biridir ve önemi giderek artmaktadır. Bu nedenle, orman yangınlarının önlenmesi, yönetilmesi ve söndürülmesi için yangın büyüklüğünü tespit etmek de tahmini kadar önemlidir. Makine öğrenimi, orman yangınlarının analizi için kullanılabilir bir yöntemdir.

Bu tezde, Antalya ve Muğla illerindeki orman yangınlarının veri analiz yöntemleri kullanılarak incelenmesi amaçlanmaktadır. Veriler, MODIS sayfasından alınan ve Terra ve Aqua EOS uydularındaki MODIS cihazları tarafından kaydedilen verilerden elde edilmiştir. NASA'nın FIRMS (Fire Information for Resource Management System) adlı sistemi, Terra ve Aqua uydularının MODIS (Moderate Resolution Imaging Spectroradiometer) cihazlarından gelen verileri kullanarak, dünya genelindeki yangınları saptamakta ve izlemektedir. Uydu verileri, yangınların konumunu, büyüklüğünü, yoğunluğunu ve yayılma hızını belirlemede son derece önemli bir kaynak sağlamaktadır. Bu veriler, yangınların neden olduğu hava kirliliği, sera gazı salınımı ve ekosistemlerdeki değişiklikler gibi diğer çevresel etkileri de izlemede de yardımcı olmaktadır. Bu sayede, uydu verileri, yangınların doğal kaynaklar, insan sağlığı ve ekonomi üzerindeki olumsuz etkilerini azaltmak için çözümler üretmek için kullanılabilir. Bu çalışmada ise, 2020-2023 yılları arasında toplanan veriler kullanılmıştır. 2020-2023 yılları arasında kaydedilen yangın verilerinin gerçekleştiği ay, uydu görüntüsünden elde edilen parlaklık sıcaklığı ve sıcaklığa olan güven değerleri gibi çeşitli faktörler incelenmiş ve yangının ortaya çıkaracağı toplam enerji miktarı hesaplanmıştır.

Bu çalışmada, yapay sinir ağı (YSA), destek vektör makineleri (SVM) ve lojistik regresyon (LR) gibi veri analiz yöntemleri kullanılmıştır. Bu yöntemlerin, orman yangınlarının tespitinde etkili oldukları kanıtlanmıştır. Veriler, ilk olarak ön işleme adımlarıyla hazırlanmıştır. Daha sonra, veriler eğitim, doğrulama ve test veri setleri olarak alt bölümlere ayrılmıştır. Eğitim veri seti, YSA, SVM ve LR modellerinin eğitimi için kullanılmıştır. Doğrulama veri seti, modellerin performansını

değerlendirmek için kullanılmıştır. Test veri seti, modellerin performansını doğrulamak için ayrılmıştır. LR modelinin doğruluk oranını artırmak için daha fazla verinin göz önüne alınması ve model parametrelerinin ayarlanması gerekebilir.

Bu çalışma ile elde edilen sonuçlar, parlaklık sıcaklığının ve sıcaklığa bağlı olarak, yangınların ortaya çıkaracağı toplam enerji miktarını belirlemede etkili olduğunu ortaya koymaktadır. Bu hesaplamalar sonucunda, yangınların olası etkileri daha doğru bir şekilde öngörülebilir ve önleme tedbirleri daha etkili bir şekilde alınabilir. Sonuç olarak, bu yöntem orman yangınlarına karşı daha iyi bir koruma sağlamak için erken uyarı sistemlerine uyumlu faydalı bir araç olabilir.

II. LİTERATÜR ARAŞTIRMASI

Orman yangınları analizi ve/veya tahmini için birçok farklı yöntem ile ulusal ve uluslararası araştırmalar, tahmin çalışmaları yapılmış olup, yararlı kaynaklar hazırlanmıştır. Orman yangınlarının önlenmesinde de bu çalışmaların büyük rolleri olacaktır. Bu kaynaklar içerisinde bazılarını yol gösterici olarak kullanılmaktadır. Bu tez çalışmasında kullanılan kaynaklar iki grupta toplanmıştır:

A. Orman Yangınları Araştırma ve Analiz Çalışmaları:

Orman yangınları analizi için yapılan örnek bir çalışma “*Uydu verilerinden karar ağaçları kullanarak orman yangını tahmini* (Beşli ve Tenekeci, 2020: 899-906)” konusunda olup, bu araştırma makalesinde Kanada için veriler, uydudan alınarak normalize edilmiştir. Arazi yüzeyi sıcaklığı, bitki örtüsü, termal anomali gibi değerler ve Gini farklılık indeksi ile karar ağaçları modellenmiş, üzerinde çalışma yapılarak tahminleme yapılmıştır. Çalışma sonucunda, elde edilen değer tahmin testlerinde kullanılan verilerin değerlerinin yüksek olası sebebi ile bir ortalamaya tabi tutularak elde edilmiş olup %98.62 oranında doğru tahmin yapılabildiği sonucuna varılmıştır. “*Büyük gözlem veri tabanı ile orman yangınlarının değerlendirilmesi* (Fılıppı et al., 2014: 3077-3091)” konusundaki araştırmada veriler gözlem istasyonlarından alınmıştır ve çeşitli yangın yayılım modelleri değerlendirilmiş olup çalışmalarda bazı simülasyon yöntemleri kullanılmıştır. Fakat bu tarz çalışmalarda daha verimli sonuçlar elde edebilmek için rüzgar yönünün de büyük bir etken ve ihtiyaç olduğu sonucuna varılmıştır. “*Brezilya Amazon Bölgesinde MODIS görüntüsü kullanılarak yangın riski ve vektör değişim analizi* (Eduardo et al., 2011: 76-84)” konulu çalışmada, MODIS’den alınan veriler karar ağaçları yöntemi kullanılarak yangın analizi yapılmıştır. 14 Belediyede çalışma test edilmiş ve hata oranları da göz önünde bulundurularak sonuçlar MODIS verileri ile karşılaştırılmıştır. Sınıflandırma probleminin çözümü için kullanılan yöntemle elde edilen bulgular %90,21’lik bir genel doğruluk ve 0,863’lük bir Kappa istatistiği olduğu gösterilmiştir. Bu sonuçlar yeterli

kabul edilmiş ve bu yöntemin yararları üzerinde durulmuştur. “*DT yöntemi ile local ölçekteki, uzun dönem yangın riski değerlendirilmesi* (Amatullı, 2006: 1-15)” konusundaki araştırma çalışmasında, GIS ile birleştirilmiş iki nonparametrik teknik kullanarak yangın riski birimlerini öngörebilecek anlamlı bir model sağlayabileceğini göstermiştir. Sonuçta elde edilen regresyon ağacı modeli iyi örnek olmuş olup, yönetim planı uygulama verimliliği için daha fazla veriye ihtiyaç olduğunu göstermektedir. Önerilen modelin, yangın yöneticilerine karar vermede yardımcı olabileceği ve daha geniş bir çözünürlükte uygulanabileceği, fakat daha fazla araştırmaya da ihtiyaç olduğu sonucuna varılmıştır.

B. Orman Yangınları Tahmin Çalışmaları:

Tahmin ve makine öğrenmesi yöntemleri kullanan örnek çalışma “*Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirmesi ve Türkiye yangın risk haritasının oluşturulması* (Fıdanboy, 2022: 206-218)”. Bu araştırma makalesinde yangın tahminine yönelik bir yangın analiz yapılmıştır. Bitki örtüsü, ilkim değişikliği, gece uydu görüntüleri, bağıl nem haritaları ve önceki yangın değerleri gibi birçok veri incelenerek bir araştırma çalışması yapılmıştır. Bu çalışma sonucunda bir risk haritası çıkarılmıştır. Sonuç olarak benzer şartların sağlanması durumunda derin öğrenme metot’u kullanan yapay zekâ modeli ile görüntü işleme aracılığı ile yangın çıkması ihtimal olan bölgeler belirlenebilecektir. Makine öğrenme yöntemleri ile tahmin çalışmaları yapan bir diğer kaynak ise “*Orman Yangınları modelleme ve tahmininde makine öğrenme yöntemlerinin performans değerlendirmesi* (Pham et al., 2020: -)” çalışmada Vietnam da bulunan Pu Mat National Park çalışma alanı olarak seçilmiş olup çalışma sonucunda orta ve yüksek duyarlılık aralığında yangınların tahmini edilmesine çalışılmıştır. Bir diğer çalışma ise Çin’deki orman yangınlarının makine öğrenmesi yöntemleri ile tahmin edilmesi için hazırlanan “*Makine öğrenme yöntemlerine dayalı olarak Çin’de oluşan orman yangınlarının öngörüsü* (Yongqi et al., 2022: 1-23)” çalışması olmuştur. Bu çalışmada, yangın noktaları, meteorolojik koşullar vb. durumları MATLAB ve R Studio aracılığı ile ANN(Yapay Sinir Ağları), RBF neural networks (Radyo Tabanlı İşlev Sinir Ağları) ve SVM(Destek Vektor Makinaları) gibi farklı modeller oluşturulmuştur. Çalışmada kullanılan modellerin doğruluk oranı %89,25 olarak belirlenmiş ve detaylı bir tahmin yeteneğine sahip

modeller oldukları tespit edilmiştir. Çalışma sonrasında da Çin'deki ormanlar için olası yangın haritası çıkarılmıştır. *“Makine öğrenme modellerin dayalı uzaktan algılama verilerini yeniden örnekleme algoritması ile orman yangınlarında duyarlı öngörü (Bahareh et al., 2020: 1-24)”* konulu araştırmada örnekleme algoritmaları ile orman yangını tahminleri üzerine çalışılmıştır. Çalışma içerisinde üç farklı makine öğrenmesi yöntemi kullanılmış olup oluşturulan modellerin doğruluğu için İran doğal kaynaklar müdürlüğünden alınan veriler ile model eğitilmiş ve doğrulanmış çalışma sonucunda yüksek kalitede orman yangını haritası çıkarılması amaçlanmıştır. Diğer bir kaynak olan *“Makine öğrenme teknikleri kullanarak orman yangılarının saptanması (Elshewey and Elsonbaty, 2020: 510-517)”* ile ilgili çalışmada da makine öğrenmesi ve veri madenciliği ile uygulama yapılmıştır. Üç farklı algoritma iki farklı senaryoda uygulanarak sonuçlarında da algoritmaların başarılı sonuçlar verdiği gösterilmiştir. Son olarak; *“Makine öğrenmesi ve uzaktan algılama verileri ile orman yangını öngörüsü (SUWEI et al., no date: 14983-14990)”* konulu çalışmada ise Endonazyda da ki orman yangınlarını önlemek için uydu verilerini ve önce gerçekleşmiş yangın verilerini kullanarak makine öğrenmesi temelli bir çalışma yapılmıştır. Bu çalışmada kullanılan metot ROC eğrisi olmuştur. Bu çalışmanın kendi alanı ve ROC metodunu kullanan çalışmalardan farkı ise sonuçta ROC eğrisi altında kalan alanda 0.81'in üzerinde başarı elde ederek diğer çalışmalardan daha iyi bir sonuç elde edilmiştir.


III. YÖNTEM

Bu bölümde, veriler ile ilgili bilgi ve veri madenciliği yöntemleri ile ilgili açıklamalara yer verilmiştir.

A. Veri:

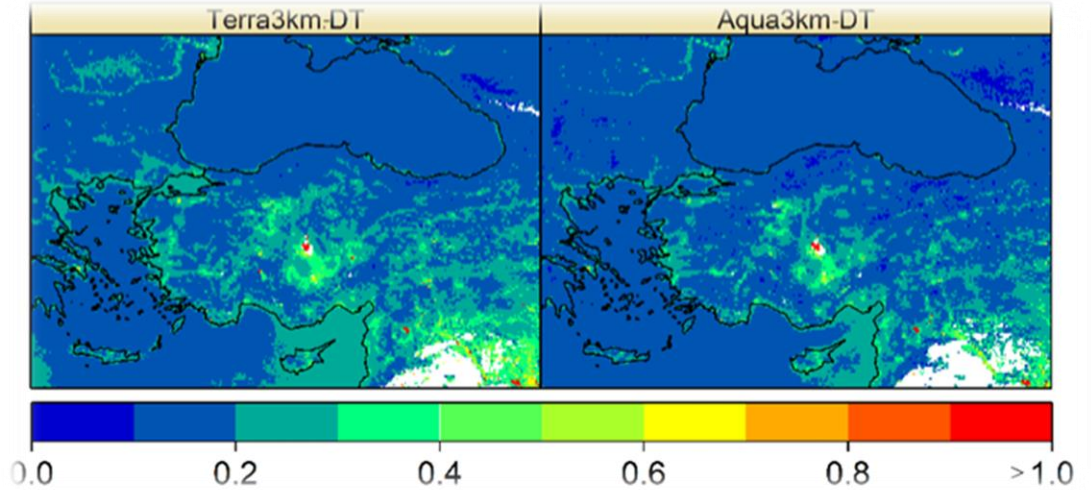
Bu çalışmada kullanılan veriler “FIRMS (Fire Information for Resource Management System)” üzerinden alınmıştır. (Schroeder et al., 2016: 210-220), (Giglio et al., 2008: 3055-3063)

Uydudan elde edilen veriler 1x1 km olarak kare bicinde elde edilmiş ve yangının tam boyutu belirlenemese de en az bir yangın olduğu bilinmektedir. Uydular, Dünya'yı izleyerek anlık görüntüler elde ederler ve aktif yangın veya diğer termal anormalliklerin piksellerin merkezinde olduğu her noktayı yangın olarak kaydederler. Bazen tek bir hat üzerinde birkaç aktif yangın görülür, bu da genellikle bir yangın cephesini temsil eder. Ancak, yangın konumlarında bazen hata meydana gelir ve bu hatalar genellikle küçüktür (<100m), ancak bazı durumlarda birkaç kilometre kadar büyük olabilir. Uzay aracı manevralarından sonra ve uzay hava olayları ile ilişkili hatalar daha da büyük olabilir. MODIS/Terra için NRT Yangın konumu doğruluğu uzay aracı manevralarından sonra düşer ve süre tipik olarak <2 saat kadardır. Uzay araçlarından etkilenen veriler de kalite ekipleri tarafından belli aralıklar ile incelenerek gürültüden temizlenmektedir, Şekil 1.



Şekil 1 - Örnek yer gözlemi

MODIS uyduları, Terra (EOS AM) ve Aqua (EOS PM) olarak adlandırılan iki uydudan veri sağlar ve her gün dünya üzerinde iki kez geçerek, 1-2 günde bir tüm küreyi kapsar. Terra uydusu ekvator üzerinden yaklaşık 10:30 ve 22:30'da geçerken, Aqua uydusu ekvator üzerinden yaklaşık 13:30 ve 01:30'da geçer. Bu sayede, her gün ekvatorun hemen hemen her yerinde en az 4 MODIS gözlemi yapılırken, kutuplara yaklaşıldıkça gözlem sayısı artar. FIRMS sitesinde gösterilen veriler ise her 5 dk'da bir güncellenmektedir. (earthdata.nasa.gov, 2023), Şekil 2.



Şekil 2 – Uyduların Yangın Görüntüleme Örneği (Karslıoğlu vd., 2022: 303-316)

Yangın verilerini ölçen uydular ile ilgili diğer bilgiler ise;

Yörünge: 705 km, 10:30 alçalan düğüm (Terra) veya 13:30 yükselen düğüm (Aqua), güneşle eş zamanlı, kutuplara yakın, dairesel

Tarama Hızı: 20,3 rpm, çapraz iz

Swath Boyutları: 2330 km (yol boyunca) x 10 km (nadirde yol boyunca)

Teleskop: 17,78 cm çap. eksen dışı, afokal (birleştirilmiş), ara alan durdurmalı

Boyut: 1,0 x 1,6 x 1,0 m

Ağırlık: 228,7 kg

Güç: 162,5 W (tek yörünge ortalaması)

Veri Hızı: 10,6 Mbps (en yoğun gündüz); 6,1 Mbps (yörünge ortalaması)

Niceleme: 12 bit

Mekansal Çözünürlük: 250 m (bant 1-2), 500 m (bant 3-7), 1000 m (bant 8-36)

Tasarım Ömrü: 6 yıl

Şeklindedir. (modis.gsfc.nasa.gov, 2023)

Veriler AY, BTEMP, CONF ve FRP alanlarını içermektedir.

AY: Olayın gerçekleştiği yılın ayını temsil eder.

BTEMP: Olayın tespit edilme anındaki parlaklık sıcaklığını. (Kelvin sıcaklık değeri)

CONF: Olayın gerçekleştiği andaki uydudan alınan verinin güvenilirliğini.

FRP: Olayın gerçekleştiği andaki Mega Watt cinsinden yangının oluşturduğu enerjiyi temsil etmektedir.

Bu çalışmada; Antalya ve Muğla illerinde 2020-2023 yılları arasında gerçekleşen yangınların verileri kullanılmıştır. MODIS cihazlarıyla kaydedilen veriler kullanılmış olup, Terra ve Aqua EOS uyduları tarafından sağlanan MODIS verileri incelenmiştir. Antalya'da 1742 ve Muğla'da 597 yangın verisi kullanılmıştır, Şekil 3 ve 4.



Şekil 3 – Antalya Harita (SAYGILI, 2023)



Şekil 4 – Antalya Harita (SAYGILI, 2023)

AY, BTEMP ve CONF verileri girdi olarak kullanılarak modelleme üzerinde ortaya çıkması belirlenen toplam yangın enerjisini yani FRP'yi tahmin etmeye ve gözlem ve tahmin değerleri aralarındaki lineer ilişkinin saptanmasına çalışılmıştır.

Daha kısa süre içinde sonuçları elde edilmek için veriler normalize edilmiştir bu da min-max yöntemi aracılığı ile sağlanmıştır. Min-max skaler, verileri belirli bir aralığa dönüştürmek için kullanılan bir veri ölçeklendirme tekniğidir. Bu yöntem, verileri 0 ile 1 arasındaki bir aralığa yeniden ölçeklendirir. Verilerin min-max scaler yöntemi ile ölçeklendirilmesi için aşağıdaki formül kullanılır, (Deepa, 2022: 10981-10996)

$$X_{\text{scaled}} = (X - X_{\text{min}}) / (X_{\text{max}} - X_{\text{min}}) \quad (3.1)$$

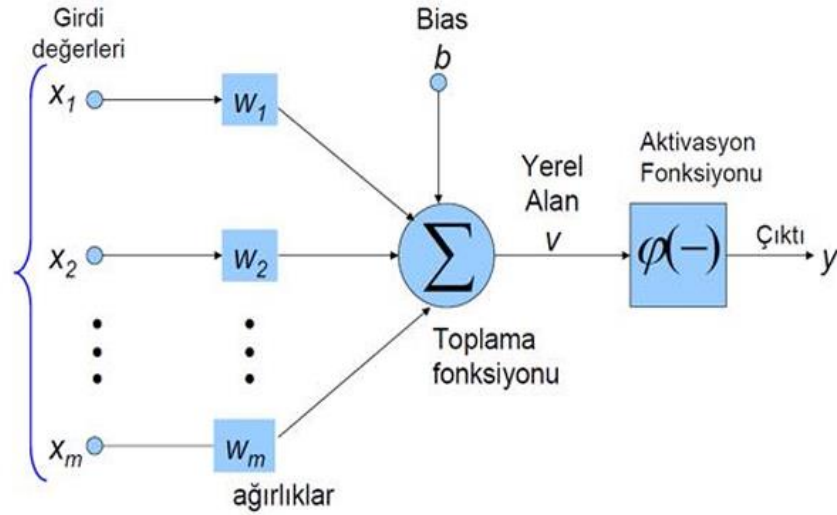
X: ölçeklendirilecek veri

X_min: veri kümesindeki en küçük değer

X_max: en büyük değerdir.

B. Neural Network (Yapay Sinir Ağları):

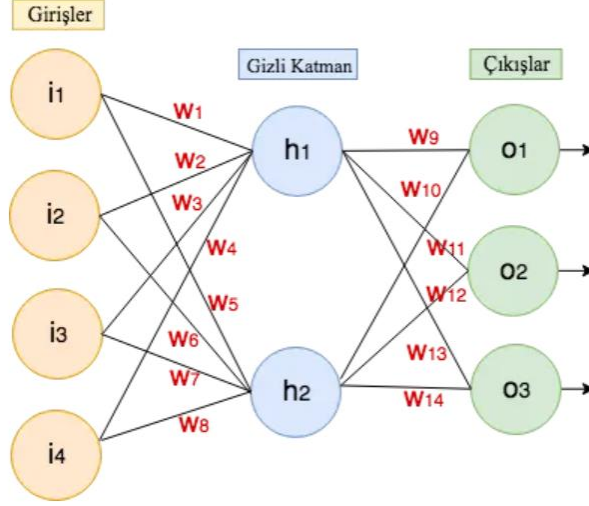
Yapay sinir ağları (YSA), bilgisayarların insan beyninin çalışma şekillerini eden matematiksel modellerdir. Karmaşık verileri anlamak, algılamak, sınıflandırmak ve tahmin etmek gibi birçok alanda kullanılabilirler. (UĞUR, 2006)



Şekil 5 - Yapay Sinir Hücresi (Keskenler, 2017: 8-18)

Yapay sinir ağlarını Şekil-2 deki gibi bir yapıda ifade edecek olursak verilerin değerlendirilmesi için bu yapı üzerinden nitekim bir filtre uygulanmaktadır. Bu sürecin çalışma şekli girdi değerlerinin gelmesi ile başlar. Gelen verilerin her birinde farklı bir

ağırlık değeri bulunmaktadır. Bu ağırlık değerlerine göre değerler, toplam fonksiyonuna veya Şekil-3 deki örnek sinir ağındaki gibi toplam fonksiyonlarına bölünerek işleme alınma süreci başlar.



Şekil 6 - Örnek Çok Katmanlı Sinir Ağı (kadirguzel.medium.com, 2018)

Yapay sinir ağları tek katmanlı ve çok katmanlı olarak iki farklı algılayıcı olarak adlandırılmaktadır. Tek katmanlı algılayıcılarda da çok katmanlı algılayıcılarda da sürecin çalışma yöntemini özetleyecek olduğumuzda giriş değeri ağırlık değerleri ile çarpılarak toplam fonksiyona gider. Toplam fonksiyonunun ve aktivasyon fonksiyonunu bir nöron olarak adlandırsak veriler nörona gelecek. Nöron içerisinde bulunan toplam fonksiyonu verileri toplar ve aksiyon fonksiyonuna iletilir. Toplam fonksiyonunda yapılan işlemler aşağıdaki gibidir, (Arı, 2017, s. 55-73):

$$\text{Toplam Fonksiyonu} = \sum_{(i = 1)}^n [w_i x_i] \quad (3.2)$$

X_i : 1'den n'e kadar giren giriş değerlerini temsil eder.

W_i : 1'den n'e kadar giren giriş değerlerine karşılık gelen ağırlık değerlerini temsil eder.

Çıktı değeri ise nöron içinde belirlenmektedir. Aktivasyon fonksiyonuna gelen değerlerde belirlenen değer üzerine çıktığı zaman çıktı olarak bize sonucu verecektir. Aktivasyon fonksiyonlarına giren değerlerin değerlendirmeden geçerken girdiği formül yapısı aşağıdaki gibidir, (Arı, 2017, s. 55-73):

Aktivasyon Fonksiyonu $=\varphi(\text{Toplam Fonksiyonu} + b)$ (3.3)

φ : Aktivasyon fonksiyonunu temsil eder.

b: bias değerini gösterir.

Aktivasyon fonksiyonlarında birkaçının temel bilgileri aşağıdaki gibidir.

- Sigmoid Fonksiyonu

Giriş değerine bakmaksızın 0 ve 1 arasında bir çıktı üretir. Bu fonksiyonda bir nöronun vereceği sonuç ihtimalleri için yorum yapabilmek adına çok kullanılan bir yöntemdir fakat gradyan zaman zaman çok büyük veya çok küçük değerler alabilir bu durumda ağ eğitimi esnasında problemler ile karşılaşılabilir. (Karlık, -:111-122) ve (Kılıçarslan vd. 2021: 75-88), (Çetin, 2015: 150 – 157)

$$y = 1/(1 + e^{(-x)}) \quad (3.4)$$

y= Yapay nöron çıktısını temsil eder.

x= Ağdaki yapay nöronların sayısını tanımlar.

- Tanh Fonksiyonu

Sigmoid fonksiyonuna benzeyen yönleri vardır fakat çıktı -1 ile 1 arasında olur Tanh fonksiyonu sigmoidden farklı olarak simetrik bir çıktı üretir. Bu fonksiyonda da ağın eğitimi sırasında gradyanın kaybolması olabilir, (YINGYING et al. , 2020: -).

$$f(x) = (1 - e^{(-2x)})/(1 + e^{(-2x)}) \quad (3.5)$$

x=Gelen değeri temsil eder.

- ReLU Fonksiyonu

Rectified Linear Unit fonksiyonu, giriş değeri pozitif ise değeri, giriş değeri negatif ise sonuç olarak 0 döndürür fakat negatif giriş değerlerinde sıfır olduğu için, bazen gradyanın kaybolmasına neden olabilir (Kılıçarslan vd. 2021: 75-88), (YINGYING et al. , 2020: -).

$$f(x) = \max(0,x) \quad (3.6)$$

x = Gelen değeri temsil eder.

- Leaky ReLU Fonksiyonu

Negatif girişler için sıfır döndürmez bunun yerine küçük bir sonuç değeri döndürür. Sıfır döndürmediği için de gradyanın kaybolma ihtimali azalır, (Jianli and Shengnan, 2019: 1 – 6).

$$f(x) = \begin{cases} x_i, & x_i > 0 \\ a_i, & x_i < 0 \end{cases} \quad (3.7)$$

a_i = Negatif kayıtlar için i 'inci kanalın katsayısıdır ve genellikle 0,01 değerini alır.

Optimizasyon fonksiyonlarında birkaçının temel bilgileri aşağıdaki gibidir.

Optimizasyon fonksiyonları, bir ağın parametrelerini ağı eğitmek için kullanılan verilerden öğrenerek amaç fonksiyonunun en küçük değerini elde etmek üzere güncellemek için kullanılır. Yapay sinir ağı eğitiminde yaygın olarak kullanılan optimizasyon fonksiyonları aşağıdaki gibidir ve her biri farklı özelliklere sahiptir.

- Stochastic Gradient Descent (Stokastik gradyan azalması)

Büyük veri kümelerindeki gradient hesaplamalarının maliyetini azaltmak için kullanılan bir optimizasyon algoritmasıdır. Her bir veri örneği için ayrı ayrı gradient hesaplanır ve bu gradientlerin ortalaması alınarak adım atılır. (Seyyarer vd. 2020: 90-98)

- Adam Optimization (Adaptive Moment Estimation)

Adam Optimasyonu, gradyan inişine benzer bir yapıda çalışır ve her seferinde daha çok hızlanarak çalışır. İşleyişi sırasında ilk olarak parametreler rastgele seçilir. Seçiler tamamlandığında Gradyan karesinin ilk ve ikinci momentleri hesaplanır. Her tekrarlayışta gradyan kural dahilinde yeniden hesaplanmaktadır. Parametreler için farklı öğrenme hızları belirlenir ve parametreler güncellenir. Bu güncelleme ve yeniden hesaplama işlemleri maksimum iterasyon sayısı veya hedef hatanın altına düşünceye kadar tekrarlanarak sonuca varılır, (Seyyarer vd. 2020: 90-98).

$$w_{t+1} = w_t - a/\sqrt{s_t + \epsilon} \cdot v_t \quad (3.8)$$

S ve V = Başlangıçta 0 alınır.

a = Genellikle 0.001 olarak kabul edilebilir.

$\beta_1=0.9$, $\beta_2=0.999$ ve ϵ ise 10^{-8} olarak kabul edilir.

- Adagrad Optimization (Adaptive Gradient)

Daha az sık görülen özellikleri vurgulamak için adaptif bir öğrenme hızı sağlayan bir optimizasyon algoritmasıdır. Adım boyutu, daha önceki adımların kareleri tarafından modifiye edilerek belirlenir, (Seyyarer vd. 2020: 90-98).

$$w_{t+1} = w_t - \eta/\sqrt{G_t + \epsilon} \cdot g_t \quad (3.9)$$

w_{t+1} : $(t+1)$ zamanındaki ağırlık vektörü

w_t : t zamanındaki ağırlık vektörü

η : öğrenme oranı (learning rate)

G_t : t zamanındaki gradyan karelerinin toplamı

ϵ = Genellikle 10^{-7} olarak alınır. (0'a bölmek için.)

g_t : t zamanındaki gradyan vektörü

- RMSProp Optimization (Root Mean Square Propagation)

Adagrad'ın aksine, daha önceki tüm adımların karelerinin toplamını hesaba katmak yerine son birkaç adımın karelerinin ortalamasını hesaba katarak adaptif bir öğrenme hızı sağlayan bir optimizasyon algoritmasıdır. Bu şekilde, daha hızlı konverjans elde edilir, (Seyyarer vd. 2020: 90-98).

$$w_{t+1} = w_t - a/\sqrt{v_t + \epsilon} \cdot g_t \quad (3.10)$$

w_{t+1} : $(t+1)$ zamanındaki ağırlık vektörü

w_t : t zamanındaki ağırlık vektörü

a : öğrenme hızı (learning rate)

g_t : t zamanındaki gradyan vektörü

$v(t)$: t zamanındaki eksponansiyel hareketli ortalama (β) karelerin toplamı

a =öğrenme oranı,

$\beta=0.9$ ve ϵ ise 10^{-6} olarak kabul edilebilir.

Loss fonksiyonlarında birkaçının temel bilgileri aşağıdaki gibidir.

Loss fonksiyonları, makine öğrenmesi modellerinin performansını belirlemek için kullanılan fonksiyonlardır. Modellerin tahminleriyle gerçek değerler arasındaki farkı hesaplar ve bir hata değeri üretir.

- Mean Squared Error (MSE):

Gerçek ve tahmin edilen değerler arasındaki farkların kareleri toplamının ortalamasıdır. Regresyon problemlerinde yaygın olarak kullanılır, (Özcan, 2021: –).

$$\frac{1}{n} \sum_{i=1}^n [(t_i - g_i)]^2 = \frac{1}{n} \sum_{i=1}^n e_j^2 \quad (3.11)$$

t_i : i . Birimin tahminini temsil eder.

g_i : i . birimin gerçek değerini temsil eder.

e_j : Tahmindeki hata değerini temsil eder.

- Mean Absolute Error (MAE):

Regresyon problemleri için kullanılan hata fonksiyonudur. Gerçek ve tahmin edilen değerler arasındaki mutlak farkların toplamının ortalamasını hesaplar. MAE, MSE gibi hata ölçütüdür fakat MSE'nin aksine hataların karesini almadan işlem yaptığı için az hassas ölçütler elde eder. MAE, özellikle aykırı değerlerin bulunduğu veri setlerinde tercih edilebilir, (Özcan, 2021: –).

$$\frac{\sum_{i=1}^n |t_i - g_i|}{n} = \frac{\sum_{i=1}^n e_j}{n} \quad (3.12)$$

t_i : i . Birimin tahminini temsil eder.

g_i : i. birimin gerek deęerini temsil eder.

e_j : Tahmindeki hata deęerini temsil eder.

Aktivasyon, optimizasyon ve loss fonksiyonları ierisinde bulunan fonksiyon trlerinden Tanh fonksiyonu, Adam optimizasyon ve Loss fonksiyonları ierinden olan Mean absolute error yntemlerini tahmin iřlemine kullanıldı.

Parametreler; EPOCH, BATCH, LOSS, Validation LOSS, MAE ve Validation MAE řeklindedir.

EPOCH: Eęitim verilerinin algoritma aracılıęıyla bir btn olarak geiřini ifade eden deęer.

BATCH: Model eęitimlerinde yinelemede kullanılan rnek kmelerine verilen isimdir.

LOSS: Gerek veriler ile tahmin edilen veriler arasındaki fark deęeridir.

VAL LOSS: Eęitim seti ile tahmin edilen verinin arasındaki, doęrulama iin kullanılan verilerdeki hata payıdır.

MAE: Ortalama Mutlak Hata / Mean Absolute Error

VAL MAE: Modelin doęrulama veri kmesi zerindeki ortalama mutlak hata deęeri.

Mean Absolute Error: bir modelin tahminlerinin gerek deęerlerden ne kadar uzak olduęunu len bir deęerdir.

Mean Squared Error: Ortalama Kare Hatası tahmin edilen sonularınızın gerek sayıdan ne kadar farklı olduęuna dair size mutlak bir sayı verir.

Max Error: Tahmin edilen sonularınızın gerek deęerden ne kadar uzak olduęunun maksimum deęerini verir.

Explained Variance Score: Tahmin edilen sonuların gerek deęerlerin varyansına oranı. Yzde 100'e yakın bir skor daha iyi bir model performansını gsterir.

Mean Absolute Percentage Error: Mean absolute percentage error: Tahmin edilen sonuçların gerçek değerlere göre yüzde kaç sapma gösterdiğini verir.

C. Support Vector Machines (Destek Vektör Makinesi):

Makine öğrenmesi alanında sınıflandırma ve regresyon problemlerini çözmek için kullanılan bir algoritmadır. SVM sınıflandırma problemlerinin çözümlenmesinde tercih edilen makine öğrenmesi yöntemlerindedir. Çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir. SVM, karar fonksiyonlarından en uygunu tahmin etmeye çalışır, iki sınıfı birbirinden en uygun şekilde ayırabilen hiper-düzlemin tanımlanması esasına dayanır.

SVM'de C değeri, algoritmanın hiper-düzlemi oluştururken sınıflandırma hatasına verilen izin seviyesini kontrol etmek için kullanılan bir parametredir. Düşük değerli bir C değeri algoritmanın daha fazla sınıflandırma hatası yapmasına izin verir, yüksek değerli c değeri ise hatayı minimize etmeye çalışır. Algoritmanın performansını optimize edebilmek için büyük önem arz eder. Çünkü çapraz doğrulama (cross-validation) gibi yöntemlerle belirlenebilir veya deneme yanılma yöntemiyle bulunabilir. Deneme yanılma yöntemi ile sonuca varabilmesi için eğitim esnasında farklı C değerleri denenir ve hangi C değerinin en iyi sonucu vereceği belirlenir.

Kernel fonksiyonları, verileri daha yüksek boyutlu bir uzaya taşıyarak doğrusal olarak ayrılabilir hale getirir. Kernel derecesi, polinom kernel gibi bazı kernel fonksiyonlarında kullanılır. Polinom Kernel ise verileri daha yüksek boyutlu bir uzaya taşımak için polinom fonksiyonunu kullanır ve polinom fonksiyonunun derecesini belirler. (Kavzoğlu ve Çölkesen, 2010: 73-82)

1. Destek Vektör Regresyonu (Support Vector Regression -SVR)

Destek Vektör regresyonu, makine öğrenmesi alanında kullanılan bir regresyon yöntemidir. SVR, doğrusal ilişkilere sahip verilerin modellenmesinde kullanılan etkili yöntemlerdendir. SVR, sınıflandırma problemlerinde kullanılan yönteminin regresyon problemlerine uyarlanmış bir versiyonudur. SVR, veri noktalarının belirli bir vektör aralığında olmasını hedefleyen bir yöntemdir.

SVR, iki temel bileşene dayanır: Bir çekirdek fonksiyonu (kernel function) ve bir marjinal hataya (margin error) dayalı bir kayıp fonksiyonu. Çekirdek fonksiyonu,

veri noktalarının yüksek boyutlu özellik uzayına haritalanmasını sağlar. Bu sayede, doğrusal olarak ayrılabilir olmayan verilerin de modellenmesi mümkün hale gelir. Kayıp fonksiyonu, regresyon hatasını ve marjinal hatayı minimize etmeye çalışır. (Awad and Khanna, 2015: 67–80)

D. Liner Regresyon

Linear regression istatistik alanında sıklıkla kullanılan bir yöntemdir. İki ya da daha fazla değişken arasındaki ilişkiyi bir doğrudan modellemektir. Çizgisel bir eğilim gösterdiği durumlarda değişkenler arasındaki bağımlılığı açıklamaya çalışır.

Basit linear regression ve çoklu linear regression olmak üzere iki temel türü vardır.

Basit linear regression tek bir bağımsız değişkenin etkisini ölçmek için kullanılırken, çoklu linear regression iki ya da daha fazla bağımsız değişkenin bir bağımlı değişken üzerindeki etkisini ölçmek için kullanılır. Linear regression modeli, en küçük kareler yöntemi ile kurulur ve regresyon doğrusunun en küçük hata kareler toplamını minimize ederek verilerin en iyi şekilde uyarlanması sağlar. Bu sayede, modelin doğruluğu R^2 değeri ile ölçülür.

IV. ANALİZ

Bu çalışmada kullanılan makine öğrenmesi yöntemlerinin parametre ve sonuç bilgileri aşağıdaki başlıklar altında açıklanmıştır. Bu çalışma içerisinde yapay sinir ağları, destek vektör makineleri ve liner regresyon gibi literatür içerisinde doğrulukları benimsenmiş makine öğrenmesi algoritmaları kullanılmıştır.

A. Yapay Sinir Ağları (Artificial Neural Networks):

Bu model, içerisinde Antalya ve Muğla'ya ait yapısal çalışma sonucu temel parametre değerlerinin normalize edilmiş ve edilmemiş sonuçları aşağıdaki Çizelgede verilmiştir. Veriler ile normalize edilerek çalışılmıştır. Normalize edildiği zaman değerler ile 0-1 arasında kalmakta ve daha yüksek performans elde edilmektedir. Çizelge 1 incelendiğinde en düşük hata payının Muğla iline ait olduğu ve doğrulama verisindeki en düşük hata payının %47.2 olduğu görülmektedir. Antalya ilindeki veriler ile model eğitimi sonrası hata payının iki katına yakın olduğu gözükmemektedir.

Çizelge 1 - YSA Eğitim parametreleri ve Sonuçları

	Antalya	Muğla
EPOCH	50	50
BATCH	5	5
LOSS	173.56	87.94
VAL_LOSS	57.35	47.20
MAE	173.56	87.94
VAL_MAE	57.35	47.20

Çizelge 2 incelendiğinde en düşük hata payının Antalya iline ait olduğu ve doğrulama verisindeki en düşük hata payının 0.0027 (~%0,3) olduğu görülmektedir. Muğla


ilindeki veriler ile model eğitimi sonrası hata payının iki katına yakın olduğu gözükmemektedir.

Çizelge 2– YSA Eğitim parametreleri ve Sonuçları – Normalize

	Antalya	Muğla
EPOCH	50	50
BATCH	5	5
LOSS	0.0244	0.0529
VAL_LOSS	0.0213	0.0375
MAE	0.0049	0.0125
VAL_MAE	0.0027	0.0037


Eğitilen model içerisinde hata oranlarının EPOCH üzerindeki değişim grafiği aşağıda gösterilmiştir. Şekil 4’deki Grafik incelendiğinde, başlangıçta hata payının yüksek olduğu görülmektedir. Bununla birlikte, test ve doğrulama verileri çoğunlukla benzer bir konumda yer almıştır, yani modelin genelleme yeteneği test verileri için de doğrulandığı görülmektedir. Yüksek sıcaklıklarda hata payı varken düşük sıcaklıklarda çoğunlukla doğruluk payı yüksek çıkmıştır.

Normalize edilmeden önceki eğitilen model içerisinde hata oranlarının EPOCH üzerindeki değişim grafiği aşağıda gösterilmiştir. Şekil 7’deki Grafik incelendiğinde doğrulama veri setindeki düşüşün düzenli olduğu gözükmemektedir fakat eğitim ve doğrulama verileri arasında hata paylarının yüksek olduğu görülmektedir.




Şekil 7 - Eğitim ve Doğrulama Seti Hata Oranları / Antalya

Şekil 8'deki Grafik incelendiğinde doğrulama veri setindeki düşüşün düzenli olduğu ve hata paylarının normalize edilen verilerden çok daha düşük olduğu gözükmektedir.




Şekil 8 - Eğitim ve Doğrulama Seti Hata Oranları / Antalya – Normalize



Şekil 9 - Eğitim ve Doğrulama Seti Hata Oranları / Muğla


Normalize edilen ve edilmeyen veriler de eğitim modeline karşıt olarak Şekil 9'teki ve Şekil 10'daki Muğla ilimize ait modellerin eğitim hata oranlarında yine test ve doğrulama verileri çoğunlukla benzer bir konumda yer almıştır, doğrulama veri seti üzerinde düşük sıcaklıklar için hata paylarının birbirine çok yakın ortalamalar üzerinde dağıldıkları gözükmemektedir.



Şekil 10 - Eğitim ve Doğrulama Seti Hata Oranları / Muğla – Normalize


Yukarıda normalize edilen ve edilmeyen eğitim ve doğrulama verilerinin sonuçları gösterilmiştir. Normalize edilen sonuçlar çok daha başarılı olması sebebi ile çalışmada normalize edilen değerler ele alınarak çalışma yapılmıştır.

Normalize edilen veriler ile eğitim ve doğrulama veri seti ile yapılan modelde bağımsız tahminler sonucu hata paylarının nasıl dağıldığı Şekil 11’de gösterilmiştir. Grafiğe göre doğrulama veri seti üzerinde verilerin uygun dağıldığı gözlemlenmektedir. Bu tahmin değerlerinde gözlemlenen sonuç ise, düşük sıcaklıklarda yangının ortaya çıkacak enerjiyi saptama oranının çok yüksek olduğu gözlemlenmiştir.




Şekil 11 – Eğitim ve Doğrulama Veri Seti Tahmin Sonuçları MAE / Antalya –
Normalize

Doğrulama (Training) veri seti üzerindeki hata oranlarının daha düzenli ve daha küçük aralıklarda olduğu, eğitim (Validation) modelinden daha başarılı olduğu grafikte gösterilmektedir.




Şekil 12 - Eğitim ve Doğrulama Veri Seti Tahmin Sonuçları MAE / Muğla – Normalize

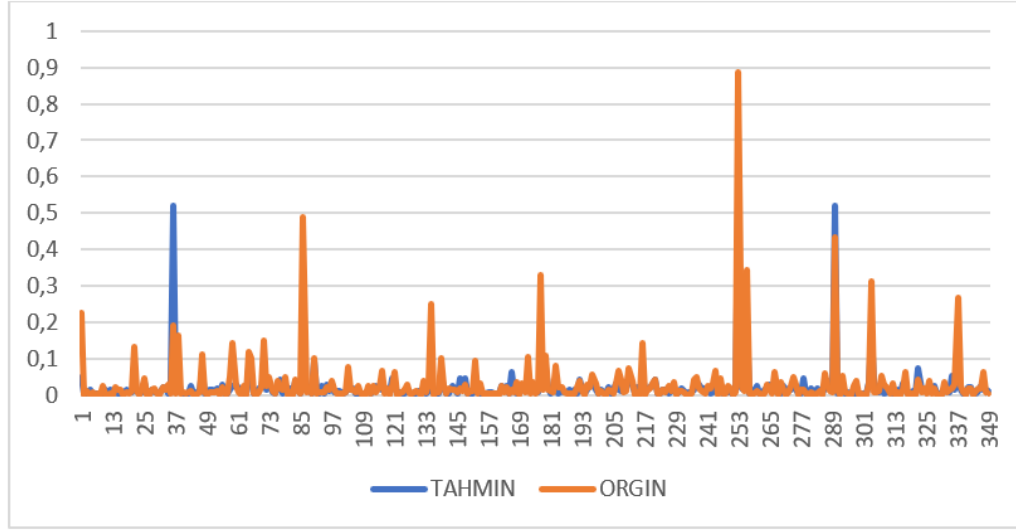
Şekil 12’de görüldüğü gibi Antalya ilimize ait sonuçlar ile karşılaştırıldığında Muğlanın data paylarının daha düzenli olması model performansının daha başarılı olduğu varsayılabılır. Verilerin linear bir çizgide toplandığı gözlemlenmektedir. Düşük sıcaklıklarda yangının ortaya çıkacak enerjisi bulma oranımızın çok yüksek olduğu gözlemlenmiştir (Şekil 13 ve 14).



Şekil 13 - Eğitim verilerinden seçilen orijinal veri / Antalya – Normalize




Şekil 14 - Eğitim sonrası tahmin / Antalya– Normalize




Şekil 15 - Tahmin ve Gözlem Verisi / Antalya – Normalize

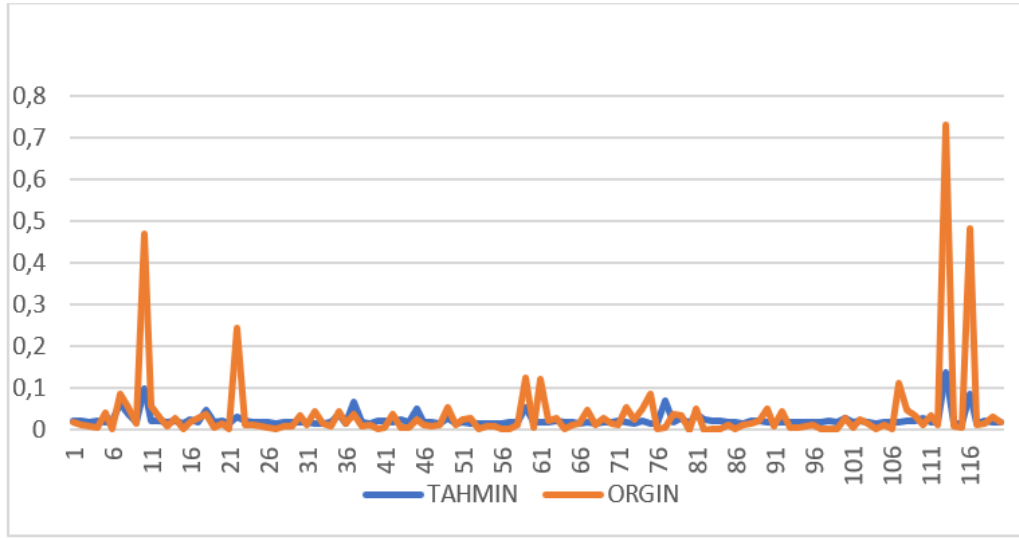
Şekil 15’de Antalya İli için bir modelin performansının değerlendirilmesi amacıyla, tahmin edilen değerlerin gerçek değerlerle karşılaştırılmasına yer verilmektedir. Bu süreç, tahmin için kullanılan gerçek değerlerin ve modelin tahmin sonuçlarının karşılaştırılması yoluyla gerçekleştirilir. Bu karşılaştırma, modelin doğruluğunu ve hata payını belirlemek için kullanılmıştır. Gerçek değerler ve tahmin sonuçları arasındaki fark ne kadar küçük olursa, modelin o kadar iyi bir performans gösterdiği söylenebilir. Şekil 16’de görüldüğü gibi düşük sıcaklıklar için tahmin ve orijinal veri karşılaştırmaları arasındaki farklar çok küçükken yüksek sıcaklıklarda farkların yüksek olduğu sonucuna varılmıştır. Şekil 13’deki grafikte de sadece orijinal veriler Şekil 14’de de sadece tahmin verileri karşılaştırmada çakışan alanların ayrımının net görülmesi için gösterilmektedir (Şekil 16 ve 17).



Şekil 16 - Eğitim verilerinden seçilen orijinal veri / Muğla – Normalize



Şekil 17 - Eğitim sonrası tahmin / Muğla – Normalize



Şekil 18 - Tahmin ve Gözlem Verisi / Muğla – Normalize

Şekil 18'te Muğla için yapılan analizler, Antalya'daki sonuçlarla benzer şekilde, düşük sıcaklıklar için tahmin edilen ve orijinal veriler arasındaki farkların çok küçük olduğunu göstermiştir. Ancak, yüksek sıcaklıklar için farkların daha yüksek olduğu tespit edilmiştir. Ayrıca, Şekil 16'deki grafikte sadece orijinal veriler ve Şekil 17'deki grafikte sadece tahmin edilen veriler karşılaştırılmış ve çakışan alanların ayrımının net bir şekilde görülebilmesi için ayrı ayrı gösterilmiştir.

Çizelge 3 – YSA Hata Oranları – Normalize

Hata Ölçüleri	Antalya	Muğla
Ortalama Mutlak Hata (Mean Absolute Error)	0.019	0.0301
Ortalama Kare Hata (Mean Squared Error)	0.0025	0.0045
Maksimum Hata (Max Error)	0.4051	0.4850
Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)	5.6279	0.8767

Yapay sinir ağları üzerinde yapılan incelemelerde, modelin düşük sıcaklıklara göre gerçekleştirdiği tahminlerin daha başarılı sonuçlar verdiği görülmektedir. Bu sonuçlar, modelin düşük sıcaklıklar için daha iyi bir öğrenme yeteneğine sahip olduğunu ve bu nedenle daha doğru tahminler yapabildiğini işaret etmektedir.

B. Destek Vektör Regresyon (Support Vector Regration):

Uygulamada kullanılan SVR modelinin iki ilimize ait (Antalya - Muğla) parametreleri aynı olarak kullanılmıştır.

Bu parametreler;

$$C = 7$$

$$\text{Degree} = 7$$

Kernel = poly. şeklindedir.

Bu yapıda eğitilen modelin performans hata oranları aşağıda Çizelge 3'de gösterilmiştir. Bu hata oranlarına bakıldığında destek vektör makinelerinin incelenen veri için Antalya 0.072 ve Muğla 0.075 değeri ile sonuçlanmıştır, ilçelerindeki ortalama mutlak hata değerleri benzerlik göstermektedir ve yaklaşık eşittir. Ortalama kare hata değeri Antalya'da 0.022 değeri ile Muğla'da bulunan 0.015 değerine göre daha yüksektir. Aynı şekilde, maksimum hata değeri de Antalya'da 1.669 değeri ile Muğla'daki 0.055 değerine göre daha yüksektir.

Bulunan varyans skoru, Muğla için daha yüksek olduğundan, Muğla ilçesi için yapılan tahminlerin gerçek değerlere daha yakın olduğu söylenebilir. Ancak, her iki ilçe için de ortalama mutlak yüzde hata değerleri 1.389 ve 1.367 ilki Antalya ikincisi Muğla'yı temsil edecek şekilde birbirine çok yakındır.


Bu modelde sonuç olarak, Muğla'da yapılan tahminlerin daha doğru olduğu söylenebilir, ancak her iki ilçe için de benzer hata ölçüleri vardır.

Çizelge 4 – SVR Hata Oranları

Hata Ölçüleri	Antalya	Muğla
Ortalama Mutlak Hata (Mean Absolute Error)	0.072	0.075
Ortalama Kare Hata (Mean Squared Error)	0.022	0.015
Maksimum Hata (Max Error)	1.669	0.055
Açıklanan Varyans Skoru (Explained Variance Score)	0.039	0.070


Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)	1.389	1.367
---	-------	-------

Antalya'nın (Şekil-14) doğrulama veri seti tahmin sonuçları, yapılan değerlendirmeler sonucunda, genel olarak pozitif bir dağılım gösterdiği ve çizgi izdüşümü üzerinde yoğunlaştığı tespit edilmiştir. Bu durum, tahminlerin gerçek değerlere yakın olduğunu ve veri setinin modele iyi uyum sağladığını göstermektedir. Ancak, bazı noktalarda tahminler gerçek değerlerden farklılıklar göstermektedir.



Şekil 19 - Doğrulama Veri Seti Tahmin Sonuçları SVM / Antalya

Muğla'nın (Şekil-20) doğrulama veri seti tahmin sonuçları, yapılan değerlendirmeler sonucunda, sonuçların pozitif ve negatif bir dağılım sergilediği ve çizgi izdüşümü dağınık olduğu tespit edilmiştir. Bu durum da, tahminler gerçek değerlere göre daha farklılık göstermektedir.



Şekil 20 - Doğrulama Veri Seti Tahmin Sonuçları SVM / Muğla

C. Liner Regresyon

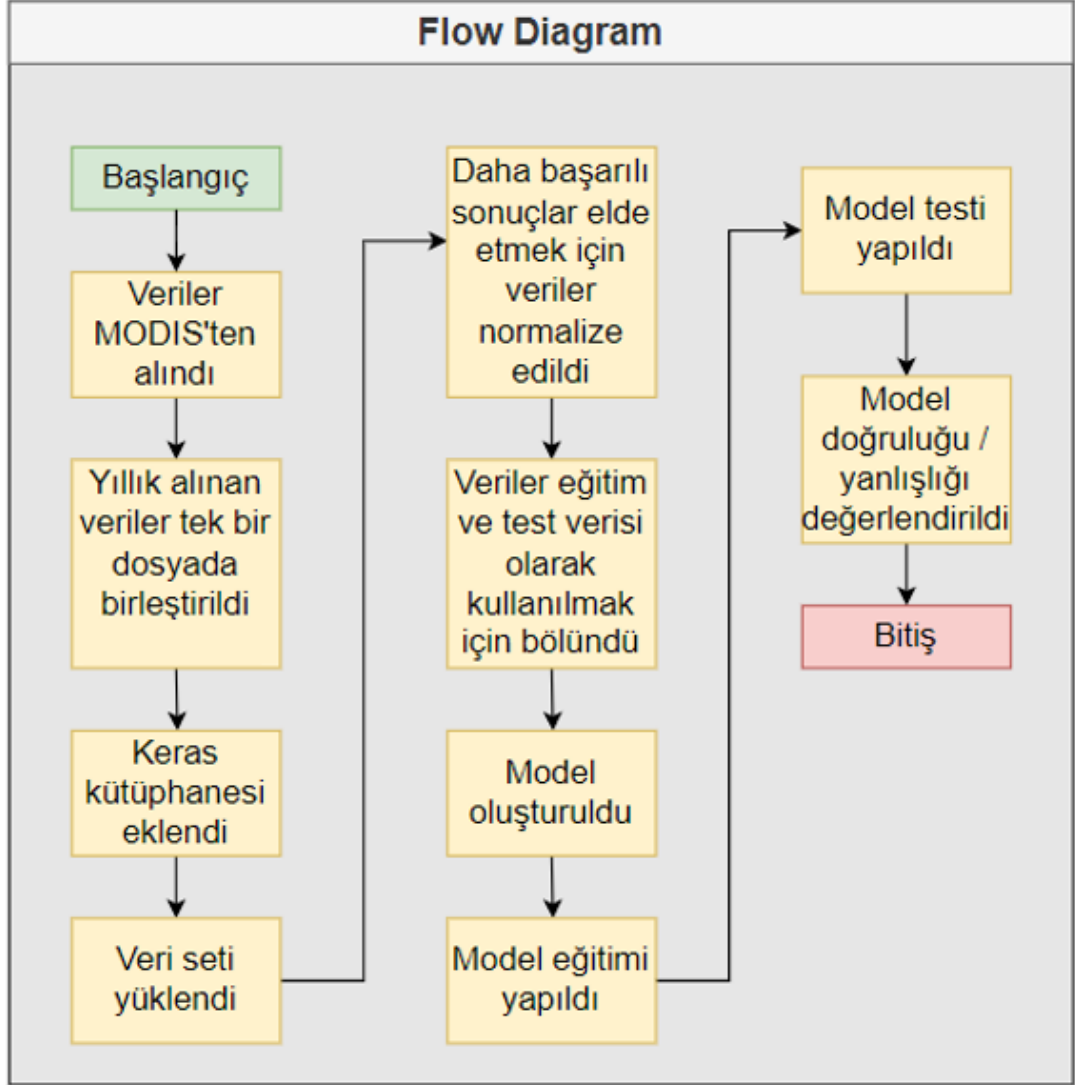
Çok sınıflı lineer regresyon ile yapılan modelleme içerisinde Çizelge 4’deki hata oranları ile doğrulama verisi sonucu modelden elde edilmiştir. Antalya’da ortalama mutlak hata değeri 0.024 iken, Muğla’da bu değer 0.029’dur. Bu nedenle, modelde verilen ölçütlere göre Antalya’da elde edilen sonuçların Muğla’dan daha iyi olduğu sonucuna varılmıştır.

Ancak, bu sonuçlar sadece belirli bir veri seti için geçerlidir ve başka veri setleri için sonuçlar farklı olabilir. Bu nedenle, bir modelin gerçekten başarılı olup olmadığını değerlendirmek için, daha geniş bir veri seti üzerinde test edilmesi ve sonuçların tekrarlanması gerekmektedir.

Çizelge 5 – Liner Regresyon Hata Oranları

Hata Ölçüleri	Antalya	Muğla
Ortalama Mutlak Hata (Mean Absolute Error)	0.024	0.029
Ortalama Kare Hata (Mean Squared Error)	0.00095	0.00125
Maksimum Hata (Max Error)	0.093	0.104
Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)	1.718	1.2714

D. Flow Diagram



Şekil 21- Flow Diagram

V. SONUÇ

Bu çalışma içerisinde Antalya ve Muğla illerine ait AY, BTEMP, CONF ve FRP orman yangını alanları MODAPS sisteminden indirilerek çalışılmıştır. Amaç FRP ile elde edilen enerjinin kilowatt cinsinden değerini saptamaktır. Düşük parlaklık sıcaklıklarında ortaya çıkan yangın enerjisinin yüksek ilişkide olduğu saptanmıştır. Hata payı sonuçları incelendiğinde Ortalama Kare Hata (Mean Squared Error) değerlerinin en düşük sonuçları verdiği görülmüştür.

Bu değerler Yapay Sinir Ağlarında Antalya için 0.0025 iken Muğla için 0.0045, Destek Vektör Regresyonu ile Antalya'da 0.022 değeri ile Muğla'da bulunan 0.015 ve Linear Regresyon modelinde ise Antalya'da ortalama mutlak hata değeri 0.024 iken, Muğla'da bu değer 0.029 olarak tespit edilmiştir.

Sonuç karşılaştırıldığında Liner regresyon modelinde en düşük hata oranının 0.00095 MSE değeri ile düşük hata payı göstermektedir. Çalışmadaki düşük sıcaklık modellemesinin başarısı, yüksek sıcaklık ve enerji başarısına göre daha yüksek parlaklık sıcaklığı ve enerji için saptanmıştır. Bu modeller ile elde edilen sonuçların olası bir yangın durumunda yangının parlaklık sıcaklığı ile yangının üreteceği toplam enerjinin tespit edilebilmesi hedeflenmiştir. Daha yüksek parlaklık sıcaklığı ve yangın enerjisi modelinin oluşturulması için daha fazla örneklemelerin incelenmesi ve gerekirse farklı modeller uygulanması gerekmektedir. Daha çok veri ve detay kullanılarak ilerleyen çalışmalarda Karar Ağları, verilerin sınıflandırılması ve özelliklerinin önem derecelerinin belirlenmesi için kullanılarak bir çalışma yapılabilir veya KNN yöntemi, bu çalışmadaki veri seti gibi küçük veri setleriyle çalışmak için ideal bir seçim olabilir. Bu yöntem, verilerin sınıflandırılması işlemleri için kullanılarak örnek çalışmalar yapılabilir.

VI. KAYNAKÇA

MAKALELER

AMATULLI, R. T. (2006). Assessing long-term fire risk at local scale by means of decision tree technique. **AGU**, s. 1-15.

ARI, M. E. (2017). Yapay Sinir Ağları ile Tahmin ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. **ACTA INFOLOGICA**, s. 55-73.

AWAD, M., & KHANNA, R. (2015, April 27). **Support Vector Regression**. s. 67–80.

BAHAREH, K., NAONORI, U., MOHAMMED, O. I., SAEID, J., KOUROSH, A., & FARZIN, S. (2020, Ocak 9). Forest Fire Susceptibility Prediction Based on Machine Learning Models with Resampling Algorithms on Remote Sensing Data. **MDPI**, s. 1-24.

BEŞLİ, T. N. (2020). Uydu verilerinden karar ağaçları kullanarak orman yangını tahmini. **Mühendislik Dergisi Sayı 11:3**, s. 899-906.

ÇETİN, F. ., (2015). An application of multilayer neural network on hepatitis disease diagnosis using approximations of sigmoid activation function. **Dicle Tıp Dergisi**, s. 150-157.

DEEPA, R. B. (2022, May 18). Epileptic seizure detection using deep learning through min max scaler normalization. **International Journal of Health Sciences ISSN**, s. 10981-10996.

EDUARDO, E. M., ARCOVERDE, G. F., PELLIKKA, P. K., & SHIMABUKURO, Y. E. (2011). Fire risk assessment in the Brazilian Amazon using MODIS imagery and change vector analysis. **Applied Geography**, s. 76-84.

- EL SHEWEY, A. M., & ELSONBATY, A. A. (2020). Forest Fires Detection Using Machine Learning Techniques. **Journal of Xi'an University of Architecture & Technology**, s. 510-517.
- FIDANBOY, A. O. (2022). Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması. **Ormancılık araştırma dergisi**, s. 206-218.
- FILIPPI, J. B., MALLET, V., & NADER, B. (2014). **Evaluation of forest fire models on a large observation database**. s. 3077-3091.
- GIGLIO, L., CSISZAR, I., RESTÁS, A., MORISETTE, J., SCHROEDER, W., MORTON, D., & JUSTICE, C. (2008). Active fire detection and characterization with the advanced spaceborne thermal emission and reflection radiometer (ASTER). **Modaps - Remote Sensing of Environment**, s. 3055-3063.
- JIANLI, F., & SHENGNAN, L. (2019). Performance Analysis of Various Activation Functions in Artificial Neural Networks. **IOP Publishing**, s. 1-6.
- KARLIK, A. V. (tarih yok). Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks. **International Journal of Artificial Intelligence And Expert Systems**, s. 111-122.
- KARSLIOĞLU, S., TEZCAN, E., TUYGUN, G. T., & ELBİR, T. (2022). Türkiye’de Terra ve Aqua MODIS Uydularından Elde Edilen Aerosol Optik Derinliğinin Değişimi. **Dokuz Eylül Üniversitesi Mühendislik Fakültesi Çevre Mühendisliği Bölümü, İzmir, TÜRKİYE**, s. 303-316.
- KAVZOĞLU, T., & ÇÖLKESEN, İ. (2010). Destek Vektör Makineleri İle Uydu Görüntülerinin Sınıflandırılmasında Kernel Fonksiyonlarının Etkilerinin İncelenmesi. **Harita Dergisi**, s. 73-82.
- KESKENLER, K. M. (2017, 12 29). Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi. **Takvim-i Vekayi**, s. 8-18.

- KILIÇARSLAN, S., ADEM, K., & ÇELİK, M. (2021). An overview of the activation functions used in deep learning algorithms. **Journal of New Results in Science**, s. 75-88.
- PHAM, B. T., THAI, B., AVAND, M., AL-ANSARI, N., DU, T. D., HOANG, P. H., . . . TRAN, T. T. (2020). Performance Evaluation of Machine Learning Methods for Forest Fire Modeling and Prediction. **MDPI**.
- SCHROEDER, W., OLIVA, P., GIGLIO, L., LORENZ, LORENZ, E., & MORELLI, F. (2016). Active fire detection using Landsat-8/OLI data. *Remote Sensing of Environment*. **Modaps - Remote Sensing of Environment**, s. 210-220.
- SEYYARER, E., AYATA, F., UÇKAN, T., & KARCI, A. (2020). Derin Öğrenmede Kullanılan Optimizasyon Algoritmalarının Uygulanması Ve Kiyaslanması. **Anatolian Journal of Computer Sciences**, s. 90-98.
- SUWEI, Y., MASSIMO, L., & KULDEEP, S. M. (tarih yok). Predicting Forest Fire Using. **The Thirty-Fifth AAAI Conference on Artificial Intelligence**, s. 14983-14990.
- YINGYING, W., YIBIN, L., YONG, S., & XUEWEN, R. (2020, 03 10). The Influence of the Activation Function in a Convolution Neural Network Model of Facial Expression Recognition. **MDPI**.
- YONGQI, P., YUDONG, L., ZHONGKE, F., ZEMIN, F., ZIYU, Z., SHILIN, C., & HANYUE, Z. (2022). Forest Fire Occurrence Prediction in China Based on Machine Learning Methods. **MDPI**, s. 1-23.

ELEKTRONİK KAYNAKLAR

- GÜZEL, K. (2018, 08 20). Medium. (Medium) 01 01, 2023 Tarihinde <https://Kadriguzel.Medium.Com/Geri-Yay%C4%B1%C4%B1m%C4%B1-%C3%A7ok-Katmanlı-Yapay-Sinir-A%C4%9flar%C4%B1-2-6a47b4f3a6c> Adresinden Alındı

SAYGILI, R. (2023, 04 2). coğrafyaharita. cograftaharita: http://cografyaharita.com/turkiye_mulki_idare_haritalari4.html Adresinden Alındı

MODIS. (2023, Nisan). earthdata nasa. earthdata nasa: <https://www.earthdata.nasa.gov/faq/firms-faq#ed-nrt-standard> adresinden alındı

SHANNELL, F. (2023, Nisan). modis.gsfc.nasa. modis.gsfc.nasa.: https://modis.gsfc.nasa.gov/about/specifications.php?_ga=1*1ozny2c*_ga*MTY4MjI3ODUwMy4xLjAuMTY4MjI3ODUwMy4wLjAuMA..*_ga_24TFH3SRXR*MTY4MjI3ODUwMy4xLjAuMTY4MjI3ODUwMy4wLjAuMA..*_ga_GPQT4GL86Z*MTY4MjI3ODUwNC4xLjAu adresinden alındı.

TEZLER

ÖZCAN, E. (2021). “Kükürt Giderme Malzeme Miktarını Yöntemleri İşlemi İçin Kullanılan N Makine Öğrenme İle Tahmini E Sra Özcan 20 21 Yüksek Lisans Tezi Bilgisayar Mühendisliği Tez Danışmanı Dr. Öğr. Üyesi Emrullah Sonuç. Tez - Kükürt Giderme İşlemi İçin Kullanılan Malzeme Miktarının Makine Öğrenme Yöntemleri İle Tahmini” . Karabük: Karabük Üniversitesi.

DİĞER KAYNAKLAR

UĞUR, K. A. (2006). “Yapay Zeka Teknikleri ve Yapay Sinir Ağları Kullanılarak Web Sayfalarının Sınıflandırılması”. Türkiye'de İnternet. Ankara.

EKLER

Pseudo Kod:

- **Yapay Sinir Ağları**

- # Kütüphaneleri yükle.
- # Veri setini yükle.
- # Verileri normalize et.
- # X ve y ekseni olarak veri setini parçala.
- # Yüzde 60 20 20 olarak doğrulama(train) test ve eğitim (validation) datası oluştur.
- # YSA modeli oluştur.
- # Train verisi ile YSA modelini eğit.
- # Eğitilen model ile eğitim (validation) verilerini tahmin et.
- # Tahmin sonuçları ve gerçek değerleri kullanarak hataları hesapla.
- # Tahmin sonuçları ve gerçek değerleri kullanarak scatter diagram çiz.

- **Destek Vektör Makineleri**

- # Kütüphaneleri yükle.
- # Veri setini yükle.
- # Verileri normalize et.
- # X ve y ekseni olarak veri setini parçala.
- # Yüzde 60 20 20 olarak doğrulama(train) test ve eğitim (validation) datası oluştur.
- # SVM modeli oluştur.
- # Train verisi ile SVM modelini eğit.
- # Eğitilen model ile eğitim (validation) verilerini tahmin et.
- # Tahmin sonuçları ve gerçek değerleri kullanarak hataları hesapla.
- # Tahmin sonuçları ve gerçek değerleri kullanarak scatter diagram çiz.

- **Liner Regresyon**

- # Kütüphaneleri yükle.
- # Veri setini yükle.
- # Verileri normalize et.
- # X ve y akseni olarak veri setini parçala.
- # Yüzde 60 20 20 olarak doğrulama(train) test ve eğitim (validation) datası oluştur.
- # LR modeli oluştur.
- # Train verisi ile LR modelini eğit.
- # Eğitilen model ile eğitim (validation) verilerini tahmin et.
- # Tahmin sonuçları ve gerçek değerleri kullanarak hataları hesapla.
- # Tahmin sonuçları ve gerçek değerleri kullanarak scatter diagram çiz.

ÖZGEÇMİŞ

Kişisel Bilgiler:

Adı ve Soyadı: Zeynep Aytolu Külahcı

Eğitim Durumu:

Lisans: 2020/ İstanbul Aydın Üniversitesi / Bilgisayar Mühendisliği

Yabancı Diller ve Düzeyi:

İngilizce: Orta

İş Denevimi:

Ray Sigorta Genel Müdürlük / Bilgi İşlem Departmanı

Analiz Ekibinde Uzman Yardımcısı olarak Ağustos 2021'den beri çalışmaktayım.

Görevim:

Kurumsal ihtiyaçlar doğrultusunda ortaya çıkan ve/veya güncellenmesi gerek uygulamaların iş birimleri ile görüşerek;

- İş ve süreç analizleri gerçekleştirmek,
- Test senaryoları üzerinde çalışmak,
- Hazırlanan senaryolar için testleri uygulamak ve denetlemek,
- Kullanıcı onay testlerinin yönetilmesi,
- Gerekli tüm dokümanların hazırlanması ve güncel tutulması.

Kurum içerisinde kullanılan Automation Anywhere 360 programı için;

- İş birimleri ile görüşerek RPA için uygun olan süreçlerin analizlerinin yapılması,
- RPA üzerinde sürecin geliştirilmesi,
- Analiz gerekliliklerinin (test, kullanıcı onay, doküman vb.) işlemlerinin yürütülmesi.

Dış kaynaklı projelerin süreç yönetimleri ve testlerinden sorumluyum.

Yayın:

Anadolu Bil Meslek Yüksekokulu Dergisi / Araştırma Makalesi

Veri Madenciliği Analiz Yöntemleriyle İngilizce Hazırlık Sınıfı Başarı Analizi