

# Çoklu Kontrast MRG’de Tranfer Öğrenme Yöntemi ile Birleşik Geriçatım-Sentez Synergistic Reconstruction-Synthesis of Multi-Contrast MRI using Transfer Learning Method

İrem Kaftan ve Özgür Bora Gevrek

Elektrik ve Elektronik Mühendisliği

Bilkent Üniversitesi

Ankara, Türkiye

irem.kaftan@ug.bilkent.edu.tr, bora.gevrek@ug.bilkent.edu.tr

Tolga Çukur

Elektrik ve Elektronik Mühendisliği

Bilkent Üniversitesi

Ankara, Türkiye

cukur@ee.bilkent.edu.tr

**Özetçe** —Manyetik rezonans görüntüleme (MRG) birçok hastalığın tanısında kullanılan müdahalesiz ve yumuşak doku kontrastı yüksek olan bir görüntüleme yöntemidir. MR sinyali görüntülen dokunun yapısına göre değişkenlik gösterdiği için MRG kullanılarak birden fazla kontrast ile görüntü alınması mümkündür. Çoklu kontrast MRG klinik tanıya yönelik bilgi miktarını artırsa da kontrastların tetkik süresi kısıtlamalarından dolayı çekiminin yapılamaması ya da yapılsa bile fazla miktarda gürültü içermesi bu yöntemin kullanımını zorlaştırmaktadır. Bu problemlere yönelik geliştirilen yöntem birleşik geriçatım-sentez sağlayan deterministik sinir ağlarında kaynak ve hedef kontrastlar arasındaki dönüşümün öğrenilmesidir. Proje kapsamında yapılan çalışmalar sonucunda yüksek derecede az örneklenen görüntülerin geriçatımının birleşik geriçatım-sentez modeli ve transfer öğrenme yöntemi ile başarıyla yapıldığı tespit edilmiştir.

**Anahtar Kelimeler**—çoklu kontrast MRG, derin öğrenme, deterministik sinir ağları, birleşik geriçatım-sentez.

**Abstract**—Magnetic resonance imaging (MRI) is a non-invasive imaging technique with high soft tissue contrast, which is used in the diagnosis of many diseases. Since MR signal varies based on the structure of the tissue to be imaged, it is possible to obtain images with more than one contrast using MRI. Although multi-contrast MRI increases the amount of information for clinical diagnosis, the problem that contrasts cannot be imaged due to scan time limitations or they contain a lot of noise even if they are imaged makes the use of this method difficult. The method developed for this problem is to learn the transformation between the source and target contrasts in deterministic neural networks that provide synergistic reconstruction-synthesis. As a result of the studies carried out within the scope of this project, it is determined that highly undersampled images are successfully reconstructed using the synergistic reconstruction-synthesis model and the transfer learning method.

**Keywords**—multi-contrast MRI, deep learning, deterministic neural networks, synergistic reconstruction-synthesis.

## I. GİRİŞ

Manyetik rezonans görüntüleme (MRG) yüksek yumuşak doku kontrastına sahip müdahalesiz bir görüntüleme yöntemi

olduğu için klinik tanıların konulmasında sıklıkla kullanılmaktadır. MR sinyal seviyesi dokuların kimyasal yapısına göre değişen T1, T2 ve PD parametrelerine bağlı olduğu için diğer medikal görüntüleme yöntemlerinin aksine MRG’de aynı dokunun farklı kontrastlar kullanarak görüntüsünü almak mümkündür. Anatomik yapılar arasında gözlemlenmesi amaçlanan kontrasta göre T1-ağırlıklı, T2-ağırlıklı ya da PD-ağırlıklı görüntüler alınmaktadır. Aynı anatomik yapının farklı kontrastlar kullanılarak alınan görüntülerinin değerlendirilmesi klinik tanı doğruluğunu artırmaktadır.

Çoklu kontrast MRG anatomik yapılarla ilgili daha çok bilgi verse de uzun tarama sürelerine ve özellikle küçük yaş ve ileri yaş hasta gruplarında daha fazla gürültü ve artefakte neden olmaktadır [1]. Bu sorunu çözmek için MRG tetkiklerinin görüntü kalitesini düşürmeden hızlandırılması gerekmektedir. Hızlandırılmış MRG için kullanılan en yaygın yöntemlerden biri sıkıştırılmış algılama (SA) yöntemidir [2], [3], [4]. MRG’de veri, görüntünün Fourier dönüşümünün kesikli örneklenmesi ile toplanmaktadır. SA yöntemi toplanan verileri Fourier uzayında R-kat hızlandırma faktörüyle raslantısal alt örnekleyerek tetkik süresini kısaltmaktadır [2]. Bu işlemde sonra eksik verileri tahmin ederek görüntünün en az bilgi kaybıyla geriçatılması gerekmektedir [4], [5], [6], [7]. Daha yüksek kalitede geriçatılabilme özelliği sebebiyle son yıllarda derin sinir ağları geriçatım modellerinde sıklıkla kullanılmaktadır [8], [9], [10], [11], [12]. Yüksek hızlandırma faktörleriyle alt örneklendirilen çoklu kontrast MR görüntülerinde derin sinir ağlarının yüksek frekans detaylarını içermesi konusunda iyi performans gösterememesi nedeniyle birleşik geriçatım-sentez yöntemleri önerilmektedir [13], [14], [15].

Bu çalışmada, çoklu kontrast MRG görüntülerinde daha yüksek kaliteli geriçatım yapabilmek için birleşik geriçatım-sentez modeli önerilmektedir. Önerilen model transfer öğrenme yöntemi ile kısıtlı miktardaki hedef kontrast görüntüsüyle yüksek kalitede geriçatım yapmaktadır. Önerilen modelin ağ mimarisi deterministik sinir ağlarına dayanmaktadır. Bu model girdi olarak tam örneklenmiş ya da 5’ten az hızlandırma faktörü ile hafif derecede az örneklenmiş kaynak kontrasta ait görüntüler ile 5 ile 50 arasındaki hızlandırma faktörleri ile yüksek derecede az örneklenmiş hedef kontrasta ait gö-


978-1-6654-3649-6/21/\$31.00 ©2021 IEEE

rüntüleri kabul etmekte ve çıktı olarak tam örneklenmiş hedef kontrasta ait görüntüleri üretmektedir. Proje kapsamında, çoklu kontrast MR görüntülerinde birleşik geriçatım-sentez yapmak için deterministik sinir ağlarına dayanarak tasarlanan transfer öğrenme yöntemi çoklu kontrast MR görüntüleri (T1, T2 ve PD) içeren IXI verisetiyle sınanmıştır. Transfer öğrenme yöntemi kullanılarak elde edilen sonuçların binlerce görüntü ile eğitilen birleşik geriçatım-sentez yöntemine yakın sonuçlar aldığı görülmüştür.

## II. YÖNTEM

### A. Birleşik Geriçatım-Sentez Modelinin Ağ Mimarisi

Geliştirilen deterministik model, görüntüden görüntüye çeviri yöntemlerinde yaygın olarak kullanılan gızyazar-gizçözer yapısını kullanır. Bu yapı, bir gızyazar ve bir gizçözerden oluşur. Gızyazar tam örneklenmiş ya da hafif derecede az örneklenmiş kaynak kontrasta ait görüntüler ile yüksek derecede az örneklenmiş hedef kontrasta ait görüntüleri girdi olarak alır. Sonrasında aldığı kaynak kontrasta ait görüntüleri işleyerek kaynak kontrasta ait görüntülerin hedef kontrasta ait görüntülere dönüşümünde kullanılacak olan saklı gösterimleri oluşturur. Gizçözer ise bu saklı gösterimleri girdi olarak alır. Sonrasında bu saklı gösterimleri işleyerek hedef kontrasta ait görüntüleri üretir. Gızyazar-gizçözer için tasarlanan deterministik ağ mimarileri için 5 CNN bloğundan oluşan bir nöral ağ oluşturulur. Her bir CNN bloğu, bir giriş katmanı, 4 evrişimsel katman, ve bir adet çıkış katmanı içerir. Örneklenen görüntüler, karmaşık sayı değerleri içerir. Bundan dolayı, giriş katmanı, örneklenen her bir kesit için her kesitin gerçek ve sanal değerlerini içeren iki kanaldan oluşur. Evrişim katmanlarındaki her bir evrişim işlemi doğrultulmuş lineer birim (Relu) aktivasyonu kullanılır. Gizli katmanlar 64 kanaldan oluşur. Çıkış katmanı ise tek kanal içerir. Bu gızyazar-gizçözer yapısına dayanan sistemin eğitilmesi ile istenen deterministik model öğrenilir. Bu ağın çalışma prensibi ve tasarımı Şekil 1'de gösterilmiştir.



Şekil 1: Deterministik ağlarda birleşik geriçatım-sentez yöntemi. Geliştirilen deterministik model gızyazar-gizçözer yapısına dayalı otokodlayıcıyı kullanır. Gızyazar tam örneklenmiş ya da hafif derecede az örneklenmiş kaynak kontrasta ait görüntüler ile yüksek derecede az örneklenmiş hedef kontrasta ait görüntüleri girdi olarak alır ve kaynak kontrasta ait görüntülerden saklı gösterimleri oluşturmayı öğrenir. Gizçözer ise bu saklı gösterimleri girdi olarak alır ve hedef kontrasta ait görüntüleri oluşturmayı öğrenir.

### B. Transfer Öğrenme Yöntemi

Transfer öğrenme yöntemi ile öğrenilen modelin görüntüleme ve doku parametrelerindeki olası değişkenliğe karşın gürbüzleştirilmesi amaçlanır. Bu nedenle hedef kontrasta ait

görüntüleri içeren büyük verisetleri yerine model parametrelerinin sıkça bulunan kaynak kontrasta ait görüntülerle ilk olarak genel eğitimi tamamlanır, daha sonrasında ince ayarı gerekli hedef görüntünün küçük veriseti ile yapılır. Çoklu kontrast MR görüntülerinde birleşik geriçatım-sentez yapmak için deterministik sinir ağlarına dayanarak tasarlanan transfer öğrenme yönteminde hedeflenen kontrasta ait görüntü yüksek derecede az örneklenmiş hedef kontrasta ait görüntü ve tam örneklenmiş ya da hafif derecede az örneklenmiş kaynak kontrasta ait görüntüler kullanılarak oluşturulur.

### C. Eğitim İşlemi

Eğitim işlemi kapsamında piksel farkına dayanan bir yitim fonksiyonu kullanılır.

$$L = E_{x,y} [|F_2(F_1(x)) - y|_1] \quad (1)$$

Denklem (1)'de  $x$  kaynak kontrasta ait az örneklenmiş ya da kaynak kontrasta ait tam örneklenmiş MR görüntüleriyle hedef kontrasta ait az örneklenmiş MR görüntüsünün birleşmiş halini,  $y$  hedef kontrasta ait oluşturulan MR görüntüsünü,  $F_1$  ağ mimarisindeki gızyazarı,  $F_2$  ağ mimarisindeki gizçözeri,  $E$  beklenti fonksiyonunu ve  $L$  toplam yitim fonksiyonunu gösterir. Proje kapsamında, tam örneklenmiş T1-ağırlıklı görüntüler ve yüksek derecede az örneklenmiş T2-ağırlıklı görüntülerden T2-ağırlıklı görüntülerin geriçatımı ve tam örneklenmiş T1-ağırlıklı görüntüler ve yüksek derecede az örneklenmiş PD-ağırlıklı görüntülerden PD-ağırlıklı görüntülerin geriçatımı yapılmıştır. Yapılan deneylerde 40 denek eğitim için 10 denek ise test için ayrılmıştır. Kullanılan T1-ağırlıklı, T2-ağırlıklı, ve PD-ağırlıklı görüntüler 3T MRG cihazı ile toplanmıştır. T1-ağırlıklı görüntüler için kullanılan tarama parametreleri şu şekildedir: TR= 9.6 ms, TE= 4.6 ms, çevirme açısı= 8°, ve görüntü matrisi boyutu= 208 x 208. T2-ağırlıklı görüntüler için kullanılan tarama parametreleri şu şekildedir: TR= 5725 ms, TE= 100 ms, çevirme açısı= 90°, ve görüntü matrisi boyutu= 192 x 187. PD-ağırlıklı görüntüler için kullanılan tarama parametreleri şu şekildedir: TR= 9.6 ms, TE= 8 ms, çevirme açısı= 90°, ve görüntü matrisi boyutu= 192 x 187. Tasarlanan deterministik ağlar Python dilinin Keras kütüphanesinde eniyilenmiştir. Bu kapsamda, ADAM eniyileyicisiyle eğitilen ağlardaki devir sayısı 5-dosyalı geçerleme ile belirlenmiştir. Eğitim esnasında grup büyüklüğü 16 olarak seçilmiştir. Bütün model parametreleri normal dağılım (ortalama: 0, standart sapma 0.02) kullanılarak rastgele başlatılmıştır.

## III. SONUÇLAR

T2-ağırlıklı görüntülerin birleşik geriçatım-sentezi için aşağıda sıralanan modeller eniyilenerek eğitilmiştir. Eğitilen modellerin sonuçları karşılaştırılarak model performansları ve transfer öğrenme yönteminin etkisi incelenmiştir.

1) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntüler ile test edilmiştir.

2) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntüler ile test edilmiştir.

3) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; transfer öğrenme kapsamında az sayıda tam örneklenmiş T1-ağırlıklı ve az örneklenmiş T2-ağırlıklı görüntülerle ince ayarı yapılarak tam örneklenmiş T1-ağırlıklı ve az örneklenmiş T2-ağırlıklı görüntülerle test edilmiştir.

PD-ağırlıklı görüntülerin birleşik geriçatım-sentezi için aşağıda sıralanan modeller eniyilenerek eğitilmiştir. Eğitilen modellerin sonuçları karşılaştırılarak model performansları ve transfer öğrenme yönteminin etkisi incelenmiştir.

1) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntüler ile test edilmiştir.

2) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntüler ile test edilmiştir.

3) Tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntüler ile eğitilen deterministik sinir ağı; transfer öğrenme kapsamında az sayıda tam örneklenmiş T1-ağırlıklı ve az örneklenmiş PD-ağırlıklı görüntülerle ince ayarı yapılarak tam örneklenmiş T1-ağırlıklı ve az örneklenmiş PD-ağırlıklı görüntülerle test edilmiştir.

Tablo 1 ve Tablo 2 farklı hızlandırma faktörlerinde (R = 5, 10, 20, 30 40, 50) IXI veriseti için T2-ağırlıklı ve PD-ağırlıklı görüntülerin deterministik sinir ağı ile birleşik geriçatım-sentezi model performans karşılaştırmalarını göstermektedir. Model 1 birleşik geriçatım-sentez yöntemini, Model 2 ve Model 3 transfer öğrenme yönteminden önceki ve sonraki birleşik geriçatım-sentez yöntemini belirtmektedir.


Önerilen deterministik sinir ağı ile birleşik geriçatım-sentez yöntemi (Model 1) PSNR (Peak Signal-to-Noise Ratio - En Yüksek Sinyal-Gürültü Oranı) ve SSIM (Structural Similarity Index Measure - Yapısal Benzerlik Index Ölçütü) değerleri açısından başarılı sonuçlar almıştır. Başta görece

**TABLO I: T2-AĞIRLIKLI GÖRÜNTÜLERDE DETERMİNİSTİK AĞLAR İLE YAPILAN BİRLEŞİK GERİÇATIM-SENTEZ VE TRANSFER ÖĞRENME SONUÇLARI**

T2 Geriçatımı	Model 1		Model 2		Model 3	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
R = 5	35.91	97.57	34.12	96.92	35.65	97.46
R = 10	32.56	95.68	30.16	27.29	32.35	95.65
R = 20	30.12	93.74	25.89	88.95	29.88	93.47
R = 30	29.42	93.04	25.89	88.95	28.95	92.60
R = 40	28.98	92.64	25.66	87.90	28.57	92.12
R = 50	28.75	92.41	24.37	86.61	28.15	91.84

**TABLO II: PD-AĞIRLIKLI GÖRÜNTÜLERDE DETERMİNİSTİK AĞLAR İLE YAPILAN BİRLEŞİK GERİÇATIM-SENTEZ VE TRANSFER ÖĞRENME SONUÇLARI**

PD Geriçatımı	Model 1		Model 2		Model 3	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
R = 5	34.55	97.78	31.66	95.97	34.08	97.67
R = 10	31.12	95.93	28.59	93.16	30.51	95.70
R = 20	28.95	93.87	27.31	90.44	28.66	93.50
R = 30	28.33	93.09	26.49	88.75	27.79	92.70
R = 40	27.90	92.62	25.72	88.06	27.57	92.19
R = 50	27.71	92.56	25.23	86.89	27.19	91.86




Şekil 2: Deterministik ağırlar ile yapılan geriçatım-sentez sonuçları. Beyaz madde, gri madde, ve beyin-omurilik sıvısı arasındaki geçiş bölgelerinin birbirinden ayırmak için kullanılmıştır. Önerilen geriçatım-sentez modelinin IXI verisetinde tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş T2-ağırlıklı görüntülerden T2-ağırlıklı görüntülerin ve tam örneklenmiş T1-ağırlıklı görüntüler ve az örneklenmiş PD-ağırlıklı görüntülerden PD-ağırlıklı görüntülerin birleşik geriçatım-sentez performansı sonuçları verilmiştir. “Kaynak” olarak isimlendirilen sütun kaynak kontrasta ait görüntüyü, “Referans” olarak isimlendirilen sütun hedef kontrasta ait görüntüyü ve “Model 1” olarak isimlendirilen sütun önerilen deterministik sinir ağı ile geriçatım-sentezi yapılan hedef kontrasta ait görüntüyü göstermektedir. A) T2-ağırlıklı görüntülerin ve B) PD-ağırlıklı görüntülerin geriçatım sonuçlarını göstermektedir.

düşük performans gösteren Model 2, 50 tane MR görüntüsü kullanılarak yapılan transfer öğrenme sonrasında (Model 3), Model 1’e oldukça yakın bir performans elde etmiştir. Önerilen deterministik sinir ağı ile yapılan birleşik geriçatım-sentez ve transfer öğrenme sonuçları görsel olarak Şekil 2 ve Şekil 3’te gösterilmiştir. Şekil 2’de Model 1 ile elde edilen sonuçlar hedef kontrasta ait referans görüntüyle beraber verilmiştir. Şekil 3’te ise Model 1 ile elde edilen sonuçlar Model 2 ve Model 3 ile elde edilen sonuçlar ile karşılaştırmalı olarak gösterilmiştir.

#### IV. TARTIŞMA

Müdahalesiz olması ve birçok farklı yumuşak doku kontrastı üretmekteki başarısından ötürü MRG, hastalık teşhis ve tetkikinde yaygın olarak tercih edilen bir görüntüleme yöntemidir. Tetkik verimliliğini artırırken görüntü bozukluk veya eksiklerini gideren yenilikçi MRG teknolojileri sağlık açısından büyük önem taşımaktadır. Birleşik geriçatım-sentez yöntemi, son yıllarda yüksek çözünürlük ve ileri performans sunan derin öğrenme modellerine dayanmaktadır. Bu bildiride, çoklu kontrast MRG tetkiklerinde kısa tetkik sürelerinde yüksek tanı bilgisi elde edilmesi için birleşik geriçatım-sentez yapan yenilikçi derin öğrenme tekniği ve transfer öğrenme yöntemi geliştirilmiştir. Bildiride önerilen method, MR görüntü geriçatımı yansıran MR görüntü sentezi için de geliştirilebilir [16], [17]. Proje kapsamında gerçekleştirilen deneyler ve analizler sonucunda, veriye dayalı bir yaklaşım kullanan



Şekil 3: Deterministik ağlar ile yapılan geriçatım-sentez ve transfer öğrenme sonuçları. A) T2-ağırlıklı görüntülerin ve B) PD-ağırlıklı görüntülerin geriçatım sonuçlarını göstermektedir. Model 2 üzerinde 50 tane görüntüyle yapılan transfer öğrenme sonucunda elde edilen Model 3, binlerce görüntüyle eğitilen Model 1'e oldukça yakın performans elde etmiştir.

derin öğrenme teknikleri kaynak ve hedef görüntü arasındaki karmaşık ilişkileri başarıyla çözebilmiş ve bunun sonucunda tam örneklenmiş kaynak ve yüksek derecede az örneklenmiş hedef kontrastına ait görüntüleri girdi olarak kullanan birleşik geriçatım-sentez yönteminin mevcut tek kontrast görüntüsüne dayalı yöntemlerden [18], [19] daha başarılı geriçatım-sentez performansları elde ettiği gözlemlenmiştir.

#### BİLGİLENDİRME

Bu proje Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından 118E256 nolu proje kapsamında desteklenmiştir.

#### KAYNAKLAR

- [1] K. Krupa and M. Bekiesinska-Figatowska, "Artifacts in Magnetic Resonance Imaging," *Pol J Radiol*, vol. 80, no. 1, pp. 93-106, 2015.
- [2] M. Lustig, D. Donoho, and J. M. Pauly, "Sparse MRI: The application of compressed sensing for rapid MR imaging," *Magn. Reson. Med.*, vol. 58, no. 6, pp. 1182-1195, 2007.
- [3] T. Çukur, M. Lustig, and D. G. Nishimura, "Improving non-contrast enhanced steady-state free precession angiography with compressed sensing," *Magnetic Resonance in Imaging*, vol. 61, no.5, pp. 1122-1131, 2009.
- [4] M. Shahdloo, E. Ilıcak, M. Tofighi, E. Ü. Sarıtaş, A. E. Çetin, and T. 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.
- [5] T. Çukur, "Accelerated Phase-Cycled SSFP Imaging with Compressed Sensing," *IEEE Transactions on Medical Imaging*, vol. 34, pp. 107-115, 2014.
- [6] E. Kopanoğlu, A. Güngör, T. Kılıç, E. Ü. Sarıtaş, K. K. Oğuz, T. Çukur, and H. E. Güven, "Simultaneous Use of Individual and Joint Regularization Terms in Compressive Sensing: Joint Reconstruction of Multi-Channel Multi-Contrasts MRI Acquisitions," *NMR in Biomedicine*, vol. 33, no. 4, pp. E4247, 2020.
- [7] L. K. Şenel, T. Kılıç, A. Güngör, E. Kopanoğlu, H. E. Güven, E. Ü. Sarıtaş, A. Koç, and T. Çukur, "Statistically Segregated k-space Sampling for Accelerating Multiple-Acquisition MRI," *IEEE Transactions on Medical Imaging*, vol. 38, pp. 1701-1714, 2019.
- [8] S. U. H. Dar, M. Yurt, M. Shahdloo, M. E. Ildız, T. Çukur, "Synergistic Reconstruction and Synthesis via Generative Adversarial Networks for Accelerated Multi-Contrast MRI," *arXiv preprint*, 2018.

- [9] S. U. H. Dar, M. Özbey, A. B. Çatlı, ad T. Çukur, "A Transfer-Learning Approach for Accelerated MRI using Deep Neural Networks," *Magnetic Resonance in Medicine*, vol. 84, no. 2, pp. 663-685, 2020.
- [10] M. Yurt, M. Özbey, S. U. H. Dar, B. Tınaz, K. K. Oğuz, and T. Çukur, "Progressively Volumetrized Deep Generative Models for Data-Efficient Contextual Learning of MR Image Recovery," *arXiv preprint*, 2020.
- [11] C. M. Hyun, H. P. Kim, S. M. Lee, S. Lee, and J. K. Seo, "Deep Learning for Undersampled MRI Reconstruction," *Physics in Medicine and Biology*, vol. 63, no. 13, 2018.
- [12] T. M. Quan, T. Nguyen-Duc and W. -K. Jeong, "Compressed Sensing MRI Reconstruction Using a Generative Adversarial Network With a Cyclic Loss," *IEEE Transactions on Medical Imaging*, vol. 37, no. 6, pp. 1488-1497, 2018.
- [13] L. Xiang "Deep Learning Based Multi-Modal Fusion for Fast MRI Reconstruction," *IEEE Transactions in Biomedical Engineering*, vol. 66, no. 7, pp. 2105-2114, 2019.
- [14] A. Falvo, D. Communiello, S. Scardapane, G. Finesi, M. Scarpiniti, and A. Uncini, "A Multi-Modal Deep Network for the Reconstruction of T2W MRI Images," *arXiv*, 2019.
- [15] A. Falvo, D. Communiello, S. Scardapane, M. Scarpiniti, and A. Uncini, "A Multi-Modal dense u-net for accelerating Multiple Sclerosis MRI," in *Proc. IEEE 29th International Workshop on Machine Learning and Signal Processing*, pp. 1-6, 2019.
- [16] M. Yurt, S. U. Dar, A. Erdem, E. Erdem, and T. Çukur, "mustGAN: Multistream Generative Adversarial Networks for MR Image Synthesis," *arXiv:1909.11504*, 2019.
- [17] S. U. Dar, M. Yurt, L. Karacan, A. Erdem, E. Erdem and T. 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.
- [18] L. Xiang et al., "Deep-learning-based multi-modal fusion for fast MR reconstruction," *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 7, pp. 2105-2114, 2019.
- [19] L. Sun, Z. Fan, X. Fu, Y. Huang, X. Ding, and J. Paisley, "A deep information sharing network for multi-contrast compressed sensing MRI reconstruction," *IEEE Transactions on Image Processing*, vol. 28, no. 12, pp. 6141-6153, 2019.