

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**MADEN MÜHENDİSLİĞİ ANABİLİM DALI**

**YAPAY SİNİR AĞLARIYLA YERALTI AYNA PATLATMALARINDA KAYA  
PARÇALANMASININ MODELLENMESİ**

**YÜKSEK LİSANS TEZİ**

**Maden Mühendisi Gerard EZOULA AGORO**

**HAZİRAN 2019  
TRABZON**



**KARADENİZ TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**



**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce**

**Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : / /**

**Tezin Savunma Tarihi : / /**

**Tez Danışmanı :**

**Trabzon**

**KARADENİZ TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**Maden Mühendisliği Anabilim Dalında  
Gerard EZOULA AGORO Tarafından Hazırlanan**

**YAPAY SİNİR AĞLARIYLA YERALTI AYNA PATLATMALARINDA KAYA  
PARÇALANMASININ MODELLENMESİ**




**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 28 / 05 / 2019 gün ve 1806 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda  
YÜKSEK LİSANS TEZİ  
olarak kabul edilmiştir.**

**Jüri Üyeleri**

**Başkan : Prof. Dr. Gürcan KONAK**

**Üye : Prof. Dr. Ayhan KESİMAL**

**Üye : Doç. Dr. Ferdi CİHANGİR**

  
.....  
  
.....  
  
.....

**Prof. Dr. Asim KADIOĞLU**

**Enstitü Müdürü**

## ÖNSÖZ

Bu tezin başlanması, sürmesi ve sona ermesine kadar benimle bilgisi ve tecrübesini paylaşan ve her türlü yardımı bana sağlayan, her aşamada beni yönlendiren değerli danışmanım Doç. Dr. Ferdi CİHANGİR'e teşekkürü borç bilirim.

Çalışmalar sırasında ve tüm yüksek lisans öğrenimim boyunca destekleri ve tavsiyelerinden yararlandığım Prof. Dr. Ayhan KESİMAL, Doç. Dr. Bayram ERÇIKDI, Dr. Öğr. Üyesi Kadir KARAMAN, Arş. Gör. Ercüment KOÇ ve KTÜ Maden Mühendisliği bölümü öğretim üyelerine ayrı ayrı teşekkürlerimi sunarım.

Saha çalışmaları sırasında bana destek olan Gümüştaş Madencilik A.Ş. (GÜMÜŞHANE) İşletme Müdürü Maden Mühendisi Ferit EKREN'e, çalışmalar sırasında bana rehberlik eden, bilgi ve verileri elde etmekte bana kolaylık sağlayan Maden Mühendisi Samet MUTLU, Maden Mühendisi Fatih ÖZDEMİR, şirketin diğer Mühendislerine, teknik ve tüm çalışan diğer personeline teşekkür borçluyum.

Yüksek lisans eğitim süresince kendisinden uzak olsam da sevgisi ve duaları beni güçlendiren babam ve tüm aileme teşekkür ediyorum.

Gerard EZOULA AGORO

Trabzon, 2019

## **TEZ ETİK BEYANNAMESİ**

Yüksek Lisans Tezi olarak sunduğum “Yapay Sinir Ağlarıyla Yeraltı Ayna Patlatmalarında Kaya Parçalanmasının Modellenmesi” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Ferdi CİHANGİR’in sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda ve sahada yaptığımı/yaptırdığımı, 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. 11/06/2019

Gerard EZOULA AGORO

## İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET .....	VII
SUMMARY .....	IX
ŞEKİLLER DİZİNİ .....	XI
TABLolar DİZİNİ.....	XII
KISALTMALAR VE VE SEMBOLLER DİZİNİ.....	XIII
1. GENEL BİLGİLER.....	1
1.1. Giriş.....	1
1.2. Tezin Gerekçesi ve Amacı .....	3
1.3. Kaya Parçalanma Analiz Yöntemleri.....	4
1.3.1. Genel Bakış .....	4
1.3.2. Ampirik Modellerle Parçalanma Analizi.....	5
1.3.2.1. Kuz-Ram Modeli .....	5
1.3.2.2. KCO Modeli .....	8
1.3.3. Görüntü Analizi .....	8
1.3.4. İstatistiksel Modeller ile Kaya Parçalanma Analizi .....	9
1.3.5. Yapay Zeka ile Kaya Parçalanma Analizi.....	9
1.4. Yeraltı Patlamalarında Parçalanma Tahmin Modelleri .....	10
1.5. Yapay Sinir Ağları (YSA).....	11
1.6. Yeraltı Ayna Patlatma Dizaynı .....	16
2. SAHA ÇALIŞMALARI VE YÖNTEM .....	18
2.1. Sahanın Konumu .....	18
2.2. Sahada Uygulanan Üretim Metodu .....	18
2.3. Sahanın Jeolojik Özellikleri .....	19
2.4. Sahada Ön Ölçümler ve Gözlem Çalışmaları .....	19
2.4.1. Kaya Kütlelerinde RQD tayini .....	19
2.4.2. Kayanın Mekanik Özelliklerinin Tayini.....	20
2.4.3. Aynalarda Kaya Kütlelerinin Fiziko-Mekanik Özelliklerinin Belirlenmesi .....	23
2.5. Patlatma Parametrelerin Ölçülmesi.....	24

2.5.1.	Gümüřtař Madencilik A.ř. Yeraltı Madeninde Ayna Dizaynı .....	24
2.5.2.	Deliklerin řarjlanması ve Ateřleme Sistemlerinin Baęlanması .....	26
2.5.3.	Patlatma Parametrelerinin Kaydedilmesi .....	28
2.6.	Split Desktop ile D80 Analizi İin Görüntü Alma ve İřleme .....	29
2.7.	oklu Regresyon ile Paralanma Tahmin Modelin Oluřturulması.....	31
2.8.	YSA ile Paralanma Tahmin Modelinin Oluřturulması .....	31
2.8.1.	Gizli Katmandaki Optimum Nöron Sayısının Belirlenmesi.....	34
3.	BULGULAR VE TARTIřMA .....	35
3.1.	Split Desktop ile D80 Deęerlerinin Belirlenmesi .....	35
3.2.	Toplanan Verilerin Özeti.....	36
3.3.	oklu Regresyon ve YSA Modelleri İle Paralanma Analizi.....	37
3.3.1.	Verilerin Hazırlanması .....	37
3.3.2.	D <sub>80</sub> Tahmin Modellerinin Oluřturulması .....	39
3.3.2.1.	Model Deęiřkenleri Verilerinin Normalite Analizleri.....	39
3.3.2.2.	oklu Regresyon Analizi ile D <sub>80</sub> Tahmin Modelinin Oluřturulması .....	40
3.3.2.3.	YSA Tahmin Modeli ve Sonuları .....	41
3.3.2.4.	Elde edilen YSA'nın özeti .....	43
3.4.	Tahmin Modellerinin Tartıřılması .....	44
3.5.	Modellerin Genelleme Performanslarının Deęerlendirilmesi .....	45
3.6.	Duyarlılık Analizi.....	50
4.	SONULAR .....	52
5.	ÖNERİLER .....	53
6.	KAYNAKLAR.....	54
7.	EKLER .....	59
	ÖZGEMİř	

Yüksek lisans tezi

## ÖZET

### YAPAY SİNİR AĞLARIYLA YERALTI AYNA PATLATMALARINDA KAYA PARÇALANMASININ MODELLENMESİ

Gerard EZOULA AGORO

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Maden Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Ferdi CİHANGİR  
2019, 58 Sayfa, 2 Sayfa Ek

Bu tez çalışmasında, yer altı ayna patlatmalarından ortaya çıkan malzemenin tane boyut tahminine yönelik bir yer altı maden işletmesinde 27 ayna için kazı çalışmaları izlenmiştir. Patlatmalar öncesinde kaya ortamının jeoteknik özellikleri ve patlatma dizayn parametreleri, patlatmalar sonrasında ise parçalanmış kaya yığınlarının ölçekli resimleri Split Desktop yazılımında görüntü işleme tekniği ile analiz edilmiştir. Analizlerde  $D_{80}$  değeri tayin edilmiştir. Yapay sinir ağları (YSA) ve çoklu regresyon analizleriyle 21 ayna verisi için (verilerin %78'i) parçalanma tahmin modelleri oluşturulmuş ve görüntü analizi değerleri ile kıyaslanarak modellerin performansları tayin edilmiştir. Geriye kalan 6 ayna verisi ise modellerin genelleme gücünü değerlendirmek için kullanılmıştır.

Elde edilen 4-8-1 mimari yapılı YSA tahmin modeli;  $R^2$  0.96, VAF %96.3 ve RMSE 0.008 performansına, çoklu doğrusal regresyon tahmin modeli ise  $R^2$  0.602; VAF %60.3 ve RMSE 0.026 performansına sahiptir. Elde edilen verileri denetlemek için genelleme testleri için modellere 6 bağımsız patlatma verisi girilmiş ve  $D_{80}$  hesaplanmıştır. Genelleme testlerine göre YSA yaklaşımıyla  $R^2$  0.84, RMSE 0.022 ve VAF %80 performansına, çoklu regresyon ise  $R^2$  0.81, RMSE 0.042 ve VAF %19 performansına sahiptir. Dolayısıyla YSA modeli çoklu doğrusal regresyon modeline göre daha yüksek tahmin gücüne sahiptir. %95 güven aralığı için YSA modeli ile tahmin edilen ve genelleme testinden elde edilen  $D_{80}$  değerlerinin değişim aralığı, ölçülen  $D_{80}$  değerleri ile çoklu doğrusal regresyon analizine kıyasla daha fazla benzerlik göstermektedir. Duyarlılık analizine göre parametrelerin parçalanma üzerine etkileri te  $TEBD=RQD > \text{ayna alanı} > \text{özümlü şarj}$  şeklindedir.

**Anahtar Kelimeler:** Patlatma, Parçalanma, Yapay sinir ağı, Çoklu regresyon, Görüntü analizi, Parça boyut tayini, Duyarlılık analizi, Split Desktop,  $D_{80}$



Master Thesis

## SUMMARY

### USE OF ARTIFICIAL NEURAL NETWORK FOR ROCK FRAGMENTATION PREDICTION IN UNDERGROUND FACE BLASTING

Gerard EZOULA AGORO

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Mining Engineering Graduate Program  
Supervisor: Assoc. Prof. Dr. Ferdi CIHANGİR  
2019, 58 Pages, 2 Pages Appendices

In this study, 27 blast events were monitored in an underground mine to investigate an efficient prediction model for rock fragmentation for face blasting activities. Before each face blasting, geotechnical properties of in-situ rock mass were collected along with blast design parameters. Afterwards, the scaled images of the muckpiles in front of the blasted faces were processed using Split Desktop to determine the  $D_{80}$  values. Then, on the basis of the 21 records (78% of the data), fragmentation prediction models were built using multivariate regression analysis (MVRA) and ANN approaches and results of each model were compared to the image analysis results to evaluate the performances of the models. The remaining 6 data were kept aside and used afterward for the generalization capabilities of the models. Optimum ANN model was obtained with a 4-8-1 architecture with performans values of  $R^2$  0.96, VAF 96.1% and RMSE 0.008. MVRA model was built with 0.602, 60.3% ve 0.026 performans criteria, respectively. ANN model predicted 6 data with  $R^2$  0.84, RMSE 0.022 and VAF 80% performance. However, MVRA model achieved the same predictions with  $R^2$  0.81, RMSE 0.042 and 19% VAF performance values. Thus, ANN and its generalization capabilities were found superior compared to MVRA. The variation interval in predicted and generalization  $D_{80}$  values using ANN model for 95% confidence interval is more similar to the measured  $D_{80}$  values compared to the MVRA results. According to the sensitivity analysis, the effectiveness of the parameters on fragmentation are very close to each other but the variables are in the order of  $TEBD = RQD > \text{face area} > \text{specific charge}$ .

**Key Words:** Blasting, Rock fragmentation, Artificial neural network, Image analysis, Multivariate regression, Fragmentation measurement, Sensitivity analysis,  $D_{80}$

## ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Yapay sinir ağlarına yönelik tipik bir geri yayılım şeması (Maier ve Dandy, 1998) .....	12
Şekil 2. Yapay sinir ağlarında işlem ünitelerinde kullanılan transfer fonksiyonları .....	13
Şekil 3. YSA geri yayılım algoritmasının genel prensipleri (Khandelwal ve Singh, 2009) .	13
Şekil 4. Ayna patlatmalarındaki farklı bölgeler (Holmberg, 1982).....	16
Şekil 5. Farklı orta çekme kesim dizaynları (Tim Magub -Ove Arup ve Partners Hong Kong Ltd.) .....	17
Şekil 6. Gümüştaş Madencilik A.Ş. konumu .....	18
Şekil 7. Aynaların yakın civarındaki sınırlanmış sondajlar.....	20
Şekil 8. Schmidt çekici testinin yeraltı aynalarında uygulanması .....	22
Şekil 9. Schmidt sertliği ve tek eksenli sıkışma dayanımı arasındaki ilişki (Deere ve Miller, 1966).....	22
Şekil 10. Fiziksel özelliklere yönelik yapılan laboratuvar deneylerinden bir görünüm .....	23
Şekil 11. Maden işletmesinde genel ayna tasarımı (toplam delik sayısı: 43+4) .....	25
Şekil 12. Jumbo ile aynada delgi işlemi .....	25
Şekil 13. Z3D30 nolu galeri aynasında uygulanan patlatma dizaynı örneği (22/12/2018).....	26
Şekil 14. Deliklerin patlayıcı ile şarjlanması ve yüzey bağlantılarının sağlanması .....	27
Şekil 15. 43 delikli bir ayna yüzeyinde gecikmeli kapsüllerin dağılımı .....	28
Şekil 16. Görüntü almada kullanılan temsili ekipmanlar .....	29
Şekil 17. Bölütleme sürecinin öncesinde (a) ve sonrasında (b) yığın görüntüsü (24/12/2018 tarihli 1350C2 nolu galeri aynası patlatması).....	30
Şekil 18. YSA'da veri işlem aşamaları ( <a href="https://www.mathworks.com/help/deeplearning/ug/choose-neural-network-input-output-processing-functions.html">https://www.mathworks.com/help/deeplearning/ug/choose-neural-network-input-output-processing-functions.html</a> ) .....	32
Şekil 19. NNtool'da YSA'nın oluşturulması.....	33
Şekil 20. NNtool'da YSA'nın eğitim ve simülasyon arayüzü.....	33
Şekil 21. 24/12/2018 tarihli 1350C2 nolu galeri aynası patlatmasıyla parçalanmış yığına ait Split Desktop ile kümülatif tane boyutu dağılımı analizi.....	35
Şekil 22. Verilere uygulanan çoklu doğrusal regresyon analizi sonuçları .....	40
Şekil 23. 21 adet very grubu için optimum YSA mimarisi .....	41
Şekil 24. Öğrenme, doğrulama ve test kümeleri için YSA performans grafikleri .....	42
Şekil 25. YSA geometrisi ve özellikleri .....	43
Şekil 26. Ölçülen ve tahmin edilen D80 değerlerinin %95 güven aralığında değişimi .....	46

Şekil 27. Bölünen 21 veri için ölçülen ve tahmin edilen D80 değerlerinin dağılımı .....	46
Şekil 28. YSA modeli için genelleme test sonuçları ve ölçülen D80 değerlerinin dağılımı ....	47
Şekil 29. Çoklu doğrusal regresyon modeli için genelleme test sonuçları ve ölçülen D <sub>80</sub> değerlerinin dağılımı .....	48
Şekil 30. Genelleme testine yönelik 6 veri için ölçülen ve tahmin edilen D <sub>80</sub> değerlerinin %95 güven aralığında değişimi .....	49
Şekil 31. Genelleme testinde kullanılan 6 veri için ölçülen ve tahmin edilen D80 değerlerinin dağılımı .....	49
Şekil 32. D80 tahmin modellerinin oluşturulmasında kullanılan verilerin duyarlılık analizleri .....	51



## TABLULAR DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Fiziksel özelliklerin istatistiksel tablosu .....	24
Tablo 2. Galeri aynalarına ait girdi ve çıktı değişkenlerinin özeti .....	36
Tablo 3. Girdi ve çıktı değişkenlerine ait istatistikleri .....	37
Tablo 4. Verilerin bölünmesi.....	38
Tablo 5. Çoklu doğrusal regresyon ve YSA tahmin modellerinde kullanılan bölünmüş değişkenlerin normalite analizleri (tek örnek Kolmogorov-Smirnov Z).....	39
Tablo 6. Çoklu doğrusal regresyon ve YSA tahmin modellerinin genelleme testlerinde kullanılan bölünmüş değişkenlerin normalite analizleri (tek örnek Kolmogorov-Smirnov Z) .....	39
Tablo 7. Farklı YSA mimari ağ yapılarıyla elde edilen sonuçlar .....	42
Tablo 8. YSA geometrisine ait özellikler .....	44
Tablo 9. Modellerin $D_{80}$ tahmin performanslarının kıyaslanması .....	45
Tablo 10. Genelleme analizine yönelik performans ölçütleri.....	48

## KISALTMALAR VE VE SEMBOLLER DİZİNİ

ANFO: Amonyum nitrat/Fuel-oil

D80: Yığının %80'sinin geçtiği tane iriliğidir

ISRM: Uluslararası Kaya Mekaniği Komitesi (International Society for Rock Mechanics)

KCO: Kuznetsov-Cunningham- Ouchterlony Modeli

MVRA: Multivariate regression Analysis

RQD: Kaya Kalite Belirteci (Rock Quality Designation)

TEBD: Tek Eksenli Basma Dayanımı (Uniaxial Compressive Stress)

UCS: Unconfined Compressive Strength

YSA: Yapay Sinir Ağı

## 1. GENEL BİLGİLER

### 1.1. Giriş

Kaya parçalama, patlatmanın en önemli konusu sayılır. Çünkü delme patlatma, yükleme ve nakliyet zamanı, kırma eleme gibi patlatma öncesi ve sonrası işlemlerin verimini ve maliyetini oldukça etkilemektedir (Trivedi vd., 2014). Çok iri malzeme, yükeleme işlemini zorlaştırmakta, ekstra maliyetli ikincil patlatma gerektirebilmekte veya kırıcının enerji tüketimini artırabilmektedir. Çok ince malzeme ise çok fazla patlayıcı malzeme sarfiyatına ve yan bloklardan kopmalarla birlikte cevher seyrilmelerine sebep olabilmektedir (Mario, 2001). Bunun için patlatma tasarımı sırasında ince tane boyutu değil optimum parça boyutunun hedeflenmesi gerekmektedir.

Optimizasyon yapmak için kullanılan en temel yöntem deneme-yanılmadır. Yani doğru sonucu elde edene kadar sahada farklı senaryoları denemektir. Fakat bu yöntem çok masraflı ve mühendisin tecrübesine bağlı olarak uzun sürebilir. İkinci yöntem ise bir model oluşturup farklı olası senaryoları dizayn aşamasından itibaren öngörmek ve en iyisini seçip sahada uygulamaktır. Bu yöntem çok hızlı ve ucuz olduğundan günümüzde en çok tercih edilendir. Patlatma alanında kayaç parçalanmasına yönelik modeller oldukça önemli yer tutmaktadır. Kaya parçalanma konusunda ampirik, istatistiksel, bilgisayara dayalı nümerik sistemler ve son zamanlarda da yapay zeka yöntemleri geliştirilmiştir.

Modelleri başarılı bir şekilde kullanabilmek için saha patlatma parametrelerini ve saha koşullarını (faktörleri) iyi bir şekilde ele almak gerekmektedir. Thornton vd. (2002)'ye göre parçalanmayı etkileyen faktörler üç gruba ayrılabilir; *i*) kaya kütle özellikleri, *ii*) patlatma geometrisi ve *iii*) patlayıcı madde özellikleri. Patlatma geometrisi (delik çapı, delikler arası mesafe, dilim kalınlığı, sıkılama vb) ve patlayıcı madde özellikleri (güç, infilak hızı (VOD), yoğunluk, özgül şarj vb.) kontrol edilebilen parametreler olarak görülmektedir. Kaya kütle özellikleri (tek eksenli basınç dayanımı (TEBD), Elastisite modülü, RQD, vb.) ise kontrol edilemeyen faktörler olarak sayılmaktadır (Enayatollahi vd., 2014).

Patlatma ile kaya parçalamada tane boyut dağılımı tahmin modelleri ampirik yöntemlerle başlamış olup günümüzde hem literatür hem de uygulamalarda en çok kullanılanlar Kuz-ram ve KCO (Kuznetsov-Cunningham-Ouchterlony) gibi yaklaşımlardır.

Fakat bu metotların ana zayıflığı, girdi verisi olarak kullanılacak parametrelerin sınırlı olması ve genelde birden fazla çıktı verisi alınamamasıdır (Tiile, 2016). Bu eksikliği aşan yöntemler ise yapay sinir ağları (YSA) gibi Yapay Zeka metotlarıdır. Yapay Sinir Ağ (YSA) yaklaşımı 1980'lerde geliştirilmiş (Grossberg, 1988) ve geleneksel metodlarla çözülemeyen karmaşık doğrusal olmayan fonksiyonların simulasyonunu yapmak için en yaygın kullanılan yöntemlerden biridir (Trivedi vd., 2014). YSA, insan beyninin çalışma şeklini taklit eden bir zekâ sistemidir (Simpson, 1990). YSA algoritmalarını, biyolojik hücrelere olan benzetme iki özelliğe dayanmaktadır: 1) Öğrenme işlemi ile bilgi edinmek, 2) Elde edilen bilgiyi, bağlantı ağırlıkları içerisinde saklamak (Kulatilake vd., 2010).

Çok değişkenli regresyon da patlatma alanında en çok kullanılan istatistiksel yöntemdir. Birçok bağımsız değişkenlerle bağımlı bir değişkeni tahmin eden bir yöntemdir. Yapay zeka metotlarıyla en çok kıyaslanan yöntemdir (Khandelwal ve Singh, 2005; Shams vd., 2015).

Bir modeli oluşturmak ve/veya performansını değerlendirmek için patlatma ile parçalanmanın ölçülebilmesi gerekmektedir. Bunun için eleme, görsel, fotogrametri ve görüntü analiz yaklaşımları bulunmaktadır. Elemanın yüksek maliyetli olması, görsel ve fotogrametri gibi yöntemlerin de iç kusurları yüksek olduğundan, en çok uygulanan parçalanma analizi yöntemi görüntü analizidir (Chakraborty vd., 2004). Bu metot ilk olarak Nyberg ve Carlsson (1983) tarafından önerilmiş olup araştırmacılar tarafından yaygın olarak tercih edilmektedir. Optik sistemler ucuz, hızlı ve diğerlerine göre daha üstün metotlardır (Chakraborty vd., 2004). Parçalanmış malzemenin tane boyut dağılımından  $D_{80}$  değeri bulunmaktadır. Bunun nedeni;  $D_{80}$ 'in genellikle yükleme makinalarının ve kırıcı tesislerinin performansının belirlenmesinde kullanılmasıdır. Düşük  $D_{80}$  değeri yüksek kepçe yükleme verimi ve birincil kırıcı performansı demektir. İlaveten, düşük miktarda iri kaya parça sayısı ise daha az ikincil patlatma gerekliliğidir (Monjezi vd., 2009).

Parçalanma analizi konusunda yapılmış araştırmalar ve geliştirilmiş modeller genellikle açık ocak maden işletmeciliği alanındadır. Fakat yer altı patlatmaları ile parçalanma analizine yönelik çalışmalar oldukça sınırlıdır (Onederra, 2004). Geliştirilen birkaç ampirik model (Adamson ve Lund, 2001) ve yazılan kodların çoğu tavan patlatmaları ile alakalıdır. Yapay sinir ağı (YSA) modeli kullanılarak yer altı ayna patlatmaları ile parçalanma analizi, yapmış olduğumuz literatür taramalarına göre ilk kez bu tez çalışmasında yapılacaktır ve önemli bilimsel ve sektörel katkılarının olması beklenmektedir.

## 1.2. Tezin Gerekçesi ve Amacı

Madencilik çalışmalarında patlatma sonrası yapılan işlerin başarısı verimli bir patlatma işlemine bağlıdır. Bu sebeple yığının tane boyutu, yükleme süresi, nakliyat, enerji maliyeti gibi patlatma sonrası süreçleri optimize etmek için kaya kütle özelliklerini ve patlatma dizaynını esas alan modeller son zamanlarda oldukça önem kazanmıştır.

Bu tez çalışmasına yönelik 27 adet yeraltı maden galerisi aynasında patlatma öncesinde *i)* aynalarda jeoteknik çalışmalar yapılmış, *ii)* patlatma dizayn parametreleri gözlenmiş, *iii)* patlatma sonrasında parçalanmış kaya kütlelerinin fotoğrafları çekilmiş, *iv)* alınan görüntülerden Split Desktop yazılımı ile  $D_{80}$  tayini yapılmış, *v)* YSA ve çoklu regresyon analizleri ile 21 ayna izlemi için ön çalışma niteliğinde modeller oluşturulmuş ve elde edilen  $D_{80}$  tahminleri Split Desktop  $D_{80}$  değerleri ile korele edilmiş, *vi)* geriye kalan 6 veri de modellerin genelleme testlerinin performanslarının tayininde kullanılmıştır. Böylece, bu tez çalışmasında temel amaç; oluşturulan modellerin performanslarını sağlıklı bir şekilde ortaya koyarak arzu edilen  $D_{80}$  boyutunun tahmin edilmesidir.

Bu noktadan hareketle bu tez çalışmasında amaca ulaşmak için izlenecek hedefler aşağıdaki gibi özetlenebilir:

- Split Desktop yazılımı ile yeraltı galeri aynalarında yapılan patlatmalardan  $D_{80}$  boyutunun belirlenmesi,
- Elde edilen verilerin %75'ini kullanarak Matlab© yazılımında yeraltı galeri aynalarında kaya kütle ortam verileri ve patlatma dizayn verileri için Yapay Sinir Ağı (YSA) metodu ile patlatma yapılan aynalar için kaya parçalanma tahmin modelinin oluşturulması,
- YSA modelinin oluşturulmasında kullanılan yeraltı galeri aynalarındaki kaya kütle ortam verileri ve patlatma dizayn verileri için çoklu regresyon analizi ile parçalanma tahmin modelinin oluşturulması,
- YSA ve çoklu regresyon analizlerinden elde edilen  $D_{80}$  değerleri ile Split Desktop yazılımından elde edilen  $D_{80}$  değerlerini kıyaslayarak oluşturulan modellerin kıyaslanması ve performanslarının belirlenmesi,
- Elde edilen modellerin genelleme gücünü tayin edebilmek için modellerin oluşturulmasında hiç kullanılmamış 6 ayna patlatmasına (verilerin %25'i) ait değerlerin önceden tahmin edilmesi ve modellerin başarısının değerlendirilmesi,



- Her girdi parametresinin kaya parçalamaya olan etkisinin seviyesinin belirlenmesi amacıyla duyarlılık analizinin yapılması.

Parçalanma analizi konusunda yapılmış arařtırmalar ve geliřtirilmiř modeller genellikle açık ocak maden iřletmecilięi alanındadır. Fakat yeraltı patlatmaları ile parçalanma analizine yönelik çalıřmalar oldukça sınırlıdır. Bunun en önemli nedenleri, yer altı çalıřma kořullarının zorluęu ve riskleri ile yeraltında kaya kütlelerinin jeoteknik özelliklerinin belirlenmesinin oldukça zor olmasıdır.

Yapay sinir aęı (YSA) modeli kullanılarak yeraltı ayna patlatmaları ile parçalanma analizine yönelik literatürde řu ana kadar herhangi bir çalıřmaya rastlanmamıř olup, ilk kez bu tez çalıřması kapsamında yapılmıřtır. Bu çalıřmanın yeraltı patlatmaları ile parçalanma analizinde ilk çalıřma olması ve YSA yönteminin kuvvetli, ucuz ve pratik çözümler üretmesi potansiyelinin yüksek olması nedeniyle önemli bilimsel ve sektörel katkılarının olacaęı öngörülmektedir.

Yapay sinir aęları ile herhangi bir aynaya yönelik temel kaya kütle/kaya mekanięi özelliklerinden yola çıkılarak arzu edilen  $D_{80}$  boyutunun önceden tahminine yönelik tahmin modelinin oluřturulmasıdır. Bu yolla, madencilik sektöründe yařanan kaya parçalanma sorunlarına daha ekonomik çözümler sunulabilecektir (Örneęin; tez çalıřmasından elde edilecek sonuçlar, tez çalıřmalarımız kapsamında yürüttüğümüz çalıřmalara imkânlar saęlayan maden řirketindeki (Gümüřtař Madencilik ve Ticaret Ař Gümüřhane-Türkiye) mühendisler ile paylařılması ve çıktıların iřletmede uygulanan patlatma tasarımının optimize edilmesinde kullanılması planlanmaktadır. Böylece optimum ve daha ekonomik patlatma tasarımının saęlanmasına, patlatma ile parçalanmıř kütlelerin yüklenmesi/nakliyesi verimlilięinin de artırılabilmesine katkıda bulunulabilecektir.

### **1.3. Kaya Parçalanma Analiz Yöntemleri**

#### **1.3.1. Genel Bakıř**

Kaya parçalanma analizleri doğrudan ve dolaylı yöntemler olmak üzere iki gruba ayrılmaktadır (Siddiqui vd., 2009). Eleme sistemi doğrudan metot sayılır. Görsel yaklařımlar (patlatma mühendisinin tecrübesine baęlı olarak atıma bakarak yaptıęı

tahminler), ampirik ve dijital sistemler ise dolaylı yöntemler grubunda yer almaktadır (Sereshki vd., 2016).

Patlatma ile parçalanmaya yönelik boyut ölçümünde en doğru yöntem şüphesiz klasik eleme sistemidir. Ancak her gün binlerce ton malzemenin üretilerek işlemlerden geçirildiği madencilik faaliyetleri, işletme ekonomisi, emek ve zaman yükünden dolayı geleneksel eleme yönteminin uygulanması neredeyse imkânsızdır. Bu sebeple yerinde (in-situ) kaya ve patlayıcı özelliklerine dayanan boyut dağılımı hesaplamaları ve parçalanma parametreleri için “Kuz-Ram modeli, SveDeFo’s eşitliği, CK modeli ve Kou-Rustan eşitliği gibi” ampirik modeller tanımlanmıştır. Bu yöntemlerin dezavantajlı oldukları nokta, kaya yığını değerini tam olarak ölçememeleridir (Bedair, 1996). Bu temel sorundan dolayı, patlatma sonrası oluşan malzemeyi nispeten düşük bir maliyetle, kısa sürede ve az iş gücü ile analiz edebilmek için dijital sistemler geliştirilmiştir.

### **1.3.2. Ampirik Modellerle Parçalanma Analizi**

Yukarıda belirlendiği gibi patlatma ile kaya parçalanma tahmininde en yaygın kullanılan ampirik modeller Kuz-Ram ve KCO modelleridir.

#### **1.3.2.1. Kuz-Ram Modeli**

Kuz-Ram modeli ilk olarak Cunningham (1983) tarafından önerilmiştir. Ağırlıklı olarak Kuznetsov’un ortalama tane boyut formülüne (Kuznetsov, 1973) ve Rosin-Rammler düzgünlük indeksine ( $n$ ) dayanmaktadır. İlk çıkışından dört sene sonra revize edilmiş ve formüle Lilly’nin kaya faktörü eklenmiştir (Cunningham, 1987). Bu düzeltme, kayanın çeşitli jeoteknik özelliklerini kapsayarak modeli geliştirmiştir. Araştırmacılar ve mühendisler arasında patlatma girdi parametrelerini optimize etme işlemlerinde rehber olarak kullanılan bu model oldukça başarılı olmuştur. Literatürde bu modelin uygulandığı birçok araştırma bulunmaktadır (Adebola vd., 2016; Afum ve Temeng, 2015; Kabwe, 2017; Strelec vd., 2011). Bu başarımlarına rağmen kuz-ram modelinin ince taneleri tahmin etmede zayıf olduğu ve iri taneli malzemelerde üst sınır limitinin belirsizliği gibi zayıf yanları bulunmaktadır (Ouchterlony, 2005). Bu iki ana eksiklikten dolayı kuz-ram modeli, aşağıdaki faktörlerin etkilerini göz ardı etmektedir (Cunningham, 2005):

-Kayanın özellikleri ve yapısı (değişim, delme paterni ile olan ilişki, eklemlerin sıklığı),

-Basamak boyutları (basamak yüksekliği, sıkılama ve taban payı ilişkisi),

-Detonasyon davranışı ve detonasyon hızı (VoD),

-Patlatma paterni (her sıradaki delik sayısı ve sıra sayısı),

-Su, hava ve toprakla yapılan ara sıkılama,

-Delikler arası zamanlama ve zamanlamanın kesinliği,

-Patlatmada önceki sınırların etkisi. Her bir sınır önceki patlatmalar ya da jeolojik koşullara bağlıdır.

Bu modelin geliştirilmesinden yaklaşık yirmi sene sonra, Cunningham, bu faktörlerden bazılarını göz önünde alarak modeli yetkinleştirmek hedefiyle birkaç katsayı eklemiş ve düzeltmeler yapmıştır (Cunningham, 2005).  $X_{50}$  formülüne “zaman katsayısı (AT) ve düzeltme faktörünü (C(A))” katsayılarını eklemiştir. Ayrıca düzgünlük indeksi formülüne de “düzeltme faktörü (C(n)) ve düzgünlük faktörü (ns)” katsayılarını eklemiştir. Kuz-Ram modeline ait güncellenen formüller aşağıdaki gibidir.

Ortalama tane boyutunu ( $X_{50}$ ) veren Kuznetsov denklemi (Eşitlik 1) ;

$$X_{50} = A * A_T * q^{-0,8} * Qe^{1/6} * \left(\frac{115}{E}\right)^{19/20} * C(A) \quad (1)$$

Burada;

A: Kaya faktörü / AT: Zaman katsayısı/ Qe: Her deliğe düşen şarj ağırlığı (kg) / E: Patlayıcının ANFO’ya ağırlıkça göreceli kuvvetidir (ANFO=100) / C(A): düzeltme faktörü (0.5-2 arasında). Algoritma bilinen A’nın değerinden farklı olduğu halde C(A) kullanılmaktadır. A şu şekilde saptanmaktadır (Eşitlik 2);

$$A = 0.06 * (RMD + RDI + HF) \quad (2)$$

Burada;

RMD (Kaya kütle sınıflaması) = çok çatlaklı, parçalanmış ise 10; masif kaya kütleli ise 50; eğer düşey eklemler ise JF.

JF (Eklem faktörü) = JCF (Eklem hal faktörü) \* JPS (Eklem düzlemi aralığı) + JPA (Eklem düzlemi yönelimi).

JCF= 1 (sıkı eklemler için); 1.5 (gevşek eklemler); 2 (dolgu malzemeli eklemler)

JPS= 10 (eklem aralığı ortalaması <0.1m); 20 (0.1-0.3m arasında ise); 80 (P nin %0.3-95%, 'ı ise); 50 (>P ise).  $P = \sqrt{S * B}$  (S delikler arası mesafe ve B dilim kalınlığı).

JPA= 10 (yatay durumda), 20 (aynanın dışına doğru dalan durumda); 30 (aynaya dik durumda); 40 (aynanın içine doğru dalan durumda).

RDI (özgül ağırlık etkisi) = 0.025\* $\rho$ -50,  $\rho$ : kayaç özgül ağırlığı (kg/m<sup>3</sup>).

HF (Sertlik katsayısı) = E/3 (E<50); UCS/5 (E>50), E: Elastisite Modülü (GPa) ve TEBD (MPa).

$A_T$  Formülü (Eşitlik 3);

$$\left\{ \begin{array}{l} A_T = 0.66 * \left(\frac{T}{T_{max}}\right)^3 - 0.13 * \left(\frac{T}{T_{max}}\right)^2 - 1.58 * \left(\frac{T}{T_{max}}\right) + 2.1 \quad \frac{T}{T_{max}} \text{ 0 - 1 arasında} \\ A_T = 0.9 + 0.1 * \left(\frac{T}{T_{max}} - 1\right) \quad \frac{T}{T_{max}} \text{ 'nin yüksek değeri için} \end{array} \right. \quad (3)$$

$T_{max}$  optimum parçalanma için optimum gecikme zamanıdır (Sıradaki delikler arası gecikme)  $T_{max} = \frac{15.6}{C_x} * B$ ,  $C_x$ : boyuna dalga hızı (km/s).

Düzgünlük indeksinin denklemi (Eşitlik 4);

$$n = n_s \sqrt{\left(2 - \frac{30B}{D}\right)} * \sqrt{\left(\frac{1+S/B}{2}\right)} * \left(1 - \frac{W}{B}\right) * \left(\frac{L}{H}\right)^{0.3} * C(n) \quad (4)$$

Burada;

H: Basamak yüksekliği / L: şarj uzunluğu / q: özgül şarj/ B: yük mesafesi (m) / S: delikler arası mesafe (m)/ D: delik çapı (mm) / W: delik sapmalarının standart sapması/ C(n): düzeltme faktörü/  $n_s$  düzgünlük faktörü  $n_s = 0.206 + \left(1 - \frac{R_s}{4}\right)^{0.8}$ ;  $R_s$  saçılma oranı  $R_s = \frac{T_r}{T_x} = 6 * \frac{\sigma_t}{T_x}$ ;  $T_x$  delikler arası istenen gecikme zamanı (ms);  $T_r$ : başlatıcı sistemlerinin gecikme saçılma dağılımı (ms);  $\sigma_t$  başlatıcı sistemlerinin gecikme standart sapması (ms).

Parçanma boyut dağılımı için Rosin-Rammler denklemi (Eşitlik 5);

$$P(x) = 1 - e^{-0.693 * \left(\frac{x}{x_{50}}\right)^n} \quad (5)$$

X: elek açıklığı / P(x): açıklığı x olan elekten geçen malzemenin oranı.

### 1.3.2.2. KCO Modeli

Kuz-Ram modelinin ince malzeme ve maksimum malzeme boyutu tahmin zayıflıklarını gidermek için Ouchterlony tarafından geliştirilmiştir (Ouchterlony, 2005). KCO kısaltması Kuznetsov Cunningham Ouchterlony anlamına gelmektedir. Çünkü Rosin-Rammler, fonksiyonunu ortalama parça boyutu temel parametresi olarak kullanmıştır. Bunun yanı sıra parçalanma boyutunda üst limit yani maksimum malzeme boyutunu belirlemiştir (Eşitlik 6). Ayrıca eğri şekil katsayısını (Eşitlik 7) da kullanarak Kuz-Ram modeline eklemiştir.

$$P(x) = \frac{1}{\left[1 + \frac{\ln(x_{max}/x)}{\ln(x_{max}/x_{50})}\right]^b} \quad (6)$$

$$b = [2 \ln 2 * \ln(x_{max}/x_{50})] * n \quad (7)$$

Burada;

x: Belirlenen elek açıklığı (cm),  $x_{50}$ : Ortalama parça boyutu (cm),  $x_{max}$ : Maksimum parça boyutu (cm), b: Eğri şekil katsayısı, n = Üniformluk indeksi'dir.

### 1.3.3. Görüntü Analizi

Görüntü tabanlı granülometri sistemleri, malzemenin boyut dağılımını belirlemek için bir kayaç yığınının ait fotoğrafların kullanılmasını esas alan sistemlerdir. Bu sistemler genellikle görüntüde bulunan bloklar arasındaki gölgeleri işleyerek blokları algılamakta ve "kenar algılama" şeklinde isimlendirilen algoritmaları kullanmaktadır. Bu yöntem ilk olarak Nyberg ve Carlsson (1983) tarafından önerilmiş ve araştırmacılar tarafından yıllar içerisinde geliştirilerek daha pratik ve daha gerçekçi sonuçlar veren bir hale gelmesiyle büyük ilgi uyandırmış ve popüler bir hal almıştır. Franklin vd. (1996) yapmış oldukları bir çalışmada bu ölçüm sistemlerinin gelişim süreçlerini değerlendirmişlerdir. Günümüzde yaygın olarak kullanılan birçok ticari görüntü işleme sistemi yazılımı bulunmaktadır. Bunlardan bazıları; Split Desktop, Fragscan, Powersieve, WipFrag, IPACS, TUCIPS,

CIAS, GoldSize, Fragalyst, KTH ve WIEP gibi yazılımlardır (Sereshki vd., 2016; Siddiqui vd., 2009). Bu tez çalışmasında görüntü analizi için Split-Desktop yazılımı kullanılmıştır.

#### **1.3.4. İstatistiksel Modeller ile Kaya Parçalanma Analizi**

Kaya parçalanma modelleri geliştirmek üzere en çok kullanılan istatistiksel yöntem çoklu lineer regresyon metodudur. Çoklu regresyon, kaya patlatmaya ilişkin literatürde genel olarak yapay zeka gibi diğer yöntemlerin yanında genellikle kıyas amaçlı uygulanmaktadır. Yine de tek metod olarak kullanıldığı çok sayıda çalışmalar vardır.

Elevli ve Topal (2012), çoklu lineer regresyon metodunu kullanarak  $P_{20}$ ,  $P_{50}$  ve  $P_{80}$  (parçalanmış yığının %20, %50 ve %80'inin geçtiği tane irilikleridir) değerleri için üç parçalanma tahmini modeli oluşturmuştur. Kirdar taş ocağında (Kütahya/Türkiye) yapılan 147 patlatma öncesi ölçülen TEBD, dilim kalınlığı ve özgül şarj parametrelerini modellerin girdi değişkenleri olarak kullanılmıştı. Silva vd. (2017), Geoblast SA'dan alınan 47 adet parçalanma veri seti esas alınarak kullanılmıştır. Çalışmada  $P_{20}$ ,  $P_{50}$  ve  $P_{80}$  tahmininde kullanılan değişkenler şu şekildedir; dilim kalınlığı, delikler arası mesafe, basamak yüksekliği, sıkılama boyu, delik çapı, baskın jeoteknik birim, patlayıcı miktarı ve özgül şarjdır.

Hudaverdi vd., (2012), yaptıkları bir çalışmada dünyanın farklı madenlerinden ve farklı kaya kütlelerinden alınan parçalanma analiz sonuçlarıyla ortalama tane boyutunun ( $D_{50}$ ) belirlendiği bir model oluşturmuştur. Bu modelde parçalanma indeksi (FI) ve elastisite modülü kayanın tanım parametreleri olarak kullanılmış ve oluşturulan modelin Kuz-Ram modeline göre daha güçlü olduğu görülmüştür.

#### **1.3.5. Yapay Zeka ile Kaya Parçalanma Analizi**

Yapay zeka grubunda Yapay Sinir Ağı, Bulanık Mantık, ANFİS (Uyarlamalı ağ tabanlı bulanık çıkarım sistemi), Genetik algoritmalar, Uzman Sistemler, Zeki etmenler yer almaktadır. Bu sistemlerin temel prensipleri; gerçek verilerle bir modele eğitim verilmesi ve bundan sonra her hangi yabancı veri sisteme konulduğunda çıktı tahmini yapılması şeklindedir. Patlatma alanında ve özellikle parçalanma analizinde en çok kullanılan yapay zeka yaklaşımları Yapay Sinir Ağı (YSA) ve Bulanık Mantıktır (BM).

YSA, insan beyninin çalışma şeklini taklit eden bir sistemdir. Parçalanma tahmininde istatistiksel ve ampirik modellerden daha verimli görülmüştür. Tiile (2016), Gana'nın Perseus Mining Limited altın madeninde kaya parçalanması, yer sarsıntısı ve hava şokunu tahmin edebilen bir YSA modeli oluşturmuştur. Çalışmasında aynı anda hem çoklu regresyon hem de bazı ampirik modeller kullanarak hesaplamalar yapmıştır. 7-13-3 mimarisinde elde edilen optimum YSA modeli,  $D_{80}$ 'i  $R^2=0.997$ ,  $MSE=0.316$  değerleri ile tahmin ederken, çoklu regresyon  $R^2=0.799$  ve  $MSE=5.968$  performansını sergilemiştir.

Bahrami vd. (2011), yaptıkları bir çalışmada on adet girdi verisinden (delik çapı, dilim kalınlığı, özgül şarj, özgül delik, patlatılabilirlik indeksi, vb.) ve bir adet hedef verisinden (parçalanma) oluşan bir YSA modeli oluşturmuştur. İleri beslemeli geri yayımlı algoritmayla yapılan ağ eğitimi sonucunda 4 katmanlı (10-9-7-1) bir ağ optimum olarak bulunmuş ve YSA'nın çoklu regesyona kıyasla ölçülen değerlere daha yakın tahminler yaptığı gözlenmiştir.

Bulanık mantık da yapay zekâ grubunda en güçlü yaklaşımlardan biridir. Klasik veya sıradan kümelerde bir elemanın üyeliği krisptir. Dolayısıyla bir eleman ya bir kümeye aittir veya ait değildir. Bu tür kümelerde, bir elemanın üyelik fonksiyonu tüm elemanları tanımlamak için yeterlidir. Fakat, normal kümelerin genellemesi olan bulanık kümelerinde kesin sınırlar yoktur ve bir eleman  $[0, 1]$  aralığında olan belli bir seviye ile bir kümeye ait olabilir. Böylelikle klasik mantığın doğruluk değerlerini zenginleştiren bir anlatım olanağı ortaya çıkar. İran'daki Sarcheshmeh Bakır Madeni'nde, kaya parçalanmasını tahmin etmek üzere bulanık mantık kullanılmıştır (Shams vd., 2015). Ölçülen ve tahmin edilen  $D_{80}$ 'ler arasında 0.922 belirtme katsayısı ( $R^2$ ) değeri ortaya çıkmıştır.

Benzer şekilde 415 patlatma verisine dayanan bulanık mantık modeli oluşturulan bir çalışmada çoklu regresyon modeli ile kıyaslamalar yapılmıştır. Bulanık mantık ile elde edilen modelin performansının ( $R^2=0.96$ ,  $RMSE=3.6$ ) çoklu regresyona göre daha yüksek ( $R^2=0.8$ ,  $RMSE=6.83$ ) olduğu görülmüştür (Monjezi vd., 2009).

#### **1.4. Yeraltı Patlamalarında Parçalanma Tahmin Modelleri**

Açık ocak madenciliği ile kıyaslandığında, yeraltı patlatmalarında parçalanma analizi ile ilgili araştırmalar oldukça sınırlıdır. Yeraltı patlatmaları ile ilgili az miktardaki uygulama da genellikle üretim aynası patlatmaları üzerinedir.

Yeraltı üretim patlatmalarına yönelik ampirik yöntemlerin uygulamaları, basit yeraltı patlatma paternleri üzerinde parçalanmayı öngörmek için sahaya özgü formüller kullanılarak Stagg ve arkadaşları tarafından yayımlanmıştır (Stagg vd., 1994). Adamson ve Lund (2001)'un yapmış oldukları bir çalışmada değiştirilmiş Kuz-Ram modelleme prosedürlerine dayanan benzer yöntemleri kullanmışlardır. Bununla birlikte, bu yaklaşımlar, yeraltı ayna patlatma koşullarında bulunan daha karmaşık geometrilerin karakteristiği olan patlayıcı şarjlarının üç boyutlu dağılımını uygun şekilde belirleyememektedir (Onederra, 2004).

Yeraltı kaya parçalanma modellemesinde doğrudan uygulanan birkaç mekaniksel model bulunmaktadır. Bu modellerin bazıları FRAGNEW, DynACAD-3D gibi yazılım paketlerinde kodlanmıştır. Sheikh ve Chung (1987), SABREX modelinin ICRAK bileşeninin uygulanmasını yeraltı Denison Madeni'nde incelemişlerdir. Ancak bu modelleme çalışması, yalnızca paralel delik içeren patlatma koşulları ile sınırlı kalmıştır (Onederra, 2004).

Yukarıdaki modeller, yeraltı tavan patlatmalarına yönelik parçalanma modelleri içindir. Ayna patlatmalarına yönelik kaya parçalanma modellemesi ise geliştirilmesi gereken bir alandır.

### **1.5. Yapay Sinir Ağları (YSA)**

Orijinal sinir ağı McCulloch ve Pitts (1943) tarafından 1940'lı yılların başlarında geliştirilmiş olup, yöntemin bilim ve mühendislik alanlarındaki uygulamaları ise zaman içerisinde gelişim göstermiştir. YSA yaklaşımı, lineer olmayan karmaşık fonksiyonları modellemek için beynin düşünme sürecini taklit eden sistemlerin oluşturulmasında kullanılmaktadır. Bunun nedeni beynin, model tanıma, algılama ve hareket kontrolü gibi karmaşık işlemlerin gerçekleştirilmesinde bilgisayar çiplerinden daha hızlı ve daha verimli olmasıdır. Bu nedenle, beyin fonksiyonlarını taklit etmek sinir ağına, fiziksel akıl yürütme ve matematiksel yaklaşımlarla çözülemeyen problemleri modellemek için çözümler üretme yeteneği verebilmektedir.

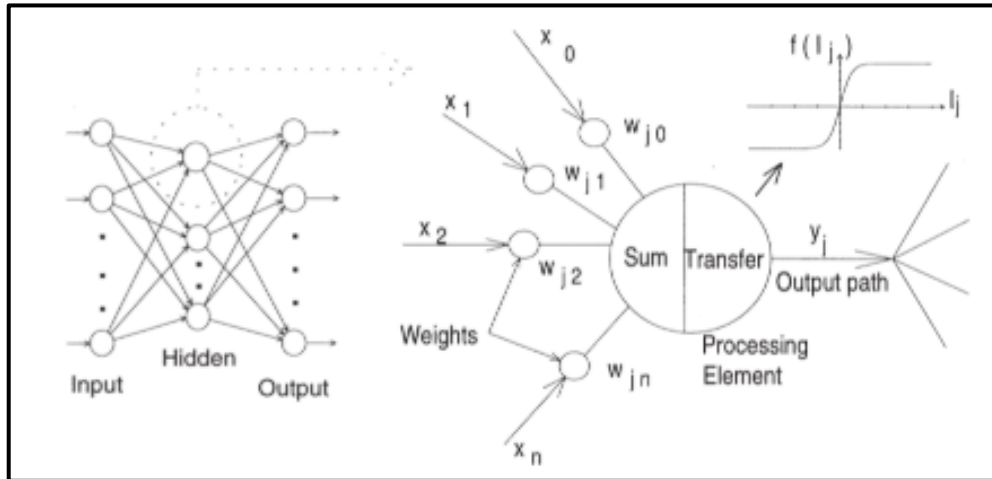
YSA; inşaat, madencilik, petrol ve doğal gaz, tıp, tarım, kontrol sistemleri, sigorta, bankacılık, askeri hedef tanıma gibi alanlara uyarlanmış ve başarıyla uygulanmış esnek ve çok yönlü sistemlerdir (Demuth vd., 2009).




Birçok farklı sinir ağı türleri bulunmaktadır. Bunlara örnek olarak; ileri beslemeli sinir ağı (FFNN), radyal temel fonksiyon sinir ağı (RBFNN), çok katmanlı algılayıcı (MLPNN), genel regresyon (GRNN), kıvrımlı/evrimli (konvolüsyonel) sinir ağı, tekrarlayan sinir ağı ve modüler sinir ağı sıralı modelleri gösterilebilir.

Bir sinir ağı, katmanlar halinde organize edilmiş birbirine bağlı nöronların (veya işlem birimlerinin) bir sistemidir. Tipik bir sinirsel sinir ağı 3 katmandan oluşur. Bunlardan birincisi giriş katmanı, ikincisi gizli katman ve sonuncusu ise çıkış katmanı şeklinde tanımlanabilir (Şekil 1). Katmanlar arasındaki bağlantılar, giriş katmanına (veya algısal katmana) sunulan bilgilerin gizli katmanlardan çıkış katmanına kadar akmasına izin verir. Düğümler arasındaki bu bağlantılar, sunulan girdiler ve karşılık gelen çıktılar arasındaki ilişkinin doğasını öğrenmek için sinir sistemi tarafından kullanılan (ve sürekli olarak güncellenen) bağlantı ağırlıklarının (veya sinaptik ağırlıkların) varlığı ile karakterize edilir.

Her nöronun içerisinde, girilen ve toplanan verileri işleyerek nöron çıktısına çeviren ve otomatik olarak sonraki katmanda bulunan nöron için bir girdi verisi haline getiren bir aktarma fonksiyonu kullanılmaktadır. İşlem ünitesinde kullanılmak üzere farklı transfer fonksiyonları mevcuttur. Ancak geri yayılım için en yaygın fonksiyonlar başlıca; log-sigmoid (Logsig), Tangent sigmoid (Tansig) ve lineer transfer fonksiyonu şeklinde sıralanabilir (Şekil 2) (Demuth vd., 2009).

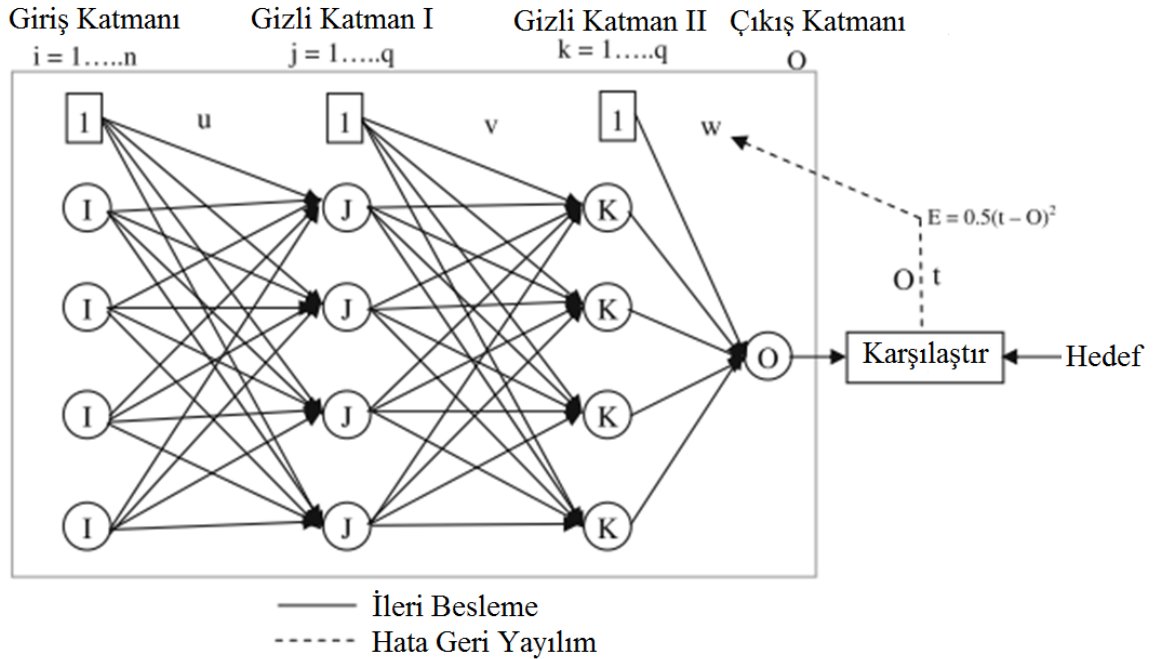


Şekil 1. Yapay sinir ağlarına yönelik tipik bir geri yayılım şeması (Maier ve Dandy, 1998)



Şekil 2. Yapay sinir ağlarında işlem ünitelerinde kullanılan transfer fonksiyonları

Öncelikle YSA metodunda ağların mümkün olduğunca fazla veri kullanılarak eğitilmeleri gerekmektedir. Rumelhart vd. (1986) tarafından geri yayılımın önerildiği birçok eğitim algoritması bulunmakla birlikte bu algoritmalar aynı zamanda en sağlam ve çok yönlü algoritmalar olarak da görülmektedir (Khandelwal ve Singh, 2009; Murthy vd., 2006). Geri yayılım algoritmalarına örnek olarak; Dereceli azalma geri yayılımını (GD), Moment geri yayımlı dereceli azalma (GDM), Levenberg-Marquardt geri yayılımını (LM), BFGS quasi - Newton geri yayılımını (BFGS, QN), vb. gösterebiliriz (Demuth vd., 2009) (EK-1). Geri yayılım algoritmasının genel prensipleri Şekil 3'te verilmiştir.



Şekil 3. YSA geri yayılım algoritmasının genel prensipleri (Khandelwal ve Singh, 2009)

Şekil 3’te tek giriş katmanı (I), iki gizli katman (J ve K) ve bir çıkış katmanı (O) olan bir ağ algoritması gösterilmektedir.  $x_i$ ’yi katmanın girdi vektörü olarak düşünebiliriz (Eşitlik 8).

$$x_i = (x_1, x_2, x_3, x_4, \dots, x_n) \quad (8)$$

Gizli katman için net girdi değerleri şu şekilde olmaktadır (Eşitlik 9).

$$Net_j = \sum_{i=1}^n x_i w_{ij} + \theta_j \quad (9)$$

" $w_{ij}$ " nin sinaptik ağırlıklar olduğu durumda, giriş katmanındaki " $i$ ." nöronunu gizli katmandaki " $j$ ." nöronuna bağlar. " $\theta_j$ " ise eşik veya sapma (isteğe bağlı) olarak adlandırılır ve " $n$ " girdi sayısına karşılık gelir. Gizli katmandan gelen net çıktı transfer fonksiyonu kullanılarak hesaplanır (sigmoid fonksiyonu) (Eşitlik 10).

$$O_j = f(Net_j) = \frac{1}{1+e^{-(Net_j+\theta_j)}} \quad (10)$$

" $k$ ." birimi için toplam girdi (Eşitlik 11);

$$Net_k = \sum_{j=1}^n w_{jk} O_j + \theta_k \quad (11)$$

" $\theta_k$ " sapma (bias) nöronunu ve  $w_{jk}$  ise  $j$ th nöronunu  $k$ th çıkışına bağlayan ağırlığı ifade etmektedir. Bu nedenle  $k$ th biriminden elde edilen toplam çıktı aşağıdaki şekilde hesaplanır (Eşitlik 12);

$$O_k = f(Net_k) \quad (12)$$

Hesaplanan  $O_k$  çıktısı genellikle ilk çalıştırmada hesaplamaların rasgele ağırlıklar kullanılarak yapıldığı düşünüldüğünde, hedeflenen çıktının gerçek değerinden farklıdır. Model çıktısı ile hedeflenen  $t_k$  değerleri arasındaki farka hata denilir ve aşağıdaki şekilde hesaplanır (Eşitlik 13):

$$e_l = t_k - O_k \quad (13)$$

Toplam hata fonksiyonu ise aşağıdaki şekildedir (Eşitlik 14);

$$E = 0.5 \sum_{k=1}^n (t_k - O_k)^2 \quad (14)$$

İşlenen hatanın ölçülmesiyle model, hatayı en aza indirmek için bağlantı ağırlıklarının ne kadar değiştirilmesi gerektiğini belirlemek amacıyla öğrenme hızı parametresi ( $\eta$ ) ile birlikte bu hatayı (E) kullanır. Bu nedenle ağırlıktaki değişim aşağıdaki formül kullanılarak hesaplanır (Eşitlik 15):

$$\nabla W_{jk} = -\eta \left( \frac{\delta E}{\delta W_{jk}} \right) \quad (15)$$

(n+1)'inci model için güncelleme ağırlıkları (Eşitlik 16)'da verilmiştir;

$$W_{jk}(n+1) = W_{jk}(n) + \nabla W_{jk}(n) \quad (16)$$

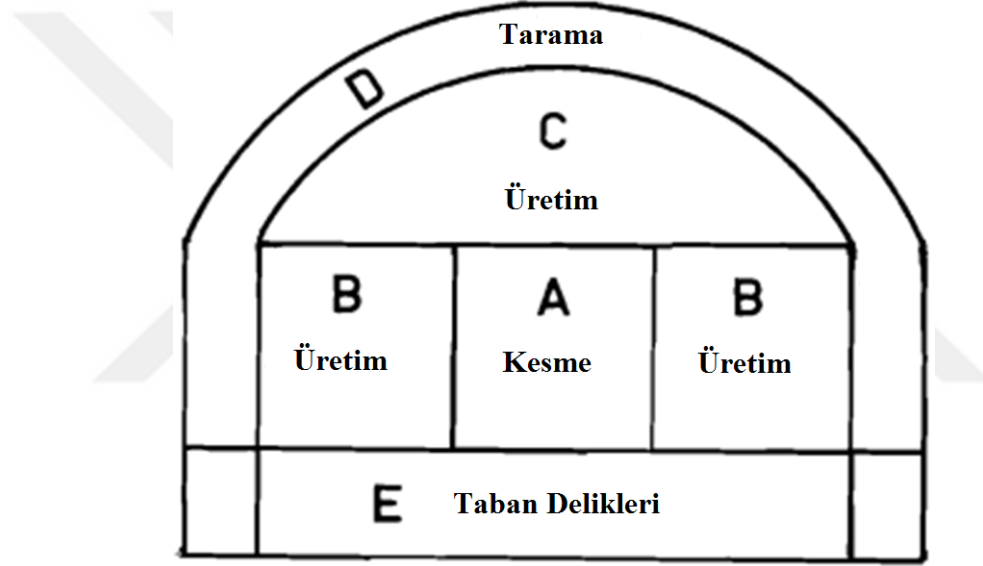
Bu hesaplama mantığı, gizli ve çıktı katmanları arasında benzer şekilde uygulanır ve tüm işlem (döngü), hata, amaç fonksiyonu tarafından belirtilen bir değere yaklaşıncaya dek mümkün olduğunca tekrarlanır. Eğitim, validasyon ve test süreçlerinden tatmin edici sonuçlar alındıktan sonra, ağ onaylanmış bilgiyi eğitim aşamasının bir parçası olmayan girdilerden çıktı almak için kullanabilir. Bu işlem “genelleme” olarak adlandırılır (Khandelwal ve Singh, 2005).

YSA, madencilik alanında, özellikle parçalanma tahmininde kullanılan patlatma mühendisliğinde (Bahrami vd., 2011; Oraee ve Asi, 2006), zemin titreşim tahminlerinde (Arpaz vd., 2013; Khandelwal ve Singh, 2009), hava basıncı hesaplamalarında (Khandelwal ve Singh, 2005) ve kaya fırlama tahminlerinde (Monjezi vd., 2010) çok faydalı bulunmuştur. Bunun temel nedeni, YSA fonksiyonunun bölgeye özgü olabilmesi ve geleneksel ampirik yöntemlerle yapılamayan parametreler arasındaki karmaşık ilişkileri çıkarabilmesidir.

Yapay sinir ağlarının kaya mekaniği alanında TEBD (Yetkin vd., 2018) ve üç eksenli basıncın olduğu koşullarda hava akış debisini tahmin etmede (Ranjith ve Khandelwal, 2012) güçlü bir tahmin aracı olarak etkinliği test edilmiştir.

### 1.6. Yeraltı Ayna Patlatma Dizaynı

Tünel veya galeri aynaları genel olarak kesme (orta çekme), üretim (stop), dış kesme/tarama/çevre (contour) ve taban delikleridir (lifters) olmak üzere dört ana bölgeye ayrılmaktadır (Şekil 4).




Şekil 4. Ayna patlatmalarındaki farklı bölgeler (Holmberg, 1982)

Kesme (iç kesme/orta çekme), ayna tasarımının en önemli kısmıdır. Dolayısıyla, başarılı bir patlamaya ulaşmak için en önemli rolü oynar. Açık ocak basamak patlatmalarındaki serbest yüzeye benzer şekilde, kesmenin rolü, kırılan kaya hareketini kolaylaştırmak için yüzeyin içinde bir boşluk oluşturmaktır. Bu da kesme bölgesini uygun şekilde ateşlemek için uygun gecikmelerin kullanılması ve daha sonra çevresindeki deliklerin yüklerini kesme açıklığına doğru yönlendirmesine olanak sağlanması ile elde edilir. Tatminkâr bir patlatma sonucu elde etmek için, kesme bölgesi uygun bir şekilde seçilmeli ve tasarlanmalı, aynaya dikkatlice yerleştirilmeli ve delinmeli, doğru yüklenmeli ve sıkılanmalıdır (Murthy vd., 2006). Yeraltı tasarımında en yaygın kullanılan kesme

yöntemleri; paralel delik (veya orta çekme) ve açılı delik kesimleri (V kesimi) olarak da bilinir. Kaya koşullarına, delme ekipmanına ve diğer çalışma koşullarına bağlı olarak her bir yöntem için farklı varyasyonlar uygulanabilmektedir (REVEY Associates, 2005).

En çok tercih edilen kesim tipi, genellikle mekanik delme işleminde kullanılan orta çekme kesimidir. Farklı çeşitte orta çekme kesimleri mevcuttur (Şekil 5) ve seçim, patlama mühendisine veya ateşleyiciye bırakılmıştır. Gümüştaş Madencilik A.Ş.'de aşağıda belirtilen 4 numaralı orta çekme kesim tipi uygulanmaktadır.



Şekil 5. Farklı orta çekme kesim dizaynları (Tim Magub -Ove Arup ve Partners Hong Kong Ltd.)

Öte yandan V-kesmeler, havalandırma, güç ve iletişim gibi önemli yer altı tesisleri için tehlikelere neden olabilecek şiddetli kaya fırlatmalarına sebebiyet vermeleri nedeniyle daha az tercih edilirler. Dahası, V-kesmelerin delinmesi nispeten zor ve daha fazla zaman gerektirmesinden ötürü daha maliyetli olmaktadır.


Üretim bölgesi kesme patlatmasının hemen ardından patlatılmaktadır. Bunun sebebi, orta kesme patlatması ile oluşan serbest yüzeyden faydalanmaktır. Bitişik şarjlar arasındaki işbirliği eksikliği, delgi hatası, delik eğiminin olmaması ve patlatmanın yer çekimine karşı yapılması gibi temel sebeplerden dolayı üretim patlatmalarında daha fazla patlayıcı tüketimi meydana gelmektedir.

Dış kesme delikleri, galeri aynasının son şeklini belirledikleri için kenar kesiciler olarak da bilinirler. Bu delikler genellikle birbirlerine yakın şekilde delinir ve kontrollü patlatmalarda daha az şarj edilirler (REVEY Associates, 2005).

## 2. SAHA ÇALIŞMALARI VE YÖNTEM

### 2.1. Sahanın Konumu

Bu teze ilişkin saha çalışmaları Gümüşhane'de (Türkiye) şehir merkezinin 1 km güney-doğusunda, N40°24'36" ile N40°25'30" enlemleri ve E39°36'36" ile E39°36'72" boylamları arasında yer alan Gümüştas Madencilik A.Ş.'de gerçekleştirilmiştir (Şekil 6). Burası 7.5825 km<sup>2</sup> alana uzanan lisansa sahip bir Kurşun-Çinko (Pb-Zn) polimetalik yeraltı madenidir (EK-2). Bu iki cevhere ilave olarak bakır (Cu) cevheri de üretilmektedir.



Şekil 6. Gümüştas Madencilik A.Ş. konumu

### 2.2. Sahada Uygulanan Üretim Metodu

Madende arakatlı-göçertmeli-dolgu yeraltı üretim metodu uygulanmaktadır. Maden işletmesinde günlük olarak her birisi 8 saatlik 3 vardiya ile çalışılmaktadır. Diğer yeraltında işletilen madenler gibi Gümüştas Madencilik A.Ş.'de de üretim delme, patlatma, havalandırma, yükleme, nakliye, tarama, tahkimat (ayna patlatmaları için) aşamalarıyla gerçekleştirilmektedir. Katarasında bulunan parçalanmış malzeme yeryüzünde bulunan

cevher depolama sahasına taşındıktan sonra katarasını bir sonraki patlatmaya hazırlamak için tarama işlemleri gerçekleştirilir. Killi olan zayıf ve duraysız kaya formasyonları içeren kütlelerin bulunması durumunda, tarama sonrasında üretim bölgelerinin güvenli hale getirilmesi için gerekli tahkimat yapılır. Kaya cıvataları ve kaya bulonları, çelik hasır ve püskürtme beton kullanılan kaya destek sistemleridir.

Galerilerde ilerlemek için jumbo kullanılarak patlatma delikleri delinmektedir. Katarası oluşturmak için ise simba kullanılmaktadır. Malzemenin taşınmasını sağlamak için yeraltı kürekleri (uzaktan kumandalı), yeraltı loderleri (GHH) ve kamyonlar kullanılmaktadır.

### **2.3. Sahanın Jeolojik Özellikleri**

Gümüştaş Madencilik A.Ş., kurşun (Pb) ve çinko (Zn) üreten bir polimetalik yeraltı madenidir. Jeolojik araştırmalar maden yatağının çok düzensiz bir yapıda olduğunu ortaya koymuştur. Kireç taşı, granit, filiş ve jura karşılaşılan temel kaya formasyonlarıdır. Cevher taşıyan solüsyonlar genelde daha zayıf kaya kütlelerine doğru hareket etmeye meyilli olmalarına rağmen cevherin kireç taşı içerisinde yoğunlaşmış olduğu bulunmuştur. Cevherin bu şekilde kireç taşı içerisine yerleşmiş olması kireç taşlarının kimyasal ve fiziksel yapısıyla açıklanmaktadır. Kireç taşları jura volkanik tabakasının üzerinde yatmaktadır. Pirit (demir sülfür), galenit (kükürlü kurşun) gibi formasyonların dışında galeri pasajlarında, kalkoprit (bakırlı pirit) ve afelerit de gözlenmektedir. Kayanın zayıf bölgelerinde kalkoprit, galenit, karataş (sfalerit) ve damarlı prite de rastlanmıştır.

### **2.4. Sahada Ön Ölçümler ve Gözlem Çalışmaları**

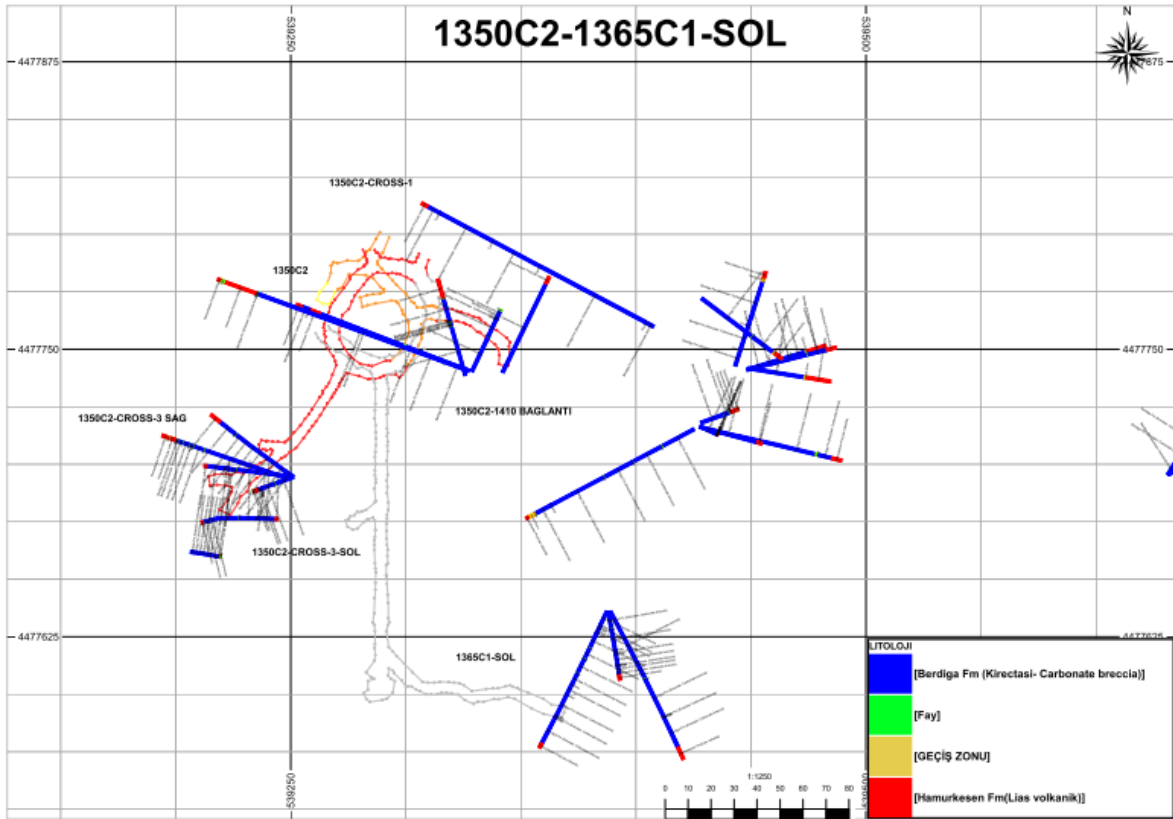
#### **2.4.1. Kaya Kütlelerinde RQD tayini**

Eksplorasyon ve üretim aşamaları boyunca şirket tarafından yüzeyden ve yeraltında karotlu sondajlar gerçekleştirilmiştir. Sondajlardan elde edilen veritabanında hesaplanmış olan RQD değerlerine şirket erişim izni vermiştir. Şirketin jeoloji ekibi ile Datamine© yazılımında her bir galeri etrafından geçen sondajlar sınırlama (constraint) fonksiyonu kullanılarak ayrılmıştır. Aynı fonksiyon ile sondajların boyutu sadece çalışılan bölge



kotları arasında olması şeklinde kısaltılmıştır. Şekil 7’de Datamine modelleme programından elde edilen bazı aynalara ait plan sonuçları sunulmuştur.

Tez çalışmasında, parçalanmaya yönelik tahmin modellerinin oluşturulmasında sağlıklı sonuçlara ulaşabilmek adına mümkün olduğunca aynı yan kaya ortamında (kristalize kireçtaşı) yapılan galeri ayna patlatmalarına eşlik edilmiştir. Dolayısıyla her bir sınırlandırılmış sondajın ortalama kireçtaşı RQD’si hesaplanmıştır. Üretilen herhangi bir aynanın RQD değeri, bu aynanın hemen yakın civarındaki sondajlardan elde edilen RQD’lerin ortalaması alınarak hesaplanmıştır.



Şekil 7. Aynaların yakın civarındaki sınırlandırılmış sondajlar

#### 2.4.2. Kayanın Mekanik Özelliklerinin Tayini

Tek eksenli basınç dayanımı (TEBD) ve elastisite modülü, kayanın mekanik özelliğinin tanımlanmasında en çok kullanılan parametrelerdendir. Saha çalışmasında yerindeki kayanın mekanik özellikleri TEBD ile nitelendirilmiştir. TEBD'yi belirlemenin en iyi yolu örnek karotların test edilmesi ve ortalama bir değer hesaplanmasıdır. Fakat bu

metot çok zaman almaktadır ve masraflıdır (Wang vd., 2016). Bu tez çalışmasında patlatmadan önce ve sonra aynadan karot üretilecek sağlıklı numune alımı ve laboratuvara getirilmesinde oldukça zorluklarla karşılaşmıştır. Patlatmadan sonra örnekleme yapmak için malzemenin galeriden stok sahasına nakliyesi beklenmiştir. Ancak daha çok gece vardiyasında gerçekleşen cevher nakliyesinden dolayı gece gelen malzeme sonraki sabah gelen stoptaki diğer malzemeler ile karışmış ve her aynaya ait kaya tespiti güçleşmiştir.


Bu sebeple TEBD'yi belirlemek için daha uygun, pratik ve dolaylı bir yöntem olan Schmidt sertlik deneyinin kullanılmasına karar verilmiştir (Şekil 8). Schmidt sertlik deneyi, dolaylı yoldan UCS değerlerini belirlemek için basit ve hızlı bir yöntemdir. Birçok araştırma farklı kaya formasyonlarda Schmidt Çekici Sertlik değeri (Hr) ve UCS arasında güçlü korelasyonların varlığını göstermiştir. Yapılan bir çalışmada üç farklı Schmidt test prosedürü kıyaslanmış ve her prosedür için UCS değerlerinin Schmidt çekiçi değeri ile güvenilir şekilde tahmin edilebildiği tespit edilmiştir (Karaman ve Kesimal, 2015).

Bu saha araştırması boyunca, Schmidt deneyleri ISRM (1978, 2007) (R1) prosedürüne göre gerçekleştirilmiştir. Bu standart doğrultusunda rastgele 20 farklı noktada her aynada Schmidt çekici ile yatay yönde seri ölçümler yapılmış ve en yüksek 10 değerlerin aritmetik ortalaması Schmidt değeri olarak kaydedilmiştir. Aynalardan alınan kayaç örneklerinden her ayna için kuru özgül birim hacim ağırlıklar ( $\text{kN/m}^3$ ) hesaplanmıştır.

Her ayna için Schimidt sertliği ve kayacın özgül birim hacim ağırlığı değerleri bulunduktan sonra Deere ve Miller (1966) abağı kullanılarak UCS değerleri saptanmıştır (Şekil 9). Bu abak, birçok çalışmada uygulanmış (Tziallas, 2009) ve çekiç değerleri düzgün olduğu sürece güvenilir sonuçlar verdiği belirlenmiştir.



Şekil 8. Schmidt çekici testinin yeraltı aynalarında uygulanması



Şekil 9. Schmidt sertliği ve tek eksenli sıkışma dayanımı arasındaki ilişki (Deere ve Miller 1966)

### 2.4.3. Aynalarda Kaya Kütlelerinin Fiziko-Mekanik Özelliklerinin Belirlenmesi

Kayaçların fiziksel özelliklerinin en önemli parametreleri, kayanın yoğunluğu (doğal ve doymuş), porozitesi ve su emme değerleridir. Bu özellikleri tayin etmek üzere her aynadan kayaç numuneleri alınarak KTÜ Maden Mühendisliği Laboratuvarında analizleri yapılmıştır.

Kayaç numunelerinin tabii ağırlığı, suya daldırılıp doymuş hale getirildikten sonra doymuş kuru yüzey ağırlığı ve hacimleri bulunmuştur. Daha sonra etüve konulup kurutularak desikatörde soğutulmuş ve kuru ağırlıkları ölçülmüştür (Ulusay vd., 2001). Şekil 10'da laboratuvar çalışmalarından bir görünüm yer almaktadır.



Şekil 10. Fiziksel özelliklere yönelik yapılan laboratuvar deneylerinden bir görünüm

Bu şekilde her bir aynayı temsil eden doğal, kuru ve doymuş yoğunluk, porozite ve su emme değerleri hesaplanmıştır. Her bir aynaya ait kayaçların kuru yoğunluk değerleri yer ivmesi (g) ile çarpılarak özgül birim hacim ağırlıkları ( $\text{kN/m}^3$ ) bulunmuştur (Tablo 1).

Tablo 1. Fiziksel özelliklerin istatistiksel tablosu

	Min	Max	Ortalama
Yoğunluk (doğal)	2.76	2.81	2.78
Yoğunluk (doygun)	2.77	2.81	2.79
Yoğunluk (kuru)	2.75	2.80	2.78
Birim hacim ağırlığı	26.98	27.47	27.23
Porozite	1.71	1.80	1.76
Su emme	0.62	0.65	0.63


## 2.5. Patlatma Parametrelerin Ölçülmesi

### 2.5.1. Gümüştaş Madencilik A.Ş. Yeraltı Madeninde Ayna Dizaynı

Gümüştaş yeraltı madeninde ayna patlatmaları (galerilerde) ve tavan patlatmaları (cevher stopelarında) olmak üzere iki çeşit patlatma operasyonu gerçekleştirilmektedir. İkinci patlatma tipi bu çalışmanın kapsamı dışındadır. Bu yüzden takip eden sayfalarda sadece ayna patlatmalarından bahsedilecektir. Patlatma operasyonlarına yönelik işlemler planlama ofisinde başlamaktadır. Maden planlayıcıları, jeologlarla işbirliği içerisinde, Datamine© gibi yazılımlar yardımıyla galeri yollarını tasarlamaktadır. Planlanan galeri yönü, eğimi ve boyutları ayna yüzeyinde harita ekibi tarafından belirlenir ve delme işlemini gerçekleştirecek ekip buna uygun şekilde hareket eder.

Maden işletmesinde paralel orta çekme delik düzeni kullanılmaktadır. ayna kesitlerinde +1 - +3 derece eğime sahip 76 mm çapında 4 adet serbest yüzey deliği yer almaktadır. Şarj delikleri, kesmeyi gerçekleştirmek için boş deliklerin arasına ve çevresine eklenmektedir. (Şekil 11).

Taban delikleri 64 mm'lik bir matkapla açılmaktadır. Deliklerin arasındaki mesafe yaklaşık 0.8m'dir. Fakat zayıf kaya formasyonlarında bu mesafe 1m'ye kadar çıkabilmektedir. Ayna koşullarına bağlı olarak, normal dizayn deliklerinin dışında, yardımcı patlatma delikleri paterne eklenebilmektedir. Taban ve serbest yüzey delikleri hariç aynadaki diğer delikler 45mm çapında delinmektedir. Deliklerin uzunluğu 3 m'dir. Şekil 12'de jumbo ile aynada delgi işleminin gerçekleştirilmesi verilmiştir.



Şekil 11. Maden işletmesinde genel ayna tasarımı (toplam delik sayısı: 43+4)



Şekil 12. Jumbo ile aynada delgi işlemi

Şekil 13'te işletmedeki patlatma tasarımının uygulanışı gösterilmiştir. Çember içerisindeki bölgede kullanılan tasarım orta çekme sistemidir. Mavi renkle işaretlenen delikler boş delikleri gösterirken sarı renkteki kesimler yüklü delikleri temsil eder. Zemin delikleri bazı durumlarda su birikintilerinin altında kalabilmektedir. Bununla birlikte, döküntülerin delikleri tıkamasını önlemek için delikler delinir delinmez deliklere PVC boruları yerleştirilmektedir. PVC'ler kırmızı renkli çizgiler ile işaretlenmiştir (Şekil 13).



Şekil 13. Z3D30 nolu galeri aynasında uygulanan patlatma dizaynı örneği (22/12/2018)

### 2.5.2. Deliklerin Şarjlanması ve Ateşleme Sistemlerinin Bağlanması

Gümüştaş Madencilik A.Ş. yeraltı madeninde aynalarda delme işlemi tamamlandığında, patlatma ekibi, deliklere patlayıcı yerleştirmek için galeri aynasına inmektedir (Şekil 14). Patlayıcı maddeler olarak ANFO ve jelatinit dinamit kullanılmaktadır. Taban delikleri her zaman dinamit ile şarj edilmektedir. Aynada herhangi bir su geliri olmaması durumunda ana patlayıcı olarak ANFO kullanılırken yemleme ve taban delikleri için deliklere dinamit konulmaktadır. Ancak, aynada herhangi bir su geliri


durumunda sadece jelatinit dinamit kullanılmaktadır. Taban delikleri haricindeki bütün delikler aynı miktarda patlayıcı ile beslenir Ateşleme sistemi olarak delik içi gecikmeli nonel kapsüller kullanılmaktadır. Aynada patlayıcı şarjı tamamlandıktan sonra yüzey bağlantıları infilaklı fitil ile yapılmakta olup sistem elektrikli kapsülle patlatılmaktadır.



Şekil 14. Deliklerin patlayıcı ile şarjlanması ve yüzey bağlantılarının sağlanması

Gecikme süresi 4 tane serbest yüzey deliklerinin ortasında bulunan merkezdeki deliğin ilk patlatılacağı biçimde ayarlanır. Bunu kesitteki diğer komşu delikler takip eder ve gecikme çevre deliklere doğru aşamalı olarak ilerler. Şekil 15'te gecikmeli kapsüllerin ayna üzerindeki dağılımını gösteren temsili bir patlatma dizaynı verilmiştir. Deliklerde sıkılama, yer altı üretim hızını düşürdüğü için (Dobrilović vd., 2005) maden işletmesinde ayna patlatmalarında uygulanmamaktadır.





Şekil 15. 43 delikli bir ayna yüzeyinde gecikmeli kapsüllerin dağılımı

### 2.5.3. Patlatma Parametrelerinin Kaydedilmesi

Tez çalışması kapsamında delme işleminden sonra patlatma temel parametrelerini kaydetmek için aynalara gidilmiştir. Aynaların geometrik özellikleri (genişlik ve yükseklik) ölçülerek alanı ( $F_a$ )  $F_a = W * H$  eşitliği ile hesaplanmıştır. Burada “ $F_a$ ” ayna alanını, “ $W$ ” ayna genişliğini ve “ $H$ ” da yüksekliği ifade etmektedir.

Patlatma sonrasında ayna yüzeyindeki ilerleme boyuna bakılarak, patlatılan kaya hacmi ( $V$ )  $V = F_a * L$  formülü ile hesaplanmıştır. Burada “ $V$ ” kaya hacmini, “ $L$ ” ise patlatma sonucu ilerlemeyi ifade etmektedir.

Her bir atımda kullanılan toplam patlayıcı miktarı (dinamit ve ANFO) ateşçiler tarafından kaydedilmektedir ve işletmenin üretim veritabanında muhafaza edilmektedir. Bu verilerden her ayna patlatması için özgül şarj aşağıdaki formül ile hesaplanmıştır.

$$Pf\left(\frac{kg}{m^3}\right) = \frac{\text{Patlayıcı ağırlığı (kg)}}{V} \quad (17)$$

## 2.6. Split Desktop ile D80 Analizi İçin Görüntü Alma ve İşleme

Bir ayna patlatmasından sonra alanın havalandırılmasındanve gerekli kontrollerden sonra alanın güvenli olduğu ilan edilene kadar beklenmektedir. Ardından patlatılarak parçalanmış kaya yığınının görüntü çalışmaları için alana giriş yapılmaktadır. Ayna önünde parçalanmış ve yayılı vaziyetteki yığından görüntü almadan önce ölçekli toplar veya ölçekli şeritler yığın üzerine yerleştirilmiştir. Görüntü örneklerinin temsil gücünü artırmak için her bir ayna atımı için birçok görüntü alınmıştır. Görüntü alma işleminde Şekil 16'da temsili görüntüsü verilen ekipmanlar kullanılmıştır.

- ✓ Dijital kamera olarak çalışmada Canon PowerShot *SX20IS* kullanılmıştır.
- ✓ Yeraltı galerilerindeki karanlık ortam düşünüldüğünde aydınlatma için projektör.
- ✓ Ölçeklendirme için şerit metre ve renkli toplar (Ø68.6 mm çapında)




Şekil 16. Görüntü almada kullanılan temsili ekipmanlar

Fotoğraf çekmeden önce projektör ışığı gölgeli alanları minimize edecek şekilde yığının yüzeyine yönlendirilmiştir. Ölçeklendirme nesnelere de yığının üzerine yerleştirildikten sonra ayna önündeki parçalanmış yığının fotoğrafları çekilmiştir (Şekil 17a).

Toplanan görüntüler dijital eleme için Split-Desktop4.0©'a yüklenmiştir. Yüklenen görüntüler; galeri duvarları, karanlık alanlar, yığının önünde yer alan ön plan vb. gibi gereksiz kısımları kaldırmak için kırılabilir. Bu alanlar genellikle fotoğrafların kenar kısımlarında bulunur ve bunları düzenlemek gereksiz vakit kaybına neden olabilir. Gerekli ayarlamalar yapıldıktan sonra bölütleme işlemine başlanılabilir.

Bölütleme işi görüntüde bulunan kaya bloklarını boyutlandırmak için yazılım algoritmalarınca kullanılan otomatik bir prosedürdür. Ölçekleme aşamasını, görüntüdeki nesne ölçeğinin boyutlarının tanımlanması takip eder. Maskeleyme aracı (mask tool), ölçeklendirme nesnelerini ve diğer bulanık olup görünmeyen bölgeleri saklar ve böylece yazılım tarafından bu kısımlar kaya parçaları olarak değerlendirilmez. Otomatik bölütleme nadiren tatmin edici ve doğrudan kullanılabilir sonuçlar verdiği için çoğu zaman manuel düzenleme yapmak gerekmektedir. Yani blok sınırlarının çoğu durumda tek tek düzeltilmesi gerekmektedir ki bu işlem zor ve zaman alıcıdır.

Şekil 17b’de, 24/12/2018 tarihinde 1350C2 nolu galeri aynasının önündeki yığından alınan ve sonradan otomatik ve manuel olarak bölütlenmiş ölçekli görüntüler verilmiştir.



Şekil 17. Bölütleme sürecinin öncesinde (a) ve sonrasında (b) yığın görüntüsü (24/12/2018 tarihli 1350C2 nolu galeri aynası patlatması)

## 2.7. Çoklu Regresyon ile Parçalanma Tahmin Modelin Oluşturulması

Çoklu regresyon bağımlı bir değişken (çıktı olarak tanımlanır) ile bağımsız değişken(ler)in (girdiler olarak bilinir) arasındaki ilişkiyi tanımlayan matematiksel bir modeldir. Bağımsız değişkenler ile bağımlı değişkenin açıklanma derecesi belirtme katsayısı ( $R^2$ ) ile belirtilir.  $R^2$  değeri bir sayısına ne kadar yakın olursa bağımsız değişkenlerin bağımlı değişkeni açıklama gücü o kadar artar.

YSA'da olduğu gibi çoklu lineer regresyonda da modeller, ölçülmüş deneysel verilere dayanmaktadır.

Çoklu lineer regresyonda " $Y_{pred}$ ", aşağıdaki denklem (Eşitlik 18) kullanılarak bağımsız girdi değişkenlerinin  $X_i$  bir fonksiyonu olarak tahmin edilir:

$$Y_{pred} = a + b_1X_1 + b_2X_2 + b_3X_3 + \dots + b_nX_n \quad (18)$$

Burada;


$a$  ; sabit terim

$b_i$  ; değerleri ise çoklu regresyon katsayılarıdır.

Çoklu regresyon modelleri oluşturmak için birçok değişik yazılımlar kullanılabilir. Bu tez çalışmasında SPSS Statistics V17 yazılımı kullanılmıştır.

## 2.8. YSA ile Parçalanma Tahmin Modelinin Oluşturulması

Bu tez çalışmasında YSA modelini eğitmek, doğrulamak ve test etmek için 27 verinin yaklaşık %20'si (Ranjith ve Khandelwal, 2012) olan 21 veri kullanılmıştır. Ölçülen değerlerin farklı büyüklük, birim vb. seviyelere sahip olduklarından hem girdi hem de çıktı değerlerini 0 ve 1 arasında ölçeklendirmek gerekmektedir. Buna YSA'da ön işlem denilmektedir. Bu işlem, sinirin en hassas bölgelerinin kullanılmasını ve böylece öğretimin daha da hızlı olmasını sağlamaktadır (Ranjith ve Khandelwal, 2012). Bu şekilde normalize edilmiş rakamlar çıktı tahmininde kullanılır ve model oluşturulduktan sonra değişkenler kendi orijinal büyüklüğüne geri çevirilir. Buna da son işlem denilmektedir. Şekil 18'de YSA'da veri işlem aşamaları verilmiştir.



Şekil 18. YSA’da veri işlem aşamaları (URL-1: <https://www.mathworks.com/help/deeplearning/ug/choose-neural-network-input-output-processing-functions.html>)

Normalizasyon işlemi aşağıdaki denklem (Eşitlik 19) kullanılarak yapılmaktadır.

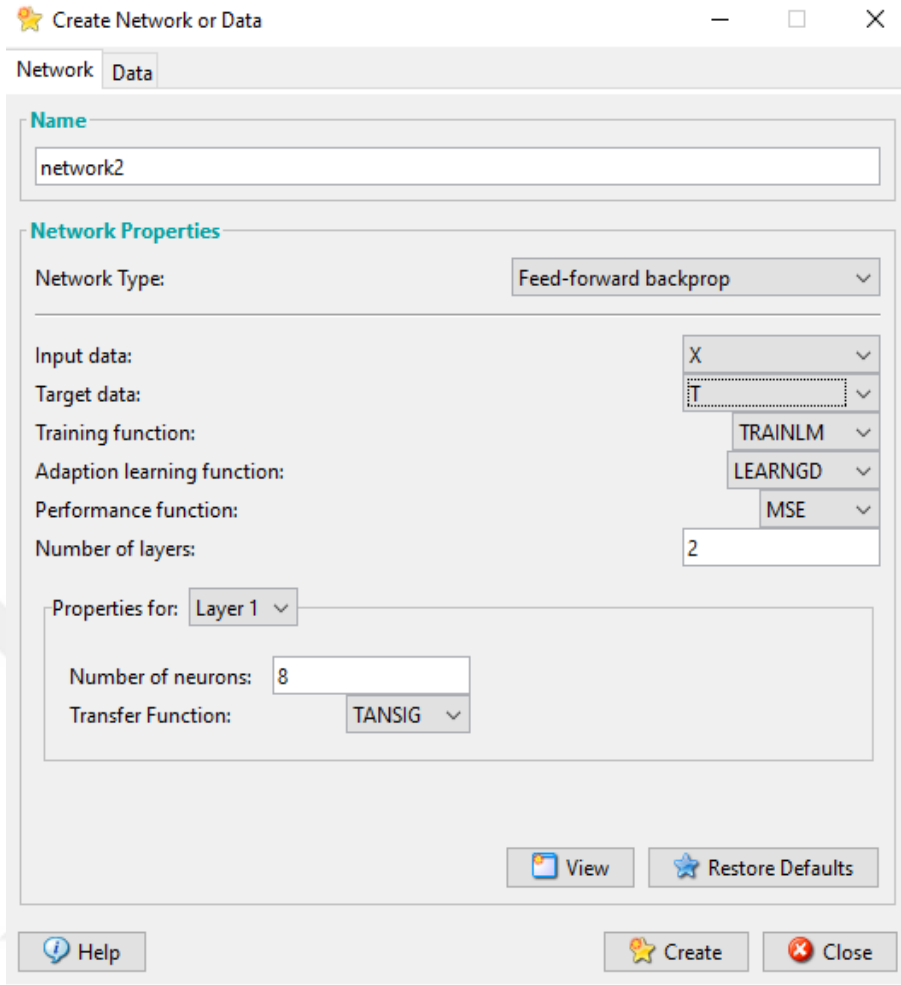
$$X_{scaled} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (19)$$

$X_{scaled}$  ( $X_{ölçekli\ veri}$ ) normalize edilmiş girdi ya da hedef değeri,  $X$  normalizasyon öncesi değeridir;  $X_{min}$  ve  $X_{max}$  sırasıyla vektörün minimum ve maksimum değerleridir. Bu ölçekleme prosedürü özellikle Levenberg Maquardt ileri-beslemeli algoritma kullanıldığında algoritmanın performansını geliştirir (Saadat vd., 2014).

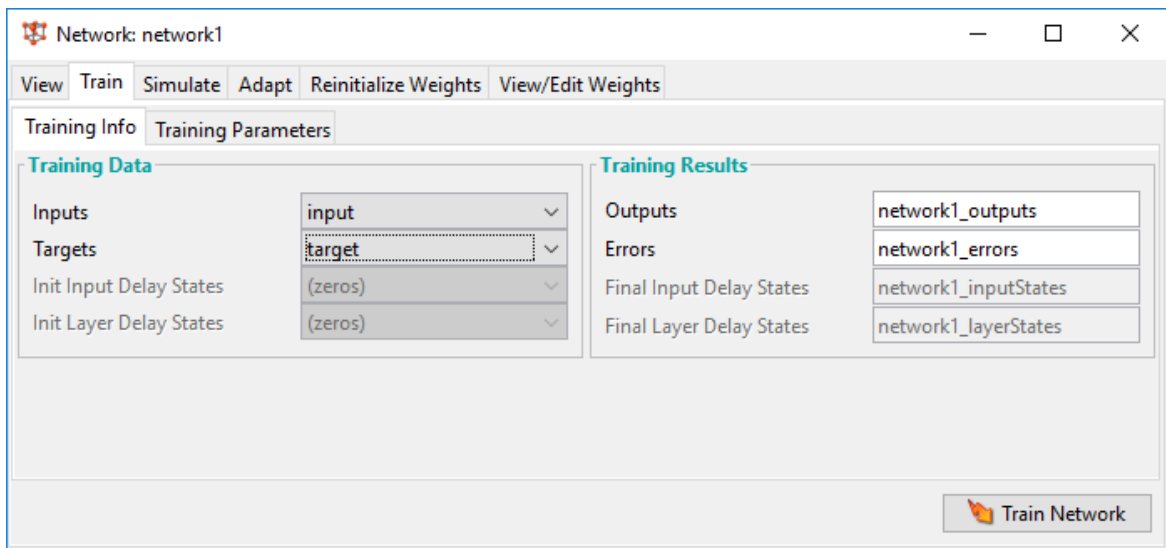
YSA geliştirme işlemi Matlab R2017b ©’ taki NNTOOL kullanarak yapılmıştır. Veriler Excel’de 21\*4, 21\*1 ve 6\*4 boyutunda sırasıyla girdi, çıktı ve test kümelerini temsil eden 3 tane matrise ayrılmıştır. Sonradan kümeler değişken olarak Matlab sistemine transfer edilmektedir. Komut alanına ‘nntool’ basarak NNTOOL arayüzü açılmaktadır. Oradan değişkenler alınmış ve ağ oluşturulmuştur (Şekil 19).

Bu çalışmada ileri beslemeli geri-yayımlı ağ tercih edilmiştir. Çünkü bu ağ, lineer tahminler için daha uygundur (Tiile, 2016). Ağı eğitmek için TRAINLM fonksiyonu kullanılmıştır. Çünkü NNtool’daki en hızlı algoritmadır. Deneme-yanılma işlemi sonunda dereceli azalma (LEARNGD) en etkin alıştırma fonksiyonu olarak görülmüş ve tercih edilmiştir.

YSA oluşturulduktan sonra, ağın eğitilmesi ve sümülasyonu aşağıdaki arayüz yardımıyla yapılmıştır (Şekil 20).



Şekil 19. NNtool'da YSA'nın oluşturulması



Şekil 20. NNtool'da YSA'nın eğitim ve simülasyon arayüzü

### 2.8.1. Gizli Katmandaki Optimum Nöron Sayısının Belirlenmesi

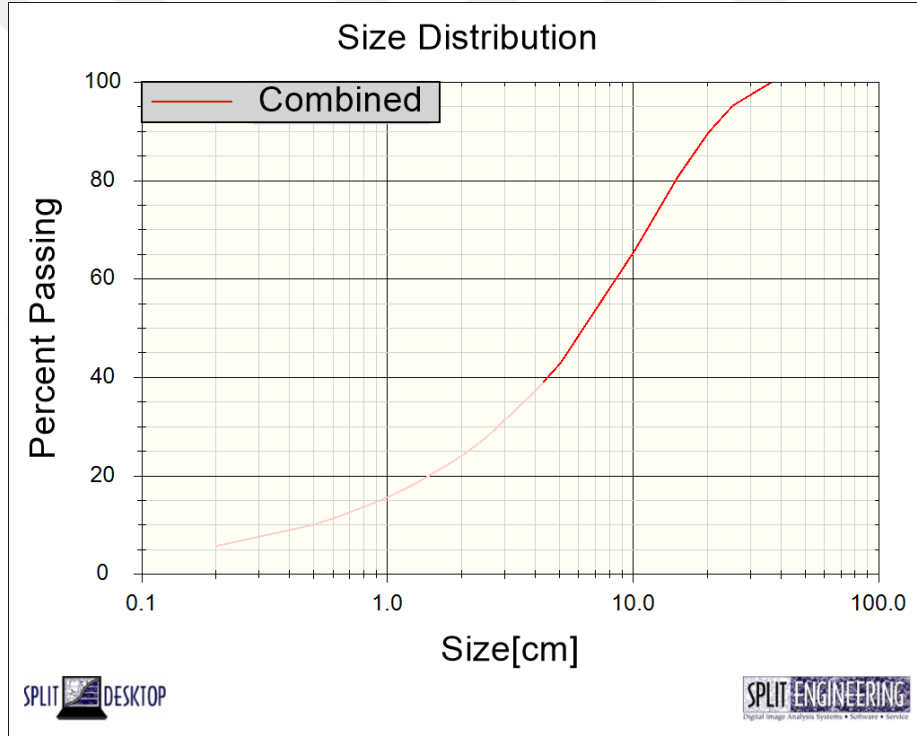
Gizli katmandaki işlem birimlerin (nöron) sayısı ağın tahmin performansını yüksek oranda etkilemektedir (Maier ve Dandy, 1998). Gizli katmandaki yetersiz nöron sayısı eğitim sırasında yakınsaklığa ulaşmayı zorlaştırabilir. Aksi durumda ise çok fazla sayıda nöron, ağın genelleştirme kapasitesini düşürebilir. Literatürde optimum nöron sayısını belirlemek için kabul edilmiş bir kural olmayıp deneme-yanılma yaklaşımı çokça tercih edilmektedir. Bununla birlikte saklı katman sayısının üst ve alt limitleriyle ilgili öneriler vardır. Bir örnek olarak Hecht-Nielsen (1987), tek saklı katmanlı geri yayılım ağına saklı nöron sayısının üst limiti olarak  $2n+1$ 'i önermiştir (“n” girdi değişkenlerinin sayısıdır). Buna uygun olarak, bu tez çalışmasında 4 girdi parametresi kullandığımız için gizli katmandaki nöron sayısı 9 ile sınırlandırılmıştır.

Gizli katmanlarda olduğu gibi, en uygun transfer fonksiyonu da deneme-yanılma yöntemiyle belirlenir. Gizli katman sayısının olası varyasyon aralığına dair bir fikrimiz olduğunda, en etkin ağ mimarisini belirlemek için farklı nöron sayıları ve farklı aktivasyon fonksiyonları ile ağ eğitilir. Her seferinde ağ, bağlantı ağırlık değerlerindeki varyasyonlar önemsiz oluncaya ve istikrarlı bir duruma ulaşana kadar birçok kez (maksimum 10 limiti eğitilir (Enayatollahi vd., 2014).

### 3. BULGULAR VE TARTIŞMA

#### 3.1. Split Desktop ile $D_{80}$ Değerlerinin Belirlenmesi

Görüntünün ölçeklendirilmesi ve blokların bölütlenmesi sonrasında yazılımda dijital elemenin sonuç sekmesine geçilir. Sonuçlar grafiksel (kümülatif yüzde ve histogram) veya tablolar şeklinde olabilir. Şekil 21’de Şekil 17’de bahsi geçen 1350C2 nolu galeri aynasındaki yığın görüntüsünden elde edilen elek altı yüzdesinin kümülatif grafiğini temsil etmektedir.



Şekil 21. 24/12/2018 tarihli 1350C2 nolu galeri aynası patlatmasıyla parçalanmış yığına ait Split Desktop ile kümülatif tane boyutu dağılımı analizi

Galeri aynalarındaki patlatmalara yönelik her bir yığından fotoğraflar alınmıştır. Split Desktop yazılımında belirli bir galeride bulunan tüm parçalanma sonuçları birleştirilmiştir. Her bir parçalanmanın eleme sonuçlarından, malzemenin %80'inin geçtiği dijital elek boyutu olan  $D_{80}$ , parçalanma karakteristik değeri olarak kaydedilmiştir.



### 3.2. Toplanan Verilerin Özeti

Split Desktop yazılımından parçalanma analizi ile elde edilen  $D_{80}$  (çıkıktı verisi) ile parçalanma üzerinde etkili olan ve tez kapsamında girdi verileri olarak araştırılan aynaların kaya kütle özellikleri (RQD, tek eksenli basınç dayanımı (TEBD)), özgül patlayıcı miktarı (Pf) ve galeri ayna alanı (Fa) Tablo 2’de özetlenmiştir. İstatiksel değerler ise Tablo 3’te verilmiştir.

Tablo 2. Galeri aynalarına ait girdi ve çıkıktı değişkenlerinin özeti

Atım Tarihi	Galeri ismi	Atım No	Girdi parametreleri				Parçalanma $D_{80}$ (m)
			Ayna alanı(m <sup>2</sup> )	Pf (Kg/m <sup>3</sup> )	RQD	TEBD (Mpa)	
22/12/2018	1365C1 Sol	G1	22.5	1.78	58.6	43.3	0.070
	Z3D30	G2	16.5	2.51	65.0	80.4	0.121
23/12/2018	1350C2-cross3-sol	G3	19.8	2.45	55.3	63.4	0.085
	1350C2-cross3-sağ	G4	22.6	2.06	50.7	50.1	0.079
	1395B	G5	22.2	2.63	56.4	60.2	0.107
	1395B Sol	G6	21.7	2.30	66.2	67.8	0.118
	Z3D30	G7	17.6	2.33	70.0	86.6	0.150
24/12/2018	1350C2-Cross1	G8	17.3	2.62	48.0	60.5	0.073
	1350C2	G9	30.3	1.65	68.0	84.6	0.182
	1350C2-1410	G10	17.0	2.82	47.3	57.8	0.064
25/12/2018	1395B	G11	22.0	2.12	56.4	60.1	0.115
	1395B Sol	G12	24.6	2.17	68.2	58.6	0.095
26/12/2018	1350C2	G13	28.3	1.8	63.0	62.5	0.212
	1350C2-cross3-sağ	G14	22.8	2.2	57.7	50.3	0.124
	1350C2-1410	G15	20.7	2.7	51.3	46.3	0.075
	1350C2-Cross1	G16	17.1	2.7	76.0	78.6	0.099
	1395B Sol	G17	23.9	1.9	46.2	38.4	0.069
	Z3D30	G18	17.6	2.8	71.0	79.3	0.143
27/12/2018	1365C1 Sol	G19	21.2	2.4	53.7	52.2	0.125
28/12/2018	1350C2	G20	27.5	1.6	68.0	60.3	0.184
	1350C2-Cross1	G21	15.5	3.4	56.2	73.6	0.148
	1350C2-cross3-sağ	G22	22.7	1.9	50.7	69.5	0.152
	1350C2-cross3-sol	G23	18.5	3.0	62.3	61.7	0.110
	1350C2-1410	G24	20.2	2.1	53.3	49.6	0.097
	1395B	G25	22.0	1.8	46.4	58.7	0.135
	1395B Sol	G26	24.5	1.9	56.2	48.5	0.084
	Z3D30	G27	16.6	2.2	71.0	80.3	0.200

Tablo 3. Girdi ve çıktı değişkenlerine ait istatistikleri

	Değişken	Minimum	Maximum	Ortalama	Standard Sapma
Girdi verileri	Fa (m <sup>2</sup> )	15.50	30.25	21.23	3.72
	Pf (kg/m <sup>3</sup> )	1.60	3.40	2.29	0.44
	RQD (%)	46.20	76.00	59.00	8.48
	TEBD (Mpa)	38.40	86.60	62.34	12.92
Çıktı verisi	D <sub>80</sub> (m)	0.064	0.212	0.119	0.042

### 3.3. Çoklu Regresyon ve YSA Modelleri ile Parçalanma Analizi

#### 3.3.1. Verilerin Hazırlanması

Bir değişkenin tahmin edilmesine yönelik tahmin modellerinde verilerin bir kısmı model oluşturulmasında bir kısm ise oluşturulan modellerin genelleme performanslarının tayininde kullanılmaktadır. Ranjith and Khandelwal (2012) 47 veri ile çalıştıkları bir modelleme çalışmasında verilerin yaklaşık %80'ini (37 veri) ağı eğitimi ve model oluşturmada geriye kalan yaklaşık %20'sini de (10 veri) ağı genelleme testinde kullanmışlardır.

Bu tez çalışmasında da veri toplamadaki zorluklar ve kısıtlı teknik imkânlardan dolayı yukarıda belirtilen 27 veri kümesinden 21'i (~verilerin %78'i) eğitim ve model üretimi için kullanılacaktır. Geriye kalan 6 kayıt ise (~verilerin %22'si) her bir modelin genelleme gücünün ortaya konulmasında kullanılacaktır. 6 adet eğitim veri kümesi bütün popülasyonu istatistiki olarak temsil edecek şekilde seçilmiştir. Tablo 4, çoklu doğrusal regresyon analizi ve YSA tahmin modellerinin oluşturulması ve oluşturulan tahmin modellerinin genelleme testlerinde kullanılmak üzere bölünen verileri göstermektedir.

Her bir galeri aynasına ait patlatmadan önce kaydedilmiş olan Pf, Fa, tek eksenli basınç dayanımı (TEBD) ve RQD parametreleri modellerin oluşturulmasında “girdi”ler olarak ve karşılık gelen “D<sub>80</sub>” değerleri ise “çıkı” olarak nitelendirilecektir.

Tablo 4. Verilerin bölünmesi

	Atım No	Ayna alanı(m <sup>2</sup> )	Pf (Kg/m <sup>3</sup> )	RQD	TEBD (Mpa)	D80 (m)
MODEL	G1	22.5	1.78	58.6	43.3	0.070
	G2	16.5	2.51	65.0	80.4	0.121
	G3	19.8	2.45	55.3	63.4	0.085
	G6	21.7	2.30	66.2	67.8	0.118
	G7	17.6	2.33	70.0	86.6	0.150
	G8	17.3	2.62	48.0	60.5	0.073
	G10	17.0	2.82	47.3	57.8	0.064
	G11	22.0	2.12	56.4	60.1	0.115
	G12	24.6	2.17	68.2	58.6	0.095
	G13	28.3	1.8	63.0	62.5	0.212
	G15	20.7	2.7	51.3	46.3	0.075
	G16	17.1	2.7	76.0	78.6	0.099
	G18	17.6	2.8	71.0	79.3	0.143
	G19	21.2	2.4	53.7	52.2	0.125
	G20	27.5	1.6	68.0	60.3	0.184
	G21	15.5	3.4	56.2	73.6	0.148
	G23	18.5	3.0	62.3	61.7	0.110
	G24	20.2	2.1	53.3	49.6	0.097
G25	22.0	1.8	46.4	58.7	0.135	
G26	24.5	1.9	56.2	48.5	0.084	
G27	16.6	2.2	71.0	80.3	0.200	
TEST	G4	22.6	2.06	50.7	50.1	0.079
	G5	22.2	2.63	56.4	60.2	0.107
	G9	30.3	1.65	68.0	84.6	0.182
	G14	22.8	2.2	57.7	50.3	0.124
	G17	23.9	1.9	46.2	38.4	0.069
	G22	22.7	1.9	50.7	69.5	0.152

### 3.3.2. D<sub>80</sub> Tahmin Modellerinin Oluşturulması

#### 3.3.2.1. Model Değişkenleri Verilerinin Normalite Analizleri

Çalışma kapsamında elde edilen ve tahmin modellerinin oluşturulmasında kullanılan 21'er örneğe sahip değişkenlerin iki taraflı asimptotik önem seviyeleri (p) 0.62-0.99 aralığında değişmekte olup normal dağılım göstermektedir (Tablo 5).

Tablo 5. Çoklu doğrusal regresyon ve YSA tahmin modellerinde kullanılan bölünmüş değişkenlerin normalite analizleri (tek örnek Kolmogorov-Smirnov Z)

	Fa	Pf	RQD	TEBD	D <sub>80</sub>	
N (örnek sayısı)	21	21	21	21	21	
İstatistikler	Ortalama	20,41	2,36	60,16	63,34	0,12
	Standard Sapma	3,64	0,46	8,73	12,38	0,04
Kolmogorov-Smirnov Z	0,74	0,37	0,66	0,76	0,52	
Asymp. Sig. (2-tailed) (p)	0,65	0,99	0,78	0,62	0,95	

Çoklu doğrusal regresyon ve YSA tahmin modellerinin genelleme testlerinde kullanılmak üzere bölünen 6'şar örneğe sahip girdi ve çıktı değişkenlerinin iki taraflı asimptotik önem seviyeleri (p) 0.43-0.99 aralığındadır ve normal dağılım göstermektedir (Tablo 6).

Tablo 6. Çoklu doğrusal regresyon ve YSA tahmin modellerinin genelleme testlerinde kullanılan bölünmüş değişkenlerin normalite analizleri (tek örnek Kolmogorov-Smirnov Z)

	Fa	Pf	RQD	TEBD	D <sub>80</sub>	
N (örnek sayısı)	6	6	6	6	6	
İstatistikler	Ortalama	24,08	2,06	54,95	58,85	0,12
	Standard Sapma	3,10	0,34	7,65	16,41	0,04
Kolmogorov-Smirnov Z	0,87	0,44	0,52	0,49	0,38	
Asymp. Sig. (2-tailed) (p)	0,43	0,99	0,95	0,97	0,99	

### 3.3.2.2. Çoklu Regresyon Analizi ile D<sub>80</sub> Tahmin Modelinin Oluşturulması

Sahadan ve Split Desktop yazılımından elde edilen ve bölünen 21 verinin kullanılması ile oluşturulan çoklu doğrusal regresyon modeli özeti Şekil 22’de verilmiştir. Bağımlı değişken D<sub>80</sub> ve bağımsız değişkenler Fa (ayna alanı; m<sup>2</sup>), Pf (özgül şarj kg/m<sup>3</sup>), RQD (kaya kalite göstergesi) ve TEBD (tek eksenli basınç dayanımı; MPa) olarak alınmıştır. Regresyon modeli 0.602 kararlılık katsayısı (R<sup>2</sup>) ve 0.004 önem seviyesine sahip F=6.052 değeri (F<sub>tablo</sub>=3.01) için anlamlıdır. Çoklu doğrusal regresyon modeli aşağıda verilmiştir (Eşitlik 20).

$$D80 = -0.210 + 0.009Fa - 0.005Pf - 9.805 \times 10^{-4}RQD + 0.004TEBD \quad (20)$$

#### Çoklu Lineer Regresyon Özeti

##### Variables Entered/Removed

Model	Variables Entered	Variables Removed	Method
1	TEBD, Pf, RQD, Fa <sup>a</sup>	.	Enter

a. All requested variables entered.

##### Model Summary<sup>b</sup>

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	Durbin-Watson
1	,776 <sup>a</sup>	,602	,503	,0297243	1,304

a. Predictors: (Constant), TEBD, Pf, RQD, Fa

b. Dependent Variable: D80

##### ANOVA<sup>b</sup>

Model		Sum of Squares	df	Mean Square	F	Sig.
1	Regression	,021	4	,005	6,052	,004 <sup>a</sup>
	Residual	,014	16	,001		
	Total	,036	20			

a. Predictors: (Constant), TEBD, Pf, RQD, Fa

b. Dependent Variable: D80

##### Coefficients<sup>a</sup>

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Collinearity Statistics	
		B	Std. Error	Beta			Tolerance	VIF
1	(Constant)	-.210	,132		-1,595	,130		
	Fa	,009	,004	,738	2,414	,028	,267	3,751
	Pf	-.005	,023	-.052	-.207	,839	,388	2,575
	RQD	,000	,001	-.203	-.820	,424	,406	2,464
	TEBD	,004	,001	1,044	3,556	,003	,288	3,468


a. Dependent Variable: D80

Şekil 22. Verilere uygulanan çoklu doğrusal regresyon analizi sonuçları

Verilen bağımsız değişkenler ile  $D_{80}$  değeri çoklu doğrusal regresyon ile yaklaşık %60 oranında tahmin edilebilmektedir. Varyans şişkinlik faktörü (VIF) “1-5” aralığında olup bağımsız değişkenler arasında orta düzeyde çoklu doğrusal bağımlılık vardır. Ancak VIF değerleri dikkate alındığında modelde herhangi bir düzeltmeye gerek bulunmadığı için regresyon modelinin güvenle kullanılabilirliği görülmektedir. Durbin-Watson istatistiğine (1.304) göre de regresyon katsayılarının standart hatalarının çok küçük seviyelerde olduğu anlaşılmaktadır.

### 3.3.2.3. YSA Tahmin Modeli ve Sonuçları

YSA'nın en uygun yapısını belirlemek için denemeler, ileri beslemeli geri yayımlı ağ tipinde en çok kullanılan Tansig ve Logsig fonksiyonlarıyla yapılmıştır. Deneme yanılma testlerinin sonuçlarına göre farklı ağlar arasından Tansig fonksiyonu ile elde edilen 4-8-1 mimari yapılı ağın en düşük ve en istikrarlı RMSE değerini sağladığı görülmüştür (Şekil 23). Bu mimari için ağın gizli katmanında Tansig fonksiyonu ve çıkış katmanında Purelin fonksiyonu kullanılmıştır. Tablo 7'de Tansig ve Logsig fonksiyonlarıyla elde edilen farklı YSA yapılarına ait model sonuçları görülmektedir.




Şekil 23. 21 adet veri grubu için optimum YSA mimarisi

Öğrenme, doğrulama ve test verileri için YSA performans grafiklerine baktığımızda (Şekil 24), öğrenme, doğrulama, test verilerin tahmininde çok yüksek bir korelasyon olduğu görülmektedir. Toplam 21 parçalanma verisi ( $D_{80}$ )  $R^2=0.96$  değeriyle tahmin edilmiştir. Buna ilave olarak model en düşük hata ile sağlanmıştır (RMSE=0.008). Dolayısıyla elde edilen bu model geriye kalan 6 patlatma verilerinin genelleme testlerine yönelik tahmini parçalanma değerlerini hesaplamak üzere kullanılabilir.

Tablo 7. Farklı YSA mimari ağ yapılarıyla elde edilen sonuçlar

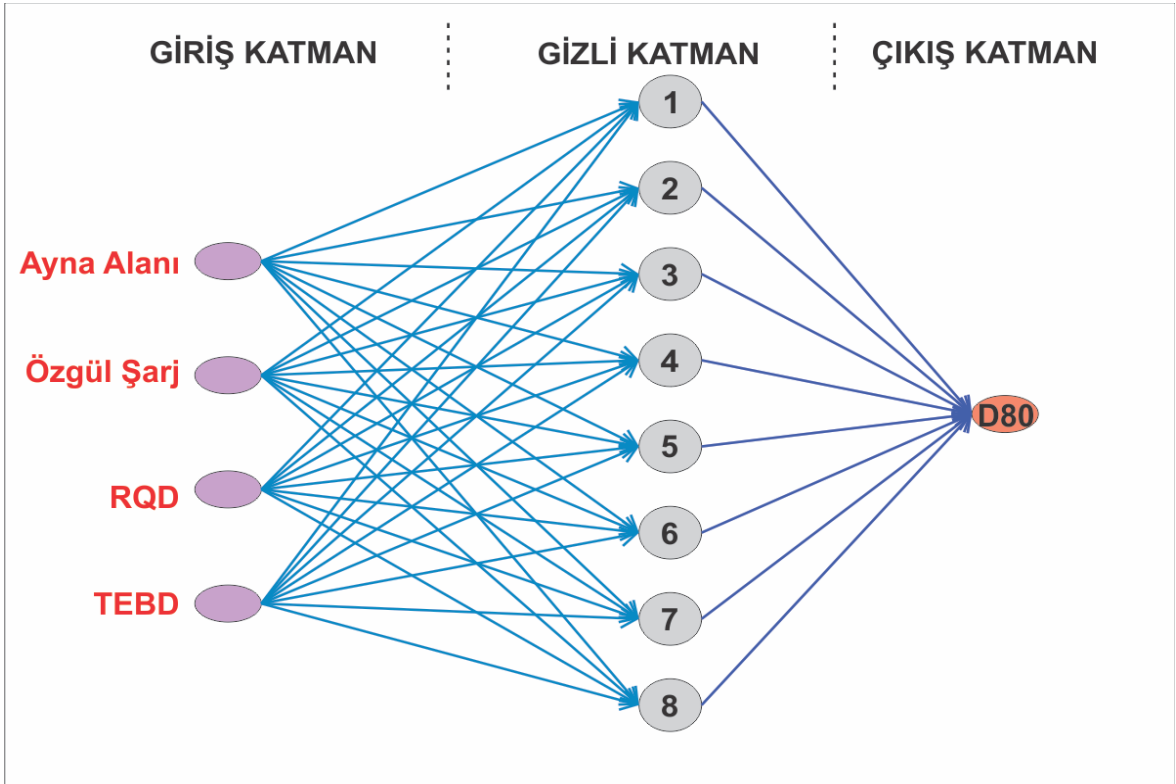
Nöron (Sınır) sayısı	Transfer fonksiyonları	$R^2$	RMSE
5	Tansig	0.79	0.038
	Logsig	0.77	0.040
6	Tansig	0.86	0.027
	Logsig	0.82	0.032
7	Tansig	0.84	0.030
	Logsig	0.70	0.035
8	Tansig	0.96	0.008
	Logsig	0.87	0.020
9	Tansig	0.90	0.025
	Logsig	0.91	0.017



Şekil 24. Öğrenme, doğrulama ve test kümeleri için YSA performans grafikleri

### 3.3.2.4. Elde edilen YSA'nın özeti

Şekil 25'te 4-8-1 mimari ağ yapısına ait en uygun YSA modeli geometrisi özetlenmektedir. Ayna alanı (Fa), özgül şarj (Pf), RQD ve TEBD değişkenleri "girdi" katmanında bulunmaktadır. Hedef değişken  $D_{80}$  ise "çıkı" katmanında yer almaktadır. 8 nöronlu tek gizli katmanlı YSA ağı ile en uygun YSA tahmin modeli geliştirilmiştir.



Şekil 25. YSA geometrisi ve özellikleri

YSA geometrisine ait eğitim parametrelerinin özeti Tablo 8'de bulunmaktadır. Eğitim sürecinde modele giren 21 verinin YSA tarafından default olarak 15 tanesi (%70'i) asıl öğrenim, 3 tanesi (%15'i) doğrulama ve 3 tanesi (%15'i) de test için kullanılmıştır.

Modelin eğitimi "sıfır (0)" hata hedefiyle ayarlanmış ve tüm eğitim 7 iterasyon içeriğinde yapılmıştır. Birinci iterasyondan sonra doğrulama performansının en düşük seviyesine ulaşılmıştır.



Tablo 8. YSA geometrisine ait ve özellikler

<b>Veri ayrılması</b>	<b>Model için toplam kullanılan veri sayısı</b>	<b>21</b>
	Eğitim için kullanılan veri sayısı	15
	Doğrulama için kullanılan veri sayısı	3
	Test için kullanılan veri sayısı	3
<b>Ağ mimarisi</b>	Girdi katmanda sinir sayısı	4
	Saklı katman sayısı	1
	Saklı katmanda sinir sayısı	8
	Çıkış katmanında sinir sayısı	1
<b>Eğitim parametreleri</b>	İterasyon sayısı	7
	Eğitim hızı (default)	0.05
	Hata hedefi	0

### 3.4. Tahmin Modellerinin Tartışılması

Modellerin performansını değerlendirmek için en sık kullanılan ölçütler, kök ortalama hata (RMSE), modelin kararlılık katsayısı ( $R^2$ ) ve Variance Account For (VAF) değerlendirme kriterleridir. Bu kriterler, tahmin modellerinin oluşturulmasında kullanılan veriler aracılığıyla eşitliklerden (Eşitlik 21-23) hesaplanabilmektedir:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} \quad (21)$$

$$R^2 = 100 \left[ \frac{\sum_{i=1}^N (y_i - y_a)(\hat{y}_i - \hat{y}_a)}{\sum_{i=1}^N (y_i - y_a) \sum_{i=1}^N (\hat{y}_i - \hat{y}_a)^2} \right]^2 \quad (22)$$

$$VAF = \left[ 1 - \frac{var(y_i - \hat{y}_i)}{var(y_i)} \right] * 100 \quad (23)$$

Yukarıdaki eşitliklerde;

“ $y_i$ ” ve “ $\hat{y}_i$ ” sırasıyla “ölçülen” ve “tahmin edilen çıktı değerleri”ni,

“ $y_a$ ” ve “ $\hat{y}_a$ ” “ölçülen” ve “tahmin edilen değerlerin ortalamaları”nı temsil etmektedir.


Bir modelin kararlılık katsayısı 1.0’a, kök ortalama hatası 0’a ve VAF %100’e ne kadar yaklaşırsa oluşturulan modelin tahmin gücü de o derecede yüksek olmaktadır.  $D_{80}$  tahminine yönelik oluşturulan çoklu doğrusal regresyon ve YSA modellerine yönelik değerlendirme kriterleri Tablo 9’da sunulmuştur. Buna göre YSA modelinin daha yüksek tahmin gücüne ve daha düşük hata oranına sahip tahminler üreteceği görülmektedir. Şekil 26’da ise %95 güven aralığı için ölçülen  $D_{80}$  verileri ile çoklu doğrusal regresyon analizi (ÇDRA) ve YSA ile tahmin edilen  $D_{80}$  verilerinin değişim aralığı görülmektedir. YSA modelinden elde edilen  $D_{80}$  verilerinin değişim aralığının ölçülen  $D_{80}$  verilerinin değişim aralığına (%95 güven aralığı için) çok yakın olduğu ve daha yüksek oranda benzerlik arz ettiği görülmektedir.

Tablo 9. Modellerin  $D_{80}$  tahmin performanslarının kıyaslanması


Tahmin Modelleri	Modellere ait tahmin performans ölçütleri		
	$R^2$	RMSE	VAF (%)
YSA	0.960	0.008	96.3
Çoklu regresyon	0.602	0.026	60.3

Şekil 27’de ölçülen  $D_{80}$  verileri ile çoklu doğrusal regresyon analizi ve YSA ile tahmin edilen  $D_{80}$  verilerinin bölünen 21 veri için dağılımları verilmiştir. Şekle bakıldığında genel olarak YSA modelinden tahmin edilen  $D_{80}$  verilerinin ölçülen  $D_{80}$  verileri ile daha fazla noktada örtüştüğü, çoğu noktada yaklaşık çakışık olduğu görülmektedir.

Dolayısıyla Tablo 9 ile Şekil 26-27 birlikte değerlendirildiğinde, YSA modeli ile çok daha yüksek doğrulukta ve daha düşük hata payı ile  $D_{80}$  tahmininin yapılabileceği anlaşılmaktadır.



Şekil 26. Ölçülen ve tahmin edilen  $D_{80}$  değerlerinin %95 güven aralığında değişimi




Şekil 27. Bölünen 21 veri için ölçülen ve tahmin edilen  $D_{80}$  değerlerinin dağılımı

### 3.5. Modellerin Genelleme Performanslarının Değerlendirilmesi

Modellerin oluşturulmasında kullanılan veriler haricinde, arazide yapılacak bir patlatmanın parçalanma sonuçlarını ne kadar doğru tahmin edebileceği sorusuna cevap vermek de gerekmektedir. Geliştirilen modellerin genel tahmin kapasitesini belirlemek üzere kaydedilen 27 patlatma verisinden modelin geliştirilmesinde kullanılmamış olan 6


patlatma girdi verileri modellere beslenmiş ve  $D_{80}$  tahmin değerleri hesaplanmıştır. Tahmin sonuçları yukarıda belirlenen 3 ölçüt kriteri (RMSE,  $R^2$ , VAF) göz önünde bulundurularak değerlendirilmiştir. Şekil 28 ve Şekil 29’da, YSA ve çoklu doğrusal regresyon analizi modellerinin (ÇDRA) oluşturulmasında kullanılmayan ve sadece modellerin tahmin testlerinde kullanılarak tahmin edilen ve ölçülen  $D_{80}$  değerlerine ait grafik gösterimler verilmiştir. Şekil 28 ve Şekil 29’a göre YSA modeli biraz yüksek korelasyona sahiptir.



Şekil 28. YSA modeli için genelleme test sonuçları ve ölçülen  $D_{80}$  değerlerinin dağılımı

Diğer taraftan çoklu regresyon modeli de 6 genelleme verisini çok büyük doğrulukta tahmin etmiştir ( $R^2=0.81$ ). Bu değer oluşturulan çoklu doğrusal regresyon modelinin  $R^2$  değerine göre (0.60) çok yüksektir. Ancak modelin hatası (RMSE=0.042) YSA modeline (RMSE=0.022) kıyasla daha yüksektir. YSA modelinden elde edilen VAF değeri de regresyon tahmin modeline göre daha yüksektir (%80). Diğer bir ifade ile regresyon modelinin  $D_{80}$  tahmininde YSA modeline göre sergilediği VAF değeri (%19) esas alındığında daha zayıf olduğu görülmektedir (Tablo 10).

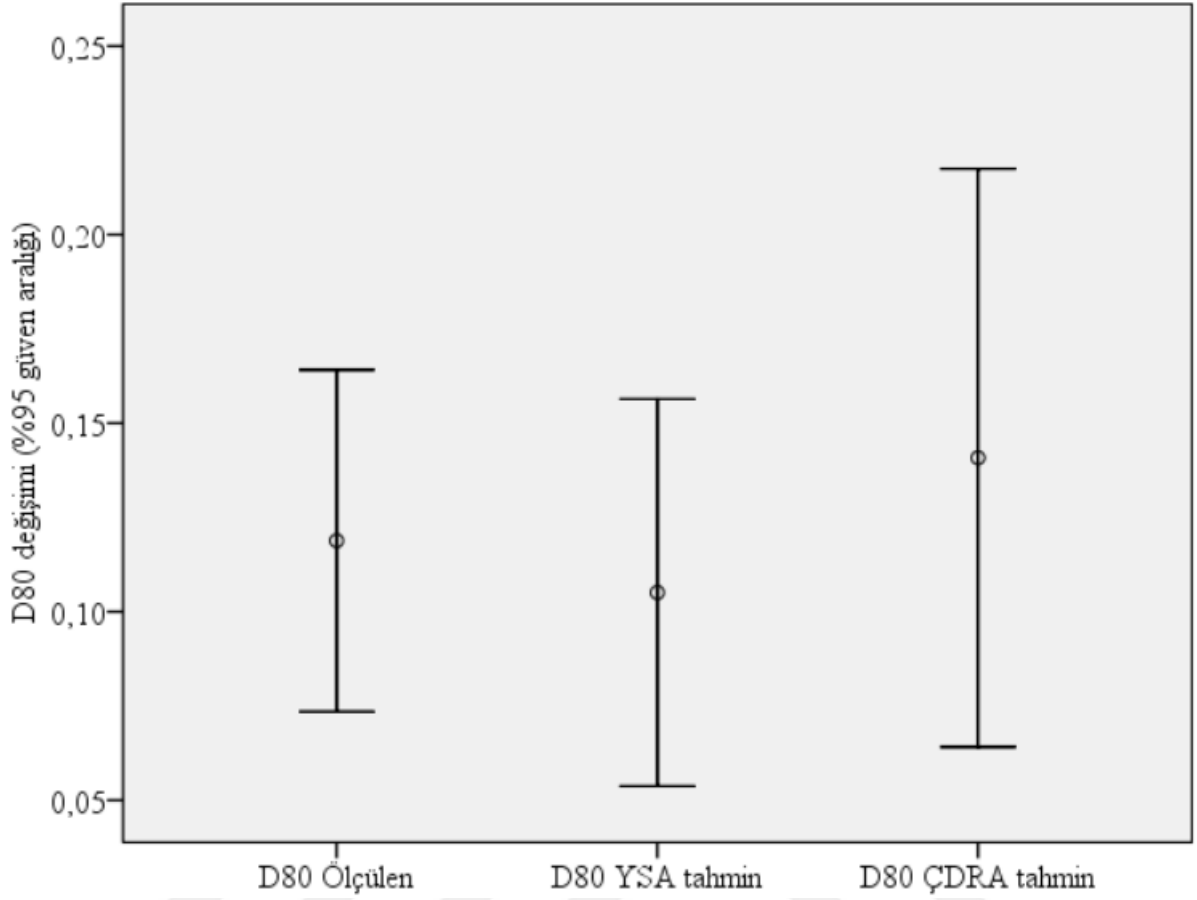
Bununla birlikte Tablo 10’da verilen performans verilerine paralel olarak Şekil 30’da YSA modelinin genelleme test sonuçlarından elde edilen 6 tahmin verisinin %95 güven aralığı için değişim aralığı, ölçülen  $D_{80}$  verilerinin değişim aralığına benzer ve daha yakındır. İlâveten, Şekil 31 incelendiğinde de YSA modelinin genelleme test sonuçlarının ölçülen  $D_{80}$  verilerine daha yakın bir eğilim çizgisi gösterdiği görülmektedir.



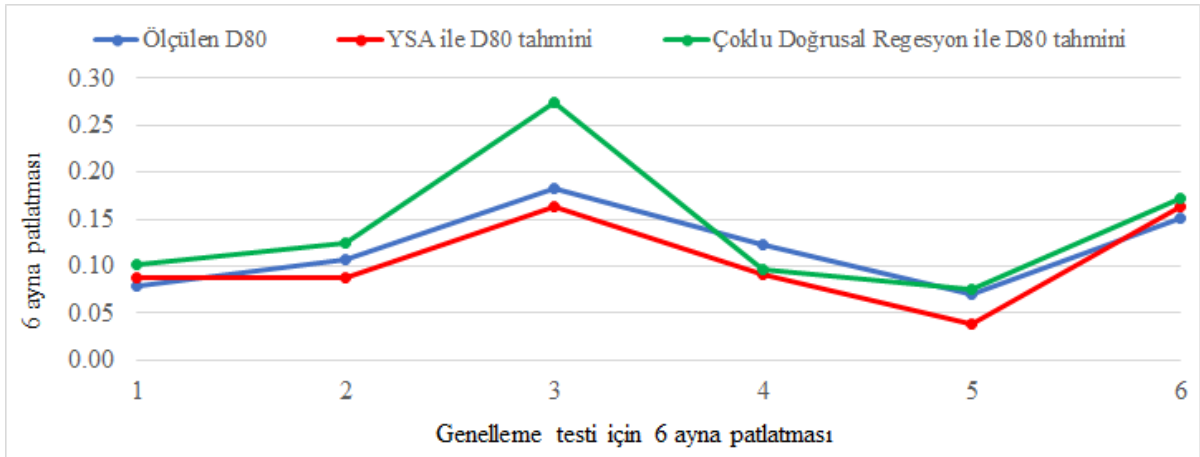
Şekil 29. Çoklu doğrusal regresyon modeli için genelleme test sonuçları ve ölçülen  $D_{80}$  değerlerinin dağılımı

Tablo 10. Genelleme analizine yönelik performans ölçütleri

Tahmin Modelleri	Modellere ait genelleme performans ölçütleri		
	$R^2$	RMSE	VAF(%)
YSA	0.84	0.022	80
Çoklu regresyon	0.81	0.042	19



Şekil 30. Genelleme testine yönelik 6 veri için ölçülen ve tahmin edilen  $D_{80}$  değerlerinin %95 güven aralığında değişimi



Şekil 31. Genelleme testinde kullanılan 6 veri için ölçülen ve tahmin edilen  $D_{80}$  değerlerinin dağılımı

### 3.6. Duyarlılık Analizi

Parçalanma konusunda tahmin modellerinin geliştirilmesinde kullanılan en hassas girdi parametreleri “Kosinüs Genlik Metodu (CAM)” (Yang ve Zhang, 1997) ile belirlenmektedir. Bu metod, her bir girdi değişkeni ile parçalanma faktörü ( $D_{80}$ ) arasındaki kuvvet derecesini nicelendirmeye imkân tanımaktadır. Bu metodun uygulanması bütün veri çiftlerinin ortak bir X-uzayında ifade edilmesiyle başlamaktadır. Burada X-uzayı elemanları;

$$X = \{x_1, x_2, x_3, \dots, x_i, \dots, x_n\} \quad \text{şeklindedir.}$$

X-uzayı içerisindeki her bir unsur olan “ $x_i$ ” şu şekilde “m” uzunluğunun bir vektördür ve;

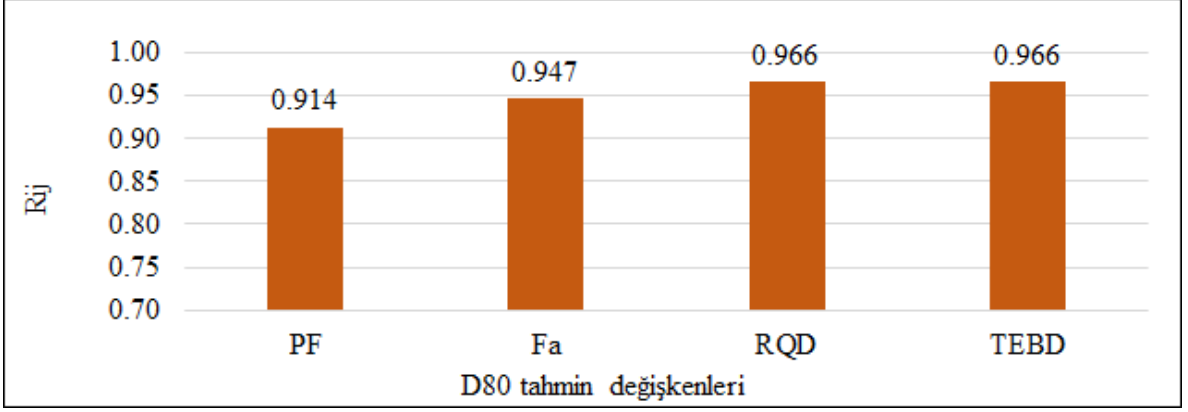
$$x_i = \{x_{i1}, x_{i2}, x_{i3}, \dots, x_{im}\} \quad \text{şeklinde ifade edilebilir.}$$

Her bir data çifti “m” boyutunun uzayında bir nokta olarak değerlendirilebilir. “ $x_i$ ” ve “ $x_j$ ” veri çiftleri arasındaki ilişkinin ( $R_{ij}$ ) gücü aşağıda Eşitlik 24’te sunulmaktadır:

$$R_{ij} = \frac{\sum_{k=1}^m x_{ik}x_{jk}}{\sqrt{\sum_{k=1}^m x_{ik}^2 \sum_{k=1}^m x_{jk}^2}} \quad (24)$$

Eşitlik 25 esas alınarak yapılan duyarlılık analizinin sonuçları Şekil 33’te özetlenmektedir.

Şekil 32’den parçalanmaya en çok etki eden değişkenlerin UCS ve RQD olduğu görülmektedir. Bu iki değişken, kontrol edilemeyen saha faktörleridir. Bunlardan sonra parçalanmayı etkileyen diğer değişkenler de sırası ile ayna alanı ve özgül şarjdır.



Şekil 32. D<sub>80</sub> tahmin modellerinin oluşturulmasında kullanılan verilerin duyarlılık analizleri





#### 4. SONUÇLAR

Bu tez çalışmasında yeraltı galeri aynalarında yapılan ayna patlatmalarında parçalanma tahmininde Yapay Sinir Ağları (YSA) modelinin kullanılabilirliği ve tahmin modelinin performansı değerlendirilmiştir. YSA tahmin modelinden elde edilen sonuçları kıyaslamak amacı ile çoklu doğrusal regresyon analizi kullanılmıştır. YSA ve çoklu doğrusal regresyon analizi ile parçalanma tahmin modellerinin oluşturulmasına yönelik Gümüşhane İl'inde yeraltı madencilik faaliyetlerini sürdüren Gümüştaş Madencilik A.Ş.'inde e yapılan yer altı ayna patlatmalarında “özümlü şarj, ayna alan, RQD ve TEBD” değişkenleri kullanılmıştır. Böylece yeraltı ayna patlatmalarından açığa çıkacak  $D_{80}$  değerlerini tahmin edebilen YSA ve çoklu doğrusal regresyon modelleri oluşturulmuş ve modeller için genelleme testleri yapılmıştır. Açığa çıkan sonuçlar şu şekilde özetlenebilir:

-YSA tahmin modeli geometrisi 4 nöronlu girdi, 8 nöronlu gizli ve 1 nöronlu çıktı şeklindeki 4-8-1 mimarisinden oluşmaktadır. Ağın gizli katmanında Tansig fonksiyonu ve çıkış katmanında Purelin fonksiyonu kullanılmıştır. YSA modelinin kararlılık katsayısı ( $R^2$ ) 0.96 ve VAF değeri %96.3'tür. YSA modelinin hata payı ise  $RMSE=0.008$ 'dir.

-Elde edilen YSA modeli sahada parçalanma tahmininde güvenle kullanılabilir. Çünkü modelin daha önce tanımadığı 6 ayna atım verilerinin parçalanma değerlerini 0.84  $R^2$ , 0.022  $RMSE$  ve %80 VAF performans değerleriyle tahmin edebilmiştir.

-Oluşturulan çoklu regresyon tahmin modelinin  $R^2$ ,  $RMSE$  ve VAF değerleri sırasıyla 0.602, 0.026 ve %60.3'tür ve YSA modeline kıyasla daha zayıftır. Buna rağmen 6 adet yabancı verilerle yapılan genelleme testinde  $R^2=0.81$ ,  $RMSE=0.042$  ve  $VAF=\%19$  ile tahminleri yapmıştır. Bu bakımdan YSA performansına çok yakın olmakla birlikte yüksek hata oranı ve düşük VAF değerleri için YSA'nın tahmin ettiği değerler daha güvenilirdir.

- Ayrıca, YSA modeli ile tahmin edilen  $D_{80}$  ile genelleme test sonucunda elde edilen  $D_{80}$  değerlerinin %95 güven aralığı için değişim aralığı, ölçülen  $D_{80}$  değerleri ile çoklu regresyon analizine kıyasla daha fazla benzerlik göstermektedir.

-Modellerin optimizasyon amacıyla kullanılabilmesine yönelik parçalanma tahmin modellerinin oluşturulmasında kullanılan her bir girdi değişkeninin parçalanmaya etkisine yönelik yapılmış duyarlılık analizi sonucunda kontrol edilemeyen faktörler olan TEBD ve RQD en etkili faktörlerdir. İşletme mühendislerinden temin edilen ve kontrol edilebilen parametrelerden ise ayna alanının özümlü şarja göre biraz daha etkili olduğu görülmüştür.

## 5. ÖNERİLER

Patlatmaya yönelik oluşturulan modellerin en önemli faktörlerinden biri veri sayısıdır. Veri sayısı ne kadar çok olursa o kadar sağlam ve güçlü bir model ortaya çıkar. Bu tezde kullanılan 27 veri ile tatmin sonuçları elde edilmesine rağmen modelleri daha da yetkinleştirmek amacıyla verilerin artırılması önerilmektedir.

Ayrıca, madenin cevher yatağı kireçtaş formasyonu olduğundan dolayı bu çalışma da kireçtaş kaya kütlelerinde yapılan patlatmalar yoğunlaştı. İleride madenin patlatma ekonomisine daha genel bir şekilde etki edebilmek için diğer kaya kütlelerinin incelenmesi önerilmektedir.

Bu tez çalışmasında, yeraltındaki riskler ve çalışma koşullarına bağlı örnek almadaki zorluklar nedeniyle tek eksenli basınç dayamı tahmininde Schmidt çekici deneyi tercih edilmiştir. İmkanlar olduğu sürece tek eksenli sıkıştırma deneylerinin laboratuvar ortamında yapılmasının ve modellerin geliştirilmesinde girdi verisi olarak elastisite modülünün de kullanılmasının elde edilen sonuçları daha da geliştirebileceği düşünülmektedir.

Tez kapsamında yapılan analizler ve aynalarda yapılan gözlemler göz önüne alındığında, Gümüştaş Madencilik A.Ş.'de yapılan ayna patlatmalarında özgül şarjın fazla kullanıldığı, şarj balansının ve ateşleme sisteminin tasarımının iyileştirilmesine ihtiyaç olduğu görülmüştür. Kontur deliklerine daha az patlayıcı konulması hem patlayıcı maliyetini hem de fazladan kazı (overbreak) olasılığını düşürecektir.

## 6. KAYNAKLAR

- Adamson, W. R. ve Lund, A. S., 2001. On the Use of Mechanistic Blast-Outcome Measurement and Modelling for Optimisation of Explosive Selection in Underground Mining, In EXPLO 2001 (pp. 207–223). NSW, Australia: The Australasian Institute of Mining and Metallurgy.
- Adebola, J. M., Ogbodo, D. A. ve Elijah O. P., 2016. Rock Fragmentation Prediction using Kuz-Ram Model, Journal of Environment and Earth Science, 6(5), 110–115.
- Afum, B. O. ve Temeng, V. A., 2015. Reducing Drill and Blast Cost through Blast Optimisation – A Case Study, Ghana Mining Journal, 15(2), 50–57.
- Arpaz, E., Koçaslan, A., Yüksek, A. G. ve Dilmaç, M. K., 2013. Kaya Kütle Özellikleri ve Patlatma Tasarım Parametrelerinin Patlatma Kaynaklı Yer Sarsıntıları Üzerine Etkilerinin İncelenmesi, In H. Akdaş, M. Yavuz, M. İphar, H. Ak, & M. Aksoy (Eds.), VII. Delme Patlatma Sempozyumu (pp. 9–20). Eskişehir (Turkey).
- Bahrami, A., Monjezi, M., Goshtasbi, K. ve Ghazvinian, A., 2011. Prediction of rock fragmentation due to blasting using artificial neural network, Engineering with Computers, 27(2), 177–181.
- Bedair, A., 1996. Digital Image Analysis of Rock Fragmentation from Blasting, Ph.D. thesis, McGill University, Department of Mining and Metallurgical Engineering, Montréal.
- Chakraborty, A. K., Raina, A. K., Ramulu, M., Choudhury, P. B., Haldar, A., Sahu, P. ve Bandopadhyay, C., 2004. Parametric study to develop guidelines for blast fragmentation improvement in jointed and massive formations, 73, 105–116.
- Cunningham, C., 1983. The Kuz-Ram model for prediction of fragmentation from blasting, In R. A. Holmberg R (Ed.), Proceedings of the 1st International Symposium on Rock Fragmentation by Blasting (pp. 439–453). Lulea Sweden.
- Cunningham, C., 1987. Fragmentation estimations and the Kuz-Ram model—four years on, In Proceedings of the second international symposium on rock fragmentation (pp. 475–87). Keystone, Colorado.
- Cunningham, C. V. B., 2005. The Kuz-Ram fragmentation model – 20 years on. Brighton Conference Proceedings, (4), 201–210.
- Deere, D. ve Miller, R., 1966. Engineering classification and index properties for intact rock, Report AFWL-TR-65-116. Air Force Weapons Laboratory (WLDC), Kirtland Air Force Base. New Mexico 87117

- Demuth, H., Beale, M. ve Hagan, M., 2009. Neural Network Toolbox™ 6 User's Guide, Natick, MA: The MathWorks, Inc.
- Dobrilović, M., Ester, Z. ve Janković, B., 2005. Measurement in Blast Hole Stem and Influence of Stemming Material on Blasting Quality, *Rudarsko-Geološko-Naftni Zbornik*, 17, 47–53.
- Elevli, B., Topal, I. ve Elevli, S., 2012. Multivariate statistics application in development of blast fragmentation charts for different rock formations in quarries, *Acta Montanistica Slovaca*, 17(4), 300–309.
- Enayatollahi, I., Aghajani Bazzazi, A. ve Asadi, A., 2014. Comparison between neural networks and multiple regression analysis to predict rock fragmentation in open-pit mines, *Rock Mechanics and Rock Engineering*, 47(2), 799–807.
- Franklin, J. A., Kemeny, J. M. ve Girdner, K. K., 1996. Evolution of measuring systems: A review, In *FRAGBLAST 5 Workshop on Measurement of Blast Fragmentation* (pp. 47–52). Montreal, Quebec, Canada.
- Grossberg, S., 1988. Nonlinear Neural Networks: Principles, Mechanisms, and Architectures, *Neural Networks*, 1, 17–61.
- Hecht-Nielsen, R., 1987. Kolmogorov's Mapping Neural Network Existence Theorem, In: 1st IEEE Annual International conference on Neural Networks (pp. 11–14). San Diego: IEEE Press.
- Hudaverdi, T., Kuzu, C. ve Fisne, A., 2012. Investigation of the blast fragmentation using the mean fragment size and fragmentation index, *International Journal of Rock Mechanics and Mining Sciences*, 56, 136–145.
- Kabwe, E., 2017. Improving Collar Zone Fragmentation by Top Air-Deck Blasting Technique, *Geotechnical and Geological Engineering*, 35(1), 157–167.
- Karaman, K. ve Kesimal, A., 2015. A comparative study of Schmidt hammer test methods for estimating the uniaxial compressive strength of rocks, *Bulletin of Engineering Geology and the Environment*, 507–520.
- Khandelwal, M. ve Singh, T. N., 2005. Prediction of Blast Induced Air Overpressure in Opencast Mine, *Noise & Vibration Worldwide*, 36(2), 7–16. <https://doi.org/10.1260/0957456053499095>
- Khandelwal, M. ve Singh, T. N., 2009. Prediction of blast-induced ground vibration using artificial neural network, *International Journal of Rock Mechanics and Mining Sciences*, (October).
- Kuznetsov, V. M., 1973. The mean diameter of the fragments formed by blasting rock, *Soviet Mining Science*, 9 (2), 144–148.

- Magub, T., Partners, O. A. ve Limited, H. K. (n.d.). Tunnel Blast Design, In Joint Technical Seminar by AGS(HK), HKIE (Geotechnical Working Group on Cavern & Tunnel Engineering) & HKTS.
- Maier, H. R. ve Dandy, G. C., 1998. The effect of internal parameters and geometry on the performance of back-propagation neural networks : An empirical study, Environmental Modelling & Software, 13, 193–209.
- Mario, A., 2001. Underground Hardrock Mine Design and Planning - A System ' s Perspective, Ph.D. thesis, Queen's University, Department of Mining Engineering, Ontario.
- Mcculloch, W. S. ve Pitts, W., 1943. A logical calculus of ideas immanent in nervous activity, Bulletin of Mathematical Biophysics, 5, 99–115.
- Monjezi, M., Bahrami, A. ve Yazdian Varjani, A., 2010. Simultaneous prediction of fragmentation and flyrock in blasting operation using artificial neural networks, International Journal of Rock Mechanics and Mining Sciences, 47(3), 476–480.
- Monjezi, M., Rezaei, M. ve Yazdian Varjani, A., 2009. Prediction of rock fragmentation due to blasting in Gol-E-Gohar iron mine using fuzzy logic, International Journal of Rock Mechanics and Mining Sciences, 46(8), 1273–1280.
- Murthy, V. M. S. R., Dey, K. ve Chimankar, R. R., 2006. Tunnel Blast Design using Artificial Neural Network-a Case Study, Journal of The Institution of Engineers, 86, 39–45.
- Nyberg, O. ve Carlsson, L., 1983. A Method for Estimation of Fragment Size Distribution With Automatic Image Processing, In: The 1<sup>st</sup> International Symposium on Rock Fragmentation by Blasting (pp. 333–345). Lulea, Sweden.
- Onederra, I., 2004. Breakage and fragmentation modelling for underground production blasting applications, In IRR Drilling & Blasting 2004 Conference (pp. 1–19). Perth.
- Oraee, K. ve Asi, B., 2006. Prediction of Rock Fragmentation in Open Pit Mines, using Neural Network Analysis, Fifteenth International Symposium on Mine Planning and Equipment Selection (MPES 2006), Turin, Italy. In: [http://\(9821\), 966–978](http://9821.966-978). Retrieved from in: <http://dspace.stir.ac.uk/bitstream/1893/2297/1/Fragmentation.pdf> %5Cnhttp://dspace.stir.ac.uk/bitstream/1893/2297/1/Fragmentation.pdf %5Cn%5BAccessed%5Cn12-11-2014%5D
- Ouchterlony, F., 2005. The Swebrec© function: linking fragmentation by blasting and crushing, Transactions of the Institution of Mining and Metallurgy, Section A, 114 (1), 29–44.

- Ranjith, P. G. ve Khandelwal, M., 2012. Artificial neural network for prediction of air flow in a single rock joint, Neural Computing and Applications, 21(6), 1413–1422.
- REVEY Associates, I., 2005. Tunnels, Shaft and Development Headings Blast Design.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J., 1986. Parallel Distributed Processing. Learning Internal Representation by Error Propagation, Explotion in the Microstructure of Cognition, 318.
- Saadat, M., Khandelwal, M. ve Monjezi, M., 2014. An ANN-based approach to predict blast-induced ground vibration of Gol-E-Gohar iron ore mine, Iran, Journal of Rock Mechanics and Geotechnical Engineering, 6(1), 67–76.
- Sereshki, F., Hoseini, S. M. ve Ataei, M., 2016. Blast fragmentation analysis using image processing, International Journal of Mining and Geo-Engineering Blast, 211–218.
- Shams, S., Monjezi, M., Majd, V. J. ve Armaghani, D. J., 2015. Application of fuzzy inference system for prediction of rock fragmentation induced by blasting, Arabian Journal of Geosciences, 8(12), 10819–10832.
- Sheikh, A. M. ve Chung, S. H., 1987. Predicting fragmentation sizing profiles for different blasting patterns, In F. W. L. and D. R. D. (Ed.) (Ed.), *Second international symposium on rock fragmentation by blasting* (pp. 521–530). Keystone, Colorado.
- Siddiqui, F. I., Shah, S. M. A. ve Behan, M. Y., 2009. Measurement of Size Distribution of Blasted Rock Using Digital Image Processing, Engineering Science, 20(2), 81–93.
- Silva, J. D., Amaya, J. G. ve Basso, F., 2017. Development of a predictive model of fragmentation using drilling and blasting data in open pit mining, The Journal of the Southern African Institute of Mining and Metallurgy, 117, 1089–1094.
- Simpson, P. K., 1990. Artificial neural system – foundation, paradigm, application and implementations, (Pergamon P). New York.
- Stagg, M. S., Otterness, R. E. ve Djahanguiri, F., 1994. Prediction of blast fragmentation of underground stopes for in situ leaching, In: 10<sup>th</sup> annual symposium on explosives and blasting research (pp. 197–208). Austin, Texas USA.
- Strelec, S., Gazdek, M. ve Mesec, J., 2011. Blasting design for obtaining desired fragmentation, Tehnicki Vjesnik, 18(1), 79–86.

- Thornton, D., Kanchibotla, S. S. ve Brunton, I., 2002. Modelling the Impact of Rockmass and Blast Design Variation on Blast Fragmentation, International Journal for Blasting and Fragmentation, 6 (2), 171–172.
- Tiile, R. N., 2016. Artificial neural network approach to predict blast- induced ground vibration , airblast and rock fragmentation, Master Thesis, Missouri University of Science and Technology, Faculty of the Graduate School, Missouri.
- Trivedi, R., Singh, T. N., Mudgal, K. ve Gupta, N., 2014. Application of Artificial Neural Network for Blast Performance Evaluation, International Journal of Research in Engineering and Technology, 3 (05), 564–574.
- Tziallas, G. P., Tsiambaos, G. ve Saroglou, H., 2009. Determination of Rock Strength and Deformability of Intact Rocks, Electronic Journal of Geotechnical Engineering, 14, 1–12.
- Ulusay, R., Gökçeođlu, C. ve Binal, A., 2001. Kaya Mekanikđi Laboratuvar Deneyleri, Ankara: TMMOB Jeoloji Mühendisleri Odası Yayınları
- Wang, H., Lin, H. ve Cao, P., 2016. Correlation of UCS Rating with Schmidt Hammer Surface Hardness for Rock Mass Classification, Rock Mechanics and Rock Engineering, (July).
- Yang, Y. ve Zhang, Q., 1997. A Hierarchical Analysis for Rock Engineering Using Artificial Neural Networks, Rock Mechanics and Rock Engineering, 30 (4), 207–222.
- Yetkin, M. E., Özfırat, M. K., Kahraman, B., 2018. Nokta Yük Dayanım Deđerleri ile Tek Eksenli Basma Dayanım Deđerinin Yapay Sinir Ađları Kullanılarak Tahminlenmesi, In: A. Kesimal, F. Cihangir, ve E. Kömürlü (Eds.), XII<sup>th</sup> Regional Rock Mechanics Symposium (ROCKMEC'2018) (syf. 268–272), Trabzon, Türkiye.

## 7. EKLER

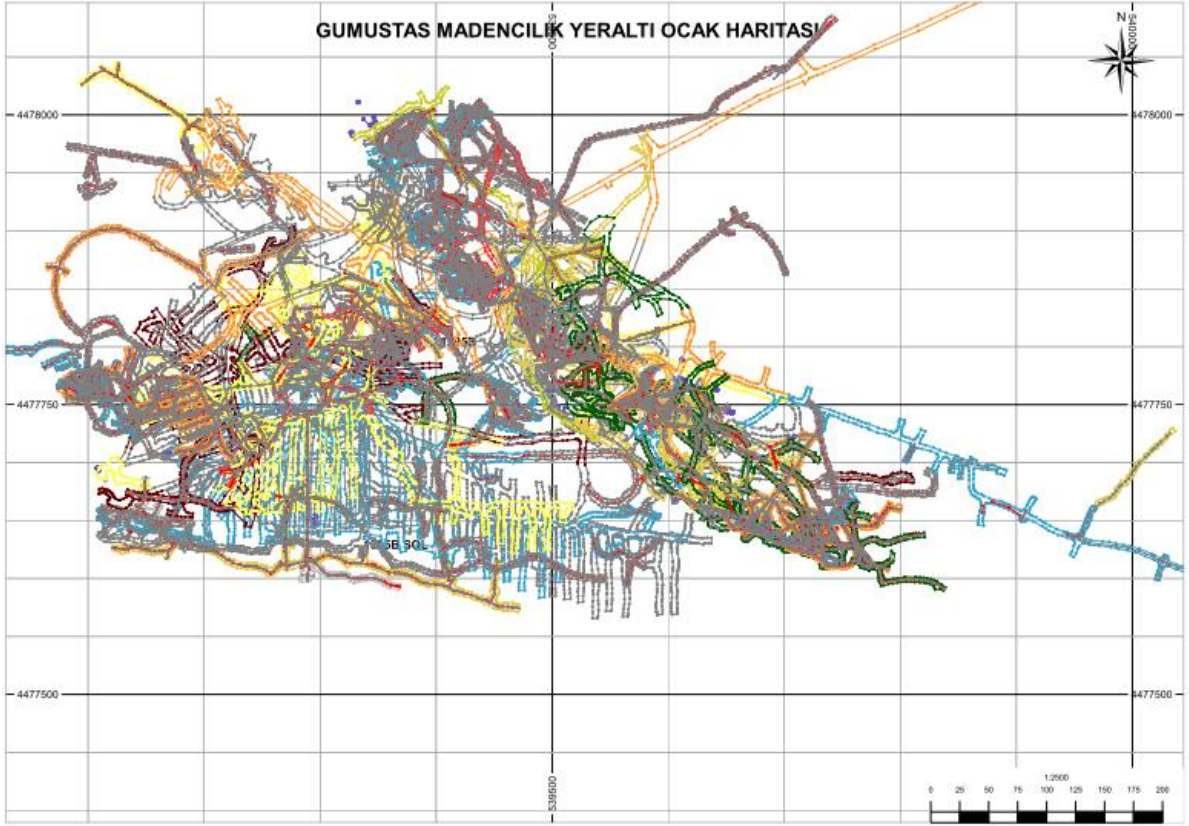
### EK-1

Training function (Demuth vd., 2009)

BFGS quasi-Newton backpropagation
BFGS quasi-newton backpropagation for use with NN model adapptive reference
Bayesian regularisation
Batch training with weight and bias learning rules
Bactch unsupervised weight/bias training
Gradient descent backpropagation
Gradient descent with adaptive learning rule backpropagation
Gradient descent with momentum backpropagation
Gradient descent with momentum and adaptive learning rule backpropagation
Scaled conjugate gradient backpropagation
Levenberg-Marquardt backpropagation One
Cyclical order incremental update
Fletcher-Powell conjugate gradient backpropagation
Polak-Ribière conjugate gradient backpropagation
Powell-Beale conjugate gradient backpropagation Fletcher-Powell
One step secant backpropagation
Random order incremental training with learning functions
Resilient backpropagation (Rprop)
Sequential order incremental training with learning functions



## EK-2



Gümüştaş Madencilik A.Ş. yeraltı maden planı

## ÖZGEÇMİŞ

Gerard EZOULA AGORO 02.10.1993 yılında Togo'da Koumonde köyünde doğdu. İlkokulu Koumonde, Bafilo ve Sokode şehirlerinde üst üste EPP koumonde, EPP Agoudade, ve EPP Bamabodolo'da okullarında okudu. Ortaokulu ve Liseyi Ste Josephine BAKHITA okulunda tamamladı. 2011 yılında kazandığı 'PEJ' bursu vasıtasıyla Burkina Faso'da 'International Institute for Water and Environment Engineering Üniversitesi'nde Maden Mühendisliği eğitimi aldı.

2016 yılında Türkiye burslarını kazanıp 2017 yılından itibaren Karadeniz Teknik Üniversitesi Maden Mühendisliği bölümünde Yüksek lisans eğitimi görmeye başladı. 2016-2017 yıllar arasında Türkçe eğitimi gördü ve çok iyi derecede Türkçe konuşmaktadır. Ülkesindeki eğitim dili Fransızca olup Fransızca'yı çok iyi derecede konuşmaktadır. İngilizce'yi de çok iyi derecede konuşmaktadır.

Gerard EZOULA AGORO, Ocak 2019'dan beri Liberya'da Avesoro Holding şirketinde Maden Planlama Mühendisi olarak çalışmaktadır.