

## Hızlı Değerlendirme Yöntemleri ve Makine Öğrenmesi Kullanılarak Binaların Sismik Performansının Tahmini: Elazığ ili Örneği

Rabia Nur SAĞLAM<sup>1\*</sup>, Muhammed Veysi GÜLER<sup>2</sup>, Mustafa ULAŞ<sup>3</sup>, Kürşat Esat ALYAMAÇ<sup>4</sup>

<sup>1,4</sup> İnşaat Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

<sup>2,3</sup> Fırat Üniversitesi, Mühendislik Fakültesi, Yapay Zeka ve Veri Mühendisliği Bölümü, Elazığ, Türkiye

<sup>\*1</sup> rabianaydin@gmail.com, <sup>2</sup> mvguler@firat.edu.tr, <sup>3</sup> mustafaulas@firat.edu.tr, <sup>4</sup> kealyamac@firat.edu.tr

(Geliş/Received: 24/06/2025;

Kabul/Accepted:07/02/2026)

**Öz:** Bu çalışmanın amacı Elazığ ilindeki mevcut binaların sismik performans düzeylerinin hızlı ve veri odaklı yöntemlerle yüksek doğrulukta tahmin edilmesidir. Bu kapsamda Elazığ Merkez mahallelerinde yapılan saha çalışmaları kapsamında toplam 4200 adet bina incelenmiştir. Elde edilen bina verileri, Kanada Sismik Tarama Yöntemi ve Hindistan Hızlı Görsel Değerlendirme yöntemi kullanılarak her bina için performans puanları hesaplanmıştır. Elde edilen puanlar, yapıların potansiyel deprem riski açısından sınıflandırılmasında referans olarak kullanılmıştır. Çalışmanın ikinci aşamasında, bu performans puanlarının yüksek doğrulukta tahmin edilmesi için XGBoost makine öğrenmesi modeli kullanılmıştır. Modelde girdi olarak sahadan alınan binaya ait kimlik bilgileri ve yapısal özellikler kullanılmıştır. Modelin hedef çıktısı olarak ise, bu yöntemlerle hesaplanan performans puanları belirlenmiştir. XGBoost modeli, doğruluk ve hata metrikleri açısından karşılaştırılarak performansları değerlendirilmiştir. Sonuçlar, uluslararası hızlı değerlendirme yöntemlerinin saha verileri ile desteklendiğinde etkili sonuçlar verdiğini ve makine öğrenmesi modelleriyle entegre edildiğinde bina performanslarının yüksek doğrulukla tahmin edilebildiğini ortaya koymaktadır. Bu yaklaşım, özellikle afet öncesi ve sonrası risk yönetimi ve müdahale planlaması süreçlerinde karar vericilere hızlı ve güvenilir bilgi sağlamayı amaçlamaktadır.

**Anahtar kelimeler:** Hızlı değerlendirme yöntemleri, Hindistan hızlı görsel değerlendirme, Kanada sismik tarama, makine öğrenmesi yöntemleri, sismik performans tahmini

### Seismic Performance Prediction of Buildings Using Rapid Assessment Methods and a Machine Learning-Based Approach: A Case Study of Elazığ Province

**Abstract:** The aim of this study is to estimate the seismic performance levels of existing buildings in Elazığ province with high accuracy using fast and data-driven methods. In this context, performance scores were calculated for each building by using building data obtained as a result of field investigations, Canadian Seismic Screening Method and Indian Rapid Visual Assessment methods. The obtained scores were used as a reference to classify the buildings in terms of potential earthquake risk. In the second stage of the study, the XGBoost machine learning model was used to predict these performance scores with high accuracy. Identification information and structural characteristics of the building taken from the field were used as input. The calculated performance scores were used as output. The XGBoost model was compared in terms of accuracy and error metrics and their performances were evaluated. The results show that international rapid assessment methods provide effective results when supported with field data and when integrated with machine learning models, building performances can be predicted with high accuracy. This approach aims to provide fast and reliable information to decision makers, especially in pre- and post-disaster risk management and response planning processes.

**Keywords:** Rapid assessment methods, India rapid visual screening, Canada seismic screening, machine learning methods, seismic performance prediction

#### 1. Giriş

Türkiye'nin birçok bölgesinde, özellikle de Doğu ve Güneydoğu Anadolu'da son yıllarda yaşanan büyük depremler, yapı güvenliğinin ne kadar önemli bir konu olduğunu tekrar hatırlatmıştır. 6 Şubat 2023 tarihinde Kahramanmaraş merkezli olarak meydana gelen ve 11 ili etkileyen 7.7 ve 7.6 büyüklüğündeki depremler, çok geniş bir coğrafyada büyük yıkımlara neden olmuş ve binlerce yapının tamamen ya da kısmen hasar görmesine yol açmıştır. Bu yıkım, sadece afet sonrası müdahalelerin değil, aynı zamanda afet öncesi risk tespiti ve müdahale planlamasının ne kadar önemli olduğunu açıkça ortaya koymuştur [1]. Aynı şekilde, 24 Ocak 2020'de Elazığ-

\* Sorumlu yazar: [rabianaydin@gmail.com](mailto:rabianaydin@gmail.com) Yazarların ORCID Numarası: <sup>1</sup>0000-0003-3015-0766, <sup>2</sup>0009-0002-8350-9808, <sup>3</sup>0000-0002-0096-9693, <sup>4</sup>0000-0002-3226-4073

Sivrice merkezli 6.8 büyüklüğündeki depremde bölgedeki yapı stokunun durumu hakkında önemli ipuçları sunmuş; yapıların çoğunun mühendislik hizmeti almadan inşa edildiği, düzensiz plan şemalarına ve yetersiz malzeme kalitesine sahip olduğu gözlemlenmiştir [2].

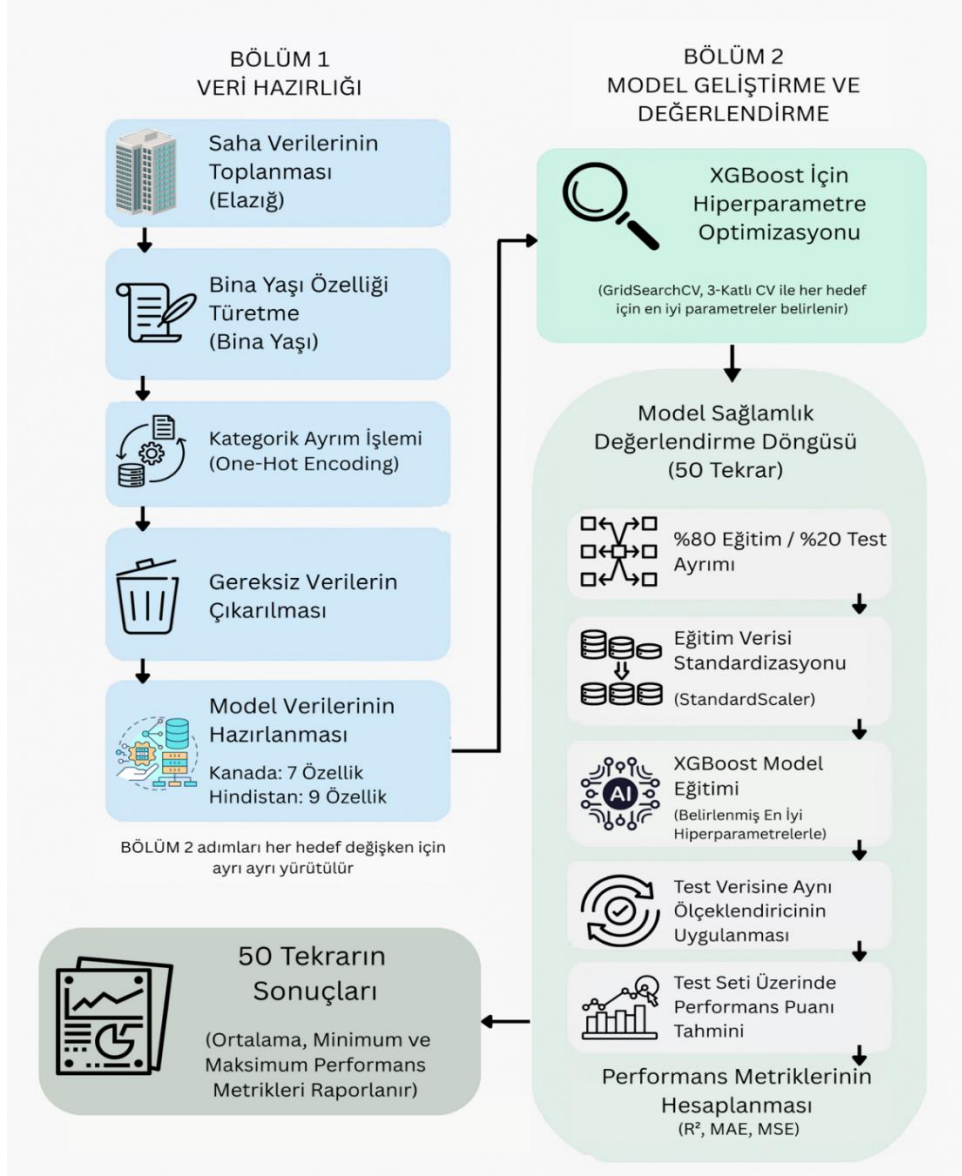
Yapıların depreme karşı güvenliğini değerlendirmek için kullanılan geleneksel yöntemler, detaylı mühendislik analizleri ve saha testleri gerektirmektedir. Bu aşamalar her bir yapı için zaman, iş gücü ve maliyet açısından büyük bir yük oluşturmaktadır. Bu nedenle, özellikle afet öncesi risk yönetimi ve önceliklendirme çalışmalarında hızlı, pratik ve ekonomik olan alternatif yöntemlere ihtiyaç giderek artmaktadır. Bu ihtiyaca cevap olarak geliştirilen hızlı değerlendirme yöntemleri, yapıların temel özelliklerine ve görsel incelemelere dayalı olarak kısa sürede ön değerlendirme yapılmasına olanak tanımaktadır. Hindistan Hızlı Görsel Değerlendirme ve Kanada Sismik Tarama gibi yöntemler, saha gözlemlerine dayalı olarak yapıların sismik performans puanlarını hızlı şekilde hesaplamayı mümkün kılan yöntemler olarak öne çıkmaktadır [3, 4]. Bu yöntemlerden Kanada Sismik Tarama, yapının kat sayısı, yapısal düzensizlikleri, kullanım türü, zemin sınıfı gibi çeşitli parametreleri göz önünde bulundurarak her bina için bir risk puanı oluşturmakta; bu puan doğrultusunda binaların performans puanına göre risk seviyesi sınıflandırılmasına olanak tanımaktadır [5]. Kanada Ulusal Araştırma Konseyi tarafından önerilen ve özellikle konut tipi yapılarda tercih edilen bir değerlendirme sistemidir [6]. Hindistan hızlı görsel tarama yönteminde ise binanın kat sayısı yapısal düzensizlikleri gibi özellikleri kullanılarak performans puanı hesaplanır. Bu yöntemde ise risk seviyesi gruplandırması bulunmamaktadır. Bina performans puanlarına göre risk önceliklendirmesi şeklinde olan bir yöntemdir [3].

Literatürde, bu tür hızlı değerlendirme yöntemlerinin saha verileriyle uygulanarak bina risk analizinde kullanılmasına yönelik pek çok çalışma bulunmaktadır. Örneğin, Gülkan ve Langenbach [7], Türkiye'deki yapı stokunun risk düzeyinin belirlenmesinde hızlı değerlendirme yöntemlerinin avantajlarını vurgulamıştır. Akkar ve vd. [8], saha verileriyle desteklenmiş hızlı tarama formlarının özellikle orta büyüklükteki kentlerdeki risk haritalaması açısından önemine dikkat çekmiştir. Ayrıca, Kanada Sismik Tarama ve Hindistan Hızlı Görsel Değerlendirme gibi yöntemlerin, yerel yapı tipleriyle uyumlaştırıldığında önemli ölçüde güvenilirlik kazandığı belirtilmiştir. Bununla birlikte, bu çalışmalar çoğunlukla puanlama sistemleriyle sınırlı kalmakta ve ileri analiz teknikleriyle entegrasyon açısından sınırlı bir çerçeve sunmaktadır. Bu durum, veri odaklı modelleme yaklaşımlarının yapı performansı tahmin süreçlerine entegre edilmesinin gerekliliğini ortaya koymaktadır.

Makine öğrenmesi gibi modern veri analizi teknikleri, büyük veri setlerinden anlamlı desenler çıkararak geleceğe dönük tahminlerde bulunabilme yetenekleri sayesinde, yapı mühendisliği alanında giderek daha yaygın biçimde kullanılmaktadır [9]. Yapay sinir ağları, karar ağaçları, destek vektör makineleri gibi çeşitli algoritmalar, yapıların fiziksel özellikleri ile sismik performansları arasında korelasyon kurarak etkili tahminler üretebilmektedir [10]. Literatürde Makine öğrenmesi teknikleri, beton dayanımı tahmini, zemin sınıflandırması, yapı hasar düzeyi tespiti gibi birçok mühendislik problemine başarıyla uygulanmıştır [11,12]. Özellikle son yıllarda yapılan çalışmalar, makine öğrenmesi algoritmalarının farklı yapısal sistemlerin sismik davranışını ve hasar durumlarını tahmin etmedeki yüksek potansiyelini ortaya koymaktadır. Bu çalışmalar, çelik çerçevelerin sismik performans tahmininden [13], betonarme çerçevelerin hasar durumu değerlendirmesine [14] ve ahşap yapıların sismik belirsizlikler altındaki davranışına [15] kadar geniş bir yelpazeyi kapsamaktadır. Bu güncel yaklaşımlar, genellikle geleneksel yöntemlere kıyasla daha hızlı ve kapsamlı analizler sunmaktadır [16].

Bu çalışmada, Elazığ ili özelinde saha verileriyle toplanan mevcut yapı bilgilerinden faydalanılarak, Kanada sismik tarama ve Hindistan hızlı görsel değerlendirme yöntemleri aracılığıyla elde edilen sismik performans puanlarının, makine öğrenmesi temelli modellerle tahmin edilmesi hedeflenmiştir. Bu bağlamda, veri odaklı yaklaşımla klasik yöntemlerin bütünleştirilmesi, bina sismik risk önceliklendirilmesinin daha hızlı ve güvenilir şekilde yapılmasına olanak sağlamaktadır. Ancak hızlı değerlendirme yöntemlerinin pratik avantajlarına rağmen, bu yöntemler genellikle sabit ve sınırlı sayıda parametreye dayalı statik puanlama sistemleri ile çalışmakta ve farklı yapı tipolojileri ya da yerel zemin koşullarına karşı duyarlılıkları sınırlı kalabilmektedir. Ayrıca, bu yöntemler kapsamında hesaplanan risk puanlarının gerçek hasar durumlarını ne ölçüde yansıttığı çoğu zaman test edilmemekte ya da yalnızca sınırlı sayıda vaka üzerinden doğrulanmaktadır. Bu bağlamda, farklı bölgelerden toplanan saha verilerinin analitik modellerle değerlendirilerek, puanlama sistemlerinin çıktılarının doğruluğunun artırılması kritik bir ihtiyaç olarak öne çıkmaktadır. Bu çalışmada önerilen yaklaşım, Kanada ve Hindistan hızlı değerlendirme yöntemlerinin yapı bazlı saha verileri üzerinden hesapladığı sismik performans puanlarının, makine öğrenmesi modelleriyle tahmin edilmesini sağlayarak bu yöntemlerin öngörü gücünü test etmeyi ve iyileştirmeyi amaçlamaktadır. Böylece, hem mevcut yöntemlerin doğruluğu değerlendirilebilmekte hem de sınırlı saha gözlemine dayalı tahminlerin daha geniş alanlara genellenebilmesi için güçlü bir modelleme çerçevesi

sunulmaktadır. Söz konusu modelleme sürecine ait genel akış, Şekil 1’de gösterilmiştir. Elde edilen sonuçlar, afet öncesi karar alma süreçlerine bilimsel ve teknolojik katkı sunmayı amaçlamaktadır.



Şekil 1. Çalışmanın akış diyagramı

## 2. Materyal ve Yöntem

Bu çalışma iki temel aşamada gerçekleştirilmiştir. İlk aşamada, Elazığ ili merkezinde yer alan yapıların AFAD Udap projesi kapsamında saha çalışması yapılmış ve bina kimlik ve yapısal bilgilerine ait veriler toplanmış; bu veriler kullanılarak hızlı değerlendirme yöntemleri olan Kanada Sismik Tarama ve Hindistan Hızlı Görsel Değerlendirme yöntemlerine göre yapıların sismik performans puanları hesaplanmıştır. İkinci aşamada ise, bu puanlar makine öğrenme modellerinde çıktı olarak ele alınmış ve ilgili yapısal veriler makine öğrenmesi algoritmalarına girdi olarak sunulmuş tahmin modelleri oluşturulmuştur. Bu bütünlük yaklaşım, hem hızlı değerlendirme yöntemlerinin yerel verilere dayalı olarak uygulanabilirliğini test etmeyi hem de makine öğrenmesi teknikleriyle desteklenen veri odaklı modellerin tahmin gücünü ortaya koymayı amaçlamaktadır.

## 2.1. Çalışma alanı ve veri toplama süreci

Çalışma alanı olarak, deprem riski yüksek ve yapı stoğu büyük ölçüde eski olan Elazığ ili seçilmiştir. Saha çalışmaları, il merkezinin farklı mahallelerinde yer alan toplam 4200 betonarme yapı üzerinde yürütülmüştür. Binalar genellikle 3 ila 7 kat arasında değişen, betonarme taşıyıcı sisteme sahip konut yapılarından oluşmaktadır. Her bir bina için; yapı tipi, taşıyıcı sistem, kat sayısı, cephe uzunluğu, plan geometrisi, zemin sınıfı, inşaa yılı, çıkma varlığı, kısa kolon veya yumuşak kat gibi düzensizlikler, kullanım amacı gibi toplam 16 farklı parametre toplanmıştır. Veriler hem doğrudan gözlemlerle hem de yapı sakinleri aracılığıyla elde edilmiştir. Elde edilen veriler eksiksizleştirildikten sonra sayısal analize uygun formata göre düzenlenmiştir.

## 2.2. Hızlı değerlendirme yöntemleri

Hızlı değerlendirme yöntemi binanın kısmen içerden çoğunlukla dışarıdan gözlemlenerek bina bilgilerinin ve yapısal kusurlarının (yumuşak kat, zayıf kat, ağır çıkma, kısa kolon, plan düzensizlikleri, çarpıma etkisi vb.) kaydedildiği bir değerlendirme yöntemidir. Öncelikli bina risk tespiti için ilk adım sokak taraması yapılarak yöntemlerde kullanılan ve bina deprem performansının üzerinde etkili olan parametrelerin gözlemlenerek belirlenmesidir. Gözlenen veriler daha sonra veri formlarına işlenerek kaydedilir. Son olarak gözlenen veriler kullanılarak belirlenen hızlı değerlendirme yöntemine göre puanlama yapılır. ABD’de geliştirilen FEMA P-154 – Rapid Visual Screening (RVS) yöntemi, saha gözlemleriyle binaların yapısal özelliklerini değerlendirerek yaklaşık performans puanı hesaplayan ve diğer birçok yöntemle temel oluşturan yaklaşımdır. Avrupa’da ve Asya ülkelerinde bu yöntemi temel alan çeşitli ulusal modeller geliştirilmiştir. Türkiye’de ise 2018 yılında yürürlüğe giren Türkiye Bina Deprem Yönetmeliği (TBDY, 2018) kapsamında, mevcut binaların deprem performanslarının ön değerlendirmesine yönelik esaslar tanımlanmıştır. Ayrıca, Çevre, Şehircilik ve İklim Değişikliği Bakanlığı tarafından yürütülen RYTEİE (Riskli Yapıların Tespit Edilmesine İlişkin Esaslar) uygulamaları, sahada kullanılan en yaygın ulusal hızlı değerlendirme yöntemidir.

Bu çalışma kapsamında, Kanada Sismik Tarama Yöntemi ve Hindistan Hızlı Görsel Değerlendirme Yöntemi seçilmiştir. Kanada yöntemi, yapısal (SI) ve yapısal olmayan (NSI) parametreleri birlikte değerlendirerek detaylı bir puanlama sistemi oluşturur. Bu yönüyle Kanada yöntemi, veri kalitesi yüksek ve parametrik analiz yapılabilen çalışmalarda tercih edilmektedir.

Hindistan Hızlı Görsel Değerlendirme Yöntemi ise saha gözlemlerine dayalı pratik bir sistemdir. Parametreler (bina yaşı, kat sayısı, yumuşak kat, kısa kolon, düzensizlik vb.) belirli değerler atanarak puanlanır. Bu yöntem, Türkiye’de uygulanan RYTEİE yaklaşımına benzer bir gözlemsel yapıya sahip olması nedeniyle çalışmada tercih edilmiştir. Böylece uluslararası geçerliliğe sahip iki farklı yaklaşımın karşılaştırılması mümkün olmuştur.

Her iki yöntemin seçimi, hem veri yapısının uygunluğu hem de literatürde sık kullanılan sistemlerle kıyaslanabilirlik sağlaması açısından yapılmıştır.

Bu çalışma kapsamında Kanada sismik tarama ve Hindistan hızlı görsel değerlendirme yöntemleri kullanılacaktır.

### 2.2.1. Kanada sismik tarama

Kanada Sismik Tarama Yöntemi, National Research Council Canada tarafından geliştirilen, yapıların saha verilerine dayalı olarak deprem performanslarının hızlı şekilde değerlendirilmesini sağlayan bir yaklaşımdır. Bu yöntemde, yapı özellikleri değerlendirilerek her birine belirli ağırlıklar atanmakta ve toplam risk puanı hesaplanmaktadır. Bu başlıklar arasında simetrik plan varlığı, yapısal sistem tipi (çerçeve, perde vs.), kat yüksekliği, komşu binalarla ilişki, zemin türü, düzensizlikler gibi kriterler yer almaktadır. Her bir kriterin yapının davranışına etkisi göz önünde bulundurularak risk puanına katkısı belirlenmekte, sonuçta bina düşük, orta veya yüksek riskli olarak sınıflandırılmaktadır [4].

Kanada Sismik Tarama Yöntemi, yapıların deprem riskini belirlemek amacıyla yapısal indeks (SI) ve yapısal olmayan indeks (NSI) olmak üzere iki ana bileşen kullanır. SI, beş temel parametreden oluşur: deprensellik (A), zemin koşulları (B), taşıyıcı sistem türü (C), düzensizlik katsayısı (D) ve bina önem katsayısı (E). Bu parametrelerin çarpımıyla yapıların yapısal indeks değeri (Denklem 1) hesaplanır.

Her parametre için farklı kategoriler ve puan aralıkları tanımlanmıştır. Örneğin deprensellik puanı 1–4 arasında (1: düşük, 4: yüksek), zemin koşulları 1–4 arasında (1: kaya zemin, 4: çok zayıf zemin), taşıyıcı sistem türü 1–3 arasında (1: sünek sistem, 3: kırılğan sistem) değer alır. Düzensizlik katsayısı 1.0–2.0 aralığında olup

planda veya düşeyde düzensizlik bulunan yapılarda artmaktadır. Bina önem katsayısı, kullanım yoğunluğu ve bina işlevine göre 0.7–3.0 aralığında değişmektedir.

Yapısal olmayan indeks (NSI), binadaki cephe elemanları, parapet, baca, giydirme cephe gibi tehlikeli unsurları temsil eden F, G ve H katsayılarının çarpımıyla hesaplanır (Denklem 2). Her bir katsayı 1–6 aralığında değer alır. Kanada sismik tarama yönteminde puan hesabı Denklem 1’de gösterildiği üzere yapısal (SI) ve yapısal olmayan (NSI) indeksleri birleştirerek yapılan sismik öncelik indeksini (SPI) hesaplamaktır.

Elde edilen SPI değeri binanın incelenme önceliğini belirtir.  $SPI > 30$  olan yapılar “çok tehlikeli”, 20–30 aralığı “yüksek öncelikli”, 10–20 aralığı “orta öncelikli”,  $<10$  ise “düşük öncelikli” olarak değerlendirilir. Bu yöntem, parametrik puanlama yapısıyla binaları sayısal öncelik sırasına koymayı mümkün kılmaktadır.

Bu çalışmada, Kanada yöntemi ayrıntılı parametre tanımları ve puanlama yapısı nedeniyle seçilmiş, Hindistan yöntemiyle birlikte karşılaştırmalı analiz yapılmıştır.

$$SPI = SI + NSI \quad (1)$$

Kanada sismik tarama puanlama hesabında yapısal indeks (SI) Denklem 2’de gösterilen şekilde hesaplanmaktadır.

$$SI = A \times B \times C \times D \times E \quad (2)$$

Burada;

A: Depremsellik puanı

B: Zemin koşulları puanı,

C: Taşıyıcı sistem tipi puanı,

D: Döşeme sistemi puanı,

E: Düzensizlik puanı,

Binanın genel durumu ve yapısal olmayan indeksleri içeren (NSI) Denklem 3’ te gösterilen şekilde hesaplanmaktadır.

$$NSI = B \times F \times G \times H \quad (3)$$

Burada;

F: Bina önemi puanı,

G: Binanın durumu puanı,

H: Yapısal olmayan elemanlar puanı

Denklem sonucunda elde edilen sismik indeks puanı limit puan ile karşılaştırılarak detaylı analiz için öncelikli binalar belirlenir. Limit puana göre binaların sismik performans değerlendirmesi ve öncelik sıralaması Tablo 1’ de verilmiştir.

**Tablo 1.** Kanada sismik tarama öncelik indeksi

Sınır Değeri	Sonuç
>30	Çok Tehlikeli Yapı
>20	Yüksek Öncelikli Yapı
10-20	Orta Öncelikli Yapı
<10	Düşük Öncelikli Yapı

### 2.2.2. Hindistan hızlı görsel değerlendirme

Bu yöntem, Hindistan Ulusal Afet Yönetimi Kurumu tarafından yayımlanan rehberde göre yapıların fiziksel özelliklerini gözlemleyerek hızlı bir puanlama yapılmasını sağlamaktadır. Yöntem, yapının kullanım amacı, taşıyıcı sistem tipi, düzensizlik durumu, zemin türü, bina yüksekliği gibi parametrelere dayanır. Hindistan Hızlı Görsel Değerlendirme Yöntemi, ABD’de geliştirilen FEMA P-154 ve Türkiye’de uygulanan RYTEİE (Riskli Yapıların Tespit Edilmesine İlişkin Esaslar) yöntemlerini temel olarak oluşturulmuştur. Hindistan’daki bina inşaat

özelliklerinin Türkiye'deki yapı stoğuna benzer olması nedeniyle, bu yöntem saha koşullarına uygun pratik bir sistem sunmaktadır.

Yöntemde binalar dört sismik tabakada değerlendirilir: çok yüksek risk, yüksek risk, orta risk ve düşük risk bölgeleri. Her bina için bir taban puanı (BS) belirlenir; bu puan bina kat sayısı ve sismik tabaka düzeyine göre değişir. Daha sonra, binada gözlenen düzensizliklerin etkisini temsil eden düzensizlik katsayısı (VSM) ile düzensizlik puanı (VS) çarpılarak taban puanına eklenir. Böylece toplam performans puanı (PS), Denklem (4) ile hesaplanır:

Burada PS, bina performans puanını; BS, taban puanını; VSM, düzensizlik katsayısını; VS ise düzensizlik puanını temsil eder. Parametreler arasında bina kat sayısı, taşıyıcı sistem, planda düzensizlik, kısa kolon, çarpışma etkisi, yumuşak kat, zemin durumu, ağır çıkma ve görünen kalite gibi özellikler yer alır.

Puanlama sisteminde daha yüksek sismik tehlike ve kat sayısı, daha düşük performans puanına karşılık gelmektedir. Dolayısıyla düşük PS değeri, binanın daha yüksek riskte olduğunu göstermektedir. Bu yöntem, RYTEİE'ye benzer biçimde mutlak bir risk sınıfı üretmemekte; ancak puanlar arası karşılaştırma ile öncelikli riskli bölgelerin veya yapıların belirlenmesine olanak tanımaktadır. Bu yönüyle, hızlı görsel değerlendirme süreçlerinde kullanılabilecek rasyonel ve sahaya uyarlanabilir bir yöntemdir.

$$PS = (BS) + \sum[(VSM) \times (VS)] \quad (4)$$

### 3. Makine Öğrenmesi Modeli Geliştirme Süreci

Bu çalışmada, Elazığ ilindeki binaların Kanada Sismik Tarama ve Hindistan Hızlı Görsel Değerlendirme yöntemleriyle hesaplanan performans puanlarını tahmin etmek amacıyla XGBoost makine öğrenmesi algoritması kullanılmıştır. Geliştirilen modellerin amacı, bu geleneksel yöntemlerin çıktılarının yapısal özelliklere dayalı olarak ne kadar doğru ve hızlı bir şekilde tahmin edilebileceğini araştırmaktır. Makine öğrenmesi süreci; veri ön işleme, özellik seçimi, model eğitimi ve performans değerlendirme adımlarını kapsamaktadır.

#### 3.1. Veri ön işleme ve özellik seçimi

Makine öğrenmesi modelinin etkin bir şekilde çalışabilmesi için, Bölüm 2.1'de detaylandırılan ve Elazığ il merkezindeki saha çalışmalarından elde edilen bina verileri üzerinde kapsamlı bir ön işleme süreci uygulanmıştır. İlk olarak, 'Bina İnşa Yılı' verisi kullanılarak, her bir yapı için 'Bina Yaşı' adında yeni bir özellik türetilmiştir. Bu, binaların zaman içindeki potansiyel yıpranma durumunu yansıtmaya açısından önemlidir. Ardından, modelin doğrudan işleyemeyeceği kategorik yapıda olan ve Kanada Sismik tarama/Hindistan Hızlı Görsel Değerlendirme yönteminde kullanılan temel özellikler (örneğin, Taşıyıcı Sistem Tipi, Bina Nizamı, Kısa Kolon Varlığı, Planda Düzensizlik Durumu, Yumuşak Kat Durumu, Zayıf Kat Durumu) One-Hot Encoding (OHE) yöntemiyle sayısal vektörlere dönüştürülmüştür. Bu dönüşüm için OHE yönteminin tercih edilmesinin temel sebebi, 'Taşıyıcı Sistem Tipi' gibi model girdisi olarak kullanılan kategorik değişkenlerin herhangi bir sıralama ilişkisi (ordinalite) içermemesidir. OHE, her bir kategoriye bağımsız bir ikili (binary) sütun olarak temsil ederek, modelin bu kategoriler arasında var olmayan hiyerarşik bir ilişki (örneğin, yığma < betonarme) öğrenmesini engeller. Label Encoding gibi alternatif yöntemler ise bu tür nominal değişkenlerde yanıltıcı bir sıralama algısı oluşturabileceğinden, modelin performansını olumsuz etkileme potansiyeli nedeniyle tercih edilmemiştir. Bu dönüşüm, her bir kategorik değeri ayrı bir ikili (0 veya 1) sütun olarak temsil ederek modelin bu bilgileri kullanabilmesini sağlamıştır. Son olarak, analiz için gereksiz olduğu düşünülen veya model performansına katkısı olmayacak tanımlayıcı bilgiler (örneğin, bina adresi, fotoğraf referansları vb.) ve OHE sonrası oluşan orijinal kategorik sütunlar veri setinden çıkarılmıştır. Bu eleme süreci, herhangi bir istatistiksel değişken seçim algoritmasına dayanmamaktadır. Çıkarılan öznelikler (bina adresi, fotoğraf referansları vb.), modelin hedefi olan sismik performans puanını doğrudan etkileyecek yapısal bir bilgi içermemeleri, yani anlamsal olarak ilgisiz olmaları nedeniyle veri setinden arındırılmıştır. Bu yaklaşımın amacı, modelin ezberleme riskini azaltmak ve yalnızca binanın fiziksel özelliklerine odaklanarak daha genellenebilir bir öğrenme süreci sağlamaktır. Yapılan kontrollerde analiz için kritik öneme sahip veriye rastlanmamıştır.

Hindistan Hızlı Görsel Değerlendirme yöntemi için model girdisi olarak 9 bina yapısal özelliği (Bina Yaşı, Serbest Kat Adedi, Çıkma (cm), Taşıyıcı Sistem Türü, Kısa Kolon Durumu, Bina Nizamı, Planda Düzensizlik Durumu, Yumuşak Kat Durumu, Zayıf Kat Durumu) kullanılmıştır. Kanada Sismik Tarama yöntemi için ise 7 yapısal özelliği (Bina Yaşı, Taşıyıcı Sistem Türü, Kısa Kolon Durumu, Bina Nizamı, Planda Düzensizlik Durumu,

Yumuşak Kat Durumu, Zayıf Kat Durumu) girdi olarak belirlenmiştir. Her iki yöntem için de çıktı değişkeni (tahmin edilmek istenen değer), ilgili hızlı değerlendirme yöntemiyle hesaplanan bina performans puanıdır. Bu çalışma kapsamında Hindistan Hızlı Görsel Değerlendirmesi için 3336 bina, Kanada Sismik Tarama Yöntemi için ise 4097 bina kaydı analizlerde kullanılmıştır.

### 3.2. Model eğitimi ve doğrulama

XGBoost, Chen ve Guestrin tarafından geliştirilen ve gradyan artırma (gradient boosting) tekniğine dayalı, yüksek performanslı bir topluluk öğrenmesi algoritmasıdır [13]. Algoritma, zayıf öğreniciler olarak kabul edilen karar ağaçlarını (decision trees) sıralı bir şekilde eğiterek çalışır. Her yeni ağaç, önceki ağaçların yaptığı hataları (artıkları) minimize etmeye odaklanır. XGBoost'un gücü, kayıp fonksiyonuna eklenen ve modelin karmaşıklığını cezalandıran L1 (Lasso) ve L2 (Ridge) regularizasyon terimlerinden gelir. Bu regularizasyon, ezberlemeyi (overfitting) önleyerek modelin genelleme kabiliyetini artırır.

XGBoost'un amacı, tahmin hatası ile regularizasyon teriminin toplamından oluşan amaç fonksiyonunu (Obj) minimize etmektir. K adet ağaçtan oluşan bir model için t-inci iterasyondaki amaç fonksiyonu Denklem 5' teki gibi ifade edilebilir:

$$\text{Obj}^{(t)} = \sum_{i=1}^n \left[ y_i - \left( \widehat{y}_i^{(t-1)} + f_t(x_i) \right) \right]^2 + \Omega(f_t) + \text{sabit} \quad (5)$$

Burada,  $\sum_i [y_i - (\widehat{y}_i^{(t-1)} + f_t(x_i))]^2$  tahmin hatasını (kayıp fonksiyonu),  $\Omega(f_t)$  ise t-inci ağacın karmaşıklığını cezalandıran regularizasyon terimini temsil eder. Regularizasyon terimi Denklem 6' da gösterilmiştir:

$$\Omega(f_t) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (6)$$

Bu denklemde, T ağaçtaki yaprak sayısı, w yaprakların skorları,  $\gamma$  ve  $\lambda$  ise regularizasyon katsayılarıdır. Algoritma, her adımda bu amaç fonksiyonunu minimize edecek yeni bir  $f_t$  ağacı bularak modeli aşamalı olarak iyileştirir.

XGBoost algoritması, her bir hedef değişken (Kanada Sismik Tarama puanı ve Hindistan Hızlı Görsel Değerlendirme puanı) için ayrı ayrı olmak üzere geliştirilmiş ve eğitilmiştir. Model geliştirme ve doğrulama süreci aşağıdaki temel adımları içermiştir:

- Hiperparametre Optimizasyonu: XGBoost modelinin her bir hedef değişken için en iyi tahmin performansını sergilemesini sağlamak amacıyla, temel hiperparametreleri optimize edilmiştir. Bu kapsamda, 'maksimum derinlik' (max\_depth: [3, 6, 10]), 'öğrenme oranı' (learning\_rate: [0.01, 0.05, 0.1]), 'ağaç sayısı' (n\_estimators: [50, 100, 150]) ve 'alt örneklem oranı' (subsample: [0.6, 0.8, 1.0]) gibi parametreler için GridSearchCV yöntemi kullanılarak bir arama yapılmıştır[14]. Optimizasyon süreci, 3-katlı çapraz doğrulama (cv=3) tekniği ile ve Negatif Ortalama Karesel Hata ('neg\_mean\_squared\_error') metriği hedeflenerek, eğitim verisinin bir alt kümesi üzerinde her bir hedef değişken için ayrı ayrı gerçekleştirilmiştir. Bu şekilde her bir puanlama sistemine özel en iyi hiperparametre setleri belirlenmiştir.
- Model Eğitimi ve Değerlendirme Döngüsü: Her bir hedef değişken için GridSearchCV ile belirlenen en iyi hiperparametre seti sabit tutularak, modelin performansının sağlamlığını ve elde edilen sonuçların tekrarlanabilirliğini değerlendirmek amacıyla, eğitim ve test süreci 50 kez tekrarlanmıştır. Her bir tekrar döngüsünde şu adımlar izlenmiştir:
  1. İlgili veri seti (Kanada veya Hindistan) rastgele olarak %80 eğitim ve %20 test alt kümelerine ayrılmıştır (train\_test\_split fonksiyonu, her döngü için farklı bir rastgele durum (random\_state=None) kullanılarak).
  2. Girdi özelliklerinin farklı sayısal aralıklarda olmasının model üzerindeki potansiyel olumsuz etkilerini gidermek amacıyla, ayrılan eğitim verisi üzerinde standartlaştırma (StandardScaler) işlemi uygulanmış ve aynı ölçeklendirme parametreleri test verisine de tatbik edilmiştir.
  3. XGBoost modeli, ilgili hedef değişken için belirlenmiş olan en iyi hiperparametrelerle, o anki döngünün ölçeklendirilmiş eğitim verisi üzerinde eğitilmiştir.
  4. Eğitilen modelin performansı, ilgili test seti üzerinde R-kare ( $R^2$ ), Ortalama Mutlak Hata (MAE) ve Ortalama Karesel Hata (MSE) performans metrikleri kullanılarak değerlendirilmiş ve bu metrikler kaydedilmiştir.

- Nihai Performans Raporlaması: Bölüm 4'te sunulacak olan nihai model performansları, bu 50 farklı çalıştırmadan elde edilen  $R^2$ , MAE ve MSE metriklerinin ortalama, minimum ve maksimum değerlerini yansıtacaktır. Tüm analizler Python programlama dili ve Scikit-learn, XGBoost, Pandas gibi ilgili veri bilimi kütüphaneleri kullanılarak gerçekleştirilmiştir.

GridSearchCV ile yürütülen optimizasyon süreci sonunda, her bir hedef değişken için en iyi performansı sağlayan ve 50 tekrarlı değerlendirme döngüsünde kullanılan hiperparametre setleri Tablo 2'de sunulmuştur.

**Tablo 2.** Hiperparametre değerleri

Hiperparametre	Kanada Sismik Tarama	Hindistan Hızlı Görsel Tarama
learning_rate	0.1	0.1
max_depth	3	3
n_estimators	150	100
subsample	0.8	1.0

Tüm analizler ve modelleme süreçleri, Python 3.8 programlama dilinde, Google Colaboratory platformu üzerinde standart bir işlemci (CPU) ve 12 GB RAM kaynağı kullanılarak gerçekleştirilmiştir. Çalışmada, temel veri bilimi kütüphanelerinden Scikit-learn (sürüm 1.2.2), XGBoost (sürüm 2.1.3) ve Pandas (sürüm 2.0.3) kullanılmıştır. Her bir hedef değişken için yürütülen 50 tekrarlı model eğitim ve değerlendirme döngüsü, yaklaşık olarak 15-20 dakika arasında tamamlanmıştır.

### 3.3. Model performans değerlendirme metrikleri

Eğitilen XGBoost modellerinin test seti üzerindeki tahmin performansını kantitatif olarak değerlendirmek amacıyla aşağıdaki metrikler kullanılmıştır:

- R-kare ( $R^2$ ): Bağımlı değişkendeki (performans puanı) varyansın bağımsız değişkenler (bina özellikleri) tarafından ne kadarının açıklandığını gösterir. Değeri 0 ile 1 arasında değişir ve 1'e yakın olması model uyumunun yüksek olduğunu gösterir.
- Ortalama Mutlak Hata (MAE): Tahmin hatalarının mutlak değerlerinin ortalamasıdır. Modelin ortalama olarak gerçek değerden ne kadar saptığını, puanlama sisteminin kendi birimi cinsinden gösterir. Daha düşük MAE değeri, daha iyi performansa işaret eder.
- Ortalama Karesel Hata (MSE): Tahmin hatalarının karelerinin ortalamasıdır. Bu metrik, büyük hatalara daha fazla ağırlık (ceza) verir. Daha düşük MSE değeri, daha iyi performansı gösterir.

Bu metriklerin matematiksel formülasyonları Denklem 7, Denklem 8 ve Denklem 9'da gösterilmiştir.

$$\mathbf{R-kare (R^2)} \quad : \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (7)$$

$$\mathbf{Ortalama Mutlak Hata (MAE)} \quad : \quad MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (8)$$

$$\mathbf{Ortalama Karesel Hata (MSE)} \quad : \quad MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (9)$$

Burada,  $y_i$  gerçek değeri,  $\hat{y}_i$  modelin tahmin ettiği değeri,  $\bar{y}$  gerçek değerlerin ortalamasını ve  $n$  toplam veri noktası sayısını temsil etmektedir.

### 3. Bulgular ve Tartışma

Bu bölümde, Bölüm 3'te açıklanan metodoloji kullanılarak geliştirilen XGBoost makine öğrenmesi modelinin, Kanada Sismik Tarama ve Hindistan Hızlı Görsel Değerlendirme yöntemiyle hesaplanan bina performans puanlarını tahmin etmedeki başarıları sunulmaktadır. Model performansları, R-kare ( $R^2$ ), Ortalama Mutlak Hata (MAE) ve Ortalama Karesel Hata (MSE) metrikleri ile değerlendirilmiş ve temel görsel analizlerle desteklenmiştir.

XGBoost modelinin Kanada Sismik Tarama ve Hindistan Hızlı Görsel Tarama performans puanlarını tahmin etmedeki sayısal başarı metrikleri, 50 farklı rastgele eğitim-test seti ayrımı üzerinden elde edilen ortalama (Mean), minimum ve maksimum değerler olarak Tablo 3 ve Tablo 4'te özetlenmektedir.

**Tablo 3:** Kanada sismik tarama puan tahmini için XGBoost modeli performans metrikleri

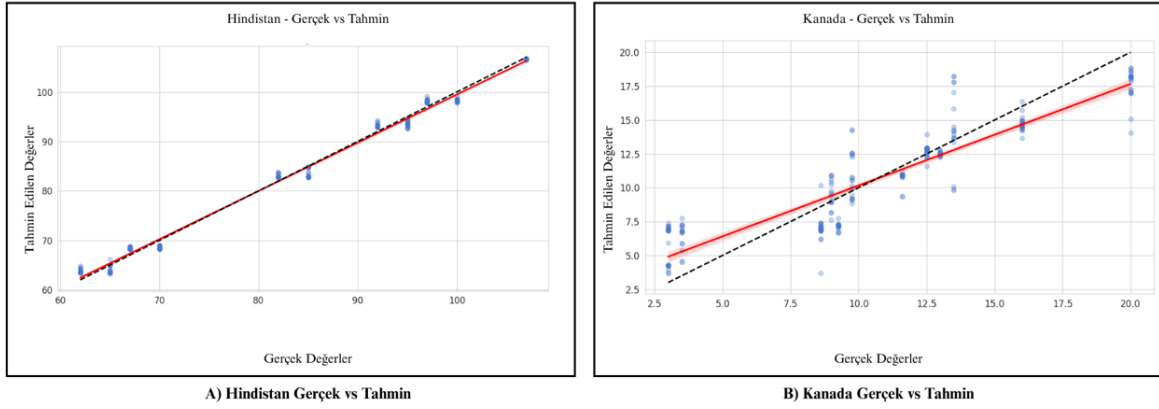
Model	Ortalama R <sup>2</sup> (%)	Minimum (%)	R <sup>2</sup> (%)	Maksimum (%)	R <sup>2</sup> (%)	Medyan (%)	R <sup>2</sup> (%)	Ortalama MAE	Ortalama MSE
XGBoost	79.830828	75.171628		83.173966		79.172797		1.585585	4.245926

**Tablo 4.** Hindistan hızlı görsel değerlendirme puan tahmini için XGBoost modeli performans metrikleri

Model	Ortalama R <sup>2</sup> (%)	Minimum (%)	R <sup>2</sup> (%)	Maksimum (%)	R <sup>2</sup> (%)	Medyan (%)	R <sup>2</sup> (%)	Ortalama MAE	Ortalama MSE
XGBoost	99.038470	98.054871		99.281600		98.668235		1.251624	2.165954

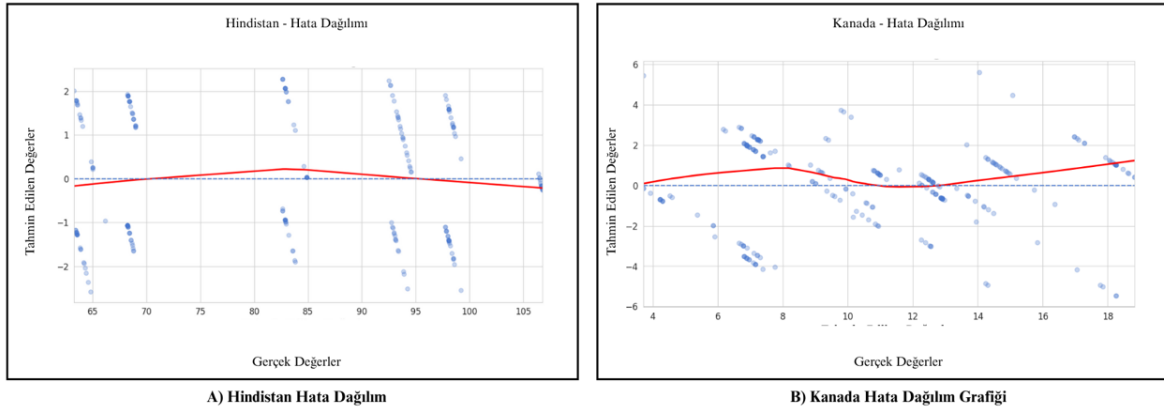
Tablolardaki metrikler incelendiğinde, XGBoost modelinin her iki yöntemin performans puanlarını da yüksek bir başarıyla tahmin edebildiği görülmektedir. Özellikle Hindistan Hızlı Görsel Değerlendirme yöntemi için elde edilen %99.038470'lik ortalama R<sup>2</sup> değeri, modelin bu yöntemin çıktılarını çok yüksek bir doğrulukla yeniden üretebildiğini göstermektedir. Bu yüksek R<sup>2</sup> değerine ek olarak, 1.251624'lük düşük Ortalama Mutlak Hata (MAE) ve 2.165954'lük Ortalama Karesel Hata (MSE) değerleri, modelin Hindistan Hızlı Görsel Değerlendirme puanlarını (yaklaşık 60-155 puan aralığında) gerçek değerlere oldukça yakın ve ortalama ~1.25 puanlık küçük bir hata ile tahmin edebileceğini teyit etmektedir. Kanada Sismik Tarama yöntemi için elde edilen %79.830828'lik ortalama R<sup>2</sup> değeri de modelin performans puanlarındaki varyansın önemli bir bölümünü açıklayabildiğini göstermektedir. Bu yöntem için hesaplanan Ortalama MAE (1.585585), Kanada Sismik Tarama puanlarının daha dar olan yaklaşık 3-26 puan aralığı düşünüldüğünde, modelin kabul edilebilir bir hata payıyla (ortalama ~1.59 puan) tahmin yapabildiğini göstermektedir. Kanada Sismik Tarama yöntemi için elde edilen R<sup>2</sup> değerinin (%79.83) göreceli olarak daha düşük olması, model seçiminin doğruluğunun sorgulanmasını gündeme getirebilir. Bu nedenle, ana analizlere ek olarak, farklı çalışma prensiplerine sahip alternatif modellerle de karşılaştırmalı denemeler yapılmıştır. Bu kapsamda, ağaç tabanlı topluluk yöntemlerinden Random Forest ve Karar Ağacı ile yapılan ön denemelerde XGBoost'a kıyasla daha düşük performans gözlemlenmiştir. Ayrıca, özellikle tablo verileri için geliştirilmiş, dikkat mekanizmalarını kullanan derin öğrenme tabanlı modern bir mimari olan TabNet modeli de değerlendirmeye alınmıştır. TabNet, Kanada RST puan tahmini için %72.72 R<sup>2</sup>, Hindistan RVS puan tahmini için ise %95.25 R<sup>2</sup> performansı sergilemiştir. Bu karşılaştırmalı denemeler sonucunda, hem Kanada hem de Hindistan yöntemleri için en yüksek R<sup>2</sup> metriğini ve en düşük hata oranlarını sunan XGBoost modelinin, bu spesifik problem için en güçlü ve uygun model olduğu teyit edilmiş ve çalışmanın ana odağı olarak seçilmesinin metodolojik geçerliliği desteklenmiştir. Her iki yöntem için de Min/Max R<sup>2</sup> değerleri arasındaki farkın görece dar olması, sonuçların rastgele veri ayrımına karşı stabil olduğunu desteklemektedir.

Model performansını görsel olarak daha derinlemesine analiz etmek amacıyla, tahmin edilen puanların gerçek puanlarla uyumunu gösteren saçılım grafikleri, hata (artıklık) dağılımları ve belirli gerçek puan değerleri için tahminlerin dağılımını gösteren keman grafikleri incelenmiştir. Şekil 2, XGBoost modelinin her iki hedef değışken (Hindistan ve Kanada) için ürettiği Gerçek-Tahmin saçılım grafiklerini bir arada sunmaktadır.



**Şekil 2.** XGBoost modeli ile gerçek ve tahmin edilen performans puanları

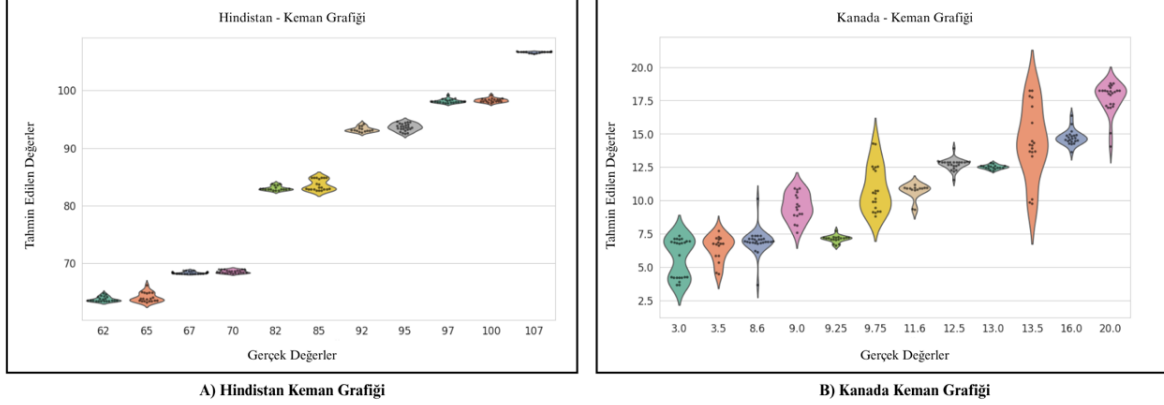
Şekil 2'deki alt grafikler incelendiğinde, tahmin edilen değerlerin gerçek değerlerle genel olarak iyi bir uyum içinde olduğu görülmektedir. Özellikle Hindistan Hızlı Görsel Değerlendirme tahminleri için (Şekil 2A), veri noktalarının mükemmel tahmini temsil eden  $y=x$  doğrusuna (siyah kesikli çizgi) çok yakın kümelendiği ve regresyon doğrusunun (kırmızı kesikli çizgi) bu doğruyla neredeyse çakıştığı gözlemlenmektedir. Bu durum, Tablo 4'deki %99.04'lük yüksek ortalama  $R^2$  değerini görsel olarak güçlü bir şekilde doğrulamaktadır. Kanada Sismik Tarama tahminlerinde (Şekil 2B) ise noktalarda  $y=x$  doğrusuna göre bir miktar daha fazla saçılım olmakla birlikte, genel trendin yine bu doğruya yakın olduğu ve regresyon doğrusunun genel eğilimi yakaladığı görülmektedir. Bu saçılım, Tablo 3'teki %79.83'lük  $R^2$  değeriyle uyumludur. Model hatalarının (artıklıkların) yapısını incelemek amacıyla, gerçek değerlere karşılık artıklıkların dağılımı Şekil 3'te gösterilmektedir.



**Şekil 3.** XGBoost Modeli için gerçek değerlere karşı Artıklık grafikleri

Şekil 3'teki her iki artıklık grafiği incelendiğinde, hataların genel olarak sıfır çizgisi (yatay kesikli mavi çizgi) etrafında belirgin bir örüntü veya trend olmaksızın dağıldığı görülmektedir. Bu durum, modelin tahminlerinde önemli bir sistematik sapma olmadığını ve farklı puan seviyelerindeki binalar için benzer hata karakteristikleri sergilediğini düşündürmektedir. Hindistan Hızlı Görsel Değerlendirme için artıklıkların (Şekil 3A) sıfır çizgisine çok daha yakın ve dar bir bantta (-2 ile +2 puan aralığında) dağılması, bu yöntem için elde edilen düşük MAE ve MSE değerleriyle tutarlıdır. Kanada Sismik Tarama için artıklıklar (Şekil 3B) ise daha geniş bir bantta (-6 ile +6 puan aralığında) saçılım göstermekte, bu da daha yüksek hata metriklerini yansıtmaktadır.

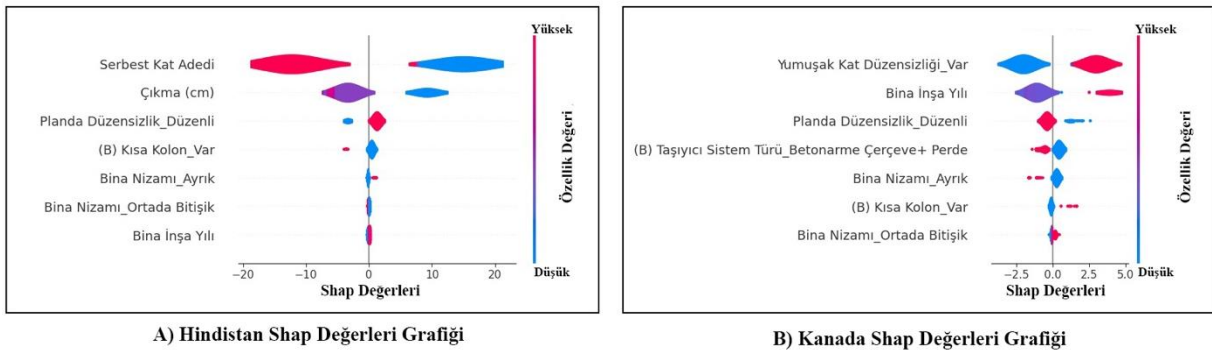
Tahminlerin belirli gerçek puan değerleri etrafındaki dağılımını ve kesinliğini daha detaylı incelemek için keman grafikleri oluşturulmuştur (Şekil 4). Bu grafikler, her bir gerçek puan kategorisi için modelin ürettiği tahminlerin olasılık yoğunluğunu göstermektedir.



Şekil 4. XGBoost modeli ile belirli gerçek puanlar için tahmin edilen puanların Keman grafikleri

Şekil 4A (Hindistan Hızlı Görsel Değerlendirme), modelin tahminlerinin her bir gerçek puan kategorisi etrafında oldukça dar ve yoğun bir şekilde toplandığını, kemanların tepe noktalarının ve içindeki bireysel tahmin noktalarının (dağılım noktaları) gerçek değere çok yakın olduğunu göstermektedir. Bu, Hindistan Hızlı Görsel Değerlendirme puanlarının yüksek kesinlikle tahmin edildiğini bir kez daha doğrular. Şekil 4B (Kanada Sismik Tarama) incelendiğinde ise, kemanların Hindistan grafiğine göre daha geniş olduğu ve bireysel tahminlerin daha fazla yayıldığı görülmektedir. Özellikle bazı gerçek puan değerleri için (örn: 9.00, 9.25, 13.00) tahminlerin dağılımı daha geniştir. Bu durum, Kanada Sismik Tarama puanlarının tahminindeki belirsizliğin Hindistan Hızlı Görsel Değerlendirme 'ye göre daha yüksek olduğunu ve modelin bu puanlama sisteminde bazı değerler için daha değişken tahminler ürettiğini göstermektedir. Ancak, çoğu durumda kemanların medyan çizgileri (veya yoğunluk tepe noktaları) hala gerçek değerlere yakın bir eğilim sergilemektedir.

Modelin sadece tahmin doğruluğunu değil, aynı zamanda bu tahminleri hangi özelliklere dayanarak yaptığını anlamak ve şeffaflığını artırmak amacıyla Açıklanabilir Yapay Zeka (XAI) tekniklerinden SHAP (SHapley Additive exPlanations) analizi de uygulanmıştır. SHAP, her bir girdi özelliğinin modelin çıktısı üzerindeki etkisini ve yönünü ortaya koyarak, modelin "kara kutu" yapısını aydınlatır. Şekil 5'te, XGBoost modelinin her iki hedef değişken için en önemli bulduğu özellikler ve bu özelliklerin tahminler üzerindeki etkileri SHAP özet grafiği ile sunulmuştur.



Şekil 5. XGBoost modeli için SHAP özet grafikleri: (A) Hindistan RVS, (B) Kanada RST

Şekil 5'te sunulan SHAP özet grafikleri, modelin kararlarını verirken hangi özelliklere öncelik verdiğini ve bu özelliklerin değerlerinin tahminleri nasıl etkilediğini detaylı bir şekilde göstermektedir. Grafikteki her bir nokta,

bir binayı temsil eder. Noktaların yatay eksenindeki konumu, o özelliğin o bina için tahmine olan etkisini (SHAP değeri), rengi ise özelliğin değerinin yüksek (kırmızı) veya düşük (mavi) olduğunu belirtir. Şekil 5A (Hindistan RVS) incelendiğinde, model için en önemli özelliğin "Serbest Kat Adedi" olduğu açıkça görülmektedir. Yüksek kat adedine sahip binalar (kırmızı noktalar), daha düşük performans puanı (negatif SHAP değeri) alma eğilimindeyken, düşük kat adedine sahip binalar (mavi noktalar) daha yüksek puan (pozitif SHAP değeri) almaktadır. İkinci en önemli özellik olan "Çıkma (cm)" ise, yüksek çıkma değerlerinin genellikle puanı artırdığını göstermektedir. Bu analiz, modelin Hindistan RVS puanlamasındaki temel mühendislik varsayımlarını başarılı bir şekilde öğrendiğini doğrulamaktadır. Şekil 5B (Kanada RST) analizinde ise en önemli özelliğin "Yumuşak Kat Düzensizliği\_Var" olduğu görülmektedir. Yumuşak katın varlığı (kırmızı noktalar, genellikle 1 değerini temsil eder), beklendiği gibi performans puanını önemli ölçüde düşürmekte (negatif SHAP değeri), yokluğu (mavi noktalar) ise puanı artırmaktadır. İkinci sırada gelen "Bina İnşa Yılı" (ve dolayısıyla Bina Yaşı) da önemli bir etkiye sahiptir; eski binalar (düşük inşa yılı, mavi noktalar) daha düşük puan alırken, yeni binalar (yüksek inşa yılı, kırmızı noktalar) daha yüksek puan alma eğilimindedir. Bu SHAP analizleri, geliştirilen XGBoost modelinin kararlarının keyfi olmadığını, aksine deprem mühendisliği bilgisiyle tutarlı, yorumlanabilir ve güvenilir olduğunu güçlü bir şekilde kanıtlamaktadır.

Bu bulgular ışığında, çalışmanın temel çıkarımları ve potansiyel etkileri aşağıdaki gibi tartışılabilir:

Geliştirilen XGBoost modellerinin, Kanada ve Hindistan yöntemleri için sergilediği belirgin performans farkının (sırasıyla %79.83 ve %99.04 ortalama  $R^2$ ) temel nedeni, iki puanlama sisteminin dayandığı matematiksel formülasyonlardaki yapısal farklılıklardır. Hindistan yönteminin puanlama sistemi, bir taban puana çeşitli düzensizlik puanlarının eklenmesiyle ( $PS = BS + \sum(VSM \times VS)$ ) büyük ölçüde toplamsal (additive) bir ilişki üzerine kuruludur. Bu tür doğrusal veya basit toplamsal ilişkiler, XGBoost gibi karar ağacı tabanlı algoritmalar tarafından yüksek doğrulukla modellenilebilir, çünkü modelin her bir ağacı veri uzayını bölerek bu toplamsal etkileri kolayca yakalayabilir.

Buna karşılık, Kanada yönteminin Yapısal İndeks (SI) hesaplaması, birden fazla parametrenin çarpımsal (multiplicative) etkileşimine dayanır ( $SI = A * B * C * D * E$ ). Makine öğrenmesi perspektifinden bakıldığında, çarpımsal ilişkiler doğası gereği daha karmaşıktır ve girdilerdeki küçük belirsizliklerin veya hataların çıktıda katlanarak artmasına (hata büyümesi) neden olabilir. Özellikle, saha gözlemlerine dayalı olan ve belirli bir özelliğe içerebilen girdi parametrelerindeki küçük bir sapma, çarpım işlemi nedeniyle nihai puanda büyük bir değişikliğe yol açabilir. Bu durum, modelin öğrenmesi gereken ilişkiyi daha "gürültülü" ve daha az kararlı hale getirir. Sonuç olarak, Kanada yöntemi için gözlemlenen daha düşük  $R^2$  değeri, modelin bir başarısızlığı olarak değil, hedef değişkenin içsel matematiksel karmaşıklığının ve gürültüye karşı hassasiyetinin bir yansıması olarak yorumlanmalıdır.

Geliştirilen XGBoost modeli, Elazığ ili özelindeki saha verileri kullanılarak hem Kanada Sismik Tarama hem de Hindistan Hızlı Görsel Değerlendirme yönteminin performans puanlarını başarılı bir şekilde tahmin edebilmiştir. Özellikle Hindistan Hızlı Görsel Değerlendirme yöntemi için elde edilen %99.04'lük yüksek ortalama  $R^2$  değeri, literatürdeki benzer çalışmalarla uyumlu ve hatta daha yüksek bir başarıyı göstermektedir. Örneğin, çelik çerçeveler için yapılan bir çalışmada %95  $R^2$  değeri raporlanırken, betonarme çerçeveler için yapılan başka bir çalışmada ise %80'lik sınıflandırma doğruluğu elde edilmiştir. Bu durum, çalışmamızda kullanılan saha verilerinin kalitesinin ve XGBoost modelinin bu spesifik problem (hızlı değerlendirme puanı tahmini) için ne kadar uygun olduğunun bir göstergesidir. Kanada Sismik Tarama için elde edilen %79.83'lük ortalama  $R^2$  değeri daha düşük olsa da, bu yöntemin de belirli bir doğrulukla tahmin edilebileceğini ortaya koymaktadır. Kanada Sismik Tarama yöntemine ait tahmin sonuçlarında, Hindistan yöntemine kıyasla daha yüksek hata değerleri gözlemlenmiştir. Bu durumun başlıca nedenlerinden biri, Kanada yönteminin daha sınırlı sayıda girdi parametresiyle çalışması ve performans puanlarının çarpanlara dayalı karmaşık bir formülle hesaplanmasıdır. Ayrıca, yapısal olmayan özelliklerin (NSI) daha öznel gözlemlere dayalı olarak değerlendirilmesi, saha verilerindeki belirsizliği artırmakta ve bu da modelin tahmin doğruluğunu olumsuz etkileyebilmektedir. Bu bağlamda, Kanada yöntemine ait performans puanlarının tahmin edilmesinde görülen hata yayılımı, yöntemsel yapının daha geniş varyanslı çıktılar üretmesinden kaynaklanmaktadır.

Bu sonuçlar, her iki uluslararası kabul görmüş hızlı değerlendirme yönteminin de lokal verilere (Elazığ örneği) uyarlandığında ve makine öğrenmesi ile desteklendiğinde anlamlı sonuçlar üretebileceğini göstermektedir. Modelin performansı, bu yöntemlerin temel aldığı yapısal özelliklerin (kat sayısı, inşa yılı/yaşı, düzensizlikler vb.) sismik davranışla ilişkili olduğunu ve bu ilişkilerin Makine öğrenmesi algoritmaları tarafından yakalanabildiğini teyit etmektedir.

Makine öğrenmesinin saha verileriyle entegrasyonu, hızlı sismik risk değerlendirme süreçlerine önemli katkılar sunmaktadır. Geleneksel yöntemler genellikle zaman alıcı ve uzmanlık gerektiren saha gözlemlerine dayanırken, eğitilmiş bir Makine öğrenmesi modeli, gerekli bina verileri sağlandığında çok daha hızlı bir şekilde performans puanı tahmini yapabilir. Bu, özellikle geniş kentsel alanlardaki binlerce yapının kısa sürede taranması ve risk önceliklendirmesi yapılması gereken durumlar için büyük bir avantajdır. Verilerin dijitalleştirilmesi ve analizin otomatize edilmesi sayesinde, daha az insan gücüyle daha geniş kapsamlı değerlendirmeler yapmak mümkün hale gelmektedir.

Bu çalışmada geliştirilen yaklaşımın afet yönetimi planlamasındaki potansiyel etkileri de dikkate değerdir. Makine öğrenmesi tabanlı hızlı değerlendirme, afet öncesi dönemde riskli bölgelerin ve yapıların belirlenerek kentsel dönüşüm veya güçlendirme çalışmalarına öncelik verilmesine yardımcı olabilir. Olası bir deprem senaryosunda, hangi bölgelerin daha yüksek risk altında olduğunu önceden bilinmesi, müdahale ekiplerinin ve kaynakların daha etkin bir şekilde yönlendirilmesini sağlayabilir. Afet sonrasında ise, benzer modeller hasar görmüş olabilecek binaların hızlı bir şekilde tespiti ve acil durum barınma planlaması gibi kritik süreçlerde karar vericilere değerli bilgiler sunabilir. Bu sayede, hem can kayıplarının azaltılmasına hem de ekonomik kayıpların minimize edilmesine katkıda bulunulabilir.

#### 4. Sonuçlar ve Öneriler

Bu çalışmada, Elazığ ilindeki mevcut bina envanterinin sismik performans puanlarının, Kanada Sismik Tarama ve Hindistan Hızlı Görsel Değerlendirme yöntemi temel alınarak, XGBoost makine öğrenmesi algoritması ile tahmin edilebilirliği başarıyla gösterilmiştir. Temel sonuçlar, geliştirilen modelin özellikle Hindistan Hızlı Görsel Değerlendirme puanlarını %99.04 gibi çok yüksek bir ortalama  $R^2$  değeriyle, Kanada Sismik Tarama puanlarını ise %79.83 ortalama  $R^2$  değeriyle tahmin edebildiğini ortaya koymuştur. Bu bulgular, makine öğrenmesinin, sahadan toplanan yapısal verilere dayanarak geleneksel hızlı değerlendirme süreçlerini önemli ölçüde hızlandırma, otomatikleştirme ve potansiyel olarak daha objektif hale getirme kapasitesine sahip olduğunu doğrulamaktadır.

Geliştirilen veri odaklı yaklaşımın, özellikle geniş kentsel alanlardaki yapı stoklarının hızlı bir şekilde taranması, risk önceliklendirmesinin yapılması ve afet yönetimi süreçlerinde karar vericilere zamanında ve etkin bilgi sağlanması gibi konularda önemli avantajlar sunduğu değerlendirilmektedir. Elde edilen makine öğrenmesi modelleri, yalnızca afet öncesi risk önceliklendirmesi amacıyla değil, aynı zamanda afet sonrasında sahadan toplanan güncel verilerle hızlı hasar tahmini yapılması için de kullanılabilir. Bu yönüyle model, acil müdahale ekiplerinin öncelikli bölgeleri belirlemesine, kaynakların etkin planlanmasına ve afet sonrası süreçte karar destek sistemi olarak kullanılmasına katkı sağlamaktadır. Bu çalışmanın pratik uygulamalara dönüştürülmesi ve daha da geliştirilmesi amacıyla aşağıdaki öneriler sunulmaktadır:

Öncelikle, modelin farklı coğrafi bölgelerde ve çeşitli yapı tipolojilerinde test edilerek genelleme kabiliyetinin artırılması ve bölgesel farklılıklara adaptasyonunun sağlanması kritik öneme sahiptir. Zemin koşulları, kullanılan yapı malzemesinin detaylı özellikleri ve daha kapsamlı yapısal düzensizlik parametreleri gibi ek girdi verilerinin modellere entegre edilmesi, tahmin doğruluğunu potansiyel olarak daha da iyileştirebilir.

Uydu görüntüleri, LiDAR taramaları veya Yapı Bilgi Modellemesi (BIM) gibi modern veri toplama teknolojilerinden otomatik özellik çıkarımı yöntemlerinin araştırılması ve bu makine öğrenmesi modelleriyle entegrasyonu, veri toplama süreçlerini daha da otomatize ederek yöntemin uygulanabilirliğini artıracaktır.

Ayrıca, geliştirilen modellerin sonuçlarının karar vericiler ve saha ekipleri tarafından kolayca erişilebilir ve kullanılabilir olması için kullanıcı dostu web tabanlı arayüzler veya coğrafi bilgi sistemi (GIS) eklentileri geliştirilmesi, bu tür teknolojik yaklaşımların pratik faydasını maksimize edecektir. Bu çalışmanın bir diğer potansiyel geliştirme alanı, modelin hata analizini derinleştirmektir. Gelecek çalışmalarda, modelin tahmin hatalarının farklı yapı tipleri (örneğin kat sayısı yüksek olanlar, planda düzensizlik içerenler vb.) üzerindeki dağılımı detaylı olarak incelenerek, modelin hangi koşullarda daha başarılı veya zayıf kaldığı daha net bir şekilde ortaya konulabilir. Ayrıca geliştirilen XGBoost modelleri yüksek tahmin başarıları sergilese de, karar mekanizmalarının şeffaflığına yönelik analizler bu çalışma kapsamında ele alınmamıştır. Modelin esnek yapısı sayesinde, deprem sonrasında güncellenmiş bina verileri (örneğin hasar gözlemleri, yeni yapı bilgileri) modele entegre edilerek kısa sürede hasar düzeyi tahminleri üretilebilir. Bu da acil müdahale ekiplerinin öncelikli bölgeleri belirlemesine, arama-kurtarma planlamasına ve kaynakların etkin kullanımına katkı sağlar.

Son olarak, bu tür yenilikçi değerlendirme yöntemlerinin standartlaştırılması ve ilgili yönetmeliklere dahil edilmesi, saha uygulamalarında hem yasal zemini güçlendirecek hem de kurumsal sürdürülebilirliği sağlayacaktır. Bu adımlar, deprem riski altındaki yapıları çevrelerin güvenliğini ve dayanıklılığını artırma yolunda makine öğrenmesinin sunduğu potansiyelden tam olarak faydalanmamıza olanak tanıyacaktır.

## Kaynaklar

- [1] AFAD. Kahramanmaraş Depremleri Değerlendirme Raporu. T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı. 2023.
- [2] AFAD. Elazığ Depremi Teknik Değerlendirme Raporu. T.C. İçişleri Bakanlığı. Ankara. 2020.
- [3] National Disaster Management Authority India. Seismic Vulnerability Assessment of Buildings using Rapid Visual Screening (RVS). Government of India. New Delhi. 2010.
- [4] Rainer J.H., Allen D.E., Jablonski A.M. Manual for Screening of Buildings for Seismic Investigation. 1993
- [5] Arya A.S., Boen T., Ishiyama Y. Guidelines for Earthquake Resistant Non-Engineered Construction. UNESCO. Paris. 2006.
- [6] Yakut A. Preliminary seismic performance assessment procedure for existing RC buildings. *Engineering Structures*. 26(10). 1447–1461. 2004.
- [7] Gulkan P., Langenbach R. The earthquake resistance of traditional timber and masonry dwellings in Turkey. 13th World Conference on Earthquake Engineering. Vancouver. 2004.
- [8] Akkar S., Sandıkkaya M.A., Ay B.O. A ground-motion predictive model for Turkey. *Bulletin of Earthquake Engineering*. 12(1). 517–547. 2014.
- [9] Salehi H., Burgueño R. Emerging artificial intelligence methods in structural engineering. *Engineering Structures*. 171. 170–189. 2018.
- [10] Çevik A., Kurtoğlu A.E., Bilgehan M., Gülşan M.E., Albegmprli H.M. Support vector machines in structural engineering: a review. *Journal of Civil Engineering and Management*. 21(3). 261–281. 2015.
- [11] A. Baghbani, T. Choudhury, S. Costa, and J. Reiner, “Application of artificial intelligence in geotechnical engineering: A state-of-the-art review,” *Earth-Science Rev.*, vol. 228, p. 103991, 2022.
- [12] F. Khademi, S. M. Jamal, N. Deshpande, and S. Londhe, “Predicting strength of recycled aggregate concrete using artificial neural network, adaptive neuro-fuzzy inference system and multiple linear regression,” *Int. J. Sustain. built Environ.*, vol. 5, no. 2, pp. 355–369, 2016.
- [13] Imam M.H., Mohiuddin M., Shuman N.M., Oyshi T.I., Debnath B., Liham M.I.M.H. Prediction of seismic performance of steel frame structures: A machine learning approach. *Structures*. 69. 107547. 2024.
- [14] Zhang H., Cheng X., Li Y., He D., Du X. Rapid seismic damage state assessment of RC frames using machine learning methods. *Journal of Building Engineering*. 65. 105797. 2023.
- [15] Xinzhe Y., Liu Jun L., Haibin Z., Yanping Z., Genda C., Cihan D. Machine learning-based seismic damage assessment of residential buildings considering multiple earthquake and structure uncertainties. *Natural Hazards Review*. 24(3). 04023024. 2023.
- [16] Z. Cahya, D. Cahya, T. Nugroho, A. Zuhri, and W. Agusta, “CNN Model with Parameter Optimisation for Fine-Grained Banana Ripening Stage Classification,” *ACM Int. Conf. Proceeding Ser.*, vol. 13, pp. 90–94, 2022, doi: 10.1145/3575882.3575900.