

T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
COĞRAFYA ANABİLİM DALI

TÜRKİYE'DEKİ DEPREMLERİN BÜYÜKLÜK TAHMİNİNDE
KARAR AĞAÇLARI YÖNTEMİNİN UYGULANMASI

YÜKSEK LİSANS TEZİ

İSMAHAN ERMİŞ

BALIKESİR, 2025

**T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
COĞRAFYA ANABİLİM DALI**

**TÜRKİYE'DEKİ DEPREMLERİN BÜYÜKLÜK TAHMİNİNDE
KARAR AĞAÇLARI YÖNTEMİNİN UYGULANMASI**

YÜKSEK LİSANS TEZİ

İSMAHAN ERMİŞ

TEZ DANIŞMANI

PROF. DR. İSA CÜREBAL

BALIKESİR, 2025

T.C.
BALIKESİR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

TEZ ONAYI

Enstitümüzün Coğrafya Anabilim Dalı'nda 202312515001 numaralı İsmahan ERMİŞ'in hazırladığı "Türkiye'deki Depremlerin Büyüklük Tahmininde Karar Ağaçları Yönteminin Uygulanması" konulu YÜKSEK LİSANS tezi ile ilgili TEZ SAVUNMA SINAVI, Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliği uyarınca 30/06/2025 tarihinde yapılmış, sorulan sorulara alınan cevaplar sonunda tezin onayına OY BİRLİĞİ ile karar verilmiştir.

Üye (Başkan) Prof. Dr. Abdullah SOYKAN

İmza

Üye (Danışman) Prof. Dr. İsa CÜREBAL

İmza

Üye Prof. Dr. A. Evren ERGİNAL

İmza

Enstitü Onayı

ETİK BEYAN

Balıkesir Üniversitesi Sosyal Bilimler Enstitüsü Tez Yazım Kuralları'na uygun olarak hazırladığım bu tez çalışmasında;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmasında yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde ve ortaya çıkan sonuçlarda herhangi bir değişiklik yapmadığımı ve
- Bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

07 / 03 / 2025

İmza

İsmahan ERMİŞ

ÖNSÖZ

Depremler doğa olayları arasında en büyük yıkımlara neden olan afetlerdendir. Türkiye, aktif fay hatları üzerinde yer almasından dolayı tarih boyunca birçok yıkıcı depremle karşı karşıya kalmış ve bu durum sismolojik çalışmaların önemini artırmıştır. Depremlerin büyüklüğünü önceden tahmin etmek olası zararları en aza indirebilmek açısından büyük önem taşımaktadır. İlgili çalışmada karar ağaçları yöntemi kullanılarak Türkiye'deki depremlerin enlem, boylam ve derinlik bilgilerine bakılarak olası magnitüd (X_m) değeri tahmini yapılmış ve bu yöntemin etkinliği değerlendirilmiştir.

Çalışmanın her aşamasında değerli katkılarıyla yolumu aydınlatan bilimsel düşünceye olan bağlılığı ve rehberliğiyle bana ilham veren danışmanım **Prof. Dr. İsa CÜREBAL**'a en derin şükranlarımı sunarım. Kendisi akademik yolculuğum boyunca yalnızca bir danışman değil aynı zamanda bana ilham verici bir rehber olmuştur.

Beni meslektaş olarak görüp ilk kıvılcımı yakarak beni bilimsel araştırmaların heyecanıyla buluşturan **merhum Doç. Dr. Doğan KALAFAT**'ı saygı ve rahmetle anıyorum. Onun azmi, çalışkanlığı ve deprem bilimine olan tutkusu, bu alandaki ilerlememin en büyük motivasyon kaynaklarından biri olmuştur.

Her zaman sonsuz desteğini hissettiğim **Öğr. Gör. Dr. Ümit SARP**'a teşekkür ederim. Bilgisi, anlayışı ve yol göstericiliğiyle bana her zaman güven veren bir akademisyen olmuştur.

Ayrıca her daim kapılarını bana açık tutan ve akademik gelişimime katkı sunan **Balıkesir Üniversitesi Coğrafya Anabilim Dalı'nın kıymetli öğretim üyelerinden Prof. Dr. Abdullah SOYKAN, Prof. Dr. Alattin KIZILÇAOĞLU**'na ve **Pamukkale Üniversitesi İktisat Teorisi Anabilim Dalı Arş. Gör. Dr. Cemal ÖZTÜRK** 'e içten teşekkürlerimi sunarım.

Hayatım boyunca beni koşulsuz seven, her anımda yanımda olan, sabırları ve sevgileriyle beni bugünlere getiren canım **annem Meryem ERMİŞ** ve **babam Halil ERMİŞ**'e minnettarım. Onların varlığı, bana güç ve ilham vermeye devam edecek.

Tezin deprem tahminleri konusunda literatüre katkı sağlamasını ve ilerleyen çalışmalara ışık tutmasını temenni ederim.

BALIKESİR, 2025

İSMAHAN ERMİŞ

ÖZET

TÜRKİYE'DEKİ DEPREMLERİN BÜYÜKLÜK TAHMİNİNDE KARAR AĞAÇLARI YÖNTEMİNİN UYGULANMASI

ERMİŞ, İsmahan

Yüksek Lisans, Coğrafya Anabilim Dalı

Tez Danışmanı: Prof. Dr. İsa CÜREBAL

2025, 42 Sayfa

Türkiye'de gelecekte meydana gelebilecek depremlerin büyüklüğünü tahmin etmek amacıyla karar ağaçları yöntemi kullanılmıştır. Yüksek sismik risk taşıyan bölgelerde, enlem, boylam ve derinlik verileri temel alınarak magnitüd tahmini yapılmıştır. Çalışmada, Boğaziçi Üniversitesi Kandilli Rasathanesi'nin 1900-2024 dönemine ait verileri değerlendirilmiş ve C4.5 karar ağacı algoritması ile bir model oluşturulmuştur. 3.0 ile 8.0 arasındaki depremleri kapsayan veri seti, %80 eğitim ve %20 test olarak ayrılmıştır.

Model, %88 doğruluk oranıyla genelleme yeteneği göstermiş olsa da, 6.0 ve üzeri depremleri tahmin etmede zorlanmıştır. Sınıf dengesizliği nedeniyle büyük magnitüdü olayların öngörüsünde başarı düşerken, küçük ve orta büyüklükteki depremlerin tahmini daha isabetli olmuştur. Derinlik ile büyüklük arasındaki ilişki Chi-Square testi ($\chi^2=5674.81$, $p=0.0$) ile incelenmiş ve istatistiksel olarak anlamlı bulunmuştur. Özellikle 0-30 km aralığında küçük ve orta büyüklükte depremler yoğunlaşırken, büyük depremlerin %92'sinin aynı derinliklerde gerçekleştiği belirlenmiştir.

Coğrafi dağılım analizleri, modelin tahminlerinin Kuzey Anadolu Fay Hattı ve Ege Graben Sistemi gibi aktif sismik bölgelerle uyumlu olduğunu göstermektedir. Karar ağaçlarının şeffaf ve yorumlanabilir bir model sunmasına rağmen, nadir büyük depremlerin öngörülmesindeki sınırlılıklar ortaya çıkmıştır. Gelecek araştırmalar için derin öğrenme tekniklerinin entegrasyonu, jeolojik ve tektonik parametrelerin modele

eklenmesi ve bölgesel tahmin merkezlerinin kurulması önerilmektedir. Bu sayede, deprem tahmininde daha hassas ve güvenilir sonuçlara ulařılması hedeflenmektedir. Ayrıca, farklı makine öğrenmesi algoritmalarının karşılaştırılması, tahmin doğruluğunu artırmak adına önemli bir katkı sağlayabilir.

Anahtar Kelimeler: Karar Ağaçları, Deprem, Yapay Zekâ, Türkiye, Makine Öğrenimi.

ABSTRACT

APPLICATION OF DECISION TREES (DTs) METHOD FOR MAGNITUDE PREDICTION OF EARTHQUAKES IN TÜRKİYE

ERMİŞ, İsmahan

Master Thesis, Department of Geography

Advisor: Prof. İsa CÜREBAL

2025, 42 Pages

The applicability of decision tree methods for predicting the magnitude of future earthquakes in Turkey has been investigated. Given the country's high seismic risk, latitude, longitude, and depth data were utilized to estimate earthquake magnitudes. This study employed earthquake records from Boğaziçi University Kandilli Observatory, covering the period from 1900 to 2024. A prediction model was developed using the C4.5 decision tree algorithm. The dataset, consisting of earthquakes ranging from magnitude 3.0 to 8.0, was divided into 80% training and 20% testing data.

The model demonstrated a generalization capability with an accuracy of 88%; however, it struggled to predict earthquakes with magnitudes of 6.0 and above due to class imbalance. While predictions for small and moderate earthquakes were more accurate, performance declined for large-magnitude events. The relationship between depth and magnitude was examined using the Chi-Square test ($\chi^2=5674.81$, $p=0.0$), confirming a statistically significant correlation. Shallow-depth earthquakes (0-30 km) were found to be more frequent in lower magnitudes, whereas 92% of large earthquakes occurred within the same depth range.

Geospatial distribution analyses indicated that the model's predictions aligned with seismically active zones such as the North Anatolian Fault and the Aegean Graben System. Although decision trees provide a transparent and interpretable approach, limitations in predicting rare large earthquakes remain a challenge. Future research should integrate deep learning techniques, incorporate geological and tectonic

parameters, and establish regional prediction centers to enhance the accuracy and reliability of earthquake forecasting.

Keywords: Decision Trees (DTs), Earthquake, Artificial Intelligence, Türkiye, Machine Learning.

İÇİNDEKİLER

Sayfa

TEZ ONAYI.....	i
ETİK BEYAN.....	ii
ÖNSÖZ	iii
ÖZET.....	v
ABSTRACT.....	vii
KISALTMALAR LİSTESİ.....	xi
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ.....	xiii
1. GİRİŞ.....	1
1.1. Araştırmanın Problemi	5
1.2. Araştırmanın Amacı	5
1.3. Araştırmanın Önemi	6
1.4. Araştırmanın Varsayımları	6
1.5. Araştırmanın Sınırlılıkları	7
1.6. Tanımlar	7
2. İLGİLİ ALANYAZIN.....	9
2.1. Kuramsal Çerçeve	9
2.2. İlgili Araştırmalar	9
3. YÖNTEM.....	14
3.1. Araştırmanın Konusu	14
3.2. Evren ve Örneklem.....	14
3.3. Veri Toplama Araçları ve Teknikleri	14
3.4. Verilerin Analizi.....	15
4. BULGULAR VE YORUMLAR.....	19
4.1. Geçmiş deprem verilerinin analiziyle Türkiye'de gelecekte meydana gelebilecek depremlerin büyüklükleri ve dağılımları tahmin edilebilir mi?	19

4.2. Karar ağacı modeli, Türkiye’de gelecekte yaşanabilecek olan depremleri ne düzeyde doğru tahmin edebilir?	21
4.3. Karar ağacı modelinin deprem magnitüdü tahmini gerçekleştirirken başlıca avantajları ve sınırlılıkları nelerdir?	21
4.4. Türkiye'deki depremlerin büyüklükleri ile derinlikleri arasında istatistiksel bir ilişki veya benzerlik var mıdır?	23
4.5. Türkiye'deki depremlerin büyüklükleri ile oluş tarihi arasında bir korelasyon var mıdır?	28
4.6. Son yüzyılda Türkiye'de meydana gelen depremler nasıl bir dağılım göstermiştir ve bu depremler hangi bölgelerde yoğunlaşmıştır?	28
5. SONUÇ VE ÖNERİLER.....	34
5.1. Sonuçlar.....	34
5.2. Öneriler.....	36
KAYNAKÇA	38

KISALTMALAR LİSTESİ

DTs: Decision Trees (Karar Ağaçları)

X_m: En büyük magnitüd değeri

TABLÖLAR LİSTESİ

Sayfa

<u>Tablo 1.</u> Literatür Tarama Sonucu Tablosu.....	9
<u>Tablo 2.</u> Dağılım ve Sınıflandırma Tablosu	19
<u>Tablo 3.</u> Doğruluk – Ağırlıklı Ortalama ve F1 Skor Tablosu	21
<u>Tablo 4.</u> Chi-Square Test Sonuçları Tablosu	25

ŞEKİLLER LİSTESİ

Sayfa

<u>Sekil 1.</u> Türkiye Levha Sınırları.....	1
<u>Sekil 2.</u> Türkiye'deki 7.0 ve Üzeri Büyüklükteki Depremlerin Dağılımı (1900-2023) (Python ile görselleştirilmiştir)	2
<u>Sekil 3.</u> Türkiye'deki 7.0 xM ve Üzeri Büyüklükteki Depremlerin Dağılımı (1900-2023)	3
<u>Sekil 4.</u> Metodoloji Akış Diyagramı.....	15
<u>Sekil 5.</u> Karar Ağaçları (DTs) Yöntemi Akış Şeması.....	16
<u>Sekil 6.</u> Hata Matrisi	20
<u>Sekil 7.</u> Karar Ağacı Modeli Düğümünün Bir Kısmı.....	22
<u>Sekil 8.</u> Derinlik - Magnitüd İlişki Grafiği	23
<u>Sekil 9.</u> 1900-2024 Yılları Arasında Gerçekleşmiş Deprem Sayısı (01.01.1900 – 31.12.2024)	24
<u>Sekil 10.</u> 1900-2024 Yılları Arasında Gerçekleşmiş Depremlerin Yüzdeleri Oranları (01.01.1900 – 31.12.2024)	24
<u>Sekil 11.</u> Derinlik Dağılımı Frekans Grafiği.....	25
<u>Sekil 12.</u> Derinlik – Magnitüd İlişkisi	26
<u>Sekil 13.</u> Yüzdeleri Dağılım Grafiği	27
<u>Sekil 14.</u> Karar Ağacı Modelinin Tahmin Ettiği Olası xM Dağılımı	18
<u>Sekil 15.</u> Gerçekleşmiş 1900- 2024 Yılı 6.0 xM ve üstü Deprem Haritası	39
<u>Sekil 16.</u> Gerçekleşmiş 1900- 2024 Yılı 5.0 - 5.9 xM ve üstü Deprem Haritası	30
<u>Sekil 17.</u> Gerçekleşmiş 1900- 2024 Yılı ve Karar Ağacı Modelinin Tahmin Ettiği Olası 4.0 – 4.9 xM Dağılımı.....	31
<u>Sekil 18.</u> Gerçekleşmiş 1900- 2024 Yılı ve Karar Ağacı Modelinin Tahmin Ettiği Olası 5.0 – 5.9 xM Dağılımı.....	32

1. GİRİŞ

Depremler, dünya çapında ciddi can ve mal kayıplarına neden olan en yıkıcı doğal afetler arasında sayılmaktadır. Deprem tehlikesinin öngörülmesi bu afetlerin etkilerinin azaltılması ve olası risklerin önlenmesi açısından büyük bir önem taşımaktadır.

Depremler; aletsel, tarihsel ve tarih öncesi dönemlere ait farklı verilerle incelenebilmektedir. Tarihsel depremlere ilişkin bilgiler çeşitli sismik kataloglardan derlenmektedir. Ancak bu katalogların kapsadığı süre arttıkça deprem kayıtlarının doğruluğu ve güvenilirliği azalmaktadır. Buna karşılık son yıllarda gelişen paleosismolojik araştırmalar sayesinde tarih öncesi depremler hakkında elde edilen veriler daha mutlak ve güvenilir şekilde tespit edilebilmektedir. Tarihsel ve tarih öncesi depremlerin ayrıntılı incelenmesi, bir bölgedeki depremlerin tekrarlanma aralıklarının belirlenmesine, aktif fayların tespit edilmesine, fay segmentlerinin ayrıştırılmasına ve her bir segment için deprem modellerinin oluşturulmasına olanak tanımaktadır (Demirtaş, R. and Yılmaz, R., 1996; Özmen, B., 2012; Akkoyunlu, M. F., 2021).



Şekil 1. Türkiye Levha Sınırları (Gordon, R. G., 1998; Westaway, R. O. B., 1994)

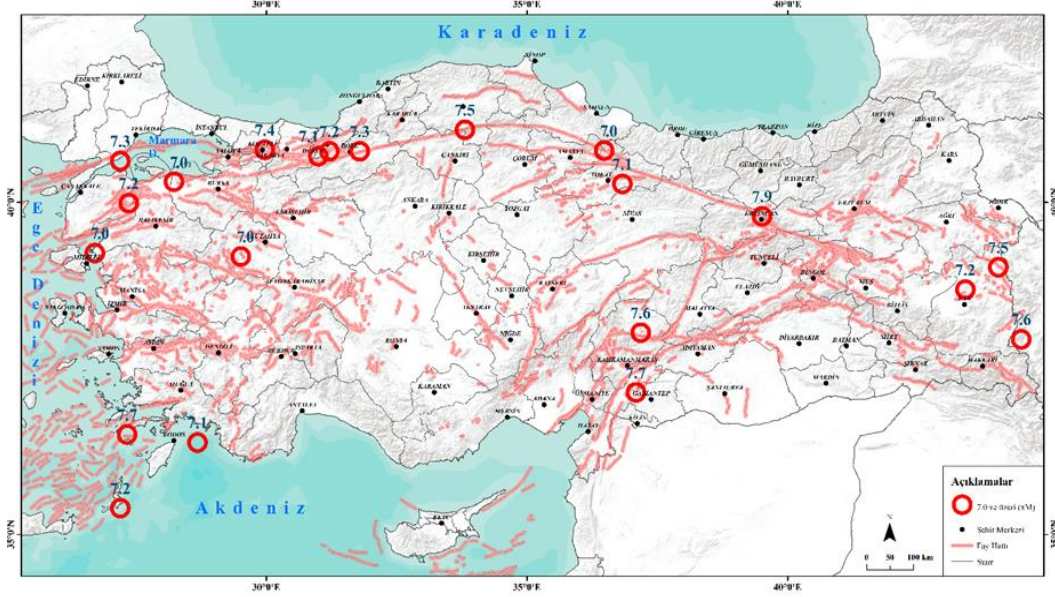
Türkiye'nin büyük bir kısmı Anadolu Levhası (Şekil 1) adı verilen bir mikrolevha üzerinde yer almaktadır. Anadolu Levhası, Arap ve Avrasya levhalarının gerilim hattında bulunmaktadır. Anadolu Levhası'na sınır komşusu olan bir diğer levha ise Afrika Levhası'dır. Bu nedenle Türkiye'nin üzerinde bulunduğu mikrolevha, üç tektonik levhanın etkileşim noktasında yer almaktadır (Khurshid, F. and Günal, A. Y., 2024). Türkiye, Alp-Himalaya dağ kuşağı içerisinde yer alması nedeniyle aktif tektonik hareketliliğe sahip bir ülkedir. Jeolojik yapısı incelendiğinde ülkenin temel iskeletini oluşturan eski sert kayalardan meydana gelen masifler, kıvrımlı eski dağ silsileleri, daha genç kıvrımlı dağ sistemleri, büyük fay hatları, çöküntü ve graben alanları ile aktif fay zonları olmak üzere altı ana bölüme ayrıldığı görülmektedir (Ketin, İ., 1968). Özellikle Kuzey Anadolu Fay Hattı ülkenin en önemli tektonik yapılarından biri olup tarih boyunca yıkıcı depremlere neden olmuştur. Türkiye'nin tektonik yapısı büyük ölçüde bu fay hatları ve jeolojik süreçler tarafından şekillendirilmiş olup ülke genelinde yüksek deprem riski oluşturmaktadır (Ketin, İ., 1968).



Şekil 2. Türkiye'deki 7.0 ve Üzeri Büyüklükteki Depremlerin Dağılımı (1900-2023) (Python ile görselleştirilmiştir)

Türkiye, aktif fay hatları üzerinde yer aldığı için yüksek derecede deprem riski taşıyan ülkeler arasında bulunmaktadır. Türkiye'deki deprem bölgeleri, ülkenin tektonik yapısı ve aktif fay hatları ile doğrudan ilişkilidir. Kuzey Anadolu Fay Hattı, ülkenin en aktif ve riskli sismik kuşağı olup Erzincan, Düzce ve Adapazarı gibi yerleşim alanlarında büyük depremlere neden olmuştur. Batı Anadolu'da Ege Graben Sistemi'ne bağlı olarak özellikle İzmir ve çevresi yüksek deprem riski taşımaktadır.

Doğu Anadolu Fay Hattı ise Van ve çevresinde önemli sismik aktivitelere yol açmaktadır. İç Anadolu Bölgesi'nde ise Tuz Gölü Fay Hattı ve çevresi belirgin sismik hareketlilik sergilemektedir. Bu bölgelerde meydana gelen depremlerin büyüklüğü ve sıklığı, bölgesel jeolojik ve tektonik faktörlerin etkileşimiyle şekillenmekte olup Türkiye'nin aktif deprem kuşağındaki hassas konumunu ortaya koymaktadır (Özdoğan, S., 1993; Kalafat, D., vd., 2007; Kalafat, D., Kekovalı, K., Akkoyunlu, F. and Ögütçü, Z., 2014).



Şekil 3. Türkiye'deki 7.0 xM ve Üzeri Büyüklükteki Depremlerin Dağılımı (1900-2023)

Türkiye, üç büyük tektonik plakanın (Avrasya, Arap ve Afrika levhaları) etkileşim noktasında yer alması nedeniyle aktif bir tektonik yapıya sahip olması nedeniyle tektonik hareketler ülke genelinde sık sık 7.0 ve üzeri depremlerin meydana gelmesine yol açmaktadır (Şekil 2, Şekil 3). Bilhassa Kuzey Anadolu Fayı (KAF), Doğu Anadolu Fayı (DAF) ve Batı Anadolu'daki gerilme rejimi (BAF) Türkiye'deki depremlerin en önemli kaynakları arasındadır. Dinamik yapı sismik aktivitenin karmaşıklığını artırırken depremlerin zamanlamasını ve etkilerini tahmin etmeyi de zorlaştırmaktadır. Ancak son yıllarda büyük veri analitiği ve yapay zekâ teknikleri bu karmaşık süreçleri daha iyi anlamak ve deprem risklerini değerlendirmek için güçlü araçlar haline gelmiştir. Makine öğrenimi yöntemleri, depremlerin oluşum dinamiklerini analiz etmek ve gelecekteki sismik hareketleri öngörmek için giderek daha fazla kullanılmaktadır.

Son yıllarda makine öğrenimi yöntemlerinin deprem büyüklüğü tahmininde kullanımı yaygınlaşmış olup bu alanda umut vadeden sonuçlar elde edilmektedir. Deprem tahmini ve analizi için farklı makine öğrenimi yöntemleri kullanılmaktadır. Makine öğrenimi algoritmaları arasında yer alan Destek Vektör Makineleri (SVM), Karar Ağaçları (DT), Rastgele Ormanlar (RF) ve Sinir Ağları (ANN) tahmin modellerinin doğruluğunu artırmak amacıyla yaygın şekilde tercih edilmektedir (Sikder and Munakata, 2009). Örneğin, Destek Vektör Makineleri (SVM) (Jiang vd., 2009), Rastgele Orman Algoritması (RFA) (Han vd., 2020), K-En Yakın Komşu (KNN) (Li & Kang, 2009), Uzun Kısa Vadeli Bellek (LSTM) (Cai vd., 2019) ve Karar Ağaçları (DT) (Bakun vd., 2011; Somodevilla vd., 2012; Özbaş, 2013; Fong, 2013; Karbassi vd., 2014; Ardakani ve Kohestani, 2015; Asencio-Cortés vd., 2016; Asencio-Cortes vd., 2017; Cassel, 2018; Ahamed ve Daub, 2019; Mignan ve Broccardo, 2020; Zhang, 2021; Xiong vd., 2021; Demertzis vd., 2022; Ridzwan ve Yusoff, 2023; Demirelli vd., 2023; Ahmed vd., 2024; Ermiş ve Cürebal, 2024) deprem tahmininde başarıyla uygulanmıştır. Bu çalışmada diğer algoritmalara oranda daha yüksek doğruluk ve güvenilirlik seviyesinde tahminler sunduğu düşünülen karar ağaçları yöntemi tercih edilmiştir.

Makine öğrenimi alanında önemli bir teknik olan karar ağaçları yöntemi, deprem büyüklüklerini öngörmek ve sismik olayların etkilerini analiz etmek için yaygın olarak tercih edilmektedir (Goswami vd., 2018; Otari and Kulkarni, 2012). Özellikle C4.5 algoritması, deprem tahmininde etkili faktörleri belirlemek ve çevresel değişkenler ile sismik verilerden yola çıkarak karar kuralları oluşturmak için umut vadetmektedir (Ardakani and Kohestani, 2015; Karbassi vd., 2014). Tarihsel deprem verilerinin analiziyle önemli tahmin edici faktörleri belirleyen karar ağaçları, bilgi teorisi kriterlerine dayalı olarak öznelikleri sıralayarak tahmin modellerinin doğruluğunu artırmaktadır (Ardakani and Kohestani, 2015).

Bu çalışmada ise Türkiye'deki depremlerin büyüklük tahmini için karar ağaçları (Decision Trees) yönteminin uygulanabilirliğini ele alarak deprem riskiyle mücadelede bilimsel bir katkı sunmayı amaçlamaktadır.

1.1. Araştırmanın Problemi

Türkiye, aktif fay hatları üzerinde konumlandığı için sık sık depremlerle karşılaşan bir ülkedir ve bu depremler, ekonomik ve toplumsal açıdan ciddi kayıplara neden olmaktadır (Erdik, M., 2013). Depremlerin büyüklüğünü tahmin etmek hem deprem tehlikesinin anlaşılması hem de bu afetlere yönelik önlemlerin geliştirilmesi açısından büyük önem taşımaktadır (Korkmaz, K. A., 2009). Ancak mevcut tahmin yöntemleri sınırlı doğruluk oranları (Ghaedi, K. and Ibrahim, Z., 2017), kullanılan algoritmaların kısıtlılığı (Etiope, G., Calcara, M. and Quattrocchi, F., 1997) ve analiz süreçlerinin karmaşıklığı ve zaman alıcılığı nedeniyle etkin bir şekilde sonuç vermemektedir (Al Banna, vd., 2020). Bu da daha etkili ve doğruluğu yüksek tahmin yöntemlerini bulma yönelme ihtiyacını artırmaktadır. Bu bağlamda, gelişmiş makine öğrenim yöntemleri ve yenilikçi algoritmaların kullanımı büyük bir önem taşımaktadır.

1.2. Araştırmanın Amacı

Çalışmanın temel amacı Türkiye'de gelecekte meydana gelebilecek olan depremlerin büyüklüğünü tahmin edebilmek için enlem, boylam ve derinlik verileriyle magnitüd tahmini gerçekleştirip, karar ağaçları (Decision Trees) yönteminin etkinliğini ve uygulanabilirliğini araştırmaktır. Bu doğrultuda deprem magnitüdünün tahmin edilmesinde makine öğrenimi tekniklerinin sağladığı veri odaklı yaklaşım kullanılarak doğru ve daha güvenilir tahminler yapılması hedeflenmektedir. Karar ağaçları yöntemi, bu tahminlerin gerçekleştirilmesinde araç olarak kullanılmıştır ve magnitüd tahminlerinin doğruluğu, güvenilirliği ve tutarlılık oranları detaylı bir şekilde incelenmiştir. Modelin tahmin yeteneği, gerçek deprem verileriyle karşılaştırılarak değerlendirilip magnitüd tahminlerinin ne kadar tutarlı ve doğru olduğu analiz edilmiştir.

Bu kapsamda çalışmanın araştırma soruları şu şekilde belirlenmiştir:

Ana Soru: Geçmiş deprem verilerinin analiziyle Türkiye'de gelecekte meydana gelebilecek depremlerin büyüklükleri ve dağılımları tahmin edilebilir mi?

Alt Soru 1: Karar ağacı modeli, Türkiye'de gelecekte yaşanabilecek olan depremleri ne düzeyde doğru tahmin edebilir?

Alt Soru 2: Karar ağacı modelinin deprem magnitüdü tahmini gerçekleştirirken başlıca avantajları ve sınırlılıkları nelerdir?

Alt Soru 3: Türkiye'deki depremlerin büyüklükleri ile derinlikleri arasında istatistiksel bir ilişki veya benzerlik var mıdır?

Alt Soru 4: Türkiye'deki depremlerin büyüklükleri ile oluş tarihi arasında bir korelasyon var mıdır?

Alt Soru 5: Son yüzyılda Türkiye'de meydana gelen depremler nasıl bir dağılım göstermiştir ve bu depremler hangi bölgelerde yoğunlaşmıştır?

1.3. Araştırmanın Önemi

İlgili çalışmanın önemi Türkiye gibi deprem riski taşıyan bir bölgede deprem büyüklüğünün doğru ve güvenilir bir şekilde tahmin edilmesinin afet yönetimi ve çevre düzenlemesi açısından kritik bir rol oynamasında yatmaktadır. Deprem büyüklüğü tahminlerinin doğruluğu, olası zararın azaltılması ve hazırlık süreçlerinin etkinliği bakımından büyük bir öneme sahiptir. Çalışmada karar ağaçları (Decision Trees) yöntemini kullanarak deprem tahminlerini daha hızlı, doğru ve uygulanabilir hale getirmek hedeflenmektedir. Ayrıca makine öğrenimi tekniklerinin özellikle büyük veri setleri ve karmaşık değişkenler söz konusu olduğunda sunduğu veri odaklı yaklaşım, geleneksel deprem tahmin yöntemlerine kıyasla daha verimli sonuçlar elde edilmesine olanak tanıyabilir. 2025 yılı itibarıyla yalnızca karar ağaçları yöntemiyle tüm Türkiye'yi kapsayan bir çalışma yapılmamış olması nedeni ile bu araştırma Türkiye'ye özgü olup deprem tahmin sistemlerine önemli bir katkı sağlama potansiyeline sahiptir. Ayrıca bu çalışma olası fay hatlarını belirleyebilme ve deprem aktivitesinin yoğun olduğu bölgelere odaklanabilme imkânı sağlamaktadır. Türkiye'ye özgü olarak yapılan çalışmada bölgesel deprem riski analizlerinin gerçekleştirilmesi ve afet yönetimi stratejilerinin daha etkin bir biçimde belirlenmesi adına büyük bir öneme sahiptir.

1.4. Araştırmanın Varsayımları

Araştırmada veri kaynağı olan Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü (KRDAE) 'nün Türkiye'deki depremlere ait enlem,

boylam ve derinlik verilerinin doğru ve güvenilir şekilde kaydedildiği varsayılmaktadır. Ayrıca karar ağaçları (Decision Trees) yönteminin deprem büyüklüğünü tahmin etmek için kabul gören ve gerçekleştirilebilir bir model sunduğu kabul edilmektedir. Çalışma kapsamında kullanılan deprem verilerinin, araştırma sürecindeki tüm değişkenler açısından yeterli ve temsil edici olduğu öngörülmektedir. Makine öğrenimi tekniklerinin, deprem şiddetini tahmin etmede tatmin edici bir doğruluk düzeyi sunarak geçerli sonuçlara ulaşılmasını mümkün kılar ve modelin sonuçlarının mevcut deprem tahmin sistemleriyle tutarlı şekilde değerlendirilebileceği varsayılmaktadır.

1.5. Araştırmanın Sınırlılıkları

1900-2024 yılları arasında Türkiye sınırları içerisinde meydana gelen 3.0 magnitüd ve üzerindeki depremlerin büyüklüğünü tahmin etmek amacıyla enlem, boylam ve derinlik verilerinin kullanılması ve bu verilerle karar ağaçları (Decision Trees) yönteminin uygulanabilirliğinin incelenmesidir. Araştırma deprem büyüklüğü (magnitüd) tahminine yönelik olarak makine öğrenimi tekniklerinin kullanımını ele alacak ve karar ağaçları yönteminin doğruluğu, güvenilirliği ve tutarlılık oranları detaylı bir şekilde değerlendirilecektir. Çalışmanın bulguları, Türkiye'deki deprem tahmin sistemlerine katkı sağlamayı amaçlamakta olup yalnızca Türkiye'deki deprem verileri üzerinde yoğunlaşılacaktır. Diğer coğrafi bölgelerdeki deprem verileri bu tezin kapsamı dışında bırakılacaktır.

1.6. Tanımlar

Karar Ağacı (Decision Tree)

Karar ağacı, ardışık karar problemlerini belirsizlik altında grafiksel bir yapı ile modelleyen bir analiz aracıdır. Bu yapı, karar verme sürecindeki her adımı ve bu adımların potansiyel sonuçlarını görselleştirmek için kullanılır. Karar ağacında düğümler karar noktalarını, dallar ise bu kararların olası seçeneklerini temsil eder. Karar ağacındaki dallar, olasılıklarla ilişkilendirilir ve bu olasılıklar kullanılarak her bir olasılığın getireceği muhtemel değer hesaplanır. Bu sayede karar ağacı, tüm seçeneklerin ve olası sonuçların görsel bir haritasını sunarak en iyi kararı seçmek için sistematik bir yöntem sağlar (Chen, K. and Jarboe, K. P., 1980; Sethi, I. K. and

Chatterjee, B., 1980). Karar ağacı arama algoritmaları, problem çözüm sürecinde gereksiz dalların budanması ve arama alanının azaltılması için kullanılır. Bu algoritmalar, graf yapılarının belirli özelliklerini kontrol ederek uygun olmayan seçenekleri erken aşamalarda eler ve böylece çözüm arayışını hızlandırır (Ghahraman, D. E., Wong, A. K. C. and Au, T., 1980). Karar ağacı, belirsizlik içeren durumlarda karar verme süreçlerini düzenli bir biçimde incelemeye olanak tanıyan; seçenekler ile sonuçlar arasındaki bağlantıları görsel olarak ortaya koyan etkili bir yöntemdir. Bu yaklaşım, karmaşık sorunları sadeleştirerek daha anlaşılır hale getirirken olasılık ve beklenen değer hesapları yoluyla en uygun seçimin yapılmasına değerli katkılar sağlar.

2. İLGİLİ ALANYAZIN

2.1. Kuramsal Çerçeve

Çalışmanın literatür taramasında, "decision trees" (karar ağaçları), "earthquake" (deprem), "prediction", "estimation" (tahmin) gibi anahtar kelimeler kullanılarak çeşitli akademik kaynaklar ve literatür üzerinde kapsamlı bir araştırma gerçekleştirilmiştir.

2.2. İlgili Araştırmalar

Tablo 1. Literatür Tarama Sonucu Tablosu

Yıl	Yazarlar	Önemli Katkıları
2011	Bakun vd.	Üç farklı yöntemi birleştirerek sadece şiddet verilerine dayanarak bir depremin konumunu ve büyüklüğünü tahmin etmişlerdir.
2012	Somodevilla vd.	Sismik risk tahmini için karar ağaçlarını tanıtmışlardır.
2013	Özbaş	İstanbul'da deprem anında bina içindeki hasar ve blokajları tespit etmek için algılayıcı geliştirilmiştir.
2013	Fong	Deprem tahmini için zaman serilerinden karmaşık istatistiksel özellikleri otomatik olarak çıkararak uygun tahmin algoritmasını seçmiştir.
2014	Karbassi vd.	Betonarme binaların gelecekteki deprem senaryolarında alacağı hasarı tahmin edilmiştir.
2015	Ardakani ve Kohestani	Depremler nedeniyle toprak sıvılaşma potansiyelinin tahmin edilmiştir.
2016	Asencio-Cortés vd.	Deprem tahmininde kullanılan sismik göstergelerin doğruluğunu artırmak için bir metodoloji geliştirmişlerdir.
2017	Asencio-Cortes vd.	Beş ardışık veri seti üzerinde tahminler yapmışlardır.
2018	Cassel	Sismik veri yorumlamasında, özellikle yatak seçimi konusunda karar ağaçlarını uygulamıştır.
2019	Ahamed ve Daub	Sismik tehlike analizlerinde makine öğrenimi için karar ağaçlarını incelemişlerdir.
2020	Mignan ve Broccardo	Derin öğrenmeye eleştirilerde bulunmuş ve karar ağaçlarının açıklanabilirliğini vurgulamışlardır.
2021	Zhang	Random Forest gibi topluluk yöntemlerini teorik olarak incelemiştir.

Tablo 2- Devamı

2021	Xiong vd.	Deprem tahminleri için Inverse Boosting Pruning Trees (İBPT) yöntemini geliştirmişlerdir.
2022	Demertzis vd.	Sismik hasar tahmini için çeşitli makine öğrenimi algoritmalarını karşılaştırmalı olarak değerlendirmişlerdir.
2023	Ridzwan ve Yusoff	Karar ağaçlarının makine öğrenimindeki kullanımını kapsamlı bir şekilde gözden geçirmişlerdir.
2023	Demirelli vd.	Deprem tahminleri için makine öğrenmesi algoritmaları kullanarak bir veri seti oluşturmuşlardır.
2024	Ahmed vd.	Sismik verilerle modeller eğiterek deprem büyüklüklerini tahmin etmek için makine öğrenimini kullanmışlardır.
2024	Ermış ve Cürebal	Karar ağaçları yöntemini kullanarak İzmir, Türkiye için deprem magnitüd olasılığı tahmini yapmışlardır.

Bakun ve diğerleri (2011), yalnızca şiddet (intensity) verilerinden bir depremin konumunu ve büyüklüğünü tahmin etmek için kullanılan üç farklı yöntemi (Bakun ve Wentworth, Boxer, MEEP) açıklamıştır. Yöntemler genellikle farklı sonuçlar verdiği ve en iyi yöntemi seçmek zor olduğu için üç yöntemin hepsini birleştirerek tahmin yapmayı tercih etmiştir.

Somodevilla ve diğerleri (2012), sismik risk tahmini için karar ağaçlarını tanıtarak bu alanda makine öğrenimi (ML) uygulamalarının temelini atmışlardır. Deprem riski tahmini ve önlenmesine yönelik bir karar destek sistemi geliştirmişlerdir. Veri ambarı ve OLAP (Online Analytical Processing) işlemleri kullanılarak ayrıca veri madenciliği araçları (ilişki kuralları, karar ağaçları ve kümeleme gibi) ile depremle ilgili çeşitli parametreler (yer, yılın zamanı, büyüklük vb.) tahmin edilmiştir. Elde edilen analiz sonuçları farklı veri setleri arasında anlamlı ilişkilerin keşfedilmesini sağlamış ve yüksek deprenselliğe sahip bölgeler ile potansiyel yeni deprem bölgeleri tespit etmişlerdir.

Özbaş (2013), İstanbul'da olası bir depremde can kayıplarını azaltmak için bina içindeki yapısal ve yapısal olmayan elemanların durumunu izlemek amacıyla bir sistem geliştirmiştir. Kapalı devre kabloları, ultrasonik mesafe ölçerler ve kameralar kullanarak depreme eş zamanlı veri aktarımı sağlamış ve veriler çeşitli algoritmalarla analiz etmiştir.

Fong (2013), gerçek zamanlı deprem izleme için uygun bir otomatik tahmin modelinin geliştirmiştir ve veri serilerinin farklı özelliklerinin en iyi doğruluğu elde etmek için hangi tahmin algoritmalarıyla eşleştirileceğinin araştırıp Decision Tree algoritmasını önermiştir.

Karbassi vd. (2014), betonarme binaların gelecekteki deprem senaryolarında alacağı hasarı tahmin etmek için C4.5 karar ağacı algoritması kullanmışlardır. Binalar tek serbestlik dereceli sistemler olarak modellenmiş ve zaman tarihli doğrusal olmayan analizler ile hasar indeksleri oluşturmuşlardır.

Ardakani ve Kohestani (2015), depremler nedeniyle toprak sıvılaşma potansiyelinin tahmin edilmesinde C4.5 karar ağacı algoritmasının etkinliği incelemiştir. Cone Penetration Test (CPT) verilerini kullanarak toprak sıvılaşma potansiyelini tahmin etmeyi amaçlamışlardır.

Asencio-Cortés vd. (2016), deprem tahmininde kullanılan sismik göstergelerin doğruluğunu artırmak için bir metodoloji geliştirmişlerdir. Çeşitli makine öğrenme sınıflandırıcılarıyla literatürde önerilen göstergelerin doğruluklarını analiz etmişler ve bu göstergelerin daha iyi ayarlanması durumunda tahmin doğruluğunun artabileceğini göstermişlerdir.

Asencio-Cortes, G., vd. (2017), Tokyo'daki büyüklüğü 5.0'dan büyük depremler ve yedi günlük zaman aralığı göz önünde bulundurularak beş ardışık veri seti üzerinde tahminler yapmışlardır. Sonuçları ise dört tanınmış makine öğrenme algoritmasıyla karşılaştırmışlardır.

Cassel (2018), karar ağaçlarını özellikle yatak seçiminde sismik verilerin yorumlanmasında uygulamıştır. Çalışmada, "hangi sismik özellik hangi detayı en iyi şekilde aydınlatır" sorusunu yanıtlamak için kural tabanlı bir karar ağacı uygulaması geliştirmiştir. Ayrıca insanları yönlendirmek ve makine öğrenimi için uygun özellikleri seçmek amacıyla prototip bir web tabanlı sismik özellik-sismik fasiyes analizi veri tabanı oluşturmuştur. Prototip, iki sismik fasiyes (denizel kütle taşınımı birikimleri ve karst çözünmeleri) üzerinde test edilmiş ve ileride genişletilmek üzere bir başlangıç noktası sunmuştur.

Ahamed ve Daub (2019), yapay sinir ağları (ANN) ve rastgele ormanlar (RF) algoritmaları kullanılarak iki makine öğrenimi modeli geliştirmiştir. Bu modeller bir kırılmanın fay üzerindeki geometrik heterojenlikleri aşım aşamayacağını tahmin

etmeyi amaçlamıştır. 1600 dinamik kırılma simülasyonundan oluşan bir veri seti ile modeller eğitilmiş ardından 400 simülasyonluk test verileriyle doğrulanmıştır. Modeller kırılma yayılımını %81'in üzerinde doğrulukla tahmin etmeyi başarmıştır.

Mignan ve Broccardo (2020), karar ağacı (Decision Tree) gibi modellerin, yapay sinir ağları gibi daha karmaşık makine öğrenimi algoritmalarına kıyasla daha basit ve daha şeffaf bir şekilde deprem tahmini yapmak için nasıl kullanılabileceği tartışmışlardır.

Zhang (2021), karar ağaçlarının “böl ve yönet” stratejisiyle karmaşık problemleri daha küçük ve yönetilebilir parçalara ayırarak nasıl çözdüğünü açıklıyor ve bazı alanlardaki başarılarına değiniyor.

Xiong ve arkadaşları (2021), 6 ve üzeri büyüklükteki 1.371 deprem verisini kullanarak, uydu verileriyle kısa vadeli deprem tahmini için yeni bir makine öğrenimi yöntemi olan Inverse Boosting Pruning Trees (IBPT) geliştirmiştir.

Demertzis ve arkadaşları (2022), betonarme binaların sismik davranışını ve hasar durumunu tahmin etmek için farklı makine öğrenimi yöntemlerini karşılaştırmışlardır.

Ridzwan ve Yusoff (2023), 2017-2021 yılları arasında yayımlanan 31 makaleyi derleyerek deprem tahmini için kullanılan makine öğrenimi (ML) yöntemlerini kapsamlı bir şekilde incelemiştir. Çalışma farklı coğrafi bölgeleri ele alarak ML algoritmalarının deprem büyüklüğü, trendi ve meydana gelme olasılığını tahmin etmedeki performansını karşılaştırmıştır. Deprem büyüklüğü tahmini için Karar Ağaçları algoritmasında en yüksek tahmin doğruluğunu elde etmişlerdir.

Demirelli vd. (2023), deprem tahminleri için jeolojik, jeodezik ve deprem verilerinden oluşan bir veri seti oluşturulmuş. Bu veri seti dört farklı makine öğrenmesi algoritmasıyla (rastgele orman, ekstrem gradyan artırma, karar ağacı ve k en yakın komşu regresyon) eğitilmiş ve test edilmiştir.

Ahmed ve arkadaşları (2024), sismik verileri kullanarak deprem büyüklüklerini tahmin etmek için ML modelleri eğitmişlerdir. Decision Tree, KNN, Random Forest, XG Boost, SVM gibi çeşitli algoritmalar kullanılmış ve verilerin ön işlenmesinde eksik değerler giderilip, özellikler ölçeklendirilmiştir.

Ermif ve Cürebal (2024), sadece karar ağaçları yöntemini kullanarak İzmir (Türkiye) için deprem büyüklüğü olasılığını hesaplamif ve bu veriyi coğrafi bilgi sistemleri (CBS) aracılığıyla haritaya aktarmiftır. Böylece coğrafya ve makine öğrenimi arasındaki multidisipliner bir çalışma gerçekleştirmiflerdir.

3. YÖNTEM

3.1. Araştırmanın Konusu

Türkiye sınırları içerisinde 1900–2024 yılları arasında meydana gelmiş olan 3.0 ve üzeri büyüklükteki depremlerin enlem, boylam ve odak derinliği verileri temel alınarak magnitüd (x_M) tahmin performansını ortaya koymayı amaçlayan çalışmada, karar ağaçları (Decision Trees) yöntemi esas alınmıştır . Söz konusu veriler, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü (KRDAE) tarafından derlenen sismik kataloglardan temin edilmiştir . Elde edilen veri seti üzerinde Karar Ağaçları Algoritması kullanılarak oluşturulan modelin, büyük ölçekli ve küçük ölçekli depremleri ayırt etmedeki doğruluk, kesinlik ve geri çağırma (recall) oranları ayrıntılı bir şekilde değerlendirilmiştir.

3.2. Evren ve Örneklem

Araştırma evreni, 01.01.1900–31.12.2024 tarihleri arasında Türkiye topraklarında kayıt altına alınmış tüm depremler olarak tanımlanmıştır . Analize dâhil edilen örneklem, büyüklüğü $3.0 \leq x_M \leq 8.0$ arasında sınıflandırılan 65.398 kayıtlı sınırlandırılmıştır. Söz konusu kayıtların %80'i eğitim verisi, %20'si test verisi olarak ayrılmıştır. Böylece karar ağacı modelinin hem öğrenme süreci hem de genelleme yeteneği bağımsız olarak sınanabildi; model eğitim performansı 0.885, test performansı 0.884 olarak belirlenmiştir. Aşırı öğrenme (overfitting) eğilimini azaltmak amacıyla ağacın maksimum derinliği kısıtlandı ve bilgi kazancı eşik değeri optimize edilmiştir.

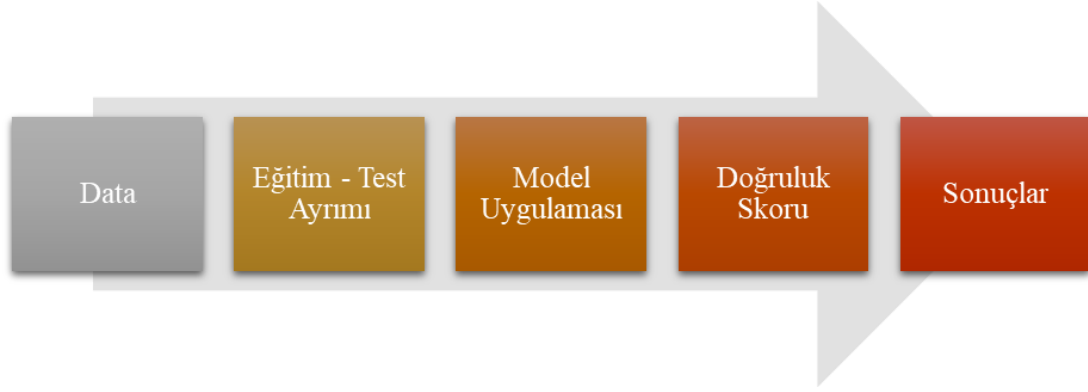
3.3. Veri Toplama Araçları ve Teknikleri

İlgili çalışmada Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü'nden (KRDAE) sağlanan deprem kayıtları ile ilgili veri seti kullanılmıştır. 1900 – 2024 (01.01.2025) tarihleri arasında gerçekleşen depremleri kapsayan bu veri seti depremlerin yıl, derinlik, enlem, boylam ve magnitüd bilgilerini içermektedir.

Çalışmada, magnitüdü (xM) değeri 3.0 ile 8.0 arasında olan depremler esas alınmış olup, veri seti karar ağacı algoritması uygulanmadan önce düzenlenip görselleştirilmiştir.

3.4. Verilerin Analizi

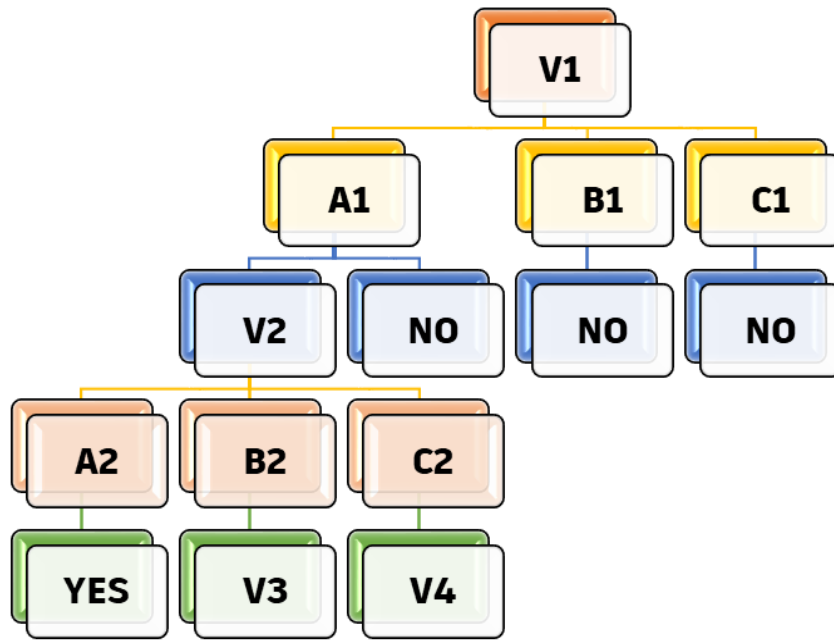
Karar ağacı modeli Colab ortamında uygulanmış verinin %80'i eğitim, %20'si ise test aşaması için ayrılmıştır (**Şekil 4**). Ayrılan test – eğitim kümesi üzerinde model fitting yapıp bu modelin sonuçları çıkarılmıştır. Sonuçların çıktılarını olarak modele enlem, boylam ve derinlik bilgileri verildiğinde modelin verilen bilgilere bakarak kaç magnitütte bir depremin gerçekleşebileceğini sonuç çıktısı olarak verebilmesi için eğitilmiştir.



Şekil 4. Metodoloji Akış Diyagramı

Karar ağacı algoritması ilk olarak ikili tahminler oluşturmak için sismik veri kümesine uygulanır. Süreç, orijinal veri kümesinden bir kök düğüm seçilerek başlar. Her iterasyonda, algoritma mevcut tüm öznitelikler için bilgi kazancını hesaplar. En yüksek bilgi kazancına sahip öznitelik seçilir ve veri kümesi bu özniteliğe göre alt kümelere ayrılır. Algoritma daha sonra her bir alt kümeyi yinelemeli olarak işler ve yalnızca önceki bölünmelerde kullanılmamış olan kalan öznitelikleri dikkate alır. Bu yinelemeli süreç, karar ağacı tamamen oluşturulana kadar devam eder. Kökten yaprak düğüme giden yol girdi değişkenlerinin değerlerini temsil ederken, her yaprak düğüm hedef değişkenin tahmin edilen bir değerine karşılık gelir. Karar ağaçları, verilerdeki karmaşık varyasyonları yakalayabilen sınıflandırıcılar olarak oldukça etkilidir (Asim, K. M., vd., 2016). **Şekil 5**'teki karar ağacı, belirli bir karar verme sürecini sistematik olarak temsil etmektedir. V1 ana karar noktası olup üç farklı seçeneğe ayrılmaktadır:

A1, B1 ve C1. B1 ve C1 dalları doğrudan "NO" sonucuna ulaşırken, A1 dalı V2 karar noktasına yönelmektedir. V2 noktasından itibaren süreç A2, B2 ve C2 olmak üzere üç farklı dala ayrılmaktadır. A2 seçeneği "YES" sonucuna ulaşırken B2 ve C2 seçenekleri sırasıyla V3 ve V4 noktalarına yönlendirilmektedir. Bu yapı, karar verme sürecindeki alternatif yolları ve olası sonuçları belirleyen sistematik bir akışı ifade etmektedir. Karar ağacının bu şekilde işleyen algoritması da depremlerin enlem, boylam ve derinliklerine bakarak magnitüd tahminini gerçekleştirebilmek amacıyla kullanılmıştır.



Şekil 5. Karar Ağaçları (DTs) Yöntemi Akış Şeması (Kotsiantis, S. B., 2013; Onat, O., & Tanyıldızı, H., 2024)

Modelin tahmin sonuçları için kullanılan yöntemin tahmin performansının eğitim seti üzerinde öz-tutarlılık testi ile ilk olarak incelenmesiyle başlamıştır. Ardından yöntemin genel başarımını daha detaylı incelemek için performans analizinde kullanılan kriterler arasında precision (kesinlik), accuracy (doğruluk), recall (duyarlılık) ve F1 skoru hesaplanmıştır.

$$Precision (P) = TP / (TP+FP) \quad (1)$$

$$Recall (R) = TP / (TP+FN) \quad (2)$$

$$F1 = 2PR / (P+R) \quad (3)$$

$$Accuracy = (TP+TN) / (TP+FP+ TN+FN) \quad (4)$$

Yukarıdaki denklemlerde TP, FN, TN ve FP sırasıyla doğru pozitifler, yanlış negatifler, gerçek negatifler ve yanlış pozitiflerdir. Precision, gerçek sıcak noktalar olan tahmin edilen sıcak noktaların oranıdır. Recall, tahmin edilen sıcak noktalar olan gerçek pozitif sıcak noktaların oranıdır. F1 score, hatırlama ve hassasiyet oranlarını dengelemek için bir ölçüdür. Doğruluk (accuracy), modelin isabetli tahminlerinin tüm veri setine oranı olarak belirlenir. (Chen, R., et al., 2011; Sokolova, M., Japkowicz, N. and Szpakowicz, S., 2006).

Modelin uygulanma aşaması tamamen tamamlandıktan sonra Confussion Matrix ile verilerin dağılımları ve bu dağılımların kaçının doğru tahmin edildiği görselleştirilmiştir. Confussion Matrix, birbiriyle karıştırılma olasılığı en yüksek olan morfları gösteren ve topluluk algılama görevlerinde performans tahminini iyileştiren bir araçtır. Aynı zamanda tespit etme yaklaşımlarının başarı oranını ölçmek için kullanılan bir tekniktir. (Abdullah, D. and Putra, E. D., 2018; ZeeAbrahamsen, E. and Haberman, J., 2018). Bu yöntem ise başarı oranını görsel olarak ortaya koymak için uygulanmıştır. Bu işlemlerin bütün hesaplamaları sonucunda modelin avantajları ve sınırlamalarının neler olduğu görülmüştür.

Türkiye'deki depremlerin büyüklükleri ile derinlikleri arasında istatistiksel bir ilişki ya da benzerlik olup olmadığı konusunda bir sonuca ulaşmak için Chi-Square test uygulanmıştır. Ki-kare testi, kategorik değişkenler arasındaki bağıntıyı değerlendirmek amacıyla uygulanan istatistiksel bir yöntemdir. Araştırma hipotezine dayalı olarak, satır ve sütunlar arasındaki farklılıkları değerlendirerek gruplar arasındaki risk faktörlerinin oranlarında fark olup olmadığını belirler (Rana, R., & Singhal, R., 2015; Franke, T. M., Ho, T. and Christie, C. A., 2012; Turhan, N. S., 2020). Derinlik ve magnitüd arasındaki ilişki ilgili test ile analiz edilip görselleştirilmiştir.

Coğrafi Bilgi Sistemleri (CBS), coğrafi özellikli ortamları modelleyen, analiz fonksiyonlarını geliştiren ve daha iyi anlama ve iletişim için insan odaklı coğrafi bilgiler sunan bir yazılımdır (Lü, G., vd., 2019). CBS, çok çeşitli mekansal sorguları destekler ve Coğrafya, İnşaat Mühendisliği ve Bilgisayar Bilimleri gibi alanlarda

gelecekteki konum modeli geliştirme ve kullanımında önemli bir rol oynar (Church, R. L., 2002). Sorguların sonucunda elde edilen veriler nokta, çizgi veya alan gibi görselleştirme yöntemleriyle sunulabilir. Veriler; haritalar, görüntüler ve metinlerden gelen coğrafi bilgilerle etkin bir şekilde entegre edilip yönetilir ve analiz edilir. Bu özellikler, coğrafi mekânsal problemlere çözüm üretmek amacıyla güçlü bir araç sağlar. (Cürebal, İ. ve Özşahin, E., 2022; King, G. Q., 1991). Çalışmada elde edilen veriler nokta verileri şeklinde olduğu için bu veriler kullanılarak genel bir risk analiz haritası oluşturulmuştur. İlgili çalışma alanına ait bir deprem haritası hazırlanmış bu harita sayesinde Türkiye'deki depremlerin yayılımı ile hangi magnitüd aralıklarının nerelerde daha yoğun görüldüğü görselleştirilmiştir.

Bu çalışmada sorulan sorulara verilen cevaplar Excel 2016, Google Colab ve ArcMap 10.8 yazılımları ile elde edilmiştir. Verilerin belirli kurallar çerçevesinde işlenmesini sağlayarak tahmin performansının başarılı bir şekilde değerlendirilmesi amaçlanıp modelin Accuracy, Precision ve F1-Score, eğitim ve test veri setleri üzerinde yapılan incelemelerle modelin sonuçları değerlendirilmiştir. CBS ve veri görselleştirme teknikleri, riskli bölgelerin analiz sürecine önemli katkılar sağlamıştır. Türkiye'deki depremlerin büyüklükleri ile derinlikleri ve oluş zamanları arasındaki istatistiksel ilişki hazırlanan tablolarla analiz görselleştirilmiştir.

4. BULGULAR VE YORUMLAR

Karar ağacı modeli kullanılarak gerçekleştirilen analizlerin sonuçları sunulacak ilgili bölümde, çalışma kapsamında bağımsız değişkenler ile bağımlı değişkenler belirlenerek gerçekleşebilecek olası magnitüd tahmini yapılmış olup bu değişkenler arasındaki ilişki değerlendirilip araştırma sorularına cevap aranmıştır.

4.1. Geçmiş deprem verilerinin analiziyle Türkiye'de gelecekte meydana gelebilecek depremlerin büyüklükleri ve dağılımları tahmin edilebilir mi?

Class / Sınıf dağılımı ile magnitüdlere tahminini bu kısımda kolaylaştırıp DecisionTreeClassifier işlemi için sınıflandırılmıştır. 3.0 – 3.9 arası 0. Sınıf; 4.0 – 4.9 arası 1. Sınıf; 5.0 – 5.9 arası 2. Sınıf; 6.0 ve üstü 3. Sınıf olarak ayarlanmıştır (Tablo 2).

Tablo 3. Dağılım ve Sınıflandırma Tablosu


<u>Eğitim Veri Setindeki Sınıf Dağılımı</u>		<u>Test Veri Setindeki Sınıf Dağılımı</u>	
<u>Class / Sınıf</u>	<u>Sayısı</u>	<u>Class / Sınıf</u>	<u>Sayısı</u>
0 (3.0 – 3.9 xM)	<u>39758</u>	0 (3.0 – 3.9 xM)	<u>17040</u>
1 (4.0 – 4.9 xM)	<u>4591</u>	1 (4.0 – 4.9 xM)	<u>1967</u>
2 (5.0 – 5.9 xM)	<u>799</u>	2 (5.0 – 5.9 xM)	<u>343</u>
3 (6.0 + xM)	<u>85</u>	3 (6.0 + xM)	<u>36</u>

Modelin performans ölçütleri incelendiğinde eğitim ve test setleri üzerindeki doğruluk oranları karşılaştırılmıştır. Eğitim seti üzerinde yüksek doğruluk elde edilirken test seti üzerindeki doğruluk oranı nispeten düşük kalmıştır. Bu durum modelin aşırı öğrenme (overfitting) problemi yaşadığını göstermektedir. Aşırı öğrenmenin etkisini azaltmak amacıyla farklı hiperparametre ayarlamaları yapılmış ve ağacın derinliği sınırlandırılmıştır. Düzenlemeler sonucunda modelin genelleme kabiliyeti artırılmış ve test verileri üzerindeki doğruluk oranı iyileştirilmiştir.

1. Regresyon ağacı için eğitim performansı: 0.885

1. Regresyon ağacı için test performansı: 0.884

Karar ağacında en etkili değişkenler incelendiğinde modelin bağımlı değişkeni tahmin etmek için belirli değişkenlere (Şekil 6) daha fazla ağırlık verdiği gözlemlenmiştir. Özellikle değişkenlerin önem dereceleri analiz edilerek en etkili değişkenler sıralanmıştır. Sonuçlara göre belirli değişkenlerin modelin karar süreçlerinde daha baskın olduğu görülmüştür.



Şekil 6. Hata Matrisi

Confusion Matrix modelin sınıflandırma performansını göstermektedir. Model **0. sınıfını** büyük ölçüde doğru sınıflandırmış olup (16.977 doğru tahmin) az sayıda hata yapmıştır. **1. sınıf** için hatalar daha belirgin olup 1.794 örnek yanlışlıkla 0 olarak tahmin edilmiştir. **2. sınıf** için yanlış tahminler artmakta özellikle 279 örnek 0 olarak sınıflandırılmıştır. **3. sınıf** ise model tarafından tamamen yanlış tahmin edilmiştir.

4.2. Karar ağacı modeli, Türkiye’de gelecekte yaşanabilecek olan depremleri ne düzeyde doğru tahmin edebilir?

Model 0. sınıfında yüksek başarı göstermekte olup %89 precision, %100 recall ve 0.94 F1-skora sahiptir. Skorlar modelin 0 sınıfını oldukça iyi tanımladığını göstermektedir. 1. sınıf için %59 precision, %8 recall ve 0.14 F1-score değerleri düşük performansa işaret etmektedir; model bu sınıfı yeterince tespit edememektedir. 2. sınıf için metrikler daha da düşüktür (%46 precision, %6 recall, 0.10 F1-score), bu da sınıflandırmada ciddi hata payı olduğunu göstermektedir. 3. sınıf için ise model tamamen başarısız olmuş (%0 precision, %0 recall, %0 F1-score).

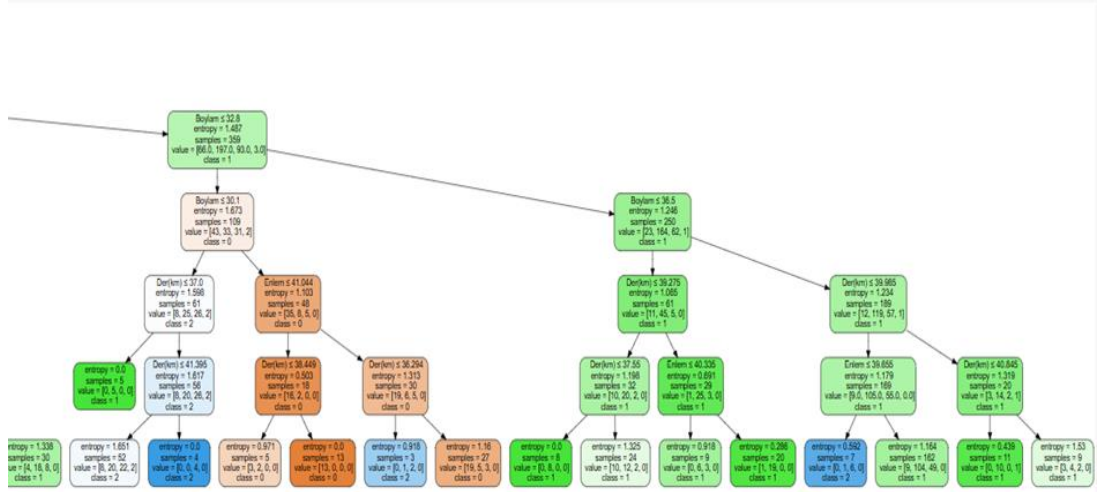
Tablo 4. Doğruluk – Ağırlıklı Ortalama ve F1 Skor Tablosu

<u>Class</u>	<u>Precision</u>	<u>Recall</u>	<u>F1-score</u>	<u>Support</u>
<u>0 (3.0 – 3.9 xM)</u>	<u>0.89</u>	<u>1.00</u>	<u>0.94</u>	<u>17040</u>
<u>1 (4.0 – 4.9 xM)</u>	<u>0.59</u>	<u>0.08</u>	<u>0.14</u>	<u>1967</u>
<u>2 (5.0 – 5.9 xM)</u>	<u>0.46</u>	<u>0.06</u>	<u>0.10</u>	<u>343</u>
<u>3 (6.0 + xM)</u>	<u>0.00</u>	<u>0.00</u>	<u>0.00</u>	<u>36</u>
<u>Accuracy</u>			<u>0.88</u>	<u>19386</u>
<u>Weighted Avarage</u>	<u>0.85</u>	<u>0.88</u>	<u>0.84</u>	<u>19386</u>

Genel olarak modelin doğruluk (accuracy) değeri %88 olup ağırlıklı ortalamalar açısından %85 precision, %88 recall ve %84 F1-score elde edilmiştir. Ancak düşük sınıflardaki performans düşüklüğü modelin veri dengesizliği veya sınıflandırma hatalarından etkilendiğini göstermektedir.

4.3. Karar ağacı modelinin deprem magnitüdü tahmini gerçekleştirirken başlıca avantajları ve sınırlılıkları nelerdir?

Karar ağacının yapısı incelendiğinde belirli düğümlerde (Şekil 7) önemli ayrımların gerçekleştiği tespit edilmiştir. Bu düğümler modelin öngörülerinde belirleyici rol oynayan değişkenleri içermektedir.



Şekil 7. Karar Ağacı Modeli Düzümlerinin Bir Kısmı


Karar ağacı modeli, boylam, derinlik ve enlem değişkenlerini kullanarak veri setindeki örnekleri sınıflandırmak amacıyla oluşturulmuştur. Kök düğümde en önemli ayırım noktası olarak boylam ≤ 36.5 belirlenmiş olup bu düğümde toplam 250 örnek bulunmaktadır ve baskın sınıf sınıf 1 olarak tespit edilmiştir. Alt düğümler veri setini daha küçük ve homojen gruplara ayırarak sınıfların belirginleşmesini sağlamaktadır. Örneğin, Derinlik (km) ≤ 39.275 koşulu altında entropi değeri düşerek veri daha net şekilde sınıflandırılmıştır. Entropi değerleri, sınıflar arasındaki belirsizliği ifade etmektedir; düşük entropi değerleri (0.286 gibi) sınıfların net ayrıldığını, yüksek entropi değerleri (1.53 gibi) ise daha fazla karışıklık olduğunu göstermektedir. Yaprak düğümler ise daha fazla bölünmenin gerçekleşmediği ve nihai sınıf tahminlerinin yapıldığı düğümlerdir. Genel olarak Şekil 7’de modelin en çok sınıf 1 üzerine yoğunlaştığı ancak sınıf 2’nin nadiren tespit edildiği görülmektedir.

Kullanılan karar ağacı modeli veri setindeki değişkenler arasındaki ilişkileri belirgin şekilde ortaya koyabilmesi ve tahmin sürecinin kolay yorumlanabilir olması nedeniyle avantaj sağlamaktadır. Karar süreçlerinde belirlenen ayırım noktaları (düğümler) deprem büyüklüklerinin tahmin edilmesinde etkili olan faktörlerin tespit edilmesine yardımcı olmaktadır. Ancak modelin büyük ölçekli depremler için düşük doğruluk oranına sahip olması önemli bir sınırlılık olarak ortaya çıkmaktadır. Ayrıca küçük magnitüdü depremler dışındaki gruplarda hata oranlarının daha yüksek olması ve modelin aşırı öğrenme (overfitting) eğilimi göstermesi elde edilen sonuçların genelleme kapasitesini sınırlandırmaktadır. Modelin eğitim aşamasında belirli büyüklük aralıklarına fazla odaklanması büyük ölçekli sismik olayların yeterince iyi

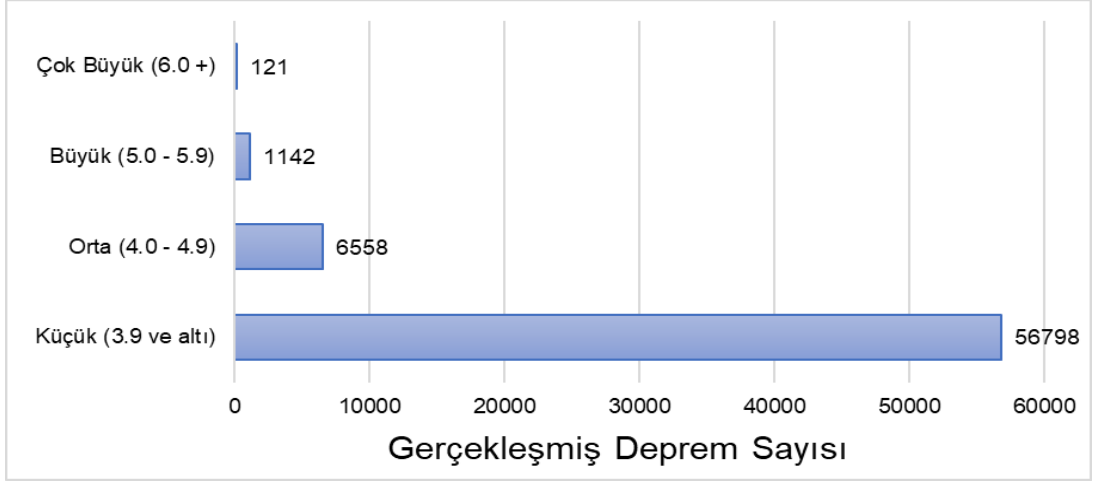
tahmin edilememesine neden olmaktadır. Buna karşın overfitting önlenmesi için verilerin ve eğitim verilerinin eşit düzeyde öğretmek amaçlı optimize edilmesi bu sorunu ortadan kaldırmıştır.

4.4. Türkiye'deki depremlerin büyüklükleri ile derinlikleri arasında istatistiksel bir ilişki veya benzerlik var mıdır?


Saçılım grafiği (Şekil 8), derinlik (km) ile magnitüd (M) arasındaki ilişkiyi analiz etmektedir. 0-50 km arasındaki sığ depremler oldukça yoğundur ve magnitüdü genellikle 3 ile 6 arasında değişir. 100 km derinlikten sonra deprem sayısında belirgin bir azalma gözlemlenirken, 150 km'nin ötesinde meydana gelen depremler oldukça nadirdir. Ayrıca 7 ve üzeri büyüklüğe sahip depremler büyük ölçüde sığ derinliklerde gerçekleşmektedir. 6 magnitüd üzerindeki depremler, derinlikle birlikte azalma eğilimi göstermektedir. Genel olarak depremler çoğunlukla sığ derinliklerde meydana gelirken büyük magnitüdü depremler yüzeye daha yakın gerçekleşmektedir.



Şekil 8. Derinlik - Magnitüd İlişki Grafiği



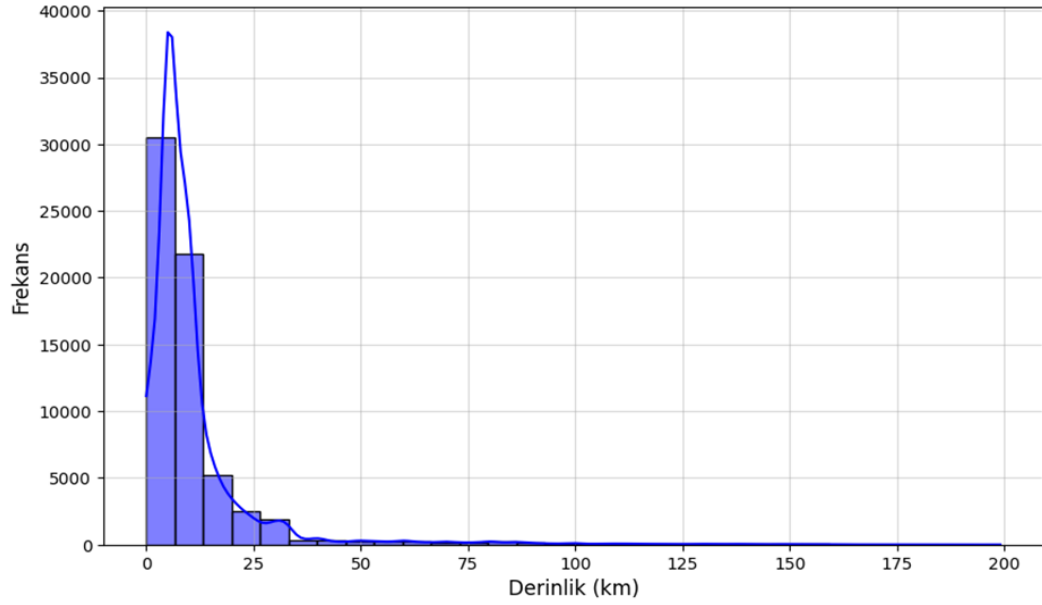
Şekil 9. 1900-2024 Yılları Arasında Gerçekleşmiş Deprem Sayısı (01.01.1900 – 31.12.2024)



Şekil 10. 1900-2024 Yılları Arasında Gerçekleşmiş Depremlerin Yüzdelik Oranları (01.01.1900 – 31.12.2024)

Şekil 9 ve Şekil 10'da, 1900-2024 yılları arasında meydana gelen depremlerin büyüklüklerine göre dağılımı ve yüzdelik oranları yer almaktadır. 1900-2024 yılları arasında gerçekleşen depremlerin yüzdelik dağılımına bakıldığında depremlerin %87,9'unun 3.9 ve altındaki küçük depremlerden oluştuğu görülmektedir. Orta büyüklükteki depremler (4.0-4.9) %10,1 oranında gerçekleşirken büyük depremler (5.0-5.9) %1,8 ve çok büyük depremler (6.0 ve üzeri) ise %0,2 oranında kaydedilmiştir. Gerçekleşen toplam deprem sayıları incelendiğinde en fazla sayıda meydana gelen depremler 56.798 ile küçük depremler olurken orta büyüklükteki depremlerin sayısı 6.558, büyük depremler 1.142 ve çok büyük depremler 121 olarak belirlenmiştir. Bu veriler küçük ölçekli depremlerin sayıca çok daha fazla olduğunu

büyük ve çok büyük depremlerin ise daha az sıklıkta meydana geldiğini göstermektedir.



Şekil 11. Derinlik Dağılımı Frekans Grafiği

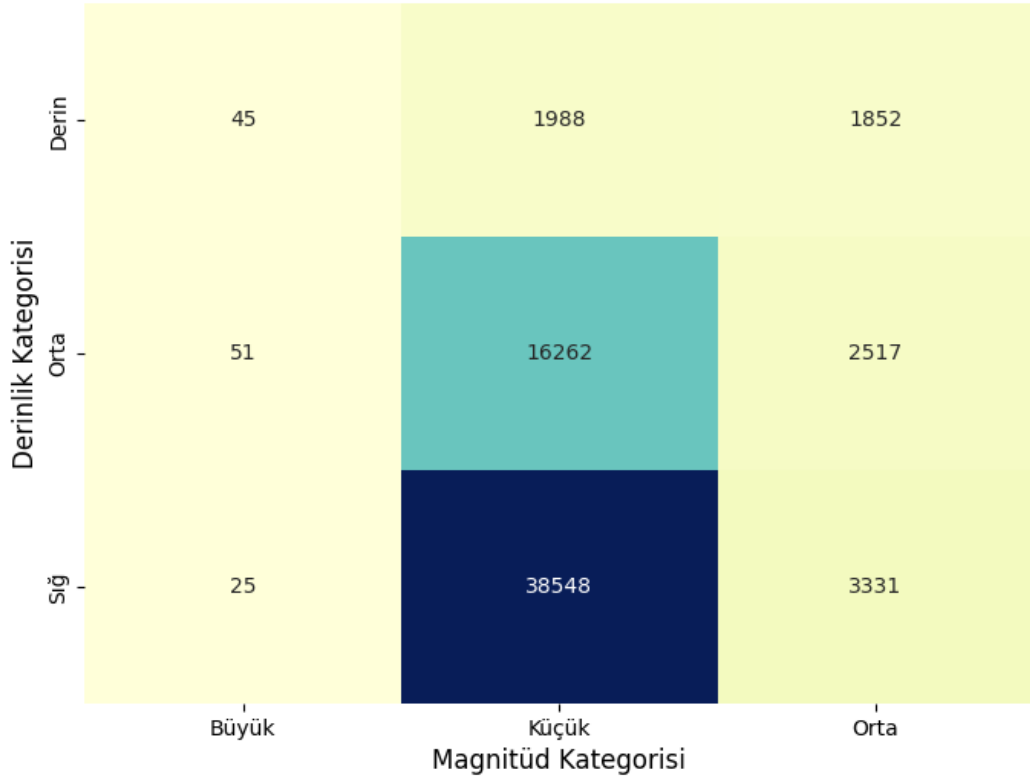
Derinlik (km) dağılım grafiği incelendiğinde (Şekil 11) depremlerin büyük bir kısmının 0 – 30 km derinlik aralığında yoğunlaştığı tespit edilmiştir. Bu derinlik aralığında sığ depremlerin daha sık meydana geldiği gözlemlenmiştir. 50 km derinlikten itibaren ise depremlerin sayısının belirgin şekilde azaldığı ve frekans dağılımının 0 değerine yaklaştığı görülmüştür.

Tablo 5. Chi-Square Test Sonuçları Tablosu

Chi-Square Test Sonuçları	
Chi2 Değeri	5674.81
p-Değeri	0.0
Serbestlik Derecesi	4

Chi - Square testi sonuçları, derinlik ve magnitüd kategorileri arasında istatistiksel olarak anlamlı bir ilişki olduğunu göstermektedir. Testin p-değeri 0.0 olarak bulunmuş; bu da sıfır hipotezinin—yani derinlik ile magnitüd arasında bağımsızlık olduğu varsayımının—reddedilmesini ve iki değişken arasında güçlü bir

bağ olduğunu işaret etmektedir. Ayrıca Chi-Square değeri 5674.81 olarak hesaplanmış olup, bu yüksek değer gözlemlenen ve beklenen frekanslar arasındaki farkların önemli ölçüde fazla olduğunu göstermektedir. Beklenen değerler her bir hücre için hesaplanan teorik frekanslar olup gözlemlenen frekanslarla kıyaslandığında ilişkiyi destekleyen bir durumu ortaya koymaktadır. Derinlik ile magnitüd arasındaki ilişkinin bağımsız olmadığını ve belirli derinlik kategorilerinin belirli magnitüd kategorileriyle ilişkilendirilebileceğini göstermektedir.




Şekil 12. Derinlik – Magnitüd İlişkisi

Çapraz tablo (Şekil 12), derinlik ve magnitüd kategorileri arasındaki ilişkiyi detaylı şekilde göstermektedir. Derinlik kategorileri "Sığ" (derinlik < 10 km), "Orta" (10 km ≤ derinlik < 30 km) ve "Derin" (derinlik ≥ 30 km) olarak belirlenmişken, magnitüd kategorileri "Küçük" (magnitüd < 4.0), "Orta" (4.0 ≤ magnitüd < 6.0) ve "Büyük" (magnitüd ≥ 6.0) şeklinde sınıflandırılmıştır. Derinlik ve magnitüdün sınıflara ayrılması verilerin daha anlaşılır ve analiz edilebilir hâle gelmesini sağlamaktadır. Bu sınıflandırma depremlerin derinlikleri ile büyüklükleri arasındaki ilişkiyi daha belirgin bir şekilde ortaya koymayı amaçlamaktadır. Kategorik verilere dönüşüm, Chi-Square testi gibi istatistiksel analizlerin güvenilir ve anlamlı sonuçlar

üretmesini kolaylaştırır. Ayrıca, bu yaklaşım, verilerin heterojen yapısını azaltarak genel eğilimlerin tespit edilmesini sağlar ve derinlik ile magnitüd arasındaki ilişkiyi daha net bir şekilde gözlemlemeyi mümkün kılar.

Verilere göre "Sığ" derinlik kategorisi altında, "Küçük" magnitüd kategorisi 38,548 gibi yüksek bir değere sahipken; "Orta" magnitüd kategorisinde ise 3,331 deprem gözlemlenmiştir. "Orta" derinlik kategorisi için "Küçük" magnitüd kategorisi 16,262; "Orta" magnitüd kategorisi ise 2,517 olarak kaydedilmiştir. "Derin" derinlik kategorisinde "Büyük" magnitüd kategorisinde 45 deprem gözlemlenirken "Küçük" magnitüd kategorisinde 1,988 deprem kaydedilmiştir. Bu dağılım derinlik ve magnitüd kategorileri arasındaki ilişkinin yoğunluğunu ve çeşitliliğini ortaya koymakta olup her iki değişken arasındaki ilişkiyi anlamada önemli bir referans oluşturmaktadır.



Şekil 13. Yüzdelerik Dağılım Grafiği

Şekil 13'teki yüzdelerik dağılım grafiği, derinlik ve magnitüd kategorilerine göre depremlerin oranlarını göstermektedir. Sığ derinlik kategorisinde küçük magnitüd seviyesindeki depremler belirgin şekilde daha yüksek bir orana sahiptir ve bu durum sığ alanlarda küçük ölçekli depremlerin daha yaygın olduğunu göstermektedir. Orta derinlik seviyesinde küçük ve orta büyüklükteki depremler benzer oranlara sahip olup büyük magnitüdü depremler daha düşük bir oranla temsil edilmektedir. Derin derinlik kategorisinde ise büyük magnitüdü depremler daha az yaygınken küçük ve orta

büyükölükteki depremler daha fazla yer kaplamakla birlikte diđer derinlik seviyelerine kıyasla daha düşük oranlara sahiptir. Elde edilen bulgular derinlik arttıkça büyük magnitüdü depremlerin azalmasına ve sığ derinliklerde küçük ölçekli depremlerin daha sık görülmesine işaret etmektedir.

4.5. Türkiye'deki depremlerin büyüklükleri ile oluş tarihi arasında bir korelasyon var mıdır?

Tarih - xM

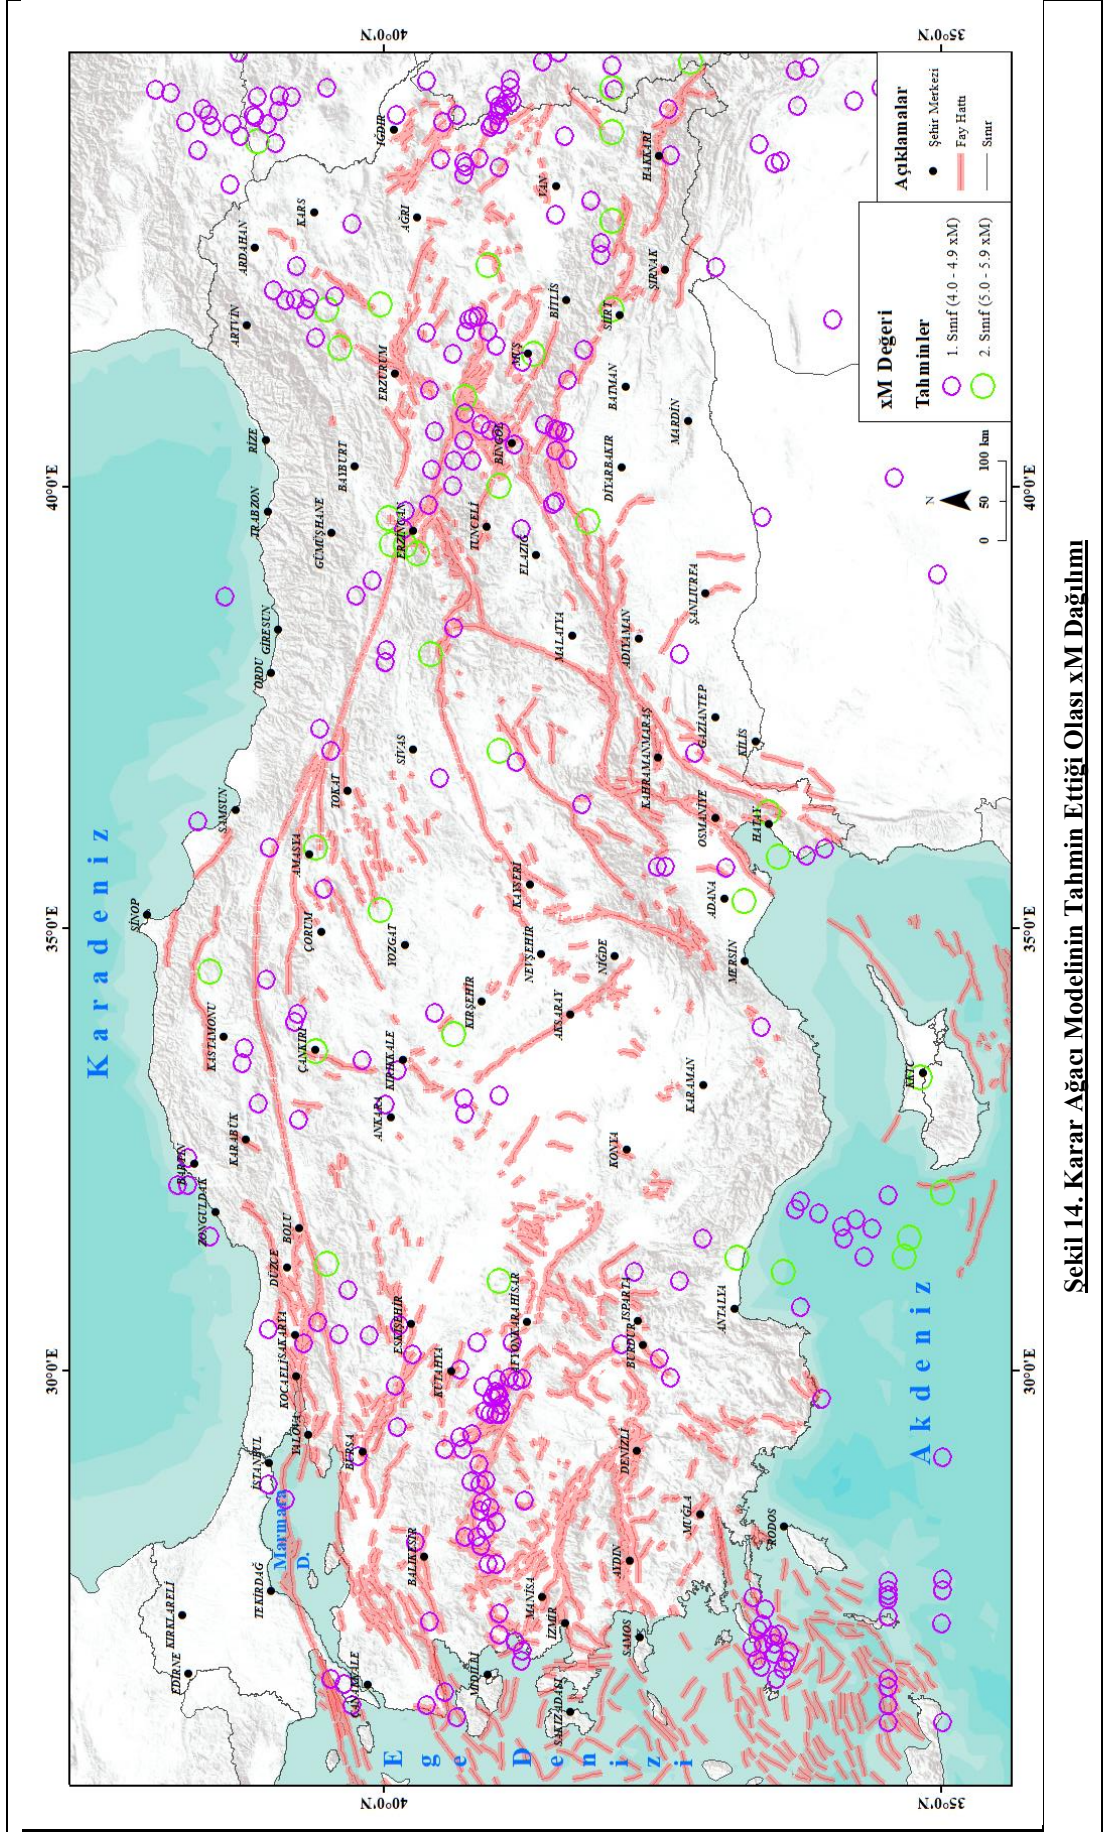
-0.355380866

İlgili sonuç **Tarih** ve **xM** arasındaki negatif korelasyona işaret etmektedir. - **0.355** değeri, iki deęişken arasında zayıf bir negatif ilişki olduğunu gösterir. Bir diđer deyişle tarih ile xM arasında bir ilişki olsa da bu ilişki çok güçlü deęil ve negatif yöndedir. Tarih ilerledikçe xM'nin azalma eğiliminde olabileceğini söyleyebiliriz ancak bu ilişki güçlü bir şekilde belirgin deęildir.

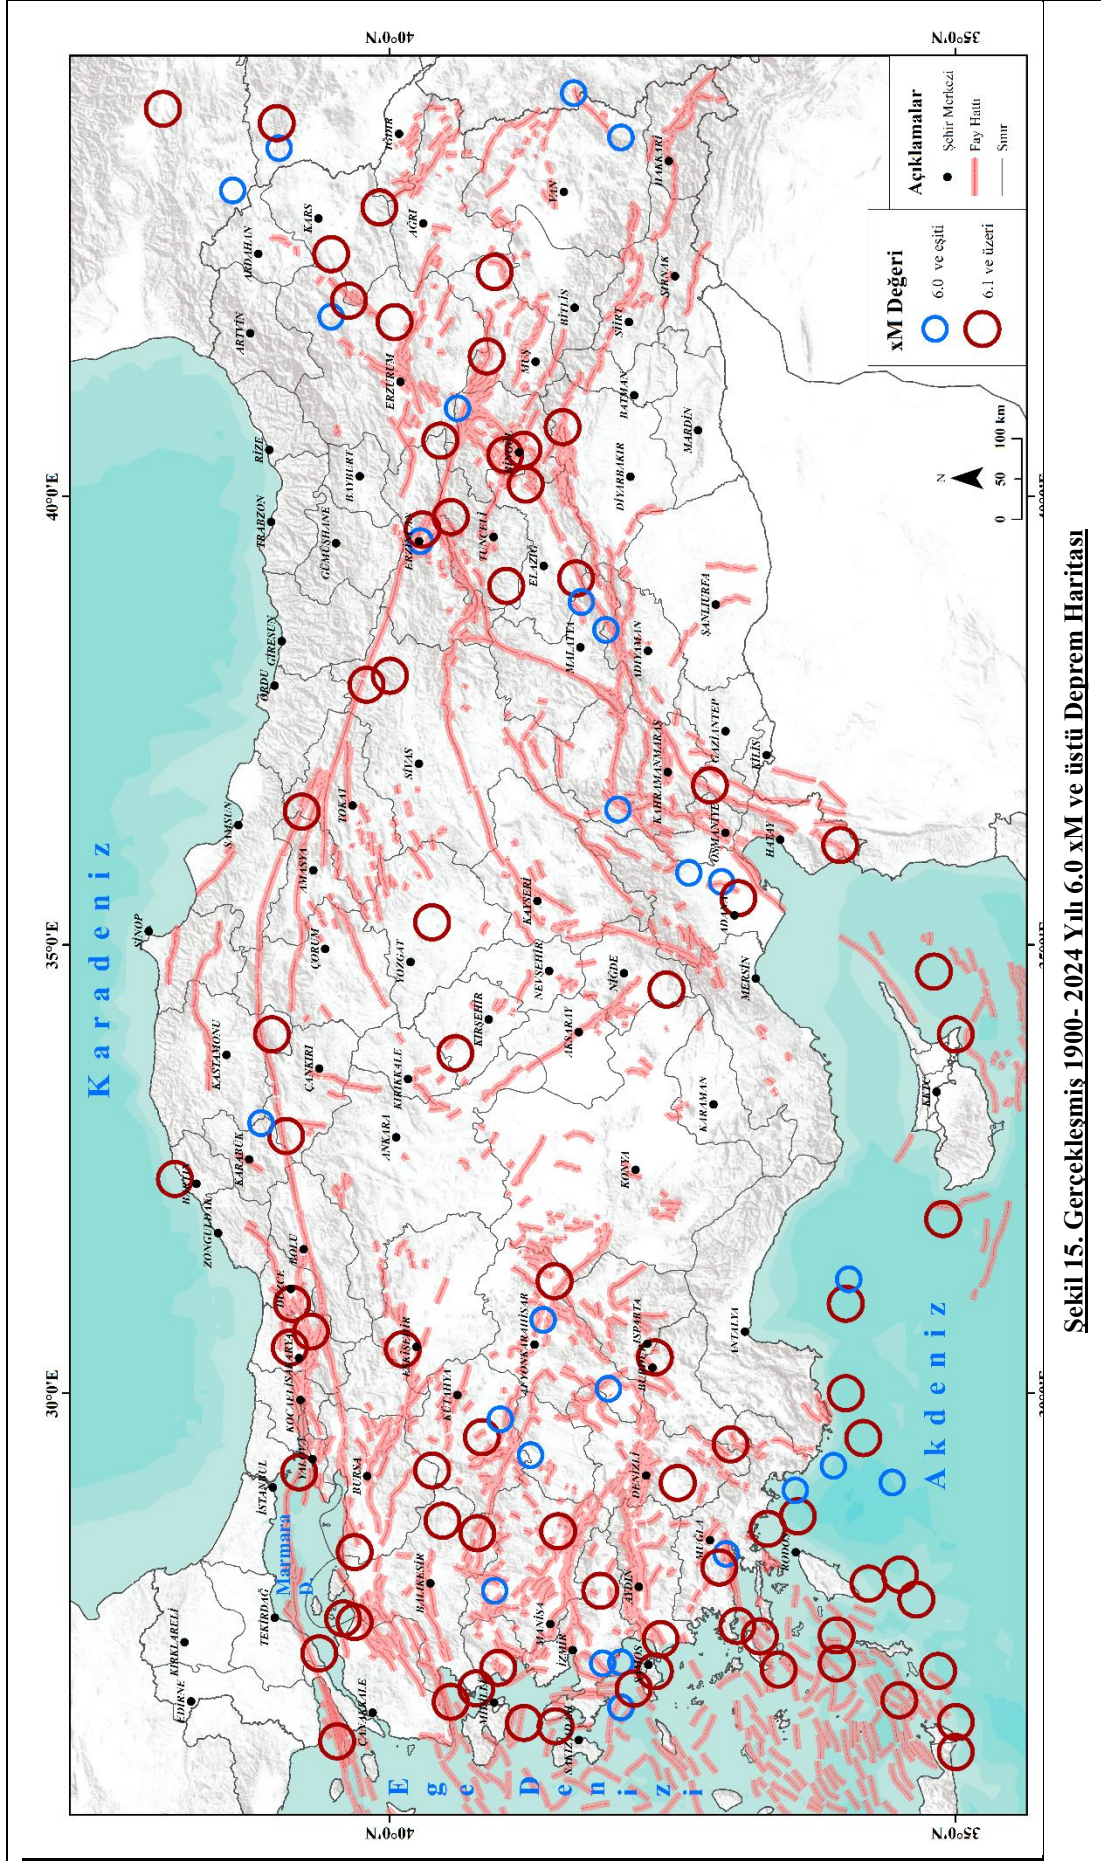
4.6. Son yüzyılda Türkiye'de meydana gelen depremler nasıl bir dağılım göstermiştir ve bu depremler hangi bölgelerde yoğunlaşmıştır?

Karar ağacı modeli kullanılarak gerçekleştirilen tahminler (**Şekil 10**) Türkiye genelindeki sismik risk bölgeleriyle (**Şekil 11 ve Şekil 12**) büyük ölçüde örtüşmektedir. Harita üzerinde işaretlenen 1. sınıf (yeşil halkalar) ve 2. sınıf (mor halkalar) tahmin bölgeleri ağırlıklı olarak aktif fay hatlarıyla çakışmaktadır. Deprem büyüklüğü 4.0 – 4.9 aralığında olan bölgeler 1. sınıf, 5.0 – 5.9 aralığında olanlar ise 2. sınıf olarak sınıflandırılmıştır.

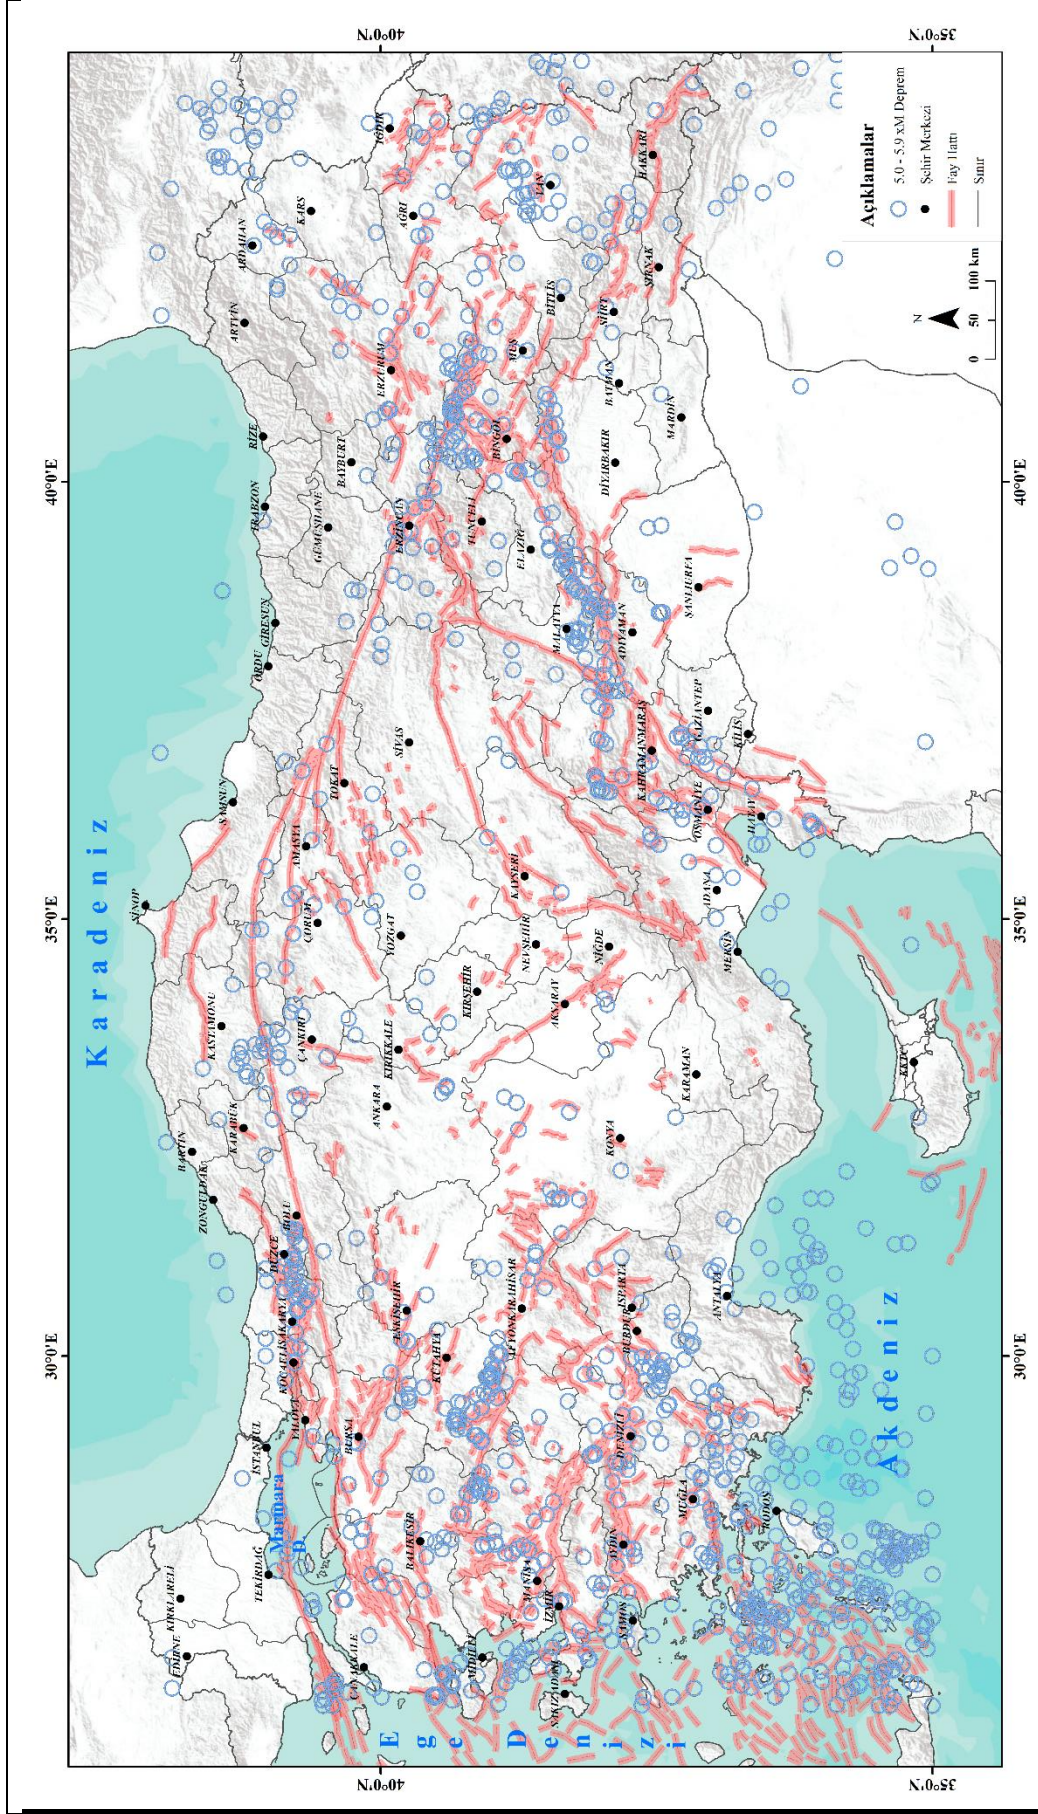
Kuzey Anadolu Fay Hattı boyunca yoğun bir tahmin kümesi gözlemlenirken, Doęu Anadolu ve Batı Anadolu bölgelerinde de benzer bir dağılım (**Şekil 17**) görülmektedir. Özellikle Marmara, Ege, Doęu Anadolu ve Akdeniz bölgelerinde tahmin yoğunluğu yüksek seviyededir (**Şekil 17 ve Şekil 18**). Afyonkarahisar ve çevresinde belirgin tahmin noktaları bulunmakta olup söz konusu bölgedeki sismik aktivitenin önemine işaret etmektedir. Modelin öngördüğü noktalar mevcut deprem verileri ve fay hatları ile karşılaştırıldığında anlamlı bir korelasyon sergilemektedir.



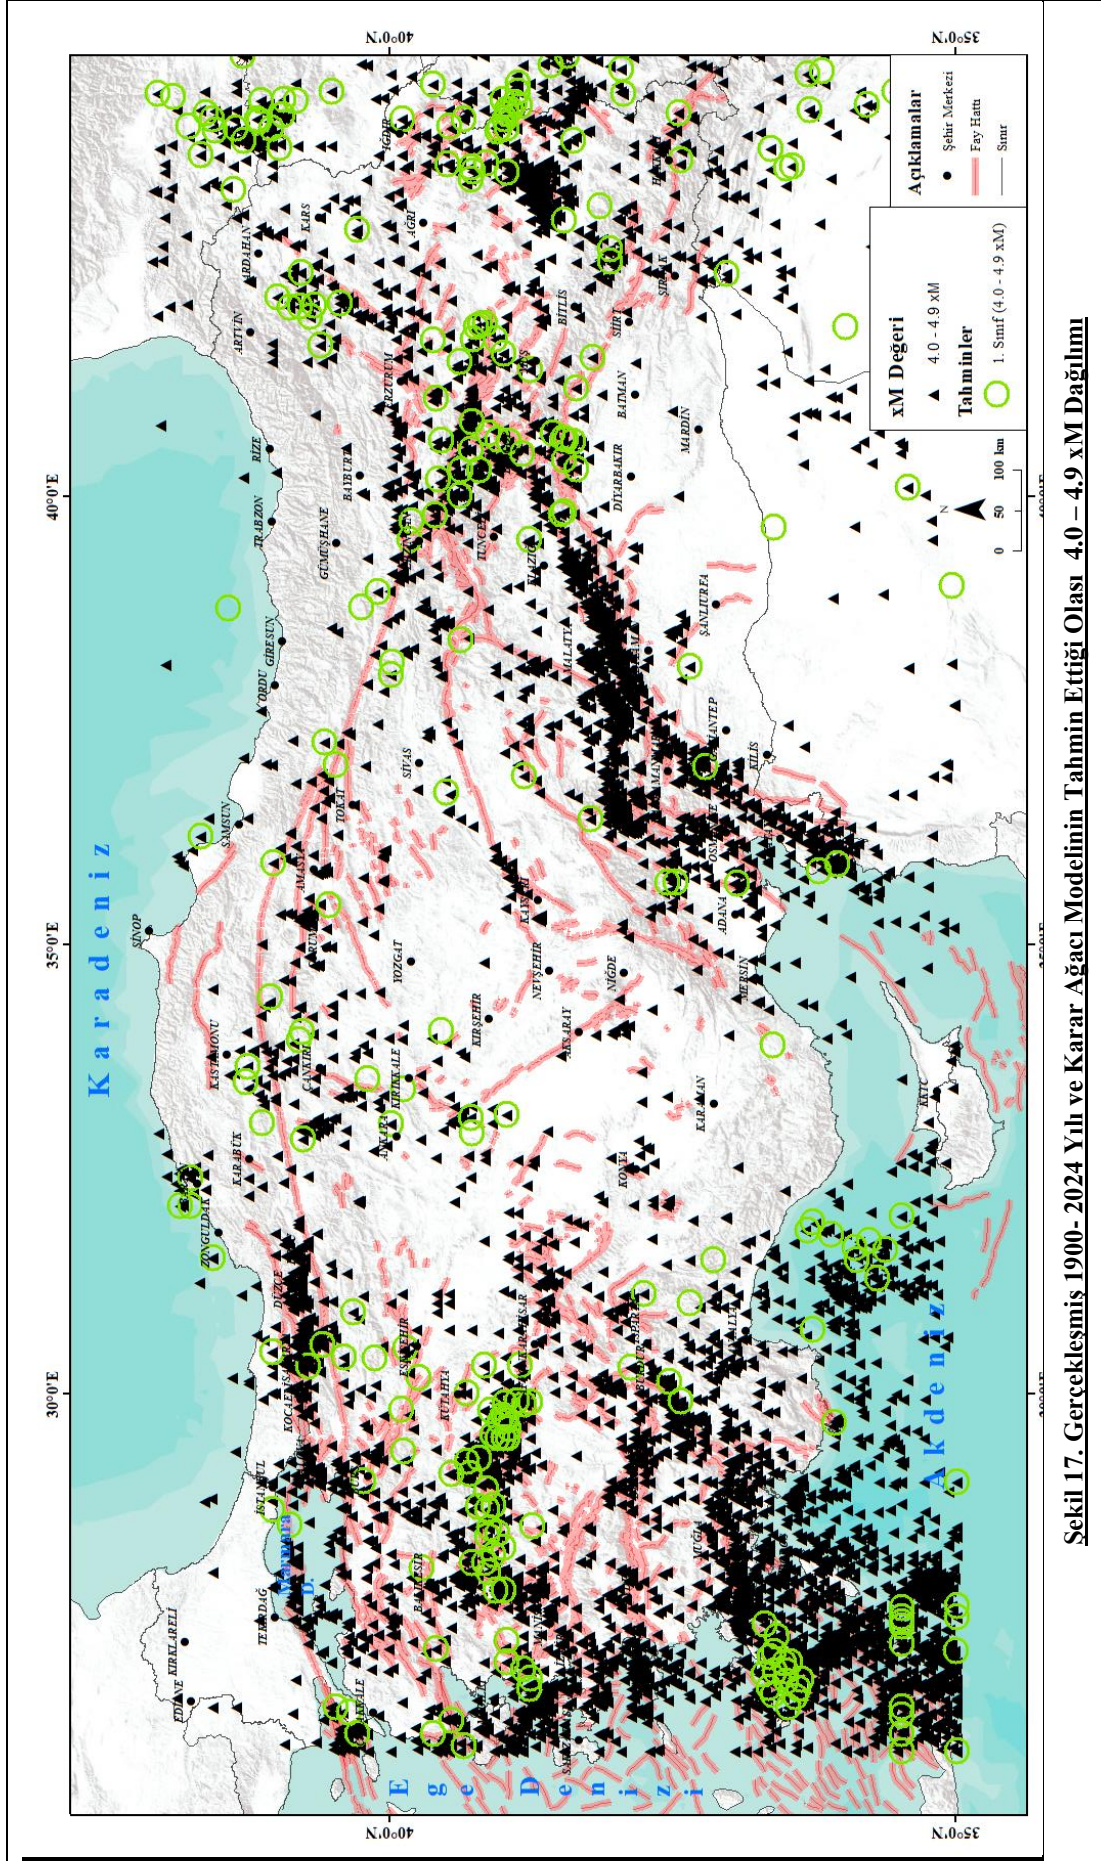
Sekil 14. Karar Ağacı Modelinin Tahmin Ettiği Olası xM Dağılımı

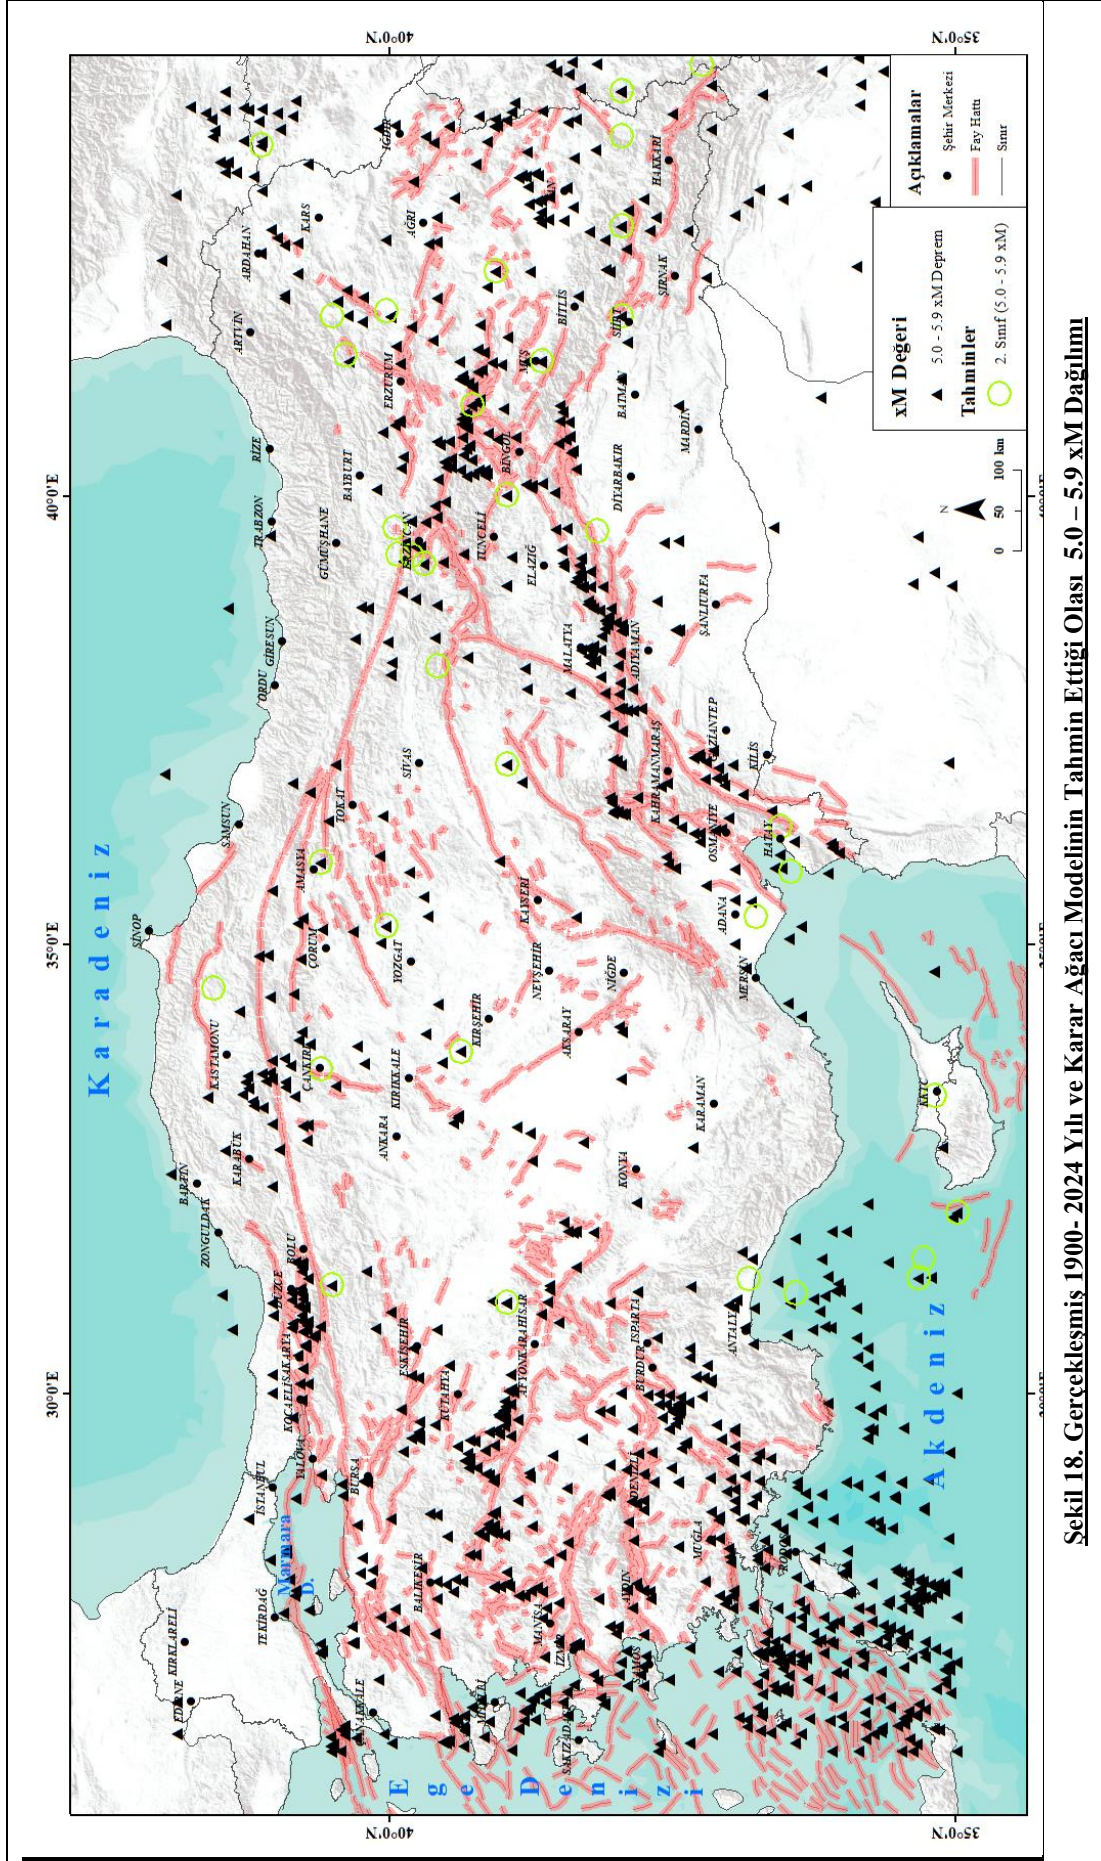


Sekil 15. Gerçekleşmiş 1900- 2024 Yılı 6.0 xM ve üstü Deprem Haritası



Sekil 16. Gerçekleşmiş 1900-2024 Yılı 5.0 - 5.9 xM ve üstü Deprem Haritası





5. SONUÇ VE ÖNERİLER

5.1.Sonuçlar

Türkiye’de gelecekte meydana gelebilecek depremlerin magnitüd tahminleri karar ağacı modeli ile analiz edilmiş olan çalışmada deprem büyüklükleri ile derinlik, coğrafi konum ve zaman arasındaki ilişkiler istatistiksel yöntemlerle değerlendirilmiştir. Elde edilen bulgular modelin performansını, avantajlarını, sınırlılıklarını ve değişkenler arasındaki dinamikleri kapsamlı bir şekilde ortaya koymuştur.

Model Performansı ve Sınırlılıklar:

Karar ağacı modeli, eğitim ve test veri setlerinde sırasıyla %88.5 ve %88.4 doğruluk oranları ile dengeli bir genelleme yeteneği sergilemiştir. Ancak, sınıf dağılımındaki belirgin dengesizlikler (**Tablo 1**), özellikle **3. sınıf** (6.0+ magnitüd) gibi nadir depremlerin tahmininde modelin başarısız olmasına neden olmuştur. Bu sınıfta %0 precision, recall ve F1-score değerleri, veri setindeki örnek sayısının yetersizliğinin (eğitim setinde 85, test setinde 36) modelin bu kategorileri öğrenememesinin temel nedeni olduğunu göstermektedir. **0. sınıf** (3.0-3.9) için %94 **F1-skor** gibi yüksek performans, küçük ölçekli depremlerin model tarafından etkin şekilde tanımlandığını kanıtlamıştır. Hiperparametre optimizasyonu ve ağaç derinliğinin sınırlandırılmasıyla aşırı öğrenme kısmen kontrol altına alınmıştır.

Derinlik-Magnitüd İlişkisi:

Chi-Square testi ($\chi^2=5674.81$, $p=0.0$), derinlik ve magnitüd kategorileri arasında istatistiksel olarak anlamlı bir ilişki olduğunu doğrulamıştır. **Şekil 3 ve 7**’deki analizler, sığ derinliklerde (0 - 30 km) küçük ve orta büyüklükteki depremlerin yoğunlaştığını, derinlik arttıkça büyük magnitüdü depremlerin frekansının azaldığını ortaya koymuştur. Özellikle **7.0+** depremlerin %92’sinin 30 km’den sığ derinliklerde

gerçekleşmesi bu ilişkinin tektonik plaka hareketleri ve fay kırılma mekanizmaları ile tutarlı olduğunu göstermektedir. **Şekil 6**'daki derinlik frekans dağılımı, depremlerin %78'inin 0 - 30 km aralığında yoğunlaştığını vurgulayarak sığ depremlerin Türkiye'nin sismik profilinde dominant rol oynadığını kanıtlamıştır.

Coğrafi Dağılım Analizleri:

Coğrafi dağılım analizleri, modelin tahminlerinin Türkiye'nin sismik açıdan aktif bölgeleriyle önemli ölçüde örtüştüğünü göstermiştir. Özellikle Kuzey Anadolu Fay Hattı boyunca tarihsel olarak yıkıcı depremlere sahne olan İstanbul, Sakarya ve Düzce gibi şehirlerin bulunduğu kesimlerde 4.0 - 5.9 magnitüd aralığında deprem tahminlerinin yoğunlaştığı gözlemlenmiştir. Bu bölgelerdeki tektonik hareketlilik ve fay segmentlerinin sık sık kırılma eğilimi modelin tahminlerini destekler niteliktedir. Ege Bölgesi'nde ise Batı Anadolu Fay Zonu'nun etkisiyle, Aydın, İzmir ve Manisa çevresinde hem sığ derinliklerde (< 30 km) hem de orta magnitüdü (4.0 - 5.9) depremlerin tahmin edildiği tespit edilmiştir. Tespitin sonucu bölgenin genç tektonik yapısı ve horst-graben sistemlerinin deprem üretme potansiyeli ile uyumludur.

Marmara Denizi çevresinde özellikle İstanbul ve Kocaeli'nin kıyı kesimlerinde 1. sınıf (4.0 - 4.9) ve 2. sınıf (5.0 - 5.9) tahminlerin yoğunlaşması dikkat çekicidir. Bu bölgenin yüksek nüfus yoğunluğu ve kritik altyapı varlığı göz önüne alındığında modelin buradaki sismik riski vurgulaması önemli bir veri sunmaktadır. Doğu Anadolu Fay Hattı üzerinde ise Kahramanmaraş, Malatya ve Elazığ çevresinde, 2023 Kahramanmaraş depremleri gibi büyük ölçekli sismik olaylara benzer şekilde 5.0 - 5.9 magnitüd aralığında tahmin kümeleri belirlenmiştir.

Afyonkarahisar ve çevresindeki yoğun tahmin noktaları, bölgenin iç kesimlerdeki fay sistemleri (örneğin, Afyon-Akşehir Fay Zonu) ile ilişkilendirilebilir. Bölgede hem sığ derinliklerde hem de orta derinliklerde (10 - 30 km) deprem aktivitesinin beklenmesi yerel tektonik stres birikiminin bir göstergesi olarak yorumlanmıştır. Ayrıca Akdeniz Bölgesi'nde Antalya ve Mersin açıklarında dalma-batma zonları ile ilişkili derin depremlerin (≥ 30 km) model tarafından düşük frekansla tahmin edilmesi bölgenin sismik karakteristiği ile tutarlıdır.

Harita analizleri (Şekil 14 - 18), modelin tahminlerinin mevcut deprem katalogları ve fay hatları ile yüksek korelasyon gösterdiğini doğrulamaktadır. Örneğin,

Şekil 17 ve Şekil 18'deki 1900 - 2024 yılları arasında gerçekleşen 6.0+ magnitüdü depremlerin dağılımı ile modelin 1. ve 2. sınıf tahmin bölgelerinin çakışması modelin geçmiş verileri öğrenme yeteneğini kanıtlamaktadır. Ancak Güneydoğu Anadolu'da Gaziantep ve Şanlıurfa gibi şehirlerde tahminlerin nispeten seyrek olması bölgedeki sismik aktivitenin düşük frekanslı ancak yüksek magnitüdü olma eğiliminden kaynaklanabilir. Bu durum veri setindeki nadir büyük depremlerin model tarafından yeterince öngörülememesine de işaret etmektedir.

Deprem tahminlerinin yapıldığı tarihten sonra meydana gelen sismik olaylar incelendiğinde, İstanbul-Silivri'de gerçekleşen depremin (http-1) yapılan tahminlerle örtüştüğü görülmektedir. Benzer şekilde Kütahya'da meydana gelen depremlerle ilgili tahminlerin de oldukça gerçekçi olduğu anlaşılmaktadır (http-2). Muğla açıklarında Marmaris çevresinde gerçekleşen deprem ile Çanakkale Gökçeada'da meydana gelen deprem de yapılan tahminlerle büyük ölçüde örtüşmektedir (http-3, http-4).

Tarih-Magnitüd Korelasyonu:

Zayıf negatif korelasyon (**-0.355**), zaman içinde magnitüdde hafif bir azalma eğilimine işaret etse de bu ilişkinin istatistiksel anlamlılığı sınırlıdır. Sınırlı olması ise depremlerin magnitüdünün zamanla değişiminden ziyade veri setinin tarihsel kapsamındaki eksikliklerden veya sismik aktivitenin doğal dalgalanmalarından kaynaklanıyor olabilir.

Genel bağlamda coğrafi dağılım analizleri, karar ağacı modelinin aktif fay sistemleri ve tarihsel deprem verileri ile uyumlu tahminler ürettiğini ortaya koymuştur. Ancak özellikle büyük magnitüdü depremlerin nadirliği ve coğrafi heterojenlik, modelin sınırlılıklarını belirginleştirmiştir.

5.2.Öneriler

Büyük ölçekli depremler için düşük tahmin doğruluğu göz önünde bulundurularak modelin performansını iyileştirmek amacıyla farklı makine öğrenmesi tekniklerinin kullanılması önerilmektedir. Derin öğrenme tabanlı yaklaşımların entegrasyonu tahmin doğruluğunu arttıracaktır.

Tahmin doğruluğunu daha da artırabilmek adına sadece büyüklük ve derinlik gibi temel parametreler yerine zemin yapısı, fay hattı özellikleri, jeolojik formasyonlar, tektonik hareketlilik ve bölgesel gerilme oranları gibi ek değişkenler modele dâhil edilebilir. Ek değişkenler modelin karar mekanizmasını daha iyi yönlendirebilir ve büyük depremlerin öngörülmesinde daha yüksek başarı sağlanmasına yardımcı olabilir.

Deprem tahmin modelinin belirlediği riskli bölgeler ile gerçek sismik aktivite alanları arasındaki benzerliklerin daha ayrıntılı bir şekilde incelenmesi modelin güvenilirliğini artıracaktır. Belirli fay hatları boyunca gerçekleştirilecek detaylı mekânsal analizler modelin hangi bölgelerde daha yüksek doğrulukla çalıştığını ve hangi alanlarda başarısız tahminlerde bulunduğunu ortaya koyacaktır.

Geliştirilecek makine öğrenmesi modelleri zaman içinde optimize edilerek deprem erken uyarı sistemlerine entegre edilebilir. Gerçek zamanlı veri akışına dayalı bir tahmin mekanizması oluşturularak yüksek risk taşıyan bölgelerde alınabilecek önlemlerin daha etkin hale getirilmesi sağlanabilir. Böylece özellikle yoğun nüfuslu şehirlerde olası can ve mal kayıplarının en aza indirilmesine katkıda bulunulabilir.

Tez çalışmasının gösterdiği gibi Türkiye'nin farklı bölgelerinde farklı büyüklük ve derinliklerde depremler meydana gelmektedir. Bu nedenle bölgesel tahmin merkezleri kurulmalı ve her bölge için özel modeller geliştirilmeli bölgesel bazda deprem risk haritaları güncellenmelidir. Özellikle İstanbul, İzmir, Erzincan, Kahramanmaraş ve Muğla gibi yüksek riskli şehirlerde “*şehir özel*” deprem araştırma ve tahmin merkezleri kurulmalıdır. Bu merkezlerde makine öğrenmesi, doğal zaman analizi ve frekans büyüklük dağılımı gibi farklı analiz yöntemleri bir arada kullanılıp depremlerin gerçekleşmeden önce tahminlemesi yapılabilir.

KAYNAKÇA

- Abdullah, D. and Putra, E. D. (2018). Comparasi edge detection roberts dan morfologi pada deteksi plat nomor kendaraan roda dua. *Journal of Science and Applied Informatics*, 1(3), 66–69.
- Ahamed, S. and Daub, E. G. (2019). *Machine learning approach to earthquake rupture dynamics*. arXiv preprint arXiv:1906.06250.
- Ahmed, F., Akter, S., Rahman, S. M., Harez, J. B., Mubasira, A. and Khan, R. (2024). Earthquake Magnitude Prediction Using Machine Learning Techniques. In *2024 IEEE International Conference on Interdisciplinary Approaches in Technology and Management for Social Innovation (IATMSI)* (Vol. 2, pp. 1-5). IEEE.
- Akkoyunlu, M. F. (2021). Tarihsel depremler ve kullanılan yöntemler. *Avrupa Bilim ve Teknoloji Dergisi*, (21), 587-590.
- Al Banna, M. H., Taher, K. A., Kaiser, M. S., Mahmud, M., Rahman, M. S., Hosen, A. S. and Cho, G. H. (2020). Application of artificial intelligence in predicting earthquakes: state-of-the-art and future challenges. *IEEE Access*, 8, 192880-192923.
- Ardakani, A. and Kohestani, V. (2015). Evaluation of liquefaction potential based on CPT results using C4.5 decision tree. *Journal of AI and Data Mining*, 3, 85–92.
- Ardakani, A. and Kohestani, V. R. (2015). Evaluation of liquefaction potential based on CPT results using C4. 5 decision tree. *Journal of AI and Data Mining*, 3(1), 85-92.
- Asencio-Cortés, G., Martínez-Álvarez, F., Morales-Esteban, A. and Reyes, J. (2016). A sensitivity study of seismicity indicators in supervised learning to improve earthquake prediction. *Knowledge-Based Systems*, 101, 15-30.
- Asencio-Cortes, G., Martinez-Alvarez, F., Troncoso, A. and Morales-Esteban, A. (2017). Medium–large earthquake magnitude prediction in Tokyo with artificial neural networks. *Neural Computing and Applications*, 28, 1043-1055.
- Asim, K. M., Idris, A., Martínez-Álvarez, F. and Iqbal, T. (2016). Short term earthquake prediction in Hindukush region using tree-based ensemble learning. In *2016 International Conference on Frontiers of Information Technology (FIT)* (pp. 365–370). IEEE.
- Bakun, W. H., Gómez Capera, A. and Stucchi, M. (2011). Epistemic uncertainty in the location and magnitude of earthquakes in Italy from macroseismic data. *Bulletin of the Seismological Society of America*, 101(6), 2712–2725. <https://doi.org/10.1785/0120110118>
- Cai, Y., Shyu, M. L., Tu, Y. X., Teng, Y. T. and Hu, X. X. (2019). Anomaly detection of earthquake precursor data using long short-term memory networks. *Applied Geophysics*, 16, 257–266.

- Cassel, M. (2018). *Machine Learning and the Construction of a Seismic Attribute-seismic Facies Analysis Data Base*. (Master's thesis, University of Oklahoma). Retrieved from <https://shareok.org/>
- Chen, K. and Jarboe, K. P. (1980). Large scale decision tree optimization by branch and bound methods. *IFAC Proceedings Volumes*, 13(6), 339–348. [https://doi.org/10.1016/S1474-6670\(17\)64815-8](https://doi.org/10.1016/S1474-6670(17)64815-8)
- Chen, R., Chen, W., Yang, S., Wu, D., Wang, Y., Tian, Y. and Shi, Y. (2011). Rigorous assessment and integration of the sequence and structure based features to predict hot spots. *Bmc Bioinformatics*, 12, 1-14.
- Church, R. L. (2002). Geographical information systems and location science. *Computers & Operations Research*, 29(6), 541–562.
- Cürebil, İ. ve Özşahin, E. (2022). *Harita Bilgisi (Bilgisayar Uygulamalı Tasarım ve Analiz)*. Bursa, Türkiye: Ekin Basın Yayın Dağıtım.
- Demertzis, K., Kostinakis, K., Morfidis, K. and Iliadis, L. (2022). *A Comparative Evaluation of Machine Learning Algorithms for the Prediction of R/C Buildings' Seismic Damage*. arXiv preprint arXiv:2203.13449.
- Demirelli, E., Solak, H. İ. and Tiryakioğlu, İ. (2023). Makine öğrenmesi algoritmaları ile deprem katalogları kullanılarak deprem tahmini. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*, 13(4), 979-989.
- Demirtaş, R. ve Yılmaz, R. (1996). Türkiye'nin sismotektoniği. *Bayındırlık ve İskân Bakanlığı Yayınları, Ankara*, 37.
- Erdik, M. (2013). Earthquake risk in Turkey. *Science*, 341(6147), 724-725.
- Ermiş, İ. and Cürebil, İ. (2024). Earthquake Probability Prediction with Decision Tree Algorithm: The Example of Izmir, Türkiye. *Journal of Artificial Intelligence and Data Science*, 4(2), 59-67.
- Etiopie, G., Calcara, M. and Quattrocchi, F. (1997). Seismogeochemical algorithms for earthquake prediction: an overview. *Annals of Geophysics*, 40(6). Fong, S. (2013). Adaptive forecasting of earthquake time series by incremental decision tree algorithm. *International Information Institute (Tokyo). Information*, 16(12), 8387.
- Franke, T. M., Ho, T. and Christie, C. A. (2012). The chi-square test: Often used and more often misinterpreted. *American Journal of Evaluation*, 33(3), 448–458.
- Ghaedi, K. and Ibrahim, Z. (2017). Earthquake prediction. *Earthquakes-Tectonics, Hazard and Risk Mitigation*, 66, 205-227.
- Ghahraman, D. E., Wong, A. K. C. and Au, T. (1980). Graph optimal monomorphism algorithms. *IEEE Transactions on Systems, Man, and Cybernetics*, 10(4), 181–188. <https://doi.org/10.1109/TSMC.1980.4308468>
- Gordon, R. G. (1998). The plate tectonic approximation: Plate nonrigidity, diffuse plate boundaries, and global plate reconstructions. *Annual Review of Earth and Planetary Sciences*, 26(1), 615-642.
- Goswami, S., Chakraborty, S., Ghosh, S., Chakrabarti, A. and Chakraborty, B. (2018). A review on application of data mining techniques to combat natural disasters. *Ain Shams Engineering Journal*, 9(3), 365–378.

- Han, J., Kim, J., Park, S., Son, S. and Ryu, M. (2020). Seismic vulnerability assessment and mapping of Gyeongju, South Korea using frequency ratio, decision tree, and random forest. *Sustainability*, 12(18), 7787.
- Jiang, C., Wei, X., Cui, X. and You, D. (2009). Application of support vector machine to synthetic earthquake prediction. *Earthquake Science*, 22, 315–320.
- Kalafat, D., Güneş, Y., Kara, M., Deniz, P., Kekovalı, K., Kuleli, H. S., ... and Özel, M. (2007). Bütünleştirilmiş Homojen Türkiye Deprem Kataloğu (1900-2005; $M \geq 4.0$). *Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Deprem Kataloğu*. İstanbul, Turkey: Boğaziçi Üniversitesi Yayınları.
- Kalafat, D., Kekovalı, K., Akkoyunlu, F. and Ögütçü, Z. (2014). Source mechanism and stress analysis of 23 October 2011 Van Earthquake ($M_w = 7.1$) and aftershocks. *Journal of seismology*, 18, 371-384.
- Karbassi, A., Mohebi, B., Rezaee, S. and Lestuzzi, P. (2014). Damage prediction for regular reinforced concrete buildings using the decision tree algorithm. *Computers & Structures*, 130, 46-56.
- Karbassi, A., Mohebi, B., Rezaee, S. and Lestuzzi, P. (2014). Damage prediction for regular reinforced concrete buildings using the decision tree algorithm. *Computers & Structures*, 130, 46–56.
- Ketin, İ. (1968). Türkiye'nin genel tektonik durumu ile başlıca deprem bölgeleri arasındaki ilişkiler. *Bulletin of the Mineral Research and Exploration*, 71(71), 129-135.
- Khurshid, F. and Günal, A. Y. (2024). Harnessing earthquake generated glass and plastic waste for sustainable construction. *Turkish Journal of Engineering*, 8(2), 394-402.
- King, G. Q. (1991). Geography and GIS technology. *Journal of Geography*, 90(2), 66–72.
- Korkmaz, K. A. (2009). Earthquake disaster risk assessment and evaluation for Turkey. *Environmental Geology*, 57, 307-320.
- Kotsiantis, S. B. (2013). Decision trees: A recent overview. *Artificial Intelligence Review*, 39(3), 261–283.
- Li, A. and Kang, L. (2009). KNN-based modeling and its application in aftershock prediction. In *Proceedings of the 2009 International Asia Symposium on Intelligent Interaction and Affective Computing* (pp. 83–86).
- Lü, G., Batty, M., Strobl, J., Lin, H., Zhu, A. X. and Chen, M. (2019). Reflections and speculations on the progress in geographic information systems (GIS): A geographic perspective. *International Journal of Geographical Information Science*, 33(2), 346–367.
- Mignan, A. and Broccardo, M. (2020). Neural network applications in earthquake prediction (1994–2019): Meta-analytic and statistical insights on their limitations. *Seismological Research Letters*, 91(4), 2330-2342.
- Onat, O. and Tanyıldızı, H. (2024). Machine learning-based estimation of the out-of-plane displacement of brick infill exposed to earthquake shaking. *Engineering Applications of Artificial Intelligence*, 136, 109007.

- Otari, G. V. and Kulkarni, R. V. (2012). A review of application of data mining in earthquake prediction. *International Journal of Computer Science and Information Technology*, 3(2), 3570–3574.
- Özbaş, B. (2013). *Deprem sonrasında algılayıcılar kullanılarak geçiş alanlarında hasara bağlı blokaj tespiti* (Master's thesis, Fen Bilimleri Enstitüsü).
- Özdoğan, S. (1993). Türkiye'nin deprem bölgeleri. *Türkiye Coğrafyası Araştırma ve Uygulama Merkezi Dergisi*, 2(1), 53-68.
- Özmen, B. (2012). Türkiye deprem bölgeleri haritalarının tarihsel gelişimi. *Türkiye Jeoloji Bülteni*, 55(1).
- Rana, R. and Singhal, R. (2015). Chi-square test and its application in hypothesis testing. *Journal of Primary Care Specialties*, 1(1), 69–71.
- Ridzwan, N. S. M. and Yusoff, S. H. M. (2023). Machine learning for earthquake prediction: a review (2017–2021). *Earth Science Informatics*, 16(2), 1133-1149.
- Senkaya, M., Silahtar, A., Erkan, E. F. and Karaaslan, H. (2024). Prediction of local site influence on seismic vulnerability using machine learning: A study of the 6 February 2023 Türkiye earthquakes. *Engineering Geology*, 107605.
- Sethi, I. K. and Chatterjee, B. (1980). Conversion of decision tables to efficient sequential testing procedures. *Communications of the ACM*, 23(5), 279–285. <https://doi.org/10.1145/358855.358863>
- Sikder, I. and Munakata, T. (2009). Application of rough set and decision tree for characterization of premonitory factors of low seismic activity. *Expert Systems with Applications*, 36, 102–110.
- Sokolova, M., Japkowicz, N. and Szpakowicz, S. (2006). Beyond accuracy, F-score and ROC: A family of discriminant measures for performance evaluation. In *Australasian Joint Conference on Artificial Intelligence* (pp. 1015–1021). Springer.
- Somodevilla, M. J., Priego, A. B., Castillo, E., Pineda, I. H., Vilariño, D. and Nava, A. (2012). Decision support system for seismic risks. *Journal of Computer Science and Technology*, 12.
- Turhan, N. S. (2020). Karl Pearson's Chi-Square Tests. *Educational Research Review*, 16(9), 575–580.
- Westaway, R. O. B. (1994). Present-day kinematics of the Middle East and eastern Mediterranean. *Journal of Geophysical Research: Solid Earth*, 99(B6), 12071-12090.
- Xiong, P., Tong, L., Zhang, K., Shen, X., Battiston, R., Ouzounov, D., Iuppa, R., Crookes, D., Long, C. and Zhou, H. (2021). Towards advancing the earthquake forecasting by machine learning of satellite data. *Science of The Total Environment*, 771, 145256.
- ZeeAbrahamsen, E. and Haberman, J. (2018). Correcting ‘confusability regions’ in face morphs. *Behavior Research Methods*, 50(4), 1686–1693.
- Zhang, J. (2021). *Dive into Decision Trees and Forests: A Theoretical Demonstration*. arXiv preprint arXiv:2101.08656

- http-1:** https://tr.wikipedia.org/wiki/2025_%C4%B0stanbul_depremi#cite_note-15 (Eriřim Tarihi: 01.07.2025)
- http-2:** <https://www.ntv.com.tr/turkiye/son-dakika-kutahyada-deprem-mi-oldu-az-once-deprem-kutahyada-nerede-oldu-kutahya-deprem-kandilli-ve-afad-son-depremler-listesi-23-mayis-2025,mWfv6iw4BUiiSWnt1hGlaw> (Eriřim Tarihi: 01.07.2025)
- http-3:** <https://www.bbc.com/turkce/articles/cn7z8mlx73do> (Eriřim Tarihi: 01.07.2025)
- http-4:** <https://www.cumhuriyet.com.tr/turkiye/canakkale-ve-akdeniz-de-deprem-5-haziran-2025-nerede-ne-zaman-deprem-oldu-2406993> (Eriřim Tarihi: 01.07.2025)

