

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĐİ DOKTORA PROGRAMI**

**BİR ÖRNEKLE ÖĐRENME YAKLAŐIMI KULLANILARAK ÇATI TİPİ
SINIFLANDIRMASI**

HAZIRLAYAN

NAİM ÖLÇER

DOKTORA TEZİ

ANKARA – 2023

**BAŐKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĐİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĐİ DOKTORA PROGRAMI**

**BİR ÖRNEKLE ÖĐRENME YAKLAŐIMI KULLANILARAK ÇATI TİPİ
SINIFLANDIRMASI**

HAZIRLAYAN

NAİM ÖLÇER

DOKTORA TEZİ

**TEZ DANIŐMANI
DOÇ. DR. EMRE SÜMER**

ANKARA – 2023

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Bilgisayar Mühendisliği Anabilim Dalı Bilgisayar Mühendisliği Doktora Programı çerçevesinde Naim Ölçer tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Doktora Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 06 / 02 / 2023

Tez Adı: Bir Örnekle Öğrenme Yaklaşımı Kullanılarak Çatı Tipi Sınıflandırması

Tez Jüri Üyeleri

İmza

Prof. Dr. Mehmet Reşit TOLUN, Çankaya Üniversitesi

.....

Doç. Dr. Emre SÜMER, Başkent Üniversitesi

.....

Prof. Dr. Ali Özgün OK, Hacettepe Üniversitesi

.....

Prof. Dr. Hamit ERDEM, Başkent Üniversitesi

.....

Dr. Öğr. Üyesi Çağatay Berke ERDAŞ, Başkent Üniversitesi

.....

ONAY

Prof. Dr. Faruk ELALDI
Fen Bilimleri Enstitüsü Müdürü
Tarih : ... / ... /

BAŞKENT ÜNİVERSİTESİ FEN BİLİMLER ENSTİTÜSÜ
DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: 06 / 02 / 2023

Öğrencinin Adı, Soyadı: Naim Ölçer

Öğrencinin Numarası: 21310026

Anabilim Dalı: Bilgisayar Mühendisliği Anabilim Dalı

Programı: Bilgisayar Mühendisliği Doktora Programı

Danışmanın Unvanı/Adı, Soyadı: Doç. Dr. Emre Sümer

Tez Başlığı: Bir Örnekle Öğrenme Yaklaşımı Kullanılarak Çatı Tipi Sınıflandırması

Yukarıda başlığı belirtilen Doktora tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 54 sayfalık kısmına ilişkin, 05 / 02 / 2023 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı %5'tir. Uygulanan filtrelemeler:

- 1. Kaynakça hariç**
- 2. Alıntılar hariç**
- 3. Beş (5) kelimedenden daha az örtüşme içeren metin kısımları hariç**

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:.....

ONAY

Tarih: 06 / 02 / 2023

Doç. Dr. Emre Sümer

TEŞEKKÜR

Yazar, bu çalışmanın gerçekleşmesinde katkılarından dolayı, aşağıda adı geçen kişi ve kuruluşlara içtenlikle teşekkür eder.

Sayın Doç. Dr. Emre SÜMER (tez danışmanı), konu seçiminden çalışmanın sonuca ulaştırılmasına kadar, karşılaşılan tüm güçlüklerin aşılmasında her zaman yardımcı ve yol gösterici olduğu için...

Tez komitemin değerli üyeleri olan Prof. Dr. Hamit ERDEM'e ve Prof. Dr. Ali Özgün OK'a tez çalışmam esnasında destekleri ve yol gösterici oldukları için...

Danışmanımın yanı sıra tez inceleme komitesi üyeleri Prof. Dr. Mehmet Reşit TOLUN'a ve Dr. Öğr. Üyesi Çağatay Berke ERDAŞ'a katkıları için...

Katkılarından dolayı Enver TOKMAK'a ...

Sevgili eşim Dr. Didem ÖLÇER'e ve kızım Beril'e destek ve yardımlarından dolayı...

ÖZET

Naim Ölçer

BİR ÖRNEKLE ÖĞRENME YAKLAŞIMI KULLANILARAK ÇATI TİPİ SINIFLANDIRMASI

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

2023

Son zamanlarda, Evrişimsel Sinir Ağları tabanlı metotlar uzaydan çekilmiş görüntüler üzerinde çatı tipi sınıflandırması yapmak için sıkça kullanılmaktadır. Bu metotlar ile yapılan sınıflandırma işlemlerinde en önemli sorun ilgili metotların çok fazla sayıda eğitim verisine ihtiyaç duymasıdır. İnsanların bir nesneyi tanınması için genelde bir veya birkaç örnek yeterlidir. Bir örnekle öğrenme yaklaşımı da aynı insan beyni gibi yalnızca bir veya birkaç eğitim örneğinden nesne kategorileri hakkında bilgi edinmeyi amaçlamaktadır. Bu metot, çok büyük miktarda veri kullanmak yerine her bir sınıf için yalnızca birkaç adet örnek kullanılarak öğrenme sağlayan bir yaklaşımdır. Bu çalışmada, Siyam Sinir Ağları modelini temel alan bir örnekle öğrenme yaklaşımı kullanılarak eğitim için az sayıda örnek ile çatı tipi sınıflandırması yapılmıştır. Eğitim için kullanılan resimler çatı verisi bulma zorluğu nedeniyle yapay olarak üretilmiştir. Test için de gerçek çatı resimlerinden oluşan iki farklı veri kümesi kullanılmıştır. Test ve eğitim veri kümeleri Teras (Flat), Beşik (Gable) ve Kırma (Hip) olmak üzere 3 farklı çatı tipinden oluşmaktadır. Yapay olarak üretilen resimlerle eğitilen Siyam Sinir Ağı modelinin ilk veri kümesine ait çatı resimleri ile test edilmesi sonucunda ortalama %66'lık bir sınıflandırma başarımı sağlanırken ikinci veri kümesi ile bu oran %85 olarak hesaplanmıştır. Aynı veriler Evrişimsel Sinir Ağları ve Destek Vektör Makineleri ile de test edilmiş, en yüksek başarımın Siyam Sinir Ağı modeli ile elde edildiği görülmüştür.

ANAHTAR KELİMELELER: Evrişimsel Sinir Ağları (CNN), Bir Örnekle Öğrenme (OSL), Siyam Sinir Ağları (SNN), Çatı Tipi, Makine Öğrenme.

ABSTRACT

Naim Ölçer

ROOF TYPE CLASSIFICATION USING ONE-SHOT LEARNING APPROACH

Başkent University Institution of Science and Engineering

Department of Computer Engineering

2023

Recently, Convolutional Neural Network-based methods have been used frequently for roof-type classification on images taken from space. The most important problem with classification processes using these methods is that they require a large amount of training data. Usually, one or a few samples are enough for a human to recognise an object. Like the human brain, the One-Shot Learning approach aims to learn object categories with just one or a few training examples per class, rather than using huge amounts of data. In this study, roof-type classification was carried out with a few training examples using the one-time learning approach and the so-called Siamese Neural Network method. The images used for training were artificially produced due to the difficulty of finding roof data. Two different data sets consisting of real roof pictures were used for the test. The test and training data set consisted of three different roof types: Flat, Gable and Hip. Finally, the Siamese Neural Network model, which was trained with artificially produced pictures, achieved an average classification performance of 66% as a result of testing with real roof pictures. With the other data set prepared, a classification success of 85% was achieved. The same data were also tested with Convolutional Neural Networks and Support Vector Machines, and it was found that the highest success was achieved with the Siamese Neural Network model.

KEYWORDS: Convolutional Neural Network (CNN), One-Shot Learning (OSL), Siamese Neural Network (SNN), Roof Type, Machine Learning.

İÇİNDEKİLER

| | Sayfa |
|--|-------|
| TEŞEKKÜR..... | i |
| ÖZET | ii |
| ABSTRACT | iii |
| İÇİNDEKİLER..... | iv |
| TABLolar LİSTESİ | vi |
| ŞEKİLLER LİSTESİ | vii |
| SİMGELER VE KISALTMALAR LİSTESİ | viii |
| 1. GİRİŞ..... | 1 |
| 1.1. Tez Çalışmasının Genel Katkıları | 3 |
| 1.2. Tez Planı | 4 |
| 2. ALAN BİLGİSİ VE LİTERATÜR..... | 5 |
| 2.1. Çatı Tipleri | 5 |
| 2.2. Literatür İncelemesi | 8 |
| 3. KULLANILAN YÖNTEM VE METOTLAR..... | 12 |
| 3.1. Destek Vektör Makinesi (SVM) | 12 |
| 3.2. Evrişimsel Sinir Ağları (CNN)..... | 14 |
| 3.3. Bir Örnekle Öğrenme (OSL) ve Siyam Sinir Ağları (SNN)..... | 18 |
| 3.4. Önerilen Yöntem..... | 22 |
| 4. VERİ KÜMELERİ | 25 |
| 4.1. Yapay Çatı Resimleri | 25 |
| 4.2. Veri Kümesi 1..... | 25 |
| 4.3. Veri Kümesi 2..... | 28 |
| 5. DENEYSEL SONUÇLAR | 31 |
| 5.1 Deneysel Kurulum..... | 31 |
| 5.2. Başarı Ölçütleri | 33 |
| 5.3. Büyük Boyutlu Veri Kümesi Karşılaştırması – CNN, SVM, SNN..... | 34 |
| 5.4. Küçük Boyutlu Veri Kümesi Karşılaştırması – CNN, SVM, SNN..... | 37 |
| 5.5. Yapay Veri Kümesi ile Eğitilen Modelin Veri Kümeleri ile Test Edilmesi ve Sonuçları | 39 |

6. SONUÇ..... 45

KAYNAKLAR..... 47

EKLER

EK 1: Tez Çalışması Kapsamında Yayımlanan Makalenin Künye Bilgileri

EK 2: Kappa Değerleri İçin Yorumlama Tablosu

TABLULAR LİSTESİ

Sayfa

| | |
|--|----|
| Tablo 5.1. Sınıflandırma Örnekleri | 32 |
| Tablo 5.2. SNN, CNN ve SVM için Büyük Boyutlu Veri Kümesi Sonuçlarının Karşılaştırması | 36 |
| Tablo 5.3. SNN, CNN ve SVM için Küçük Boyutlu Veri Kümesi Sonuçlarının Karşılaştırma | 39 |
| Tablo 5.4. Yapay Resim Veri Kümesi Karşılaştırması | 40 |
| Tablo 5.5. Veri Kümesi 1 - Test 10 için Hata Matrisi..... | 41 |
| Tablo 5.6. Veri Kümesi 1 - Test 10 için Performans Değerleri | 42 |
| Tablo 5.7. Veri Kümesi 2 – Test 1 için Hata Matrisi | 43 |
| Tablo 5.8. Veri Kümesi 2 – Test 1 için Performans Değerleri..... | 44 |

ŞEKİLLER LİSTESİ

Sayfa

| | |
|--|----|
| Şekil 2.1. Çatı Tipleri Farklı Örnek a) Teras b) Beşik c) Kırma..... | 6 |
| Şekil 2.2. Teras Çatı Tipi Örnekleri | 7 |
| Şekil 2.3. Beşik Çatı Tipi Örnekleri | 7 |
| Şekil 2.4. Kırma Çatı Tipi Örnekleri | 8 |
| Şekil 3.1. SVM Hiper Düzlem Örneği | 13 |
| Şekil 3.2. Basit Bir Evrişimsel Sinir Ağı Mimarisi..... | 16 |
| Şekil 3.3. Örnek DenseNet Mimarisi..... | 17 |
| Şekil 3.4. DenseNet Mimarisi | 17 |
| Şekil 3.5. Bir Örnekle Öğrenme (OSL) Yaklaşımı | 19 |
| Şekil 3.6. Siyam Sinir Ağları Yaklaşımı | 19 |
| Şekil 3.7. Siyam Sinir Ağları Benzerlik Hesaplama Yaklaşımı..... | 20 |
| Şekil 3.8. Siyam Sinir Ağlarının Yapısı | 21 |
| Şekil 3.9. Eğitim Aşamasının Adımları..... | 23 |
| Şekil 3.10. Test Aşamasının Adımları..... | 24 |
| Şekil 4.1. Yapay Olarak Üretilen Veri Kümesi Örnekleri a) Teras b) Beşik c) Kırma..... | 25 |
| Şekil 4.2. Veri Kümesi 1-Teras Çatı Tipi Test Örnekleri..... | 26 |
| Şekil 4.3. Veri Kümesi 1-Beşik Çatı Tipi Test Örnekleri | 27 |
| Şekil 4.4. Veri Kümesi 1-Kırma Çatı Tipi Test Örnekleri..... | 27 |
| Şekil 4.5. Çatı Verisi Toplama Uygulaması Ekran Örneği | 28 |
| Şekil 4.6. Veri Kümesi 2- Teras Çatı Tipi Test Örnekleri | 29 |
| Şekil 4.7. Veri Kümesi 2- Beşik Çatı Tipi Test Örnekleri | 29 |
| Şekil 4.8. Veri Kümesi 2- Kırma Çatı Tipi Test Örnekleri | 30 |
| Şekil 5.1. İterasyon – Eğitim Kayıp Grafiği..... | 32 |

SİMGELER VE KISALTMALAR LİSTESİ

| | |
|-------|-------------------------------|
| 2B | İki Boyutlu |
| 3B | Üç Boyutlu |
| CNN | Evrişimsel Sinir Ağları |
| SVM | Destek Vektör Makinesi |
| CBS | Coğrafi Bilgi Sistemleri |
| OSL | Bir Örnekle Öğrenme |
| SNN | Siyam Sinir Ağları |
| RGB | Kırmızı, Yeşil, Mavi |
| LIDAR | Işın Algılama ve Mesafe Ölçme |
| RBF | Çapsal Tabanlı Fonksiyon |

1. GİRİŞ

Uzaydan veya havadan çekilen görüntüler dünya yüzeyi hakkında önemli ölçüde bilgi sağlamaktadır. Bu bilgilerden bazıları; binalar, arazi kullanım alanları ve farklı arazi örtüleri hakkında olabilmektedir. Binalar kentsel yaşamın en belirgin yapılarıdır. Binaların 2B ayak izlerinin veya 3B modellerinin hesaplanması veya bilinmesi; arazi yönetimi, iklim değişikliği izleme, afet yönetimi, ekolojik çalışmalar, kentleşme ve kaynak yönetiminin yapılması gibi işlemlere ek olarak [1] Coğrafi Bilgi Sistemleri için de temel bir veri kaynağı oluşturma, harita oluşturma, şehir planlama, altyapı iyileştirmelerinde önemli bir role sahiptir. Binaların belirlenmesinde önemli bir veri kaynağı olan uydu görüntüleri, yüksek konumsal çözünürlüğe sahip olmakla birlikte kalıcılık ve geniş spektral çözünürlük gibi özellikleriyle de birçok çalışmada sıkça kullanılmaktadır.

Çatı, bir yapı modelindeki en önemli unsurlardan biridir. Çatı, estetik değerlerinin yanı sıra yağmur, rüzgâr, dolu, kar, yüksek sıcaklık ve soğuk gibi olumsuz hava şartlarına karşı koruma olarak da önemli bir rol oynamaktadır. Başlıca görevi yapının üzerini örtmek ve içinde bulunanların rahat ve güvenli bir ortamda yaşamasını sağlamaktır. Sık sık yağmur ya da kar yağın ortamlarda, yağmur suyunun ve karın verimli bir şekilde tahliye edilmesini sağlayan eğimli çatıların kullanılması en iyi çözümdür. Modern yapılardaki müstakil evlerde veya kamu binalarında teras çatılar çok sık rastlanan çatı tiplerinin başında gelmektedir. Teras çatıların en büyük avantajı, nispeten düşük inşaat maliyetinin yanı sıra temizlik veya onarım yapmak için kolay erişilebilir olmalarıdır. Çatı tipi, ayrıca bir binanın enerji verimliliğini de etkiler. Doğru çatı tasarımı ve malzemelerin kullanımı, binanın ısı kaybını azaltır ve enerji tasarrufu sağlar.

Çatı genellikle ahşap, metal, kiremit veya asfalt kiremitlerden yapılır. Çatının şekli genellikle evin bulunacağı iklim koşullarına göre tasarlanır. Ahşap bir çatı, yan yana dizilmiş ahşap kalaslardan yapılır. Plakalar genellikle asfalt zona veya metal levhalarla kaplanır. Ahşap çatılar daha çok Kuzey Amerika ve Avrupa'da yaygındır. Metal bir çatı, kirişlere çivilenmiş çelik, alüminyum veya bakır levhalardan yapılır. Metal çatılar dayanıklı olup endüstriyel binalarda ve depolarda yaygın olarak kullanılır. Kiremit çatı, kil veya beton kiremitlerden yapılır. Kiremit çatılar ağırdır ve güçlü bir destek yapısı gerektirir. Avrupa, Asya ve Orta Doğu'da yaygındırlar.

Asfalt kiremitleri asfalt kaplı kâğıt veya fiberglastan yapılıdır. Asfalt zona hafiftir ve montajı kolaydır. Kuzey Amerika'daki en yaygın çatı türüdür [2].

Çatı modeli, 3B modellemede bir bina için en önemli bileşenlerden biridir. Coğrafi bilgi sistemi uygulamaları, enerji verimliliği gibi çeşitli analizlerin 3B modeller üzerinde yapılabilmesi için genellikle çatı tipi ve çatı geometrisine ihtiyaç duyulur. Ayrıca, daha yüksek seviyelerdeki 3B şehir modelleri; güneş enerjisi potansiyeli tahmini, kalite değerlendirmesi ve mevcut verilerin doğrulanması, çatı rekonstrüksiyonu gibi 3B coğrafi bilgi sistemleri uygulamalarında kullanılabilecek çatı geometrilerini içerir. Geleneksel bölütleme ve sınıflandırma yöntemleri genellikle köşeler, kenarlar ve çizgi parçaları gibi özelliklere dayanır [3]. Aynı zamanda çatı modelleme için, bir dijital yüzey modelinden çıkarılan ayrıntılı çizgiler, köşeler ve düzlemler gibi ipuçlarına dayanırken, çatı tipinin doğru tespiti ve modellemesi, dijital yüzey modelinin düşük kalitesi nedeniyle başarısız olabilir [4].

Kentsel alanlarda fotovoltaik kurulumları yoluyla güneş enerjisi dağıtımı, büyük ölçüde mevcut çatıların şekline, boyutuna ve yönüne bağlıdır [5]. Ayrıca uydu görüntülerinden asbest içeren çatıların tespiti, insan sağlığı için bir risk anlamına gelen asbestin kapsamını ve durumunu tespit edebilen araçların geliştirilmesi bakımından büyük önceliğe sahiptir [6].

Ayrıca son zamanlarda, sürdürülebilir binalar için yeşil çatılar önerilmektedir. Yeşil çatılar, bina enerji tüketiminin azaltılması, kentsel ısı adası (urban heat island) etkisinin azaltılması [7-9] hava kirliliğinin iyileştirilmesi, hava ve su yönetimi [10], ses yalıtımının artırılması ve kentsel alanlarda biyolojik çeşitliliğin artırılması [11] ile ilgili konularda fayda sağlamaktadır.

Bu bağlamda, tezin ana odak noktası, binaların çatı tiplerinin az sayıda görüntü kullanılarak sınıflandırılması için yeni bir yöntem önererek yukardaki kullanım alanlarına katkı sunmaktır. Literatürde en yaygın olarak kullanılan çatı tipi sınıflandırma yöntemlerinden ikisi; derin öğrenme yaklaşımı olan Evrişimsel Sinir Ağları (CNN) ve klasik makine öğrenmesi yaklaşımı olan Destek Vektör Makinesidir (SVM)'dir. Ancak eğitim için özellikle CNN tabanlı yöntemlerde büyük miktarda veriye ihtiyaç duyulmaktadır. Bu nedenle bu tez ile, Bir Örnekle Öğrenme (OSL)

yaklaşımı sunularak öğrenme sürecini az sayıda veri örneği ile gerçekleştirmeyi amaçlamaktadır.

1.1. Tez Çalışmasının Genel Katkıları

Bu tez aşağıdaki araştırma sorularını cevaplamayı amaçlamaktadır:

1. Az sayıda veri ile bir çatı tipi sınıflandırma modeli eğitilebilir mi?
2. Veri kümesi bulma zorluğu olan durumlarda yapay olarak üretilmiş resimlerin kullanımı ile tatmin edici düzeyde bir sınıflandırma başarımı elde edilebilir mi?

Tez çalışmasının literatüre olan genel katkıları iki farklı açıdan değerlendirilebilir. Bunlardan ilki, öğrenme için çok fazla veriye ihtiyaç duymadan çatı tipi sınıflandırma modelini eğitmektir. Makine öğrenmesi ve derin öğrenme algoritmalarının en büyük problemi, öğrenme için büyük miktarda veriye ihtiyaç duymalarıdır. Bu çalışmada bir örnekle öğrenme yöntemi kullanılarak çok büyük miktarda veri kullanmak yerine her bir sınıf için yalnızca birer adet örnek ile öğrenme gerçekleştirilmiştir. Literatürdeki çatı tipi sınıflandırma işlemlerinin büyük bir çoğunluğu popüler bir derin öğrenme yaklaşımı olan CNN ve yine popüler bir klasik makine öğrenmesi yaklaşımı olan SVM ile gerçekleştirilmiştir. Çatı tipi sınıflandırma işlemlerinin bir örnekle öğrenme yaklaşımı kullanılarak yapıldığı herhangi bir çalışmaya literatürde rastlanmamıştır.

Tez çalışmasının bir diğer katkısı ise çatı veri kümesi bulma zorluğu sebebiyle eğitim için kullanılacak resimlerin yapay olarak üretilmesidir. Üretilen bu yapay resimler teras, beşik ve kırma olmak üzere 3 farklı çatı tipini temsil etmektedir. Model eğitimi için yapay olarak üretilen bu çatı resimleri kullanılmıştır. Model eğitimi aşamasında kullanılacak yapay verinin üretilmesi ve az sayıda veri ile eğitim gerçekleştirebilme yönleriyle bu çalışmanın literatüre özgün bir katkı sunduğu değerlendirilmektedir. Ayrıca test edilecek gerçek çatı veri kümesi bulma zorluğu nedeniyle yeni bir veri kümesinin bu çalışma kapsamında üretilmesi ve literatüre kazandırılması da sağlanacaktır. Bu veri kümesi California Eyaletinin San Diego şehrinin çatı resimlerinin çeşitli işlemlerden sonra kesilmesiyle elde edilmiştir.

1.2. Tez Planı

Bölüm 2, Alan Bilgisi ve Literatür başlığı altında, Destek Vektör Makinesi (SVM), Evrişimsel Sinir Ağları (CNN) ve Bir Örnekle Öğrenme (OSL) yöntemleri ile gerçekleştirilen çalışmaları inceleyerek literatür hakkında genel bir bakış açısı sunmaktadır. Ayrıca çalışmada kullanılan çatı tipleri hakkındaki temel bilgiler bu bölümde verilmektedir.

Bölüm 3, Destek Vektör Makinesi (SVM), Evrişimsel Sinir Ağları (CNN) ve bir CNN alt metodu olan DenseNet hakkında alan bilgileri ve geçmiş çalışmalara yer vermektedir. Bu bölümde ayrıca Bir Örnekle Öğrenme (OSL) yöntemi ve bu yöntemi gerçekleştirmek için kullanılan SNN metodu hakkında detaylı bilgi verilip tarihçesinden bahsedilmektedir. Son olarak bu bölüm, tez için önerilen az sayıda veri ile çatı sınıflandırma için bir yöntem sunmaktadır.

Bölüm 4, eğitimde kullanılan yapay resimlerin nasıl üretildiği, üretim aşamasında hangi araçların kullanıldığı bilgilerine yer vermektedir. Daha sonra bu çalışmada kullanılan veri kümeleri ve üzerinde yapılan ön işleme adımları hakkında bilgilere yer verilmiştir.

Bölüm 5, yapay resimlerle SNN kullanılarak eğitilen modelin Veri Kümesi 1 ve Veri Kümesi 2 üzerindeki deneysel sonuçlarını, bu sonuçların karşılaştırmasını ve değerlendirmesini sunar.

Son olarak, Bölüm 6, tezin genel sonuçlarını özetlemekte, sınırlamaları tartışmaktadır. Ayrıca tez çalışmasının devamında yapılabilecek çalışmaları da sunmaktadır.

Tez çalışması kapsamında yayımlanan makalenin künye bilgisi ekler bölümünde verilmiştir.

2. ALAN BİLGİSİ VE LİTERATÜR

Bu bölüm, bu çalışmada konu edilen çatı tipleri ile ilgili genel bilgiler sunmaktadır. Daha sonra tez çalışmasında kullanılan yöntemler ile ilgili yapılan çalışmaların incelemesi verilmektedir.

2.1. Çatı Tipleri

Dünya üzerinde şimdiye kadar inşa edilmiş binalarda birçok farklı çatı tipi kullanılmıştır. Bir binanın hangi çatı tipine sahip olacağı genelde yapının bulunduğu iklim koşullarına, yapının kullanım türüne, bölgenin mimarisine, taşıyıcı sistemde kullanılan malzemeye, eğimlerine, dış şekillerine, kullanım şekline ve estetik açıdan görünüşüne göre değişiklik gösterebilmektedir. Bu çalışmada çatıların dış şekillerinin tahmin edilmesi üzerinde durulacaktır.

Dış şekillerine göre çatılar:

➤ Doğrusal Eğimli Çatılar:


- Teras çatılar,
- Tek eğimli çatılar,
- Beşik çatılar,
- Kıрма çatılar,
- Haç biçimli çatılar,
- Şed çatılar,
- Katlanmış plak çatılar,
- Sivri (kule) çatılar,
- Mansard çatılar,
- Kelebek çatılar,

➤ Eğrisel Eğimli Çatılar:

- Tonoz çatılar,
- Kubbe çatılar

şeklinde listelenebilir.

En sık rastlanan çatı tiplerinden bazıları; Teras, Beşik, Kıрма olarak gösterilebilir. Bu çalışmada da sınıflandırma için en temel çatı tiplerinden Teras, Beşik ve Kıрма tipleri seçilmiştir. Seçilen bu çatı tiplerinin bazı temel özellikleri hakkında bilgiler aşağıda verilmiştir. Ayrıca her bir çatı tipine yönelik örnekler Şekil 2.1’de görülmektedir.



Şekil 2.1. Farklı Çatı Tiplerine Örnekler a) Teras b) Beşik c) Kıрма [12]

Teras Çatı Tipi: Düşük eğimli çatılar, genellikle "teras çatı" olarak adlandırılır. Sahip oldukları bu hafif eğim, çatının suya karşı direncini artırır. Su, eğimli bir çatıda daha hızlı akar ve çatıya zarar vermeden kolayca akarak drenaj sistemine gider. Ayrıca, düşük eğimli çatılar enerji verimliliği de sağlar çünkü daha az alan kaplar ve böylece daha az ısı kaybı olur. Şekil 2.2’de teras çatı örnekleri gösterilmektedir.



Şekil 2.2. Teras Çatı Tipi Örnekleri [13]

Beşik Çatı Tipi: Çatının yan yüzeylerinin eğimli olarak yükseldiği çatı tipidir. Eğimli yükselme nedeniyle yağmurun veya karın daha hızlı akarak drenaj sistemine gitmesini sağlar. Genellikle ön ve arka cepheler arasında bir açı oluştururlar. Bu açı, çatının suya karşı daha dayanıklı olmasını sağlar. Hem ısıtma hem de soğutma açısından verimli olduğu için enerji verimliliği sağlar. Bu çatılar, aynı zamanda suya karşı dayanıklı ve bakımı kolaydır. Soğuk veya ılıman iklimlerde kullanılan en yaygın çatı şeklidir. Şekil 2.3'te beşik çatı örnekleri gösterilmektedir.



Şekil 2.3. Beşik Çatı Tipi Örnekleri [14]

Kırma Çatı Tipi: Tüm kenarların duvarlara doğru aşağı yönde eğimli olduğu, genellikle hafif bir eğime sahip bir çatı türüdür. Dikdörtgen bir plan üzerine kurulur ve yapının kenar sayısı kadar eğimli yüzeye sahiptir. Bu çatı türü, yapının her cephesinde aynı seviyede ve yatay düzlemde bulunan bir saçak içerir. Bu, yapının su ve rüzgâra karşı daha dayanıklı hale gelmesini sağlar. Yağmurlu, karlı ve çok rüzgârlı iklimlerde kullanılan yaygın çatı şekillerinden biridir. Şekil 2.4'te ise kırma çatı örnekleri gösterilmektedir.



Şekil 2.4. Kırma Çatı Tipi Örnekleri [15]

2.2. Literatür İncelemesi

Son yıllarda uydudan çekilen resimlerden CNN ve SVM tabanlı yöntemler kullanılarak çatı sınıflandırma çalışmaları yapılmıştır. Mohajeri ve arkadaşları çalışmalarında güneş paneli yerleştirmeye uygun bir yer bulabilmek için geleneksel bir makina öğrenmesi yaklaşımı olan SVM yöntemini kullanmıştır [5]. Bu çalışmada, veri kümesi olarak İsviçre'nin Cenevre şehrinden elde edilmiş 10,085 adet çatı verisi kullanılmış ve 6 çatı tipi; teras ve dökten, beşik, kırma, gambrel ve mansard, çapraz/köşe beşik ve kırma, karmaşık çatılar (flat & shed, gable, hip,

gambrel & mansard, cross/corner gable & hip ve complex roofs) %66'lık doğruluk (accuracy) oranıyla sınıflandırılmıştır. Castagno ve Atkins tarafından gerçekleştirilen çalışmada ise CNN metotlarından ResNet-50, Inception-ResNet-v2 ve Inception-v3 kullanılmıştır [16]. Bu çalışmada, New York şehrinin Manhattan bölgesinin, Almanya'nın Witten şehrinin ve Michigan eyaletinin Ann Arbor şehrinin çatı veri kümeleri hem Kırmızı, Yeşil ve Mavi (RGB) hem de Işın Algılama ve Mesafe Ölçme (LIDAR) formatlarında kullanılmış, en iyi sonucun LIDAR verileri ile ResNet-50 metodu kullanılarak %88,3 başarı ile sağlandığı görülmüştür. Büyükdemircioğlu ve arkadaşlarının çalışmasında ise amaç, ilk olarak çok yüksek çözünürlüklü (10 cm) ortofotolardan bir çatı veri kümesi oluşturmak ve daha sonra oluşturulan bu çatı kümesi ile CNN mimarisi kullanarak sınıflandırma yapmaktır [3]. Bu çalışmada yaklaşık 10.000 resimlik bir veri kümesi kullanılmış ve Karmaşık, Teras, Beşik, Yarım Kırma, Kırma ve Piramit (Complex, Flat, Gable, Halfhip, Hip, Pyramid) olmak üzere 6 tip çatı sınıflandırılmıştır. Sonuçlar; Karmaşık, Teras, Beşik, Yarım Kırma, Kırma ve Piramit çatı tipleri için sırasıyla %83, %86, %81, %67, %76 ve %79 olarak elde edilmiştir. Partovi ve arkadaşları çalışmalarında yüksek çözünürlüklü uydu görüntülerinden çatı tipi tahminlemesi yapılması için veri kümesi olarak WorldView-2 uydusundan çekilmiş Münih şehrinin resimleri kullanmış ve CNN ile SVM metotlarının sonuçlarını karşılaştırmıştır [4]. Sonuç olarak, CNN'de teras çatı tipi için %80, beşik çatı tipi için de %79'luk başarımlar sağlanmıştır. SVM için de aynı çatı tiplerinden elde edilen sonuçlar %77 ve %80 olarak hesaplanmıştır.

Binaların geometrik özelliklerinin tahmin edilmesi çatılar için çok önemli bir adımdır çünkü mevcut bina çatılarında büyük ölçekli güneş fotovoltaik dağıtımı ve nötr karbon emisyonları, kentsel alanlarda en verimli ve uygulanabilir yenilenebilir enerji kaynaklarından biridir. İlgilenilen alan üzerinde bir analiz yapılması gerektiğinden, bina çatılarının geometrik özelliklerini tahmin etmek çok önemli bir adımdır. Assouline ve arkadaşları çalışmalarında çok katmanlı bir makine öğrenimi olarak Rassal Orman Algoritmasını önermişlerdir. İsviçre'deki tüm bina çatıları için 6 çatı tipini sınıflandırmaya çalışmışlardır [17]. Bu çalışma sonucunda ortalama %67 oranında bir başarımlar elde etmişlerdir. Bunun sebebi olarak bazı sınıflar iyi tanımlanmış olsa da yeterince temsil edilmeyen diğer sınıfların tespit edilmesi zor olmuştur. Lin ve arkadaşları ise çalışmalarında GF-2 görüntülerinde bina çatılarının bağlamsal bilgilerini birleştirerek DeepLabv3+'yı genişleten bir bina çıkarma yöntemi geliştirerek çatı sınıflandırması için Hough dönüşümü ve Canny kenar tespitine dayanan bir sırt çizgisi tespit algoritması önermişlerdir.

Önerdikleri çatı tanıma yöntemi olan DeepLabv3+ ağını geliştirerek %95,56 oranında doğruluk elde etmişlerdir.

Çatılar ile ilgili bir diğer çalışma alanı ise çatı tipinin tanınması olup bu bilgi binanın 3B modellenmesine ve işlenmesine izin vermek için kullanılmaktadır [18][19]. Zang ve arkadaşlarının [19] çalışmasında karmaşık yapılar parçalara ayrılıp tüm sistemin bu parçalara göre tanınmasına olanak sağlanan bir algoritma önerilmiştir. Bir çatı görüntüsünü daha iyi karakterize etmek için, bir çatı kenarı görüntüsünden çıkarılan yeni bir özellik tasarladıktan sonra çatı resimlerinin sınıflandırılması için kullanılmaktadırlar.

Ek olarak, afetler veya diğer dış koşullardan kaynaklanan hasarları tespit etme gibi sorunları çözmek için Kim ve arkadaşları büyük görüntülerde binaların bulunduğu alanları tespit etmek ve tespit edilen alanlardaki çatı malzemelerini sınıflandırmak için bir CNN yapısı önermişlerdir. Çatıları tespit etmek ve malzemeleri sınıflandırmak için 43 katmanlı bir CNN algoritması önerilmiş ve bu mimari önceden eğitilmiş bir GoogleNet yapısıyla karşılaştırıldığında doğruluk performansında %5-7 oranında iyileşme gözlenmiştir [20].

Siyam Sinir Ağları (SNN) kavramı ilk olarak 1993 yılında yayımlanan bir çalışmada ortaya çıkmıştır [21]. Bu çalışmada öznitelik vektör çıkarımı için aynı model çift olarak kullanılmış ve iki girdi örneğinin benzerliği hesaplanmıştır. SNN kullanarak çatı sınıflandırılması çalışmasına literatürde rastlanmamasına rağmen farklı çalışmalar mevcuttur.

Bir Örnekle Öğrenme yaklaşımı ilk olarak Siyam Sinir Ağları modeli ile, Koch ve arkadaşları tarafından gerçekleştirilen bir çalışmada kullanılmış olup bir alfabe verisi olan Omniglot veri kümesi kullanılarak %92 oranında karakter tanıma başarısı sağlanmıştır [22]. Hsiao ve arkadaşları ise çalışmalarında kötü amaçlı yazılım örneklerini bir dizi ön işlem ile resimlere dönüştürmüş ve SNN modeli ile sınıflandırma işlemini yapmışlardır [23]. Bu çalışmada, SNN modeli ile sınıflandırma işleminin geleneksel yöntemlerden daha başarılı olduğu görülmüştür. Zhang ve arkadaşlarının çalışmasında CNN temelli bir meta-öğrenme çerçevesi geliştirilmiştir [24]. Bu çerçeve temelde çift CNN ile sınıflandırma yapmak için NWPU-RESISC45 ve RSD46-WHU veri kümelerini kullanarak elde edilen sonuçları karşılaştırmıştır. Geliştirilen CNN temelli meta-öğrenme çerçevesi bir örnek (one-shot) için %69,46 beş örnek (five-shot) için %84,66'lık başarımlar elde etmiştir. Chakrapani ve arkadaşları

çalışmalarında el yazısı ile yazılmış kelimeleri tanımaya yönelik öğrenme yaklaşımı üzerine çalışmış ve model eğitimi için SNN modelini kullanmıştır [25]. Çalışmalarında George Washington veri kümesi ve Hindistan şehir isimlerinden oluşan veri kümesi kullanılarak çalışmada five-shot için %92,4 oranında başarı sağlanmıştır. Bir başka çalışmada ise Bir Örnekle Öğrenme temelli Bir Örnekle Hipotez Türetme yaklaşımı, iki zorlu bilgisayarla gördü görevi olan Malayalam karakter tanıma ve retina görüntülerinden nörolojik tanı üzerinde denenmiş ve sonuçları SNN kullanılarak karşılaştırılmıştır [26]. Sonuç olarak önerilen yöntemin SNN modeli ile sınıflandırmaya göre daha iyi sonuç verdiği gözlemlenmiştir.

Öte yandan çatı sınıflandırmaları için olmasa da benzer açıdan SNN kullanan çalışmalar bulunmaktadır [27-29]. Bina çıkarımı için, birkaç örnek mevcut olsa bile, bilinmeyen bina dışı sınıf dağılımları hakkında tahminlerde bulunma yeteneği nedeniyle çok ölçekli bir Siyam ağı kullanılmıştır [27]. Wang ve arkadaşları çalışmalarında perakende ürünlerin otomatik olarak tanınmasına yönelik tek seferlik perakende ürün tanımlaması için Siyam ağını kullanarak bir çalışma önermiştir [28]. Çalışmaları, perakende ürün tanımlama konusunda eğitim aşamasında yetersiz veri problemini çözebilen bir yöntemin geleneksel yöntemlerden daha iyi performans gösterdiğini göstermiştir. Yang ve arkadaşları ise çalışmalarında optik uzaktan algılama görüntülerindeki değişiklikleri algılamak için 862 optik görüntü çifti için derin bir Siyam semantik bölümlenme ağına dayalı denetimli bir yöntem önermiştir [29]. Deneysel sonuçları, önerilen Siyam ağının değişiklik saptama problemlerinde diğer yöntemlerden daha iyi olduğunu göstermiştir.

Literatürde CNN modelleri ile çatı tiplerini tahmin eden birçok çalışma fazla miktarda veriye ihtiyaç duymaktadır. Bununla birlikte, sınırlı veri ve bölge bağımlılığı nedeniyle bu çalışmanın motivasyonu, çatı tiplerini tahmin etmede daha küçük veri kümelerini eğiterek OSL yönteminin başarısını keşfetmektir. Bu nedenle bu çalışmada, ilk defa OSL yaklaşımı kullanılarak uydu görüntülerinden bina çatı tipi sınıflandırması yapılmıştır. Diğer bir yenilikçi bir yön olarak sanal ortamda Teras, Beşik ve Kırmızı çatı tiplerinde örnek yapay resimler üretilmiştir. Böylece çatı tipi sınıflandırma problemi için gerek duyulan eğitim verisinin gerçek görüntülerden alınma zorunluluğu ortadan kaldırılmıştır. Daha sonra, SNN modelinden faydalanılarak çok az sayıda resim örneğinden öğrenme gerçekleştirilmiş ve eğitilen model test edilmiştir. Test süreci için uydudan çekilmiş gerçek çatı resimleri kullanılmıştır.


3. KULLANILAN YÖNTEM VE METOTLAR

Bu bölüm tezde kullanılan tekniklerin genel bir incelemesini ve önerilen çerçevenin temellerini içerir. Birinci bölümde uydudan çekilen görüntülerle yapılan çalışmalarda sıkça kullanılan yöntemlerden biri olan destek vektör makineleri ile ilgili çalışmalar hakkında bilgiler sunulmaktadır. Daha sonra bir diğer yöntem olan evrimsel sinir ağları ile ilgili yapılan çalışmalar aktarılmıştır. Takip eden bölüm, bu tez çalışmasında önerilen çerçevenin temelini oluşturan bir örnekle öğrenme ve siyam sinir ağları ile yapılan çalışmaları anlatmaktadır. Son bölümde ise bu tez çalışması kapsamında önerilen yaklaşımların akış özetleri sunulmuştur.

3.1. Destek Vektör Makinesi (SVM)

Makine Öğrenimi (ML), son yıllarda birçok alanda önemli bir yükseliş eğilimi içerisindedir. ML kredi kartı işlemlerinde dolandırıcılık tespiti, nesne tanıma, yüz tanıma ve karar destek sistemleri gibi birçok alanda kullanılmaktadır. Destek Vektör Makinesi (SVM), hem sınıflandırma hem de regresyon problemleri için kullanılabilen denetimli bir makine öğrenme algoritmasıdır. Başka bir deyişle, SVM, verilere aşırı uyumu (over-fit) otomatik olarak önlerken tahmin doğruluğunu en üst düzeye çıkarmak için makine öğrenimi teorisini kullanan bir sınıflandırma ve regresyon tahmin aracıdır.

Destek Vektör Makinesi yönteminde amaç, bir sınıfın tüm veri noktalarını diğer sınıflardan ayıran en iyi hiper düzlemi bulmaktır. En yakın iki nokta arasındaki uzaklık marj olarak bilinir. Amaç, verilen veri kümesindeki destek vektörleri arasında mümkün olan maksimum marjı olan bir hiper düzlem (hyperplane) seçmektir.



Şekil 3.1. SVM Hiper Düzlem Örneği [30]

Şekil 3.1' de görüleceği üzere verilen veri kümesindeki destek vektörleri arasında seçilebilecek uygun hiper düzlemler gösterilmektedir. Buna göre; H1 hiper düzlemi sınıfları doğru biçimde ayırmaz. H2 hiper düzlemi sınıfları çok küçük bir farkla ayırır. H3 hiper düzlemi ise sınıfları maksimum marjla ayırır. El yazısı analizi, yüz analizi, metin tanıma, duygu analizi ve benzeri birçok uygulamada kullanımının yanı sıra özellikle örüntü sınıflandırma ve regresyon tabanlı uygulamalar da bu yaklaşım kullanılmaktadır.

SVM ilk olarak 1992'de Boser, Guyon ve Vapnik tarafından COLT-92 de duyurulmuştur [31-32]. SVM genellikle geleneksel yöntemlerden daha yüksek sınıflandırma doğruluğu üreten küçük eğitim veri kümelerini başarılı bir şekilde işleme yetenekleri nedeniyle uzaktan algılama alanında özellikle ilgi çekicidir [33]. İyi organize edilmiş bir SVM öğreticisinde, bir görüntü tanıma probleminde SVM yönteminin avantajlarını göstermek için basit bir deney tanımlanmıştır [34]. Bu gösterimde SVM tabanlı eğitimin performansı, görüntü sınıflandırmasında değerlendirilmiştir. SVM için önemli bir terim çoğu yazar tarafından farklı kavramlar altında tanımlanmıştır. Aşırı öğrenme (overfitting) kavramına [35] farklı çalışmalarda sapma-varyans (bias-variance) değiş tokuşu [36] veya kapasite kontrolü (capacity control) [37] olarak çeşitli şekillerde atıfta bulunulmuştur. SVM tabanlı sınıflandırmanın, belirli miktarda eğitim modelinde elde edilen doğruluk ile görünmeyen verileri genelleme yeteneği arasında doğru dengeyi sağladığı bilinmektedir.

SVM yönteminden elde edilen faydaların yanı sıra çeşitli zorluklar da vardır. SVM yönteminin uygulanabilirliği ile ilgili en büyük engel çekirdek seçimidir. Pek çok seçenek mevcut olsa da çekirdek işlevlerinden bazıları uzaktan algılama uygulamaları için en uygun SVM yapılandırmasını sağlamayabilir. Örneğin uydu görüntü verilerinin SVM tabanlı sınıflandırmasında uygulanan farklı çekirdek seçimine dayalı farklı sonuçlar elde edildiği gözlemlenmiştir [38]. SVM çekirdekleri ve bunların işlevselliği hakkında çok sayıda makale vardır [39]. Uzman olmayan kullanıcıların bakış açısından, SVM teorisi, özellikle daha verimli SVM varyantlarının genellikle bazı anlaşılması zor kavramları içermesi nedeniyle SVM yönteminin etkili disiplinler arası uygulamalarını sınırlar.

Uzaktan algılama sınıflandırmaları için optimum bir SVM yöntemi seçmek kolay değildir. Foody and Mathur çalışmalarında SVM yöntemine dayalı yaklaşımları karar ağaçları ve sinir ağları gibi diğer sınıflandırma yöntemleri ile karşılaştırarak; SVM tabanlı yaklaşımın, farklı boyutlardaki eğitim örnekleriyle diğer yöntemlerden daha iyi performans gösterdiğini bulmuşlardır [40]. Bir başka çalışmada ise genetik optimizasyon çerçevesine dayalı en uygun özellik alt uzayı ve model seçimi araştırılmıştır [41].

SVM radyal tabanlı fonksiyon (RBF) ve doğrusal olmak üzere 2 alt yöntemden oluşur. Optimizasyon problemlerinde genellikle doğrusal yöntem tercih edilirken tahminleme problemlerinde veri kümesi çok büyük değilse genellikle RBF tercih edilir. RBF, SVM çalışmalarında kullanılan bir çekirdek türüdür. Bu çekirdek, her bir veri noktasının belirli bir noktaya olan benzerliğini normal dağılım ile ölçer ve bu benzerliğe göre sınıflandırma yapar. Gama hiper parametresi, normal dağılımın genişliğini kontrol etmek için kullanılır. Gama değeri ne kadar küçükse, dağılım o kadar geniş olur. Model aşırı öğrenme sorunu yaşarsa gama değerini düşürmek, model yetersiz öğrenme sorunu yaşarsa da ilgili değeri yükseltmek gerekir.

3.2. Evrimsel Sinir Ağları (CNN)

Son yıllarda derin öğrenmeye olan ilginin artması sonucu Evrimsel Sinir Ağları yönteminin kullanımı fazlasıyla yaygınlaşmıştır. Özellikle yüksek miktarda veriyi işleyebildiği için tercih edilme sebebi olmuştur. Evrimsel Sinir Ağları özellikle makine öğrenme problemlerinde çok başarılı sonuçlar vermektedir. Başlıca kullanım alanlarına örnek olarak nesne sınıflandırma ve nesne bölütleme verilebilir.

Evrişimsel Sinir Ağları mimarisinin tarihi ve mimarisi [42] makalesinde detaylı olarak çalışılmış ve paylaşılmıştır. Evrişimsel Sinir Ağları mimarisinin temeli ilk olarak Hubel and Wiselin'in 1959 yılındaki çalışmasıyla atılmıştır [43]. Bu çalışmaya göre; hayvan görsel korteksindeki hücrelerin, küçük alıcı alandaki ışığı tanıdığı ortaya koyulmuştur. 1980'de bu çalışmadan ilham alan Kunihiro Fukusima, neocognitron [44]'u önermiştir. Bu ağ, CNN için ilk teorik model olarak kabul edilir. 1990 yılında Y. Lecun, L. Bottou, Y. Bengio ve P. Haffner el yazısı ile yazılan rakamları tanımak için CNN'nin LeNet-5[44] adlı modern çerçevesini geliştirmişlerdir.

Geçmiş yıllarda gerek algoritmanın yeni olması gerekse veri azlığı ve bilgisayarlardaki performans düşüklükleri nedeniyle CNN ile çok başarılı sonuçlar alınamamaktaydı. 2012 yılında teknolojinin de gelişmesiyle A. Krizhevsky, I. Sutskever ve G. E. Hinton tarafından yayımlanan [45] çalışması ile tasarlanan AlexNet adlı CNN temelli algoritma aslında LeNet-5 algoritması ile benzer ama daha derin bir yapıya sahiptir. Bu algoritma görüntü sınıflandırma işlemlerinde önceki metotlara göre çok daha iyi performans göstermiştir. AlexNet'in bu başarısı, farklı CNN modellerinin ortaya çıkmasına ve bu modellerin bilgisayarla görme ve doğal dil işlemenin farklı alanlarında uygulanmasının yolunu açmıştır. Başlıca modeller, ZFNet [46], VGGNet [47], GoogleNet [48] ve ResNet [49]'dir. Mimarilerin evrimleşmesinde genel yöntem ağların derinleşmesidir. Örneğin, ILSVR (ImageNet Large Scale Visual Recognition Challenge) 2015'te şampiyonluğu kazanan ResNet, AlexNet'ten yaklaşık 20 kat ve VGGNet 'ten 8 kat daha derindir.

CNN mimarisinin Şekil 3.2'de gösterildiği gibi bir veya birden fazla evrişim (Convolutional) ve havuzlama (Pooling) katmanından ve bir veya birkaç tamamen bağlı (Fully Connected) katmanından ve bir adet çıktı (Output) katmanından oluşmaktadır.

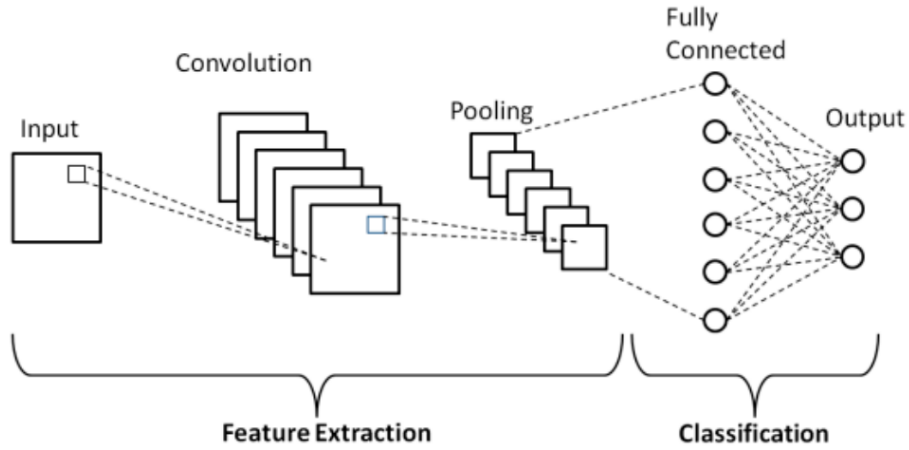
Evrişim katmanı; CNN mimarisinin temel yapı taşıdır ve görüntünün özelliklerini algılamaktan sorumludur. Bu katman her bir nöronun çekirdek gibi davrandığı bir dizi evrişimsel çekirdekten oluşmaktadır. Evrişimsel çekirdek; görüntüyü küçük parçalara böler. Görüntünün küçük parçalara bölünmesi özellik motiflerinin çıkarılmasına yardımcı olur. Bu katman kısaca girdi (input) olarak verilen verinin özelliklerini (feature) öğrenmeyi amaçlar.

Havuzlama katmanı, girdi olarak Evrişimsel katmanın çıktısının küçük bir bölümünü alır ve tek bir çıktı üretmek için onu örnekler. Farklı farklı havuzlama algoritmaları vardır. Bunlardan

bazıları; maksimum havuzlama, minimum havuzlama ve ortalama havuzlamadır.

CNN mimarisinin son kısmı bir veya birden fazla tamamen bağı (FC) katmanından oluşur. Tamamen bağı (FC) katmanı, havuzlama veya evrişimsel katmanından girdi alır ve CNN'nin nihai çıktısını üretir.

Görüntü sınıflandırması esnasında CNN iki kademededen oluşur. İlki özellik çıkarımı diğeri ise sınıflandırmadır. Evrişimsel ve Havuzlama katmanlarında özellik çıkarımı yapılır. Özellik çıkarımına örnek verilecek olursa, bir insan resminden, iki el, iki ayak, iki göz, tek burun vs. gibi özelliklerin algılanması beklenir. Bu özellikler çıktıktan sonra tamamen bağı (FC) katmanı sınıflandırma işini yapar ve aslında bu özelliklerin bir insana ait olma ihtimalini ekler.




Şekil 3.2. Basit Bir Evrişimsel Sinir Ağı Mimarisi [50]

Bu çalışmada, CNN'nin DenseNet mimarisi, OSL yaklaşımı ile karşılaştırılmak üzere seçilmiştir.

DenseNet: DenseNet 'in temel özelliği görsel nesne tanıma ve nesne bölütleme problemlerinde sıklıkla kullanılmasıdır. Diğeri derin öğrenme mimarilerinin tercih ettiği girdi ve çıktı arasındaki derin yollar yerine yoğun bloklar kullanarak bir önceki katmanın çıktısını bir sonraki katmanla birleştirir [51]. DenseNet 'teki her katman, önceki tüm katmanları girdi olarak aldığından, daha çeşitli özelliklere ve daha zengin desenlere sahip olma eğilimindedir. Standart ConvNet'te, giriş

görüntüsü, sınıflandırıcının en karmaşık özellikleri kullanması için yüksek seviyeli özellikler elde etmek amacıyla birden fazla evrişimdir. Öte yandan, DenseNet'te sınıflandırıcı, tüm karmaşıklık seviyelerindeki özellikleri kullanarak daha yumuşak karar sınırları verme eğilimindedir. Bu ayrıca eğitim verileri yetersiz olduğunda DenseNet 'in neden diğer CNN mimarilerinden daha iyi performans gösterdiğini de açıklamaktadır.


Şekil 3.3'te örnek bir DenseNet mimarisi gösterilmektedir [51]. DenseNet bir temel evrişim (Convolutional) ve bir havuzlama (Pooling) katmanı ile başlar. Bu katmanlar, CNN mimarisinin temel yapı taşlarını oluşturur ve görüntünün özelliklerini algılamadan sorumludur.



Şekil 3.3. Örnek DenseNet Mimarisi [51]

Girdi olarak verilen verilerin özelliklerini öğrenmeyi amaçlayan evrişim katmanı, her bir nöronun bir çekirdek görevi gördüğü bir dizi evrişimsel çekirdekte oluşur. Evrişim katmanındaki filtre, görüntüyü daha küçük parçalara bölerek özellik motiflerinin çıkarılmasına yardımcı olur.

Havuzlama (Pooling) katmanı, evrişim katmanının çıktısının küçük bir kısmını girdi olarak alır ve tek bir çıktı üretmek için onu örnekler. Ardından dense blok gelir ve bir geçiş katmanı (Transition Layer) (başka bir evrişim katmanından ve başka bir havuz katmanından oluşur) bunu takip eder. Daha sonra başka bir dense blok, ardından bir geçiş katmanı, başka bir dense blok ve ardından bir sınıflandırma katmanı gelir.



Şekil 3.4. DenseNet mimarisi

Her dense blok, 1x1 ve 3x3 boyutlarında çekirdeklere sahip iki evrişim katmanına sahiptir. Dense bloklar sırasıyla 6, 12, 24 ve 16 tekrar ile çalışır. Her dense bloktan sonra, kanal sayısı arttıkça modelin karmaşıklığını kontrol etmek için geçiş katmanı kullanılır (Şekil 3.4).


Geçiş (Transition) katmanı, kullanılan evrişim katmanı sayısını azaltır ve 2. adımda ortalama havuz katmanının yüksekliğini ve genişliğini yarıya indirerek modelin karmaşıklığını azaltır. Son olarak, dense blok ve ardından bir sınıflandırma katmanı vardır.

3.3. Bir Örnekle Öğrenme (OSL) ve Siyam Sinir Ağları (SNN)

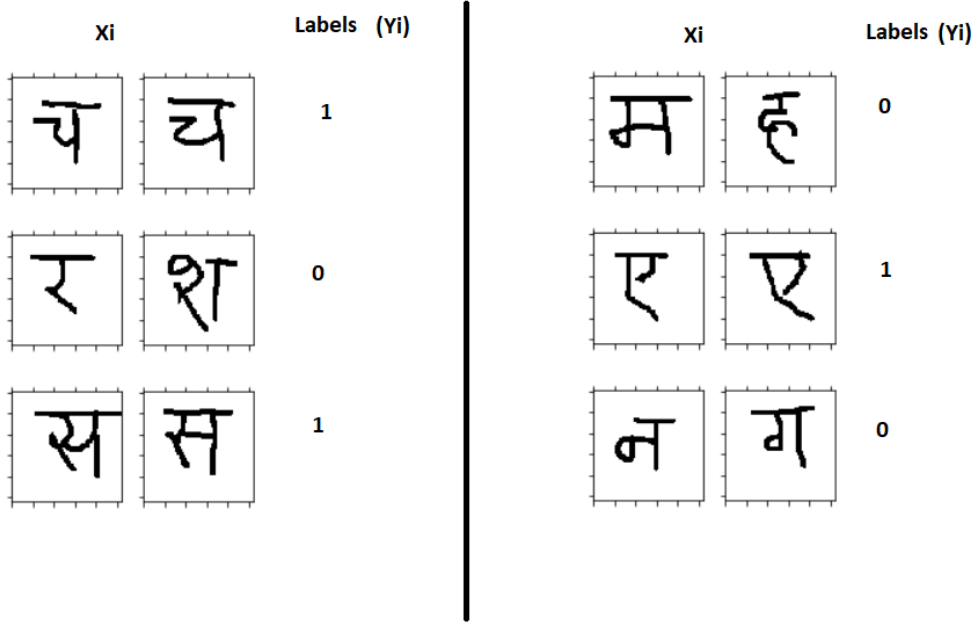
Evrişimsel Sinir Ağları sınıflandırma işlemlerinde çok başarılı sonuçlar vermektedir. Fakat, CNN ve benzer alt yapıya sahip metotların en temel problemi fazla sayıda veriye ihtiyaç duyulmasıdır. Bazı uygulamalar veya problemler için çok fazla sayıda veri olmayabilir. OSL yönteminin amacı bir veya birkaç veri ile modeli eğitip, fazla sayıda veriye ihtiyaç duyulmadan çözüm üretmektir.

SNN kavramı ilk olarak 1993 yılında imza doğrulama problemi için Bromley, J., Guyon, I., LeCun, Y. [21] tarafından tanımlanmıştır. SNN yönteminin ana fikri ikiz ağları denetimli bir yöntemle eğitmektir. SNN; her biri bir girdi kabul eden iki özdeş alt sinir ağından oluşmaktadır. İki alt ağın çıktıları, aralarında bir mesafe metriği hesaplayan bir mesafe katmanına iletilir. Uzaklık metriği, bir çiftteki iki görüntü iki farklı sınıftan geliyorsa yüksek, aynı sınıftan geliyorsa düşük bir değer üretir. Diğer bir tanımda ise SNN; temelde iki CNN algoritmasının birlikte çalışmasından meydana gelmektedir. Bu yüzden Siyam adını almıştır.

Temelde bu yöntem iki görüntü alır ve iki görüntü arasındaki benzerliği gösteren bir değer döndürür (Şekil 3.5). Görüntüler aynı nesneyi içeriyorsa, sinir ağı belirli bir eşikten (örneğin sıfır) daha küçük bir değer döndürür ve aynı nesne değilse, eşikten daha yüksek olacaktır. [22] çalışmasında ilk olarak SNN yaklaşımı kullanılmıştır. Bu çalışma 2015 yılında yayımlanmış olup bir alfabe verisi olan Omniglot veri kümesi [22][52] kullanılmıştır. Çalışmada sonuç olarak %92 oranında başarı sağlanmıştır.




Şekil 3.5. Bir Örnekle Öğrenme (OSL) Yaklaşımı



Şekil 3.6. Siyam Sinir Ağları Yaklaşımı [53]


Şekil 3.6'dan da görüleceği üzere Siyam Sinir Ağlarında eğitim aşamasında aynı sınıfta olan resim çiftleri '1' olarak etiketlenir. Fark bir sınıfa ait resim çiftleri ise '0' olarak etiketlenir. Sonuç olarak '1' olarak etiketlenen resimler doğru, '0' olarak etiketlenen resimler ise yanlış bilgi olarak eğitime verilir. Şekil 3.6'da X_i , resim çiftlerini Y_i etiketleri temsil etmektedir. Bu kısımda resim çifti aynı sınıfta ise Y_i '0' değerini eğer iki resim farklı sınıflarda ise '1' değerini alır.



Şekil 3.7. Siyam Sinir Ağları Benzerlik Hesaplama Yaklaşımı

Şekil 3.7’ de gösterilen iki Evrişimsel Sinir Ağı farklı ağlar değildir, aynı ağın iki kopyasıdır buna Siyam Ağ adı verilir. Temelde aynı parametreleri paylaşırlar. Şekil 3.8’de ConvNet mimarisinin detayları görülmektedir.

İlk olarak, iki resim (x_1 ve x_2) her biri ($h(x_1)$ ve $h(x_2)$) için sabit uzunlukta bir özellik vektörü oluşturulmak üzere ConvNet (CNN)’ten geçirilir. SNN modelinin doğru bir şekilde eğitildiği durumda, modele girdi olarak verilen iki resim görüntüsü aynı sınıfa aitse öznitelik vektörleri benzer, farklı sınıflara aitse özellik vektörleri farklı olmalıdır. Bu nedenle iki öznitelik vektörü arasındaki mutlak fark hesaplanır. Hesaplanan bu değer sigmoid katmanından geçirilir ve benzerlik puanı hesaplanır.



Şekil 3.8. Siyam Sinir Ağlarının Yapısı [53]

3.4. Önerilen Yöntem

Yukarıda verilen bilgiler ışığında CNN, SVM ve SNN yöntemlerinin çatı tipi tahmin başarımları iki farklı veri kümesi ile test edilerek karşılaştırılmıştır. Bu bağlamda yapılan işlemler 2 temel adımda özetlenmiştir.

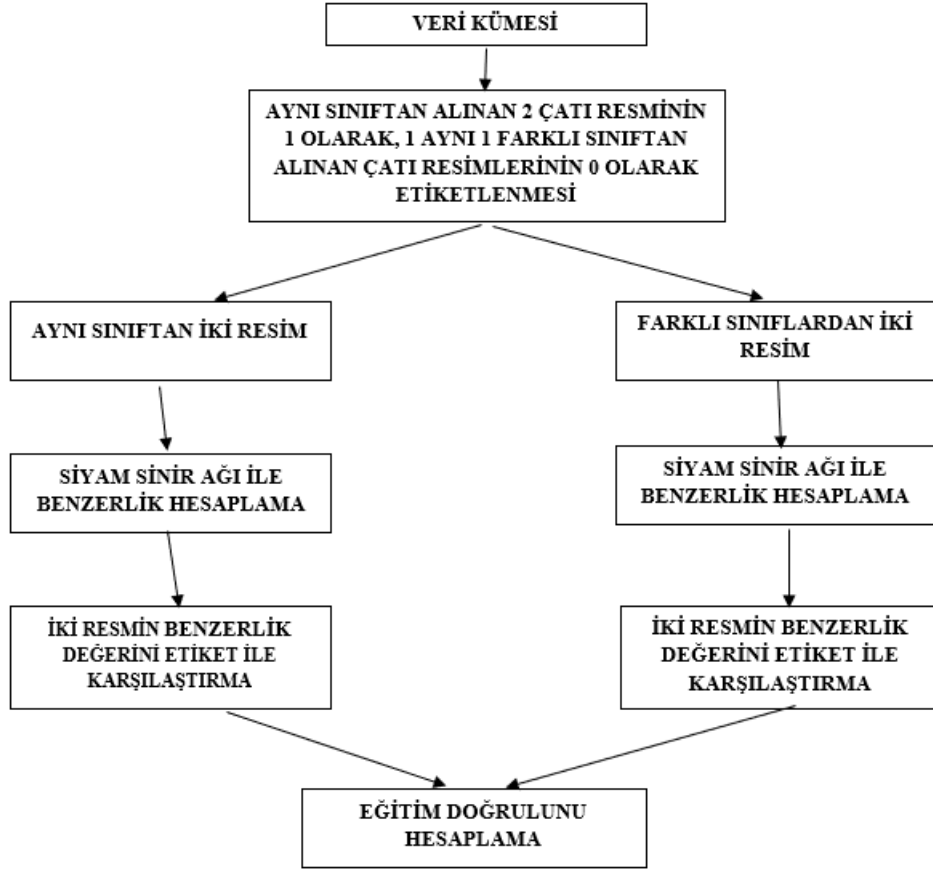
1. Adım

- Kullanılacak verilerin ön işleme adımından geçirilmesi.
- Eğitim için benzer ve benzer olmayan görüntü çiftlerinin etiketlenmesi.
- Modellerin farklı veri miktarları ile eğitilip test edilerek karşılaştırılması (SVM, CNN, SNN)

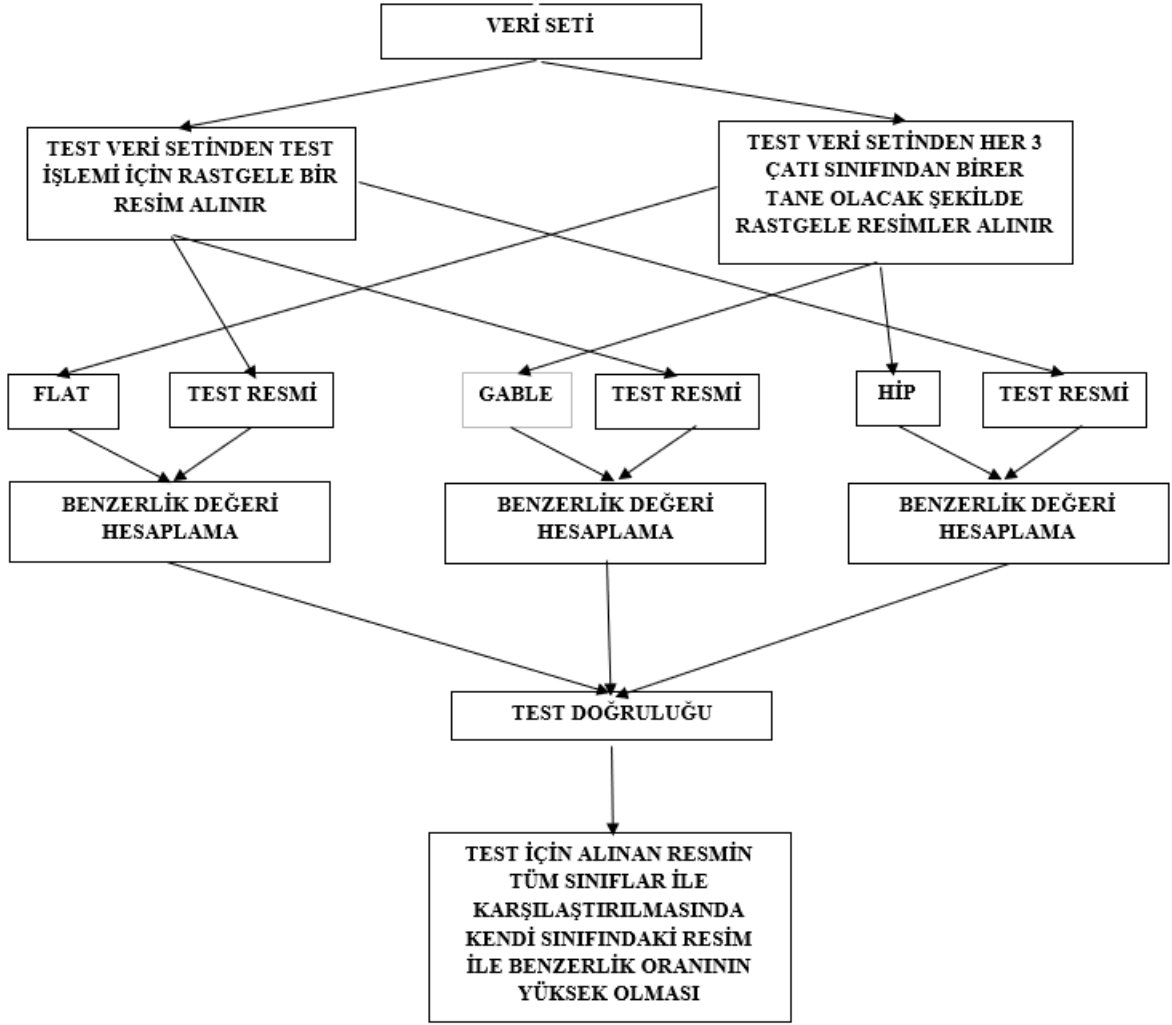
2. Adım

- Autodesk Maya uygulaması ile yapay çatı resimlerinin üretilmesi.
- Kullanılacak olan ikinci veri kümesinin oluşturulması.
- Yapay çatı resimleri ile eğitilen SNN modelinin iki veri kümesi üzerinde testlerinin gerçekleştirilmesi.

Şekil 3.9 ve 3.10'da tez çalışması kapsamında gerçekleştirilen eğitim ve test aşamalarının işlem adımları görülmektedir



Şekil 3.9. Eğitim Aşamasının Adımları



Şekil 3.10. Test Aşamasının Adımları


4. VERİ KÜMELERİ

Bu bölümde önerilen yöntemlerin eğitilmesinde ve test edilmesinde kullanılan veri kümeleri (yapay çatı resimleri, Veri Kümesi 1 ve Veri Kümesi 2) ile ilgili genel bilgiler verilmektedir.

4.1. Yapay Çatı Resimleri

Çatı veri kümesi bulmanın zorluğu ve çalışmanın bölgeden bağımsız yapılabilmesi için model eğitimi, Şekil 4.1'de sunulan yapay olarak üretilmiş çatı görüntüleri ile gerçekleştirilmiştir. Test sürecinde ise gerçek çatı resimleri kullanılmıştır.

Bu verilerin üretimi Autodesk Maya yazılımı [54] ile farklı güneş açıları hesaba katılarak yapılmıştır. Gerçeklik düzeyinin artırılmasına yönelik olarak her çatı tipi için 3 farklı güneş açısına sahip resim ve farklı çatı dokusu üretilmiştir.



Şekil 4.1. Yapay Olarak Üretilen Veri Kümesi Örnekleri a) Teras b) Beşik c) Kırma


Test için iki farklı veri kümesi kullanılmıştır. Test için kullanılan veri kümelerinde de aynı 3 çatı tipi (Teras, Beşik ve Kırma) yer almaktadır.

4.2. Veri Kümesi 1


Veri hazırlama süreci özellikle görüntülerin girdi olarak kullanıldığı çalışmalarda yaygın olarak kullanılan bir aşamadır. Bu çalışmalar genellikle veri kümesini boyut bakımından çalışmaya uygun hale getirme, görüntüdeki gürültüleri giderme veya filtre uygulama gibi işlemlerden oluşmaktadır. Bu çalışmada kullanılan her iki test veri kümesi de ön işleme adımlarından geçirilerek kullanıma uygun hale getirilmiştir.

Bu çalışmada kullanılan ilk veri kümesi “<https://github.com/loosgagnet/Building-detection-and-roof-type-recognition>” adresinden alınmış [52] olup bu veri kümesi tezde “Veri Kümesi 1” olarak adlandırılacaktır. Veri Kümesi 1, her çatı tipi için 4800’er adet olmak üzere toplam 14400 adet çatı resminden oluşmaktadır. Veri Kümesi 1’de yer alan görüntüler 224x224 boyutunda ve .tif formatındadır. Çalışmada SNN yaklaşımı için kullanılmış kod bloğu ise .jpg formatında ve boyutları 105x105 olan resimleri kabul etmektedir. Bu nedenle .tif uzantılı resimler 224x224 boyutlarından 105x105’e indirgenerek .jpg formatına dönüştürülmüştür.

Şekil 4.2’de Veri Kümesi 1’de bulunan Teras çatı tipi, Şekil 4.3’de Veri Kümesi 1’de bulunan Beşik çatı tipi ve Şekil 4.4’de Veri Kümesi 1’de bulunan Kırma çatı tipi için örnekler gösterilmektedir. Bu veri kümesindeki Kırma çatılı resimlerin içinde Kırma, Kırma & Vadi tipinde alt çatı tipleri; Beşik çatılı resimlerin içinde de Beşik, Dormerlı Beşik ve Beşik & Vadi alt çatı tipleri bulunmaktadır. Ancak bu çalışmada alt kategoriler dikkate alınmayıp tamamı üst kategoriye göre etiketlenmiştir.



Şekil 4.2. Veri Kümesi 1-Teras Çatı Tipi Test Örnekleri



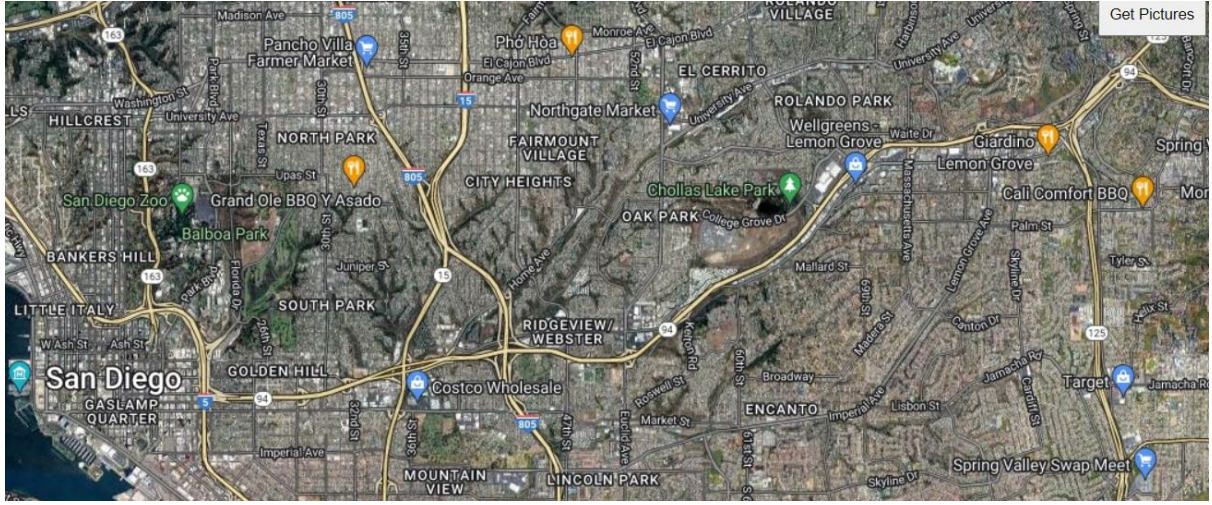
Şekil 4.3. Veri Kümesi 1-Beşik Çatı Tipi Test Örnekleri




Şekil 4.4. Veri Kümesi 1-Kırma Çatı Tipi Test Örnekleri

4.3. Veri Kümesi 2


Bu çalışma için kullanılan diğer veri kümesi ise California Eyaleti'nin San Diego şehrine ait çatı resimlerinin manuel kesilmesiyle elde edilmiştir. Bu veri kümesi tezde “Veri Kümesi 2” olarak adlandırılacaktır. İlk olarak San Diego şehrinin uydudan çekilen tüm poligonları Open Street Map Web uygulaması [55] ile .osm formatında indirilmiştir. Daha sonra indirilen bu veri QGIS Desktop 3.28.2 [56] versiyonu ile açılıp Tip alanı “Building” olan veriler filtrelenmiştir. Daha sonra filtrelenen bu veri, poligonların koordinatlarını gösterecek şekilde. Geojson formatında kaydedilmiştir. Bu işlemlerden sonra elde edilen çatı koordinatlarını Google Map ile [57] açarak çatı bölgelerini otomatik olarak kırpan ve Şekil 4.5'te de ekran görüntüsüne yer verilen basit bir uygulama geliştirilmiştir. Yapılan tüm işlemler sonucunda, 50 adet Teras, 50 adet Beşik ve 50 adet Kıрма olmak üzere toplam 150 adet çatı resmi üretilmiştir. Şekil 4.6'da Teras, Şekil 4.7'de Beşik ve Şekil 4.8'te Kıрма çatı tipleri için örnekler gösterilmektedir.




Şekil 4.5. Çatı Verisi Toplama Uygulaması Ekran Örneği



Şekil 4.6. Veri Kümesi 2- Teras Çatı Tipi Test Örnekleri



Şekil 4.7. Veri Kümesi 2- Beşik Çatı Tipi Test Örnekleri



Şekil 4.8. Veri Kümesi 2- Kıрма Çatı Tipi Test Örnekleri

5. DENEYSEL SONUÇLAR

Veriler üzerindeki ön çalışma tamamlandıktan sonra, uydudan çekilmiş az sayıdaki test görüntüsünden bir örnekle öğrenme yaklaşımı kullanılarak özellik çıkarım yoluyla bina çatı tipinin tahmin edilmesi gerçekleştirilmiştir.

5.1. Deneysel Kurulum

Çalışmanın eğitim aşamasında ilk olarak herhangi bir sınıftan rastgele 1 adet resim alınır. Daha sonra ilk alınan resim ile aynı sınıftan farklı bir resim alınarak bu resim çifti '1' olarak etiketlenir. Takip eden adımda, ilk alınan resimden farklı bir sınıfa ait olan rastgele bir resim alınıp bu iki resim '0' olarak etiketlenir. Buradaki amaç 1 olarak etiketlenen resimlerin doğru, 0 olarak etiketlenen resimlerin ise yanlış çift olarak eğitime verilmesidir. Daha sonra benzerlik oranı hesabı için resimlere SNN yöntemi uygulanır. Bu yöntemde iki resmin öznitelik vektörleri kullanılarak bir benzerlik değeri hesaplanır. Uygulama sonucunda, aynı sınıftaki resimlerin benzerlik oranının daha yüksek, farklı sınıflarda olan resimlerin benzerlik oranının ise daha düşük olması beklenir. Daha sonra bulunan bu benzerlik oranı başlangıçta verilen etiketler ile karşılaştırılarak eğitim doğruluk oranı (training accuracy) hesaplanır. Eğitim, parametrik olarak verilen iterasyon sayısına bağlı olarak yapılmaktadır. Verilen iterasyon sayısı kadar rastgele seçilen resimler eğitime verilmektedir.

Test aşamasında ilk adım olarak, test veri kümesinden rastgele bir çatı resmi alınır. Daha sonra ilk alınan resimle karşılaştırmak için, alınan resmin bulunduğu sınıf da dahil olmak üzere teras, beşik ve kırma sınıflarından 3 adet rastgele çatı resmi alınır. İlk alınan resim ile daha sonra alınan diğer sınıflardaki resimler eşleştirilir. Bu aşamada, ilk alınan resim ve teras çatı tipi resmi, ilk alınan resim ve beşik çatı tipi resmi ve ilk alınan resim ve kırma çatı tipi resmi olmak üzere 3 adet 2'li resim kümesi oluşur. Daha sonra bu resim ikilileri için SNN yöntemi kullanılarak benzerlik oranları hesaplanır. Sonuç olarak ilk alınan resmin kendi sınıfındaki resim ile oluşturduğu resim kümesinin en yüksek benzerlik oranına sahip olması beklenir.

Tablo 5.1'deki ilk karşılaştırma (Örnek 1) teras çatı tipinde rastgele alınan bir resmin, kendi sınıfı dahil 3 çatı tipi sınıfından rastgele alınan 3 resim ile benzerlik oranlarını göstermektedir. En yüksek sonuç, doğru sınıflandırmayı gösteren ve Teras-Teras benzerlik değeri olan 0.434'tür. Tablo 5.1'deki ikinci karşılaştırma ise (Örnek 2) beşik çatı tipinde rastgele alınan bir resmin, kendi sınıfı dahil 3 çatı tipi sınıfından rastgele alınan 3 resim ile benzerlik oranlarını göstermektedir. Ancak Örnek 2'de Beşik-Kırma çatı benzerliği, Beşik-Beşik çatı benzerliğinden daha yüksek olarak gösterilmiştir. Bu durum yanlış sınıflandırmayı göstermektedir.

Tablo 5.1. Sınıflandırma Örnekleri


a) Örnek 1

| Çatı Tipi | Karşılaştırılan çatı tipi | Sonuç |
|-----------|---------------------------|--------|
| Teras | Teras | 0.439 |
| Teras | Kırma | -1.079 |
| Teras | Beşik | 0.189 |

b) Örnek 2

| Çatı Tipi | Karşılaştırılan çatı tipi | Sonuç |
|-----------|---------------------------|--------|
| Beşik | Beşik | -4.694 |
| Beşik | Kırma | -0.119 |
| Beşik | Teras | -2.892 |

Çalışmada eğitim aşamalarında toplam iterasyon sayısı ilk veri kümesi için 4000, ikinci veri kümesi için ise 10000 olarak belirlenmiştir. Bu farkın sebebi öğrenmenin Şekil 5.1'te görüldüğü üzere daha az iterasyon ile tamamlanmasıdır. Şekil 5.1' te görüldüğü üzere 2000'den sonra eğitilen model neredeyse hiç değişmemektedir.



Şekil 5.1. İterasyon – Eğitim Kayıp Grafiği

İlk olarak, çalışmada Veri Kümesi 1 kullanılarak testler gerçekleştirilmiştir. Bu aşamada eğitim ve testler aynı veri kümesinin farklı verileri ile gerçekleştirilerek sonuçlar elde edilmiştir.

5.2. Başarı Ölçütleri

Sınıflandırma performansını değerlendirmek için Doğruluk (accuracy) (1), Kesinlik (precision) (2), Duyarlılık (recall) (3) ve Kappa Puanı (cohen's kappa score) (4) metrikleri kullanılmıştır. Doğruluk, bir sınıflandırma problemini modelin ne oranda doğru tahmin ettiğinin oranıdır. Buna göre Eşitlik 5.1'de gösterildiği gibi doğruluk, doğru tahmin edilen sınıfların tüm tahminlere bölünmesi ile ölçülmektedir. Eşitlik 5.2 ve 5.3'de de sırasıyla kesinlik ve duyarlılık metrikleri verilmiştir. Kesinlik, tüm öngörülen pozitifler arasında tahmini pozitiflerin kaçının doğru tahmin edilen pozitif değer olduğunu gösterirken duyarlılık ise tüm gerçek pozitifler arasından modelin kaç pozitifini doğru tahmin ettiğini ölçmektedir.

$$\text{Doğruluk} = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (5.1)$$

$$\text{Kesinlik} = \frac{TP}{(TP+FP)} \quad (5.2)$$

$$Duyarluluk = \frac{TP}{(TP+FN)} \quad (5.3)$$

Bu denklemlerdeki TP, FP, TN ve FN sırasıyla; gerçek pozitif, yanlış pozitif, doğru negatif ve yanlış negatif anlamına gelmektedir.

Cohen'in Kappa Puanı ise makine öğrenimi sınıflandırma modellerinin performansını ölçmek için kullanılan bir istatistiktir. Pe, her iki değerlendiricinin de rastgele tahminde bulunması halinde her ikisinin de aynı etiketi seçme olasılığıdır. P₁, her iki değerlendiricinin de ilk etiketi rastgele seçme (başarılı) olasılığıdır olup P₂, her ikisinin de ikinci etiketi seçme (başarısız) olasılığıdır. Bu olasılıklar, yukarıda açıklanan gerçek pozitif ve gerçek negatif sayısı artı iki ek terim kullanılarak hesaplanabilir. Denklem 5.4'te Cohen'in Kappa Puanı hesaplama formülü gösterilmiştir. Kappa değeri ile ilgili değerlendirme tablosu EK 2'de verilmektedir.

$$N = TP + FP + FN + TN$$

$$P_1 = \frac{(TP+FN)*(TP+FP)}{N*N}$$

$$P_2 = \frac{(TN+FN)*(TN+FP)}{N*N}$$

$$Pe = P_1 + P_2$$

$$Kappa = \frac{Doğruluk + Pe}{1 - Pe} \quad (5.4)$$

5.3. Büyük Boyutlu Veri Kümesi Karşılaştırması – CNN, SVM, SNN

Veri kümesinin eğitime verilen veri miktarları değiştirilerek SNN, CNN ve SVM karşılaştırılması yapılmıştır. Bu kısımda 4800 örnekten rastgele seçilen toplam 2400 adet gerçek çatı görüntüsü test için kullanılmış; eğitim için ise 100, 200, 400, 600, 1200 ve 2400 adet gerçek çatı resmi modele verilmiştir. CNN, SVM ve SNN yöntemleri için aynı eğitim ve test kümesi kullanılmıştır.

1. İlk olarak Veri Kümesi 1 ile yapılan deney senaryosunda eğitime ve teste 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır.

SNN yaklaşımı ile yapılan denemede öğrenme oranı 0.0006 alınarak yaklaşık %92 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %97'lik başarı oranı, SVM yöntemi denemesinde ise %77.1'lik başarı oranı elde edilmiştir.

2. Veri Kümesi 1 ile yapılan diğer bir deney senaryosunda eğitime 1200'er adet Teras, Beşik ve Kıрма, teste ise 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı 0.0006 alınarak yaklaşık %86 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %93'lük bir başarı oranı, SVM yöntemi denemesinde ise %74.4'lük başarı oranı elde edilmiştir.
3. Daha sonra eğitime verilen veri miktarı 600'e düşürülerek yeniden test yapılmıştır. Bu deney senaryosunda, test için 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilmiştir. SNN yaklaşımı ile yapılan denemede öğrenme oranı 0.0006 alınarak yaklaşık %85 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %84'lük bir başarı oranı, SVM yöntemi denemesinde ise %73.9'lük başarı oranı elde edilmiştir.
4. Test verileri korunup, eğitim verileri 400'e düşürülerek yapılan denemelerde ise; SNN yaklaşımı ile yapılan deneyde öğrenme oranı 0.0006 alınarak yaklaşık %85 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %88'lik bir başarı oranı, SVM yöntemi denemesinde ise %72'lik başarı oranı elde edilmiştir.
5. Test verileri korunup, eğitim verileri 200'e düşürülerek yapılan denemelerde ise; SNN yaklaşımı ile yapılan deneyde öğrenme oranı 0.0006 alınarak yaklaşık %80 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %58'lik bir başarı oranı, SVM yöntemi denemesinde ise %70'lik başarı oranı elde edilmiştir.

6. Test verileri korunup, eğitim verileri 100'e düşürülerek yapılan denemelerde ise; SNN yaklaşımı ile yapılan deneyde öğrenme oranı 0.0006 alınarak yaklaşık %79 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %43'lük bir başarı oranı, SVM yöntemi denemesinde ise %66'lık başarı oranı elde edilmiştir.

Testlerin yapıldığı SNN yöntemi ConvNet mimarisi ile, karşılaştırma yaptığımız ilk metot olan CNN algoritması ise DenseNet mimarisi ile çalışmaktadır. DenseNet'in eğitim sürecinde Adam Optimizer kullanılmıştır. Epoch değeri 50'ye, mini yığın boyutu (batch size) 32'ye ve öğrenme oranı değeri 0.001'e ayarlanmıştır. Karşılaştırma yaptığımız bir diğer metot olan SVM de ise kernel yöntemi olarak RBF seçilmiş olup C değeri 0.01, gama değeri 0.00000001 olarak ayarlanmıştır.

Tablo 5.2. SNN, CNN ve SVM için Büyük Boyutlu Veri Kümesi Sonuçlarının Karşılaştırması

| Veri Adedi | SNN Doğruluk Değerleri | CNN Doğruluk Değerleri | SVM Doğruluk Değerleri |
|------------|------------------------|------------------------|------------------------|
| 100 | 0.79 | 0.43 | 0.66 |
| 200 | 0.8 | 0.58 | 0.70 |
| 400 | 0.87 | 0.88 | 0.72 |
| 600 | 0.85 | 0.84 | 0.739 |
| 1200 | 0.864 | 0.93 | 0.744 |
| 2400 | 0.926 | 0.97 | 0.771 |

OSL mimarisi bir veya birkaç resimle modelin eğitilmesini amaçlamaktadır. Tablo 5.2' de gösterilen sonuçlar beklendiği üzere veri miktarı arttıkça CNN metodolojisinin daha iyi sonuçlar verdiğini, eğitime verilen veri miktarı azaldıkça ise SNN metodolojisinin daha iyi sonuçlar verdiğini göstermektedir. Yapılan çalışmalarda SNN modeli ilk olarak yüksek miktarda gerçek çatı resmi ile eğitilmiş, sonrasında OSL yönteminin mantığına uygun bir şekilde veri miktarı azaltılarak çalışmalar yinelenmiştir. Daha sonra aynı veri kümeleri CNN ve SVM yöntemleri ile çalıştırılarak karşılaştırma yapılmıştır. Alınan sonuçlara göre az sayıda veri ile SNN modelinin daha iyi sonuç verdiği gözlemlenmiştir. Öte yandan veri miktarının 1000'in

üzerine çıkmasıyla birlikte CNN modelinin daha iyi sonuçlar vermeye başladığı gözlemlenmiştir.

5.4. Küçük Boyutlu Veri Kümesi Karşılaştırması – CNN, SVM, SNN


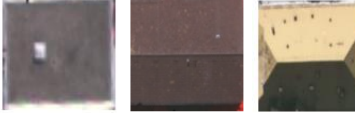

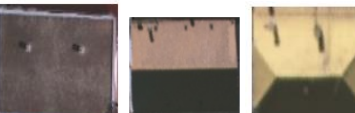
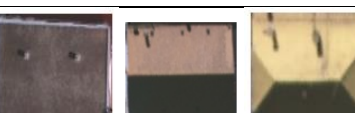
Bu bölümde veri miktarı daha da azaltılarak SNN, CNN ve SVM yöntemlerinin sonuçlarının karşılaştırılması yapılmıştır. Bu kısımda 4800 örnekten rastgele seçilen toplam 2400 adet gerçek çatı görüntüsü test için kullanılmış; eğitim için ise 1, 5, 10, 20, 40 ve 60 adet gerçek çatı resmi modele verilmiştir. CNN, SVM ve SNN yöntemleri için aynı eğitim ve test kümesi kullanılmıştır.

1. Veri Kümesi 1 ile yapılan bu deney senaryosunda eğitime; 60'ar adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı 0.0006 alınarak yaklaşık %92 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde %39'luk başarı oranı, SVM yöntemi denemesinde ise %47'lik başarı oranı elde edilmiştir.
2. Diğer deney senaryosunda eğitime; 40'ar adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı değeri 0.0006 alınarak yaklaşık %81 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde herhangi bir başarı oranı elde edilememişken SVM yönteminde %45.4'lük bir başarı oranı elde edilmiştir.
3. Eğitime verilen veri miktarını düşürdüğümüz diğer bir deney senaryosunda eğitime; 20'şer adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı değeri 0.0006 alınarak yaklaşık %85 oranında bir başarı elde edilmiştir. Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde ise herhangi bir başarı oranı elde edilememişken SVM yönteminde %40'lık bir başarı oranı elde edilmiştir.

4. Eğitime verilen veri miktarını düşürdüğümüz diğer bir deney senaryosunda eğitime; 10'ar adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı değeri 0.0006 alınarak yaklaşık %74 oranında bir başarı elde edilmiştir Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde ise herhangi bir başarı oranı elde edilememişken SVM yönteminde %38.7'lik başarı oranı elde edilmiştir.
5. Eğitime verilen veri miktarını düşürdüğümüz diğer bir deney senaryosunda eğitime; 5'er adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek denemeler yapılmıştır. SNN yaklaşımı ile yapılan denemede öğrenme oranı değeri 0.0006 alınarak yaklaşık %77 oranında bir başarı elde edilmiştir Aynı test ve aynı eğitim verileri ile öğrenme oranı değeri 0.001 olarak alınan CNN yöntemi denemesinde ise herhangi bir başarı oranı elde edilememişken SVM yönteminde %39.5'lik başarı oranı elde edilmiştir.
6. Son olarak, eğitime 1'er adet Teras, Beşik ve Kıрма, teste ise aynı şekilde 2400'er adet Teras, Beşik ve Kıрма çatı tiplerinden oluşan resimler verilerek sonuçlar gözlemlenmiştir. Tablo 5.3'te görülen sonuçlara göre; Test-1'de gösterilen resimler için alınan sonuç yaklaşık %58 iken, Test-2'de gösterilen resimler için bu oran %69, Test-3'de gösterilen resimler için %65, Test-4'te gösterilen resimler için %49 ve Test-5'te gösterilen resimler için %71 olarak hesaplanmıştır. Bu çalışmalarda SNN yöntemi için öğrenme oranı değeri 0.0006 olarak alınmıştır. Aynı test ve aynı eğitim verileri ile yapılan CNN ve SVM yöntemi denemelerinde ise herhangi bir başarı oranı elde edilememiştir.

Her sınıf için resim sayısı azaltılarak elde edilen sonuçlar Tablo 5.3' de gösterilmektedir. Tablo 5.2'deki veri miktarı azaltılarak yeni testler yapıldığında benzer şekilde, az sayıda veri ile SNN yönteminin CNN yöntemine göre daha başarılı olduğu kanıtlanmıştır. Ayrıca, CNN modelinin 60 adet veriye kadar hiçbir sonuç üretmediği, SVM yönteminin ise bir adet veri ile güvenilir sonuç üretmediği gözlemlenmiştir. Bu nedenle tablo üzerindeki ilgili doğruluk değerleri '-' sembolü ile gösterilmiştir.

Tablo 5.3. SNN, CNN ve SVM için Küçük Boyutlu Veri Kümesi Sonuçlarının Karşılaştırması

| | Veri Adedi | SNN Doğruluk Değerleri | CNN Doğruluk Değerleri | SVM Doğruluk Değerleri |
|--------|---|------------------------|------------------------|------------------------|
| Test-1 |  | 0.580 | 0 | - |
| Test-2 |  | 0.699 | 0 | - |
| Test-3 |  | 0.658 | 0 | - |
| Test-4 |  | 0.439 | 0 | - |
| Test-5 |  | 0.819 | 0 | - |
| | 5 | 0.776 | 0 | 0.395 |
| | 10 | 0.740 | 0 | 0.387 |
| | 20 | 0.852 | 0 | 0.400 |
| | 40 | 0.816 | 0 | 0.454 |
| | 60 | 0.880 | 0.390 | 0.470 |


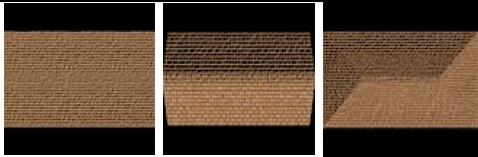


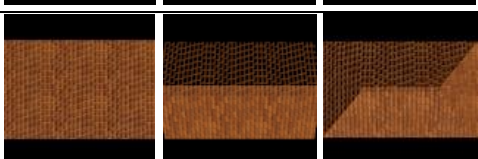
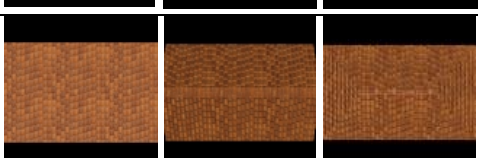
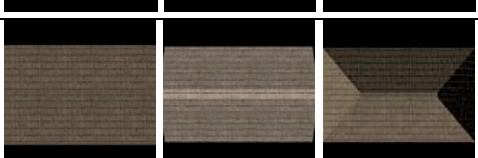

5.5. Yapay Veri Kümesi ile Eğitilen Modelin Veri Kümeleri ile Test Edilmesi ve Sonuçları

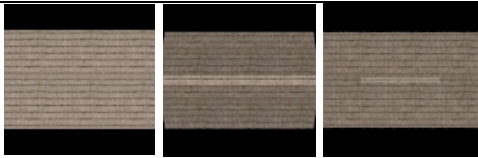

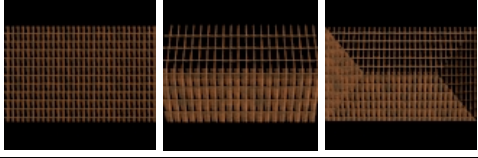
Şimdiye kadarki yapılmış testler gerçek çatı resimlerinin eğitim sürecinde kullanılması ile gerçekleştirilmiştir. Bu aşamadan sonra, Bölüm 4.1’de bahsi geçen yapay olarak üretilmiş çatı resimleri ile eğitim gerçekleştirilerek veri kümeleri üzerinde çeşitli testler yapılmıştır.

Yapay veri kümeleri ile eğitilmiş model ile yapılmış testler sonucunda; Veri Kümesi 1 ile yapılan testlerde en başarılı sonuç Tablo 5.4’te görüleceği üzere %66,1 doğruluk (accuracy) oranı

ile 10. testteki görüntü kümesi ile elde edilmiştir. Veri Kümesi 2 ile yapılan testler sonucunda ise elde edilen en yüksek sonuç %85,2 doğruluk oranı ile 1. testteki görüntü kümesi ile elde edilmiştir.

Tablo 5.4. Yapay Resim Veri Kümesi Karşılaştırması

| | Veri Türleri | | | Veri Kümesi 1 Doğruluk Değerleri | Veri Kümesi 2 Doğruluk Değerleri |
|--------|---|--|--|--|--|
| Test-1 |  | | | 0.560 | 0.852 |
| Test-2 |  | | | 0.518 | 0.808 |
| Test-3 |  | | | 0.591 | 0.782 |
| Test-4 |  | | | 0.478 | 0.586 |
| Test-5 |  | | | 0.502 | 0.741 |
| Test-6 |  | | | 0.606 | 0.730 |
| Test-7 |  | | | 0.540 | 0.589 |
| Test-8 |  | | | 0.501 | 0.814 |

| | | | |
|---------|---|--------------|-------|
| Test-9 |  | 0.489 | 0.843 |
| Test-10 |  | 0.661 | 0.761 |
| Test-11 |  | 0.523 | 0.670 |

OSL metodolojisine uygun ve SNN metodu kullanılarak gerçekleştirilen çatı tipi sınıflandırma sonuçları için Tablo 5.4'e bakıldığında Veri Kümesi 1 ile yapılan testlerde en başarılı test; 10. testteki görüntü kümesi ile %66 olarak elde edilmiştir. Alınan bu sonuca ilişkin Hata Matrisi (Confusion Matrix) Tablo 5.5'te gösterilmektedir. Tablo 5.5'teki matrise göre 4000 kez rastgele seçilen çatı tiplerinden 1274'ü teras, 1409'u beşik ve 1317 tanesi de kırma çatı tipi gelmiştir. Cohen'in Kappa Puanı ise 0.494 olarak hesaplanmış olup sınıflandırma sonuçlarının orta düzeyde uyumlu olduğu görülmektedir.

Tablo 5.5. Veri Kümesi 1 – Test 10 için Hata Matrisi

| | | Gerçek | | | Toplam |
|--------|-------|--------|-------|-------|--------|
| | | Teras | Beşik | Kırma | |
| Tahmin | Teras | 1259 | 7 | 8 | 1274 |
| | Beşik | 390 | 657 | 362 | 1409 |
| | Kırma | 301 | 288 | 728 | 1317 |
| | | 1950 | 952 | 1098 | 4000 |

Teras çatı tipi için yapılan 1274 testten 1259'u doğru sınıflandırılırken, teras çatı tipi olması gereken 7 adet veri beşik çatı tipi, 8 adet veri ise kırma çatı tipi olmak üzere toplam 15 adet veri yanlış sınıflandırılmıştır. Bu verilere göre teras çatı tipinin sınıflandırma doğruluğu yaklaşık %99 olarak hesaplanmıştır.

Beşik çatı tipi için yapılan 1409 testten 657'si doğru sınıflandırılırken, beşik çatı tipi olması gereken 390 adet veri teras çatı tipi, 362 adet veri ise kırma çatı tipi olmak üzere toplam 752 adet veri yanlış sınıflandırılmıştır. Bu verilere göre beşik çatı tipinin sınıflandırma doğruluğu yaklaşık %47 olarak hesaplanmıştır.

Kırma çatı tipi için yapılan testlerde ise 1317 testten 728'i doğru sınıflandırılırken, kırma çatı tipi olması gereken 301 adet veri teras çatı tipi, 288 adet veri ise beşik çatı tipi olmak üzere toplam 589 adet veri yanlış sınıflandırılmıştır. Bu verilere göre kırma çatı tipinin sınıflandırma doğruluğu yaklaşık %55 olarak hesaplanmıştır.

Tablo 5.5'teki verilere göre hesaplanan doğruluk (Accuracy), kesinlik (Precision) ve duyarlılık (Recall) metrikleri ise Tablo 5.6'da sunulmuştur. Bu sonuçlara göre, teras çatı tipinin doğruluk ve duyarlılık değerleri 0.99 iken kesinlik değeri 0.65, beşik çatı tipinin doğruluk ve duyarlılık değerleri 0.47 iken kesinlik değeri 0.70, kırma çatı tipinin doğruluk ve duyarlılık değerleri 0.55 iken kesinlik değeri 0.66 olarak hesaplanmıştır.

Tablo 5.6. Veri Kümesi 1 – Test 10 için Performans Değerleri

| | Doğruluk | Kesinlik | Duyarlılık |
|--------------|-----------------|-----------------|-------------------|
| Teras | 0.99 | 0.65 | 0.99 |
| Beşik | 0.47 | 0.70 | 0.47 |
| Kırma | 0.55 | 0.66 | 0.55 |

Veri Kümesi 2 ile yapılan testlerde en başarılı test; 1. testteki görüntü kümesi ile %85,2 olarak elde edilmiştir. Alınan bu sonuca ilişkin Hata Matrisi Tablo 5.7'de gösterilmektedir. Tablo 5.7'deki matrisi göre 10000 kez rastgele seçilen çatı tiplerinden 3372'si teras, 3283'u beşik ve

3345 tanesi de kırma çatı tipi gelmiştir. Ayrıca, Cohen'in Kappa Puanı 0.777 olarak hesaplanmış olup sınıflandırma sonuçlarının iyi düzeyde uyumlu olduğu anlaşılmaktadır.

Tablo 5.7. Veri Kümesi 2 – Test 1 için Hata Matrisi

| | | Gerçek | | | Toplam |
|--------|-------|--------|-------|-------|--------|
| | | Teras | Beşik | Kırma | |
| Tahmin | Teras | 3372 | 0 | 0 | 3372 |
| | Beşik | 490 | 2661 | 132 | 3283 |
| | Kırma | 742 | 116 | 2487 | 3345 |
| | | | | | 10000 |

Teras çatı tipi için yapılan 3372 testin tamamı doğru sınıflandırılmıştır. Bu verilere göre teras çatı tipinin sınıflandırma doğruluğu %100 olarak hesaplanmıştır. Beşik çatı tipi için yapılan 3283 testten 2661'i doğru sınıflandırılırken, beşik çatı tipi olması gereken 490 adet veri teras çatı tipi, 132 adet veri ise kırma çatı tipi olmak üzere toplam 622 adet veri yanlış sınıflandırılmıştır. Bu verilere göre beşik çatı tipinin sınıflandırma doğruluğu yaklaşık %81 olarak hesaplanmıştır. Kırma çatı tipi için yapılan testlerde ise 3345 testten 2487'si doğru sınıflandırılırken, kırma çatı tipi olması gereken 742 adet veri teras çatı tipi, 116 adet veri ise beşik çatı tipi olmak üzere toplam 858 adet veri yanlış sınıflandırılmıştır. Bu verilere göre kırma çatı tipinin sınıflandırma doğruluğu yaklaşık %74 olarak hesaplanmıştır.

Tablo 5.7'deki verilere göre hesaplanan doğruluk (Accuracy), kesinlik (Precision) ve duyarlılık (Recall) metrikleri ise Tablo 5.8'de sunulmuştur. Bu sonuçlara göre, teras çatı tipinin doğruluk ve duyarlılık değerleri 1 iken kesinlik değeri 0.73, beşik çatı tipinin doğruluk ve duyarlılık değerleri 0.81 iken kesinlik değeri 0.96, kırma çatı tipinin doğruluk ve duyarlılık değerleri 0.74 iken kesinlik değeri 0.96 olmuştur.

Tablo 5.8. Veri Kümesi 2 – Test 1 için Performans Değerleri

| | Doğruluk | Kesinlik | Duyarlılık |
|--------------|-----------------|-----------------|-------------------|
| Teras | 1 | 0.73 | 1 |
| Beşik | 0.81 | 0.96 | 0.81 |
| Kırma | 0.74 | 0.96 | 0.74 |

Her iki veri kümesi içinde bakıldığında Teras çatı tipinde doğruluk oranının çok yüksek olmasının sebebi teras çatı tiplerinin düz bir yüzeye sahip olması ve test resimlerinin çok fazla detay içermemesidir. Benzer şekilde, beşik ve kırma çatı resimlerinde çok fazla detay bulunması ve uydu görüntülerinin çözünürlüğünün çok yüksek olmaması gibi nedenlerden dolayı başarı oranları teras çatı tipine göre daha düşük kalmıştır.

Bu çalışma, çok fazla veriye ihtiyaç duyulmadan tek bir veri ile eğitilen modelin sınıflandırmada tatmin edici düzeyde başarı sağlayabileceğini göstermiştir.

6. SONUÇ

Bu çalışmanın temel amacı CNN tabanlı metotların çatı tipi sınıflandırması yapmak için çok fazla eğitim verisine ihtiyaç duymasının getirdiği zorluklara çözüm bulmaktır. Çatı veri kümesi üretiminin zorlu bir süreç olması nedeniyle yapay bir veri kümesi üretimi gerçekleştirilmiştir. Model eğitimi aşamasında kullanılacak yapay verinin üretilmesi ve az sayıda veri ile eğitim gerçekleştirilme yönleriyle bu çalışmanın literatüre özgün bir katkı sunacağı düşünülmektedir.

Çalışma kapsamında Bir Örnekle Öğrenme metodolojisi SNN yöntemi kullanılarak önce yüksek miktardaki veri kümeleri ile denenmiş, sonrasında Bir Örnekle Öğrenme yaklaşımına uygun bir şekilde veri miktarı azaltılarak çalışmalar yapılmıştır. Aynı veri kümeleri CNN yöntemi ile de çalıştırılarak elde edilen sonuçlar karşılaştırılmıştır. CNN yaklaşımının belli bir veri miktarının altında sonuç üretmediği gözlenmiştir. OSN yaklaşımının tek bir veride bile tatmin edici sonuçlar üretebildiği kanıtlanmıştır.

Eğitilen modelin test edilmesi sırasında rastgele alınan bir resmin kendi bulunduğu sınıf dahil teras, beşik ve kırma sınıflarından alınan 3 adet rastgele resim ile karşılaştırılması sonucunda SNN yöntemi kullanılarak benzerlik oranı en yüksek olan sınıf değerlendirmeye alınmaktadır. Eğer ilk alınan resmin kendi sınıfı ile olan benzerliği diğerlerinden daha büyük bir değere sahip ise sınıflandırma doğru, daha küçük bir değere sahip ise de sınıflandırma yanlış olarak değerlendirilir. Bu aşamada benzerlik değerleri negatif çok düşük değerler olabilmektedir. Yanlış olarak kabul edilen sınıflandırmalar için benzerlik değerlerine bir eşik değer sınırı eklenmesi halinde (çok küçük negatif değerler hesaba katılmaz ise) test doğruluk oranının daha yüksek olması öngörülmektedir. Daha sonraki çalışmalarda test doğruluğu için bir eşik değeri belirlenerek daha iyi sonuçlar alınabileceği düşünülmektedir.

Yapay eğitim verileri eşliğinde kullanılan yöntemin umut verici olduğu, metodun farklı test verileri ile daha genel bir yaklaşım haline dönüştürülebileceği öngörülmektedir. Kullanılan modelin sonuçları tatmin edici olmasına rağmen, daha yüksek çözünürlüklü test verileri ile daha iyi sonuçlar alınabileceği düşünülmektedir. Daha sonraki çalışmalarda yapay veri üretiminin farklı çatı dokuları ile çeşitlendirilmesinin faydalı olabileceği değerlendirilmektedir. Ayrıca, bu tez çalışmasında önerilen metot, çatı veri kümesinin oluşturulma ve bulunma zorluğundan

kaynaklı yalnızca iki çalışma alanı üzerinde denenebilmiştir. Daha farklı veri kümeleri ile yöntemin test edilmesi takip eden çalışma konularından biri olacaktır.

KAYNAKLAR

- [1] Alidoost, F., Arefi, H., & Tombari, F. (2019). 2D image-to-3D model: Knowledge-based 3D building reconstruction (3DBR) using single aerial images and convolutional neural networks (CNNs). *Remote Sensing*, 11(19), 2219. <https://doi.org/10.3390/rs11192219>
- [2] <https://www.centuryroofing.ca/b/roofing-materials-around-the-world>, Son erişim tarihi: 20.01.2023
- [3] Buyukdemircioglu, M., Can, R., & Kocaman, S. (2021). Deep learning based roof type classification using very high resolution aerial imagery. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 43, 55-60.
- [4] Partovi, T., Fraundorfer, F., Azimi, S., Marmanis, D., & Reinartz, P. (2017). Roof Type Selection based on patch-based classification using deep learning for high Resolution Satellite Imagery. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences-ISPRS Archives*, 42(W1), 653-657, <https://doi.org/10.5194/isprs-archives-XLII-1-W1-653-2017>
- [5] Mohajeri, N., Assouline, D., Guiboud, B., Bill, A., Gudmundsson, A., & Scartezzini, J. L. (2018). A city-scale roof shape classification using machine learning for solar energy applications. *Renewable Energy*, 121, 81-93.
- [6] Tommasini, M., Bacciottini, A., & Gherardelli, M. (2019). A QGIS tool for automatically identifying asbestos roofing. *ISPRS International Journal of Geo-Information*, 8(3), 131.
- [7] Berardi, U. (2016). The outdoor microclimate benefits and energy saving resulting from green roofs retrofits. *Energy and buildings*, 121, 217-229. doi:10.1016/j.enbuild.2016.03.021.
- [8] Santamouris, M. (2014). Cooling the cities—a review of reflective and green roof mitigation technologies to fight heat island and improve comfort in urban environments. *Solar energy*, 103, 682-703. doi:10.1016/j.solener.2012.07.003.

- [9] Ng, E., Chen, L., Wang, Y., & Yuan, C. (2012). A study on the cooling effects of greening in a high-density city: An experience from Hong Kong. *Building and environment*, 47, 256-271. doi:10.1016/j.buildenv.2011.07.014.
- [10] Rowe, D. B. (2011). Green roofs as a means of pollution abatement. *Environmental pollution*, 159(8-9), 2100-2110.
- [11] Francis, R. A., & Lorimer, J. (2011). Urban reconciliation ecology: the potential of living roofs and walls. *Journal of environmental management*, 92(6), 1429-1437. doi:10.1016/j.jenvman.2011.01.012.
- [12] <https://engineeringdiscoveries.com/different-types-of-roofs/>, Son erişim tarihi: 20.01.2023
- [13] https://en.wikipedia.org/wiki/Flat_roof, Son erişim tarihi: 20.01.2023
- [14] <https://en.wikipedia.org/wiki/Gable>, Son erişim tarihi: 20.01.2023
- [15] https://en.wikipedia.org/wiki/Hip_roof, Son erişim tarihi: 20.01.2023
- [16] Castagno, J., & Atkins, E. (2018). Roof shape classification from LiDAR and satellite image data fusion using supervised learning. *Sensors*, 18(11), 3960.
- [17] Assouline, D., Mohajeri, N., & Scartezzini, J. L. (2017, October). Building rooftop classification using random forests for large-scale PV deployment. In *Earth resources and environmental remote Sensing/GIS Applications VIII (Vol. 10428, pp. 47-58)*. SPIE.; <https://doi.org/10.1117/12.2277692>
- [18] Axelsson, M., Soderman, U., Berg, A., & Lithen, T. (2018, April). Roof type classification using deep convolutional neural networks on low resolution photogrammetric point clouds from aerial imagery. In *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1293-1297). IEEE.; doi: 10.1109/ICASSP.2018.8461740.

- [19] Zang, A., Zhang, X., Chen, X., & Agam, G. (2015, May). Learning-based roof style classification in 2D satellite images. In *Geospatial Informatics, Fusion, and Motion Video Analytics V* (Vol. 9473, pp. 166-176). SPIE.; <https://doi.org/10.1117/12.2180393>
- [20] Kim, J., Bae, H., Kang, H., & Lee, S. G. (2021). CNN algorithm for roof detection and material classification in satellite images. *Electronics*, 10(13), 1592.
- [21] Bromley, J., Guyon, I., LeCun, Y., Säckinger, Eduard, & Shah, R., 1993. Signature Verification Using a "Siamese" Time Delay Neural Network, in: *Proceedings of the 6th International Conference on Neural Information Processing Systems*, Morgan Kaufmann Publishers Inc., San Francisco, CA, USA. pp.737–744.
- [22] Koch, G., Zemel, R., & Salakhutdinov, R. (2015, July). Siamese neural networks for one-shot image recognition. In *ICML deep learning workshop* (Vol. 2, p. 0).
- [23] Hsiao, S. C., Kao, D. Y., Liu, Z. Y., & Tso, R. (2019). Malware image classification using one-shot learning with siamese networks. *Procedia Computer Science*, 159, 1863-1871.
- [24] Zhang, P., Bai, Y., Wang, D., Bai, B., & Li, Y. (2021). Few-shot classification of aerial scene images via meta-learning. *Remote Sensing*, 13(1), 108.
- [25] Chakrapani Gv, A., Chanda, S., Pal, U., & Doermann, D. (2019, November). One-shot learning-based handwritten word recognition. In *Asian Conference on Pattern Recognition* (pp. 210-223). Springer, Cham.
- [26] Varghese, D., Bauer, R., Baxter-Beard, D., Muggleton, S., & Tamaddoni-Nezhad, A. (2021, October). Human-like rule learning from images using one-shot hypothesis derivation. In *International Conference on Inductive Logic Programming* (pp. 234-250). Springer, Cham.
- [27] He, H., Zhou, J., Chen, M., Chen, T., Li, D., & Cheng, P. (2019). Building extraction from UAV images jointly using 6D-SLIC and multiscale Siamese convolutional networks. *Remote Sensing*, 11(9), 1040.

- [28] Wang, C., Huang, C., Zhu, X., & Zhao, L. (2022). One-Shot Retail Product Identification Based on Improved Siamese Neural Networks. *Circuits, Systems, and Signal Processing*, 1-15.
- [29] Yang, L., Chen, Y., Song, S., Li, F., & Huang, G. (2021). Deep Siamese networks-based change detection with remote sensing images. *Remote Sensing*, 13(17), 3394.
- [30] Paladini, E., Vantaggiato, E., Bougourzi, F., Distante, C., Hadid, A., & Taleb-Ahmed, A. (2021). Two ensemble-CNN approaches for colorectal cancer tissue type classification. *Journal of Imaging*, 7(3), 51.
- [31] Vapnik, V., & Vapnik, V. (1998). *Statistical learning theory* Wiley. New York, 1(624), 2.
- [32] Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE transactions on neural networks*, 10(5), 988-999.
- [33] Mantero, P., Moser, G., & Serpico, S. B. (2005). Partially supervised classification of remote sensing images through SVM-based probability density estimation. *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 559-570.
- [34] Burges, C. J. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121-167.
- [35] Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis*. John Wiley & Sons.
- [36] Geman, S., Bienenstock, E., & Doursat, R. (1992). Neural networks and the bias/variance dilemma. *Neural computation*, 4(1), 1-58.
- [37] Guyon, I., Vapnik, V., Boser, B., Bottou, L., & Solla, S. A. (1992, January). Capacity control in linear classifiers for pattern recognition. In *11th IAPR International Conference on Pattern Recognition. Vol. II. Conference B: Pattern Recognition Methodology and Systems (Vol. 1, pp. 385-386)*. IEEE Computer Society.

- [38] Zhu, G., & Blumberg, D. G. (2002). Classification using ASTER data and SVM algorithms: The case study of Beer Sheva, Israel. *Remote sensing of Environment*, 80(2), 233-240.
- [39] Kavzoglu, T., & Colkesen, I. (2009). A kernel functions analysis for support vector machines for land cover classification. *International Journal of Applied Earth Observation and Geoinformation*, 11(5), 352-359.
- [40] Foody, G. M., & Mathur, A. (2004). A relative evaluation of multiclass image classification by support vector machines. *IEEE Transactions on geoscience and remote sensing*, 42(6), 1335-1343.
- [41] Bazi, Y., & Melgani, F. (2006). Toward an optimal SVM classification system for hyperspectral remote sensing images. *IEEE Transactions on geoscience and remote sensing*, 44(11), 3374-3385.
- [42] Ghosh, A., Sufian, A., Sultana, F., Chakrabarti, A., & De, D. (2020). Fundamental concepts of convolutional neural network. In *Recent trends and advances in artificial intelligence and Internet of Things* (pp. 519-567). Springer, Cham.
- [43] Hubel, D. H., & Wiesel, T. N. (1968). Receptive fields and functional architecture of monkey striate cortex. *The Journal of physiology*, 195(1), 215-243.
- [44] LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- [45] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25.
- [46] Zeiler, M. D., & Fergus, R. (2014, September). Visualizing and understanding convolutional networks. In *European conference on computer vision* (pp. 818-833). Springer, Cham.
- [47] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.

- [48] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., & Rabinovich, A. (2015). Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 1-9).
- [49] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 770-778).
- [50] Phung, V. H., & Rhee, E. J. (2018). A deep learning approach for classification of cloud image patches on small datasets. *Journal of information and communication convergence engineering*, 16(3), 173-178.
- [51] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4700-4708).
- [52] <https://github.com/loosgagnet/Building-detection-and-roof-type-recognition>, Son erişim tarihi: 20.01.2023
- [53] <https://towardsdatascience.com/one-shot-learning-with-siamese-networks-using-keras-17f34e75bb3d> , Son erişim tarihi: 20.01.2023
- [54] <https://www.autodesk.com/products/maya/overview>, Son erişim tarihi: 20.01.2023
- [55] <https://www.openstreetmap.org/export#map=16/32.7176/-117.1554>, Son erişim tarihi: 20.01.2023
- [56] <https://www.qgis.org/>, Son erişim tarihi: 20.01.2023
- [57] <https://www.google.com/maps>, Son erişim tarihi: 20.01.2023
- [58] Landis, J. R., & Koch, G. G. (1977). The measurement of observer agreement for categorical data. *biometrics*, 159-174.

EKLER

EK 1: TEZ ÇALIŞMASI KAPSAMINDA YAYIMLANAN MAKALENİN KÜNYE BİLGİLERİ

MAKALE

N. Ölçer, D. Ölçer ve E. Sümer, "Roof Type Classification with Innovative Machine Learning Approaches," *PeerJ Computer Science*, 9: e1217, 2023 (SCI-E) <https://doi.org/10.7717/peerj-cs.1217>

EK 2: KAPPA DEĞERLERİ İÇİN YORUMLAMA TABLOSU[58]

| Kappa değeri | Yorum |
|--------------|--|
| <0 | Şansa bağlı olabilecek uyumdan daha kötü bir uyum olması |
| 0.01 — 0.20 | Önemsiz düzeyde bir uyum olması |
| 0.21 — 0.40 | Zayıf düzeyde bir uyum olması |
| 0.41 — 0.60 | Orta düzeyde bir uyum olması |
| 0.61 — 0.80 | İyi düzeyde bir uyum olması |
| 0.81 — 1.00 | Çok iyi düzeyde bir uyum olması |