

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

JEOFİZİK MÜHENDİSLİĞİ ANABİLİM DALI

**DEPREMLERİN MAGNİTÜD TÜRÜ DÖNÜŞÜMÜ VE MAKSİMUM YER HAREKETİ İVMESİ
(PGA) TAHMİNİNDE YAPAY ZEKA UYGULAMALARI**

DOKTORA TEZİ

Kaan Hakan ÇOBAN

**TEMMUZ 2021
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

JEOFİZİK MÜHENDİSLİĞİ ANABİLİM DALI

**DEPREMLERİN MAGNİTÜD TÜRÜ DÖNÜŞÜMÜ VE MAKSİMUM YER HAREKETİ
İVMESİ (PGA) TAHMİNİNDE YAPAY ZEKA UYGULAMALARI**

Kaan Hakan ÇOBAN

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"DOKTOR (JEOFİZİK MÜHENDİSLİĞİ)"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 15 / 06 / 2021

Tezin Savunma Tarihi : 08 / 07 / 2021

Tez Danışmanı : Prof. Dr. Nilgün Lütfiye SAYIL

Trabzon 2021

ÖNSÖZ

Bu tez kapsamında, Sismoloji alanında karşılaşılan magnitüd türü dönüşümü ve maksimum yer hareketi ivmesinin (PGA) tahmini olarak iki önemli problem belirlenmiştir. Bu problemlere, son yıllarda gelişen Yapay Zekâ teknikleri (Yapay Sinir Ağları, Makine Öğrenme Algoritmaları ve Meta-Sezgisel Algoritmalar) uygulanarak daha güvenilir denklemler ve modeller oluşturularak hata oranları az çözümler üretilmesi amaçlanmıştır.

Çalışmalarında tecrübesiyle bana yol gösteren, katkılarıyla destek olan danışmanım Sayın Prof. Dr. Nilgün SAYIL' a emeği ve hoşgörüsü için teşekkürlerimi sunarım.

Tez sürecimde bilgi ve tecrübeleriyle bana yardımcı olan Dr. Öğr. Üyesi Ali Erden BABACAN ve Prof. Dr. Aykut AKGÜN' ne teşekkürlerimi sunarım.

Tez çalışmalarım, akademik çalışmalarım ve iş hayatımda yardımlarını hiçbir zaman esirgemeyen Arş. Gör. Dr. Özgenç AKIN ve Dr. Öğr. Üyesi Erdem BAYRAK başta olmak üzere tüm bölüm arkadaşlarıma teşekkür ederim.

Yoğun tez çalışmalarım sırasında anlayışı ve hoşgörüsü ile bana her zaman destek olan, hayat arkadaşım sevgili eşim Jeofizik Yüksek Mühendisi Bengi Behiye ÇOBAN'a teşekkür ederim.

Hakkını hiçbir zaman ödeyemeyeceğim, beni zor şartlarda yetiştiren ve büyüten, her zaman bana güç veren, hayatımın en değerli varlığı annem Nahide ÇOBAN'a ve ailemi oluşturan rahmetli Teyzem Nazife GÜNGÖR'e, Eniştem İsmail GÜNGÖR'e ve Kuzenlerime sonsuz teşekkürlerimi sunarım.

Bu tezi sevgili Anneme ve Eşime ithaf ediyorum.

Kaan Hakan ÇOBAN
Trabzon 2021

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Depremlerin Magnitüd Türü Dönüşümü ve Maksimum Yer Hareketi İvmesi (Pga) Tahmininde Yapay Zeka Uygulamaları” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Nilgün Lütfiye SAYIL‘ın sorumluluğunda tamamladığımı, verileri kendim topladığımı, analizleri kendi yaptığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 08/07/2021

Kaan Hakan ÇOBAN

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	VII
SUMMARY	VIII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ.....	XVI
SEMBOLLER DİZİNİ	XVII
1. GİRİŞ	1
1.1. Tezin Amacı ve Kapsamı.....	6
1.2. Magnitüd Türleri ve Dönüşüm Bağlılıları	9
1.3. Azalım İlişkilerinde Kullanılan Parametreler	15
1.3.1. Kuvvetli Yer Hareketi Parametreleri	15
1.3.2. Deprem-İstasyon Arası Uzaklık Parametreleri	21
1.3.3. Zemin Özellik Parametresi (Kayma dalga hızı, Vs30)	22
1.4. Literatürdeki Azalım İlişkileri	25
1.5. Yapay Zekâ	30
1.5.1. Makine Öğrenme Yöntemleri	31
1.5.2. Yapay Sinir Ağları Genel Bilgiler	33
1.5.3. Meta-Sezgisel Algoritmalar	39
2. TÜRKİYE’NİN TEKTONİĞİ VE DEPREMSELLİĞİ	41
2.1. Türkiye’nin Tektoniği.....	41
2.1.1. Kuzey Anadolu Fay Zonu (KAFZ).....	44
2.1.2. Doğu Anadolu Fay Zonu (DAFZ)	45
2.1.3. Diğer Tektonik Yapılar	45
2.2. Türkiye’nin Depremselliliği.....	47
3. YÖNTEM	49
3.1. Regresyon Yöntemleri	49
3.2. Makine Öğrenme Yöntemlerinde Kullanılan Algoritmalar.....	52

3.3.	Yapay Sinir Ağları (YSA) ve Meta-sezgisel Algoritmalar.....	57
4.	VERİ	66
5.	YAPILAN ÇALIŞMALAR	75
5.1.	Magnitüd Türü Dönüşüm Denklemleri İçin Yapılan Çalışmalar .	75
5.1.1.	Regresyon Analizleri	75
5.1.2.	Makine Öğrenmesi Algoritmalarıyla Yapılan Uygulamalar.....	78
5.2.	Maksimum Yer Hareketi İvmesi (PGA)Tahmini İçin Yapılan Çalışmalar	83
5.2.1.	Yapay Sinir Ağları ve Meta-sezgisel Algoritmalarla Yapılan Uygulamalar.....	84
5.2.2.	Makine Öğrenmesi Algoritmalarıyla Yapılan Uygulamalar.....	101
5.3.	Test Verileriyle Yapılan Çalışmalar	106
5.3.1.	Magnitüd Türü Dönüşüm Denklemleri ve Regresyon Modelleriyle Yapılan Hesaplamalar	106
5.3.2.	PGA Tahmini İçin Oluşturulan Regresyon Modelleriyle Yapılan Hesaplamalar.....	112
5.4.	Magnitüd Türü Dönüşümü ve PGA Tahmini İçin Kullanıcı Arayüzü Tasarlanması	119
6.	SONUÇLAR VE TARTIŞMA	127
7.	KAYNAKLAR	134
8.	EKLER.....	148
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

DEPREMLERİN MAGNİTÜD TÜRÜ DÖNÜŞÜMÜ VE MAKSİMUM YER HAREKETİ İVMESİ (PGA) TAHMİNİNDE YAPAY ZEKA UYGULAMALARI

Kaan Hakan ÇOBAN

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Jeofizik Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Nilgün Lütfiye SAYIL
2021, 149 Sayfa, 17 Sayfa Ek

Türkiye, Kuzey Anadolu Fay Zonu, Doğu Anadolu Fay Zonu ve Ege Açılma Sistemi gibi aktif tektonik yapıları içermesinden dolayı yüksek deprem tehlikesine sahiptir. Bu nedenle, sismik tehlike değerlendirme çalışmalarının güvenilir ve doğruluğunun yüksek olması gerekmektedir. Sismoloji ve tehlike değerlendirme çalışmaları içerisinde homojen deprem magnitüd türü için dönüşüm denklemleri ve depremlerin mühendislik yapılarına etkilerini belirlemek için maksimum yer hareketi ivmesi (PGA) değerleri kullanılmaktadır. Bu tez kapsamında depremlerin magnitüd türü dönüşümü ve depremlerin PGA değerlerinin hesaplanması için Yapay Sinir Ağları (YSA), Meta-sezgisel algoritmalar ve Makine Öğrenmesi algoritmaları gibi Yapay Zeka (YZ) teknikleri kullanılarak denklemler, YSA ve regresyon modelleri geliştirilmiştir. Magnitüd türü dönüşümü için, Türkiye ve civarında (1900-2020) meydana gelen ($M \geq 4.0$) depremlerin farklı magnitüd türleri ve değerleri kullanılarak regresyon yöntemleriyle 8 denklem ve makine öğrenmesi algoritmalarıyla 3 regresyon modeli oluşturulmuştur. PGA tahmini için, Türkiye ve civarında meydana gelen depremlerin (1976–2020) parametrelerinden oluşan 2 veri setiyle ($M \geq 3.0$ ve $M_w \geq 5.0$) 6 farklı veri formuna göre YSA ile Meta-sezgisel algoritmalar kullanılarak modeller ve makine öğrenmesi algoritmalarıyla 3 regresyon modeli oluşturulmuştur. Tüm modeller oluşturulan test verileriyle literatürden seçilen magnitüd türü dönüşümü ve PGA tahmin denklemleri ile karşılaştırılmıştır. Magnitüd türü dönüşümü için oluşturulan regresyon modelleri gerçek değerlere daha yakın sonuçlar vermişlerdir. PGA tahmini için oluşturulan YSA ve regresyon modellerinin, literatürden seçilen tahmin denklemlerine göre ölçülen PGA değerlerine daha yakın değerler hesapladığı görülmüştür. Özellikle, YZ teknikleriyle yapılan ölçülen değerlere daha yakın PGA tahminleri sismik tehlike çalışmalarının güvenilirliğini artıracaktır. Ayrıca, sismoloji ve mühendislik sismolojisi alanlarındaki bu önemli değerlendirmelerde YZ tekniklerinin etkin bir şekilde kullanılabileceği görülmüştür.

Anahtar Kelimeler: Yapay Zeka, Yapay Sinir Ağları, Makine Öğrenmesi, Meta-sezgisel, Magnitüd, Maksimum Yer Hareketi İvmesi (PGA), Sismik Tehlike

PhD. Thesis

SUMMARY

THE APPLICATIONS OF ARTIFICIAL INTELLIGENCE FOR MAGNITUDE TYPES CONVERSION AND PEAK GROUND ACCELERATION (PGA) PREDICTION OF EARTHQUAKES

Kaan Hakan ÇOBAN

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Geophysical Engineering
Supervisor: Prof. Dr. Nilgün Lütfiye SAYIL
2021, 149 Pages, 17 Pages Appendix

Turkey has a high seismic hazard due to the inclusion of active tectonic structures such as the North Anatolian Fault Zone, the East Anatolian Fault Zone and the Aegean System. Therefore, seismic hazard assessment must be reliable and have high accuracy. In seismology and hazard assessment, magnitude type conversion equations and peak ground acceleration (PGA) values are used for a homogeneous earthquake magnitude type and for determining the effects of earthquakes on engineering structures. The goal of this thesis, Artificial Neural Networks (ANN) models, regression models and equations have been developed to calculate PGA values of earthquakes and conversion of earthquake magnitude types by using Artificial Intelligence (AI) techniques such as ANN, Meta-heuristic algorithms and Machine Learning (ML) algorithms. For magnitude type conversion 8 equations and 3 regression models were created by using regression methods and ML algorithms by values and magnitude ($M \geq 4.0$) types of earthquakes (1900-2020) occurred in Turkey and its surroundings. For PGA prediction, ANN models and 3 regression models were created using ANN with Meta-heuristic algorithms and ML algorithms according to 6 different data forms with 2 data sets consisting of parameters of earthquakes ($M \geq 3.0$ and $M_w \geq 5.0$). All models were compared with the magnitude type conversion and PGA prediction equations selected from the literature according to the test data. Regression models formed for the magnitude type conversion gave close results to the real values. The formed ANN models and regression models calculated close values to the measured PGA values from the compared PGA prediction equations. In particular, close PGA values to the measured PGA values predicted by AI techniques will increase the reliability of seismic hazard assessments. In addition, it has been observed that AI techniques can be used effectively in seismology and engineering seismology.

Key Words: Artificial Intelligence, Artificial Neural Networks, Machine Learning, Meta-heuristic, Magnitude, Peak Ground Acceleration (PGA), Seismic Hazard

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. 1. Farklı magnitüd türlerinin doygunluk dereceleri; Mw, moment magnitüdü; mb, kısa periyotlu cisim dalgası magnitüdü; mB uzun periyotlu cisim dalgası magnitüdü ML, lokal magnitüd; Ms, yüzey dalgası magnitüdü; MJMA, Japon Meteoroloji Ajansı magnitüdü (Heaton vd., 1986).	12
Şekil 1. 2. GÜRALP-3T geniş-band hızölçer tepki spektrumu ve farklı model (streckeisen STS-1, STS-2; SRO ve DWWSSN) sismometreler ile karşılaştırılması (Stein ve Wyssession, 2003'den değiştirilerek alınmıştır).....	16
Şekil 1. 3. AFAD istasyon ağındaki TK.4404 nolu istasyonundaki Mw=6.8 Sivrice (Elazığ) depreminin doğu-batı (EW) bileşen ivme-hız-yer değiştirme kayıt örnekleri (Mavi ile gösterilen işlenmemiş, ham kayıtlar; kırmızı ile gösterilen trent-etkisi giderilmiş, işlenmiş kayıtlardır) AFAD-TADAS'dan alınmıştır (URL-1, 2021).	16
Şekil 1. 4. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Sivrice (Elazığ) Mw=6.8 depreminin doğu-batı (EW) bileşeni ve Fourier dönüşümü alınarak elde edilen Fourier genlik spektrumu (AFAD – TADAS'dan alınmıştır, URL-1, 2021).	18
Şekil 1. 5. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Sivrice (Elazığ) Mw=6.8 depreminin doğu-batı (EW) bileşeninin ivme tepki spektrumu (AFAD-TADAS'dan alınmıştır, URL-1, 2021).	20
Şekil 1. 6. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Mw=6.8 Sivrice (Elazığ) depreminin doğu-batı (EW) bileşeninin Arias şiddet grafiği (AFAD-TADAS'dan alınmıştır, URL-1, 2021).	20
Şekil 1. 7. Farklı eğimli fay geometrileri ve farklı istasyon konumları için tanımlanan; Repi, Rhypo, Rrup ve Rjb uzaklık parametreleri.....	21
Şekil 1. 8. 1985 Meksiko depreminin farklı zemin ve uzaklıktaki istasyonlarda kayıt edilen PGA değerleri.	23
Şekil 1. 9. MASW yönteminde veri toplama aşaması ve S-dalgası hızını belirlemek için uygulanan veri işlem aşamaları (Kanbur vd., 2014'den değiştirilerek alınmıştır).	24
Şekil 1. 10. Yapay Zekâ ve alt dallarının tarihsel gelişimi.	31
Şekil 1. 11. Makine öğrenmesinin veriler üzerinden öğrenme ve işlem yapma şekilleri.	32
Şekil 1. 12. a) Biyolojik sinir hücresi ve b) yapay sinir hücresi.....	34

Şekil 1. 13. Yapay sınır hücresi işlevi ve eşik değeri (bias) gösterimi.	35
Şekil 1. 14. Aktivasyon fonksiyonu çeşitleri ve gösterimi.	36
Şekil 2. 1. Türkiye'nin levha hareketleri ve temel tektonik yapıları (KAFZ, Kuzey Anadolu Fay Zonu; DAFZ, Doğu Anadolu Fay Zonu; KDAFZ, Kuzeydoğu Anadolu Fay Zonu; ÖDFZ, Ölü Deniz Fay Zonu; TGF, Tuz Gölü Fay Zonu; AS, Apşeron Sil; ASM, Anaximander deniz dağları; BF, Bozova Fault; BGF, Beyşehir Gölü Fayı; BMG, Büyük Menderes Grabeni; BuF, Burdur Fayı; CTF, Cephalonia Transform Fayı; DF, Deliler Fayı; EcF, Ecemiş Fayı; EF, Elbistan Fayı; EPF, Ezine Pazarı Fayı; ErF, Erciyes Fayı; ESM, Eratosthenes deniz dağları; G Gökova; Ge, Gediz Grabeni; GF, Garni Fayı; IF, Iğdır Fayı; KBF, Kavakbaşı Fayı; KF, Kağızman Fayı; KFZ, Karataş-Osmaniye Fay Zonu; MF, Malatya Fayı; MT, Muş fayı; OF, Ovacık Fayı; PSF, Pampak-Savan Fayı; PTF, Paphos Transform Fayı; RB, Rodos Baseni; SaF, Salmas Fayı; Si, Simav Grabeni; SuF, Sultandağı Fayı; TeF, Tebriz Fayı; TF, Tatarlı Fayı ifade etmektedir. Yolsal ve Taymaz 2010'dan değiştirilerek alınmıştır).....	42
Şekil 2. 2. Türkiye ve civarının temel tektonik yapıları ve neotektonik bölgeleri (KAFZ, Kuzey Anadolu Fay Zonu; DAFZ, Doğu Anadolu Fay Zonu; KDAFZ, Kuzeydoğu Anadolu Fay Zonu; ÖDFZ, Ölü Deniz Fay Zonu; TZ, Tuz Gölü Fay Zonu; EY, Ege Yayı; KY, Kıbrıs Yayını ifade etmektedir. Kürçer ve Gökten 2014'den değiştirilerek alınmıştır).....	43
Şekil 2. 3. Jeodezik ölçümler sonucu levha hareketlerine göre GPS hızları (Reilinger vd., 2006'dan değiştirilerek alınmıştır).	44
Şekil 2. 4. 1976-2010 yılları arasında meydana gelen depremlerin ($M_w \geq 4.0$) fay düzlemi çözümleri (Veriler Türkiye ve çevresi faylanma-kaynak parametreleri moment tensör kataloğu (Kalafat vd., 2009) ile GCMT-Harvard kataloğundan derlenmiş ve Yalçın vd., 2013'den değiştirilerek alınmıştır).....	46
Şekil 2. 5. MS17-1900 yılları arası Anadolu'da meydana gelmiş büyük ($M \geq 7.0$) depremler. Tektonik harita Şaroğlu vd. (1992)'den alınmıştır...	47
Şekil 2. 6. Türkiye ve civarında 1900 ile 2020 yılları arasında meydana gelmiş kuvvetli ($M \geq 6.0$) ve büyük ($M \geq 7.0$) depremlerin dağılımı (Depremlerin konumları KRDAE-BTDİM kataloglarından alınmıştır URL-2, 2020).	48
Şekil 3. 1. a) En küçük kareler yöntemi, b) Ortogonal regresyon yöntemi.	50
Şekil 3. 2. a) Karar ağaçları yapısı, b) Karar ağaçlarının 2-boyutlu gösterimi (Kavzaoğlu ve Çölkesen, 2010'dan değiştirilerek alınmıştır).	53

Şekil 3. 3. a) Torbalama (Bagging) b) Yükseltme (Boosting) orman algoritmaları adımları (Zhang vd., 2018'den değiştirilerek alınmıştır).....	54
Şekil 3. 4 a) Doğrusal ve doğrusal olmayan, b) Doğrusal hiper düzlem gösterimi, c) Gauss, d) Kuadratik (Quadratic) destek vektör makineleri örnekleri.....	55
Şekil 3. 5. İleri beslemeli çok katmanlı YSA örneği (Dramsch, 2020'den değiştirilerek alınmıştır).....	58
Şekil 3. 6. İleri beslemeli geri yayımlı YSA mimarisi.	59
Şekil 3. 7. Geri yayılım algoritmasının görsel olarak işlem adımları, a) x1 girişi için y1 çıkışın hesaplanması, b) YSA içindeki her nöron tarafından hesaplanan değerler ile beklenen çıkış değerleri arasındaki hatanın belirlenmesi, c) Hata değerlerinin geri yayılım ile ağırlık tekrar verilmesi, d) Ağırlıkların güncellenmesi.	61
Şekil 3. 8. Parçacık sürü optimizasyon (PSO) algoritmasının akış diyagramı. ..	62
Şekil 3. 9. Parçacık sürü optimizasyon (PSO) algoritmasının çalışma prensibinin matematiksel ifadesinin şekilsel gösterimi ve N-iterasyon sonucu çözüme yaklaşımı. Mavi yıldız en iyi çözümü ifade etmektedir (Bryson vd., 2016'dan değiştirilerek alınmıştır).	63
Şekil 3. 10. YSA'ların ağırlık ve bias değerlerinin güncellenmesi için uygulanan yöntemlerin akış diyagramı.	65
Şekil 4. 1. Magnitüd dönüşümü için kullanılan veri seti ($M \geq 4.0$) a) Yıllara göre deprem sayısı b) Yıllara göre kümülatif deprem sayısı.....	66
Şekil 4. 2. Magnitüd dönüşümü için kullanılan depremlerin ($M \geq 4.0$) episantr dağılımı (KRDAE–BDTİM ve AFAD kataloglarından alınmıştır, URL-2 ve 3, 2020).....	68
Şekil 4. 3. PGA tahmini için kullanılan veri seti ($M \geq 3.0$) a) Yıllara göre deprem sayısı b) Yıllara göre kümülatif deprem sayısı.	69
Şekil 4. 4. PGA tahmininde kullanılan depremlerin ($M \geq 3.0$) episantr dağılımı (KRDAE–BDTİM ve AFAD kataloglarından alınmıştır, URL-2 ve 3, 2020).....	70
Şekil 4. 5. Hesaplamalarında kullanılan PGA değerlerin normal ve logaritmik dağılımları a) 1. veri seti ($M \geq 3.0$), b) 2. veri seti ($M_w \geq 5.0$).	71
Şekil 4. 6. PGA hesaplamaları için oluşturulan 1. veri seti ($M \geq 3.0$) parametre dağılımları a) Repi-Magnitüd (M), b) Repi - Vs30 (m/sn), c) Repi – PGA(cm/sn2)	71

Şekil 4. 7. PGA hesaplamaları için oluşturulan 1. veri setinin ($M \geq 3.0$) içerdiği 4 deprem parametresinin kendi aralarında dağılımı ve histogram çizimleri (Mak. Fr., maksimum frekansı ifade etmektedir).....	72
Şekil 4. 8. PGA hesaplamaları için oluşturulan 2. veri seti ($M_w \geq 5.0$) parametre dağılımları a) Repi-Magnitüd (M), b) Repi - Vs30 (m/sn), c) Repi – PGA(cm/sn2).	73
Şekil 4. 9. PGA hesaplamaları için oluşturulan 2. veri setinin ($M_w \geq 5.0$) içerdiği 4 deprem parametresinin kendi aralarında dağılımı ve histogram çizimleri (Mak. Fr., maksimum frekans ifade etmektedir).	74
Şekil 5. 1. Lineer (LR) ve ortogonal (OR) regresyon yöntemlerine göre oluşturulan magnitüd türü dönüşüm denklemlerinin karşılaştırmaları a) Afad M_w - KRDAE ML, b) Afad M_w – KRDAE M_w , c) GMT M_w - KRDAE mb, d) GMT M_w - KRDAE ML, e) GMT M_w - KRDAE M_s , f) GMT M_w - KRDAE M_w , g) GMT M_w - Afad M_w , h) GMT M_w - KRDAE Md arasındaki dönüşüm denklemleri ve grafikleri (Renkleri açık maviden koyu maviye doğru giden altıgen kutucuklar veri yoğunluğunu temsil etmektedir).....	77
Şekil 5. 2. Makine öğrenme algoritmalarıyla eğitilen regresyon modelleri için hesaplama adımları ve akış diyagramı.....	79
Şekil 5. 3. Makine öğrenmesi algoritmalarıyla magnitüd türü dönüşüm için oluşturulan doğrusal ve doğrusal olmayan regresyon modellerinin karşılaştırılması a) Afad M_w - KRDAE ML, b) Afad M_w – KRDAE M_w , c) GMT M_w - KRDAE mb, d) GMT M_w - KRDAE ML, e) GMT M_w - KRDAE M_s , f) GMT M_w - KRDAE M_w , g) GMT M_w - Afad M_w a, h) GMT M_w - KRDAE Md arasındaki regresyon modeli.	81
Şekil 5. 4. YSA-Multi algoritması akış diyagramı (M, magnitüd; Vs30, S-dagası hızı; Repi, episantr ile istasyon arasındaki dış merkez uzaklığı).	85
Şekil 5. 5. YSA-Multi koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi $\rightarrow$ LogPGA, b) M-LogVs30-LogRepi $\rightarrow$ LogPGA, c) M-Vs30-LogRepi $\rightarrow$ LogPGA, d) M-LogVs30-Repi $\rightarrow$ LogPGA, e) M-Repi $\rightarrow$ LogPGA, f) M-LogRepi $\rightarrow$ LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).	86
Şekil 5. 6. YSA-Multi koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024 parametre) göre	

6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).	88
Şekil 5. 7. YSA-PSO ve YSA-TLBO algoritmaları akış diyagramı. (M, magnitüd; Vs30, S-dagası hızı; Repi, episantr ile istasyon arasındaki dış merkez uzaklığı).....	90
Şekil 5. 8. YSA-PSO hibrit koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).	91
Şekil 5. 9. YSA-PSO hibrit koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).	93
Şekil 5. 10. YSA- TLBO hibrit koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).	95
Şekil 5. 11. YSA- TLBO hibrit koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024	

- parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), a) M-Vs30-Repi →LogPGA v, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir)..... 97
- Şekil 5. 12. WEKA yazılımıyla oluşturulan 3 farklı YSA mimarisi a) 10 nöron tek katmanlı b) 6-10 nöron iki katmanlı c) 6-10-3 nöron üç katmanlı ağ mimarisi örneği (giriş parametreleri; M, Vs30, Repi yeşil, tahmin edilen PGA sarı dikdörtgenlerle ve nöronlar kırmızı dairelerle gösterilmiştir)..... 99
- Şekil 5. 13. Makine öğrenmesi algoritmalarıyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilerek oluşturulan en iyi regresyon modelleri; a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA veri, f) M-LogRepi →LogPGA veri formlarına göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği. 103
- Şekil 5. 14. Makine öğrenmesi algoritmalarıyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilerek oluşturulan en iyi regresyon modelleri; a) M-Vs30-Repi →LogPGA, b) M-LogVs30-LogRepi →LogPGA, c) M-Vs30-LogRepi →LogPGA, d) M-LogVs30-Repi →LogPGA, e) M-Repi →LogPGA, f) M-LogRepi →LogPGA veri formlarına göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği. 104
- Şekil 5. 15. Farklı 8 denklem formuna göre test verisiyle hesaplanan ve gerçek veri arasındaki fark (hata) değerleri a) Afad M_w - KRDAE ML, b) Afad M_w - KRDAE M_w , c) GMT M_w - KRDAE mb, d) GMT M_w - KRDAE ML, e) GMT M_w - KRDAE M_s , f) GMT M_w - KRDAE M_w , g) GMT M_w - Afad M_w , h) GMT M_w - KRDAE Md formu için fark hata değerleri (LR, Lineer regresyon; OR, Ortogonal Regresyon; RM, Makine öğrenmesi algoritmalarıyla oluşturulan regresyon modelini ifade etmektedir)..... 109
- Şekil 5. 16. Veri seti 1 için farklı 6 denklem formuna göre test verisiyle hesaplanan PGA ve ölçülen PGA arasındaki fark (hata) değerleri a) Farklı veri formuna göre toplam hatalar, b) 8 farklı PGA tahmin denklemi fark (hata) değerleri 114
- Şekil 5. 17. Veri seti-2 için farklı 6 denklem formuna göre test verisiyle hesaplanan PGA ve ölçülen PGA arasındaki fark (hata) değerleri a)

Farklı veri formuna göre seçilen en iyi modele göre toplam farklar (hatalar), b) 8 farklı PGA tahmin denklemi fark(hata) değerleri.....	116
Şekil 5. 18 YSA ve regresyon modelleriyle en iyi hesaplanan ve gerçek PGA arasındaki toplam fark (hata) değerleri a) 1. Veri seti için 2-bağımsız değişkene göre Esteva (1973) denklemi ve VF-6 eğitilen RM-3 modeli, 3-bağımsız değişkene göre Akkar (2014) oluşturduğu denklem ve VF-1 eğitilen YSA-PSO modeli ile, b) 2. Veri seti için 2-bağımsız değişkene göre Sadıgh (1998) denklemi ve VF-6 eğitilen RM-3 modeli, 3-bağımsız değişkene göre Akkar (2014) oluşturduğu denklem ve VF-1 eğitilen YSA-PSO modeli ile yapılan hesaplamalar.	118
Şekil 5. 19. Magnitüd türü dönüşümü için tasarlanan arayüzün genel görünümü.	120
Şekil 5. 20. Magnitüd türü dönüşümü için tasarlanan arayüzün hesaplama adımları akış diyagramı.	120
Şekil 5. 21. PGA tahmini için tasarlanan arayüzün genel görünümü.	121
Şekil 5. 22. PGA tahmini için tasarlanan arayüzün hesaplama adımları akış diyagramı.	122
Şekil 5. 23. AFAD tarafından oluşturulan Türkiye tehlike haritaları uygulamasından; DD-3 deprem yer hareketi düzeyine göre 20 deprem istasyonu konumu için alınan PGA (cm/sn ²) değerleri.	124
Şekil 5.24. Sivrice (Elazığ) depreminin episantr noktası ve civarındaki 20 deprem istasyonunda ölçülen PGA (cm/sn ²) değerleri.	125
Şekil 5. 25. 1.Verit seti için; VF-1 veri formuna göre eğitilen YSA ve regresyon modellerinin hesapladığı PGA (cm/sn ²) değerleri.	125
Şekil 5. 26. 1.Verit seti için, VF-5 veri formuna göre eğitilen YSA ve regresyon modellerinin hesapladığı PGA (cm/sn ²) değerleri.	126

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. 1. Sadigh ve Egan (1998) tarafından geliştirilen azalım ilişkisinin farklı magnitüd aralıkları ($M_w < 6.5$ ve $M_w \geq 6.5$), zemin grupları, fay türlerine göre hesaplanan katsayıları.	27
Tablo 1. 2. Makine öğrenme algoritmalarının denetimli ve denetimsiz öğrenme yöntemleri.	32
Tablo 1. 3. Biyolojik sinir ve yapay sinir hücresi elemanları.	34
Tablo 5. 1. Magnitüd türü dönüşümü için oluşturulan 8 denklemin regresyon katsayıları, determinasyon katsayısı (R^2) ve Standart sapma (σ) değerleri.	76
Tablo 5. 2. Hesaplamalarda kullanılan makine öğrenme algoritmaları.	79
Tablo 5. 3. Makine öğrenme algoritmaları içerisinde seçilen en iyi 3 algoritmanın 8 farklı veri seti için hesaplanan hata değerleri.	80
Tablo 5. 4. YSA'ların eğitim veri setleri için oluşturulan 6 farklı veri formu.	84
Tablo 5. 5. Farklı nöron sayıları ve katmanlara göre WEKA yazılımıyla 6 farklı veri formu için eğitilen YSA'ların R ve	100
Tablo 5. 6. Makine öğrenme algoritmaları hata fonksiyonları değerlerine göre 1. veri seti ve 2. veri seti için seçilen en iyi 3 regresyon modeli.	102
Tablo 5. 7. Magnitüd türü dönüşümü için ilk 4 denklem formuna göre test verileri sonuçları ve R^2 değerleri	107
Tablo 5. 8. Magnitüd türü dönüşümü için son 4 denklem formuna göre test verileri sonuçları ve R^2 değerleri.	108
Tablo 5. 9. Veri seti-1 için oluşturulan regresyon modelleri içerisinde seçilen en iyi regresyon modelleriyle hesaplanan PGA, R ve R^2 değerleri.	113
Tablo 5. 10. Veri seti-2 için oluşturulan regresyon modelleri içerisinde seçilen en iyi regresyon modelleriyle hesaplanan PGA, R ve R^2 değerleri.	115
Tablo 5. 11. Sivrice'de (Elazığ) 24.01.2020 tarihinde meydana gelen depremin ($M_w=6.8$) parametrelerine göre hesaplanan PGA, Türkiye deprem tehlike haritaları (AFAD) uygulamasından alınan PGA değerleri ve 20 istasyonda ölçülen PGA değerlerinin karşılaştırması.	123

SEMBOLLER DİZİNİ

A	: Maksimum genlik
a	: İvme
AFAD	: T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi
BP	: Geri Yayılım Algoritması
DAFZ	: Doğu Anadolu Fay Zonu
DD	: Deprem yer hareketi düzeyi
DVM	: Destek vektör makineleri
EKK	: En küçük kareler yöntemi
GMT	: Harvard Global Centroid-Moment-Tensor kataloğu
GRM	: Gauss regresyon modelleri
HRVD	: Harvard Üniversitesi
KAFZ	: Kuzey Anadolu Fay Zonu
KRDAE -BDTİM	: Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi
LR	: Lineer regresyon
M	: Magnitüd
ML	: Lokal magnitüd
M _w	: Moment magnitüd
m _b	: Cisim dalgası magnitüdü
M _s	: Yüzey dalgası magnitüdü
M _d	: Süreye bağlı magnitüd
M _o	: Sismik moment
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MASW	: Yüzey Dalgalarının Çok Kanallı Analizi Yöntemi
MSE	: Ortalama kare hata
NGA	: Yeni kuşak azalım ilişkisi
OR	: Ortogonal regresyon

PEER	: Pasifik Deprem Mühendisliği Araştırma Merkezi
PGA	: Maksimum yer hareketinin ivmesi
PHA	: Pik yatay ivme
PSO	: Parçaçık sürü optimizasyon
ISC	: Uluslararası Sismoloji Merkezi
R	: Korelasyon katsayısı
R ²	: Determinasyon katsayısı
R _{epi}	: Deprem ile istasyon arası dış merkez uzaklığı
R _{hypo}	: Deprem odak noktası ile istasyon arasındaki uzaklık veya iç merkez uzaklığı
R _{rup}	: Fayın yüzey kırığına olan en yakın uzaklık
R _{JB}	: Fayın kırılma düzleminin düşey izdüşümüne olan en yakın uzaklık
RA	: Regresyon ağaçları
RM	: Regresyon modeli
RMSE	: Kök ortalama kare hata
SASW	: Yüzey Dalgalarının Spektral Analizi Yöntemi
SD	: Standart sapma
T	: Periyot
TA	: Topluluk ağaçları
TADAS	: Türkiye İvme Veritabanı ve Analiz Sistemi
TLBO	: Öğrenme öğretme optimizasyon algoritması
USGS	: Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu
Vs30	: 30 metre için hesaplanan kesme dalga hızı
VF	: Veri formu
W	: WEKA (Waikato Environment for Knowledge Analysis) Yazılımı
Y	: En büyük yer ivmesi
YZ	: Yapay zeka
YSA	: Yapay sinir ağları
f(Δ , h)	: Bölgeye ait episantr ve derinliğe göre hesaplanan fonksiyon
Q(Δ , h)	: Episantr ve derinliğe bağlı bir fonksiyon
Δ	: Episantr uzaklığı
σ	: Standart Sapma

1. GİRİŞ

Türkiye, dünyanın en aktif deprem kuşaklarından biri olan Alp-Himalaya kuşağı üzerinde yer alması ve bu kuşağın en önemli tektonik yapılarından olan Kuzey Anadolu Fay Zonu (KAFZ) ve Doğu Anadolu Fay Zonu'nu (DAFZ) içermesinden dolayı yüksek deprem tehlikesine sahiptir. Tarihsel ve aletsel dönemde bu fay zonları üzerinde meydana gelmiş büyük yıkıcı depremler, bu fay zonlarına yakın kurulan şehirlerde can ve mal kayıplarına yol açmıştır. Bu nedenlerden dolayı, Türkiye için sismik tehlikenin ve buna bağlı riskin güvenilir ve doğru bir şekilde belirlenmesi deprem zararlarının azaltılmasında önemli bir adımdır.

Depremlerin etkilerini belirlemek ve bu etkilerin zararlarının azaltmak için yapılan önemli çalışmalar sismolojide sismik tehlike değerlendirme çalışmaları olarak adlandırılmaktadır. Araştırmacılar uzun yıllardır bu önemli değerlendirme analizlerini geliştirmek ve doğruluğunu artırmak için çalışmalar yapmaktadırlar. Bu amaçla yapılan sismik tehlike analizlerinde, meydana gelmiş depremlerin parametreleri kullanılarak tektonik, zemin özellikleri, sismolojik, istatistiksel ve diğer bilgileri sistematik bir şekilde birleştirerek, bölgesel olarak ileride oluşacak sismik aktivite için değerlendirmeler yapılmaktadır. Dünyanın farklı bölgelerinde ve Türkiye'de deprem aktivitesi yüksek tektonik kaynakların yaratacağı sismik tehlike birçok araştırmacının ilgisini çekmiştir (Erdik vd., 1985, 1999; Atakan vd., 2002; Selçuk vd., 2010; Akkar vd., 2018; Giardini vd., 2018; Sesetyan vd., 2018; Sianko vd., 2020). Sismik tehlikenin değerlendirilmesinde literatürde temel olarak deterministik ve olasılıksal olmak üzere iki yöntem kullanılmaktadır. Bu yöntemler içerisinde deprem parametrelerinin; magnitüd (büyüklük), maksimum yer hareketinin ivmesi (PGA: Peak Ground Accelaration) ve depremlerin konumlarının en az hata payıyla belirlenmesi sismik tehlike değerlendirmesinin o derece doğru ve güvenilir olarak yapılması anlamına gelmektedir. Ayrıca, bu üç parametrenin yanısıra zemin özelliği de depremlerin yıkıcı ve hasar yapıcı etkisini belirleyen diğer önemli bir parametredir.

Depremlerin magnitüd değerlerinin belirlenmesi, bölgesel olarak tektonizma hakkında bilgi vermekte ve yapılacak istatistiksel deprem olasılık çalışmalarına temel bilgiler sağlamaktadır. Depremlerin oluşturduğu yer hareketinin ivme (PGA) değerlerinin ivme-ölçerler tarafından ölçülmesi veya geliştirilen azalım ilişkileriyle belirlenmesi, meydana gelen bir deprem sırasında bölgedeki mühendislik yapılarının etkilenebileceği sismik yükler

açısından bilgi sağlamaktadır. Ayrıca, gelecekte bölge için yapılacak yapı tasarımlarında ivme parametresi belirleyici rol oynamaktadır. Bu parametreler yanında bölgenin zemin özellikleri, deprem dalgaları üzerindeki etkisiyle mühendislik yapılarına etki eden sismik kuvvetleri belirleyen diğer önemli bir parametredir. Literatürde, deprem ve deprem kuvvetlerini etkileyen parametreler; sismometreler ve sismik aletler ile ölçülerek ya da çeşitli regresyon modelleriyle geliştirilen denklemlerle veya iteratif yöntemlerle hesaplanmaktadır.

Sismolojide depremlerin magnitüd (büyüklük) değerini hesaplayan bağıntı ilk kez 1935 yılında Richter tarafından Kaliforniya depremleri için geliştirilmiştir. Daha sonra Gutenberg (1945a) tarafından cisim dalgası magnitüdü (mb) ile yüzey dalgası magnitüdü (Ms) ve Bisztricsany (1958) tarafından süreye bağlı magnitüd (Md) bağıntıları tanımlanmıştır. Hanks ve Kanamori (1979) sismik momentle deprem büyüklüğünü ilişkilendirerek moment magnitüd (Mw) bağıntısını geliştirmiştir.

Maksimum yer hareketi ivmesi (PGA), deprem sırasında ölçülmüş kuvvetli yer hareketi ölçümlerinden veya bu ölçüm değerleri kullanılarak geliştirilen azalım ilişkileriyle belirlenebilmektedir. Literatürde araştırmacılar tarafından dünyanın farklı bölgeleri için ivme azalım ilişkileri (PGA tahmin denklemi veya sönüm denklemi) geliştirilmiş, hatta bunlardan bazıları diğer azalım ilişkileri oluşturulurken temel olarak kullanılmıştır (Esteve ve Villaverde, 1973; Ambraseys, 1975, 1978; Ambraseys vd., 1996; Abrahamson ve Silva, 1997; Sadigh vd., 1997; Campbell, 1985; Joyner ve Boore, 1988; Fukushima ve Tanaka, 1990; Akkar ve Bommer, 2010; Bommer vd., 2011; Akkar vd., 2014). Ayrıca, Türkiye'nin farklı bölgeleri içinde araştırmacılar tarafından sönüm denklemleri geliştirilmiştir (İnan vd., 1996; Aydan vd., 1996; Gülkan and Kalkan, 2002; Özbey vd., 2003; Kalkan ve Gülkan, 2004; Ulusay vd., 2004; Beyaz, 2004; Çeken, 2007; Ulutaş ve Özer, 2010; Kale vd., 2015).

Sismik tehlike değerlendirme çalışmaları içerisinde yapılan istatistiksel çalışmalarda temel olan magnitüd parametresinin ve oluşturulan azalım ilişkilerinden maksimum yer hareketi parametresinin belirlenmesinde bir takım zorluklarla karşılaşmaktadır. Her bir deprem izleme merkezinin (ajansının) hesaplama yönteminin farklı olmasından dolayı magnitüd değerinde farklılıklar oluşmaktadır. Bu nedenle, araştırmacılar dünyanın farklı deprem ajanslarının verdiği magnitüd türleri ve değerleri arasında dönüşüm bağıntıları geliştirmişlerdir (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Kadirioğlu ve Kartal, 2016; Tang vd., 2016). Diğer önemli bir zorluk ise, PGA değerini hesaplamak için geliştirilen azalım ilişkilerinin hata paylarının yüksek olmasıdır. Bunun nedeni, farklı deprem magnitüdüleri için yeterli sayıda ivmeölçer kaydının olmaması, farklı deprem

büyükliklerine ait parametreleri içeren geniş bir veri seti kullanılarak bu bağıntıların oluşturulmaması ve yeteri kadar zemin özelliği belirleyen parametreleri içermemesi veya diğer parametrelerle zemin parametresi arasında anlamlı bir ilişkinin zor kurulmasıdır. Araştırmacıların bu çalışmalarda genel olarak sadece regresyon analizlerini kullanması da bir eksiklik yaratmaktadır.

Son yıllarda gelişen bilgisayar teknolojisiyle birlikte, Yapay Zeka (YZ) teknikleri karmaşık mühendislik problemlerin çözümünde bir çok alanda kullanılmaktadır. Matematiksel olarak modellenmesi zor olan problemlerin, hata değerlerini en az indirmek için sezgisel, sinirsel ve makine öğrenmesi gibi çeşitli YZ teknikleri kullanılarak modellenmesi mümkündür. Ayrıca bu tekniklerle mühendislik alanında karşılaşılan modelleme problemlerinin optimizasyonu, tahmini, sınıflandırılması ve kümelemesi şeklinde çözümler sunulmaktadır. Genelleme yapabilme, çözüm uzayını yakınsama yapmadan tarama ve en iyi çözüme kısa sürede yaklaşma gibi özellikleri olan YZ teknikleri, sezgisel arama/optimizasyon yöntemlerinin mühendislik problemlerinin çözümünde tercih edilmelerini sağlamaktadır. YZ'nin bir alt dalı olan Yapay Sinir Ağları (YSA), sinyal işleme (Lou, 1995), enerji-endüstri uygulamaları (Chen ve Maun, 2000; Jemei vd., 2008), akarsu akış hızını tahmin edilmesi (Nacar vd., 2018) gibi farklı alanlarda karmaşık problemlerin çözümlerinde etkili bir yöntem olarak uygulanmıştır. YZ'nin diğer bir alt dalı olan makine öğrenmesi yöntemleri farklı araştırmacılar tarafından biyoloji alanında (Ching vd., 2018), kimya alanında (Schutt vd., 2017), medikal görüntü işlemede (Shen vd., 2017), uzaktan algılamada (Lary vd., 2016), jeomorfolojide (Valentine ve Kalnins, 2016) birçok probleme uygulanmıştır. YZ yöntemleri içerisinde yer alan Meta-sezgisel algoritmalar, optimizasyon problemleri çözümünde (Karaboğa ve Baştürk, 2007), inşaat mühendisliği problemlerinde (Sönmez, 2011), endüstriyel elektronikte dijital filtre tasarımında (Yu ve Xinjie, 2007), doppler cihazlarındaki gürültülü sinyallerin filtrelenmesinde (Karaboğa ve Latifoğlu, 2013), elektrik güç sistemlerinde enerji akışının planlanması (Güvenç vd., 2012), senkron motorun uyarım akımının tahmini (Kahraman, 2014), kıyı şeridindeki sediman hareketinin belirlenmesi (Uzlu vd., 2014), Çoruh nehri üzerinde sediman birikiminin hesaplanması (Yılmaz vd., 2018) gibi bir çok alanda çözüm üretmek veya çözümü daha iyileştirmek için uygulanmıştır. Araştırmacılar bu yöntemleri ortak kullanarak hibrit yöntemler de geliştirmişlerdir (Satapathy vd., 2012). Bu yöntemlerden, YSA ile Öğrenme öğretme optimizasyon algoritmasından (TLBO:Teaching Learning Based Optimization) oluşan hibrit algoritma, yağmur miktarı tahmininde (Rani vd., 2014), aynı hibrit algoritma

Türkiye'nin enerji tüketiminde ve uzun dönem elektrik enerji talebinin tahmininde (Uzlu vd., 2014; Kankal ve Uzlu, 2017) ve bu hibrit algoritma yanında YSA ile arı kolonisi meta-sezgisel algoritmasından oluşan hibrit algoritma akarsulardaki sediman yükleme tahmininde uygulanmıştır (Yılmaz vd., 2019).

YZ yöntemleri son yıllarda birçok probleme uygulanmıştır. Yerbilimlerinde ise, Güllü ve Ercelebi (2007), PGA tahmininde YSA'yı uygulamışlardır. Çalışma, daha önce Türkiye için regresyon yöntemleriyle hesaplanan azalım ilişkilerinde kullanılan veri setlerini kullanmışlar; YSA ile yapılan hesaplamaların, regresyon yöntemi ile oluşturulan denklemlerden daha iyi PGA değerleri verdiğini belirtmişlerdir. Günaydın ve Günaydın (2008), PGA tahmini için 15 depremin farklı istasyonlardaki 95 adet üç bileşen kaydıyla oluşturdukları veri setine üç farklı YSA mimarisini uygulamışlar ve bu ağ yapılarının tahmin sonuçları performansını arttırdığını belirtmişlerdir. Kuyuk vd., (2011), İstanbul ve civarında meydana gelen mikro-depremler ile patlatmaların ayırt edilmesi için denetimsiz öğrenmeli YSA'yı uygulamışlar; karmaşıklık, spektral oran, S/P dalgası genliği pik oranı ve olayların zamanlarını giriş parametreleri olarak kullanıp 179 adet depremi ($1.8 < M_d < 3.0$) sınıflandırmışlardır. Bu problemin çözümünde, karmaşıklık ve pik genliği oranının kullanılmasının daha uygun olduğunu ve farklı deprem bölgelerinde kullanılabileceğini belirtmişlerdir. Pekşen vd., (2011), Parçacık sürü optimizasyon (PSO: Particle Swarm Optimization) algoritmasını mineral araması ve model parametrelerini (merkezden uzaklık, derinlik, polarizasyon açısı, eğim) hesaplamak için doğal potansiyel verilerine uygulamışlardır. Birkaç araştırmacı tarafından daha önce kullanılmış Süleymanköy, Weiss ve Nalbant Çeşmesi verilerini kullanmışlar ve kendi sonuçlarıyla karşılaştırmışlardır. PSO algoritmasının doğal potansiyel verilerinin değerlendirilmesinde uygulanabileceğini belirtmişlerdir. Göktürkler ve Balkaya (2012), doğal potansiyel verilerinin ters çözümünde genetik algoritma ve PSO gibi meta-sezgisel algoritmaları ile tavlama benzetimi algoritmasını uygulamışlardır. Balkaya (2013), popülasyon tabanlı evrimsel bir algoritma olan diferansiyel evrim algoritmasını düşey elektrik verileri ile doğal potansiyel verilerinin ters çözümüne uygulamış; sentetik ve iki saha verisiyle hesaplamalar yapmış ve sonuçları PSO algoritması sonuçlarıyla karşılaştırmıştır. Pekşen vd., (2014), anizotropik ortamlarda PSO algoritması kullanarak 1-boyutlu DC öz direnç modellemesi ve yorumlanması yapmışlardır. PSO algoritmasıyla yatay-düşey rezistivite ve kalınlık gibi model parametrelerini hesaplamışlardır. Algoritmayı hem sentetik veri hem de gerçek arazi verisiyle değerlendirmişler ve algoritmanın bu tarz çalışmalarda kullanılabileceğini

belirtmişlerdir. Balkaya vd., (2017), diferansiyel evrim algoritmasını üç boyutlu doğrusal olmayan manyetik anomalilerin ters çözümünde kullanmışlardır. Ekinci vd., (2017), 2-boyutlu manyetik anomalilerin analitik sinyal ters çözüm aşamalarında meta-sezgisel algoritmalarından biri olan diferansiyel gelişim algoritmasını kullanmışlardır. Alkan ve Balkaya (2018), yatay halka elektromanyetik verilerin üzerinden diferansiyel arama algoritmalarını parametre hesaplamalarının ters çözüm işlemlerine uygulamışlardır. Kaftan vd., (2017), Türkiye'nin batısında meydana gelmiş deprem ($M > 3.0$) kataloglarını YSA ve bulanık mantık algoritmalarıyla değerlendirmişler ve aylık deprem sayıları tahmininde YSA'ların başarılı sonuçlar verdiğini belirtmişlerdir. Shen (2018), derin öğrenme algoritmalarının su kaynakları üzerine çalışan araştırmacılar için, artan veri hacimlerinin ve çeşitliliğinin idaresinde ve verilerden faydalı bilgiler çıkarmasında yardımcı olması açısından çok önemli olacağını belirtmiştir. Wang vd., (2018), hidrokarbon keşfi için elde edilen sismik verilerin boyutundaki çarpıcı artışla birlikte, yapısal yorumlamanın zor olmasından ve daha fazla zaman alıcı çalışmalar yapılması gerektiğini vurgulamışlardır. Bu zorlukların aşılmasında araştırmacıların sismik verileri yoruma hazır hale gelmesinde makine öğrenimi tekniklerinin etkili bir şekilde kullanılabileceğinden bahsetmişlerdir. Yaghmaei-Sabegh, (2018), 950 adet ivme kaydını kullanarak kuvvetli yer hareketi zamanını genelleştirilmiş YSA yöntemi ile hesaplamıştır. Hareket süresinin iki tipik modelini (% 5-95 ve % 5-75 Arias Şiddeti) baz alarak oluşturmuş, analiz sonuçlarına göre eğitim ve test verilerinin iyi uyum gösterdiğini belirtmiştir. YSA'ların bu tip sismoloji ve kuvvetli yer hareketleri problemlerinde çözüm üretme kapasitesinin olduğunun vurgulamıştır. Derakhshani ve Foruzan (2019), Pasifik deprem mühendisliği araştırma merkezinin deprem kataloğundan 12556 adet deprem kaydına ait magnitüd, uzaklık ve Vs30 hız parametrelerini kullanarak derin öğrenme algoritmalarıyla PGA tahmini üzerine çalışmışlardır. Zhu vd., (2019), 2008 Wenchuan depremi ($M_w=7.9$) sonrası bir ay içerisinde meydana gelen artçı şokların faz bilgilerini kullanarak deprem dalga fazlarının belirlenmesinde derin öğrenme algoritmalarını uygulamışlardır. Bergen vd., (2019), makine öğrenmesi yöntemlerinin yerbilimlerindeki karmaşık problemlerin çözümlerinin araştırılmasında ve çözümlere daha hızlı ulaşılmasında kilit rol oynayacağını belirtmişlerdir. Hara vd., (2019), depremlerin dalga formu verilerinden P-dalgası ilk hareketini belirlemek için derin öğrenme tekniklerini uygulamışlardır. Oluşturdukları ağın P-dalgası polarizasyon belirlemesine, insan tecrübelerinden daha tutarlı sonuçlar verdiğini ifade etmişlerdir. Raghucharan vd., (2019), Hindistan'da meydana gelen depremlerin magnitüd, uzaklık, Vs 30 ve PGA parametrelerini

kullanarak YSA ile azalım ilişkisi geliştirmişlerdir ve bölge için oluşturulmuş diğer azalım ilişkileriyle karşılaştırmışlardır. Dhanya ve Raghukanth (2020), 498 adet depremin 13294 yatay bileşen kaydını kullanarak YSA'lar yardımıyla PGA tahmini yapmışlardır. YSA'ları eğitirken genetik algoritma ve Levenberg–Marquardt algoritmalarının birleşimi hibrit bir yöntem kullanmışlardır. Giriş parametreleri olarak depremlerin magnitüdüleri (M_w), deprem episantr noktasına en yakın uzaklık, zeminin V_{s30} hız parametrelerini kullanarak PGA tahmini yapmışlar, sonuçlarını güncel PGA tahmin denklemleriyle karşılaştırmışlardır. Asım vd., (2020), Kıbrıs ve civarında kısa dönemde meydana gelen magnitüdü $M > 3.0$ olan depremleri makine öğrenme algoritmaları içerisinde yer alan süper vektör makineleri, rasgele orman algoritmaları ve YSA'lar ile değerlendirmişlerdir. Withers vd., (2020), Güney Kaliforniya için sentetik veriler oluşturup makine öğrenmesi algoritmalarıyla PGA tahmin modeli geliştirmiş ve gerçek PGA değerleriyle model sonuçlarını karşılaştırmışlardır. Shiuly vd.,(2020), Himalaya bölgesinde meydana gelen 26 depremin kaya zeminde kaydedilen PGA değerlerini kullanarak YSA ve genetik algoritmayla PGA tahmini üzerine çalışmalar yapmışlardır. Elde ettikleri sonuçları bölge için geliştirilen azalım ilişkileriyle karşılaştırmışlar ve az veri olmasına rağmen YSA ve genetik algoritmayla oluşturulan PGA tahmin modelinin iyi sonuçlar verdiğini belirtmişlerdir. Son olarak, Dramsch (2020), yaptığı çalışmada son 70 yıldaki makine öğrenme algoritmalarının yerbilimindeki gelişimini incelemiş ve gelecekte daha çok uygulanacağını belirtmiştir. Literatürde yer bilimleri alanında YZ teknikleriyle yapılan bu çalışmaların son yıllarda daha fazla artması, gelecekte de YZ'nın yer bilimleri alanında geniş bir yere sahip olacağını göstermektedir.

1.1. Tezin Amacı ve Kapsamı

Depremlerin ve depremler sırasında meydana gelen yer hareketinin tanımlanmasında kullanılan başlıca iki önemli parametre: Magnitüd (büyüklük) ve maksimum yer hareketi ivmesidir (PGA). Bu iki parametrenin düşük hata paylarıyla hesaplanması, bir bölgenin sismik tehlikesinin daha doğru ve güvenilir bir şekilde yapılmasını sağlamaktadır. Sismik tehlike değerlendirme çalışmaları içerisindeki yer alan istatistiksel olasılık çalışmalarında ve depremi tanımlamada kullanılan magnitüd parametresi farklı deprem izleme merkezleri tarafından farklı yöntemlerle hesaplanabilmektedir. Depremler fayların kırılma parametreleriyle doğrudan ilişkili olduğundan, son yıllarda bilimsel ve mühendislik amaçlı

çalıřmalarda deprem büyüklüğünü en iyi temsil edenin moment magnitüd (M_w) türü olduđu düşünölmekte ve kullanılmaktadır. Ayrıca, istatistiksel çalıřmalarda magnitüd türünün homojen yani kullanılacak deprem verilerinin aynı magnitüd türündeki değörlere sahip olması gerektiğinden, magnitüd türleri arasında dönüřümü sağılayan bir takım bağıntılar geliştirilmesine ihtiyaç duyulmuřtur. Diğöer önemli bir parametre olan maksimum yer hareketi ivmesi (PGA) için arařtırmacılar ivmeölçerler tarafından ölçölen PGA değörleri kullanarak, literatürde çok sayıda PGA tahmin denklemi geliřtirmişlerdir. Depremlerin magnitüd değörleri, istasyon ile deprem kaynağı arasındaki mesafeleri, faylanma türlerini ve zemin özellikleri kullanılarak PGA tahmin denklemlerinin oluşturulmasında bir takım zorluklar vardır. Bunlar, yeterli sayıda ivme kayıt verisinin olmaması veya çok sayıda ivme kayıt verisiyle azalım ilişkisi oluşturulmasında hesaplama zorluğu, doğrusal olmayan zemin davranışının denklem içerisinde temsilinin zor olması ve zemin özelliklerinin belirlenmesinde kullanılan 30 metre için hesaplanan kesme dalga hızı (V_{s30}) parametresinin oluşturulan çoğı denklemde değışken olarak kullanılamamasıdır.

Bu tez kapsamında, Sismoloji alanında karşılaşılan magnitüd dönüřümü ve maksimum yer hareketi ivmesinin (PGA) tahmini olarak tanımlanan bu iki önemli problem için son yıllarda gelişen bilgisayar teknolojisiyle geniş uygulama alanı bulan YZ teknikleri uygulanarak daha güvenilir ve doğru denklemler ile modeller oluşturularak çözümler üretilmesi amaçlanmıştır. Bu bağlamda, iki problem için iki farklı veri seti oluşturulmuřtur. Magnitüd dönüřümü için, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Arařtırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değörlendirme Merkezi (KRDAE - BDTİM), T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi (AFAD) ve Harvard Global Centroid-Moment-Tensor (GMT) deprem kataloglarından faydalanarak, Türkiye ve civarında 1900-2020 yılları arasında meydana gelmiş ($M \geq 4.0$) depremlerin farklı magnitüd türleri için veri setleri oluşturulmuřtur. PGA tahmini için, AFAD deprem kataloglarındaki 1976 – 2020 yılları arasında meydana gelmiş depremlerin ($M \geq 3.0$ ve $M_w \geq 5.0$) parametrelerinden 2 veri seti oluşturulmuřtur. Oluřturulan veri setleri üzerinde;

- 1) Magnitüd türü dönüřümleri için;
 - a) Lineer ve Ortogonal Regresyon uygulamaları,
 - b) Makine öğrenmesi yöntemleriyle hesaplamalar,
- 2) PGA tahmini için;
 - a) Yapay sinir ağıları uygulamaları,

- b) YSA ile Meta-Sezgisel algoritmalarla hibrit uygulamalar,
- c) Makine öğrenmesi yöntemleriyle hesaplamalar yapılmıştır.

Böylece, YZ teknikleriyle daha doğru, güvenilir ve hata payları daha düşük magnitüd türü dönüşümleri ve PGA tahminleri yapılmıştır. Magnitüd türü dönüşümü için, regresyon yöntemleriyle yeni 8 farklı magnitüd türü dönüşüm denklemi (1-AFAD Mw - KRDAE ML arasında, 2-AFAD Mw - Krdae Mw arasında, 3-GMT Mw - Krdae mb arasında, 4-GMT Mw - Krdae ML arasında, 5- GMT Mw - Krdae Ms arasında, 6- GMT Mw - Krdae Mw arasında, 7-GMT Mw - AFAD Mw arasında, 8-GMT Mw - Krdae Md arasında) ve YZ teknikleriyle (Makine öğrenmesi algoritmaları) regresyon modelleri oluşturulmuştur. PGA tahmini için, depremlerin magnitüd değerleri (M), ölçülen PGA değerleri, deprem ile istasyon arasındaki uzaklık (R_{epi}) ve zemin özelliklerini tanımlayan 30 metredeki ortalama kesme dalga (S-dalga) hızı (V_{s30}) parametreleri kullanılarak YZ teknikleriyle (YSA, Makine öğrenmesi algoritmaları ve Meta- Sezgisel algoritmalar) 2 veri seti için 6 farklı veri formuna göre YSA ve regresyon modelleri geliştirilmiştir. Bu hesaplamaların kolayca yapılabilmesi için, magnitüd türü dönüşüm denklemlerini ve YZ teknikleriyle oluşturulan YSA ve regresyon modellerini içeren iki arayüz tasarlanmıştır. Ayrıca, magnitüd dönüşümü için oluşturulan denklemler literatürde yer alan farklı veri setleriyle oluşturulan denklemlerle (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Kadirioğlu ve Kartal, 2016; Tang vd., 2016) ve PGA tahmini için oluşturulan modeller ile yapılan tahmin değerleri, yine literatürde yer alan dünyanın farklı bölgeleri için geliştirilen PGA tahmin denklemlerinin sonuç değerleriyle karşılaştırılmıştır (Esteva ve Villaverde, 1973; İnan vd., 1996; Boore vd., 1997; Sadigh ve Egan, 1998; Kalkan ve Gülkan, 2004; Özbey vd., 2003; Beyaz, 2004; Akkar vd., 2014).

Bu tez kapsamında yapılan çalışmalar ışığında, farklı uygulama alanlarında yaygın bir şekilde kullanılan YZ tekniklerinin Sismoloji alanındaki problemlerin çözümünde de etkili sonuçlar verdiği gözlenmiştir. Ayrıca, gelişen teknoloji ve bilgisayar kapasitelerine eş olarak gelişen YZ tekniklerinin gelecekte Sismoloji alanında daha çok uygulama alanına sahip olacağı düşünülmektedir.

1.2. Magnitüd Türleri ve Dönüşüm Bağlılıkları

Sismolojide ilk kez Richter 1935 yılında deprem anında açığa çıkan enerjinin aletsel büyüklüğünü, yani magnitüdünü sismometre yardımı ile ölçerek açıklamaya çalışmıştır. Richter (1935) bir depremin Lokal magnitüdünü (ML), episantrdan 100 km uzaklıkta kısa periyotlu Wood-Anderson burulma (torsion) sismografıyla (doğal frekansı 1.25 Hz, sönüm değeri 0.8 ve büyütmesi 2800) kaydedilen maksimum yer hareketinin genliğinin (mikron cinsinden) 10 tabanına göre logaritması olarak tanımlamış ve matematiksel ifadesi (1.1) bağıntısı ile vermiştir.

$$M_L = \log \left[\frac{A}{T} \right] + f(\Delta, h) + C_r + C_s \quad (1.1)$$

Burada A, maksimum genlik (mikron); T, periyot (sn); $f(\Delta, h)$, bölgeye ait episantr ve derinliğe göre hesaplanan fonksiyondur ve uzaklığın etkisini (geometrik yayınım ve yırılmadan dolayı genliğin etkilenmesi) düzeltmek için kullanılır. C_r , bölgesel düzeltme katsayısıdır ve depremin olduğu bölgeye göre değişir ve deprem mekanizması ile dalga yayınımına bağlıdır. C_s , istasyon düzeltme katsayısıdır ve istasyondaki özel durumlar için uygulanır (yerel yapı parametreleri). Dünyanın farklı bölgeleri için bu katsayılar hesaplanmış ve o bölgeyi temsil eden denklemler geliştirilmiştir. Bu magnitüd türü episantr uzaklığı 600 km'den yakın ve aletsel büyüklükleri $M < 6.0$ olan depremler için kullanılmaktadır. Havskov ve Ottemöller (2010), bu magnitüd türünün hesaplanması için, deprem kaydının düşey bileşeni için yer değiştirme sismogramının hesaplanması, Wood-Anderson filtresinin kullanılması ve çok küçük depremler için, gürültünün üzerinde maksimum yer değiştirme genliği açıkça görülene kadar kullanılan filterinin düşük frekans değerinin artırılmasını tavsiye etmişlerdir.

Yeryüzünün derinliklerinde meydana gelen depremlerin aletsel büyüklüğünü belirlemek için Gutenberg (1945a), cisim dalgalarının (P, PP ve PS) genlik bilgisine dayalı farklı bir magnitüd türü olan ve (1.2) bağıntısı ile verilen cisim dalgası magnitüdünü (m_b) tanımlamıştır.

$$m_b = \log \left[\frac{A}{T} \right] + Q(\Delta, h) \quad (1.2)$$

Burada A, maksimum genlik (mikron); T, periyot (sn); $Q(\Delta, h)$, episantr uzaklığı ve odak derinliğine bağlı bir fonksiyondur. Uluslararası Sismoloji ve Yeriçi Fiziği (IASPEI) kurumu tarafından mb magnitüdünün, episantr uzaklığı $20^\circ - 100^\circ$ arasında olan istasyonların düşey bileşen yerdeğiştirme kayıtlarında PP-fazından önce gelen tüm P-dalgası paketi üzerinden okunan maksimum genlik değeri kullanılarak hesaplanması tavsiye edilmiştir.

Gutenberg (1945b) tarafından (1.3) bağıntısıyla verilen, 20 sn periyotlu Rayleigh dalgalarının yatay bileşenlerinin mikron cinsinden maksimum genliğinin kullanıldığı başka bir magnitüd türü olan yüzey dalgası magnitüdü (M_s) tanımlanmıştır. Bu magnitüd türü farklı uzaklık ve sismometre tipine göre uygulanacak şekilde geliştirilmiştir. Ancak, burada dalga genliğinin episantr uzaklığıyla nasıl değişeceğinin iyi bilinmesi gerekmektedir. Ayrıca, sismogramdaki iz genliği yerine gerçek yer hareketi genliği ve Rayleigh dalgaları kullanılır.

$$M_s = \text{Log} \left[\frac{A}{T} \right] + a \log \Delta + \beta \quad (1.3)$$

Burada A, Rayleigh dalgalarının yatay bileşeninin genliği (mikron); T, periyot (sn); Δ , episantr uzaklığı (derece); α ve β , sabit katsayıları ifade etmektedir. Bu magnitüd türü, genellikle yaklaşık 1000 km'den uzak, odak derinliği 70 km'den daha az olan, orta ve büyük depremlerin aletsel büyüklüklerini belirlemek için kullanılmıştır. Rayleigh dalgalarının düşey bileşeni için de benzer formüller geliştirilmiştir. IASPEI kurumu M_s magnitüdünün hesaplanmasında, episantr uzaklığı $20^\circ - 160^\circ$ arasında ve odak derinliği 60 km'den az olan depremlerin 18–22 sn periyotlu yüzey dalgalarının düşey bileşenleri üzerinden maksimum genliğin kullanılmasını tavsiye etmiştir. Bisztricsany (1958) tarafından, deprem kayıtlarının üzerinde deprem dalgalarının kapsadığı zaman esas alınarak hesaplanan ve (1.4) bağıntısıyla verilen süreye bağlı magnitüdü (M_d , süre magnitüdü) tanımlanmıştır.

$$M_d = a \log(d) + b \Delta + c \quad (1.4)$$

Burada d, depremin kaydının süresi; Δ , episantr uzaklığı (derece); a, b ve c, sabit katsayıları ifade etmektedir. Bu magnitüd türü episantr uzaklığı 300 km'den yakın ve aletsel büyüklüğü $M < 5.0$ olan depremlerin tanımlanmasında kullanılmaktadır. Büyük depremlerin, sismometre üzerinde salınım etkisinin daha uzun süreli olacağı düşüncesinden yola çıkılarak

geliştirilmiştir. Bu nedenle, sinyal genliği yerine sinyal süresi hesaplanarak bu magnitüd türü hesaplanmaktadır.

Yukarıda tanımlanan magnitüd türlerinin kabullerinden farklı olarak Hanks ve Kanamori (1979), deprem büyüklüğünü sismik momentle ilişkilendirerek (1.5) bağıntısı ile verilen Moment magnitüdünü (M_w) tanımlamışlardır.


$$M_w = \frac{2}{3} \log M_0 - 10.7 \quad (1.5)$$

Burada M_0 , sismik momenti (Nm) ifade etmektedir. Moment magnitüd (M_w), fayın boyutlarını içeren sismik moment ve dolayısıyla sismik enerji ile ilişkili olarak hesaplandığı için daha güvenilir bir magnitüd türü olarak kabul edilir. Bu magnitüd türü, büyüklükleri $M > 4.0$ olan depremler için kullanılmaktadır. P- veya S- dalgaları kullanılarak herhangi bir büyüklükteki deprem için moment magnitüd değeri belirlenebilir. Ancak, çoklu yırtılmalarla oluşan büyük depremlerin momentinin hesaplanması zor olduğundan bu magnitüd türü iyi sonuç vermeyebilir.

Farklı mesafe ve magnitüd aralıkları için farklı magnitüd türlerinin kullanılması daha uygun olmaktadır. Ayrıca, uzak mesafedeki ($> 20^\circ$) küresel depremler için magnitüd türleri uluslararası kabul edilen parametreler ile sabitlenebilirken, yerel ve bölgesel mesafelerde meydana gelen depremler için magnitüd türü parametreleri yerel soğrulma ve geometrik yayılım koşulları nedeniyle farklılıklar gösterebilmektedir. IASPEI kurumu tarafından, magnitüdü 6.0 – 7.0'den küçük, episantr uzaklıkları 1500 km'den az ve frekans bandı 1 – 20 Hz olan depremler için ML; magnitüdü 7.0'den küçük, episantr uzaklığı $20^\circ - 100^\circ$ arasında, frekansları 1 Hz civarında ve 0.3 Hz'den büyük olan telesismik depremler için mb; magnitüdü 8.0'e kadar olan, episantr uzaklığı $20^\circ - 160^\circ$ arasında ve periyodu 18 – 22 sn olan telesismik depremler için M_s ve herhangi bir mesafedeki bir deprem için M_w magnitüd türünün kullanılabileceği tavsiye edilmiştir. Ayrıca, Kabuk ve Üst-manto yapılarının güçlü etkisi nedeniyle özellikle 1000 - 2000 km'lik bölgesel mesafelerde magnitüd belirlemelerinin güvenilir bir şekilde yapılmasının zor olduğunu ve bu episantr uzaklıkları için M_s ve M_w haricinde diğer magnitüd türlerinin yeterli doğrulukta hesaplanamayacağını belirtmişlerdir.

Genlik ve süreye göre yapılan magnitüd hesaplamasının, fay boyunun 5 - 50 km civarında olduğu depremler için güvenilir sonuçlar verdiği, ancak fay boyunun kullanılan genliğe ait enerjinin dalga boyunu geçtiğinde magnitüd değerlerinin doygunluğa ulaştığı

(satüre olduğu) ve güvenilir sonuçlar vermediği kabul edilir (Kanamori, 1977). Bu nedenle, M_L , m_b , M_s ve M_d magnitüd türleri yanında büyüklük tanımlaması sismik moment (M_0) ile ilişkilendirilerek verilen ve çok büyük depremlerin boyutunu tanımlamak için yer sarsıntısı özelliklerine dayalı olmayan (yani satüre olmayan) Moment magnitüd (M_w) daha güvenilirdir. Farklı magnitüd türleri arasındaki ilişki ve doygunluğu Şekil (1.1)'de verilen grafikte tanımlanmıştır. Bu şekilde görüldüğü gibi sabit eğimli bir doğru ile gösterilen M_w grafiği, büyük değerlerde ($M > 8.0$) bile satüre olmayan tek magnitüd türünün Moment magnitüdü (M_w) olduğunu ifade etmektedir. Diğer magnitüd türlerine ait grafiklerin küçük magnitüd değerlerinde doğrusal oldukları, ancak belirli magnitüd değerlerinden sonra doygunluğa ulaşarak doğrusallıktan uzaklaştıkları yani satüre oldukları gözlenmiştir.



Şekil 1. 1. Farklı magnitüd türlerinin doygunluk dereceleri; M_w , moment magnitüdü; m_b , kısa periyotlu cisim dalgası magnitüdü; m_B uzun periyotlu cisim dalgası magnitüdü M_L , lokal magnitüd; M_s , yüzey dalgası magnitüdü; M_{JMA} , Japon Meteoroloji Ajansı magnitüdü (Heaton vd., 1986).

Magnitüdlerin farklı doygunluk değerlerinden (Şekil 1.1) dolayı, son yıllarda güvenilir bir magnitüd türü olan M_w , mühendislik çalışmalarında tercih edilmektedir. Bu nedenle deprem kataloglarını homojen hale getirmek için diğer magnitüd türlerinin Moment magnitüd (M_w) türüne dönüşümünü hesaplayan denklemler geliştirilmiştir. Ulusay vd., (2004), tarafından 1976 ile 2003 yılları arasında meydana gelen 170 depremin farklı türdeki magnitüd değerleri kullanarak M_w 'nin M_s , m_b , M_d ve M_L 'ye dönüşüm denklemleri elde edilmiş ve (1.6-1.9) bağıntıları ile verilmiştir.

$$M_w = 0.6798M_s + 2.0402 \quad (r = 0.96, SD = 0.827) \quad (1.6)$$

$$M_w = 1.2413mb - 0.8994 \quad (r = 0.90, SD = 0.598) \quad (1.7)$$

$$M_w = 0.9495M_d + 0.4181 \quad (r = 0.94, SD = 0.716) \quad (1.8)$$

$$M_w = 0.7768ML + 1.5921 \quad (r = 0.94, SD = 0.709) \quad (1.9)$$

Burada r , korelasyon katsayısını; SD , standart sapmayı ifade etmektedir. Scordilis (2006), 1976 ile 2003 yılları arasında Dünya'nın farklı bölgelerinde meydana gelmiş depremlerin farklı deprem ajansları (ISC, USGS, HRVD, vd.) tarafından hesaplanan M_s ve mb magnitüd değerlerini, HRVD ve USGS ajansları tarafından hesaplanan M_w değerine dönüştüren (1.10-1.12) bağıntılarını geliştirmiştir.

$$M_w = 0.85(\pm 0.04)M_b + 1.03(\pm 0.04) \quad (R^2 = 0.53) \quad (1.10)$$

$$M_w = 0.67(\pm 0.005)M_s + 2.07(\pm 0.03) \quad (R^2 = 0.77) \quad (1.11)$$

$$M_w = 0.99(\pm 0.02)M_s + 0.08(\pm 0.13) \quad (R^2 = 0.81) \quad 6.2 \leq M_s \leq 8.2 \quad (1.12)$$

Çıvgın (2015), 1900 ile 2014 yılları arasında Türkiye ve civarında meydana gelmiş magnitüdü $M \geq 4.0$ olan depremlerin ayrı deprem ajansları (KRDAE-Bdtim, ISC, GMT, USGS) tarafından farklı magnitüd türlerine (ML , mb , M_s ve M_d) göre hesaplanmış değerlerini, M_w 'ye dönüştüren bağıntıları lineer ve ortogonal regresyon yöntemleriyle geliştirmiştir. Ayrıca, KRDAE- M_w ile GMT- M_w arasındaki dönüşümleri de değerlendirmiştir. Bu çalışmanın sonuçlarına göre, (1.13-1.17) bağıntılarını en yüksek determinasyon katsayısını (R^2) veren en iyi ilişkiler olarak bulmuştur.

$$M_w = 0.7917(\pm 0.0400)ML + 1.1760(\pm 0.2080) \quad (R^2 = 0.7366) \quad (1.13)$$

$$M_w = 0.7898(\pm 0.0710)mb + 1.2502(\pm 0.3640) \quad (R^2 = 0.5228) \quad (1.14)$$

$$M_w = 0.6140(\pm 0.1615)M_s + 2.3580(\pm 0.0301) \quad (R^2 = 0.8736) \quad (1.15)$$

$$M_w = 0.5321(\pm 0.683)M_d + 2.6890(\pm 0.3480) \quad (R^2 = 0.5582) \quad (1.16)$$

$$M_w = 0.8140(\pm 0.0379)M_w(KRDAE) + 1.102(\pm 0.2088) \quad (R^2 = 0.9003) \quad (1.17)$$

Kadirioğlu ve Kartal (2016) tarafından Türkiye’de meydana gelmiş 489 adet depremin Harvard GMT kataloğundaki M_w değerleri kullanılarak ML, mb, M_s ve M_d dönüşümleri lineer ve ortogonal regresyon yöntemleriyle geliştirilmiştir. Bu çalışmada hesaplanan ve veriyi en iyi temsil dönüşüm denklemleri (1.18-1.22) bağıntıları ile verilmiştir.

$$M_w = 0.8095(\pm 0.0310)ML + 1.3003(\pm 0.1540) \quad (R^2 = 0.6244) \quad (1.18)$$

$$M_w = 1.0319(\pm 0.0250)mb + 0.0223(\pm 0.023) \quad (R^2 = 0.7734) \quad (1.19)$$

$$M_w = 0.5716(\pm 0.0249)M_s + 2.4980(\pm 0.1171) \quad M_s \leq 5.4 \quad (1.20)$$

$$M_w = 0.8126(\pm 0.683)M_s + 1.1723(\pm 0.3480) \quad M_s \geq 5.5 \quad (1.21)$$

$$M_w = 0.7947(\pm 0.0330)M_d + 1.3420(\pm 0.1630) \quad (R^2 = 0.7329) \quad (1.22)$$

Tang vd., (2016) tarafından Çin’in batı bölgesi için Çin deprem merkezi tarafından oluşturulan deprem kataloglarından 1900 ile 2014 yılları arasındaki depremlerin farklı magnitüd türlerinin (ML, mb, M_s), GMT tarafından yayınlanan Moment magnitüdüne (M_w) dönüşüm denklemleri elde edilmiştir. (1.23-1.25) bağıntıları ile verilen dönüşüm denklemleri oluşturulurken lineer ve ortogonal regresyon yöntemleri kullanılmıştır.

$$M_w = 0.71ML + 1.48 \quad (SD = 0.13) \quad (1.23)$$

$$M_w = 1.16mb + 0.55 \quad (SD = 0.10) \quad (1.24)$$

$$M_w = 0.69M_s + 1.61 \quad (SD = 0.06) \quad (1.25)$$

Bu çalışma sonuçlarına göre standart sapması (SD) en az olan denklemler (1.23-1.25) bağıntılarıdır. Yukarıda detaylı olarak verilen bağıntılar bu tez kapsamında oluşturulan mangitüd dönüşüm bağıntılarıyla karşılaştırılmıştır.


1.3. Azalım İlişkilerinde Kullanılan Parametreler

Literatürdeki azalım ilişkileri incelendiğinde hesaplamalarda genel olarak deprem sonrası oluşan maksimum yer hareketinin ölçülen değeri, depremin büyüklüğü, deprem kaynağı ile istasyon arasındaki uzaklık ve zemin özelliğini temsil eden kayma dalga (S-dalgası) hızı gibi ana parametreler kullanılmıştır.

1.3.1. Kuvvetli Yer Hareketi Parametreleri


Depremlerden sonra meydana gelen hasar yapıcı kuvvetlerin belirlenmesi veya ölçülmesi, deprem sırasında deprem-zemin-yapı arasındaki ilişkinin belirlenmesinde önemli bir rol oynamaktadır. Depremin bir noktaya olan etkisini belirlemek için o noktadaki yer hareketinin ivmesinin ivmeölçerler aracılığıyla ölçülmesi veya geliştirilen azalım ilişkileriyle belirlenmesi gerekmektedir. Bu sayede o bölgedeki sismik tehlike ve risk doğru bir şekilde değerlendirilebilir ve uygun yapı tasarımı yapılabilir.

Yer hareketleri zamana bağlı olarak ivme, hız ve yer değiştirme olmak üzere farklı genlik parametreleri kullanılarak kaydedilirler. İlk kez yer hareketi ivme kaydının Kaliforniya’da 1933 yılında alınmasından itibaren, depremlerin oluşturduğu yer hareketinin ivmelerinin ölçülmesinde Dünya’nın farklı yerlerinde konumlandırılan ivmeölçer cihazları kullanılmaktadır. Türkiye için AFAD ve KRDAE –BDTİM kurumlarının farklı bölgelere konumlandıkları ivmeölçer istasyonları yer hareketi ivmesi ölçmektedir. Bu iki ulusal kurum son yıllarda toplamda 1000’ den fazla deprem istasyonu işleterek Türkiye’de ve civarında meydana gelen depremleri izlemektedir. Bu iki kurum işlettikleri deprem istasyonlarında farklı duyarlıklara ve periyot aralıklarına (kısa, uzun ve geniş periyot) sahip çeşitli modellerde (GURALP, SARA, GEOSIG, ETNA ve AKASHI) ivmeölçer ve hızölçerler kullanılmaktadırlar (Şekil 1.2).




Şekil 1. 2. GÜRALP-3T geniş-band hızölçer tepki spektrumu ve farklı model (streckeisen STS-1, STS-2; SRO ve DWWSSN) sismometreler ile karşılaştırılması (Stein ve Wysession, 2003'den değiştirilerek alınmıştır).

AFAD ulusal ivmeölçer ağıнын 24.01.2020 tarihinde Türkiye saati ile 17:55:11'de kayıt edilen $M_w=6.8$ Sivrice (Elazığ) depreminin TK.4404 istasyonundaki doğu-batı (EW) bileşen ivme-hız-yer değiştirme kayıtları örnek olarak Şekil 1.3'de verilmiştir.



Şekil 1. 3. AFAD istasyon ağıındaki TK.4404 nolu istasyonundaki $M_w=6.8$ Sivrice (Elazığ) depreminin doğu-batı (EW) bileşen ivme-hız-yer değiştirme kayıt örnekleri (Mavi ile gösterilen işlenmemiş, ham kayıtlar; kırmızı ile gösterilen trent-etkisi giderilmiş, işlenmiş kayıtlardır) AFAD-TADAS'dan alınmıştır (URL-1, 2021).

Şekil 1.3'ün devamı




İvme kayıtları, “ cm/sn^2 (gal)” biriminde ve yer çekimi ivmesi ($g=981\text{cm/sn}^2$)’ nin yaklaşık 1/1000’i değerine karşılık gelmektedir. Hız kayıtlarının birimi “ cm/sn ” ve yer değiştirme kayıtlarının birimi “ cm ” olarak tanımlanmaktadır.

Yer hareketlerinin etkileri genlik, frekans içeriği, yer hareketinin süresi, güç ve tepki spektrumları gibi yer hareketi parametreleriyle belirlenmektedir. Yer hareketinin genliğini belirlemede pik yer ivmesi (PGA) veya pik yatay ivme (PHA) en yaygın ölçüt olarak kullanılmaktadır. PGA, kayıt edilen yer hareket bileşeni içerisinde mutlak değer olarak en büyük genlik değeri olarak da açıklanabilir. Yer hareketi tahminlerinde düşey ivmelere göre yatay ivme değerleri daha çok dikkate alınmaktadır. Bunun nedeni, mühendislik yapılarının yatay yer hareketi ivmelerinin yarattığı çekme ve kesme kuvvetlerine karşı az dayanım göstermelerine karşın düşey yer hareketi ivmelerine karşı yeterli dayanımı göstermeleridir. Bu nedenlerden dolayı, azalım ilişkileri geliştirilirken genellikle yatay yer hareketi ivmeleri kullanılarak oluşturulmaktadır. PGA değerleri yüksek olan depremler sonrası oluşan yer hareketleri genellikle daha düşük PGA değerlerine göre daha yıkıcı etki yapmaktadırlar. Bu etki ayrıca yer hareketinin süre parametresine göre değişiklik göstermektedir. Yer hareketinin genliğini tanımlayan diğer bir parametre ise pik yatay hız (PHV) parametresidir.

Bu parametre, yer hareketinin orta frekanslardaki genliğini tanımlamada PGA parametresinden daha duyarlıdır. Bu iki parametre yanında daha düşük frekans değerlerine duyarlı pik yer değiştirme değeri yer hareketinin genliğini tanımlamada kullanılmaktadır. Ancak, bu parametrenin belirlenmesinde kullanılan veri işlem aşamalarındaki hatalar, integral işlemleri ve gürültülerden (uzun periyotlu) dolayı hesaplanması zordur ve daha az kullanılmaktadır (Joyner ve Boore, 1988; Kramer, 1996). Bu üç parametreye örnek kayıtlar Şekil 1.3’ de verilmiştir.


Depremler sonrasında meydana gelen yer hareketinin genliği farklı frekans aralıklarına dağılabilmektedir. Bu dağılımı, diğer bir yer hareketi tanımlama parametresi olan frekans içeriği açıklamaktadır. Aynı zamanda, depremlerin büyüklükleriyle ilişkili bu parametre depremlerin hasar yapıcı etkisini belirlemede önemli rol oynamaktadır. Ayrıca, frekans içeriği mesafeye bağlı olarak değişim göstermesinden dolayı bu parametre iyi bir şekilde tanımlanmazsa, yer hareketinin içeriği tam olarak açıklanamaz. Frekans içeriğini belirlemek için zamana bağlı olarak alınan kayda Fourier dönüşümü uygulanarak Fourier genlik spektrumları oluşturulmaktadır. Böylece, deprem dalgasının hangi frekanslı ve genlikli harmonikleri içerdiği ve hangi frekanstaki genliklerin baskın olduğu belirlenmektedir. Sivrice (Elazığ) Mw=6.8 depreminin TK.4404 istasyonundaki ivme kaydının doğu-batı EW bileşeninin Fourier spektrumu Şekil 1.4’de verilmiştir. Fourier genlik spektrumlarının karesi alınarak dalga bileşenlerinin güç spektrumları oluşturulmakta ve böylece yapı üzerindeki etkileri daha iyi bir şekilde tanımlanabilmektedir.



Şekil 1. 4. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Sivrice (Elazığ) Mw=6.8 depreminin doğu-batı (EW) bileşeni ve Fourier dönüşümü alınarak elde edilen Fourier genlik spektrumu (AFAD –TADAS’dan alınmıştır, URL-1, 2021).


Spektral ivme (SA), bir nesne üzerinde bir deprem kaynaklı maksimum ivmeyi tanımlayan, g (dünyanın yerçekimine bağlı ivme) cinsinden ölçülen bir birimdir. SA, farklı salınım frekanslarında ve farklı sönümlleme derecelerinde ölçülebilir, ancak genellikle % 5 sönümlleme uygulanmaktadır. Farklı frekanslardaki SA, bir tepki spektrumu oluşturmak için grafik haline getirilebilir. Deprem mühendisliğinde binanın doğal titreşim frekansı ile ilgili bir değere sahip spektral ivme kullanılmaktadır. Bu değer, belirli bir doğal periyot ve sönümlleme seviyesine sahip doğrusal bir osilatörde bir yer hareketinin neden olacağı maksimum ivmeyi temsil eder. Gerçek ölçü, sözde (pseudo)-spektral ivmedir (PSA) ve spektral yer değiştirme ile doğal frekansın karesinin çarpımına eşittir, ancak fark genellikle ihmal edilebilir düzeydedir ve bu nedenle genellikle SA olarak tanımlanır. Ancak, SA genellikle yerbilimciler ve inşaat mühendisleri tarafından farklı bir şekilde tanımlanır. Fark, bir noktadaki deprem yer hareketlerinin birden fazla yönde meydana gelmesinden kaynaklanmaktadır. İnşaat mühendisleri genellikle yatay düzlemde tek bir eksen boyunca yer hareketinin neden olduğu SA'yı kullanırken, yerbilimciler genellikle bir yer hareketinin birbirine dik iki yatay bileşeni (KG ve DB) için SA değerlerini hesaplayıp, bu değerlerin geometrik ortalamasını kullanmaktadırlar. Bazı sismik tehlike haritaları da spektral ivme kullanılarak üretilmektedir.

Yer hareketinin özellikle bina üzerindeki etkisini tanımlamada tepki spektrumları kullanılmaktadır. Tepki spektrumları, bir deprem hareketine karşı tek serbestlik dereceli bir sistemin periyoda ve sönüm oranına bağlı maksimum tepkisini tanımlar. Mühendislik yapıları planlanırken ivme, hız ve yer değiştirme tepki spektrumları dikkate alınarak yapılmaktadır. İvme tepki spektrumları yapıya etkileyen kuvvetleri, hız tepki spektrumları yapıyı etkileyen maksimum enerjiyi ve yer değiştirme tepki spektrumları yer değiştirmenin veya şekil değiştirmenin etkisinin yapı içindeki gerilmelerle ilişkilerini göstermektedir. 24 Ocak 2020 tarihinde meydana gelen Sivrice (Elazığ) $M_w=6.8$ depreminin AFAD ivmeölçer ağının TK.4404 istasyonundaki ivme kaydının doğu-batı (EW) bileşeninin ivme tepki spektrumu Şekil 1.5'te verilmiştir



Şekil 1. 5. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Sivrice (Elazığ) Mw=6.8 depreminin doğu-batı (EW) bileşeninin ivme tepki spektrumu (AFAD-TADAS'dan alınmıştır, URL-1, 2021).


Kuvvetli yer hareketlerinin mühendislik yapıları üzerinde etkisi süre parametresiyle de ilişkili olarak değişmektedir. Orta düzeyde genliğe sahip uzun süreli yer hareketi, yüksek genlikli kısa süreli yer hareketine göre daha hasar yapıcı etkiye sahip olabilir. Kuvvetli yer hareketinin süresi meydana gelen depremin magnitudü, odak uzaklığı ve zemin özelliklerine göre değişiklik göstermektedir (Trifunac ve Brady, 1976). Mühendislik amaçlı çalışmalarda genel olarak sınırlandırılmış süre ve etkin süre tanımlamaları kullanılmaktadır. Sınırlandırılmış süre, ivme değerlerinin $0.05g$ (50 cm/sn^2) eşik değerini ilk ve son kez aştığı zaman aralığı olarak tanımlanmıştır. Etkin süre ise, Husid vd., (1969) tarafından deprem sinyalinin enerjisinin %5 ile %95'i arasında geçen zaman olarak tanımlanmıştır. Bu parametreyi belirlemek için yer hareketinin Arias şiddet (Arias,1970) grafikleri çizilmektedir. Etkin süreyi belirlemek için örnek olarak Sivrice (Elazığ) Mw=6.8 depreminin TK.4404 istasyonundaki ivme kaydının doğu-batı (EW) Arias şiddet grafiği (Husid çizimi) Şekil 1.6'da verilmiştir.



Şekil 1. 6. AFAD ivmeölçer ağının TK.4404 nolu istasyonundaki Mw=6.8 Sivrice (Elazığ) depreminin doğu-batı (EW) bileşeninin Arias şiddet grafiği (AFAD-TADAS'dan alınmıştır, URL-1, 2021).

1.3.2. Deprem-İstasyon Arası Uzaklık Parametreleri

Deprem dalgalarının genlikleri kaynaktan uzaklaştıkça azalmaktadır. Bu azalımı tanımlamak için depremi kaydeden istasyon ile deprem kaynağı arasındaki uzaklık parametresinden faydalanılmaktadır. Literatürde azalım ilişkileri oluştururken yaygın olarak; deprem kaynağının (iç merkez, hiposantr) yer yüzeyindeki izdüşümü olan dış merkez (episantr) ile istasyon arasındaki dış merkez uzaklığı R_{epi} , deprem kaynağı ile istasyon arasındaki iç merkez uzaklığı R_{hyp} , istasyondan fayın yüzey kırığına olan en yakın uzaklık R_{rup} (Abrahamson ve Silva, 1997) ve istasyondan fayın kırılma düzleminin yeryüzündeki izdüşümüne en yakın olan uzaklık R_{jb} (Joyner ve Boore, 1988) gibi uzaklık parametreleri kullanılmıştır. Farklı eğimli fay geometrileri ve farklı istasyon konumları için tanımlanan uzaklık parametreleri Şekil 1.7’de verilmiştir.



Şekil 1. 7. Farklı eğimli fay geometrileri ve farklı istasyon konumları için tanımlanan; R_{epi} , R_{hypo} , R_{rup} ve R_{jb} uzaklık parametreleri


Dışmerkez uzaklığı R_{epi} ile iç merkez uzaklığı R_{hyp} arasında h odak derinliğine bağlı bağıntı (1.26) gibi bir ilişki vardır.

$$R_{hyp} = \sqrt{R_{epi}^2 + h^2} \quad (1.26)$$

Literatürde farklı araştırmacılar tarafından yukarıda tanımlanan uzaklık parametreleri, kuvvetli yer hareketi tahminleri için geliştirilen azalım ilişkilerinde kullanılmıştır (Joyner ve Boore, 1988; Campbell, 1985; Idriss, 1995; İnan vd., 1996; Aydan vd., 1996; Sadigh, 1997; Abrahamson ve Silva, 1997; Boore vd., 1997; Gülkan ve Kalkan, 2002; Özbey vd., 2003; Kalkan ve Gülkan, 2004; Ulusay vd., 2004; Beyaz, 2004; Çeken, 2007; Akkar ve Bommer, 2010; Ulutaş ve Özer., 2010; Bommer vd., 2011; Akkar vd., 2014; Bommer vd., 2016).


1.3.3. Zemin Özellik Parametresi (Kayma dalga hızı, V_{s30})

Deprem sonrası oluşan yer hareketinin etkisini kontrol eden ve belirleyen en önemli parametrelerden birisi de yerel zemin özellikleridir. Bu özellikler; ana-kaya derinliği, havza geometrisi, topoğrafya, yer altı su seviyesi, zeminin kalınlığı, yoğunluğu ve dinamik özelliklerine bağlı olarak değişiklik göstermektedir. Bu yerel zemin özellikleri depremlerin yüzeydeki yıkıcı ve hasar verici etkisini belirleyen en önemli parametredir. Lachet vd., (1996), yaptıkları çalışmada yerel zemin koşullarının mühendislik yapılarında hasar ve deprem kayıtları üzerinde etki yaratabileceğini vurgulamıştır. Zemin katmanlarının etkileri; özellikle kaya zemin ve alüvyon zemin olma durumuna göre deprem dalgaları üzerinde büyük değişimler göstermektedir. Alüvyon zeminlerde yüksek periyodlu dalgalar etkili olurken, kaya zeminlerde düşük periyodlu dalgalar etkili olmaktadır. Başka bir deyişle, alüvyon zeminlerde yüksek periyodlu yani çok katlı yapılar daha fazla hasar yapıcı etkiye uğrarken, kaya zeminlerde düşük periyodlu yani az katlı yapılar daha fazla hasar yapıcı etkiye maruz kalmaktadırlar. Zemin özelliklerinin etkileri, 19 Eylül 1985 yılında Meksika'nın başkentin Meksiko şehrine (Mexico City) yaklaşık 400 km uzaklıkta meydana gelen 8.1 magnitudündeki depremin, alüvyon (yumuşak) zemine kurulan şehir üzerindeki hasar yapıcı ve yıkıcı etkisinden sonra detaylı olarak araştırılmaya başlanmıştır. 1985 yılından meydana gelen bu depremin farklı zemin ve uzaklıktaki istasyonlarda alınan ivme kayıtları örnekleri Şekil 1.8' de gösterilmiştir.



Şekil 1. 8. 1985 Meksiko depreminin farklı zemin ve uzaklıktaki istasyonlarda kayıt edilen PGA değerleri.

Son yıllarda zemin özelliklerin belirlenmesinde aktif ve pasif kaynaklı yüzey dalgası yöntemleri kullanılmaktadır. Aktif kaynaklı yöntem olarak, “Yüzey Dalgalarının Spektral Analizi Yöntemi (SASW)” ve “Yüzey Dalgalarının Çok Kanallı Analizi Yöntemi (MASW)” kullanılmaktadır. Pasif kaynaklı yöntemler ise doğal titreşimleri kullanan tek ve çok istasyonlu mikrotremor yöntemleridir. Aktif kaynaklı yöntemlerde kaynak olarak balyoz ya da patlayıcı maddeler kullanılırken, pasif kaynaklı yöntemlerde ise kültürel, tektonik ve meteorolojik kaynaklı yerin doğal titreşimleri kullanılmaktadır. Aktif kaynaklı yöntemler, sığ yapıları daha yüksek çözünürlüğe sahip olarak belirlemektedirler. Bu nedenle, pasif kaynaklı yöntemler daha derin araştırmalar için tercih edilirken, aktif kaynaklı yöntemler daha sığ araştırmalar için tercih edilmektedir. Sığ zemin özelliklerini belirlenmesinde sık kullanılan Yüzey Dalgalarının Çok Kanallı Analizi Yöntemi’ nin veri toplama aşaması ve kayma dalga (S-dalgası) dalga hızının (V_s) belirlenmesi için uygulanan veri işlem aşamaları Şekil 1.9’ da gösterilmiştir.



Şekil 1. 9. MASW yönteminde veri toplama aşaması ve S-dalgası hızını belirlemek için uygulanan veri işlem aşamaları (Kanbur vd., 2014'den değiştirilerek alınmıştır).

Kuvvetli yer hareketi tahminleri için geliştirilen azalım ilişkilerinde, deprem kayıt istasyonlarındaki zemin koşullarını tanımlamak için üst 30 metredeki ortalama kayma-dalgası hızının (V_{s30}), zemin özelliğini teslim eden bir parametre olarak kullanılabileceği belirlenmiştir. Literatürde oluşturulan yeni nesil azalım ilişkilerinde, zemin özelliğini temsil eden V_{s30} hızı veya bu hıza bağlı olarak tanımlanan zemin sınıflama katsayısı kullanılmıştır (Özbey vd., 2003; Kalkan ve Gülkan, 2004; Çeken, 2007; Akkar ve Bommer, 2010; Bommer vd., 2011; Akkar vd., 2014; Çağnan vd., 2017).

1.4. Literatürdeki Azalım İlişkileri

Literatürde, azalım ilişkileri uzun bir zamandır oluşturulmakta ve geliştirilmektedir. İlk yapılan çalışmalarda bu ilişkiler, depremlerin büyüklük ve uzaklık parametreleri temel olarak oluşturulmuştur (Esteva ve Villaverde, 1973; Ambraseys, 1975, 1978). Sonraki yıllarda tektonik ve yerel zemin koşullarını içeren parametreleri de ekleyip gelişen bilgisayar teknolojisi sayesinde daha duyarlı olasılıksal ve istatistiksel hesaplamalar yapan araştırmacılar ikinci kuşak azalım ilişkilerini geliştirilmiştir (Joyner ve Boore, 1988; Ambraseys ve Bommer, 1991; Campbell, 1997, 2000). Bu tür azalım ilişkilerinde daha çok zemin sınıflamalarına ağırlık verilmiş ve farklı regresyon (ilişki) yöntemleri ile matematiksel modeller kullanılmıştır. Pasifik Deprem Mühendisliği Araştırma Merkezi (PEER) tarafından batı Amerika için geliştirilen yeni kuşak azalım denklemleri (NGA, Next Generation Attenuations) çok sayıda deprem ve kayıt verisi kullanılarak oluşturulmuştur. Bu modellerde ikinci kuşak modellerden farklı olarak zemin türlerini sınıflandırmak yerine, zeminin doğrusal ve doğrusal olmayan davranışını yansıtmak için doğrudan kayma dalga hızını (V_{s30}) parametre olarak kullanılmıştır (Abrahamson ve Silva, 2008; Boore ve Atkinson, 2008; Campbell ve Bozorgnia, 2008; Idriss, 2008; Kale vd., 2015; Bommer vd., 2016; Gülerce vd., 2017; Çağnan vd., 2017; Bindi vd., 2019).

Yer hareketini tahmin etmek için araştırmacılar uzun yıllardır farklı matematiksel modelleri, yer hareketini tanımlayan farklı parametreleri ve sayıları gün geçtikçe artan sismik ağ verilerini kullanarak farklı analiz yöntemlerine göre birçok azalım ilişkisi geliştirmişler ve geliştirmeye devam etmektedirler (Esteva ve Villaverde, 1973; Ambraseys, 1975, 1978; Campbell, 1985; Joyner ve Boore, 1988; Fukushima ve Tanaka, 1990; Ambraseys ve Bommer, 1991; Ambraseys vd., 1996; İnan vd., 1996; Aydan vd., 1996; Abrahamson ve Silva, 1997; Sadigh vd., 1997; Boore vd., 1997; Sadigh ve Egan 1998; Campbell, 1997, 2000; Gülkan ve Kalkan, 2002; Kalkan ve Gülkan, 2004; Bommer vd., 2003; Özbey vd., 2003; Ulusay vd., 2004; Beyaz, 2004; Çeken, 2007; Abrahamson ve Silva 2008; Boore ve Atkinson 2008; Campbell ve Bozorgnia, 2008; Idriss, 2008; Ulutaş ve Özer, 2010; Akkar ve Bommer, 2010; Akkar ve Çağnan 2010; Bommer vd., 2011; Akkar vd., 2014; Kale vd., 2015; Bommer vd., 2016; Gülerce vd., 2017; Çağnan vd., 2017; Bindi vd., 2019).

Bu tez kapsamında elde edilen PGA tahmin değerlerinin karşılaştırılacağı ve literatürde kabul gören farklı azalım ilişkileri (tahmin denklemleri) detaylı olarak bu

bölümde açıklanmıştır. Esteva ve Villaverde (1973), deprem büyüklüğüne ve uzaklığına bağlı (1.27) bağıntısıyla ile verilen bir azalım ilişkisini geliştirmişlerdir. Bu azalım ilişkisi için ABD’de meydana gelmiş depremler kullanılmışlar ve bağıntının 15-150 km arasında duyarlılığa sahip olduğunu belirtmişlerdir.

$$a = 5600e^{0.8M}(R + 40)^{-2} \quad (1.27)$$

Burada a , ivme (cm/sn^2); M , deprem magnitüdü ve R uzaklığı, (km) ifade etmektedir.

İnan vd., (1996) tarafından 1976 ile 1996 yılları arasında Türkiye’de meydana gelen depremlerin ivme kayıtları kullanılarak, (1.28) bağıntısı ile verilen azalım ilişkisini oluşturulmuştur.

$$\text{LogPGA} = 0.65 M - 0.9 \log R - 0.44 \quad (1.28)$$

Burada PGA, en büyük yer ivme (cm/sn^2); M , deprem magnitüdü ve R , episantr uzaklığını (km) ifade etmektedir.

Boore vd., (1997) tarafından Kuzey ABD’de meydana gelen magnitüdü $M_w > 5.0$ olan depremlerin kuvvetli yer hareketi parametrelerinden oluşturulan veri setiyle (1.29) bağıntısında verilen azalım ilişkisi geliştirilmiştir. Yerel zemin koşullarını ifade etmek için üst 30 metredeki kayma dalga hızını (V_{s30}), kırılmanın yeryüzündeki izdüşümüne en yakın mesafesini (R_{jb}) ve deprem magnitüd değerini kullanarak regresyon analizleri ile PGA tahmin denklemi oluşturmuşlardır.

$$\log Y = b_1 + b_2(M - 6) + b_3(M - 6)^2 + b_4 r + b_5 \log r + b_v(\log V_s - \log V_A) \quad (1.29)$$

$$r = \sqrt{(d^2 + h^2)}$$

Burada Y , en büyük yer ivmesi (g); M , deprem magnitüdü; d , kırılmanın yeryüzündeki izdüşümüne en yakın mesafe (km), $b_1 = -0.038$, $b_2 = 0.216$, $b_3 = 0$, $b_4 = 0$, $b_5 = -0.777$, $h = 5.48$, $b_v = -0.364$; V_s , 30 metredeki kayma dalga hızını ve $V_A = 1390 \text{ m/sn}$ olarak ifade edilmiştir.

Sadigh ve Egan (1998) tarafından geliştirilen ve (1.30) bağıntısıyla verilen azalım ilişkisinde, farklı fay türlerine ve farklı magnitüd aralıklarına göre ($M_w < 6.5$ ve $M_w \geq 6.5$) veri setlerini kullanarak ilişki katsayılarını hesaplamışlardır. Ayrıca, V_{s30} hızına göre iki

farklı zemin gurubu oluşturmuşlar ve hesaplamalarda bu zemin gruplarını ele almışlardır (Tablo 1.1).

$$\ln PGA = C_1 + C_2 M + C_3 \ln[r_{rup} + \exp(C_4 + C_5 M)] \quad (1.30)$$

Burada PGA, en büyük yer ivmesi (g); M, deprem magnitüdü; r_{rup} , fayın yüzey kırığına olan en yakın uzaklığını ifade etmektedir.

Tablo 1. 1. Sadıgh ve Egan (1998) tarafından geliştirilen azalım ilişkisinin farklı magnitüd aralıkları ($M_w < 6.5$ ve $M_w \geq 6.5$), zemin grupları, fay türlerine göre hesaplanan katsayıları.

Magnitüd aralığı	Zemin grubu	Katsayı
$M < 6.5$ $M \geq 6.5$		$C_4 = 1.29649, C_5 = 0.25$ $C_4 = -0.48451, C_5 = 0.524$
$M < 6.5$ " $M \geq 6.5$ "	Kaya zemin " "	$C_3 = -2.1$ $C_1 = -0.949, C_2 = 1.05$ (doğrultu atımlı fay) $C_1 = 0.276, C_2 = 0.9$ (ters fay) $C_1 = -1.274, C_2 = 1.1$ (doğrultu atımlı fay) $C_1 = -1.024, C_2 = 1.1$ (ters fay)
$M < 6.5$ " $M \geq 6.5$ "	Yumuşak zemin " "	$C_3 = -1.75$ $C_1 = -1.11, C_2 = 0.875$ (doğrultu atımlı fay) $C_1 = -0.0895, C_2 = 0.75$ (ters fay) $C_1 = -1.383, C_2 = 0.917$ (doğrultu atımlı fay) $C_1 = -1.175, C_2 = 0.917$ (ters fay)

Kalkan ve Gülkan (2004) tarafından 1976-2003 yılları arasında meydana gelen ve magnitüdüleri $4.0 < M_w \leq 4.7$ olan 57 depremin 112 ivme kaydını kullanarak (1.31) bağıntısıyla verilen bir azalım ilişkisi geliştirmişlerdir. Kullanılan veri setinde 250 km uzaklıktan kaydedilen veriler de bulunmaktadır.

$$\ln Y = b_1 + b_2(M - 6) + b_3(M - 6)^2 + b_5 \ln r + b_V \ln\left(\frac{V_s}{V_A}\right) \quad (1.31)$$

$$r = \sqrt{(r_{cl}^2 + h^2)}$$

Burada Y, en büyük yer ivmesini (cm/sn^2); M, depremin moment magnitüdü; r_{cl} , fayın yüzey kırığına olan en yakın uzaklığını (km); V_s , kayma-dalgası hızını (m/sn); h, odak derinliği

(km) ve V_A alüvyondaki kayma dalga hızını (m/sn) ifade etmektedir. Bağıntının katsayıları; $b_1 = -0.682$, $b_2 = 0.253$, $b_3 = 0.036$, $b_5 = -0.562$ $b_V = -0.297$ ve $V_A = 1381$ m/sn, $h = 4,48$ km olarak verilmiştir.

Özbey vd., (2003) tarafından KAFZ'ın kuzeybatı kısmında 1999 – 2000 yılları arasında meydana gelen magnitüdü $M_w \geq 5.0$ olan 17 depremin 195 ivme kaydı kullanılarak bölge için (1.32) bağıntısı ile verilen bir azalım ilişkisi geliştirilmiştir. Veri seti genel olarak 17 Ağustos Kocaeli ve 12 Kasım Düzce Depremi ile bu depremlerin artçı şokları kullanılmıştır.

$$\ln Y_{ij} = a + b(M_{wi} - 6) + c(M_{wi} - 6)^2 + d \log \left(\sqrt{(r_{ij}^2 + h^2)} \right) + eG_1 + fG_2 \quad (1.32)$$

Burada Y_{ij} , en büyük yatay yer ivmesinin iki bileşeninin (KG ve DB) geometrik ortalamasını (cm/sn^2); M_{wi} , i'nci depremin moment magnitüdünü; R_{ij} , j'inci kaydın i'inci depremin yol açtığı kırığın izdüşümüne en yakın mesafesini (km) ve h , odak derinliğini (km) ifade etmektedir. Bağıntının katsayıları; $a=3.287$, $b= 0.503$, $c=-0,079$, $d=-1.177$, $e=0.141$, $f=0.33$ ve $h=14.82$ km olarak verilmiştir. Araştırmacılar zemin parametresi olarak; kaya zemin ($V_s > 750$ m/sn ve $V_s=360-750$ m/sn, A ve B grubu) için $G_1 = 0$ ve $G_2 = 0$, normal zemin ($V_s=180-360$ m/sn, C grubu) için $G_1 = 1$ ve $G_2 = 0$ ve yumuşak zemin ($V_s < 180$ m/sn, D grubu) için $G_1 = 0$ ve $G_2 = 1$ değerlerini kullanmışlardır.

Beyaz (2004), 1976-2004 yılları arasında Türkiye'de meydana gelen magnitüdüleri $M_w \geq 4.0$ olan depremlerin kaydedilen kuvvetli yer hareketi kayıtları kullanarak (1.33) bağıntısı ile verilen azalım ilişkisini geliştirmiştir. Bu bağıntı oluşturulurken pik ivme değeri 20 cm/sn^2 'nin üzerinde seçilmiş ve 200 km'den uzak istasyon kayıtları kullanılmamıştır.

$$\log A = 2.08 + (0.0254M_w^2) - 1.001 \log(R + 1) \quad (1.33)$$

Burada A , en büyük yatay yer ivmesi (cm/sn^2); R , deprem episantr mesafesi (km); M_w , depremin moment magnitüdünü ifade etmektedir.

Akkar vd., (2014) tarafından daha önceki nesil azalım ilişkilerindeki modeller (Ambraseys vd., 1996 , 2005; Bommer vd., 2003; Akkar ve Bommer, 2010) baz alınarak ve Avrupa veri tabanı kullanılarak, Avrupa ve Orta Doğu için yeni nesil bir azalım ilişkisi geliştirilmiştir. Bu azalım ilişkisine, doğrusal olmayan zemin büyütme fonksiyonu için $V_s 30$ hızını baz alan bir parametre ile kaya zeminde referans olarak maksimum yer ivmesi

parametresi eklenmiştir. Azalım ilişkisi, magnitüdü $M_w \geq 4.0$ olan depremler ve uzaklığı 200 km kadar olan mesafeler için kullanılabılır hale getirilmiş ve hatta geliştirilen modelin farklı kaynak-istasyon arası mesafe türleri için de uygulanabileceği belirtilmiştir. Bu modele eklenen parametrelerle ve iyileştirmelerle Avrupa ve Orta Doğu'daki sığ (odak derinliği 30 km'den az) kabuk depremleri için daha önce yayınlanmış olan azalım ilişkilerinden daha iyi PGA tahmini yapılabileceği vurgulanmıştır. Geliştirilen azalım ilişkisi (1.34), (1.35) ve (1.36) bağıntılarıyla verilmiştir.

$$\ln Y = \ln Y_{REF} + \ln S \quad (1.34)$$

$$\ln Y_{REF} = \begin{cases} a_1 + a_2(M - 6.75) + a_3(8.5 - M)^2 + [a_4 + a_5(M - 6.75)] \ln \sqrt{R^2 + a_6^2} + a_8 F_N + a_9 F_R & M_w \leq 6.75 \\ a_1 + a_7(M - 6.75) + a_3(8.5 - M)^2 + [a_4 + a_5(M - 6.75)] \ln \sqrt{R^2 + a_6^2} + a_8 F_N + a_9 F_R & M_w > 6.75 \end{cases} \quad (1.35)$$

$$\ln S = \begin{cases} b_1 \ln \left(\frac{V_{S30}}{V_{REF}} \right) + b_2 \ln \left[\frac{PGA_{REF} + c \left(\frac{V_{S30}}{V_{REF}} \right)^n}{PGA_{REF} + c \left(\frac{V_{S30}}{V_{REF}} \right)^n} \right] & V_{S30} \leq V_{REF} \\ b_1 \ln \left[\frac{\min(V_{S30}, V_{CON})}{V_{REF}} \right] & V_{S30} > V_{REF} \end{cases} \quad (1.36)$$

Burada Y, en büyük yer ivmesini (g); V_{REF} , kaya zeminde referans Vs30 hızı (m/sn) ve V_{CON} , zemin büyütmesiyle ilgili sabit Vs30 hızını (m/sn) ifade etmektedir. Modelde fay tiplerine göre; doğrultu atımlı faylar için $F_N = F_R = 0$, normal faylar için $F_N = 1$, $F_R = 0$ ve ters faylar için $F_R = 1$, $F_N = 0$ olarak katsayılar belirlenmiştir. Tüm uzaklık türlerine göre katsayılar; $a_8 = -0.1091$, $a_9 = 0.0937$, $a_2 = 0.0029$, $a_5 = 0.2529$, $a_6 = 7.5$ ve $a_7 = -0.5096$ olarak hesaplanmıştır. Farklı uzaklıklar için diğer katsayılar ise; R_{JB} için $a_1 = 1.85329$, $a_3 = -0.02807$, $a_4 = -1.23452$, R_{epi} için $a_1 = 2.52977$, $a_3 = -0.05496$, $a_4 = -1.31001$, R_{hypo} için $a_1 = 3.26685$, $a_3 = -0.04846$, $a_4 = -1.47905$ olarak verilmiştir. Modeldeki diğer katsayılar için Sandıkkaya vd., (2013) tarafından hesaplanan $V_{REF} = 750 \text{ m/sn}$, $V_{CON} = 1000 \text{ m/sn}$, $b_1 = -0.41997$, $b_2 = -0.28846$, $c = 2.5$ ve $n = 3.2$ değerleri kullanılmıştır.

Literatürdeki kuvvetli yer hareketi tahmini için oluşturulan azalım ilişkileri incelendiğinde gelişim sürecinin devam ettiği gözlenmektedir. Doğrusal olmayan zemin davranışının bağıntı içerisinde temsilinin zor olması ve sayısı günden güne artan deprem istasyonları sayesinde kayıt edilen veri sayısının artması, ancak sınırlı sayıdaki verinin işlemlere konulması bu azalım ilişkilerinin oluşturulmasında güçlük yaratmaktadır. Bu

nedenle bu tez kapsamında gelişen YZ yöntemlerinin çok sayıdaki verilerin işlemini kolaylaştırması ve doğrusal olmayan davranışlar için anlamlı ilişkiler kurulabilmesinde daha etkili olmalarından dolayı bu yöntemler kullanılarak PGA tahmini yapılmıştır. Hesaplanan değerler yukarıda detaylı açıklanan literatürde yer alan Türkiye ve Dünyanın farklı bölgeleri için geliştirilen 8 farklı PGA tahmin denklemi (modeli) ile karşılaştırılmıştır.

1.5. Yapay Zekâ

Zekâ, bir şeyi kavrama veya önemini anlama olarak tanımlanabilir. Ayrıca, zekâ bireysel bilgi birikimi ve deneyimlerle ilişkili olarak gelişmektedir. Zekânın, gerçek hayat durumları veya koşullarına göre iyileştirilebilir, geliştirilebilir ve değiştirilebilir olduğu belirtilmiştir.


Yapay Zekâ (YZ) ise insanın düşünme yapısını anlamak ve bunun benzeri davranışları bilgisayar işlemleri tarafından yapılmasını geliştirmek olarak tanımlanabilir. Daha açık bir tanım olarak, YZ anlama, düşünme, yorumlama, kavrama ve öğrenme yapılarının bilgisayar kodlarıyla taklit edilerek problemlere çözüm sunmaları olarak da ifade edilebilir. Daha detaylı olarak YZ;

- Bilgisayarların algılama, bilgi edinme, düşünme ve karar verme gibi insan zekâsına özgü olguları içermesi,
- İnsanların karar verme ve düşünme süreçlerini, çeşitli yöntemler kullanarak taklit etmesi,
- İnsanın düşünme yapısının bir benzerini bilgisayar işlemleri şeklinde geliştirmeye çalışması ve böylece bir bilgisayarın düşünme girişimi olarak da tanımlanmıştır.

YZ, bilgisayar bilimi ve mühendisliği, felsefe, biyoloji, dilbilimi, kavram bilimi, psikoloji, iktisat, istatistik ve matematik gibi geniş bilim dallarını içermektedir. YZ, bir problem için girdi ve çıktıları arasındaki ilişkinin matematiksel olarak modellenemediği, algoritmasının oluşturulamadığı durumlarda problemi modellemek için kullanılan istatistiksel, sinirsel, sezgisel ve bulanık mantık gibi yöntemlerden biri ya da bir kaçını kullanarak çözümler üretmektedir. Doğrusal (Lineer) ve doğrusal olmayan problemlerin modellenmesi için de YZ teknikleri kullanılmaktadır.

YZ, yaygın bir şekilde farklı alanlarda araştırma ve uygulama alanı bulan bazı alt dallar içermektedir. Bunlardan makine öğrenme teknikleri, en iyi çözüme kısa sürede yaklaşma özelliğine sahip YSA'lar, meta-sezgisel optimizasyon yöntemleri (PSO, TLBO,


Genetik algoritma, Yapay arı kolonisi algoritması, Simbiyotik organizma arama algoritması, Yerçekimi Arama Algoritması, Diferansiyel Gelişim Algoritması, ...vb.) ve hibrit olarak kullanılan YZ teknikleri (YSA ile meta-sezgisel algoritmalar) birçok alanda olduğu gibi mühendislik problemlerinin çözümünde de uygulanmaktadır. Son yıllarda bilgisayarın işlem kapasitelerinin artmasıyla birlikte YZ'nin alt dalları makine öğrenmesi ve derin öğrenme yöntemleriyle tanımlanmaktadır (Şekil 1.10).



Şekil 1. 10. Yapay Zekâ ve alt dallarının tarihsel gelişimi.

1.5.1. Makine Öğrenme Yöntemleri

Makine öğrenmesi, verilerden öğrenme gerçekleştirerek karşılaşılan durumlar hakkında modelleme ve tahmin yapmasını sağlayan yöntemler olarak tanımlanır. Makine öğrenmesi YZ'nin bir alt alanı olarak değerlendirilmektedir. Makine öğrenmesi, bir giriş verisi ile sonuç arasındaki ilişkiyi belirlemek için probleme ait verilerden yola çıkarak modelleme yapmak olarak da tanımlanabilmektedir. Başka bir açıdan makine öğrenmesi; sonuç değerlerini tahmin etmek için girilen verilerini analiz eden programlanmış algoritmalar kullanan YZ'nin bir alt dalıdır. Oluşturulan algoritmalara, yeni veriler verildiğinde sonuçları iyileştirmek ve zamanla 'zekâ' geliştirmek için kullanılan makine öğrenmesi yöntemleriyle öğrenir ve optimize ederler. Makine öğrenmesi, denetimli ve denetimsiz öğrenme yöntemleriyle veriler üzerinde kümeleme, sınıflandırma ve tahmin gibi farklı işlemleri yapmaktadır (Şekil 1.11).



Şekil 1. 11. Makine öğrenmesinin veriler üzerinden öğrenme ve işlem yapma şekilleri.

Giriş verilerinin sonuçları biliniyorsa denetimli öğrenme, eğer sonuçları bilinmiyorsa denetimsiz öğrenme olarak tanımlanmaktadır. Denetimli öğrenmenin mantığı, giriş verileri kullanılarak yeni giriş verileri için sınıflandırma veya tahmin yapılmasına dayanmaktadır. Bu öğrenme yönteminde giriş verileri içeriğinde, her veri için giriş ve çıkış değerlerinin olması gerekmektedir. Oluşturulan model bu giriş verileri üzerinden giriş ve çıkış arasındaki ilişkiyi öğrenmektedir. Başka bir deyişle, belirli bir X girişi için Y çıkışının olasılığı ne olduğunun öğrenilmesini amaçlar. Bu öğrenme yöntemiyle makine öğrenme algoritmaları verileri sınıflandırabilir veya regresyon yardımıyla gelecekteki durumu tahmin edebilir. Sınıflandırma, bir veri kümesinin belirlenen sınıflar arasında dağıtma işlemi olarak tanımlanır. Bu yöntemle algoritma, verilen eğitim kümesinden bu dağılım şeklini öğrenerek, sınıfı belli olmayan verileri doğru şekilde sınıflandırmayı hedeflemektedir. Regresyon yönteminde ise, iki veya çok değişkenli verilerin sebep-sonuç ilişkisini öğrenerek, bu değişkenler arasında tahmin yürütme olarak tanımlanmaktadır. Denetimli makine öğrenme yöntemleri genel olarak Tablo 1.2 verilmiştir.

Tablo 1. 2. Makine öğrenme algoritmalarının denetimli ve denetimsiz öğrenme yöntemleri.

Sınıflama Yöntemleri	Regresyon Yöntemleri	Kümeleme Yöntemleri
Yapay Sinir Ağları (YSA)	Yapay Sinir Ağları (YSA)	Yapay Sinir Ağları (YSA)
Destek vektör makinesi	Lineer Regresyon	K-means (KNN)
Naive Bayes sınıflandırıcısı	Destek vektör ve Gauss regresyonu	Hiyerarşik
En yakın komşu algoritması	Karar ağaçları	Gauss modeli
Diskriminant (Ayırma) analizi	Topluluk ağaçları	Gizli Markov modeli

Denetimsiz öğrenme mantığında ise, öğrenme için sadece giriş verileri vardır ve bunlara karşılık sonuç verileri yoktur. Kümeleme yöntemi bu öğrenme türü için örnek olarak verilebilir. Kümeleme yöntemi, ilişkilendirme ölçütlerini kullanarak verileri birkaç grup halinde kümeleme işlemi olarak tanımlanmaktadır. Verilerin önceden belirlenmiş kriterlere göre gruplandırılması işlemi olarak da tanımlanabilir. Örnek olarak kümeleme algoritmaları, görüntü ve ses işleme, anahtar kelimelerin aranması gibi uygulanmalarda kullanılmaktadır. Denetimsiz makine öğrenme için örnek yöntemler Tablo 1.2 gösterilmiştir. Bilgisayarların gelişen teknolojisi ve işlem kapasiteleriyle ilişkili olarak farklı makine öğrenme yöntemleri gelecek zaman içerisinde geliştirilecektir.

1.5.2. Yapay Sinir Ağları Genel Bilgiler


YZ tekniklerinden biri olan Yapay Sinir Ağları (YSA) biyolojik sinir sisteminin basit bir simülasyonunu içeren bilgisayar algoritmalarıdır. Bu şekilde, insanoğluna özgü deneyerek (yaşayarak) öğrenme yeteneğini bilgisayar ortamına taşıyabildiği düşünülen YSA teknolojisi, bir bilgisayar sistemine “girdi verisinden öğrenme” kapasitesi sağlamaktadır. YSA, basit biyolojik bir sinir sisteminin çalışma prensibini temel almaktadır. Sinir sistemi, sinir hücreleri yani nöronları içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak sinir ağlarını oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler. Diğer bir ifadeyle, YSA’lar normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. YSA, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Bir işlem elemanı, aslında transfer fonksiyonu olarak anılan bir denklemdir. Bu işlem, diğer nöronlardan sinyalleri alır, bunları birleştirir, dönüştürür ve sayısal bir sonuç ortaya çıkartır. Bu yapıda, işlem elemanları gerçek nöronlara karşılık gelirler ve bir ağ içinde birbirlerine bağlanırlar, bu yapı da sinir ağlarını oluşturmaktadır. YSA, en kısa ve basit şekilde, bir örnekler kümesi yardımıyla parametrelerin uyarlanabilmesini sağlayacak bir matematiksel formül için yazılan bilgisayar kodları olarak tanımlanabilir.

YSA’lar insan beyninin aktivitesi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak benzerlikler vardır. YSA mimarisi içerisindeki bir yapay sinir hücresi, biyolojik sinir ağlarının sinir hücresine benzetilmiştir (Tablo 1.3).

Tablo 1. 3 . Biyolojik sinir ve yapay sinir hücresi elemanları.

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Nöron →	Yapay Nöron (İşlemci Eleman)
Dendrit →	Toplama Fonksiyonu
Hücre Gövdesi →	Transfer Fonksiyonu
Aksonlar →	Yapay Nöron Çıkışı
Sinapslar →	Ağırlıklar

YSA birbirine bağlı doğrusal veya doğrusal olmayan birçok elemandan oluşur. Biyolojik sinir sistemi ile yapay sinir ağları arasındaki benzerlikler Şekil 1.12’de verilmiştir.



Şekil 1. 12. a) Biyolojik sinir hücresi ve b) yapay sinir hücresi.

Yapay sinir hücreleri, girdi (x_i), ağırlık katsayıları (w_i), net bilgileri fonksiyonu (NET), eşik değeri (bias), aktivasyon fonksiyonu ve çıktı (y_i) bileşenlerinden oluşmaktadır.

Girdiler (x_i): Yapay sinir ağının öğrenmesi için probleme dayalı verilen bilgilerdir.

Ağırlık katsayıları (w_i): YSA katmanlarında bulunan her bir yapay sinir hücresinin diğer katmana bilgileri hangi ağırlıkta taşıyacağını tanımlayan ağırlık değerleridir.

Net fonksiyonu (NET): Ağda bilgilerin, bir katmandan diğer katmana nasıl ulaştırılacağını belirleyen fonksiyondur. Ağ bilgilerinin taşınması aşağıda verilen fonksiyonlar ile yapılmaktadır.

Toplam fonksiyonu: Her bir yapay sinir hücresinden gelen bilgilerin toplanması ile hücreye gelen net girdi değeri hesaplanmaktadır. Yapay sinir ağı uygulamalarında sıkça kullanılan bu fonksiyonun ifadesi (1.37) bağıntısı ile verilmektedir.

$$NET = \sum_{i=1}^n x_i w_i \quad i = 1, 2, \dots, n \quad (1.37)$$

Maksimum değer fonksiyonu: Yapay sinir hücrelerinden gelen bilgilerin maksimumunu net girdisi olarak ileten fonksiyondur ve (1.38) bağıntısı ile tanımlanmaktadır.

$$NET = \max(x_i w_i) \quad i = 1, 2, \dots, n \quad (1.38)$$


Minimum değer fonksiyonu: Yapay sinir hücrelerinden gelen bilgilerin minimumunu net girdisi olarak ileten fonksiyondur ve (1.39) bağıntısı ile verilmektedir.

$$NET = \min(x_i w_i) \quad i = 1, 2, \dots, n \quad (1.39)$$

Çarpım fonksiyonu: Her bir yapay sinir hücresinden gelen bilgilerin çarpılmasıyla net girdi değerini hesaplayan fonksiyondur ve (1.40) bağıntısı ile hesaplanmaktadır.

$$NET = \prod_{i=1}^n x_i w_i \quad i = 1, 2, \dots, n \quad (1.40)$$

Eşik değer (bias): YSA'da belirsizliklerin giderilmesi amacıyla kullanılan yapay sinir hücresidir ve değeri 1 olarak kullanılır (Şekil 1.13).




Şekil 1. 13. Yapay sinir hücresi işlevi ve eşik değer (bias) gösterimi.

Net girdi fonksiyonunun toplam fonksiyonu olması halinde, eşik değerin dahil edilmesi (1.41) bağıntısı ile gösterilmektedir.

$$NET = \sum_{i=1}^n x_i w_i + b_i \quad i = 1, 2, \dots, n \quad (1.41)$$

Başka bir ifadeyle, giriş sinyalleri toplamı sıfır olduğunda öğrenme gerçekleşmez, çıkış değeri hep 1 olan bias nöronları giriş sinyallerinin sürekli sıfırdan farklı olmasını sağlayan bir değerdir. Bias, öğrenmeyi hızlandırırken yerel optimum değerlere takılmayı güçleştirilir.

Aktivasyon (transfer) fonksiyonu: Net girdi değerlerini net çıktı değerine dönüştüren aktivasyon fonksiyonu, doğrusal ya da doğrusal olmayan fonksiyon olabilir. Uygulamalarda kullanılan bazı aktivasyon fonksiyonları Şekil 1.14'de verilmektedir.



Şekil 1. 14. Aktivasyon fonksiyonu çeşitleri ve gösterimi.

Adım fonksiyonu: Belirlenen bir eşik değeri için net çıktıları oluşturarak adım fonksiyonu genellikle sınıflandırma problemlerinde ve doğru-yanlış sonuçlarının araştırıldığı uygulamalarda kullanılmaktadır. Adım fonksiyonunun matematiksel ifadesi (1.42) bağıntısı ile verilmiştir.

$$f(net_j) = \begin{cases} \delta : net_j < \theta \\ \beta : net_j > \theta \end{cases} \quad (1.42)$$

Sigmoid fonksiyonu: Mühendislik problemlerinin çözümünde sıklıkla kullanılan sigmoid fonksiyonu, 0 ile 1 arasında net çıktıları üretir. Fonksiyonun diğer özellikleri ise monotonik, artan, sürekli ve doğrusal olmamasıdır. Sigmoid fonksiyonu (1.43) bağıntısı ile verilmiştir.

$$f(net_j) = \frac{1}{1 + e^{-net_j}} \quad (1.43)$$

Hiperbolik tanjant fonksiyonu: Sigmoid fonksiyon ile aynı özelliklere sahip bu fonksiyonun sigmoid fonksiyonundan farkı -1 ile +1 aralığında net çıktıları üretmesidir. Hiperbolik tanjant fonksiyonunun matematiksel ifadesi (1.44) bağıntısı ile verilmiştir.

$$f(net_j) = \frac{e^{net_j} - e^{-net_j}}{e^{net_j} + e^{-net_j}} \quad (1.44)$$

Çıktı (y_i): Yapay sinir hücrelerinde hesaplanan çıktı değerlerini içermektedir.

İyi bir YSA minimum hataya sahip olmalıdır. İyi bir öğrenme fonksiyonu YSA'nın hatalarını minimuma taşımaktadır. YSA'ların eğitim verileri ile uyumu ve sonuçlarının gerçek verilerle olan ilişkileri hata fonksiyonlarıyla ölçülmektedir. En sık kullanılan hata fonksiyonları (1.45-48) bağıntılarıyla, korelasyon (R) ve determinasyon (R^2) katsayıları ise (1.49) ve (1.50) bağıntılarıyla tanımlanmaktadır:

Ortalama Kare Hata (MSE);

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (1.45)$$

Kök Ortalama Kare Hata (RMSE);

$$RMSE = \sqrt{MSE} \quad (1.46)$$

Ortalama Mutlak Hata (MAE);

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (1.47)$$

Ortalama Mutlak Yüzde Hata (MAPE);

$$MAPE = 100 \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}}{n} \quad (1.48)$$

Korelasyon Katsayısı (R);

$$R = \frac{n \sum x_i y_i - \sum x_i \sum y_i}{\sqrt{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} * \sqrt{n \sum_{i=1}^n y_i^2 - (\sum_{i=1}^n y_i)^2}} \quad (1.49)$$

Determinasyon Katsayısı (R^2);

$$R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (1.50)$$

Bu denklemlerde x_i ve y_i , verileri; $\hat{y}_i$, tahmin değerlerini; $\bar{y}_i$, gözlenen verinin ortalamasını ve n, veri sayısını ifade etmektedir. Ortalama Kare Hata (MSE) pozitif değerlidir ve sıfıra yakın değerler değişkenlerin daha iyi uyum gösterdiği anlamına gelmektedir. Kök Ortalama Kare Hata (RMSE) değerleri sıfırdan büyük değerler alırlar ve düşük RMSE değerleri daha iyi uyum anlamına gelmektedir. Ortalama Mutlak Hata (MAE) değerleri sıfırdan büyük değerler alır ve düşük MAE değerleri sonuçların daha iyi olduğu göstermektedir. Ortalama Mutlak Yüzde Hata (MAPE) tahmin edilen değerler ile gerçek değerler arasındaki hata değerlerini yüzdelik olarak tanımlamaktadır. Korelasyon katsayısı değeri $R=1$ ise x ve y arasında çok kuvvetli pozitif, $R = -1$ ise x ve y çok kuvvetli negatif korelasyon ilişkisi olduğu anlamına gelmektedir. $R < 0.5$ ise değişkenler arasında zayıf bir ilişki olduğunu ifade eder. Determinasyon Katsayısı (R^2) tahmin değerlerinin gerçek veri değerlerine ne kadar yaklaştığını tanımlar ve $R^2 = 1$ olması durumunda tahmin değeri ile gerçek değer arasında mükemmel bir uyum olduğunu göstermektedir.

YSA'nın yapısı girdi, gizli ve çıktı katmanlarından oluşmaktadır. YSA'da her katmanda bulunan yapay sinir hücreleri (nöron), bir sonraki katmanda bulunan tüm yapay sinir hücrelerine bilgiyi taşıyan ağırlık katsayıları ile paralel olarak bağlanmaktadır. Girdi ve çıktı katmanında olaya veya probleme ait veriler bulunmaktadır. Bu nedenle girdi ve çıktı katmanındaki sinir hücrelerinin sayıları problemde tanımlanan bilgilere bağlıdır. Gizli katmanda, yapay sinir hücrelerinin sayısı ve kaç adet gizli katman kullanılacağı deneme yanılma yolu ile probleme bağlı olarak belirlenmektedir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir. YSA'lar temel olarak;

- İleri beslemeli YSA
- Geri beslemeli YSA olmak üzere iki gruba,

Öğrenme Stratejilerine göre ise;

- Danışmanlı Öğrenme

- Danışmansız Öğrenme
- Takviyeli Öğrenme
- Karma Stratejiler olmak üzere dört gruba ayrılmaktadırlar.

YSA'lar gelişen bilgisayar teknoloji sayesinde birçok alandaki karmaşık problemlerin çözümde etkili ve daha doğru sonuçlar vermesinden dolayı gelecekte daha fazla uygulama alanına sahip olacaktır.

1.5.3. Meta-Sezgisel Algoritmalar

YZ optimizasyonu kullanılarak problem çözümlerini oluşturmak için iteratif- döngüsel çözüm, rastgele yürüyüş, sezgisellik veya meta-sezgisellik ve çözüm uzayı düzenlemeleri gibi bazı temel yaklaşımlar kullanılmaktadır.

İnsanlar yaşamları boyunca karar verme süreçlerinde izlediği genel olarak yollardan birisi de sezgilerini kullanmaktır. Bu yaklaşıma benzer olarak optimizasyonla problemlerin çözümlerinde sezgisel yaklaşımlar sıklıkla uygulanmaktadır. Buradaki sezgisel yaklaşımı, çözümün nerede bulunacağından emin olmamakla birlikte, çözüm nesnelerinin algoritma içi yapılarından güç almak suretiyle, kısıtlı mantıksal ve matematiksel bileşenlerle birlikte, çözümün bulunmasının garanti olmadığı şartlar altında çözüme yaklaşım sağlamak olarak tanımlanabilir (Weise, 2021; Karaboğa, 2014). Sezgisel yaklaşımın, mantıksal yönünün yanında matematiksel karşılığı da rastgele yürüyüş teorisi ile gerçekleştirilebilmektedir. Diğer yandan, yerel optimumlara yakalanma gibi sorunlardan kurtulabilen, daha karmaşık optimizasyon problemlerinin çözümü noktasında, sezgisel yaklaşımından daha etkili olan meta-sezgisellik, zeki optimizasyonun temel yaklaşımlarından birisi olarak belirtilmiştir. (Gendreau ve Potvin, 2010; Yang, 2010).

Meta-Sezgisel algoritmalar doğada gözlemlenen süreçleri ya da olayları taklit ederek arama ve geliştirme yapan tekniklerdir. Diğer bir ifadeyle, Meta-Sezgisel algoritmalar canlıların yaşama, üreme ve beslenme gibi davranış biçimlerinden esinlenerek geliştirilmiş popülasyon temelli optimizasyon algoritmalarıdır. Bunlar; biyolojik tabanlı, fizik tabanlı, sürü tabanlı, kimya tabanlı, evrimsel tabanlı olmaktadır (Mange ve Tomassini, 1998; Bonabeau vd., 1999; Boettcher ve Percus, 2000; Marrow, 2000; Shadbolt, 2004; Yang, 2010; Fogel, 2006; Karaboğa, 2014; Köse, 2015).

Meta-Sezgisel algoritmelerde amaç, optimizasyon kısıtlarını sağlayacak şekilde fonksiyonun minimum veya maksimum değerlerini veren deęişkenlerin en ideallerinin bulunmasıdır. Başlıca meta-sezgisel algoritmalar;

- Parçacık sürü optimizasyon algoritması (PSO)
- Öğretme-öğrenme temelli optimizasyon algoritması (TLBO)
- Genetik Algoritma (GA)
- Yapay arı kolonisi (ABC)
- Karınca kolonisi algoritması (ACO)
- Simbiyotik organizma arama algoritması (SOS)
- Yerçekimi arama algoritması (GSA)
- Diferansiyel Gelişim Algoritması (DE)


Yukarıda bahsedilen başlıca meta-sezgisel algoritmalar gün geçtikçe gelişmekte ve farklı problemlerin çözümleri için uygulanan yeni algoritmalar oluşturulmaktadır. Bu tez kapsamında PSO ve TLBO algoritmaları hesaplamalarda kullanılmıştır.

2. TÜRKİYE’NİN TEKTONİĞİ VE DEPREMSELLİĞİ

2.1. Türkiye’nin Tektoniği


Türkiye, Alp-Himalaya orojenik (Batı-Doğu uzanımlı) sistemin içerisinde Akdeniz bölgesinde yer almaktadır (Şekil 2.1). Tektonik hareketin kaynağı, Afrika, Ege, Arap, Anadolu, Avrasya ve Hazar plakalarının göreceli hareketlerin sonucunda oluşmaktadır (Mckenzie, 1978; Le Pichon ve Angelier, 1979; Burke ve Şengör, 1986; McClusky vd., 2000; Reilinger vd., 2006, 2010). Bu sistemde Alp orojenezi, Avrupa ile Asya plakalarının arasındaki sıkışma, Himalaya orojenezi de Asya ile Hindistan plakalarının çarpışması sonucu oluşmuştur.

Kuzeyinde Avrasya, güneyinde Arap ve Afrika plakaları ile doğusunda Doğu Anadolu ve batısında Ege bloğunun yer aldığı Türkiye, plakalar arası çarpışma, açılma, yitim gibi kompleks tektonik hareket oluşumlarını barındırmaktadır. Bu levhalardan Afrika levhası, Türkiye’nin güneybatı kısmından Ege ve Kıbrıs yayı altına dalmaktadır (Mckenzie, 1978; Le Pichon ve Angelier, 1979; McClusky vd., 2000). Arap ve Avrasya plakaları ise Türkiyenin doğusunda Bitlis-Zagros bindirme zonunda çarpışarak, kabukta deformasyona ve kalınlaşmaya neden olmaktadır (Dewey vd., 1986; Reilinger vd., 2006). Bu hareketler sonucu Türkiye’nin en önemli tektonik yapıları olan sağ yönlü doğrultu atımlı Kuzey Anadolu Fay Zonu (KAFZ) ve sol yönlü doğrultu atımlı Doğu Anadolu Fayı Zonu (DAFZ) oluşmuştur (Mckenzie, 1976; Şengör, 1979; Dewey vd., 1986; Barka, 1992; Bozkurt, 2001; Le Pichon vd. 2003; Şengör vd., 2005; Özener vd., 2010; Yönlü vd., 2017). Ayrıca, bu iki transform fay zonu boyunca batıya doğru kaçış hareketi yapan Anadolu plakası Ege (Helen) yayı nedeniyle genişlemiş ve Ege Graben sistemini meydana getirmiştir (Seyitoğlu ve Scott, 1991; Şaroğlu vd., 1992; Taymaz ve Price 1992; Westaway, 1993; Bozkurt, 2003; Bozkurt ve Sözbilir, 2006).



Şekil 2. 1 Türkiye'nin levha hareketleri ve temel tektonik yapıları (KAFZ, Kuzey Anadolu Fay Zonu; DAFZ, Doğu Anadolu Fay Zonu; KDAFZ, Kuzeydoğu Anadolu Fay Zonu; ÖDFZ, Ölü Deniz Fay Zonu; TGF, Tuz Gölü Fay Zonu; AS, Apşeron Sil; ASM, Anaximander deniz dağları; BF, Bozova Fault; BGF, Beyşehir Gölü Fayı; BMG, Büyük Menderes Grabeni; BuF, Burdur Fayı; CTF, Cephalonia Transform Fayı; DF, Deliler Fayı; EcF, Ecemiş Fayı; EF, Elbistan Fayı; EPF, Ezine Pazarı Fayı; ErF, Erciyes Fayı; ESM, Eratosthenes deniz dağları, G Gökova; Ge, Gediz Grabeni; GF, Gami Fayı; IF, Iğdır Fayı; KBF, Kavakbaşı Fayı; KF, Kağızman Fayı; KFZ, Karataş-Osmaniye Fay Zonu; MF, Malatya Fayı; MT, Muş fayı; OF, Ovacık Fayı; PSF, Pampak-Savan Fayı; PTF, Paphos Transform Fayı; RB, Rodos Baseni; SaF, Salmas Fayı; Si, Simav Grabeni; SuF, Sultandağı Fayı; TeF, Tebriz Fayı; TF, Tatarlı Fayı ifade etmektedir. Yolsal ve Taymaz 2010'dan değiştirilerek alınmıştır).


Türkiye, neotektonik özellikleri bakımından dört farklı bölge olarak sınıflandırılmıştır. Bunlar; Kuzey Anadolu bölgesi, Doğu Anadolu daralma bölgesi, Orta Anadolu bölgesi ve Batı Anadolu bölgesidir. Türkiye'nin genel tektonik yapıları Şekil 2.2' de detaylı olarak verilmiştir. Tektonik anlamda ülkemizde bulunan önemli yapılar; KAFZ, DAFZ, Batı Anadolu Graben Sistemi, Ege Yayı, Bitlis-Zagros Bindirme Zonu (Kenet Kuşağı).



Şekil 2. 2. Türkiye ve civarının temel tektonik yapıları ve neotektonik bölgeleri (KAFZ, Kuzey Anadolu Fay Zonu; DAFZ, Doğu Anadolu Fay Zonu; KDAFZ, Kuzeydoğu Anadolu Fay Zonu; ÖDFZ, Ölü Deniz Fay Zonu; TZ, Tuz Gölü Fay Zonu; EY, Ege Yayı; KY, Kıbrıs Yayı ifade etmektedir. Kürçer ve Gökten 2014'den değiştirilerek alınmıştır).

Afrika ve Avrasya plakalarının bu göreceli hareketleri sonucunda, Türkiye'nin iç kesimlerinde deformasyona neden olmakta ve bunun yanı sıra Anadolu plakası batıya doğru bir kaçış hareketi gerçekleştirmektedir (Dewey vd., 1986; Burke ve Şengör, 1986; Koçyiğit ve Beyhan, 1998). Yapılan jeodezik gözlemler sonucunda, Anadolu ve çevresinin Avrasya plakasına göre saat yönü tersine bir hareket mekanizması göstermektedir (McClusky vd., 2000; Aktuğ vd., 2013). Anadolu ve Ege plakalarının Avrasya plakasına göre hareketi batı-kuzey batı yönünde sırasıyla 21 mm/yıl ve 33 mm/yıl, kuzey-kuzey batı yönlü hareket eden Arap ve Afrika plakalarının hareketi ise sırasıyla 15 mm/yıl ve 5 mm/yıl olarak hesaplamıştır (Reilinger vd., 2006). KAFZ ise Anadolu ve Avrasya levhaları arasında, Anadolu levhasının

kuzey sınırı boyunca jeodezik çalışmalara göre 24 mm/yıl kadar göreceli bir hareket mekanizmasına sahiptir (McClusky vd., 2000; Reilinger vd., 2006). Anadolu ve Afrika plakaları ile Arap plakası arasındaki hareket sonucunda oluşan DAFZ ve Ölü Deniz Fayı Zonu'nun (ÖDFZ) yaklaşık olarak sırasıyla 10 mm/yıl ve 4 mm/yıl sol yönlü göreceli hareketleri saptanmıştır (Reilinger vd., 2006). Jeodezik ölçümler sonucu levha hareket (kayma) miktarını gösteren GPS hızları Şekil 2.3'de verilmiştir.



Şekil 2. 3. Jeodezik ölçümler sonucu levha hareketlerine göre GPS hızları (Reilinger vd., 2006'dan değiştirilerek alınmıştır).

2.1.1. Kuzey Anadolu Fay Zonu (KAFZ)

Ketin (1957), Kuzey Anadolu Fay Zonunu (KAFZ) ilk önce Kuzey Anadolu Deprem Fayı olarak adlandırmıştır. Daha sonraki yıllarda Ketin (1976), Kaliforniya'daki San Andreas Fayı ile KAFZ'ı karşılaştırmıştır. KAFZ doğuda Karlıova'dan, batıda Saros körfezine kadar uzanan yaklaşık olarak 1500 km uzunlukta sağ yanal yönlü hareket gösteren bir fay zonudur (sistemidir). KAFZ, Karlıova civarında sol yönlü DAFZ ile birleşmektedir ve bu nokta Karlıova üçlü birleşme noktası (KB) olarak adlandırılmaktadır. KAFZ, Karlıova civarında net olarak gözlenememektedir fakat Karlıova'dan Erzincan'a kadar fay zone üzerinde süreklilik belirlenebilmektedir. Devam eden bölgede, Erbaa ile Reşadiye arasında sürekliliğini tekrar kaybetmiştir. KAFZ, Mudurnu civarında iki ana kola ayrılmaktadır,

kuzey kolu İzmit-Sapanca gölü içinden geçer ve devamında Marmara denizini girer. Marmara denizinde karmaşık bir yapı gösterir ve deniz tabanından birkaç yüz metre yüksekliğe erişen sırtları (Çınarcık Çukuru) ve Tekirdağ havzası gibi derin deniz fay havzalarını oluşturmaktadır. Marmara denizinin batısında Trakya civarında yüzeye çıkarak Ganos Fayıyla devam eden fay zonu Saros körfezine ulaşmaktadır. KAFZ boyunca bu fay parçalarının kırılması sonucunda farklı büyüklüklerde depremler meydana gelmiştir.

2.1.2. Doğu Anadolu Fay Zonu (DAFZ)

DAFZ, sol yönlü doğrultu atımlı yaklaşık 600 km uzunlukta 30 km genişliğinde kuzeydoğu yönünde ilerleyen birbirine paralel şekilde dizilmiş eğik fay segmentlerinden oluşan bir fay zonudur (sistemidir). DAFZ, Arap ve Afrika plakaları ile Anadolu ve Avrasya plakaları arasındaki sınır boyunca oluşan transform bir fay özelliğine sahiptir. Bu fay zonu boyunca 50 km ile 145 km arasında farklı uzunlukta 6 farklı segment tanımlanmıştır. Bunlar; Karlıova ile Bingöl arasında Karlıova-Bingöl segmenti (~ 65 km), Palu ile Hazar Gölü arasında Palu – Hazar Gölü segmenti (~ 50 km), Hazar Gölü ile Sincik arasında Hazar-Sincik segmenti (~ 85 km), Çelikhan ile Gölbaşı arasında Çelikhan-Gölbaşı segmenti (~ 50 km), Gölbaşı ile Türkoğlu arasında Gölbaşı-Türkoğlu segmenti (~ 90 km) ve Türkoğlu ile Antakya arasında (~ 145 km) Türkoğlu-Antakya segmentidir (Şaroğlu vd., 1992; Aksoy vd., 2007). DAFZ'ın Karlıova ile Ermenistan arasında yaklaşık 350 km uzunluğundaki kalan bölümü Kuzeydoğu Anadolu Fay Zonu (KDFAZ) olarak adlandırılmaktadır. Bu fay Erzurum'dan Kafkas dağlarına kadar uzanmaktadır ve sol yönlü hareket mekanizmasına sahiptir.


2.1.3. Diğer Tektonik Yapılar

Sismik aktivitenin en yoğun olduğu tektonik yapılardan biri de Ege (Batı Anadolu) Graben sistemidir. Bu sistemin en belirgin özelliklerinden biri doğu-batı yönlü yayılım gösteren grabenler (Bakırçay, Kütahya, Simav, Gediz, Küçük Menderes, Büyük Menderes ve Gökova grabenleri) ve bu havza sınırlarında gözlenen normal faylardır (Seyitoğlu ve Scott, 1991; Şaroğlu vd., 1992; Taymaz ve Price, 1992; Westaway, 1993; Bozkurt, 2003; Bozkurt ve Sözbilir, 2006). Bu graben sisteminin kuzeyi Edremit Körfezi civarı KAFZ ile Batı Anadolu' daki çekme rejiminin etkisi altındadır. Karmaşık bir tektonik yapıya sahip olmasından dolayı bu bölgenin deprem oluşturma potansiyeli yüksektir.

Türkiye için diğer önemli bir tektonik yapı ise zonu Arap ve Avrasya plakaları çarpışması sonucu meydana gelen Bitlis-Zagros Bindirme Zonudur (Kenet Kuşağı). Bu fay zonu plaka sınırları boyunca oluşmuş bindirme ve kıvrılma yapılarını içermektedir (Şengör ve Kidd, 1979). Bu fay zonu Türkiye'nin güneydoğusundan başlayıp İran'daki Zagros dağlarına kadar uzanan, karmaşık kıta-okyanus ve kıta-kıta çarpışma sınırıdır. Türkiye sınırları içerisinde, Kahramanmaraş ile Yüksekova arasında güneye yönelmiş ters faylanmalardan oluşmaktadır.

Bu tektonik yapılar tarafından çevrelenen ve etkisi altında olan Orta Anadolu Bölgesi, kıtasal litosferin deformasyona uğradığı ve gerilmelerin olduğu yapıları içeren bir bölgedir. Bu yapılardan en önemlisi yaklaşık 200 km uzunlukta olan Tuz gölü Fay Zonudur (TGZ). Diğer bölgelere göre daha az depremselliğe sahip olmasına rağmen düşüğe olsa deprem üretme potansiyeline sahip bir bölgedir.

Bu tektonik yapıların yanında, Türkiye civarında deprem potansiyeli yüksek tektonik yapılarda mevcuttur. Bunlardan biri, yaklaşık 1000 km uzunlukta sol yönlü doğrultu atımlı özelliğine sahip ÖDFZ, diğerleri ise Afrika ve Anadolu levhaları arasındaki hareket sonucunda oluşan Ege (Helen) yayı (EY) ve Kıbrıs yaylarıdır (KY). EY, Ege bölgesi üzerinde ve bu yayın devamı niteliğindeki KY ise Akdeniz bölgesi üzerinde deprem tehlikesini artırmaktadır. Bu tektonik yaylar üzerinde meydana gelebilecek bir depremin Ege ve Akdeniz bölgelerini etkileme potansiyeli yüksektir.




Şekil 2. 4. 1976-2010 yılları arasında meydana gelen depremlerin ($M_w \geq 4.0$) fay düzlemi çözümleri (Veriler Türkiye ve çevresi faylanma-kaynak parametreleri moment tensör kataloğu (Kalafat vd., 2009) ile GCMT-Harvard kataloğundan derlenmiş ve Yalçın vd., 2013'den değiştirilerek alınmıştır).

Türkiye’deki tektonik yapıların sıkışma, açılma ve doğrultu atımlı faylanma rejimlerini, bu bölgelerde oluşan depremlerin fay düzlemi çözümlemeleri de doğrulamaktadır (Şekil 2.4).


2.2. Türkiye’nin Depremselliği

Türkiye’nin tarihsel (1900 yılı öncesi) ve aletsel (1900 yılı sonrası) dönem depremselliği incelediğinde, yukarıda tanımlanan tektonik yapılardan kaynaklı yoğun aktivite sahip olduğu ve büyük yıkıcı depremler meydana geldiği gözlenmektedir. Tarihsel dönemde Türkiye’de meydana gelen büyük depremler Şekil 2.5’de gösterilmiştir.



Şekil 2. 5. MS 17-1900 yılları arası Anadolu’da meydana gelmiş büyük ($M \geq 7.0$) depremler. Tektonik harita Şaroğlu vd. (1992)’den alınmıştır.

Aletsel dönemde Türkiye’de meydana gelmiş en büyük deprem 1939 Erzincan ($M=7.9$) depremidir. Yine bu dönemde KAFZ, DAFZ, Batı Anadolu ve Van Gölü civarında yıkıcı etkiye sahip büyük ($M \geq 7.0$), 9 Ağustos 1912 Tekirdağ ($M=7.3$), 24 Ocak 1916 Tokat ($M=7.1$), 20 Aralık 1942 Erbaa-Niksar ($M=7.0$), 26 Kasım 1943 Samsun - Ladik ($M=7.2$), 1 Şubat 1944 Bolu-Gerede ($M=7.2$), 6 Ekim 1964 Balıkesir ($M=7.0$), 28 Mart 1970 Kütahya ($M=7.2$), 24 Kasım 1976 Van ($M=7.5$), 17 Ağustos 1999 Kocaeli ($M=7.4$), 12 Kasım 1999 ($M=7.2$) Düzce, 23 Ekim 2011 Van ($M=7.2$) depremleri meydana gelmiştir. Büyük depremlerin yanı sıra kuvvetli ($M \geq 6.0$) depremler de ülkemizde yıkıcı etkiler yaratmıştır. Özellikle, 2020 yılı içerisinde yaşanan 24 Ocak Elazığ-Sivrice ($M=6.7$) ve 30 Ekim İzmir açıklarındaki Sisam adası ($M=6.9$) depremleri can ve mal kayıplarına neden olmuştur. Türkiye ve civarında 1900 ile 2020 yılları arasında meydana gelmiş kuvvetli kuvvetli ($M \geq 6.0$) ve büyük ($M \geq 7.0$) depremlerin dağılımı Şekil 2.6’da verilmiştir.



Şekil 2. 6. Türkiye ve civarında 1900 ile 2020 yılları arasında meydana gelmiş kuvvetli ($M \geq 6.0$) ve büyük ($M \geq 7.0$) depremlerin dağılımı (Depremlerin konumları KRDAE-BTİM kataloglarından alınmıştır URL-2, 2020).

3. YÖNTEM

3.1. Regresyon Yöntemleri

Regresyon genel olarak, iki veya daha çok değişken arasındaki ilişkiyi tanımlayarak, buradan sonuç değerlerinin hesaplanmasını sağlayan istatistiksel bir yöntem olarak ifade edilmektedir. Regresyon yöntemleri sayesinde değişkenler arasında bir ilişki olup olmadığı, varsa bu ilişkinin anlamlılığı ve derecesi belirlenebilmektedir. Bir bağımsız değişken x ile bağımlı değişken y arasındaki ilişkinin tanımlandığı regresyon yöntemine tek değişkenli regresyon, birden çok bağımsız değişken kullanıldığında ise yöntem çok değişkenli regresyon olarak tanımlanmaktadır.

Bir bağımlı değişken (y) ile bir bağımsız değişken (x) arasındaki tek değişkenli basit regresyon denklemi (3.1) bağıntısıyla verilmektedir.

$$y = b_0 + b_1x + e \quad (3.1)$$


Burada y , bağımlı değişken; x , bağımsız değişken; b_0 , regresyon sabiti; b_1 , regresyon katsayısı ve e , rastgele hata olarak ifade edilir.

Bir bağımlı değişken (y) ile birden çok bağımsız değişken (x_i) arasındaki çok değişkenli regresyon denklemi aşağıdaki gibi tanımlanmıştır.

$$y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n + e \quad i = 1, 2, \dots, n \quad (3.2)$$

Burada y , bağımlı değişken; x , bağımsız değişken; b_0 , regresyon sabiti; b , regresyon katsayısı; n , bağımsız değişken sayısı ve e , rastgele hata olarak ifade edilir.

İncelenen verileri temsil edebilecek en uygun doğruyu bulmak için genellikle en küçük kareler (EKK) ve ortogonal regresyon (OR) yöntemleri tercih edilmektedir. EKK yönteminde, oluşturulan uyum eğrisi üzerindeki regresyon $\hat{y}_i$ değerleri ile gözlemsel y_i değerleri arasındaki düşey uzunlukların kareleri toplamının minimum yapılması hedeflenir (Ludbrook, 2010). Ortogonal regresyon yönteminde ise, oluşturulan uyum eğrisine olan dik (ortogonal) uzaklıkların minimum yapılması hedeflenir (Şekil 3.1).



Şekil 3. 1. **a)** En küçük kareler yöntemi, **b)** Ortogonal regresyon yöntemi.

En küçük kareler EKK yönteminde; (3.1) bağıntısındaki b_0 ve b_1 katsayılarını hesaplamak için (3.3) bağıntısında verildiği gibi EKK koşulunu sağlayacak şekilde, gözlemsel y_i değerleri ile beklenen $\hat{y}_i$ değerleri arasındaki hataların (farkların) kareleri toplamı minimum yapılır.

$$\min \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.3)$$

b_0 ve b_1 katsayılarını hesaplamak için (3.1) bağıntısının $\widehat{b}_0$ ve $\widehat{b}_1$ göre kısmi türevi alınıp sıfıra eşitlenir.

$$\sum_{i=1}^n (y_i - (\widehat{b}_0 + \widehat{b}_1 x_i))^2 = L \quad (3.4)$$

$$\sum_{i=1}^n y_i = \widehat{b}_0 n + \widehat{b}_1 \sum_{i=1}^n x_i \quad (3.5)$$

$$\sum_{i=1}^n x_i y_i = \widehat{b}_0 \sum_{i=1}^n x_i + \widehat{b}_1 \sum_{i=1}^n x_i^2 \quad (3.6)$$

Buradan $\widehat{b}_0$ ve $\widehat{b}_1$ katsayıları (3.7) ve (3.8) bağıntılarından hesaplanabilmektedir.

$$\hat{b}_1 = \frac{n[\sum_{i=1}^n x_i y_i] - (\sum_{i=1}^n x_i)(\sum_{i=1}^n y_i)}{n(\sum_{i=1}^n x_i^2) - (\sum_{i=1}^n x_i)^2} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3.7)$$

$$\hat{b}_0 = \frac{\sum_{i=1}^n y_i + \hat{b}_1 \sum_{i=1}^n x_i}{n} = \bar{y} - \hat{b}_1 \bar{x} \quad (3.8)$$

Ortogonal regresyon OR yöntemi; regresyon yöntemleri içerisinde kullanılan diğer bir hesaplama yöntemidir (Carroll ve Ruppert, 1996; Carr, 2012). Bu yöntemde (3.9) ve (3.10) bağıntılarıyla tanımlanan bağımlı (y) ve bağımsız (x) değişkenleriyle ilişkili oluşan hatalar (Syy, Sxx) da yapılan hesaplamalara (3.11) ve (3.12) bağıntılarıyla verilen OR katsayılarının (a ve b) daha güvenli biçimde elde edilmektedir.

$$Sxx = \sum_{i=1}^n (x_i - \bar{x})^2 \quad (3.9)$$

$$Syy = \sum_{i=1}^n (y_i - \bar{y})^2 \quad (3.10)$$

$$b = \frac{(Syy - \eta Sxx) + \sqrt{Syy - \eta Sxx^2 + 4\eta Sxy^2}}{2Sxy} \quad (3.11)$$

$$a = \bar{y} - b\bar{x} \quad (3.12)$$

Burada $\bar{x}$ ve $\bar{y}$, değişkenlerin ortalama değerleridir. Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi temsil eden eta (η) parametresinin belirlenmesi zordur ve bu tez kapsamında $\eta = 1$ olarak alınmıştır. Başka bir değişle, hata payının değişkenler arasında eşit dağıldığı varsayılmıştır. Bu yöntem farklı deprem parametreleri ve veri grupları üzerinde kullanılmıştır (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Öztürk, 2012; Kadirioğlu ve Kartal, 2016; Tang vd., 2016; Öztürk vd., 2020). Bu tez kapsamında, magnitüd dönüşüm denklemlerinin oluşturulması aşamasında da bu yöntemler Statgraph, (2005) yazılımı yardımıyla uygulanmıştır.

3.2. Makine Öğrenme Yöntemlerinde Kullanılan Algoritmalar

YZ' nın bir alt dalı olarak değerlendirilen makine öğrenme yöntemleri uygulamada çeşitli algoritmaları içermektedir. Bu algoritmalar, karmaşık veri kümelerinin analiz edilmesine ve anlamlı ilişkiler türetmesine yardımcı olan kod parçacıklar olarak tanımlanabilir. Her algoritma, belirli bir hedefi öğrenmesi için izleyebileceği adımları ve sınırları belirten yönergeleri içermektedir. Bu algoritmalar yardımıyla kullanılan verilerle tahmin yapma ve verileri kategorilere ayırma işlemleri yapılmaktadır. Makine öğrenme algoritmalarını genel olarak denetimli ve denetimsiz olmak üzere iki başlığa ayırabiliriz. Denetimli öğrenme yöntemi regresyon ve sınıflandırma algoritmalarıyla tahmin problemlerinde, denetimsiz öğrenme ise kümeleme algoritmalarıyla verilerin ayrılmasında kullanılmaktadır. Makine öğrenmesi hakkında genel bilgiler bölüm 1.5.1' de detaylı olarak verilmiştir.

Bu tez kapsamında makine öğrenmesinin denetimli öğrenme kategorisinde yer alan regresyon algoritmaları kullanılmış ve Matlab yardımıyla uygulanmıştır. Bu algoritmalar;

- Lineer regresyon modelleri,
- Regresyon karar ağaçları,
- Topluluk ağaçları
- Destek vektör makineleri,
- Gauss süreci regresyon modelleridir.


Lineer regresyon modelleri; uygulamada kendi içerisinde basit lineer, etkileşimli (interactions), sağlam (robust) ve adım sal (stepwise) regresyon yöntemleri olarak uygulamada ayrılmaktadır. Basit lineer (doğrusal) regresyon yöntemi bölüm 3.1' de detaylı olarak anlatılmıştır. Etkileşimli regresyon modeli ise değişkenler arasındaki etkileşimin de göz önüne alınarak modellerin oluşturulması şeklinde tanımlanmaktadır. Örnek olarak, (3.13) bağıntısıyla verilen iki değişken (x_1 ve x_2) arasındaki çarpım, değişkenlerin etkileşimi olarak tanımlanabilir.

$$y = b_0 + b_1x_1 + b_2x_2 + b_3x_1x_2 \dots b_ix_i + e \quad i = 1, 2, \dots, n \quad (3.13)$$

Sağlam lineer regresyon yöntem, veri setindeki değerlerin homojen dağılmamasından kaynaklanan ve doğrusallıktan sapan değerlerin etkisini azaltarak daha güvenli sonuçlara ulaşılmasını amaçlar. Başka bir deyişle, yüksek hata oranlarının etkisinin azaltılması olarak

tanımlanmaktadır. Adımsal regresyon yönteminde ise, değişkenlerin hangi sırayla modele gireceğine matematiksel bir kritere göre karar verilerek model oluşturulmaktadır. Bu yöntem iki aşamalı olarak uygulanabilmektedir; değişkenler sırayla modele eklenerek ileri (forward) veya tüm değişkenler modele verilip, sonrasında kritere uymayanlar çıkarılarak geriye doğru (backward) olarak yapılmaktadır. Bu aşamalara göre modelin anlamlılığına karar verilmektedir.


Regresyon karar ağaçları modeli; parametrik olmayan istatistiksel bir öğrenme yöntemi olarak tanımlanmaktadır (Breiman vd., 1984). Karar ağaçları algoritmaları, kural çıkarma üzerine kurulu ve bir dizi mantıksal testin birleşiminden oluşan, sıralı modeller içeren güvenilir bir yöntemdir. Regresyon veya sınıflandırma problemleri için verilen eğitim setinde bir tane bağımlı niteliğin diğer belirleyici niteliklere göre çözümlerini üretir. Karar ağaçları hiyerarşik bir düzende kök, dal ve yaprak olmak üzere üç ana yapıdan oluşmaktadır ve bu yapıda her bir adım karar düğümü olarak tanımlanmaktadır (Şekil 3.2). Yaprığın en üst kısmı kök, kök ile yaprak arasındaki kısım ise dal olarak belirtilmiştir. Bir karar ağacı yapısındaki her düğüm, örnekteki bir özelliği temsil eder ve her dal ise, düğümün üstlenebileceği bir değeri göstermektedir. İşlemler kök düğümünden başlar ve özellik değerlerine göre hiyerarşik bir yapıda sıralanmaktadır (Kotsiantis, 2013). Karar alma yöntemine bakıldığında, tepeden aşağıya doğru inen iç içe geçmiş “eğer-ise” kurallarına dayanan bir stratejiyi içerdiği görülmektedir.



Şekil 3. 2. **a)** Karar ağaçları yapısı, **b)** Karar ağaçlarının 2-boyutlu gösterimi (Kavzaoglu ve Çölkesen, 2010’dan değiştirilerek alınmıştır).

Regresyon problemleri için kullanılan karar ağaçları algoritmaları kendi içinde genellikle basit (fine), orta (medium) ve kaba (coarse) karar ağaçları olarak ayrılmaktadır ve tez kapsamında bu üç yöntem kullanılmıştır.

Topluluk ağaçları modeli; rastgele (random) orman algoritmaları olarak tanımlanmaktadır. Bu modelde birden çok karar ağacının bir araya gelmesiyle oluşturulan bir ormandan yola çıkarak problemlere çözüm aranmaktadır. Rastlantısal olarak seçilen karar ağaçlarının bir araya gelmesiyle oluşan bütüne karar ormanı denilmektedir. Bu algoritma, torbalama (Bagging) ve yükseltme (Boosting) yaklaşımı olarak iki farklı yaklaşımı içermektedir (Şekil 3.3). Torbalama yönteminde, veri setinden öncelikle rastgele seçimler yapılarak alt örnekler oluşturulmaktadır. Paralel bir şekilde çözüm arayan bu alt örnek ağaçlarının sonuçlarının ortalamalarına göre tahmin değerleri belirlenmektedir. Bu yöntemde aşırı öğrenme problemi azalır ve tekil karar ağacına göre daha güvenilir bir yöntemdir. Yükseltme yönteminde ise, veri setine tek bir alt örnek oluşturulur ve ağırlıklandırma yapılarak karar verilmesi sağlanır. Başlangıçta tüm verilere eşit ağırlıklar verilmektedir. Yanlış sınıfların ağırlıkları artırılarak farklı bir model oluşturulur ve bu hiyerarşik yapıya göre diğer modeller oluşturulmaktadır. Son karar modeli bu modellerin ağırlıklandırılmış ortalamasıdır.




Şekil 3. 3. **a)** Torbalama (Bagging) **b)** Yükseltme (Boosting) orman algoritmaları adımları (Zhang vd., 2018'den değiştirilerek alınmıştır).

Destek vektör makineleri modeli; istatistiksel öğrenme teorisine dayanmakta ve incelenen sınıflar arası ayrımı, oluşturulan optimal ayırma hiper düzlemi sayesinde yapmaktadır (Vapnik, 1995). Algoritmanın temeli, verileri iyi farklı sınıfa ayırmak için en iyi hiper düzlemin oluşturulmasına dayanmaktadır. Bu yöntem doğrusal ve doğrusal olmayan problemlerde kullanılabilir (Şekil 3.4). Doğrusal olarak ayrılabilen veri setleri için (3.14) bağıntısı kullanılmaktadır.

$$F(x) = w^T x + b = \sum_{j=1}^M w_j x_j + b = 0 \quad (3.14)$$

Burada w , M -boyutlu vektörü; b , sabit değeri ifade etmektedir. w vektörü ve b sabiti ayırma hiper düzleminin konumunu tanımlamak için kullanılmaktadır. Destek vektör makineleri, doğrusal olmayan veri setleri için sigmoid, radyal ve polinom tabanlı çekirdek fonksiyonları kullanarak destek vektör makineleri çözüm üretmektedir. Bu model çok sınıflı problemleri bir dizi ikili sınıflandırma problemine indirgemektedir.



Şekil 3. 4 **a)** Doğrusal ve doğrusal olmayan, **b)** Doğrusal hiper düzlem gösterimi, **c)** Gauss, **d)** Kuadratik (Quadratic) destek vektör makineleri örnekleri.

Sınıflama problemleri yanında destek vektör makineleri, regresyon problemlerinde de uygulanmaktadır. Bu tez kapsamında regresyon problemi için lineer, kuadratik ve kübik

destek makineleri ile basit, orta ve kaba gauss destek makineleri Matlab yardımıyla uygulanmıştır.

Gauss regresyon modeli; eğitim verilerindeki bilinmeyen noktaları tahmin etmek için noktalar arasındaki benzerlik ölçüsünü (çekirdeğe dayalı olasılık) kullanan, parametrik olmayan bir yaklaşımdır. Parametrik olmayan özelliği sayesinde bu yöntemle, belirli bir fonksiyona uydurma sınırlamaları dikkate alınmaz ve tüm olası fonksiyonlar için farklı olasılık dağılımları hesaplanabilmektedir. Model, her parametre için belirli değerleri sağlamaz, yalnızca eğitilmiş verileri kullanarak son olasılıkları ve w parametresiyle önceki $p(w)$ dağılımını da hesaplamaktadır. Bu yöntem, hem önceki hem de olasılıkların bir Gauss dağılımını takip ettiğini varsayarak, sağlanan X -test verileriyle f -tahmin dağılımını bulmaktadır.

$$P(w|y, X) = \frac{P(y|X, w)p(w)}{P(y|X)} \quad (3.15)$$

$$\text{Son dağılım} = \frac{\text{Olabilirlik} \times \text{önceki dağılım}}{\text{marjinal olabilirlik}} \quad (3.16)$$

$$P(f|x, y, X) = \int P(f|x, w)P(w|y, X)dw \quad (3.17)$$

Burada $P(w|y, X)$; son dağılım, önceki dağılımdan ve verilen veri setindeki bilgileri içererek güncellenmektedir. Ayrıca x tahmin dağılımını elde etmek için, tüm olası tahminlerin son dağılımları ağırlıklandırılmaktadır. İlk aşamada önceki olasılık, ortalama ve çekirdek (kovaryans) fonksiyonlarıyla oluşturulur.

$$f(x) \sim GP(m(x), k(x, x')) \quad (3.18)$$

Burada $m(x)$, ortalama fonksiyonu; $k(x, x')$, çekirdek (kovaryans) fonksiyonu ifade etmektedir. (3.18) bağıntısına Gauss gürültüsü eklenerek (3.19) bağıntısı oluşturulur.

$$f(x) \sim GP(m(x), k(x, x')) + \delta_{ij}\sigma_n^2 \quad (3.19)$$

Eğitim ve test verilerinin kovaryans matrislerinin oluşturulmasıyla model tahmin denklemi (3.20) bağıntısındaki formu almaktadır.

$$\begin{bmatrix} y \\ f \end{bmatrix} \sim N\left(\begin{bmatrix} \mu \\ \mu_* \end{bmatrix}, \begin{bmatrix} k(X, X) + \sigma_n^2 I & k(X, X_*) \\ k(X_*, X) & k(X_*, X_*) \end{bmatrix}\right) \quad (3.20)$$

Gauss süreci regresyon modelinde, farklı çekirdek kovaryans matrisler kullanılmaktadır. Bu tez kapsamında kullanılan üstel (exponential), kare üstel (squared exponential), rasyonel kuadratik (rational quadratic) ve matern 5/2 çekirdek matrisleri sırasıyla (3.21)-(3.24) bağıntılarında verilmiştir.

$$k(x_i, x_j | \theta) = \sigma_f^2 \exp\left(-\frac{r}{\sigma_l}\right) \quad r = \sqrt{(x_i - x_j)^T (x_i - x_j)} \quad (3.21)$$

$$k(x_i, x_j | \theta) = \sigma_f^2 \exp\left(-\frac{1}{2} \frac{(x_i - x_j)^T (x_i - x_j)}{\sigma_l^2}\right) \quad (3.22)$$

$$k(x_i, x_j | \theta) = \sigma_f^2 \left(1 + \frac{r^2}{2a\sigma_l^2}\right)^{-a} \quad (3.23)$$

$$k(x_i, x_j) = \sigma_f^2 \left(1 + \frac{\sqrt{5}r}{\sigma_l} + \frac{5r^2}{3\sigma_l^2}\right) \exp\left(-\frac{\sqrt{5}r}{\sigma_l}\right) \quad (3.24)$$


Bu bağıntılarda tanımlanan $k(x_i, x_j | \theta)$, çekirdek (kovaryans) fonksiyonunu; σ_l , uzunluk skalasını; σ_f , sinyal standart sapmasını; a , pozitif değerli ölçek parametresini; r , x_i ve x_j arasındaki öklid uzaklığını ifade etmektedir. Yapılan hesaplamalarda bu yöntemler Matlab yardımıyla uygulanmıştır.

3.3. Yapay Sinir Ağları (YSA) ve Meta-sezgisel Algoritmalar

Bu tez kapsamında, ileri beslemeli (feedforward) geri yayılım (back-propagation) eğitim algoritmasını içeren danışmanlı YSA'lar ve bu ağlar içerisinde en az hata oranına sahip YSA ağırlık değerlerini elde etmek için Meta-sezgisel algoritmalar kullanılarak hibrit


yöntemler uygulanmıştır. YSA ve Meta-sezgisel algoritmalar hakkında genel bilgiler bölüm 1.5.2 ve 1.5.3’ de detaylı olarak verilmiştir.

YSA mimarileri genel olarak ileri ve geri beslemeli olarak iki farklı gruba ayrılmaktadır. İleri beslemeli ağ yapısında, işlem akış yönü giriş verilerinden çıkışa doğrudur ve girdi katmanından gelen giriş verileri bir değişikliğe uğratılmadan ara katmanlara iletilir (Şekil 3.5). İleri beslemeli ağlarda gecikme zamanı yoktur. Geri beslemeli yapay sinir ağının ileri beslemeli ağ yapısından en büyük farkı, bir nöronun çıktısının önceki katmanda veya aynı katmanda bulunan herhangi bir nörona girdi olarak verilebilmesidir.



Şekil 3. 5. İleri beslemeli çok katmanlı YSA örneği (Dramsch, 2020’den değiştirilerek alınmıştır).

YSA ağırlıklarının belirlenmesinde kullanılan farklı öğrenme algoritmaları vardır ve geri yayılım algoritması bunların başında gelmektedir. Bu algoritma, her ağırlığın lokal hatalarını hesaplar ve bunları ağda geriye doğru yayarak ağırlıkların öğrenmesini hedefler. Bu işlem sırasında delta kuralı veya gradyan iniş yöntemini kullanarak hata fonksiyonunun minimum değerini arar. Böylece, giriş verisi ile ağırlık çıkış verisi arasındaki fark göze alınarak ağırlıklar güncellenmektedir (Şekil 3.6). Geri yayılım algoritmasında kullanılan öğrenme parametresinin istenilen sonuca yaklaşımda önemli etkisi vardır. Bu parametre sabit olabileceği gibi ağ içinde güncellenebilmektedir.



Şekil 3. 6. İleri beslemeli geri yayımlı YSA mimarisi.

İleri besleme geri yayımlı YSA işlem adımları;

- Giriş ve Çıkış verilerinden oluşan eğitim setinin oluşturulması,
- Ağın topolojisinin belirlenmesi,
- Ağın öğrenme parametre ve fonksiyonlarının belirlenmesi,
- Ağırlıkların rastgele başlangıç değerlerinin belirlenmesi,
- Giriş verilerin ağıya girilmesi,
- İleri doğru hesaplama aşaması: Giriş katmanı, Ara katman(lar) ve çıkış katmanı değerlerinin hesaplanması,
- Çıkış değerlerinin hatalarının hesaplanması,
- Hata değerlerinin her katmana yayılması,
- Ağırlıkların güncellenmesi,
- Belirlenen iterasyon sayısı veya durdurma kriterine kadar bu ağırlıkların tekrar hesaplanması şeklindedir.

Basit olarak YSA'nın nöron hücreleri için basit matematiksel gösterimi (3.25) bağıntısı ile verilmiştir.

$$f\left(b + \sum_{i=1}^n x_i w_i\right) \quad (3.25)$$

Burada f , transfer fonksiyonu; b , bias değerini; x , giriş nöronu ve w , ağırlıkları ifade etmektedir. Geri yayılım algoritmasının, aktivasyon fonksiyonu sigmoid olan bir ağ yapısı için ifadesi (3.26) ve (3.27) bağıntıları ile gösterilmektedir.

$$\Delta w_{ij} = -\eta[-e_j][(1 - y_j)y_j][x_i] = \eta e_j (1 - y_j) y_j x_i \quad (3.26)$$


$$E = \frac{1}{2} \sum_j e_j^2 = \frac{1}{2} \sum_j (d_j - y_j)^2 \quad (3.27)$$

Burada E , hata fonksiyonu; d_j , beklenen çıkış değerini; y_j , YSA'nın hesaplanan çıkış değeri; w_{ij} , ara katmandaki i . nörona x_i girişini bağlayan ağırlık değeri olarak tanımlanmaktadır. Geri yayılım algoritmasında, ağırlıkların güncellenmesinde (3.28) ve (3.29) bağıntıları kullanılmaktadır.

$$\Delta w_{şimdiki} = -\eta \frac{\partial SSE}{\partial w_{şimdiki}} + \alpha \Delta w_{önceki} \quad (3.28)$$

$$\Delta w_{ij}(t + 1) = -\eta \frac{\partial E}{\partial w_{ij}} + \alpha \Delta w_{ij}(t) \quad (3.29)$$

Burada η , öğrenme katsayısını; α , yerel minimumu yakalanmamak için kullanılan momentum katsayısını ifade etmektedir. Geri yayılım algoritmasının görsel olarak işlem adımları Şekil 3.7'de verilmiştir.




Şekil 3. 7. Geri yayılım algoritmasının görsel olarak işlem adımları, **a)** x_1 girişi için y_1 çıkışın hesaplanması, **b)** YSA içindeki her nöron tarafından hesaplanan değerler ile beklenen çıkış değerleri arasındaki hatanın belirlenmesi, **c)** Hata değerlerinin geri yayılım ile ağı tekrar verilmesi, **d)** Ağırlıkların güncellenmesi.

YSA ağırlık değerlerinin hata payının düşük bir şekilde belirlenmesi ağı öğrenmesi ve bunun sonucu tahmin değerlerini doğruya yakın elde etmesini sağlayan en etkili parametrelerden biridir. Ağırlık değerlerinin belirlenmesinde YZ içerisinde yer alan Meta-sezgisel sürü algoritmaları da hibrit bir yöntem olarak kullanılmaktadır. Sürü algoritmaları, merkezi bir kontrole bağlı olmayan, bireysel zekânın çözülemeyecek problemlere karşı ortak bir zekâ gibi davranışlar sergileyen ve kendi kendine organize olabilen, doğal ya da yapay sistemleri ifade etmektedir (Köse, 2015). Bu yaklaşım, genel olarak doğadan esinlenilmiş olmakla beraber, çok sayıda bireyin problemlere karşı ortak davranış yaklaşımı içerisinde birleştiği ve birbirleriyle etkileşimin olduğu bir bütünü ifade etmektedir. Bu şekilde doğada yer alan sistemler genelde kuş sürüleri, balık sürüleri, karıncalar, arılar ve ortak davranış sergileyen her türlü canlı – cansız gruplar olabilmektedir (Garnier vd., 2007; Blum ve Li, 2008; Parpinelli ve Lopes, 2011; Karaboğa, 2014; Köse, 2015).


Parçacık Sürü optimizasyon (PSO) algoritması sürü algoritmaları içerisinde yer alan ve Kennedy ve Eberhart (1995) tarafından kuş sürülerinin davranışlarından esinlenerek

geliştirilmiş popülasyon tabanlı meta-sezgisel bir algoritmadır. Kuşların, yerini bilmedikleri yiyecekleri aramalarından esinlenilmiştir. Kuşlar yiyecek ararken yiyeceğe en yakın olan kuşu takip ederler. Parçacık olarak adlandırılan her tekil çözümde, arama uzayındaki bir kuşa karşılık gelecek şekilde algoritma oluşturulmuştur. Bu algoritmanın akış diyagramı Şekil 3.8’de tanımlanmıştır.



Şekil 3. 8. Parçacık sürü optimizasyon (PSO) algoritmasının akış diyagramı.

Bu algoritmalar bir takım temel kabullere dayanmaktadır. Bunlar; başlangıçta belirlenmiş çözüm uzayı sınırları, optimizasyon sürecine göre durma kriteri, çözüm sürecine sürülen parçacıkların birbirleriyle ve çözüm uzayıyla etkileşim içerisine girmesine imkân sağlayacak parametreler, çözüm sürecinde parçacıkların rastgele dağılımını sağlayacak hareket yönelimli matematiksel işlemler, çözüm bakımından başarılı parçacıkların çözüme daha hızlı ulaşabilmesi için parametrelerini güncelleyen matematiksel işlemler, parçacıkların hesapladıkları çözümlere göre geliştirilmesini sağlayan matematiksel işlemlerdir.



Şekil 3. 9. Parçacık sürü optimizasyon (PSO) algoritmasının çalışma prensibinin matematiksel ifadesinin şekilsel gösterimi ve N-iterasyon sonucu çözüme yaklaşımı. Mavi yıldız en iyi çözümü ifade etmektedir (Bryson vd., 2016'dan değiştirilerek alınmıştır).

Algoritmanın çalışma prensibine göre, her parçacık bir önceki konumundan yararlanarak sürü içerisindeki en iyi konumu (çözümü) göz önüne alarak kendi pozisyonunu konumlandırır. Sürünün o andaki en iyi konuma sahip bireyine göre diğer parçacıklar, konumunu ve hareketini güncellemektedir. Bu konumlandırmanın hızı rastgele gelişmektedir. Ayrıca, parçacıkların son konumları ilk konumlarına göre genelde daha iyidir. Bu döngü belirlenen durdurma kriterine veya hedefe ulaşıncaya durmaktadır (Şekil 3.9). PSO algoritmasının matematiksel olarak ifadesi (3.30) bağıntısıyla verilmiştir.

$$v_{k+1}^i = wv_k^i + c_1 rand \frac{(p^i - x_k^i)}{\Delta t} + c_2 rand \frac{(p_k^g - x_k^i)}{\Delta t} \quad (3.30)$$

Burada v_{k+1}^i , i parçacığının $k+1$ zamanındaki hızını; w , eylemsizlik katsayısını; c_1 , parçacığa ait katsayı (genel olarak 1.5 - 2 arasında alınır); c_2 , sürüye bağlı katsayıyı (genel olarak 2 - 2.5 arasında alınır); p^i , parçacığın en iyi konumunu; p_k^g , sürünün en iyi konumunu ifade etmektedir. Eylemsizlik (w) katsayısı sabit bir katsayı olacağı gibi farklı stratejilerle rastgelede seçilebilir (Bansal vd., 2011).

Kullanılan meta-sezgisel algoritmalarından bir diğeri de Öğretme-Öğrenme temelli optimizasyon (TLBO) algoritmasıdır. YSA ağırlık değerlerini hesaplamada hibrit bir yöntem

olarak kullanılmaktadır. Rao vd., (2011) tarafından geliştirilen algoritmanın temeli bir sınıf içerisindeki öğrenciler üzerindeki öğretmenin etkisine dayanmaktadır. İyi bir öğretmen tarafından eğitilen sınıftaki öğrencilerin sınav sonuçları yüksek olmaktadır. Öğrenmenin iyi ve kaliteli olması, sınav sonuçları üzerinde etkilidir. Ayrıca sınav sonuçları üzerinde, öğrenci arasındaki bilgi aktarımı ve etkileşiminin de katkısı olmaktadır. Bu algoritmada, öğrenciler problemin çözümlerini, öğrencilerin notları da uygunluk fonksiyonu olarak tanımlanabilir. Kısaca ifade edilirse, tanımlanan algoritma bir sınıf ortamında gerçekleşen bu öğrenme süreci ve sonuçlarını baz almaktadır. TLBO meta sezgisel algoritması sayısal yapısının kolaylığı açısından diğer algoritmalara göre daha kullanışlıdır ve daha doğru optimum çözümler sağlamaktadır.

TLBO algoritması temel olarak iki aşamadan oluşmaktadır. Bunlar, öğretme aşaması ve öğrenme aşamasıdır. Ayrıca, algoritma öğrenci sayısı (popülasyon) ve durdurma kriteri olmak üzere iki parametre ile kontrol edilmektedir. TLBO algoritmasında, bir sınıf (3.31) bağıntısındaki gibi ifade edilir.

$$\text{sınıf} = \begin{bmatrix} x_1^1 & \dots & x_n^1 \\ \dots & \dots & \dots \\ x_1^s & \dots & x_n^s \end{bmatrix} \rightarrow \begin{matrix} \text{öğrenci} \rightarrow f(x^1) \\ \text{öğrenci} \rightarrow f(x^2) \\ \text{öğrenci} \rightarrow f(x^s) \end{matrix} \quad (3.31)$$

Burada, sınıf matrisindeki her bir satırı bir öğrenciyi tanımlamakta ve bir çözümü ifade etmektedir. $f(x^1) \dots f(x^s)$ ile verilen her bir öğrencinin amaç fonksiyonu ise sonuç değerini tanımlamaktadır.

Bu sınıfın öğretme aşaması şu şekilde ilerlemektedir; en iyi öğrenci öğretmen olarak tanımlanır ve sınıftaki diğer öğrenciler bu öğretmenin bilgisi doğrultusunda kendi bilgilerini günceller, eğer daha iyi bir çözüm verirse eski öğrenciyle yer değiştirir. Bu şekilde öğretme aşaması tamamlanır ve matematiksel olarak (3.32) bağıntısı ile verilir.

$$x^{yeni,i} = x^i + r(x_{\text{öğretmen}} - T_f x_{\text{ort}}) \quad (3.32)$$


Burada T_f , öğretme katsayısını (1 veya 2 olarak belirlenir); r ise 0 ile 1 arasında rastgele bir sayıyı; $x^{yeni,i}$, yeni öğrenciyi; x^i , eski öğrenciyi; $x_{\text{öğretmen}}$, en iyi çözümü ve x_{ort} , sınıfın ortalamasını temsil etmektedir.

Bu sınıfın öğrenme aşaması ise, sınıftaki öğrenciler arasında etkileşime dayanmaktadır. Daha iyi çözüme sahip bilgi düzeyi daha yüksek olan öğrenciden diğer öğrenciye bilgi aktarımı olmakta ve karşılaştırılma yapılmaktadır. Eğer yeni öğrenci eski öğrenciden daha iyi bir çözüm verirse onun yerine geçmektedir. Bu işlemin matematiksel ifadesi (3.33) ve (3.34) bağıntısıyla verilmektedir.

$$\text{Eğer } f(x^i) < f(x^j) \rightarrow x^{yeni,i} = x^i + r(x^i - x^j) \quad (3.33)$$

$$\text{Eğer } f(x^i) > f(x^j) \rightarrow x^{yeni,i} = x^i + r(x^j - x^i) \quad (3.34)$$

Bu tez kapsamında, bahsedilen geri yayılım algoritması, PSO ve TLBO meta-sezgisel algoritmaları YSA'ların ağırlık ve bias değerlerini güncellemek ve en düşük hata oranıyla belirlemek için Alam (2016) ve Heris (2015)'in Matlab kodları modifiye edilerek uygulanmıştır. Yapılan hesaplamalarda kullanılan akış diyagramı Şekil 3.10 'da verilmiştir.




Şekil 3. 10. YSA'ların ağırlık ve bias değerlerinin güncellenmesi için uygulanan yöntemlerin akış diyagramı.

4. VERİ


Bu tez kapsamında kullanılan deprem verileri, Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi (KRDAE -BDTİM), T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi (AFAD) ve Harvard Global Centroid-Moment-Tensor (GMT) tarafından hazırlanan deprem kataloglarından alınmıştır.

Tezin amacı doğrultusunda belirlenen iki probleme göre 3 farklı veri seti oluşturulmuştur. İlk problem olarak belirlenen magnitüd dönüşümü için, KRDAE–BDTİM, AFAD ve GMT (Dziewonski, 1981; Ekström, 2012) tarafından hazırlanan deprem kataloglarından Türkiye ve civarında 1900-2020 yılları arasında meydana gelmiş magnitüdü $M \geq 4.0$ olan 3995 tane depremin farklı magnitüd türü bilgilerini içeren veri seti oluşturulmuştur. 120 yıllık zaman aralığı için veri setinin ($M \geq 4.0$) tamamlılığı Al-Tarazia ve Sandvol, (2007) tarafından önerilen yöntemle yıllara göre deprem sayısı ve kümülatif deprem sayısı grafiklenerek, test edilmiş ve yaklaşık 1960 yılından itibaren doğrusal olduğu görülmüştür (Şekil 4.1). Yapılan çalışmada önemli olan daha çok veriyle daha anlamlı ve hata oranı az olan magnitüd türü dönüşüm bağıntıları elde etmek olduğundan 1900-2020 yılları arasındaki tüm veriler kullanılmıştır.




Şekil 4. 1. Magnitüd dönüşümü için kullanılan veri seti ($M \geq 4.0$) a) Yıllara göre deprem sayısı b) Yıllara göre kümülatif deprem sayısı.

Şekil 4. 1'in devamı



Magnitüd dönüşümü için yapılan hesaplamalarda moment magnitüdü kullanılmış ve magnitüdün eşik değeri 4.0 olarak seçilmiştir. Bunun nedeni, literatürdeki daha önce yapılan çalışmalar, moment magnitüd türünün büyük depremler için daha iyi sonuç vermesi ve küçük magnitüd değerlerinin mühendislik yapılarında hasar yapıcı etkisi olmamasıdır. Kullanılan depremlerin episantr dağılım haritası Şekil 4.2’de verilmiştir.




Şekil 4. 2. Magnitüd dönüşümü için kullanılan depremlerin ($M \geq 4.0$) episantr dağılımı (KRDAE–BDTİM ve AFAD kataloglarından alınmıştır, URL-2 ve 3, 2020).

Magnitüd dönüşümü için oluşturulan veri setlerinde öncelikle KRDAE–BDTİM ve AFAD kataloglarındaki depremler oluş zamanları ve magnitüd türlerine göre eşleştirilmiş, sonrasında bu depremler GMT kataloğundaki M_w karşılıklarına göre gruplandırılmıştır. Veri setleri oluşturulurken deprem tekrarları çıkarılmış ve aynı depremin farklı raporlanması gibi uyumsuzluklar da göz önüne alınmıştır. Diğer magnitüd türlerinden (M_L , M_s , M_d ve m_b) moment magnitüd türüne (M_w) ve farklı deprem veri merkezleri arasında da dönüşüm sağlayacak 8 denklemi oluşturulmak için kullanılan veri setleri ile ilgili bilgiler Tablo 4.1 verilmiştir.

Tablo 4. 1. Magnitüd dönüşüm denklemleri oluşturmak için kullanılan veri setleri


No	Denklem Formu	Deprem sayısı
1	AFAD M_w - KRDAE M_L	624
2	AFAD M_w - KRDAE M_w	602
3	GMT M_w - KRDAE m_b	86
4	GMT M_w - KRDAE M_L	199
5	GMT M_w - KRDAE M_s	48
6	GMT M_w - KRDAE M_w	183
7	GMT M_w - AFAD M_w	266
8	GMT M_w - KRDAE M_d	44
	Toplam	2052

İkinci problem olarak tanımlanan PGA tahmini için 1900-2020 yılları arasında meydana gelmiş magnitüdü $M \geq 3.0$ olan depremlerden oluşan veri setinin tamamlılığı Al-Tarazia ve Sandvol, (2007) tarafından önerilen yöntemle yıllara göre deprem sayısı ve kümülatif deprem sayısı çizilerek test edilmiş ve yaklaşık 1998 yılından itibaren doğrusal olduğu görülmüştür (Şekil 4.3). Ancak, PGA tahmini için yüksek veri sayısı ile tahmin modelleri oluşturulması amaçlandığından tüm veri seti kullanılmıştır.



Şekil 4.3. PGA tahmini için kullanılan veri seti ($M \geq 3.0$) a) Yıllara göre deprem sayısı b) Yıllara göre kümülatif deprem sayısı.


Bu deprem verileri kullanılarak iki farklı veri seti Türkiye ve civarında 1976 – 2020 yılları arasında meydana gelen magnitüdü $M \geq 3.0$ olan depremlerin AFAD tarafından işletilen farklı istasyonlarda kaydedilen parametrelerinden oluşturulmuştur (Şekil 4.4).



Şekil 4. 4. PGA tahmininde kullanılan depremlerin ($M \geq 3.0$) episantr dağılımı (KRDAE–BDTİM ve AFAD kataloglarından alınmıştır, URL-2 ve 3, 2020).


Hesaplamalar için farklı iki veri seti oluşturulmuştur. Birinci veri seti, magnitüdüleri $M \geq 3.0$ olan depremlerin farklı istasyonlardaki 56384 parametresini içermektedir. İkinci veri seti ise, magnitüdüleri $M_w \geq 5.0$ olan depremlerin 4024 parametresinden oluşmaktadır. İlk veri seti, daha çok parametreyle hesaplama yapılabilmesi ve magnitüd türü bağımsız olmaması için magnitüdüleri $M \geq 3.0$ olan depremlerden oluşturulmuştur. Böylece PGA tahmini için literatürde bahsedilen az veri sayısı ve magnitüd türü duyarlılık probleminden kaçınılmak istenmiştir. İkinci veri setinde, mühendislik yapılarına hasar verebilecek ve büyüklük tanımlaması daha güvenilir olan, literatürdeki birçok azalım ilişkisinde de kullanılan moment magnitüd (M_w) türüne göre magnitüdü $M_w \geq 5.0$ olan depremlerin parametreleri kullanılmıştır. Böylece, bu veri seti magnitüd türü bakımından homojen bir yapıya sahip olmuştur. İki farklı veri seti kullanılması veriler arasındaki farklılıkların incelenmesine de olanak sağlamıştır. Kuvvetli yer hareketi tahmini için oluşturulan azalım

ilişkilerinde, PGA bağımlı değişkenin genel olarak logaritması alınarak hesaplamalar yapılmaktadır. Bunun nedeni, PGA'nın logaritmasının normal dağılım göstermesidir (Şekil 4.5).




Şekil 4. 5. Hesaplamalarında kullanılan PGA değerlerin normal ve logaritmik dağılımları a) 1. veri seti ($M \geq 3.0$), b) 2. veri seti ($M_w \geq 5.0$).

Bu tez kapsamında bağımlı değişken, PGA'nın logaritması ve bağımsız değişkenler, deprem ile istasyon arasındaki uzaklık (Repi) ve zemin parametresi S-dalga hızı (V_{s30}) değerlerinin hem normal hem de logaritması alınarak hesaplamalar yapılmıştır. Birinci veri setinin içerdiği magnitüdü ($M \geq 3.0$) olan depremlerin uzaklık Repi (km)'ye göre magnitüd (M), V_{s30} (m/sn) ve PGA (cm/sn^2) dağılımları Şekil 4.6'te verilmiştir (Toplam 56384 parametre). Bu veri setinin içerdiği bu dört parametrenin kendi aralarında dağılımı, histogram çizimleri ve PGA değerinin logaritmasının normal dağılıma uyumu Şekil 4.7'te gösterilmiştir.




Şekil 4. 6. PGA hesaplamaları için oluşturulan 1. veri seti ($M \geq 3.0$) parametre dağılımları a) Repi-Magnitüd (M), b) Repi - V_{s30} (m/sn), c) Repi - PGA(cm/sn^2)

Şekil 4. 6'nın devamı




Şekil 4. 7. PGA hesaplamaları için oluşturulan 1. veri setinin ($M \geq 3.0$) içerdiği 4 deprem parametresinin kendi aralarında dağılımı ve histogram çizimleri (Mak. Fr., maksimum frekansı ifade etmektedir).

İkinci veri setinin içerdği magnitüdü ($M_w \geq 5.0$) olan depremlerin uzaklık Repi (km)'ye göre magnitüd (M), Vs30 (m/sn) ve maksimum yer ivmesi (PGA) dağılımı Şekil 4.8'de verilmiştir (Toplam 4024 parametre). Veri setinin içerdği bu dört parametrenin kendi aralarında dağılımı, histogram çizimleri ve PGA değerinin logaritmasının normal dağılıma uyumu Şekil 4.9'da gösterilmiştir. Bu tez kapsamında bu bölümde detaylı olarak tanımlanan üç farklı veri seti üzerine YZ yöntemleri uygulanarak hesaplamalar yapılmıştır.



Şekil 4. 8. PGA hesaplamaları için oluşturulan 2. veri seti ($M_w \geq 5.0$) parametre dağılımları
a) Repi-Magnitüd (M), **b)** Repi - Vs30 (m/sn), **c)** Repi – PGA(cm/sn²).



Şekil 4. 9. PGA hesaplamaları için oluşturulan 2. veri setinin ($M_w \geq 5.0$) içerdiği 4 deprem parametresinin kendi aralarında dağılımı ve histogram çizimleri (Mak. Fr., maksimum frekans ifade etmektedir).

5. YAPILAN ÇALIŞMALAR

Bu tezin amacı doğrultusunda, magnitüd türü dönüşüm denklemlerinin oluşturulması ve maksimum yer hareketi ivmesi (PGA) tahmini olarak belirlenen iki problem için yapılan çalışmalar ve hesaplamalar bu bölümde detaylı olarak anlatılmıştır. Yapılan çalışmalar şu şekilde özetlenebilir;

- Magnitüd dönüşüm denklemlerinin oluşturulması için yapılan çalışmalar,
 - Lineer ve Ortogonal Regresyon uygulamaları,
 - Makine Öğrenmesi Algoritmalarının uygulanması,
- Maksimum yer hareketi ivmesi (PGA) tahmini için yapılan çalışmalar,
 - YSA ve Meta-Sezgisel (Hibrit YSA) algoritmalarının uygulanması,
 - Makine Öğrenmesi Algoritmalarının uygulanması,
- Test verileriyle yapılan çalışmalar ve kullanıcı arayüzlerinin tasarlanması.

5.1. Magnitüd Türü Dönüşüm Denklemleri İçin Yapılan Çalışmalar

5.1.1. Regresyon Analizleri

Homojen deprem kataloglarının hazırlanmasında kullanılan magnitüd türleri arasında dönüşüm denklemleri, genellikle regresyon yöntemleriyle belirlenmektedir (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Kadirioğlu ve Kartal, 2016; Tang vd., 2016). Bu çalışmada, birçok araştırmacının da kullandığı ve yöntem kısmında detaylı açıklanan lineer (LR) ve ortogonal (OR) regresyon yöntemleri ve ayrıca makine öğrenmeleri algoritmaları kullanılarak magnitüd türü dönüşüm denklemleri oluşturulmuştur. Hesaplamalarda, veri kısmında detaylı açıklanan KRDAE-BDTİM, AFAD ve GMT tarafından hazırlanan deprem kataloglarından, 1900-2020 yılları arasında meydana gelmiş magnitüdü $M \geq 4.0$ olan depremlerin farklı magnitüd türü bilgileri kullanılmıştır. Farklı magnitüd türlerini (ML, Ms, Md ve mb) moment magnitüd türüne (Mw) ve aynı zamanda 3 farklı veri merkezine göre de dönüşümü sağlayacak 8 denklem oluşturulmuştur.


Bu hesaplamalarda izlenen metodoloji; farklı magnitüd türü ile moment magnitüd bilgisi içeren depremlerin eşleştirilmesi ve veri setleri oluşturulması (Tablo 4.1’de detaylı açıklanmıştır), veri setlerine regresyon yöntemleri ve makine öğrenmesi algoritmalarının uygulanması ve sonuçların literatürdeki denklemlerle karşılaştırılması şeklindedir.

Tablo 5. 1. Magnitud türü dönüşümü için oluşturulan 8 denklemin regresyon katsayıları ve Standart sapma (σ) değerleri.

No	Veri	Y	X	Linear Regresyon ($Y = a+bX$)				Ortogonal Regresyon ($Y = a+bX$)			
				a	b	σ		a	b	σ	
1	624	AFAD Mw	KRDAE ML	0.2003 (± 0.0622)	0.9551 (± 0.0136)	0.5219		-0.0695 (± 0.0661)	1.0145 (± 0.0145)	0.5384	
2	602	AFAD Mw	KRDAE Mw	1.1508 (± 0.1227)	0.7558 (± 0.0274)	0.4581		0.00003 (± 0.1643)	1.0144 (± 0.0368)	0.5198	
3	86	GMT Mw	KRDAE mb	-0.0345 (± 0.3724)	1.0488 (± 0.0727)	0.3907		-1.2793 (± 0.4589)	1.2924 (± 0.0896)	0.4307	
4	199	GMT Mw	KRDAE ML	1.0189 (± 0.1569)	0.8174 (± 0.0307)	0.3694		0.5246 (± 0.1755)	0.9143 (± 0.0343)	0.3892	
5	48	GMT Mw	KRDAE Ms	2.4377 (± 0.1762)	0.5975 (± 0.0327)	0.3971		2.3186 (± 0.1827)	0.6198 (± 0.0340)	0.4041	
6	183	GMT Mw	KRDAE Mw	3.2442 (± 0.2410)	0.3886 (± 0.0487)	0.3067		2.2223 (± 0.3687)	0.5961 (± 0.0747)	0.3469	
7	266	GMT Mw	AFAD Mw	0.5462 (± 0.0630)	0.9052 (± 0.0120)	0.4594		0.4467 (± 0.0643)	0.9242 (± 0.0122)	0.4642	
8	44	GMT Mw	KRDAE Md	1.7345 (± 0.2634)	0.7246 (± 0.0496)	0.6116		1.4642 (± 0.2819)	0.7759 (± 0.0531)	0.5343	


Y, bağımlı değişkeni; X, bağımsız değişkeni; a ve b regresyon katsayıları; AFAD, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi; KRDAE, Kandilli Rasathanesi Deprem Araştırma Enstitüsü; GMT, Harvard Global Centroid-Moment-Tensor katalogunu ifade etmektedir.

Kullanılan LR ve OR regresyon yöntemleri, gelişmiş istatistiksel fonksiyonların sade bir şekilde uygulanmasını sağlayan Statgraph, (2005) yazılımı kullanılarak uygulanmıştır. OR hesaplamalarında bağımlı ve bağımsız değişkenler arasındaki ilişkiyi temsil eden eta parametresinin değeri $\eta=1$ olarak kabul edilmiştir. Oluşturulan 8 denklemin regresyon katsayıları standart sapma (σ) değerleri detaylı olarak Tablo 5.1’de verilmiştir. Yapılan hesaplamalar sonucunda oluşturulan tabloya göre LR ve OR regresyon yöntemine göre σ değerleri incelendiğinde 7 denklem için LR yönteminin, 1 denklem (GMT Mw-KRDAE Md) için ise OR yönteminin diğer yöntemlere göre düşük σ değerleri verdiği gözlenmiştir. Standart sapma değerleri LR yöntemi için $\sigma = 0.3067 - 0.6116$ ve OR yöntemi için $\sigma = 0.3892 - 0.5384$ aralıklarında hesaplanmıştır. Bunun sonucu olarak, OR yöntemine göre düşük σ değerlerine sahip olan LR yönteminin oluşturulan veri setlerine daha duyarlı sonuç verdiği düşünülmektedir. Oluşturulan denklemlerin veri dağılımları ve iki regresyon yöntemine göre hesaplanan doğru denklemleri detaylı olarak Şekil 5.1’de verilmiştir.



Şekil 5. 1. Lineer (LR) ve ortogonal (OR) regresyon yöntemlerine göre oluşturulan magnitüd türü dönüşüm denklemlerinin karşılaştırmaları **a)** AFAD Mw - KRDAE ML, **b)** AFAD Mw - KRDAE Mw, **c)** GMT Mw - KRDAE mb, **d)** GMT Mw - KRDAE ML, **e)** GMT Mw - KRDAE Ms, **f)** GMT Mw - KRDAE Mw, **g)** GMT Mw - AFAD Mw, **h)** GMT Mw - KRDAE Md arasındaki dönüşüm denklemleri ve grafikleri (Renkleri açık maviden koyu maviye doğru giden altıgen kutucuklar veri yoğunluğunu temsil etmektedir).

Şekil 5.1'in devamı



5.1.2 Makine Öğrenmesi Algoritmalarıyla Yapılan Uygulamalar

Makine öğrenme algoritmaları, oluşturulan veri setlerine Matlab, (2018) Regression Learner kullanılarak uygulanmıştır. Bu uygulama içerisinde kullanılan 19 farklı makine öğrenme algoritması Tablo 5.2'de verilmiştir. Veri setlerine 10 katlamalı çapraz geçerlilik (cross validation) örnekleme yöntemi uygulanarak, makine öğrenme algoritmalarıyla regresyon modelleri eğitilmiştir. Böylece aşırı öğrenme (overfitting) probleminin önüne geçilmesi amaçlanmıştır.


Tablo 5. 2. Hesaplamalarda kullanılan makine öğrenme algoritmaları.

Lineer Regresyon Modelleri (LR)	Regresyon Ağaçları (RA)	Destek Vektör Makinesi (DVM)	Gauss Regresyon Modelleri (GRM)	Topluluk Ağaçları (TA)
➤ Basit LR	➤ Basit (Fine) RA	➤ Lineer DVM	➤ Rasyonel (Rational) Kuadratik GRM	➤ Yükseltme (Boosted) TA
➤ Etkileşimli (Interactions) LR	➤ Orta (Medium) RA	➤ Kuadratik DVM	➤ Kare üstel (Squared Exponential) GRM	➤ Torbalama (Bagged) TA
➤ Sağlam (Robust) LR	➤ Kaba (Coarse) RA	➤ Kübik DVM	➤ Matern 5/2 GRM	
➤ Adımsal (Stepwise) LR		➤ Basit (Fine) Gauss DVM	➤ Üstel (Exponential) GRM	
		➤ Orta (Medium) Gauss DVM		
		➤ Kaba (Coarse) Gauss DVM		

Makine öğrenme algoritmalarıyla yapılan hesaplamalar için işlem adımları;

- Regresyon yöntemleri uygulamalarında kullanılan denklem formlarına (Tablo 5.1) göre oluşturulan veri setlerine Tablo 5.2’de belirtilen makine öğrenme algoritmaları uygulanarak doğrusal ve doğrusal olmayan regresyon modellerin oluşturulması,
- Uygulanan 19 algoritma içerisinde, hata değerlerine göre en iyi 3 algoritmanın regresyon modelinin seçilmesi,
- Oluşturulan 8 farklı denklem formuna göre, her biri için seçilen 10 adet test verisi kullanılarak, bu en iyi 3 algoritmanın regresyon modeli ile hesaplanması,
- Aynı test verileriyle en iyi 3 makine öğrenmesi algoritma model sonuçlarının, regresyon yöntemi sonuçlarının ve literatürdeki diğer denklemler ile hesaplanan sonuçların karşılaştırması şeklindedir.

Makine öğrenmesi algoritmalarıyla eğitilen regresyon modellerini oluşturmak için uygulanan hesaplama adımları ve akış diyagramı Şekil 5.2’de verilmiştir.



Şekil 5. 2. Makine öğrenme algoritmalarıyla eğitilen regresyon modelleri için hesaplama adımları ve akış diyagramı


En iyi model RMSE, R^2 , MSE ve MAE hata değerleri göz önüne alınarak belirlenmiştir. Uygulanan 19 makine öğrenmesi algoritması içinden seçilen en iyi 3 regresyon modelin hata değerleri ve karşılaştırmaları Tablo 5.3’de verilmiştir.

Tablo 5. 3. Makine öğrenme algoritmaları içerisinde seçilen en iyi 3 algoritmanın 8 farklı veri seti için hesaplanan hata değerleri.

Veri seti-1			Veri seti-2			Veri seti-3			Veri seti-4						
AFAD Mw-KRDAE ML			AFAD Mw - KRDAE Mw			GMT Mw - KRDAE mb			GMT Mw - KRDAE ML						
1	GRM	RMSE	0,1759	1	GRM	RMSE	0,3310	1	Kuadratik DVM	RMSE	0,2134	1	GRM	RMSE	0,1651
	Matern 5/2	R ²	0,8900	Matern 5/2	R ²	0,5900	0,5900			R ²	0,7500	Matern 5/2	R ²	0,8200	
		MSE	0,0300												MSE
2	GRM	MAE	0,1307	GRM	MAE	0,2070	0,2070	2	Küçük DVM	MAE	0,1703	2	Küçük DVM	MAE	0,1259
	RMSE	0,1760	RMSE												
	Rasyonel (Rational)	R ²	0,8900	Kare üstel	R ²	0,5900	0,5900			R ²	0,7400	R ²	0,8200		
MSE		0,0310	MSE											0,1100	MSE
Kuadratik		MAE	0,1310	(Squared Exponential)	MAE	0,2070	MAE	0,1729	MAE	0,1278					
3	Küçük DVM	RMSE	0,1780	3	RA	RMSE	0,3310	3	Sağlam (Robust)	RMSE	0,2336	3	Kuadratik DVM	RMSE	0,1671
	R ²	0,8900	Kaba (Coarse)	R ²	0,5900	LR	R ²	0,7000	R ²	0,8200					
	MSE	0,0310									MSE	0,1100	MSE	0,0279	MSE
		MAE	0,1320		MAE	0,2100		MAE	0,1812		MAE	0,1289			
Veri seti-5			Veri seti-6			Veri seti-7			Veri seti-8						
GMT Mw - KRDAE Ms			GMT Mw - KRDAE Mw			GMT Mw - AFAD Mw			GMT Mw - KRDAE Md						
1	Kuadratik DVM	RMSE	0,1425	1	Torbalama (Bagged)	RMSE	0,3310	1	GRM	RMSE	0,7320	1	Kuadratik DVM	RMSE	0,1902
		R ²	0,8900	TA	R ²	0,2600	Matern 5/2	R ²	0,9800	R ²	0,8800				
		MSE	0,0203									MSE	0,1110	MSE	0,0054
2		MAE	0,1061	GRM	MAE	0,2294	2	Küçük DVM	MAE	0,0443	MAE	0,1495			
	RMSE	0,1501	RMSE										0,3350	RMSE	0,0826
	Küçük DVM	R ²	0,8800	Üstel (Exponential)	R ²	0,2600		R ²	0,9700	R ²	0,8700				
MSE		0,2253	MSE									0,1113	MSE	0,0068	MSE
3		LR	MAE	0,1132	3	LR	MAE	0,2286	3	LR	MAE	0,0563	3	GRM	MAE
	RMSE	0,1542	RMSE	0,3376											
		R ²	0,8700		R ²	0,2400		R ²	0,9600	Rasyonel (Rational)	R ²	0,8600			
MSE		0,0238	MSE										0,1140	MSE	0,0010
		MAE	0,1193		MAE	0,2428		MAE	0,0705		MAE	0,1630			


LR, Linear Regresyon; DVM, Destek Vektör Makinesi; GRM, Gauss Regresyon Modelleri; TA, Topluluk Ağaçları; AFAD, T.C. İçişleri Bakanlığı Afet ve Acil Durum Yönetimi Başkanlığı Deprem Dairesi; KRDAE, Kandilli Rasathanesi Deprem Araştırma Enstitüsü; GMT, Harvard Global Centroid-Moment-Tensor kataloğunu ifade etmektedir.

Giriş veri setlerine göre makine öğrenme algoritmalarıyla eğitilerek oluşturulan en iyi 3 regresyon modeli (Tablo 5.3) içinden, en iyisine ait gerçek ve hesaplanan değer grafikleri ve 8 veri setine göre karşılaştırmaları Şekil 5.3’de verilmiştir.



Şekil 5. 3. Makine öğrenmesi algoritmalarıyla magnitüd türü dönüşüm için oluşturulan doğrusal ve doğrusal olmayan regresyon modellerinin karşılaştırılması **a)** AFAD Mw - KRDAE ML, **b)** AFAD Mw – KRDAEMw, **c)** GMT Mw - KRDAE mb, **d)** GMT Mw - KRDAE ML, **e)** GMT Mw - KRDAE Ms, **f)** GMT Mw - KRDAE Mw, **g)** GMT Mw- AFAD Mw a, **h)** GMT Mw - KRDAE Md arasındaki regresyon modeli.

Şekil 5. 3'ün devamı



Regresyon modellerinin R^2 değerleri incelendiğinde, veri seti-6 hariç 0.59'dan yüksek olduğu görülmektedir. Diğer RMSE, MSE ve MAE hata değerlerinin en düşük olduğu modeller, en iyi 3 model olarak seçilmiştir. En iyi model seçimi genel olarak RMSE değerleri göz önüne alınarak belirlenmiştir. Hesaplanan RMSE değerlerine göre (Tablo 5.3); veri seti-1 için 0.1759 değeriyle GRM Matern 5/2 algoritmasının, veri seti 2 için 0.3310 değeriyle GRM Matern 5/2 algoritmasının, veri seti-3 için 0.2134 değeriyle Kuadratik DVM algoritmasının, veri seti-4 için 0.1651 değeriyle GRM Matern 5/2 algoritmasının, veri seti-5 için 0.1425 değeriyle Kuadratik DVM algoritmasının, veri seti-6 için 0.3310 değeriyle Torbalama (Bagged) TA algoritmasının, veri seti-7 için 0.7320 değeriyle GRM Matern 5/2 algoritmasının, veri seti-8 için 0.1902 değeriyle Kuadratik DVM algoritmasının oluşturduğu regresyon modeli veriye en iyi uyum sağlayan model olarak seçilmiştir. Genel olarak makine öğrenme algoritmaları veri seti-5 haricinde doğrusal olmayan bir tepki vermiştir. Veri setlerinin ve model sayılarının fazla olmasından dolayı seçilen en iyi 2. ve 3. regresyon modellerinin grafikleri tezin ekler (Ek-1 ve Ek-2) kısmında verilmiştir.

Bu bölümde yapılan çalışmalar sonucunda LR ve OR regresyon yöntemleriyle oluşturulan 8 denklem ve makine öğrenmesi algoritmalarıyla oluşturulan 8 regresyon modeli kullanılarak rastgele oluşturulan test veriyle hesaplamalar yapılmıştır. Aynı test verileri, literatürde farklı araştırmacılar tarafından oluşturulan magnitüd dönüşüm denklemleri ile de hesaplanmış ve tüm sonuçlar karşılaştırmalı olarak detaylı bir şekilde bölüm 5.3.1' de açıklanmıştır.

5.2. Maksimum Yer Hareketi İvmesi (PGA) Tahmini İçin Yapılan Çalışmalar

Depremın yıkıcı etkisini belirleyen en önemli parametrelerden biri olan PGA'nın doğru bir şekilde hesaplanması ve tahmin edilmesi için uzun yıllardır araştırmacılar birçok PGA tahmin denklemi (azalım ilişkisi) geliştirmişlerdir. Bu araştırmacılar genellikle regresyon analizlerini (modellerini) kullanarak deprem parametreleri arasında ilişki kurmaya çalışmışlardır. Tezin amacı doğrultusunda PGA hesaplamalarının daha doğru bir şekilde yapılması için gelişen teknoloji ile günümüzde daha çok uygulama alanı bulan YZ teknikleri uygulanarak deprem parametreleri arasında ilişki kurulmuştur. Bölüm 3'de detaylı olarak açıklanan yöntemler yardımıyla PGA hesaplamalarında izlenen adımlar;

- AFAD deprem kataloglarındaki 1976–2020 yılları arasında Türkiye ve civarında meydana gelen (Şekil 4.4) magnitüdüleri $M \geq 3.0$ olan depremlerin parametreleri kullanılarak 6 farklı veri formu (Tablo 5.4) için iki farklı eğitim veri seti oluşturması,
- Daha fazla veri kullanılması için magnitüd türüne bakılmaksızın, magnitüdü $M \geq 3.0$ olan depremlerin parametrelerinden (Şekil 4.6) 1. eğitim veri setinin (56384 parametre) oluşturulması,
- Deprem magnitüdüne göre homojenlik sağlamak ve günümüzde daha duyarlı olmasından dolayı sık kullanılan büyüklük türü olan moment magnitüd (M_w) baz alınarak, hasar verici etkiye sahip büyüklüğü $M_w \geq 5.0$ olan depremlerin parametrelerinden (Şekil 4.6) 2. eğitim veri setinin (4024 parametre) oluşturulması,
- Matlab programlama diliyle geri yayılım algoritmasına göre geliştirilen çoklu YSA (YSA-Multi) kodunun iki veri setine uygulanması,
- Matlab programlama diliyle PSO ve TLBO meta-sezgisel algoritmalarına göre yazılan YSA-PSO ve YSA-TLBO hibrit kodların iki veri setine uygulanması,
- WEKA yazılımı (Frank vd., 2016) yardımıyla farklı nöron sayıları baz alınarak iki veri setine YSA modellerinin uygulanması,
- Matlab yazılımı yardımıyla farklı makine öğrenme algoritmalarının iki veri setine uygulanması ve regresyon tahmin modellerinin oluşturulması ve en iyi 3 modelin hata değerlerine göre belirlenmesi,

- Uygulanan tüm yöntemlerle oluşturulan YSA ve regresyon modellerine, rastgele seçilen 30 adet depreme ait parametrelerden oluşan giriş test verisi verilmesi ve model çıktıların hesaplanması,
- Aynı 30 adet test verisi kullanılarak literatürden seçilen azalım ilişkileriyle PGA'ların hesaplanması,
- Yapılan tüm hesaplamaların sonucu elde edilen PGA değerlerinin karşılaştırılması şeklinde özetlenebilir.

Tablo 5. 4. YSA'ların eğitim veri setleri için oluşturulan 6 farklı veri formu.

Veri Formu	Giriş Verisi	Çıkış Verisi
1	M-Vs30-Repi	LogPGA
2	M-LogVs30-LogRepi	LogPGA
3	M-Vs30-LogRepi	LogPGA
4	M-LogVs30-Repi	LogPGA
5	M-Repi	LogPGA
6	M-LogRepi	LogPGA


M, magnitüd; Vs30, S-dalga hızı, Repi; deprem ile istasyon arasındaki uzaklık; PGA, Maksimum yer hareketinin ivmesini ifade etmektedir.

5.2.1. Yapay Sinir Ağları ve Meta-sezgisel Algoritmalarla Yapılan Uygulamalar

Bu bölümde, oluşturulan iki veri setine YSA'ların uygulanma aşamaları açıklanmıştır. İlk aşamada ileri beslemeli geri yayılım eğitim algoritmasına göre oluşturulan çoklu YSA-Multi modeli, PSO ve TLBO meta-sezgisel algoritmaların YSA eğitim süreci içinde kullanılarak oluşturulan hibrit YSA-PSO ve YSA-TLBO modelleri her iki veri setine de uygulanmıştır. İkinci aşamada farklı nöron ve katman sayılarına göre farklı bir yazılım (WEKA) kullanılarak iki veri setine göre YSA modelleri oluşturulmuştur.


İlk aşamada yapılan hesaplamalarda YSA-Multi, YSA-PSO ve YSA-TLBO kodları kullanılmıştır. YSA'larının veri setleri hazırlanırken temel olarak, tüm veri setinin %70'inin eğitim veri seti, %20'sinin doğrulama (değerlendirme) veri seti, %10'unun test verisi olarak kullanılmasıdır (Wuest vd., 2016). YSA'larının gizli katman ve nöron sayılarının belirlenmesi, birkaç kabul dikkat alınarak yapılabilmektedir. Bunlar nöron sayısının giriş katmanı veri sayısının iki katından az olmaması ve giriş katmanı veri sayısının 2/3'ü ile çıkış katmanının toplamı kadar olmalıdır. Ancak, genel bir kuralı olmadığından gizli katman ve

nöron sayılarına ağıın performansına bakılarak karar verilmektedir. Bu çalışmada, YSA'ların nöron ve gizli katman sayılarına, farklı nöron ve gizli katman sayılarına göre oluşturulan ağ performanslarına bakılarak karar verilmiştir. YSA-Multi için, veri setinin %70'i eğitim veri seti olarak, %20'si doğrulama (değerlendirme) veri seti olarak, %10'u test verisi olarak belirlenmiştir. Gizli katman sayısı 1 ve nöron sayısı 10 olarak seçilmiştir. Eğitim fonksiyonu olarak Levenberg-Marquardt geri yayılma algoritması ve aktivasyon fonksiyonu olarak Sigmoid fonksiyonu seçilmiştir. Ağıın performansı MSE hata fonksiyonuna göre değerlendirilmiştir. YSA-Multi algoritması 100 tur kendi içerisinde farklı ağlar oluşturmakta ve içlerinden hata fonksiyonuna göre en iyi olanı seçmektedir. Bu seçilen en iyi YSA ağına rastgele seçilen 30 deprem parametresi (M, Vs30 ve Repi) verilerek PGA tahmini yapılmış ve tahmini sonuçları gerçek PGA değerleriyle karşılaştırılmıştır. YSA-Multi algoritmasının akış diyagramı Şekil 5.4' de verilmiştir.




Şekil 5. 4.YSA-Multi algoritması akış diyagramı (M, magnitüd; Vs30, S-dagası hızı; Repi, episantr ile istasyon arasındaki dış merkez uzaklığı).

YSA-Multi kodu kullanılarak magnitüdü $M \geq 3.0$ olan depremlerin (M, Vs30, Repi ve LogPGA) parametrelerinden oluşan 1. eğitim veri setine (56384 parametre) göre 6 farklı veri formunda eğitilen YSA, ağıın R hata sonuçları ve test verisi olarak belirlenen 30 depreme ait giriş parametreleri verilen ağıın yaptığı PGA tahminleri Şekil 5.5'te verilmiştir.




Şekil 5. 5. YSA-Multi koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M , Vs_{30} , $Repi$ ve LogPGA değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), **a)** $M\text{-}Vs_{30}\text{-}Repi \rightarrow \text{LogPGA}$, **b)** $M\text{-}\text{Log}Vs_{30}\text{-}\text{LogRepi} \rightarrow \text{LogPGA}$, **c)** $M\text{-}Vs_{30}\text{-}\text{LogRepi} \rightarrow \text{LogPGA}$, **d)** $M\text{-}\text{Log}Vs_{30}\text{-}Repi \rightarrow \text{LogPGA}$, **e)** $M\text{-}Repi \rightarrow \text{LogPGA}$, **f)** $M\text{-}\text{LogRepi} \rightarrow \text{LogPGA}$ veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).

Şekil 5. 5'in devamı




YSA-Multi kodu kullanılarak magnitüdü $M_w \geq 5.0$ olan depremlerin parametrelerinden oluşan 2. eğitim veri setine (4024 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, bu ağın R hata sonuçları ve test verisi olarak belirlenen 30 depreme ait giriş parametreleri için ağın yaptığı PGA tahminleri Şekil 5.6'da verilmiştir.




Şekil 5. 6. YSA-Multi koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M , V_{s30} , R_{epi} ve LogPGA değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), **a)** M - V_{s30} - $R_{epi} \rightarrow \text{LogPGA}$, **b)** M - $\text{Log}V_{s30}$ - $\text{Log}R_{epi} \rightarrow \text{LogPGA}$, **c)** M - V_{s30} - $\text{Log}R_{epi} \rightarrow \text{LogPGA}$, **d)** M - $\text{Log}V_{s30}$ - $R_{epi} \rightarrow \text{LogPGA}$, **e)** M - $R_{epi} \rightarrow \text{LogPGA}$, **f)** M - $\text{Log}R_{epi} \rightarrow \text{LogPGA}$ veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).


Şekil 5. 6'nın devamı



Şekil 5. 6'nın devamı




Matlab programlama dilinde oluşturulan YSA-PSO hibrit kodu yine oluşturulan 2 farklı veri setine uygulanmıştır. Oluşturulan YSA modeli 10 nöron sayısına sahip ileri beslemeli bir ağ yapısından oluşmaktadır. Bu ağın içerisindeki PSO algoritması için çözüm kümesi -1.5 - 1.5 arasında, w katsayısı 0.4 - 1.4 arasında rastgele, $c_1=1.5$, $c_2 = 2.5$ ve popülasyon sayısı 50 olarak seçilmiş ve 100 iterasyon yapılacak şekilde dizayn edilmiştir. Hata fonksiyonu MSE kullanılmıştır. YSA-PSO algoritmasının akış diyagramı Şekil 5.7'de verilmiştir.




Şekil 5. 7. YSA-PSO ve YSA-TLBO algoritmaları akış diyagramı. (M, magnitüd; Vs30, S-dagası hızı; Repe, episantr ile istasyon arasındaki dış merkez uzaklığı).

YSA-PSO kodu kullanılarak 1. eğitim veri setine ($M \geq 3.0$ ve 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, bu ağların R hata sonuçları ve test verilerine göre YSA'ların yaptığı PGA tahminleri Şekil 5.8'te verilmiştir.




Şekil 5. 8. YSA-PSO hibrit koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M , $Vs30$, $Repi$ ve $LogPGA$ değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı $LogPGA$ hesaplamaları (tahminleri), **a)** $M-Vs30-Repi \rightarrow LogPGA$, **b)** $M-LogVs30-LogRepi \rightarrow LogPGA$, **c)** $M-Vs30-LogRepi \rightarrow LogPGA$, **d)** $M-LogVs30-Repi \rightarrow LogPGA$, **e)** $M-Repi \rightarrow LogPGA$, **f)** $M-LogRepi \rightarrow LogPGA$ veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).

Şekil 5. 8'in devamı




2. eğitim veri setine ($M_w \geq 5.0$ ve 4024 parametre) göre 6 farklı veri formuna göre YSA-PSO hibrit kodu kullanılarak eğitilen YSA'lar, bu ağların R hata sonuçları ve test verisine göre ağların yaptığı PGA tahminleri Şekil 5.9'da gösterilmiştir.




Şekil 5. 9. YSA-PSO hibrit koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı LogPGA hesaplamaları (tahminleri), **a)** M-Vs30-Repi → LogPGA, **b)** M-LogVs30-LogRepi → LogPGA, **c)** M-Vs30-LogRepi → LogPGA, **d)** M-LogVs30-Repi → LogPGA, **e)** M-Repi → LogPGA, **f)** M-LogRepi → LogPGA veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).

Şekil 5. 9'un devamı




YSA-TLBO hibrit algoritması için 10 nöronlu ileri beslemeli bir YSA modeli oluşturulmuştur. Bu ağın içerisindeki TLBO modeli için çözüm kümesi -5 ile 5 arasında, popülasyon sayısı 50 olarak ve öğretim katsayısı 1 ile 2 arasında rastgele değerler alınarak, hata fonksiyonu MSE olarak belirlenmiş ve 100 döngü yapacak şekilde dizayn edilmiştir. YSA-TLBO algoritmasının akış diyagramı Şekil 5.7'de verilmiştir.

YSA-TLBO hibrit kodu kullanılarak 1. eğitim veri setine ($M \geq 3.0$ ve 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, bu ağların R hata sonuçları ve test verilerine göre YSA'ların yaptığı PGA tahminleri Şekil 5.10 'da verilmiştir.




Şekil 5. 10. YSA- TLBO hibrit koduyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M , $Vs30$, R_{epi} ve $LogPGA$ değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı $LogPGA$ hesaplamaları (tahminleri), **a)** $M-Vs30-R_{epi} \rightarrow LogPGA$, **b)** $M-LogVs30-LogR_{epi} \rightarrow LogPGA$, **c)** $M-Vs30-LogR_{epi} \rightarrow LogPGA$, **d)** $M-LogVs30-R_{epi} \rightarrow LogPGA$, **e)** $M-R_{epi} \rightarrow LogPGA$, **f)** $M-LogR_{epi} \rightarrow LogPGA$ veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).

Şekil 5. 10'un devamı




2. eğitim veri setine ($M_w \geq 5.0$ ve 4024 parametre) göre 6 farklı veri formuna göre YSA-TLBO hibrit kodu kullanılarak eğitilen YSA'lar, bu ağların R hata sonuçları ve test verisine göre ağların yaptığı PGA tahminleri Şekil 5.11'de gösterilmiştir.



Şekil 5. 11. YSA- TLBO hibrit koduyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M , Vs_{30} , R_{epi} ve $LogPGA$ değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilen YSA'lar, ağların R değerleri ve eğitilen YSA'ların test giriş verilerine (Rastgele seçilen 30 depreme ait parametreler) göre yaptığı $LogPGA$ hesaplamaları (tahminleri), **a)** $M-Vs_{30}-R_{epi} \rightarrow LogPGA$ v, **b)** $M-LogVs_{30}-LogR_{epi} \rightarrow LogPGA$, **c)** $M-Vs_{30}-LogR_{epi} \rightarrow LogPGA$, **d)** $M-LogVs_{30}-R_{epi} \rightarrow LogPGA$, **e)** $M-R_{epi} \rightarrow LogPGA$, **f)** $M-LogR_{epi} \rightarrow LogPGA$ veri formlarına göre oluşturulan ağlar ve hesaplama grafikleri (Mavi çizgi hesaplanan eğriyi; kesikli gri çizgi ideal eğriyi ifade etmektedir).


Şekil 5. 11'in devamı



YSA-Multi, YSA-PSO ve YSA-TLBO algoritmaları, verilen 2 farklı veri setine ve 6 farklı veri giriş formuna göre eğitilen ağların R hata fonksiyonlarına göre incelendiğinde; 1. eğitim veri setine ($M \geq 3.0$) göre eğitilen YSA-Multi için $R=0.8101$ ile en yüksek değeri

4. giriş veri formu göstermiş, diğer veri formlarında R değeri 0.7887'den başlamaktadır, YSA-PSO için $R=0.7677$ değeri ile en yüksek 3. veri formu vermiş, diğer veri formlarında ise R değeri 0.63996'dan başlamaktadır. YSA-TLBO için $R=0.5647$ ile en düşük değeri 3. veri formu ve $R=0.77015$ ile en yüksek değeri ise 6. veri formu göstermiştir. Diğer veri seti ($M_w \geq 5.0$) ile eğitilen YSA-Multi için $R=0.8267$ ile en yüksek değeri 2. veri formu göstermiş, diğer giriş veri formlarında ise R değeri 0.7916'dan başlamaktadır. YSA-PSO için $R=0.72222$ ile en yüksek değeri 1. veri formu, $R=0.4723$ ile en düşük değeri 4. veri formu göstermiştir. YSA-TLBO için $R=0.56942$ ile en düşük değeri 3. veri formu, $R=0.74847$ ile en yüksek değeri ise 1. veri formu göstermiştir. Yüksek R değerine sahip modeller, giriş verileri arasında daha tutarlı bir ilişki oluşturmaktadır.

İkinci aşamada oluşturulan 2 farklı veri seti aynı zamanda farklı nöron ve gizli katman sayılarına göre WEKA yazılımı yardımıyla da değerlendirilmiştir. WEKA, grafik kullanıcı arayüzü olan açık kaynak kodlu bir makine öğrenmesi yazılımıdır (Frank vd., 2016). Bu yazılımın içerisinde yer alan 'Çok Katmanlı Algılayıcı' (Multilayer Perceptron) algoritmasıyla 10 nöron içeren tek katman, 6-10 nöron içeren iki katman ve 6-10-3 nöron içeren üç katmanlı YSA mimarileri oluşturulmuştur (Şekil 5.12). Ağların eğitimi yine 6 farklı giriş verisi formuna (Tablo 5.4) göre yapılmış, öğrenme katsayısı (Learning rate) 0.3, momentum katsayısı 0.2 ve döngü (epoch) sayısı 500 olarak seçilmiştir. Aynı test, veri seti oluşturulan YSA'lara giriş verisi olarak tanıtılarak PGA hesaplamaları (tahmini) yapılmıştır.



Şekil 5. 12. WEKA yazılımıyla oluşturulan 3 farklı YSA mimarisi a) 10 nöron tek katmanlı b) 6-10 nöron iki katmanlı c) 6-10-3 nöron üç katmanlı ağ mimarisi örneği (giriş parametreleri; M, Vs30, Repi yeşil, tahmin edilen PGA sarı dikdörtgenlerle ve nöronlar kırmızı dairelerle gösterilmiştir).

Farklı nöron sayıları ve katmanlara göre WEKA yazılımıyla 6 farklı veri formu için eğitilen YSA'ların R ve RMSE değerleri Tablo 5.5'de verilmiştir.

Tablo 5. 5. Farklı nöron sayıları ve katmanlara göre WEKA yazılımıyla 6 farklı veri formu için eğitilen YSA'ların R ve RMSE değerleri.


Veri Seti-1 (M ≥ 3.0 depremlerin M, Vs30, Repi ve LogPGA oluşan 56384 parametre)											
Veri Formu-1			Veri Formu-2			Veri Formu-3					
M-Vs30-Repi→LogPGA			M-Log Vs30-LogRepi→LogPGA			M-Vs30-LogRepi→LogPGA					
1	10 Nöron	RMSE R	0.4711 0.8023	1	10 Nöron	RMSE R	0.4585 0.7959	1	10 Nöron	RMSE R	0.4698 0.8025
2	6-10 Nöron	RMSE R	0.4623 0.8081	2	6-10 Nöron	RMSE R	0.4633 0.8087	2	6-10 Nöron	RMSE R	0.4652 0.8087
3	6-10-3 Nöron	RMSE R	0.4841 0.8067	3	6-10-3 Nöron	RMSE R	0.4798 0.8064	3	6-10-3 Nöron	RMSE R	0.4758 0.8067
Veri Seti-2 (Mw ≥ 5.0 depremlerin M, Vs30, Repi ve LogPGA oluşan 4024 parametre)											
Veri Formu-1			Veri Formu-2			Veri Formu-3					
M-Vs30-Repi→LogPGA			M-Log Vs30-LogRepi→LogPGA			M-Vs30-LogRepi→LogPGA					
1	10 Nöron	RMSE R	0.4720 0.8049	1	10 Nöron	RMSE R	0.5017 0.7851	1	10 Nöron	RMSE R	0.6247 0.3769
2	6-10 Nöron	RMSE R	0.4613 0.8081	2	6-10 Nöron	RMSE R	0.5022 0.7881	2	6-10 Nöron	RMSE R	0.6141 0.3847
3	6-10-3 Nöron	RMSE R	0.4893 0.8070	3	6-10-3 Nöron	RMSE R	0.5160 0.7856	3	6-10-3 Nöron	RMSE R	0.6176 0.3832
Veri Seti-3 (Mw ≥ 5.0 depremlerin M, Vs30, Repi ve LogPGA oluşan 4024 parametre)											
Veri Formu-1			Veri Formu-2			Veri Formu-3					
M-Vs30-Repi→LogPGA			M-Log Vs30-LogRepi→LogPGA			M-Vs30-LogRepi→LogPGA					
1	10 Nöron	RMSE R	0.3689 0.809	1	10 Nöron	RMSE R	0.3807 0.8084	1	10 Nöron	RMSE R	0.3794 0.8088
2	6-10 Nöron	RMSE R	0.3637 0.8143	2	6-10 Nöron	RMSE R	0.3647 0.8133	2	6-10 Nöron	RMSE R	0.3690 0.8084
3	6-10-3 Nöron	RMSE R	0.3659 0.8154	3	6-10-3 Nöron	RMSE R	0.3624 0.8171	3	6-10-3 Nöron	RMSE R	0.3666 0.8112
Veri Seti-4 (Mw ≥ 5.0 depremlerin M, Vs30, Repi ve LogPGA oluşan 4024 parametre)											
Veri Formu-4			Veri Formu-5			Veri Formu-6					
M-LogVs30-Repi→LogPGA			M-Repi→LogPGA			M-LogRepi→LogPGA					
1	10 Nöron	RMSE R	0.3694 0.8097	1	10 Nöron	RMSE R	0.4229 0.7724	1	10 Nöron	RMSE R	0.4564 0.7474
2	6-10 Nöron	RMSE R	0.3628 0.8162	2	6-10 Nöron	RMSE R	0.4266 0.7762	2	6-10 Nöron	RMSE R	0.4297 0.7783
3	6-10-3 Nöron	RMSE R	0.371 0.8088	3	6-10-3 Nöron	RMSE R	0.4261 0.7823	3	6-10-3 Nöron	RMSE R	0.4224 0.7815

WEKA ile eğitilen ağların R ve RMSE hata değerleri incelendiğinde; veri seti-1 için veri formu-6 ile eğitilen ağ hariç diğer veri formlarına göre eğitilen ağların R değerinin 0.7851'den başladığı, veri formu-2 ile eğitilen ağda ise $RMSE=0.4585$ 'lik en küçük değer gözlenmiştir. Veri formu-2 ile eğitilen 6-10 nöronlu 2 katmanlı YSA giriş verisiyle en iyi ilişki oluşturulmuştur. Veri seti-2 için $R=0.7474$ 'lük en düşük değeri, veri formu-6 ile eğitilen 10 nöronlu tek katmanlı YSA mimarisinde görülmüştür. $RMSE=0.3624$ 'lük en düşük değeri ise veri formu-2 için hesaplanmıştır. En düşük RMSE ve yüksek R değerine sahip veri formu-2, giriş verisiyle en iyi uyum sağlayan YSA mimarisi olarak değerlendirilmiştir.

5.2.2. Makine Öğrenmesi Algoritmalarıyla Yapılan Uygulamalar


Makine öğrenme algoritmaları bölüm 5.1.2' de uygulanan metodolojiye benzer şekilde PGA tahmini için oluşturulan 2 farklı setine (1. veri seti magnitüdü $M \geq 3.0$ olan depremlerin 56384 parametresi ve 2. veri seti magnitüdü $M_w \geq 5.0$ olan depremlerin 4024 parametresi) 6 farklı veri formu için Matlab, (2018)-Regression Learner kullanılarak uygulanmıştır. Tablo 5.2'de tanımlanan 19 farklı makine öğrenme algoritması kullanılmıştır. Veri yoğunluğu fazla olan 1. veri seti için 6 farklı veri formuna göre yapılan hesaplamalarda, her bir veri formu için hesaplama süresi 12 saatten fazla sürmüştür. Yapılan hesaplamalar sonucunda hata fonksiyonları değerlerine göre 1. ve 2. veri seti için seçilen en iyi 3 regresyon modeli Tablo 5.6'da verilmiştir. Genel olarak GRM, TA ve RA makine öğrenmesi algoritmaları, veri setlerine daha az hata oranlarıyla cevap vermişlerdir. Veri seti-1 için Torbalama (Bagged) TA algoritması 4 veri formu için daha iyi hata oranları vermiştir. Bu algoritma en düşük $RMSE=0.3480$ değeri ile 4. veri formu için hesaplanmıştır. Farklı veri formlarına göre seçilen ilk 3 algoritma arasında, en yüksek hata değeri gösteren veri formu- 5 ve 6 için Basit (Fine) Gauss DVM ile Torbalama (Bagged) TA algoritmasıdır. Bu iki algoritma için $RMSE=0.3900$ olarak hesaplanmıştır. Veri Seti-2 için yine GRM, TA ve RA makine öğrenmesi algoritmaları daha düşük hata paylarıyla regresyon modelleri üretmiştir. GRM Üstel (Exponential) makine öğrenmesi algoritması en iyi regresyon modellerini en düşük hata paylarıyla tüm veri formları için üretmiştir. Bu algoritma $RMSE=0.3500$ 'lik en düşük değeriyle veri formu-1 için en iyi regresyon modelini oluşturmuştur. Ayrıca, veri seti-1'de olduğu gibi en yüksek hata oranı gösteren veri formu-5 ve 6 için Basit (Fine) Gauss DVM ile Torbalama (Bagged) TA algoritmasıdır.

Makine öğrenmesi algoritmalarıyla eğitilerek oluşturulan en iyi 3 regresyon modeli içinden 1. veri seti için 6 farklı veri formuna göre hesaplanan en iyi regresyon modeline ait gerçek ve hesaplanan değer grafikleri Şekil 5.13'te verilmiştir. Veri setlerinin ve model sayılarının fazla olmasından dolayı seçilen en iyi 2. ve 3. regresyon modellerinin grafikleri tezin ekler (Ek-3) kısmında verilmiştir.




Şekil 5. 13. Makine öğrenmesi algoritmalarıyla 1. eğitim veri setine ($M \geq 3.0$ depremlerin M , $Vs30$, $Repi$ ve $LogPGA$ değerlerinden oluşan 56384 parametre) göre 6 farklı veri formunda eğitilerek oluşturulan en iyi regresyon modelleri; **a)** $M-Vs30-Repi \rightarrow LogPGA$, **b)** $M-LogVs30-LogRepi \rightarrow LogPGA$, **c)** $M-Vs30-LogRepi \rightarrow LogPGA$, **d)** $M-LogVs30-Repi \rightarrow LogPGA$, **e)** $M-Repi \rightarrow LogPGA$ veri, **f)** $M-LogRepi \rightarrow LogPGA$ veri formlarına göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği.

Şekil 5. 13'ün devamı




Aynı uygulama 2. veri seti içinde yapılmış en iyi 3 regresyon modeli içinden 6 farklı veri formuna göre hesaplanan en iyi regresyon modeline ait gerçek ve hesaplanan değer grafikleri Şekil 5.14'te verilmiştir. Bu veri setine ait 2. ve 3. regresyon modellerin grafikleri tezin ekler (Ek-4) kısmında verilmiştir.



Şekil 5. 14. Makine öğrenmesi algoritmalarıyla 2. eğitim veri setine ($M_w \geq 5.0$ depremlerin M, Vs30, Repi ve LogPGA değerlerinden oluşan 4024 parametre) göre 6 farklı veri formunda eğitilerek oluşturulan en iyi regresyon modelleri; a) M-Vs30-Repi $\rightarrow$ LogPGA, b) M-LogVs30-LogRepi $\rightarrow$ LogPGA, c) M-Vs30-LogRepi $\rightarrow$ LogPGA, d) M-LogVs30-Repi $\rightarrow$ LogPGA, e) M-Repi $\rightarrow$ LogPGA, f) M-LogRepi $\rightarrow$ LogPGA veri formlarına göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği.

Şekil 5. 14'ün devamı



5.3. Test Verileriyle Yapılan Çalışmalar

Bu bölümde magnitüd türü dönüşümü için oluşturulan denklemler ve regresyon modelleri ile PGA tahmini için oluşturulan regresyon modelleri, rastgele belirlenen test verileriyle test edilmiş ve sonuçlar literatürde daha önceden geliştirilen tahmin denklemleri (azalım ilişkileriyle) karşılaştırılmıştır.

5.3.1. Magnitüd Türü Dönüşüm Denklemleri ve Regresyon Modelleriyle Yapılan Hesaplamalar

Magnitüd türü dönüşümü için regresyon yöntemleri (LR ve OR) kullanılarak oluşturulan denklemler ile makine öğrenmesi algoritmalarıyla oluşturulan en iyi 3 regresyon modeli, test verileri kullanılarak test edilmiş ve sonuçları literatürdeki denklemlerle karşılaştırılmıştır. Yapılan hesaplamalarda, 8 farklı denklem formuna göre rastgele seçilen 10 depremin magnitüd değerleri kullanılmıştır. Aynı test verileri, literatürde kullanılan magnitüd türü dönüşümü denklemleriyle hesaplanmıştır (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Kadirioğlu ve Kartal, 2016; Tang vd., 2016). Tüm sonuçlar birbiriyle karşılaştırılmıştır. Denklem formlarına göre belirlenen test giriş verileri ve bunlara karşılık gelen gerçek veriler kullanılarak denklemler ve regresyon modelleriyle hesaplanan sonuçlar R^2 değerleriyle birlikte ilk 4 denklem formu için Tablo 5.7’de diğer 4 denklem formu Tablo 5.8’de verilmiştir. Her denklem formu için, bağımlı değişken gerçek veriyi ve bağımsız değişken ise test verisini ifade etmektedir. Oluşturulan denklem, regresyon modellerine ve literatürdeki denklemlere giriş verisi olarak test verisi verilmiş ve sonuçlar hesaplanmıştır. Çıkan sonuçlar, gerçek veri ile karşılaştırılmış ve R^2 değerlerine göre değerlendirilmiştir. Genel olarak farklı veri formlarına göre makine öğrenmesi algoritmaları içerisinde seçilen en iyi 3 regresyon modeli daha yüksek R^2 değerlerine sahiptir. Bu yüksek değerler karşılaştırılan LR, OR ve literatürdeki denklemlerden test verilerine daha iyi sonuçlar verdiğini göstermektedir. En yüksek $R^2 = 0.9774$ değeri ile 4. denklem formu GMT Mw - KRDAE ML için regresyon modeli-1 vermiştir. En düşük $R^2 = 0,3840$ değeri ile 6. denklem formu GMT Mw - KRDAE Mw için LR, OR, RM-3 ve Çıvgın 2015 denklemi vermiştir. Determinasyon katsayısını tanımlayan R^2 değerinin düşük olmasına ise, gerçek veri ile hesaplanan arasındaki saçılmanın neden olduğu düşünülmektedir.

Tablo 5.7. Magnitüd türü dönüşümü için ilk 4 denklem formuna göre test verileri sonuçları ve R^2 değerleri

1. Denklem formu AFAD Mw - KRDAE ML										
Gerçek Veri AFAD Mw	Test Verisi KRDAE ML	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadroğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
4.8	5.1	5.1	5.1	5.1	5.1	5.0	5.6	5.4	5.2	5.1
5.1	5.1	5.1	5.1	5.1	5.1	5.0	5.6	5.4	5.2	5.1
6.8	6.7	6.6	6.7	6.7	6.7	6.8	6.8	6.7	6.5	6.2
5.4	5.6	5.5	5.6	5.6	5.6	5.6	5.9	5.8	5.6	5.5
4.9	5.1	5.1	5.1	5.1	5.1	5.0	5.6	5.4	5.2	5.1
4.6	5	5.0	5.0	5.0	5.0	4.9	5.5	5.3	5.1	5.0
4.6	4.6	4.6	4.6	4.6	4.6	4.5	5.2	5.0	4.8	4.7
5	5.2	5.1	5.2	5.2	5.2	5.1	5.6	5.5	5.3	5.2
5.8	5.7	5.6	5.7	5.7	5.7	5.7	6.0	5.9	5.7	5.5
4.8	5.1	5.1	5.1	5.1	5.1	5.0	5.6	5.4	5.2	5.1
R^2	0.9478	0.9478	0.9462	0.9452	0.9452	0.9527	0.9478	0.9478	0.9478	0.9478
2. Denklem formu AFAD Mw - KRDAE Mw										
Gerçek Veri AFAD Mw	Test Verisi KRDAE Mw	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadroğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
4.5	4.7	4.7	4.8	4.8	4.8	4.9				
4.2	4.1	4.2	4.2	4.2	4.2	4.1				
5.1	4.8	4.8	4.9	4.9	4.9	4.9				
4.5	4.2	4.3	4.3	4.3	4.3	4.3				
4	4.1	4.2	4.2	4.2	4.2	4.1				
4.5	4.3	4.4	4.4	4.4	4.4	4.4				
4.1	4.1	4.2	4.2	4.2	4.2	4.1				
4	4.3	4.4	4.4	4.4	4.4	4.4				
5	5.1	5.0	5.2	5.1	5.2	5.1				
4.6	4.5	4.6	4.6	4.6	4.6	4.6				
R^2	0.719	0.719	0.719	0.724	0.723	0.692				
3. Denklem formu GMT Mw - KRDAE Mb										
Gerçek Veri GMT Mw	Test Verisi KRDAE Mb	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadroğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
5.4	4.8	5.0	4.9	5.0	5.0	5.0	5.1	5.0	5.0	5.0
5.5	5.3	5.5	5.6	5.5	5.5	5.5	5.7	5.5	5.4	5.6
5.3	5	5.2	5.2	5.2	5.2	5.2	5.3	5.2	5.2	5.3
5.5	5.1	5.3	5.3	5.3	5.3	5.3	5.4	5.3	5.3	5.4
5.3	5	5.2	5.2	5.2	5.2	5.2	5.3	5.2	5.2	5.3
5.6	5.4	5.6	5.7	5.6	5.6	5.6	5.8	5.6	5.5	5.7
5.8	5.5	5.7	5.8	5.7	5.7	5.7	5.9	5.7	5.6	5.8
5.7	5.5	5.7	5.8	5.7	5.7	5.7	5.9	5.7	5.6	5.8
6	5.7	5.9	6.1	6.0	6.0	6.0	6.2	5.9	5.8	6.1
5.2	5.1	5.3	5.3	5.3	5.3	5.3	5.4	5.3	5.3	5.4
R^2	0.7666	0.7666	0.8270	0.8334	0.7666	0.7666	0.7666	0.7666	0.7666	0.7666
4. Denklem formu GMT Mw - KRDAE ML										
Gerçek Veri GMT Mw	Test Verisi KRDAE ML	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadroğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
5.1	5.1	5.2	5.2	5.1	5.1	5.1	5.6	5.4	5.2	5.1
5.1	5.1	5.2	5.2	5.1	5.1	5.1	5.6	5.4	5.2	5.1
6.8	6.7	6.5	6.7	6.9	6.8	6.8	6.8	6.7	6.5	6.2
5.6	5.6	5.6	5.6	5.6	5.6	5.5	5.9	5.8	5.6	5.5
4.9	5.1	5.2	5.2	5.1	5.1	5.1	5.6	5.4	5.2	5.1
4.8	5	5.1	5.1	5.1	5.1	5.1	5.5	5.3	5.1	5.0
4.7	4.6	4.8	4.7	4.9	4.8	4.8	5.2	5.0	4.8	4.7
5.2	5.2	5.3	5.3	5.2	5.2	5.2	5.6	5.5	5.3	5.2
5.7	5.7	5.7	5.7	5.7	5.6	5.6	6.0	5.9	5.7	5.5
5	5.1	5.2	5.2	5.1	5.1	5.1	5.6	5.4	5.2	5.1
R^2	0.9745	0.9745	0.9774	0.9735	0.9758	0.9745	0.9745	0.9745	0.9745	0.9745


LR, Lineer regresyon; OR, Ortogonal Regresyon; RM, Makine öğrenmesi algoritmalarıyla oluşturulan regresyon modelini ifade etmektedir.

Tablo 5. 8. Magnitüd türü dönüşümü için son 4 denklem formuna göre test verileri sonuçları ve R^2 değerleri.

5. Denklem formu GMT Mw - KRDAE Ms										
Gerçek Veri GMT Mw	Test Verisi KRDAE Ms	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadırlıoğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
5.5	5.4	5.7	5.7	5.6	5.6	5.7	5.7	5.6	5.7	5.3
5.6	5.9	6.0	6.0	5.9	6.0	6.0	6.1	5.9	6.0	5.7
5.2	5	5.4	5.4	5.4	5.4	5.4	5.4	5.4	5.4	5.1
6.3	6.4	6.3	6.3	6.3	6.3	6.3	6.4	6.2	6.3	6.0
6	6	6.0	6.0	6.0	6.0	6.0	6.1	5.9	6.0	5.8
5.4	5.5	5.7	5.7	5.7	5.7	5.7	5.8	5.6	5.7	5.4
5.8	5.7	5.8	5.9	5.8	5.8	5.8	5.9	5.8	5.9	5.5
6.4	6	6.0	6.0	6.0	6.0	6.0	6.1	5.9	6.0	5.8
5.5	5.3	5.6	5.6	5.6	5.6	5.6	5.6	5.5	5.6	5.3
5.4	5.1	5.5	5.5	5.5	5.5	5.5	5.5	5.4	5.5	5.1
R^2		0.7805	0.7805	0.7841	0.7848	0.7805	0.7805	0.7805	0.7805	0.7805
6. Denklem formu GMT Mw - KRDAE Mw										
Gerçek Veri GMT Mw	Test Verisi KRDAE Mw	LR	OR	RM-1	RM-2	RM-3	Ulusay 2004	Kadırlıoğlu ve Kartal 2016	Çıvgın 2015	Tang 2016
6.1	6.1	5.6	5.9	5.8	5.8	5.6	5.9	5.8	5.6	5.7
5	6	5.6	5.8	5.6	5.7	5.6	5.8	5.7	5.6	6.0
5.2	4.4	5.0	4.8	5.0	5.0	5.0	4.8	5.0	5.0	4.7
4.8	5	5.2	5.2	5.3	5.2	5.2	5.2	5.2	5.2	5.2
4.8	4.5	5.0	4.9	5.0	5.0	5.0	4.9	5.0	5.0	4.8
5.2	4.5	5.0	4.9	5.0	5.0	5.0	4.9	5.0	5.0	4.8
4.8	4.4	5.0	4.8	5.0	5.0	5.0	4.8	5.0	5.0	4.7
4.8	4.1	4.8	4.7	5.0	5.0	5.0	4.7	5.0	5.0	4.4
5.4	5.1	5.2	5.3	5.1	5.2	5.2	5.3	5.1	5.2	5.3
4.9	4.8	5.1	5.1	5.0	5.0	5.0	5.1	5.0	5.0	5.0
R^2		0.3840	0.3840	0.4046	0.4144	0.3840	0.4046	0.4144	0.3840	0.3840
7. Denklem formu GMT Mw - AFAD Mw										
Gerçek Veri GMT Mw	Test Verisi AFAD Mw	LR	OR	RM-1	RM-2	RM-3	Çıvgın 2015	Gerçek Veri GMT Mw	Test Verisi KRDAE Mw	Ulusay 2004
5.1	4.8	4.9	4.9	4.9	4.9	4.9	5.0	5	4.8	5.2
5.1	5.1	5.2	5.2	5.1	5.1	5.2	5.3	4.8	4.2	4.8
6.8	6.8	6.7	6.7	6.8	6.8	6.7	6.6	5.1	5	5.4
5.6	5.4	5.4	5.4	5.4	5.4	5.4	5.5	5.6	5	5.4
4.9	4.9	5.0	5.0	4.9	5.0	5.0	5.1	5.6	5.5	5.7
4.8	4.6	4.7	4.7	4.8	4.8	4.7	4.8	5.2	4.4	4.9
4.7	4.6	4.7	4.7	4.8	4.8	4.7	4.8	6.3	6.2	6.2
5.2	5	5.1	5.1	5.0	5.0	5.1	5.2	5.2	4.7	5.1
5.7	5.8	5.8	5.8	5.8	5.8	5.8	5.8	6	5.8	5.9
5.0	4.8	4.9	4.9	4.9	4.9	4.9	5.0	5.5	5.2	5.5
R^2		0.9690	0.9690	0.9606	0.9674	0.9690	0.9690	R^2	0.8608	0.8608
8. Denklem formu GMT Mw - AFAD Md										
Gerçek Veri GMT Mw	Test Verisi AFAD Mw	LR	OR	RM-1	RM-2	RM-3	Çıvgın 2015	Gerçek Veri GMT Mw	Test Verisi KRDAE Mw	Ulusay 2004
5.1	4.8	4.9	4.9	4.9	4.9	4.9	5.0	5	4.8	5.2
5.1	5.1	5.2	5.2	5.1	5.1	5.2	5.3	4.8	4.2	4.8
6.8	6.8	6.7	6.7	6.8	6.8	6.7	6.6	5.1	5	5.4
5.6	5.4	5.4	5.4	5.4	5.4	5.4	5.5	5.6	5	5.4
4.9	4.9	5.0	5.0	4.9	5.0	5.0	5.1	5.6	5.5	5.7
4.8	4.6	4.7	4.7	4.8	4.8	4.7	4.8	5.2	4.4	4.9
4.7	4.6	4.7	4.7	4.8	4.8	4.7	4.8	6.3	6.2	6.2
5.2	5	5.1	5.1	5.0	5.0	5.1	5.2	5.2	4.7	5.1
5.7	5.8	5.8	5.8	5.8	5.8	5.8	5.8	6	5.8	5.9
5.0	4.8	4.9	4.9	4.9	4.9	4.9	5.0	5.5	5.2	5.5
R^2		0.8608	0.8608	0.8651	0.8542	0.8531	0.8608	0.8651	0.8542	0.8608




LR, Lineer regresyon; OR, Ortogonal Regresyon; RM, Makine öğrenmesi algoritmalarıyla oluşturulan regresyon modelini ifade etmektedir.

Yapılan bu hesaplamalar sonucunda 8 denklem formunun her biri için gerçek veri ile hesaplanan veri arasındaki farklar (hatalar) grafiksel olarak Şekil 5.15’de verilmiştir.






Şekil 5. 15.Farklı 8 denklem formuna göre test verisiyle hesaplanan ve gerçek veri arasındaki fark (hata) değerleri **a)** AFAD Mw - KRDAE ML, **b)** AFAD Mw – KRDAE Mw, **c)** GMT Mw - KRDAE mb, **d)** GMT Mw - KRDAE ML, **e)** GMT Mw - KRDAE Ms, **f)** GMT Mw - KRDAE Mw, **g)** GMT Mw- AFAD Mw, **h)** GMT Mw - KRDAE Md formu için fark hata değerleri (LR, Lineer regresyon; OR, Ortogonal Regresyon; RM, Makine öğrenmesi algoritmalarıyla oluşturulan regresyon modelini ifade etmektedir).

Şekil 5. 15'in devamı



Şekil 5. 15'in devamı



Fark (hata) grafikleri incelendiğinde, test verilerine göre her denklem ve model için farklı değerler gözlenmiştir. Bu fark (hata) değişimleri veri setlerinin içeriği ve yöntemlerin farklılığından kaynaklandığı düşünülmektedir. Makine öğrenmesi algoritmalarıyla oluşturulan RM-1, RM-2 ve RM-3 modelleri genel olarak düşük hata oranlarıyla farklı denklem formlarında test verileriyle yapılan hesaplamalarda gerçek ve hesaplanan veri arasında iyi uyum göstermişlerdir. Diğer kullanılan LR ve OR regresyon yöntemleri de regresyon modellerine yakın, yani düşük hata değerleri vermiştir.

5.3.2. PGA Tahmini İçin Oluşturulan Regresyon Modelleriyle Yapılan Hesaplamalar

PGA tahmini için YSA ve makine öğrenmesi algoritmalarıyla oluşturulan modellere, rastgele seçilen 30 depreme ait parametrelerle hazırlanan test verileri giriş verisi olarak verilmiş ve hesaplanan sonuçlar literatürden seçilen 8 farklı PGA tahmin denklemiyle karşılaştırılmıştır (Esteva ve Villaverde, 1973; İnan vd., 1996; Boore vd., 1997; Sadigh ve Egan 1998; Özbey vd., 2003; Kalkan ve Gülkan, 2004; Beyaz, 2004; Akkar vd., 2014). Her 2 veri seti (1. veri seti; magnitüdü $M \geq 3.0$ olan depremlerin 56384 parametresi ve 2. veri seti; magnitüdü $M_w \geq 5.0$ olan depremlerin 4024 parametresi) ile farklı 6 veri formuna göre yapılan tüm modeller için hesaplamalar ve sonuçların korelasyon (R) ve determinasyon (R^2) katsayısı değerleri tablolar halinde Ekler (Ek-5 ve Ek-6) kısmında verilmiştir. Veri seti-1 için; 6 farklı veri formuna göre eğitilerek oluşturulan farklı regresyon modelleri içerisinde R ve R^2 değerlerine göre seçilen en iyi modeller kullanılarak, test giriş verileriyle yapılan PGA tahminleri, R ve R^2 sonuçları Tablo 5.9'da verilmiştir. Oluşturulan regresyon modellerinin R^2 değerleri 0.5610 - 0.7579 arasında, R değerleri 0.7490 - 0.8706 arasında değişmektedir. En iyi $R=0.8706$ ve $R^2=0.7579$ değeri ile 6. veri formu için oluşturulan RM-3 modelidir. Bu model, test verilerine en yakın PGA tahminlerini yapmıştır. $R=0.7490$ ve $R^2=0.5610$ değeri ile 4. veri formu için oluşturulan YSA-PSO modeli, en düşük regresyon modelidir. Her bir veri formu için test giriş verilerine göre yapılan PGA tahminleri, ölçülen PGA değerleri ile karşılaştırılmış ve aralarındaki farklar (hatalar) grafiksel olarak Şekil 5.16'da verilmiştir. Ayrıca literatürden seçilen 8 farklı ivme tahmin denklemiyle de, aynı test verileri kullanılarak hesaplanmış PGA'lar Tablo 5.9'da ve bunların karşılaştırmaları Şekil 5.16'da gösterilmiştir. Özellikle toplam hata grafikleri incelendiğinde, regresyon modelleriyle yapılan PGA tahminlerinin hata değerlerinin daha düşük olduğu gözlenmiştir.

Tablo 5. 9. Veri seti-1 için oluşturulan regresyon modelleri içerisinde seçilen en iyi regresyon modelleriyle hesaplanan PGA, R ve R2 değerleri.

Test Verisi				Seçilen PGA tahmin denklemleri															
M	Vs30	Repi	PGA	VF-1	VF-2	VF-3	VF-4	VF-5	VF-6	Esteva 1973	Boore 1997	Sadigh 1998	Özbey 2004	Kalkan 2004	Inan 1996	Beyaz 2004	Akkar 2014		
				YSA- PSO	RM-2	RM-3	YSA- PSO	RM-1	RM-3										
3.1	192	14.3715	0.7700	0.6084	1.9404	1.9404	0.5803	2.0281	1.8072	22.6202	53.2417	21.6909	1.0601	20.8716	3.4139	13.6833	7.1390		
3.1	709	74.9585	0.1245	0.0389	0.1646	0.1646	0.0439	0.1364	0.1407	5.0601	9.6469	2.1806	0.2455	4.9228	0.7721	2.7646	0.1477		
3.4	219	40.7060	0.3658	0.7724	0.5675	0.5675	0.5938	0.4303	0.4082	13.0514	27.4663	7.0493	0.8848	12.9861	2.0956	5.6468	1.4473		
3.4	234	46.1303	0.8801	0.7002	0.5195	0.5195	0.5581	0.3478	0.3639	11.4593	24.3658	5.8715	0.7807	11.5818	1.8725	4.9963	1.0852		
4.4	337	125.5637	0.4955	1.1683	0.6708	0.6708	0.6684	0.5338	0.5707	6.9020	16.1905	2.8395	1.8268	11.9449	3.3964	2.9331	0.6228		
5.2	1323	50.0517	28.2846	43.8242	12.9718	12.9718	37.1322	9.2491	12.8351	44.2455	29.8229	21.8563	17.5874	45.0287	25.7349	11.4051	6.8597		
3.6	313	73.8637	0.5081	0.6453	0.3964	0.3964	0.4845	0.2328	0.2889	7.6946	16.8493	3.3801	0.7208	9.4895	1.6535	3.4122	0.4926		
5.5	181	279.7177	2.8534	0.1147	1.0385	1.0385	8.7313	0.6838	0.7567	4.4622	18.8407	1.9405	4.0867	10.2572	8.5694	2.4982	1.2939		
4.2	348	12.3034	10.4828	7.6503	17.9804	17.9804	3.6890	11.0764	11.0408	58.9329	82.1558	54.8712	10.4892	78.6957	20.3694	25.2912	29.5548		
3.8	555	12.7593	4.6117	5.7727	5.5475	5.5475	5.9316	7.0664	6.3096	42.0577	55.4811	40.3210	4.8504	53.4549	10.8332	20.2788	14.7240		
3.8	356	30.4067	1.7876	2.6575	1.5765	1.5765	1.6562	1.4478	1.6051	23.6165	35.0324	14.4907	2.6290	26.4914	4.9582	8.8768	3.7966		
5.6	186	353.9452	0.2379	0.0200	0.7251	0.7251	9.8091	0.3227	0.3432	3.1839	16.3302	1.4261	3.5875	8.5649	8.0530	2.1078	1.0479		
5.7	243	202.4129	0.6862	0.8528	1.6058	1.6058	2.6988	1.5820	1.5367	9.1088	24.0340	3.9178	7.6034	15.1105	15.4663	3.9315	2.6997		
5.7	248	344.0663	1.4610	0.0265	0.7251	0.7251	2.5535	0.4609	0.4463	3.6288	15.8002	1.6293	4.2105	9.1616	9.5945	2.3164	1.1659		
5.9	273	193.4270	0.8385	1.2657	2.0160	2.0160	2.2807	1.6715	1.1625	11.5281	26.3594	4.9919	10.2294	17.0668	21.7338	4.7112	3.8262		
5.9	216	168.6507	1.5561	1.7665	3.3574	3.3574	4.1247	3.1579	2.1692	14.4284	31.9278	6.2226	11.9107	19.4198	24.5873	5.3999	5.1429		
6.8	195	249.3240	3.3740	0.7314	8.3946	8.3946	2.4547	4.5113	4.3132	15.4163	38.2752	7.0630	19.5039	19.3628	66.5139	7.1383	12.1060		
6.8	720	261.9778	4.7481	0.4182	5.6598	5.6598	0.1046	4.0161	3.8860	14.1514	22.8941	6.5177	18.4574	18.4795	63.6154	6.7945	7.7341		
6.0	415	219.5411	0.5695	0.9614	1.2482	1.2482	0.8910	1.2503	1.0309	10.1016	21.5588	4.4222	9.9950	15.7456	22.5235	4.4521	3.4978		
6.0	1141	243.5445	1.0680	0.2885	0.4870	0.4870	0.1463	1.1954	1.0817	8.4637	13.7641	3.7325	8.9048	14.2780	20.5154	4.0147	2.0732		
6.2	403	153.2111	15.2626	3.1046	12.5112	12.5112	2.1461	8.9043	10.1042	21.3907	31.8229	9.3063	18.6501	23.8793	41.9990	7.3464	8.2326		
6.2	203	385.4127	3.1738	0.0161	3.0082	3.0082	3.9480	1.5696	1.9329	4.4123	19.9540	2.0672	6.6802	10.0060	18.3091	2.9291	2.8666		
6.8	214	439.0501	2.5317	0.0099	3.0082	3.0082	0.2703	1.2112	0.9406	5.6233	23.8411	2.7779	10.3759	11.3530	39.9703	4.0584	6.4389		
6.8	340	174.9356	12.4058	2.1565	5.6598	5.6598	0.9353	7.0049	5.8452	27.9340	41.1640	12.4353	28.9227	27.0417	91.4976	10.1601	17.5942		
4.8	192	110.7637	3.6437	2.0358	3.1901	3.1901	2.1074	1.7563	1.7599	11.4627	26.7194	4.8447	4.0861	17.4057	6.9190	4.1197	2.1145		
4.8	348	248.2582	0.6185	0.1106	0.3591	0.3591	0.2336	0.2957	0.4566	3.1356	11.5027	1.3020	1.6711	8.1397	3.3465	1.8457	0.3896		
6.1	350	194.4802	3.2809	0.6094	1.2482	1.2482	1.0154	1.6207	1.6642	9.3036	22.3888	4.1194	10.0751	14.9607	24.0108	4.3458	3.8397		
6.1	507	192.6567	1.6944	1.6884	2.0160	2.0160	1.1312	2.3340	2.3692	13.6180	23.3142	5.9441	12.9531	18.5113	29.4235	5.4427	4.5934		
5.2	265	57.2967	2.0810	7.8573	9.1201	9.1201	3.8716	6.8344	6.7174	37.9016	48.2606	18.0891	15.2849	39.7373	22.7868	9.9863	10.4464		
5.6	480	159.8751	1.1070	2.7282	1.3372	1.3372	1.7085	2.3812	1.1163	12.3683	21.4363	5.2721	8.6880	18.1205	16.4663	4.6542	2.8108		
				R ²	0.6894	0.5664	0.5664	0.5610	0.6038	0.7579	0.3829	0.1047	0.1791	0.3426	0.2981	0.1655	0.1899	0.2096	
				R	0.8303	0.7526	0.7526	0.7490	0.7771	0.8706	0.6188	0.3236	0.4232	0.5854	0.5460	0.4068	0.4358	0.4578	

VF, Veri formunu; RM, regresyon modelini; M, magnitüdü; Vs30, S-dalga hızı; Repi, deprem ile istasyon arasındaki uzaklığı; PGA, Maksimum yer hareketinin ivmesini ifade etmektedir.

VF, Veri formunu; RM, regresyon modelini; M, magnitudü; Vs30, S-dalga hızı; Repi, deprem ile istasyon arasındaki uzaklığı; PGA, Maksimum yer hareketinin ivmesini ifade etmektedir



Şekil 5. 16. Veri seti 1 için farklı 6 denklem formuna göre test verisiyle hesaplanan PGA ve ölçülen PGA arasındaki fark (hata) değerleri **a)** Farklı veri formuna göre toplam hatalar, **b)** 8 farklı PGA tahmin denklemi fark (hata) değerleri


Tablo 5.10. Veri seti-2 için oluşturulan regresyon modelleri içerisinde seçilen en iyi regresyon modelleriyle hesaplanan PGA, R ve R² değerleri.

Test Verisi				Seçilen PGA tahmin denklemleri													
M	Vs30	Repi	PGA	VF-1	VF-2	VF-3	VF-4	VF-5	VF-6	Esteva 1973	Boore 1997	Sadigh 1998	Özbey 2004	Kalkan 2004	Inan 1996	Beyaz 2004	Akkar 2014
				W-10	YSA- TLBO	W- 6-10-3	W-10	YSA- TLBO	YSA- TLBO								
5.2	1323	50.0517	28.2846	5.9566	18.6242	7.3790	5.7412	19.0133	10.0973	44.2455	29.8229	21.8563	17.5874	45.0287	25.7349	11.4051	7.6504
5.2	323	79.1236	21.3458	5.0234	8.9593	4.6989	5.0699	10.4084	2.8940	25.2847	35.0039	11.2966	10.8376	29.4183	17.0422	7.2636	5.6684
5.5	192	194.5010	2.3107	2.6546	2.3670	2.3496	2.4660	2.0010	0.6007	8.2946	24.4517	3.5309	6.1237	14.4486	11.8842	3.5885	2.1426
5.5	301	210.4178	3.5651	1.6368	0.8288	1.4588	1.4962	1.7366	0.5105	7.2737	19.5303	3.1052	5.6110	13.4160	11.0720	3.3181	1.5715
5.6	199	299.3061	0.6088	1.3062	1.0864	1.0046	1.3032	1.1185	0.2586	4.2918	18.1500	1.8882	4.3253	10.0329	9.3647	2.4917	1.4841
5.6	346	385.5095	0.5814	0.3273	0.4837	0.3475	0.3819	1.0590	0.1497	2.7290	12.1913	1.2352	3.2613	8.2294	7.4571	1.9355	0.7894
5.7	314	111.2830	4.3049	5.9704	2.7873	5.7677	5.6885	4.9055	3.3826	23.3879	34.8250	10.1262	14.7377	26.5370	26.4981	7.1266	6.9116
5.7	316	145.7723	2.3244	3.8019	1.6088	3.6308	3.5481	3.0883	1.5817	15.5099	28.1811	6.6402	10.9435	20.5865	20.7822	5.4505	4.5251
5	519	108.6941	1.7384	1.6558	1.4900	1.5488	1.7179	4.0489	1.1570	13.8286	20.8534	5.8922	5.6972	19.7746	9.4932	4.7074	1.9981
5	579	111.5369	0.3744	1.4825	1.2410	1.3836	1.5453	3.8192	1.1024	13.3146	19.6423	5.6584	5.5380	19.3008	9.2752	4.5883	1.8248
5.9	216	169.9164	1.3122	5.1404	3.2727	4.4668	4.7973	2.0593	1.3536	14.2549	31.7430	6.1486	11.8124	19.2835	24.4224	5.3599	5.6607
5.9	480	317.8763	0.0598	0.8279	1.0471	0.6745	0.8091	1.2476	0.2163	4.9045	14.5942	2.2068	5.8831	10.6831	13.8985	2.8711	1.5899
6	226	132.0886	12.7967	8.2604	5.5578	7.1779	8.1658	2.7588	3.7732	22.9772	39.8988	9.9454	17.5579	25.4101	35.5813	7.3813	9.3977
6	407	201.9869	0.8138	2.6607	1.7119	2.3281	2.5293	1.5718	0.8700	11.6203	23.1635	5.0630	10.9657	17.0325	24.2778	4.8375	3.9938
6.2	282	376.5037	1.7412	1.5066	2.3462	1.2794	1.4421	2.7832	0.1281	4.6031	18.0284	2.1498	6.8569	10.2292	18.6985	2.9983	2.6034
6.2	292	130.9468	14.0257	8.6696	5.8947	8.1658	9.0157	2.4653	6.4171	27.3254	40.4185	11.8898	22.1857	27.6826	48.3743	8.5873	11.6761
6.2	341	126.7773	17.1441	8.1470	4.8672	8.0910	8.5704	2.5618	7.3713	28.7088	39.1703	12.4988	22.9920	28.5381	49.8038	8.8678	11.5381
6.2	303	381.0869	2.3684	1.3366	2.3331	1.1614	1.2912	2.8818	0.1232	4.5034	17.3989	2.1067	6.7649	10.1131	18.4960	2.9623	2.4846
6.5	192	369.5543	1.4263	4.0179	9.9158	2.8642	4.1783	7.6310	0.1709	6.0520	24.4238	2.8662	9.5382	11.7337	29.7913	3.8171	5.1780
6.5	358	185.3979	3.7279	5.5847	6.7221	5.9293	6.2661	2.7153	3.2905	19.9811	33.2644	8.8367	20.5657	22.4888	55.4250	7.5934	10.4462
6.5	540	408.5638	1.1240	0.9226	2.5483	0.8570	0.9661	9.8841	0.1174	5.0451	15.5055	2.4239	8.5276	10.6736	27.2186	3.4532	2.9963
5.2	696	73.0990	12.5239	3.9537	3.3239	2.9854	3.9446	11.7541	3.5278	28.0502	28.1412	12.7091	11.8024	31.6778	18.3012	7.8548	4.7226
5.2	234	49.5502	28.7320	11.5080	78.7195	10.3514	12.8529	19.2180	10.4089	44.7425	56.4627	22.1619	17.7702	45.4487	25.9692	11.5183	13.7800
5.2	236	51.9471	66.5823	10.7895	71.1016	9.7499	11.9124	18.2608	9.0358	42.4402	54.2824	20.7592	16.9265	43.5104	24.8883	10.9964	12.7381
5.2	549	85.0499	5.0817	3.3884	2.3527	2.7669	3.3963	9.2526	2.4308	22.9449	27.2896	10.1337	10.0227	27.4958	15.9696	6.7629	4.0391
5.5	356	156.0020	1.0744	2.4044	0.9947	2.2803	2.2542	3.0490	0.9636	11.8731	23.1771	5.0426	7.8218	17.7858	14.4938	4.4694	2.8185
5.5	265	149.7993	9.8818	3.1769	1.9677	3.1046	2.9309	3.2985	1.0546	12.6618	26.6317	5.3805	8.1812	18.4784	15.0328	4.6534	3.3929
5.5	357	216.0997	1.0234	1.3552	0.6285	1.1940	1.2647	1.6582	0.4834	6.9545	17.9784	2.9725	5.4471	13.0832	10.8096	3.2311	1.6603
5.4	234	208.0272	1.4308	1.7418	1.2390	1.5631	1.6181	1.7260	0.4726	6.8445	20.5479	2.9069	4.9610	12.9894	9.6315	3.1488	1.7748
5.4	219	195.5261	1.1071	2.0417	1.6300	1.8707	1.8967	1.9478	0.5323	7.5904	22.0870	3.2170	5.3148	13.7708	10.1839	3.3493	2.0176

R² 0.5793 0.6759 0.5836 0.6022 0.5801 0.6657 0.6601 0.4746 0.6913 0.3111 0.6577 0.0731 0.6124 0.5013

R 0.7611 0.8221 0.7640 0.7760 0.7617 0.8159 0.8125 0.7782 0.8315 0.5577 0.8110 0.2704 0.7825 0.7080


W; WEKA ile farklı norön sayılarıyla oluşturulan modelleri; VF, Veri formunu; RM, regresyon modelini; M, magnitudü; Vs30, S-dalga hızını, Repi; deprem ile istasyon arasındaki uzaklık; PGA, Maksimum yer hareketinin ivmesini ifade etmektedir.



Şekil 5. 17. Veri seti-2 için farklı 6 denklem formuna göre test verisiyle hesaplanan PGA ve ölçülen PGA arasındaki fark (hata) değerleri **a)** Farklı veri formuna göre seçilen en iyi modele göre toplam farklar (hatalar), **b)** 8 farklı PGA tahmin denkleminin fark(hata) değerleri

Veri seti-2 için; 6 farklı veri formuna göre eğitilerek oluşturulan farklı regresyon modelleri içerisinde R ve R^2 değerlerine göre seçilen en iyi modeller kullanılarak, test giriş verileriyle yapılan PGA tahminleri, R ve R^2 sonuçları Tablo 5.10'da verilmiştir. Tablo incelendiğinde, oluşturulan regresyon modelleri içerisinde en yüksek $R= 0.8221$ ve $R^2 = 0.6759$ değerleri ile 2. veri formu için oluşturulan YSA-TLBO modelidir. Bu model test verilerine en yakın PGA tahminlerini yapmıştır. En düşük $R= 0.7611$ ve $R^2= 0.5793$ değerleri ise 1. veri formu için oluşturulan 10 nöronlu WEKA (W-10) modele aittir. Ayrıca 8 farklı ivme tahmin denklemiyle hesaplanan PGA değerleri, R ve R^2 değerleri de Tablo 5.10'da verilmiştir. Regresyon modelleri ve 8 farklı ivme tahmin denklemiyle hesaplanan PGA değerleri ile ölçülen PGA değerleri arasında farklar (hatalar) grafiksel olarak Şekil 5.17'de verilmiştir. Grafikler incelendiğinde, her bir test verisi için oluşturulan toplam hatayı gösteren bir sütundaki en küçük alana sahip model veya denklemin, ölçülen PGA'ya en yakın değeri verdiği anlamına gelmektedir. Ayrıca grafik her bir test verisi için toplam hatalar göz önüne alınarak değerlendirildiğinde, regresyon modellerinin sonuçlarının tahmin denklemleri sonuçlarına göre daha düşük fark (hata) değerine sahip oldukları ve gerçeğe daha yakın sonuçlar verdiği gözlenmiştir.

Veri seti-1 ve 2 kullanılarak eğitilen YSA ve regresyon modelleriyle hesaplanan PGA değerlerinin, ölçülen PGA değerleri ile arasındaki R^2 değerlerine bakılarak modeller içinden en iyi sonuç veren seçilmiştir. Bu seçilen modeller, literatürde yine R^2 değerlerine bakılarak en iyi sonuç veren PGA tahmin denklemleriyle karşılaştırılmıştır. Literatürdeki tahmin denklemleri genel olarak 2 (M ve Repi) veya 3 (M, Repi ve Vs30) bağımsız değişkene göre oluşturulmuştur. Bu karşılaştırmalar yapılırken PGA tahmin denklemlerinin bağımsız değişkenleri göz önüne alınarak yapılmıştır. Bu kriterlere göre; 1. Veri seti için 2-bağımsız değişkene göre Esteva (1973) denklemi ve VF-6'ya göre eğitilen RM-3 algoritmasıyla, 3-bağımsız değişken için Akkar vd. (2014)'nin oluşturduğu denklem ve VF-1 göre eğitilen YSA-PSO algoritmasıyla yapılan PGA tahmin sonuçları seçilmiştir. Veri seti 2 için ise 2 -bağımsız değişkene göre Sadigh (1998)'in oluşturduğu denklem ve VF-6 göre eğitilen YSA-TLBO algoritmasıyla, 3-bağımsız değişken için Akkar vd. (2014)'nin oluşturduğu denklem ve VF-2 göre eğitilen YSA-TLBO algoritmasıyla yapılan PGA tahmin sonuçları seçilmiştir. Yapılan PGA tahminleri veri sayısına göre toplam hatalar şeklinde 1. Veri seti ve 2. Veri setine göre Şekil 5.18'de verilmiştir.



Şekil 5. 18. YSA ve regresyon modelleriyle en iyi hesaplanan ve gerçek PGA arasındaki toplam fark (hata) değerleri **a)** 1. Veri seti için 2-bağımsız değişkene göre Esteva (1973) denklemi ve VF-6 eğitilen RM-3 modeli, 3-bağımsız değişkene göre Akkar (2014) oluşturduğu denklem ve VF-1 eğitilen YSA-PSO modeli ile, **b)** 2. Veri seti için 2-bağımsız değişkene göre Sadigh (1998) denklemi ve VF-6 eğitilen RM-3 modeli, 3-bağımsız değişkene göre Akkar (2014) oluşturduğu denklem ve VF-1 eğitilen YSA-PSO modeli ile yapılan hesaplamalar.

Yapılan karşılaştırmalar sonucunda daha küçük magnitüdlü ($M \geq 3.0$) depremler kullanılarak yapılan PGA tahminlerinde, literatürden seçilen denklemler daha yüksek hata değerleriyle gerçekten uzak tahminler yapmışlardır. Bu hata paylarının, 2. Veri setinde daha büyük magnitüdlü ($M_w \geq 5.0$) depremler ile yapılan hesaplamalarda azaldığı görülmüştür. Oluşturulan YSA ve regresyon modelleri, her 2 veri seti içinde literatürden seçilen denklemlerden daha az hata değerleriyle, ölçülen PGA değerine daha yakın değerler vermişlerdir.

5.4. Magnitüd Türü Dönüşümü ve PGA Tahmini İçin Kullanıcı Arayüzü Tasarlanması

Tez kapsamında belirlenen magnitüd türü dönüşümü ve gerçeğe yakın PGA tahmini problemleri için regresyon yöntemleri ve makine algoritmaları kullanılarak oluşturulan denklemler ve regresyon modellerinin kolay uygulanabilir bir yapıya getirilmesi için Matlab programlama dili kullanılarak 2 arayüz tasarlanmıştır. Bu sayede, kullanıcılara farklı yöntemlerle geliştirilen denklemlerin ve modellerin, depremler üzerinde yapılan farklı çalışmalarda ve mühendislik uygulamalarında kullanılmasında kolaylık sağlanması amaçlanmıştır.

Tasarlanan 1. Arayüz; magnitüd türü dönüşümü için magnitüdü $M \geq 4.0$ olan depremlerin farklı magnitüd türü bilgilerini içeren veri setiyle LR, OR ve makine öğrenmesi algoritmaları içerisinde seçilen en iyi üç algoritmaya göre oluşturulan denklem ve regresyon modellerini içermektedir. Bu sayede tez kapsamında belirlenen 1. problem için çözümler üretilmektedir. Tasarlanan 1. Arayüzün genel görünümü Şekil 5.19'da verilmiştir.


		METHOD				
		Linear	Orthogonal	Reg. Model1	Reg. Model2	Reg. Model3
1- Afad Mw	4.6	4.7	4.7	4.8	4.8	4.7
2- Koeri ML	5.1	5.1	5.1	5.1	5.1	5
3- Koeri Mw	4.5	4.6	4.6	4.6	4.6	4.6
4- Koeri ML	5.1	5.2	5.2	5.1	5.2	5.1
5- Koeri Ms	5.3	5.6	5.6	5.6	5.6	5.6
6- Koeri Md	5.2	5.5	5.5	5.4	5.4	5.4
7- Koeri Mw	4.4	5	4.8	5	5	5
8- Koeri Mb	5.5	5.7	5.8	5.7	5.7	5.7

Şekil 5. 19. Magnitüd türü dönüşümü için tasarlanan arayüzün genel görünümü.

Bu arayüzün çalışma adımları;

- Veri grubunda tanımlanan 8 farklı denklem formu içerisinde seçim butonu yardımıyla seçim yapılması ve magnitüd değerinin girilmesi,
- Seçilen denklem formunun çıkış verisinin giriş magnitüd değerine göre hesaplanması ve “method” grubu altında sonucun gösterilmesi,
- Bir sonraki denklem formu seçimi ve hesaplama işlemine başlamadan önce ‘Veri Temizle’ butonu yardımıyla hafızada yer alan bir önceki verilerin silinmesi şeklindedir.

Arayüzün arka planında, hafızasında yer alan YSA ağlarıyla ve regresyon modellerini kullanarak yaptığı hesaplama adımları akış diyagramı Şekil 5.20’de verilmiştir.



Şekil 5. 20. Magnitüd türü dönüşümü için tasarlanan arayüzün hesaplama adımları akış diyagramı.

Tasarlanan 2. Arayüz; PGA tahmini için 2 farklı veri seti (magnitüdü $M \geq 3.0$ olan depremlere ait 56384 parametre ve magnitüdü $M_w \geq 5.0$ olan depremlere ait 4024 parametre) 6 farklı veri formuna göre eğitilen YSA-Multi, YSA-PSO, YSA-TLBO modellerini ve en iyi 3 makine öğrenme algoritmasına göre oluşturulan regresyon modellerini kullanarak hesaplamalar yapmaktadır. Arayüzün genel görünümü Şekil 5.21’de verilmiştir.

The screenshot shows a software window titled 'Pga_predicted'. It contains several input fields and buttons. At the top, there are four input fields labeled 'Magnitude', 'Vs30', 'Repi', and 'PGA' with values 6.8, 450, 23.81, and 292.80 respectively. To the right of these fields is a red button labeled 'Veri temizle'. Below these fields are two sections: 'Veri Setleri' with radio buttons for 'Veri $M \geq 3$ ' (selected) and 'Veri $M_w \geq 5$ '; and 'Veri Formları' with six radio buttons for different regression models, with 'Mag-Vs30-Repi = LogPga' selected. To the right of these is a 'Yöntemler' section with six radio buttons for different machine learning models, with '6-Reg_Learner_Model3' selected. On the far right, there is a table with two columns: 'Hesaplanan PGA' and 'Hatalar'. The table contains six rows of data, each corresponding to a model number and its calculated PGA value and error.

	Hesaplanan PGA	Hatalar
1-	143.8684	148.9316
2-	6.7384	286.0616
3-	205.7586	87.0414
4-	51.9822	240.8178
5-	196.8702	95.9298
6-	82.1777	210.6223


Şekil 5. 21. PGA tahmini için tasarlanan arayüzün genel görünümü.

Arayüzün çalışma adımları;

- Deprem magnitüd, Vs30 hızı, istasyon ve deprem arasındaki uzaklık (Repi) ve varsa depremin ölçülen PGA değerinin girilmesi,
- Veri seti grubundan hangi veri setine göre eğitilmiş YSA ve regresyon modellerinin kullanılacağını seçilmesi,
- Veri Formları grubundan 6 veri formu içerisinde hangi veri formuna göre eğitilmiş YSA ve regresyon modelinin seçiminin yapılması,
- Seçilen veri seti ve veri formuna göre eğitilen YSA-Multi, YSA-PSO, YSA-TLBO ve en iyi 3 makine öğrenme algoritmasının yöntem grubundan seçilmesi,

- Seçilen yönteme göre girilen magnitüd, Vs30 ve Repi değerinin giriş verisi olarak eğitilen ağlara veya regresyon modeline gösterilip, PGA tahminin yapılması,
- Ölçülen PGA değeri var ise hesaplanan PGA değeri arasındaki farkın (hata) hesaplanması,
- Bir sonraki hesaplama işlemine başlamadan önce “Veri Temizle” butonu yardımıyla hafızada yer alan bir önceki verilerin silinmesi şeklindedir.

Tasarlanan arayüzün arka planında yaptığı hesaplamaların adımlarının akış diyagramı Şekil 5.22’de verilmiştir.



Şekil 5. 22. PGA tahmini için tasarlanan arayüzün hesaplama adımları akış diyagramı.


PGA tahmini için tasarlanan arayüz ile 24.01.2020 tarihinde saat 17:55:11’de meydana gelen Sivrice (Elazığ) depreminin ($M_w=6.8$) Elazığ ve civarındaki 20 istasyonda kaydedilen parametreleri kullanılarak PGA tahminleri yapılmıştır. Bu PGA tahminleri, 2-bağımsız (M ve Repi) ve 3-bağımsız (M, Repi ve Vs30) değişkene göre oluşturulan veri formları dikkate alınarak ve 20 istasyonda ölçülen PGA değerlerine en yakın sonucu veren algoritmalarla hesaplanan PGA değerleri seçilerek oluşturulmuştur. Ayrıca, AFAD tarafından oluşturulan Türkiye tehlike haritalarından, istasyon konumlarına göre PGA değerleri alınmıştır. Bu değerler, deprem yer hareketi düzeyi-2 (DD-2); büyüklüklerin 50 yılda aşılma olasılığının %10 ve buna karşı gelen tekrarlanma periyodunun 475 yıl olduğu seyrek deprem yer hareketine göre, deprem yer hareketi düzeyi-3 (DD-3); büyüklüklerin 50 yılda aşılma olasılığının %50 ve buna karşı gelen tekrarlanma periyodunun 72 yıl olduğu sık deprem yer hareketine ve deprem yer hareketi düzeyi-4 (DD-4); büyüklüklerin 50 yılda aşılma olasılığının %68 (30 yılda aşılma olasılığı %50) ve buna karşı gelen tekrarlanma periyodunun 43 yıl olduğu çok sık deprem yer hareketine göre hesaplanan haritalardan AFAD uygulaması üzerinden alınmıştır. Arayüz kullanılarak YSA ve regresyon modellerinden hesaplanan PGA değerleri, AFAD uygulaması üzerinden alınan PGA değerleri ve ölçülen PGA değerleri Tablo 5.11’de karşılaştırılmıştır.

Tablo 5. 11. Sivrice'de (Elazığ) 24.01.2020 tarihinde meydana gelen depremin ($M_w=6.8$) parametrelerine göre hesaplanan PGA, Türkiye deprem tehlike haritaları (AFAD) uygulamasından alınan PGA değerleri ve 20 istasyonda ölçülen PGA değerlerinin karşılaştırması.


İstasyon Kod	Boylam (°D)	Enlem (°K)	M	Vs	Repi	Ölçülen PGA	Veri Seti-1 ($M \geq 3.0$)				Veri Seti-2 ($M_w \geq 5.0$)				AFAD	
							VF-5	VF-1	VF-5	VF-1	VF-5	VF-1	DD-2	DD-3	DD-4	DD-4
2308	39.3102	38.45063	6.8	450	23.8141	292.8034	202.3952	205.7599	196.4351	203.5289	609.5600	225.4000	142.1000			
4404	38.87385	38.19588	6.8	1380	24.5522	228.4459	199.9005	171.5961	191.7025	190.3015	637.9800	232.2600	141.1200			
2301	39.19267	38.67043	6.8	407	36.3891	137.7792	124.7779	137.1124	124.2739	141.8413	375.3400	145.0400	97.0200			
0204	39.03472	38.02897	6.8	555	36.8141	110.1164	110.3984	106.0507	119.2255	90.8253	363.5800	146.0200	103.8800			
0212	38.62409	38.0277	6.8	481	53.2052	43.52172	37.6852	62.2730	54.8260	43.9542	533.1200	189.1400	121.5200			
2302	39.67541	38.39231	6.8	907	53.5109	31.36289	37.4681	44.5746	31.5545	35.7998	468.4400	181.3000	124.4600			
4401	38.34019	38.34962	6.8	481	63.0363	87.63077	84.7227	60.2069	58.3445	59.1448	343.9800	134.2600	90.1600			
0205	38.61597	37.79177	6.8	660	74.2530	41.01224	38.8053	38.5897	35.5038	40.4415	198.9400	75.4600	52.9200			
0207	38.24763	38.03225	6.8	660	79.9972	31.5595	32.5820	30.1237	29.8936	30.2542	570.3600	205.8000	124.4600			
2304	39.86293	38.72096	6.8	489	80.3587	13.74563	29.3350	11.4169	7.7754	21.1481	617.4000	235.2000	147.0000			
4407	38.26406	38.78066	6.8	735	83.7825	31.04924	30.5015	30.7681	32.6910	25.5165	350.8400	95.0600	61.7400			
2307	39.93199	38.69583	6.8	329	84.3469	20.82823	25.5572	18.0026	21.5752	22.0703	639.9400	249.9000	151.9000			
4406	37.97378	38.34388	6.8	815	94.9961	24.02365	24.2309	24.0482	24.5138	23.4765	387.1000	108.7800	71.5400			
0201	38.26742	37.76121	6.8	391	96.3033	44.61344	48.9380	35.4223	24.3332	34.9889	240.1000	97.0200	64.6800			
2305	40.13103	38.72778	6.8	907	101.5205	4.789889	14.8198	4.9928	7.2894	6.8235	654.6400	257.7400	154.8400			
4408	37.88732	38.09616	6.8	654	106.7817	16.24286	17.8108	16.1715	16.2712	16.2100	456.6800	153.8600	98.0000			
2306	40.03927	38.95945	6.8	663	107.8835	5.417577	13.6627	6.9863	7.2079	8.9059	526.2600	199.9200	129.3600			
4405	37.9396	38.8107	6.8	579	109.7893	11.59503	13.6212	10.0824	12.3366	10.7093	204.8200	76.4400	52.9200			
2101	40.20278	37.93088	6.8	519	110.4708	26.38894	21.4101	24.7689	22.5136	20.2895	138.1800	59.7800	43.1200			
6304	38.51316	37.36509	6.8	376	120.6286	77.71162	61.3834	27.3527	21.3522	19.0443	147.9800	53.9000	36.2600			

M, magnitüd; Vs30 (m/sn), S dalga hızı, Repi (km); deprem ile istasyon arasındaki uzaklık; PGA(cm/sn²), Maksimum yer hareketinin ivmesini; M, VF-5, M-Repi →LogPGA; VF-1, M-Vs30-Repi →LogPGA; DD-2, deprem yer hareketi düzeyi-2; DD-3, deprem yer hareketi düzeyi-3 ve DD-4, deprem yer hareketi düzeyi-4'ü ifade etmektedir.


Tablo 5.10'daki sonuçlar incelendiğinde, daha küçük magnitüdlü depremlerin parametrelerini içeren 1. veri seti için VF-1 (2-bağımsız değişken; M ve Repi) ve VF-5 (3-bağımsız değişken; M, Repi ve Vs30) veri formlarına göre eğitilen YSA ve regresyon modellerinin tahmin ettiği PGA değerlerinin, ölçülen (gerçek) PGA değerlerine yakın olduğu gözlenmiştir. AFAD tarafından oluşturulan Türkiye tehlike haritaları uygulamasından; DD-2, DD-3 ve DD-4 deprem yer hareketi düzeylerine göre 20 istasyon noktası için alınan PGA değerlerinin, ölçülen PGA değerlerden daha yüksek olduğu görülmüştür. 1. Veri setine göre VF-1 ve VF-5 için hesaplanan değerler, AFAD uygulamasından; DD-3 düzeyine göre alınan değerler ve 20 istasyonda ölçülen PGA değerleri harita üzerinde istasyon konumlarına göre karşılaştırılmıştır (Şekil 5.23-5.26).




Şekil 5. 23. AFAD tarafından oluşturulan Türkiye tehlike haritaları uygulamasından; DD-3 deprem yer hareketi düzeyine göre 20 deprem istasyonu konumu için alınan PGA (cm/sn²) değerleri.



Şekil 5. 24. Sivrice (Elazığ) depreminin episantır noktası ve civarındaki 20 deprem istasyonunda ölçülen PGA (cm/sn²) değerleri.



Şekil 5. 25. 1.Verı setı için; VF-1 veri formuna göre eğitilen YSA ve regresyon modellerinin hesapladığı PGA (cm/sn²) değerleri.



Şekil 5. 26. 1. Veri seti için, VF-5 veri formuna göre eğitilen YSA ve regresyon modellerinin hesapladığı PGA (cm/sn²) değerleri.

Haritalar incelendiğinde 1. Veri seti için, VF-5 (2-bağımsız değişken; M ve Repi için) veri formuna göre eğitilen YSA ve regresyon modellerinin, VF-1 (3-bağımsız değişken; M, Repi ve Vs30) veri formuna göre eğitilen modeller ile genel olarak yakın sonuçlar verdiği gözlenmiştir. Bu iki veri formuna göre hesaplanan PGA değerlerinin, ölçülen PGA değerleri ile oldukça yakın, uyumlu sonuçlar verdiği görülmüştür.

6. SONUÇLAR VE TARTIŞMA

Bu tez kapsamında, depremlerin magnitüd (büyüklük) türü dönüşümlerinde ve maksimum yer hareketi (PGA) tahmininde farklı YZ teknikleri kullanılarak daha düşük hata değerlerine sahip hesaplamalar yapabilmek için denklemler ve modeller oluşturulmuştur. YSA'lar, Meta-Sezgisel algoritmalar (PSO ve TLBO) ve makine öğrenme algoritmaları (Tablo 5.2) gibi farklı YZ teknikleri içerisinde yer alan yöntemler kullanılarak denklemler, YSA ve regresyon modelleri oluşturulmuştur. Bu bağlamda;

- Magnitüd türü dönüşümlerinde LR, OR ve eğitim veri setleri için hesaplanan hata (RMSE, R^2 , MSE ve MAE) değerlerine göre seçilen en iyi 3 makine öğrenme algoritması kullanılmıştır (Tablo 5.3). PGA tahmini için YSA-Multi, YSA-PSO, YSA-TLBO hibrit algoritmaları, WEKA yazılımı ile oluşturulan modeller ve hata değerlerine göre seçilen en iyi 3 makine öğrenme algoritması kullanılmıştır.
- Yapılan hesaplamalarda, magnitüd türü dönüşümü için Türkiye ve civarında 1900-2020 yılları arasında meydana gelmiş magnitüd $M \geq 4.0$ olan depremlerin magnitüd parametreleri (Tablo 4.1), PGA tahmini için eğitilen YSA ve regresyon modellerinde 1976–2020 yılları arasında magnitüdü $M \geq 3.0$ olan depremlerin (M , V_{s30} (m/sn), R_{epi} (km) ve PGA (cm/sn²)) 56384 parametresi (Şekil 4.6, Şekil 4.7) ile magnitüdü $M_w \geq 5.0$ olan depremlerin 4024 parametresi (Şekil 4.8, Şekil 4.9) kullanılmıştır.
- Bu veri setleri hesaplamalarda; magnitüd türü dönüşüm için 8 farklı denklem formuna (Tablo 4.1) göre, PGA tahmini için de 6 farklı veri formuna (Tablo 5.4) göre düzenlenmiştir.
- Magnitüd türü dönüşümü için oluşturulan denklemler ve regresyon modelleri rastgele seçilen 10 depremin parametrelerin içeren test verileriyle, PGA tahmini için oluşturulan YSA ve regresyon modelleri rastgele seçilen 30 depremin parametrelerini içeren test verileriyle test edilmiş ve ölçülen (gerçek) ile hesaplanan PGA değerleri arasındaki farklara (hatalara) bakılmıştır (Tablo 5.7, Tablo 5.8 ve Tablo 5.9).
- Aynı test verileri kullanılarak literatürde daha önceden oluşturulan magnitüd türü dönüşümü ve PGA tahmini için oluşturulan denklemlerle hesaplamalar yapılmış ve sonuçları bu tez kapsamında hesaplanan sonuçlarla karşılaştırılmıştır.

- Sismik tehlike ve risk değerlendirmelerinde, mühendislik sismolojisi ve mühendislik problemleri çözümünde kullanılması amacıyla, magntüd türü dönüşümü için oluşturulan tüm denklem ve regresyon modellerini içeren Matlab programlama dilinde bir arayüz, PGA tahmini için oluşturulan tüm YSA ve regresyon modellerini içeren bir arayüz olmak üzere iki arayüz tasarlanmıştır.
- PGA tahmini için tasarlanan arayüz kullanılarak, DAFZ üzerinde 24.01.2020 tarihinde saat 17:55:1'de meydana gelen Sivrice (Elazığ) ($M_w=6.8$) depreminin 20 deprem kayıt istasyonundaki parametreleri (V_{s30} , Repi ve PGA) kullanılarak PGA tahminleri yapılmış ve ölçülen PGA değerleriyle karşılaştırılmıştır.

Magnitüd türü dönüşümü için; farklı magnitüd türlerinden (ML, Ms, Md ve mb) moment magnitüd (M_w) türüne dönüşüm için LR ve OR regresyon yöntemleriyle 8 farklı denklem oluşturulmuştur (Tablo 5.1). Kullanılan LR yönteminin OR yöntemine göre, veri setlerine düşük standart sapma (σ) değerleriyle daha iyi uyum sağlayan doğru denklemleri oluşturduğu gözlenmiştir. Seçilen en iyi üç makine öğrenme algoritması (Tablo 5.3) uygulanarak, bu 8 denklem formu için doğrusal ve doğrusal olmayan yaklaşımlarla regresyon modelleri oluşturulmuştur. Bu algoritmaların R^2 değerleri incelendiğinde, bir denklem formu (GMTMw-KRDAE M_w) hariç $R^2= 0.5900$ değerinden yüksek değerler hesaplanmıştır. GRM Matern 5/2, Kuadratik DVM ve Torbalama (Bagged) TA makine öğrenme algoritmaları 8 denklem formuna göre en az RMSE değerlerine sahip, verilere en iyi uyum gösteren regresyon modellerini oluşturmuşlardır. (Tablo 5.3). Genel olarak bu algoritmalar veri setleri ile doğrusal olmayan bir yaklaşım göstererek regresyon modellerini oluşturmuşlardır (Şekil 5.3).

Magnitüd türü dönüşümü için; regresyon yöntemleriyle oluşturulan denklemler, makine öğrenmesi algoritmalarıyla oluşturulan regresyon modelleri ve literatürde yer alan magnitüd türü değişim denklemleri (Ulusay vd., 2004; Scordilis, 2006; Çıvgın, 2015; Kadirioğlu ve Kartal, 2016; Tang vd., 2016) kullanılarak, rastgele seçilen 10 test verisiyle yapılan hesaplamaların sonuçları R^2 değerlerine göre karşılaştırılmıştır (Tablo 5.7-5.8). Böylece, oluşturulan denklem ve modellerin güvenilirliği gerçek veriyle de test edilmiştir. Gerçek deprem magnitüd değerleri ile 8 denklem formuna göre hesaplanan magnitüdler arasındaki R^2 değerleri incelendiğinde, genelde yöntemler ve literatürden seçilen denklem sonuçları birbirine yakın değerlere sahip olmasına rağmen, makine öğrenmesi yaklaşımıyla yapılan hesaplamalarda daha yüksek R^2 değerleri elde edilmiştir (Tablo 5.7, Tablo 5.8). Özellikle, 3. denklem formu için literatürdeki denklemlerin determinasyon değerleri

$R^2=0.7666$ iken, makine öğrenmesi yaklaşımıyla oluşturulan RM-1 ve RM-2 modellerinin determinasyon değerleri sırasıyla, $R^2=0.8270$ ve $R^2=0.8334$ olarak hesaplanmıştır (Tablo 5.7). Bunun anlamı, literatürden seçilen denklemlere göre makine öğrenmesi algoritmalarıyla oluşturulan regresyon modellerinin daha az hata değerleri verdiği ve gerçek değerlere daha çok yaklaştığı gözlenmiştir.

PGA tahmini için; YSA modelleri YSA Multi, YSA-PSO ve YSA-TLBO algoritmalarıyla iki veri setine (1. eğitim veri seti $M \geq 3.0$ depremlerin 56384 parametresi ve 2. eğitim veri seti $M_w \geq 5.0$ depremilerin 4024 parametresi) ve 6 farklı veri formuna (Tablo 5.4) göre eğitilmiştir. YSA modellerinin 2 farklı eğitim veri setine göre korelasyon katsayıları (R), YSA Multi için Şekil 5.5-5.6'da, YSA-PSO için Şekil 5.7-5.8'de ve YSA-TLBO için Şekil 5.8-5.9'da verilmiştir. YSA-Multi için hesaplanan R değerlerine göre en iyi veri-model uyumu; 1. veri seti için 4. veri formunda ($R=0.8101$), 2. veri seti için 2. veri formu için ($R=0.8267$) gözlenmiştir. YSA-PSO algoritması için en iyi veri-model uyumu; 1. veri seti için 3. veri formunda ($R=0.7678$), 2. veri seti için 1. veri formunda ($R=0.7222$) hesaplanmıştır. YSA-TLBO algoritmasında ise en iyi veri-model uyumu; 1. veri seti için 6. veri formunda ($R=0.7702$), 2. veri seti için 1. veri formunda ($R=0.7485$) hesaplanmıştır. Yukarıda belirtilen veri formları için bu üç YSA algoritması, diğer veri formlarına göre giriş verisiyle daha tutarlı (anamlı) modeller üretmişlerdir. Farklı nöron ve katman sayısı (10 nöron, 6-10 nöron ve 6-10-3 nöron) dikkate alınarak WEKA yazılımıyla aynı 6 veri formuna göre oluşturulan YSA modelleri R ve RMSE değerleri Tablo 5.5'de verilmiştir. Bu değerlere göre eğitim veri seti-1 ($M \geq 3.0$) için, tüm veri formları için 6-10 nöronlu 2 katmanlı YSA modellerinin test verisiyle daha uyumlu olduğu gözlenmiştir. Veri formu 2 ile eğitilen 6-10 nöronlu YSA, en düşük $RMSE=0.4633$ ve en yüksek $R=0.8087$ değeriyle en iyi uyuma sahip modeli üretmiştir. Veri formu-6'nın en düşük veri-model uyumuna sahip olduğu gözlenmiştir. Eğitim veri seti-2 ($M_w \geq 5.0$) için, veri formu-4 hariç diğer veri formlarında 6-10-3 nöronlu YSA modelleri en iyi veri-model uyumuna sahiptir. Tüm veri formları için, anlamlı veri-model uyumu gösteren yüksek korelasyon ($R \geq 0.7474$) değerleri hesaplanmıştır. Nöron ve katman sayıları açısından WEKA modelleri incelendiğinde, birbirlerine yakın R ve RMSE hata değerlerine sahip olduğu gözlenmiştir (Tablo 5.5).

PGA tahmini için; regresyon modelleri 2 farklı eğitim veri seti ve 6 farklı veri formuna göre en iyi 3 makine öğrenmesi algoritması ile oluşturulmuştur (Tablo 5.6). Eğitim veri seti-1 ve veri seti-2 için GRM, TA ve RA makine öğrenmesi algoritmaları diğer algoritmalarından daha düşük RMSE ve daha yüksek R^2 değerlerine sahip, daha iyi veri-model uyumu

içerisinde regresyon modelleri üretmişlerdir (Tablo 5.6). Bu algoritmalar, her iki veri seti içinde en düşük $R^2=0.6200$ değeriyle giriş verileri arasında anlamlılık düzeyi yüksek ilişkiye sahip regresyon modelleri üretmişlerdir.

PGA tahmini için; YSA modelleri (YSA Multi, YSA-PSO, YSA-TLBO, W 10, W 6-10 ve W 6-10-3) ve makine öğrenmesi algoritmalarıyla oluşturan regresyon modelleri kullanılarak rastgele seçilen 30 depreme ait parametrelerle (M, Vs30 (m/sn), R_{epi} (km) ve PGA) hazırlanan test verileriyle PGA tahminleri yapılmış ve gerçek PGA değerleri arasındaki R ve R^2 değerleri göre karşılaştırılmıştır. Farklı 6 veri formuna göre yapılan bu hesaplamalardan, R ve R^2 değerlerine göre seçilen en iyi modeller ve literatürden seçilen 8 farklı PGA tahmin denklemleri (Esteve ve Villaverde, 1973; İnan vd., 1996; Boore vd., 1997; Sadigh ve Egan 1998; Özbey vd., 2003; Kalkan ve Gülkan, 2004; Beyaz, 2004; Akkar vd.,2014) ile aynı test verileri kullanılarak PGA tahmini yapılmıştır. Veri seti-1 için YSA ve Regresyon modelleri literatürdeki denklemlerden ölçülen PGA değerlerine daha yakın PGA değerleri hesaplamışlardır (Tablo 5.9). Bu veri seti için 30 test verisine göre ölçülen PGA ve hesaplanan PGA arasındaki toplam farkları (hataları) gösteren Şekil 5.16 incelendiğinde, YSA ve Regresyon modelleri literatürdeki denklemlerden daha az fark (hata) değerleriyle ölçülen değere daha çok yaklaşmışlardır. Veri Seti-2'ye göre yapılan PGA hesaplama sonuçları incelendiğinde, YSA ve Regresyon modellerinin R^2 değerleri, 0.5793 ile 0.6759 arasında daha dar bir aralıkta, literatürdeki denklemlerle yapılan PGA tahminlerinde ise R^2 değerleri 0.0731 ile 0.6913 daha geniş bir aralıkta değişmektedir (Tablo 5.10). Bu hesaplamaların toplam hata grafikleri de incelendiğinde, YSA ve Regresyon modellerinin literatürdeki denklemlerden gerçek PGA değerine daha yakın PGA değerleri hesaplandığı gözlenmiştir (Şekil 5.16, Şekil 5.17). Literatürdeki PGA tahmin denklemlerinin bağımsız değişken sayılarına göre yapılan karşılaştırmalarda da YSA ve Regresyon modellerinin daha düşük fark (hata) değerleriyle PGA tahmini yaptığı görülmüştür (Şekil 5.18). Ayrıca YSA ve Regresyon modellerinde, daha fazla veri içeren eğitim veri setleri kullanıldığı için literatürdeki denklemlerden daha geniş magnitüd aralığında daha iyi PGA tahmini yaptığı gözlenmiştir.

Tez kapsamında yapılan değerlendirmeler ve önemli çıktılar;

- Magnitüd türü dönüşümü için; kullanılan makine öğrenmesi yöntemleri sonuçlarının literatürdeki denklemlerden hesaplanan sonuçlarından daha az hata payıyla gerçek değerlere daha yakın sonuçlar verdiği gözlenmiştir (Şekil 5.15). Ayrıca, bu sonuçların LR ve OR yöntem sonuçları ile arasındaki farklara (hatalara)

bakıldığında, birbirlerine yakın olmasına rağmen makine öğrenmesi algoritmalarının sonuçları daha iyileştirdiği ve gerçeğe daha yakın değerler hesapladığı gözlenmiştir (Şekil 5.15).

- Magnitüd türü dönüşümü için; yapılan bu detaylı karşılaştırmalar ve değerlendirmeler sonucunda, GMT Mw-KRDAE Md dönüşüm için oluşturulan denklem hariç, diğer denklemlerin değişken hata değerleri göz önüne alınarak kullanılabileceği açıkça görülmektedir.
- PGA tahmini için; kullanılan YSA modelleri ile makine öğrenmesi algoritmalarıyla oluşturulan regresyon modellerinin sonuçlarının, literatürde kullanılan denklemlerle yapılan hesaplamaların sonuçlarından her iki veri seti için de gerçeğe daha yakın PGA tahminleri yaptığı gözlenmiştir (Şekil 5.16-5.17). Özellikle, Veri seti-1 gibi çok parametre (56384 parametre) içeren bir veri seti kullanılarak makine öğrenme algoritmaları ile oluşturulan regresyon modelleri düşük fark (hata) değerleriyle tahminler yapması, tez kapsamında elde edilen önemli bir çıktıdır. Ayrıca, bu veri seti küçük magnitüdlü ($M \geq 3.0$) depremleri de içermesinden dolayı, literatürdeki oluşturulan PGA tahmin denklemlerinin sınırlı veri setlerinden daha geniş bir magnitüd aralığında tahmin yapabilmektedir. Daha homojen ve daha büyük ($M_w \geq 5.0$) depremlerin parametrelerinden oluşan veri seti- 2 yapılan PGA tahminlerinde, literatürdeki denklemlerle yapılan tahminlerden daha az fark (hata) değerleriyle gerçeğe yakın hesaplamalar yapılmıştır (Şekil 5.17). Ayrıca, bu veri seti ile literatürdeki denklemlerle yapılan hesaplamalarda görülen toplam hata değer aralığı, ilk veri seti için görülen toplam hata değer aralığından daha az olduğu gözlenmiştir. Bunun nedeni, bu denklemleri oluşturulurken genellikle magnitüdü $M \geq 5.0$ olan depremlerden oluşan veri setlerinin kullanılması olarak düşünülmektedir (Şekil 5.16-5.17).
- PGA tahmini için; her 2 veri seti için 6 farklı veri formuna göre YSA ve regresyon modelleri incelendiğinde yöntemlerin değişen R ve R^2 değerlerine sahip olduğu gözlenmiştir. Bunun sonucu, her modelin giriş veri setine göre farklı doğrulukta değerler hesaplaması anlamına gelmektedir. Test verileriyle yapılan çalışmaların sonuçlarına göre, YSA modellerini oluşturmak için kullanılan YSA Multi, YSA-PSO, YSA-TLBO kendi aralarında veri setlerine göre farklı değerler verebilirken W 10, W 6-10 ve W 6-10-3 algoritmaları kendi aralarında birbirine daha yakın sonuçlar verdiği gözlenmiştir. Oluşturulan 3 regresyon modeli için kullanılan

makine öğrenme algoritmaları ise tüm test verileriyle yapılan hesaplamalarda 3 model içerisinde birbirine yakın değerler verdiği gözlenmiştir.

- PGA tahmini için; bu karşılaştırma ve test işlemlerine ek olarak Türkiye'nin önemli tektonik yapılarından biri olan DAFZ üzerinde 24.01.2020 tarihinde saat 17:55:11'de meydana gelen Sivrice (Elazığ) depreminin parametreleri kullanılarak PGA tahminleri yapılmıştır (EK-7). Tahmin sonuçları incelendiğinde, makine öğrenmesi algoritmalarıyla oluşturulan regresyon modellerinin hem uygulanan modeller arasında hem de ölçülen PGA değerlerine daha yakın sonuçlar verdiği gözlenmiştir.
- Yaghmaei-Sabegh, (2018), Derakhshani ve Foruzan (2019), Raghucharan vd., (2019), Dhanya ve Raghukanth (2020), Asım vd., (2020), Withers vd., (2020) ve Shiuly vd., (2020)'de yaptıkları çalışmalarda YSA ve Makine öğrenme algoritmalarıyla, özellikle geniş veri setlerinde anlamlı ilişkiler kurulabileceğini ve gerçeğe yakın PGA tahminlerinin yapılabileceğini vurgulamışlardır. Bu tez kapsamında da bu yöntemler geniş veri setlerine uygulanmış ve benzer şekilde ölçülen PGA değerlerine yakın tahmin sonuçları hesaplanmıştır.
- Türkiye için deprem parametrelerinden oluşan geniş veri setleri kullanılarak PGA tahmininde ve magnitüd türü dönüşümünde YZ tekniklerinin ilk kez kullanılması bu tezin önemli bir özgün değeridir.
- Türkiye'nin önemli tektonik yapıları içermesi ve aktif depremselliğe sahip bu yapıların yıkıcı ve hasar verici depremler oluşturma potansiyelinin olması nedeniyle de özellikle PGA tahminlerinin gerçeğe yakın yapılması deprem risklerinin azaltılması açısından oldukça önemlidir. Bu tez kapsamında kullanılan yöntemlerle hesaplanan YSA ve regresyon modellerini içeren PGA tahmin arayüzü kullanılarak PGA tahmin değerlerinin iyileştirmesi ve farklı bir hesaplama yöntemi sunması önemli bir çıktıdır.

Bu sonuçlar ışığında, bu tez kapsamında uygulanan YZ teknikleri içerisinde yer alan YSA ve Makine öğrenme algoritmalarının sismoloji ve mühendislik sismoloji alanındaki problemlerin çözümünde etkin bir yeri olduğu gösterilmiştir. Sismik tehlike değerlendirme çalışmaları içerisinde yer alan istatistiksel çalışmaların önemli adımlarından biri olan magnitüd türü açısından homojen bir veri kataloğunun oluşturulmasında ve farklı deprem merkezleri tarafında verilen deprem magnitüdüleri arasındaki dönüşümde YZ teknikleriyle oluşturulan modellerin etkin bir şekilde kullanılabileceği yapılan bu çalışmanın sonucunda

görülmektedir. Bir bölgenin sismik tehlike/risk değerlendirme çalışmalarının en önemli parametrelerinden biri olan doğruya daha yakın PGA değerinin tahmininde, YZ tekniklerinin daha az ile gerçeğe daha yakın değerler tahmin ettiği bu çalışma sonuçlarında gözlenmiştir. Ayrıca, YZ tekniklerinin ilerleyen yıllarda gelişen bilgisayar teknolojiye paralel ve yeni üretilen yöntemlerle daha etkin bir şekilde sismoloji ve mühendislik sismolojisi alanında kullanılacağı düşünülmektedir.



7. KAYNAKLAR

- Abrahamson, N. A. ve Silva, W. J., 1997. Empirical Response Spectral Attenuation Relations for Shallow Crustal Earthquakes, Seismological Research Letters, 68, 94-127.
- Abrahamson, N. A. ve Silva, W., 2008. Summary of the Abrahamson&Silva NGA Ground-motion Relations, Earthquake Spectra, 24, 1, 67–97 .
- Akkar, S. ve Bommer, J.J., 2010. Empirical Equations for the Prediction of PGA, PGV, and Spectral Accelerations in Europe, the Mediterranean Region, and the Middle East, Seismological Research Letters, 81, 195-206.
- Akkar, S. ve Çağnan, Z., 2010. A Local Ground-Motion Predictive Model for Turkey, and Its Comparison with Other Regional and Global Ground-Motion Models, Bulletin of the Seismological Society of America, 100, 6, 2978–2995.
- Akkar, S., Sandıkkaya, M.A. ve Bommer, J.J., 2014. Empirical Ground-Motion Models for Point- And Extended-Source Crustal Earthquake Scenarios İn Europe and the Middle East, Bulletin of Earthquake Engineering, 12, 359–387.
- Akkar, S., Kale, Ö., Yakut, A. vd., 2018. Ground-Motion Characterization for the Probabilistic Seismic Hazard Assessment in Turkey, Bullettin of Earthquake Engineering , 16, 3439–3463.
- Aksoy, E., İnceöz, M. ve Koçyiğit, A., 2007. Lake Hazar Basin: A Negative Flower Structure on the East Anatolian Fault System (NAFS), SE Türkiye, Turkish Journal of Earth Sciences 16, 319–338.
- Aktuğ, B., Dikmen, U., Doğru, A. ve Özener, H., 2013. Seismicity and Strain Accumulation around Karlıova Triple Junction (Turkey), Journal of Geodynamics, 67, 21-29.
- Alam, M.N., 2016 Codes in MATLAB for Training Artificial Neural Network using Particle Swarm Optimization. Doi: 10.13140/RG.2.1.2579.3524
- Alkan, H. ve Balkaya, Ç., 2018. Parameter Estimation by Differential Search Algorithm from Horizontal Loop Electromagnetic (HLEM) Data, Journal of Applied Geophysics, 149, 77–94.
- Al-Tarazia E, Sandvol E (2007) Alternative models of seismic hazard evaluation along the Jordan-Dead Sea transform. Earthq Spectra 23(1):1–19
- Ambraseys, N. N., 1975. Ground motions in the near field of Small-Magnitude Earthquakes, Proceedings of the Commission on the Safety of Nuclear Installations, Organisation of Economic Cooperation in Europe, 1, 113–136.

- Ambraseys, N. N., 1978. Middle East - A Reappraisal of Seismicity, The Quarterly Journal of Engineering Geology, 11, 1, 19–32.
- Ambraseys, N. N. ve Bommer, J. J., 1991. The Attenuation of Ground Accelerations in Europe, Earthquake Engineering and Structural Dynamics, 20, 12, 1179–1202.
- Ambraseys N. N., Simpson K. A. ve Bommer J. J., 1996. The Prediction of Horizontal Response Spectra in Europe, Earthquake Engineering and Structural Dynamics, 25, 371–400.
- Ambraseys N. N., Douglas J., Sarma S. K. ve Smit P. M., 2005. Equations for the Estimation of Strong Ground Motion from Shallow Crustal Earthquakes Using Data from Europe and the Middle East: Horizontal Peak Ground Acceleration and Spectral Acceleration. Bulletin of Earthquake Engineering, 3, 1–53.
- Arias, A. 1970. A Measure of Earthquake Intensity, Design of Nuclear Power Plants, Hansen J., MIT Press, Cambridge, MA, 438–483.
- Asım, K.M., Moustafa, S.S., Niaz, I.A., Elawadi, E.A., Iqbal, T. ve Martínez-Álvarez, F., 2020. Seismicity Analysis and Machine Learning Models for Short-Term Low Magnitude Seismic Activity Predictions in Cyprus, Soil Dynamics and Earthquake Engineering 130, 105932.
- Atakan, K., Ojeda, A., Meghraoui, M., Barka, A.A., Erdik, M. ve Bodare, A. 2002. Seismic Hazard in Istanbul following the 17 August 1999 İzmit and 12 November 1999 Düzce Earthquakes. Bulletin of the Seismological Society of America, 92, 1, 466–482.
- Aydan, Ö., Sedaki, M. ve Yazar, R., 1996. The Seismic Characteristics of Turkish Earthquakes, Eleventh World Conference on Earthquake Engineering, 23–28 June, Acapulco, Mexico, 1025.
- Balkaya, Ç., 2013. An Implementation of Differential Evolution Algorithm for Inversion of Geoelectrical Data, Journal of Applied Geophysics, 98, 160–175.
- Balkaya, Ç., Ekinci, Y.L., Göktürkler, G. ve Turan, S., 2017. 3D Non-linear Inversion of Magnetic Anomalies Caused by Prismatic Bodies Using Differential Evolution Algorithm. Journal of Applied Geophysics. 136, 372–386.
- Bansal, J.C., Singh, P.K., Saraswat, M., Verma, A., Singh Jadon, S. ve Abraham, A., 2011. Inertia weight strategies in particle swarm optimization Proceedings of the 2011 Third World Congress on Nature and Biologically Inspired Computing, IEEE press, New York, 640–647.
- Barka, A.A., 1992. The North Anatolian Fault zone, Annales Tectonicae, 5, 6, 164–195.
- Bergen, K. J., Johnson, P. A., Maarten, V., ve Beroza, G. C., 2019. Machine Learning for Data-Driven Discovery in Solid Earth Geoscience. Science, 363, 6433.

- Beyaz, T., 2004. Zemin Etkisinden Arındırılmış Deprem Kayıtlarına Göre Türkiye için Yeni Bir Deprem Enerjisi Azalım Bağıntısının Geliştirilmesi, Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Bisztricsany, E., 1958. A New Method for the Determination of the Magnitude of Earthquakes, Geofiz. Kozlemen, 7, 69-96.
- Bindi, D., Weatherill, G., Kotha, S-R., Lanzano, G., Luzi, L. ve Cotton, F., 2019. The Pan-European Engineering Strong Motion (ESM) Fatfile: Consistency Check Via Residual Analysis. Bulletin of Earthquake Engineering, 17, 583–602.
- Blum, C. ve Li, X., 2008. Swarm Intelligence in Optimization, In: Swarm Intelligence, Eds: Springer, 43-85.
- Boettcher, S. ve Percus, A., 2000. Nature's Way of Optimizing, Artificial Intelligence, 119, 1-2, 275-286.
- Bonabeau, E., 1999. Dorigo, M. ve Theraulaz, G., Swarm Intelligence: From Natural to Artificial Systems, 1, Oxford University Press.
- Bommer J. J., Douglas, J. ve Strasser, F. O., 2003. Style-of-Faulting in Ground Motion Prediction Equations, Bulletin of Earthquake Engineering, 1, 171-203.
- Bommer, J. J., Akkar, S. ve Kale, Ö., 2011. A Model for Vertical-to-Horizontal Response Spectral Ratios for Europe and the Middle East, Bulletin of the Seismological Society of America, 101, 4, 1783–1806.
- Bommer, J. J., Dost, B., Edwards, B., Stafford, P. J., Van Elk, J., Doornhof, D. ve Ntinalexis, M., 2016. Developing An Application-Specific Ground-Motion Model for Induced Seismicity, Bulletin of the Seismological Society of America, 106, 1, 158-173.
- Boore, D. M., Joyner, W. B. ve Fumal. T. E., 1997. Equations for Estimating Horizontal Response Spectra and Peak Acceleration from Western North American Earthquakes: A Summary of Recent Work, Seismological Research Letters, 68, 1, 128-153.
- Boore D. M. ve Atkinson, G. M., 2008. Ground-motion Prediction Equations for the Average Horizontal Component of PGA, PGV and 5% Damped PSA at Spectral Periods Between 0.01 s and 10 s. Earthquake Spectra, 24, 1, 99–138.
- Bozkurt, E., 2001. Neotectonics of Turkey - a Synthesis, Geodinamica Acta, 14, 1-3, 3-30.
- Bozkurt, E., 2003. Origin of NE-trending basins in Western Turkey, Geodinamica Acta, 16, 61–81.
- Bozkurt, E. ve Sözbilir, H., 2006. Evolution of the large-scale active Manisa Fault, Southwest Turkey: implications on fault development and regional tectonics, Geodinamica Acta, 19, 427–453.

- Breiman, L., Friedman, J., Olshen, R., ve Stone, C., 1984. Classification and Regression Trees. Wadsworth Int. Group, 37, 15, 237-251.
- Bryson, J. T., Jin, X. ve Agrawal, S. K., 2016. Optimal Design of Cable-Driven Manipulators Using Particle Swarm Optimization, ASME, Journal of Mechanisms Robotics, 8, 4, 041003.
- Burke, K. ve Şengör, C., 1986. Tectonic Escape in the Evolution of the Continental Crust, in Reflection Seismology, M. B. A. L. Brown Editor, American Geophysical Union, Washington, D. C.
- Campbell, K. W., 1985. Strong motion attenuation relations: A ten-year perspective. Earthquake Spectra, 1,4, 759-804.
- Campbell K. W. 1997. Empirical Near-Source Attenuation Relationships for Horizontal and Vertical Components of Peak Ground Acceleration, Peak Ground Velocity, and Pseudo-Absolute Acceleration Response Spectra, Seismological Research Letters, 68, 1, 154-179.
- Campbell, K. W. 2000. Erratum: Empirical Near-Source Attenuation Relationships for Horizontal and Vertical Components of Peak Ground Acceleration, Peak Ground Velocity, and Pseudo-Absolute Acceleration Response Spectra, Seismological Research Letters, 71, 3, 352–354.
- Campbell, K. W. ve Bozorgnia, Y., 2008. NGA Ground Motion Model for the Geometric Mean Horizontal Component of PGA, PGV, PGD and 5% Damped Linear Elastic Response Spectra for Periods Ranging from 0.01 to 10s, Earthquake Spectra, 24, 1, 139–171.
- Carr, J.R., 2012. Orthogonal Regression: A Teaching Perspective, International Journal of Mathematical Education in Science and Technology, 43, 1, 134-143.
- Carroll, R.J., Ruppert, D., 1996. The Use and Misuse of Orthogonal Regression in Linear Errors in Variables Models, The American Statistician, 50, 1, 1-6.
- Chen, Z. ve Maun, J.C., 2000. Artificial neural network approach to single-ended fault locator for transmission lines, IEEE Transactions on Power Systems, 370-375.
- Ching, T., Himmelstein, D. S., Beaulieu-Jones, B. K., Kalinin, A. A., Do, B. T., Way, G. P. ve Greene, C. S., 2018. Opportunities and Obstacles for Deep Learning in Biology and Medicine. Journal of the Royal Society Interface, 15, 141.
- Çağnan, Z., Akkar, S., Kale, Ö. ve Sandıkkaya, A., 2017. A Model for Predicting Vertical Component Peak Ground Acceleration (PGA), Peak Ground Velocity (PGV), and 5% Damped Pseudospectral Acceleration (PSA) for Europe and The Middle East. Bulletin of Earthquake Engineering, 15, 2617–2643.

- Çeken, U., 2007. Marmara Bölgesinin Kuvvetli Yer Hareketi Azalim İlişkisi Modeli, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Çıvgın, B., 2015. Regression Relations for Conversion of Various Magnitude Types and Catalogs for The Earthquakes of Turkey and Vicinity, Seismological Research Letters, 86, 876-889.
- Derakhshani, A. ve Foruzan, A.H., 2019. Predicting the Principal Strong Ground Motion Parameters: A Deep Learning Approach, Applied Soft Computing, 80,192-201.
- Dewey, J., Hempton, M., Kidd, W., Şaroğlu, F. ve Şengör, A., 1986. Shortening of Continental Lithosphere: The Neotectonics of Eastern Anatolia—a Young Collision Zone, Geological Society London Special Publications, 19, 1, 1-36.
- Dhanya, J. ve Raghukanth, S.T.G., 2020. Neural Network-Based Hybrid Ground Motion Prediction Equations for Western Himalayas and North-Eastern India, Acta Geophysica, 68, 303–324.
- Drams, J.S., 2020. 70 years of machine learning in geoscience in review, Advance in Geophysics, 61, 1–55.
- Dziewonski, A. M., Chou, T.A. ve Woodhouse, J. H., 1981. Determination of Earthquake Source Parameters from Waveform Data for Studies of Global and Regional Seismicity, Journal of Geophysical Research, 86, 2825-2852.
- Ekinci, Y.L., Özyalın, Ş., Sındırgı, P., Balkaya, G. ve Göktürkler, G., 2017. Amplitude inversion of 2D analytic signal of magnetic anomalies through differential evolution algorithm, Journal of Geophysical Engineering, 14, 1492–1508.
- Ekström, G., Nettles, M. ve Dziewonski, A. M., 2012. The Global CMT Project 2004-2010: Centroid-Moment Tensors for 13,017 Earthquakes, Physics of the Earth and Planetary Interiors, 200-201, 1-9.
- Erdik, M., Doyuran, V., Akkaş, N. ve Gülkan, P. 1985. A Probabilistic Assessment of the Seismic Hazard in Turkey, Tectonophysics, 117, 3–4, 295-344.
- Erdik M., Biro, Y.A., Onur, T., Sesetyan, K.ve Birgoren, G., 1999. Assessment of Earthquake Hazard in Turkey and Neighboring Regions, Annals of Geophysics, 42, 1125–1138.
- Esteva, L. ve Villaverde, L., 1973. Seismic Risk, Design Spectra and Structural Reliability, Proceedings of Fifth World Conference on Earthquake Engineering, 2, 2586-2596.
- Fogel, D. B., 2006. Evolutionary Computation: Toward A New Philosophy of Machine Intelligence, John Wiley & Sons.

- Frank, E., Hall, M.A. ve Witten, I.H., 2016. The WEKA Workbench, Online Appendix for "Data Mining: Practical Machine Learning Tools and Techniques, Morgan Kaufmann, Fourth Edition.
- Fukushima, Y. ve Tanaka, T., 1990. A New Attenuation Relation for Peak Horizontal Acceleration of Strong Earthquake Ground Motion in Japan, Bulletin of the Seismological Society of America, 80, 757-783.
- Garnier, S., Gautrais, J. ve Theraulaz, G., 2007. The Biological Principles of Swarm Intelligence, Swarm Intelligence, 1, 1, 3-31.
- Gendreau, M. ve Potvin, J. Y., 2010. Handbook of Metaheuristics, Springer.
- Giardini, D., Danciu, L., Erdik, M. vd., 2018. Seismic Hazard Map of the Middle East, Bulletin of Earthquake Engineering, 16, 3567–3570.
- Göktürkler, G. ve Balkaya, Ç., 2012. Inversion of Self-Potential Anomalies Caused by Simple Geometry Bodies Using Global Optimization Algorithms, Journal of Geophysics and Engineering, 9, 498–507.
- Gutenberg, B., 1945a. Amplitudes of Surface Waves and Magnitudes of Shallow Earthquakes, Bulletin of the Seismological Society of America, 35, 3-12.
- Gutenberg, B., 1945b. Magnitude Determination of Deep-Focus Earthquakes, Bulletin of the Seismological Society of America, 35, 117-130.
- Gülerce, Z., Kamai, R., Abrahamson, N. A. ve Silva, W. J., 2017. Ground Motion Prediction Equations for the Vertical Ground Motion Component Based on the NGA-W2 Database, Earthquake Spectra, 33, 2, 499-528.
- Gülkan, P. ve Kalkan, E., 2002. Attenuation Modeling of Recent Earthquakes in Turkey, Journal of Seismology, 6, 397-409
- Güllü, H. ve Erçelebi, E., 2007. A Neural Network Approach for Attenuation Relationships: An Application Using Strong-Ground-Motion Data From Turkey, Engineering Geology 93, 3, 65–81.
- Günaydın, K. ve Günaydın A., 2008. Peak ground acceleration prediction by artificial neural networks for northwestern Turkey, Mathematical Problems in Engineering, ID 919420.
- Güvenç, U., Sönmez, Y., Duman, S., Yörükeren, N. 2012. Combined economic and emission dispatch solution using gravitational search algorithm, Scientia Iranica, 1754-1762.
- Hanks, T. C. ve Kanamori, H., 1979. A Moment Magnitude Scale, Journal of Geophysical Research, 84, 2348-2350.

- Hara, S., Fukahata, Y. ve Iio, Y., 2019. P-wave First-Motion Polarity Determination of Waveform Data in Western Japan Using Deep Learning, Earth Planets Space, 71, 127.
- Havskov, J. ve Ottemöller, L., 2010. Array Processing, Routine Data Processing in Earthquake Seismology, Springer.
- Heaton, T.H., Tajima, F. ve Mori, A.W., 1986. Estimating ground motions using recorded accelerograms, Surveys in Geophysics, 8, 25-83.
- Husid, R., Medina, H. ve Rios, J. 1969. Analisis de Terremotos Nor-teamericanosy Japoneses; Revista DEL IDIEM 8.Chile.
- Heris, S.M.K., 2015. Teaching-Learning-based Optimization in MATLAB, Yarpiz, Project Code: YPEA111.
- Idriss, I. M., 1995. Evaluating Seismic Risk in Engineering Practice, Proceedings of the Eleventh International Conference on Soil Mechanics and Foundation Engineering, Vol.I. San Francisco, 255-320.
- Idriss I. M., 2008. An NGA Empirical Model for Estimating the Horizontal Spectral Values Generated by Shallow Crustal Earthquakes, Earthquake Spectra, 24, 1, 217-242.
- İnan, E., Çolakoğlu, Z., Koç, N., Bayülke, N. ve Çoruh, E., 1996. 1976-1996 Yılları Arası İvme Kayıtları Olan Deprem Kataloğu, T.C. Bayındırlık ve İskan Bakanlığı Afet İşleri Genel Müdürlüğü Deprem Araştırma Dairesi Başkanlığı, Ankara, 98 s.
- Jemei, S., Hissel, D., Pera, M. ve Kauffmann, J.M., 2008. A new modeling approach of embedded fuel-cell power generators based on artificial neural network, IEEE Transactions on Industrial Electronics, 437-447.
- Joyner, W. B. ve Boore, D. M., 1988. Measurement, Characterization, and Prediction of Strong Ground Motion, Earthquake Engineering and Soil Dynamics II, Proceedings American Society Civil Engineering Geotechnical Engineering Division Specialty Conference, 43-102.
- Kadirioğlu, F.T. ve Kartal, R.F., 2016. The New Empirical Magnitude Conversion Relations Using An Improved Earthquake Catalogue for Turkey and Its Near Vicinity (1900–2012). Turkish Journal of Earth Science, 25, 4, 300–310.
- Kaftan, I., Şalk, M. ve Şenol, Y., 2017. Processing of Earthquake Catalog Data of Western Turkey with Artificial Neural Networks and Adaptive Neuro-Fuzzy Inference System, Arabian Journal of Geoscience, 10, 243.
- Kahraman, H.T., 2014. Metaheuristic Linear Modeling Technique for Estimating the Excitation Current of a Synchronous Motor, Turkish Journal of Electrical Engineering & Computer Sciences, 22, 1637-1652.

- Kalafat, D., Kekovalı, K., Güneş, Y., Yılmaz, M., Kara, M., Deniz, P. ve Berberoğlu, M., 2009. Türkiye ve çevresi faylanma-kaynak parametreleri (MT) kataloğu (1938-2008). Boğaziçi Üniversitesi Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü, İstanbul.
- Kale, O., Akkar, D. S., Ansari, A. ve Hamzehloo, H., 2015. A Ground-Motion Predictive Model for Iran and Turkey for Horizontal PGA, PGV, and 5% Damped Response Spectrum: Investigation of Possible Regional Effects, Bulletin of the Seismological Society of America, 105, 963-980.
- Kalkan, E. ve Gülkan, P., 2004. Empirical attenuation equations for vertical ground motion in Turkey, Earthquake Spectra, 20, 4, 1111-1138.
- Kanamori, H., 1977. The Energy Release in Great Earthquakes, Journal of Geophysical Research, 82, 2981-2987.
- Kanbur, M., Silahtar, A. ve Özsoy, C., 2014. Sığ Sismik Yansıma, MASW ve ReMi Yöntemleri ile Sığ Yapıların İncelenmesi: Isparta Yerleşim Merkezi Kuzeyi Pliyo-Kuvaterner Çökel Yapı Örneği . Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 15, 3, 224-232.
- Kankal, M. ve Uzlu, E., 2017. Neural network approach with teaching-learning-based optimization for modeling and forecasting long-term electric energy demand in Turkey, Neural Computer & Application, 28, 737-747.
- Karaboğa, D. ve Baştürk, B., 2007. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (abc) algorithm, Journal of Global Optimization 39, 3, 459-471.
- Karaboğa, D., 2014. Yapay Zekâ Optimizasyon Algoritmaları, Ankara, Nobel Akademik Yayıncılık.
- Karaboğa, N. ve Latifoglu, F., 2013. Elimination of noise on transcranial Doppler signal using IIR filters designed with artificial bee colony-ABC-algorithm, Digital Signal Processing, 23, 3, 1051-1058.
- Kavzoğlu, T. ve Çölkesen, İ., 2010. Karar ağaçları ile uydu görüntülerinin sınıflandırılması: Kocaeli örneği, Harita Teknolojileri Elektronik Dergisi, 2, 36-45.
- Kennedy, J. ve Eberhart, R., 1995. Particle Swarm Optimization, Proceedings of ICNN'95-International Conference on Neural Networks, Perth, WA, Australia, 4, 1942-1948.
- Ketin İ., 1957. Kuzey Anadolu Deprem Fayı, İTÜ Dergisi, 15, 49-52.
- Ketin İ., 1976. San Andreas ve Kuzey Anadolu Fayları Arasında Bir Karşılaştırma, Türkiye Jeoloji Kurumu Bülteni, 19, 149-154.

- Kotsiantis, S. B., 2013. Decision Trees: A Recent Overview, Artificial Intelligence Review, 39, 4, 261-283.
- Koçyiğit, A. ve Beyhan, A., 1998. A New Intracontinental Transcurrent Structure: The Central Anatolian Fault Zone, Turkey, Tectonophysics, 284, 3-4, 317-336.
- Köse, U., 2015. Present State of Swarm Intelligence and Future Directions, In: Encyclopedia of Information Science and Technology, Third Edition, Eds: IGI Global, 239-252.
- Kramer, S. L., 1996. Geoteknik Deprem Mühendisliği, Kayabalı, K., Gazi Kitabevi, Ankara, 708, 2003.
- Kuyuk, H.S., Yıldırım, E., Dogan, E. ve Horasan, G., 2011. An Unsupervised Learning Algorithm: Application to the Discrimination of Seismic Events and Quarry Blasts in the Vicinity of Istanbul, Natural Hazards and Earth System Sciences, 11, 1, 93-100.
- Kürçer, A. ve Gökten, Y.E., 2014. Tuz Gölü Fay Zonu'nun Neotektonik Dönem Özellikleri, Depremselliği, Geometrisi ve Segment Yapısı, Maden Tetkik ve Arama Dergisi, 149, 19-69.
- Lachet, C., Hatzfeld, D. Ve Bard, P.Y., Theodulidis, N., Papaioannou, C. ve Savvaidis, A., 1996. Site Effects and Microzonation in the City of Thessaloniki-Comparison of Different Approaches, Bulletin of the Seismological Society of America, 86, 6, 1692-1703.
- Lary, D. J., Alavi, A. H., Gandomi, A. H. ve Walker, A. L., 2016. Machine Learning in Geosciences and Remote Sensing, Geoscience Frontiers, 7, 1, 3-10.
- Le Pichon, X. ve Angelier, J., 1979. The Hellenic Arc and Trench System: a Key to the Neotectonic Evolution of the Eastern Mediterranean Area, Tectonophysics, 60, 1-2, 1-42.
- Le Pichon, X., Chamot-Rooke, N., Rangin, C. ve Şengör A.M.C., 2003. The North Anatolian fault in the Sea of Marmara, Journal of Geophysical Research, 108, B4, 2179.
- Lou, H.L., 1995. Implementing the Viterbi algorithm, IEEE Signal processing magazine, 12, 42-52.
- Ludbrook, J., 2010. Linear Regression Analysis for Comparing Two Measurers or Methods of Measurement: But Which Regression?, Clinical and Experimental Pharmacology and Physiology, 37, 7, 692-699.
- Nacar, S., Hınıs, M. A. ve Kankal, M., 2018. Forecasting Daily Streamflow Discharges Using Various Neural Network Models and Training Algorithms, Ksce Journal Of Civil Engineering, 22, 9, 3676-3685.

- Mange, D. ve Tomassini, M., 1998. Bio-Inspired Computing Machines: Towards Novel Computational Architectures, Presses Polytechniques et Universitaires Romandes.
- Marrow, P., 2000. Nature-Inspired Computing Technology and Applications, BT Technology Journal, 18, 4, 13-23.
- Matlab, 2018. R2018a, Natick, Massachusetts: The MathWorks Inc.
- McClusky, S., Balassanian, S., Barka, A., Demir, C., Ergintav, S., Georgiev, I., Gurkan, O., Hamburger, M., Hurst, K., Kahle, H., Kastens, K., Kekelidze, G., King, R., Kotzev, V., Lenk, O., Mahmoud, S., Mishin, A., Nadariya, M., Ouzounis, A., Paradissis, D., Peter, Y., Prilepin, M., Reilinger, R., Sanli, I., Seeger, H., Tealeb, A., Toksöz, M. N. ve Veis, G., 2000. Global Positioning System Constraints on Plate Kinematics and Dynamics in the Eastern Mediterranean and Caucasus, Journal of Geophysical Research: Solid Earth, 105, B3, 5695-5719.
- McKenzie, D., 1978. Active Tectonics of the Alpine-Himalayan Belt: the Aegean Sea and Surrounding Regions, Geophysical Journal International, 55, 1, 217-254.
- Özbey, C., Sarı, A., Manuel, L., Erdik, M. ve Fahjan, Y., 2003. Empirical Strong Ground Motion Attenuation Relations for Northwestern Turkey, Fifth National Conference on Earthquake Engineering, Istanbul, Turkey.
- Özener, H., Arpat, E., Ergintav, S., Doğru, A., Çakmak, R., Turgut, B. ve Doğan, U., 2010. Kinematics of the eastern part of the North Anatolian Fault Zone, Journal of Geodynamics, 49, 141-150.
- Öztürk, S., 2012. İstatistiksel Regresyon Yöntemlerinin Farklı Veri Gruplarına Uygulanması Üzerine Bir Analiz, Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 2, 2, 55-67.
- Öztürk, S., Ghassemi, M. R. ve Sarı, M., 2020. A comparison of alternative curve fitting techniques for different earthquake fault parameters of Iranian earthquakes, Earth Sciences Research Journal, 24, 4, 459-472.
- Parpinelli, R. S. ve Lopes, H. S., 2011. New Inspirations in Swarm Intelligence: A Survey, International Journal of Bio-Inspired Computation, 3, 1, 1-16.
- Pekşen, E., Yas, T., Kayman, A.Y. ve Özkan, C., 2011. Application of particle swarm optimization on self-potential data, Journal of Applied Geophysics, 75, 2, 305-318.
- Pekşen, E., Yas, T. ve Kıyak, A., 2014. 1-D DC Resistivity Modeling and Interpretation in Anisotropic Media Using Particle Swarm Optimization, Pure and Applied Geophysics, 171, 2371-2389.

- Rao, R. V., Savsani, V. J. ve Vakharia, D. P., 2011. Teaching-Learning Based Optimization: A Novel Method for Constrained Mechanical Design Optimization Problems, Computer-Aided Design, 43, 303-315.
- Rani, B. K., Srinivas, K. ve Govardhan, A., 2014. Rainfall Prediction with TLBO Optimized ANN, Journal of Scientific & Industrial Research, 73, 10, 643–647.
- Raghucharan, M., Somala, S.N. ve Rodina S., 2019. Seismic Attenuation Model Using Artificial Neural Networks, Soil Dynamics and Earthquake Engineering, 126.
- Reilinger, R., McClusky, S., Vernant, P., Lawrence, S., Ergintav, S., Cakmak, R., Ozener, H., Kadirov, F., Guliev, I. ve Stepanyan, R., 2006. GPS Constraints on Continental Deformation in the Africa-Arabia-Eurasia Continental Collision Zone and Implications for the Dynamics of Plate Interactions, Journal of Geophysical Research: Solid Earth, 111.
- Reilinger, R., McClusky, S., Paradissis, D., Ergintav, S. ve Vernant, P., 2010. Geodetic Constraints on the Tectonic Evolution of the Aegean Region and Strain Accumulation along the Hellenic Subduction Zone, Tectonophysics, 488, 1-4, 22-30
- Richter, C. F., 1935. An Instrumental Earthquake Magnitude Scale, Bulletin of the Seismological Society of America, 25, 1-32.
- Sadigh, R. K.ve Egan, J. A., 1998. Updated Relationships for Horizontal Peak Ground Velocity and Peak Ground Displacement for Shallow Crustal Earthquakes. In Proceedings of the Sixth U.S. National Conference on Earthquake Engineering.
- Sadigh, K., Chang, S.Y., Egan, J. A., Makdısı, F. ve Youngs, R. R., 1997. Attenuation Relationships for Shallow Crustal Earthquakes Based on California Strong Motion Data, Seismological Research Letters, 68, 1, 180-189.
- Sandıkkaya, M.A., Akkar, S. ve Bard, P-Y., 2013. A Nonlinear Site Amplification Model for the New Pan-European Ground-Motion Prediction Equations, Bulletin of the Seismological Society of America, 103, 19–32.
- Satapathy S.C., Naik A. ve Parvathi K., 2012. Teaching Learning Based Optimization for Neural Networks Learning Enhancement, In: Panigrahi B.K., Das S., Suganthan P.N., Nanda P.K. (eds) Swarm, Evolutionary, and Memetic Computing, Lecture Notes in Computer Science, Springer, Berlin, Heidelberg.
- Schutt, K. T., Arbabzadah, F., Chmiela, S., Muller, K. R. ve Tkatchenko, A., 2017. Quantum-Chemical Insights from Deep Tensor Neural Networks, Nature Communication, 8, 13890.
- Scordilis, E.M., 2006. Empirical Global Relations Converting MS and mb to Moment Magnitude. Journal of Seismology, 10, 225–236.


- Selçuk, L., Selçuk, A.Z. ve Beyaz, T., 2010. Probabilistic Seismic Hazard Assessment for Lake Van Basin, Turkey, Natural Hazards, 54, 949–965.
- Sesetyan, K., Demircioglu, M.B., Duman, T.Y. vd., 2018. A Probabilistic Seismic Hazard Assessment for the Turkish Territory—part I: the Area Source Model, Bulletin of Earthquake Engineering, 16, 3367–3397.
- Seyitoğlu, G. ve Scott, B., 1991. Late Cenozoic crustal extension and basin formation in west Turkey, Geological Magazine, 128, 155–166.
- Shadbolt, N., 2004. Nature-Inspired Computing, IEEE Intelligent Systems, 19, 1, 2-3.
- Shen, D., Wu, G. ve Suk, H. I., 2017. Deep Learning in Medical Image Analysis. Annual Review of Biomedical Engineering, 19, 221–248.
- Shen, C., 2018. A Transdisciplinary Review of Deep Learning Research and Its Relevance for Water Resources Scientists, Water Resources Research, 54, 11, 8558–8593.
- Shiuly, A., Roy, N. ve Sahu, R.B., 2020. Prediction of Peak Ground Acceleration for Himalayan Region Using Artificial Neural Network and Genetic Algorithm. Arabian Journal of Geosciences 13, 215.
- Sianko, I., Ozdemir, Z., Khoshkholghi, S. vd., 2020. A Practical Probabilistic Earthquake Hazard Analysis Tool: Case Study Marmara Region, Bulletin of Earthquake Engineering, 18, 2523–2555.
- Sönmez, M., 2011. Artificial Bee Colony algorithm for optimization of truss structures, Applied Soft Computing, 2406-2418.
- Statgraphics, 2005. Centurion XV User Manual.
- Stein, S. ve Wysession, M., 2003. An Introduction to Seismology, Earthquakes, and Earth Structure, Oxford: Blackwell Science.
- Şaroğlu, F., Emre, O. ve Kuşcu, I., 1992. Active Fault Map of Turkey, Mineral Research and Exploration Institute (MTA) of Turkey Publications, Ankara.
- Şengör, A. M. C., 1979. The North Anatolian Transform: Its Age, Offset and Tectonics Significance, J. Geol. Soc. London, 136, 269-282.
- Şengör, A. M. C. ve Kidd, W. S. F., 1979. Post-Collisional Tectonics of the Turkish-Iranian Plateau and a Comparison with Tibet, Tectonophysics, 55, 3-4, 361-376.
- Şengör A.M.C., Tuysuz, C., Sakıncı, M., Eyidoğan, H., Görür, N., Le Pichon, X ve Rangin, C., 2005. The North Anatolian Fault: a new look, Annual Review of Earth and Planetary Sciences, 33, 37–112.

- Tang, C., Zhu, L. ve Huang, R., 2016. Empirical MW-ML, mb, and Ms Conversions in western China, Bulletin of the Seismological Society of America, 106, 6, 2614-2623.
- Taymaz, T. ve Price, S., 1992. The 1971 May 12 Burdur earthquake sequence, SW Turkey: a synthesis of seismological and geological observations. Geophysical Journal of International, 108, 589–603.
- Trifunac, M. D. ve Brady, A. G., 1976. Correlations of Peak Acceleration, Velocity and Displacement with Earthquake Magnitude, Distance and Site Conditions, Earthquake Engineering and Structural Dynamics, 4, 5, 455–471.
- Ulusay, R., Tuncay, E., Sonmez, H. ve Gokceoglu, C., 2004. An Attenuation Relationship Based on Turkish Strong Motion Data and Iso-Acceleration Map of Turkey, Engineering Geology, 74, 265-291.
- Ulutaş, E., ve Özer, M. F., 2010. Empirical Attenuation Relationship of Peak Ground Acceleration for Eastern Marmara Region in Turkey, Arabian Journal for Science and Engineering, 35, 1A, 187–203.
- Uzlu, E., Akpinar, A., Öztürk, H. T., Nacar, S. ve Kankal, M., 2014. Estimates of Hydroelectric Generation Using Neural Networks with the Artificial Bee Colony Algorithm for Turkey. Energy, 69, 638-647.
- Valentine, A. P. ve Kalnins, L. M., 2016. An Introduction to Learning Algorithms and Potential Applications in Geomorphometry and Earth Surface Dynamics, Earth Surface Dynamics, 4, 445–460.
- Vapnik, V. N., 1995. The Nature of Statistical Learning, Theory.
- Wang, Z., Di, H., Shafiq, M. A., Alaudah, Y., ve AlRegib, G., 2018. Successful Leveraging of Image Processing and Machine Learning in Seismic Structural Interpretation: A review, The Leading Edge, 37, 6, 451–461.
- Weise, T., Global Optimization Algorithms – Theory and Application, <http://www.it-weise.de/projects/book.pdf>. 10 Şubat 2021.
- Westaway, R., 1993. Neogene evolution of the Denizli region of western Turkey, Journal of Structural Geology, 15, 37-53.
- Withers, K. B., Moschetti, M. P. ve Thompson, E. M., 2020. A Machine Learning Approach to Developing Ground Motion Models from Simulated Ground Motions, Geophysical Research Letters, 47.
- Wuest, T., Weimer, D., Irgens, C. ve Thoben, K. D., 2016. Machine learning in manufacturing: advantages, challenges, and applications, Production & Manufacturing Research, 4,1, 23-45.


- Yaghmaei-Sabegh, S., 2018. Earthquake ground-motion duration estimation by using of general regression neural network, Scientia Iranica, 25, 5, 2425-2439.
- Yang, X.-S., 2010. Nature-Inspired Metaheuristic Algorithms, Luniver Press.
- Yalçın, H., Gülen, L. ve Utkucu, M., 2013. Türkiye ve Yakın Çevresinin Aktif Fayları Veri Bankası ve Deprem Tehlikesinin Araştırılması, Yerbilimleri, 34, 3, 141-168.
- Yılmaz, B., Aras, E., Nacar, S. ve Kankal, M., 2018. Estimating suspended sediment load with multivariate adaptive regression spline, teaching-learning based optimization, and artificial bee colony models, Science of the Total Environment, 639, 826-840.
- Yılmaz, B., Aras, E., Kankal, M. ve Nacar, S., 2019. Prediction of Suspended Sediment Loading by Means of Hybrid Artificial Intelligence Approaches, Acta Geophysica 67, 1693–1705.
- Yolsal, S ve Taymaz, T. 2010. Sensitivity Analysis on Relations Between Earthquake Source Rupture Parameters and Far-Field Tsunami Waves: Case Studies in the Eastern Mediterranean Region, Turkish Journal of Earth Sciences, 19, 3, 313-349.
- Yönlü, O., Altunel, E. ve Karabacak, V., 2017. Geological and geomorphological evidence for the southwestern extension of the east Anatolian fault zone, Turkey, Earth Planet Science Letter, 469, 1–14.
- Yu, Y. ve Xinjie Y., 2007. Cooperative co-evolutionary genetic algorithm for digital IIR filter design, IEEE Transactions on Industrial Electronics, 54, 1311-1318.
- Zhang, Z. vd., 2018. Exploring the Clinical Features of Narcolepsy Type 1 Versus Narcolepsy Type 2 from European Narcolepsy Network Database with Machine Learning, Scientific Reports, 8, 10628.
- Zhu, L., Peng, Z., McClellan, J., Li, C., Yao, D., Li, Z. ve Fang, L., 2019. Deep Learning for Seismic Phase Detection and Picking in the Aftershock Zone of 2008 Mw 7.9 Wenchuan Earthquake, Physics of the Earth and Planetary Interiors, 293, 106261.
- URL-1, <https://tadas.afad.gov.tr/waveform-detail/50813> Dalga formları. 1 Şubat 2021.
- URL-2, <http://www.koeri.boun.edu.tr/sismo/zeqdb/> Deprem kataloğu. 15 Haziran 2020.
- URL-3, <https://deprem.afad.gov.tr/> Deprem kataloğu. 15 Haziran 2020.

8. EKLER


EK-1 Makine öğrenmesi algoritmalarıyla magnitüd türü dönüşüm için oluşturulan doğrusal ve doğrusal olmayan en iyi 2. regresyon modelleri karşılaştırmaları; **a)** AFAD Mw - KRDAE ML, **b)** AFAD Mw – KRDAE Mw, **c)** GMT Mw - KRDAE mb, **d)** GMT Mw - KRDAE ML, **e)** GMT Mw - KRDAE Ms, **f)** GMT Mw - KRDAE Mw, **g)** GMT Mw- AFAD Mw, **h)** GMT Mw - KRDAE Md arasındaki regresyon modelleri.




EK-2 Makine öğrenmesi algoritmalarıyla magnitüd türü dönüşüm için oluşturulan doğrusal ve doğrusal olmayan en iyi 3. regresyon modelleri karşılaştırmaları; **a)** AFAD Mw - KRDAE ML, **b)** AFAD Mw – KRDAE Mw, **c)** GMT Mw - KRDAE mb, **d)** GMT Mw - KRDAE ML, **e)** GMT Mw - KRDAE Ms, **f)** GMT Mw - KRDAE Mw, **g)** GMT Mw- AFAD Mw, **h)** GMT Mw - KRDAE Md arasındaki regresyon modelleri.



EK-3 Makine öğrenmesi algoritmalarıyla 1. eğitim veri setine ($M \geq 3.0$) göre 6 farklı veri formunda (Tablo 5.4) eğitilerek oluşturulan en iyi 2. regresyon modelleri **a)** VF-1, **b)** VF-2, **c)** VF-3, **d)** VF-4, **e)** VF-5, **f)** VF-6; en iyi 3. regresyon modelleri **g)** VF-1, **h)** VF-2, **i)** VF-3, **j)** VF-4, **k)** VF-5, **l)** VF-6'ya göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği.



EK-4 Makine öğrenmesi algoritmalarıyla 2. eğitim veri setine ($Mw \geq 5.0$) göre 6 farklı veri formunda (Tablo 5.4) eğitilerek oluşturulan en iyi 2. regresyon modelleri **a)** VF-1, **b)** VF-2, **c)** VF-3, **d)** VF-4, **e)** VF-5, **f)** VF-6; en iyi 3. regresyon modelleri **g)** VF-1, **h)** VF-2, **i)** VF-3, **j)** VF-4, **k)** VF-5, **l)** VF-6'ya göre eğitilen regresyon modelin gerçek ve hesaplanan değerler grafiği.



EK-5 Veri seti 1 ($M \geq 3.0$ olan depremlerin 56384 parametresi) için 6 veri formuna göre oluşturulan YSA ve regresyon modellerinin test verilerine göre PGA tahmin sonuçları.

VF-1 (M-Vs30-Repi →LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	2.2094	0.6084	0.4940	4.9431	3.8815	4.7534	2.0156	1.7084	1.6088
3.1	709	74.9585	0.1245	0.1048	0.0389	0.1324	0.2460	0.2009	0.2228	0.1175	0.1184	0.1057
3.4	219	40.7060	0.3658	0.5711	0.7724	0.4251	1.2078	1.1066	1.2134	0.6320	0.4861	0.4477
3.4	234	46.1303	0.8801	0.4666	0.7002	0.3571	0.9863	0.9462	1.0000	0.4944	0.4419	0.4151
4.4	337	125.5637	0.4955	0.5972	1.1683	0.2733	1.0304	1.0641	1.2331	0.6433	0.5959	0.6957
5.2	1323	50.0517	28.2846	7.4223	43.8242	17.8756	11.5080	8.4528	9.0365	3.3327	6.4625	3.0606
3.6	313	73.8637	0.5081	0.3207	0.6453	0.2541	0.6531	0.6471	0.6823	0.3222	0.2987	0.2925
5.5	181	279.7177	2.8534	1.0551	0.1147	0.1994	1.5704	2.3659	2.5293	1.6971	1.1901	1.1803
4.2	348	12.3034	10.4828	13.4897	7.6503	59.4684	23.3884	21.9786	22.2331	10.2967	12.1983	13.5550
3.8	555	12.7593	4.6117	5.8262	5.7727	19.4645	9.7949	10.7647	11.8304	5.5680	8.8920	9.1033
3.8	356	30.4067	1.7876	1.7374	2.6575	3.7778	2.8840	3.2063	3.4356	2.0133	2.0526	2.0840
5.6	186	353.9452	0.2379	0.9106	0.0200	0.5154	0.8690	1.3646	1.5849	0.9931	0.6613	0.4640
5.7	243	202.4129	0.6862	2.7072	0.8528	0.3537	4.5290	4.9545	5.1880	1.9643	2.4479	3.4119
5.7	248	344.0663	1.4610	0.8606	0.0265	0.4379	0.9954	1.4825	1.6749	1.3555	0.7745	0.9561
5.9	273	193.4270	0.8385	3.6610	1.2657	0.7581	6.4714	6.5013	7.0307	1.2729	1.8950	1.4302
5.9	216	168.6507	1.5561	5.1808	1.7665	2.3275	8.9331	9.8628	9.2257	3.2734	4.4300	4.4005
6.8	195	249.3240	3.3740	7.1846	0.7314	0.5994	13.3968	12.9122	11.2980	6.2144	7.2028	4.0644
6.8	720	261.9778	4.7481	2.3241	0.4182	0.2471	6.1235	3.7584	4.4157	2.4906	3.2591	3.5678
6.0	415	219.5411	0.5695	2.4169	0.9614	0.2756	4.5186	3.8371	4.7315	0.9380	1.5937	1.5255
6.0	1141	243.5445	1.0680	1.3011	0.2885	0.0069	0.9268	1.3274	1.2618	0.6615	0.8644	1.2156
6.2	403	153.2111	15.2626	6.7807	3.1046	7.9973	12.0781	10.9648	11.8577	7.8469	7.5284	13.1583
6.2	203	385.4127	3.1738	1.7690	0.0161	0.6444	1.6181	2.9854	3.6058	2.8353	2.4177	2.7365
6.8	214	439.0501	2.5317	3.1701	0.0099	0.1688	2.5293	4.8641	5.3211	3.1391	2.2983	1.6742
6.8	340	174.9356	12.4058	12.0049	2.1565	28.9409	18.4077	18.5780	17.3780	4.6602	6.6757	4.1639
4.8	192	110.7637	3.6437	1.9653	2.0358	1.1047	3.0761	3.9446	3.7584	2.4099	2.1223	1.9182
4.8	348	248.2582	0.6185	0.2762	0.1106	0.0641	0.5598	0.5140	0.5495	0.6020	0.3655	0.3933
6.1	350	241.4802	3.2809	2.6694	0.6094	0.2702	4.7534	4.3451	5.1523	2.3774	2.0142	1.5311
6.1	507	192.6567	1.6944	2.8987	1.6884	0.6923	6.0954	4.8417	6.0256	2.4519	2.8432	2.7791
5.2	265	57.2967	2.0810	7.6577	7.8573	62.0452	13.1220	13.5207	15.0314	8.1979	7.8037	9.6095
5.6	480	159.8751	1.1070	2.3046	2.7282	0.6767	4.0832	3.8019	4.5082	1.0498	1.7902	1.1285
R²				0.3975	0.6894	0.1514	0.3558	0.2723	0.2795	0.2364	0.3566	0.2136
R				0.6305	0.8303	0.3891	0.5965	0.5218	0.5286	0.4862	0.5972	0.4622

EK-5'in devamı

VF-2 (M-LogVs30-LogRepi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	1.9059	0.9396	1.5244	3.2137	3.7584	4.2855	1.9815	1.9404	1.6607
3.1	709	74.9585	0.1245	0.1065	0.1848	0.0669	0.2061	0.2023	0.2193	0.1157	0.1646	0.1104
3.4	219	40.7060	0.3658	0.5458	0.4657	0.8245	1.4028	1.0990	1.2050	0.5425	0.5675	0.5379
3.4	234	46.1303	0.8801	0.4738	0.3922	0.7285	1.1668	0.9183	1.0093	0.4606	0.5195	0.4947
4.4	337	125.5637	0.4955	0.5456	0.7754	0.7517	0.9376	1.0715	1.2190	0.5765	0.6708	0.6160
5.2	1323	50.0517	28.2846	6.4932	3.4979	16.5593	7.0958	11.1173	8.2794	4.4988	12.9718	5.3101
3.6	313	73.8637	0.5081	0.3432	0.3514	0.4409	0.6982	0.6353	0.6776	0.3054	0.3964	0.2901
5.5	181	279.7177	2.8534	1.2000	5.2878	0.1671	2.1878	2.3768	2.6122	1.5094	1.0385	1.2036
4.2	348	12.3034	10.4828	12.8662	6.0993	16.6219	14.8252	21.8776	20.6538	9.2918	17.9804	14.2233
3.8	555	12.7593	4.6117	5.6772	3.4926	7.5561	6.6222	9.4624	10.4954	5.6195	5.5475	8.3464
3.8	356	30.4067	1.7876	1.8485	1.3554	2.2066	2.7227	3.2063	3.2063	2.2756	1.5765	2.0119
5.6	186	353.9452	0.2379	0.9837	3.5969	0.1523	1.7100	1.3868	1.6181	0.8337	0.7251	0.7565
5.7	243	202.4129	0.6862	2.6078	4.5404	0.8512	4.2364	6.0117	5.4828	1.6485	1.6058	2.4395
5.7	248	344.0663	1.4610	0.9730	1.8140	0.4936	1.7258	1.4997	1.5488	1.1511	0.7251	0.8764
5.9	273	193.4270	0.8385	3.5090	3.8902	1.7300	5.9979	7.6913	7.4302	1.3515	2.0160	2.2295
5.9	216	168.6507	1.5561	5.1642	8.3053	0.6707	8.5507	10.0231	10.9396	3.4946	3.3574	4.7304
6.8	195	249.3240	3.3740	7.0805	2.1136	0.6448	26.3633	13.2434	19.4536	6.4640	8.3946	7.6384
6.8	720	261.9778	4.7481	2.1820	0.1297	68.8120	10.7399	4.5499	5.2481	2.9964	5.6598	2.8399
6.0	415	219.5411	0.5695	2.1123	0.9682	6.8102	4.4875	4.9774	4.3351	0.9087	1.2482	1.5926
6.0	1141	243.5445	1.0680	0.7808	0.0654	13.3696	1.9634	1.5959	1.4289	0.6825	0.4870	0.8084
6.2	403	153.2111	15.2626	6.4723	1.8790	15.1544	11.9950	11.2202	13.4896	6.1404	12.5112	6.7019
6.2	203	385.4127	3.1738	2.0367	2.5377	0.2487	3.9446	3.0690	3.1405	2.8754	3.0082	2.3169
6.8	214	439.0501	2.5317	3.3743	1.2707	0.4600	9.2897	4.6132	5.9156	2.2197	3.0082	2.8550
6.8	340	174.9356	12.4058	11.4939	2.2202	13.3637	34.1979	15.9956	21.2814	4.7731	5.6598	7.2862
4.8	192	110.7637	3.6437	2.0296	4.4849	0.4468	2.8314	3.7325	3.9174	2.2845	3.1901	2.0531
4.8	348	248.2582	0.6185	0.2641	0.4995	0.5305	0.5408	0.5093	0.5534	0.6246	0.3591	0.3907
6.1	350	241.4802	3.2809	2.3312	1.4185	4.2323	5.0816	5.4450	4.8865	2.2213	1.2482	2.1179
6.1	507	192.6567	1.6944	2.7344	0.6860	14.7156	5.9566	5.9566	5.5590	3.4293	2.0160	2.7441
5.2	265	57.2967	2.0810	8.3438	8.6116	3.7700	11.2202	13.3660	13.5207	8.7378	9.1201	7.4234
5.6	480	159.8751	1.1070	2.2862	1.1902	6.5564	3.4754	4.5920	4.1687	1.1973	1.3372	1.9275
R²				0.3528	0.0285	0.1116	0.1829	0.3269	0.2457	0.2631	0.5664	0.2824
R				0.5939	0.1689	0.3340	0.4277	0.5718	0.4957	0.5130	0.7526	0.5314

EK-5'in devamı

VF-3 (M-Vs30-LogRepi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	2.3269	2.0744	0.9254	3.9264	3.7844	3.8019	1.7857	2.0272	1.9404
3.1	709	74.9585	0.1245	0.1065	0.1412	0.3870	0.2208	0.2028	0.2259	0.1150	0.1154	0.1646
3.4	219	40.7060	0.3658	0.5780	0.6502	0.4374	1.3032	1.1324	1.0765	0.6253	0.5232	0.5675
3.4	234	46.1303	0.8801	0.4808	0.5280	0.3823	1.0839	0.9397	0.9099	0.5311	0.4678	0.5195
4.4	337	125.5637	0.4955	0.5602	0.5943	0.4112	0.9204	1.0965	1.1561	0.6272	0.5977	0.6708
5.2	1323	50.0517	28.2846	6.3026	0.6606	16.4894	10.3039	12.2462	11.9950	3.8744	6.4062	12.9718
3.6	313	73.8637	0.5081	0.3302	0.3231	0.2953	0.6761	0.6397	0.6577	0.3292	0.2983	0.3964
5.5	181	279.7177	2.8534	1.0081	3.2525	0.3786	2.3823	2.0989	2.2646	1.2888	1.1787	1.0385
4.2	348	12.3034	10.4828	13.2828	9.8126	3.3789	24.6604	21.7771	21.5278	10.6170	14.5915	17.9804
3.8	555	12.7593	4.6117	5.4667	4.5929	2.3041	11.0662	9.2470	10.7647	6.6451	8.4411	5.5475
3.8	356	30.4067	1.7876	1.6967	1.6299	1.1537	3.1915	3.2734	3.3574	1.9566	1.9503	1.5765
5.6	186	353.9452	0.2379	0.7316	2.6515	0.3413	1.9055	1.2589	1.5066	0.7117	0.7288	0.7251
5.7	243	202.4129	0.6862	2.5675	5.0875	0.6406	5.0350	5.5208	5.0933	2.0611	2.6540	1.6058
5.7	248	344.0663	1.4610	0.8360	2.3202	0.4302	1.8967	1.4355	1.5276	1.2340	0.8308	0.7251
5.9	273	193.4270	0.8385	3.4817	6.0867	0.8422	7.6384	7.0958	6.5766	1.3418	2.1179	2.0160
5.9	216	168.6507	1.5561	5.1381	10.4091	0.7725	11.4288	9.0157	8.6497	3.4080	4.5279	3.3574
6.8	195	249.3240	3.3740	7.2336	12.5890	0.4890	39.0841	12.2180	16.4059	5.7161	7.2227	8.3946
6.8	720	261.9778	4.7481	2.0412	0.3257	2.5936	13.2434	4.6666	6.1944	2.4288	2.9874	5.6598
6.0	415	219.5411	0.5695	2.1894	2.4286	1.3838	5.4576	4.6989	4.3451	1.1558	1.5527	1.2482
6.0	1141	243.5445	1.0680	0.8788	0.0519	9.0071	2.3067	1.5205	1.3772	0.5876	0.7411	0.4870
6.2	403	153.2111	15.2626	7.2088	4.9724	2.3334	16.5959	10.6660	10.5196	7.6560	6.8675	12.5112
6.2	203	385.4127	3.1738	1.6767	4.1566	0.3906	4.7863	2.6792	3.0339	2.6044	2.3977	3.0082
6.8	214	439.0501	2.5317	2.5104	3.5315	0.3394	13.0017	4.1591	5.9979	2.3421	2.4194	3.0082
6.8	340	174.9356	12.4058	12.0207	9.6473	1.2713	45.4988	16.9824	22.0293	5.3827	7.3995	5.6598
4.8	192	110.7637	3.6437	1.9635	2.2924	0.5384	2.9648	3.5481	3.6983	2.3507	2.1463	3.1901
4.8	348	248.2582	0.6185	0.2684	0.4941	0.3671	0.5534	0.5058	0.5649	0.6002	0.3841	0.3591
6.1	350	241.4802	3.2809	2.4466	3.5101	1.0189	6.3533	5.2723	4.9431	1.9187	2.0912	1.2482
6.1	507	192.6567	1.6944	2.8013	1.7725	2.5363	7.5509	5.2602	4.9888	2.0673	2.7258	2.0160
5.2	265	57.2967	2.0810	8.0850	7.9787	2.2461	16.7494	14.0929	13.4896	9.7006	7.6630	9.1201
5.6	480	159.8751	1.1070	2.1643	1.7022	1.7807	4.0644	4.1687	3.9264	1.0320	1.9458	1.3372
R²				0.3549	0.0269	0.5423	0.1913	0.3678	0.3444	0.2435	0.3315	0.5664
R				0.5957	0.1639	0.7364	0.4373	0.6065	0.5869	0.4935	0.5758	0.7526

EK-5'in devam

VF-4 (M-LogVs30-Repi →LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	2.2646	0.5803	0.5723	4.6559	3.9446	4.4055	1.6406	1.5660	1.9404
3.1	709	74.9585	0.1245	0.1083	0.0439	0.3943	0.2239	0.2104	0.2280	0.1274	0.1127	0.1646
3.4	219	40.7060	0.3658	0.5356	0.5938	0.7959	1.2735	1.0789	1.2445	0.4944	0.5107	0.5675
3.4	234	46.1303	0.8801	0.4500	0.5581	0.7925	1.0447	0.8995	1.0233	0.4367	0.4495	0.5195
4.4	337	125.5637	0.4955	0.5761	0.6684	0.9831	1.0116	0.9886	1.1588	0.5687	0.6119	0.6708
5.2	1323	50.0517	28.2846	4.9817	37.1322	0.4861	11.2980	8.9950	6.7453	5.0003	5.4138	12.9718
3.6	313	73.8637	0.5081	0.3175	0.4845	0.8216	0.6761	0.6266	0.6730	0.3199	0.2890	0.3964
5.5	181	279.7177	2.8534	1.2060	8.7313	1.3086	2.1627	2.2336	2.6363	1.8690	1.1921	1.0385
4.2	348	12.3034	10.4828	14.3594	3.6890	2.0838	24.7742	22.6986	22.5944	10.8868	11.1944	17.9804
3.8	555	12.7593	4.6117	5.6237	5.9316	0.9767	11.0154	10.1158	12.0781	5.4338	9.0678	5.5475
3.8	356	30.4067	1.7876	1.7828	1.6562	1.3547	2.9309	3.3806	3.6224	2.0635	2.0907	1.5765
5.6	186	353.9452	0.2379	0.8586	9.8091	0.3655	1.5031	1.4997	1.9143	0.8744	0.6399	0.7251
5.7	243	202.4129	0.6862	2.3802	2.6988	9.9273	4.7098	4.5709	5.2240	2.1727	2.2501	1.6058
5.7	248	344.0663	1.4610	0.9324	2.5535	0.4454	1.4191	1.4859	1.5417	1.2817	0.8166	0.7251
5.9	273	193.4270	0.8385	3.3160	2.2807	13.9112	6.8707	6.5313	6.9984	1.3521	1.9670	2.0160
5.9	216	168.6507	1.5561	5.1054	4.1247	51.2640	10.9396	9.4189	9.6605	2.4044	4.6068	3.3574
6.8	195	249.3240	3.3740	7.4983	2.4547	70.4890	16.8655	10.4232	13.0317	6.2488	7.2144	8.3946
6.8	720	261.9778	4.7481	2.8153	0.1046	2.5396	6.3973	4.1020	4.6026	2.1822	3.2742	5.6598
6.0	415	219.5411	0.5695	2.5004	0.8910	2.7847	4.4055	4.0551	4.4566	0.9924	1.5831	1.2482
6.0	1141	243.5445	1.0680	0.9077	0.1463	0.5509	1.4723	1.7219	1.5171	0.5563	0.8976	0.4870
6.2	403	153.2111	15.2626	7.3738	2.1461	7.8817	14.5211	13.3352	14.5546	7.3468	7.4353	12.5112
6.2	203	385.4127	3.1738	1.8511	3.9480	1.8106	3.6392	3.1189	4.2364	2.8003	2.3703	3.0082
6.8	214	439.0501	2.5317	2.6149	0.2703	2.2159	8.4918	4.6666	6.7453	2.9121	2.5090	3.0082
6.8	340	174.9356	12.4058	12.6561	0.9353	169.5834	24.4343	19.2752	17.7828	4.7446	6.4313	5.6598
4.8	192	110.7637	3.6437	2.0521	2.1074	3.5465	3.2961	3.2359	4.1783	2.4609	2.0720	3.1901
4.8	348	248.2582	0.6185	0.2864	0.2336	0.4379	0.5188	0.4989	0.5649	0.6853	0.3708	0.3591
6.1	350	241.4802	3.2809	2.6244	1.0154	5.4269	4.7753	4.3652	5.3951	2.0960	2.0845	1.2482
6.1	507	192.6567	1.6944	2.8848	1.1312	2.1289	6.3387	5.8479	5.4828	1.6638	2.8874	2.0160
5.2	265	57.2967	2.0810	7.8897	3.8716	5.4094	17.7011	12.3880	13.8038	7.8614	7.4097	9.1201
5.6	480	159.8751	1.1070	2.2254	1.7085	1.3381	4.1783	4.6666	4.0551	1.3530	1.7402	1.3372
R²				0.2972	0.5610	0.0545	0.3068	0.3249	0.2444	0.3329	0.3121	0.5664
R				0.5451	0.7490	0.2335	0.5539	0.5700	0.4944	0.5769	0.5587	0.7526

EK-5'in devamı

VF-5 (M-Repi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	1.8186	0.8474	0.8653	3.9084	4.1687	4.1115	2.0281	1.8582	1.8557
3.1	709	74.9585	0.1245	0.1602	0.2253	0.2185	0.3289	0.3289	0.3548	0.1364	0.1497	0.1222
3.4	219	40.7060	0.3658	0.4564	0.5866	0.9104	1.0023	1.0162	1.0351	0.4303	0.4774	0.4418
3.4	234	46.1303	0.8801	0.3694	0.5196	0.8060	0.8356	0.8147	0.8414	0.3478	0.3883	0.3658
4.4	337	125.5637	0.4955	0.4941	0.4424	0.6206	0.9550	1.0280	1.0814	0.5338	0.4629	0.5931
5.2	1323	50.0517	28.2846	8.0643	14.7171	21.6111	20.4174	13.8995	15.5955	9.2491	7.6138	7.9616
3.6	313	73.8637	0.5081	0.2618	0.3468	0.6400	0.6109	0.5508	0.5970	0.2328	0.2469	0.2443
5.5	181	279.7177	2.8534	0.5906	0.7951	0.3277	1.0715	1.3305	1.3213	0.6838	0.5732	0.6902
4.2	348	12.3034	10.4828	12.2412	3.5789	10.7379	25.0611	23.3346	23.9883	11.0764	11.6735	12.6794
3.8	555	12.7593	4.6117	6.8004	1.7938	4.3459	11.7220	13.8676	13.3045	7.0664	6.4834	7.1089
3.8	356	30.4067	1.7876	1.6541	1.1758	2.3521	2.8445	3.2584	3.3189	1.4478	1.5517	1.4054
5.6	186	353.9452	0.2379	0.3343	0.6065	0.2847	0.6577	0.7586	0.8241	0.3227	0.3176	0.2703
5.7	243	202.4129	0.6862	1.4410	2.8374	0.6419	3.4914	3.3037	3.6308	1.5820	1.5038	2.0128
5.7	248	344.0663	1.4610	0.4299	0.8031	0.2943	0.8710	1.0641	1.0471	0.4609	0.4130	0.6610
5.9	273	193.4270	0.8385	2.2054	4.5932	0.8703	5.7280	4.9204	5.7016	1.6715	2.1772	1.4501
5.9	216	168.6507	1.5561	3.0984	6.4723	1.3529	8.1283	7.0632	7.6913	3.1579	3.4930	2.7970
6.8	195	249.3240	3.3740	4.5911	6.6373	1.0088	11.5345	8.4918	9.5060	4.5113	5.3040	4.1200
6.8	720	261.9778	4.7481	4.2991	5.9716	0.8537	10.3514	7.9433	8.4333	4.0161	4.6548	4.4679
6.0	415	219.5411	0.5695	2.0549	3.9173	0.6718	4.9431	4.3451	4.8306	1.2503	1.7902	1.0597
6.0	1141	243.5445	1.0680	1.6699	3.0334	0.5249	3.7844	3.6308	3.7844	1.1954	1.5603	1.0188
6.2	403	153.2111	15.2626	6.5512	12.2537	3.1636	16.2555	14.6893	12.7350	8.9043	6.7999	13.2770
6.2	203	385.4127	3.1738	1.5391	1.6710	0.3237	1.7100	1.9634	1.7579	1.5696	1.0264	2.4860
6.8	214	439.0501	2.5317	1.0160	2.7038	0.4097	4.2267	3.6559	2.9992	1.2112	1.1858	1.5125
6.8	340	174.9356	12.4058	6.6890	14.7812	5.3079	26.2422	20.1372	16.5577	7.0049	7.7073	6.6834
4.8	192	110.7637	3.6437	1.6202	1.4951	1.1788	2.3335	2.7542	2.9040	1.7563	1.5241	1.9856
4.8	348	248.2582	0.6185	0.2659	0.1780	0.2949	0.4634	0.4634	0.4875	0.2957	0.2789	0.2542
6.1	350	241.4802	3.2809	2.0760	3.5952	0.5750	4.6238	4.2073	4.4463	1.6207	1.9391	1.3189
6.1	507	192.6567	1.6944	3.3605	6.2566	1.0968	8.2414	6.6681	7.7804	2.3340	2.9161	1.6140
5.2	265	57.2967	2.0810	6.4954	12.4646	14.8704	16.5196	11.6681	13.0017	6.8344	6.0534	6.7655
5.6	480	159.8751	1.1070	2.0411	4.2483	1.1138	5.2360	4.9317	5.3703	2.3812	2.5515	2.2162
R²				0.4952	0.5301	0.5820	0.5458	0.4731	0.4685	0.6038	0.4946	0.5346
R				0.7037	0.7281	0.7629	0.7388	0.6878	0.6845	0.7771	0.7033	0.7311

EK-5'in devamı

VF-6 (M-LogRepi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	1.9433	0.8702	0.3680	0.2109	0.1963	0.1963	2.0179	2.0869	1.8072
3.1	709	74.9585	0.1245	0.1623	0.1834	0.0331	0.2109	0.1963	0.1963	0.1353	0.1200	0.1407
3.4	219	40.7060	0.3658	0.4877	0.4443	0.1702	0.2443	0.2786	0.2742	0.4326	0.4208	0.4082
3.4	234	46.1303	0.8801	0.3907	0.3886	0.1387	0.2443	0.2786	0.2742	0.3518	0.3574	0.3639
4.4	337	125.5637	0.4955	0.4568	0.4320	0.1729	0.4732	0.5070	0.4989	0.5198	0.5398	0.5707
5.2	1323	50.0517	28.2846	8.0746	13.6960	6.7996	1.0000	1.0328	0.9441	8.8206	9.1432	12.8351
3.6	313	73.8637	0.5081	0.2564	0.2909	0.0976	0.2723	0.3342	0.3221	0.2342	0.2394	0.2889
5.5	181	279.7177	2.8534	0.5752	0.4679	0.3045	1.3740	1.2050	1.2560	0.6368	0.5352	0.7567
4.2	348	12.3034	10.4828	11.9484	14.5994	10.1249	0.4055	0.4375	0.4446	11.4025	12.5401	11.0408
3.8	555	12.7593	4.6117	5.9723	5.1692	3.1886	0.3076	0.3690	0.3614	6.1859	5.9020	6.3096
3.8	356	30.4067	1.7876	1.5095	1.2086	0.7369	0.3076	0.3690	0.3614	1.4458	1.4955	1.6051
5.6	186	353.9452	0.2379	0.4319	0.2378	0.2367	1.5276	1.2706	1.3740	0.3528	0.2289	0.3432
5.7	243	202.4129	0.6862	1.6338	1.7936	1.0124	1.7022	1.3490	1.4962	1.7628	1.9360	1.5367
5.7	248	344.0663	1.4610	0.5326	0.2986	0.3218	1.7022	1.3490	1.4962	0.5032	0.4410	0.4463
5.9	273	193.4270	0.8385	2.4898	2.5622	1.8978	2.0989	1.5382	1.7418	1.7624	1.6815	1.1625
5.9	216	168.6507	1.5561	3.4542	3.7949	2.5877	2.0989	1.5382	1.7418	3.0395	3.4174	2.1692
6.8	195	249.3240	3.3740	5.3726	0.5944	9.1822	5.0003	3.9537	2.5235	4.2964	4.2599	4.3132
6.8	720	261.9778	4.7481	4.9162	0.5108	8.1505	5.0003	3.9537	2.5235	3.9237	4.0068	3.8860
6.0	415	219.5411	0.5695	2.1500	1.8505	1.8583	2.3281	1.6596	1.8621	1.2229	0.9867	1.0309
6.0	1141	243.5445	1.0680	1.6923	1.3213	1.4723	2.3281	1.6596	1.8621	1.1588	1.0723	1.0817
6.2	403	153.2111	15.2626	6.7280	5.1763	7.1711	2.8314	1.9770	2.0797	8.4217	13.0768	10.1042
6.2	203	385.4127	3.1738	1.0042	0.2547	0.8769	2.8314	1.9770	2.0797	1.4230	1.6485	1.9329
6.8	214	439.0501	2.5317	2.2951	0.0823	2.4031	5.0003	3.9537	2.5235	1.1015	1.3077	0.9406
6.8	340	174.9356	12.4058	10.6762	1.5427	21.7107	5.0003	3.9537	2.5235	7.4628	6.7920	5.8452
4.8	192	110.7637	3.6437	1.4733	1.2720	0.4884	0.6730	0.7674	0.6607	1.7014	1.7507	1.7599
4.8	348	248.2582	0.6185	0.2407	0.1974	0.0902	0.6730	0.7674	0.6607	0.3193	0.3765	0.4566
6.1	350	241.4802	3.2809	2.0245	1.4022	1.9422	2.5704	1.8072	1.9770	1.7877	1.7976	1.6642
6.1	507	192.6567	1.6944	3.4358	2.8334	3.2485	2.5704	1.8072	1.9770	2.6002	2.2967	2.3692
5.2	265	57.2967	2.0810	6.7226	11.1995	5.0175	1.0000	1.0328	0.9441	6.5736	6.7546	6.7174
5.6	480	159.8751	1.1070	2.4492	3.0340	1.3213	1.5276	1.2706	1.3740	2.4992	2.5270	1.1163
R²				0.4988	0.4362	0.3481	0.0230	0.0305	0.0176	0.5951	0.5916	0.7579
R				0.7063	0.6604	0.5900	0.1518	0.1748	0.1328	0.7715	0.7691	0.8706

EK-6 Veri seti 2 ($M_w \geq 5.0$ olan depremlerin 4024 parametresi) için 6 veri formuna göre oluşturulan YSA ve regresyon modellerinin test verilerine göre PGA tahmin sonuçları.

VF-1 (M-Vs30-Repi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
3.1	192	14.3715	0.7700	2.2094	0.6084	0.4940	4.9431	3.8815	4.7534	2.0156	1.7084	1.6088
3.1	709	74.9585	0.1245	0.1048	0.0389	0.1324	0.2460	0.2009	0.2228	0.1175	0.1184	0.1057
3.4	219	40.7060	0.3658	0.5711	0.7724	0.4251	1.2078	1.1066	1.2134	0.6320	0.4861	0.4477
3.4	234	46.1303	0.8801	0.4666	0.7002	0.3571	0.9863	0.9462	1.0000	0.4944	0.4419	0.4151
4.4	337	125.5637	0.4955	0.5972	1.1683	0.2733	1.0304	1.0641	1.2331	0.6433	0.5959	0.6957
5.2	1323	50.0517	28.2846	7.4223	43.8242	17.8756	11.5080	8.4528	9.0365	3.3327	6.4625	3.0606
3.6	313	73.8637	0.5081	0.3207	0.6453	0.2541	0.6531	0.6471	0.6823	0.3222	0.2987	0.2925
5.5	181	279.7177	2.8534	1.0551	0.1147	0.1994	1.5704	2.3659	2.5293	1.6971	1.1901	1.1803
4.2	348	12.3034	10.4828	13.4897	7.6503	59.4684	23.3884	21.9786	22.2331	10.2967	12.1983	13.5550
3.8	555	12.7593	4.6117	5.8262	5.7727	19.4645	9.7949	10.7647	11.8304	5.5680	8.8920	9.1033
3.8	356	30.4067	1.7876	1.7374	2.6575	3.7778	2.8840	3.2063	3.4356	2.0133	2.0526	2.0840
5.6	186	353.9452	0.2379	0.9106	0.0200	0.5154	0.8690	1.3646	1.5849	0.9931	0.6613	0.4640
5.7	243	202.4129	0.6862	2.7072	0.8528	0.3537	4.5290	4.9545	5.1880	1.9643	2.4479	3.4119
5.7	248	344.0663	1.4610	0.8606	0.0265	0.4379	0.9954	1.4825	1.6749	1.3555	0.7745	0.9561
5.9	273	193.4270	0.8385	3.6610	1.2657	0.7581	6.4714	6.5013	7.0307	1.2729	1.8950	1.4302
5.9	216	168.6507	1.5561	5.1808	1.7665	2.3275	8.9331	9.8628	9.2257	3.2734	4.4300	4.4005
6.8	195	249.3240	3.3740	7.1846	0.7314	0.5994	13.3968	12.9122	11.2980	6.2144	7.2028	4.0644
6.8	720	261.9778	4.7481	2.3241	0.4182	0.2471	6.1235	3.7584	4.4157	2.4906	3.2591	3.5678
6.0	415	219.5411	0.5695	2.4169	0.9614	0.2756	4.5186	3.8371	4.7315	0.9380	1.5937	1.5255
6.0	1141	243.5445	1.0680	1.3011	0.2885	0.0069	0.9268	1.3274	1.2618	0.6615	0.8644	1.2156
6.2	403	153.2111	15.2626	6.7807	3.1046	7.9973	12.0781	10.9648	11.8577	7.8469	7.5284	13.1583
6.2	203	385.4127	3.1738	1.7690	0.0161	0.6444	1.6181	2.9854	3.6058	2.8353	2.4177	2.7365
6.8	214	439.0501	2.5317	3.1701	0.0099	0.1688	2.5293	4.8641	5.3211	3.1391	2.2983	1.6742
6.8	340	174.9356	12.4058	12.0049	2.1565	28.9409	18.4077	18.5780	17.3780	4.6602	6.6757	4.1639
4.8	192	110.7637	3.6437	1.9653	2.0358	1.1047	3.0761	3.9446	3.7584	2.4099	2.1223	1.9182
4.8	348	248.2582	0.6185	0.2762	0.1106	0.0641	0.5598	0.5140	0.5495	0.6020	0.3655	0.3933
6.1	350	241.4802	3.2809	2.6694	0.6094	0.2702	4.7534	4.3451	5.1523	2.3774	2.0142	1.5311
6.1	507	192.6567	1.6944	2.8987	1.6884	0.6923	6.0954	4.8417	6.0256	2.4519	2.8432	2.7791
5.2	265	57.2967	2.0810	7.6577	7.8573	62.0452	13.1220	13.5207	15.0314	8.1979	7.8037	9.6095
5.6	480	159.8751	1.1070	2.3046	2.7282	0.6767	4.0832	3.8019	4.5082	1.0498	1.7902	1.1285
R²				0.3975	0.6894	0.1514	0.3558	0.2723	0.2795	0.2364	0.3566	0.2136
R				0.6305	0.8303	0.3891	0.5965	0.5218	0.5286	0.4862	0.5972	0.4622

EK-6'nın devamı

VF-2 (M-LogVs30-LogRepi →LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
5.2	1323	50.0517	28.2846	4.8248	2.7117	18.6242	4.7131	6.7144	5.1618	4.3853	3.6728	3.9902
5.2	323	79.1236	21.3458	4.8898	6.6097	8.9593	3.7528	5.1888	4.4172	3.7497	4.2462	4.2855
5.5	192	194.5010	2.3107	2.3992	1.2063	2.3670	2.2924	1.4722	2.2192	1.6904	2.0893	2.1878
5.5	301	210.4178	3.5651	1.4135	1.1752	0.8288	1.4296	1.1586	1.3723	1.0162	1.3397	1.3274
5.6	199	299.3061	0.6088	1.0035	0.7476	1.0864	0.8307	0.7845	1.2332	0.8590	1.0139	0.8690
5.6	346	385.5095	0.5814	0.3523	0.5132	0.4837	0.3139	0.5241	0.4863	0.3882	0.3334	0.3048
5.7	314	111.2830	4.3049	6.7814	3.3059	2.7873	6.0453	5.0323	5.3690	4.2073	5.4702	5.1050
5.7	316	145.7723	2.3244	4.0124	2.2463	1.6088	4.2235	2.5248	3.3282	2.5882	3.2509	2.8379
5	519	108.6941	1.7384	1.4802	3.4614	1.4900	2.2778	1.7357	1.4244	1.2106	1.7258	1.4723
5	579	111.5369	0.3744	1.3075	3.0341	1.2410	1.6948	1.4344	1.2700	1.0666	1.5382	1.3366
5.9	216	169.9164	1.3122	3.8752	1.8294	3.2727	3.9619	2.6161	4.4810	3.6475	4.2267	3.0269
5.9	480	317.8763	0.0598	0.5188	0.6909	1.0471	0.5889	0.5473	0.7611	0.6053	0.6442	0.5458
6	226	132.0886	12.7967	4.4203	2.3167	5.5578	9.3533	5.5512	7.7182	6.4417	8.5901	5.6885
6	407	201.9869	0.8138	1.3017	1.5407	1.7119	1.6870	1.1032	2.3485	1.8197	2.4717	1.8197
6.2	282	376.5037	1.7412	1.8385	1.8609	2.3462	1.8407	1.7711	1.3413	1.1015	1.1298	1.1912
6.2	292	130.9468	14.0257	15.1020	2.8966	5.8947	11.6465	12.2115	8.8576	7.6384	11.1944	8.5507
6.2	341	126.7773	17.1441	14.6862	2.9889	4.8672	11.5164	12.1099	8.4746	7.1614	11.0408	8.5704
6.2	303	381.0869	2.3684	1.6441	1.8052	2.3331	1.5115	1.7463	1.2270	1.0116	1.0351	1.0965
6.5	192	369.5543	1.4263	4.4488	3.3646	9.9158	4.3652	2.5839	2.9325	2.8576	2.6607	3.0620
6.5	358	185.3979	3.7279	8.3487	4.5828	6.7221	6.2350	4.6079	6.1733	5.8210	7.1121	9.0157
6.5	540	408.5638	1.1240	1.1665	2.5694	2.5483	0.7986	1.0192	0.9179	0.9226	0.9354	1.0617
5.2	696	73.0990	12.5239	3.1360	5.6266	3.3239	2.4453	3.4496	3.3628	2.6730	3.0620	3.0339
5.2	234	49.5502	28.7320	8.9902	6.8365	78.7195	8.6637	8.7756	11.1536	8.3368	8.9950	9.3756
5.2	236	51.9471	66.5823	8.5577	6.6655	71.1016	8.0704	8.7756	10.3018	7.8705	8.4140	8.7902
5.2	549	85.0499	5.0817	3.2949	5.7368	2.3527	2.6606	2.9537	2.8977	2.3496	2.8510	2.7990
5.5	356	156.0020	1.0744	2.5306	1.8530	0.9947	2.3772	1.5335	2.0315	1.5560	2.0417	2.1528
5.5	265	149.7993	9.8818	3.3160	2.0510	1.9677	2.8744	2.5730	2.6861	2.1135	2.6122	2.8510
5.5	357	216.0997	1.0234	1.1638	1.0328	0.6285	1.1037	0.9683	1.1447	0.8492	1.1143	1.0965
5.4	234	208.0272	1.4308	1.5465	1.1081	1.2390	1.6019	1.3947	1.4829	1.1092	1.4791	1.6069
5.4	219	195.5261	1.1071	1.8770	1.2002	1.6300	1.8907	1.4287	1.7269	1.3122	1.7338	1.9143
R²				0.2755	0.4210	0.6759	0.3194	0.4620	0.5556	0.5046	0.3533	0.4381
R				0.5249	0.6488	0.8221	0.5651	0.6797	0.7454	0.7104	0.5944	0.6619

EK-6'nın devamı

VF-3 (M-Vs30-LogRepi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
5.2	1323	50.0517	28.2846	3.5864	3.1985	5.0033	8.1846	3.3113	7.3790	5.1086	6.7143	6.4640
5.2	323	79.1236	21.3458	4.8155	4.2136	5.0180	4.7424	4.5920	4.6989	4.0626	5.1892	4.4422
5.5	192	194.5010	2.3107	2.2324	1.8994	0.8430	2.3605	1.9999	2.3496	2.3281	1.4723	1.5675
5.5	301	210.4178	3.5651	1.4001	1.0805	1.0361	1.6749	1.4488	1.4588	1.4618	1.1585	1.3887
5.6	199	299.3061	0.6088	1.1153	0.8891	0.2848	1.1830	0.8810	1.0046	0.8588	0.7845	0.6707
5.6	346	385.5095	0.5814	0.3595	0.3135	0.2658	0.4797	0.3597	0.3475	0.3258	0.5241	0.3750
5.7	314	111.2830	4.3049	6.9989	9.2561	4.4831	5.5208	5.9704	5.7677	6.0062	5.0327	5.5808
5.7	316	145.7723	2.3244	3.9479	4.6022	2.9446	3.7154	3.5975	3.6308	4.5227	2.5246	3.8566
5	519	108.6941	1.7384	1.5494	1.1936	3.4313	1.9815	1.8836	1.5488	2.3950	1.7358	2.2511
5	579	111.5369	0.3744	1.3666	1.0233	3.4343	1.8239	1.6711	1.3836	1.7494	1.4345	1.4200
5.9	216	169.9164	1.3122	3.4750	10.7016	2.0956	4.6345	4.1976	4.4668	3.4261	2.6158	2.4820
5.9	480	317.8763	0.0598	0.5710	0.7280	1.1597	0.9419	0.7709	0.6745	0.5794	0.5474	0.6107
6	226	132.0886	12.7967	4.0575	29.9609	3.9769	7.5858	8.5704	7.1779	8.4043	5.5514	6.0117
6	407	201.9869	0.8138	1.3267	3.4244	2.6213	2.7990	2.8119	2.3281	1.5125	1.1033	1.2170
6.2	282	376.5037	1.7412	1.8970	1.8755	0.4896	1.4454	1.1246	1.2794	1.8954	1.7709	2.6026
6.2	292	130.9468	14.0257	15.2827	32.5264	5.2846	8.7297	12.1619	8.1658	12.8766	12.2124	17.6522
6.2	341	126.7773	17.1441	15.1397	24.2719	5.7353	8.3176	12.3595	8.0910	12.6474	12.1088	12.3225
6.2	303	381.0869	2.3684	1.7168	1.6326	0.5219	1.3459	1.0593	1.1614	1.6342	1.7462	2.2300
6.5	192	369.5543	1.4263	4.0620	5.0241	0.5676	2.8774	2.2131	2.8642	4.6957	2.5840	3.8124
6.5	358	185.3979	3.7279	8.6096	9.9401	5.2232	6.7143	8.1283	5.9293	6.2488	4.6079	4.1831
6.5	540	408.5638	1.1240	1.1931	0.6491	2.5998	1.1830	1.1015	0.8570	0.7856	1.0193	0.9285
5.2	696	73.0990	12.5239	3.2071	1.7669	4.9020	3.4754	3.1477	2.9854	2.3105	3.4498	2.8281
5.2	234	49.5502	28.7320	8.9273	14.6693	8.5702	10.8393	9.1622	10.3514	9.2087	8.7761	11.3188
5.2	236	51.9471	66.5823	8.5083	13.2056	8.1243	10.1158	8.5901	9.7499	8.4898	8.7761	10.4184
5.2	549	85.0499	5.0817	3.0578	2.0311	4.7249	3.1915	3.0832	2.7669	2.6946	2.9539	2.5073
5.5	356	156.0020	1.0744	2.3647	1.8708	2.3556	2.4831	2.3014	2.2803	2.3469	1.5336	1.9525
5.5	265	149.7993	9.8818	3.1365	2.7374	2.0620	3.0832	2.7990	3.1046	2.8820	2.5728	2.9861
5.5	357	216.0997	1.0234	1.1486	0.8794	1.1830	1.4555	1.2531	1.1940	1.0819	0.9683	0.7874
5.4	234	208.0272	1.4308	1.5060	1.0836	0.7290	1.7061	1.4655	1.5631	1.6007	1.3948	1.5926
5.4	219	195.5261	1.1071	1.7768	1.3004	0.8148	1.9543	1.6982	1.8707	1.8471	1.4289	1.6596
R²				0.2511	0.1580	0.5638	0.5830	0.3161	0.5836	0.3284	0.4620	0.3986
R				0.5011	0.3975	0.7508	0.7636	0.5622	0.7640	0.5731	0.6797	0.6314

EK-6'nın devamı

VF-4 (M-LogVs30-Repi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
5.2	1323	50.0517	28.2846	6.1394	1.5464	9.5436	5.7412	5.2723	5.4075	5.9786	6.7143	7.2996
5.2	323	79.1236	21.3458	5.1042	2.8664	5.0541	5.0699	4.6026	4.1879	3.8468	5.1892	4.7830
5.5	192	194.5010	2.3107	2.5532	7.1920	3.9048	2.4660	1.8967	2.2029	2.3057	1.4723	1.9213
5.5	301	210.4178	3.5651	1.4906	5.4842	2.1971	1.4962	1.2303	1.3521	1.4286	1.1585	1.4207
5.6	199	299.3061	0.6088	0.8982	2.7991	3.8497	1.3032	0.9638	1.0864	0.8531	0.7845	0.6230
5.6	346	385.5095	0.5814	0.2858	0.3490	0.8855	0.3819	0.2642	0.2754	0.3098	0.5241	0.3930
5.7	314	111.2830	4.3049	6.6346	21.6379	6.8630	5.6885	4.8865	5.1286	5.9965	5.0327	5.6014
5.7	316	145.7723	2.3244	3.8466	13.1854	4.7922	3.5481	2.8379	3.1333	4.3833	2.5246	3.2367
5	519	108.6941	1.7384	1.4287	2.8109	4.1608	1.7179	1.4928	1.4093	2.2331	1.7358	2.2888
5	579	111.5369	0.3744	1.2342	3.7205	4.3210	1.5453	1.3183	1.2677	1.7235	1.4345	1.3999
5.9	216	169.9164	1.3122	3.4929	54.0274	5.9187	4.7973	3.2509	4.2462	3.8922	2.6158	2.5369
5.9	480	317.8763	0.0598	0.5336	0.8710	0.9059	0.8091	0.4920	0.6982	0.6021	0.5474	0.7820
6	226	132.0886	12.7967	3.8910	66.5361	8.6505	8.1658	6.2661	6.7608	9.1180	5.5514	4.6111
6	407	201.9869	0.8138	1.2702	0.9453	3.7210	2.5293	1.9498	2.2646	1.6432	1.1033	1.0471
6.2	282	376.5037	1.7412	1.7739	4.7011	2.0720	1.4421	1.6482	1.0889	1.9055	1.7709	2.5299
6.2	292	130.9468	14.0257	14.2025	5.4356	11.1529	9.0157	9.2045	7.5858	11.7409	12.2124	12.7732
6.2	341	126.7773	17.1441	13.3725	1.9639	11.8809	8.5704	9.0991	7.5509	11.9261	12.1088	12.9599
6.2	303	381.0869	2.3684	1.5103	4.5132	1.6917	1.2912	1.4757	0.9772	1.5610	1.7462	2.1918
6.5	192	369.5543	1.4263	5.1400	8.7976	9.4201	4.1783	3.6644	2.7040	4.3501	2.5840	4.0579
6.5	358	185.3979	3.7279	7.8052	2.3809	9.2328	6.2661	7.6736	5.3456	5.8036	4.6079	4.0151
6.5	540	408.5638	1.1240	1.1026	1.6395	0.7789	0.9661	1.0889	0.7396	0.7411	1.0193	1.0619
5.2	696	73.0990	12.5239	3.5500	9.3867	8.2550	3.9446	3.5156	3.3806	2.6266	3.4498	2.6230
5.2	234	49.5502	28.7320	11.5113	0.8242	5.4461	12.8529	11.0408	10.1391	11.0154	8.7761	13.1856
5.2	236	51.9471	66.5823	10.8304	0.8564	5.3658	11.9124	10.3514	9.4842	10.2164	8.7761	12.5632
5.2	549	85.0499	5.0817	3.1800	9.4624	6.6783	3.3963	3.0200	2.8249	2.7309	2.9539	2.3939
5.5	356	156.0020	1.0744	2.4627	7.6955	3.4603	2.2542	1.8923	1.9231	2.4038	1.5336	2.2631
5.5	265	149.7993	9.8818	3.3000	12.4203	3.6582	2.9309	2.4322	2.5586	2.8550	2.5728	2.7542
5.5	357	216.0997	1.0234	1.2323	3.0411	1.9259	1.2647	1.0162	1.1402	1.0597	0.9683	0.9590
5.4	234	208.0272	1.4308	1.6667	4.1112	2.5872	1.6181	1.3804	1.4588	1.6044	1.3948	1.5042
5.4	219	195.5261	1.1071	1.9791	4.1940	2.9342	1.8967	1.5996	1.6982	1.8754	1.4289	1.8088
R²				0.4189	0.0063	0.1183	0.6022	0.5487	0.5873	0.4419	0.4620	0.5695
R				0.6473	-0.0793	0.3439	0.7760	0.7407	0.7663	0.6647	0.6797	0.7547

EK-6'nın devamı

VF-5 (M-Repi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
5.2	1323	50.0517	28.2846	9.1376	4.831	19.0133	6.109	5.383	5.321	8.616	8.211	8.857
5.2	323	79.1236	21.3458	4.3754	3.682	10.4084	2.924	2.716	2.630	4.745	4.752	5.045
5.5	192	194.5010	2.3107	1.1638	1.921	2.0010	0.957	0.899	0.847	1.289	1.013	1.527
5.5	301	210.4178	3.5651	0.9989	1.594	1.7366	0.828	0.764	0.719	1.181	0.978	1.478
5.6	199	299.3061	0.6088	0.4522	0.639	1.1185	0.460	0.402	0.375	0.428	0.411	0.322
5.6	346	385.5095	0.5814	0.2243	0.250	1.0590	0.215	0.211	0.210	0.225	0.331	0.201
5.7	314	111.2830	4.3049	4.6235	6.028	4.9055	3.357	3.581	3.034	4.369	3.934	3.678
5.7	316	145.7723	2.3244	2.7739	4.324	3.0883	2.104	2.173	1.820	3.525	2.057	4.616
5	519	108.6941	1.7384	1.6679	1.614	4.0489	1.250	1.250	1.312	2.648	2.661	2.282
5	579	111.5369	0.3744	1.6058	1.559	3.8192	1.194	1.197	1.268	2.289	2.017	2.114
5.9	216	169.9164	1.3122	2.0173	3.945	2.0593	2.118	2.275	1.660	2.309	1.811	2.500
5.9	480	317.8763	0.0598	0.5065	0.628	1.2476	0.653	0.571	0.457	0.534	0.611	0.436
6	226	132.0886	12.7967	2.5910	6.208	2.7588	3.776	4.550	3.221	3.439	4.712	2.212
6	407	201.9869	0.8138	1.2381	2.850	1.5718	1.795	1.854	1.352	0.966	1.013	0.701
6.2	282	376.5037	1.7412	1.4410	0.419	2.7832	0.703	0.637	0.813	1.650	1.466	2.607
6.2	292	130.9468	14.0257	10.4223	6.856	2.4653	5.082	6.138	5.333	13.050	11.784	15.624
6.2	341	126.7773	17.1441	11.0033	7.149	2.5618	5.395	6.501	5.610	13.549	11.784	16.535
6.2	303	381.0869	2.3684	1.4059	0.402	2.8818	0.682	0.615	0.793	1.682	1.306	2.895
6.5	192	369.5543	1.4263	2.1480	1.148	7.6310	1.172	1.180	1.442	2.153	1.810	1.683
6.5	358	185.3979	3.7279	7.0436	5.332	2.7153	4.150	4.236	4.571	5.920	5.724	4.355
6.5	540	408.5638	1.1240	1.4371	0.909	9.8841	0.931	0.918	1.183	1.921	1.458	2.312
5.2	696	73.0990	12.5239	4.9786	3.905	11.7541	3.342	3.055	2.951	5.054	4.752	5.794
5.2	234	49.5502	28.7320	9.2802	4.853	19.2180	6.209	5.458	5.408	8.708	8.211	8.947
5.2	236	51.9471	66.5823	8.6262	4.751	18.2608	5.781	5.093	5.012	8.224	8.211	8.551
5.2	549	85.0499	5.0817	3.8914	3.471	9.2526	2.588	2.438	2.371	4.294	3.571	4.399
5.5	356	156.0020	1.0744	1.7479	2.964	3.0490	1.416	1.387	1.309	1.818	1.552	1.937
5.5	265	149.7993	9.8818	1.8821	3.168	3.2985	1.521	1.493	1.413	2.119	1.921	2.255
5.5	357	216.0997	1.0234	0.9468	1.490	1.6582	0.787	0.721	0.679	1.177	0.978	1.435
5.4	234	208.0272	1.4308	1.0491	1.355	1.7260	0.726	0.675	0.665	0.949	0.914	1.008
5.4	219	195.5261	1.1071	1.1805	1.572	1.9478	0.817	0.769	0.760	1.159	0.947	1.289
R²				0.4810	0.247	0.5801	0.575	0.449	0.499	0.392	0.453	0.334
R				0.6935	0.497	0.7617	0.759	0.670	0.706	0.626	0.673	0.578

EK-6'nın devamı

VF-6 (M-LogRepi → LogPGA)												
Test Verisi				YSA			WEKA			RM		
M	Vs30	Repi	PGA	YSA-Multi	YSA-PSO	YSA-TLBO	W-10	W-6-10	W-6-10-3	RM-1	RM-2	RM-3
5.2	1323	50.0517	28.2846	6.5666	6.9713	10.0973	4.4875	4.6774	4.8865	8.1433	6.8470	9.3132
5.2	323	79.1236	21.3458	3.7469	2.6235	2.8940	1.9634	2.5704	2.6977	4.6602	4.0701	5.0606
5.5	192	194.5010	2.3107	1.3242	1.1197	0.6007	0.7499	0.8710	0.8995	1.2903	1.2656	1.1806
5.5	301	210.4178	3.5651	1.1053	1.0197	0.5105	0.6699	0.7362	0.7516	1.1890	1.0940	1.1580
5.6	199	299.3061	0.6088	0.5570	0.7634	0.2586	0.4721	0.3784	0.3540	0.4112	0.5271	0.3379
5.6	346	385.5095	0.5814	0.3121	0.6145	0.1497	0.3420	0.2223	0.2244	0.2412	0.2515	0.2562
5.7	314	111.2830	4.3049	5.4711	4.1832	3.3826	2.4660	3.2584	3.2285	4.4627	5.5963	4.0383
5.7	316	145.7723	2.3244	3.2192	2.3673	1.5817	1.5596	1.9454	1.7298	3.5253	2.7868	3.1754
5	519	108.6941	1.7384	1.9922	1.1913	1.1570	0.8790	1.3032	1.2246	2.6742	1.9249	2.6430
5	579	111.5369	0.3744	1.9332	1.1577	1.1024	0.8472	1.2503	1.1803	2.2761	1.8604	1.9783
5.9	216	169.9164	1.3122	2.3282	2.5219	1.3536	1.6520	2.0512	1.5205	2.2746	2.2223	1.6649
5.9	480	317.8763	0.0598	0.6116	0.8840	0.2163	0.6383	0.5370	0.4710	0.5466	0.6063	0.4970
6	226	132.0886	12.7967	3.3886	5.6546	3.7732	3.0130	4.3853	3.2659	3.6796	5.9129	2.8340
6	407	201.9869	0.8138	1.4879	2.1088	0.8700	1.4555	1.7458	1.3397	0.9947	1.6982	0.7876
6.2	282	376.5037	1.7412	1.4687	0.9123	0.1281	0.7499	0.6152	0.7112	1.5129	1.1148	2.2315
6.2	292	130.9468	14.0257	12.0254	9.6393	6.4171	4.3451	6.6069	5.7412	12.4222	9.7051	14.6352
6.2	341	126.7773	17.1441	12.7253	10.6192	7.3713	4.6238	7.0469	6.0814	12.9181	10.5439	14.7469
6.2	303	381.0869	2.3684	1.4319	0.8959	0.1232	0.7379	0.5957	0.6950	1.4925	1.0765	2.2136
6.5	192	369.5543	1.4263	2.2689	1.2782	0.1709	1.1803	1.1722	1.5136	2.2284	2.3121	2.2351
6.5	358	185.3979	3.7279	8.1605	7.0173	3.2905	3.8459	4.7643	6.7298	6.0674	7.3536	6.3110
6.5	540	408.5638	1.1240	1.8964	1.0566	0.1174	1.0116	0.8995	1.1668	1.6815	1.6099	2.1697
5.2	696	73.0990	12.5239	4.1305	3.0418	3.5278	2.2491	2.8379	2.9717	4.9283	4.3853	4.8150
5.2	234	49.5502	28.7320	6.6547	7.1467	10.4089	4.5814	4.7534	4.9545	8.0816	6.9359	9.3132
5.2	236	51.9471	66.5823	6.2569	6.3686	9.0358	4.1783	4.4463	4.6452	8.2073	6.5298	9.7724
5.2	549	85.0499	5.0817	3.4193	2.3095	2.4308	1.7418	2.3442	2.4660	4.1918	3.8098	3.8566
5.5	356	156.0020	1.0744	2.1645	1.5082	0.9636	1.0399	1.3213	1.4256	1.8176	1.9847	1.6800
5.5	265	149.7993	9.8818	2.3614	1.6029	1.0546	1.1066	1.4191	1.5453	2.1106	2.1802	2.3812
5.5	357	216.0997	1.0234	1.0393	0.9892	0.4834	0.6457	0.6934	0.7063	1.1671	1.0409	1.1836
5.4	234	208.0272	1.4308	0.9777	0.9355	0.4726	0.5970	0.6501	0.7261	0.9607	1.0325	0.8744
5.4	219	195.5261	1.1071	1.1206	0.9982	0.5323	0.6501	0.7464	0.8395	1.1593	1.1569	0.9535
R²				0.2585	0.3509	0.6657	0.4946	0.3557	0.3596	0.4005	0.3486	0.4231
R				0.5084	0.5924	0.8159	0.7033	0.5964	0.5996	0.6328	0.5905	0.6504

EK-7 24.01.2020 Sivrice (Elazığ) depremini kaydeden 20 istasyon konumuna göre YSA ve Regresyon modellerinden tahmin edilen PGA (cm/sn²) değerleri.

No	İstasyon Kod	Boylam (°D)	Enlem (°K)	Veri Seti 1 (M ≥ 3)				Veri Seti 2 (Mw ≥ 5.0)			
				VF-1		VF-5		VF-1		VF-5	
				Model	PGA	Model	PGA	Model	PGA	Model	PGA
1	2308	39.3102	38.45063	YSA-TLBO	205.7599	YSA-PSO	202.3952	YSA-Multi	203.5289	YSA-Multi	196.4351
2	4404	38.87385	38.19588	YSA-TLBO	171.5961	RM-3	199.9005	YSA-Multi	190.3015	YSA-Multi	191.7025
3	2301	39.19267	38.67043	RM-1	124.7779	RM-2	137.1124	YSA-Multi	141.8413	YSA-Multi	124.2739
4	0204	39.03472	38.02897	RM-2	106.0507	RM-3	110.3984	RM-1	90.8253	RM-3	119.2255
5	0212	38.62409	38.0277	RM-3	62.273	RM-3	37.6852	W-6-10-3	43.9542	RM-3	54.8260
6	2302	39.67541	38.39231	RM-2	44.5746	RM-3	37.4681	RM-1	35.7998	YSA-PSO	31.5545
7	4401	38.34019	38.34962	RM-2	60.2069	W-10	84.7227	RM-1	59.1448	W-10	58.3445
8	0205	38.61597	37.79177	YSA-Multi	38.5897	RM-1	38.8053	YSA-PSO	40.4415	RM-1	35.5038
9	0207	38.24763	38.03225	RM-2	30.1237	RM-1	32.5820	RM-3	30.2542	RM-1	29.8936
10	2304	39.86293	38.72096	RM-1	11.4169	RM-3	29.3350	RM-2	21.1481	YSA-TLBO	7.7754
11	4407	38.26406	38.78066	YSA-Multi	30.7681	YSA-Multi	30.5015	RM-1	25.5165	W-10	32.9610
12	2307	39.93199	38.69583	RM-3	18.0026	RM-3	25.5572	RM-2	22.0703	YSA-Multi	21.5752
13	4406	37.97378	38.34388	YSA-Multi	24.0482	RM-1	24.2309	YSA-PSO	23.4765	YSA-PSO	24.5138
14	0201	38.26742	37.76121	YSA-Multi	35.4223	YSA-PSO	48.9380	YSA-PSO	34.9889	YSA-PSO	24.3332
15	2305	40.13103	38.72778	RM-1	4.9928	RM-3	14.8198	YSA-TLBO	6.8235	YSA-TLBO	7.2894
16	4408	37.88732	38.09616	RM-2	16.1715	RM-1	17.8108	RM-1	16.2100	RM-1	16.2712
17	2306	40.03927	38.95945	RM-1	6.9863	RM-3	13.6627	YSA-TLBO	8.9059	YSA-TLBO	7.2079
18	4405	37.9396	38.8107	RM-3	10.0824	RM-3	13.6212	YSA-TLBO	10.7093	YSA-Multi	12.3366
19	2101	40.20278	37.93088	YSA-Multi	24.7689	RM-2	21.4101	RM-3	20.2895	YSA-PSO	22.5136
20	6304	38.51316	37.36509	W-10	27.35269	YSA-TLBO	61.3834	W-6-10	24.0436	YSA-PSO	21.3522

EK-8 Kullanılan deprem verileri, hesaplanan YSA ve regresyon modellerinin Matlab matris dosyaları ve yazılan Matlab kodlarını içeren 1 adet CD.



ÖZGEÇMİŞ

İlköğrenimini İsmet İnönü İlkokulu'nda 1996 yılında, orta öğrenimini 24 Kasım Anadolu Lisesi'nde 2003 yılında Kocaeli'nde tamamladı. 2004 yılında Kocaeli Üniversitesi Mühendislik Fakültesi Jeofizik Mühendisliği Bölüm'ünde eğitime başladı ve 2008 yılında mezun oldu. 2009-2010 yılları arasında askerlik hizmetini yaptı. 2012 yılında Kocaeli Tüpraş'ta İş güvenliği uzmanı olarak çalıştı. 2013 yılında Karadeniz Teknik Üniversitesi Jeofizik Mühendisliği Bölümü'ne araştırma görevlisi olarak atandı. Halen göreve bu kurumda devam etmektedir. Sismolojisi alanında çalışmalar yapmaktadır.

