

Ortak Sözlük Öğrenimi ile Sıkıştırılmış Çoklu-Kontrast Manyetik Rezonans Görüntülerinin Geri-kazanımı

Joint Dictionary Learning Reconstruction of Compressed Multi-Contrast Magnetic Resonance Imaging

Alper Güngör^{1,2}, Emre Kopanoğlu^{2,4}, Tolga Çukur³, Emre Güven², Fatoş T. Yarman-Vural¹

¹ Bilgisayar Mühendisliği Bölümü / Orta Doğu Teknik Üniversitesi

alpergungor@aselsan.com.tr, vural@ceng.metu.edu.tr

² ASELSAN Araştırma Merkezi / ASELSAN A.Ş.

ekopanoglu@aselsan.com.tr, hegüven@aselsan.com.tr

³ Elektrik ve Elektronik Mühendisliği Bölümü / İhsan Doğramacı Bilkent Üniversitesi

çukur@ee.bilkent.edu.tr

⁴ Cardiff University Brain Research Imaging Centre, School of Psychology / Cardiff University

Özet

Bu çalışma sıkıştırılmış manyetik rezonans görüntülerinin (MRG) ortak sözlük öğrenimi kullanılarak geri-kazanımını incelemektedir. Genellikle sıkıştırılmış algılama için önceden belirlenmiş sözlükler kullanılır. Burada, görüntü ve seyrelten dönüşümün yalnızca veri kullanılarak geri-kazanılması için dönüşümlü minimizasyon tabanlı bir algoritma önerilmektedir. Önerilen yöntem aynı zamanda daha önceden kullanılan bir öngörüsüz sıkıştırılmış algılama metodunun ortak geri-kazanım için genişletilmesi şeklinde de görülebilir [1]. Algoritma başarımını ölçmek için, algoritma yakınsama hızı ve görüntü kalitesi olarak hem ayrık sözlük öğrenimi tabanlı metod [1] ile hem de önceden belirlenmiş sözlükleri kullanan bir MRG için ortak geri-kazanım algoritması ile kıyaslanmıştır [2].

Abstract

This study deals with reconstruction of compressed multi-contrast magnetic resonance image (MRI) reconstruction using joint dictionary learning. Usually pre-determined dictionaries are used for compressed sensing reconstructions. Here, we propose an alternating-minimization based algorithm for recovering image and sparsifying transformation from only data itself. The proposed method can also be viewed as a joint multi-contrast reconstruction extension of a previous blind compressive sensing algorithm [1]. For evaluation, the algorithm is compared in terms of convergence speed and image quality to both individual dictionary learning based method [1], and a joint reconstruction algorithm using pre-determined dictionaries for MRI [2].

önden tasarlanmış birden çok dönüşüm uzayındaki seyreklikten faydalanarak geri-kazanımın tamamlanmasını içermektedir [2, 3, 4]. Buna ek olarak, birden çok kontrast görüntünün bulunduğu durumlarda ortak geri-kazanım fonksiyonlarının daha avantajlı olabildiği gösterilmiştir [2, 5]. Ancak, önden tasarlanmış dönüşümler hızlı sonuç verse de, bu dönüşümlerin bütün görüntüler için en uygun çözüm olmadığı bilinmektedir. Bu bildiride, sıkıştırılmış çoklu-kontrast MRG için sözlük öğrenimi tabanlı bir geri-kazanım yöntemi ele alınmıştır.

Sözlük öğrenimi, verilen bir sinyal kümesi için bu kümeyi en iyi sıkıştırabilen veya seyrelten dönüşüm uzaylarını bulmak için kullanılan bir sinyal işleme aracıdır. Seyrelten dönüşüm uzayları genellikle sıkıştırma veya öznitelik ayrımı amaçlarıyla kullanılmaktadır. Daha önce bu dönüşüm uzaylarının seyreltme özelliğinden faydalanılarak, sözlük öğrenimi sıkıştırılmış algılama ile görüntü geri-çatımı amacıyla kullanılmıştır. Bu bağlamda hem dönüşüm uzayının hem de görüntünün bir arada geri-kazanımının yapıldığı çevirim içi sözlük öğrenimi problemi olarak modellenmiştir [1].

Bu çalışmada farklı kontrast görüntüler için bir ortak sözlük öğrenimi yöntemi önerilmiştir. Farklı kontrast görüntü vektörleri üzerinde tek bir ortak sözlük kullanılmış, ardından bu vektörlerin aynı koordinat noktalarının seyrek olması zorlanmıştır. Bu sayede farklı kontrast görüntüler arasındaki ortak bilgi de sözlük öğrenimi problemine birleştirilmiş ve toplanan veriden en yüksek verim elde edilmesi hedeflenmiştir. Önerilen yöntem, hem önden tasarlanmış dönüşüm uzayları içeren bir yöntem ile hem de ayrık sıkıştırılmış algılayıcı sözlük öğrenimi metodu ile tepe sinyal gürültü oranı ($pSNR$) kullanılarak görsel olarak kıyaslanmıştır.

1. Giriş

Manyetik Rezonans Görüntüleme (MRG), yumuşak dokuların yüksek çözünürlüklü olarak görüntülenmesini sağlayan bir yöntemdir. MRG üzerindeki çeşitli sıkıştırılmış algılama uygulamaları dalgacık dönüşümü seyrekliği ve toplam değişim gibi

2. Genel Bilgiler

2.1. Görüntüleme Modeli

Bir çok görüntüleme probleminde görüntü vektörü ($\mathbf{x} \in \mathbb{C}^N$) ile veri vektörü ($\mathbf{y} \in \mathbb{C}^M$) arasındaki bağıntı doğrusal op-

eratörler kullanılarak modellenilebilir. Görüntüleme matrisi ($\mathbf{A} \in \mathbb{C}^{M \times N}$) bu iki vektörü, şu eşitliğe göre bağlamaktadır:

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{n}. \quad (1)$$

Denklemden $\mathbf{n} \in \mathbb{C}^M$ gürültü vektörünü ifade etmektedir. Bir den çok kontrast MRG verisi var iken ise, bu model her kontrast görüntü vektörü $\mathbf{x}^{(i)}$ için şu şekilde genişletilebilir:

$$\mathbf{y}^{(i)} = \mathbf{A}^{(i)}\mathbf{x}^{(i)} + \mathbf{n}^{(i)}. \quad (2)$$

Denklemden üstel olarak ifade edilen (i) , herhangi bir vektörün hangi kontrast görüntüye ait olduğunu göstermektedir. MRG, verisi Fourier uzayında toplanmaktadır. Çoğunlukla frekans uzayında verinin tamamı alınmamaktadır. Bu sebeple, her kontrast için problem modeli $\mathbf{A}^{(i)}$ kısmi Fourier dönüşümünü ifade etmektedir. Bu matris, alt-örnekleme matrisi $\mathbf{M}^{(i)}$ ve Fourier dönüşüm matrisi \mathbf{U} 'nin çarpımı şeklinde ifade edilebilir:

$$\mathbf{A}^{(i)} = \mathbf{M}^{(i)}\mathbf{U}. \quad (3)$$

Burada her kontrast görüntü için farklı alt-örnekleme matrisi kullanılabileceği gibi, benzer alt-örnekleme matrisleri de kullanılabilir.

2.2. MRG için Sıkıştırılmış Algılama

Sıkıştırılmış algılama, bir dönüşüm uzayında seyrek olan bir sinyalin az sayıda örnek ile geri-kazanımını sağlayan bir sinyal işleme yöntemidir [6, 7]. MRG literatüründe alt-örnekleme veriden geri-kazanım için sıkça kullanılmaktadır [1, 2, 3]. Tipik olarak görüntünün dalgacık ve gradyan uzaylarındaki seyrekliği kullanılmakta, ve aşağıdaki tarzda bir optimizasyon problemi çözülmektedir [3, 4, 8]:

$$\underset{\mathbf{x}}{\text{minimize}} \quad \alpha_1 \|\mathbf{W}\mathbf{x}\|_1 + \alpha_2 TV(\mathbf{x}) + \frac{1}{2} \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2^2. \quad (4)$$

Burada \mathbf{W} dalgacık dönüşümünü, $TV(\cdot)$ ise toplam değişim fonksiyonunu ifade etmektedir ve görüntünün gradyanı üzerinde seyreklik zorlaması yapmaktadır. Güncel çalışmalar çoklu-kontrast için ortak yöntemlerin daha iyi çalıştığını göstermektedir [9, 2, 5]. Bu durumda görüntüler üzerindeki ortak seyreklik bilgisi kullanılmakta, ve aşağıdaki gibi bir problem çözülmektedir:

$$\underset{\mathbf{x}}{\text{minimize}} \quad \alpha_1 \|\mathbf{W}\mathbf{x}\|_{2,1} + \alpha_2 JTV(\mathbf{x}) + \sum_{i=1}^C \frac{1}{2} \|\mathbf{A}^{(i)}\mathbf{x}^{(i)} - \mathbf{y}^{(i)}\|_2^2. \quad (5)$$

Fonksiyonlar şu şekilde tanımlanmıştır:

$$\|\mathbf{x}\|_{2,1} = \sum_j \sqrt{\sum_i (\mathbf{x}^{(i)}[j])^2} \quad (6)$$

$$JTV(\mathbf{x}) = \sum_j \sqrt{\sum_i (\nabla_1 \mathbf{x}^{(i)}[j])^2 + (\nabla_2 \mathbf{x}^{(i)}[j])^2} \quad (7)$$

Burada ∇_1 ve ∇_2 iki yönde gradyan işlemlerini, $\mathbf{x}[j]$ ise vektörün j . indisini ifade etmektedir. Bu problemde ifade edilen $\|\cdot\|_{2,1}$ ve $JTV(\cdot)$ fonksiyonları bütün kontrast görüntüler üzerinde ortak olarak hesaplanmakta, ve farklı kontrastlar arasında aynı koordinatların birlikte seyrek olmasını sağlamaktadır.

2.3. Sıkıştırılmış Algılama için Sözlük Öğrenimi

Sıkıştırılmış algılamada, kullanılan dönüşüm uzayının oluşturulan görüntü üzerine etkisi büyüktür. Bir önceki kısımda bahsedilen yöntemler ise *genel geçer* dönüşüm uzaylarını kullanmaktadır. Ancak genel geçer dönüşüm uzayları, MRG uygulaması için en iyi dönüşüm uzayını ifade etmeyebilir. Matematiksel olarak, sözlük öğrenimi verilen bir veri kümesi (\mathbf{Y}) için en iyi seyrekleştirilen dönüşüm uzayını (\mathbf{W}) ve bu dönüşüm uzayında kullanılan seyrek kodları (\mathbf{X}) aynı anda bulma problemidir ve şu şekilde ifade edilebilir:

$$\underset{\mathbf{W}, \mathbf{X}}{\text{minimize}} \quad \|\mathbf{W}\mathbf{X} - \mathbf{Y}\|_F^2 + Q(\mathbf{W}) \\ \text{subject to} \quad \|\mathbf{X}\|_0 \leq S, \quad (8)$$

S seyreklik limitini, $Q(\mathbf{W})$, seyreklik uzayı üzerinde kullanılan düzenleyici terimi ifade etmektedir. Bu problem çözülerek elde edilen \mathbf{W} daha sonra sıkıştırılmış algılama problemi ile geri-kazanım sırasında kullanılabilir. Bu yöntem *çevirim dışı* sözlük öğrenimi denilmektedir.

Sözlük öğrenimi, sıkıştırılmış algılama ile birlikte hem görüntü, hem seyreklik uzayı hem de seyrek kodlarının bir arada bulunması için de kullanılabilir. Bu durumda, çevrimiçi sözlük öğrenimi probleminin çözülmesi gerekmektedir. Ancak bu problem değişken sayısı itibarıyla daha zor bir problem oluşturmaktadır. Bu sebeple görüntü parçalara bölünmekte, ve her bir parça üzerinde seyreklik varsayımı yapılmaktadır [1]:

$$\underset{\mathbf{W}, \mathbf{x}, \mathbf{B}}{\text{minimize}} \quad \sum_{j=1}^N \|\mathbf{W}\mathbf{P}_j \mathbf{x} - b_j\|_2^2 \\ + \nu \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_F^2 + Q(\mathbf{W}) \\ \text{subject to} \quad \|\mathbf{B}\|_0 \leq s. \quad (9)$$

Burada, \mathbf{P}_j parça seçim matrisini ifade etmektedir ve kesişen parçalar üzerinden problem (9) çözülerek hem görüntü, hem de seyreklik uzayı aynı anda geri-kazanılabilir.

3. Yöntem

Çoklu-kontrast ortak geri-kazanım yöntemlerinin birden çok kontrast görüntünün verisinin alındığı durumlarda görüntü kalitesini arttırdığı gösterilmiştir. Bu çalışmada daha önce tekli-kontrast için önerilen sözlük öğrenimi yöntemi çoklu-kontrast için genişletilmiştir. Bu amaçla, ilk olarak algoritma bütün kontrastlar için tek bir dönüşüm uzayı öğrenmeye, ikinci olarak ise öğrenilen dönüşüm uzayının farklı kontrastlarda aynı koordinatları seyrek yapmaya zorlanmıştır. Önerilen yöntem aşağıdaki problemin çözümünü içermektedir:

$$\underset{\mathbf{W}, \mathbf{x}, \mathbf{B}}{\text{minimize}} \quad \sum_{i=1}^C \left(\sum_{j=1}^N \|\mathbf{W}\mathbf{P}_j \mathbf{x}^{(i)} - b_j^{(i)}\|_2^2 \right. \\ \left. + \nu \|\mathbf{A}^{(i)}\mathbf{x}^{(i)} - \mathbf{y}^{(i)}\|_F^2 \right) + Q(\mathbf{W}) \\ \text{subject to} \quad \|\mathbf{B}\|_{2,0} \leq s. \quad (10)$$

Bu problem NP-Hard sınıfındadır ve çözümünü pratikte uygulanabilir bir zamanda yapılamamaktadır. Bu sebeple çeşitli yaklaşık çözümler önerilmiştir [1]. Bu çalışmada problem (9) için kullanılan benzer bir çözüm yöntemi kullanılmaktadır, ve önerilen problem (10) "dönüşümlü minimizasyon" tabanlı bir yöntem ile çözülmektedir. Buna göre, problem üç parçaya bölünmekte ve her parça için ayrı ayrı yinelemeli olarak çözülmektedir. Algoritma seyrek kodlama, sözlük güncellemesi

Tablo 1: **Algoritma: Çoklu Kontrast MRG için Öngörüsüz Sıkıştırılmış Algilama**

1. Başlangıç ($\mathbf{W}^0, \mathbf{B}^0, \mathbf{x}^0$).
2. **for** $t = 1:J$
3. $\mathbf{P}_j \mathbf{x}^{(i)}$ değerlerini sütun olarak dizerek \mathbf{X} oluştur.
 $L^{-1} = (\mathbf{X}\mathbf{X}^H + 0.5\lambda\mathbf{I})^{-1/2}$.
4. **for** $l = 1:M$
5. Sözlük Güncellemesi:
- 5.a. $\mathbf{W} = \mathbf{V}\mathbf{U}^H, \mathbf{U}\mathbf{S}\mathbf{V}^H = \mathbf{X}\mathbf{B}^H$.
6. Seyrek Kodlama:
- 6.a. Pr. (12) kullanarak \mathbf{B} değişkenini güncelle.
7. **end**
8. **for** $i = 1: \text{Kontrast Sayısı}$, Görüntü güncellemesi:
- 8.a. $c = \sum_{j=1}^N \mathbf{P}_j^T \mathbf{W}^H \mathbf{B}_j^{(i)}, S = FFT(c)$.
- 8.b. $\sum_{j=1}^N \mathbf{P}_j^T \mathbf{W}^H \mathbf{W} \mathbf{P}_j$ ilk sütununu a_1 'e eşitle.
- 8.c. $\gamma = \sqrt{p} \times FFT(a_1)$.
- 8.d. Görüntünün Fourier dönüşümünün (k_x, k_y) indislerini:
$$\begin{cases} \frac{S(k_x, k_y)}{\gamma(k_x, k_y)}, & \text{eğer } (k_x, k_y) \notin \mathbf{M} \\ \frac{S(k_x, k_y) + \nu(\mathbf{A}^{(i)})^H \mathbf{y}^{(i)}}{\gamma(k_x, k_y) + \nu}, & \text{eğer } (k_x, k_y) \in \mathbf{M} \end{cases}$$
- 8.e. **end**
9. **end**

ve görüntü güncellemesi isimlerinde üç adımdan oluşmaktadır [1]. Öncelikle, seyrek kodlama adımı için aşağıdaki gibi bir problem çözülmemektedir:

$$\begin{aligned} & \underset{\mathbf{B}}{\text{minimize}} && \sum_{i=1}^C \sum_{j=1}^N \|\mathbf{W} \mathbf{P}_j \mathbf{x}^{(i)} - \mathbf{B}^{(i)}\|_2^2 \\ & \text{subject to} && \|\mathbf{B}\|_{2,0} \leq s \end{aligned} \quad (11)$$

$\mathbf{Q}^{(i)} = \mathbf{W} \mathbf{P}_j \mathbf{x}^{(i)}$ için, bu problemin çözümü eşiklemeye denk gelmektedir. Öncelikle, bütün kontrastlar için i yönünde $\|\mathbf{Q}^{(i)}[j]\|_2$ değeri hesaplanır. Ardından bu değere göre en küçük s değeri içeren j koordinatlarından T_S kümesi oluşturulur. O zaman sonuç şu şekilde hesaplanabilir:

$$\mathbf{B}^{(i)}[j] = \begin{cases} \mathbf{Q}^{(i)}[j] & j \in T_S \\ 0 & j \notin T_S \end{cases} \quad (12)$$

Sözlük güncellemesi adımı ve görüntü güncellemesi adımları ise bir önceki bölümdeki algoritma ile benzer şekilde hesaplanabilir [1]. Algoritmanın genel hali tablo 1 içerisinde verilmiştir.


4. Sonuçlar

Önerilen yöntem MATLAB üzerinde kodlanmıştır. Deneyler iki adet Intel Xeon E5-2650 v2 işlemciye ve 64 GB RAM'e sahip bir iş istasyonu üzerinde yapılmıştır. Bütün deneyler için ilk değerler en küçük kareler çözümü olan görüntülerden ($A^H \mathbf{y}$) başlatılmıştır. Algoritmalar yakınsayana kadar çalıştırılmıştır. Yakınsama, iterasyonlar arasındaki kestirilen görüntüler üzerindeki farkın belirli bir limitin altına düşmesi şeklinde tanımlanmıştır.

Önerilen ortak sözlük öğrenimi tabanlı geri-kazanım yöntemi, ayrık sözlük öğrenimi tabanlı geri-kazanım yöntemi ve yön değiştiren çarpanlar yöntemi (YDÇY) tabanlı genel geçer dönüşüm uzayı kullanan ortak yöntem ile kıyaslanmıştır [1, 2]. Öncelikle, yöntemler için en uygun katsayılar

belirlenmiştir. Bu değerler, monte-carlo benzetimi sonucu her algoritma için ayrı ayrı en yüksek ortalama $pSNR$ değerini elde edecek şekilde belirlenmiştir.


İlk olarak, Aubert-Broche veri kümesi üzerinde kıyas yapılmıştır [10]. Aubert-Broche farklı kontrast görüntülerin üretilebildiği 11 farklı doku içeren bir nümerik fantomdur. Bu çalışmada Proton Yoğunluklu (PY), T_1 -ağırlıklı ve T_2 -ağırlıklı kontrast görüntüleri üretilip karmaşık-değerli görüntüler elde etmek için üzerine bir faz bindirilmiştir. Daha sonra, %25 alt-örnekleme kullanılmış ve üç farklı yöntem ile geri-kazanım sağlanmıştır. Şekil 1'de üç farklı algoritma için görüntü oluşturma zamanı ile ortalama $pSNR$ değişimi sonucu görülmektedir. Buna göre, YDÇY tabanlı yöntem çok kısa süre içerisinde $pSNR$ olarak 35 dB seviyesine çıkmış olsa da, sözlük öğrenimi tabanlı yöntemler daha iyi sonuç üretmiştir. Benzer bir şekilde, ayrık sözlük öğrenimi tabanlı yöntem, ortak sözlük öğrenimi tabanlı yöntemden $pSNR$ açısından başlangıçta daha iyi bir değere ulaşsa da performansı sınırlı kalmıştır. Hesaplama zamanı kısıtı olmadığı durumlarda önerilen sözlük öğrenimi tabanlı algoritma iyi sonuçlar üretse de, geri-kazanım zamanının daha limitli olduğu durumlarda diğer algoritmaların kullanımı daha uygun olabilir.



Şekil 1: Aubert-Broche beyin fantomu için zamana bağlı ortalama $pSNR$ değişimi grafiği (%25 veri)


Daha sonra, bir önceki deney için görüntü sonuçları incelenmiştir. Sonuçlar Şekil 2 (a–d) üzerinde verilmiştir. Soldan sağa doğru, PY , T_1 -a, T_2 -a kontrast görüntü geri-kazanım sonuçlarını ve en sağda ise toplam geri-kazanım hatasının 16 katı gösterilmiştir. Şekil 2 (b)'de görüntüler üzerinde genel bir gürültü bulunmaktadır. Şekil 2 (c)'de ise, toplam hata düşük görünse de, görüntüler üzerinde doku geçişlerinin bulunduğu bölgelerde geçişler çok yumuşak görülmektedir. Bu, geri-kazanım görüntülerinin yüksek frekans bölgelerinde çok başarılı olmadığını göstermektedir. Ancak önerilen yöntem, farklı kontrastlar arasındaki ortak bilgiden de faydalanarak bu sorundan kaçınmıştır.

Son olarak, veri miktarı artırılmıştır ve yakınsama sonuçları incelenmiştir. Şekil 3'te %50'lik bir alt-örnekleme yapıldığı durumda görüntüler arasında ortalaması alınan $pSNR$ açısından yakınsama sonuçları gösterilmiştir. Veri miktarının yüksek olduğu durumda sözlük öğrenimi tabanlı yöntemler ile YDÇY



Şekil 2: (a) Referans Görüntü, (b) Önden Tasarlanmış Dönüşüm Uzayı - YDCY tabanlı yöntem ile geri-kazanılmış görüntüler ve hata miktarı, (c) Ayrık sözlük öğrenimi tabanlı yöntem ile geri-kazanılmış görüntüler ve hata miktarı, (d) Önerilen Ortak sözlük öğrenimi tabanlı yöntem ile geri-kazanılmış görüntüler ve hata miktarı. Soldan sağa, PY , T_1 -a, T_2 -a ve her bir kontrast için hataların toplamının 16 katı görüntüsü. (%25 veri)

arasındaki toplam fark azalmıştır. Ancak yine ortak sözlük öğrenimi tabanlı yöntem, diğer yöntemlerden daha iyi sonuç vermiştir. Bu durumda, YDCY yaklaşık 100 saniyede 40.57 dB değerine ulaşmışken, ayrık sözlük öğrenimi yöntemi 500 saniyede 41.21 dB değerine ulaşmış, önerilen yöntem ise 625 saniyede 43.15 dB değerine ulaşmıştır. Veri miktarı artırıldığında YDCY tabanlı yöntemin kestirim süresinde çok değişiklik olmasa da, sözlük öğrenimi tabanlı yöntemler daha kısa sürede yakınsamıştır.



Şekil 3: Aubert-Broche beyin fantomu için zamana bağlı ortalama $pSNR$ değişimi grafiği (%50 veri)

5. Tartışma

Bu çalışma, sıkıştırılmış MRG için ortak sözlük öğrenimi kullanarak çoklu-kontrast görüntülerin bir arada geri-kazanımını yapabilen bir algoritma sunmaktadır. Algoritma hem çoklu kontrast görüntülerini, hem de bu görüntüler için ortak bir seyreklik sözlüğünü bir arada geri-kazanmaktadır. Önerilen yöntem hem benzer bir ayrık sözlük öğrenimi yöntemiyle, hem de önceden tasarlanmış ortak sözlük içeren bir sıkıştırılmış algılama yöntemiyle kıyaslanmıştır. Sözlük öğrenimi tabanlı yöntemler uzun zaman almaktadır. Ancak, hesaplama zamanından feragat edildiği durumda, önerilen yöntem hem $pSNR$ hem de görüntü kalitesi açısından daha iyi sonuçlar elde etmiştir.

6. Kaynaklar

- [1] S. Ravishanker, B. Wen, and Y. Bresler, "Online sparsifying transform learning, part i: Algorithms," *IEEE Journal of Selected Topics in Signal Processing*, vol. 9, pp. 625–636, June 2015.
- [2] A. Güngör, E. Kopanoğlu, T. Çukur, and H. E. Güven, "Compressed multi-contrast magnetic resonance image reconstruction using augmented lagrangian method," in *2016 24th Signal Processing and Communication Application Conference (SIU)*, pp. 1985–1988, May 2016.
- [3] M. Lustig, D. L. Donoho, J. M. Santos, and J. M. Pauly, "Compressed sensing mri," *IEEE Signal Processing Magazine*, vol. 25, pp. 72–82, March 2008.
- [4] J. Huang, S. Zhang, and D. Metaxas, "Efficient mr image reconstruction for compressed mr imaging," *Medical Image Analysis*, vol. 15, no. 5, pp. 670 – 679, 2011. Special Issue on the 2010 Conference on Medical Image Computing and Computer-Assisted Intervention.
- [5] J. Huang, C. Chen, and L. Axel, "Fast multi-contrast mri reconstruction," *Magnetic Resonance Imaging*, vol. 32, no. 10, pp. 1344–1352, 2014.
- [6] T. Cukur, M. Lustig, E. U. Saritas, and D. G. Nishimura, "Signal compensation and compressed sensing for magnetization-prepared mr angiography," *IEEE Trans Med Imaging*, vol. 30, pp. 1017 – 1027, 2011.
- [7] T. Cukur, "Accelerated phase-cycled ssfp imaging with compressed sensing," *IEEE Transactions on Medical Imaging*, vol. 34, pp. 107–115, 2015.
- [8] H. E. Güven, A. Güngör, and M. Cetin, "An augmented lagrangian method for complex-valued compressed sar imaging," *IEEE Transactions on Computational Imaging*, vol. 2, no. 3, pp. 235–250, 2016.
- [9] E. Ilicak, L. K. Senel, E. Biyik, and T. Cukur, "Profile-encoding reconstruction for multiple-acquisition balanced steady-state free precession imaging," *Magnetic Resonance in Medicine*, 2016.
- [10] B. Aubert-Broche, A. C. Evans, and L. Collins, "A new improved version of the realistic digital brain phantom," *NeuroImage*, vol. 32, no. 1, pp. 138 – 145, 2006.