



T.C.
KONYA TEKNİK ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME ALGORİTMALARI
KULLANARAK UYDU GÖRÜNTÜLERİ
ZENGİNLEŞTİRME

Semih KAHVECİ

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Kasım-2020
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Semih KAHVECİ tarafından hazırlanan “Derin Öğrenme Algoritmaları Kullanarak Uydu Görüntüleri Zenginleştirme.” adlı tez çalışması 27/11/2020 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Doç.Dr. Erdiñç AVAROĞLU

Danışman

Doç.Dr. İsmail BABAOĞLU

Üye

Dr.Öğr.Üyesi Alper KILIÇ

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Saadettin Erhan KESEN
Enstitü Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Semih KAHVECİ
27/11/2020

ÖZET

YÜKSEK LİSANS TEZİ

DERİN ÖĞRENME ALGORİTMALARI KULLANARAK UYDU GÖRÜNTÜLERİ ZENGİNLEŞTİRME

Semih KAHVECİ

**Konya Teknik Üniversitesi
Lisansüstü Eğitim Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı**

Danışman: Doç. Dr. İsmail BABAÖĞLU

2020, 67 Sayfa

Jüri

**Danışman Doç.Dr. İsmail BABAÖĞLU
Doç.Dr. Erdiñ AVAROĞLU
Dr.Öğr. Üyesi Alper KILIÇ**

Günümüzde sivil savunma operasyonları, maden arama çalışmaları, tarımsal üretim ve coğrafi bilgi sistemleri gibi birçok alan için uydu görüntülerinden elde edilen bilgiler kullanılmaktadır. Görüntülerin çözünürlüğü ve bulundurduğu bileşenlerin detay seviyeleri elde edilen bilgilerin doğruluğunda ve kullanılabilirliğinde önemli etkindir. Bu nedenle görüntülerin çözünürlüğü ve kalitesini arttırmak için literatürde birçok görüntü zenginleştirme algoritması geliştirilmiştir. Görüntü zenginleştirme algoritmaları düşük çözünürlüklü görüntüyü belli işlemlerden geçirerek içerdiği bileşenlerin seviyesini ve görüntünün çözünürlüğünü artırma işlemi olup günümüzde daha çok süper çözünürlük olarak bilinmektedir. Son zamanlarda popüler olarak çalışılan alanlardan biri olan derin öğrenme, süper çözünürlük problemlerinde de yüksek performans göstermektedir. Bu sebeple, derin öğrenme tabanlı süper çözünürlük algoritmaları son zamanlarda en çok araştırılan alan olmuştur. Bu tez çalışmasında derin öğrenme tabanlı süper çözünürlük algoritmaları kullanılarak düşük çözünürlüklü uydu görüntülerinden yüksek çözünürlüklü görüntüler elde edilmiştir. Ayrıca süper çözünürlük için yeni bir derin öğrenme tabanlı algoritma önerilmiştir. Önerilen algoritma, diğer algoritmalarla referanslı görüntü kalite ölçüm metrikleri ile kıyaslanmış olup elde edilen sonuçlar değerlendirilmiştir.

Anahtar Kelimeler: Derin öğrenme, Süper çözünürlük, Uydu görüntüleri, Görüntü zenginleştirme

ABSTRACT

MS THESIS

ENHANCEMENT OF SATELLITE IMAGES USING DEEP LEARNING ALGORITHMS

Semih KAHVECİ

**Konya Technical University
Institute of Graduate Studies
Department of Computer Engineering**

Advisor: Assoc. Prof. İsmail BABAÖĞLU

2020, 67 Pages

Jury

**Advisor Assoc. Prof. İsmail BABAÖĞLU
Assoc. Prof. Erdiñç AVAROĞLU
Assists. Prof. Alper KILIÇ**

Today, the information obtained by satellite images is used in many areas such as civil defense operations, mineral exploration, agricultural production and geographical information systems. The accuracy and usability of the information obtained from the images are related to the resolution of the image and the detail levels of the components. For this reason, many image enhancement algorithms have been developed in literature to increase the resolution and quality of the images. Image enhancement algorithms are the process of increasing the level of components and resolution of the image by processing low resolution image, and today it is more known as super resolution. Deep learning, one of the most popular areas of study recently, also shows high performance in super resolution problems. For this reason, deep learning based super resolution algorithms have been the most researched area recently. In this thesis, high resolution satellite images were obtained by using deep learning based super resolution algorithms developed to increase the quality and resolution of satellite images obtained using existing imaging equipment. In addition, a new deep learning based algorithm has been proposed for super resolution. The proposed algorithm was compared with image quality measurement metrics referenced with other algorithms and the results obtained were evaluated.

Keywords: Image enhancement, Deep learning, Super resolution, Satellite images,

ÖNSÖZ

Hava araçları ve uydular aracılığı ile fiziksel bir temas olmadan elde edilen uydu görüntüleri tanıma, teşhis ve tespit gibi askeri uygulamalar, düşman saldırılarına, doğal afetlere ve büyük yangınlara karşı can ve mal kaybını en aza indirilmesi için gerçekleştirilen sivil savunma operasyonları ile doğal afetlerde zarar görecektir olan yerleşim yerlerinin öngörülmesi veya riskli bölgelerin belirlenmesi, arazilerin parsel bölünmesi gibi coğrafi bilgi sistemlerinin yanında birçok alanda bilgi edinmek gayesiyle kullanılmaktadır. Bu nedenle kullanılacak görüntülerin çözünürlüğü ve kalitesinin yükseltilmesi daha doğru ve sağlıklı bilgi edinmeyi sağlayacaktır. Bu alanda yazılım tabanlı çözümlerin kullanılması uydu görüntülerinin çözünürlüğünün ve kalitesinin artırılmasına katkı sağlayacaktır.

Bu çalışmada görüntü zenginleştirmede kullanılan eski yöntemler ile yeni teknoloji süper çözünürlük algoritmaları arasında bir karşılaştırma yapılmaya çalışılmıştır. Ayrıca başarılı bir derin öğrenme algoritması süper çözünürlük algoritması olarak uyarlanmıştır.

Tez çalışmamda planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın danışman hocam Doç.Dr. İsmail BABOĞLU' na, yüksek lisans eğitimim boyunca maddi ve manevi desteğini esirgemeyen değerli Babam Prof.Dr. Nuri KAHVECİ' ye, değerli eşim Songül KAHVECİ' ye ve aileme sonsuz teşekkürlerimi sunarım.

Semih KAHVECİ
KONYA-2020

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	iv
ÖNSÖZ	iv
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR	iv
1. GİRİŞ	5
1.1. Tezin Önemi ve Amacı	6
1.2. Tezin Organizasyonu	7
2. KAYNAK ARAŞTIRMASI	8
2.1. Uydu Görüntüleri	8
2.2. Süper Çözünürlük.....	8
2.2.1. Enterpolasyon Tabanlı Yaklaşımlar.....	9
2.2.2. Yeniden Yapılandırma Tabanlı Yaklaşımlar	10
2.2.3. Öğrenme Tabanlı Yaklaşımlar.....	11
2.2.3.1. Derin öğrenme tabanlı yaklaşımlar	11
2.2.3.2. Doğrusal Ağlar (Lineer Networks).....	12
2.2.3.3. Artık Ağlar (Residual Network- ResNet).....	13
3. MATERYAL ve YÖNTEM	15
3.1. Veri Kümeleri.....	15
3.2. Süper Çözünürlük.....	15
3.2.1. Enterpolasyon Tabanlı Yöntemler	16
3.2.1.1. En Yakın Komşu (Neares Neighbor- NN)	17
3.2.1.2. Bilinear Enterpolasyon	17
3.2.1.3. Bikubik Enterpolasyon	17
3.2.2. Yeniden Yapılandırma Tabanlı Yöntemler.....	18
3.2.3. Öğrenme Tabanlı Yöntemler	19
3.3. Derin Öğrenme.....	20
3.3.1. Evrişimsel Sinir Ağları (ESA)	20
3.3.1.1. Evrişim Katmanı (Konvolüsyon)	21
3.3.1.2. Doğrultulmuş Doğrusal Ünite (Rectified Lineer Unit - Relu).....	22
3.3.2. Artık Ağları (Residual Network- ResNet)	23
3.3.2.1. Artık Öğrenmesi	24
3.3.2.2. Kısayol bağlantısı	25
3.4. Süper Çözünürlük için Derin Öğrenme.....	25
3.4.1. VDSR.....	25
3.5. Süper Çözünürlük için Artık Ağlar	26
3.5.1. Süper Çözünürlük için Geliştirilmiş Derin Artık Ağları (Enhanced Deep Super Resolution - EDSR).....	27

3.5.1.1.	Artık Birim	27
3.5.1.2.	Tek Ölçekli Model.....	28
3.5.1.3.	Çok Ölçekli Model	29
3.5.2.	Süper Çözünürlük için Derin Piramit Artık Ağı.....	30
3.5.2.1.	Alt-Piksel Evrişim Katmanı	33
4.	ARAŞTIRMA BULGULARI VE TARTIŞMA	34
4.1.	Veri Kümesi Üzerinde Yapılan İşlemler.....	34
4.2.	Referanslı Görüntü Kalite Metrikleri	34
4.3.	Eğitim Parametreleri ve Sonuçları	35
5.	SONUÇLAR ve ÖNERİLER.....	55
KAYNAKLAR		57



SİMGELER VE KISALTMALAR

Simgeler

μ	:	Yerel Ortalama
σ	:	Standart Sapma
α	:	Artış Katsayısı
β	:	Beta Katsayısı
I^{LR}	:	Yüksek Çözünürlüklü Görüntü
I^{HR}	:	Düşük Çözünürlüklü Görüntü

Kısaltmalar

SR	:	Süper Çözünürlük
HR	:	Yüksek Çözünürlük
LR	:	Düşük Çözünürlük
MLP	:	Çok Katmanlı Algılayıcı
SRCNN	:	Süper Çözünürlük Evrişimli Sinir Ağları
FSRCNN	:	Hızlı Süper Çözünürlük Evrişimli Sinir Ağları
VDSR	:	Süper Çözünürlük için Çok Derin Evrişimli Sinir Ağları
ESPCN	:	Etkili Alt Piksel Evrişimli Sinir Ağı
ResNet	:	Derin Artık Ağları
SRResNet	:	Süper Çözünürlük için Derin Artık Ağları
ILSVRC	:	ImageNet Büyük Ölçekli Görsel Tanıma Yarışması
EDSR	:	Süper Çözünürlük için Geliştirilmiş Artık Ağları
NTIRE	:	Görüntü Restorasyon ve İyileştirmede Yeni Trendler Atölyesi
ESA	:	Evrişimli Sinir Ağları
CNN	:	Evrişimli Sinir Ağları
RGB	:	Kırmızı Yeşil Mavi
ReLU	:	Doğrultulmuş Doğrusal Birim
MSE	:	Ortalama Kareysel Hata
PSNR	:	Tepe Sinyal-Gürültü Oranı
SSIM	:	Yapısal Benzerlik İndeksi Ölçüsü
Conv	:	Konvolüsyon Katmanı
BN	:	Toplu Normalleştirme Katmanı

1. GİRİŞ

Uydu görüntüleri uzaktan algılama uyduları tarafından dijital olarak elde edilmektedir ve bu görüntüler Dünya'nın geniş bir perspektifini, arazinin topoğrafik yapısını, doğal kaynaklarını ve insanların dünya üzerindeki etkilerini sunmaktadır. Uydu görüntülerinden elde edilen bilgiler; tanıma, teşhis ve tespit gibi askeri uygulamalar, düşman saldırılarına, doğal afetlere ve büyük yangınlara karşı can ve mal kaybını en aza indirilmesi için gerçekleştirilen sivil savunma operasyonları ile doğal afetlerde zarar görebilecek olan yerleşim yerlerinin öngörülmesi veya riskli bölgelerin belirlenmesi gibi kullanıldığı alanlar ile değerini belli etmektedir.

Dijital görüntü gerçekte var olan bir nesneye ait bir resmin sayısal bilgisayar verisine dönüştürülmüş halidir. Dijital görüntü yan yana sıralanmış çok küçük kare şeklindeki elemanların birleşiminden oluşmuştur. Görüntüde bulunan bu küçük kareler piksel olarak tanımlanır ve piksellerin yoğunluğuna göre görüntüler düşük çözünürlüklü görüntü veya yüksek çözünürlüklü görüntü olarak incelenmektedir. Yüksek çözünürlüklü görüntüler düşük çözünürlüklü görüntülere kıyasla daha ince detaylar ve daha fazla piksel sayısı içermektedir. Başka bir ifade ile düşük çözünürlüklü görüntüler içeriğinde yüksek frekanslı bilgiler bulundurmamaktadır. Bu nedenle dijital görüntü uygulamalarında görüntülerin analizi için yüksek çözünürlüklü görüntüler daha çok tercih edilmektedir.

Günümüzde kullanılan uzaktan algılama uydularında bulunan sensörler ve uydular ile veri alışverişi gerçekleştiren bilgisayarlar arasından bulunan iletişim bant genişliği sınırlamaları nedeniyle genellikle elde edilen uydu görüntülerin çözünürlüğü düşük olmaktadır (Lu ve ark., 2019). Elde edilen görüntüler; uydu görüntüleri analizi gereksinimlerini karşılayamadığı için yüksek çözünürlüklü görüntülere ihtiyaç duyulmaktadır. Görüntülerin yüksek çözünürlükte elde edilebilmesi düşünüldüğünde akla ilk olarak kullanılan ekipmanların güncellenmesi başka bir ifade ile donanımsal tabanlı çözümler gelmektedir. Ancak söz konusu uydu görüntüleri olduğu zaman donanım tabanlı çözümlerde, fırlatılmış olan uydu ekipmanlarının güncellenmesinin imkansızlığı ve bu ekipmanların oldukça pahalı olması gibi bazı dezavantajları bulunmaktadır. Bu nedenle donanım maliyetlerinden ödün vererek donanımdaki bir güncellemeye kıyasla çok daha az maliyet ve zaman gerektiren yazılım tabanlı çözümlerin kullanılması zamandan tasarruf sağlarken ekonomik olarak da kazanç sağlamaktadır.

Yazılım tabanlı çözümler görüntünün içeriğini zenginleştiren görüntü zenginleştirme algoritmalarıdır. Görüntü zenginleştirme algoritmalarındaki temel fikir düşük çözünürlüklü görüntüyü bir dizi işlemde geçirerek yüksek çözünürlüklü bir görüntü elde etmektir. Günümüzde yüksek çözünürlüklü görüntü elde etmek için görüntüye uygulanan bu işlemler Görüntü Süper Çözünürlük algoritmaları olarak tanımlanmaktadır (Singh & Singh, 2020). Görüntü süper çözünürlük kavramı temelde yüksek çözünürlüklü görüntü gereksinimlerini esas alarak düşük çözünürlüklü görüntüden daha ince detaylar içeren yüksek çözünürlüklü görüntü elde etmeyi amaçlayan algoritmaları ifade etmektedir. Başka bir ifade ile Görüntü süper çözünürlük algoritmaları düşük çözünürlüklü görüntüden, sanki yüksek çözünürlüğe sahip bir sensör yardımıyla alınmış gibi ince detaylar içeren yüksek çözünürlüklü görüntü elde etmeyi amaçlamaktadır (Fernandez-Beltran ve ark., 2017). Bu algoritmalar bilgisayarla görmede görüntü ve videoların çözünürlüğünü arttırmak için kullanılan önemli görüntü işleme algoritmaları sınıfındadır. Görüntü süper çözünürlük algoritmalarından elde edilen yüksek çözünürlüklü görüntüler yüksek tanımlı televizyon (HDTV), medikal görüntüleme, uydu görüntüleme ve gözetim sistemleri gibi birçok gerçek dünya uygulamasında başarılı bir şekilde kullanılmaktadır. Görüntü SÇ herhangi bir düşük çözünürlüklü görüntü girişi için çok sayıda çözüm üretir ve bu çözümler için temelde enterpolasyon tabanlı, yeniden yapılandırma tabanlı, öğrenme tabanlı ve hibrit yöntemler olarak dört grup altında birçok algoritma önerilmiştir (Singh & Singh, 2020).

1.1. Tezin Önemi ve Amacı

Uydu görüntülerinden elde edilen veriler maden arama işlerinin ön fizibilite ve fizibilite çalışmalarında, olabilecek doğal afetler için risk değerlendirmesinde, dünyadaki nüfus artışına paralel olarak artan tarımsal üretim ihtiyacı ile dünyanın tarımsal kaynaklarının uygun bir şekilde yönetilmesi hususunda önemli bilgiler sağlamaktadır. Verilerin detayını ve doğruluğunu arttırmak için söz konusu alanlarda yüksek çözünürlüklü görüntüler tercih edilmektedir. Uydu görüntülerini yüksek çözünürlük seviyesine çıkartarak görüntülerden elde edilen verilerin kalitesini ve doğruluğunu arttırmak için bugüne kadar birçok yazılım tabanlı çalışma yapılmış ve farklı yöntemler geliştirilmiştir.

Son yıllarda artan bir popülerliğe sahip olan derin öğrenme nesne tanıma, doğal dil işleme, nesne çıkarımı ve benzeri uygulamalarla birçok alanda başarısını ispat etmiştir.

Derin öğrenme algoritmalarının süper çözünürlük problemlerine uygulanması ile görüntü zenginleştirme problemlerinde de derin öğrenme algoritmaları başarı göstermiş olup günümüzde süper çözünürlük algoritmalarının en popüler şekilde araştırılan ve geliştirilen alt dalı haline gelmiştir. Süper çözünürlüğe uyarlanan derin öğrenme algoritmaları ile görüntünün çözünürlüğü artırılırken aynı zamanda görüntüde daha ince detaylar elde edilmektedir.

Bu tez çalışması uydu görüntüleri zenginleştirme işlemini bir süper çözünürlük problemi olarak ele almış olup derin öğrenme tabanlı süper çözünürlük yöntemlerini uygulayarak daha ince detaylara sahip yüksek çözünürlüklü uydu görüntüleri elde edilmesi amacı üzerine yapılmıştır. Aynı zamanda bu çalışma daha önce farklı bilgisayarla görme problemlerinde önemli başarı elde etmiş yeni bir derin öğrenme algoritmasının süper çözünürlük problemine uyarlamayı da amaçlamaktadır.

1.2. Tezin Organizasyonu

Bu tez çalışması beş farklı bölümden oluşmakta olup bölümlerin içeriği ve sırası şu şekildedir.

Birinci bölüm giriş bölümü olup bu bölümde uydu görüntülerinin kullanım alanları ve öneminden, uydu görüntüleri zenginleştirme işleminin süper çözünürlük ile ilişkilendirilmesinden, tezin amacından ve öneminden bahsedilmiştir.

İkinci bölüm kaynak araştırması bölümü olup süper çözünürlük yöntemlerinin geçmişte ve günümüzde kullanılan popüler yöntemlerinden ve uydu görüntüleri zenginleştirilmesi ile ilgili yapılmış daha önceki çalışmalardan bahsedilmiştir.

Üçüncü bölüm materyal ve yöntem bölümü olup süper çözünürlük kavramından, çalışmada kullanılacak yöntemlerden ve çalışmada önerdiğimiz yöntemden bahsedilmiştir.

Dördüncü bölüm araştırma bulguları ve tartışma bölümü olup çalışma için kullanılan veri setinden, yapılan çalışmaların sonuçlarından ve bu sonuçları önceki sonuçlarla kıyaslamak için kullanılan ölçüm metriklerinden bahsedilmiştir.

Beşinci bölüm Sonuç ve öneriler bölümü olup tezin son bölümüdür. Bu bölümde yapılan çalışmanın genel değerlendirilmesi yapılmış olup çalışmanın konusu ile ilgili araştırmacılara yeni öneriler verilmiştir.

2. KAYNAK ARAŞTIRMASI

Bu bölümde literatürde bulunan ve tezin oluşmasında yararlanılan kaynaklar verildi. İlk önce uydu görüntülerinin zenginleştirilmesi üzerine yapılan çalışmalar incelendi. Sonrasında ise geçmişten günümüze popüler olarak kullanılan süper çözünürlük algoritmaları, derin öğrenme tabanlı süper çözünürlük algoritmaları ve güncellenen versiyonları incelendi.

2.1. Uydu Görüntüleri

Literatürde uydu görüntülerinin çözünürlüğünü arttırmak için farklı dalgacık algoritmaları ve sürü zekâsı algoritmalarının kullanıldığı çalışmalar bulunmaktadır. (Sharma & Khunteta, 2016) Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform - DWT) tekniğini kullanarak giriş görüntüsünü dört farklı frekans alt bandın ayırmış ve yüksek frekanslı alt bant görüntülerine enterpolasyon işlemi uygulayarak uydu görüntülerini zenginleştirmiştir. Enterpolasyon işlemi sırasında düşük çözünürlüklü görüntüde yüksek frekanslı bileşenler kaybolmaktadır. Bu kaybolma problemini çözmek için (Naik & Gharge, 2016) Çift Ağaç Karmaşık Dalgacık Dönüşümü ve döndürülmüş versiyonuna dayanan yeni bir algoritma dönüşümü kullanmıştır. Uydu görüntülerinin kontrast değerini arttırmak için sürü zekâsı, guguklu arama ve yapay arı kolonisi algoritmaları kullanılmıştır (Singh ve ark., 2016). Babaoğlu ve ark. Evrişimli sinir ağlarını kullanarak tasarladıkları model mimarisi ile düşük çözünürlüklü uydu görüntülerinden gelişmiş görüntüler elde etmeyi amaçlamışlardır. Elde ettikleri sonuçlar göre bilinen bilinear, bikubik ve lanczos3 enterpolasyon yöntemlerinden ve Süper çözünürlüklü evrişimli sinir ağı (SRCNN)'den daha üstün performans göstermektedir (Babaoğlu ve ark., 2019).

2.2. Süper Çözünürlük

Görüntü Süper çözünürlük yöntemlerin fonksiyonel işlevlerine göre dört farklı bölüme ayrılır. Literatürde her bölüm için birbirinden farklı algoritmalar bulunmaktadır. Bu başlık altında söz konusu bölümler için gruplar halinde önerilen algoritmalar incelenmiş ve sunulmuştur.

2.2.1. Enterpolasyon Tabanlı Yaklaşımlar

Tek görüntü süper çözünürlük algoritmaları enterpolasyon tabanlı, yeniden yapılandırma tabanlı, öğrenme tabanlı ve hibrit yaklaşımlar olarak alt bölümlere ayrılmaktadır. Görüntü enterpolasyon işlemi, görüntü işlemedeki temel işlemlerdir. Enterpolasyon tabanlı süper çözünürlük yöntemleri düzgün bir çekirdek işlevi kullanarak yüksek çözünürlüklü görüntüyü düşük çözünürlüklü görüntüden enterpole etmektedir. Literatürde kullanılan birçok enterpolasyon yöntemleri mevcuttur. Enterpolasyon teknikleri temelde görüntünün içeriğindeki özellikleri dikkate almadan direk olarak pikselleri işleme almaktadır. En yakın komşu (Nearest Neighbor), İki doğrulu (Bilinear), Bikubik bilinen Enterpolasyon yöntemleridir. En yakın komşu enterpolasyon tekniği bilinen en yakın komşu piksel değerlerinin çevirisini içerir. Görüntü ne kadar yüksek çözünürlükte piksel değerlerine sahipse yöntemde o kadar iyi sonuç vermektedir. Ancak görüntünün kenarındaki bazı bilgiler kaybolmaktadır (Franke, 1982). İki doğrulu enterpolasyon yöntemi yeni piksel değerini oluştururken her iki tarafında bulunan piksel değerlerinin ortalama değerlerinden faydalanır ve yöntemin uygulanması kolaydır (Allebach & Wong, 1996). Bu teknik en yakın komşu tekniğinden daha iyi sonuç vermektedir ve bikubik enterpolasyon tekniğine kıyasla daha az hesaplama zamanı gerektirmektedir. Bikubik enterpolasyon yöntemi en yakın piksellerin ağırlıklı ortalamasını kullanmaktadır. Bu yöntem diğer enterpolasyon yöntemlerine kıyasla daha iyi sonuç verir ancak daha fazla hesaplama zamanı almaktadır. Zamanda kısıtlama bulunmadığı durumlarda bikubik enterpolasyon yöntemi daha çok tercih edilmektedir (Fritsch & Carlson, 1980). Li tarafından doğal görüntüler için düşük hesaplama zamanına sahip karmaşık kenar odaklı enterpolasyon algoritması önerilmiştir. Bu yöntemde düşük çözünürlüklü görüntüden önce kovaryans katsayıları tahmin edilmiş ve daha sonra bu tahminler düşük çözünürlüklü kovaryans ile yüksek çözünürlüklü kovaryans arasındaki geometrik ikiliğe dayanarak görüntüyü daha yüksek çözünürlüğe ulaştırmak için kullanılmıştır (Li & Orchard, 2001). Zhang ve Wu (2006) kenar keskinliğini korumak ve sahte sinyal olarak görünen yapay öğeleri azaltmak için yeni kenar odaklı doğrusal olmayan enterpolasyon yöntemi önermiştir. Zhang bu yöntemde doğrusal minimum ortalama kare hatası tekniğinden yararlanmıştır (Zhang & Wu, 2006).

2.2.2. Yeniden Yapılandırma Tabanlı Yaklaşımlar

Enterpolasyon tabanlı süper çözünürlük yöntemleri pürüzsüz alanlarda başka bir ifade ile düşük frekanslı bilgilerin bulunduğu bölgelerde iyi performans göstermektedir ancak yüksek frekanslı bilgilerin bulunduğu bölgelerde ve görüntünün kenarlarında performansları düşmektedir. Sonuç olarak enterpolasyon tabanlı süper çözünürlük yöntemlerinin kapasitesi sınırlıdır. Yeniden yapılandırma tabanlı süper çözünürlük yaklaşımları düşük çözünürlüklü görüntüyü enterpolasyon yöntemleri ile ölçeklendirir ve daha sonra, giriş görüntüsünde bulunan ayrıntıları ölçeklendirilmiş görüntüde sağlamak için görüntüyü yeniden yapılandırmaktadır. Bu yöntemler netleştirme(debluring) ve gürültü giderme (denoising) problemlerini çözmektedir ve enterpolasyon yöntemlerinin kapasitelerinin üzerinde performans sağlamaktadır (Deshpande & Patavardhan, 2019). Deshpande, uzun menzilli yakalanan iris polar görüntülerini geliştirmek için iteratif geri projeksiyon ve gelişmiş iteratif geri projeksiyon yöntemlerini geliştirmiştir. Yeniden yapılandırma tabanlı bu yöntemler alandaki öncü çalışmalardan bazılarıdır (Deshpande & Patavardhan, 2016). Gözlemlenen düşük çözünürlüklü görüntüler ile simüle edilmiş düşük çözünürlüklü görüntüler arasındaki hatanın yüksek çözünürlüklü görüntüyü tahmin etmek için kullanıldığı Irani ve Peleg tarafından yinelemeli geri projeksiyon algoritması önerilmiştir (Irani & Peleg, 1991). Shan ve ark. tarafından geliştirilmiş olan nokta yayılma fonksiyonu (Point-spread function - PSF) dekonvolüsyonuna dayanan süper çözünürlük yöntemi, ölçek büyütme problemini netleştirme açısından ele almaktadır. PSF dekonvolüsyonu 3 fazın bir araya gelmesi ile oluşmaktadır. İlk aşamada görüntü istenilen ölçeğe enterpole edilmektedir. İkinci aşama da PSF tahmini gerçekleştirilmektedir. Son aşamada ise elde edilen tahminler dekonvolüsyon yöntemi ile süper çözülmüş görüntüyü oluşturmada kullanılmaktadır (Shan ve ark., 2008). Diğer bir yeniden yapılandırma tabanlı gradyan profili (Gradient Profile GP) yöntemi Jian ve ark. tarafından geliştirilmiştir. Bu yöntem GP şeklinin ölçekler arasında değişmez olma eğiliminden yararlanmaktadır (Sun ve ark., 2008). Bahsedilen bu çalışmalar yeniden yapılandırma tabanlı süper çözünürlük algoritmalarının öncü çalışmaları olarak literatürde geçmektedir.

2.2.3. Öğrenme Tabanlı Yaklaşımlar

Öğrenme tabanlı algoritmalar ilk olarak parmak izi görüntülerinin çözünürlüğünü geliştirmek için 1986 yılında Eric tarafından bir sinir ağı ile kullanılmıştır (Mjolsness, 1986). Öğrenme tabanlı algoritmalar temelde iki adımda gerçekleşmektedir. İlk adım olarak harici bir veri setinden bazı yüksek çözünürlüklü görüntüler ile bu görüntülerin düşük çözünürlüklü versiyonları arasındaki ilişkiler öğrenilmektedir. Öğrenilen bu ilişkiler daha sonra kullanılarak süper çözünürlüklü görüntü oluşturulmaktadır. Shin ve ark. tarafından iris görüntülerini zenginleştirmek için çok katmanlı algılayıcılar (Multi Layer Perceptron - MLP) kullanılmıştır (Shin ve ark., 2009). Bu yöntem ile MLP'nin çıkış değerlerine dayalı olarak yüksek çözünürlüklü görüntü yeniden oluşturulur. Geri yayılma algoritması MLP'leri eğitmek için kullanılmaktadır. Wang ve ark. tarafından girdi görüntüleri ile örnek görüntüler arasındaki seyrek bağlantıyı öğrenmek için seyrek kodlama (Sparse Coding) yöntemi geliştirilmiştir (Wang ve ark., 2010).

Öğrenme tabanlı yaklaşımlar görüntü süper çözünürlük için günümüzde en etkili araştırma yöntemlerinden biridir ve geleneksel öğrenme yöntemleri ve derin öğrenme yöntemleri olarak iki alt başlıkta incelenmektedir. Geleneksel öğrenme algoritmaları uzun yıllardır kullanılmasına rağmen derin öğrenme tabanlı yaklaşımlar daha yüksek performans sergilemektedir. Bu nedenle en yeni algoritmalar doğru süper çözünürlük sonucu için gerekli olan ayrıntıları yeniden oluşturmak amacıyla veri odaklı derin öğrenme modellerine dayanmaktadır (Anwar ve ark., 2019).

2.2.3.1. Derin öğrenme tabanlı yaklaşımlar

Literatürde bulunan başarılı birçok derin öğrenme algoritmaları görüntü süper çözünürlük için uyarlanmıştır. Bu bölümde derin öğrenme tabanlı süper çözünürlük yaklaşımları modellerin mimarisine göre iki farklı kategori altında incelenmiştir. Öncelikle daha basit model yapısına sahip olan doğrusal ağlar (Lineer Networks), daha sonra daha derin mimarilerin tasarlanabilmesi için yapısında kısayol(atlama) bağlantıları bulduran Artık ağlar (Residual Networks) (Anwar ve ark., 2019) incelenmiştir.

2.2.3.2. Doğrusal Ağlar (Linear Networks)

Doğrusal ağlar, herhangi bir kısayol(atlama) bağlantısı veya çoklu dal olmadan sadece tek bir ana yoldan oluşan basit bir mimariye sahiptir. Bu mimarilerde, birkaç konvolüsyon katmanı üst üste istiflenir ve giriş verisi, başlangıçtan sonraki katmanlara sırayla aktarılmaktadır. Dong ve ark tarafından geliştirilen Süper Çözünürlük Konvolüsyonel Sinir Ağları (Super Resolution Convolutional Neural Networks - SRCNN) sadece konvolüsyon katmanlarını kullanan ilk çalışma olup bu alandaki birçok çalışmaya öncülük etmiştir (Dong ve ark., 2014). Toplamda 3 konvolüsyon 2 doğrultulmuş doğrusal ünite (Rectified Linear Unit - ReLU) katmanı art arda sıralanan basit bir yapıya sahiptir. SRCNN’de girdi görüntüsü önce aşağı örneklenir ve görüntünün düşük çözünürlüklü versiyonu oluşturulur. Daha sonra düşük çözünürlüklü görüntü bikubik enterpolasyonu ile istenilen ölçeğe yükseltilir. Düşük çözünürlüklü görüntüde tespit edilen özellikler oluşturulan yüksek çözünürlüklü görüntüye kopyalanmaya çalışılır (Dong ve ark., 2014). Model ölçeklendirilmiş alan üzerinde çalışmaktadır. Bu durum hesaplama karmaşıklığı ve zaman açısından dezavantaj oluşturmuştur. SRCNN’de bulunan dezavantajları ortadan kaldırmak için Hızlı süper çözünürlük konvolüsyonel sinir ağları (Fast Super Resolution Convolutional Neural Networks - FSRCNN) geliştirilmiştir. Bu model girdi görüntüsünü önceden ölçeklendirmek yerine orijinal düşük çözünürlüklü görüntü üzerinde çalışmaktadır. Ağın sonunda bulunan dekonvolüsyon katmanı yardımı ile görüntü ölçeklendirilir ve yüksek çözünürlüklü görüntü elde edilmektedir. FSRCNN önceki versiyonuna göre önemli bir performans artışı göstermiştir (Dong ve ark., 2016). Bu iki mimari istenilen her ölçek için farklı model eğitimleri sunmakta olup literatürde ölçeğe özgü ağ mimarileri olarak geçmektedir. SRCNN ve FSRCNN kullanılan mimarilerin aksine daha derin bir mimariye sahip olan Çok Derin Süper Çözünürlük (Very Deep Super Resolution - VDSR) mimarisi Kim ve ark. tarafından önerilmiştir. Önerilen bu ağ yapısında sabit boyutlu konvolüsyon (3x3) katmanı bulunmaktadır ve model oldukça derin bir yapıya sahiptir. Önceki iki mimarinin aksine VDSR ağı birden fazla ölçek için eğitilebilir bir yapıya sahiptir. Model girdi olarak bikubik enterpolasyon yöntemi ile ölçeklendirilmiş görüntü almaktadır (Kim ve ark., 2016). Bu durum her ölçek değeri için ayrı ölçeklendirme işlemi gerektirmekte olduğu için daha ağır hesaplama süresine neden olmaktadır. Hem görüntüler hem videolar için gerçek zamanlı çalışan hızlı bir süper çözünürlük yaklaşımı He ve ark. tarafından Etkili Alt-piksel Konvolüsyonel Sinir Ağları (Efficient Sub-pixel Convolutional Neural Network

- ESPCN) önerilmiştir. Bahsedilen diğer modellerin aksine ESPCN mimarisi girdi olarak ölçeklendirilmemiş düşük çözünürlüklü görüntü üzerinde çalışmaktadır (He ve ark., 2015). Modelde düşük çözünürlüklü görüntüden özellik çıkarımı yaparken eş zamanlı olarak yüksek çözünürlüklü görüntü tahmini yapmak için ağın en sonunda alt-piksel konvolüsyon katmanı kullanılmıştır (Shi ve ark., 2016). Bu katman sayesinde düşük çözünürlüklü alanda özellik işleme, bellek ve hesaplama gereksinimleri önemli derecede azalmıştır.

2.2.3.3. Artık Ağlar (Residual Network- ResNet)

Doğrusal derin öğrenme modelleri incelendiği zaman daha derin mimariye sahip modellerin daha üstün performans gösterdiği görülmüştür. Ancak giderek derinleşen ağ mimarisi ile bazı problemler ortaya çıkmaktadır. Bu problemlerden en önemlisi Eğimin Kaybolması (Vanishing Gradient) Problemidir (Bengio ve ark., 1994, Glorot & Bengio, 2010). Bu problem aktivasyon fonksiyonlarından elde edilen sonuçların giderek sıfır değerine yaklaşması ve ağı eğitilememesi problemdir. He ve ark tarafından görüntü tanıma için daha derin mimariye sahip ve eğimin kaybolması problemini aşan Artık Ağları (Residual Network - ResNet) önerilmiştir. Bu mimaride Doğrusal ağların aksine kendisinden 2 veya 3 katman sonraki katmana direk bağlantı kuran kısayol bağlantıları bulunmaktadır. Bu kısayol bağlantıları ile verilerin daha sonraki katmanlara direk olarak aktarılması sayesinde eğimin kaybolması gibi sorunlara çözüm getirilmiştir. Önerilen Artık Ağları 2015 yılında yapılan büyük ölçekli görsel tanıma yarışmasında (ImageNet Large Scale Visual Recognition Challenge 2015 - ILSVRC2015) birinci olarak başarısını ispat etmiştir (He ve ark., 2015). Bu başarıdan ilham alınarak ilk olarak Ledig ve ark. Tarafından 2017 yılında Artık Ağları süper çözünürlük için uyarlanmış olup Süper çözünürlük Artık Ağları (Super Resolution Residual Network- SRResNet) mimarisini önerilmiştir. Orijinal ResNet mimarisi üzerinde fazla değişiklik yapılmadan uygulanan model diğer son teknoloji modellere göre üstün performans göstermiştir (Ledig ve ark., 2017). Ancak orijinal ResNet mimarisi üst düzey bilgisayar görme sorunları için geliştirilmiş bir mimari olup süper çözünürlük gibi düşük seviyeli görme problemleri için karmaşık bir yapıya sahiptir (Lim ve ark., 2017). Lim ve ark. SRResNet mimarisinin başarısını temel alarak bulunan karmaşıklığı çözmek ve daha basit bir model sunmak için Geliştirilmiş Derin Kalıntı Ağları (Enhanced Deep Residual Network - EDSR) modelini önermiştir. Lim ve ark. SRResNet modelini analiz ederek ve artık birim içerisinde

bulunan toplu normalleştirme katmanlarını çıkartarak daha basit ve daha derin bir yaklaşım önermiştir. Önerilen model 2017 yılında Süper Çözünürlük Yarışması'nda (NTIRE) diğer süper çözünürlük modellerine kıyasla yüksek performans sergilemiştir (Lim ve ark., 2017).



3. MATERYAL ve YÖNTEM

Bu bölümde çalışmada kullanılan uydu görüntüleri içeren veri setleri, görüntülerin zenginleştirilmesi için kullanılan süper çözünürlük algoritmaları, önerdiğimiz yeni yöntem ve elde edilen yeni yüksek çözünürlüklü görüntülerin kalitelerini ölçmek için kullanılan ölçüm metrikleri açıklanmıştır.

3.1. Veri Kümeleri

Bu çalışmada veri seti olarak uzaktan algılama görüntüleri içeren iki farklı veri seti kullanılmıştır. Bunlar NWPU-RESISC45 ve UC Merced Land veri setleridir.

NWPU-RESISC45 veri seti, Northwestern Politeknik Üniversitesi tarafından oluşturulan 45 farklı alanın uzaktan algılama görüntülerini içeren kullanımı halka açık veri setidir. Her alana ait 256x256x3 boyutlarında 700 görüntü bulunmaktadır. Söz konusu 45 farklı alan; uçak, havaalanı, beysbol sahası, basketbol sahası, plaj, köprü, bot, kilise, dairesel tarım arazileri, bulut, ticari alan, yoğun konut, çöl, orman, otoyol, golf sahası, karayolu sahası, liman, endüstriyel alan, kavşak, ada, göl, çayır, orta yerleşim, mobil ev parkı, dağ, üst geçit, saray, otopark, demiryolu, tren istasyonu, dikdörtgen tarım arazileri, nehir, dolambaçlı, pist, deniz, gemi, karlı dağ, seyrek yerleşim, stadyum , depolama tankı, tenis kortu, teras, termik santral ve sulak alanlardır (Cheng ve ark., 2017).

UC Merced Land veri seti ülkedeki çeşitli kentsel alanlar için USGS Ulusal Harita Kentsel Alan Görüntüleri koleksiyonundan büyük görüntülerden manuel olarak çıkarılarak oluşturulmuştur. 21 Farklı alan ve her alana ait 256x256x3 boyutlarında 100 adet görüntü bulunmaktadır. Söz konusu 21 farklı alan; tarım, uçak, beysbol sahası, plaj binalar, bot, yoğun konut, orman, otoban, golf kursu, liman, kesişim, orta yoğunlukta konut alanı, mobil ev parkı, üst geçit, otopark, nehir, koşu yolu, seyrek konut alanı, depolama tankları ve tenis kortu alanlarıdır (Yang & Newsam, 2010).

3.2. Süper Çözünürlük

Süper çözünürlük kavramı temel olarak düşük çözünürlüklü görüntüden yüksek çözünürlüklü görüntü elde etme işlemleri olarak tanımlanmaktadır. Çözünürlük bir görüntüde bulunan piksel sayısını ifade etmektedir. Piksel sıralı bir dikdörtgen ızgarada bulunan dijital görüntüdeki en küçük unsur olarak tanımlanır. Görüntüde bulunan piksel

yoğunluğuna göre yüksek çözünürlük ve düşük çözünürlük kavramları ortaya çıkmaktadır. Yüksek çözünürlük kavramı, görüntü çerçevesinde bulunan piksellerin yoğunluğunun yüksek olduğu görüntüler için kullanılırken düşük çözünürlük kavramı tam aksine bu piksellerin yoğunluğunun düşük olduğu görüntüler için kullanılmaktadır. Bu nedenle yüksek çözünürlüğe sahip bir görüntü daha fazla piksel içerdiği için görüntüde daha fazla ayrıntı sunmaktadır ve bu nedenle dijital görüntü uygulamalarında büyük öneme sahiptir(Nasrollahi & Moeslund, 2014, Fernandez-Beltran ve ark., 2017, Singh & Singh, 2020).

Süper çözünürlük, birim alan başına denk düşen piksel sayısını yani görüntünün çözünürlüğünü arttırmaktadır. Kavramda yer alan süper kelimesi düşük çözünürlüklü görüntüleme sistemlerinin doğal çözünürlük sınırlamalarını aşan bu tekniğin özelliklerini çok iyi yansıtmaktadır. Süper çözünürlük görüntüleme cihazının sensörüne göre sanki daha yüksek çözünürlüğe sahip bir sensör kullanılmış gibi görüntüde daha ince ayrıntılar elde etmeyi amaçlamaktadır (Fernandez-Beltran ve ark., 2017).

Süper çözünürlük yaklaşımının avantajlarından bazıları şunlardır;


- 1- Donanım tabanlı çözümlere göre daha az maliyet gerektirmektedir.
- 2- Mevcut bulunan düşük çözünürlüklü görüntüleme sistemlerini herhangi bir güncellemeye gerek kalmadan kullanılabilir.
- 3- Esneklik sunmaktadır.

Görüntü süper çözünürlük yöntemleri fonksiyonel özelliklerine göre enterpolasyon tabanlı, yeniden yapılandırma tabanlı, öğrenme tabanlı ve hibrit yöntemler olarak alt kategorilere ayrılmaktadır (Singh & Singh, 2020).

3.2.1. Enterpolasyon Tabanlı Yöntemler

Görüntü enterpolasyonu, temel olarak bir görüntünün içindeki belirli bir alandaki piksel sayısını yapay olarak artırarak görüntünün çözünürlüğünü arttıran yöntemler olarak ifade edilmektedir. Bu tekniklerde görüntülerin içerdiği özellikler yerine pikseller işleme alınmaktadır. Enterpolasyon yöntemleri görüntü işlemedeki temel işlemlerden olup geleneksel süper çözünürlük yöntemleri olarak bilinirler. Görüntü enterpolasyon yöntemleri süper çözünürlük için en hızlı çözüm üreten yöntemlerdir (Deshpande & Patavardhan, 2019). En yakın komşu (Nearest Neighbor- NN), Bilinear (BL) ve

Bikubik(BC) en iyi bilinen enterpolasyon yöntemleridir. Şekil 3.1. ile aşağıda bu yöntemlerin karşılaştırılması verilmiştir.



Şekil 3.1. Enterpolasyon yöntemlerinin karşılaştırılması

3.2.1.1. En Yakın Komşu (Neares Neighbor- NN)

En yakın komşu yöntemi, görüntü matrisindeki piksel değerlerini yeniden örnekleyen en basit ve en hızlı enterpolasyon yöntemidir. Bu yöntemle oluşturulan yeni piksel değeri, sadece en yakındaki tek bir piksel değerinden kopyalanarak oluşturulur. Yüksek çözünürlüğe sahip görüntüler için daha iyi sonuçlar üretir ancak elde edilen görüntü pürüzlü kenarlar içerebilmektedir (Franke, 1982).

3.2.1.2. Bilinear Enterpolasyon

Bu yöntem en yakın 2x2 (4 piksel) piksel inceler, bu alandaki piksellerin yakınlığına ve parlaklığına bağlı olarak ağırlıklı bir ortalama oluşturulur ve bu ortalama çıktı piksel değerine atanır. En yakın komşu enterpolasyonuna göre daha yumuşak hatlar oluşturur (Allebach & Wong, 1996).

3.2.1.3. Bikubik Enterpolasyon

Her çıkış hücre (piksel) değerinin hesaplanması için en yakın 4x4 (16 piksel) piksellik giriş hücresi kullanılır. Giriş hücre değerlerinin ortalaması için ağırlıklandırma faktörleri, kübik (üçüncü dereceden) bir mesafe fonksiyonu ile hesaplanmaktadır. Bikubik enterpolasyon yöntemi, en yakın komşu ve bilinear yöntemlerine kıyasla

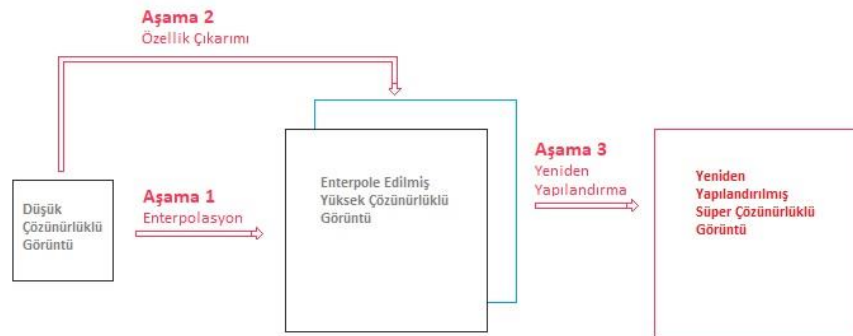
örtüşme(aliasing) ve bulanıklığı azaltmaktadır. Hesaplama süresi faktörü önemsiz olduğu durumlarda en iyi sonucu üreten enterpolasyon tekniğidir (Fritsch & Carlson, 1980).

3.2.2. Yeniden Yapılandırma Tabanlı Yöntemler

Yeniden yapılandırma yöntemleri girdi olarak aldıkları düşük çözünürlüklü görüntüyle aynı algısal özelliklere sahip, ancak daha yüksek çözünürlüklü bir süper çözülmüş görüntü oluşturmayı amaçlamaktadır (Nasrollahi & Moeslund, 2014). Enterpolasyon algoritmalarının neden olduğu bulanıklık ve örtüşme sorunlarını önlemek için enterpolasyon işleminden sonra düşük çözünürlüklü görüntünün kalitesini kopyalamaya çalışır (Fernandez-Beltran ve ark., 2017). Yeniden yapılandırma tabanlı algoritmalar temelde şu üç aşamadan oluşmaktadır;

- 1- Düşük çözünürlüklü görüntü bilinen bikubik, bilinear veya lanczos düzenli enterpolasyon yöntemleri ile istenilen ölçeğe getirilmektedir.
- 2- Yeni oluşturulacak görüntünün kalitesi için düşük çözünürlüklü alandan özellik çıkarımı yapılmaktadır.
- 3- Bu aşamada ölçeklendirilmiş görüntü ile düşük çözünürlüklü görüntüden çıkarılan özellikler birleştirilerek süper çözünürlüklü görüntü elde edilmektedir.

Mevcut bütün yeniden yapılandırma algoritmaları yukarıda tanımlanan üç aşamayı gerçekleştirmektedir. Şekil 3.2. ile yeniden yapılandırma tabanlı algoritmaların aşamaları aşağıda gösterilmiştir.




Şekil 3.2. Yeniden yapılandırma tabanlı yöntemlerin aşamaları

3.2.3. Öğrenme Tabanlı Yöntemler

Öğrenme tabanlı yöntemler günümüzde süper çözünürlük problemleri için en etkili çözümleri sunan ve popüler olan yöntemlerdir. Bu yöntemler kullanılarak oluşturulan süper çözünürlüklü görüntünün kalitesi daha yüksektir. Ancak görüntü oluşturulmasından önce bulunan öğrenme aşamasından dolayı yöntem daha önce bahsedilen yöntemlere nazaran daha yavaştır. Öğrenme tabanlı yöntemlerin süper çözünürlüklü görüntüyü oluşturmadaki temel fikri, bir görüntünün düşük çözünürlüklü ve yüksek çözünürlüklü versiyonları arasındaki ilişkileri harici bir veri setinden öğrenir ve yeni yüksek çözünürlüklü görüntüyü bu ilişkileri kullanarak oluşturmaktadır. Harici veri setinde bulunan görüntülerden öğrenilen ilişkilerin boyutu üretilen süper çözünürlüklü görüntünün kalitesini belirlemektedir. Veri kümesinde bulunan görüntülerin miktarının artması daha iyi sonuçlar üretmesine fayda sağlayabilir ancak bu durum her zaman iyi sonuçlar üreteceği anlamına gelmemektedir. Girdi görüntüsü ile alakasız verilerin veri setindeki fazlalığı görüntünün kalitesini olumsuz olarak etkilemektedir (Fernandez-Beltran ve ark., 2017). Öğrenme tabanlı yöntemler temelde üç aşamadan meydana gelmektedir ve bu aşamalar Şekil 3.3. ile gösterilmiş olup şu şekilde sıralanmaktadır;

- 1- Harici bir veri setinden düşük çözünürlüklü ve yüksek çözünürlüklü görüntü çiftleri arasındaki ilişkileri öğrenilmektedir.
- 2- Öğrenilen ilişkiler, yüksek çözünürlüklü bileşenleri tahmin etmek için kullanılmaktadır.
- 3- Süper çözünürlüklü görüntüyü oluşturmak için giriş düşük çözünürlüklü görüntü ile tahmin edilen yüksek frekanslı bileşenler birleştirilmektedir.



Şekil 3.3. Öğrenme tabanlı yöntemlerin aşamaları

3.3. Derin Öğrenme


Geleneksel makine öğrenmesi algoritmaları yüksek boyutlu verileri işlemede yetersiz kalmaktadır ve aynı zamanda algoritmaların sonucu tahmin ederken dikkate alacağı verilerde bulunan özellikler manuel olarak belirlenmektedir. Bu nedenler geleneksel algoritmalara bazı dezavantajlar oluşturmakta ve nesne tanıma, doğal dil işleme, segmentasyon gibi üst düzey bilgisayar görme problemlerinden yetersiz kalmalarına neden olmaktadır. Derin öğrenme bu dezavantajları ortadan kaldırmak için derin ve çok katmanlı sinir ağlarını kullanan makine öğrenmesi alt dallarındandır. Derin sinir ağları art arda sıralanmış birçok katmandan oluşmakta olup bu durum ağın derinliğini belirlemektedir. Mimaride bulunan her katman çıkışı bir sonraki katmana giriş olarak aktarmaktadır. Derin sinir ağlarında, geleneksel ağların aksine öğrenilecek özellikleri manuel olarak belirlemek yerine ağ kendi oluşturduğu filtreler yardımı ile bu özellikleri öğrenmektedir. Her katmanda özellikler bir önceki katman çıkışından hesaplanmaktadır. Özellikler aşamalı olarak düşük seviyeden yüksek seviyeye doğru öğrenilmektedir (LeCun ve ark., 2015).

Hesaplamaalarda GPU kullanımının başlaması ile hesaplama gücünde oluşan artış büyük veri setleri ve daha güçlü algoritmaların kullanılabilmesi derin öğrenme algoritmalarının popülerliğini arttırmış ve son zamanlarda doğal dil işleme, nesne çıkarımı, görüntü işleme gibi çeşitli alanlarda kullanılmaktadır (Büyükyılmaz, 2017). LeCun tarafından incelenen farklı derin öğrenme modelleri; derin inanç ağları (DBN'ler), derin Boltzmann makineleri (DBM'ler), SAE'ler, yığılmış denoising AE'ler (SDAE'ler), kısıtlı Boltzmann makineleri (RBM'ler) ve Konvolüsyonel Sinir Ağları (CNN) içeren bir araştırma yapılmıştır ve bu çalışmada modeller arasında en yaygın kullanılan model Konvolüsyonel Sinir Ağları olarak belirtilmiştir (LeCun ve ark., 2015).

3.3.1. Evrişimsel Sinir Ağları (ESA)

Evrişimsel sinir ağları (ESA) obje tanıma, özellik çıkarımı, doğal dil işleme vb. gibi alanlarda kullanılan bir giriş, çok sayıda gizli ve bir çıkış katmanı olan ve özellik haritası olarak adlandırılan yüksek seviyeli öznetelikler çıkarabilen katmanları bulunan yapay sinir ağlarıdır. ESA mimarisinde giriş katmanı, evrişim katmanı, doğrultulmuş doğrusal birim katmanı, havuzlama katmanı, tam bağlantılı katman, dropout katmanı ve sınıflandırma katmanları sırasıyla bulunmaktadır. Evrişim katmanı, havuzlama katmanı

ve doğrusal birim katmanları gizli katmanın yapısını oluşturmaktadır. Gizli katman içerisinde bulunan katmanlar ardışık bir şekilde istenildiği gibi tekrar edebilir ve bu tekrar tamamen modeli tasarlayana bağlı olarak değişerek ağıın derinliğini belirlemektedir (LeCun ve ark., 2015). Şekil 3.4. ile ESA mimarisi aşağıda gösterilmiştir.



Şekil 3.4. Evrişimli Sinir Ağı Katmanları (Büyükyılmaz, 2017)

ESA katmanlarında bulunan nöronlar klasik sinir ağlarındakine benzer birer ağırlık katsayılarına sahiptir. Her bir nöron giriş değerlerini ve ağırlık katsayılarını iç çarpım işleminden geçirdikten sonra sonucuna bir aktivasyon fonksiyonu uygulamaktadır. Ağdaki bütün katmanlar bir skor fonksiyonuna ve çıkış katmanı ise bir kayıp fonksiyonuna sahiptir.

ESA yapay sinir ağlarından farklı olarak genişlik, yükseklik ve derinlik olmak üzere 3 boyutlu nöronlara sahiptir. ESA'da iki boyutlu evrişim(konvolüsyon) katmanı kullanılmaktadır. Evrişim katmanında görüntü üzerinde bir filtre yatay ve dikey olarak hareket ettirilerek özellik haritaları oluşturulmaktadır. Çıkarılan bu özellik haritalarının sayısı artarak devam etmektedir. Özellik haritaları parlaklık ve kenar bilgisi gibi basit özellikler ile başlayarak her eklenen katmanda nesneyi benzersiz şekilde tanımlayan özelliklerin seviyesini arttırmaktadır. ESA mimarisinde aktivasyon fonksiyonu olarak doğrultulmuş doğrusal birim katmanı (Rectified Linear Unit - ReLU) daha sıklıkla tercih edilmektedir (Nair & Hinton, 2010).

3.3.1.1. Evrişim Katmanı (Konvolüsyon)

Görüntüler, genişlik, yükseklik ve renk bilgilerinin çok boyutlu diziler olarak saklandığı verilerdir. Geleneksel sinir ağlarında bu diziler bir ağırlık matrisi ile çarpılır ve bir vektör yapısına dönüştürüldükten sonra ağa girdi olarak verilir yani görüntülerin

bu özel yapısı dikkate alınmamaktadır. Ancak ESA mimarisinde görüntünün özel yapısı dikkate alınır. Evrişim katmanı ESA mimarisinin yapı taşıdır ve matris yapısını koruyan doğrusal bir dönüşümdür. Evrişim katmanının ilk görevi oluşturduğu filtreleri kullanarak girdi olarak aldığı veri üzerinde bu filtreleri yatay ve dikey şekilde hareket ettirerek veriden özellik çıkarımı yapmaktır. Özellik çıkarımı yapılırken matrise uygulanacak olan filtrenin x ve y eksenine göre simetrisi alınmaktadır. Bütün değerler matriste eleman eleman çarpılarak toplanır ve hesaplanan değer, sonuç matrisinin ilgili hücrenin değeri olmaktadır (Botalb ve ark., 2018). Evrişim katmanında bazı parametreler vardır ve şu şekilde tanımlanmaktadır;

- Özellik haritası: Konvolüsyon işlemi sonucunda üretilen çıktı matrisi veya matrisleridir.
- Filtre Boyutu: Girdi üzerinde gezdirilecek olan filtrenin boyutlarıdır. Girdinin boyutlarından küçük olması gerekir.
- Filtre sayısı: Girdi üzerinde uygulanacak olan filtrelerin miktarıdır. Bu değer çıktı matrisinin kanal sayısını etkilemektedir.
- Adım sayısı: Girdi üzerinde gezdirilecek olan filtrenin hareketini tanımlayan bu değer filtre boyutu ile uyumlu seçilmelidir. Bu değer evrişim katmanının çıktı boyutunu etkilemekte olup küçük bir değer seçilmesi durumunda alıcı alanların üst üste gelmesine, büyük bir değer seçilmesi durumunda ise bazı özniteliklerin işleme alınmamasına neden olmaktadır.
- Sıfır Dolgusu: Evrişim katmanının çıktı boyutlarını kontrol etmek için kullanılan bu parametre girdi matrisinde sıfır olarak doldurulacak hücrelerin sayısını tanımlamaktadır.

3.3.1.2. Doğrultulmuş Doğrusal Ünite (Rectified Lineer Unit - Relu)

Doğrultulmuş doğrusal ünite derin öğrenme modellerinde en çok tercih edilen aktivasyon fonksiyonudur. Aktivasyon fonksiyonları nöronların çıktısına karar veren ve sadece fonksiyon türüne göre belirli değerleri bir sonraki katmana aktaran fonksiyonlardır. ReLu aktivasyon fonksiyonu denklem 3.1 ile aşağıda gösterilmiştir.

$$ReLu(x) = \max(x, 0) \quad (3.1)$$

Fonksiyona gelen pozitif değerler herhangi bir işleme tabi tutulmadan sonraki katmana olduğu gibi aktarılırken negatif değerler ise sıfır olarak aktarılmaktadır. ReLu aktivasyon fonksiyonu ağın etkili ve hızlı bir şekilde eğitilmesini sağlamaktadır (Nair & Hinton, 2010).

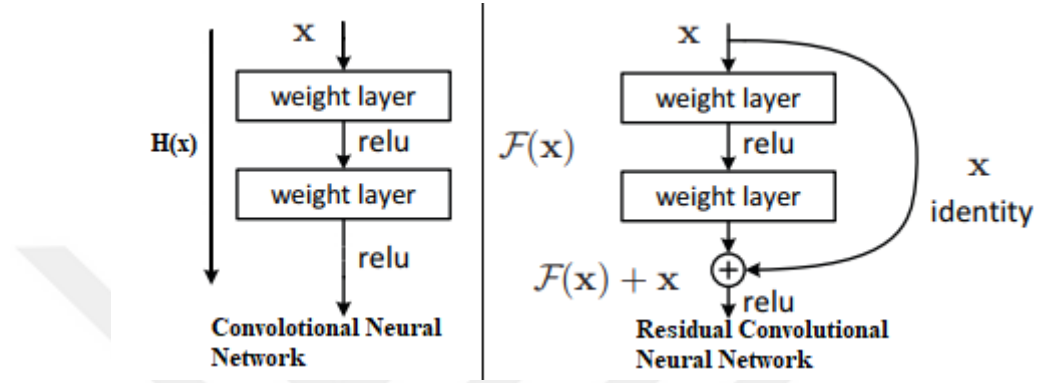
3.3.2. Artık Ağları (Residual Network- ResNet)

ESA mimarisi, görüntü sınıflandırma problemlerinin çözümünde büyük yeniliklere getirmiştir. Özellik seviyelerinin ağda art arda sıralanan katmanların sayısı ile yani ağın derinliği ile zenginleştirilebilir olması daha derin mimarilerin tasarlanmasına yol açmıştır. ImageNet büyük ölçekli görsel tanıma yarışması ile derin mimarilerin sığ mimarilere kıyasla üstün performans gösterdiği görülmüştür. Yarışmada üstün performans gösteren modellerin 16 ila 30 katman derinliğinde modeller olduğu görülmüştür (Krizhevsky ve ark., 2017). Ancak derin mimariler tasarlamaya yönelik olan bu yaklaşımlar her zaman daha iyi performans göstermemektedir (He ve ark., 2015).

Bir ESA modeli stokastik gradyan inişi kullanılarak eğitilir. Stokastik gradyan inişi, eğitim safhasında ilk olarak model tarafından yapılan tahmin hatasını hesaplar ve sonrasında bunu eğitimin sonraki adımlarında tahmin hatasını azaltmak amacıyla ağıdaki ağırlıkları güncellemek için kullanılan gradyanı tahmin etmek için kullanılmaktadır. Bu hata gradyan son katmandan ilk katmana doğru geriye yayılım algoritması ile yayılmaktadır. Her katmanda ağırlıklar bir aktivasyon fonksiyonundan geçirilerek güncellenmektedir. Birçok aktivasyon fonksiyonu bu değerleri küçük bir aralığa doğrusal olmayan bir şekilde sıkıştırmaktadır. Bu sıkıştırma işlemi ağ derinleştikçe gradyan değerlerinin küçülmesine neden olmaktadır. Bu nedenle derin ağ mimarilerinde son katmandan ilk katmanlara doğru yaklaştıkça bu değer neredeyse kaybolarak ağırlıkların güncellenmesinde etkisiz hale gelir ve bu durum kaybolan gradyan (eğim) problemini ortaya çıkarmaktadır. Bu durum ağın eğitimini yavaşlatır ve hatta durdurabilir (He ve ark., 2015).

Ağların derinleşmeye başlamasıyla bir bozulma sorunu ortaya çıkmaktadır; doğruluk doyum noktasına ulaşarak sonrasında hızla bozulmaya başlar ve daha fazla katman eklenmesi durumu daha yüksek eğitim hatası alınmasına neden olmaktadır. Eğitim doğruluğunun bozulması sistemlerin optimize edilmesinin kolay olmadığını göstermektedir.

Bahsedilen bu sorunlara çözüm için Artık Ağları önerilmiştir. Artık ağlarının katkıları derinleşen ağların eğitimini ve ağların optimizasyonunu kolaylaştırmasıdır. Artık ağları bu sorunları çözmek için kısayol bağlantıları ile katmanlar arasında atlama gerçekleştirir (He ve ark., 2015). Katmanın girişi iki veya daha sonraki katmanların çıkışına kısayol bağlantıları ile aktarılır ve böylece değerler sürekli korunmuş olur. Şekil 3.5. ile artık ağı ve normal ESA mimarisi kıyaslanmıştır.



Şekil 3.5. Evrişimli sinir ağı ve Artık ağı mimarisi farkı (He ve ark., 2016)

3.3.2.1. Artık Öğrenmesi

Bozunma problemine çözüm olarak artık öğrenme kullanılmaktadır. Geleneksel bir evrişim ağında sıralı iki katman arasındaki ileri yayılım denklem 3.2 ve denklem 3.3 ile formüle edilmektedir.

$$y_l = F(x_l, W_l) + b \quad (3.2)$$

$$x_{l+1} = f(y_l) \quad (3.3)$$

Denklemdaki x_l ve x_{l+1} l . evrişim katmanına ait giriş ve çıkış özellikleri olarak tanımlanır. F konvolüsyon operatörüdür ve b önyargı(bias) terimidir ve f aktivasyon fonksiyonunu gösterir. İteratif olarak L . katmandaki çıktı denklem 3.4 ile gösterilmiştir.

$$X_L = \prod_{i=1}^{L-1} f(F(X_i, W_i) + b) \quad (3.4)$$

Eđitim sırasında geriye yayılım ařamasında daha derin katmanda bulunan hatanın gradyan deęeri, daha sıđ ađlara yayılmaktadır. Gradyan deęeri yayılmadan dolayı git gide küçülür ve bir noktadan sonra eđitime etki etmemektedir. Önerilen yeni artık öğrenme ile bu sorun çözülmektedir. Artık öğrenme denklem 3.5 ile ařađıda gösterilmiřtir.

$$y_l = h(x_l) + F(x_n, W_n) \quad (3.5)$$

$$x_{l+1} = f(y_n) \quad (3.6)$$

Denklem... da gösterilen $h(x_n)$ aslında $h(x(n))$ dir, $x(n)$ giriş deęeri ve $h(x)$ ise kimlik eřleřtirme fonksiyonudur. $h(x_n)$ Mimariye eklenen kimlik kısayol bađlantısını ifade etmektedir (He ve ark., 2016).

3.3.2.2. Kısayol bađlantısı

Kısayol bađlantıları, bir veya daha fazla katmanı atlayan bađlantılardır. Artık ađlarında kısayol bađlantılarında kimlik eřlemesi fonksiyonu bulunur ve çıktıları atlanan katmanın çıkıřına ekler. Kimlik kısayol bađlantıları ađa ekstra parametre ve hesaplama karmařıklıđı eklememektedir (Han ve ark., 2017).

3.4. Süper Çözünürlük için Derin Öğrenme


Derin öğrenme tabanlı yaklařımlar öğrenme tabanlı süper çözünürlük yaklařımının alt dalıdır. Amaç düşük çözünürlüklü giriş görüntüsünden (I^{LR}) yüksek çözünürlüklü (I^{HR}), süper çözülmüř (I^{SR}) görüntüyü tahmin etmektir. Burada I^{LR} yüksek çözünürlüklü I^{HR} görüntüsünün düşük çözünürlüklü versiyonudur. I^{HR} Sadece eđitim esnasında kullanılmaktadır. I^{LR} Görüntü I^{HR} görüntüye alt örnekleme faktörü (r) uygulanarak elde edilir. W genişliđine, H yüksekliđine ve C renk kanalına sahip bir I^{HR} görüntüsü $W*H*C$ olarak, görüntünün I^{LR} versiyonu ise $rW*rH*C$ olarak tanımlanmaktadır (Fernandez-Beltran ve ark., 2017).

3.4.1. VDSR

VDSR ImageNet sınıflandırılmasında kullanılan çok derin evriřimli sinir ađı VGG-Net mimarisinden esinlenilerek Kim ve ark. tarafından geliřtirilmiřtir. Sadece artık

bilgilerin öğrenildiği ve ayarlanabilir gradyan kırpma ile son derece yüksek öğrenme oranlarının kullanıldığı etkili bir eğitim sunulmuştur. İlk ve son katman dışında kalan katmanların aynı olduğu 3x3 boyutlarında 64 filtreden oluşan d adet katman kullanılmıştır. İlk katman girdi görüntüsü üzerinde çalışır. Son katman ise 3x3x64 boyutunda tek bir filtreden oluşan ve görüntüyü yeniden yapılandıran katmandır (Kim ve ark., 2016).

Model girdi olarak istenilen çözünürlüğe enterpole edilmiş düşük çözünürlüklü görüntünün ölçeklendirilmiş versiyonunu alır ve görüntü ayrıntılarını tahmin etmektedir. Daha iyi performans için kullanılan çok derin evrişimli sinir ağlarının bir sorunu her evrişim katmanından sonra özellik haritalarının boyutlarının biraz azalmasıdır. İstenilen boyutu ayarlamak için sıfır dolgusu kullanılarak söz konusu sorun giderilmiştir. Mimari görüntü ayrıntılarını tahmin ettikten sonra en son katmanda nihai süper çözünürlüklü görüntüyü oluşturmak için bu tahminler giriş düşük çözünürlüklü görüntüsüne eklenmektedir (Kim ve ark., 2016). Şekil 3.6. ile VDSR mimarisi aşağıda gösterilmiştir.



Şekil 3.6. VDSR ağ mimarisi (Kim ve ark., 2016)

Çok derin sinir ağlarında özellikle ölçeğe özgü mimariler kullanıldığı durumlarda zaman ve bellek açısından maliyetli olmaktadır. Bu maliyeti azaltmak için parametrelerin paylaşıldığı çok ölçekli eğitim prosedürü bu mimari ile sunulmuştur. Eğitim için gereken bütün ölçeklerdeki görüntülerin bulunduğu büyük bir veri seti kullanılmaktadır.

3.5. Süper Çözünürlük için Artık Ağlar

Süper çözünürlük için ilk olarak süper çözünürlük artık ağları (Super Resolution Residual Network SRResNet) kullanılmıştır. Orijinal ResNet mimarisi üzerinde

değişiklik yapmadan süper çözünürlüğe uygulanmıştır. 16 artık birim derinliğinde ve farklı hata fonksiyonları ile uygulanan SRResNet önceki derin öğrenme tabanlı algoritmalara kıyasla daha iyi performans göstermiştir (Ledig ve ark., 2017).


3.5.1. Süper Çözünürlük için Geliştirilmiş Derin Artık Ağları (Enhanced Deep Super Resolution - EDSR)

EDSR, SRResNet mimarisini baz alarak Lim ve ark. Tarafından 2017 yılında geliştirilmiştir ve 2017 yılında yapılan Uluslararası süper-çözünürlük yarışması (NTIRE-2017) (Agustsson & Timofte, 2017) en gelişmiş yöntemlerden üstün performans göstermiştir. EDSR, ResNet mimarisinin süper çözünürlük için çok karmaşık olduğunu ve gereksiz hesaplama yükü olduğunu SRResNet çalışmasıyla gözlemlemiş olup bu yükü azaltmak için mimariyi optimize etmiştir. Bu sayede ağın eğitimini kolaylaştırmış ve performansını arttırmıştır. EDSR, ResNet mimarisinde bulunan artık birimler üzerinde değişiklik yapmıştır. Özetle geleneksel artık ağ mimarisine dayanan, daha iyi performansa sahip, daha büyük bir model yapısı sunulmuştur (Lim ve ark., 2017). Bu çalışmada Tek ölçekli ve diğer ölçek katsayılarıyla parametre paylaşımı yapan çok ölçekli mimari önerilmiştir.

3.5.1.1. Artık Birim

Artık ağlar son zamanlarda birçok yüksek seviyeli bilgisayarla görme problemlerinde yüksek performans göstermiştir (He ve ark., 2015). Standart ResNet mimarisinde bulunan artık birim incelendiği zaman yapısında sırasıyla evrişim, toplu normalleştirme, aktivasyon, evrişim ve toplu normalleştirme katmanlarını bulundurmaktadır. Aktivasyon fonksiyonu olarak geleneksel ESA mimarisinde kullanılan ReLu tercih edilmektedir. Kullanılan bu artık birim yapısı model yüksek seviyeli bilgisayarla görme problemlerinde iyi performans göstermektedir ancak süper çözünürlük gibi daha düşük seviyeli problemler için karmaşık bir yapı olmaktadır. (Szegedy ve ark., 2016) Bu karmaşıklığı çözmek daha büyük ve yüksek performanslı bir yapı sunmak için artık birimden bazı gereksiz katmanlar kaldırılmıştır. Bütün ağa giren verileri normalleştirdiği için ilk olarak toplu normalleştirme katmanı artık birimden kaldırılmıştır. Ağdaki diğer bir değişiklik; kısayol bağlantısı ile birleşiminden sonra Doğrultulmuş doğrusal birim katmanı bulunmamaktadır. Deney sonuçlarına göre bu


değişikliklerin performansı önemli derecede arttırdığı gözlemlenmiştir. Ayrıca toplu normalleştirme katmanları evrişim katmanlarıyla hemen hemen aynı miktarda bellek kullandığı için ağıdan kaldırılması ile yaklaşık %40 oranında GPU kullanımında tasarruf sağlanmıştır. Şekil 3.7. ile artık birimlerin kıyaslanması aşağıda gösterilmiştir (Lim ve ark., 2017).



Şekil 3.7. Mimarilerdeki artık birimlerin kıyaslanması (Lim ve ark., 2017).

3.5.1.2. Tek Ölçekli Model


Yüksek ölçek katsayılı modeller eğitilirken bilgiyi daha önce eğitmiş olduğu düşük ölçek katsayılı modellerden aktaran tek ölçekli bir yaklaşım sunulmuştur. Bu modelde performans ağı derinliği ve özellik haritalarının diğer modellerden daha fazla olmasına ve gereksiz hesaplama yükü getiren katmanların mimariden kaldırılmasına bağlı olup model başarısını ispat etmiştir. Model giriş görüntüsünü bikubik enterpolasyonu ile alt örneklenmiş olarak kabul etmektedir. Görüntü ağı en sonunda ölçeklendirilerek süper çözünürlüklü görüntü elde edilir (Lim ve ark., 2017). Şekil 3.8. ile tek ölçekli EDSR modeli gösterilmiştir.



Şekil 3.8. EDSR mimarisi (Lim ve ark., 2017).

3.5.1.3. Çok Ölçekli Model

Tek ölçekli model de yüksek ölçek katsayısında eğitim için önceki eğitilmiş modelin kullanılması ile çoklu ölçeklerde süper çözölmüş görüntü oluşturmının ölçeklerin birbirleriyle ilişkili olduğu sonucuna varılmış olup yeni sunulan çok ölçekli modelde ölçekler arasında parametre paylaşımı olan bir eğitim prosedürü sunulmuştur. Bu model VDSR modelinde ki ölçekler arası ilişkiden esinlenilerek geliştirilmiştir. Süper çözünürlüğü birden çok ölçekte ele almak modelin başında ölçeğe özgü ön işleme modülleri sunulmuştur. Parametrelerin ölçekler arasında paylaşılması için modelin temelinde 16 artık birimli tek bir ana dal oluşturulmuştur. Modelin sonunda çok ölçekli yeniden yapılandırmayı gerçekleştirmek için ölçeğe özgü yukarı ölçeklendirme katmanı bulunmaktadır. Çok ölçekli modelde tek ölçekli modele göre toplamda daha az parametre kullanılarak farklı ölçeklerde süper çözünürlüklü görüntüler elde edilmekte olup iki model karşılaştırılabilir performans sergilemiştir (Lim ve ark., 2017). Şekil 3.9. ile çok ölçekli model gösterilmiştir.



Şekil 3.9. Çok ölçekli EDSR modeli (Lim ve ark., 2017).

3.5.2. Süper Çözünürlük için Derin Piramit Artık Ağı

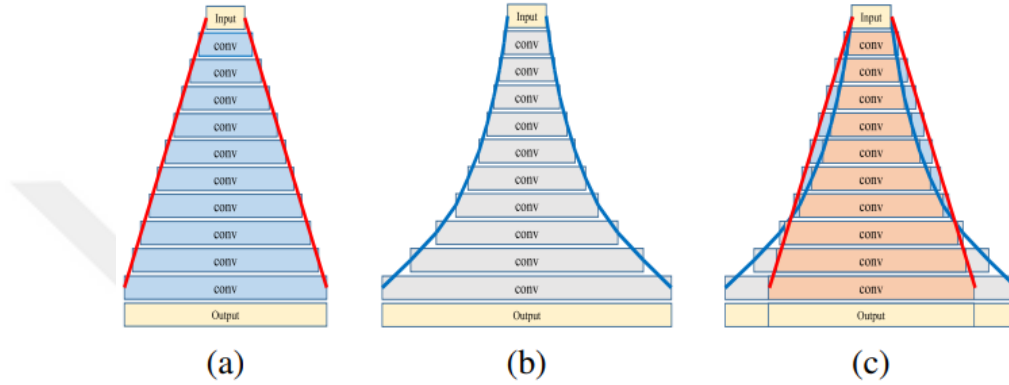
Derin piramit artık ağları temelde standart artık ağ mimarisinin güncellenmiş bir versiyonudur. Bu mimarideki ana fikir standart evrişimsel sinir ağı ve standart artık ağında olduğu gibi özellik haritalarının boyutlarını belirgin bir farkla arttırmak yerine belirli bir oranla kademeli olarak arttırmaktır (Han ve ark., 2017). Genelde derin evrişimli sinir ağlarında özellik haritalarının boyutları herhangi bir alt örnekleme katmanından sonra belirgin bir farkla arttırılmaktadır. Artık ağlarında ise özellik haritalarının boyutları k 'inci artık birim için denklem 3.7'deki gibi hesaplanmakta ve aynı artık birim içindeki katmanlarda özellik haritalarının boyutları aynı olmaktadır. Piramit artık ağlarında ise özellik haritalarının boyutları her artık birimde iki kat birden arttırmak yerine kademeli olarak arttırılmakta ve arttırma yükü bütün katmanlara eşit olarak dağıtılmaktadır. Bu tasarım yukarıdan aşağıya genişleyen özellik haritalarının boyutları nedeniyle piramit yapısına benzer ve yöntem adını buradan almaktadır. Piramit artık ağında özellik haritalarının boyutlarının artışı toplamsal ve üstsel olarak iki farklı şekilde arttırılmaktadır (Han ve ark., 2017). Denklem 3.8 ile toplamsal, denklem 3.9 ile üstsel artış aşağıda gösterilmiştir. Şekil 3.10. ile artış yöntemleri ve kıyaslamaları aşağıda gösterilmiştir.

$$D_k = \begin{cases} 16, & n(k) = 1, \\ 16 \cdot 2^{n(k)-2}, & n(k) \geq 2, \end{cases} \quad (3.7)$$

$$D_k = \begin{cases} 16, & k = 1, \\ \lfloor D_{k-1} + \alpha/N \rfloor, & 2 \leq k \leq N + 1, \end{cases} \quad (3.8)$$

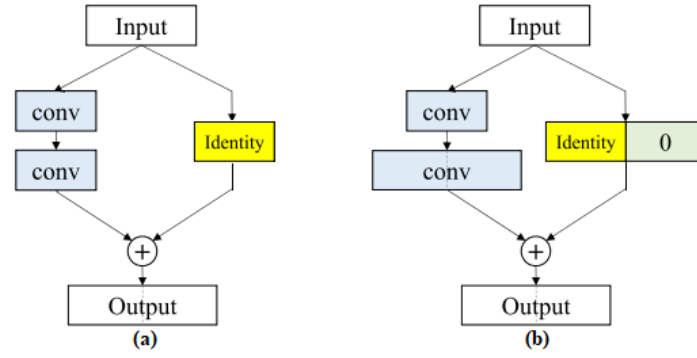
$$D_k = \begin{cases} 16, & k = 1, \\ \lfloor D_{k-1} \cdot \alpha^{1/N} \rfloor, & 2 \leq k \leq N + 1, \end{cases} \quad (3.9)$$

Denklemlerde bulunan D_k n'inci gruba ait k'inci artık birim evrişim katmanı özellik haritası boyutu (kanal sayısı), N artık birimlerin toplam sayısı, artık birim derinliği, α özellik haritası boyut artış katsayısıdır.



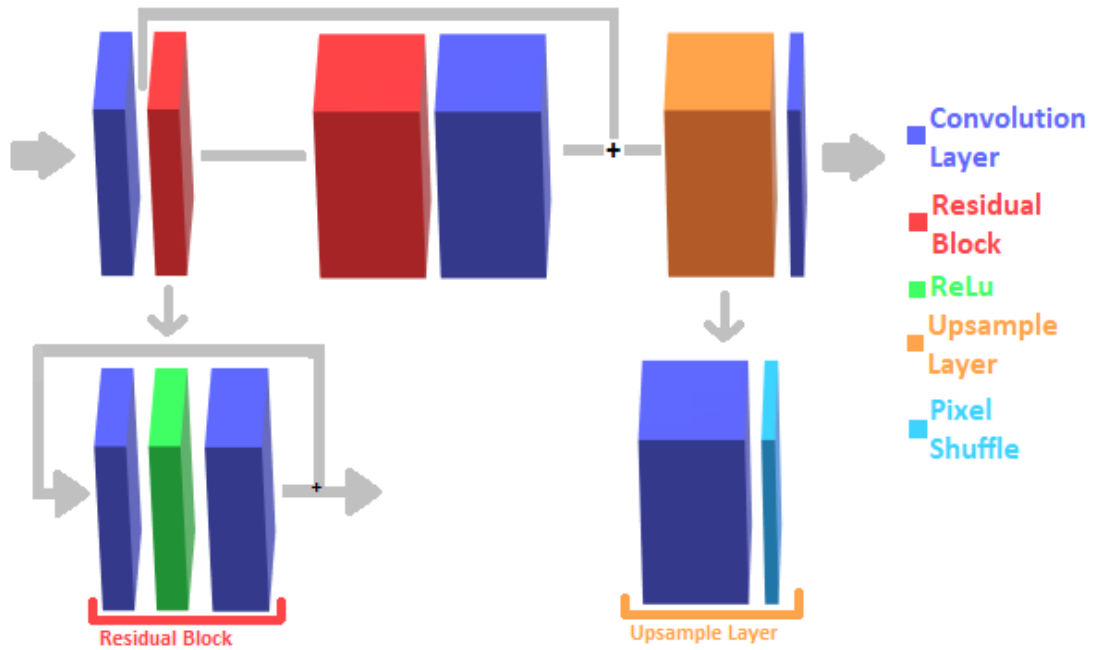
Şekil 3.10. (a) Toplamsal, (b) Geometrik, (c) iki yöntemin karşılaştırılması (Han ve ark., 2017)

Piramit artık ağlarında özellik haritalarının diğer artık ağlardan bir diğer farkı kısayol bağlantılarıdır. Artık ağlarda kısayol bağlantısında kimlik eşleme fonksiyonu bulunurken, piramit artık ağlarında durum artık birim içerisindeki katmanlarda özellik haritalarının boyutları (kanal sayıları) sürekli artış gösterdiğinden artık birimin girdi ve çıktıları arasında boyut farklılıkları oluşmaktadır. Girdi artık birimin çıkışına eklendiğinden aradaki farkı kapatmak için kısayol bağlantılarında sıfır dolgululu kimlik eşleme fonksiyonu kullanılmaktadır. Kullanılan sıfır dolgusu ek bir parametre bulundurmadığı için aşırı öğrenmeye neden olmamakta ve yöntemin diğer kısayol bağlantılarına kıyasla önemli bir genelleme yeteneği olduğu görülmektedir. Şekil 3.11 ile normal artık birim ve piramit artık birim aşağıda gösterilmiştir.



Şekil 3.11. (a) Derin artık ağ mimarisine ait artık birim, (b) Derin piramit artık ağı mimarisine ait artık birim

Bu tez çalışmasında kademeli olarak özellik haritalarının boyutlarını (kanal sayısını) arttırma fikri süper çözünürlük problemi için uyarlanmış olup süper çözünürlük için derin piramit ağları modeli önerilmiştir. Standart piramit artık biriminde bulunan bazı katmanların oluşturduğu hesaplama karmaşıklığı ve GPU kullanım yükünden kurtulmak için (Nah ve ark., 2017)'den esinlenilerek toplu normalleştirme katmanları kaldırılmıştır. Şekil 3.12 ile yeni önerilen mimari gösterilmiştir.



Şekil 3.12. Süper çözünürlük için Derin piramit ağları


Ağ performansını arttırmanın bilinen en basit yolu parametre sayısını arttırmaktır. Evrişimli sinir ağı mimarilerinde model performansını arttırmak için katman sayısı

(derinlik) veya kanal sayısı (özellik haritası boyutu) sayısını arttırılabilir. Önerdiğimiz modelin yapısından dolayı özellik haritalarının boyutlarında ağın derinliği boyunca sürekli bir artış olmaktadır. Ağın artan derinliğine bağlı olarak artan kanal sayısı performansa etki etmektedir. Ancak kanal sayısının belli bir miktarın üzerine çıktığı durumlarda, artık birim parametrelerinin dengesizlik göstermeye başladığı, model eğitiminin başlarında öldüğü ve sıfır üretmeye başladığı görülmüştür. Bu problem öğrenme oranını düşürerek veya normalleştirme katmanlarını kaldırarak çözülememiştir. Artık birimde bulunan evrişim katmanındaki parametrelerin genellikle 0.1 ve 0.3 ölçek değerleri arasında bir değer ile ölçeklendirilmesi ile söz konusu sorun çözülmüş olup bu değer artık ölçeklendirmesi (Szegedy ve ark., 2016) olarak adlandırılmaktadır.

Önermiş olduğumuz model mimarisi girdi olarak bikubik alt örnekleme görüntü kabul etmektedir. Model performansını arttırmak ve hesaplama karmaşıklığını önlemek için mimari alt örnekleme alan üzerinde çalışmaktadır. Modelin sonuna yerleştirilen alt-piksel evrişim katmanı ile görüntü istenilen ölçeğe yukarı örnekleme ve süper çözülmüş görüntü elde edilmektedir.

3.5.2.1. Alt-Piksel Evrişim Katmanı

Alt piksel evrişim (Sub-pixel) katmanı uçtan uca öğrenilebilir bir yukarı örnekleme katmanıdır. Çok sayıda özellik haritalarının konvolüsyon işlemine girmesi ve daha sonrasında yeniden şekillendirme yoluyla yukarı örnekleme gerçekleştirilir. Bu katmanda S^2 ölçek kanallı çıktılar üretmek için bir konvolüsyon işlemi uygulanmaktadır. Burada S ölçeklendirme faktörüdür. Girişin $H \times W \times C$ olduğu düşünüldüğünde konvolüsyon çıkışı $H \times W \times S^2 C$ olmaktadır. Daha sonra yeniden şekillendirme ile bu çıktı $sH \times sW \times C$ olarak şekillendirilmektedir. Alt-piksel evrişim katmanı şekil 3.13 ile aşağıda gösterilmiştir (Shi ve ark., 2016).



Şekil 3.13. Alt-piksel evrişim katmanı aşamaları (Shi ve ark., 2016)

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde, önerilen yöntem ile kıyaslanan yöntemlerin deneysel çalışmaları ile ilgili bilgiler verilmiştir. Başlangıçta çalışmada kullanılan iki farklı veri setinden bahsedilmiştir. Daha sonra yöntemlerin kıyaslanmasında kullanılan referanslı görüntü kalite metrikleri açıklanmıştır. Devamında, çalışmada kullanılan yöntemlerin eğitim parametreleri verilmiş olup kullanılan yöntemlerin sonuçları kalite metrikleri açısından kıyaslanmıştır. Son başlıkta ise doğrulama veri setinde bulunan verilerden bazıları verilerek yöntemler arasındaki farklılıklar gözlemlenmiştir.

Tez kapsamında yapılan deneysel çalışmalar, Intel® Core™ i7-9700K CPU @ 3.60GHz işlemci, 16 GB Ram, GeForce RTX2070 ekran kartına sahip bir bilgisayar ve Google Tarafından sunulan Colabortory ortamında yapılmıştır. Yazılım geliştirme platformu olarak Spyder ve yazılım dili olarak Python 3.8.5 kullanılmıştır.

4.1. Veri Kümesi Üzerinde Yapılan İşlemler

Bu çalışma kapsamında kullanılan yöntemler iki farklı veri seti üzerine uygulanmış olup sonuçları kıyaslanmıştır. Eğitim için kullanılan veri setlerinde farklı kategorilerde bulunan görüntülerden rastgele 2100 görüntü seçilmiştir. Seçilen 2100 görüntüden rastgele 1800 tanesi eğitim için 400 tanesi doğrulama için ayrılmıştır. Görüntüler 48*48 boyutlarına düşürülmüş olup rastgele olarak yatay ve 90 derecelik açılarla döndürülerek veri miktarı arttırılmıştır.

4.2. Referanslı Görüntü Kalite Metrikleri

Görüntü kalite metrikleri, iki görüntü arasındaki sapmayı ölçerek, belirli bir görüntünün özelliklerini görüntünün bozulmamış versiyonu ile karşılaştırır. Bu çalışmada kullanılan yöntemleri kıyaslayabilmek için iyi bilinen tepe sinyal-gürültü oranı (Peak signal to noise ratio PSNR) ve Yapısal benzerlik indeksi ölçüsünü (Structural similarity index measure) kullanılmıştır.

Tepe sinyal-gürültü oranı, bir sinyalin olası maksimum değeri ile referansının kalitesini düşüren gürültü gücü arasındaki oranı temsil etmektedir. PSNR desibel(dB) cinsinden ölçülmektedir. PSNR değeri ne kadar yüksekse, referans görüntünün kalitesi de o kadar iyi olduğu anlamına gelmektedir. Ortalama kare hatası (Mean square error -

MSE) ve PSNR görüntü sıkıştırma kalitesini karşılaştırmak için kullanılan iki hata ölçüsüdür. MSE, sıkıştırılmış ve orijinal görüntü arasındaki kümülatif kare hatasını, PSNR ise tepe hatası değerini hesaplamaktadır (Nasrollahi & Moeslund, 2014). Denklem 4.2 ile MSE, denklem 4.1 ile PSNR hesaplamaları aşağıda verilmiştir.

$$MSE = \frac{\sum_{j=1}^N (\sum_{i=1}^M (X_{i,j} - Y_{i,j})^2)}{MN} \quad (4.1)$$

$$PSNR = 10 \log \frac{(Maks.Piksel\ Değeri)^2}{MSE} \quad (4.2)$$

İlk denklemde bulunan M ve N değerleri, sırasıyla girdi görüntülerinde bulunan satır ve sütun sayısıdır.

Yapısal benzerlik indeksi ölçüsü Wang ve arkadaşları tarafından geliştirilen iki görüntü arasındaki yapısal benzerliği ölçmek için kullanılan bilinen bir kalite ölçüm metriğidir. SSIM geleneksel hata ölçüm yöntemlerini kullanmanın aksine, herhangi bir görüntü bozulmasını korelasyon kaybı, kontrast ve parlaklık bozulması olarak üç faktörün kombinasyonu şeklinde ele almaktadır (Wang ve ark., 2004). SSIM insan görsel sistemine iyi uyum gösteren bir ölçüm metriği olarak bilinmektedir. Sonuç olarak 0 ile 1 arasında bir değer üretir ve değer 0'a yakınsa kıyaslanan görüntüler arasında yapısal benzerliğin çok az olduğu eğer değer 1'e yakınsa yapısal benzerliğin çok fazla olduğu anlamına gelir (Nasrollahi & Moeslund, 2014). Denklem 4.3 ile SSIM hesaplaması aşağıda verilmiştir.

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (4.3)$$

Denklemden bulunan μ_x, μ_y, σ_x ve σ_y terimleri x ve y görüntüleri için yerel ortalamalar, standart sapmalar ve çapraz kovaryans'tır.

4.3. Eğitim Parametreleri ve Sonuçları

Bu bölümde çalışmada kullandığımız üç farklı eğitilebilir model ve üç farklı enterpolasyon yöntemi seçilen veri setleri üzerinde uygulanarak sonuçlar incelenmiştir. Çalışmada seçilen modellerin eğitiminde kullanılan bazı parametreler şu şekildedir;

- Minibatch boyutu: Hesaplama aşamasındaki veri miktarını azaltmak için veriler bazı gruplara ayrılmaktadır. Minibatch katsayısı hesaplamada ne kadar verinin kullanılacağını belirtmektedir.
- Öğrenme Oranı (Learning Rate): Kullandığımız modellerin eğitimi esnasında geriye yayılım algoritması eğitimde bulunan parametreleri güncellemektedir ve bu güncellemeyi yaparken öğrenme oranı katsayısını kullanmaktadır.
- Optimizasyon Algoritması: Eğitim esnasında optimum değerlere ulaşabilmek için seçilen optimizasyon algoritmaları kullanılmaktadır.
- Eğitim Turu (Epoch): Eğitimde veriler küçük gruplar halinde eğitime katılır. Eğitim ilk grupla başlamak üzere bütün gruplar tek tek eğitime dahil edilir. Bu süreç her adımda tekrar edilir ve eğitim turu parametresi olarak belirlenir.
- Ölçek Faktörü: Oluşturacağımız süper çözünürlüklü görüntü için belirlediğimiz ölçeklendirme katsayısıdır.

Çalışmada kullanılan öğrenme algoritmalarının eğitim aşamasında optimizasyon için ADAM optimizasyon algoritması tercih edilmiş olup parametreleri $\beta_1 = 0.9$, $\beta_2 = 0.999$ ve $\epsilon = 10^{-8}$ şeklinde belirlenmiştir (Kingma & Ba, 2014). Bütün algoritmalar için Minibatch katsayısı 16 olarak belirlenmiştir. Öğrenme oranı ise 10^{-4} ile başlamak üzere her 2×10^5 minibatch'te yarıya düşürülmektedir. Algoritmalar için değişkenlik gösteren diğer parametreler aşağıda Tablo 4.1. ile yer verilmiştir.

Tablo 4.1. Parametre Tablosu

Model	Ölçek	Tur Sayısı	Artık Blok Sayısı	Özellik Haritası Sayısı	Alfa Katsayısı
EDSR Base	2	600	16	64-Sabit	Yok
	4	600	16	64-Sabit	Yok
Add-Pyramid	2	500	24	16-269	256
	4	500	24	16-269	256
Mul-Pyramid	2	500	24	16-361	32
	4	500	24	16-361	32

Tablo 4.1. ile verilen parametre değerlerine göre çalışmada kullanılan EDSR Baseline, Add-Pyramid ve Mul-Pyramid öğrenme algoritmalarının seçilen veri setleri ile eğitiminden elde edilmiş olan sonuçlar Tablo 4.2. ile aşağıda yer verilmiştir.

Tablo 4.2. Doğrulama veri seti PSNR ve SSIM sonuçları

		Add-Pyramid	Mul-Pyramid	EDSR Baseline	Bicubic	Bilinear	Lanczos3
UC Merced	X2	34,1945 / 0,8911	34,1861 / 0,8905	34,1697 / 0,8898	34,0837 / 0,9076	32,9190 / 0,8602	33,7849 / 0,8933
NWPU-RESISC45		34,9329 / 0,9258	34,8780 / 0,9249	34,8278 / 0,9242	33,7998 / 0,8999	32,9766 / 0,8507	33,4188 / 0,8836
UC Merced	X4	31,7819 / 0,7243	31,7352 / 0,7223	31,7468 / 0,7199	31,0351 / 0,6876	31,1794 / 0,6835	30,8333 / 0,6685
NWPU-RESISC45		31,9507 / 0,7455	31,9060 / 0,7417	31,8558 / 0,7344	31,1902 / 0,6750	31,3787 / 0,6744	31,0153 / 0,6565

Tablo 4.2. de verilen değerler doğrulama için ayırdığımız 400 adet görüntü üzerinden alınan skorların ortalama değerleridir. Tablo incelendiği zaman kırmızı ile gösterilen değerler ilgili veri seti ve ilgili ölçek değerlerinde en iyi skoru, yeşil renk ile gösterilen değerler ise ikinci en iyi skoru göstermektedir. Sonuçlar değerlendirildiği zaman bütün veri setleri ve bütün ölçek değerlerinde önerdiğimiz modelin toplamsal tabanlı yaklaşımı olan Add-pyramid algoritmasının en iyi skoru elde ettiği görülmektedir. Aynı zamanda önerdiğimiz modelin çarpımsal tabanlı yaklaşımı olan Mul-Pyramid algoritmasında bir durum haricinde en iyi ikinci skoru elde etmektedir.

Çalışmada yeni önerilmiş olan iki farklı öğrenme tabanlı algoritmaların diğer algoritmalarından belirgin bir farkı olup olmadığını gözlemleyebilmek için sonuçlarımıza ilgili iki numune arasındaki ölçümleri karşılaştırmak için kullanılan parametrik olmayan wilcoxon işaretli sıra testini uygulanmış olup elde ettiğimiz sonuçlar Tablo 4.3. ve Tablo 4.4. ile aşağıda yer verilmiştir.

Tablo 4.3. Add-Pyramid and EDSR Baseline Wilcoxon Test

		Öntest-sontest	Toplam	EDSR	Add-Pyramid	p
UC Merced	X2	Negatif sıra	80	135,25	10820,00	
		Pozitif sıra	320	216,81	69380,00	,00
		Eşit	0			
NWPU-RESISC45	X2	Negatif sıra	147	154,72	22744,00	
		Pozitif sıra	193	182,52	35226,00	,00
		Eşit	0			
UC Merced	X4	Negatif sıra	158	164,27	25954,00	


NWPU-RESISC45	Pozitif sıra	240	222,70	53447,00	,00
	Eşit	0			
	Negatif sıra	133	122,92	16348,00	
	Pozitif sıra	207	201,07	41622,00	,00
	Eşit	0			

Tablo 4.3.'te bulunan Wilcoxon testi öntest-sontest sonuçlarında p değerinin 0.05 değerinden küçük olması yeni uygulanan yöntemde önceki yönteme göre belirgin bir fark gösterdiğini ifade etmektedir. Tablodaki sonuçlar incelendiğinde p değeri bütün test sonuçlarında 0.05 değerinden küçük olmaktadır. Böylece yeni önerilmiş Add-Pyramid algoritmasında bulunan farklılıkların EDSR Baseline algoritmasına göre daha iyi performans gösterdiği gözlemlenmektedir.


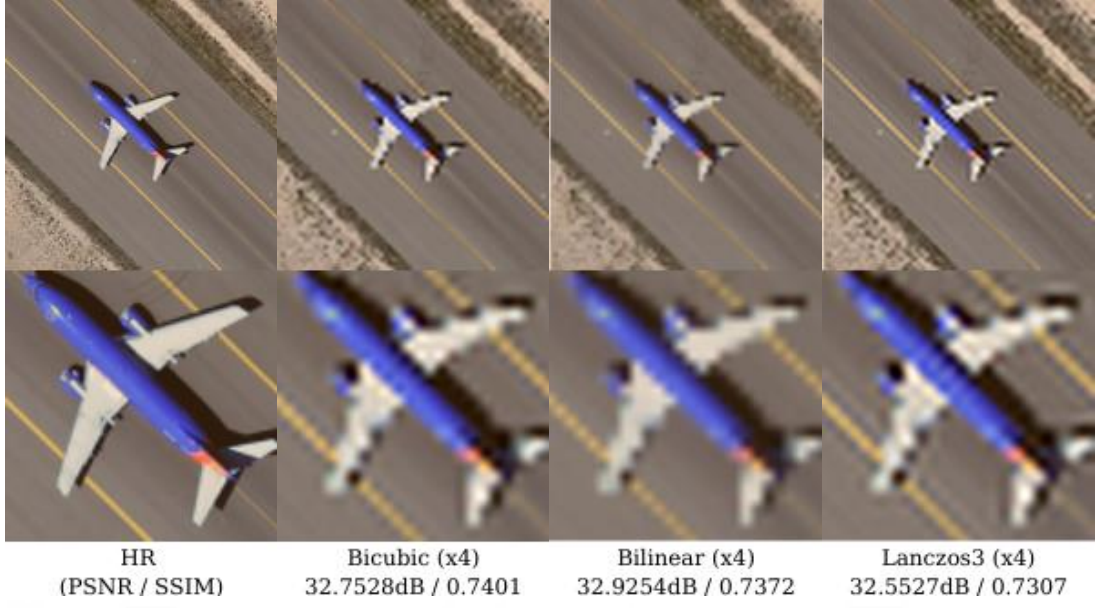
Tablo 4.4. Mul-Pyramid and EDSR Baseline Wilcoxon Test

		Öntest-sontest	Toplam	EDSR	Mul-Pyramid	p
UC Merced	X2	Negatif sıra	120	165,10	19812,00	
		Pozitif sıra	280	215,67	60388,00	,00
		Eşit	0			
NWPU-RESISC45		Negatif sıra	155	160,00	24800,00	
		Pozitif sıra	185	179,30	33170,00	,02
		Eşit	0			
UC Merced	X4	Negatif sıra	167	179,07	29904,00	
		Pozitif sıra	231	214,27	49497,00	,00
		Eşit	0			
NWPU-RESISC45		Negatif sıra	138	138,83	19158,00	
		Pozitif sıra	202	192,14	38812,00	,00
		Eşit	0			



Tablo 4.4.'te bulunan Wilcoxon öntest-sontest sonuçları incelendiğinde p değerinin bütün durumlarda 0.05 değerinden küçük olduğu görülmüştür. Böylece yeni önerilmiş olan Mul-Pyramid algoritmasında bulunan farklılıkların EDSR Baseline algoritmasına göre daha iyi performans gösterdiği gözlemlenmektedir.




Şekil 4.1. UC Merced veri setinden Uçak kategorisine ait görüntünün x2 ölçeklendirilmesi




Şekil 4.2. UC Merced veri setinden Uçak kategorisine ait görüntünün x4 ölçeklendirilmesi




Şekil 4.3. UC Merced veri setinden Uçak kategorisine ait görüntünün x2 ölçeklendirilmesi




Şekil 4.4. UC Merced veri setinden Uçak kategorisine ait görüntünün x4 ölçeklendirilmesi




Şekil 4.5. NWPU-RESISC45 veri setinden Ada kategorisine ait görüntünün x2 ölçeklendirilmesi




Şekil 4.6. NWPU-RESISC45 veri setinden Ada kategorisine ait görüntünün x4 ölçeklendirilmesi




Şekil 4.7. NWPU-RESISC45 veri setinden Havaalanı kategorisine ait görüntünün x2 ölçeklendirilmesi



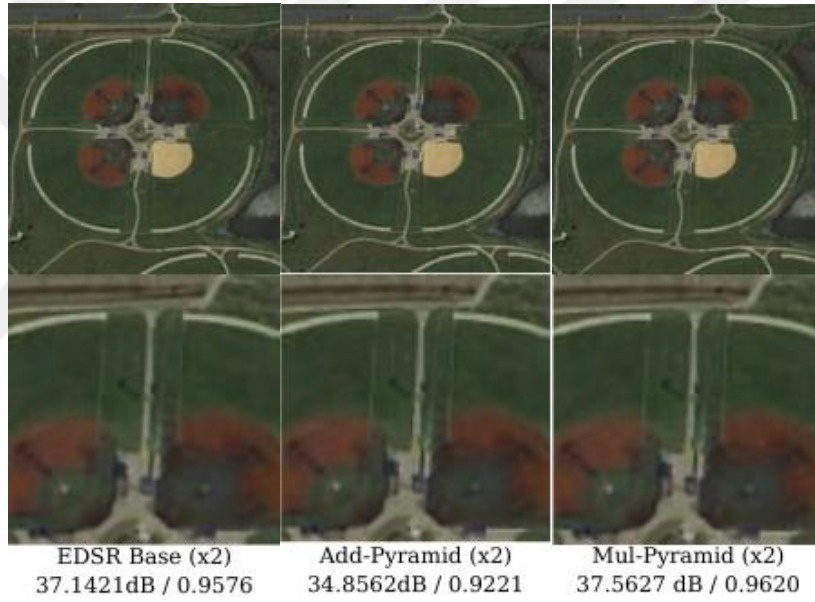
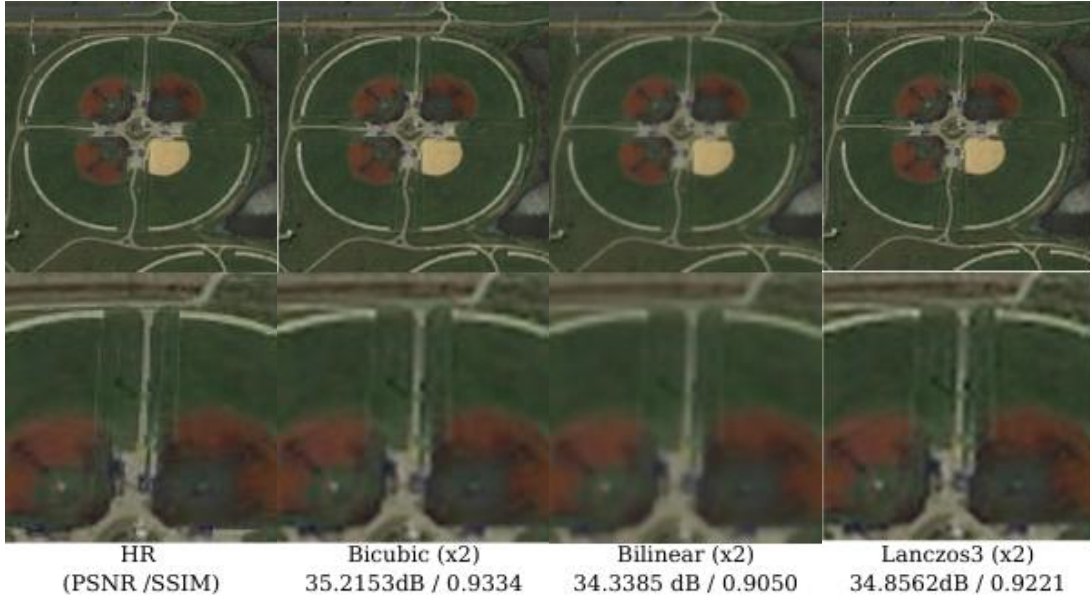
Şekil 4.8. NWPU-RESISC45 veri setinden Havaalanı kategorisine ait görüntünün x4 ölçeklendirilmesi



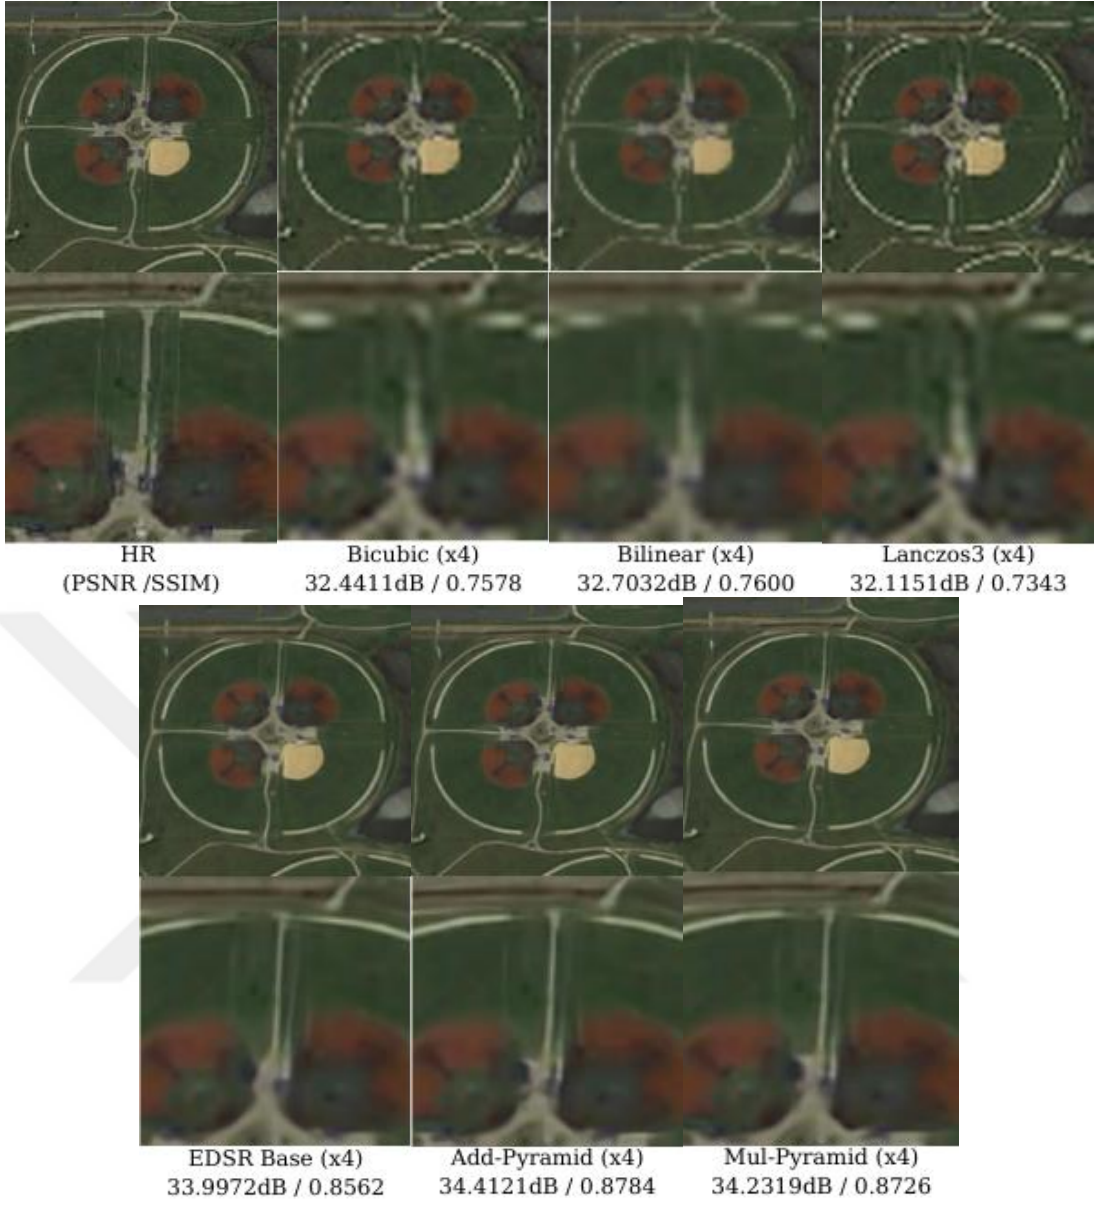
Şekil 4.9. NWPU-RESISC45 veri setinden Dairesel Tarım Alanı kategorisine ait görüntünün x2 ölçeklendirilmesi




Şekil 4.10. NWPU-RESISC45 veri setinden Dairesel Tarım Alanı kategorisine ait görüntünün x4 ölçeklendirilmesi




Şekil 4.11. NWPU-RESISC45 veri setinden Golf Sahası kategorisine ait görüntünün x2 ölçeklendirilmesi




Şekil 4.12. NWPU-RESISC45 veri setinden Golf Sahası kategorisine ait görüntünün x4 ölçeklendirilmesi




Şekil 4.13. NWPU-RESISC45 veri setinden Otoyol kategorisine ait görüntünün x2 ölçeklendirilmesi



Şekil 4.14. NWPU-RESISC45 veri setinden Otoyol kategorisine ait görüntünün x4 ölçeklendirilmesi



Şekil 4.15. UC Merced veri setinden Depolama Tankları kategorisine ait görüntünün x2 ölçeklendirilmesi



Şekil 4.16. UC Merced veri setinden Depolama Tankları kategorisine ait görüntünün x4 ölçeklendirilmesi

5. SONUÇLAR ve ÖNERİLER

Görsel iletişim ve sahnenin analizi için görüntü işlemenin hızla geliştirilmesi sadece izleyiciye daha iyi görselleştirme sağlamak için değil aynı zamanda görüntülerden ek bilgi ve ayrıntılar çıkarmak için yüksek çözünürlüklü görüntü sağlama konusunda güçlü bir talep bulunmaktadır. Örneğin yüksek çözünürlüklü bir görüntü tıbbi görüntüleme tanı koyarken doktorlara yardımcı olmak için, uydu görüntülerinde ise bölgelerin daha iyi sınıflandırılması ve bölge hakkında bilgi sağlamak için önemli fayda sağlamaktadır.

Yüksek çözünürlüklü görüntüler elde etmeye yönelik en doğrudan yaklaşım, sensörlerde bulunan piksel boyutlarını azaltarak piksel sayısını arttırmaktır. Bununla birlikte, sensör teknolojisinde sensörün piksel boyutunu azaltmada sınırlama bulunmaktadır. Sensörde bulunan piksel boyutları küçüldüğü zaman alınan görüntünün de kalitesi buna bağlı olarak azalmaktadır. Bunun nedeni, görüntüyü bozan gürültü miktarının aynı kalması ancak sinyal gücünün ise sensörün piksel boyutundaki küçülme ile orantılı olarak azalmasıdır. Ayrıca, sensör boyutlarını arttırmak yüksek maliyet gerektirir. Görüntülerin boyutunu ve çözünürlüğünü arttırmak veya azaltmak için daha az maliyet gerektiren ve daha kaliteli sonuçlar sağlayan bazı algoritmalar geliştirilmiştir.

Görüntü süper çözünürlüğü görüntüyü yüksek çözünürlüğe ulaştırmak için görüntü elde etme cihazının ve kötü durumdaki görüntü edinme koşullarının sınırlamalarını aşmak veya eksikliklerini telafi etmeyi amaçlayan algoritmaları ifade etmektedir. Görüntü süper çözünürlük algoritmaları düşük çözünürlüklü görüntünün çözünürlüğünü artırırken paralel olarak görüntüde bulunan detay seviyelerini sanki yüksek çözünürlüklü bir sensör kullanılarak elde edilmiş gibi arttırmayı amaçlamaktadır. Görüntü süper çözünürlüğü daha kaliteli sonuçlar sunarken aynı zamanda daha az maliyet, mevcut sistemlerin herhangi bir güncelleştirme yapılmadan kullanılması ve hızlı bir şekilde uygulanabilirlik gibi avantajlar sağlamaktadır. Bu avantajlar son yıllarda süper çözünürlük algoritmaları ile ilgili çalışmalara olan popülerliği arttırmıştır. Son yıllarda geliştirilen algoritmalar görüntüye yaklaşımı ve sonuç açısından birbirlerinden farklılıklar göstermektedir. Süper çözülmüş görüntüyü üretirken bazı algoritmalar yeni her piksel değeri için komşu piksel değerlerinden faydalanan enterpolasyon yaklaşımlarını kullanırken, diğer algoritmalar kaynak bir görüntü ile görüntünün süper çözümlenmiş karşılığı arasındaki ilişkiyi elde etmek için makine öğrenimi algoritmalarını kullanır.

Bu çalışma doğal kaynakların araştırılması, coğrafi bilgi sistemleri ve sivil savunma operasyonları gibi birçok alanda kullanılan uydu görüntülerinin çözünürlüğünü ve kalitesini arttırmak için yapılmıştır. Görüntülerin çözünürlüğünü arttırırken süper çözünürlük algoritmalarının ilk önce düşük maliyet daha sonra mevcut görüntü edinme sistemlerini kullanma gibi avantajlarından faydalanılarak gerçekleştirilmiştir. Çalışmada başarılı bir derin öğrenme algoritması olan derin piramit artık ağ mimarisi süper çözünürlük problemine uyarlanmıştır. Uyarlanmış olan algoritma derin öğrenme tabanlı diğer süper çözünürlük algoritmaları ile kıyaslanmış olup daha iyi performans sergilemiştir. Çalışmanın son bölümünde kullanılan veri setlerinden elde edilen görüntülerin sonuçları Tablo 4.2 ile sunulmuş olup değerler Wilcoxon işaretli sıra testine tabi tutulmuştur. Test sonucu değerlendirildiğinde önerilmiş olan algoritma, esas alınarak geliştirilen algoritmaya kıyasla sonuçlara belirgin bir fark kattığı görülmüştür.

Daha sonraki yapılacak çalışmalar için çok yüksek çözünürlüklü görüntülerden oluşturulan veri setlerinden elde edilen yüksek frekanslı bilgiler ile modellerin eğitilerek daha kaliteli ve yüksek çözünürlüklü görüntüler oluşturmada kullanılabilir. Ayrıca çalışmada kullanılan yöntemlerde de bulunan artık ağlarındaki kısayol bağlantıları üzerinde araştırmalar yapılarak model eğitiminde etkisi arttırılabilir.

KAYNAKLAR

- Agustsson, E. ve R. Timofte (2017). Ntire 2017 challenge on single image super-resolution: Dataset and study. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*.
- Allebach, J. ve P. W. Wong (1996). Edge-directed interpolation. *Proceedings of 3rd IEEE International Conference on Image Processing*, IEEE.
- Anwar, S., ve ark. (2019). "A deep journey into super-resolution: A survey." *arXiv preprint arXiv:1904.07523*.
- Babaoğlu, İ., ve ark. (2019). "Satellite Image Enhancement Using Convolutional Neural Networks." *Proceedings of the 2nd International Conference of Engineering, Science and Mathematics Education (ICESME)*: 92-100.
- Bengio, Y., ve ark. (1994). "Learning long-term dependencies with gradient descent is difficult." *IEEE transactions on neural networks* **5**(2): 157-166.
- Botalb, A., ve ark. (2018). Contrasting Convolutional Neural Network (CNN) with Multi-Layer Perceptron (MLP) for Big Data Analysis. *2018 International Conference on Intelligent and Advanced System (ICIAS)*, IEEE.
- Büyükyılmaz, M. (2017). Mikroskopik görüntüler üzerinde derin öğrenme algoritmaları kullanarak hastalıklı hücrelerin otomatik tanımlanması, Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü.
- Cheng, G., ve ark. (2017). "Remote sensing image scene classification: Benchmark and state of the art." *Proceedings of the IEEE* **105**(10): 1865-1883.
- Deshpande, A. ve P. Patavardhan (2016). "Single Frame Super Resolution of Non-Cooperative Iris Images." *ICTACT Journal on Image and Video Processing* **7**(2): 1362-1365.

- Deshpande, A. ve P. P. Patavardhan (2019). "SURVEY OF SUPER RESOLUTION TECHNIQUES." *ICTACT Journal on Image & Video Processing* **9**(3).
- Dong, C., ve ark. (2014). Learning a deep convolutional network for image super-resolution. *European conference on computer vision*, Springer.
- Dong, C., ve ark. (2016). "Accelerating the Super-Resolution Convolutional Neural Network: Supplementary File." *Computer Vision-ECCV 2016*.
- Fernandez-Beltran, R., ve ark. (2017). "Single-frame super-resolution in remote sensing: a practical overview." *International Journal of Remote Sensing* **38**(1): 314-354.
- Franke, R. (1982). "Scattered data interpolation: tests of some methods." *Mathematics of computation* **38**(157): 181-200.
- Fritsch, F. N. ve R. E. Carlson (1980). "Monotone piecewise cubic interpolation." *SIAM Journal on Numerical Analysis* **17**(2): 238-246.
- Glorot, X. ve Y. Bengio (2010). Understanding the difficulty of training deep feedforward neural networks. *Proceedings of the thirteenth international conference on artificial intelligence and statistics*.
- Han, D., ve ark. (2017). Deep pyramidal residual networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- He, K., ve ark. (2015). Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. *Proceedings of the IEEE international conference on computer vision*.
- He, K., ve ark. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Irani, M. ve S. Peleg (1991). "Improving resolution by image registration." *CVGIP: Graphical models and image processing* **53**(3): 231-239.

- Kim, J., ve ark. (2016). Accurate image super-resolution using very deep convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Kingma, D. P. ve J. Ba (2014). "Adam: A method for stochastic optimization." *arXiv preprint arXiv:1412.6980*.
- Krizhevsky, A., ve ark. (2017). "Imagenet classification with deep convolutional neural networks." *Communications of the ACM* **60**(6): 84-90.
- LeCun, Y., ve ark. (2015). "Deep learning." *nature* **521**(7553): 436-444.
- Ledig, C., ve ark. (2017). Photo-realistic single image super-resolution using a generative adversarial network. *Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Li, X. ve M. T. Orchard (2001). "New edge-directed interpolation." *IEEE transactions on image processing* **10**(10): 1521-1527.
- Lim, B., ve ark. (2017). Enhanced deep residual networks for single image super-resolution. *Proceedings of the IEEE conference on computer vision and pattern recognition workshops*.
- Lu, T., ve ark. (2019). "Satellite image super-resolution via multi-scale residual deep neural network." *Remote Sensing* **11**(13): 1588.
- Mjolsness, E. (1986). *Neural Networks, Pattern Recognition, and Fingerprint Hallucination*, UMI.
- Nah, S., ve ark. (2017). Deep multi-scale convolutional neural network for dynamic scene deblurring. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*.

- Naik, V. V. ve S. Gharge (2016). Satellite image resolution enhancement using DTCWT and DTCWT based fusion. *2016 International Conference on Advances in Computing, Communications and Informatics (ICACCI)*, IEEE.
- Nair, V. ve G. Hinton (2010). "ICML'10 Proceedings of the 27th International Conference on Machine Learning." *Omnipress, Madison*.
- Nasrollahi, K. ve T. B. Moeslund (2014). "Super-resolution: a comprehensive survey." *Machine vision and applications* **25**(6): 1423-1468.
- Shan, Q., ve ark. (2008). "High-quality motion deblurring from a single image." *Acm transactions on graphics (tog)* **27**(3): 1-10.
- Sharma, A. ve A. Khunteta (2016). Satellite image contrast and resolution enhancement using discrete wavelet transform and singular value decomposition. *2016 International Conference on Emerging Trends in Electrical Electronics & Sustainable Energy Systems (ICETEESES)*, IEEE.
- Shi, W., ve ark. (2016). "Is the deconvolution layer the same as a convolutional layer?" *arXiv preprint arXiv:1609.07009*.
- Shin, K. Y., ve ark. (2009). Super-resolution method based on multiple multi-layer perceptrons for iris recognition. *Proceedings of the 4th International Conference on Ubiquitous Information Technologies & Applications*, IEEE.
- Singh, A. ve J. Singh (2020). "Survey on Single Image based Super-resolution—Implementation Challenges and Solutions." *Multimedia Tools and Applications* **79**(3): 1641-1672.
- Singh, V., ve ark. (2016). Analytical evaluation for the enhancement of satellite images using swarm intelligence techniques. *2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)*, IEEE.

- Sun, J., ve ark. (2008). Image super-resolution using gradient profile prior. *2008 IEEE Conference on Computer Vision and Pattern Recognition*, IEEE.
- Szegedy, C., ve ark. (2016). "Inception-v4, inception-resnet and the impact of residual connections on learning." *arXiv preprint arXiv:1602.07261*.
- Wang, J., ve ark. (2010). "Resolution enhancement based on learning the sparse association of image patches." *Pattern Recognition Letters* **31**(1): 1-10.
- Wang, Z., ve ark. (2004). "Image quality assessment: from error visibility to structural similarity." *IEEE transactions on image processing* **13**(4): 600-612.
- Yang, Y. ve S. Newsam (2010). Bag-of-visual-words and spatial extensions for land-use classification. *Proceedings of the 18th SIGSPATIAL international conference on advances in geographic information systems*.
- Zhang, L. ve X. Wu (2006). "An edge-guided image interpolation algorithm via directional filtering and data fusion." *IEEE transactions on image processing* **15**(8): 2226-2238.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Semih KAHVECİ
Uyruğu : Türk Vatandaşı
Doğum Yeri ve Tarihi : Erzurum / 1994
Telefon : 532 720 39 01
Faks :
E-Posta : semihkahveci@outlook.com

EĞİTİM

Derece	Adı	İlçe	İl	Bitirme Yılı
Lise	: Toki Duran Karabuğuş Lisesi	Dulkadirođlu		2012
Üniversite	: Selçuk Üniversitesi Bilgisayar Mühendisliđi			2017
Yüksek Lisans	: Konya Teknik Üniversitesi			-