



## Classification varieties of marble and granite by convolutional neural networks with transfer learning method

Bahadır Elmas\*<sup>ID</sup>

Mimar Sinan Fine Arts University, Faculty of Arts and Sciences, Department of Statistics, 34380, Sisli Istanbul, Turkey

### Highlights:

- Marble and granite data set in Turkey was created
- Classification of 102 Varieties of marble and granite has been made in Turkey
- 102 types of marble and granite in Turkey are classified

### Keywords:

- Marble and Granite Classification
- Convolutional Neural Network
- Pre-Trained Networks
- Transfer Learning

### Article Info:

Research Article

Received: 12.05.2021

Accepted: 29.08.2021

### DOI:

10.17341/gazimmfd.936835

### Correspondence:

Author: Bahadır Elmas

e-mail:

bahadir.elmas@msgsu.edu.tr

phone: +90 530 695 8935

### Graphical/Tabular Abstract

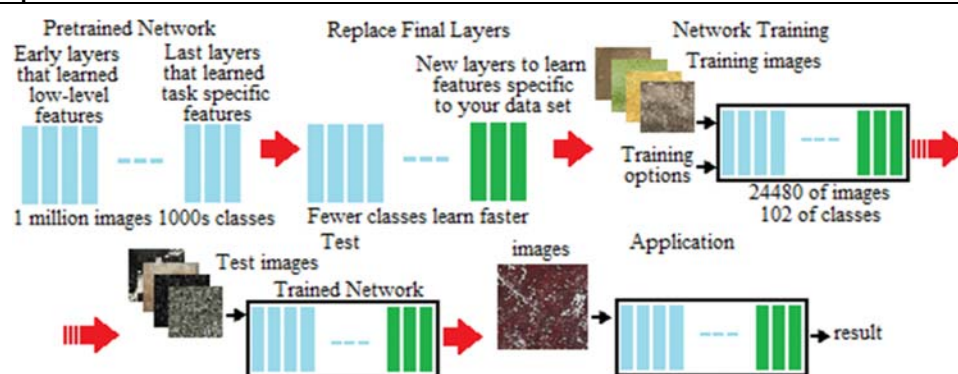


Figure A. Classification of marble and granite by transfer learning method

Turkey has 40% of the world's marble potential with its marble reserves in more than 120 different colors and designs. In addition, it is a country with a high potential with nearly 20 granite reserves. The classification of stones such as marble and granite is quite difficult due to the similar color and pattern. This situation poses a major problem for industry employees and customers. In order to solve this problem, a method has been proposed to classify marble and granite types in Turkey. Data sets with four mobile phones and two cameras have been created in quarries and retail stores in ten cities. Lens and imaging technology diversity was provided with 6 cameras used. In addition to stone images with ideal and non-ideal pattern-color tones, images of stones exposed to improper storage conditions and photographic errors such as light and shadow were also included in the data set. As a result of the study, a new data set containing 24480 images of 102 stones in total, 88 of which are marble and 14 of which are granite, was created. The number of images was increased to 171360 with three different data augmentation methods. With the data set, 7 convolutional neural networks were trained using transfer learning method. Stratified Shuffle Split, K fold cross validation methods were used to prevent memorization in training and to increase the performance and reliability of networks. The classification accuracy rate of the most successful network is 97.4%.

**Purpose:** To classify marble and granite varieties in Turkey by using convolutional neural networks with the transfer learning method, and to prepare a data set that can be used in similar studies and in the industry.

### Theory and Methods:

In this study, convolutional neural networks, which show a high accuracy rate in visual identification, were used by transfer learning method. In convolutional neural networks, the input and intermediate layers learn high-level properties such as edges, textures, patterns, while the last layers learn more specific properties. In the transfer learning method preferred for this study, the input and intermediate layers are preserved, and the last layers are designed according to the problem.

### Results:

The total number of images in the data set is 24480. The number of images was increased to 171360 with three different data augmentation methods. Two different methods were used for the training and validation data set. The networks used in training are AlexNet, DenseNet201, ResNet18, ResNet50, ResNet101, VGG16 and VGG19. The classification accuracy rate of the most successful network is 97.4%.

### Conclusion:

This study has shown that when a transfer learning method suitable for the problem, data and network is selected, pre-trained networks will provide fast and accurate solutions to these and similar problems. This visual type classification, which proves to be a good solution going forward with its success, is a useful solution proposal for industry employees and customers in terms of solving the difficulty of classification marble and granite.



## Evrişimli sinir ağları ile mermer ve granit çeşitlerinin transfer öğrenme yöntemiyle sınıflandırılması

Bahadır Elmas\*<sup>ID</sup>

Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Edebiyat Fakültesi, İstatistik Bölümü, 34380, Şişli İstanbul, Türkiye

### Ö N E Ç I K A N L A R

- Türkiye'deki mermer ve granit veri seti oluşturulmuştur
- Türkiye'deki 102 çeşit mermer ve granit sınıflandırılmıştır
- Transfer öğrenme ile probleme hızlı ve doğru çözüm getirilmiştir

#### Makale Bilgileri

Araştırma Makalesi

Geliş: 12.05.2021

Kabul: 29.08.2021

#### DOI:

10.17341/gazimmfd.936835

#### Anahtar Kelimeler:

Mermer ve granit sınıflandırma, evrişimli sinir ağlar, önceden eğitilmiş ağlar, transfer öğrenme

#### ÖZ

Türkiye 120'den fazla farklı renk ve desende mermer rezervi ile dünya mermer potansiyelinin %40'na sahiptir. Ayrıca 20'ye yakın granit rezervleriyle de yüksek potansiyele sahip bir ülkedir. Mermer ve granit gibi taşların sınıflandırması benzer renk ve desen nedeniyle oldukça zordur. Bu durum sektör çalışanları ve müşterileri için büyük sorun teşkil etmektedir. Bu soruna çözüm getirmek için Türkiye'deki mermer ve granit çeşitlerini sınıflandıracak bir yöntem önerilmiştir. On ildeki taş ocakları ve satış mağazalarında dört cep telefonu ve iki fotoğraf makinesi ile veri seti oluşturulmuştur. Kullanılan 6 kamera ile lens ve görüntüleme teknoloji çeşitliliği sağlanmıştır. İdeal ve ideal olmayan desen-renk tonlarına sahip taş görüntüleri yanı sıra, yanlış depolama şartlarına maruz kalmış taş görüntüleri, ışık-gölge gibi fotoğraflama hataları da veri setine dahil edilmiştir. Çalışma sonucunda 88'i mermer, 14'ü granit olmak üzere toplamda 102 taşa ait 24480 görüntü içeren yeni bir veri seti oluşturulmuştur. Üç farklı veri artırma yöntemi ile görüntü sayısı 171360'a çıkarılmıştır. Eğitimde ezberlemenin önüne geçebilmek ve ağların performansı ile güvenilirliğini artırmak için Stratified Shuffle Split, K fold cross validation yöntemleri kullanılmıştır. Veri setiyle 7 adet önceden eğitilmiş evrişimli sinir ağı transfer öğrenme yöntemi kullanılarak eğitilmiştir. En başarılı ağ ResNet-50 olup, sınıflandırma başarı oranı %97,4'tür.

## Classification varieties of marble and granite by convolutional neural networks with transfer learning method

### H I G H L I G H T S

- Marble and granite data set in Turkey was created
- Classification of 102 Varieties of marble and granite has been made in Turkey
- 102 types of marble and granite in Turkey are classified

#### Article Info

Research Article

Received: 12.05.2021

Accepted: 29.08.2021

#### DOI:

10.17341/gazimmfd.936835

#### Keywords:

Marble and granite classification, convolutional neural network, pre-trained networks, transfer learning

#### ABSTRACT

Turkey has 40% of the world's marble potential with its marble reserves in more than 120 different colors and designs. In addition, it is a country with a high potential with nearly 20 granite reserves. The classification of stones such as marble and granite is quite difficult due to the similar color and pattern. This situation poses a major problem for sector employees and customers. In order to solve this problem, a method has been proposed to classify marble and granite types in Turkey. Data sets with four mobile phones and two cameras have been created in quarries and retail stores in ten cities. Lens and imaging technology diversity was provided with 6 cameras used. In addition to stone images with ideal and non-ideal pattern-color tones, images of stones exposed to improper storage conditions and photographic errors such as light and shadow were also included in the data set. As a result of the study, a new data set containing 24480 images of 102 stones in total, 88 of which are marble and 14 of which are granite, was created. The number of images was increased to 171360 with three different data augmentation methods. Stratified Shuffle Split, K fold cross validation methods were used to prevent memorization in training and to increase the performance and reliability of networks. With the data set, 7 pre-trained convolutional neural networks were trained using transfer learning method. The most successful network is ResNet-50, with a classification success rate of 97.4%.

## 1. GİRİŞ (INTRODUCTION)

Mermer, metamorfizm olayı sonucunda kalker ve dolomit kalkerlerin yeniden kristalleşmesiyle meydana gelmiş bileşimdir. Bileşimlerinin %90-98'i Kalsiyum Karbonattan oluşmakta ve düşük oranda Magnezyum Karbonat içermektedir. Genellikle beyaz ve gri renktedir. Bunun yanı sıra yabancı maddeler nedeniyle kırmızı, sarı, siyah, pembe, mavi vb. renklerde de olabilirler [1]. Mermer madenlerinin geçmişi Anadolu'da MÖ 7. yüzyıla kadar dayanmaktadır. Anadolu'da MÖ 7. yüzyıl ile MS 7. yüzyıl arası mermerin altın çağıdır. Yapılan arkeolojik çalışmalarda Hitit dönemine ait süsleme ve heykelerde, Antik Yunan ve Roma dönemine ait tiyatro, arena ve diğer eserlerde, Selçuklu dönemine ait saray, hamam, kervansaray, cami ve medrese külliyelerinde, Osmanlı dönemine ait cami, minare ve çeşmelerde mermer çok yaygın bir şekilde kullanılmıştır [2]. Granit, bileşiminde %10 ile %40 arasında Kuvars, %30 ile %60 arasında Alkali Feldispat, %35'e kadar Mika ve %10 ile %35 arasında koyu renkli mineral bulunduran açık renkli, asidik bileşimli derinlik kayalarlardır. Granitler beyaz, açık gri, koyu gri, pembe, kırmızı ve zeytin yeşili gibi renklerde olabilir. Granitin Anadolu'da gemişi Roma imparatorluğu dönemine dayanır. Bu döneme ait taş ocakların bulunmuştur. Anadolu'da granit anıtsal yapılarda ve mezar taşlarında kullanılmıştır.

Türkiye sahip olduğu potansiyelle doğal taş sektöründe dünyanın beş ülkesinden birisidir. Mermer sektörü Türkiye ekonomisinde önemli bir yere sahiptir. Maden Tetkik ve Arama Genel Müdürlüğü raporlarına göre Türkiye 5 milyar m<sup>3</sup> mermer rezervi ile dünya mermer potansiyelinin %40'ına sahiptir. 2019 yılında 6,6 milyon ton mermer işlenmiş ve 1,69 milyar dolarlık ihracat yapılmıştır. Aynı dönemde 5,06 milyon ton blok ve plaka mermer ihraç edilmiş ve 869 milyon dolarlık gelir elde edilmiştir. Bu değerler ile 2019 yılında Türkiye'nin yaptığı maden ihracının %34,06'sı işlenmiş mermer, %17,46'sı ise ham blok ve plaka mermerdir [3]. İstanbul Maden İhracatçıları Birliği verilerine göre 2019 yılında 5,48 milyon dolar işlenmiş, 9,29 milyon dolar blok granit ihraç edilmiştir [4]. Türkiye'de 80'in üzerinde değişik yapıda, 120'nin üzerinde değişik renk ve desende mermer rezervi belirlenmiştir. Türkiye'de mermer ocaklarının %90'ı Ege ve Marmara bölgesindedir. Granitin önemli rezerv kaynakları ise Ordu, Rize, Trabzon, Balıkesir, Kırklareli, Kırşehir, Bolu, İzmit, Çanakkale ve İzmir'de bulunmaktadır. Mermer ve Granit türlerinin isimlendirilmesinde genel bir standart olmamasına rağmen, genel olarak renk veya çıkarıldığı bölge veya her ikisi birlikte kullanılır. Günümüzde yapıtaşından çok kaplama, döşeme ve dekorasyonda kullanılan doğal taşların özelliğine göre kullanım alanı da değişmektedir. Granit dış yapıların kaplanmasında ve döşemelerde, mermer ise daha çok inşaat sektöründe iç mekânlar, güzel sanatlar ve dekorasyon gibi alanlarda kullanılmaktadır. Son yıllarda doğal taşların manuel olarak sınıflandırılması, benzer desen, renk ve görsel görünüm nedeniyle çok yönlü bir zorluk haline gelmiştir. Alan uzmanları karşılaştıkları mermer veya granitin

tanımlanmasında oldukça zorlanmaktadır. Bu durum sektör verimliliğini azaltmakta, çalışanlar ve müşteriler için büyük sorun ve zorluk teşkil etmektedir. Literatürde mermer ve granit türlerini sınıflandırmak veya kalitesini belirlemek için bazı çalışmalar yapılmıştır. Makine öğrenmesine dayalı bilgisayarla görme uygulamaları da bu alandaki çalışmaların önemli bir kısmıdır. Bu çalışmada Türkiye'deki mermer ve granit çeşitlerinin tanımlanması için son yıllarda görsel tanımlamada yüksek başarı oranı gösteren evrişimli sinir ağları transfer öğrenme yöntemiyle kullanılmıştır. Renk ve dokuyu aynı anda birleştiren evrişimli sinir ağlara dayalı sınıflandırma, özellikleri ayrı ayrı kullanan diğer geleneksel yöntemlere göre daha başarılıdır. Mermer ve granit görüntülerini evrişimli sinir ağları ile sınıflandırmak için kullanılan bu çalışmanın amacı; benzer çalışmalarda ve sektörde kullanılabilecek bir veri seti hazırlamak, bu veri setiyle eğitilmiş evrişimli sinir ağını sektör çalışanlarının ve müşterilerinin kullanımına sunmaktır. Mermer ve granit endüstrileri, özelliklerine ve görsel görünümüne bağlı olarak, mermer ve granit görüntüleri üzerindeki desenlere göre sınıflandırmak için makine öğrenimi prosedürleri ile desteklenen bilgisayarla görme algoritmalarını kullanmayı amaçlamakta ve bu yöndeki çalışmalarla ilgilenmektedirler. Literatür incelendiğinde, dünya genelinde mermer ve granite büyük talep olmasına rağmen bu alanda az sayıda çalışma vardır. İncelenen çalışmalarda ağırlıklı olarak kalite sınıflandırması yapılmış ve üzerinde çalışılan doğal taş sayısı sınırlı tutulmuştur. Doğal taş sınıflandırması yapan çalışma sayısı daha az olup, bu çalışmalarda da incelenen doğal taş çeşidi sınırlıdır.

Juan ve arkadaşları mermer plakalarını dokularına göre sınıflandırılmak için bir LVQ (Learning Vector Quantization) sinir ağını kullanmışlardır. Çalışmalarında Crema Marfil Sierra Puerta tür mermerin plaka verilerini kullanmışlar ve %81,8 ile %90 arasında başarı elde etmişlerdir [5]. Alajarin ve arkadaşları 75 adet mermer görüntü örneği üzerinde toplam ve fark histogramları algoritması ile yapılan doku analizi sonrasında, temel bileşen analizi ile özellik çıkarma işlemi gerçekleştirilmişlerdir. Bu verilerle mermer plakalarını kalitelere göre üç kategoride sınıflandırmak için geri yayılım algoritması ile eğitilmiş çok katmanlı bir algılayıcı sinir ağı kullanmışlar ve %98,9 sınıflandırma oranı elde etmişlerdir [6]. Selver ve arkadaşları mermer kalite sınıflandırması için iki aşamalı bir yöntem izlemişlerdir. İlk aşamada 193 Limestone bloğundan 1158 görüntü olarak özellik çıkartmışlar ve birçok yapay sinir ağı ile test etmişlerdir. Daha sonra HRBFN (Hierarchical Radial Basis Function Network) kullanılarak kalite sınıflandırması yapılmıştır. Belirledikleri kalite sınıfına göre %96,84 ile %99,39 arasında başarı elde etmişlerdir [7]. Topalova ve Tzokev, çalıştıkları mermer dokularını gerçek zamanlı olarak altı sınıfa ayırmak için çok katmanlı yapay sinir ağlarını ve Programlanabilir Mantık Denetleyicisini kullanmışlardır. Çalışmalarında %87 ile %96 arasında başarı elde etmişlerdir [8]. Ferreira ve Giraldi, MNIST1, MNIST2, MNIST3 ve CIFAR evrişimli sinir ağlarını kullanılarak 25 farklı graniti sınıflamışlardır. Sınıf başına 40 görüntü olmak

üzere toplam 1000 görüntü üzerinde çalışmışlardır. 1500x1500 çözünürlükteki görüntüleri MNIST1, MNIST2 ve MNIST3 için 28x28, CIFAR için 32x32 boyutlarında bölerek görüntü sayısını artırmışlardır. CIFAR ile %87,26 sınıflandırma doğruluğu elde etmişlerdir [9]. Kaynar ve arkadaşları doğal taşları sınıflandırması için çalışmalarında 6 adet doğal taşta ait 996 görüntü kullanmışlardır. Çalışmalarında yapay sinir ağları, destek vektör makineleri (Support Vector Machine) ve Naïve Bayes yöntemlerini kullanmışlardır. Çalışmalarında destek vektör makineleri sınıflandırıcı ile %80,7'lik başarı elde etmişlerdir [10].

Torun ve arkadaşları mermer kalitesini belirlemek amacıyla AlexNet modeli ve LBP+SVM (Local Binary Pattern + Support Vector Machine) yöntemlerini kullanmışlardır. Bu amaçla 3 ayrı mermer sınıfı için toplam 600 adet mermer görüntü örneği içeren veri seti oluşturmuşlardır. LBP+SVM yönteminde %99,8, AlexNET modelinde ise %99,21'lik sınıflandırma başarısı elde etmişlerdir [11]. Pençe ve Çeşmeli çalışmalarında evrişimli sinir ağları kullanarak mermer türüne ait 80 adet görüntü örneğini birinci ve ikinci kalite olarak sınıflandırmışlar ve %75 başarı elde etmişlerdir [12]. Ather ve arkadaşları her biri 80 görüntü içeren 25 sınıfa ayrılmış 2000 granit görüntüsünden oluşan veri setiyle granit sınıflandırması yapmışlardır. Yöntem olarak evrişimli sinir ağlarını kullanmışlar %99,3 sınıflandırma başarısı elde etmişlerdir [13]. Karaali ve Eminağaoğlu 6 farklı mermerin kalite sınıfını belirlemek için bir evrişimli sinir ağ tasarlamışlardır. Her mermerden 350 görüntü olmak üzere toplamda 2100 örnekten oluşan bir veri seti oluşturmuşlardır. Veri setini büyütme işlemlerinden sonra, mermer görüntü veri seti boyutunu 6300'e çıkarmışlar ve çalışmalarında %96,1 başarı elde etmişlerdir [14]. Canayaz ve Uludağ çalışmalarında 28 farklı mermer görüntülerini içeren ve toplamda 5600 mermer görüntüsünden oluşan bir veri seti oluşturmuşlardır. Oluşturulan bu veri setiyle VGG16, ResNet ve LeNet modelleri eğitilmiş, VGG16 modelinde %97 başarı elde etmişlerdir [15]. Tablo 1'de 1999 ile 2020 yılları arasında yapılan yukarıdaki çalışmalar ve kullanılan yöntemler kronolojik olarak verilmiştir.

## 2. DENEYSEL METOT (EXPERIMENTAL METHOD)

Makine öğrenmesi, bir sistemin belirli bir problem üzerinde karar vermesini sağlayan yöntemlerin geliştirildiği bilgisayar bilim alanıdır [16]. Derin öğrenme ise, çok büyük verilerde özelliklerin çıkarılması için kullanılan, yapay sinir ağlarından türetilmiş, çoklu katmanlı, makine öğrenmesi sistemlerinin alt gruplarında incelenen ve çoğu durumda klasik makine öğrenme yöntemlerinin aksine veri ön işleme gerektirmeyen bir makine öğrenme metodudur [17, 18]. Fakat makine öğrenimine göre yetenekleri farklılaşmıştır. İnsan düzeyine yakın görüntü sınıflandırması, konuşma tanıma, metin okuma ve seslendirme gibi konuları kapsamaktadır [19]. Derin öğrenme algoritmaları içerisinde birçok sınıflandırma modeli kullanılmaktadır. Bunların arasında en sık kullanılan ve popüler olan evrişimli sinir ağlarıdır [17]. Evrişimli sinir ağları nesnelerin sınıflandırılması ve tespiti ile ilgili yapılan yarışmalarda normal makine öğrenmesi yöntemlerinden çok daha iyi derecelere alanının en iyisi olduğunu kanıtlamıştır [20]. Evrişimli sinir ağları çoğunlukla Şekil 1'deki gibi Convolution (Evrişimli Katmanlar) [21, 22], Rectified Linear Unit (ReLU), Pooling (Havuzlama) ve Fully Connected Layers (Tam Bağlantılı Katmanlar) katmanlarından oluşur [18, 23]

Evrişimli sinir ağlarının ilk katmanlarda verilen girdi üzerinde, filtreler yoluyla özellik çıkarımı gerçekleştirilir. Aynı zamanda bir yandan hesaplama maliyetini düşürmek diğer yandan ise girdiden öğrenilen özelliklerin özet bilgisini diğer katmanlara aktarmak amacıyla boyut düşürme fonksiyonları kullanılır. Daha sonra girdiden elde edilen bu özellikler tek boyutlu bir vektör haline getirilir ve tam bağlantılı katman veya katmanlara girdi olarak verilip sınıflandırma işlemi gerçekleştirilir. Ağın filtreler ve ağırlıklar altındaki performansı bir kayıp fonksiyonu ile hesaplanır ve öğrenilebilir parametreler yani filtreler ve ağırlıklar geri yayılım yoluyla kayıp değerine göre güncellenir [24]. Evrişimli sinir ağlarının her biri farklı mimari kullanarak eğitim işlemi gerçekleştirilmektedir. Bu çalışmada kullanılan evrişimli sinir ağları; AlexNet,

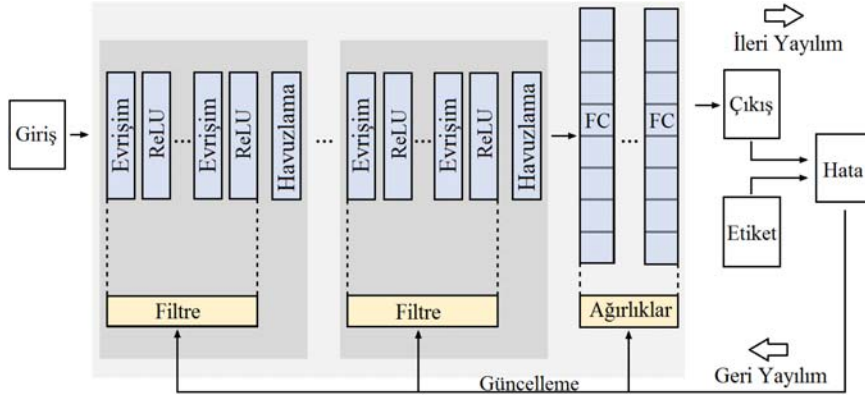
**Tablo 1** Literatür Çalışmaları (Literature Studies).

Çalışma	Tarih	Kullanılan Yöntem ve Yapılan Sınıflandırma	Taş Gör. Say.	Gör. Say.
[5]	1999	Öğrenmeli Vektör Kuantalama (Mermer Kalite Sınıflandırma)	1	44
[6]	2005	Yapay Sinir Ağları (Mermer Kalite Sınıflandırma)	1	75
[7]	2009	Yapay Sinir Ağları, HRBFN (Mermer Kalite Sınıflandırma)	1	1158
[8]	2011	Yapay Sinir Ağları (Mermer Sınıflandırma)	6	100
[9]	2017	Evrişimli Sinir Ağları (Granit Sınıflandırma)	25	1000
[10]	2018	Yapay Sinir Ağları, SVM, Naïve Bayes (Granit ve Mermer Sınıflandırma)	6	996
[11]	2019	Evrişimli Sinir Ağları ve LBP+SVM (Mermer Kalite Sınıflandırma)	3	600
[12]	2019	Evrişimli Sinir Ağları (Mermer Kalite Sınıflandırma)	1	80
[13]	2019	Evrişimli Sinir Ağları (Granit Sınıflandırma)	25	2000
[14]	2020	Evrişimli Sinir Ağları (Mermer Kalite Sınıflandırma)	6	6300
[15]	2020	Evrişimli Sinir Ağları (Mermer Sınıflandırma)	28	5600

DenseNet201, ResNet18, ResNet50, ResNet101, VGG16 ve VGG19'dur. Tablo 2'e mimarileri söz konusu ağların katman, derinlik, parametre sayısı, görüntü giriş boyutları, Tablo 3'te ise söz konusu ağların verilmiştir [25-28].

Evrişimli sinir ağlarının eğitilmesi, ağırlık karmaşıklığı ya da veri setinin büyüklüğü nedeniyle standart bilgisayar işlemcilerinde gerçekleştirmek çok zordur. Bu nedenle güçlü grafik işleme birimlerine ihtiyaç duyulur. Uzun süren eğitimler sonucunda eğitilmiş birçok modelden problem için uygun bir model seçilerek problemin çözümünde kullanılabilir. Eğitilmiş bir ağırlık ilgili ikinci bir görevde yeniden tasarlandığı, hızlı ilerleme ve gelişmiş performans

sağlayan bu makine öğrenmesi tekniğine transfer öğrenme denir. Transfer öğrenme; veri büyüklüğüne bağlı olarak zaman kısıtını ve donanım gereksinimini gözetmeden, derin öğrenme modeli oluşturmanın en az maliyetli yoludur. Geleneksel makine öğrenme teknikleri her görevi sıfırdan öğrenmeye çalışırken, transfer öğrenme teknikleri önceki görevlerden elde ettiği bilgileri yeni bir görevi öğrenme hedefine aktarır [29]. Öğrenilen niteliklerin taşınabilir olması derin öğrenmeyi eski ve sığ öğrenme yaklaşımlarından ayıran önemli avantajlarından biridir ve derin öğrenmeyi küçük veri problemlerinde etkin yapar [30]. Evrişimli sinir ağlar giriş ve ara katmanlar genellikle kenar, doku, desen, gibi üst seviye özellikleri öğrenirken son



Şekil 1. Evrişimli Sinir Ağları (Convolutional Neural Networks Workflow).

Tablo 2. Çalışmada kullanılan Derin Öğrenme ağları (Deep Learning networks used in the study).

	AlexNet	DenseNet201	ResNet-18	ResNet-50	ResNet-101	VGG16	VGG19
Derinlik	8	201	18	50	101	16	19
Katman	25	709	72	177	347	41	47
Parametre (Milyon)	61	20,2	11,7	25,6	44,6	138	144
Resim Giriş Boyutu	227x227	224x224	224x224	224x224	224x224	224x224	224x224

Tablo 3. Ağ mimarileri (Network architectures).

AlexNet	DenseNet201	ResNet-18	ResNet-50	ResNet-101	VGG16	VGG19
11x11con,967x7,con		7x7,con,64	7x7,con,64	7x7,con,64	[3x3con,64]x2	[3x3con,64]x2
max-pool	max-pool	max-pool	max-pool	max-pool	max-pool	max-pool
5x5con,256	1x1,con	3x3con,64	1x1con,64	1x1con,64	[3x3con,128]x2	[3x3con,128]x2
max-pool	3x3,con	3x3con,64	3x3con,64	3x3con,64	max-pool	max-pool
3x3con,384	1x1,con	3x3con,128	1x1con,256	1x1con,256	[3x3con,256]x3	[3x3con,256]x4
3x3con,384	aver-pool	3x3con,128	1x1con,128	1x1con,128	max-pool	max-pool
3x3con,256	1x1,con	3x3con,256	3x3con,128	4x3x3con,128	[3x3con,512]x3	[3x3con,512]x4
max-pool	3x3,con	3x3con,256	1x1con,512	1x1con,512	max-pool	max-pool
fc4096	1x1,con	3x3con,512	1x1con,256	1x1con,256	[3x3con,512]x3	[3x3con,512]x4
fc4096	aver-pool	3x3con,512	3x3con,256	6x3x3con,256	max-pool	max-pool
fc1000	1x1con	aver-pool	1x1con,1024	1x1con,1024	fc4096	fc4096
softmax	3x3,con	fc1000	1x1con,512	1x1con,512	fc4096	fc4096
	1x1,con	softmax	3x3con,512	3x3x3con,512	fc1000	fc1000
	aver-pool		1x1con,2048	1x1con,2048	softmax	softmax
	1x1,con		aver-pool	aver-pool		
	3x3,con		fc1000	fc1000		
	aver-pool		softmax	softmax		
	fc1000					
	softmax					

katmanlar daha spesifik özellikleri öğrenir. Bu yüzden giriş ve ara katmanlar korunurken son katman probleme uygun şekilde tasarlanıp, mevcut veri setiyle eğiterek hızlı bir şekilde yeni bir model elde edilebilir. Veri ve hedef görev, orijinal modelin üzerinde çalıştığı veri ve hedef görevle benzerlik gösteriyorsa bu yaklaşım en iyi sonucu verir. Bununla birlikte, bir modeli sıfırdan eğitmek için yeterli veri varsa ve görevler o kadar yakın olmasa da önceden eğitilmiş bir model kullanarak parametreleri başlatmak rasgele başlatmadan daha iyi sonuçlar verebilir. Ayrıca sahip olunan veri problemleri ve miktarı yetersiz ise; bu veri için tasarlanmış özel model, önce genel bir görev için hazırlanmış büyük bir veri kümesi kullanılarak eğitilip daha sonra mevcut veri ile eğitilebilir. Bu yöntemde aktarılan şey temel olarak parametrelerin başlangıç değerleridir. Ağırlıkları rastgele başlatmak yerine önceden eğitilmiş bir ağı kullanarak başlatmak; ağı öğrenmede iyi bir başlangıç yapmasını, öğrenme gelişiminde daha dik eğimi ve daha yüksek performans elde etmesini sağlayarak yakınsamayı hızlandırır. Ayrıca yeterli veri olmadığı durumlarda transfer öğrenme ağı aşırı öğrenmeden koruyarak eğitmek için iyi bir seçenektir. Tam bağlı katman dışındaki tüm katmanları aktarmak en uygun transfer öğrenme türüdür. Bu çalışmada da bu yöntemin kullanılması tercih edilmiştir. Transfer edilen katmanların ilk katmanlar olması gerekmez. Görevler aynıysa ancak girdi verilerinin türü biraz farklıysa, son katmanları da transfer etmek mümkündür. Transfer öğrenme pek çok görev için kullanılabilir. Ancak bir model başka bir modele transfer etmek her zaman mümkün değildir. Veri türünün ve görevin oldukça farklı olduğu durumlar bu kapsama girer. Transfer öğreniminin uygulanamayabileceği bir başka durum, özellikleri transfer edilecek model ile aktarılan modelin mimarisinin uyumsuzluk durumudur. Farklı mimariye sahip modeller arasında bilgi transferi sağlayan teknik model ise damıtmadır. Önceden eğitilmiş bir modelin damıtılması; yeni modeli, doğrudan veriler üzerinde eğitmek yerine önceden eğitilmiş modelin çıktılarını taklit edecek şekilde eğitilmesidir. Bu yaklaşım özellikle kaynak modelden daha küçük bir modelin eğitilmesinde oldukça verimlidir. Tanımlayıcı sistemler geliştirilirken karşılaşılan en büyük sorun güvenilir ve performans artırıcı veri setleri oluşturmaktır. Türkiye'de 80'in üzerinde değişik yapıda, 120'nin üzerinde değişik renk ve desende mermer rezervi, 20'ye yakın granit olmasına rağmen mevcut veri setlerinin en büyüğü 28 mermer çeşidini kapsamaktadır. Granit alanında ise Türkiye'ye özgü benzer bir veri seti yoktur. Türkiye'de çok sayıda mermer ve granit rezervi olduğu düşünüldüğünde büyük bir veri seti oluşturmak bu ve benzeri çalışmalar için yararlı olacaktır. Söz konusu veri eksikliğini

gidermek, görüntülerinden doğal taşları sınıflandırmak amacıyla 2019 yılının ilk aylarında veri seti oluşturma çalışmalarına başlanılmıştır. Bu amaçla Afyon, Ankara, Antalya, Balıkesir, Bilecik, Bursa, Denizli, Elâzığ, İstanbul, Kayseri'deki mermer, granit ocakları veya satış mağazaları ziyaret edilerek fotoğraf çekimleri yapılmıştır. Çalışmada 4 farklı cep telefonu kamerası ve 2 fotoğraf makinesi kullanılmıştır. Böylece mercek ve görüntüleme teknoloji çeşitliliği sağlanarak fotoğraflar çekimlerinin tek kameradan yapılmasının önüne geçilmiştir. Dikkat edilen diğer bir husus ise çok fazla sayıda mermer ve granit plakasından çekimler yapmak olmuştur. Yapılan çalışmalar sonucunda 88 mermer, 14 granit çeşidi kapsayan bir veri seti oluşturulmuştur. Mermer görüntü sayısı 21120, granit görüntü sayısı ise 3360'dır. Her mermer ve granit çeşidinden 16 ayrı plakadan 240 adet görüntü toplanmıştır. Veri seti oluşturulduktan aşağıdaki özel durumlarda göz önünde tutulmuş, bu özel durumları temsil eden görüntüleri toplamak için firmaların görüntü kaynaklarından da yararlanılmıştır. Bunlardan birincisi; uzun süre depo, vitrin veya stantlarda bekleyen malzeme üzerinde meydana gelen toz, ıslaklık vb. etkenlere müdahale edilmemiştir. Şekil 2'deki gibi bu tür görüntülerin veri setine eklenmesine özen gösterilmiştir.


İkinci olarak; fotoğraf çekimlerinde özel bir aydınlatma düzeneği kullanılmamış, taşın bulunduğu ortamdaki güneş ışığına veya farklı renklerdeki ışıklandırma düzeneklerine müdahale edilmemiştir. Şekil 3'te verildiği gibi taşlar üzerinde meydana gelen güneş ışığı, aydınlatma, yansıma ve gölgeleri içeren görüntüler veri setine eklenmiştir.

Bunun yanı sıra Şekil 4 ve Şekil 5'te verildiği gibi taşın üzerinde meydana gelen çatlaklar veya taşın alışıla gelmiş desen veya renk tonu dışındaki farklılıkları içeren görüntüler veri setine dâhil edilmiştir. Ayrıca fotoğraf çekimleri yüzey normali dışındaki farklı açılardan da yapılmıştır. Yukarıda bahsedilen özel durumları temsil eden görüntüleri toplamak için yapılan çekimlerin yanı sıra firmaların görüntü kaynaklarından da sınırlı oranda faydalanılmıştır. Bu oran toplam verinin %1'inden azdır. Bununla birlikte fotoğraf çekimleri esnasında tekrarlanan fotoğraf kareleri kaldırılmıştır. Bu iki işlemin dışında eksik veriyi tamamlama, temizleme, normalleştirme, boyut indirgeme, birleştirme vb. veri ön işlem adımları uygulanmamıştır.


Tablo 4'te 88 adet mermer ve 14 adet granit isimleri, kullanılan plaka ve görüntü sayısı, Şekil 6'da ise çalışmada kullanılan mermer ve granitlerin birer adet görüntü örneği verilmiştir.



Şekil 2. Toz ve Islaklık etkisi (Dust and Wetness effect).



Şekil 3. Işık, yansımaya ve gölge etkisi (Light, reflection and shadow effect).



Şekil 4. Plakalarda meydana gelen çatlaklar (Cracks in the plates).



Şekil 5. Desen ve renk tonu farklılıkları (Pattern and color tone differences).

### 3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Ağların eğitilmesi süreçlerinde veri seti, eğitim ve doğrulama veri seti olmak üzere iki gruba ayrılır. Ağ başarı oranı eğitim ve doğrulama veri setine bağlı olarak yüksek değişirliğe sahiptir [30]. Eğitim ve doğrulama veri setinin tüm veri setini temsil etmesi için çeşitli yöntemler geliştirilmiştir. Çalışmada literatürde yaygın olarak kullanılan iki yöntem kullanılmıştır. Birinci yöntem; Stratified Shuffle Split (Katmanlı Karışık Bölme) olarak adlandırılan yöntemdir [31, 32, 33]. Veri setinden her defasında rastgele veri alınarak, verinin belirlenen bir bölümü doğrulama geri kalanı ise eğitim amaçlı kullanılmıştır. Bu işlem 10 defa tekrarlanmış ve her bir ağ 10'ar defa eğitilmiştir. Daha sonra elde edilen doğrulama sonuçlarının ortalama değeri alınmıştır. Kullanılan ikinci yöntem ise K-fold cross validation (K-katlamalı Çapraz doğrulama) yöntemidir. Bu yöntemde; veri seti 10 parçaya ayrılmış, ağ belirlenen parça veriyle eğitilmiş, kalan veri doğrulama için kullanılmıştır [30]. Bu işlem 10 defa tekrarlanmış ve her bir ağ 10'ar defa eğitilmiş daha sonra

birinci yöntemdeki gibi doğrulama sonuçlarının ortalama değeri alınmıştır. Her iki sonuçta birbirine çok yakın olup çalışmadaki sonuçlar her iki yöntemin ortalama değeridir.

Çalışmada, beş farklı değerlendirme ölçütü Doğruluk (Accuracy), Kesinlik (Precision), Geri Çağırma (Recall), F-ölçütü (F Score) ve Eğri Altındaki Alan - Alıcı Çalışma Karakteristikleri (AUC-ROC) kullanılmıştır. Tablo 5'te verilen Karışıklık Matrisi (Confusion Matrix) bir sınıflandırma probleminde gerçekleşen ve tahminlenen değerleri göstermektedir. Karışıklık matrisi kullanılarak, belirlenen beş performans ölçütü hesaplanabilmektedir [34, 35].


Doğruluk, Kesinlik, Geri Çağırma ve F1-Ölçütü metriklerinin formülleri ve açıklamaları Tablo 6'da verilmiştir [34, 35].

İşlem Karakteristik Eğrisi, Doğru Pozitif Oranı-Yanlış Pozitif Oranı grafiğidir. Bu metriklerin formülleri Tablo 7'de verilmiştir. Eğri Altında Kalan Alan ise İşlem Karakteristik Eğrisi altında kalan alandır [34, 35].

**Tablo 4.** Mermer ve Granit Veri Seti (Marble and Granite Dataset).

Doğal Taş Adı	Plaka Say.	Gör. Say.	Doğal Taş Adı	Plaka Say.	Gör. Say.
1 Adıyaman Dark Emperador	16	240	52 Marino Grey	16	240
2 Adranos Beyaz	16	240	53 Marmara Beyaz	16	240
3 Adranos Siyah	16	240	54 Maroon Marinace	16	240
4 Afrodit	16	240	55 Metalicus Elazığ	16	240
5 Afyon Beyaz	16	240	56 Milas Kavaklıdere	16	240
6 Afyon Beyaz Arcoboleno	16	240	57 Milas Limon	16	240
7 Afyon Gri	16	240	58 Muğla Beyaz	16	240
8 Afyon Kaplan Postu	16	240	59 Mustafa Kemalpaşa Beyaz	16	240
9 Afyon Menekşe	16	240	60 Olive Maroon	16	240
10 Afyon Şeker	16	240	61 Onyx Adıyaman	16	240
11 Agora Bej	16	240	62 Picasso Denizli	16	240
12 Akşehir Siyah	16	240	63 Rosa Bellissimo	16	240
13 Alexander Black	16	240	64 Rosalia	16	240
14 Bartın Bej	16	240	65 Salome	16	240
15 Bianco Royal	16	240	66 Savana Gri	16	240
16 Bilecik Gül Kurusu	16	240	67 Silver Grey Isparta	16	240
17 Bilecik Pembe	16	240	68 Silver Marmara	16	240
18 Burdur Badem	16	240	69 Silver White	16	240
19 Burdur Bej	16	240	70 Sivrihisar Bej	16	240
20 Burdur Kahverengi	16	240	71 Siyah Emperador	16	240
21 Bursa Açık Bej	16	240	72 Sofita Bej	16	240
22 Bursa Koyu Bej	16	240	73 Söğüt Altın	16	240
23 Bursa Light Emperador	16	240	74 Söğüt Bej	16	240
24 Cappuccino Bej	16	240	75 Süpren	16	240
25 Çubuklu Marmara	16	240	76 Tobacco Gold	16	240
26 Denizli Pembe	16	240	77 Toros Bej	16	240
27 Diana Bej	16	240	78 Toros Gül	16	240
28 Diana Rose	16	240	79 Toros Siyah	16	240
29 Dinar Bej	16	240	80 Tundra Blue	16	240
30 Diyarbakır Bej	16	240	81 Tundra Gri	16	240
31 Diyarbakır Pembe	16	240	82 Uşak Beyaz	16	240
32 Dolomit	16	240	83 Uşak Sarı	16	240
33 Ege Bej	16	240	84 Uşak Yeşil	16	240
34 Ege Bordo	16	240	85 Vanillia Ice	16	240
35 Ege Kahve	16	240	86 Vanillia Mocha	16	240
36 Elazığ Vişne	16	240	87 Vize Pembe	16	240
37 Elmalı Bej	16	240	88 Yeşilli Beyaz Muğla	16	240
38 Emperador Dark	16	240	89 Aksaray Sipahi	16	240
39 Emperador Light	16	240	90 Aksaray Yaylak	16	240
40 Fildişi Bej	16	240	91 Ankara Füme	16	240
41 Golden Brown	16	240	92 Balaban Green	16	240
42 Gri Emperador	16	240	93 Bergama Gri	16	240
43 Harmankaya Bej	16	240	94 Bulancak Füme	16	240
44 Hazar Pembe	16	240	95 Crema Imperial	16	240
45 Karacabey Siyah	16	240	96 Crema Lal	16	240
46 Kastamonu-Eflani Bej	16	240	97 Ezine	16	240
47 Kayseri Kamelyon	16	240	98 Giresun Vizon	16	240
48 Konya Beyşehir Emperador	16	240	99 Hisar Gri	16	240
49 Kumru Tüyü	16	240	100 Hisar Yaylak	16	240
50 Leopar (Salome)	16	240	101 Nero Nebiyan	16	240
51 Manyas Beyaz	16	240	102 Verde Kiwi	16	240





Şekil 6. Mermer ve Granit Görüntüleri (Marble and Granite Images)

Tablo 5. Karışıklık Matrisi (Confusion Matrix)

Gerçekleşen	Tahminlenen	
	Doğru Pozitif (DP)	Yanlış Negatif (YN)
Yanlış Pozitif (YP)	Doğru Negatif (DN)	

Tablo 6. Değerlendirme Metrikleri (Performance Metrics)

Metrik	Formül	Açıklama
Doğruluk (Accuracy)	$(DP+DN) / (DP+DN+YP+YN)$	Modelin genel performansı
Kesinlik (Precision)	$DP / (DP+YP)$	Doğru tahminlerin ne kadar kesin olduğu
Geri Çağırma (Recall)	$DP / (DP+YN)$	Gerçek pozitif örneklerin oranı
F-ölçütü (F1 Score)	$2DP / (2DP+YP+YN)$	Dengesiz sınıflar için yararlı hibrit metrik

Verilerin toplanması sürecinde az sayıda mermer ve granit plakasından özgün desen ve renk görüntülerinin toplanması yerine çok sayıda plakadan Şekil 2 ile Şekil 5 arasında verilen etkenlerin desen üzerindeki olumsuz etkilerinin de içeren fotoğrafların veri setine eklemenin ağırlık güvenilirlik ve performansı üzerinde etkili olacağı sonucuna varılmıştır. Bu amaçla ideal görüntülerle birlikte, doğal taş desenini olumsuz etkileyen sorunları yansıtacak görüntüler de veri setine eklenmiştir. Tanımlayıcı sistem geliştirirken veri setinin boyutunun, görüntü çeşitliliğinin, görüntülenen taş plaka sayısının, eğitim verisi oranının, ağların derinlik, katman ve parametre sayısının sınıflandırma doğruluğu üzerinde etkisini deneysel olarak görmek amacıyla Tablo 8'deki gibi üç adet veri seti oluşturulmuştur.

Mermer ve granit sınıflandırılması spesifik bir problem çözümdür. Bu yüzden çalışma için oluşturulan mermer ve granit veri seti ile çalışmada kullanılan ağların eğitilmesi gerekir. Ağların giriş katmanından sınıflandırma katmanına kadar olan ara katmanlar Şekil 7'deki gibi korunmuştur. Veri

seti ağların giriş katmanından itibaren verilmiştir. Çalışmada kullanılan ağlar 1000 sınıflandırma yaparken bu çalışmada 102 sınıflandırma yapılmaktadır. Kullanılan ağların çıkış katmanı yeni sınıflandırma sayısına göre ayarlanmıştır. Ağlardan AlexNet, VGG16 ve VGG19'da havuzlama katmanında maksimum havuzlama yöntemi kullanılırken, DenseNet-201, ResNet-18, ResNet-50 ve ResNet-101 ağlarında ise maksimum ve ortalama havuzlama yöntemi kullanılmıştır. Çalışmada kullanılan ağlar oluşturulan veri setiyle MATLAB ortamında yazılan kodlar ve Deep Network Designer toolbox'ı kullanılarak eğitilip test edilmiştir. Modelin öğrenme oranı 0,01, momentum katsayısı 0,9, yığın sayısı 16, eniyileme yöntemi adam, kayıp fonksiyonu kategorik çarpaz entropi'dir.


Eğitimde kullanılan bilgisayarın işletim sistemi 64 bit, işlemcisi i7-2,90 GHz, RAM'i 16GB olup ekran kartı Radeon Pro 560'dır. Çalışmada kullanılan ağın katmanlarına ait Özellik Haritası (Feature Map) görselleri Şekil 8'de verilmiştir.

**Tablo 7.** Doğru Pozitif Oranı-Yanlış Pozitif Oranı (True Positive Rate-False Positive Rate)


Metrik	Formül
Doğru Pozitif Oran	$DP / (DP + YN)$
Yanlış Pozitif Oran	$YP / (DN + YP)$

**Tablo 8.** Veri Setleri (Datasets)

Veri seti	Plaka Say.	Her Taş İçin Gör.Say.	Top. Gör. Say.	Veri Artırma	Arttırılmış Gör. Say.	Veri Seti Özelliği
Birinci	4	60	6120	-	-	İdeal görüntüler
İkinci	8	120	12240	-	-	İdeal ve İdeal olmayan görüntüler
Üçüncü	16	240	24480	Var	171360	İdeal ve İdeal olmayan görüntüler



**Şekil 7.** Çalışmada kullanılan ağ yapısı (Network structure used in the study).



**Şekil 8.** Özellik Haritası (Feature Map)

Birinci veri setinde görüntülenen taş plaka sayısı az tutulmuştur. Bunun yanı sıra birinci veri seti; görüntüleme ve depolama şartlarına maruz kalmayan, mermer ve granitin özgün renk ve desenini yansıtan, desen farklılıkları ile renk tonlarını içermeyen görüntülerden oluşmaktadır. Birinci veri seti, 4'er adet mermer ve granit plakasının her birinden 15'er adet fotoğraf almak üzere her bir taş çeşidinden 60'ar adet görüntü içermektedir. Toplam görüntü sayısı 6120'dir. Tablo 9'da görüleceği üzere ağların başarı oranı eğitim verisi oranına bağlı olarak değişmektedir. Eğitim verisi oranı %30 ve %50 olduğunda en başarılı ağ ResNet50, %70 olduğunda ise DenseNet201'dir.

**Tablo 9.** Birinci veri seti ağ başarı oranları  
(First dataset network accuracy rates)

Ağ Modelleri	Eğitim Yüzde Değeri		
	30%	50%	70%
AlexNet	88,84	93,26	94,61
DenseNet201	93,83	97,20	98,33
ResNet18	89,69	94,61	96,83
ResNet50	94,92	97,48	98,21
ResNet101	93,55	96,85	97,28
VGG16	84,71	88,96	90,60
VGG19	85,12	90,45	93,14

Fakat ağlar renk tonu, desen farklılıkları içeren plakalardan elde edilen görüntüler ile yanlış fotoğraflama ve depolama şartlarına maruz kalan plakalardan elde edilen görüntülerle test edildiğinde ağların performanslarında %36,45'e varan düşüşler gerçekleşmiştir. Ağ başarı oranındaki bu düşüşün önüne geçebilmek amacıyla yeni ideal görüntülerle birlikte renk tonu, desen farklılıkları ile yanlış fotoğraflama ve depolama şartlarına maruz görüntülerin birinci veri setine eklenmesiyle ikinci veri seti oluşturulmuştur.

İkinci veri setindeki görüntülenen plaka sayısı 8'e, mermer ve granit çeşidi başına görüntü sayısı ise 120'ye çıkarılmıştır. Veri setindeki toplam görüntü sayısı 12240'dır. İdeal olmayan görüntülerin veri setine eklenmesiyle ağların performansında tüm eğitim yüzdeleri için birinci veri seti eğitime göre %16,91 ile %27,32 arasında değişen düşüşler gerçekleşmiştir. Tablo 10'da görülebileceği gibi eğitim verisi oranı %30 olduğunda en başarılı ağ DenseNet201, eğitim verisi oranı %50 ve %70 olduğunda ise ResNet 50'dir.

**Tablo 10.** İkinci veri seti ağ başarı oranları  
(Second dataset network accuracy rates)


Ağ Modelleri	Eğitim Yüzde Değeri		
	30%	50%	70%
AlexNet	61,53	69,70	74,63
DenseNet201	72,42	75,18	81,25
ResNet18	64,33	71,57	77,59
ResNet50	72,10	77,61	81,30
ResNet101	70,62	73,85	79,94
VGG16	58,99	65,93	68,78
VGG19	59,68	66,48	69,87

İkinci veri setiyle eğitilen ağların başarısındaki en büyük düşük olan %27,32, birinci veri setiyle eğitilen ve ideal olmayan görüntülerle test edilen ağların %36,45'e varan düşüşüyle karşılaştırıldığında kayda değer bir gelişmedir. Yaklaşık 9 puanlık bir performans artışı elde edilmiştir. Daha fazla ideal ile ideal olmayan görüntünün ve veri artırma yöntemlerinin ağların performansını artıracığı düşüncesiyle üçüncü bir veri seti oluşturulmuştur.

Sinir ağlarında küçük veri setleri modellerin veriyi ezberlemesine, dolayısıyla modellerin düşük doğrulukta çalışmasına neden olmaktadır. Bu sorunu çözmek için ise veri artırımı yöntemleri uygulanır. Veri artırımı resimler için; döndürme, öteleme, kırpma, soldurma, ölçeklendirme, gürültü ve gri gölge ekleme gibi teknikler ile orijinal veriden sentetik kopyalarının üretme işlemidir [36]. Çalışmada üç veri artırma yöntemi uygulanmıştır. Birinci veri artırma yöntemi veri setindeki her bir görüntüye Şekil 9'daki gibi sağa 90°, sola 90°, dikey ve yatay döndürme işlemi uygulanmıştır. İkinci veri artırma yöntemi olarak Şekil 2 ile Şekil 5 arasında verilen etkenlerin desen üzerindeki olumsuz etkilerini temsil etmesi amacıyla Şekil 10'daki gibi taş görüntüleri üzerinde rastgele gri gölge eklenmesidir. Veri Artırımı için kullanılan üçüncü yöntem ise depolama şartları nedeniyle taş üzerinde meydana gelebilecek tozlanma ve görüntüleme kalitesini temsil etmesi amacıyla görüntülere gürültü eklenmesidir. Şekil 11'de Gaussian noise eklenmiş doğal taş örnekleri verilmiştir.

Üçüncü veri setinde görüntülenen plaka ve görüntü sayısı bir kez daha iki katına çıkarılmıştır. Böylece her doğal taş için plaka sayısında 16'ya, görüntü sayısında ise 240'a ulaşılmıştır. Veri setindeki toplam görüntü sayısı 24480'dir. Döndürme, gri gölge ve gürültü ekleme veri artırma yöntemleri aşamalı olarak üçüncü veri setine uygulanmış, sonuçta her doğal taş için görüntü sayısında 1680'e ulaşılmıştır. Böylece üçüncü veri setindeki toplam görüntü sayısı 24480'den 171360'a çıkmıştır. Söz konusu veri setiyle eğitilen ağların başarısı Tablo 11'de verildiği gibi eğitim verisi oranına bağlı olarak %78,75 ile %97,40 arasında değişmektedir. En yüksek başarı oranı eğitim verisi oranı %70 olduğunda %97,40 ile ResNet50 ağında gerçekleşmiştir. Böylece ikinci veri setindeki düşüşün önüne geçilmiş ve birinci veri setinin başarısına yaklaşılmıştır. Şekil 12'de ise her üç veri setiyle eğitilen en başarılı ağların başarı oranları karşılaştırılmalı olarak verilmiştir. Şekilde görülebileceği üzere genel eğilim; eğitim verisi ve eğitimde kullanılan yüzdelik dilim artıkça ağ başarı oranları artmaktadır.


Üçüncü veri setine veri artırma yöntemleri uygulanmadan önce en başarılı ağın başarı oranı %86,7'dir. Tablo 12'de görüldüğü üzere veri artırımı yöntemleri uygulandıktan sonra sınıflandırma başarısı artmış ve sınıflandırma hatası azalmıştır. Başlangıçta en başarılı ağın %86,7 olan başarı oranı, veri artırma yöntemleri uygulandıktan sonra %97,4 oranına yükselmiştir. Hata oranı ise %13,3'ten %2,6'ya düşmüştür.



Şekil 9. Görüntüleri döndürme (Rotating images)



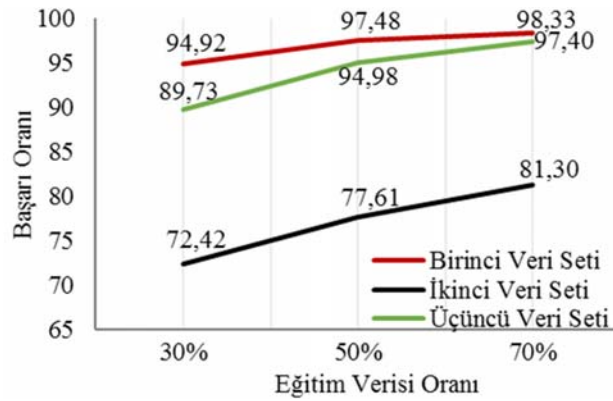
Şekil 10. Görüntülere gri gölge ekleme (Adding gray shadow to images)



Şekil 11. Görüntülere gürültü ekleme (Adding noise to images)

Tablo 11. Üçüncü veri seti ağ başarı oranları (Third dataset network accuracy rates)

Ağ Modelleri	Eğitim Yüzde Değeri		
	30%	50%	70%
AlexNet	82,38	89,15	91,30
DenseNet201	89,21	94,98	97,33
ResNet18	84,72	91,28	94,21
ResNet50	89,73	94,91	97,40
ResNet101	89,40	94,54	96,91
VGG16	79,40	86,90	89,41
VGG19	78,75	86,14	89,50



Şekil 12. Üçüncü veri seti ağ başarı oranı değerleri (Third dataset network accuracy rates)

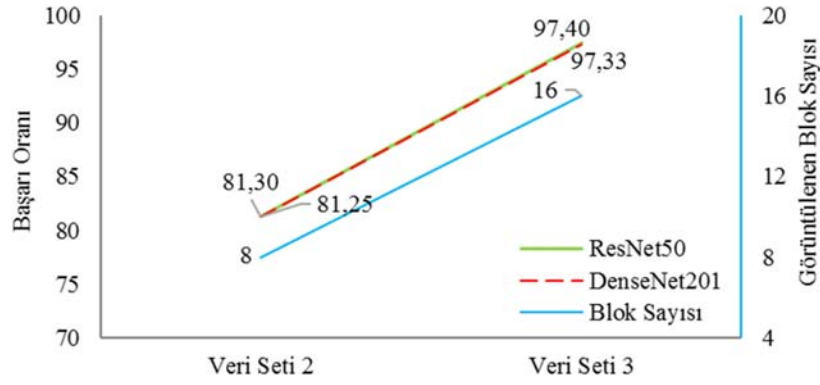
Şekil 13'te ise veri setlerinde en yüksek başarı gösteren ResNet50 ve DenseNet201 ağlarının görüntülenen mermer ve granit plaka sayısı artışına paralel olarak ağ başarı oranlarının da arttığı görülebilir.

Şekil 12, Tablo 12 ve Şekil 13 görüntü sayısı ve görüntü çeşitliliği arttıkça ağ başarı oranının ve güvenilirliğinin artacağını göstermektedir. Üçüncü veri setinde eğitim veri seti oranı %70 olduğunda en başarılı ağ ResNet50 ağının

Doğruluk, Kesinlik, Geri Çağırma ve F1 Ölçütü metrik değerleri Tablo 13'te verilmiştir. Şekil 14'te sınıflandırılması zor olan mermer (Afyon Beyaz, Agora Bej, Bianco Royal, Silver White) ve granit (Aksaray Yaylak, Bergama Gri, Hisar Gri, Hisar Yaylak) çeşidinden dörder tanesinin ROC grafikleri verilmiştir. Tablo 14'te ise ResNet50 ağının üçüncü veri setinde eğitim veri seti oranı %70 olduğu için veri setindeki her mermer ve granit çeşidi için sınıflandırma başarı oranları verilmiştir.

**Tablo 12.** Veri Artırma Yönteminin Ağ Başarısına Etkileri (Effects of Data Augmentation Method on Network Accuracy)

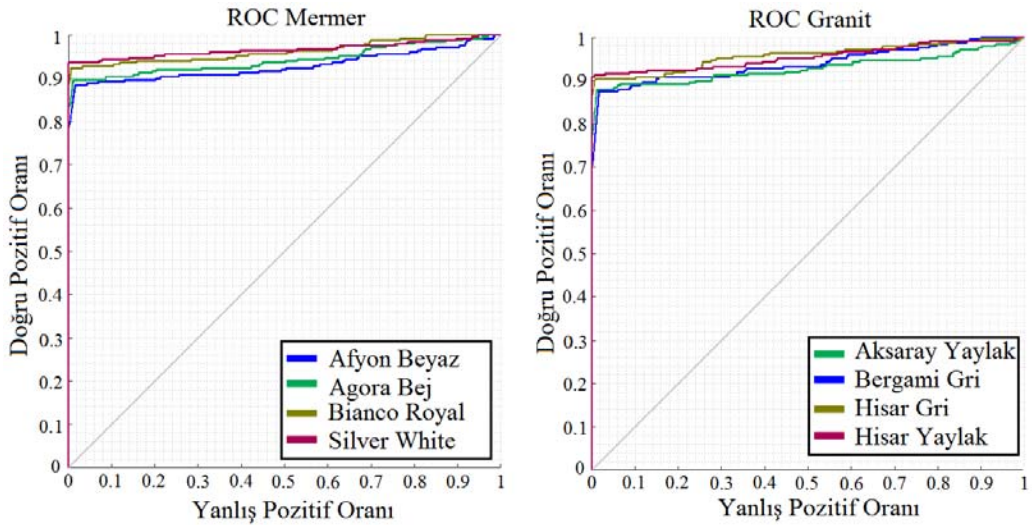
Veri Artırma Yöntemi	Başarı Oranı	Başarı Artışı	Hata Oranı
Orijinal Veri (OV)	86,70	-	13,3
Orijinal Veri+Döndürme (OV+D)	94,15	7,45	7,85
Orijinal Veri+Döndürme+Gri Gölge Ekleme (OV+D+GGE)	95,60	1,45	5,70
Orijinal Veri+Döndürme+Gri Gölge Ekleme+Gürültü Ekleme (OV+D+GGE+GE)	97,40	1,80	2,60



**Şekil 13.** Doğal Taş Blok Sayısı-Ağ Başarısı (Number of natural stone blocks-Network Accuracy)

**Tablo 13.** Sınıflandırma metrikleri (Classification metrics)

Metrik	Oran (%)	Metrik	Oran (%)
Doğruluk	97,4	Geri Çağırma	97,81
Kesinlik	97,4	F1 Ölçütü	97,48



**Şekil 14.** ROC Eğrisi (ROC Curve)

Deneyleerde, ağların katman sayısının ve ağ derinliğinin sınıflandırma üzerindeki etkisi incelenmiş, katman sayısının ve derinliğinin başarı oranı ile doğru orantılı olduğu gözlenmiştir. Tablo 15'te üçüncü veri setinde eğitim verisi oranı %70 olduğunda tüm ağların Katman-Derinlik-Başarı tablosu verilmiştir. Şekil 15 ve Şekil 16'da katman sayısı ve derinliği fazla olan ağlar soldan sağa doğru sıralanırken ağ

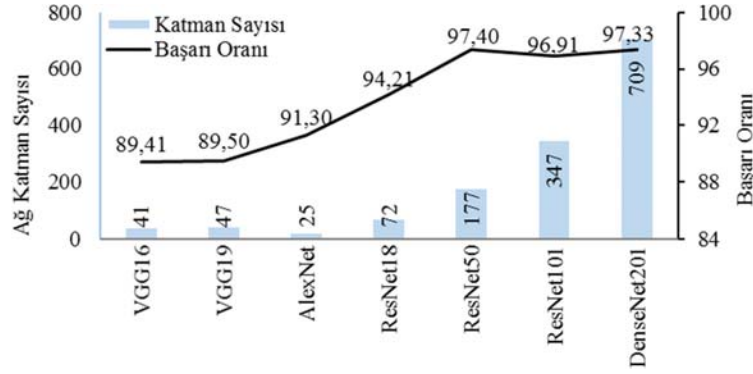
başarı oranı da ağların büyük bir bölümünde aynı şekilde soldan sağa doğru artış göstermektedir. Eğitimlerde elde edilen diğer bir sonuç; parametre sayısı az olan ağların bu çalışmadaki gibi özel problemlere uygulandığında ağ performanslarının parametre sayısı fazla olan ağlara göre daha iyi olduğudur. Söz konusu bu durumu yansıtan sonuçlar Şekil 17'de verilmiştir.

**Tablo 14.** Mermer ve Granit sınıflandırma başarı oranları (Marble and Granite classification accuracy rates)

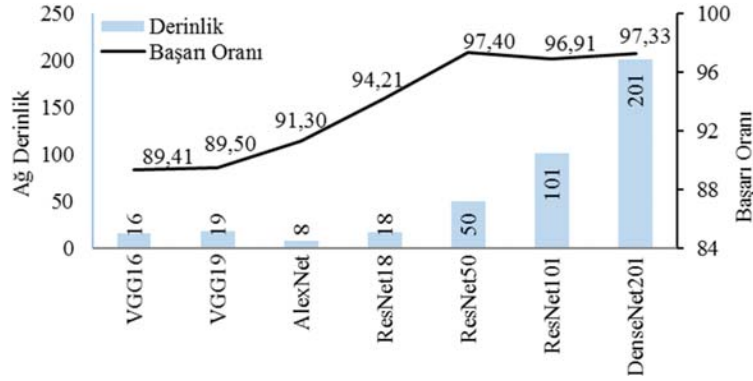
Mermer ve Granit	Ağ Baş.	Mermer ve Granit	Ağ Baş.	Mermer ve Granit	Ağ Baş.
Adıyaman Dark Emperador	94,84	Ege Kahve	99,40	Silver White	93,45
Adranos Beyaz	98,61	Elaziğ Vişne	99,60	Sivrihisar Bej	93,85
Adranos Siyah	99,60	Elmalı Bej	96,83	Siyah Emperador	99,21
Afrodit	99,01	Emperador Dark	95,44	Sofita Bej	98,41
Afyon Beyaz	87,90	Emperador Light	98,41	Söğüt Altın	99,40
Afyon Beyaz Arcoboleno	93,85	Fildişi Bej	95,04	Söğüt Bej	99,21
Afyon Gri	98,61	Golden Brown	99,21	Süpren	99,40
Afyon Kaplan Postu	95,83	Gri Emperador	98,81	Tobacco Gold	99,60
Afyon Menekşe	98,81	Harmankaya Bej	98,61	Toros Bej	99,01
Afyon Şeker	99,21	Hazar Pembe	99,01	Toros Gül	99,80
Agora Bej	88,49	Karacabey Siyah	99,40	Toros Siyah	98,81
Akşehir Siyah	100,0	Kastamonu-Eflani Bej	98,61	Tundra Blue	99,40
Alexander Black	99,40	Kayseri Kamelyon	100,0	Tundra Gri	98,41
Bartın Bej	98,61	Konya Beyşehir Emperador	99,60	Uşak Beyaz	98,21
Bianco Royal	92,46	Kumru Tüyü	99,01	Uşak Sarı	99,21
Bilecik Gül Kurusu	93,85	Leopar (Salome)	98,81	Uşak Yeşil	100,0
Bilecik Pembe	95,83	Manyas Beyaz	98,81	Vanillia Ice	95,83
Burdur Badem	87,90	Marino Grey	93,25	Vanillia Mocha	99,60
Burdur Bej	95,83	Marmara Beyaz	99,60	Vize Pembe	98,61
Burdur Kahverengi	99,60	Maroon Marinace	99,01	Yeşilli Beyaz Muğla	99,80
Bursa Açık Bej	99,21	Metalicus Elaziğ	99,21	Aksaray Sipahi	98,81
Bursa Koyu Bej	93,06	Milas Kavaklıdere	100,0	Aksaray Yaylak	87,70
Bursa Light Emperador	99,01	Milas Limon	99,21	Ankara Füme	100,0
Cappuccino Bej	91,47	Muğla Beyaz	98,41	Balaban Green	99,21
Çubuklu Marmara	99,60	Mustafa Kemalpaşa Beyaz	99,80	Bergama Gri	87,70
Denizli Pembe	99,40	Olive Maroon	97,42	Bulancağ Füme	99,01
Diana Bej	94,84	Onyx Adıyaman	100,0	Crema Imperial	90,67
Diana Rose	99,01	Picasso Denizli	99,21	Crema Lal	89,68
Dinar Bej	98,81	Rosa Bellissimo	98,81	Ezine	99,60
Diyarbakır Bej	90,67	Rosalia	99,80	Giresun Vizon	99,21
Diyarbakır Pembe	98,41	Salome	99,60	Hisar Gri	90,48
Dolomit	98,81	Savana Gri	98,81	Hisar Yaylak	90,67
Ege Bej	99,40	Silver Grey Isparta	97,62	Nero Nebiyan	100,0
Ege Bordo	100,0	Silver Marmara	99,21	Verde Kiwi	99,40

**Tablo 15.** Katman-Derinlik-Ağ Başarı (Layer-Depth- Network Accuracy)

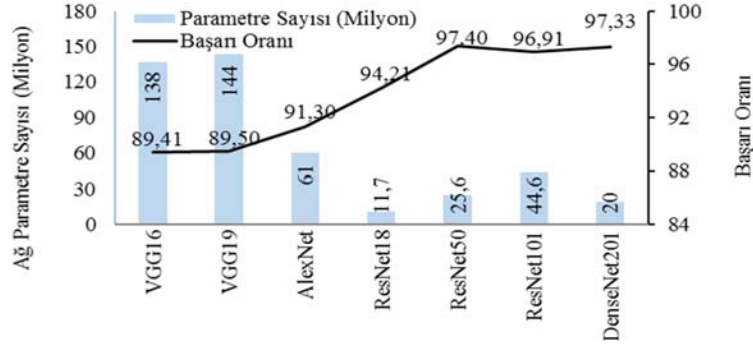
Ağ Modelleri	Katman	Derinlik	Parametre Sayısı (Mil.)	Başarı
VGG16	41	16	138	89,41
VGG19	47	19	144	89,50
AlexNet	25	8	61	91,30
ResNet18	72	18	11,7	94,21
ResNet50	177	50	25,6	97,40
ResNet101	347	101	44,6	96,91
DenseNet201	709	201	20	97,33



Şekil 15. Katman Sayısı- Ağ Başarı (Number Layers-Network Accuracy)



Şekil 16. Derinlik- Ağ Başarı (Depth-Network Accuracy)



Şekil 17. Parametre Sayısı-Ağ Başarı Oranı (Number Of Parameters- Network Accuracy)

Tablo 16. Literatür karşılaştırma tablosu (Literature comparison chart)

Yapılan Çalışmalar	Kullanılan Yöntemler	Taş Say.	Gör. Say.	Baş. Ora. (%)
Juan ve diğ.,	Öğrenmeli Vektör Kuantalama	1	44	81,8 - 90
Alajarin ve diğ.,	Yapay Sinir Ağları	1	75	98,9
Selver ve diğ.,	Yapay Sinir Ağları, HRBFN	1	1158	96,8- 99,4
Topalova ve Tzokev	Yapay Sinir Ağları	6	100	87 - 96
Ferreira ve Giraldi	Evrişimli Sinir Ağları	25	1000	87,26
Kaynar ve diğ.,	Yapay Sinir Ağları, SVM ve Naïve Bayes	6	996	80,7
Torun ve diğ.,	Evrişimli Sinir Ağları ve LBP+SVM	3	600	99,2 - 99,8
Pençe ve Çeşmeli	Evrişimli Sinir Ağları	1	80	75
Ather ve diğ.,	Evrişimli Sinir Ağları	25	2000	99,3
Karaali ve Eminağaoğlu	Evrişimli Sinir Ağları	6	6300	96,1
Canayaz ve Uludağ	Evrişimli Sinir Ağları	28	5600	97
Çalışma	Evrişimli Sinir Ağları (88 Mermer + 14 Granit =102)	102	24480	%97,4

Literatür incelendiğinde bu çalışma Türkiye'deki mermer ve granit çeşitlerinin büyük bir bölümünü içermesi açısından önemlidir. Bunun yanı sıra Tablo 16'da görüleceği gibi doğal taş çeşidi, görüntü sayısı ve başarı oranı olarak gerek Türkiye'deki gerekse diğer doğal çeşidini inceleyen çalışmalar ile karşılaştırıldığında kayda değer bir başarı göstermiştir. Özellikle çeşit-başarı ilişkisi dikkate alındığında tatmin edici sonuçlar elde edilmiştir.

#### 4. SONUÇLAR (CONCLUSIONS)

Bu çalışma elde edilen sonuçlar; probleme, veriye ve ağa uygun transfer öğrenmesi yöntemi seçildiğinde önceden eğitilmiş ağların bu ve benzeri problemlerin çözümlerine katacakları yararları göstermesi açısından önemlidir. Toplanan verilerle ileriye dönük iyi bir çözüm olduğunu ispatlayan bu görsel tür sınıflandırması; mermer ve granitlerin sınıflandırılmasındaki zorluğa çözüm getirmesi açısından sektör çalışanları ve müşterileri için yararlı bir çözüm önerisidir. Bu çalışmanın diğer bir amacı, benzer çalışmalarda ve sektörde kullanılacak bir veri seti hazırlamaktır. Oluşturulan veri setinin ağ eğitiminde gösterdiği başarı kullanılabilirliğinin ve geliştirilmeye açık olduğunun göstergesidir.

Çalışmada en büyük başarı oranı mermer ve granitin en çok bilinen renk ve desenini yansıtan görüntülerden oluşan birinci veri setinde %98,33 ile gerçekleşmiştir. Fakat verilerin toplanması aşamasında aynı veya farklı taş ocaklarından çıkarılan blokların renk tonunun değiştiği, desenlerin ise taşın doğası gereği taş bloğunun her yerinde aynı olmadığı hatta taş bloğunun bazı bölgeleri ideal desende çok farklı desenlerin olduğu gözlemlenmiştir. Blokların plakaya dönüştürülmesi veya plakaların daha küçük parçalara ayrıldığı aşamada söz konusu durumlar dahada belirgin hale gelmiştir. Bunun yanı sıra depolama ve fotoğraflama şartlarının çekilen görüntüyü etkilediği diğer bir gözlemdir. Tüm bu sorunları veri setine yansıtmanın ağların güvenilirliği ve doğruluğu açısından doğru bir yaklaşım olacağı sonucuna varılmıştır. Böylece depolama ve fotoğraflama şartlarından elde edilen görüntüler veri setine eklenmiş ayrıca plaka başına çok sayıda görüntü elde etmek yerine çok sayıda plakadan veri toplanmıştır. En çok bilinen renk ve deseni yansıtan görüntülerle oluşturulan veri seti ile eğitilen ağların ideal olmayan görüntülerle karşılaştığında sınıflandırma başarı oranının çok düştüğü çalışma esnasında test edilerek görülmüştür. Görüntülenen plaka sayısına paralel olarak artırılan ideal ve ideal olmayan görüntülerin birinci veri setine eklenmesiyle oluşturulan ikinci veri setiyle eğitilen ağların başarısı başlangıçta belirgin bir düşüş göstermiştir. Fakat aynı yöntemle görüntü sayısı artırılarak oluşturulan üçüncü veri setiyle eğitilen ağların başarı oranı belirgin bir artış göstermiştir. Başarı oranını daha da artırmak için üç farklı veri artırma yöntemi kullanılmış özellikler iki veri artırma yöntemi ideal olmayan görüntüleri temsil edecek şekilde seçilmiştir. Veri artırma yöntemi ağ başarısını 10,7 artırmıştır. Ağların eğitilmesinde ve doğrulanmasında kullanılan veri setlerini rastgele seçmek yerine literatürde başarısını kanıtlamış iki iki eğitim ve doğrulama yöntemi kullanılmıştır. Böylece veri setini doğru temsil eden eğitim

ve doğrulama veri setleri elde edilmiştir. Kullanılan tüm bu yöntemlerin sonucunda üçüncü veri setinde %97,4 başarı oranı elde edilmiştir.

Çalışmada kullanılan ağların katman sayısı ve derinliği arttıkça ağ başarı oranı artmıştır. Ağ parametre sayısı arttıkça ise başarı oranının düştüğü gözlenmiştir. Veri boyutunun ağ parametre sayısına göre çok küçük kalması bu sonucu doğurmuştur. İlerleyen süreçlerde gerçekleştirilecek proje kapsamında görüntü sayısı ve doğal taş çeşidi artırıldıkça bu sorunda ortadan kalkacaktır. Fakat mermer ve granit çeşidi sayısı arttıkça desen ve renk benzerliğinden dolayı başarı oranının düşeceği öngörülmektedir. Yüksek performans gösteren ağ mimarileri ve çalışma esnasında kazanılan tecrübeler yeni proje kapsamında probleme özgü ağ tasarımının referans alınacaktır. Ağ girişini yüksek çözünürlükte görüntü alabilecek şekilde tasarlamak başarı oranındaki sorunun çözümü için iyi bir yaklaşım olacaktır. Yeni projede tasarım ve eğitim süreci Python programlama dili ile gerçekleştirilecektir. Proje tamamlandığında uygulamanın kullanımı için bir Web sayfası oluşturulacak, kullanıcılar Web sayfasına yükledikleri görüntüden mermer veya granit çeşidini öğrenebilecektir. Ayrıca kullanıcıların onay vermesi durumunda kullandıkları görüntü veri setine eklenecek ve veri seti herkese açık hale getirilecektir.

#### KAYNAKLAR (REFERENCES)

1. Arıkan M., Türkiye'de Mermercilik, Bilimsel Madencilik Dergisi, 2 (7), 463-468, 1962.
2. Delta Mermer. Geçmişten günümüze mermer. <https://www.deltamarble.com/tr/gecmisten-gunumuze-mermer/>. Yayın tarihi 2020. Erişim tarihi Kasım 29, 2020.
3. MTA Genel Müdürlüğü Fizibilite Etütleri Daire Başkanlığı. Madencilik Sektörüne Ait Temel Ekonomik Göstergeler. <https://www.mta.gov.tr/v3.0/sayfalar/bilgi-merkezi/maden-serisi/img/TEG2019.pdf>. Yayın tarihi 2019. Erişim tarihi Kasım 29, 2020.
4. İstanbul Maden İhracatçılar Birliği. 2020 Yılı Aylık Bazda Maden İhracat Verileri. <https://www.imib.org.tr/tr/raporlar/ihracat-istatistikleri>. Yayın tarihi 2020. Erişim tarihi Kasım 29, 2020.
5. Juan M.C.V.A., Balibrea T., Manuel L., Marble Slabs Quality Classification System using Texture Recognition and Neural Networks Methodology, European Symposium on Artificial Neural Networks, Bruges, 75-80, 1999.
6. Alajarín J. M., Delgado J. D. L., Balibrea L. M. T., Automatic system for quality-based classification of marble textures, IEEE Transactions on Systems Man Cybernetics-Part C: Applications and Reviews, 35 (4), 488-497, 2005.
7. Selver M. A., Akay O., Ardalı E., Yavuz A. B., Önal O., Özden G., Cascaded and hierarchical neural networks for classifying surface images of marble slabs, IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), 39 (4), 426-439, 2009.
8. Topalova I.C., Tzokev A., Adaptive marble plate classification system based on neural network and PLC



- Implementation, Proceedings of the 22nd International DAAAM Symposium, Intelligent Manufacturing & Automation', Vienna, 22 (1), 453-454, 2011
9. Ferreira A., Girald G., Convolutional Neural Network approaches to granite tiles classification, *Expert Systems With Applications*, 84, 1-11, 2017.
  10. Kaynar O., Torun Y., Temiz M., Görmez Y., Automatic Classification of Natural Stone Tiles with Computer Vision, 3rd International Conference on Computer Science and Engineering (UBMK), Saraybosna, 527-532, 2018.
  11. Torun Y., Akbaş M.R., Çelik M.A., Kaynar O., Mermer Sınıflandırılması İçin Makineli Görü Sistem Geliştirilmesi, 2019 27th Signal Processing and Communications Applications Conference (SIU), Sivas, 5112520, 2019.
  12. Pençe İ., Çeşmeli M. Ş., Deep Learning in Marble Slabs Classification, *Techno-Science*, 2 (1), 21-26, 2019.
  13. Ather M., Khan B., Wang Z., Song G., Automatic Recognition and Classification of Granite Tiles Using Convolutional Neural Networks (CNN), ICAAI 2019: Proceedings of the 2019 3rd International Conference on Advances in Artificial Intelligence, Northumbria University, İstanbul, 193-197, 2019.
  14. Karaali İ., Eminağaoğlu M., A convolutional neural network model for marble quality classification, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 347-357, 2021.
  15. Canayaz M., Uludağ F., Marble Classification Using Deep Neural Networks, *European Journal of Technique (EJT)*, 10 (1), 52-63, 2020.
  16. Arı A., Hanbay D., Tumor detection in MR images of regional convolutional neural networks, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (3), 1395-1408, 2019.
  17. Dandil E., Polattimur R., Dog Behavior Recognition and Tracking based on Faster R-CNN, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (2), 819-834, 2020.
  18. Yıldız O., Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 2241-2260, 2019.
  19. Bingöl K., Akan A.E., Örmecioğlu H.T., Er A., Artificial intelligence applications in earthquake resistant architectural design: Determination of irregular structural systems with deep learning and ImageAI method, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (4), 2197-2209, 2020.
  20. Aktaş A., Doğan B., Demir Ö., Tactile paving surface detection with deep learning methods, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35 (3), 1685-1700, 2020.
  21. Lawrence S., Giles C.L., Tsoi A.C., Back A.D., Face recognition: A convolutional neural-network approach, *IEEE Transactions on Neural Networks*, 8 (1), 98-113, 1997.
  22. MathWorks. Introduction to convolutional neural networks. <https://www.mathworks.com/help/deeplearning/ug/introduction-to-convolutional-neural-networks.html>. Yayın tarihi 2019. Erişim tarihi Kasım 26, 2019.
  23. Baykal E., Dogan H., Ercin M.E., Ersoz S., Ekinci M., Transfer learning with pre-trained deep convolutional neural networks for serous cell classification, *Multimedia Tools and Applications*, 1-19, 2019.
  24. Nebauer, C., Evaluation of convolutional neural networks for visual recognition, *IEEE Transactions on Neural Networks*, 9 (4), 685-696, 1998.
  25. Zhou Y., Nejadi H., Do T.T., Cheung N.M., Cheah L., Image-based vehicle analysis using deep neural network: A systematic study, *IEEE international conference on digital signal processing*, Beijing, 276-280. 2016.
  26. He K., Zhang X., Ren S., Sun J., Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Las Vegas, 770-778, 2016.
  27. Ye H., Han H., Zhu L., Duan Q., Vegetable pest image recognition method based on improved VGG convolution neural network, *Journal of Physics: Conference Series*, Xi'an, 1237 (3), 2019
  28. Theckedath D., Sedamkar R.R., Detecting Affect States Using VGG16, ResNet50 and SE-ResNet50 Networks, *Springer Nature Computer Science*, 79, 1-7, 2020.
  29. Pan S.J., Yang Q., A survey on transfer learning, *IEEE Transactions on Knowledge and Data Engineering*, 22 (10), 1345-1359, 2010.
  30. Chollet F. *Deep Learning with Python*, Manning Publications, New York, 2017.
  31. Kaggle. Stratified Shuffle Split Working with less data. <https://www.kaggle.com/viswanathanc/stratifiedshuffle-split-working-with-less-data>. Yayın tarihi 2019. Erişim tarihi Ekim 12, 2020.
  32. Medium, StratifiedKFold v.s KFold v.s, <https://xzz201920.medium.com/stratifiedkfold-v-s-kfold-v-s-stratifiedshufflesplit-ffcae5bfdf>. Erişim tarihi Ekim 12, 2020.
  33. Github, Cross-Validation: Why and how to do it, <https://srikarvaka.github.io/model-evaluation/Cross-validation/>. Yayın tarihi Ocak 29, 2019. Erişim tarihi Ekim 12, 2020
  34. Amidi A., Stanford University CS-229 Cheatsheet-machine-learning-tips-and-tricks, <https://stanford.edu/~shervine/1/tr/teaching/cs-229/cheatsheet-machine-learning-tips-and-tricks>. Yayın tarihi Mayıs 1, 2019. Erişim tarihi Temmuz 18, 2021.
  35. Özbay E., Çınar A., A Comparative Study of Object Classification Methods Using 3D Zernike Moment on 3D Point Clouds, *Traitement du Signal*, 36 (6), 549-555, 2019.
  36. Mash R., Borghetti B., Pecarina J., Improved Aircraft Recognition for Aerial Refueling through Data Augmentation in Convolutional Neural Networks, 12th International Symposium on Visual Computing Advances in Visual Computing, Las Vegas, 12, 113-122, 2016.

