

# Uydu İmgelerine Derin Öğrenme Tabanlı Süper Çözünürlük Yöntemlerinin Uygulanması

Ayşe CENGİZ<sup>1</sup>, Derya AVCI<sup>2</sup>

<sup>1</sup> Fırat Üniversitesi, Fen Bilimleri Enstitüsü, Elazığ.

<sup>2</sup> Fırat Üniversitesi, Teknik Bilimler MYO, Bilgisayar Teknolojileri Bölümü, Elazığ.

Sorumlu yazar, e-posta: aayscengiz@gmail.com  
davci@firat.edu.tr

ORCID ID: <https://orcid.org/0000-0003-3829-3243>  
ORCID ID: <https://orcid.org/0000-0002-9708-3425>

Geliş Tarihi: 28.11.2020

Kabul Tarihi: 12.10.2021

## Öz

Askeri ve sivil hayatta önemli tüm uygulamalar için kullanılan görüntünün çözünürlüğünün yüksek olması çok önemlidir. Uydu imgeleri barındıran çalışmalarda süper çözünürlük ile iyileştirilmiş imgelerin kullanımı bina tespiti gibi uygulamalarda gereklidir. Düşük çözünürlüklü görüntünün giriş olarak verildiği süper çözünürlük algoritmalarında çeşitli iyileştirme adımları neticesinde çıktı olarak yüksek çözünürlüklü görüntü elde edilir. Bu çalışmada kullanıma açık uydu görüntülerinden alınan 6 sınıfa ayrılmış toplam 900 imge üzerinde, derin öğrenme tabanlı evrimsel sinir ağları ile süper çözünürlük iyileştirilmesinin performansı analiz edilmiştir. Veri seti üzerinde derin öğrenme için test ve eğitim verileri ayrılmıştır. Verilere DenseNet201, SqueezeNet, Vgg16 olmak üzere toplam 3 derin öğrenme mimarisi ayrı ayrı uygulanmıştır. Süper çözünürlük adımı öncesinde ve sonrasında doğru sınıflandırılmış veri oranının kontrolü için evrimsel sinir ağları uygulanmıştır. Sınıflandırma sonuçları karşılaştırılmış, sınıflandırma sonucunda evrimsel sinir ağları öğrenme özellikleri süper çözünürlük sayesinde iyileştirilmiştir. Sınıflandırılma başarısı 6 sınıflandırılma mimarisi için en düşük %2,4 ve en yüksek %3,6 oranında arttırılmış olduğu kanıtlanmıştır.

## Anahtar kelimeler

Süper Çözünürlük;  
Evrimsel Sinir Ağları;  
Derin Öğrenme;  
Softmax

## Application of Deep Learning Based Super Resolution Methods To Satellite Images And Improvement Of Images

### Abstract

High resolution of the image used for all important applications in military and civil life is very important. In works with satellite images, the use of images enhanced with super resolution is necessary in applications such as building detection. In the super resolution algorithms where the low-resolution image is given as input, high resolution image is obtained as a result of various improvement steps. The performance of super resolution improvement with deep learning based convolutional neural networks on 900 images taken from available satellite images was analyzed. Test and training data are reserved for deep learning on the dataset. A total of 3 softmax functions (DenseNet201, SqueezeNet, Vgg16) were applied to the data separately. Evolutionary neural networks were applied to control the number of correctly classified data before and after the super resolution step. The classification results are compared and as a result of the classification, the learning properties of the convolutional neural networks are increased by super resolution. Classification success has proven to be increased by the lowest 2.4% and the highest 3.6% for the 6 classification architectures.

### Keywords

Super Resolution;  
Convolutional Neural  
Network; Deep  
Learning; Softmax

### 1. Giriş

Nihai Uydu görüntüleri günümüzde adres sorgulama, alan inceleme, şehir planlama, tarım gibi birçok alanda aktif kullanılmaktadır. Dünya'nın topografik ölçümlerini mümkün kılan büyük miktarda yüksek çözünürlüklü (uzamsal çözünürlük)

uydu görüntüleri uydular sayesinde elde edilmiştir. Bununla birlikte, yüksek uzamsal çözünürlüğe sahip uydu görüntüleri, görüntü sınıflandırmada birçok sorun ortaya çıkarmaktadır. Mekansal çözünürlüğün artmasıyla birlikte, dünya yüzeyinde bulunan daha fazla ayrıntı uydu görüntülerinde ortaya çıkmakta ve

aynı tür sahnelerde yer alan nesnelere, yüksek çözünürlükteki görüntüler arasında farklı ölçeklerde ve oryantasyonlarda görülebilmektedir.

Uydu imgelerine yakınlaştırma yapılırken çözünürlük düştüğü için net görüntü elde etmek zordur ve düşük çözünürlükte görüntü kalitesi azaldığı için sınıflandırma yapıldığı zaman iyi bir performans elde edilemez. Düşük çözünürlükte yanlış sınıflandırma yapılması önlenemeyeceği için önce imge çözünürlüğü artırılmalı ve sonra sınıflandırma işlemi yapılmalıdır. Süper çözünürlük (SR) aynı görüntünün bir veya daha çok düşük çözünürlüklü halinden yüksek çözünürlüklü görüntüleri elde etme yöntemidir. Süper çözünürlük yüksek piksel yoğunluğuna sahiptir. Çözünürlüğü artan imgelerin doğru sınıflandırılma oranı artmaktadır (Chopade ve Patil 2015).

Son yıllarda, yüksek çözünürlüklü görüntünün yeniden yapılandırılması için birçok yeni algoritma önerilmiştir. Görüntünün tek kare süper çözünürlüğü için ana yaklaşımlardan biri, düşük frekanslı görüntüden yüksek frekanslı bilgilerin çıkarıldığı ve ilk görüntüde ayrıntılı bilgi için tahminin yapıldığı görüntünün enterpolasyonudur (Chopade ve Patil 2015).

Süper çözünürlük için ayrıntıları eklemeyen piksel sayısını artıran standart enterpolasyon tekniklerine (piksel replikasyonu, bilinear, bi-kübik, lineer enterpolasyon) dayanan birçok yöntem mevcuttur. Görüntü önceliklerine göre, tek görüntü süper çözünürlük algoritmaları dört tipe kategorize edilebilir. Bunlar tahmin modelleri, kenar tabanlı yöntemler, görüntü istatistiksel yöntemleri ve yama tabanlı (veya örnek tabanlı) yöntemlerdir. Bu yöntemler Yang vd. (2014) çalışmasında kapsamlı bir şekilde araştırılmış ve değerlendirilmiştir. Bunlar arasında, örnek tabanlı yöntemler (Glasner vd. 2009, Kim vd. 2010, Timofte vd. 2013, Yang vd. 2013) en gelişmiş performansa ulaşmaktadır. Dahili örnek tabanlı yöntemler öz-benzerlik özelliğinden yararlanır ve giriş görüntüsünden örnek yamalar oluşturur. İlk olarak Glasner vd. (2009) çalışmasında uygulamayı hızlandırmak için bazı geliştirilmiş varyantlar (Freedman ve Fattal 2011,

Yang vd. 2010) önerilmektedir. Harici örnek tabanlı yöntemler (Timofte vd. 2013, Bevilacqua vd. 2012, Chang vd. 2004, Dai vd. 2015, Freeman vd. 2000, Schuler vd. 2015, Yang vd. 2012, Yang vd. 2008, Yang vd. 2010, Zeyde vd. 2012) harici veri kümelerinden düşük / yüksek çözünürlüklü yamalar arasında bir harita öğrenir. Seyrek kodlama temelli yöntem ve çeşitli gelişmeleri (Timofte vd. 2013, Yang vd. 2012, Timofte vd. 2014) günümüzde en gelişmiş SR yöntemleri arasındadır. Bu yöntemlerde, yamalar optimizasyonun odağıdır; yama çıkarma ve toplama aşamaları, ön / son işlem olarak kabul edilir ve ayrı olarak ele alınmaktadır (Chao vd. 2015)

## 2. Materyal ve Metot

Uydu imgelerinin belirlenmiş sınıflara göre toplanması, derin makine öğrenmesi yardımı ile sınıflandırılması, süper çözünürlük algoritmalarının uygulanması ve süper çözünürlük ile iyileşmiş imgelerin tekrar sınıflandırılması adımları için çeşitli işlemler ve araçlar kullanılmıştır.

Bu çalışmanın temel amacı uydu imgelerinin sınıflandırılma performansını arttırmak üzere imgelere derin öğrenme tabanlı süper çözünürlük yöntemleri uygulamaktır. Bu çalışmada uydu imgelerine süper çözünürlük adımları uygulayarak evrimsel sinir ağları yardımı ile sınıflandırmak üzere imgeler kullanılmıştır. Ana sınıflar belirlenirken uydu imgelerinden yararlanılmış ve ayırt edici özellikleri bulunan cami, ev, hastahane, okul, park ve stadyum olmak üzere toplamda 6 sınıf belirlenmiştir.

Sınıflandırma performansının etkilerini görme amaçlı olarak veri seti, Türkiye'deki çeşitli illerden cami, ev, hastahane, okul, park ve stadyum sınıflarına ait, her sınıf için 150 imge açık erişim imkânı bulunan Google Earth (Int kyn. 1) kullanılarak manuel olarak toplanmıştır. Toplamda 900 imge üzerinde derin öğrenme tabanlı sınıflandırma ve süper çözünürlük algoritmaları uygulanmıştır.

Şekil 1' de bu çalışmada kullanılan veri setine ait uydu imgelerinden bazıları verilmiştir.



Şekil 1. Veri setine ait uydu imgeleri

Evrişimsel sinir ağları için eğitim ve test olmak üzere iki ana bölüme ayırdığımız verilerin işlenmesi için Matlab 2020a yazılımı kullanılmıştır. Derin makine öğrenmesi uygulamaları için 16 GB RAM bulduran intel i7 3.1 Ghz işlemcili Macbook Pro kullanılmıştır. Windows işletim sistemi gerektiren dosyadan imge okuyan ve imge üzerinde iyileştirmelerde bulduktan sonra yeni imgeyi klasöre kaydeden süper çözünürlük algoritması için intel i5 işlemcili 8 GB RAM bulduran bilgisayar kullanılmıştır. Genel yaklaşım gereği mevcut veri, eğitim için %70 ve test için %30 oranında kümelere bölünmüştür. Softmax sınıflandırıcı katmanlarının eğitim ve sonuç verileri Matlab yazılımı ile çıkarılmış sonrasında süper çözünürlük yöntemi için tekrar Matlab yazılımı üzerinden sınıflara bağlı olarak tüm imgeler iyileştirilmiştir. Süper çözünürlük algoritmasının uydu imgelerini iyileştirerek daha iyi bir sınıflandırma yaptığını kanıtlamak amacı ile süper çözünürlük adımından sonra iyileştirilmiş imgeler bir kez daha evrişimsel sinir ağları yardımı ile sınıflandırılmıştır. Bu işlemler sonucunda oluşan grafikler, test süreleri, doğruluk değerleri, karmaşıklık matrisleri ile sınıflandırma performansı kontrolü için gerekli analiz bilgileri, bulgular ve tartışma bölümünde açıklanmıştır.

Derin evrişimsel sinir ağlarına dayalı modelin performansı üç farklı derin öğrenme mimarisi parametresi kullanılarak ayrı ayrı test edilmiştir. Toplamda 900 imge ilk önce evrişimsel sinir ağları yardımı ile softmax fonksiyonları olan DenseNet201 Simonyan vd. (2014), SqueezeNet Mateen vd. (2019) ve VGG16 Zhang (2019) ile sınıflandırılmıştır. Derin öğrenme mimarilerinden öznitelik çıkarılarak bu öznitelikler SVM, KNN, karar ağaçları, Naive bayes gibi sınıflandırıcılarla sınıflandırılmıştır. Karmaşıklık matrisleri ve öğrenme grafikleri elde edildikten sonra imgeler üzerine süper çözünürlük algoritması uygulanmıştır.

Matcovnet kütüphanesine ihtiyaç duymayan, mevcut süper çözünürlük algoritmalarından daha iyi performans gösterdiği kanıtlanmış olan süper çözünürlük yöntemi kullanılarak imgelerin çözünürlüğünü arttırılmıştır (Jia-Bin vd. 2015). Çözünürlük işlem adımından sonra imgelerin doğru sınıflandırılmalarındaki oranı gözlemleyebilmek için süper çözünürlük işlemi uygulanan imgeler tekrar evrişimsel sinir ağları, SVM, KNN ile sınıflandırılmıştır. Sonuçları bulgular ve tartışma bölümünde açıklanmıştır.

### 3. Bulgular

Uydu imgelerinin süper çözünürlük ile iyileştirilmesini amaçlayan bu çalışmada öncelikle uydu imgeleri kullanılarak süper çözünürlük algoritması uygulanmıştır. Şekil 2’de çalışmada kullanılan uydu imgesi, Şekil 3’te uydu imgesine süper çözünürlük uygulanmış imge verilmiştir.



Şekil 2. Uydu imgesi




**Şekil 3.** Uydu imgesine süper çözünürlük uygulanmış imge

Çizelge 1’de veri setinde kullanılan cami, ev, hastahane, okul, park ve stadyum sınıflarına ait, her sınıf için bir imgenin büyüme faktörü X2 altında tepe sinyal gürültü oranı(PSNR) ve yapısal benzerlik endeksi(SSIM) metrikleri verilmiştir.

**Çizelge 1.** Görüntü Metrikleri Tablosu

Veri seti sınıfları	PSNR	SSIM
Veri seti 1	38,04	0,96
Veri seti 2	34,48	0,92
Veri seti 3	38,07	0,96
Veri seti 4	38,12	0,95
Veri seti 5	38,32	0,94
Veri seti 6	38,17	0,96

Süper çözünürlük algoritması sonucunda oluşan iyileşmeyi doğru analiz edebilmek için görüntüler üzerinde süper çözünürlük yöntemleri kullanılmadan önce ve sonra derin evrimsel sinir ağları, SVM, KNN ile sınıflandırma yapılarak sonuçlar karşılaştırılmıştır.



**Şekil 4.** Uygulanan yöntemler

Kullanılan ilk evrimsel sinir ağı mimarisi DenseNet201 evrimsel sinir ağı mimarisi softmax

yapısı %95,93 doğruluk oranına ulaşıldıktan sonra doğru tanıma oranını arttırma amaçlı imgelere süper çözünürlük uygulanmıştır. Uygulanan süper çözünürlük algoritması sonucunda elde edilen yeni imgeler tekrar sınıflandırılmıştır. İmgelerin çözünürlüklerinin arttırılması doğru tanıma oranını arttırmış %96,30 başarı oranı ile doğru tanıma yapıldığı gözlemlenmiştir.

Bir başka uygulamada DenseNet201 ile özellik çıkarımı yapılmış ve 1000 özellik çıkarılmıştır. Çıkarılan özellikler SVM, KNN, Naive Bayes gibi sınıflandırıcılara verilmiş ve başarı oranları süper çözünürlük öncesi ve sonrası oluşan değerler gözlemlenmiştir.

Elde edilen tüm sonuçlar süper çözünürlük önce ve sonrası şeklinde Çizelge 2.’de verilmiştir. En başarılı sonuç DenseNet201-Quadratic SVM ile %98,4 oranında elde edilmiştir. Süper çözünürlük kullanılarak %3,2 ‘lik başarı artışı sağlanmıştır.

**Çizelge 2.** DenseNet201 Sonuç Tablosu

Uygulanan Sınıflandırıcılar	Süper Çözünürlük Öncesi Doğruluk Oranları	Süper Çözünürlük Sonrası Doğruluk Oranları
DenseNet Softmax	%95,93	%96,30
DenseNet201-Cubic SVM	%95,7	%98,3
DenseNet201-Quadratic SVM	%95,2	<b>%98,4</b>
DenseNet201-Linear SVM	%93,8	%95,7
DenseNet201-Medium Guassian SVM	%95,2	%97,3
DenseNet201-Coarse Guassian SVM	%86,5	%89,7
DenseNet201-Fine KNN	%93,5	%96,8
DenseNet201-Medium KNN	%85,4	%88,9
DenseNet201-Cosine KNN	%88,1	%88,0
DenseNet201-Cubic KNN	%84,6	%88,8
DenseNet201-Weighted KNN	%88,7	%93,1
DenseNet201-Subspace KNN	%89,2	%94,4
DenseNet201-Bagged Trees	%94,0	%97,1
DenseNet201-Kernel Naive Bayes	%87,6	%89,2

DenseNet201 mimarisine ait en iyi sınıflandırma başarısını gösteren Quadratic SVM sonucunda oluşturulmuş karmaşıklık matrisleri süper çözünürlük algoritması imgelere uygulanmadan önce yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 5’ te ve süper çözünürlük algoritması imgelere uygulandıktan sonra yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 6’da verilmiştir. DenseNet201 mimarisi için en yüksek yanlış sınıflandırılma oranı eve ait imgelerin %6,2’sinin okul




sınıfına tanınması iken bu oran SR ile %1,3'e düşmüştür. Şekil 7'de DenseNet201 süper çözünürlük öncesi genel doğruluk ve kayıp grafiği, Şekil 8'de DenseNet201 süper çözünürlük sonrası genel doğruluk ve kayıp grafiği verilmiştir.

Cami	100.0%	1.9%		2.7%	0.9%	
Ev		92.4%	1.0%	6.2%		
Hastahane			98.1%	2.7%	0.9%	
Okul		4.8%	1.0%	87.5%		1.0%
Park				0.9%	98.1%	
Stadyum		1.0%				99.0%
PPV	100.0%	92.4%	98.1%	87.5%	98.1%	99.0%
FDR		7.6%	1.9%	12.5%	1.9%	1.0%
	Cami	Ev	Hastahane	Okul	Park	Stadyum


Şekil 5. DenseNet201 SR öncesi karmaşıklık matrisi

Cami	100.0%	0.7%		0.7%		
Ev		98.1%	0.7%	1.3%	0.7%	
Hastahane			98.7%	0.7%		
Okul		1.3%	0.7%	97.4%		
Park		1.3%			99.3%	
Stadyum		0.7%				100.0%
PPV	100.0%	98.1%	98.7%	97.4%	99.3%	100.0%
FDR		3.9%	1.3%	2.6%	0.7%	
	Cami	Ev	Hastahane	Okul	Park	Stadyum

Şekil 6. DenseNet201 SR sonrası karmaşıklık matrisi



Şekil 7. DenseNet201 süper çözünürlük öncesi genel doğruluk ve kayıp grafiği



Şekil 8. DenseNet201 süper çözünürlük sonrası genel doğruluk ve kayıp grafiği

Diğer bir uygulamada SqueezeNet evrimsel sinir ağı mimarisi softmax sınıflandırma %92,22 doğruluk oranına ulaşıldıktan sonra doğru tanıma oranını arttırma amaçlı imgelere süper çözünürlük uygulanmıştır. Uygulanan süper çözünürlük algoritması sonucunda elde edilen yeni imgeler tekrar sınıflandırılmıştır. İmgelerin çözünürlüklerinin arttırılması sınıflandırma doğruluğunu arttırmış %93,70 başarı oranı ile doğru tanıma yapıldığı gözlemlenmiştir.

Bir diğer uygulamada SqueezeNet ile özellik çıkarımı yapılmış ve 1000 özellik çıkarılmıştır. Çıkarılan özellikler SVM, KNN, Naive Bayes gibi sınıflandırıcılara verilmiş ve başarı oranları süper çözünürlük öncesi ve sonrası oluşan değerler gözlemlenmiştir.

Elde edilen tüm sonuçlar süper çözünürlük önce ve sonrası şeklinde Çizelge 3.'te verilmiştir. En başarılı sonuç SqueezeNet-Quadratic SVM sonucunda %98,8 oranında elde edilmiştir. Süper çözünürlük kullanılarak %2,9 'luk başarı artışı sağlanmıştır.

Çizelge 3. SqueezeNet Sonuç Tablosu

Uygulanan Sınıflandırıcılar	Süper Çözünürlük Öncesi Doğruluk Oranları	Süper Çözünürlük Sonrası Doğruluk Oranları
SqueezeNet Softmax	%92,22	%93,70
SqueezeNet-Cubic SVM	%95,6	%98,4
SqueezeNet-Quadratic SVM	%95,9	<b>%98,8</b>
SqueezeNet-Linear SVM	%93,5	%94,6
SqueezeNet-Medium Guassian SVM	%92,9	%97,0
SqueezeNet-Coarse Guassian SVM	%85,9	%86,3
SqueezeNet-Fine KNN	%89,7	%96,8
SqueezeNet-Medium KNN	%84,1	%86,1
SqueezeNet-Coarse KNN	%75,7	%74,6
SqueezeNet-Cosine KNN	%72,7	%82,0
SqueezeNet-Cubic KNN	%80,0	%86,4
SqueezeNet-Weighted KNN	%86,0	%92,4
SqueezeNet-Subspace KNN	%88,7	%96,6
SqueezeNet-Bagged Trees	%88,3	%90,9

SqueezeNet mimarisine ait en iyi sınıflandırma başarısını gösteren Quadratic SVM sonucunda oluşturulmuş karmaşıklık matrisleri süper çözünürlük algoritması imgelere uygulanmadan önce yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 9'da ve süper çözünürlük algoritması imgelere


uygulandıktan sonra yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 10'da verilmiştir. SqueezeNet mimarisi için en yüksek yanlış sınıflandırılma oranı okula ait imgelerin %9,0'unun ev sınıfına tanınması iken bu oran SR ile %5,9'a düşmüştür. Eve ait imgelerin park, hastaneye ait imgelerin park ve okul, okula ait imgelerin stadyum

Cami	99.0%	0.9%	1.9%	1.0%	0.9%	
Ev	1.0%	90.1%		4.0%		
Hastahane			96.3%		0.9%	
Okul		9.0%	0.9%	94.0%		
Park			0.9%		96.3%	
Stadyum				1.0%	1.9%	100.0%
PPV	99.0%	90.1%	96.3%	94.0%	96.3%	100.0%
FDR	1.0%	9.9%	3.7%	6.0%	3.7%	
	Cami	Ev	Hastahane	Okul	Park	Stadyum

Şekil 9. SqueezeNet SR öncesi karmaşıklık matrisi


Cami	99.3%	0.7%	2.0%	0.7%	0.6%	
Ev	0.7%	92.8%		4.1%	1.3%	
Hastahane			98.0%			
Okul		5.9%		95.3%		
Park		0.7%			96.1%	
Stadyum					1.9%	100.0%
PPV	99.3%	92.8%	98.0%	95.3%	96.1%	100.0%
FDR	0.7%	7.2%	2.0%	4.7%	3.9%	
	Cami	Ev	Hastahane	Okul	Park	Stadyum

Şekil 10. SqueezeNet SR sonrası karmaşıklık matrisi



Şekil 11. SqueezeNet süper çözünürlük öncesi genel doğruluk ve kayıp grafiği

sınıfına yanlış tanınması tamamen ortadan kalkmıştır. Şekil 11'de SqueezeNet süper çözünürlük öncesi genel doğruluk ve kayıp grafiği, Şekil 12'de SqueezeNet süper çözünürlük sonrası genel doğruluk ve kayıp grafiği verilmiştir.



Şekil 12. SqueezeNet süper çözünürlük sonrası genel doğruluk ve kayıp grafiği

Bir başka uygulamada Vgg16 evrimsel sinir ağı mimarisi softmax sınıflandırma %95,56 doğruluk oranına ulaşıldıktan sonra doğru tanıma oranını artırma amaçlı imgelere süper çözünürlük uygulanmıştır. Uygulanan süper çözünürlük algoritması sonucunda elde edilen yeni imgeler tekrar sınıflandırılmıştır. İmgelerin çözünürlüklerinin artırılması doğru tanıma oranını arttırmış %96,30 başarı oranı ile doğru tanıma yapıldığı gözlemlenmiştir.

Bir başka uygulamada Vgg16 ile özellik çıkarımı yapılmış ve 1000 özellik çıkarılmıştır. Çıkarılan özellikler SVM, KNN, Naive Bayes gibi sınıflandırıcılara verilmiş ve başarı oranları süper çözünürlük öncesi ve sonrası oluşan değerler gözlemlenmiştir.

Elde edilen tüm sonuçlar süper çözünürlük önce ve sonrası şeklinde Çizelge 4.'te verilmiştir. Vgg16-Quadratic sonucunda %97,1 oranında yüksek başarı elde edilmiştir. Süper çözünürlük kullanılarak %3,6 'lık başarı artışı sağlanmıştır.

Çizelge 4. Vgg16 Sonuç Tablosu

Uygulanan Sınıflandırıcılar	Süper Çözünürlük Öncesi Doğruluk Oranları	Süper Çözünürlük Sonrası Doğruluk Oranları
Vgg16 Softmax	%95,56	%96,30
Vgg16-Cubic SVM	%93,2	%96,7
Vgg16-Quadratic SVM	%93,5	<b>%97,1</b>
Vgg16-Linear SVM	%90,6	%93,3
Vgg16-Medium Guassian SVM	%92,4	%95,3
Vgg16-Coarse Guassian SVM	%81,4	%83,1
Vgg16-Fine KNN	%86,8	%92,3

Vgg16-Medium KNN	%78,9	%79,7
Vgg16-Coarse KNN	%64,9	%67,4
Vgg16-Cosine KNN	%79,0	%80,6
Vgg16-Cubic KNN	%79,7	%79,0
Vgg16-Weighted KNN	%83,0	%85,6
Vgg16-Subspace KNN	%87,3	%91,8
Vgg16-Kernel Naive Bayes	%80,3	%80,3

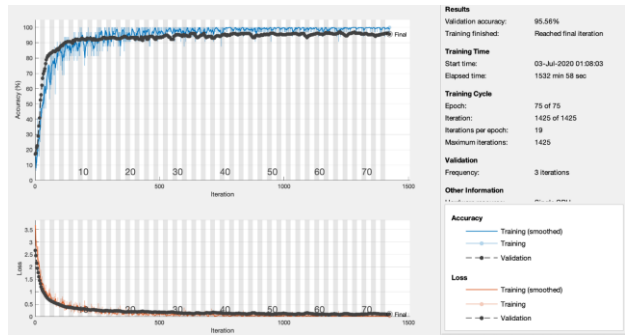
VGG16 mimarisine ait en iyi sınıflandırma başarısını gösteren Quadratic SVM sonucunda oluşturulmuş karmaşıklık matrisleri süper çözünürlük algoritması imgelere uygulanmadan önce yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 13'te ve süper çözünürlük algoritması imgelere uygulandıktan sonra yapılan sınıflandırma sonucu oluşturulmuş karmaşıklık matrisi Şekil 14'te verilmiştir. VGG 16 mimarisi için en yüksek yanlış sınıflandırılma oranı eve ait imgelerin %5,6'sının okul sınıfına tanınması iken bu oran SR ile %1,3'e düşmüştür. Eve ait imgelerin park, parka ait imgelerin stadyum, okul ve cami sınıfına yanlış tanınması tamamen ortadan kalkmıştır. Şekil 15'te VGG16 süper çözünürlük öncesi genel doğruluk ve kayıp grafiği, Şekil 16'da VGG16 süper çözünürlük sonrası genel doğruluk ve kayıp grafiği verilmiştir.

Cami	97.8%	5.4%	4.3%	1.9%	1.0%	
Ev	2.2%	97.4%			5.6%	
Hastahane			91.3%			
Okul		4.5%	2.6%	88.9%	1.0%	
Park		0.9%	1.7%	2.8%	97.1%	
Stadyum		1.8%		0.9%	1.0%	100.0%
PPV	97.8%	87.4%	91.3%	88.9%	97.1%	100.0%
FDR	2.2%	12.6%	8.7%	11.1%	2.9%	

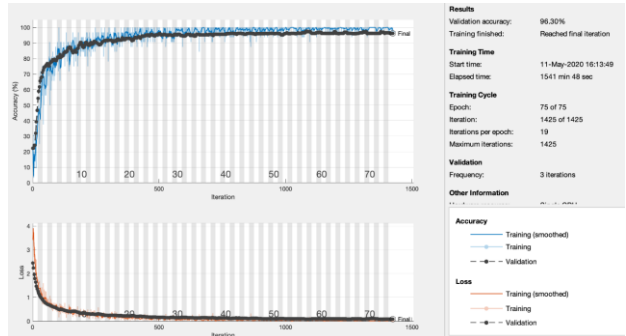
Şekil 13. VGG16 SR öncesi karmaşıklık matrisi

Cami	99.3%	3.2%	0.6%	1.3%		
Ev	0.7%	93.0%		1.3%		
Hastahane			96.8%			
Okul		3.2%	1.3%	94.7%		
Park			1.3%	1.3%	100.0%	
Stadyum		0.6%		1.3%		100.0%
PPV	99.3%	93.0%	96.8%	94.7%	100.0%	100.0%
FDR	0.7%	7.0%	3.2%	5.3%		

Şekil 14. VGG16 SR sonrası karmaşıklık matrisi



Şekil 15. VGG16 süper çözünürlük öncesi genel doğruluk ve kayıp grafiği



Şekil 16. VGG16 süper çözünürlük sonrası genel doğruluk ve kayıp grafiği

Karmaşıklık matrisleri ile 3 sınıf üzerinde imgelerin doğru ve yanlış sınıflandırılması üzerinde durulmuştur. Süper çözünürlük sonucu imge netleştiği için öz nitelik çıkarımı artmaktadır. Bu nedenle doğru sınıflandırılma oranı artmıştır.

#### 4. Tartışma ve Sonuç

Uydu imgelerine süper çözünürlük algoritmalarının uygulanması ve giriş, çıkış imgelerinin evrişimsel sinir ağları mimarileri ile sınıflandırılarak sınıflandırılma doğruluk oranlarının artırılması amaçlanmıştır.

Bu çalışmada yapılan uygulamaların karşılaştırılması ile DenseNet201 mimarisi için %95,2 iken süper çözünürlük sonrası %3,2 artarak %98,4 oranında başarıma ulaşılmıştır. SqueezeNet mimarisi için %95,9 iken süper çözünürlük sonrası %2,9 artarak %98,8 oranında başarıma ulaşılmıştır. VGG16 mimarisi için %93,5 iken süper çözünürlük sonrası %3,6 artarak %97,1 oranında başarıma ulaşılmıştır.

Uygulanan sinir ağları ile görüntü sınıflandırma sürecinde, doğruluk oranları %100'e yaklaşmıştır. Evrişimsel sinir ağı mimarilerinden DenseNet201, SqueezeNet ve VGG-16 görüntüler üzerine uygulanmış ve sonucunda test süreleri, doğruluk oranları Tablo 4'te verilmiştir. DenseNet201 için doğruluk değeri %95,2 iken süper çözünürlük sonrası sınıflandırma sonucu doğruluk oranı %98,4 olmuştur. SqueezeNet için doğruluk değeri %95,9 iken süper çözünürlük sonrası sınıflandırma sonucu doğruluk oranı %98,8 olmuştur. VGG-16 için doğruluk değeri %93,5 iken süper çözünürlük sonrası sınıflandırma sonucu doğruluk oranı %97,1 olmuştur.

Çizelge 5'te üzerinde imgelere uygulanan sınıflandırma mimarilerinden en iyi sınıflandırmaların doğruluk oranları ve test süreleri ile imgelere süper çözünürlük uygulandıktan sonra elde edilen süper çözünürlük doğruluk oranları ile süper çözünürlük test süreleri verilmiştir. Uygulanan evrişimsel sinir ağları çeşitlerinde görüldüğü gibi süper çözünürlük işlemi sonrası doğruluk değerlerinde artış olmuştur.

**Çizelge 5.** Evrişimsel Sinir Ağları Mimarilerine Ait Sonuç Tablosu

Evrişimsel Sinir Ağı Mimarileri	S.Ç. Öncesi Doğruluk Oranı	S.Ç. Öncesi Test Süresi	S.Ç. Sonrası Doğruluk Oranı	S.Ç. Sonrası Test Süresi
<b>DenseNet201</b>				
Quadratic SVM	%95,2	1.7387	<b>%98,4</b>	1.7228
<b>SqueezeNet</b>				
Quadratic SVM	%95,9	0.50443	<b>%98,8</b>	0.48742
<b>Vgg16</b>				
Quadratic SVM	%93,5	1.204	<b>%97,1</b>	0.61612

Yapılan uygulamalar sonucunda sınıflandırılma başarısı 3 mimari için en düşük %2,9 ve en yüksek %3,6 oranında artırılmış olduğu kanıtlanmıştır. Süper çözünürlük algoritması uygulanan uydu görüntüleri üzerinde evrişimsel sinir ağları yöntemlerinin özellik çıkartması artmıştır. Özellik çıkartma aşamasının geliştirilmesi ile karmaşıklık matrislerinde doğru pozitif sınıflandırma artmış ve doğru sınıflandırma performansı olumlu etkilenmiştir.

#### 5. Kaynaklar

- Bevilacqua, M., Roumy, A., Guillemot, C., Morel, M.L.A. 2012. Low-complexity single-image super-resolution based on nonnegative neighbor embedding, *British Machine Vision Conference*.
- Chang, H., Yeung, D.Y., Xiong, Y. 2004. Super-resolution through neighbor embedding, *IEEE Conference on Computer Vision and Pattern Recognition*, 1-1.
- Chao D., Chen C. L., Kaiming H., Xiaoou T. 2015. Image Super-Resolution Using Deep Convolutional Networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 38,2, 295-307.
- Chopade P. B., Patil P. M. 2015. Image super resolution Scheme based on wavelet transform and its performance analysis, *International Conference on Computing, Communication and Automation*, 1182-1186.
- Dai, D., Timofte, R., Van Gool, L. 2015. Jointly optimized regressors for image super-resolution, *Eurographic*, 95-104.



- Freedman, G., Fattal, R. 2011. Image and video upscaling from local self-examples, *ACM Transactions on Graphics*, 30,2, 12.
- Freeman, W.T., Pasztor, E.C., Carmichael, O.T. 2000. Learning low-level vision, *International Journal of Computer Vision*, 40,1, 25–47.
- Glasner, D., Bagon, S., Irani, M. 2009. Super-resolution from a single image, *IEEE International Conference on Computer Vision*, 349–356.
- Jia-Bin H., Abhishek S., and Narendra A., 2015, Single Image Super-Resolution from Transformed Self-Exemplars, *Computer Vision and Pattern Recognition*, 5197-5206.
- Kim, K.I., Kwon, Y. 2010. Single-image super-resolution using sparse regression and natural image prior, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32,6, 1127–1133.
- Mateen M., Wen J., Song S.N., Huang Z. 2019. Fundus Image Classification Using VGG-19 Architecture with PCA and SVD, *Symmetry*.
- Schulter, S., Leistner, C., Bischof, H. 2015. Fast and accurate image upscaling with super-resolution forests, *IEEE Conference on Computer Vision and Pattern Recognition*, 3791–3799.
- Simonyan K., Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition, *arXiv*, 1409.1556.
- Timofte R., De Smet, Van Gool L. 2013. Anchored neighborhood regression for fast example-based super-resolution, *IEEE International Conference on Computer Vision*, 1920–1927.
- Timofte, R., De Smet, V., Van Gool, L. 2014. A+: Adjusted anchored neighborhood regression for fast super-resolution, *IEEE Asian Conference on Computer Vision*, 111–126.
- Yang, C.Y., Huang, J.B., Yang, M.H. 2010. Exploiting self-similarities for single frame super-resolution, *IEEE Asian Conference on Computer Vision*, 497–510.
- Yang, C.Y., Ma, C., Yang, M.H. 2014. Single image super resolution: A benchmark, *European Conference on Computer Vision*, 372–386.
- Yang, J., Lin, Z., Cohen, S. 2013. Fast image super-resolution based on in-place example regression, *IEEE Conference on Computer Vision and Pattern Recognition*, 1059–1066.
- Yang, J., Wang, Z., Lin, Z., Cohen, S., Huang, T. 2012. Coupled dictionary training for image super-resolution, *IEEE Transactions on Image Processing*, 21,8, 3467–3478.
- Yang, J., Wright, J., Huang, T., Ma, Y. 2008. Image super-resolution as sparse representation of raw image patches, *IEEE Conference on Computer Vision and Pattern Recognition*, 1–8.
- Yang, J., Wright, J., Huang, T.S., Ma, Y. 2010. Image super-resolution via sparse representation, *IEEE Transactions on Image Processing*, 19,11, 2861–2873.
- Zeyde, R., Elad, M., Protter, M. 2012. On single image scale-up using sparse-representations, *Curves and Surfaces*, 711–730.
- Zhang J. 2019. A full convolutional network based on DenseNet for remote sensing scene classification, *Mathematical Biosciences and Engineering*, 6, 5, 3345–3367.

#### **İnternet kaynakları**

1-<http://www.google.com/int/tr/earth>, (01.04.2020)