

Çoklu Kontrast MRG’de Çoklu Görüntü Geriçatımı Multi-Image Reconstruction in Multi-Contrast MRI

Muzaffer Özbey^{1,2}, Tolga Çukur^{1,2,3}

¹Elektrik ve Elektronik Mühendisliği Bölümü, Bilkent Üniversitesi, Ankara, Türkiye

²Ulusal Manyetik Rezonans Araştırma Merkezi, Bilkent Üniversitesi, Ankara, Türkiye

³Sinirbilim Programı, Mühendislik ve Fen Bilimleri Enstitüsü, Bilkent Üniversitesi, Ankara, Türkiye
muzaffer@ee.bilkent.edu.tr, cukur@ee.bilkent.edu.tr

Özetçe —Çoklu kontrastlı manyetik rezonans görüntülerinin (MRG) edinimi, tanı bilgi birikimini artırarak klinik tanıda önemli bir role sahiptir. Hastanın hareketsiz kalması gereken uzun tetkik süreleri, çoklu kontrast MRG edinimini sınırlandırmaktadır. Görüntülerin alt örneklenerek toplanması ve geriçatımı ile tarama süreleri kısaltılabilmektedir. Yaygın yöntemler, tek kontrasta ait alt örneklenmiş MR görüntülerinden aynı kontrasta ait tam örneklenmiş MR görüntüsü üretmektedir. Ancak girdi verisindeki tek kontrastlı MR görüntüsüne ait sınırlı bilgiler, geriçatım performansını sınırlandırmaktadır. Bu yüzden, çoklu kontrast MRG girdi verilerinin kullanımı ile geriçatım performansı artırılabilir. Bu çalışma kapsamında, birden fazla kontrasta ait alt örneklenmiş görüntülerden, tam örneklenmiş görüntüleri eş zamanlı olarak üreten bir çoklu kontrast MRG geriçatım yöntemi önerilmiştir. Önerilen yöntem, yüksek frekans değerlerini daha iyi tahmin ederek oldukça gerçekçi görüntüler üreten çekışmeli üretici ağlar kullanılarak uygulanmıştır. Önerilen yöntem, çoklu kontrast beyin MR görüntüleri içeren verisetinde test edilmiş, sayısal ve görsel değerlendirmeler sonucunda alternatif tekli kontrast geriçatım yöntemine göre daha üstün performans sağladığı kanıtlanmıştır.

Anahtar Kelimeler—MR görüntü geriçatımı, Derin öğrenme, Çekışmeli üretici ağlar, Çoklu kontrast MRG.

Abstract—The acquisition of multiple contrast magnetic resonance images (MRI) has an important role in clinical diagnosis by increasing diagnostic knowledge. Long scanning durations, in which the patient must remain immobile, limits the acquisition of multiple contrast MRIs. Scanning times can be reduced by undersampled acquisitions and reconstruction of undersampled images. Common methods produce a fully sampled MR image of a single contrast from undersampled MR image of the same contrast. However, limited prior information of a single contrast MR image in the input data limits the reconstruction performance. Hence, reconstruction performance can be increased with the use of multiple contrast MRI as input data. In this study, a multi-contrast MRI reconstruction method is proposed which simultaneously produces fully sampled images from undersampled images of more than one contrast. This method is applied using generative adversarial network that produce highly realistic images by better recovering the high frequency details. The proposed method has been tested on a dataset containing multiple contrast brain MR images, and it has been demonstrated that it provides superior performance compared to the alternative single contrast reconstruction method as a result of numerical and visual evaluations.

Keywords—MR image reconstruction, Deep learning, Generative adversarial network, Multi-contrast MRI.

I. GİRİŞ

Manyetik rezonans görüntüleme (MRG), müdahalesiz olması ve yumuşak doku tetkikindeki başarısından ötürü nörolojik hastalıklar başta olmak üzere klinik tanıda etkin rol üstlenmektedir. MR sinyal seviyesi, dokuların kimyasal yapısının yanısıra uygulanan sinyalin parametrelerine de oldukça bağlıdır. Bundan dolayı, diğer medikal görüntüleme tekniklerinden farklı olarak MRG’de birden fazla doku kontrastı ile çekim yapabilmek mümkündür. Dokular arasında gözlemlenmesi hedeflenen kontrasta göre, bağımsız MRG sekansları ile T_1 -ağırlıklı (örneğin beyaz/gri cevher ayrımı) veya T_2 -ağırlıklı (sıvı/yumuşak doku ayrımı) görüntüler elde edilebilir. Çoklu kontrast edinimi, klinik tanı bilgi birikimini artırmakta ve radyolojik tanı hassasiyetini yükseltmektedir.

Tanıya yönelik bilgi miktarını artıran çoklu kontrast MRG tetkikleri istemsiz sınırlamalara tabidir. Hastanın hareketsiz olması gereken uzun tetkik süreleri ve ekonomik kaygılar nedeniyle yüksek kaliteli MR görüntüsü elde etmek her zaman mümkün olmamaktadır [1]. Bu sorunu aşmak için MRG tetkiklerinin görüntü kalitesinden ödün vermeden hızlandırılması gerekmektedir. Bu sebeple, alt örneklenme ile kısa tarama süreleri ile elde edilen görüntülerden, tam örneklenmiş görüntülerin elde edinimi, çoklu kontrast MRG tetkikleri için önem arz etmektedir.

Hızlandırılmış MRG için literatürde farklı çalışmalar mevcuttur. MR görüntüleri doğal olarak sıkıştırılabilir olduğundan, hızlandırılmış MRG için yaygın bir teknik sıkıştırılmış algılama (SA) yöntemidir [2], [3]. Benzer şekilde Kararlı-Hal Veri Toplama teknikleri, k-uzayında toplanan veri miktarını azaltmakta ve sonrasında eksik verilerin giderilmesini sağlamaktadır [4], [5]. Fakat bu tarz geriçatım(ing: reconstruction) yöntemleri, artan veri boyutu ile giderek karmaşılaşan yinelemeli optimizasyon algoritmalarına ve kernel bazlı interpolasyon yöntemlerine dayalıdır [6]. Bu tarz yaklaşımlar yüksek frekans bilgilerinin geri tahmininde sıkıntılara sebep olmaktadır. Alternatif olarak daha sonraki çalışmalarda evrişimsel(ing: convolutional) sinir ağlarına dayalı derin öğrenme yöntemleri önerilmiştir.

Son yıllarda derin öğrenme teknikleri görüntü sentezi ve geriçatımı alanlarında başarılı sonuçlar elde etmektedir [7], [8], [9]. Özellikle çekışmeli üretici ağlar(GAN) modeli, verilerin genel dağılımı hakkında istatistiksel bilgileri öğrenmekte ve gerçekçi görüntüler üretebilmektedir. MR görüntü geriçatımı içinde başarılı GAN modeli uygulamaları literatürde mevcuttur. Önerilen derin öğrenme bazlı geriçatım yöntemlerinde,

yaygın olarak belirli bir kontrasta ait alt örneklenmiş MR görüntüsü girdi olarak kullanılmakta ve aynı kontrasta ait tam örneklenmiş MR görüntüsü üretilmeye çalışılmaktadır. Girdi kanalında, tek bir kontrasta ait görüntü kullanımı içerdiği sınırlı bilgi sebebiyle geriçatım performansını sınırlandırmaktadır. Yapılan literatür araştırmalarında, MRG alanı için geliştirilen derin öğrenme yöntemlerinde, girdi bilgisini artırmanın performans artışını sağladığı gözlenmiştir [10], [11]. Bu sebeple, tek kontrasta ait görüntü geriçatımındaki performans sınırlanması, çoklu kontrast kullanımı ile giderilebilir.

Bu çalışmada, MRG geriçatımı için yeni bir çoklu kontrast geriçatım yöntemi önerilmiştir. Önerilen yöntemde, iki farklı kontrasta ait beyin MR görüntüleri birlikte kullanılarak eş zamanlı olarak geriçatılmaktadır. Çoklu kontrast girdi verisinin kullanılması ile birlikte geriçatım performansı artmaktadır. $T1$ ve $T2$ ağırlıklı görüntü içeren beyin MRG veriseti üzerinde, önerilen yöntem ve tekli kontrast geriçatım yöntemleri sınanmıştır. Görsel ve sayısal değerlendirmeler sonucunda, önerilen yöntemin, tekli kontrast geriçatım yöntemine kıyasla üstün performans sağladığı gözlenmiştir.

II. YÖNTEM

A. Çekişmeli Üretici Ağlar

Çekişmeli Üretici Ağlar(GAN) modeli, iki alt ağ yapısının birleşiminden oluşur ve bu alt iki ağ modeli birbiri ile rekabet halindedir. Alt ağ yapıları, Üretici (G) ve ayrıştırıcı (D) ağ modelleridir. Üretici ağ (G) yapısı, istenilen hedef görüntünün olasılık dağılımlarını taklit eder ve rastgele gürültüden ilgili sahte hedef görüntüleri (\hat{y}) oluşturur; $G(z) = \hat{y}$. Üretici modelin yanısıra, ayrıştırıcı (D) ağ modeli ise üretilen sahte hedef görüntüleri(\hat{y}) ile ilgili gerçek hedef görüntülerini(y) karşılaştırarak sahte ve gerçek görüntüleri ayırtmaya çalışır $D(y) = [1, 0], D(\hat{y}) = [1, 0]$. Eş zamanlı olarak bu iki model birbirleriyle rekabet halinde eğitilir. Bu süreçte üretici ağ(G), ayrıştırıcı ağ(D) yapısının ayırt edemeyeceği kalitede gerçekçi görüntüler üretmeye çalışırken, ayrıştırıcı(D) ise üretilen gerçekçi görüntülerdeki ayırt edici farkları bularak üretici(G) modelini daha başarılı üretimlere yönlendirmektedir [12]. Bunun için çekişmeli yitim fonksiyonuna bağlı bir kayıp fonksiyonu, eğitim sürecinde kullanılır.

$$L_{GAN} = -E_y[(D(y) - 1)^2] - E_z[D(G(z))^2] \quad (1)$$

B. Koşullu Çekişmeli Üretici Ağlar

Klasik GAN modelleri, sahte görüntü üretiminde girdi olarak rastgele gürültü kullanılmaktadır. Sıfırdan görüntü üretmek yerine, aynı içeriğin farklı versiyonlardaki görüntülerini üretmek için de GAN modelleri kullanılabilir. Bunu için, klasik GAN modelinde bazı değişiklikler yapılabilir. Girdi verisi olarak, rastgele görüntü yerine üretilmek istenen ilgili içeriğin başka bir versiyonu kullanılabilir. Aynı içeriğin kullanılması ile ağ yapıları koşullandırılmakta ve koşullu GAN(cGAN) modelleri tasarlanmaktadır [13]. Klasik GAN modellerinde olduğu gibi, üretici(G) ağ modeli girdi verisini kullanarak, ilgili içeriğin hedef versiyonundaki sahte görüntüsünü (\hat{y}) üretir; $G(x) = \hat{y}$. Diğer yandan ayrıştırıcı (D) ağ modeli ise üretilen sahte hedef görüntüleri(\hat{y}) ile gerçek hedef görüntülerini(y) karşılaştırarak sahte ve gerçek görüntüleri ayırtmaya çalışır $D(y) = [1, 0], D(\hat{y}) = [1, 0]$. Klasik GAN modellerinde

olduğu gibi, ağ yapıları, çekişmeli yitim fonksiyonuna bağlı bir kayıp fonksiyonu kullanılarak eğitilir.

$$L_{cGAN} = -E_y[(D(y) - 1)^2] - E_x[D(G(x))^2] \quad (2)$$

Koşullu GAN modelinde, aynı içeriğin farklı versiyonundaki görüntüsü üretilmektedir. Eğer üretilmeye çalışılan görüntünün referans görüntüsü veri setinde bulunuyorsa, eğitim sürecinde ilave kayıp fonksiyonları kullanılabilir. Çekişmeli yitim fonksiyonuna ek olarak üretilen görüntü ile referans görüntü arasındaki piksel farkına dayanan bir kayıp fonksiyonu eğitim sürecine dahil edilebilir. Böylelikle, görüntülerin daha yüksek kalitede üretilmesi sağlanır.

$$L_{cGAN} = -E_y[(D(y) - 1)^2] - E_x[D(G(x))^2] + E_{xy}[||y - G(x)||] \quad (3)$$

C. Tekli Görüntü MR görüntü geriçatımı

Tekli görüntü geriçatımında, belirli bir MR kontrastında (c_1), k-uzayında alt örneklenme ile edilen MR görüntüsü (im_{us}) kullanılarak yine aynı kontrasta ait k-uzayında tam örneklenme ile edilen MR görüntüsü(im_{fs}) geriçatılmaya çalışılmaktadır. MRG tekli görüntü geriçatımında cGAN modellerinin kullanımı sırasında, üretici ağ(G), im_{us} görüntüsünü girdi olarak alıp, im_{fs} görüntüsünü üretmeye çalışır, $G(im_{us}) = im_{fs}$. Diğer yandan ayrıştırıcı ağ(D) ise geriçatılan sahte görüntü ve elde bulunan referans görüntüsünü ayırt etmeye çalışır $D(im_{fs}) = [1, 0], D(im_{us}) = [1, 0]$. Eğitim sürecinde, tam örneklenmiş MR görüntüleri kullanılır ve böylece G ve D ağ yapıları, çekişmeli yitim fonksiyonu ve piksel farkına dayanan bir kayıp fonksiyonu kullanılarak eş zamanlı olarak eğitilir.

$$L_{cGAN} = -E_{im_{fs}}[(D(im_{fs}) - 1)^2] - E_{im_{us}}[D(G(im_{us}))^2] + E_{im_{us}, im_{fs}}[||im_{fs} - G(im_{us})||] \quad (4)$$

D. Çoklu Görüntü MR görüntü geriçatımı

Literatür araştırması yapıldığında, tekli görüntü ile yapılan MRG geriçatım tekniklerinin başarılı performans sergiledikleri görülmüştür. Fakat yüksek hızlandırma faktörlerinde, tekli görüntü geriçatım yöntemlerinin yüksek frekans değerlerinin tahmini konusunda sıkıntı yaşadığı ve geriçatım performansında düşüş gözlenmiştir. Bu konuda yapılan çalışmalar, girdi verisinde çoklu görüntü kullanımının performansı artırdığını göstermiştir. Bu yüzden bu çalışmada, eş zamanlı olarak birden fazla kontrast görüntüsünde MRG geriçatımı yapan cGAN modeli geliştirilmiş ve yüksek performanslı bir MRG geriçatım yöntemi önerilmiştir. Önerilen çoklu görüntü MRG geriçatım yönteminde 2 farklı kontrasta ait alt örneklenmiş MR görüntülerinden ($X_{us} = [im_{1_{us}}, im_{2_{us}}]$), bu kontrastlara ait tam örneklenmiş MR görüntüleri($X_{fs} = [im_{1_{fs}}, im_{2_{fs}}]$) geriçatılmaktadır. Böylece farklı kontrastlara ait bilgiler ortaklaşa kullanılarak geriçatım performansı artırılmaktadır. Koşullu çekişmeli üretici ağlarda olduğu gibi model bir üretici(G) ve bir ayrıştırıcı(D) ağ yapılarından oluşmaktadır. Üretici ağ çoklu kontrasttaki alt örneklenmiş MRG girdi verisini kullanarak, aynı kontrastlardaki tam örneklenmiş MRG üretilmektedir($G(X_{us}) = \hat{X}_{fs}$). Ayrıştırıcı ağ yapısı da geriçatılan sahte MR görüntüleri ile referans MR görüntülerini ayırtmaya çalışmaktadır($D(X_{fs}) = [1, 0], D(\hat{X}_{fs}) = [1, 0]$). Diğer

$cGAN$ modellerinde olduğu gibi, çekişmeli yitim fonksiyonu ve piksel farkına dayanan bir kayıp fonksiyonu kullanılarak ağ yapıları eş zamanlı olarak eğitilir.

$$L_{cGAN} = -E_{X_{fs}}[(D(X_{fs}) - 1)^2] - E_{X_{us}}[D(G(X_{us}))^2] + E_{X_{us}, X_{fs}}[||X_{fs} - G(X_{us})||] \quad (5)$$

III. DENEYLER

Önerilen çoklu kontrast MR görüntü geriçatımının($cGAN_{many}$), geriçatım performans başarısını göstermek için önerilen yöntem literatürdeki tekli kontrast kullanımı ile yapılan geriçatım teknikleri($cGAN_{one}$) ile kıyaslanmıştır. Bu kapsamda yöntemler beyin görüntüleri içeren IXI(<https://brain-development.org/ixi-dataset/>) veri seti üzerinde test edilmiştir. Bu veri setinde, 53 sağlıklı deneye ait T_1 ve T_2 görüntüleri kullanılmıştır. Bu 53 deneye ait görüntüler 38'i eğitim, 5'i doğrulama ve 10 tanesi test olmak üzere üç gruba rastgele ayrılmıştır. Eğitim ve test süreçlerinde, her deneyin yüzer adet aksiyal görüntüsü kullanılmıştır.

$cGAN_{one}$ ve $cGAN_{many}$ yöntemleri farklı hızlandırma faktörlerinde alt örneklenmiş görüntülerin geriçatımı için eğitilmiş ve performansları kıyaslanmıştır($R=[4,8,12]$). $cGAN_{one}$ yöntemi için her hızlandırma faktöründe, iki farklı kontrast görüntüsü için iki ayrı geriçatım modeli birbirinden bağımsız olarak eğitilmiştir. Diğer yandan $cGAN_{many}$ yöntemi için, her hızlandırma faktörüne ait tek bir geriçatım modeli eğitilerek iki kontrast görüntüsü eş zamanlı olarak işlenerek geriçatılmıştır. Geriçatılan MR görüntüleri tam örneklenen referans görüntüleriyle kıyaslanarak, modellerin geriçatım performansları sınanmıştır.

Önerilen ile alternatif yöntemlere ait üretici ve ayrıştırıcı ağ yapılarının tasarımı için özellikle MR görüntülerinin geriçatımı ve sentezi için optimize edilmiş modeller incelenmiştir. Üretici ve ayrıştırıcı yapılar, evrişimsel sinir ağları kullanılarak oluşturulmuştur. Geriçatım modelleri, daha önce çoklu MR görüntü sentez-geriçatımı için önerilen GAN modeli temel alınarak oluşturulmuştur. Bu modelde, üretici ağ yapısı birbirini takip eden 3 evrişimsel sinir ağı, 9 ResNet bloku ve 3 evrişimsel sinir ağından oluşmakta iken ayrıştırıcı ağ yapısı ise birbirini takip eden 5 evrişimsel sinir ağından oluşmaktadır. $cGAN_{one}$ modelinde üretici ağ tek kontrasta ait alt örneklenmiş görüntüyü girdi kanalından alıp, aynı kontrasta ait tam örneklenmiş hedef görüntüsünü tek çıktı kanalından üretirken, $cGAN_{many}$ modelinde ise üretici ağ iki kontrasta ait alt örneklenmiş görüntüleri farklı girdi kanallarından alıp, aynı kontrastlara ait tam örneklenmiş hedef görüntülerini farklı çıktı kanallarından üretir. İki yöntem de aynı parametreler kullanılarak eğitilmiştir. Bu bağlamda, üretici ve ayrıştırıcı ağ yapıları eş zamanlı olarak ($\beta_1 = 0.999, \beta_2 = 0.5$) değerlerini kullanan Adam eniyileyicisiyle 100 devir boyunca eğitilmiştir. İlk 50 devirde öğrenme oranı 0.0002 iken, sonraki 50 devirde öğrenme oranı doğrusal bir şekilde 0'a doğru azaltılmıştır.

IV. SONUÇLAR

Önerilen $cGAN_{many}$ yöntemi, alternatif ($cGAN_{one}$) yöntemi ile birlikte, sağlıklı deneklere ait beyin görüntülerini içeren IXI veri setinde sınanmıştır. Yöntemler 4 farklı hızlandırma faktörlerinde alt örneklenmiş T_1 ve T_2 görüntülerin geriçatımı için eğitilmiş ve performansları kıyaslanmıştır($R=[4,8,12]$).


Her hızlandırma faktörü için tek bir $cGAN_{many}$ modeli 2 kontrastın eşzamalı geriçatımı için eğitilirken, 2 farklı $cGAN_{one}$ modeli ise T_1 ve T_2 görüntülerin geriçatımı için ayrı ayrı eğitilmiştir.

Tablo I önerilen yöntem ile alternatif yöntemin farklı hızlandırma oranları için test verisindeki tek seferlik geriçatım performansını PSNR ve SSIM metriklerini kullanarak göstermektedir. Önerilen yöntemin alternatif yöntemle göre daha yüksek performans sağladığı görülmektedir. Önerilen yöntem, T_1 geriçatımında [0.74-0.94] aralığında daha yüksek PSNR ve [1.88-5.03]% aralığında daha yüksek SSIM, T_2 geriçatımında [0.66-0.74] aralığında daha yüksek PSNR ve [1.42-3.09]% aralığında daha yüksek SSIM elde edebilmektedir. Önerilen

TABLE I: GERİÇATIM SONUÇLARI

		$cGAN_{many}$		$cGAN_{many}$	
		PSNR	SSIM	PSNR	SSIM
R=4x	T_1	32.63 ± 2.38	92.46 ± 1.82	31.88 ± 2.23	90.58 ± 1.59
	T_2	33.68 ± 1.48	92.61 ± 1.53	32.95 ± 1.47	91.19 ± 1.57
R=8x	T_1	29.80 ± 2.57	90.62 ± 2.57	29.06 ± 2.31	87.96 ± 2.17
	T_2	30.84 ± 1.47	90.58 ± 2.04	30.18 ± 1.37	88.79 ± 1.95
R=12x	T_1	27.48 ± 2.45	86.20 ± 3.91	26.61 ± 2.06	81.29 ± 2.90
	T_2	28.22 ± 1.34	86.35 ± 2.93	27.48 ± 1.24	83.28 ± 2.79
R=16x	T_1	27.01 ± 2.48	85.09 ± 4.29	26.07 ± 2.10	80.06 ± 3.11
	T_2	27.40 ± 1.27	85.09 ± 3.10	26.68 ± 1.20	82.00 ± 3.03

yöntemin üstün performansı sayısal sonuçların yanı sıra görsel sonuçlarla da desteklenmiştir. Şekil 1, önerilen yöntem ve alternatif yöntemin R=4x hızlandırma faktöründeki geriçatım sonuçlarını, hata resimlerini, referans görüntülerle birlikte göstermektedir. Burada, önerilen çoklu kontrast geriçatım yönteminin, daha başarılı geriçatım sonuçları ürettiği görülmektedir.



Şekil 1: IXI veri setinde hızlandırma faktörü 4 için geriçatım sonuçları: a) T_1 , b) T_2 . İlk sütun girdi görüntülerini, ikinci sütun referans görüntülerini, üçüncü sütun önerilen yöntemle ait geriçatım görüntülerini ve son sütun alternatif yöntemle ait geriçatım sonuçlarını içermektedir.

V. TARTIŞMA

Bu çalışmada, eşzamanlı olarak birden çok kontrasta ait görüntülerin birlikte geriçatımını gerçekleştiren bir çoklu kontrast MRG geriçatım yöntemi önerilmiştir. Önerilen yöntem, çoklu kontrast MRG’de, klasik derin öğrenme yöntemlerine yüksek frekans detaylarını daha iyi koruyarak gerçekçi görüntüler üretmede üstün performans göstermiş koşullu çekışmeli üretici ağılar temel alınarak geliştirilmiştir. Önerilen yöntem IXI verisetinde uygulanmış ve sonuçları analiz edilmiştir. Yapılan incelemeler sonucunda, önerilen yöntemin alternatif yöntemlere kıyasla daha başarılı geriçatım performansı sağladığı gözlenmiştir. Önerilen yöntem ilerde model üzerindeki yeni düzenlemelerle daha da geliştirilebilir. Çoklu kontrast görüntülerinin sentezlenmesi için geliştirilen MustGan [14] makalesinde olduğu gibi çoklu girdilerin birleşimi optimize edilebilir. Aynı şekilde derin öğrenme yöntemlerinin MR görüntülerindeki performanslarının transfer öğrenme yöntemi ile geliştiğı görülmüştür, benzer bir ön eğitim ile geriçatım performansı artırılabilir [15]. Ayrıca kademeli bir şekilde farklı oryantasyonlardaki kesit görüntüleriyle yapılan, MRG sentez ve geriçatım tekniklerinin daha başarılı görüntüler ürettiğı [16], [17] makalelerinde gözlenmiştir. Benzer şekilde MR görüntüleri kademeli olarak geriçatılabilir.

BİLGİLENDİRME

Bu çalışma Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 118E256 nolu proje, Avrupa Moleküler Biyoloji Örgütü (EMBO) tarafından IG 3028 nolu proje, TÜBA GEBİP 2015 programı, BAGEP 2017 programı ve Nvidia GPU hibe programı kapsamında desteklenmiştir.

KAYNAKLAR

- [1] Brij Bhushan Thukral, “Problems and preferences in pediatric imaging,” *The Indian journal of radiology & imaging*, vol. 25, no. 4, pp. 359, 2015.
- [2] L. K. Senel, T. Kilic, A. Gungor, E. Kopanoglu, H. E. Guven, E. U. Saritas, A. Koc, and T. Çukur, “Statistically Segregated k-Space Sampling for Accelerating Multiple-Acquisition MRI,” *IEEE Transaction on Medical Imaging*, vol. 38, no. 7, pp. 1701–1714, Jul 2019.
- [3] Mohammad Shahdloo, Efe Ilicak, Mohammad Tofighi, Emine U Saritas, A Enis Çetin, and Tolga Çukur, “Projection onto epigraph sets for rapid self-tuning compressed sensing mri,” *IEEE transactions on medical imaging*, vol. 38, no. 7, pp. 1677–1689, 2018.
- [4] T. Çukur, “Accelerated phase-cycled SSFP imaging with compressed sensing,” *IEEE Transaction on Medical Imaging*, vol. 34, no. 1, pp. 107–115, Jan 2015.
- [5] E. Ilicak, L. K. Senel, E. Biyik, and T. Çukur, “Profile-encoding reconstruction for multiple-acquisition balanced steady-state free precession imaging,” *Magnetic Resonance in Medicine*, vol. 78, no. 4, pp. 1316–1329, Oct 2017.
- [6] E. Kopanoglu, A. Güngör, T. Kilic, E. U. Saritas, K. K. Oguz, T. Çukur, and H. E. Güven, “Simultaneous use of individual and joint regularization terms in compressive sensing: Joint reconstruction of multi-channel multi-contrast MRI acquisitions,” *NMR in Biomedicine*, vol. 33, no. 4, pp. e4247, Apr 2020.
- [7] Salman Ul Hassan Dar, Mahmut Yurt, Levent Karacan, Aykut Erdem, Erkut Erdem, and Tolga Çukur, “Image synthesis in multi-contrast MRI with conditional generative adversarial networks,” *IEEE Transactions on Medical Imaging*, vol. 38, no. 10, pp. 2375–2388, 2019.
- [8] Salman Ul Hassan Dar, Mahmut Yurt, Mohammad Shahdloo, Muhammed Emrullah Ildiz, and Tolga Çukur, “Synergistic reconstruction and synthesis via generative adversarial networks for accelerated multi-contrast mri,” *arXiv preprint*, 2018.
- [9] Mahmut Yurt, Salman Ul Hassan Dar, Berk Tınaz, Muzaffer Özbey, and Tolga Çukur, “Semi-supervised learning of mutually accelerated multi-contrast mri synthesis without fully-sampled ground-truths,” *arXiv preprint*, 2020.
- [10] Salman U H Dar, Mahmut Yurt, Mohammad Shahdloo, Muhammed Emrullah Ildiz, Berk Tınaz, and Tolga Çukur, “Prior-guided image reconstruction for accelerated multi-contrast mri via generative adversarial networks,” *IEEE Journal of Selected Topics in Signal Processing*, vol. 14, no. 6, pp. 1072–1087, 2020.
- [11] Mahmut Yurt and Tolga Çukur, “Multi-image super resolution in multi-contrast mri,” in *2020 28th Signal Processing and Communications Applications Conference (SIU)*. IEEE, 2020, pp. 1–4.
- [12] Ian J Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio, “Generative adversarial networks,” *arXiv preprint arXiv:1406.2661*, 2014.
- [13] Mehdi Mirza and Simon Osindero, “Conditional generative adversarial nets,” *arXiv preprint arXiv:1411.1784*, 2014.
- [14] Mahmut Yurt, Salman Uh Dar, Aykut Erdem, Erkut Erdem, and Tolga Çukur, “mustGAN: Multi-Stream Generative Adversarial Networks for MR Image Synthesis,” *arXiv preprint*, 2019.
- [15] Salman Ul Hassan Dar, Muzaffer Özbey, Ahmet Burak Çatlı, and Tolga Çukur, “A transfer-learning approach for accelerated MRI using deep neural networks,” *Magnetic Resonance in Medicine*, vol. 84, no. 2, pp. 663–685, 2020.
- [16] Mahmut Yurt, Muzaffer Özbey, Salman Ul Hassan Dar, Berk Tınaz, Kader Karlı Oğuz, and Tolga Çukur, “Progressively volumetrized deep generative models for data-efficient contextual learning of mr image recovery,” *arXiv preprint*, 2020.
- [17] Muzaffer Özbey, Mahmut Yurt, Salman Ul Hassan Dar, and Tolga Çukur, “Three dimensional mr image synthesis with progressive generative adversarial networks,” *arXiv preprint arXiv:2101.05218*, 2020.