

Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması

Development of a forest fire prediction model based on deep learning and forecast fire risk map of Turkey

Mehmet FİDANBOY¹

Nihat ADAR¹

Savaş OKYAY¹

¹ Eskişehir Osmangazi Üniversitesi, Mühendislik-Mimarlık Fakültesi, Eskişehir

Sorumlu yazar (Corresponding author)

Mehmet FİDANBOY

mfidanboy93@gmail.com

Geliş tarihi (Received)

07.02.2022

Kabul Tarihi (Accepted)

09.05.2022

Sorumlu editör (Corresponding editor)

Oğuzhan SARIKAYA

oguzhan.sarikaya@btu.edu.tr

Atıf (To cite this article): Fidanboy, M. , Adar, N. & Okyay, S. (2022). Derin öğrenmeye dayalı orman yangını tahmin modeli geliştirilmesi ve Türkiye yangın risk haritasının oluşturulması . Ormanlık Araştırma Dergisi , 9 (2) , 206-218 . DOI: 10.17568/ogmoad.1066557



Creative Commons Atıf -
Türetilmez 4.0 Uluslararası
Lisansı ile lisanslanmıştır.

Öz

Orman yangınları; doğal hayatı tehdit eden ve ormancılık faaliyetlerini sekteye uğratarak ekonomik kayıplara neden olan ana sorunlardan birisidir. Yangınlar; bitki örtüsü, su ve hava gibi doğal kaynakların zarar görmesine neden olabilir. Ayrıca ormanların çevresinde bulunan yerleşim veya tarım alanlarında can ve mal kayıplarına sebep olabilir. Bu yüzden orman yangınlarıyla mücadelede doğru kararların verilmesi ve etkili planlamaların yapılması önem arz etmektedir. Bu çalışmada orman yangınlarıyla mücadelede kullanılmak için Orman Yangını Analiz Tahmin (OYAT) modeli oluşturulmuştur. OYAT; resmi kaynaklardan elde edilen bitki örtüsü, iklim değişiklikleri, beşeri etmenler ve daha önceki yangın verilerine dayandırılarak geliştirilmiştir. Bu veriler derin öğrenme tekniği ile işlenerek OYAT modeli oluşturulmuştur. OYAT kullanılarak orman yangını tahmini yapılır ve bölgesel yangın risk haritası elde edilir. OYAT coğrafi bilgi sistemleri ile uyumlu çalışan, kolay kullanıma sahip, dinamik veriler ile güncellenebilen ve görselleştirilerek saklanabilen bir yapıya sahiptir. Türkiye'deki 2013-2019 yılları arasındaki orman yangını verileri OYAT modelinin değerlendirilmesinde kullanılmıştır. OYAT ile oluşturulan risk haritalarının %98 doğruluk oranına sahip olduğu gözlenmiştir. İzleyen yıllarda veri havuzunun büyümesiyle birlikte, OYAT modelinin yangın önleme için yapılacak planlamalarda daha verimli ve başarılı olacağı öngörülmektedir.

Anahtar Kelimeler: Orman yangını, risk analizi, derin öğrenme, OYAT

Abstract

Forest fires are one of the main problems that threatening natural life and cause economic losses by disrupting forestry activities. Fires can cause damage to natural sources like vegetation, water, and air. They can also cause loss of life and property by damaging the residential and cultivated areas around the forests. Therefore, it is important to make the right decisions and do effective planning in the fight against forest fires. In this study, Forest Fire Analysis Forecasting (OYAT) model has been created to be used in the fight against forest fires. The OYAT model has been built based on previous fires, vegetation, climate changes, and human factors datasets obtained from official sources. The OYAT model has been created by processing these datasets with deep learning techniques. By using OYAT, forest fires can be predicted and a regional fire risk map can be forecasted. OYAT has a structure that works in harmony with geographic information systems easy-to-use, can be updated with dynamic data and stored by visualizing. Forest fire data in Turkey between 2013 and 2019 was used for the evaluation of the OYAT model. It was observed that the maps created with OYAT had an accuracy rate of 98%. With the growth of the datasets in the following years, it is predicted that the OYAT model will be more efficient and successful in planning for fire prevention.

Keywords: Forest fire, risk analysis, deep learning, OYAT

1. Giriş

Doğal hayatın önemli ve ayrılmaz parçalarından birisi olan ormanlar dünya üstündeki yaşamın devamlılığı için vazgeçilmez bir unsurdur. Uluslararası ekonomik, toplumsal ve kültürel iş birliği oluşturmak için kurulan, Birleşmiş Milletler'e bağlı olan ve açlıkla savaşmak, tarımı geliştirmek amaçları güden Gıda ve Tarım Örgütü'ne (FAO) göre dünya üzerinde 4,06 milyar hektar (ha) alan kaplamakta ve bu da dünya kara yüz ölçümünün %31'ine denk gelmektedir. Bu alan kişi başı 0,52 ha ormanlık alana eşittir (FAO, 2020). Bu kadar geniş bir ekosistemi barındıran ormanlık alanlar, sanayi ve tarım alanlarının gelişmesi (Burke ve ark., 2016) ve iklim değişiklikleri yüzünden ciddi bir tehditle karşı karşıyadır.

İnsan etkeni, genişleyen yerleşim ve tarım alanları (Prasetyo ve ark., 2016), orman zararlıları ve özellikle de kontrol edilmesi çok güç olan orman yangınları sebebiyle, orman alanları her geçen gün daha da azalmaktadır. Tekrarlanan orman yangınları; ekosistemdeki canlı hayatın aksamasına, besin ve organik maddelerin yok olmasına (Lierop ve ark., 2015), topraktaki su döngüsünün etkilenmesine ve su kaynaklarının zarar görmesine (Mota ve ark., 2019), bitki örtüsünün zayıflamasına neden olur. Zayıflayan bitki örtüsü ile erozyon ve toprak kayıpları meydana gelir (Dale ve ark., 2001). Tetiklenmeyle beraber orman zararlıları ve patojen salgınları oluşabilir (Ayres ve Lombardero, 2000).

Gerek şehirleşme gerek iklim değişiklikleri nedenleriyle orman yangını riskleri giderek artmaktadır. Yeryüzünde 1990'dan bu yana yaklaşık 178 milyon ha ormanlık alanın yok olduğu tahmin edilmektedir ve bu alan Libya boyutunda bir kara parçasına karşılık gelmektedir. Zararlı böcek, çevre felaketi ve iklim gibi etkenler 40 milyon ha ormana zarar verirken, orman yangınlarının ise 98 milyon ha alana zarar verdiği düşünüldüğünde bu tehdidin ne kadar gerçekçi olduğu açıkça görülebilir (FAO, 2020).

Orman Genel Müdürlüğü'nün (OGM) görevleri, 3234 sayılı Kanun'da "*Orman kaynaklarını; ekolojik, ekonomik ve sosyo-kültürel faydalarını dikkate alarak, bitki ve hayvan varlığı ile birlikte, ekosistem bütünlüğü içinde idare etmek, katılımcı ve çok amaçlı şekilde planlamak, usulsüz müdahalelere, tabii afetlere, yangınlara karşı korumak, muhtelif zararlıları ile mücadele etmek ve ettirmek, ormanlık karantina hizmetlerini yürütmek, geliştirmek, orman alanlarını ve ormanlara ilişkin hizmetleri artırmak, ormanları imar ve ıslah etmek, silvikültürel bakımını ve gençleştirilmesini sağlamak*" olarak belirtilmektedir (URL-2). Görevi gereği OGM, orman yangınlarıyla ilgili istatistiksel veri

oluşturmakta ve yayınlamaktadır. OGM istatistiklerine göre 2019 yılında Türkiye'deki ormanlar 22.740.297 ha alanı kapsamaktadır (URL-3). Aynı yıl çıkan 2688 orman yangınında 11.332 ha ormanlık alan zarar görmüştür. Bu orman yangınlarının bir kısmının nedeni anlaşılırken, önemli bir kısmı olan %48'inin nedeni bulunamamıştır (URL-3). Bu yangınların çıkış dağılımlarını bulmak ve nedenlerini keşfetmek, ileriye yönelik tüm yangınlarda etkin mücadeleye katkı sağlayacaktır.

Orman yangını çıkmasına sebep olan etkenleri kullanarak yangın risk ve tehlike potansiyelini tahmin etmeye çalışan sistemler uzun süredir araştırılmaktadır. Bu konuda öncül araştırmalar Avustralya (McArthur, 1958), Amerika, (Deeming ve Brown, 1975; Cohen ve Deeming, 1985) ve Kanada'da (Van Wagner, 1987) yapılmıştır.

Tuyen ve ark. (2021), orman yangınlarına duyarlı alanların kentsel alanlar etrafında merkezlenmiş olduğuna ve önceki çalışmaların da bunu desteklediğine değinerek, orman yangınlarının genel karakteri hakkında fikir vermişlerdir. Orman yangınlarının avcılık, hayvancılık, sigara, orman ateşi, kundaklama ve çeşitli kazalar nedeniyle çıkması bu araştırma ile desteklenmektedir. Bu tür yangınların çıktığı bölgeler, insan yerleşim yerleri ile kesişmekte ve hava durumu, yükseklik ve bitki örtüsü gibi doğal sebeplerle şekillenmektedir.

Orman yangınlarıyla mücadelede hız ve doğru bilgi önemli bir etkenidir. Yangınlar, kontrol edilemediğinde, telafi edilemeyecek zararlar vererek ekosistemi etkileyebilir. Kısıtlı kaynakların doğru ve hızlı bir şekilde kullanılabilmesi için, bu kaynakların doğru yerde doğru zamanda konumlandırılmaları ve etkili politikaların geliştirilmesi gerekmektedir (Mota ve ark., 2019; Ekayani ve ark., 2016). Bunu sağlayabilmek için de orman yangınlarının doğru modellenmesi ve orman yangınları ile ilgili risk değerlendirmelerinin yapılması gerekmektedir (You ve ark., 2017).

Orman yangını modelleri oluşturulurken kullanılacak başlıca kaynak, daha önceden gerçekleşmiş olan orman yangınları ve bu yangınları etkileyen faktörlerdir (Karsai ve ark., 2016). Geleneksel modeller basit hava durumu ve insan faktörü değerlendirmesinin ötesine geçemezken sorunun doğru çözümlenmesi için gereken şey, geçmişte yaşanan yangınların daha derinlemesine incelenerek gözden kaçan etkenlerin bulunarak doğru bir şekilde analiz edilmesidir.

Teknolojinin gelişmesi ve harita biliminin teknoloji ile birleşmesiyle beraber modeller, bilgisayar desteği ile yeniden yaratılmaya başlamıştır.

Coğrafi Bilgi Sistemleri (CBS; İngilizce GIS) ile yapılan kapsamlı analizler ile oluşturulan haritalar ve risk hesaplamaları, modellemelerde yeni bir boyut kazandırmıştır. CBS'lerin bilgisayar üstünde yüksek kapasiteyle işlem yapması, modellemelerde daha verimli sonuçların ortaya çıkmasını sağlamıştır. Bu avantajlardan ötürü bazılarında makalede atıf yapılan birçok araştırmacı çalışmalarında CBS kullanarak risk analizleri yapmayı tercih etmiştir.

CBS ile yapılan araştırmalarda genel olarak yeryüzü şekilleri, hava durumu, bitki örtüsü ve insan faktörlerinin risk boyutu derecelendirilmiş ve bu faktörlere bağlı muhtemel yangın bölgeleri tespit edilmeye çalışılmıştır. Her etken bir katman olarak değerlendirilmiş, bütün katmanlara bir ağırlık düzeyi verilmiş ve katmandaki ölçümler yangın riskiyle ilişkilendirilerek risk haritası oluşturulmuştur (Yin ve ark., 2004; Gai ve ark., 2011; Ajin ve ark., 2016; Gülçin ve Deniz, 2020).

CBS ile beraber uydu analizlerinin de devreye girmesiyle, yangın oluşabilecek bölgelerin konumları daha sağlıklı ortaya çıkmaya başlamıştır. Ama bu araştırmaların ortaya attığı modellerde, değişken gruplarının risk dereceleri araştırmacılar tarafından belirlenmiştir. Örneğin Gai ve ark. (2011), araştırmalarında 0-500 metre (m) yüksekliği yüksek risk alanı olarak değerlendirirken Gülçin ve Deniz (2020) 0-250 m arasını yüksek risk alanı olarak kabul etmiştir. Yin ve ark. (2004) yerleşim yerlerine 500 m ve daha yakın alanları yüksek risk bölgesi olarak varsayarken Ajin ve ark. (2016) bu risk bölgesini 2.723 m'den daha yakın alanlar için varsayımlardır. Risk derecelerinin araştırmacılar tarafından belirlenmesi araştırmanın analizini ve dolayısıyla başarı oranını doğrudan etkilemektedir. Bu yüzden çalışmalarda kullanılacak risk faktörlerinin derecelerinin bağımsız ölçümler ile tespit edilmesi daha doğru olacaktır. Bu işlemi gerçekleştirmek için kullanılacak yöntemlerden birisi de yapay zekâ yöntemlerinden derin öğrenmedir.

Orman yangınlarının analizinde kullanmak için birçok yapay zekâ tekniği daha önceden araştırılmaya başlanmıştır. Günümüzde yapılan araştırmalarda yer şekilleri, bitki örtüsü, hava durumu ve insanların etkisi temel veri olarak kullanılmaktadır. Zheng ve ark. (2020), Ant-Miner algoritmasını (Martens ve ark., 2006) kullanarak riskleri daha dinamik hesaplamaya başlamış ve modellerini kendi kendine güncellenen bir yapıya çevirmişlerdir. Jin ve ark. (2020), orman yangınlarına benzer bir sorun olan şehir içi yangın vakalarını, derin öğrenme yöntemi ile oluşturdukları *Yangın Durum Tahmin Modeli* üzerinden analiz etmişler ve şehir içi yangın risk alanlarını belirlemişlerdir.

Cortez ve Morais, (2007) veri madenciliği yöntemi ile orman yangınlarını tahmin etmeye çalışmıştır. Ana veri olarak sadece hava durumu verilerini kullanmıştır. You ve ark. (2017), CBS kullanarak uydu görüntülerini analiz etmiş ve risk haritalaması oluşturmuşlardır. Karsai ve ark. (2016) ormanların ve orman yangınlarının hayat döngüsü akış şemasını çıkarmışlardır.

Mohajane ve ark. (2021) yapay zekâ tekniklerinden olan makine öğrenmesi ile Fas'ta meydana gelen yangınları analiz ederek yangın modellemesi oluşturmuşlardır. Çıkardıkları modeller ile orman yangını etkenlerinin önem derecelerini hesaplamışlar ve modeller bazında başarı oranlarını karşılaştırmışlardır. Tuyen ve ark. (2021) yerel ağırlıklandırılmış öğrenim algoritmaları ile Vietnam'ın orman yangınlarını analiz ederek orman yangını risk haritası oluşturmuşlardır. Oluşturdukları model ile orman yangınında en büyük faktör olarak insan faaliyetlerini göstermişler ve yerleşim yerleri ile ulaşım ağlarının yangınlara büyük neden olduğuna değinmişlerdir.

Jaafari ve ark. (2017) tarafından İran için yapılmış ve yangınlar ile yer şekilleri arasındaki etkileşim detaylı bir şekilde analiz edilmiştir. CBS ile uyumlu çalışan bir model ortaya koymuşlardır. Achu ve ark. (2021) tarafından yapılan araştırmada meteorolojik olaylar baz alınarak Hindistan'daki orman yangınları üzerindeki etkiler makine öğrenmesi tekniği ile analiz edilmiştir. Orman yangını çıkma ihtimaline göre sıcaklık haritası oluşturulmuştur.

Orman yangınlarıyla ilgili çalışmalar devam etse de hala nedeni bulunamayan çok sayıda orman yangını mevcuttur. (URL-3) incelendiğinde ülkemizde çıkan 2.688 orman yangınından yaklaşık %48'inin nedeni geleneksel yöntemlerle bulunamamıştır. Bu çalışmanın amacı, yeryüzünde bulunan ormanlık alanlarda meydana gelen yangınların gelişimini tahmin etmektir. Bu çalışmada önerilen yöntem, geleneksel modellerden farklı olarak yapay zekâ tekniklerinden biri olan 'Derin Öğrenme' ile orman yangınlarının karakteristik gelişimini incelemektir. Derin öğrenme teknikleri sayesinde orman yangınlarına neden olan etkenlerin bilgisayar destekli modellemesi oluşturulabilir ve yangınlardaki tüm etkenler belirlenerek yangınların asıl nedenlerine bir açıklık getirilebilir.

Önerilen yenilikçi model ile çok katmanlı veriler kullanılarak orman yangın tahmini ve yangın risk haritası oluşturulur. Gelecekte oluşabilecek yangınların ihtimallerine dayalı olarak ortaya konulan yangın risk haritası ile orman yangınlarını önlemek için yapılan çalışmalar daha verimli ve etkili olarak planlanabilecektir.

2. Materyal ve yöntem

2.1. Materyal

Araştırma dâhilinde kullanılacak materyaller orman yangınlarının başlangıcını ve dağılmasını etkileyen faktörlerin Türkiye coğrafyasındaki değerleri olarak kabul edilmiştir. Veriler Türkiye sınırları içindeki alanları kapsamakta olup bu sınırların dışındaki alanlar modelden çıkarılmıştır. Veriler 2013-2019 yılları arasında kapsamakta ve aylık olarak gruplandırılmaktadır.

Bu araştırmada kullanılan veriler resmi kaynaklardan alınmıştır. Her bir veri türü oluşturulan CBS veri tabanında katman olarak ele alınmaktadır. Her bir katmanı oluşturan verilerin kaynakları ve kullanılış nedenleri aşağıda listelenmiş olan alt başlıklarda detaylandırılmaktadır.


- Geçmiş yangın verileri,
- Bitki örtüsü haritası,
- Ortalama sıcaklık haritası,
- Dünya gece uydu görüntüleri,
- Bağıl nem haritası,
- Hava basınç haritası,
- Nüfus haritası,
- Arazi örtüsü haritası,
- Yeryüzü yükseklik haritası,
- Rüzgâr verisi

İzleyen bölümlerde geçmiş yangın verileri, bitki örtüsü haritası ve gece görüş haritaları metin içinde şekil olarak verilmiştir. Diğer katmanlara ait haritalar ise metni gereksiz uzatmamak için verilmemiştir. Tüm katmanlara ait haritalara (URL-10) adresinden ulaşılabilir.

2.1.1. Geçmiş yangın verileri

OGM Türkiye’de bulunan bütün orman yangınlarının resmi tutanaklar ile kaydını tutmaktadır. Bu bilgiler yangınlar hakkındaki koordinat, yükseklik gibi fiziki bilgileri, hava durumunu ve yangın nedenini içermektedir. Bu veriler sayesinde yangınları tetikleyen alt unsurları keşfetmek amaçlanmaktadır. Bu kapsamda oluşturmuş oldukları veri paketi 2013-2020 arası gerçekleşmiş olan 22.238 yangının bilgilerini içermektedir (OGM, 2021). Oluşturulan bu verinin içinde; yangınların bulunduğu idari birimler, yangının çıkış ve söndürme tarihleri, yangın çıkış nedenleri, yangın bölgesinin coğrafi konumu, yangın zamanı hava sıcaklığı, rüzgâr yönü ve hızı, yangın bölgesinin yüksekliği ve yangın bölgesiyle ilgili sınıfsal veri (koru alanı, bataklık alanı, ağaçlandırma alanı, maki alanı), yangına ilk müdahale süresi ve yanma süresi bilgileri bulunmaktadır.

Bu çalışma kapsamında, Orman Genel Müdürlüğü’nden sağlanan bu veriler, koordinat sistemi vasıtasıyla görselleştirilerek eğitiminden beklenen çıktı için temel teşkil edecektir. Şekil 1’de Türkiye Marmara Bölgesi’nden alınan 302,08×302,08 km²’lik bir alanda 2014 yılı Ocak ayında gerçekleşen yangınlar örnek olarak gösterilmiştir.




Şekil 1. Marmara Bölgesi orman yangınları
Figure 1. Forest fires of Marmara Region

2.1.2. Bitki örtüsü haritası

Yangınlara yakıt olan biyokütle ormanların sık olduğu alanlarda yoğunlaşmaktadır. Bu yüzden ormanların yoğun olduğu alanların belirlenmesi, risk analizinde gerekli bir koşuldur. Teorik olarak bitki örtüsü belirtisi, bitkilerin yapraklarından yansıyan spektral yansıma izleridir. Görünen yansıyan enerji, aktif pigmentlerin emmesi nedeniyle düşük miktarda, mavi ve kırmızı dalga boylarında en yüksek seviyededir. Sonuç olarak, kırmızı ve yakın-kızılötesi (NIR) yansıma arasındaki kontrast farkı bitki örtüsü miktarı hakkında ölçüm ifade etmektedir. Maksimum kırmızı – NIR farkı tam dolu bitki örtüsü katmanını işaret ederken, minimum kırmızı – NIR farkı bitkisiz ortamı ifade etmektedir (Didan ve ark., 2015). Bu farktan yararlanılarak Normalize Edilmiş Bitki İndeksi (NDVI) değeri elde edilir. NDVI, NIR değerinin yakın yansıma değerine göre oranının bulunmasıyla ölçülür. -1 ve 1 arasında değer kümesi alacak bir şekilde standarda kavuşturulmuştur.

NDVI, güneş ve geliş açısı, bulutlar ve oluşturdukları gölge alanlar, topografya ve atmosferik inceliğin neden olduğu etkileri oransal olarak minimum seviyelere çeker (Didan ve ark., 2015). Lineer (doğ-

rusal) olmamaları sebebiyle, bazı coğrafi koşullardan bitki örtülerinde duyarsızlığa yol açan asimptotik davranışlar sergileyebilirler. Orantı ayrıca atmosferik etkilerin spektral bağımlılıklarını, arka plan etkileşimi ve örtü gölgelerine etki eden parçacıkları hesaba katmakta başarısız olur. Şekil.2’de Marmara Bölgesi’nden alınan örnek bitki örtüsü verisi gösterilmiştir.



Şekil 2. Marmara Bölgesi bitki örtüsü verisi
Figure 2. Vegetation data of Marmara Region

2.1.3. Ortalama sıcaklık haritası


Bir yangının oluşumunu etkileyen üç temel özellik vardır: havadaki oksijen, sıcaklık ve yakıt. Bu üç temel değişken literatürde ‘Yangın Üçgeni’ ya da ‘Fire Triangle’ olarak geçer. Bu üç özellik bir araya geldikten sonra meydana gelen ekzotermik (ısı çıkaran) kimyasal reaksiyon ateşi başlatır. Yangının çıkmasına sebep olan faktörlerin sağlamak zorunda olduğu ısı miktarı hava sıcaklığına bağlı olarak değişir. Örneğin yapılan bir araştırmada (Achu ve ark., 2021) özellikle 30°C ve üzerindeki hava sıcaklığında orman yangınlarının yoğunlaştığı vurgulanmıştır.

2.1.4. Gece uydu görüntüleri

Yoğunlaşan nüfus ve artan yakıt kullanımı ile geceleri yerleşim alanları daha parlak renklerde görünmeye başlamıştır. Özellikle geceleri artan bina ve yol ışıklandırmaları ile dünya üstündeki insan faktörünün doğru bir yayılımı tespit edilebilir. Büyük yerleşim alanları, bu alanları birbirine bağlayan yollardaki ışıklandırma, araba ve gemi gibi ışık kaynakları kullanılarak insan aktivite kalıpları çıkarılabilir (Román ve ark., 2019).

İnsanların neden olduğu kaza ve kasıtlı eylemler orman yangını riskini arttırmaktadır. Özellikle

araçlardan atılan sigara izmaritleri gibi faktörlerin orman yangınlarına neden olabileceği göz önünde bulundurulduğunda (Tuyen ve ark., 2021), bu profilin orman yangınlarıyla alakalı olabileme ihtimali hiç de az görünmemektedir. Dolayısıyla yoğun alanların daha yüksek risk faktörü içermesi nedeniyle, parlak alanlarda orman yangını oluşma ihtimali artmaktadır. Bu veri paketinin kullanılma amacı daha işlek yolların ve yerleşim alanlarının yangına etkisini incelemektir. Şekil 3’te Marmara Bölgesi gece haritası bu ışık profilini göstermek için örnek olarak verilmiştir.



Şekil 3. Marmara Bölgesi gece görüntüleri
Figure 3. Night images of Marmara Region

2.1.5. Bağlı nem haritası

Yeryüzündeki suyun buharlaşarak havaya karışmış haline nem denilmektedir. Havanın, bulunduğu sıcaklığa ve basınca göre taşıyabileceği bir nem kapasitesi vardır. Buna maksimum nem denir. Özgül nem ise birim ağırlık havada bulunan su buharı ağırlığıdır. Bağlı nem (RH), havadaki nem miktarının aynı sıcaklık ve basınçta havayı doyurmak için gerekli nem miktarına oranıdır.

Ormanlık alanda bulunan yerdeki ölü ağaçlar ve diğer yakıtların durumu yangında büyük öneme sahiptir (Van Wagner, 1987). Havadaki nem ile bu yakıtlar arasındaki nem aktarımı da, bağlı nemin orman yangınlarında önemli olmasının nedenidir. Bağlı nem azaldığı zaman bu yakıtlardan havaya nem akışı olur ve yakıt daha kuru bir hale geldiği için yangına elverişliliği artar. Yüksek bağlı nem durumunda ise havadan yakıtlara nem aktarımı olmaktadır ve bu yakıtların yanma potansiyeli düşmektedir (Cohen ve Deeming, 1985). Bu çalışma kapsamında Türkiye’de ölçülmüş aylık ortalama bağlı nem haritaları kullanılarak, bu faktörün yangınlar üzerindeki etkisi ölçülmeye çalışılmıştır.

2.1.6. Hava basınç haritası

Hava basıncının ateş ve yangınların davranışlarına etkileri konusunda çeşitli araştırmalar vardır (Kuang ve ark., 2013). Yapılan çalışmalarda basınç ile ateş yüksekliği arasında orantı saptanmıştır. Genel olarak hava basıncı azalırken ateşin yüksekliği ve dolayısıyla yüksek sıcaklıktaki ateş bölgesinin yüksekliği artış eğilimi göstermektedir ve kritik bir noktadan sonra düşük hava yoğunluğundan dolayı düşüşe geçmektedir (Kuang ve ark., 2013). Yüksek basınç altında, ateşin yüksek sıcaklık bölgesi yerdeki yakıtı daha yakın olduğu için, bu bölgeleri daha hızlı kurutmakta ve artan kuru yakıt miktarı ile ateşin yayılım hızı artmaktadır. Hava akımının yüksek basınç alanından alçak basınç alanlarına doğru oluşması ile yüksek basınç alanlarında oluşan yangınların daha hızlı bir şekilde yayılması öngörülmektedir. Dolayısıyla orman yangınları ile basınç alanlarının arasındaki etkileşimin incelenmesi gerekmektedir.

2.1.7. Nüfus haritası

OGM resmi istatistiklerine göre 2020 yılında çıkan 3.399 yangından 1.156 yangın ihmalden ve 72 yangın insani nedenlerden dolayı çıkmıştır (URL-5). Yaklaşık %36 olan bu etkiyi ölçmenin başlıca yollarından birisi de insan miktarını incelemektir. İnsan yoğunluğunun artması, ormanların tahribinin artmasına ve orman alanlarının azalmasına neden olmaktadır. İnsan yoğunluğu odaklı veri seti 2010, 2015 ve 2020 yılındaki verilere göre oluşturulmuştur. Aylara göre yangın verileri kendilerine en yakın olan tarihteki, nüfus haritası ile eşleştirilerek nüfusun orman yangınlarına etkisi incelenecektir.

2.1.8. Arazi örtüsü haritası

Orman yangınlarının oluşmasındaki faktörlerin etkisini şekillendiren ana özellik arazilerin kullanılma türüne göre dağılımıdır. Arazi örtüsündeki değişiklikleri takip edilebilmesi, küresel değişimin modellenmesinde esas olacaktır (Yoram ve Ark., 1998). Bu doğrultuda arazi değişimi kullanılarak yangınların oluşum eğilimleri de modellenebilir.

Orman yangınlarının büyük yerleşim merkezlerinde oluşması beklenemeyecek bir durumdur. Ayrıca tarım alanlarından kaynaklanan ateşlerin ormanlara zarar vermesi gibi bir olasılık da mevcuttur. OGM resmi istatistiklerine göre 2019 yılında 184 anız yakma kaynaklı orman yangını meydana gelmiştir (URL-3). Ayrıca mesire alanlarında yakılan piknik ateşinden kaynaklanan orman yangınları ve sönmemiş sigaradan kaynaklanan yangınlar da OGM istatistiklerinde görünmektedir. Diğer araştırmalarda, mesela Tuyen ve ark. (2021), bu faktör

göz önünde bulundurulmaktadır. Bu verinin kullanılmasında amaç, arazinin kullanılma özelliğine göre dağılımlarının (Sulla-Menashe ve ark., 2018) orman yangınları üstündeki etkisini ortaya koymaktır.

2.1.9. Yeryüzü yükseklik haritası

Ateşin yanabilmesi için temel gereksinimler yakıt, ısı ve oksijendir. Ayrıca ateşin başlayabilmesi için gerekli enerji ısı olarak var olmalıdır. Yükseklik arttıkça yeryüzü sıcaklığı ve oksijen yoğunluğu giderek azalmaktadır (Kuang ve ark., 2013). Bu iki faktörün ateşi etkileyen ana faktörler olması nedeniyle, yükseklik faktörü diğer etkenlerin etkisini doğrudan etkilemektedir. Dolayısı ile yükseklik faktörünün, yangınlar üzerindeki etkisi, modelleme yapılırken göz ardı edilemez. Ayrıca, bir araştırmada (Jaafari ve ark., 2017), eğimli arazilerde orman yangını çıkma ihtimalinin, düz alanlara göre daha yüksek olduğu vurgulanmıştır. Bu katman sayesinde eğimlerin, yükseltelerin ve topografik yapıların yangınlar üstündeki etkisinin anlaşılması amaçlanmaktadır.

2.1.10. Rüzgâr verisi

Rüzgârın yangınlar üzerindeki etkisi yadsınamayacak kadar fazladır. Yangınlar üstünde yelpaze etkisi yaparak yangının yayılımını ve hızını etkiler. Yangın alanına oksijen taşıyarak kimyasal tepkimeye yardımcı olur. Yerde bulunan yakıtta buharlaşmayı hızlandırarak, yakıtın yanma potansiyelini artırır. Yangın yolundaki yakıtı ve ateşi hareket ettirerek yangının ilerlemesini ve yayılmasını hızlandırır. Yüksek hızlı rüzgârın kıvılcımları daha ileri götürerek, normalde yangının aşamayacağı sınır ve bariyerleri aşarak başka yangınlar çıkmasına neden olabilir. Bir araştırmada rüzgâr hızının 7 metre/saniye'den (m/sn) yüksek olduğu durumlarda, yangın tespit edilmediğine değinilmiştir (Achu ve ark., 2021). Bu da rüzgârın yangını önleyici etkiye de sahip olabileceğini ortaya koymuştur. Bu veri setinin kullanılması sayesinde rüzgârın yangınlar üstündeki etkisi ölçülmeye çalışılmıştır.

2.2. Yöntem

Yöntem olarak araştırmada sunulan Orman Yangını Analiz Tahmin (OYAT) modeli ile beraber geçmişte yaşanan orman yangınları kullanılarak yangına neden olan etkenleri incelenmektedir. Böylece gelecekte benzer şartların oluşması ile yangın çıkma bölgeleri belirlenebilecektir. Modelin yapısı gereği, yeni yıllara ait verilerin modele eklenmesi için gereken şey, yeni verilerin CBS'ye katman olarak eklenmesi ve OYAT modeli ile analiz edilmesidir. Bu veri alt yapısı ile OYAT'ın yeni

verileri işlenmesi de basitleştirilmiş olmaktadır. Her yıl yeni verilerin eklenmesi ile güncel olarak yangın risk bölgeleri belirlenebilecektir. OYAT ile oluşturulan yangın risk haritası ile Yangınla Mücadele Eylem Planı daha verimli ve etkin oluşturulabilecektir.

2.1. Katmanlı dijital verilerin oluşturulması

OGM tarafından sağlanan yangın verilerinin metin formatında olması, görüntü bölümlenme işlemini engellemektedir. Bu yüzden bu metin verilerinin, görsel formata dönüştürülmesi gerekmektedir. Bu metin verilerinde yangın verilerini görsel olarak temsil eden özellik kuzey ve doğu koordinatlarıdır. Bu koordinatlar Küresel Konumlama Dizgesi'nde (URL-1; URL-8) yangının çıkış yerlerini temsil etmektedir. Bu verilerin temsil ettiği koordinatlara yerleştirilmesi için, *Geospatial Data Abstraction Library* (GDAL) kullanılmıştır (URL-6). GDAL coğrafi formatları okuyan, yazan ve işleyebilen açık kaynak kodlu bir yazılım kütüphanesidir (Qin ve ark., 2014). GDAL ile işlenen verileri görselleştirmek ve kontrol işlemlerini sağlamak için *Quantum Geographic Information System* (QGIS) kullanılmıştır (URL-7). QGIS açık kaynak kodlu bir CBS uygulamasıdır. GDAL ile QGIS uygulamasına aktarılan veriler, yıllara ve aylara göre gruplanarak koordinat sisteminde görselleştirilmiştir.

Bitki örtüsü haritası, aylık ortalama sıcaklık haritası, dünya gece uyu görüntüleri, aylık bağıl nem haritası, aylık basınç haritası, dünya insan nüfus haritası, aylık rüzgâr verisi ve yeryüzü yükseklik haritaları ABD Ulusal Havacılık ve Uzay İdaresi (NASA) tarafından açık kaynak olarak paylaşılmaktadır (URL-9). NASA'nın oluşturduğu *Earth-data* (URL-4) platformundan edinilen bu verilerden yükseklik haritalarına *Height* (HGT) formatında, diğer verilere ise *Hierarchical Data Format* (HDF) formatında erişilmiştir. HDF dosyalarında, veri paketlerini oluşturan alt katmanlardan gerekli veriler seçilmiştir. Seçilen veriler GDAL ile CBS'ye aktarıldıktan sonra birleştirilerek her katman için bütün bir görsel oluşturulmuştur.

Görselleştirilen harita verileri, Türkiye haritası ile maskelenerek, eğitim bölgesi dışındaki verilerin modeli etkilemesinin önüne geçilmiştir. Verilerde, Türkiye sınırları dışında kalan alanlar, deniz ve göller eğitim modeline etki etmesin diye standart değerlere çevrilmiştir. Oluşturulan görseller 512×512 piksel çözünürlükteki kesitlere ayrılarak, modelde kullanılacak eğitim verileri oluşturulmuştur. Sonuç olarak her katmanda 2013-2019 yılları arasındaki aylık verileri gösteren 2.016 görsel veri oluşturulmuştur. Bu veriler temsil ettiği ay ve yıla göre etiketlenerek derin öğrenme ağı için uy-

gun hale getirilmişlerdir.

Araştırma verisinin formatı gereği, eğitim görüntü işleme yöntemleri ile yapılacaktır. Görüntü bölümlenme, yapay zekâ ile görüntü işleme yöntemlerinden birisidir. Verilen görüntülerdeki sınır değerlerinin ve alan özelliklerinin bilgisayar tarafından tanınması için bu alanların niteliğinin belirlenmesi lazımdır. Görüntüdeki alanların ve sınırlarının neye karşılık geldiğinin belirlenmesi için çeşitli modeller ortaya atılmıştır. Bu modellerden bazıları U-Net, FastFCN, Gated-SCNN, DeepLab, Mask R-CNN gibi nöron ağlarıdır (Ronneberger ve ark., 2015). Bu ağlar görüntülerin parçalara ayrılması, bölgesel görüntülerin tanınması ve bu görüntülere göre görüntü bölgelerini ayırtmak için geliştirilmiştir.

U-Net ağı, Ronneberger ve arkadaşları tarafından yayınlanan bir makale ile ilk kez dünyaya duyurulmuştur (Ronneberger ve ark., 2015). Tıp alanındaki görüntülerin işlenmesi ve görüntü bölümlenmesi için geliştirilen bu ağ modeli, veri artırımının yüksek oranda kullanılarak, verilerin daha efektif bir şekilde kullanıldığı ağ ve eğitim stratejisi önermektedir. Sunulan ağda 512×512 piksel boyutlarındaki bir görüntünün hali hazırda piyasada olan grafik kartları üzerinde bir saniyeden kısa bir sürede bölümlendiği ileri sürülmüştür.

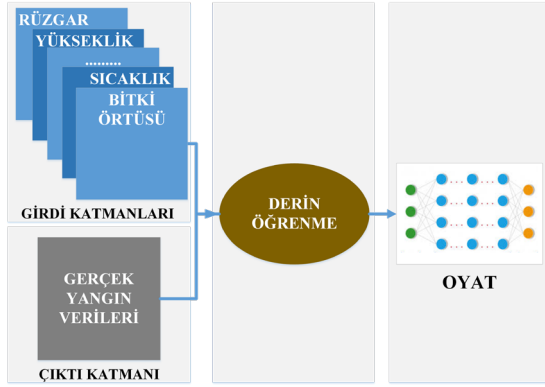
U-Net modeli bir daralma ve genişletme yolu üstünde işlem yapmaktadır. Daralma yolu, normal bir evrişim ağının mimarisi gibi iki tane 3×3 piksel konvolüsyonun tekrarlanarak uygulamasından oluşur. Bu uygulamalardan her biri, düzeltilmiş doğrusal birimden (ReLU) ve alt örnekleme için 2×2 piksel maksimum havuzlama işlemleri ile oluşur. Her alt örnekleme adımında, özellik kanallarının sayısı ikiye katlanır.

Genişleme yolu ise, özellik haritasının bir üst örneklemesinden ve özellik kanallarının sayısını yarıya indiren bir 2×2 piksel evrişimden (yukarı evrişim) meydana gelir. Ayrıca, daralma yolundan uygun şekilde kırılmış özellik haritasıyla bir birleşmeden ve iki 3×3 piksel evrişimden oluşur. Her bir evrişimin ardından bir ReLU işlemi uygulanır. Kırılma işlemi, her evrişimde kenar piksellerinin kaybı nedeniyle gereklidir. Son katmanda, her 64 bileşenli özellik vektörünü istenen sayıda sınıfa eşlemek için 1×1 piksellik bir evrişim kullanılır. Bu sinir ağı toplamda 23 tane katmana sahip olur. Veri setiyle oluşturulan bölümlenme haritaları veri modeli eğitimi için kullanılır. Yeterli veri olmadığı zaman, modellerden alınan 3×3 piksel kesitler, yer değiştirme ve rastgele vektör kullanımı ile verilerin artırımı sağlanır.

2.2.2. Orman yangını tahmin modeli

Araştırma verileri CBS veri altyapısında toplandıktan sonra öğrenme işleminin gerçekleştirilebilmesi için, derin öğrenmeye dayalı platform oluşturulmuştur. Model, derin öğrenme platformu olarak açık kaynak kodlu *Tensorflow* kütüphanesi (Abadi ve ark., 2016) ve sinir ağı olarak *Keras* kütüphanesi (Grattarola ve Alippi, 2021) üzerinde geliştirilmiştir.

Araştırmada, zamansal ve bölgesel gruplandırılmış katman verileri, gerçekleşmiş yangın verileri ile kullanılarak OYAT modeli oluşturulmuştur. OYAT modeli Şekil 4'te gösterilmektedir. Bu model üzerinden 2019 yılına ait aylık orman yangını tahmin haritası üretilmiştir. Oluşturulan 512×512 piksel büyüklüğündeki bölgesel veriler birleştirilerek 12 aylık Türkiye orman yangını tahmin haritaları çıkarılmıştır. 2019 ağustos ayına ait Türkiye orman yangını tahmin haritası Şekil 5'te gösterilmiştir.



Şekil 4. OYAT modeli

Figure 4. 'Forest Fire Analysis and Prediction' model



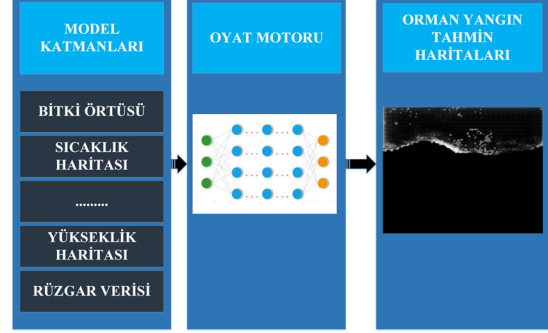
Şekil 5. Türkiye orman yangını tahmin haritası, Ağustos 2019

Figure 5. Forest fire probability map of Turkey, August 2019

3. Bulgular


Araştırmada, Türkiye bitki örtüsü, iklim değişiklikleri, beşeri etmenler ve daha önceki yangın verilerinin OYAT ile analiziyle orman yangını tahmin haritaları oluşturulmuştur. Bu haritalar Türkiye'nin belirli coğrafi bölgelerinde çıkabilecek

yangınların olasılıklarını göstermektedir. OYAT modeli 2013-2018 verileri kullanılarak oluşturulmuş ve doğruluğunun kontrolü için 2019 da gerçekleşen yangın verileri kullanılmıştır. Şekil 6'da OYAT modelinin çalışma prensibi ve tahmin haritalarının oluşturulma süreci gösterilmiştir.




Şekil 6. Orman yangını tahmin haritası oluşturma
Figure 6. Forecast forest fire probability map

OYAT'ın oluşturduğu orman yangını tahmin haritaları, gerçekleşmiş yangınları gösteren haritalar ile kıyaslanmıştır (Şekil 7). Sol tarafta görülen haritalarda gerçek yangınlar kırmızı noktalar ile işaretlenmiştir. Sağ tarafta görülen OYAT'ın oluşturduğu orman yangını tahmin haritalarında ise siyah düşük olasılıklı yerleri ve beyaz yüksek olasılıklı yerleri temsil etmektedir. Özellikle Akdeniz ve diğer kıyı bölgelerimizde gözlemlenen beyaz alanlar daha yüksek yangın çıkma olasılığını işaret etmektedir.



Şekil 7. Türkiye'nin farklı coğrafi bölgelerinde gerçekleşen yangın haritaları ve orman yangını tahmin haritaları

Figure 7. Maps of forest fires that occurred and predicted in different geographical regions of Turkey



Şekil 7 devamı /Figure 7 continued

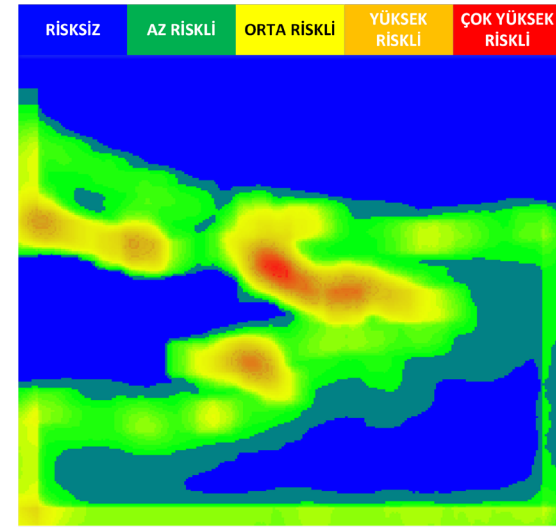

Yine Şekil 7’de sağ tarafta görülen OYAT haritalarda gri noktalar yangın olasılığının yüksek olduğu yerleri işaret etmektedir.

Modelin doğruluğunun tespiti için; gerçek yangın haritaları ve OYAT’ın öngördüğü orman yangını tahmin haritaları analiz edilerek bölgesel gerçekleşmiş yangın haritası ve OYAT bölgesel yangın risk haritasına çevrilmiştir. Yapılan analizde, merkez nokta çevresinde çıkan yangın sayısına ve yangın tahminine göre, merkez noktanın yangınlara karşı duyarlılığını ölçülmektedir. Bu analiz kapsamında aşağıdaki işlemler yapılmıştır:

Gerçekleşen yangın haritalarında bulunan her bir piksel sırayla merkez kabul edilerek, çevresindeki 9×9 piksellik (5,3×5,3 km²) alan taranmıştır; bu alanda yıl boyunca çıkan yangın sayısına göre merkez pikselin yangın duyarlılığı beş risk grubundan birine eşlenmiştir.

Bu risk grupları aşağıdaki gibidir:

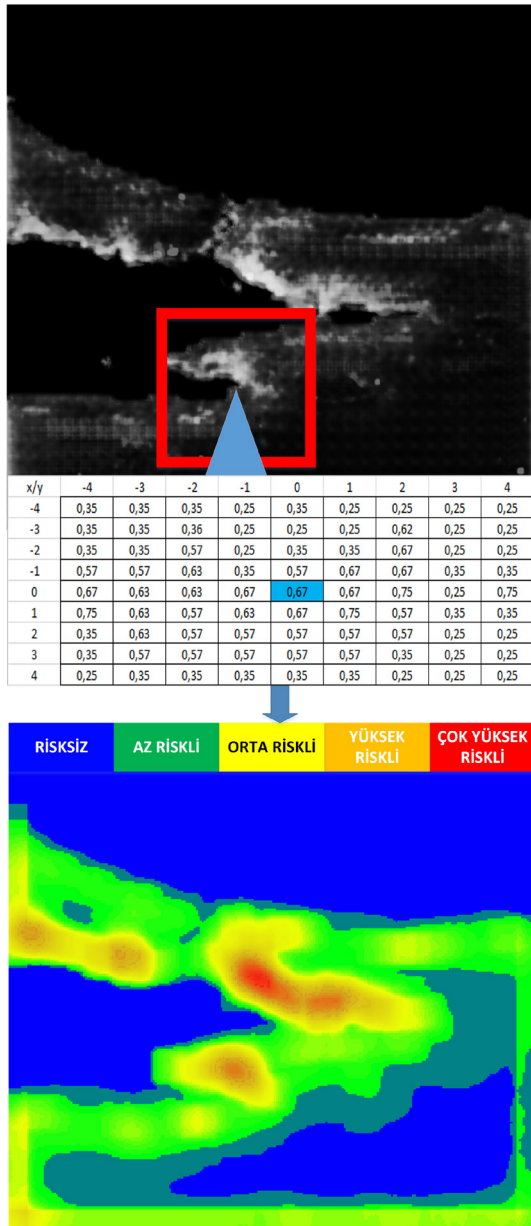
- Risksiz bölge
- Az riskli bölge
- Orta riskli bölge
- Yüksek riskli bölge
- Çok yüksek riskli bölge



Şekil 8. Bölgesel gerçekleşen yangın haritası oluşturma
Figure 8. Forecast regional occurred fire map

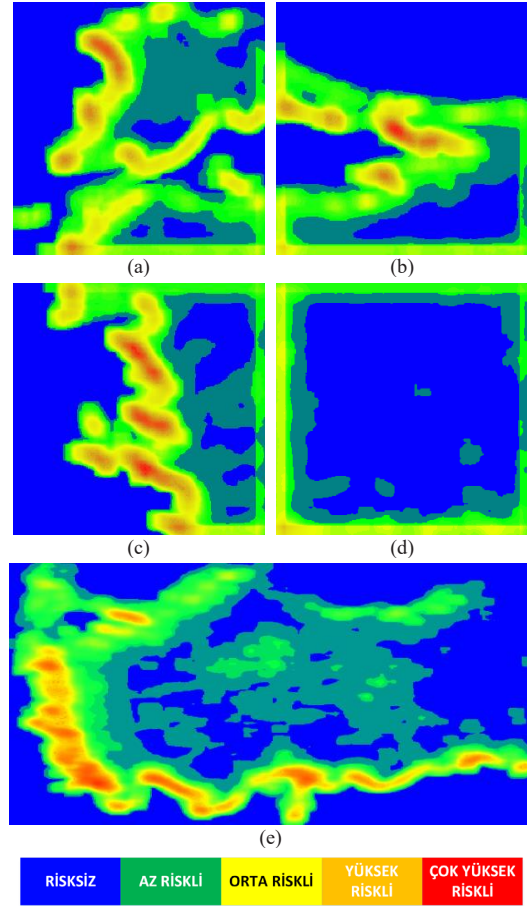
Gerçekleşen yangın haritalarında bulunan her pikselin analizi sonucu bölgesel gerçekleşmiş yangın haritası oluşmuştur. Bu işlem akışı Şekil.8’de verilmiştir. Aynı işlem OYAT’ın öngördüğü tahmin haritalarına da uygulanmıştır. OYAT orman yan-

gını tahmin haritalarındaki her bir piksel sırayla merkez kabul edilerek, çevresindeki 9×9 piksellik (5,3×5,3 km²) alan taranmıştır; bu alanda yıl boyu öngörülen yangın çıkma tahminleri toplamına göre merkez pikselin yangın duyarlılığı beş risk grubundan birine eşlenmiştir. Tahmin haritalarının analizinde gerçekleşen yangın haritalarıyla aynı risk grupları kullanılmıştır. Orman yangını tahmin haritalarındaki her pikselin analizinden sonra OYAT bölgesel yangın risk haritası oluşmuştur. Bu işlem akışı Şekil 9’da gösterilmektedir.



Şekil 9. Bölgesel yangın risk haritası oluşturma
Figure 9. Forecast regional fire risk map

Bölgesel gerçekleşen yangın haritası ile OYAT bölgesel yangın risk haritası beş risk grubu üzerinden kıyaslanmış ve %98’lik bir doğruluk oranı gözlemlenmiştir. Şekil.10’da Türkiye’nin yüksek riskli orman yangını bölgelerinin ve bütününün OYAT bölgesel risk haritaları örnek olarak verilmiştir. Bu haritalarda görülebileceği gibi kıyı bölgelere gidildikçe bölgesel yangın riski artmaktadır. Ayrıca İstanbul, İzmir ve Çanakkale gibi sahilde yer alan büyük şehirlere yakın alanlarda da bölgesel yangın riski artmaktadır. Bunların aksine iç bölgelere ve Doğu Karadeniz Bölgesi’ne doğru gidildikçe bölgesel yangın riski de azalmaktadır.



Şekil 10. Oluşturulmuş Türkiye bölgesel yangın risk haritaları, (a) Trakya Bölgesi yangın risk haritası, (b) İstanbul Bölgesi yangın risk haritası, (c) İzmir Bölgesi yangın risk haritası, (d) Doğu Ege Bölgesi yangın risk haritası, (e) Türkiye geneli yangın risk haritası

Figure 10. The created regional fire risk map, (a) Fire risk map of Thrace Region, (b) Fire risk map of İstanbul Region, (c) Fire risk map of İzmir Region, (d) Fire risk map of East Aegean Region, (e) Fire risk map of Turkey-wide

4. Tartışma ve sonuç

Bu araştırmada, Türkiye’de 2013-2019 dönemine ait orman yangını verileri kullanılarak, gelecekte yaşanacak orman yangınlarının derin öğrenme ile başarılı bir modellemesinin yapılıp yapılamayacağı değerlendirilmiştir. Yangınlara etki eden çevre faktörleri değerlendirilmiş ve buna göre bir risk derecelendirmesi yapılmıştır. Bu amaçla derin öğrenme temelli OYAT modeli geliştirilmiştir. OYAT kullanılarak orman yangını tahmin haritaları ve bölgesel yangın risk haritaları oluşturulmuştur. Özellikle iklim şartlarının, yer şekillerinin, bakının ve insan faktörünün yangın riskine etkisi olduğu gözlenmiştir. Çıkan sonuçlarda hem koşullara göre değişen hem de varlığını her ay koruyan risk alanları bulunmaktadır.

Varlığını her ay koruyan risk alanlarının güney batı kıyılarında gözlenmesi de modelin sonuçlarında dikkat çeken bir bulgudur. Güneş ışınlarının dik açılarla gelip, hava sıcaklığının gün içinde en yüksek seviyeye geldiği saatlerde güneş ışınlarının bu bölgelerin güney batı yamaçlarına vuruyor olması bu bulguyu tetiklemiş olabilir.

Kış aylarından yaz aylarına doğru gidildikçe yangın ihtimallerin kurak olan iç bölgelere doğru yayılması, hava durumunun yangınlar üstündeki etkisini göstermektedir.

Oluşturulan risk haritasında, insan yerleşimlerinin olduğu bölgelerin yüksek riskli olduğu gözlenmiştir. Özellikle İstanbul, İzmir, Çanakkale, Antalya, Mersin gibi yüksek nüfuslu ve ormanlarla iç içe illerde yangın riskine daha çok dikkat edilmelidir. Dolayısıyla yangınlarda insan kaynaklı kusurların baskın olduğu keşfedilmiştir. Konya, Bolu, Burdur, Çankırı gibi iç bölgelere gidildikçe yangın ihtimalinin azaldığı saptanmış ancak Tuz Gölü, Van Gölü, Beyşehir Gölü gibi sulak bölgelerin, burada bulunan mesire ve piknik alanlarından dolayı risk bölgesine dönüştüğü görülmüştür. Ayrıca sahil kesimlerinde de daha fazla yangın görüldüğü tespit edilmiştir.

İleride yapılacak çalışmalarda, araştırmacıların daha bölgesel çalışarak, daha yüksek kapasitede verilerin üstünde çalışması araştırmanın doğruluğunu olumlu etkileyeceği düşünülmektedir. Özellikle OGM’nin çıkarmış olduğu yangın envanteri çok kapsamlı bir orman yangını tarihçesi içermektedir (URL-3; URL-5). Bu envanteri destekleyecek diğer verilerin ayrı kaynaklardan derlenip bir araya toplanması bu araştırmada başarılı bir kazanımdır. Oluşmuş olan veri havuzunun başka araştırmacılarla paylaşılması ve gelecek akademik araştırmalara temel hazırlaması bu araştırma

için önemli bir görev olarak görülmektedir.

Oluşturulacak veri havuzu ile Türkiye ve Dünya’daki orman yangınlarının önüne geçen planlamalar yapılabilecektir. Özellikle son yıllarda yaşanan küresel ısınma ile beraber orman yangınlarında artış olmaktadır. Bu nedenle orman yangınlarına karşı daha proaktif müdahale yöntemleri geliştirilmelidir. Çalışmada oluşturulan derin öğrenme modeli ile yeni verileri sürekli işleyerek orman yangın risk tahminlerini güncelleyen otonom sistem oluşturulabilir. Otonom sistemlerin kullanılmasıyla birlikte, orman yangınlarını önleyici tedbirler ve hızlı müdahale yöntemleri için kullanılacak bilginin güncel kalması sağlanabilecektir. Bu sayede, orman yangınları gibi doğal felakete karşı mücadelede ve doğal hayatın korunması yönünde daha ileri gidilebilecektir.

Teşekkür

Araştırmaya gerek duyulan verileri sağlayan Orman Genel Müdürlüğü, Orman Yangınlarıyla Mücadele Dairesi Başkanlığı’na teşekkür ederiz.

Kaynaklar

Abadi, M., Barham, P., Chen J., Chen Z., Davis A., Dean J., Devin M., Ghemawat S., Irving G., Isard M., ark. 2016.

Tensorflow: A system for large-scale machine learning. 12th symposium on operating systems design and implementation 16: 265–283.

Achu, A. L., Thomas, J., Aju, C.D., Gopinath, G., Kumar, S., Reghunath, R., 2021. Machine-learning modeling of fire susceptibility in a forest-agriculture mosaic landscape of southern India. *Ecological Informatics*, s. 101348.

Ajin, R.S., Loghin, A. M., Vinod, P. G., Jacob, M. K., 2016. RS and GIS-based forest fire risk zone mapping in the Periyar Tiger Reserve, Kerala, India. *Journal of Wetlands Biodiversity* 6:139–148.

Ayres, M. P., Lombardero, M. J., 2000. Assessing the consequences of global change for forest disturbance from herbivores and pathogens. *Science of the Total Environment* 262(3):263–286.

Burke, D. J., Knisely, C., Watson, M. L., Carrino-Kyker, S. R., Mauk, R. L., 2016. The effects of agricultural history on forest ecological integrity as determined by a rapid forest assessment method. *Forest Ecology and Management* 378:1–13.

Cohen, J. D., Deeming J. E. 1985. *The national fire-danger rating system: basic equations* 82. US Department of Agriculture, Forest Service, Pacific Southwest Forest and Range Experiment Station.

Cortez, P., Morais, A. D. J. R. (2007). A data mining

approach to predict forest fires using meteorological data. I Associação Portuguesa para a Inteligência Artificial (APPIA)

Dale, H.V., Joyce, L.A., McNulty, S., Neilson, R. P., Ayres, M.P., Flannigan, M.D., Hanson, J.P., Irland, L.C., Lugo, E.A., Peterson, C. J., Simberloff, D., Swanson, F.J., Stocks, B.J., Wotton, B. M., 2001. Climate change and forest disturbances: climate change can affect forests by altering the frequency, intensity, duration, and timing of fire, drought, introduced species, insect and pathogen outbreaks, hurricanes, windstorms, ice storms, or landslides. *BioScience* 51(9): 723–734.

Deeming J. E., Brown J.K. 1975. Fuel models in the national fire-danger rating system. *Journal of forestry* 73(6):347–350.

Didan, K., Munoz, A. B., Solano, R., & Huete, A. (2015). MODIS vegetation index user's guide (MOD13 series). University of Arizona: Vegetation Index and Phenology Lab.

Ekayani, M., Nurrochmat, D.R., Darusman, D., 2016. The role of scientists in forest fire media discourse and its potential influence for policy-agenda setting in Indonesia *Forest Policy and Economics* 68:22–29.

FAO. 2020. FAO. 2020. Global Forest Resources Assessment 2020 – Key findings. Rome. URL: <https://www.fao.org/3/CA8753EN/CA8753EN.pdf> [erişim tarihi: 13-Şubat-2022].

Gai, C., Yuan, H., Weng, W., 2011. GIS-based forest fire risk assessment and mapping. 2011 Fourth International Joint Conference on Computational Sciences and Optimization. IEEE, 1240–1244.

Grattarola D., Alippi C., 2021. Graph neural networks in tensorflow and keras with spektral. *IEEE Computational Intelligence Magazine* 16(1):99-106

Gülçin, D., Deniz, B., 2020. Remote sensing and GIS-based forest fire risk zone mapping: The case of Manisa, Turkey. *Turkish Journal of Forestry* 21(1):15–24.

Jaafari, A., Gholami, D. M., Zenner, E. K., 2017. A Bayesian modeling of wildfire probability in the Zagros Mountains, Iran. *Ecological Informatics* 39:32–44.

Jin, G., Wang, Q., Zhu, C., Feng, Y., Huang, J., Hu, X., 2020. Urban Fire Situation Forecasting: Deep sequence learning with spatio-temporal dynamics. *Applied Soft Computing* 97:106730.

Karsai, I., Roland, B., Kamps, G., 2016. The effect of fire on an abstract forest ecosystem: An agent based study. *Ecological Complexity* 28:12–23.

Kuang, C., Li, Y., Zhu, S., & Li, J. (2013). Influence of different low air pressure on combustion characteristics of ethanol pool fires. *Procedia Engineering* 62:226-233.

Lierop, P., Lindquist, E., Sathyapala, S., Franceschini, G., 2015. Global forest area disturbance from fire, insect pests, diseases and severe weather events. *Forest Eco-*

logy and Management 352:78–88.

Martens, D., Backer, M. D., Haesen, R., Baesens, B., & Holvoet, T. (2006). Ants constructing rule-based classifiers. *Swarm intelligence in data mining* (pp. 21-43). Springer, Berlin, Heidelberg.

McArthur A.G., 1958. The preparation and use of fire danger tables. *Fire Weather Conference*, 15–17 Temmuz Melbourne, Avustralya

Mohajane, M., Costache, R., Karimi, F., Pham, Q. B., Essahlaoui, A., Nguyen, H., Laneve, G., Oudija, F., 2021. Application of remote sensing and machine learning algorithms for forest fire mapping in a Mediterranean area. *Ecological Indicators* 129:107869.

Mota, P. H. S., Rocha, S. J. S. D., Castro, N. L. M. D., Marcatti, G. E., França, L. C. J., Schettini, B. L. S., Villanova, P. H., Santos, H. T. D., Santos, A. R. D., 2019. Forest fire hazard zoning in Mato Grosso State, Brazil. *Land use policy* 88:104206.

OGM., 2021. *Yangın sayıları teknik raporları (iç dağıtım)* [sayı:E-41170819-622.03-706908]

URL-1: National Geodetic Survey 2016. World Geodetic System. URL: https://en.wikipedia.org/wiki/World_Geodetic_System [erişim tarihi: 01-Ocak-2022].

URL-2: 31.10.1985 tarih ve 3234 sayılı Orman Genel Müdürlüğü Teşkilat ve Görevleri Hakkında Kanun Hükümünde Kararnamenin Değiştirilerek Kabulü Hakkında Kanun. URL: <https://www.ogm.gov.tr/tr/e-kutuphane-sitesi/mevzuat-sitesi/> [erişim tarihi: 01-Ocak-2022].

URL-3: OGM Resmi İstatistikleri / Orman Alanları 2019 ve Yanan Alanlar 2019. URL: <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler> [erişim tarihi: 13-Şubat-2022].

URL-4: NASA Earthdata 2022. URL: <https://search.earthdata.nasa.gov/search> [erişim tarihi: 13-Şubat-2022].

URL-5: OGM Resmi İstatistikleri / Orman Alanları 2020 ve Yanan Alanlar 2020. URL: <https://www.ogm.gov.tr/tr/e-kutuphane/resmi-istatistikler> [erişim tarihi: 13-Şubat-2022].

URL-6: Geospatial Data Abstraction Library (GDAL) 2022. URL: <https://gdal.org/> [erişim tarihi: 13-Şubat-2022].

URL-7: Quantum Geographic Information System (QGIS) 2022. URL: <https://www.qgis.org/tr/site/> [erişim tarihi: 13-Şubat-2022].

URL-8: World Geodetic System (WGS84) 2021. URL: <https://gisgeography.com/wgs84-world-geodetic-system> [erişim tarihi: 13-Şubat-2022].

URL-9: National Aeronautics and Space Administration 2022. URL: <https://www.nasa.gov> [erişim tarihi: 13-Şubat-2022].

URL-10: OYAT araştırma sonuçları ve örnek resimler

-
2022. URL: <https://github.com/mfidanboy/orman-yangini> [erişim tarihi: 13-Şubat-2022].
- Prasetyo, L. B., Dharmawan, A. H., Nasdian, F. T., Ramdhoni, S., 2016. Historical forest fire occurrence analysis in Jambi Province during the period of 2000–2015: its distribution & land cover trajectories. *Procedia Environmental Sciences* 33:450–459.
- Qin, C. Z., Zhan, L. J., & Zhu, A. X. (2014). How to apply the geospatial data abstraction library (GDAL) properly to parallel geospatial raster I/O?. *Transactions in GIS*, 18(6):950-957.
- Román M.O., Wang Z., Shrestha R., Yao T., Kalb V., 2019. *Black marble user guide version 1.0*. NASA: Washington, DC, USA.
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-net: Convolutional networks for biomedical image segmentation. International Conference on Medical image computing and computer-assisted intervention. *Springer*, 234–241.
- Sulla-Menashe, D., & Friedl, M. A. (2018). User guide to collection 6 MODIS land cover (MCD12Q1 and MCD12C1) product. *USGS: Reston, VA, USA*, 1, 18.
- Tuyen, T. T., Jaafari, A., Yen, H. P. H., Nguyen-Thoi, T., Phong, T. V., Nguyen, H. D., Le, H. V., Phuong, T. T. M., Nguyen, S. H., Prakash, I., Pham, B. T., 2021. Mapping forest fire susceptibility using spatially explicit ensemble models based on the locally weighted learning algorithm. *Ecological Informatics* 63: 101292.
- Van Wagner C.E., Forest P., ark., 1987. Development and structure of the Canadian forest fireweather index system. *Can. For. Serv., Forestry Tech. Rep. Citeseer*.
- Yin, H., Kong, F., Li, X., 2004. RS and GIS-based forest fire risk zone mapping in da hinggao mountains. *Chinese geographical science* 14(3):251–257.
- Yoram J.K., Herring D.D., Ranson K.J., Collatz G.J., 1998. Earth Observing System AM1 mission to earth. *IEEE Transactions on Geoscience and Remote Sensing* 36(4):1045–1055.
- You, W., Lin, L., Wu, L., Ji, Z., Yu, J., Zhu, J., Fan, Y., He, D., 2017. Geographical information system-based forest fire risk assessment integrating national forest inventory data and analysis of its spatiotemporal variability. *Ecological Indicators* 77:176–184.
- Zheng, Z., Gao, Y., Yang, Q., Zou, B., Xu, Y., Chen, Y., Yang, S., Wang, Y., Wang, Z., 2020. Predicting forest fire risk based on mining rules with ant-miner algorithm in cloud-rich areas. *Ecological Indicators* 118: 106772.