



Earthquake intensity estimation via an artificial neural network: Examination of different network designs and training algorithms

Aslı Sebatlı-Sağlam*^{ID}, Fatih Çavdur^{ID}

Department of Industrial Engineering, Faculty of Engineering, Bursa Uludag University, 16240, Bursa, Turkey

Highlights:

- Development of an artificial neural network for earthquake intensity estimation
- Network structure optimization by considering different network designs
- Determining an appropriate training algorithm for the determined network design

Graphical/Tabular Abstract

In this study, using a multi-layer feed-forward artificial neural network, we estimate earthquake intensity based on the magnitude and the depth of an earthquake and the distance of the disaster victims from the epicenter of the earthquake. In this context, we use significant earthquakes database of the United States Geological Survey as the inputs of the artificial neural network. We first determine an appropriate network design by estimating earthquake intensity with different artificial neural network designs and then the best training algorithm for the appropriate network design by evaluating different algorithms for the corresponding network design.

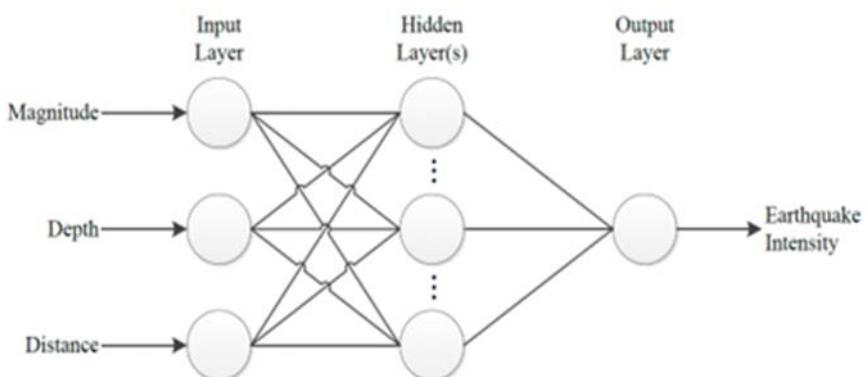


Figure A. Artificial neural network design

Article Info:

Research Article

Received: 07.09.2020

Accepted: 27.11.2021

DOI:

10.17341/gazimfd.791337

Acknowledgement:

This research was supported by TUBITAK, the Scientific and Technological Research Council of Turkey (115M020). We would like to thank TUBITAK.

Correspondence:

Author: Aslı Sebatlı Sağlam
e-mail:
aslisebatli@gmail.com
phone: +90 224 294 2077

Purpose: We aim to estimate the earthquake intensity via an artificial neural network.

Theory and Methods: We obtain significant earthquakes data from the database of the United States Geological Survey. An artificial neural network is developed using the MATLAB Neural Network Toolbox. We first determine an appropriate network design by estimating earthquake intensity with different artificial neural network designs and then the best training algorithm for the appropriate network design by evaluating different algorithms for the corresponding network design.

Results: In terms of the average performance parameters, the network structure with two hidden layers and five and ten hidden neurons in each respective layer is determined as the most appropriate design. We observe the best results in terms of performance parameters by using the Levenberg-Marquardt training algorithm with Bayesian Regularization for the corresponding network structure.

Conclusion: Earthquake intensity estimation is critical in predicting the impact that will occur after a disaster. In this study, we estimate earthquake intensity via an artificial neural network. In future studies, associated with earthquake intensity, we can estimate the number of casualties, damages to the buildings, economic loss and so on. Integrating earthquake intensity estimation into other disaster operation management studies may be another future study direction.



Yapay sinir ağı ile deprem şiddeti tahmini: Farklı ağ tasarımlarının ve eğitim algoritmalarının incelenmesi

Aslı Sebatlı-Sağlam*^{ID}, Fatih Çavdur^{ID}

Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü, 16240, Bursa, Türkiye

Ö N E Ç I K A N L A R

- Deprem şiddeti tahmini için yapay sinir ağı geliştirilmesi
- Farklı ağ tasarımlarının dikkate alınmasıyla ağ yapısı optimizasyonu
- Belirlenen ağ tasarımi için uygun eğitim algoritmasının belirlenmesi

Makale Bilgileri

Araştırma Makalesi

Geliş: 07.09.2020

Kabul: 27.11.2021

DOI:

10.17341/gazimmd.791337

Anahtar Kelimeler:

Afet operasyonları yönetimi, afet yardım operasyonları, makine öğrenmesi, yapay sinir ağları, deprem şiddeti tahmini

ÖZ

Bu çalışmada, ileri beslemeli geri yayılmış bir yapay sinir ağı ile depremin büyüklüğü, derinliği ve afetzedelerin merkez üssüne olan uzaklıklarına bağlı olarak deprem şiddeti tahmini yapılmıştır. Bu kapsamında, Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu'nun veri tabanında yer alan ve önemli depremler olarak adlandırılan depremlere ilişkin bilgiler yapay sinir ağının girdisi olarak kullanılmıştır. Farklı yapay sinir ağı tasarımları için deprem şiddeti tahmin edilerek uygun bir ağ tasarımı elde edilmiştir. Ardından söz konusu uygun ağ tasarımı için farklı eğitim algoritmaları kullanılarak ağ eğitilmiş ve bu algoritmalar arasından en uygun eğitim yöntemi belirlenmiştir. Farklı ağ tasarımlarının ve eğitim algoritmalarının performansları, ortalama karesel hata ve korelasyon katsayısı cinsinden analiz edilmiştir. Performans parametrelerinin ortalaması açısından, iki gizli katman ve her bir katmanda sırasıyla beş ve on gizli nöronun bulunduğu ağ yapısı en uygun tasarım olarak belirlenmiştir. Söz konusu ağ yapısı için Bayes Düzenlemesi ile Levenberg-Marquardt eğitim algoritmasının kullanıldığı durumda performans parametreleri açısından en iyi sonuçlar gözlemlenmiştir.

Earthquake intensity estimation via an artificial neural network: Examination of different network designs and training algorithms

H I G H L I G H T S

- Development of an artificial neural network for earthquake intensity estimation
- Network structure optimization by considering different network designs
- Determining an appropriate training algorithm for the determined network design

Article Info

Research Article

Received: 07.09.2020

Accepted: 27.11.2021

DOI:

10.17341/gazimmd.791337

Keywords:

Disaster operations management, disaster relief operations, machine learning, artificial neural networks, earthquake intensity estimation

ABSTRACT

magnitude and the depth of an earthquake and the distance of the disaster victims from the epicenter of the earthquake. In this context, we use significant earthquakes database of the United States Geological Survey as the inputs of the artificial neural network. We first determine an appropriate network design by estimating earthquake intensity with different artificial neural network designs and then the best training algorithm for the appropriate network design by evaluating different algorithms for the corresponding network design. These analyses are performed in terms of the mean square error and correlation coefficient. In terms of the average performance parameters, the network structure with two hidden layers and five and ten hidden neurons in each respective layer is determined as the most appropriate design. We observe the best results in terms of performance parameters by using the Levenberg-Marquardt training algorithm with Bayesian Regularization for the corresponding network structure.

1. GİRİŞ (INTRODUCTION)

Her yıl dünyada 500'den fazla afetin meydana geldiği ve bu durumun on binlerce insanın ölümüne neden olduğu, yüz milyonlarca insanın da çeşitli şekillerde afetlerden etkilendiği tahmin edilmektedir [1]. Türkiye'de ise 20. yüzyılda meydana gelen depremler, toplam 110.000 ölüm ve 250.000 yaralanmayla birlikte 600.000'den fazla konutu tahrip ederek büyük can ve mal kaybına neden olmuştur [2].

Kumar vd. [3] tarafından yapılan çalışmada da belirtildiği gibi her yıl meydana gelen afet sayısının giderek arttığı ve bu durumun da kayıtları önemli ölçüde arttırdığı gözlenmektedir. Aynı çalışmada, yılda meydana gelen ortalama afet sayıları incelendiğinde; 1980'li yıllarda 180, 1990'lı yıllarda 300 ve 2000-2010 yılları arasında 384 afetin meydana geldiği belirtilmiştir. 2011 yılında ise önceki on yılla kıyaslandığında dramatik bir artış gözlenmiş ve dünya çapındaki afetlerde sayısı yılda ortalama 232,0 milyondan 244,7 milyona yükselmiştir. 2011 yılında, doğal afetlerden kaynaklanan ekonomik zararların ise o yıla kadar kaydedilen en yüksek seviyede olduğu söylemektedir. Kendinden önceki on yılla kıyaslandığında, ekonomik zarar %235 oranında artış göstererek 109,3 milyar Amerikan Doları'ndan 366,1 milyar Amerikan Doları'na yükselmiştir. Avrupa Komisyonu tarafından sunulan bir raporda da nüfus artışı ve iklim değişikliği gibi çeşitli faktörler nedeniyle afetlerin sıklığı, yoğunluğu ve etkisinin son yıllarda arttığı belirtilmiştir [4].

Van Wassenhove [1] tarafından yapılan sınıflandırmada afetler, hızına göre yavaş başlangıçlı ve ani başlangıçlı olmak üzere iki sınıfa ayrılmıştır. Burada; açlık, kuraklık ve mülteci sorunları gibi afetler yavaş başlangıçlı afetler arasında yer alırken depremler, kasırgalar ve terör saldıruları ani başlangıçlı afetler olarak sınıflandırılmıştır. Afet sonrası aniden meydana gelen talep ise mevcut kaynakların miktarını aşarak düzensiz yapıya sahip olmakta ve düzensiz aralıklarla meydana gelmektedir [5, 6]. Afetin meydana geliş yeri ve zamanı ile şiddeti önceden bilinemediği için afet sonucunda meydana gelecek etkinin de önceden tahmini oldukça zordur. Öte yandan, afet öncesi ve sonrası yapılacak çeşitli operasyonların başarılı bir şekilde gerçekleştirilebilmesi için afet şiddetinin tahmini kritik önem taşımaktadır. Afet şiddetinin tahminine bağlı olarak afet sonrası oluşabilecek talep de tahmin edilebilecek ve afet

öncesi ve sonrasında gerçekleştirilecek operasyonların da seviyesi belirlenebilecektir. Böylelikle, olası can ve mal kaybının azaltılmasına imkan sağlanacaktır.

Bu çalışmada, depremin büyüklüğü, derinliği ve afetzedelerin merkez üssüne olan uzaklıklarına bağlı olarak deprem şiddeti tahmin edilmiştir. Bu amaçla, literatür araştırması bölümünde detaylandırıldığı gibi afet operasyonları yönetimi kapsamında yapılan tahmin çalışmalarında sıkılıkla kullanılan yaklaşımardan olan, çok katmanlı ileri beslemeli ve geri yayılmış bir yapay sinir ağının kullanılmıştır. Yapay sinir ağının eğitimi için gerekli olan veri seti, Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu'nun (United States Geological Survey – USGS) veri tabanında yer alan Önemli Depremler Arşivi'nden (Significant Earthquakes Archive) elde edilmiştir [7]. Farklı ağ tasarımları için uygulama yapılarak performans parametreleri açısından en uygun ağ yapısının belirlenmesi ve bu ağın farklı eğitim algoritmaları kullanılarak eğitilmesinin ardından elde edilen sonuçların, performans parametreleri cinsinden analiz edilerek en uygun eğitim yöntemini belirlenmesi çalışmanın öne çıkan unsurlarını oluşturmaktadır.

Makalenin ilerleyen bölümleri şu şekildedir: İlkinci bölümde literatür araştırması özetiğiştir. Üçüncü bölümde çalışma kapsamında önerilen metodoloji sunulmuştur. Uygulama aşaması ve elde edilen sonuçlara ilişkin detaylar dördüncü bölümde yer alırken beşinci ve son bölümde genel değerlendirme yapılmıştır.

2. LİTERATÜR ARAŞTIRMASI (LITERATURE REVIEW)

Afetin meydana gelişinin, büyülüüğünün, şiddetinin ve afet sonrasında olacak hasarın tahmini afet operasyonları yönetimi açısından kritik önem taşımaktadır. Bu bölümde literatürde yer alan çeşitli tahmin çalışmaları Tablo 1'de görüldüğü gibi özetenmiştir.

Literatürde yer alan çalışmalar incelendiğinde, öncelikle afetin meydana gelişini tahmin eden çalışmalar ele alınmıştır. Reyes vd. [8] tarafından yapılan çalışmada geliştirilen ileri beslemeli yapay sinir ağ ile ele alınan bir bölgede takip eden beş gün içinde deprem meydana gelme olasılığı tahmin edilmektedir. Çalışma kapsamında, bir eşik değerden daha fazla büyülüklükte depremin meydana gelme

Tablo 1. Literatür taraması (Literature review)

Tahmin Edilen	Yöntem
Afetin meydana gelişisi	Derin öğrenme [10], Rassal ormanlar [11], Regresyon ağaçları [9], Regresyon modelleri [11], Yapay sinir ağları [8], Diğer [3, 12]
Afete ilişkin parametreler	Bulanık mantık [21], Derin öğrenme [17, 24, 25, 29], Destek vektör makineleri [26, 32], Rassal ormanlar [19, 22, 32], Regresyon modelleri [27], Yapay sinir ağları [13-15, 16-20, 30-32], Diğer [19, 22, 23, 28]
Afet sonrası oluşan hasar	Derin öğrenme [50, 51], Destek vektör makineleri [52], Karar ağaçları [48, 52], Rassal ormanlar [41, 47, 48], Regresyon modelleri [41, 49, 52], Yapay sinir ağları [34, 36-38, 41, 45, 47], Diğer [35, 39, 40, 42, 43, 46, 48]

olasılığı ve sınırlı büyülü aralığında bir depremin meydana gelme olasılığı olmak üzere iki tip tahmin yapılmaktadır. Corbi vd. [9] tarafından sunulan çalışmada ise regresyon ağaçları ile depremin meydana geliş zamanını ve boyutunu tahmin eden bir yaklaşım sunulmuştur. Sankaranarayanan vd. [10] sıcaklık ve yağış yoğunluğu gibi hava durumu parametrelerine göre sel oluşumunu tespit etmek için derin öğrenme yaklaşımını kullanmışlardır. Destek vektör makineleri, k -en yakın komşu ve Naive Bayes olmak üzere diğer makine öğrenme modelleri ile önerilen yaklaşımın performansı karşılaştırılmıştır. Kuradusenge vd. [11] tarafından yapılan çalışmada hem jeolojik ve morfolojik faktörler hem de yağış miktarı gibi birtakım tetkikleyici faktörler dikkate alınarak rassal orman ve lojistik regresyon olmak üzere iki farklı yöntemle heyelan oluşumu tahmin edilmiştir. Birtakım çalışmalarında ise afetin meydana geliş ile sonrasında oluşacak maddi ve hayatı kaybın tahmini bütünsel olarak ele alınmıştır. Bu çalışmalara örnek olarak Kumar vd. [3] ve Battarra vd. [12] tarafından yapılan çalışmalar verilebilir. Kumar vd. [3] tarafından yapılan çalışmada afet öncesi lojistik faaliyetlerinin planlanması için bütünsel bir tahmin aracı geliştirilmiştir. Burada hem meydana gelen afet sayısı hem de insanı ve ekonomik kayıp tahmin edilmekte, ilgili parametre için uygun istatistiksel dağılım ve parametresi belirlenmektedir. Battarra vd. [12] ise çalışmalarında, afet öncesi yardım malzemesi tahsisi için deprem meydana gelme olasılığını ve etkilenen nüfusun tahmin etmişlerdir. Ardından merkezi kuruluşların envanter tahsisi problemini ele almışlardır.

Afete ilişkin önemli parametrelerden olan büyülüğünün tahmin edilmesi literatürde sıkılıkla yapılan bir konu olup burada yapay sinir ağının temelli çalışmaların öne çıktığı söyleyenbilir. Bu amaçla, olasılıksal yapay sinir ağının [13], çok katmanlı ileri beslemeli yapay sinir ağının [14-16] ve evrişimli yapay sinir ağının [17] gibi yöntemler kullanıldığı gibi farklı makine öğrenmesi tekniklerinin karşılaştırıldığı çalışmalar da yer almaktadır. Örneğin; Panakkat ve Adeli [18] tarafından yapılan çalışmada ileri beslemeli ve geri yayılmış Ağ, tekrarlayan Ağ ve radyan temelli fonksiyon Ağının olmak üzere üç farklı tipte yapay sinir ağının kullanılarak bir sonraki aydakı en büyük depremin büyülüğünü tahmin edilmiştir. Bu yapay sinir ağlarının performansları, farklı istatistiksel ölçütler kullanılarak değerlendirilmiştir. Asim vd. [19] ise dört farklı makine öğrenmesi teknigi kullanarak elde edilen sonuçları karşılaştırmışlardır. Bunlar; örüntü tanıma yapay sinir ağının, tekrarlayan yapay sinir ağının, rassal ormanın ve doğrusal programlama destekli topluluk sınıflandırma (linear programming boost ensemble classifier) teknikleridir. Bu çalışmaların farklı olarak, zaman serileri kullanılarak büyülüğü ifade eden en uygun eğrinin veya olasılık dağılımının bulunduğu çalışmalar da bulunmaktadır [20].

Afetin yüzündeki etkilerini ifade eden şiddet kavramının önceden tahmin edilmesi de kritik bir süreçtir. Bu alanda literatürde yer alan ilk çalışmaların biri Juang ve Elton tarafından yapılmış olup söz konusu çalışmada, binalarda meydana gelen hasara dayanarak bulanık mantık ile deprem şiddeti tahmin edilmiştir [21]. Kubo vd. [22] deprem

kayaklı yer hareketi şiddetenin tahmini için geleneksel yer hareketi şiddeti tahmin denkleminin yanı sıra, rassal orman temelli makine öğrenmesi yöntemi kullandıkları hibrit bir yaklaşım önermişlerdir. Bradley [23] ise koşullu olasılık dağılımı ile belirli bir bölge için yer hareketlerinin şiddetini tahmin etmekte fakat literatürdeki diğer çalışmalarдан farklı olarak şiddet için tek bir değer değil farklı değerlerin dağılımını sunmaktadır. Jozinovic vd. [24] tarafından yapılan çalışmada, depremin kaynağının ilişkin lokasyon ve büyülü bilgisi olmadan ham dalga formu verileri kullanılarak evrişimli yapay sinir ağının yer sarsıntısının şiddetini tahmin edilmiştir. Nicolis vd. [25] uzun kısa süreli hafıza ve evrişimli yapay sinir ağının olmak üzere iki derin öğrenme yapısı kullanarak sismik olayların hem yoğunluğunu hem de lokasyonunu tahmin ettikleri bir çalışma sunmuşlardır. Asif vd. [26] uyuştu görüntülerinden kasırga şiddetinin tahmin edilebilmesi için destek vektör regresyon modeli temelli bir yaklaşım önererek web-tabanlı bir uygulama geliştirmiştir. Birtakım çalışmalarında ise literatürde ele alınan depreme ilişkin fizikal unsurlarla birlikte sosyal unsurlar da dikkate alınarak regresyon teknikleri [27] ve akan veri analizi [28] yöntemleri kullanılarak deprem şiddeti tahmini yapılmıştır. Söz konusu çalışmalarda sosyal unsur olarak farklı dillerdeki "deprem" veya "tsunami" sözcüklerini içeren Tweetler kullanılmıştır. Benzer bir çalışmada, Zahera vd. [29] tarafından, afetin çevresine ilişkin geçmiş verinin yanı sıra sosyal medya verisi de dikkate alınarak kasırga şiddeti tahmini için derin öğrenme temelli bir yaklaşım sunulmuştur.

Birtakım çalışmalarında afetin büyülüğünü ve şiddetini etkileyen faktörlerin tahmini ele alınmaktadır. Deprem afeti özellikle incelediğinde; depremin büyülüğünü ve şiddetini etkileyen jeolojik unsurlar arasında maksimum yer ivmesi ve sismik kırılganlık gibi önemli parametreler yer almaktadır. Günaydın ve Günaydın [30] tarafından sunulan çalışmada üç farklı yapay sinir ağının teknigi kullanılarak maksimum yer ivmesi tahmini yapılmış ve elde edilen sonuçlar analiz edilmiştir. Bu teknikler ise ileri beslemeli geri yayılmış sinir ağının, radyal temelli fonksiyon sinir ağının ve genelleştirilmiş regresyon sinir ağıdır. Wang vd. [31] tarafından yapılan çalışma ise kırılganlık eğrilerinin hesaplanmasıın risk analizinde çok önemli bir unsur olduğu fakat bu sürecin çok zaman alan maliyetli bir işlem olduğu vurgulanmıştır. Yapay sinir ağının temelli bir istatistiksel metamodel geliştirilerek daha kısa sürede sismik kırılganlık analizi yapılabilen bir yaklaşım geliştirilmiştir. Asim vd. [32] özniteliklerin çıkarılması için sismik analizi ve deprem tahmini için çeşitli makine öğrenmesi yöntemlerini önermişlerdir. Enerji salınımı, sismik hız, sismik hızın değişimi gibi parametrelerin de içinde bulunduğu altmış farklı sismik öznitelik çıkarılmıştır. Ardından, yapay sinir ağının, rassal ormanın ve destek vektör makinesi kullanılarak farklı zaman periyotları için farklı büyülükteki depremler tahmin edilmiştir. Afetin yapısına ilişkin unsurların yanı sıra afet sonrası ortaya çıkacak hasarın tahmin edilmesi de afet operasyonları yönetimi açısından büyük önem taşımaktadır. Erdik vd. [33] tarafından sunulan çalışmada, 2000-2010 yılları arasında deprem sonrası kayıpların tahmin edilmesi

icin geliştirilen müdahale sistemlerine ilişkin yaklaşımlar incelenmiştir. Bu uygulamalar kapsadığı alana göre global ve lokal olmak üzere iki sınıfta ele alınmış ve her iki sınıf için de Dünya'nın farklı bölgelerinde uygulanan yaklaşımlar örneklendirilmiştir. Sebatlı ve Çavdur [34] tarafından yapılan simülasyon çalışmasında, afet sonrasında dağıtım yapılacak yardım malzemelerinin taleplerinin ve dağıtım faaliyetlerinin seviyesinin belirlenmesi için bir yapay sinir ağı ile deprem şiddeti tahmini yapılmıştır. Ardından tahmin edilen şiddetde etkileşimlilikle afetten etkilenen nüfus ve afet müdahale operasyonlarının seviyesi belirlenmiştir. Afetzede (yaralı/ölü) sayısını tahmin eden çalışmalar incelendiğinde; en küçük kareler yöntemi [35], ileri beslemeli ve geri yayılmış yapay sinir ağı [36, 37], kendi kendini düzenleyen rekabetçi sinirsel ağ [38], üç öğrenme makinesi [39], topluluk öğrenme [40] gibi yaklaşımın kullanıldığı görülmektedir. Ganguly vd. [41] doğrusal regresyon, rassal orman ve yapay sinir ağı olmak üzere farklı yöntemlerle afetzede sayısını tahmin ederek; literatürdeki diğer çalışmalarдан farklı olarak hane halkı ölçüngünde problemi ele almışlardır. Bazı çalışmalarında afetzede sayısı tahmini ile birlikte binalarda oluşan hasar da tahmin edilmektedir [42, 43]. Musson [44] yer hareketine ilişkin parametrelerle bina hasarı tahmini yapmanın karmaşıklığını vurgulanmış ve burada çok sayıda parametre olduğunu ifade etmiştir. Bina hasarı tahmini yapan çalışmalarında coğrafi bilgi sistemlerinden [42], literatürde yer alan ampirik ifadelerden [43], yapay sinir ağlarından [45] veya binaların iki boyutlu doğrusal olmayan sonlu eleman modellerinden [46] yararlanılmaktadır. Farklı makine öğrenme yöntemleri kullanılarak bu yöntemlerin performansının analiz edildiği çalışmalar da bulunmaktadır [47, 48]. Oluşacak maddi hasarın tahmini de bir diğer önemli konudur. Bu alanda Cavallo vd. [49] tarafından sunulan regresyon teknikleri ve Kim vd. [50] tarafından derin öğrenme kullanılarak yapılan çalışma örnek olarak gösterilebilir. Bazı çalışmalar ise afet kaynaklı yeryüzünde oluşacak hasara dikkat çekilmiştir. Bi vd. [51] deprem sonrası yollarda ve binalarda ciddi hasarlara neden olabilecek sıvılaşmanın analiz edilebilmesi için derin öğrenme temelli bir yaklaşım önermişlerdir. Xu vd. [52] destek vektör makineleri, doğrusal regresyon ve karar ağaçları olmak üzere farklı makine öğrenme teknikleri kullanarak sismik hasar tahmini yapmışlardır.

Bu çalışmada, deprem şiddeti tahmini için ileri beslemeli geri yayılmış bir yapay sinir ağı geliştirilmiş, farklı ağ tasarımları ve eğitim algoritmalarının performansı incelenmiştir. Çalışmanın literatürde yer alan diğer çalışmalarдан öne çıkan yönleri, deprem şiddeti tahmini için farklı ağ tasarımlarının dikkate alınmasıyla ağ yapısının optimize edilmesi ve bu ağ tasarımu için en uygun eğitim algoritmasının belirlenmesi olarak söylenebilir.

3. METODOLOJİ (METHODOLOGY)

Yapay sinir ağıının girdilerinin elde edilmesi için USGS'nin Önemli Depremler Arşivi'nde yer alan depremler kullanılmıştır. Bu noktada, hem Türkiye'deki önemli

depremleri (örneğin, Van depremini) hem de dünyadaki önemli depremleri (örneğin, Tohoku depremini) içermesi ve farklı büyüklükteki depremlerin varlığı sebebiyle 2011 yılı verileri kullanılmıştır. İlgili yılda meydana gelen her önemli deprem için "Depremi hissettiniz mi? (Did you feel it?)" sayfasındaki cevaplar elde edilmiştir. Burada, söz konusu deprem için afetzedelere birtakım sorular sorulmakta ve afetzedelerin vermiş oldukları cevaplar doğrultusunda deprem şiddetine ilişkin önemli bilgiler alınmaktadır. Depremin büyüklüğün ve derinliğinin yanı sıra merkez üssüne farklı uzaklıklarda bulunan afetzedelerin vermiş olduğu cevaplara bağlı olarak deprem şiddeti belirlenmektedir. Burada, deprem şiddeti ve deprem büyüklüğünün iki farklı kavram olduğuna dikkat edilmelidir. Deprem şiddeti, herhangi bir derinlikte olan depremin yeryüzünde hissedildiği bir noktadaki etkisinin ölçüsü olarak tanımlanırken; deprem büyüklüğü deprem sırasında aşağı çıkan enerjinin bir ölçüsüdür ve büyülüklük değeri Richter tarafından bulunan bir yöntemle hesaplanmaktadır. Bu bağlamda geliştirilen bağıntılar hakkında detaylı bilgi edinmek isteyen okuyucular Richter'in çalışmasını inceleyebilirler [53]. Söz konusu çalışmada da sunulduğu gibi depremlerin şiddeteri ve büyüklükleri arasında birtakım ampirik bağıntılar bulunmaktadır. Deprem şiddeti kavramı, depremin yeryüzündeki etkilerini ifade etmekle birlikte, deprem şiddetine etki eden birçok faktör bulunmaktadır ve depremin hissedildiği noktaya göre farklılık gösterebilmektedir. Buna ek olarak, aynı noktada bulunan farklı bireyler tarafından da farklı hissedilebilen göreceli bir kavramdır. Deprem esnasında bulunan konum, içinde bulunan binanın yapısı, zeminin durumu, sarsıntıının tanımlanma biçimini, afetzededen uyruk olup olmaması, bulunan yerdeki insanların ve nesnelerin durumu, insanların sarsıntıya vermiş oldukları reaksiyon ve çevrede meydana gelen hasar gibi birçok faktör deprem şiddetine etkilemektedir. Bu çalışmada ise Tablo 2'de görüldüğü gibi deprem şiddeti, depremin büyüklüğü, derinliği ve ilgili soruya cevap veren afetzededen merkez üssüne olan uzaklığı ile ilişkilendirilerek tahmin edilmektedir. Bu kapsamda uluslararası standartlara uygun olarak tabloda görüldüğü gibi büyüklük ve derinlik kavramlarına ilişkin altı kategoriden oluşan bir sınıflandırma ele alınmıştır. Uzaklık değeri ise benzer şekilde, deprem şiddeti açısından anlamlı sonuçların elde edildiği altı kategoriye ayrılmıştır. Böylelikle 216 farklı kategori oluşturulmuş ve USGS'nin veri tabanında yer alan 2011 yılına ait önemli depremlere ilişkin büyüklük, derinlik ve uzaklık değerlerine ilişkin deprem şiddeti değerleri ilgili veri tabanından elde edilmiştir.

Tablo 3'te yer alan Deprem Şiddet Cetvelinde de görüldüğü gibi hissedilen sarsıntı ve ortaya çıkan hasar direkt olarak deprem şiddeti ile ilişkilendirilebilir [54, 55]. Deprem şiddeti için Wood ve Neumann [54] tarafından önerilen 12 seviyeli bir yapı kullanılmakta olup tabloda da görüldüğü gibi USGS tarafından 10 ve üzeri şiddet değerleri tek bir seviyede ele alınmaktadır. En genel haliyle, 5 ve üzeri şiddet değerine sahip depremlerin nüfusun büyük çoğunluğu tarafından hissedildiği fakat önemli hasara neden olmadığı söylenebilir. Şiddeti 7 ve üzeri olan depremlerde ise büyük hasarın

Tablo 2. Deprem şiddetini etkileyen faktörler ve kategorileri
(Factors affecting earthquake intensity and their categories)

Büyüklük Kategorisi	Büyüklük Değeri (mmw)	Derinlik Kategorisi	Derinlik Değeri (km)	Uzaklık Kategorisi	Uzaklık Değeri (km)
1	$B < 3$	1	$D \leq 5$	1	$U \leq 50$
2	$3 \leq B < 4$	2	$5 < D \leq 10$	2	$50 < U \leq 100$
3	$4 \leq B < 5$	3	$10 < D \leq 20$	3	$100 < U \leq 200$
4	$5 \leq B < 6$	4	$20 < D \leq 40$	4	$200 < U \leq 400$
5	$6 \leq B < 7$	5	$40 < D \leq 80$	5	$400 < U \leq 800$
6	$B \geq 7$	6	$D > 80$	6	$U > 800$

Tablo 3. Deprem şiddet cetveli (Earthquake intensity scale)

Şiddet	Sarsıntı	Açıklama / Hasar
I	Yok (Not felt)	Çok özel durumlar dışında hasar yoktur.
II	Zayıf (Weak)	Yalnızca hareketsiz kişiler tarafından özellikle de binaların üst katlarında hissedilmektedir.
III	Zayıf (Weak)	Özellikle binaların üst katlarında olan kişiler tarafından belirgin bir şekilde hissedilmektedir. Birçok kişi sarsıntıyı deprem olarak tanımlamamaktadır. Motorlu taşıtlarda hafif kayma olabilmektedir. Kamyon geçişine benzer bir sarsıntı oluşturmaktadır.
IV	Hafif (Light)	Bina içlerindeki birçok kişi tarafından hissedilmektedir, dışında ise gündüzleri birkaç kişi tarafından hissedilebilmektedir. Geceleri bazı kişiler uyanıbmektedir. Mutfak eşyaları, pencereler, kapılar hasar almaktır; duvarlardan çatlama sesi duyulmaktadır. Ağır bir kamyonun binaya çarpmasına benzer bir etki uyandırmaktadır. Motorlu taşıtlarda belirgin şekilde sarsıntı oluşturmaktadır.
V	Orta (Moderate)	Neredeyse herkes tarafından hissedilmektedir, birçok kişi uyanmaktadır. Bazı mutfak eşyaları, pencereler kırılmaktadır. Sabitlenmemiş nesneler devrilmektedir. Sarkaçlı saatler durabilmektedir.
VI	Güçlü (Strong)	Herkes tarafından hissedilmektedir, birçok kişi korkmaktadır. Bazı ağır mobilyalar hareket etmektedir, duvarlardan sıvalar düşmektedir. Zarar hafiftir.
VII	Çok güçlü (Very strong)	İyi tasarım ve yapıya sahip binalarda öünsüz seviyede hasar meydana gelmekte, iyi inşa edilmiş sıradan yapılarda hafif ila orta hasar oluşmakta, kötü yapılanmış veya kötü tasarlanmış yapılarda ise ciddi hasar meydana gelmekte; bazı bacalar kırılmaktadır.
VIII	Yıkıcı (Severe)	İyi tasarıma sahip binalarda hafif hasar meydana gelirken, sıradan büyük binalarda önemli hasarlar ve kısmi çöküşler oluşmaktadır, kötü yapılanmış yapılarda ise hasar çok büyktür. Bacalar, fabrika çatıları, sütunlar, anıtlar ve duvarlar düşmektedir. Ağır mobilyalar devrilmektedir.
IX	Çok yıkıcı (Violent)	İyi tasarıma sahip yapılarda hasar önemli düzeydedir, sağlam yapıların formu bozulmaktadır. Büyük binalarda hasar çok fazladır ve kısmi çöküşler görülebilmektedir. Binaların temelleri yer değiştirmektedir.
X+	Çok ağır yıkıcı (Extreme)	Bazı iyi inşa edilmiş ahşap yapılar yıkılmakta, birçok taş yapılar temelden yıkılmaktadır. Raylar bükülmektedir. Şiddetin 10 üzerine çıktıgı durumlarda çok daha büyük çapta hasar meydana gelmektedir.

meydana geldiği, 10 ve üzerindeki şiddet değerine sahip depremlerde çok büyük hasarın olduğu hatta deprem sonrasında coğrafyanın değiştiği ve nüfusun büyük ölçüde yok olduğu kabul edilmektedir. Dolayısıyla, USGS'nin veri tabanında yer alan önemli depremler için en büyük şiddet değeri olarak 9 değeri yer almaktadır.

USGS veri tabanından elde edilen veriler öncelikle, 4. bölümde anlatıldığı gibi birtakım ön işlemlerden geçirilmiştir. Ardından yapay sinir ağının girdisi olarak ele

almıştır. Yapay sinir ağları, insan sinir sisteminin çalışma mekanizmasından esinlenerek geliştirilen ve sınıflandırma, fonksiyon kestirimi, özellik belirleme gibi problemlerin çözümünde kullanılan bir modelleme tekniğidir. Yapay sinir ağlarının bir tahmin aracı olarak kullanımına da literatürde sıkılıkla rastlanmaktadır. Bu çalışmada ise Şekil 1'de yer alan yapay sinir ağının tasarımında görüldüğü gibi girdi katmanında; (i) depremin büyüklüğü, (ii) depremin derinliği ve (iii) afetzededen merkez üssüne olan uzaklığını olmak üzere üç adet nöron bulunmaktadır. Ardından detayları sonraki bölümde

anlatılan gizli katman(lar) ve deprem şiddeti olmak üzere bir nöronandan oluşan çıktı katmanı yer almaktadır. Bu çalışmada, gizli katman ve bu katman(lar)daki gizli nöron sayıları değiştirilerek farklı ağ tasarımları için performans analizleri yapılmıştır. Belirlenen en uygun ağ yapısı için farklı eğitim algoritmaları kullanılarak en uygun eğitim yöntemi belirlenmiştir.

4. UYGULAMA VE BULGULAR (IMPLEMENTATION AND RESULTS)

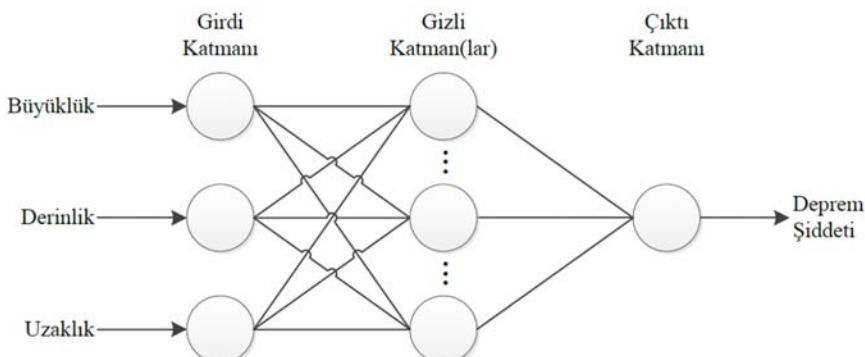
Uygulama aşamasında öncelikle, yapay sinir ağına girdi oluşturulması için USGS'nin veri tabanında yer alan 2011 yılında meydana gelen önemli depremlere ilişkin afetzedelerin verdiği cevaplar elde edilmiştir. Burada 161 önemli deprem için toplam 30.263 adet cevap bulunmaktadır. Yukarıda da bahsedildiği gibi deprem şiddeti göreceli bir kavram olmakla birlikte aynı büyüklük, derinlik ve uzaklık kategorisindeki bir deprem için iki afetzedede farklı değerlendirmeler yapabilmektedir. Bu karışıklığı gidermek ve her bir kategori için nihai deprem şiddetini belirlemek amacıyla, elde edilen veriler birtakım ön işlemlerden geçirilmiştir ve ağırlıklı ortalama alınarak şiddet değeri belirlenmiştir. Örneğin, Tablo 4'te görüldüğü gibi büyülüklük, derinlik ve uzaklık kategorileri sırasıyla 1, 1 ve 1 olan deprem için toplamda 106 adet geri dönüş alınmıştır. Tabloda, hangi şiddet değerini toplamda kaç kişinin hissettiği bilgisi yer almaktadır. Bu deprem için nihai deprem şiddeti, toplam cevap sayısına göre şiddet değerlerinin ağırlıklı ortalaması alınarak 4,73 olarak hesaplanmıştır.

Benzer şekilde 216 kategorinin hepsi için nihai deprem şiddeti değerleri, cevap sayısı ile ilişkilendirilerek hesaplanmıştır ve elde edilen sonuçlar yapay sinir ağına girdi olarak verilmiştir. Çalışmada geliştirilen yapay sinir ağları ileri beslemeli ve geri yayılmış bir ağ olup farklı ağ tasarımları ve eğitim algoritmaları için analiz yapılmıştır. Önce bölümde de bahsedildiği gibi geliştirilen yapay sinir ağının girdi katmanında; (i) depremin büyülüklüğü, (ii) depremin

derinliği ve (iii) afetzededen merkez üssüne olan uzaklıği olmak üzere üç adet nöron bulunmaktadır. Çıktı katmanı ise bir nörondan oluşmaktadır ve burada deprem şiddeti bilgisi yer almaktadır. Çalışma kapsamında, gizli katman sayısı ve her katmandaki gizli nöron sayıları için farklı ağ tasarımları yapılarak deprem şiddet tahmini için en uygun ağ yapısı belirlenmiştir. Ardından, belirlenen ağ tasarımı için yapay sinir ağları farklı eğitim algoritmaları kullanılarak eğitilmiş ve en uygun eğitim yöntemi belirlenmiştir. Burada yapılan tüm analizler, ortalama karesel hata ve R -değeri dikkate alınarak yapılmıştır.

Yapay sinir ağının geliştirilmesi için MATLAB Neural Network uygulaması kullanılmıştır. İleri beslemeli ve geri yayılmış bir yapay sinir ağının oluşturulması için kullanılan veri eğitim, test ve doğrulama amacıyla üç sınıfa rassal olarak bölünmüştür. Burada verinin bölünmesinde her aşama için sırasıyla 0,70, 0,15 ve 0,15 oranları verilmiştir. Durdurma kriteri olarak 1.000 tekrar sayısı ele alınmış ve ortaya çıkan her bir durum için yapay sinir ağı 10 kez eğitilmiştir. Çalışmanın ilk aşaması olan, uygun gizli katman ve her katmandaki gizli nöron sayılarının belirlenmesi aşamasında uygulamanın varsayılan eğitim algoritması olan Levenberg-Marquardt algoritması (trainlm) kullanılmıştır.

Farklı gizli katman ve nöron sayıları için ortalama karesel hata ve R -değeri cinsinden elde edilen sonuçlar Tablo 5 ve Tablo 6'da verilmiştir. Burada ilk sütunda ağ tasarımıyla ilişkin bilgi verilmekte; ilk değer girdi katmanı için nöron sayısını (3 girdi) ve son değer çıktı katmanı için nöron sayısını (1 çıktı) gösterirken; aradaki değer(ler) her bir gizli katmandaki nöron sayılarını göstermektedir. Tablo 5'te yer alan sonuçlar bir gizli katmanı ve Tablo 6'da yer alan sonuçlar iki gizli katmanı bulunan ağ tasarımları için elde edilen sonuçlardır. Tablo 6'da da görüldüğü gibi her bir gizli katmanda on adet gizli nöron olmak üzere iki gizli katmanın bulunduğu ağ tasarımı (3/10/10/1) performans parametreleri açısından en iyi sonucu vermektedir. Bu değerler, ilgili ağın 2. eğitiminde elde edilmiş olup italik olarak yazılmıştır.



Şekil 1. Yapay sinir ağı tasarımı (Artificial neural network design)

Tablo 4. 1/1/1 kategorisindeki bir deprem için yanıtların gösterimi
(Representation of responses for an earthquake in the 1/1/1 category)

Deprem Şiddeti	1	2	3	4	5	6	7	8	9
Toplam Cevap Sayısı	0	7	4	37	30	19	9	0	0

Tablo 5. Farklı ağ tasarımları için elde edilen sonuçlar: 1 gizli katman
(Results for different network designs: 1 hidden layer)

AT		1	2	3	4	5	6	7	8	9	10	Ort
3/5/1	OKH	0,39	0,40	0,33	0,38	0,42	0,45	0,38	0,38	0,55	0,28	0,39
	R	0,87	0,87	0,90	0,87	0,85	0,84	0,87	0,87	0,83	0,91	0,87
3/10/1	OKH	0,46	0,27	0,36	0,51	0,25	0,21	0,40	0,42	0,30	0,21	0,34
	R	0,86	0,91	0,88	0,84	0,92	0,93	0,87	0,86	0,90	0,93	0,89
3/20/1	OKH	1,10	0,27	0,26	0,22	0,25	0,47	0,80	0,47	0,26	0,29	0,44
	R	0,72	0,91	0,91	0,93	0,92	0,84	0,83	0,85	0,93	0,90	0,88

AT: Ağ Tasarımı, OKH: Ortalama Karesel Hata, R: R-Degeri, Ort: Ortalama

Tablo 6. Farklı ağ tasarımları için elde edilen sonuçlar: 2 gizli katman
(Results for different network designs: 2 hidden layers)

AT		1	2	3	4	5	6	7	8	9	10	Ort
3/5/5/1	OKH	0,33	0,65	0,25	0,21	0,35	0,25	0,55	0,24	0,58	0,23	0,36
	R	0,89	0,77	0,92	0,93	0,89	0,92	0,82	0,92	0,81	0,92	0,88
3/5/10/1	OKH	0,16	0,27	0,32	0,21	0,40	0,24	0,29	0,27	0,39	0,29	0,28
	R	0,95	0,91	0,90	0,93	0,86	0,92	0,91	0,91	0,88	0,91	0,91
3/5/20/1	OKH	0,19	0,28	0,39	0,25	0,21	0,41	0,24	0,19	0,25	0,71	0,31
	R	0,94	0,91	0,87	0,92	0,93	0,86	0,92	0,94	0,92	0,79	0,90
3/10/5/1	OKH	1,22	0,21	0,21	0,33	0,21	0,28	0,24	0,32	1,04	0,33	0,44
	R	0,52	0,93	0,93	0,89	0,93	0,91	0,92	0,90	0,60	0,90	0,84
3/10/10/1	OKH	0,25	0,14	0,41	0,42	0,45	0,44	0,27	1,75	0,48	0,31	0,49
	R	0,92	0,96	0,88	0,87	0,85	0,85	0,92	0,23	0,85	0,90	0,82
3/10/20/1	OKH	0,28	0,24	0,25	0,34	0,20	0,55	0,62	0,35	0,37	0,21	0,34
	R	0,91	0,92	0,94	0,88	0,93	0,81	0,86	0,89	0,88	0,93	0,90
3/20/5/1	OKH	0,82	0,32	0,32	0,66	0,56	0,59	0,25	0,21	0,29	1,08	0,51
	R	0,70	0,91	0,90	0,80	0,81	0,85	0,92	0,93	0,90	0,57	0,83
3/20/10/1	OKH	0,38	0,49	0,23	0,28	0,63	0,25	0,51	0,28	0,22	0,22	0,35
	R	0,88	0,84	0,92	0,92	0,82	0,92	0,87	0,92	0,93	0,93	0,89
3/20/20/1	OKH	0,71	0,36	0,92	0,60	0,36	0,55	0,25	0,39	1,00	0,55	0,57
	R	0,78	0,89	0,73	0,84	0,89	0,85	0,92	0,91	0,77	0,83	0,84

AT: Ağ Tasarımı, OKH: Ortalama Karesel Hata, R: R-Degeri, Ort: Ortalama

Burada ortalama karesel hata değeri 0,14 ve R-değeri 0,96'dır. Öte yandan, söz konusu ağıın 8. eğitiminde performans parametreleri açısından en kötü değerler gözlemlenmiştir. Bu değerler italik olarak yazılmış olup ortalama karesel hata değeri 1,75 iken R-değeri 0,23 olarak elde edilmiştir. Bu açıdan incelendiğinde, 3/10/10/1 tasarımlı için elde edilen sonuçların diğerleriyle karşılaştırıldığında oldukça geniş bir aralıktır yer aldığı söyleyenebilir. Bu nedenle, performans parametrelerinin ortalamaları açısından incelendiğinde, iki gizli katman ve her bir katmanda sırasıyla beş ve on gizli nöronun bulunduğu ağ tasarımlının daha kararlı sonuçlar üreten bir ağ yapısı olduğu görülmektedir. Burada italik olarak yazıldığı gibi ortalama karesel hataların ortalama değeri 0,28 ve R-değerlerinin ortalaması 0,91'dir. Böylece hem herhangi bir eğitim için ve hem de ortalama olarak bütün eğitimlerde en iyi sonuçları üreten iki farklı ağ tasarımı ortaya çıkmış olmaktadır.

Uygun ağ tasarımlarının belirlenmesinin ardından, hem performans parametrelerinin gerçekleştirilen deneyler içindeki tekil olarak en iyi sonucu veren 3/10/10/1 tasarımlındaki, hem de performans parametrelerinin bütün deneylerdeki ortalamaları açısından en iyi sonucu veren 3/5/10/1 tasarımlındaki ağılar farklı eğitim algoritmaları 2140

kullanılarak eğitilmiş ve en uygun eğitim yöntemi belirlenmiştir. Burada MATLAB'ta bulunan ve ileri beslemeli ağılar için uygun algoritmalar kullanılmıştır. Kullanılan algoritmalarla ilişkin açıklamalar Tablo 7'de sunulmuştur [56]. Önceki aşamada olduğu gibi elde edilen eğitim sonuçları ortalama karesel hata ve R-değeri cinsinden analiz edilmiştir. Tablo 8 ve Tablo 9'da sırasıyla 3/10/10/1 ve 3/5/10/1 ağ tasarımı için elde edilen sonuçlar verilmiştir. Her iki ağ tasarımı için de Bayes Düzenlemesi ile Levenberg-Marquardt eğitim algoritmasının kullanıldığı eğitimi yöntemi (trainbr) en uygun yöntem olarak belirlenmiştir. Bu yöntem ile Tablo 8 ve Tablo 9'da italik olarak yazılan hücrelerde de görüldüğü gibi hem performans parametreleri hem de performans parametrelerinin ortalaması cinsinden en iyi sonuçlar elde edilmiştir. Ortalama karesel hataların ortalama değeri 0,13 ve R-değerlerinin ortalaması 0,96 olarak gözlenmiştir.

Çalışma kapsamında en uygun eğitim yöntemi olarak belirlenen "trainbr" eğitim algoritmasında ağırlık ve sapma değerleri Levenberg-Marquardt algoritmasına göre güncellenmektedir. Karesel hatalar ve ağırlıkların doğru kombinasyonunu minimize eden ağ yapısı belirlenmekte ve bu süreçte Bayes Düzenlemesi (Bayesian Regularization)

Tablo 7. Eğitim algoritmalarının açıklamaları (Descriptions of the training algorithms)

Algoritma	Açıklama
LM	Levenberg-Marquardt geri yayılımı (Levenberg-Marquardt backpropagation)
BFG	BFGS yarı-Newton geri yayılımı (BFGS quasi-Newton backpropagation)
BR	Bayes düzenlemesi geri yayılımı (Bayesian regularization backpropagation)
CGB	Powell-Beale yeniden başlatmaları ile eşlenik gradyan geri yayılımı (Conjugate gradient backpropagation with Powell-Beale restarts)
CGF	Fletcher-Reeves güncellemeleri ile eşlenik gradyan geri yayılımı (Conjugate gradient backpropagation with Fletcher-Reeves updates)
CGP	Polak-Ribiere güncellemeleri ile eşlenik gradyan geri yayılımı (Conjugate gradient backpropagation with Polak-Ribiere updates)
GD	Gradyan azalış geri yayılımı (Gradient descent backpropagation)
GDA	Uyarlanabilir öğrenme oranı geri yayılımlı gradyan azalışı (Gradient descent with adaptive learning rate backpropagation)
GDM	Momentum geri yayılımlı gradyan azalışı (Gradient descent with momentum backpropagation)
GDX	Momentum ve uyarlanabilir öğrenme oranı geri yayılımlı gradyan azalışı (Gradient descent with momentum and adaptive learning rate backpropagation)
OSS	Tek-adımlı sekant geri yayılımı (One-step secant backpropagation)
RP	Esnek geri yayılım (Resilient backpropagation)
SCG	Ölçeklendirilmiş eşlenik gradyan geri yayılımı (Scaled conjugate gradient backpropagation)

denmektedir. Çalışmanın ilk aşaması olan, uygun gizli katman ve her katmandaki gizli nöron sayılarının belirlenmesi aşamasında varsayılan eğitim algoritması olarak kullanılan 'trainlm' eğitim fonksiyonu ise sıklıkla kullanılan hızlı bir fonksiyon olup MATLAB Neural Network uygulamasının da varsayılan yöntemidir. Bu yöntemin farklı bir uyarlaması olan ve çalışmada en uygun yöntem olarak belirlenen 'trainbr' yöntemi çalışma kapsamında yapılan deneylerde maksimum tekrar sayısı olan 1.000 iterasyon boyunca uygulanmış ve yaklaşık 10 saniye sonunda sonuçlar elde edilmiştir. Tekrar sayısı artırıldığında anlamlı farklar gözlenmemiştir.

Şekil 2 ve Şekil 3'te uygun ağ tasarımları olarak belirlenen ağ yapıları verilmiştir. Şekil 2'deki tasarım performans parametreleri cinsinden en iyi sonuçları veren, iki gizli katmanın bulunduğu ve her bir gizli katmanda on adet gizli nöronun bulunduğu ağ yapısıdır. Şekil 3'te performans parametrelerinin ortalaması için en iyi sonuçları veren, iki gizli katmanın bulunduğu ve her bir gizli katmanda sırasıyla beş ve on adet gizli nöronun bulunduğu ağ tasarımları sunulmuştur. Şekil 4 ise bu ağların Levenberg-Marquardt algoritmasının Bayes Düzenlemesi ile revize edildiği yöntem ile eğitildiği durum için elde edilen eğitim sonuçları gösterilmiştir. Bu değerler 3/10/10/1 tasarımlının 4. eğitiminde ve 3/5/10/1 tasarımlının 1. eğitiminde elde edilmiştir. Tablo 8 ve Tablo 9'da da ilgili değerler italik olarak yazılmıştır. Çalışma kapsamında oluşturulan bir regresyon modeli için (yapay sinir ağına benzer şekilde), y

tahmin edilen deprem şiddeti, \mathbf{x} vektörünün bileşenleri de depremin büyüklüğü, depremin derinliği ve afetzededenin merkez üssüne olan uzaklığını olmak üzere; $y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_3x_3$ modeli ile yapılan tahminin performansı incelendiğinde, ortalama karesel hata değeri 0,70 ve R -değeri 0,75 olarak elde edilmiştir. Tahmin edilen regresyon katsayıları ve diğer performans ölçütleri Tablo 10'da sunulmuştur.

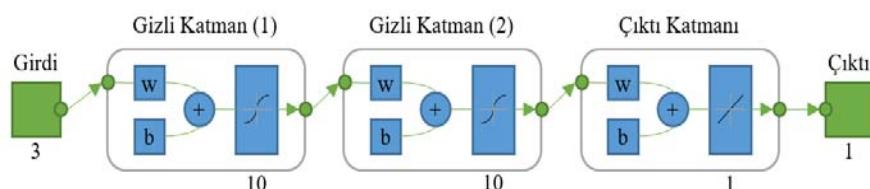
5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, ileri beslemeli ve geri yayılımlı bir yapay sinir ağı ile deprem şiddeti tahmini yapılmıştır. Öncelikle, USGS veri tabanında yer alan ve 2011 yılında gerçekleşen önemli depremler olarak adlandırılan depremlere ilişkin bilgiler elde edilmiştir. Bu bilgiler arasında depremin büyüklüğü ve derinliğinin yanı sıra merkez üssüne farklı uzaklıklarda bulunan afetzedelerin depremi nasıl hissettiğine ilişkin bilgiler de yer almaktadır. Ardından bu veriler ön işlemlerden geçirilerek yapay sinir ağıının girdisi olarak ele alınmıştır. Farklı ağ tasarımları için yapay sinir ağı eğitilerek ortalama karesel hata ve R -değeri açısından en iyi sonucu veren ağ yapısı belirlenmiştir. Burada, iki gizli katmanın ve her gizli katmanda sırasıyla beş ve on gizli nöronun bulunduğu ağ tasarımları, performans parametrelerinin ortalaması cinsinden en uygun ağ yapısı olarak belirlenmiştir. Ardından, bu ağ farklı eğitim algoritmaları kullanılarak eğitilmiş ve elde edilen sonuçlar analiz edilerek en uygun eğitim yöntemi belirlenmiştir. Söz konusu ağ

Tablo 8. Farklı eğitim algoritmaları için elde edilen sonuçlar: 3/10/10/1 ağ tasarımı
(Results for different training algorithms: 3/10/10/1 network design)

Alg.		1	2	3	4	5	6	7	8	9	10	Ort
LM	OKH	0,25	0,14	0,41	0,42	0,45	0,44	0,27	1,75	0,48	0,31	0,49
	R	0,92	0,96	0,88	0,87	0,85	0,85	0,92	0,23	0,85	0,90	0,82
BFG	OKH	0,53	0,39	0,35	0,27	0,37	0,25	0,40	0,39	0,55	0,46	0,40
	R	0,82	0,87	0,88	0,91	0,87	0,92	0,87	0,88	0,81	0,84	0,87
BR	OKH	0,16	0,17	0,11	0,09	0,12	0,13	0,13	0,10	0,15	0,11	0,13
	R	0,95	0,95	0,97	0,97	0,96	0,96	0,96	0,97	0,95	0,97	0,96
CGB	OKH	0,56	0,91	0,25	0,46	0,57	0,42	0,53	0,31	0,43	0,79	0,52
	R	0,81	0,65	0,92	0,84	0,80	0,86	0,81	0,90	0,85	0,75	0,82
CGF	OKH	0,43	0,41	1,00	0,63	0,63	0,35	0,40	0,31	0,45	0,30	0,49
	R	0,85	0,87	0,60	0,77	0,77	0,88	0,87	0,90	0,85	0,90	0,83
CGP	OKH	0,50	0,79	0,38	0,36	0,58	0,97	0,38	0,28	0,42	0,55	0,52
	R	0,83	0,70	0,87	0,88	0,79	0,62	0,87	0,91	0,86	0,81	0,81
GD	OKH	0,34	0,56	0,48	1,66	0,36	0,32	0,36	0,53	16,45	0,54	2,16
	R	0,89	0,80	0,84	0,65	0,88	0,89	0,88	0,81	-0,40	0,81	0,70
GDA	OKH	0,81	0,66	0,80	0,89	0,72	0,85	1,00	1,28	0,73	0,72	0,85
	R	0,71	0,77	0,76	0,66	0,75	0,70	0,68	0,50	0,74	0,74	0,70
GDM	OKH	3,43	9,92	4,58	5,89	2,62	3,76	11,76	2,82	1,50	1,85	4,81
	R	0,38	-0,31	0,54	0,38	0,56	0,19	0,18	0,43	0,74	0,63	0,37
GDX	OKH	0,52	0,45	0,38	1,97	0,49	0,43	1,26	1,04	0,75	0,45	0,77
	R	0,82	0,85	0,87	0,34	0,83	0,85	0,51	0,61	0,75	0,84	0,73
OSS	OKH	0,43	0,74	0,60	0,56	0,41	0,49	0,56	1,14	0,57	0,76	0,63
	R	0,86	0,75	0,79	0,80	0,86	0,83	0,80	0,53	0,80	0,72	0,77
RP	OKH	0,29	0,41	0,65	0,77	0,72	0,60	0,59	0,41	0,36	0,49	0,53
	R	0,90	0,87	0,77	0,73	0,77	0,79	0,79	0,86	0,88	0,83	0,82
SCG	OKH	0,88	0,38	0,81	0,33	0,42	0,50	0,41	0,57	0,29	0,99	0,56
	R	0,72	0,87	0,70	0,89	0,86	0,82	0,86	0,80	0,91	0,62	0,80

Alg: Algoritma, OKH: Ortalama Karesel Hata, R: R-Değiri, Ort: Ortalama



Şekil 2. 3/10/10/1 ağ tasarımı (3/10/10/1 network design)

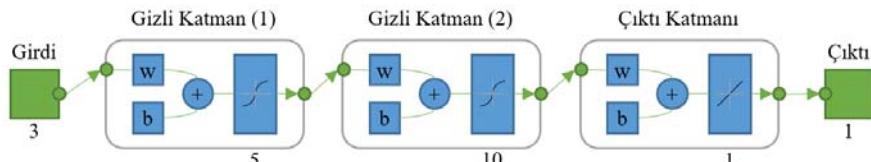
yapısı için Bayes Düzenlemesi ile Levenberg-Marquardt algoritmasının kullanıldığı eğitim yöntemi ile performans parametreleri açısından en iyi sonuçlar elde edilmiştir. Deprem şiddeti tahmini, afet sonrasında oluşacak etkinin tahmin edilmesi ve dolayısıyla afet operasyonlarının seviyesinin belirlenmesinde kritik öneme sahiptir. Bu çalışma kapsamında önerilen deprem şiddet tahmini yapısı ile gelecek çalışmalarda, deprem sonrasında oluşacak yaralı sayısının, binalardaki hasarın ve ekonomik kaybın tahmini yapılabilir. Deprem şiddeti tahmininin afet operasyonları

yönetimi kapsamında ele alınan diğer çalışmalara entegre edilmesi de bir diğer gelecek çalışma alanı olabilir. Örneğin, afet öncesinde konumlandırılan yardım tesislerinin konumlarının ve kapasitelerinin belirlenmesinde, afet sonrasında dağıtılabilecek yardım malzemelerinin talep miktarlarının belirlenmesinde kullanılan mevcut yöntemlere şiddet tahmin yapısı entegre edilerek bütünlük bir optimizasyon çatısı sunulabilir. Böylelikle, lokal ve merkezi yönetim birimleri için afet yardım operasyonları için etkin planlar yapılabilir.

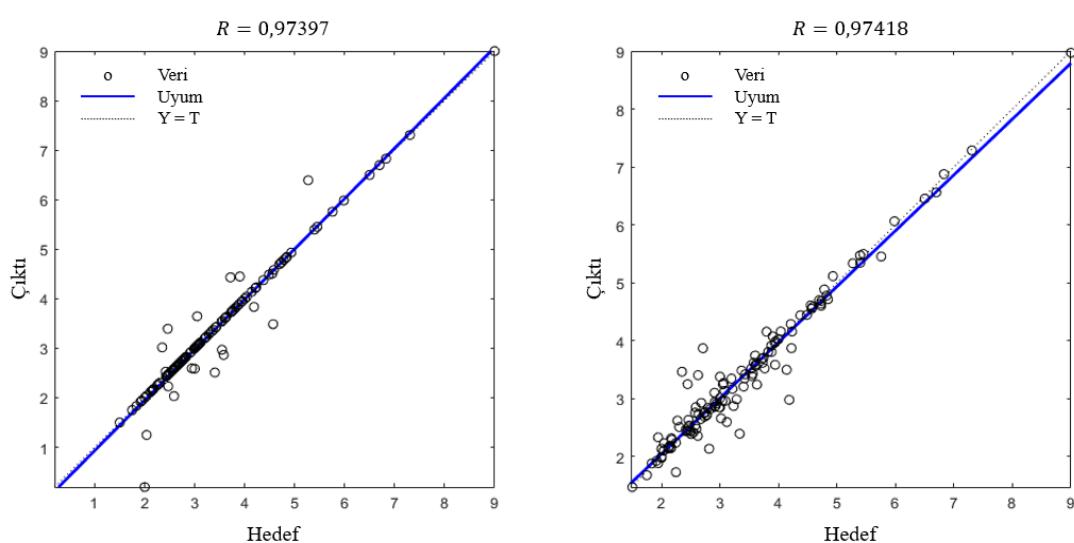
Tablo 9. Farklı eğitim algoritmaları için elde edilen sonuçlar: 3/5/10/1 ağ tasarımı
 (Results for different training algorithms: 3/5/10/1 network design)

Alg.		1	2	3	4	5	6	7	8	9	10	Ort
LM	OKH	0,16	0,27	0,32	0,21	0,40	0,24	0,29	0,27	0,39	0,29	0,28
	R	0,95	0,91	0,90	0,93	0,86	0,92	0,91	0,91	0,88	0,91	0,91
BFG	OKH	1,07	0,33	0,50	1,67	0,39	0,47	1,50	0,57	0,33	0,46	0,73
	R	0,67	0,89	0,83	0,31	0,87	0,84	0,19	0,80	0,89	0,84	0,71
BR	OKH	0,08	0,16	0,11	0,14	0,14	0,12	0,20	0,11	0,16	0,10	0,13
	R	0,97	0,95	0,96	0,95	0,95	0,96	0,93	0,96	0,95	0,97	0,96
CGB	OKH	0,63	0,38	0,40	0,37	0,96	0,47	0,72	0,52	0,67	0,46	0,56
	R	0,78	0,87	0,87	0,87	0,64	0,84	0,75	0,82	0,76	0,84	0,80
CGF	OKH	0,64	0,36	0,52	0,63	0,50	0,67	1,50	0,57	0,40	0,53	0,63
	R	0,79	0,88	0,83	0,77	0,82	0,77	0,23	0,80	0,87	0,81	0,76
CGP	OKH	0,54	0,75	1,56	0,45	0,94	0,77	0,47	0,53	0,47	1,78	0,83
	R	0,81	0,72	0,33	0,85	0,64	0,72	0,84	0,81	0,84	0,14	0,67
GD	OKH	0,45	17,11	15,40	0,75	0,70	0,48	2,81	0,58	0,36	0,45	3,91
	R	0,84	-0,53	0,72	0,72	0,74	0,83	0,22	0,79	0,88	0,85	0,61
GDA	OKH	0,97	0,62	0,53	0,62	1,08	1,20	1,02	2,28	2,37	0,82	1,15
	R	0,62	0,78	0,82	0,78	0,59	0,59	0,60	0,59	-0,09	0,70	0,60
GDM	OKH	4,06	4,49	10,66	8,47	64,67	3,70	1,87	5,35	8,95	47,30	15,95
	R	0,50	0,04	0,03	0,37	-0,49	-0,11	0,59	-0,23	0,15	-0,36	0,05
GDX	OKH	1,54	0,59	0,83	0,65	1,30	1,64	2,31	1,51	1,58	0,77	1,27
	R	0,26	0,79	0,69	0,77	0,44	0,30	0,20	0,63	0,38	0,72	0,52
OSS	OKH	1,32	1,33	0,47	1,38	0,38	0,60	0,90	0,66	0,70	0,49	0,83
	R	0,45	0,38	0,83	0,36	0,87	0,78	0,70	0,77	0,76	0,83	0,67
RP	OKH	0,48	1,17	0,36	0,49	0,56	0,81	1,06	0,63	0,83	0,85	0,72
	R	0,84	0,54	0,88	0,83	0,80	0,70	0,57	0,77	0,68	0,73	0,73
SCG	OKH	0,55	0,47	0,55	0,56	0,77	0,58	0,45	1,00	0,78	0,36	0,61
	R	0,80	0,84	0,81	0,82	0,74	0,79	0,84	0,60	0,70	0,88	0,78

Alg: Algoritma, OKH: Ortalama Karesel Hata, R: R-Degeri, Ort: Ortalama



Şekil 3. 3/5/10/1 ağ tasarımı (3/5/10/1 network design)



Şekil 4. 3/10/10/1 ve 3/5/10/1 tasarımlarındaki ağlar için eğitim sonuçları: Bayes Düzenlemesi
 (Training results for the 3/10/10/1 and 3/5/10/1 network designs: Bayesian Regularization)

Tablo 10. Çoklu-doğrusal regresyon modeli için elde edilen sonuçlar (Results for multiple-linear regression model)

Katsayı	Tahmin Edilen Değer	Standart Hata	t-İstatistiği	p-Değeri
β_0	3,33100	0,257890	12,9160	$1,2049 \times 10^{-24}$
β_1	0,52449	0,060334	8,6930	$1,8538 \times 10^{-14}$
β_2	-0,13053	0,054911	-2,3770	$1,8994 \times 10^{-2}$
β_3	-0,44666	0,045782	-9,7563	$5,2876 \times 10^{-17}$

TEŞEKKÜR (ACKNOWLEDGEMENT)

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 115M020 numaralı proje kapsamında desteklenmiştir. Desteklerinden dolayı TÜBİTAK'a teşekkürlerimizi sunarız.

KAYNAKLAR (REFERENCES)

- Van Wassenhove L.N., Humanitarian aid logistics: supply chain management in high gear, *J. Oper. Res. Soc.*, 57 (5), 475-489, 2006.
- Erdik M., Earthquake vulnerability of buildings and a mitigation strategy: Case of Istanbul, Washington DC: World Bank, 79-92, 2003.
- Kumar A., Latif Y.L., Daver F., Developing forecasting tool for humanitarian relief organizations in emergency logistics planning, *International Journal of Economics and Management Engineering*, 6 (11), 3194-3200, 2012.
- European Commission. Action plan on the Sendai framework for disaster risk reduction 2015–2030, European Union. <http://ec.europa.eu>. Yayın tarihi Haziran 17, 2016. Erişim tarihi Mayıs 13, 2020.
- Xu X., Qi Y., Hua Z., Forecasting demand of commodities after natural disasters, *Expert Syst. Appl.*, 37 (6), 4313-4317, 2010.
- Sheu J.B., Challenges of emergency logistics management, *Transportation Research Part E: Logistics and Transportation Review*, 43 (6), 655-659, 2007.
- United States Geological Survey. Earthquake Hazards Program, Significant Earthquakes Archive. <https://earthquake.usgs.gov/earthquakes/browse/significant.php>. Yayın tarihi 2011. Erişim tarihi Mart 8, 2017.
- Reyes J., Morales-Esteban A., Martínez-Álvarez F., Neural networks to predict earthquakes in Chile, *Appl. Soft Comput.*, 13 (2), 1314-1328, 2013.
- Corbi F., Sandri L., Bedford J., Funiciello F., Brizzi S., Rosenau M., Lallemand S., Machine learning can predict the timing and size of analog earthquakes, *Geophys. Res. Lett.*, 46 (3), 1303-1311, 2019.
- Sankaranarayanan S., Prabhakar M., Satish S., Jain P., Ramprasad A., Krishnan A., Flood prediction based on weather parameters using deep learning, *J. Water Clim. Change*, 11 (4), 1766-1783, 2020.
- Kuradusenge M., Kumaran S., Zennaro M., Rainfall-induced landslide prediction using machine learning models: The case of Ngororero District, Rwanda, *Int. J. Environ. Res. Public Health*, 17 (11), 4147, 2020.
- Battarra M., Balcik B., Xu H., Disaster preparedness using risk-assessment methods from earthquake engineering, *Eur. J. Oper. Res.*, 269 (2), 423-435, 2018.
- Adeli H., Panakkat A., A probabilistic neural network for earthquake magnitude prediction, *Neural networks*, 22 (7), 1018-1024, 2009.
- Külahçı F., İnceöz M., Doğru M., Aksoy E., Baykara O., Artificial neural network model for earthquake prediction with radon monitoring, *Appl. Radiat. Isot.*, 67 (1), 212-219, 2009.
- Alarifi A.S., Alarifi N.S., Al-Humidan S., Earthquakes magnitude predication using artificial neural network in northern Red Sea area, *Journal of King Saud University-Science*, 24 (4), 301-313, 2012.
- Amit Z., Arjun S., Quantification of recent seismicity and a back propagation Neural Network for forecasting of earthquake magnitude in Northeast Region of India, *Disaster Advances*, 10 (6), 17-34, 2017.
- Mousavi S.M., Beroza G.C., A machine-learning approach for earthquake magnitude estimation, *Geophys. Res. Lett.*, 47 (1), e2019GL085976, 2020.
- Panakkat A., Adeli H., Neural network models for earthquake magnitude prediction using multiple seismicity indicators, *Int. J. Neural Syst.*, 17 (01), 13-33, 2007.
- Asim K.M., Martínez-Álvarez F., Basit A., Iqbal T., Earthquake magnitude prediction in Hindukush region using machine learning techniques, *Nat. Hazard.*, 85 (1), 471-486, 2017.
- Moustra M., Avraamides M., Christodoulou C., Artificial neural networks for earthquake prediction using time series magnitude data or seismic electric signals, *Expert Syst. Appl.*, 38 (12), 15032-15039, 2011.
- Juang C.H., Elton D.J., Fuzzy logic for estimation of earthquake intensity based on building damage records, *Civil Engineering Systems*, 3 (4), 187-191, 1986.
- Kubo H., Kunugi T., Suzuki W., Suzuki S., Aoi S., Hybrid predictor for ground-motion intensity with machine learning and conventional ground motion prediction equation, *Sci. Rep.*, 10 (1), 1-12, 2020.
- Bradley B.A., Site-specific and spatially-distributed ground-motion intensity estimation in the 2010–2011 Canterbury earthquakes, *Soil Dyn. Earthquake Eng.*, 61, 83-91, 2014.
- Jozinovic D., Lomax A., Stajduhar I., Michelini A., Rapid prediction of earthquake ground shaking intensity using raw waveform data and a convolutional neural network, *Geophys. J. Int.*, 222 (2), 1379-1389, 2020.
- Nicolis O., Plaza F., Salas R., Prediction of intensity and location of seismic events using deep learning, *Spatial Stat.*, 42, 100442, 2021.
- Asif A., Dawood M., Jan B., Khurshid J., DeMaria M., PHURIE: hurricane intensity estimation from infrared satellite imagery using machine learning, *Neural Computing and Applications*, 32 (9), 4821-4834, 2020.

27. Burks L., Miller M., Zadeh R., Rapid estimate of ground shaking intensity by combining simple earthquake characteristics with tweets, 10th US National conference on earthquake engineering, Anchorage, Alaska, USA, 21-25 July, 2014.
28. Kropivnitskaya Y., Tiampo K.F., Qin J., Bauer M.A., Real-Time Earthquake Intensity Estimation Using Streaming Data Analysis of Social and Physical Sensors, *Pure Appl. Geophys.*, 174 (6), 2331-2349, 2017.
29. Zahera H.M., Sherif M.A., Ngonga Ngomo A.C., Jointly learning from social media and environmental data for typhoon intensity prediction, 10th International Conference on Knowledge Capture, Marina Del Rey, CA, USA, 231-234, 19-21 November, 2019.
30. Günaydin K., Günaydin A., Peak ground acceleration prediction by artificial neural networks for northwestern Turkey, *Math. Probl. Eng.*, 2008, 1-20, 2008.
31. Wang Z., Zentner I., Pedroni N., Zio E., Adaptive artificial neural networks for seismic fragility analysis, 2nd International Conference on System Reliability and Safety (ICSRs), Milan, Italy, 414-420, 20-22 December, 2017.
32. Asim K.M., Moustafa S.S., Niaz I.A., Elawadi E.A., Iqbal T., Martínez-Álvarez F., Seismicity analysis and machine learning models for short-term low magnitude seismic activity predictions in Cyprus, *Soil Dyn. Earthquake Eng.*, 130, 105932, 2020.
33. Erdik M., Şeşetyan K., Demircioğlu M.B., Hancılar U., Zülfikar C., Rapid earthquake loss assessment after damaging earthquakes, *Soil Dyn. Earthquake Eng.*, 31 (2), 247-266, 2011.
34. Sebatlı A., Çavdur F., Analysis of relief supplies distribution operations via simulation, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2079-2096, 2019.
35. Samardjieva E., Badal J., Estimation of the expected number of casualties caused by strong earthquakes, *Bull. Seismol. Soc. Am.*, 92 (6), 2310-2322, 2002.
36. Aghamohammadi H., Mesgari M.S., Mansourian A., Molaei D., Seismic human loss estimation for an earthquake disaster using neural network, *Int. J. Environ. Sci. Technol.*, 10 (5), 931-939, 2013.
37. Gul M., Guneri A.F., An artificial neural network-based earthquake casualty estimation model for Istanbul city, *Nat. Hazard.*, 84 (3), 2163-2178, 2016.
38. Amirifar L., Shafiee H., Estimating of Loss Human Life Caused Through Earthquake Employing Neural Network, *Journal of Advances in Computer Research*, 9 (2), 71-89, 2018.
39. Xing H., Junyi S., Jin H., The casualty prediction of earthquake disaster based on Extreme Learning Machine method, *Nat. Hazard.*, 102 (3), 873-886, 2020.
40. Cui S., Yin Y., Wang D., Li Z., Wang Y., A stacking-based ensemble learning method for earthquake casualty prediction, *Appl. Soft Comput.*, 101, 107038, 2021.
41. Ganguly K.K., Nahar N., Hossain B.M., A machine learning-based prediction and analysis of flood affected households: A case study of floods in Bangladesh, *Int. J. Disaster Risk Reduct.*, 34, 283-294, 2019.
42. Hashemi M., Alesheikh A.A., A GIS-based earthquake damage assessment and settlement methodology, *Soil Dyn. Earthquake Eng.*, 31 (11), 1607-1617, 2011.
43. So E., Spence R., Estimating shaking-induced casualties and building damage for global earthquake events: a proposed modelling approach, *Bull. Earthquake Eng.*, 11 (1), 347-363, 2013.
44. Musson R.M.W., Intensity-based seismic risk assessment, *Soil Dyn. Earthquake Eng.*, 20 (5-8), 353-360, 2000.
45. Molas G.L., Yamazaki F., Neural networks for quick earthquake damage estimation, *Earthquake engineering & structural dynamics*, 24 (4), 505-516, 1995.
46. Barbosa A.R., Ribeiro F.L., Neves L.A., Influence of earthquake ground-motion duration on damage estimation: application to steel moment resisting frames, *Earthquake Engineering & Structural Dynamics*, 46 (1), 27-49, 2017.
47. Chaurasia K., Kanse S., Yewale A., Singh V.K., Sharma B., Dattu B.R., Predicting Damage to Buildings Caused by Earthquakes Using Machine Learning Techniques, 2019 IEEE 9th International Conference on Advanced Computing (IACC), Tiruchirappalli, India, 81-86, 13-14 December, 2019.
48. Mangalathu S., Sun H., Nweke C.C., Yi Z., Burton H.V., Classifying earthquake damage to buildings using machine learning, *Earthquake Spectra*, 36 (1), 183-208, 2020.
49. Cavallo E., Powell A., Becerra O., Estimating the direct economic damages of the earthquake in Haiti, *The Economic Journal*, 120 (546), F298-F312, 2010.
50. Kim J.M., Bae J., Son S., Son K., Yum S.G., Development of Model to Predict Natural Disaster-Induced Financial Losses for Construction Projects Using Deep Learning Techniques, *Sustainability*, 13 (9), 5304, 2021.
51. Bi C., Fu B., Chen J., Zhao Y., Yang L., Duan Y., Shi Y., Machine learning based fast multi-layer liquefaction disaster assessment, *World Wide Web*, 22 (5), 1935-1950, 2019.
52. Xu Y., Lu X., Tian Y., Huang Y., Real-time seismic damage prediction and comparison of various ground motion intensity measures based on machine learning, *J. Earthquake Eng.*, 1-21, 2020.
53. Richter, C.F., An instrumental earthquake magnitude scale, *Bull. Seismol. Soc. Am.*, 25 (1), 1-32, 1935.
54. Wood, H. O., Neumann, F. Modified Mercalli intensity scale of 1931, *Bull. Seismol. Soc. Am.*, 21 (4), 277-283, 1931.
55. United States Geological Survey. The Modified Mercalli Intensity Scale. <https://www.usgs.gov/natural-hazards/earthquake-hazards/science/modified-mercalli-intensity-scale>. Yayın tarihi 1989. Erişim tarihi Nisan 11, 2017.
56. MathWorks. Help Center, Deep Learning Toolbox. <https://www.mathworks.com/help/deeplearning>. Yayın tarihi 2020. Erişim tarihi Mayıs 4, 2020.

