



A novel super-resolution approach for computed tomography images by inverse distance weighting method

Mehmet Cem Çatalbaş*, Arif Gülten

Department of Electrical and Electronics Engineering University of Fırat, Elazığ, Turkey

Highlights:

- Adaptive image enhancement applications
- Improved inverse distance weighting method
- Super-resolution on medical images

Keywords:

- Image enhancement
- Histogram matching
- Inverse distance weighting
- Biomedical image processing
- Single image super-resolution

Graphical/Tabular Abstract

In this study, a single image super-resolution (SR) approach, which is an integrated use of inverse distance weighting (IDW) and histogram equalization methods, is proposed. The performance of the approach has been tested using a computed tomography database (115 CT images). The implementation process of the proposed algorithm is shown in Figure 1.

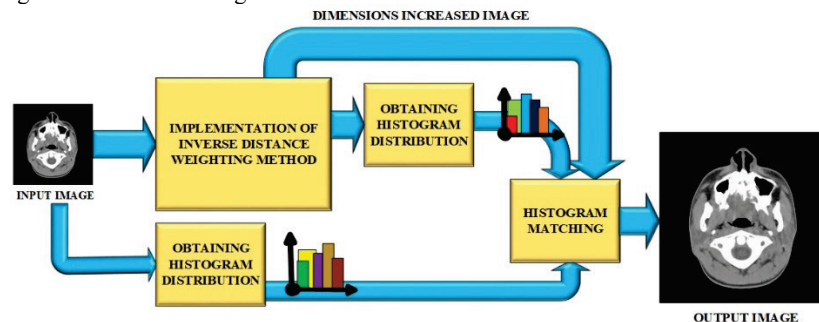


Figure 1. Flowchart of Proposed Algorithm

Purpose: In the proposed approach, while the edge information of the image is successfully preserved by the inverse distance weighting method, the brightness values of the pixels are approximated to the true image through general histogram equalization. It is aimed to reduce the detail loss which will be the result of increasing the dimensions of the images.

Theory and Methods: In this work, a hybrid approach is proposed for single image super-resolution algorithm. It contains inverse distance weighting and histogram matching method.

Results:

The performance results of the algorithm were compared common SR algorithm and other SR algorithm in literature via structural similarity index (SSIM). The name of method 1 is iterative back projection based single image super-resolution approach and the name of method 2 is single-image super-resolution using sparse regression and natural image prior.

Article Info:

Received: 15.12.2016

Accepted: 23.06.2017

DOI:

10.17341/gummfd.57389

Acknowledgement:

Correspondence:

Author: Mehmet Cem
Catalbas
e-mail: catalbas@firat.edu.tr
phone: +90 424 237 0000 /
5216

Table 1. Comparison of methods according to SSIM parameter

Method	SSIM			
	Mean	Standart Deviation	Minimum Value	Maximum Value
Nearest-neighbor	0,8731	0,0135	0,8415	0,9125
Bilinear	0,8965	0,0111	0,8696	0,9310
Lanczos	0,8990	0,0108	0,8728	0,9322
Bicubic	0,8983	0,0108	0,8721	0,9318
Method 1	0,9083	0,0115	0,8802	0,9383
Method 2	0,9134	0,0105	0,8897	0,9395
Proposed Method	0,9225	0,0090	0,8999	0,9496

Conclusion: The proposed algorithm has better and robust results according to SSIM parameter. Additionally, the algorithm is protected edge information (figure of merit) more successfully. The protection rate of edge information is increased by about 2 percent.



Ters mesafe ağırlıklandırma yöntemiyle bilgisayarlı tomografi imgeleri için yeni bir süper çözünürlük yaklaşımı

Mehmet Cem Çatalbaş*^{ID}, Arif Gülten^{ID}

Fırat Üniversitesi, Mühendislik Fakültesi, Elektrik ve Elektronik Mühendisliği Bölümü, Elazığ, 23200, Türkiye

Ö N E Ç İ K A N L A R

- Uyarlamalı imge detaylandırma uygulamaları
- Ters mesafe ağırlıklandırma yöntemi
- Medikal imgelerde süper çözünürlük

Makale Bilgileri

Geliş: 15.12.2015

Kabul: 23.06.2017

DOI:

10.17341/gazimmfd.416379

Anahtar Kelimeler:

İmge iyileştirme
histogram eşleştirme
ters mesafe ağırlıklandırma
biyomedikal imge işleme
tekli imge süper çözünürlük

ÖZET

Bu çalışmada ters mesafe ağırlıklandırma yöntemi ve histogram eşitleme yöntemlerinin bütünlük kullanılması ile oluşturulan bir tekli imge süper çözünürlük yaklaşımı önerilmiştir. Yapılan çalışmada imgelerin boyutlarının artırılması sonucu oluşacak detay kayıplarının en aza indirgenmesi hedeflenmiştir. Önerilen yaklaşımda, ters mesafe ağırlıklandırma yöntemi ile imgeye ait kenar bilgileri başarı ile korunurken, piksellere ait parlaklık değerleri genel histogram eşitleme sayesinde gerçek imgeye benzetilmiştir. Bilgisayarlı tomografi imgelerinden oluşan bir veri tabanı kullanılarak yaklaşımın başarımı test edilmiştir. Elde edilen sonuçlar, literatürde kullanılan çeşitli süper çözünürlük yöntemleri ile detaylı bir şekilde karşılaştırılmıştır. Yöntemlerin başarımları karşılaştırılırken, korelasyon katsayısı, tepe sinyal gürültü oranı, yapısal benzerlik indeksi ve Pratt'ın başarımlar ölçüsünden faydalanılmıştır.

A novel super resolution approach for computed tomography images by inverse distance weighting method

H I G H L I G H T S

- Adaptive image enhancement applications
- Improved inverse distance weighting method
- Super-resolution on medical images

Article Info

Received: 15.12.2015

Accepted: 23.06.2017

DOI:

10.17341/gazimmfd.416379

Keywords:

Image enhancement
Histogram matching
Inverse distance weighting
Biomedical image
processing
Single image super-
resolution

ABSTRACT

In this study, a single image super-resolution approach, which is an integrated use of inverse distance weighting and histogram equalization methods, is proposed. It is aimed to reduce the detail loss which will be the result of increasing the dimensions of the images. In the proposed approach, while the edge information of the image is successfully preserved by the inverse distance weighting method, the brightness values of the pixels are approximated to the true image through general histogram equalization. The performance of the approach has been tested using a computed tomography database. The results obtained were compared in detail with various super-resolution methods available in the literature. When comparing the performance of the method, correlation coefficient, peak signal to noise ratio, structural similarity index and Pratt's figure of merit were used.

1. GİRİŞ (INTRODUCTION)

Süper çözünürlük (SÇ), düşük çözünürlüklü bir veya birkaç imgeden yüksek çözünürlüklü yeni bir imgenin türetilmesi sürecidir [1]. SÇ ile birim alanda bulunan piksel sayısı artırılarak imgenin detaylandırılması sağlanır [2]. SÇ yöntemleri genellikle imge enterpolasyon teknikleri ile karıştırılmaktadır ve bu iki kavram bir anlamda iç içe geçmiştir. İmge enterpolasyon teknikleri genel olarak imgede bulunan yüksek frekanslı detayların korunması veya geri getirilmesi yerine belirli bir komşuluk ilişkisi içerisinde bulunan piksel değerlerini kullanarak yeni piksel değerlerinin elde edilmesini hedeflemektedir. Fakat bu bağlamda kenar uyarlamalı yani yüksek çözünürlüklü bileşenlerin boyut artırılması sürecinde korunması veya geliştirilmesini hedefleyen enterpolasyon teknikleri de SÇ uygulamaları kapsamında değerlendirilmektedir. SÇ kavramının karıştırıldığı diğer yöntemler olan imge restorasyonu, imge keskinleştirme gibi yöntemlerde çıkış imgesinin detayları artırılmış olmasına rağmen giriş ve çıkış imgeleri aynı boyutlardadır. Ancak SÇ yönteminde çıktı imgesindeki detaylarla birlikte birim alandaki piksel sayısı da artırılmaktadır. Bu bağlamda SÇ, birim alandaki piksel sayısının artırılmasının yanı sıra yüksek frekanslı bileşenlerin (kenar bilgilerinin) korunmasını sağlayan yöntemlere verilen genel bir ad olarak da tanımlanabilir.

SÇ'ün oldukça geniş bir uygulama alanı vardır ve bu kavramının başlıca uygulamaları şu şekilde sıralanabilir; uydru veya hava görüntülerinin [3], yüz imgelerinin [4], iris ve göz imgelerinin [5], yazı çıktılarının [6], işaret veya plaka bilgilerinin, parmak izi imgelerinin geliştirilmesi [7]. Bunlara ek olarak biyomedikal imge işleme alanında da SÇ kavramına ait çok sayıda uygulama bulunmaktadır [8, 9]. SÇ kavramı hem yazılım hem de donanım tabanlı olarak uygulanabilir olmasına rağmen, literatür çalışmalarının büyük kısmı yazılım tabanlı SÇ uygulamaları üzerinedir. Donanım tabanlı SÇ uygulamalarında kullanılan sensör sayısının artırılarak ve/veya piksel boyutları azaltılarak çıktı imgesi üzerindeki detayların artırılması amaçlanmaktadır [10, 11]. SÇ uygulamalarının gerçekleştirilmesi için çeşitli yöntemler önerilmiştir. İlk olarak, SÇ gerçek imge ile hesaplama sonucu elde edilen imge arasındaki farkın toplam enerjisinin azaltılmasını tanımlayan kavramsal bir hata parametresi olarak literatürde yer bulmuştur [12]. İlerleyen süreçlerde yapay sinir ağlarındaki gelişmelere paralel olarak SÇ alanında çok sayıda yapay sinir ağı tabanlı uygulama gerçekleştirilmiştir [13, 14]. Yakın zamanda ise ilgili alandaki gelişmelere paralel olarak derin öğrenme kapsamında da çok sayıda SÇ uygulaması gerçekleştirilmiştir [15]. Medikal imge gibi içerdiği bilgiler açısından hayati önem arz eden bir imgenin detaylandırılması veya yakınlaştırılması sonucu kaybolan detayların başarı ile geri getirilmesi oldukça önemlidir. Detayları artırılmış veya yorumlaması kolaylaştırılmış bir medikal imge bu alanda çalışan uzmanların teşhis koyma başarısını doğrudan artıracaktır. Medikal imgelerin elde edilmesi sürecinde çok sayıda istenmeyen etki söz

konusudur. Bunlardan bazıları: düşük çözünürlük (konum ve frekans tabanlı), yüksek gürültü oranı, düşük kontrastlı imgeler, geometrik deformasyonlar ve görüntümeden kaynaklanan yapay dokulardır [16]. İstenmeyen bu durumlardan kurtulmak için literatürde önerilen ve bu çalışma kapsamında başarıyı karşılaştırılan yaklaşımlardan birisi, geri yayımlı tekrarlayan yöntemdir [17]. Bu yöntemde girdi imgesine ait çoklu düşük çözünürlüklü alt imgeler kullanılmaktadır. İlk aşamada süreç düşük çözünürlüklü bir girdi imgesi ile başlatılır. Sonraki aşamada ise başlangıç için gerekli olan yüksek çözünürlüklü görüntü girdi imgesine ait piksellerin seyreltilmesi ile elde edilir. Gözlemlenen düşük çözünürlüklü imgeyi elde etmek için yüksek çözünürlüklü başlangıç imgesi bozulur ve alt örneklenir. Benzetim sonucu elde edilen düşük çözünürlüklü imge ile gözlemlenen imge birbirlerinden çıkartılarak bu imgelere ait fark elde edilir. Sonraki aşamada bu farka yüksek geçiren bir filtre yapısı uygulanmaktadır. İlgili uygulama sonucu elde edilen kenar bilgileri düşük çözünürlüklü imgeye eklenerek detaylandırılır. Bu süreç iki çıktı arasındaki farkın enerjisinin belirli bir eşik değere yakınsamasına kadar tekrarlanır. Bu sayede kenar bilgileri başarı ile korunmuş yüksek çözünürlüklü imge elde edilir. Belirtilen bu geri yayımlı tekrarlayan SÇ yönteminin dezavantajı, eşik değerinin kullanıcı tarafından ön bilgisiz bir şekilde tanımlanmasıdır. Bu değer çok düşük olarak belirlenmesi, çıktı imgesinde oluşacak yapay dokulara neden olmaktadır. Ayrıca bu değerın olması gerekenden büyük olarak belirlenmesi sonucu girdi imgesi yeteri kadar detaylandırılmamaktadır [17]. İmgelerden bulunan istenmeyen çıktılardan arındırılmak amacıyla önerilen ve başarıyı karşılaştırılan bir diğer yöntem ise seyrek regresyon ve doğal görüntü öncelikli tekli imge SÇ yöntemidir [18]. İstatistik tabanlı bu çalışmada ise düşük çözünürlüklü giriş imgelerinden örnek giriş çıkış imge çiftlerine dayalı bir örnekleme haritası oluşturulmaktadır ve bu ilişkileri içeren harita kullanılarak hedef olarak belirlenen yüksek çözünürlüklü imgenin oluşturulması sağlanır. Bu eşleşme sürecinde girdi imgesi Bikübik enterpolasyon yöntemine tabi tutularak büyütülür ve bu süreçte kaybolan detayları geri getirmek için regresyon analizi gerçekleştirilir. Regresyon sonucu elde edilen girdi imgesini detaylandırmak için bir grup aday imge kümesi oluşturulur. Adaylar belirli bir benzerlik ölçütüne bağlı olarak düşük çözünürlüklü imgeye uygulanarak düşük çözünürlüklü imgedeki detaylar artırılır. Bu süreç sonucu elde edilen yüksek çözünürlüklü imgede bulunan ve istenmeyen yapay dokular işlem sonrası gerçekleştirilen bir süreç sonucu azaltılarak yüksek çözünürlüklü çıktı imgesi elde edilir. Seyrek regresyon ve doğal görüntü öncelikli tekli imge SÇ yaklaşımının dezavantajı ise seçilen yama boyutu ile yöntemin başarımın doğru orantılı olması ve bu değerın başarıyı doğrudan etkilemesidir. Büyük boyutlardaki girdi imgelerinde bu yöntemin gerçekleştirilme süresi oldukça uzundur [18]. Bu makale kapsamında ise tekli imge süper çözünürlük (SÇ) uygulamasına ilişkin yenilikçi bir yaklaşım önerilmiştir. Bu yaklaşım ile örnek test imgesinin boyutlarının artırılması sürecinde karşılaşılabilecek detay kaybının en aza indirilmesi

hedeflenmiştir. Birim alandaki piksel sayısı kenar bilgileri göz önünde bulundurularak artırılmış ve genel histogram eşitleme yöntemiyle düşük çözünürlüklü orijinal girdiye ait piksel değerleri eşleştirilmiştir. Bu sayede yüksek frekanslı bileşenlerin (kenar bilgilerinin) korunmasını sağlayan ve gerçek imge ile benzer piksel değerlerine sahip yüksek çözünürlüklü çıktılar elde edilmiş ve sonuçların başarımı çeşitli yöntemlerle karşılaştırılmıştır.

2. TEKLİ VE ÇOKLU İMGE SÜPER ÇÖZÜNÜRLÜK (SINGLE AND MULTI IMAGE SUPER-RESOLUTION)

SÇ yöntemleri genel olarak iki ayrı başlık altında incelenmektedir ve bunlar tekli ve çoklu imge süper çözünürlük yöntemleridir [19]. Tekli imge ile SÇ yöntemi, tek bir girdi imgesi üzerinden kaybolan detayların, tekrar aynı düşük çözünürlükteki imge üzerinden geri getirilmesi sürecini kapsar [20]. Bu bağlamda kaybolan bu detaylar iki farklı şekilde geri getirilebilir. Bunlardan birincisi; kullanıcı tarafından belirlenen veya uyarlamalı olarak hesaplanan komşuluk ilişkileri üzerinden imgenin yeniden detaylandırılması veya orijinal girdi imgesinin tamamı düşük boyutlardaki [3x3,5x5,vb.] yama yapıları şeklinde düşünülerek boyut büyütme işleminin benzer yapıdaki yamalar ile detaylandırılması şeklindedir [21]. Burada yama kavramı düşük boyutlardaki, orijinal imgeye ait olan alt imge grupları olarak tanımlanabilmektedir ve SÇ için bu kavram oldukça önem arz etmektedir [22]. Yama tabanlı SÇ yöntemlerinde yamaların benzerliklerini belirlemek ve anlamlandırmak için çeşitli örüntü tanıma yöntemlerine ihtiyaç vardır ve bu yöntemlerin başarımı ile SÇ yönteminin başarımı doğru orantılıdır. Çoklu imgeler vasıtası ile gerçekleştirilen SÇ yöntemlerinde ise benzer bilgileri içeren aynı imgelerden oluşan bir imge veri tabanı oluşturulur [23]. Bu veri tabanının oluşturulması süreci genellikle akıllı öğrenme yöntemleri ile çeşitli etiket bilgilerinin bağdaştırılması şeklinde olabileceği gibi, kullanıcı tarafından elle de bu etiket bilgileri ayarlanabilmektedir. Benzer özneliklere veya etiket bilgilerine ait imgelerde bulunan düşük çözünürlükteki detaylar, büyük boyutlardaki

yeni imgenin detaylandırılması sürecinde kullanılmaktadır [24]. Farklı SÇ yaklaşımlarının genel hatları ile olumlu ve olumsuz yönleri Tablo 1’de gösterilmiştir. Gerçek zamanlı olarak kolayca gerçekleştirilebilmesi, çıktılar üzerinden başarımların daha kolay karşılaştırılması ve herhangi bir harici veri tabanına ihtiyaç duymaması nedeniyle bu çalışmada tek imge üzerinden SÇ yaklaşımı gerçekleştirilmiştir. Bu çalışma kapsamında önerilen tekli imge SÇ yaklaşımı ise iki farklı yöntemin birleşiminden oluşmaktadır. Bu yöntemler, ters mesafe ağırlıklandırma (TMA) ve genel histogram eşitlemedir. Bu yöntemlerden TMA, Jeostatistik alanında belirli bir noktanın yükseklik, sıcaklık veya benzeri parametrelerin uyarlamalı olarak kestirilmesi sürecinde kullanılır. İmge uzayına ait piksel değerlerinin yükselti uzayına ait değerler ile benzerlik göstermesi, girdi imgesine ait değerlere göre uyarlamalı olması ve uygulamadaki kolaylıkları nedeniyle TMA yöntemi bu çalışma için tercih edilmiştir. Bir diğer yöntem olan genel histogram eşleştirme yöntemi ise imgelere ait piksel değerlerinin referans imge ile eşleştirilmesini gerçekleştirerek imgelerin gerçek piksel değerleri üzerinden detaylandırılmasını sağlayan bir yöntemdir. Bu iki yöntemin beraber ve belirli bir öncelik sırasına göre kullanılması sayesinde, yüksek çözünürlüklü ve detayları artırılmış imgeler elde edilmektedir.

3. TERS MESAFE AĞIRLIKLANDIRMA YÖNTEMİ (INVERSE DISTANCE WEIGHTING METHOD)

TMA Yöntemi sıklıkla yer bilimciler tarafında kullanılan bir enterpolasyon yöntemidir. Yöntem, kullanıcının belirli bir bölgeye veya alana ilişkin bilinenler ışığında, bilinmeyen bir alanın veya noktanın değerinin belirlenmesini sağlamaktadır [25]. İlgili enterpolasyon yönteminde x ve y koordinat bilgileri kullanılarak yükselti değerinin istenilen bölge için hesaplanması sağlanmaktadır [26, 27]. Temel bir enterpolasyon probleminde istenilen z değeri Eş. 1’de gösterildiği gibi tanımlanır.

$$z(x_0, y_0) = f(x_i, y_i) \quad (1)$$

Tablo 1. Süper Çözünürlük yaklaşımlarının karşılaştırılması (Comparison of super resolution approaches)

SÇ Yaklaşımı	Artıları	Eksileri
Tek İmgeden Süper Çözünürlük	<ul style="list-style-type: none"> Hızlı olması Kolay uygulanması Temel uygulamalar için yeterli sonuçlar vermesi 	<ul style="list-style-type: none"> Başarımın çoklu imgeye göre düşük olması Tek bir imge üzerindeki detaylar ile başarımların doğru orantılı olması İşlem maliyetinin ve sürecinin fazla olması Uygulanması için ayrı bir veri tabanı gereksinimi
Çoklu İmgeden Süper Çözünürlük	<ul style="list-style-type: none"> Başarımın genel olarak tek imgeye SÇ yöntemine göre yüksek olması Gerçek sonuca yakın değerler vermesi Yeni nesil uygulamalar için daha uygun olması Detayların önem arz ettiği SÇ uygulamalarında tercih sıklıkla kullanılması 	<ul style="list-style-type: none"> Başarımı ile ilgili veri tabanının boyutunun doğru orantılı olması. Veri tabanının boyutunun artması ile hesaplama süresinin karesel olarak artması

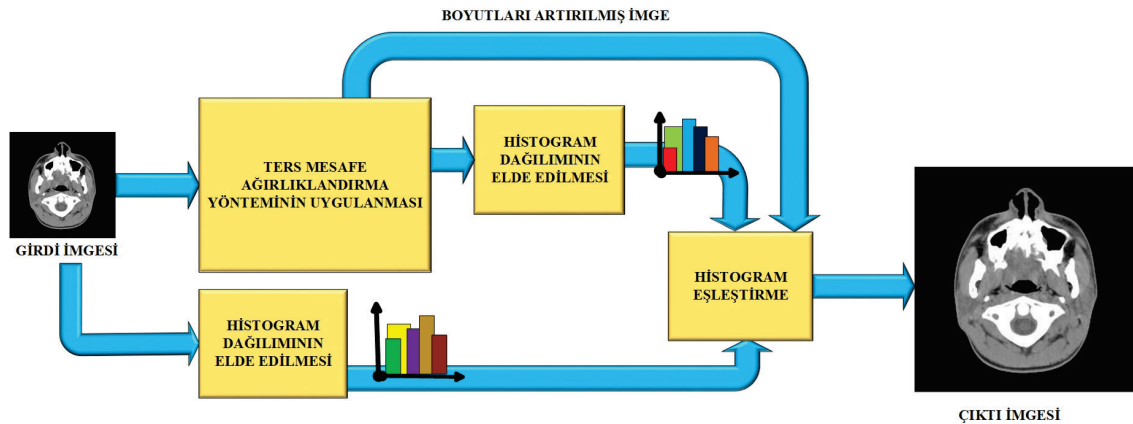
TMA yönteminde ise kestirimde bulunulan z değeri Eş. 2’de gösterildiği gibi tanımlanır. İlgili eşitlikte TMA yönteminde sıklıkla kullanılan Shepard yaklaşımı verilmektedir [28].

$$z(x_0, y_0) = \frac{\sum_{i=1}^N \frac{z(x_i, y_i)}{h_{i,0}^{-p}}}{\sum_{i=1}^N \frac{1}{h_{i,0}^{-p}}} \quad (2)$$

Eş. 2’de gösterilen denklemde toplam gözlem sayısı N olarak ifade edilmektedir ve mxm boyutlarındaki bir imge için bu değer $N = m^2$ olarak tanımlanır, i parametresi ise gözlem noktalarına karşılık gelmektedir. $h_{i,0}$ parametresi gözlem noktaları ile kestirimde bulunmak istenen nokta arasındaki Öklid uzaklığıdır ve iki farklı şekilde hesaplanabilir. Bu hesaplama yöntemleri Tablo 2’de gösterilmektedir. Tabloda gösterildiği gibi ikinci yöntemde δ parametresi olarak gösterilen bir yumuşatma parametresi bulunmaktadır [29]. Bu parametre sayesinde mesafeler arasındaki ilişki, δ parametresine bağlı olarak daha yumuşak bir şekilde zayıflatılmaktadır. Bu sayede kestirilmek istenen yeni piksel değeri ile komşu piksel değerleri arasındaki etkinin boyutu azaltılmıştır. Bu parametre daha çok yumuşak geçişlerin bulunduğu veya yükselti değişiminin az olduğu bölgelere ait kestirim yapıldığı zaman kullanılmaktadır. Fakat bu yöntem ile elde ettiğimiz SÇ uygulamasında kenar bilgilerinin yüksek oranda kaybolmasına yol açması nedeniyle önerilen çalışmada tercih edilmemiştir. Önerilen yaklaşım, birinci yöntem vasıtasıyla yapılan hesaplamalar ışığında gerçekleştirilmiştir. TMA yönteminde, bu parametrelerin yanı sıra p olarak tanımlanan bir kuvvet parametresi bulunmaktadır [30]. Bu parametre ile seçilen bölgedeki komşuluk ilişkilerinin mesafeler yönünden önemi artırılıp azaltılmaktadır. Şekil 1’de önerilen yaklaşıma ait blok şema

gösterilmektedir. Şekilde görüldüğü gibi düşük boyutlardaki imgeye ait orijinal histogram dağılımı elde edilmektedir. Elde edilen bu histogram dağılımı, TMA yöntemi sonucu boyutları artırılan imgeye ait histogram bilgilerinin eşleştirilmesi sürecinde referans olarak kullanılmaktadır. Bu sayede çıktı olarak, boyutları artırılmış, kenar bilgileri ve piksel değerleri uyarlamalı olarak korunmuş büyük boyutlu çıktı imgesi elde edilmektedir. Şekil 2’de farklı p değerleri için bağıl ağırlık ve mesafe arasındaki değişim gösterilmektedir. İlgili şekilde mesafe parametresi, kestirilmek istenen piksel değeri ile komşu pikseller arasındaki uzaklığın Öklid uzayı cinsinden değerini, bağıl ağırlık ise bu komşu piksellerin, kestirilecek olan piksel üzerindeki etkilerinin oranını göstermektedir. Şekilde de görüldüğü gibi farklı p değerlerine bağlı olarak komşu pikseller arasındaki etkileşimin değişimi gösterilmektedir. Bu çalışmada kuvvet parametresi, literatür çalışmalarına benzer şekilde $p=2$ olarak seçilmiştir.


TMA yönteminde, komşuluk ilişkileri arasındaki mesafenin tanımlandığı r parametresi olarak adlandırılan bir parametre de bulunmaktadır. Bu parametre sayesinde yeni bulunacak değerlerin hangi mesafedeki veriler kullanılarak oluşturulacağı belirlenmektedir. Örneğin $r=5$ olarak tanımlanırsa, 5 birimlik bir komşuluk ilişkisi içerisindeki piksel değerleri kullanılarak kestirilmek istenen yeni piksel değeri hesaplanmaktadır. Bu değerlerin seçimi TMA yöntemi için önem arz etmektedir. Büyük r değeri detayların kaybolmasına ve kenar bilgilerinin zayıflamasına yol açarken, düşük r değeri ise düşük sayıda veri kullanılarak kestirim yapılmasını sağlar. Bu çalışmada kullanılan veri tabanı için deneysel çalışmalar sonucunda en uygun değer $r=9$ olduğu gözlenmiştir.



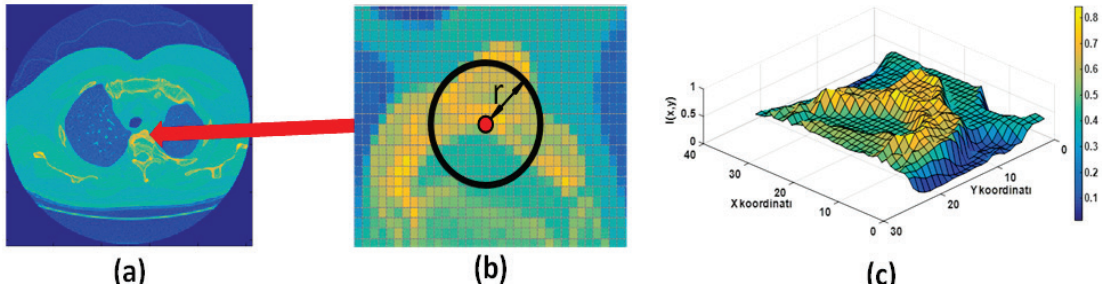
Şekil 1. Algoritma akış şeması (Algorithm flowchart)

Tablo 2. $h_{i,0}$ parametresinin hesabı (Calculation of parameter $h_{i,0}$)

Yöntem	Eşitlikler
1	$h_{i,0} = \sqrt{(x - x_i)^2 + (y - y_i)^2}$
2	$d_{i,0} = \sqrt{(x - x_i)^2 + (y - y_i)^2}$ $h_{i,0} = \sqrt{d_{i,0}^2 + \delta^2}$



Şekil 2 p değerinin değişimi (Change of p value)



Şekil 3. a) Test imgesi b) İmge parçası c) İmge parçasının yükselti uzayı (a) Test image b) Image part c) 3d image part)

Ayrıca bu çalışmada komşuluk mesafesine ilişkin farklı değerlerin başarımına etkisi de incelenmiştir. Şekil 3a'da test veri tabanından alınan amfizeimli test imgesine ait gösterim bulunmaktadır. Şekil 3b'de ise ilgili imgenin yakınlaştırılmış gösterimi sunulmuştur. Verilen şekilde gösterilen çembere ait r değeri komşuluk yarıçapı değerini, merkez nokta ise kestirimde bulunmak istenen piksel değerini göstermektedir. Şekil 3c'de ise yakınlaştırılmış imgenin yükselti uzayındaki temsili gösterimi bulunmaktadır. Şekilde görüldüğü gibi imge uzayı ile belirli bir bölgeye ait yükselti uzayı benzerlik göstermektedir. Bu nedenle TMA yönteminin imge uzayına ait bir uygulamada kullanılmasının başarımı oldukça artıracığı öngörülmüştür ve önerilen yaklaşıma ait sonuçlar bu öngörüü kanıtlayacak niteliktedir.

4. HİSTOGRAM EŞLEŞTİRME VE İMGE İYİLEŞTİRME (HISTOGRAM MATCHING AND IMAGE ENHANCEMENT)

Histogram eşleştirme yöntemi bir zaman serisinin, imgenin veya yüksek boyutlardaki sayısal bir verinin histogramının referans bir histogram ile eşleştirilmesi sürecidir [31, 32]. Bu yöntem imge işleme alanında sıklıkla imgelerin parlaklık seviyelerinin eşitlenmesi amacıyla kullanılmaktadır. Önerilen yaklaşımda ise düşük çözünürlüklü orijinal girdi imgesi ile TMA sonucu boyutları artırılmış imgenin histogram bilgilerinin benzeştirilmesi amacıyla


kullanılmıştır. Şekil 4'te ilgili test veri tabanında bulunan amfizeimli bir akciğer imgesine, histogram eşleştirme uygulanması sonucu elde edilen çıktı gösterilmektedir. Şekilde de görüldüğü gibi histogram eşleştirme işlemi sonucu bilgisayarlı tomografi imgesine ait detaylar daha belirgin olmaktadır. Şekil 5'te, daha önceden Şekil 4'te histogram eşitleme sonucu elde edilen imgeye, girdi ve referans imgesine ilişkin birikimli dağılım fonksiyonlarının gösterimi bulunmaktadır [33]. Birikimli dağılım fonksiyonunda, piksellerin parlaklık değeri 0-1 arasında normalize edilmektedir ve bu değerler küçükten büyüğe sıralanmaktadır. Bu sayede herhangi bir imgeye ait piksellerin dağılımına ait karakteristik elde edilmektedir. Şekil 5'te x eksenini girdi imgesine ait piksellerin normalize edilmiş toplam sayısını, y eksenini ise o gözleme karşılık gelen pikselin 0-1 arasında normalize edilmiş parlaklık değerini temsil etmektedir. Bu çıktı üzerinden imgelere ait parlaklık seviyeleri ve bunlar arasındaki farklar kolaylıkla gözlemlenmektedir.

Şekilde de görüldüğü gibi histogram eşleştirme sonucu imgelerin parlaklık seviyeleri oldukça benzerlik göstermektedir. Birikimli dağılım fonksiyonu $F(x)$ Eş. 3'te gösterildiği gibi tanımlanmaktadır. Bu eşitlikte $P(x)$, x rassal değişkeninin gerçekleşme olasılığını tanımlanmaktadır.


$$F(x) = P[X \leq x] \quad \text{için } 0 < x < 1 \quad (3)$$



Şekil 4. a) Girdi imgesi b) Referans imge c) Histogram eşleştirilmiş imge
(a) Input image b) Reference image c)Histogram matched image



Şekil 5. İmgelere ilişkin birikimli dağılım fonksiyonları (Cumulative distribution of images)



Şekil 6. Histogram eşleştirilmesine ilişkin blok şema gösterimi (Block chart of histogram equalization process)

Histogram eşleştirme yönteminin gerçekleştirilmesinde ilk olarak histogram dağılımlarının kendi içinde eşitlenmesi gerekmektedir. Histogram eşitlemeye ilişkin denklemler Eş. 4, 5'te gösterilmektedir [34].

İlgili eşitlikte n_j parametresi r_j griton değerine sahip piksellerin sayısını, n toplam piksel sayısını, r_k girdiye ait parlaklık seviyesini, s_k histogram eşitleme sonucu elde edilen parlaklık seviyesini, k değeri parlaklık seviyesine ait tanım aralığını (örnek:0-1), L ise toplam parlaklık seviyesini temsil etmektedir ve bu değer 8 bit bir imge için $2^8 - 1 = 255$ şeklinde tanımlanmıştır. Bu işlemler sonucunda histogramı kendi içinde eşitlenmiş imge (s) elde edilir.

$$s_k = T(r_k) = \sum_{j=0}^k p_r(r_j) \quad \text{için} \quad 0 \leq k \leq L - 1 \quad (4)$$

$$p_r(r_j) = \frac{n_j}{n}, j = 0, \dots, L - 1 \quad \text{ve} \quad n = \sum_{j=0}^{L-1} n_j \quad (5)$$

Histogramların kendi içinde eşitlenmesinden sonra ilgili histogramların referans imgesine göre eşleştirilmesi gerekmektedir. X,Y ve Z sırasıyla girdi, referans ve çıktı imgelerini p_x, p_y ve p_z ise girdi, referans ve çıktı imgesine ait eşitlenmiş histogramı temsil etmektedir. Şekil 6'da ilgili sürece ait blok diyagram verilmiştir.

Eş. 6'da histogramların eşleştirilmesi sürecine ait matematiksel ifadeler gösterilmektedir.

$$X = f(x) = \int_0^x p_x(u) du$$

$$Y = g(x) = \int_0^y p_y(u) du \quad Z = g^{-1}(Y) \quad (6)$$

5. İMGE BENZERLİK ÖLÇÜM PARAMETRELERİ (IMAGE SIMILARITY MEASUREMENT PARAMETERS)

Önerilen yaklaşımın başarımı karşılaştırılırken dört farklı benzerlik parametresinden yararlanılmıştır. Bu parametreler; tepe sinyal gürültü oranı (PSNR), korelasyon katsayısı, yapısal benzerlik indeksi (SSIM) ve bu parametrelere ek olarak kenar bilgilerinin belirlenme aşamasında Pratt'ın başarımlar ölçüsü (Pratt's Figure of Merit) olarak seçilmiştir.

Tepe sinyal gürültü oranının büyük olması iki imge arasındaki benzerlik hakkında fikir vermektedir [35]. 2-boyutlu korelasyon katsayısı ise -1 ve 1 arasında değişiklik göstermektedir. Benzerlik arttıkça ilgili katsayı 1 değerine, farklılık arttıkça da -1 değerine yaklaşmaktadır [36]. Yapısal benzerlik indeksi olarak belirtilen SSIM parametresi, algılanan sayısal televizyon, sinematik veya diğer türlerdeki sayısal imge veya videonun kalitesinin kestirilmesi amacıyla imge işleme alanında sıklıkla kullanılan etkin bir parametredir [37]. Bu parametre 0 ve 1 arasında değerler almaktadır ve 1 değerine yaklaştıkça benzerlik artmaktadır [38]. Pratt'ın başarımlar ölçüsünde (FOM) ise gerçek imgeye ait kenar bilgiler ile önerilen yaklaşıma ait başarımlar karşılaştırılır ve önerilen yaklaşımın gerçek imgeye ait kenarları koruma oranı hakkında bilgi sağlanır [39]. Eş. 7, 8'de sırasıyla korelasyon katsayısının ve tepe sinyal gürültü oranının hesaplanmasına ilişkin eşitlikler gösterilmektedir. İlgili eşitliklerde x girdi imgesini y referans imgeyi, N ve M ise imgelere ait boyut bilgilerini temsil etmektedir.

$$r_{xy} = \frac{\sum_{i=1}^{NM} ((x_i - \mu_x)(y_i - \mu_y))}{\sqrt{\sum_{i=1}^{NM} (x_i - \mu_x)^2 \sum_{i=1}^{NM} (y_i - \mu_y)^2}} \quad (7)$$

$$MSE_{xy} = \frac{1}{NM} \sum_{i=1}^N \sum_{j=1}^M [x_{ij} - y_{ij}]^2$$

$$PSNR_{xy} = 10 \log_{10} \frac{255}{MSE_{xy}} \quad (8)$$

Eş. 9, 10'da SSIM parametresinin hesaplanmasına ilişkin denklemler gösterilmektedir. İlgili eşitliklerde I_{xy} parlaklık, C_{xy} karışıklık ve S_{xy} ise yapı değerine ait parametreyi temsil etmektedir. α , β ve γ ise önem verilen parametrelerin ağırlıklarını içermektedir. σ_{xy} ise x ve y imgelerine ait kovaryansı, σ_x , σ_y parametreleri ise sırasıyla x ve y girdilerine ait standart sapmalara karşılık gelmektedir. Bölme işlemindeki zayıf parametreleri dengelemek için $c_1 = (k_1 L)^2$, $c_2 = (k_2 L)^2$, $c_3 = \frac{c_2}{2}$ parametreleri tanımlanmıştır. L, toplam parlaklık seviyesini (8 bit için $L = 2^8 - 1 = 255$) temsil etmektedir. $k_1 = 0,01$ ve $k_2 = 0,03$ şeklinde varsayılan olarak tanımlanmıştır.

$$I_{xy} = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad C_{xy} = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}$$

$$S_{xy} = \frac{\sigma_{xy} + c_3}{\sigma_x + \sigma_y + c_3} \quad (9)$$

$$SSIM_{xy} = [I_{xy}^\alpha \cdot C_{xy}^\beta \cdot S_{xy}^\gamma]$$

$$SSIM_{xy} = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (10)$$

Figure of Merit(FOM) parametresi genellikle kenar bulma yöntemlerinin başarımının karşılaştırılmasında kullanılmaktadır [40]. Bu çalışmada ise önerilen yaklaşım ile diğer SÇ yaklaşımlarının, orijinal imgeye ait kenar bilgilerini korumadaki başarımının karşılaştırılması amacıyla kullanılacaktır. FOM parametresine ait genel denklem Eş. 11'de gösterilmektedir. Bu parametre hesaplanırken imgelerin kenar bilgilerinin bulunması sürecinde Sobel yaklaşımından yararlanılmıştır.

$$FOM = \frac{1}{I_N} \sum_{i=1}^{I_F} \frac{1}{1 + \alpha d_i^2} \quad (11)$$

Orijinal imgedeki ideal kenar noktalarının sayısı I_1 , test imgesindeki kenar noktalarının sayısı I_F 'dir. I_N ise I_1 ve I_F 'nin maksimum değerini temsil etmektedir. α , ölçekleme sabitini ($\alpha=0,1$), d_i ise bulunan kenar noktası ile ideal kenar noktası arasındaki mesafeyi temsil etmektedir.

6. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Çalışmanın bu aşamasında yaklaşımın uygulanması süreci irdelenmiştir. İlgili çalışma, amfizem görülen 115 adet bilgisayarlı tomografi imgesi üzerinden gerçekleştirilmiştir [41]. Önerilen yaklaşımın başarımını test etmek amacıyla kullanılan bilgisayar tomografisi imgelerine ait özellikler şu şekildedir. Bilgisayar tomografi taraması dört satırla ve $0,78 \times 0,78$ düzlemsel çözünürlüğü, dilim kalınlığı 1,25 mm, tüp voltajı 140kV ve tüp akımı 200mAs olan bir cihazla elde edilmiştir ve bu dilimler, yüksek uzaysal çözünürlüklü (bone) yöntemi kullanılarak yeniden oluşturulmuştur. İlgili veri tabanında toplam 39 denek bulunmaktadır. Bu denekleri oluşturan 9 kişi asla sigara içmemiştir, 10 kişi sigara içmektedir ve 20 kişi ise sigara içen ve kronik obstrüktif akciğer (KOAH) hastasıdır. Önerilen yaklaşımın uygulaması şu şekildedir: Girdi imgesi olarak $[128 \times 128]$ boyutlardaki imgeler kullanılmıştır ve bu imgeler TMA yöntemi ile boyutları $[256 \times 256]$ oranına büyütülürken, aynı zamanda düşük boyutlu orijinal imgeden alınan histogram bilgileri ile TMA yöntemine ait çıktı imgesinin histogramları eşitlenmiştir. Bu sayede girdi imgesinde detay kaybı en az olacak şekilde boyutları büyütülmüştür. Yöntemin başarımı literatürde sıklıkla kullanılan çeşitli SÇ yöntemleri olan; en yakın komşu, Bilinear, Lanczos ve Biküzik enterpolasyon yöntemlerinin yanı sıra literatürde önem arz eden iki adet yöntemle daha karşılaştırılmıştır. Bu yöntemler; geri yayımlı tekli imge SÇ yöntemi [17] ve seyrek regresyon ve doğal görüntü öncelikli tekli imge SÇ yöntemidir [18]. Çalışmanın geri kalanında, geri yayımlı tekli imge SÇ yöntemi Yöntem 1, seyrek regresyon ve doğal görüntü öncelikli tekli imge SÇ yöntemi ise Yöntem 2 olarak kısaltılmıştır. İlk aşamada veri tabanı için farklı mesafe (r) değerlerinin benzerlik ölçüm parametreleri ışığındaki ortalama başarımlar sonuçları Tablo 3'te gösterilmiştir. Ayrıca bu değerlere ait standart sapmalar ve bu dağılımlara ilişkin maksimum ve minimum değerler arasındaki farkların yüzde

cinsinden gösterimi verilmiştir. Bu detaylı analiz sayesinde ilgili veri tabanı için en uygun r değeri tabloda koyu olarak belirlenmiştir. Tablo 3'te gösterilen farklı mesafe değerlerine göre başarımların sonuçları irdelendiğinde en yüksek başarımın r=9 değerinde elde edildiği gözlemlenmiştir. Fakat ilgili tablo irdelendiğinde başarımların oranının mesafeye bağlı olarak çok az miktarda değiştiği gözlemlenmiştir. Önerilen yaklaşım ile alternatif SÇ yöntemlerinin benzerlik ölçüm

kriterleri olan; PSNR, korelasyon katsayısı, SSIM ve FOM ışığında karşılaştırılmasına ilişkin detaylı sonuçlar sırasıyla Tablo 4, 5, 6 ve 7'de gösterilmiştir. Tablolarda belirtilen değerler, önerilen yaklaşımın çıktıları ile aynı boyutlardaki orijinal imgelerin karşılaştırılması sonucu elde edilmiştir. Bu çalışmada önerilen yaklaşımın başarımı artırdığı çıktılar üzerinden açıkça gözlenmektedir. Bu oran Bikübik enterpolasyon yöntemine göre PSNR değeri bakımından

Tablo 3. Farklı mesafe değerlerinin (r) performans analizi sonuçları (Performace analysis result of different distance values)

Mesafe Değeri (r)									
Parametre	3	5	7	9	11	13	15	Standart Sapma	% Maks - Min
Korelasyon Katsayısı	0,982	0,984	0,986	0,987	0,985	0,983	0,981	0,002	0,0609
PSNR (dB)	30,161	30,197	30,491	30,787	30,422	30,296	30,283	0,215	0,0206
SSIM	0,915	0,916	0,919	0,922	0,921	0,920	0,918	0,002	0,0761
FOM (%)	92,188	92,233	92,537	92,775	92,678	92,431	92,342	0,221	0,0063

Tablo 4. Yöntemlerin PSNR değerlerine göre karşılaştırılması (Comparison of methods according to PSNR values)

Yöntem	PSNR (dB)			
	Ortalama	Standart Sapma	Minimum Değer	Maksimum Değer
En yakın Komşu	27,2790	1,0460	25,7967	32,1331
Bilineer	29,0242	1,0053	27,5247	34,0489
Lanczos	28,9160	1,0051	27,3381	33,9161
Bikübik	28,9005	0,9973	27,3239	33,9040
Yöntem 1	30,2842	1,0771	26,1154	33,2501
Yöntem 2	30,6316	0,9676	28,2263	33,1148
Önerilen Yaklaşım	30,7879	0,9915	29,2349	36,0813

Tablo 5. Yöntemlerin korelasyon katsayısına göre karşılaştırılması (Comparison of methods according to correlation coefficient)

Yöntem	Korelasyon Katsayısı			
	Ortalama	Standart Sapma	Minimum Değer	Maksimum Değer
En yakın Komşu	0,9715	0,0062	0,9550	0,9836
Bilineer	0,9807	0,0042	0,9694	0,9887
Lanczos	0,9803	0,0044	0,9682	0,9884
Bikübik	0,9802	0,0044	0,9681	0,9884
Yöntem 1	0,9812	0,0034	0,9693	0,9887
Yöntem 2	0,9838	0,0048	0,9701	0,9953
Önerilen Yaklaşım	0,9873	0,0029	0,9796	0,9928

Tablo 6. Yöntemlerin SSIM parametresine göre karşılaştırılması (Comparison of methods according to SSIM parameter)

Yöntem	SSIM			
	Ortalama	Standart Sapma	Minimum Değer	Maksimum Değer
En yakın Komşu	0,8731	0,0135	0,8415	0,9125
Bilineer	0,8965	0,0111	0,8696	0,9310
Lanczos	0,8990	0,0108	0,8728	0,9322
Bikübik	0,8983	0,0108	0,8721	0,9318
Yöntem 1	0,9083	0,0115	0,8802	0,9383
Yöntem 2	0,9134	0,0105	0,8897	0,9395
Önerilen Yaklaşım	0,9225	0,0090	0,8999	0,9496

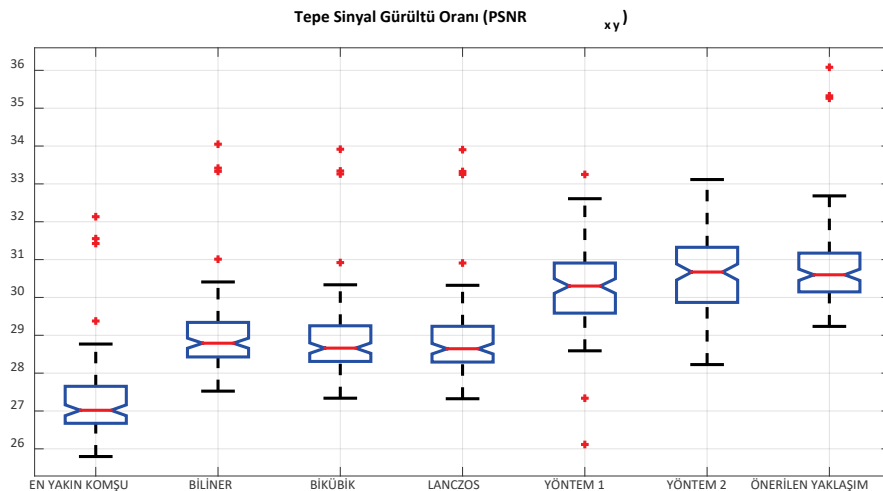
yaklaşık olarak 6,5% ve SSIM parametresi bakımından yaklaşık 3% dir. SÇ alanındaki çalışmalarda, Bikübik enterpolasyon yöntemi kolay hesaplanması ve çıktılar üzerindeki tatmin edici başarımı nedeniyle genellikle referans veya bir kıstas yöntem olarak tanımlanmaktadır. FOM parametresi açısından ise önerilen yaklaşımın Yöntem 1'e göre başarımı yaklaşık 3%, Yöntem 2'ye göre ise yaklaşık 2,5% oranında artırdığı görülmüştür. SÇ uygulamalarının başarımlarından bir diğeri de farklı imgelere göre başarımlarının çok fazla değişiklik göstermemesidir. Aksi durumda, imgelerin değişimine bağlı olarak uygulama çıktılarında istenmeyen veya gerçek olmayan detaylar ortaya çıkmaktadır ve bu tarz istenmeyen sonuçlar özellikle bilgisayar tomografisi gibi hayati önem taşıyan bilgiler içeren imgeler için olumsuz sonuçlar doğurmaktadır. Bu duruma literatürde yapay doku (artifact) etkisi adı verilmektedir. Bu etki nedeniyle çıktı imgesinde gerçek olmayan kenar bilgileri veya pikseller ortaya çıkmaktadır. Benzerlik ölçüm yöntemlerinin istatistiksel analiz sonuçları irdelendiğinde dört adet benzerlik parametresine göre önerilen yaklaşımın en düşük standart sapma değerine sahip olduğu gözlenmektedir. Böyle bir sonucun elde edilmesinin temel nedeni, önerilen yaklaşımın tekrarlamalı

(iterative) olmaması, dolayısıyla kullanıcı tarafından tanımlanması gereken herhangi bir ön bilgiye (hata kriteri, tekrarlama sayısı) ihtiyaç duymamasıdır. Ayrıca FOM parametreleri irdelendiğinde önerilen yaklaşımın kenar bilgilerini en yüksek başarımla koruduğu gözlemlenmektedir. Bu bağlamda kenar bilgilerinin önem arz ettiği SÇ uygulamalarında önerilen yaklaşımın uygulanmasının başarımlarını artıracakları öngörülmektedir. 115 adet bilgisayarlı tomografi test imgesine ait SÇ yöntemlerinin tepe sinyal gürültü oranı, korelasyon katsayıları, yapısal benzerlik indeksi ve Pratt'ın başarımlar ölçüsüne (FOM) ait değişim sonuçlarının kutu grafiği gösterimi sırasıyla Şekil 7, 8 ve 9'da verilmiştir.

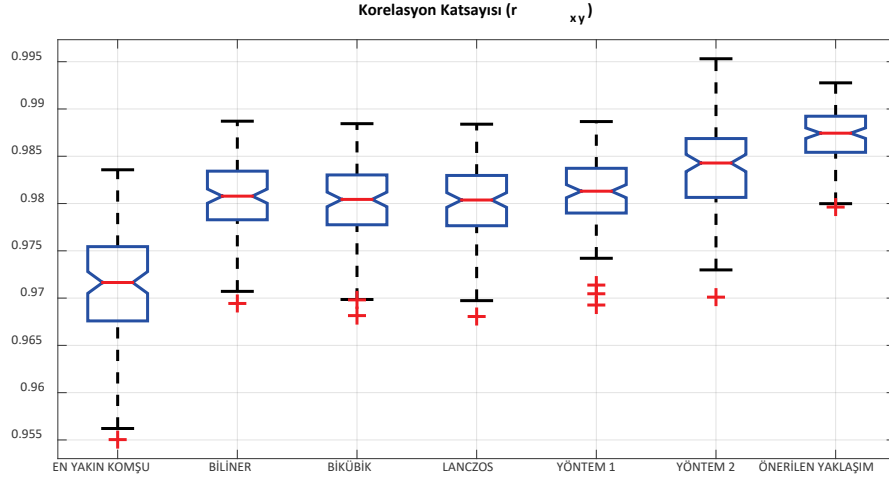
Şekil 11, 12 ve 13'te örnek test imgelerinin karşılaştırılması gösterimi bulunmaktadır. Bu çalışmada önerilen yaklaşımın, geleneksel yöntemlere ve tekli imge SÇ alanında özel olarak geliştirilmiş yöntemlere göre kenar bilgilerini daha başarılı bir şekilde koruduğu ve orijinal imgeye daha benzer imgeler verdiği çıktılar üzerinden gözlemlenmektedir. Şekil 14'te gösterilen imgede SSIM parametresi açısından önerilen yaklaşımın, Bikübik enterpolasyon yöntemine göre başarımlarını yaklaşık 3,5% oranında artırmaktadır.

Tablo 7. Yöntemlerin FOM parametresine göre karşılaştırılması (Comparison of methods according to FOM parameter)

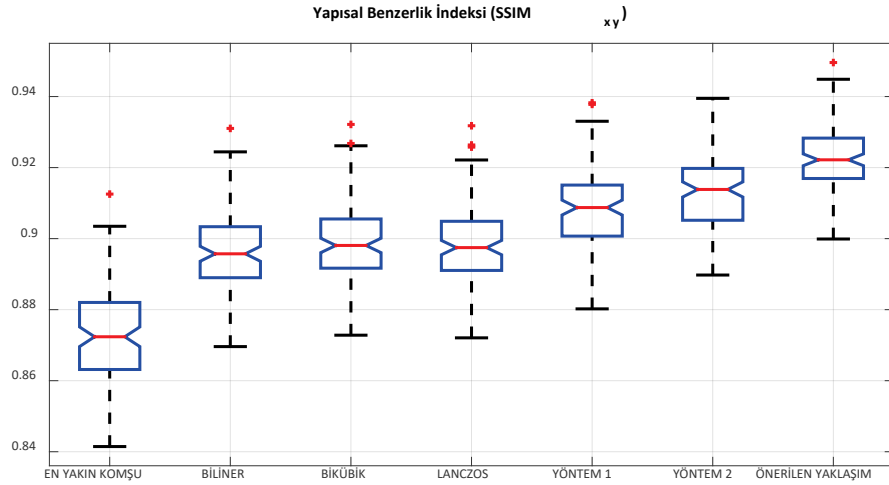
Yöntem	FOM(%)			
	Ortalama	Standart Sapma	Minimum Değer	Maksimum Değer
En yakın Komşu	88,9973	1,6998	85,0548	93,3096
Bilineer	88,9343	1,4890	84,6806	92,4338
Lanczos	90,5827	1,6096	86,0578	95,4668
Bikübik	91,1295	1,4396	87,7531	94,2020
Yöntem 1	90,3529	1,5888	86,8103	95,1892
Yöntem 2	90,9154	1,5077	87,3028	95,4091
Önerilen Yaklaşım	92,9490	1,4190	88,9224	96,1802



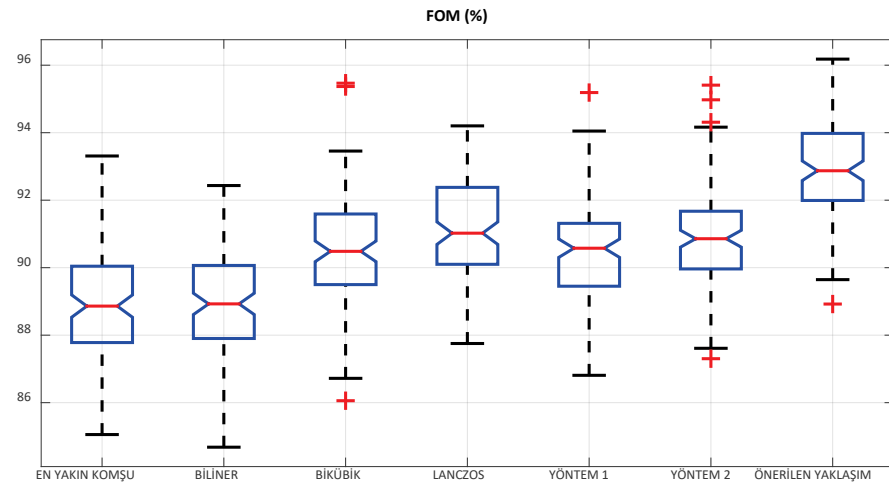
Şekil 7. Yöntemlerin başarımının PSNR parametresine göre değişimi (Change of performance of methods according to PSNR parameter)




Şekil 8. Farklı yöntemlerin başarımının korelasyon katsayısına göre değişimi
(Change of performance of methods according to correlation coefficient parameter)




Şekil 9. Farklı yöntemlerin başarımının SSIM parametresine göre değişimi
(Change of performance of methods according to SSIM parameter)



Şekil 10. Farklı yöntemlerin başarımının FOM (%) parametresine göre değişimi
(Change of performance of methods according to FOM (%) parameter)




Şekil 11. a) En yakın komşu (SSIM=0,881) b) Biliner (SSIM=0,902) c) Bikübik (SSIM=0,905) d) Lanczos (SSIM=0,904) e) Yöntem 1 (SSIM=0,918) f) Yöntem 2 (SSIM=0,923) h) Önerilen yaklaşım (SSIM=0,929) (i) Gerçek İmge
 (a) NN (SSIM=0,881) b) Bilinear (SSIM=0,902) c) Bicubic (SSIM=0,905) d) Lanczos (SSIM=0,904) e) Method 1 (SSIM=0,918) f) Method 2 (SSIM=0,923) h) Proposed Method (SSIM=0,929) (i) Real Image)



Şekil 12. a) En yakın komşu (SSIM=0,886) b) Biliner (SSIM=0,909) c) Bikübik (SSIM=0,911) d) Lanczos (SSIM=0,913) e) Yöntem 1 (SSIM=0,926) f) Yöntem 2 (SSIM=0,929) h) Önerilen yaklaşım (SSIM=0,933) (i) Gerçek İmge
 (a) NN (SSIM=0,886) b) Bilinear (SSIM=0,909) c) Bicubic (SSIM=0,911) d) Lanczos (SSIM=0,913) e) Method 1 (SSIM=0,926) f) Method 2 (SSIM=0,929) h) Proposed Method (SSIM=0,933) (i) Real Image)


Şekil 11’de gösterilen imgeye ait FOM değerleri Yöntem 1 için 91,317, Yöntem 2 için 92,123 şeklindedir. Bu çalışma kapsamında önerilen yaklaşım ile bu değer 93,011 şeklinde elde edilmektedir. Bu bilgiler ışığında önerilen yaklaşım ile kenar bilgileri en yüksek yüzde ile korunmuştur. SÇ uygulaması sonucu elde edilen şekiller irdelendiğinde, en yakın komşu yaklaşımının en başarısız sonuçları sergilediği

gözlemlenmiştir. Bikübik enterpolasyon yönteminde ise kenar bilgilerinin kaybolduğu ve gerçek imgeden uzaklaştığı gözlemlenmiştir. Geri yayımlı tekli imge süper çözünürlük yönteminin çıktılarında ise yapay dokuların oluştuğu ve bu nedenle yöntemine ait çıktılar ile gerçek imgeler arasındaki benzerliğin azaldığı gözlemlenmiştir. Seyrek regresyon ve doğal görüntü öncelikli tekli imge SÇ yöntemine ait çıktılar



Şekil 13. a) En yakın komşu (SSIM=0,903) b) Biliner (SSIM=0,924) c) Bikübik (SSIM=0,926) d) Lanczos (SSIM=0,928) e) Yöntem 1 (SSIM=0,923) f) Yöntem 2 (SSIM=0,932) h) Önerilen yaklaşım (SSIM=0,944) i) Gerçek İmge
(a) NN (SSIM=0,903) b) Bilinear (SSIM=0,924) c) Bicubic (SSIM=0,926) d) Lanczos (SSIM=0,928) e) Method 1 (SSIM=0,923) f) Method 2 (SSIM=0,932) h) Proposed Method (SSIM=0,944) i) Real Image)

incelendiğinde ise önerilen yaklaşıma çok benzer sonuçlar verdiği, fakat FOM parametresine göre kenar bilgilerini korumakta önerilen yaklaşıma göre daha az başarılı olduğu gözlemlenmiştir. Şekil 14’te, Şekil 13’te verilen bilgisayarlı tomografi imgesine ait birikimli dağılım fonksiyonunun yakınlştırılmış gösterimi bulunmaktadır. Önerilen yaklaşım ile gerçek imgeye ait birikimli dağılımların birbirilerine oldukça benzerlik gösterdiği gözlenmektedir Bu bağlamda, önerilen yaklaşıma ait çıktının kenar bilgilerini korumanın yanı sıra parlaklık değerlerini de başarı ile muhafaza ettiği gözlemlenmiştir.



Şekil 14. Örnek çıktı imgelerine ilişkin birikimli dağılım fonksiyonları
(Cumulative distribution functions for sample output images)

7. SONUÇLAR (CONCLUSIONS)

Bu çalışmada bilgisayarlı tomografi imgelerinin iyileştirilmesi ve detaylandırılması için yenilikçi bir SÇ yaklaşımı önerilmiştir. Önerilen bu yaklaşımda, Jeoistatistik alanında sıklıkla kullanılan Ters mesafe ağırlıklandırma

yöntemi ile Genel histogram eşleştirme yöntemi bütünlük olarak kullanılmıştır. Yöntemin başarımı 115 adet amfizem görülen bilgisayarlı tomografi imgesi üzerinden test edilmiştir ve önerilen yaklaşımın başarımı, tepe sinyal gürültü oranı, korelasyon katsayısı, yapısal benzerlik indeksi ve Pratt’ın başarımlar kriteri kapsamında irdelenmiştir. Önerilen yaklaşıma ait çıktılarda görüldüğü gibi detaylar önemli ölçüde geri kazanılmış ve imgeler için önem arz eden kenar bilgileri yüksek başarımla korunmuştur. Bunlara ek olarak, imgelere ait piksellerin gerçek parlaklık değerleri de bu süreçte başarı ile korunmuştur. Önerilen yaklaşıma ait sonuçlar literatürde sıklıkla kullanılan yöntemler ile karşılaştırılmıştır. SÇ alanında referans yöntem olan Bikübik enterpolasyon yöntemi ile yapılan karşılaştırma sonuçlarına göre başarımlar büyük oranda artırılmıştır. Bu oranlar, SÇ çalışmalarında sıklıkla kullanılan yapısal benzerlik indeksine göre yaklaşık 3% ve tepe sinyal oranı bakımından yaklaşık 6% şeklindedir. Ayrıca Pratt’ın başarımlar parametresi açısından ise önerilen yaklaşımın geri yayımlı tekli imge süper çözünürlük yöntemine göre başarımlar yaklaşık 3% artırdığı, seyrek regresyon ve doğal görüntü öncelikli tekli imge süper çözünürlük göre ise de yaklaşık 2,5% oranında artırdığı görülmüştür. Bu bağlamda önerilen yaklaşım kenar bilgilerini korumakta oldukça başarılıdır.

KAYNAKLAR (REFERENCES)

1. Candès E.J., Fernandez-Granda C., Towards a Mathematical Theory of Super-resolution. Communications on Pure and Applied Mathematics, 67 (6), 906-956, 2014.
2. Nasrollahi K., Moeslund T.B., Super-resolution: a comprehensive survey, Machine vision and applications, 25 (6), 1423-1468, 2014.

3. Dong W., Fu F., Shi G., Cao X., Wu J., Li G., Li X., Hyperspectral image super-resolution via non-negative structured sparse representation. *IEEE Transactions on Image Processing*, 25 (5), 2337-2352, 2016.
4. Jiang J., Hu R., Wang Z., Han Z., Face super-resolution via multilayer locality-constrained iterative neighbor embedding and intermediate dictionary learning, *IEEE Transactions on Image Processing*, 23 (10), 4220-4231, 2014.
5. Nguyen K., Fookes C., Sridharan S., Denman S., Feature-domain super-resolution for iris recognition, *Computer Vision and Image Understanding*, 117 (10), 1526-1535, 2013.
6. Glasner D., Bagon S., Irani M., Super-resolution from a single image. In *Computer Vision, 2009 IEEE 12th International Conference on*, 349-356, 2009.
7. Singh K., Gupta A., Kapoor R., Fingerprint image super-resolution via ridge orientation-based clustered coupled sparse dictionaries. *Journal of Electronic Imaging*, 24 (4), 043015, 2015.
8. Rueda A., Malpica N., Romero E., Single-image super-resolution of brain MR images using overcomplete dictionaries. *Medical image analysis*, 17 (1), 113-132, 2013.
9. Okuhata H., Imai R., Ise M., Omaki R. Y., Nakamura, H., Hara, S., Shirakawa, I., Implementation of dynamic-range enhancement and super-resolution algorithms for medical image processing, In *Consumer Electronics (ICCE), 2014 IEEE International Conference on*, 181-184, 2014.
10. Wanner S., Goldluecke B., Variational light field analysis for disparity estimation and super-resolution. *IEEE transactions on pattern analysis and machine intelligence*, 36 (3), 606-619, 2014.
11. Long F., Zeng S., Huang Z.L., Localization-based super-resolution microscopy with an sCMOS camera Part II: Experimental methodology for comparing sCMOS with EMCCD cameras. *Optics Express*, 20 (16), 17741-17759, 2012.
12. Gerchberg R.W., Super-resolution through error energy reduction. *J. Mod. Opt.* 21 (9), 709-720, 1974.
13. Çatalbaş M.C., Öztürk S., Super resolution using radial basis neural networks, In *Signal Processing and Communications Applications Conference (SIU)*, 21st, 1-4, 2013.
14. Mjolsness E., Neural networks, pattern recognition, and fingerprint hallucination, PhD thesis, California Institute of Technology, 1985.
15. Kim J., Kwon Lee J., Mu Lee K., Accurate image super-resolution using very deep convolutional networks, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1646-1654, 2016.
16. Isaac J.S., Kulkarni R., Super resolution techniques for medical image processing, In *Technologies for Sustainable Development (ICTSD), 2015 International Conference on*, 1-6, 2015.
17. Bareja M.N., Modi C.K., An effective iterative back projection based single image super resolution approach, In *Communication Systems and Network Technologies (CSNT), 2012 International Conference on*, 95-99, 2012.
18. Kim K.I., Kwon Y., Single-image super-resolution using sparse regression and natural image prior, *IEEE Trans. Pattern Analysis and Machine Intelligence*, 32 (6) 1127-1133, 2010.
19. Farsiu S., Robinson D., Elad M., Milanfar P., Advances and challenges in super-resolution, *International Journal of Imaging Systems and Technology*, 14 (2), 47-57, 2004.
20. Xu H., Zhai G., Yang X., Single image super-resolution with detail enhancement based on local fractal analysis of gradient, *IEEE Transactions on circuits and systems for video technology*, 23 (10), 1740-1754, 2013.
21. Faramarzi E., Rajan D., Christensen M. P., Unified blind method for multi-image super-resolution and single/multi-image blur deconvolution, *IEEE Transactions on Image Processing*, 22 (6), 2101-2114, 2013.
22. Mac Aodha, O., Campbell N.D., Nair A., Brostow G. J., Patch based synthesis for single depth image super-resolution, In *European Conference on Computer Vision*, 71-84, Springer, Berlin, Heidelberg, 2012.
23. Tian J., Ma K.K., A survey on super-resolution imaging, *Signal, Image and Video Processing*, 5 (3), 329-342, 2011.
24. Pickup Lyndsey C., *Machine learning in multi-frame image super-resolution*, Oxford University, 2007.
25. Lu G. Y., Wong D. W., An adaptive inverse-distance weighting spatial interpolation technique. *Computers & geosciences*, 34 (9), 1044-1055, 2008.
26. Jing M., Wu J., Fast image interpolation using directional inverse distance weighting for real-time applications, *Optics Communications*, 286, 111-116, 2013.
27. De Mesnard L., Pollution models and inverse distance weighting: Some critical remarks, *Computers & Geosciences*, 52, 459-469, 2013.
28. Faghidian S.A., Jozie A., Sheykhloo M.J., Shamsi A., A novel method for analysis of fatigue life measurements based on modified Shepard method, *International Journal of Fatigue*, 68, 144-149, 2014.
29. Tomczak M., Spatial interpolation and its uncertainty using automated anisotropic inverse distance weighting (IDW)-cross-validation/jackknife approach, *Journal of Geographic Information and Decision Analysis*, 2 (2), 18-30, 1998.
30. Chen F.W., Liu C.W., Estimation of the spatial rainfall distribution using inverse distance weighting (IDW) in the middle of Taiwan. *Paddy and Water Environment*, 10 (3), 209-222, 2012.
31. Zuo C., Chen Q., Sui X., Range limited bi-histogram equalization for image contrast enhancement, *Optik-International Journal for Light and Electron Optics*, 124 (5), 425-431, 2013.
32. Shen D., Image registration by local histogram matching, *Pattern Recognition*, 40 (4), 1161-1172, 2007.

33. Pianosi F., Wagener T., A simple and efficient method for global sensitivity analysis based on cumulative distribution functions, *Environmental Modelling & Software*, 67, 1-11, 2015.
34. Devasena C.L., Hemalatha M., Hybrid Image Classification Technique to Detect Abnormal Parts in MRI Images, In *Computational Intelligence and Information Technology*, 200-208, Springer, Berlin, Heidelberg, 2011.
35. Tanchenko A., Visual-PSNR measure of image quality, *Journal of Visual Communication and Image Representation*, 25 (5), 874-878, 2014.
36. Kılıç O., Çerçioğlu H., Application of compromise multiple criteria decision making methods for evaluation of TCDD's railway lines projects, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31 (1), 211-220, 2016.
37. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P., Image quality assessment: from error visibility to structural similarity. *IEEE transactions on image processing*, 13 (4), 600-612, 2004.
38. Brunet D., Vrscay E.R., Wang Z., On the mathematical properties of the structural similarity index, *IEEE Transactions on Image Processing*, 21 (4), 1488-1499, 2012.
39. Wharton E.J., Panetta K., Agaian S.S., Logarithmic edge detection with applications. In *Systems, Man and Cybernetics*, 2007. ISIC, IEEE International Conference on, 3346-3351, 2007.
40. Hagara M., Hlavatovic A., Video segmentation based on Pratt's figure of merit, In *Radioelektronika*, 2009. RADIOELEKTRONIKA'09. 19th International Conference, 91-94, 2009.
41. Sorensen L., Shaker S.B., De Bruijne M., Quantitative Analysis of Pulmonary Emphysema using Local Binary Patterns, *IEEE Transactions on Medical Imaging*, 29 (2), 559-569., 2010.

