



**T.C.
BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
BİLİMSEL ARAŞTIRMA PROJESİ
SONUÇ RAPORU**

**BEYİN MR GÖRÜNTÜLERİNİN İYİLEŞTİRİLMESİ İÇİN
GPU TABANLI KUADRATİK GÖRÜNTÜ FİLTRE
TASARIMI**

PROJE YÜRÜTÜCÜSÜ : Dr. Öğr. Üyesi Süleyman UZUN
PROJE NUMARASI : 2019-01.BŞEÜ.03-06
ARAŞTIRMACILAR : Dr. Öğr. Üyesi Emre DANDIL
Öğr. Gör. Ali Osman SELVİ

BAŞLAMA TARİHİ :12.06.2019
BİTİŞ TARİHİ :12.06.2020

Sonuç Rapor Dönemi :11.12.2019 - 12.06.2020

**BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ
BİLECİK 2020**

İÇİNDEKİLER

1. GİRİŞ	6
2. PROJENİN I. ARA DÖNEMİ VE GERÇEKLEŞTİRİLEN ÇALIŞMALAR	8
2.1. Ara Rapor Dönemi Çalışma Planı	8
2.2. Literatür taraması	8
2.3. Ara Rapor Döneminde Temin Edilen Malzemeler	9
3. PROJENİN II. ARA DÖNEMİ VE GERÇEKLEŞTİRİLEN ÇALIŞMALAR.....	11
3.1. İkinci Rapor Dönemi Çalışma Planı	11
3.2. Çalışmalarda Kullanılan Veri Seti	12
3.3. Çalışmalarda Kullanılan Donanımlar ve Özellikleri.....	13
3.4. Beyin MR Görüntülerinin İyileştirilmesi İçin GPU Tabanlı Kuadratik Görüntü Filtre Tasarımı ve Deneysel Sonuçları.....	14
3.4.1. Kuadratik Görüntü Filtreleri.....	15
3.4.2. GPU Tabanlı Popülasyon Temelli Yöntem (GPU Population Based Method – GPBM) 16	
3.4.3. Deneysel Çalışma	17
3.5. Derin Öğrenme Tabanlı MR Görüntüleri Üzerinden Tümör Tespiti	24
3.5.1. Beyin MR görüntüleri üzerindeki Tümörlü Bölümlerin İşaretlenmesi	26
3.5.2. Derin öğrenme algoritması ile sistemin eğitilmesi.....	27
3.5.3. Deneysel Çalışma	29
4. SONUÇLAR	36
5. PROJE KAPSAMINDA YÜRÜTÜLEN BİLİMSEL ETKİNLİKLER	37
6. TEŞEKKÜR.....	38
KAYNAKLAR	39

ŞEKİLLER DİZİNİ

Şekil 1. Proje kapsamında temin edilen Geforce RTX Ekran kartı	10
Şekil 2. Hızlandırma çalışmasında kullanılan 392×512 boyutlarındaki referans görüntüler	13
Şekil 3. Hızlandırma çalışmasında kullanılan 728×896 boyutlarındaki referans görüntüler	13
Şekil 4. GPBM yönteminin çalışma şeması.....	17
Şekil 5. Hızlandırma çalışmasında kullanılan gürültülü referans görüntüleri (0.21 katsayılı Gauss gürültüsü)	22
Şekil 6. 392×512 boyutlarındaki görüntülerin Kuadratik filtreler ile filtrelenmesi sonucu elde edilen filtrelenmiş görüntüler	23
Şekil 7. 728×896 boyutlarındaki görüntülerin Kuadratik filtreler ile filtrelenmesi sonucu elde edilen filtrelenmiş görüntüler	23
Şekil 8. Kullanılan CNN'nin mimarisi.....	25
Şekil 9. Beyin MR görüntüsü üzerindeki tümörlü bölgenin işaretlenmesi	27
Şekil 10. CNN ağının eğitilmesi için kullanılan parametreler	28
Şekil 11. Tümörlü bölgenin CNN eğitim aşamasından sonra bulunması	28
Şekil 12. Kuadratik görüntü filtresinin filtreleme yöntemi blok şeması	29
Şekil 13. MAE ve MSE görüntü kalitesinin hesaplama yöntemi blok şeması.....	30
Şekil 14. Deneysel çalışmada kullanılan test ve eğitim aşamasında kullanılan örnek görüntüler	31
Şekil 15. Tümörlü bölgenin %100 olarak tespit edildiği örnek görüntüler.....	33
Şekil 16. Sadece ön işlemler tarafından tümörlü bölgenin bulunduğu örnek görüntüler	34
Şekil 17. Tümörlü bölgenin yanlış tespit edildiği örnek görüntüler	34
Şekil 18. Tümörlü bölgenin hiç tespit edilemeyen örnek görüntüler.....	35

ÇİZELGELER DİZİNİ

Tablo 1. Proje çalışma planı (ilk 6 aylık dönem).....	8
Tablo 2. Proje çalışma planı (İkinci 6 aylık dönem).....	12
Tablo 3. Deneysel çalışmalarda kullanılan bilgisayar konfigürasyonu	14
Tablo 4. Deneysel çalışmalarda kullanılan PU kartlar ve özellikleri.....	14
Tablo 5. 392×512 ve 728×896 boyutlarındaki birer görüntünün CPU üzerinde Kuadratik Görüntü filtreleri ile filtreleme sonuçları	18
Tablo 6. 392×512 boyutlarındaki b1 referans görüntüsünün GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçlarının zaman karşılaştırılması	19
Tablo 7. 728×896 boyutlarındaki b1 referans görüntüsünün GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçlarının zaman karşılaştırılması	20
Tablo 8. 392×512 boyutlarındaki görüntülerin GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile elde edilen ortalama sonuçlarının zaman karşılaştırılması	21
Tablo 9. 728×896 boyutlarındaki görüntülerin GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile elde edilen ortalama sonuçlarının zaman karşılaştırılması	22
Tablo 10. Derin öğrenmenin eğitimi aşamasında elde edilen başarımlar örnekleri.....	32
Tablo 11. Tümörlü bölgeyi tespit etme başarımları	32
Tablo 12. 392×512 boyutlarındaki b1 referans görüntüsünün GTX 980 ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları	42
Tablo 13. 728×896 boyutlarındaki b1 referans görüntüsünün GTX 980 ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları	43
Tablo 14. 392×512 boyutlarındaki b1 referans görüntüsünün RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları	44
Tablo 15. 728×896 boyutlarındaki b1 referans görüntüsünün RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları	45
Tablo 16. 392×512 boyutlarındaki görüntülerin GTX 980 ekran kartında GPBM yöntemi ile filtreleme sonuçları	46
Tablo 17. 728×896 boyutlarındaki görüntülerin GTX 980 ekran kartında GPBM yöntemi ile filtreleme sonuçları	46

Tablo 18. 392×512 boyutlarındaki görüntülerin RTX 2080Ti ekran kartında GPBM yöntemi ile filtreleme sonuçları	47
Tablo 19. 728×896 boyutlarındaki görüntülerin RTX 2080Ti ekran kartında GPBM yöntemi ile filtreleme sonuçları	47

1. GİRİŞ

Manyetik Rezonans Görüntüleme (MRG) insan vücudundaki doku ve organlar için detaylı görüntüler sağlayabilmektedir. MRG taramalarının görsel kalitesi kazanım esnasında, oluşan gürültü nedeniyle büyük ölçüde azalabilmektedir [1]. Bu nedenle, MR görüntülerinde oluşan giderilmesi ve azaltılması beyin gibi önemli organlardaki tümör gibi kitlelerin sınırlarının tam olarak belirlenmesi için önemli bir ön-işleme prosedürü olarak karşımıza çıkmaktadır.

MR görüntüleri üzerindeki gürültüleri gidermek için literatürde özellikle, filtreleme, dönüşüm tabanlı metotlar ve istatistiksel yöntemler bulunmaktadır [2]. MR görüntülerindeki gürültüleri gidermek için kullanılan filtreleme yöntemleri doğrusal ve doğrusal olmayan filtreleme yöntemleri olarak ikiye ayrılmaktadır. Doğrusal olmayan filtrelerde ise yaygın olarak kullanılan ve gürültüleri azaltmada oldukça başarılı olan filtrelerden birisi de Kuadratik filtrelerdir.

Kuadratik görüntü filtreleri, doğrusal olmayan filtreler sınıfına ait Volterra filtrelerinin bir alt sınıfıdır ve doğrusal olmayan karakteristiklere sahip görüntülerin işlenmesinde doğrusal filtrelere göre daha iyi sonuç üretirler. Doğrusal olmayan karakteristiklere sahip gürültülerin temizlenmesinde doğrusal filtrelere göre daha iyi sonuç üretirler. Genetik algoritmalar (GA), girişte uygulanan gürültü eklenmiş referans görüntüsünü filtreleyerek çıkışta elde edilen filtrelenmiş referans görüntüsünü, referans görüntüsü ile karşılaştırarak bir uygunluk değeri bulunur. Bu uygunluk değerine göre filtre ağırlıkları güncellenir ve sonuçta en iyi filtre ağırlıkları hesaplanabilir. Görüntü işleme uygulamalarında eğitim sürelerinin uzun olması uygunluk fonksiyonunun hesaplanma maliyetlerini de arttırmaktadır.

Bu çalışmada, beyin MR görüntülerin iyileştirilmesi için Grafik İşlem Birimi (Graphics Processing Unit - GPU) tabanlı Kuadratik görüntü filtre tasarlanmıştır. Çalışmada kullanılan Kuadratik görüntü filtrelerin maske ağırlıkları farklı eğitim görüntüleri üzerinde Genetik Algoritmalar ile eğitilerek belirlenmiştir. Eğitim sürelerini karşılaştırmak amacıyla eğitimler Merkezi İşlem Birimi (Central Process Unit – CPU), Nvidia® GTX980 ve Nvidia® RTX2080Ti GPU kartlarında yapılmıştır. GPU kartlar üzerinde yapılan eğitimlerde GPU tabanlı popülasyon temelli yöntem kullanılmıştır. Eğitim zamanları her iki yöntem için ayrı ayrı ölçülmüş ve her bir eğitim 30 kez tekrarlanmıştır. Bu 30 kez çalışma sonucunda elde edilen Ortalama Mutlak Hata (Mean Absolute Error – MAE), Ortalama Karesel Hata (Mean Squared Error – MSE) ve hesaplama zaman ölçülerinin ortalaması alınarak karşılaştırılmıştır. Hesaplanan ağırlıklar kullanılarak beyin MR görüntüleri filtrelenerek iyileştirilen görüntüler elde edilmiştir. Kuadratik filtreler ile filtrelenmiş beyin MR görüntülerdeki tümörlü bölgelerin tespiti ve bu bölgelerinin kenarlarının daha iyi korunduğu görülmüştür. Tümörlü bölgenin daha iyi tespit edildiğini göstermek amacıyla derin öğrenme algoritmalarından Bölgesel

Evrişimsel Sinir Ağlarının (Regional Convolutional Neural Network - R-CNN) kullanıldığı farklı bir çalışma daha yapılmıştır. Bu çalışmada R-CNN ağına;

- Beyin MR görüntüleri üzerinde hiçbir işlem yapılmadan,
- Beyin MR görüntüleri medyan filtreden geçirildikten sonra,
- Beyin MR görüntüleri Kuadratik görüntü filtrelerinden geçirildikten sonra,

Şeklinde sunulmuştur. Sonuçta R-CNN'in tümörlü bölgeyi tespit etme oranları çıkartılarak karşılaştırılmıştır. Ön işlemsiz şekilde kullanılan görüntülerde tümörlü bölgeyi tespit etme oranı %89, medyan filtreden geçirildikten sonra tümörlü bölgeyi tespit etme oranı %90 ve Kuadratik filtreden geçirildikten sonra tümörlü bölgeyi tespit etme oranı %92 olarak ölçülmüştür.

2. PROJENİN I. ARA DÖNEMİ VE GERÇEKLEŞTİRİLEN ÇALIŞMALAR

Proje ara rapor dönemine kadar olan süreçte literatür tarama süreci yürütülmüş, malzeme temini gerçekleştirilmiş ve temin edilen malzemeler ile çalışmalarda kullanılmak üzere görüntü verileri elde edilmiştir.

2.1. Ara Rapor Dönemi Çalışma Planı

Çalışma planına göre ilk 6 aylık süreçte yapılması planlanan iş paketleri Tablo 1'de verilmiştir. Bu plana göre bu dönem içinde, literatür taramalarının yapılması, proje kapsamında temin edilen malzemeler ve görüntü verilerin elde edilmesi, elde edilen verilerin incelenmesi ve ön çalışma işlemlerinin yapılması hedeflenmekteydi.

Tablo 1. Proje çalışma planı (ilk 6 aylık dönem)

İş Paketi No	İş Paketi Adı / Tanımı	AYLAR					
		01	02	03	04	05	06
1	Literatür Taraması	✓	✓				
2	Görüntü verilerinin elde edilmesi	✓	✓	✓	✓	✓	✓
3	Elde edilen görüntüler içerisinde çalışmada kullanılacak görüntülerin seçilmesi			✓	✓		
4	Bazı ön çalışma işlemlerinin yapılması ve bu çalışmanın bildiri şekline dönüştürülerek bir konferansta sunulması.			✓	✓	✓	✓

2.2. Literatür taraması

Kuadratik görüntü filtreleri, biyomedikal görüntü işleme alanında özellikle de doğrusal olmayan gürültülerin temizlenmesi esnasında oldukça başarı gösterdiğinden tercih edilmektedir [3]. Kuadratik görüntü filtreleri, gürültü filtreleme işlemlerinde görüntü üzerindeki kenarları ve detaylarını da korumaktadır [4].

Yapılan çalışmalarda Kuadratik görüntü filtrelerinin doğrusal filtrelere göre gürültü temizlemede oldukça başarılı olduğu gösterilmektedir. Bu kapsamda Ramponi [5], referans görüntü üzerine Gaussian ve Gaussian darbe gürültüsü ekleyerek gürültülü

görüntüler elde etmiştir. Gürültülü görüntüleri hem Kuadratik hem de doğrusal filtreleri kullanarak kenar belirleme işlemlerinden geçirmiş ve sonuçta Kuadratik görüntü filtrelerinin daha başarılı olduğunu tespit etmiştir. Ramponi ve Sicuranza [6], Kuadratik görüntü filtrelerini görüntü iyileştirme ve gürültü temizleme işlemlerinde kullanmışlar ve diğer filtrelere göre daha iyi sonuçlar elde etmişlerdir.

Kuadratik görüntü filtrelerin biyomedikal görüntü filtreleme işlemleri ile ilgili olarak Zhou ve arkadaşları yaptıkları çalışmada görüntü detaylarını korurken yüksek bozuk gri skala görüntülerindeki gürültüyü temizlemek amacıyla Kuadratik görüntü filtrelerini kullanmışlardır. Mamogram görüntülerinin görsel kalitesini artırarak yüksek çözünürlüklü ve yüksek kontrastlı görüntüler elde etmişlerdir. Ayrıca mamogram görüntüler üzerindeki gürültülerin temizlendiğini ve karanlık bölgeleri geliştirdiği sonucuna varmışlardır. Johilakshmi ve arkadaşları [7] yaptıkları çalışmada, Gaussian, zehir ve beyaz gürültülerden etkilenen mamogram görüntülerinin kontrast iyileştirilmesi amacıyla Kuadratik görüntü filtrelerini kullanmışlardır. Filtrenin başarımını test etmek amacıyla aynı görüntüleri alçak, medyan, minimum ve maksimum gibi doğrusal olmayan filtreler ile karşılaştırmışlardır. Kuadratik görüntü filtresinin diğerlerine göre çok daha başarılı olduğunu gözlemlemişlerdir. Meenavathi ve Rajesh [3] ise Gaussian ve Gaussian darbe gürültülerin iyileştirilmesi ve onarımı için Kuadratik görüntü filtrelerini kullanmışlar ve karşılaştırma yapmak için alçak geçiren filtre, yüksek geçiren filtre ve medyan filtre kullanmışlardır. Elde ettikleri sonuca göre kuadratik görüntü filtreleri ile çok daha yüksek başarımlar elde etmişlerdir. Mitra [8], kontrast iyileştirme, darbe gürültüsünü yok etme ve görüntü yaklaştırma uygulamalarında Kuadratik görüntü filtrelerini kullanmıştır. Çalışma sonucunda, doğrusal olmayan gürültülerin temizlenmesinde doğrusal filtrelerin başarımlarının düşük olduğuna, görüntü kenarlarını bulanıklaştırdığına ve görüntü detaylarının kaybolduğuna ulaşmıştır. Ayrıca Kuadratik görüntü filtrelerinin çok daha iyi sonuçlar verdiğini gözlemlemiştir.

2.3. Ara Rapor Döneminde Temin Edilen Malzemeler

Projenin ara rapor döneminde öncelikle deneysel çalışmalarda kullanılmak üzere Şekil 1’de de görülebileceği üzere Nvidia® GeForce RTX 2080 Ti 11G GPU ekran kartı satın alınmıştır.



Şekil 1. Proje kapsamında kullanılan GPU Kartlar. a) GTX 980 GPU b) Proje kapsamında temin edilen ve deneylerde kullanılan Geforce RTX 2080Ti Ekran kartı

3. PROJENİN II. ARA DÖNEMİ VE GERÇEKLEŞTİRİLEN ÇALIŞMALAR

Projenin ikinci rapor döneminde, ilk rapor döneminde elde edilen beyin MR görüntülerinden çalışmada kullanılmak üzere tümörlü görüntüler seçilmiştir. Seçilen bu görüntüler CPU, GTX 980 ve RTX2080Ti GPU kartları üzerinde Kuadratik görüntü filtreleri kullanılarak filtrelenmiş ve MAE, MSE değerleri ile hesaplama zamanları ölçülerek karşılaştırılmıştır. Bu çalışma sonucunda elde edilen hesaplama zamanları kabul edilebilir sınırlar içerisinde olduğundan dolayı Kuadratik görüntü filtrelerinin başarımını ölçmek amacıyla derin öğrenme algoritmalarından R-CNN kullanılarak beyin MR görüntüleri üzerindeki tümörlü bölgenin tespit edilme başarımları incelenmiştir.

3.1. İkinci Rapor Dönemi Çalışma Planı

Projenin çalışma planına göre ikinci 6 aylık süreçte yapılan iş paketleri Tablo 2'de verilmiştir. Bu plana göre bu dönem içinde, 392×512 ve 728×896 boyutlarına sahip iki farklı tip görüntü ve her birinden 10'ar tane tümörlü beyin MR görüntüleri seçilmiştir. Seçilen görüntülerin Kuadratik görüntü filtreleri kullanılarak CPU, GTX980 ve RTX2080Ti GPU kartları üzerinde elde edilen görüntülerin MAE, MSE ve hesaplama zamanları ölçülmüştür. CPU üzerinde filtreleme işlemlerinin çok uzun sürmesinden dolayı farklı boyutlardaki görüntülerden birer adet seçilerek sonuçlar elde edilmiştir. Tasarlanan Kuadratik görüntü filtresi kullanılan her bir görüntü 30 kez çalıştırılmış olup ortalaması alınmıştır. Elde edilen hesaplama zamanları karşılaştırılmıştır.


Kuadratik görüntü filtrelerinin birçok doğrusal olmayan görüntü filtrelerine göre daha başarılı sonuçlar verdiği hem literatürde hem de yapılan bu çalışmalarda görülmüştür. Bu görüntü filtresinin farklı sistemlerde ön işlem olarak kullanılması durumunda sonuca olan etkisini göstermek amacıyla farklı bir çalışma daha yapılmıştır. Bu çalışmada beyin MR görüntülerindeki tümörlü bölgenin derin öğrenme yöntemlerinden R-CNN ile tespitindeki başarımı ölçülmüştür. Bu amaçla, R-CNN ağına, hiçbir ön işleme tabi tutulmadan, görüntüler medyan filtreden geçirildikten sonra ve görüntüler Kuadratik filtreden geçirildikten sonra verilmiştir. Sonuçta R-CNN'in tümörlü bölgeyi bulmadaki başarımı ölçülmüş ve bir birleriyle karşılaştırılmıştır.

Tablo 2. Proje çalışma planı (İkinci 6 aylık dönem)


İş Paketi No	İş Paketi Adı / Tanımı	AYLAR					
		07	08	09	10	11	12
5	Görüntülerin seçilmesi	✓					
6	Görüntülerin Kuadratik görüntü filtreleri ile CPU ve GTX980 GPU kartında filtrelenerek MAE, MSE ve hesaplama zamanlarının elde edilmesi.		✓	✓			
7	Görüntülerin Kuadratik görüntü filtreleri ile RTX2080Ti GPU kartlarında filtrelenerek MAE, MSE ve hesaplama zamanlarının elde edilmesi.			✓	✓		
8	Kuadratik görüntü filtresinin, R-CNN'nin tümörlü bölgeyi tespit etmedeki başarımının ölçülmesi.				✓	✓	
9	Yapılan çalışmalarda elde edilen sonuçların analizi ve raporlanması işlemleri.					✓	✓

3.2. Çalışmalarda Kullanılan Veri Seti

Deneysel çalışmalarda kullanılan görüntüler Sincan Nafiz Körez Devlet Hastanesindeki MR tarayıcılarından alınmış olan referans görüntüler kullanılmıştır. Etik kurul raporu EK-1'de sunulmuştur. Bu görüntülerden Şekil 2'de gösterilen 392×512 ve Şekil 3'de 728×896 boyutlarına sahip iki farklı boyuttaki ve her birinden 10'ar tane tümörlü beyin MR görüntüleri hızlandırma çalışmasında kullanılmak amacıyla seçilmiştir.



Şekil 2. Hızlandırma çalışmasında kullanılan 392×512 boyutlarındaki referans görüntüler



Şekil 3. Hızlandırma çalışmasında kullanılan 728×896 boyutlarındaki referans görüntüler

Deneysel çalışma sonucunda elde edilen tüm sonuçlar, her bir referans MR görüntüsü 30 kez çalıştırılmış ve ortalaması alınarak elde edilmiştir.

3.3. Çalışmalarda Kullanılan Donanımlar ve Özellikleri

Deneysel çalışmalarda elde edilen sonuçlar Tablo 3’de gösterilen masaüstü bilgisayar üzerinde çalıştırılarak hesaplanmıştır.

Tablo 3. Deneysel çalışmalarda kullanılan bilgisayar konfigürasyonu

Donanım	Özellik
Merkezi İşlem Birimi (CPU)	İntel® Core™ i7-3770 3.40GHz (8 CPUs)
Bellek (RAM)	16 GB (DDR3 166MHz)
AnaKart	ASUS P8H77-V LE
Grafik Kartı (GPU)	Nvidia GeForce GTX980, 4 GB RAM
Harddisk (HDD)	256 GB SSD HDD

Yapılan hesaplamalar özellikleri Tablo 4’de verilen GPU kartlar üzerinde gerçekleştirilmiştir. Bu GPU kartlar Tablo 3’de özellikleri verilen masaüstü bilgisayar üzerine ayrı ayrı takılarak hesaplamalar yapılmıştır.

Tablo 4. Deneysel çalışmalarda kullanılan PU kartlar ve özellikleri

Donanım	Özellik
Grafik Kartı (GPU)	Nvidia GeForce GTX980
	GPU Mimarisi : Maxwell™
	Bellek : 4 GB RAM
	Bellek Hızı : 7 Gbps
	CUDA Çekirdekleri (Cores) : 2048
Hesaplama Kapasitesi (ComputeCapability) : 5.2	
Grafik Kartı (GPU)	Nvidia GeForce RTX2080Ti
	GPU Mimarisi : Turing™
	Hafıza : 11 GB RAM
	Bellek Hızı : 14 Gbps
	CUDA Çekirdekleri (Cores) : 4352
Hesaplama Kapasitesi (ComputeCapability) : 7.5	

3.4. Beyin MR Görüntülerinin İyileştirilmesi İçin GPU Tabanlı Kuadratik Görüntü Filtre Tasarımı ve Deneysel Sonuçları

Projenin bu aşamasında yapılan çalışmada, yukarıda özellikleri verilen farklı iki boyuttaki 10’ar görüntü kullanılarak Kuadratik görüntü filtreleri ile CPU, GTX980 ve RTX2080Ti GPU kartları üzerinde filtrelenmiştir. Filtreleme sonucunda MAE, MSE ve hesaplama zamanları elde edilmiştir. GPU kartları üzerinde çok farklı yöntemler kullanılarak Kuadratik görüntü filtrelerin filtre ağırlıkları eğitilmektedir.

3.4.1. Kuadratik Görüntü Filtreleri

Kuadratik görüntü filtreleri, ayrık doğrusal olmayan volterra serilerinin bir alt sınıfıdır [3] ve Volterra filtrelerinin ikinci dereceden açılmış hallerine verilen isimdir. Volterra filtrelerinin birinci dereceden açılmış hallerine ise doğrusal filtreleri, üçüncü dereceden açılmış hallerine ise kübik filtreler şeklinde farklı olarak isimlendirilmektedir [3], [9]. Volterra filtrelerinin en genel formu Eş. 1’de gösterilmektedir.

$$y(n) = w_0 + \sum_{p=1}^{\infty} w_p [x(n)] \quad (1)$$

Eş. 1’de verilen y_n çıkışı, w_0 offset değerini (genellikle sıfır olarak kabul edilir), w_p Volterra filtrelerinin p^{th} denklemlerinin açılacağı dereceyi göstermektedir. Kuadratik görüntü filtrelerinin kullanılan en genel matematiksel denklemi Eş. 2’de gösterilmektedir.

$$y(m, n) = y_0 + y_1(m, n) + y_2(m, n) \quad (2)$$

Eş. 2’de verilen y_0 sabit bir değeri (genellikle sıfır kabul edilir), $y(m, n)$ çıkışı, $y_1(m, n)$ Kuadratik görüntü filtrelerinin doğrusal kısmını ve $y_2(m, n)$ ise Kuadratik kısmını göstermektedir [10]–[12]. Eş. 3’de genel formda verilen $y_1(m, n)$ ve $y_2(m, n)$ ’nin açık hallerini göstermektedir [13], [14].

$$\left. \begin{aligned} y_1(m, n) &= \sum_{i=-(N-1)/2}^{(N-1)/2} \sum_{j=-(N-1)/2}^{(N-1)/2} w_{i,j}^1 x_{m+i,n+j} \\ y_2(m, n) &= \sum_{i=-(N-1)/2}^{(N-1)/2} \sum_{j=-(N-1)/2}^{(N-1)/2} \sum_{k=-(N-1)/2}^{(N-1)/2} \sum_{l=-(N-1)/2}^{(N-1)/2} w_{i,j,k,l}^2 x_{m+i,n+j} x_{m+k,n+l} \end{aligned} \right\} \quad (3)$$

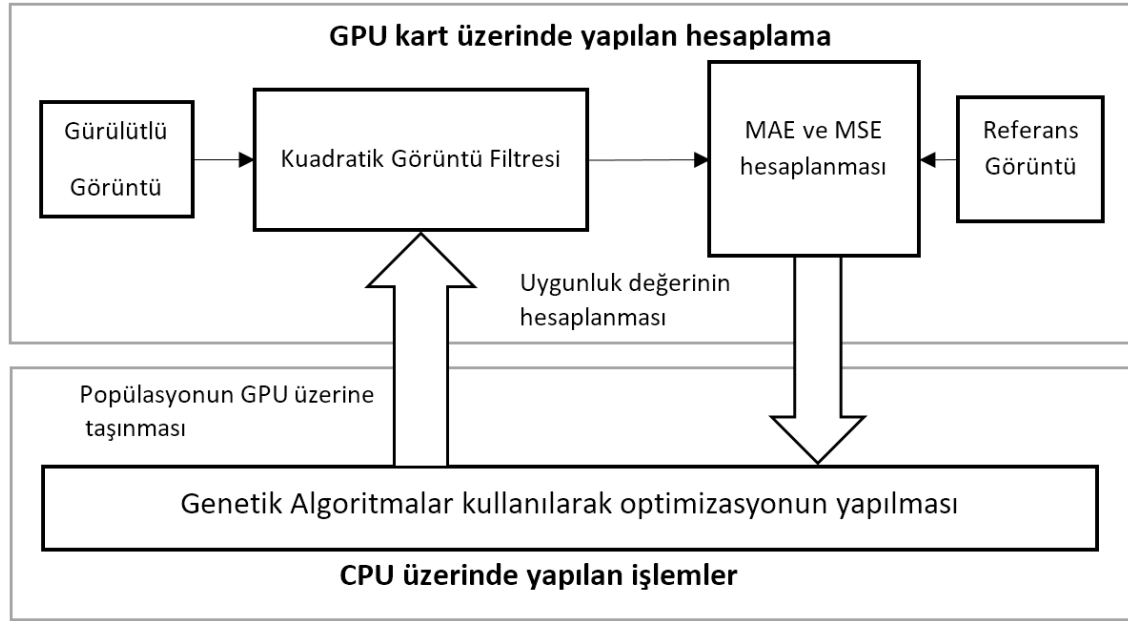
Eş. 3’de verilen m ve n filtrenecek olan piksellerin koordinatlarını, N filtre maskesi boyutunu, i ve j filtre maskesinde seçilen piksellerin konumunu, k ve l Kuadratik çarpımları elde etmek için filtre maskesinde seçilen piksellerin konumunu belirtmektedir. Yapılan çalışmada 3×3 boyutlarında filtre maskesi kullanılmıştır. Yapılan çalışmada, seçilen 10 adet beyin MR görüntüleri tek tek Kuadratik görüntü filtrelerinden geçirilerek filtrelenmiştir. Filtreleme işlemlerinde her bir görüntü için Kuadratik filtre ağırlıkları

görüntünün karakteristik özelliklerine göre GA ile eğitilerek yeniden hesaplanarak filtrelenmiştir. Kuadratik filtrelerin ağırlıklarının eğitilerek hesaplanması sayesinde karakteristikleri farklı olan görüntüler daha iyi bir şekilde filtrelenmiştir. Kuadratik filtrelerin filtre ağırlıklarının hesaplanma işlemleri çok uzun sürdüğünden tüm bu işlemler GPU üzerinde gerçekleştirilmiştir.

3.4.2. GPU Tabanlı Popülasyon Temelli Yöntem (GPU Population Based Method – GPBM)

GPBM yönteminde, GA tarafından oluşturulan popülasyon toplu halde GPU içerisinde genel hafızaya alındığı bir yöntemdir. Popülasyonun toplu halde GPU içerisine alınması işlemi, CPU ile GPU arasında sık yapılan işlemleri ortadan kaldırdığı için hesaplama zamanını oldukça düşürmüştür. Şekil 4’de GPBM yöntemin çalışma şeması görülmektedir. Bu yöntemde popülasyonun tamamı bir kerede GPU içerisine alınmakta ve uygunluk değeri paralel bir şekilde işlenerek hesaplanmaktadır. Bu şekilde bir uygulamayla uygunluk değerinin hesaplanması sırasında sürekli olarak CPU’dan GPU’ya ve GPU’dan CPU’ya doğru yapılan kopyalama işlemleri azaltılarak deneysel sonuçlarla da ifade edildiği gibi, ciddi zaman kazançları elde edilmiştir.

Bu yaklaşım, Her bir blok içerisinde blok uygunluk değeri hesaplanmaktadır ve bu hesaplanan değerler sonrasında GPU’ya ait olan *atomicAdd()* fonksiyonu ile toplanarak GA’ya gönderilmektedir. GA bu uygunluk değerlerine göre yeni popülasyonlar oluşturmakta ve bu popülasyonlar tekrar toplu halde GPU içerisine alınarak bu iş ve işlemler maksimum tekrarlama sayısına ulaşıncaya kadar devam etmektedir. Yine bu hesaplama sonucunda görüntü kalitesini etkileyen herhangi bir iş veya işlem yapılmadığından elde edilen görüntü kalitesi diğer yöntemlerde elde edilenler ile aynı seviyede elde edilir.



Şekil 4. GPBM yönteminin çalışma şeması

3.4.3. Deneysel Çalışma-1

Proje kapsamında yapılan ilk çalışmada, beyin MR görüntülerinin iyileştirilmesi için GPU tabanlı Kuadratik görüntü filtre tasarımı yapılmıştır. Yapılan bu tasarım ile beyin MR görüntüleri filtrelenerek MAE, MSE ve hesaplama zamanları elde edilmiştir. Hesaplama zamanlarını karşılaştırma yapmak amacıyla farklı boyutlara sahip toplam 20 adet görüntü kullanılmıştır. Çalışmada kullanılan her bir görüntü tasarlanan sistemde 30'ar kez çalıştırılmış ve elde edilen sonuçların ortalaması alınmıştır. Çalışmalarda kullanılan 392×512 boyutlarındaki görüntüler Şekil 2'de ve 728×896 boyutlarındaki görüntüler ise Şekil 3'de gösterilmektedir. Kuadratik görüntü filtrelerinin filtre ağırlıklarının eğitilmesi için GA kullanılmıştır. GA'nın parametreleri; mutasyon oranı 0.1, çaprazlama oranı 0.5, Kuadratik görüntü filtresinin doğrusal kısmının alt ve üst sınırları 1.0 ile -1.0 arasında, Kuadratik görüntü filtresinin kuadratik kısmının alt ve üst sınırları 0.5 ile -0.5, popülasyon sayısı sabit olarak 1000 ve iterasyon sayısı 300 olarak belirlenmiş olup durdurma kriteri olarak maksimum iterasyon sayısı olarak belirlenmiştir. Yapılan işlemler CPU üzerinde çok uzun sürdüğünden dolayı farklı boyutlardaki görüntülerden her birinde birer görüntü için tasarlanan algoritma çalıştırılmıştır. Bunun dışında bütün görüntüler özellikleri Tablo 4'de verilen GTX980 ve RTX2080Ti GPU kartları üzerinde filtrelenmiştir.

Tablo 5’de CPU üzerinde çalıştırılan görüntülere ait MAE, MSE ve hesaplama süreleri görülmektedir.

Tablo 5. 392×512 ve 728×896 boyutlarındaki birer görüntünün CPU üzerinde Kuadratik Görüntü filtreleri ile filtreleme sonuçları

CPU					
GPBM (GPU Popülasyon Temelli Yöntem) Yöntemi					
Referans Görüntü	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
392x512_b1	23.250687	748.022949	7.842018	103.491310	11312.480736
728x896_b1	21.052839	708.676208	9.162480	124.571678	36812.528912
Farklar	-2.197848	-39.346741	1.320462	21.080368	25500.048176

Tablodan da anlaşılacağı gibi MAE ve MSE değerleri önemli derecede azaltılmıştır. Fakat hesaplama zamanlarına bakılacak olursa sürelerin oldukça fazla olduğu görülmektedir. Bu süreler normal görüntü işleme uygulamalarında kabul edilebilecek süreler olmadığı görülmektedir.

Kuadratik görüntü filtrelerinin filtre ağırlıklarını GA ile eğitilerek belirlenmektedir. Eğitim için referans görüntü, gürültülü görüntü ve filtrelenmiş görüntülere ihtiyaç vardır. Bu deneysel çalışmada sadece eğitim zamanları karşılaştırılmak istendiği için çalışmada kullanılan referans görüntüleri üzerine gürültü eklenmiştir. Her bir görüntü 30 kez filtrelenmiş ve elde edilen sonuçların ortalaması çalışmaya eklenerek yorumlanmıştır.

Tablo 10’da 392×512 boyutlarındaki görüntülerden “b1” görüntüsünün GTX 980 ve RTX 2080Ti GPU kartları üzerindeki 30 çalışmasından elde edilen sonuçlar görülmektedir. Aynı zamanda GPU kartın özellikleri değiştiğinde eğitim sürelerinin ne kadar düşürüldüğü de görülmektedir. RTX2080Ti GPU kartı içerisinde GTX 980 GPU kartına göre çok daha fazla çekirdek olmasından dolayı eğitimi ortalama 82.74 saniye daha hızlı bitirmektedir. Çalışma farklı GPU kartlar üzerinde çalıştırılmış olsa da görüntü kalitesi metriklerini bakıldığında bir birine çok yakın olduğu görülmektedir. Bu da görüntü kalitelerinden ödün vermeden tasarlanan algoritmanın hızlandırıldığı görülmektedir. Ayrıca referans görüntüsüne gürültü eklenerek elde edilen gürültülü görüntünün MAE değeri 23.212959 iken filtreleme sonucunda bu değer ortalama 7.811954 olmaktadır. Bu

da gürültülerin büyük bir çoğunluğunun temizlendiği anlamına gelmektedir. Tablo 6 ve Tablo 7’de verilenlerin detaylı sonuçları EK-1’de sunulmuştur.

Tablo 6. 392×512 boyutlarındaki *b1* referans görüntüsünün GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçlarının zaman karşılaştırılması

Çalışma Sayısı	392×512 Görüntüler GTX 980 GPBM (GPU Popülasyon Temelli Yöntem) Yöntemi			392×512 Görüntüler RTX 2080Ti GPBM (GPU Popülasyon Temelli Yöntem) Yöntemi			Zaman Farkı
	MAE - MSE Değerleri		Hesaplama Zamanı	MAE - MSE Değerleri		Hesaplama Zamanı	
	MAE	MSE	Zaman (sn.)	MAE	MSE	Zaman (sn.)	
	Çalışma-1	7.810427	102.677361	102.733740	7.814318	103.044609	
Çalışma-2	7.809437	102.622063	103.741138	7.810206	102.853210	19.947451	83.793687
Çalışma-3	7.813911	102.853600	102.818672	7.811052	102.988953	20.014701	82.803971
Çalışma-4	7.809982	102.649864	103.447332	7.812425	103.003517	20.098905	83.348427
Çalışma-5	7.814003	102.897865	103.790722	7.816261	103.061363	20.080552	83.710170
Çalışma-6	7.811998	102.757286	103.054380	7.813858	103.161797	20.083423	82.970957
Çalışma-7	7.810503	102.674957	102.596890	7.811895	102.971344	20.189936	82.406954
Çalışma-8	7.808592	102.601173	103.395990	7.815181	103.033379	19.961081	83.434909
Çalışma-9	7.811726	102.703331	103.943906	7.810703	102.961555	20.100701	83.843205
Çalışma-10	7.813678	102.805611	103.136694	7.812907	103.072762	21.142184	81.994510
Çalışma-11	7.816936	102.918922	102.947899	7.812027	103.027367	20.019339	82.928560
Çalışma-12	7.814741	102.880615	103.221099	7.817328	103.166016	20.024681	83.196418
Çalışma-13	7.810285	102.623901	102.496156	7.811687	102.969994	19.727894	82.768262
Çalışma-14	7.812250	102.810005	102.543638	7.815279	103.152367	20.070579	82.473059
Çalışma-15	7.811669	102.767059	102.962304	7.811728	102.896851	20.518028	82.444276
Çalışma-16	7.811085	102.689934	103.133366	7.813363	102.995918	20.649082	82.484284
Çalışma-17	7.811152	102.612633	103.104184	7.811454	102.874580	20.651949	82.452235
Çalışma-18	7.810276	102.610909	103.285931	7.812487	102.992798	20.333403	82.952528
Çalışma-19	7.811121	102.673973	102.806098	7.811706	102.899315	20.406306	82.399792
Çalışma-20	7.812081	102.750999	102.447203	7.810558	102.995483	20.604949	81.842254
Çalışma-21	7.811417	102.703529	103.020142	7.810492	102.930901	20.652195	82.367947
Çalışma-22	7.810696	102.647774	102.444997	7.816059	103.131752	20.540929	81.904068
Çalışma-23	7.812499	102.784180	103.744654	7.810791	102.968475	20.644094	83.100560
Çalışma-24	7.809529	102.560394	102.606223	7.812168	103.045937	20.053134	82.553089
Çalışma-25	7.813540	102.869865	103.421713	7.812852	103.030418	20.713666	82.708047
Çalışma-26	7.814262	102.932220	103.424110	7.810152	102.961700	20.608881	82.815229
Çalışma-27	7.810596	102.681580	103.600523	7.812780	102.993462	20.686592	82.913931
Çalışma-28	7.813358	102.777550	103.022479	7.811948	102.952515	20.578619	82.443860
Çalışma-29	7.813092	102.720940	102.958007	7.811723	103.001930	20.620246	82.337761
Çalışma-30	7.813765	102.849892	102.889405	7.811584	102.838875	20.644565	82.244840
Ortalama	7.811954	102.737000	103.091320	7.812566	102.999305	20.350211	82.741109
Minimum	7.808592	102.560394	102.444997	7.810152	102.838875	19.727894	82.717103
Maksimum	7.816936	102.932220	103.943906	7.817328	103.166016	21.142184	82.801722

Tablo 7’de ise 728×896 boyutlarındaki görüntülerden “*b1*” görüntüsünün GTX 980 ve RTX 2080Ti GPU kartları üzerindeki 30 çalışmasından elde edilen sonuçlar görülmektedir. RTX2080Ti GPU kartı içerisinde GTX 980 GPU kartına göre çok daha

fazla çekirdek olmasından dolayı eğitimi ortalama 268.42 saniye daha hızlı bitirmektedir. Çalışma farklı GPU kartlar üzerinde çalıştırılmış olsa da görüntü kalitesi metriklerini bakıldığında bir birine çok yakın olduğu görülmektedir. Referans görüntüsüne gürültü eklenerek elde edilen gürültülü görüntünün MAE değeri 21.032328 iken filtreleme sonucunda bu değer ortalama 9.152829 olmaktadır. Bu da gürültülerin büyük bir çoğunluğunun temizlendiği anlamına gelmektedir.

Tablo 7. 728×896 boyutlarındaki b1 referans görüntüsünün GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçlarının zaman karşılaştırılması

Çalışma Sayısı	728×896 Görüntüler GTX 980 GPBM (GPU Populasyon Temelli Yöntem) Yöntemi			728×896 Görüntüler RTX 2080Ti GPBM (GPU Populasyon Temelli Yöntem) Yöntemi			Zaman Farkı
	MAE - MSE Değerleri		Hesaplama Zmanı	MAE - MSE Değerleri		Hesaplama Zmanı	
	MAE	MSE	Zaman (sn.)	MAE	MSE	Zaman (sn.)	
	Çalışma-1	9.165334	124.425941	318.623034	9.153228	124.477692	
Çalışma-2	9.164543	124.465965	320.942377	9.151053	124.386467	51.207771	269.734606
Çalışma-3	9.168588	124.505257	320.808262	9.157578	124.577415	51.332410	269.475852
Çalışma-4	9.168544	124.573860	323.500453	9.151359	124.389893	51.460054	272.040399
Çalışma-5	9.166879	124.534630	319.732372	9.152276	124.533875	51.311209	268.421163
Çalışma-6	9.165864	124.457741	318.566238	9.151476	124.392853	51.501227	267.065011
Çalışma-7	9.170979	124.638634	320.548543	9.152420	124.500977	51.286385	269.262158
Çalışma-8	9.165660	124.515572	319.949331	9.153835	124.467796	51.401507	268.547824
Çalışma-9	9.165454	124.481529	321.486133	9.152428	124.456055	51.495178	269.990955
Çalışma-10	9.165144	124.499023	319.076798	9.154242	124.443810	51.240336	267.836462
Çalışma-11	9.163760	124.334984	322.584690	9.157562	124.601051	51.166923	271.417767
Çalışma-12	9.165891	124.477898	319.375674	9.153080	124.473816	51.404829	267.970845
Çalışma-13	9.165092	124.503113	321.161247	9.155869	124.521812	53.972429	267.188818
Çalışma-14	9.164674	124.411964	320.698321	9.151921	124.460793	51.467951	269.230370
Çalışma-15	9.165736	124.459328	318.672879	9.150661	124.383301	51.492429	267.180450
Çalışma-16	9.171666	124.754265	319.180878	9.151567	124.399452	51.187638	267.993240
Çalışma-17	9.163885	124.454460	319.530877	9.150584	124.371910	51.249344	268.281533
Çalışma-18	9.173385	124.755493	319.320975	9.150790	124.421776	51.408161	267.912814
Çalışma-19	9.166206	124.526207	319.537653	9.152858	124.433525	51.505043	268.032610
Çalışma-20	9.163708	124.432716	320.211819	9.150372	124.389076	54.245016	265.966803
Çalışma-21	9.165729	124.528587	320.975721	9.151662	124.398041	51.619870	269.355851
Çalışma-22	9.169978	124.658081	324.042531	9.154080	124.505562	51.326758	272.715773
Çalışma-23	9.164301	124.481972	318.425737	9.154661	124.522972	51.749480	266.676257
Çalışma-24	9.165844	124.489464	318.210329	9.153104	124.497932	51.550149	266.660180
Çalışma-25	9.166923	124.477539	321.119320	9.152639	124.505768	51.277746	269.841574
Çalışma-26	9.164628	124.429535	319.082739	9.151433	124.425537	52.393641	266.689098
Çalışma-27	9.165701	124.522278	319.760717	9.153373	124.499390	51.341013	268.419704
Çalışma-28	9.166192	124.508514	319.463908	9.154636	124.534485	51.041205	268.422703
Çalışma-29	9.165132	124.487114	322.814966	9.154012	124.541046	51.903283	270.911683
Çalışma-30	9.165265	124.459198	318.623034	9.150099	124.376717	51.709610	266.913424
Ortalama	9.166356	124.508362	320.200919	9.152829	124.463027	51.596985	268.603934
Minimum	9.163708	124.334984	318.210329	9.150099	124.371910	50.660955	267.549374
Maksimum	9.173385	124.755493	324.042531	9.157578	124.601051	54.245016	269.797515

Tablo 8’de ise 392×512 boyutlarındaki görüntülerin tamamının GTX 980 ve RTX 2080Ti GPU kartları üzerindeki 30 çalışmasından elde edilen sonuçların ortalama değerleri görülmektedir. RTX2080Ti GPU kartı içerisinde GTX 980 GPU kartına göre çok daha fazla çekirdek olmasından dolayı eğitimi ortalama 78.15 saniye daha hızlı bitirmektedir. Çalışma farklı GPU kartlar üzerinde çalıştırılmış olsa da görüntü kalitesi metriklerini bakıldığında bir birine çok yakın olduğu görülmektedir. Bu da görüntü kalitelerinden ödün vermeden tasarlanan algoritmanın hızlandırıldığı görülmektedir. Ayrıca referans görüntüsüne gürültü eklenerek elde edilen gürültülü görüntünün MAE değeri 22.727523 iken filtreleme sonucunda bu değer ortalama 7.803843 olmaktadır. Bu da gürültülerin büyük bir çoğunluğunun temizlendiği anlamına gelmektedir. Tablo 8 ve Tablo 9’da verilenlerin detaylı sonuçları EK-2’de sunulmuştur.

Tablo 8. 392×512 boyutlarındaki görüntülerin GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile elde edilen ortalama sonuçlarının zaman karşılaştırılması

Referans Görüntü	392x512 Görüntüler GTX 980 GPBM (GPU Popülasyon Temelli Yöntem) Yöntemi			392x512 Görüntüler RTX 2080Ti GPBM (GPU Popülasyon Temelli Yöntem) Yöntemi			Zaman Farkı
	MAE - MSE Değerleri		Hesaplama Zamanı	MAE - MSE Değerleri		Hesaplama Zamanı	
	MAE	MSE	Zaman (sn.)	MAE	MSE	Zaman (sn.)	
	b1	7.811954	102.737000	103.091320	7.812566	102.999305	
b2	8.348015	121.223326	103.035306	8.325851	120.773843	20.344847	82.690459
b3	7.734155	99.741165	98.551440	7.721108	99.694466	20.312718	78.238721
b4	7.793245	101.038412	98.536374	7.782602	100.799204	20.090583	78.445791
b5	7.672215	97.931055	98.479003	7.641728	97.104914	20.462168	78.016834
b6	7.851873	102.349969	98.521361	7.853137	102.282598	20.071453	78.449909
b7	7.657575	97.586883	98.503886	7.661565	97.494533	20.083484	78.420403
b8	7.799071	100.934488	98.499178	7.745981	99.617146	20.102121	78.397057
b9	7.892844	108.588825	98.448810	7.888361	108.676343	20.294469	78.154341
b10	7.477479	96.394677	98.506008	7.434003	95.446601	20.162470	78.343538

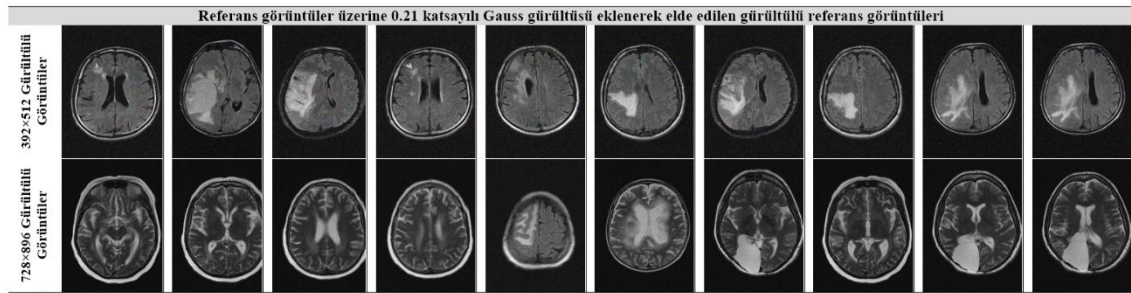
Tablo 9’da ise 728×896 boyutlarındaki görüntülerin tamamının GTX 980 ve RTX 2080Ti GPU kartları üzerindeki 30 çalışmasından elde edilen sonuçların ortalama değerleri görülmektedir. RTX2080Ti GPU kartı içerisinde GTX 980 GPU kartına göre çok daha fazla çekirdek olmasından dolayı eğitimi ortalama 298.69 saniye daha hızlı bitirmektedir. Çalışma farklı GPU kartlar üzerinde çalıştırılmış olsa da görüntü kalitesi metriklerini bakıldığında bir birine çok yakın olduğu görülmektedir. Referans görüntüsüne gürültü

eklenerek elde edilen gürültülü görüntünün MAE değeri 21.157957 ve MSE değeri 698.617755 iken filtreleme sonucunda bu değerler ortalama MAE değeri 8.601635 ve MSE değeri 115.479436 olmaktadır.

Tablo 9. 728×896 boyutlarındaki görüntülerin GTX 980 ve RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile elde edilen ortalama sonuçlarının zaman karşılaştırılması


Referans Görüntü	728x896 Görüntüler GTX 980 GPBM (GPU Popülasyon Temelli Yöntem)			728x896 Görüntüler RTX 2080Ti GPBM (GPU Popülasyon Temelli Yöntem)			Zaman Farkı
	MAE - MSE Değerleri		Hesaplama Zamanı	MAE - MSE Değerleri		Hesaplama Zamanı	
	MAE	MSE	Zaman (sn.)	MAE	MSE	Zaman (sn.)	
	b1	9.166356	124.508362	320.200919	9.152829	124.463027	
b2	8.899775	120.255300	320.086338	8.928385	120.918549	51.737547	268.348792
b3	8.866483	118.420225	331.569886	8.874193	118.643851	52.061929	279.507958
b4	8.400788	110.993002	320.863577	8.410303	111.314235	52.624431	268.239146
b5	7.171082	88.723058	321.328793	7.150327	88.072630	52.639089	268.689704
b6	8.641557	122.894124	320.399157	8.620800	122.146444	52.392587	268.006570
b7	8.643784	115.908943	320.875527	8.619108	115.487672	52.446010	268.429517
b8	9.004043	121.626859	305.960251	9.005715	121.806988	52.550570	253.409681
b9	8.658703	116.150746	604.969674	8.655714	116.197845	52.492173	552.477502
b10	8.636376	116.601631	343.866918	8.598975	115.743117	52.660269	291.206650

Şekil 5’de referans görüntülerine 0.21 katsayısına sahip Gaussina gürültüsü eklendiğinde elde edilen gürültülü referans görüntüler görülmektedir.




Şekil 5. Hızlandırma çalışmasında kullanılan gürültülü referans görüntüleri (0.21 katsayılı Gauss gürültüsü)

Şekil 5’de görülen gürültülü referans görüntüler Kuadratik görüntü filtreleri kullanılarak filtrelendiklerinde elde edilen filtrelenmiş referans görüntüler Şekil 7’de görülmektedir.



Şekil 6. 392×512 boyutlarındaki görüntülerin Kuadratik filtreler ile filtrelenmesi sonucu elde edilen filtrelenmiş görüntüler

Şekil 6’da görülen gürültülü referans görüntüler Kuadratik görüntü filtreleri kullanılarak filtrelendiklerinde elde edilen filtrelenmiş referans görüntüler ise Şekil 8’de görülmektedir.



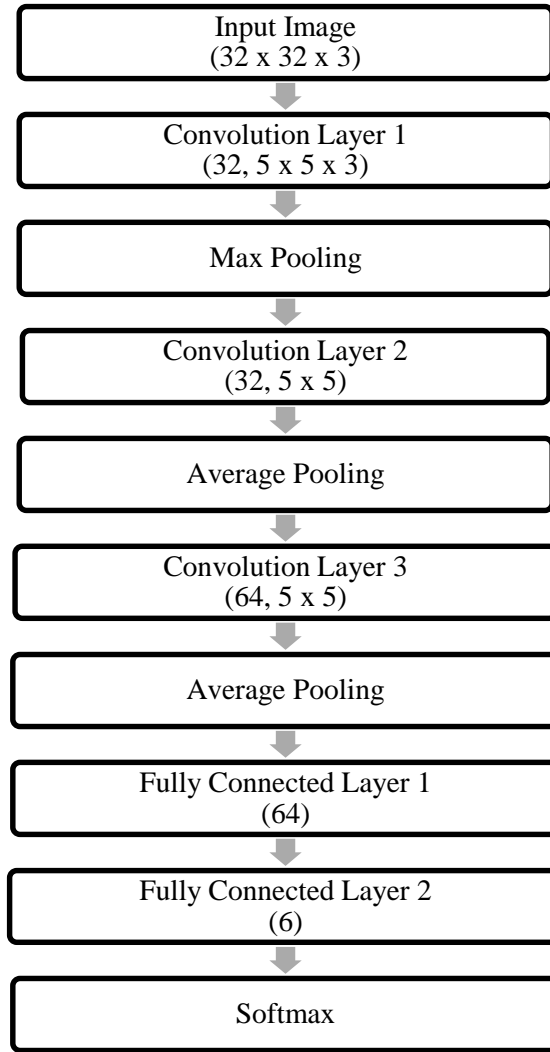
Şekil 7. 728×896 boyutlarındaki görüntülerin Kuadratik filtreler ile filtrelenmesi sonucu elde edilen filtrelenmiş görüntüler

Şekil 5 ile Şekil 7 ve Şekil 6 ile Şekil 8’e bakıldığında gürültülerin temizlenerek gözle fark edilebilecek düzeyde görüntülerde bir iyileşme olduğu görülmektedir.

Sonuç olarak yapılan bu deneysel çalışmada, beyin MR görüntülerinin Kuadratik görüntü filtreleri ile filtrelenmesi için GPU tabanlı hızlandırma çalışmaları yapılmıştır. Elde edilen sonuçlara bakıldığında günümüz teknolojisinde üretilen GPU kartlar kullanıldığında görüntü işlemenin her alanında Kuadratik görüntü filtrelerinin filtreleme işlemlerini kullanılabilecek süreler içerisinde tamamladığı görülmektedir. Bu deneysel çalışmanın devamı olarak farklı bir deneysel çalışma daha yapılmıştır. Bu çalışma, R-CNN ile beyin MR görüntüleri üzerindeki tümörlü bölgelerin tespit edilmesidir. R-CNN ağında eğitim ve test görüntüleri, hiçbir ön işlemten geçirilmeden R-CNN ağına sunulması, görüntülerin medyan filtreden geçirildikten sonra ağına sunulması ve görüntülerin Kuadratik görüntü filtresinden geçirildikten sonra ağına sunulmuştur. Sonuçta R-CNN'in tümörlü bölgeyi tespit etmedeki başarımları ölçülmüştür.

3.5. Derin Öğrenme Tabanlı MR Görüntüleri Üzerinden Tümör Tespiti

CNN bilgisayarlı görü uygulamalarında kullanılmak üzere geliştirilmiş çok katmanlı yapay sinir ağlarının özel bir modelidir. Yapısında konvolüsyon, havuzlama ve tam bağlı gibi, kendine özgü görevleri olan ayrı katmanları barındırır. Bunlar birbirini takip edecek şekilde dizilerek CNN oluşturulur. Bu yapının ilk kısımlarında öznitelik çıkartım işlemleri gerçekleştirilirken sınıflandırma işlemi ise son katmanlarda gerçekleşir [15].



Şekil 8. Kullanılan CNN'nin mimarisi

Bu proje çalışmada üç CNN katmanı, üç pooling işlemi ve tam bağlantılı katman olmak üzere toplamda beş katmanlı bir CNN mimarisi oluşturulmuştur. Oluşturulan 5 katmanlı CNN modeli hazırlanan eğitim veriseti ile eğitilmiştir. Ayrıca son tam bağlantılı katmanın çıkışı 6 yollu bir “softmax” ile beslenmiştir. Oluşturulan CNN yapısına ait akış şeması Şekil 8’de görülmektedir.


Öğrenme transferi, büyük bir veri kümesi modelinden öğrenilmiş ağırlıkların alındığı ve bunların çeşitli sabit katmanlara uygulandığı, kalan katmanların tekrar eğitildiği veya ağıncı ince ayarlarının yapıldığı, yaygın olarak kullanılan bir derin öğrenme tekniğidir. CNN yapısı oluştururken eğitim için bir veri kümesine ihtiyaç duyulur ve bu veri kümesi yeteri kadar büyük değilse oluşturulan ağ teste tabi tutulduğunda düşük bir doğruluk oranı verir. Bu durumda eğitim veri kümesinin büyütülmesi yani etiketli veri sayısının

arttırılması gerekir. Fakat bazı durumlarda bu mümkün değildir ve sınırlı sayıdaki etiketli eğitim verisi ile çalışmak zorunda kalınabilir. Bu koşullarda en iyi doğruluk derecesine sahip sonuçların öğrenme transferi ile elde edildiği görülmüştür. Yani öğrenme transferi, küçük veri kümeleri ile yüksek doğruluk derecesine sahip sonuçlar alınmasını sağlayabilir.

Ön işlemeli çalışmada, beyin MR görüntüleri ön işlem olarak tek tek Kuadratik görüntü filtrelerinden geçirilerek filtrelenmiştir. Filtreleme işlemlerinde her bir görüntü için Kuadratik filtre ağırlıkları görüntünün karakteristik özelliklerine göre GA ile eğitilerek yeniden hesaplanarak filtrelenmiştir. Kuadratik filtrelerin ağırlıklarının eğitilerek hesaplanması sayesinde karakteristikleri farklı olan görüntüler daha iyi bir şekilde filtrelenmiştir. Kuadratik filtrelerin filtre ağırlıklarının hesaplanma işlemleri çok uzun sürdüğünden tüm bu işlemler GPU üzerinde gerçekleştirilmiştir.

3.5.1. Beyin MR görüntüleri üzerindeki Tümörlü Bölümlerin İşaretlenmesi

Bu aşamada beyin MR görüntüleri üzerindeki tümörlü bölgenin analiz edilmesi için tümörlü bölgenin olduğu bölümlerin işaretlenmesi işlemi yapılmaktadır. Bunun için öncelikle tümörlü bölgeler tamamen işaretlenmiş ve işaretlenen bölgelerin koordinatları “.mat” formatında kaydedilmiştir. Şekil 8’de bu amaçla tümörlü bölgeler işaretlenmiştir. Görüntü üzerinde birden fazla ve farklı noktalarda olan tümörlü bölgelerin işaretlenmesi görülmektedir. Burada tanınacak bölgenin koordinatları bütün görüntülerin işaretlenme işlemleri bittikten sonra “.mat” dosyasına kaydedilmektedir.



Şekil 9. Beyin MR görüntüsü üzerindeki tümörlü bölgenin işaretlenmesi

3.5.2. Derin öğrenme algoritması ile sistemin eğitilmesi

Tümörü tespit etmek için CNN derin öğrenme uygulamalarında yaygın olarak kullanılan transfer öğrenme iş akışını kullanır. Transfer öğrenmesinde, geniş bir resim koleksiyonu üzerine eğitilmiş bir ağ, yeni bir sınıflandırma veya tespit görevini çözmek için başlangıç noktası olarak kullanılır. Bu yaklaşımı kullanmanın avantajı, önceden eğitilmiş ağın çok çeşitli görüntülere uygulanabilecek zengin bir dizi görüntü özelliği öğrenmiş olmasıdır. Bu öğrenme, ağa ince ayar yaparak yeni göreve aktarılabilir. Bir ağ, orijinal görev için öğrenilen özellik sunumlarının yeni görevi destekleyecek şekilde hafifçe ayarlandığı şekilde ağırlıklardaki küçük ayarlamalar yaparak ince ayar yapılır. Bu amaçla CNN ağının eğitilmesi için kullanılan parametreler Şekil 9'da sunulmuştur.


```

layers =
15x1 Layer array with layers:
  1 '' Image Input          32x32x3 images with 'zerocenter' normalization
  2 '' Convolution          32 5x5 convolutions with stride [1 1] and padding [2 2]
  3 '' ReLU                 ReLU
  4 '' Max Pooling          3x3 max pooling with stride [2 2] and padding [0 0]
  5 '' Convolution          32 5x5 convolutions with stride [1 1] and padding [2 2]
  6 '' ReLU                 ReLU
  7 '' Max Pooling          3x3 max pooling with stride [2 2] and padding [0 0]
  8 '' Convolution          64 5x5 convolutions with stride [1 1] and padding [2 2]
  9 '' ReLU                 ReLU
 10 '' Max Pooling          3x3 max pooling with stride [2 2] and padding [0 0]
 11 '' Fully Connected      64 fully connected layer
 12 '' ReLU                 ReLU
 13 '' Fully Connected      10 fully connected layer
 14 '' Softmax              softmax
 15 '' Classification Output cross-entropy

```

Şekil 10. CNN ağının eğitilmesi için kullanılan parametreler

Ağ eğitim algoritması, Momentum (SGDM) ile, 0.001'lik bir başlangıç öğrenme oranı ile Stokastik Gradyan Descent'i kullanır. Eğitim sırasında, ilk öğrenme oranı her 8 adımda bir azaltılır. Eğitim algoritması 40 epoch için çalıştırılmıştır. Eğitim aşamasından sonra tümörlü bölgenin CNN tarafından belirlenmiş hali Şekil 10'da gösterilmiştir.



Şekil 11. Tümörlü bölgenin CNN eğitim aşamasından sonra bulunması

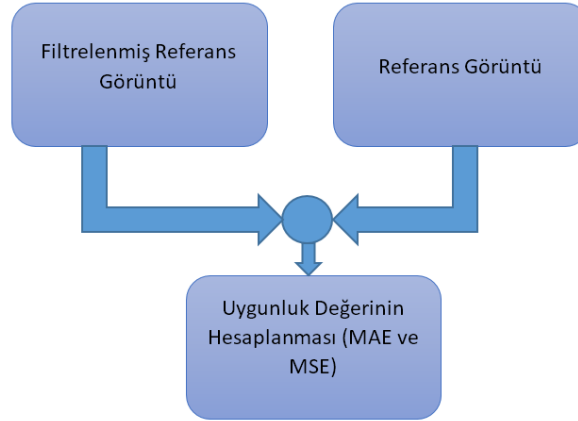
3.5.3. Deneysel Çalışma-2

Bu deneysel çalışma, R-CNN ile beyin MR görüntüleri üzerindeki tümörlü bölgelerin tespit edilmesidir. R-CNN ağında eğitim ve test görüntüleri, hiçbir ön işlemlemeden R-CNN ağına sunulması, görüntülerin medyan filtreden geçirildikten sonra ağına sunulması ve görüntülerin Kuadratik görüntü filtresinden geçirildikten sonra ağına sunulmuştur. Sonuçta ön işlemlemeden geçirilen ve geçirilmeyen görüntüler ağına verildiğinde R-CNN'in tümörlü bölgeyi tespit etmedeki başarımları ölçülmüştür. Çalışmada toplam 405 adet görüntü kullanılmış olup bu görüntülerin 305 âdeti eğitim aşamasında 100 âdeti ise test aşamasında kullanılmıştır. Çalışma kapsamında görüntüler derin öğrenme sistemine görüntü üzerinde hiçbir işlem yapmadan (ön işlemsiz olarak) alınarak eğitimler yapılmış ve daha sonra test görüntüleri üzerinde test edilerek başarımları kaydedilmiştir. Yine aynı eğitim ve test görüntüleri ön işlemlemeden geçirilerek derin öğrenme sistemine görüntüler yüklenmiştir. Burada ön işlem olarak çalışmada kullanılan bütün görüntüler Medyan filtresi ve Kuadratik görüntü filtresinden geçirilerek filtrelenmiş görüntüler elde edilmiştir. Her bir görüntü için Kuadratik görüntü filtrelerinin ağırlıkları GA ile eğitilerek hesaplanmış ve filtrelenmiştir. Deneysel çalışmada kullanılan GA'nın mutasyon oranı 0.05, çaprazlama oranı 0.3, Kuadratik çözüm üst sınırı 1.0, kuadratik çözüm alt sınırı -1.0 olarak belirlenmiştir. Popülasyon adeti 1000, maksimum iterasyon sayısı 300 ve GA'nın durdurma kriteri olarak maksimum iterasyon sayısı olacak şekilde belirlenmiştir. Eğitim aşamasında hata oranını hesaplamak amacıyla bütün görüntüleri gri seviyesi alınmıştır. Şekil 11'de filtreleme yönteminin blok şeması görülmektedir.



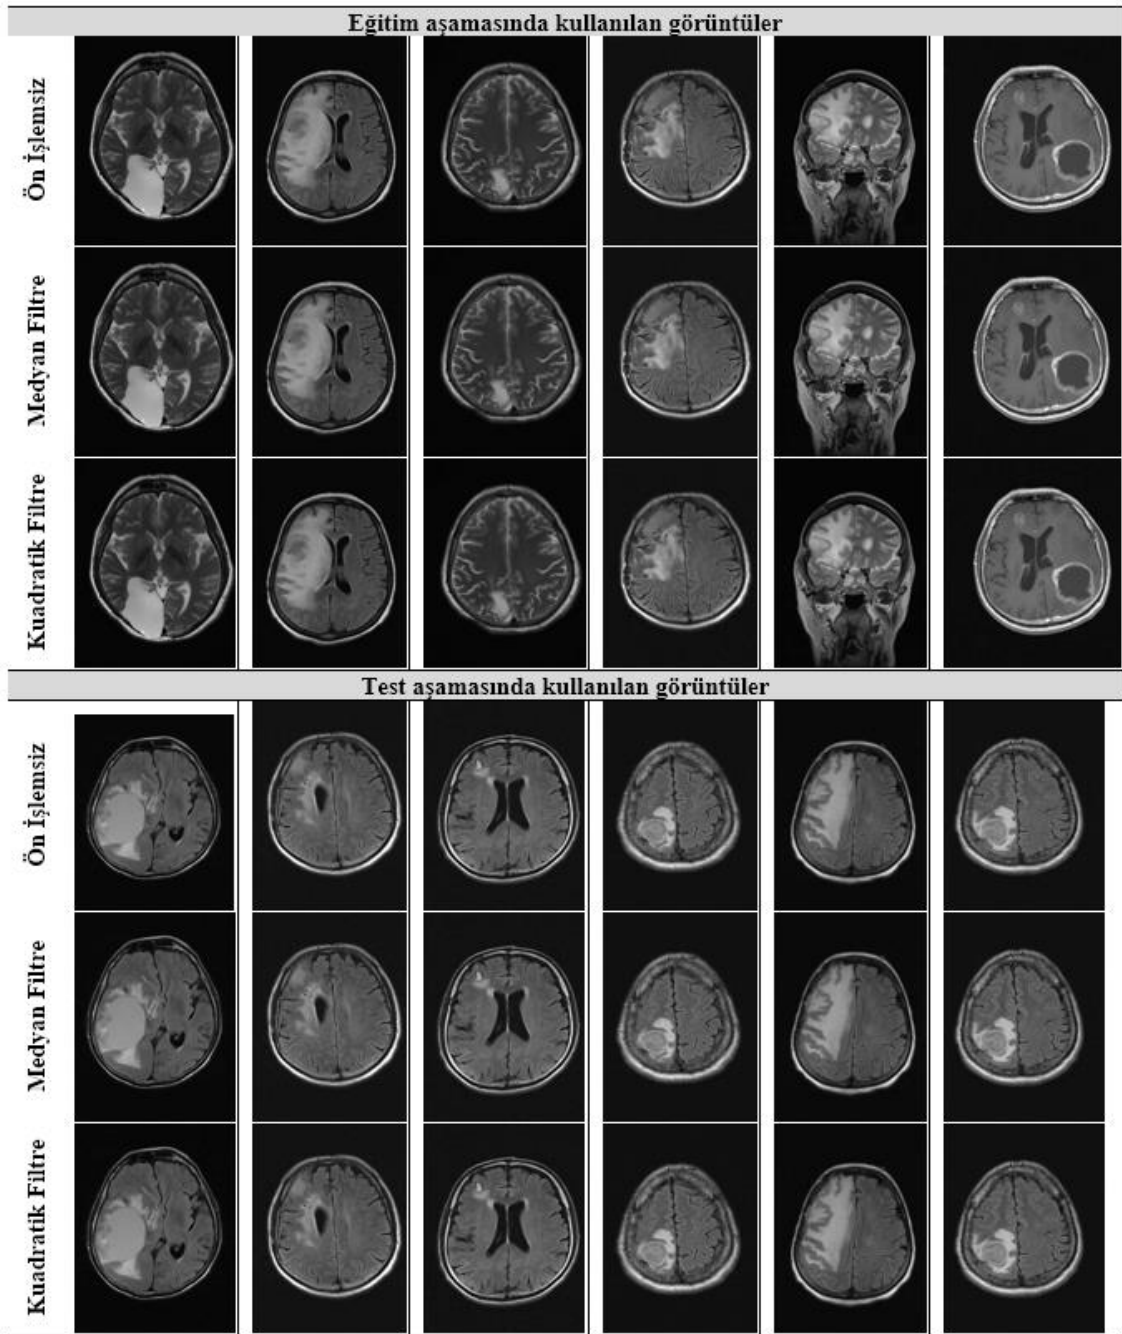
Şekil 12. Kuadratik görüntü filtresinin filtreleme yöntemi blok şeması

MAE ve MSE görüntü kalitesi değerleri hesaplanırken Şekil 12’de gösterilen filtrelenmiş görüntü ile gri seviyesi alınmış görüntü karşılaştırılarak hesaplanmıştır.



Şekil 13. MAE ve MSE görüntü kalitesinin hesaplama yöntemi blok şeması

Ön işlemden geçirilen görüntüler derin öğrenme sistemine yüklenerek ön işlemlerle eğitim görüntüleri ile eğitim yapılarak ön işlemlerle test görüntüleri ile testler yapılmış başarımları kaydedilmiştir. Çalışmada kullanılan görüntülerin ön işlemlerle çalışma ile ön işlemsiz çalışma arasındaki görüntü kalitelerini belirlemek amacıyla MAE ve MSE görüntü kalitesi ölçüm metrikleri kullanılmıştır. Şekil 13’de deneysel çalışmada kullanılan eğitim ve test görüntü örnekleri görülmektedir.



Şekil 14. Deneysel çalışmada kullanılan test ve eğitim aşamasında kullanılan örnek görüntüler

Şekil 13’de gösterilen eğitim görüntüleri üzerinde bulunan tümörlü bölgeler derin öğrenme sistemine öğretilmektedir. Eğitim aşamasından sonra, test görüntüleri derin öğrenme sistemine verilmektedir. Bu test görüntüleri derin öğrenmenin daha önce hiç görmediği farklı görüntülerden oluşmaktadır. Bu görüntüler üzerinde bulunan tümörlü bölgeleri tespit etmedeki başarımları ölçülmüştür. Ön işlemler çalışmada, ön işlem olarak

hem test hem de eğitim görüntüleri medyan filtre ve Kuadratik görüntü filtreleri kullanılarak filtelenmiştir.

Tablo 10’da derin öğrenme sisteminin eğitim aşamasında ön işlemsiz çalışmada ve ön işlemlili çalışmada elde edilen başarıml örnekleri görölmektedir. Ön işlemsiz çalışmada eğitim başarımlı ortalama %98.35, ön işlemlili çalışmalardan medyan filtrelili çalışmada eğitim başarımlı ortalama %98.51 ve Kuadratik görüntü filtrelili çalışmada ise eğitim başarımlı ortalaması %98.63 olarak gerçekteşmiştir.

Tablo 10. Derin öğrenmenin eğitimi aşamasında elde edilen başarıml örnekleri


Adım Sayısı	Tekrarlama Sayısı	Öğrenme Oranı	Ön İşlemsiz Çalışma			Ön İşlemlili Çalışma					
			Geçen Süre (Saniye)	Kayıp	Kazanç (%)	Medyan Filtre			Kuadratik Görüntü Filtresi		
						Geçen Süre (Saniye)	Kayıp	Kazanç (%)	Geçen Süre (Saniye)	Kayıp	Kazanç (%)
90	50	0.001000	227.37	0.0090	99.22	227.57	0.0201	99.22	229.28	0.0031	100.00
91	50	0.001000	229.98	0.0007	100.00	229.63	0.0261	99.22	231.38	0.0014	100.00
92	50	0.001000	231.41	0.0024	100.00	231.71	0.006	100.00	235.50	0.0335	99.21
93	50	0.001000	235.29	0.0318	99.22	233.91	0.003	100.00	237.53	0.0422	98.44
94	50	0.001000	237.52	0.0442	99.22	236.10	0.0034	100.00	239.56	0.0018	100.00
95	50	0.001000	239.68	0.0066	100.00	240.21	0.0009	100.00	241.58	0.0005	100.00
96	50	0.001000	241.68	0.0683	98.44	242.25	0.0040	100.00	245.63	0.0049	100.00
97	50	0.001000	245.58	0.0025	100.00	244.37	0.0136	99.22	247.62	0.0008	100.00
98	50	0.001000	247.54	0.0090	100.00	246.47	0.0065	100.00	249.66	0.0021	100.00
99	50	0.001000	249.52	0.0006	100.00	248.52	0.0285	99.22	251.68	0.0021	100.00
100	50	0.001000	253.41	0.0007	100.00	252.60	0.0019	100.00	255.71	0.0009	100.00

Tablo 11’de yapılan çalışmlar sonucunda, hem ön işlemsiz hem de ön işlemlili çalışmada derin öğrenmenin tümörlü bölgeyi tespit etme başarımları karşılaştırılmıştır. Ön işlemlili çalışmada derin öğrenme sisteminin tümörlü bölgeleri tespit etme başarımlarının ön işlemsiz çalışmaya göre daha yüksek olduđu görölmektedir. Ön işlemlili çalışmada ise görüntülerin Kuadratik görüntü filtrelerinden geçirildikten sonra yapılan deneysel çalışmada ise tümörlü bölgeyi tespit etme başarımlınının medyan filtreye göre daha yüksek olduđu görölmektedir.

Tablo 11. Tümörlü bölgeyi tespit etme başarımları

<i>Filtreleme Türü</i>	<i>Çalışma Türü</i>	<i>Tümörlü Bölgeyi Tespit Etme Başarımı</i>
Ham görüntü	Ön İşlemsiz Çalışma	%85.87
Medyan Filtre	Ön İşlemlili Çalışma	%88.70
Kuadratik Görüntü Filtre	Ön İşlemlili Çalışma	%91.06

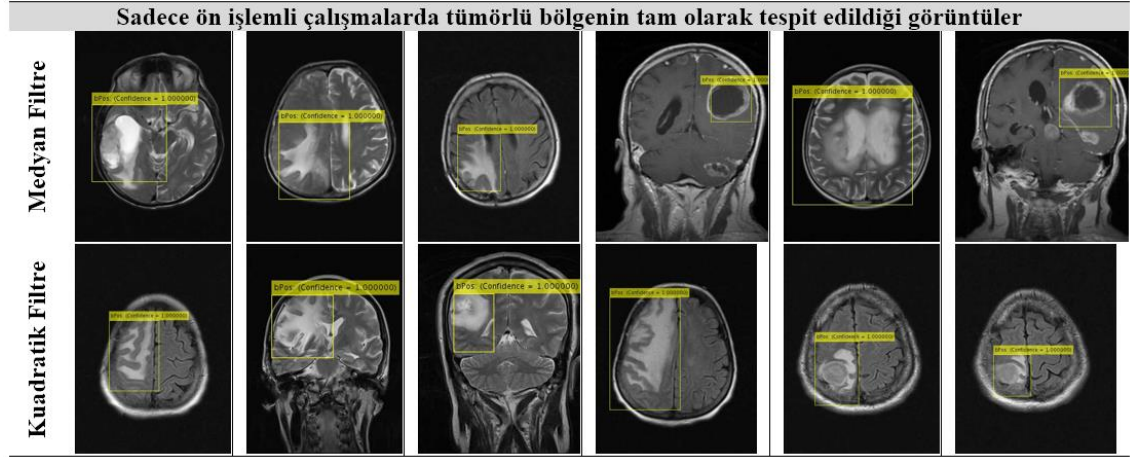
Şekil 14’de, ön işlemlili ve ön işlemsiz çalışmada tümörlü bölgenin %100 olarak tespit edildiği örnek görüntüler görülmektedir. Ön işlemsiz çalışmada, tümörlü bölgenin %100 tespit edilebildiği görüntü sayısı test görüntülerinin %8’i kadardır. Medyan filtrenin kullanıldığı ön işlemlili çalışmada tümörlü bölgenin %100 tespit edilebildiği görüntü sayısı ise test görüntülerinin %28’i iken Kuadratik görüntü filtrenin kullanıldığı ön işlemlili çalışmada tümörlü bölgenin %100 tespit edilebildiği görüntü sayısı da test görüntülerinin %28 kadardır.



Şekil 15. Tümörlü bölgenin %100 olarak tespit edildiği örnek görüntüler

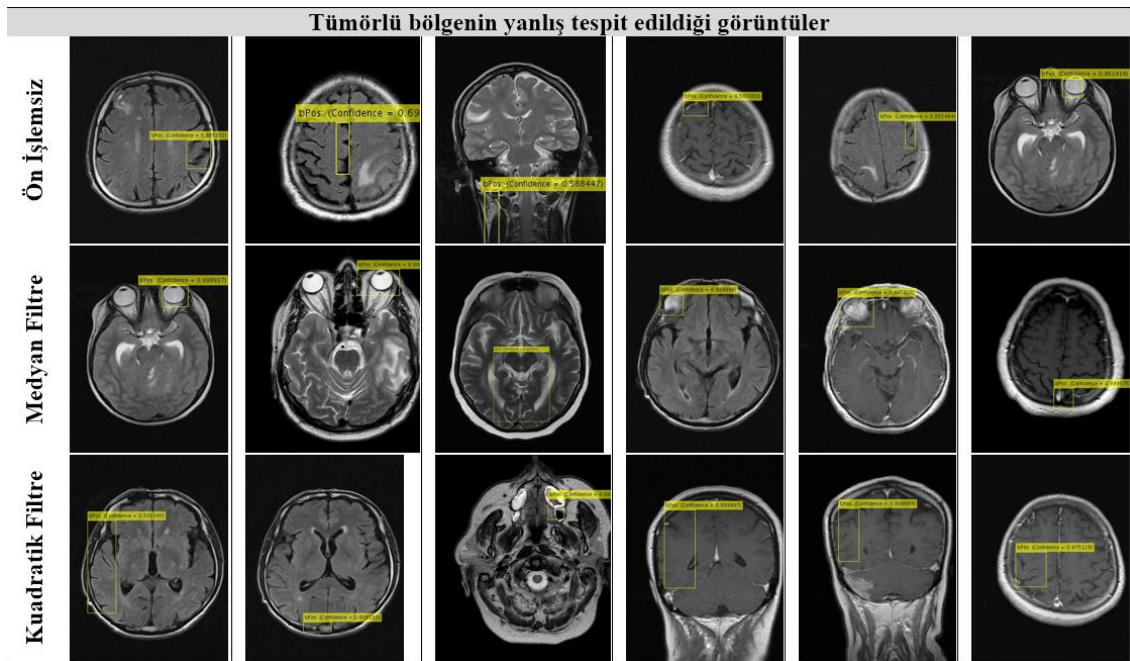
Şekil 15’de ise ön işlemsiz çalışmada tümörlü bölgenin hiç tespit edilemediği ya da düşük oranlarda tespit edebildiği fakat ön işlemlili çalışmada %100 olarak tespit edildiği örnek görüntüler görülmektedir. Ön işlemlili çalışmada medyan filtre ile Kuadratik görüntü filtrenin kullanıldığı durumlarda test görüntüleri üzerindeki tümörlü bölgenin %100 tespit edildiği görüntü sayıları aynı olsa da diğer %57’lik görüntüler üzerindeki tümörlü bölgeyi

tespit etme oranı Kuadratik görüntü filtresinin kullanıldığı durumda daha yüksek olduğu görülmektedir.




Şekil 16. Sadece ön işlemlenmiş çalışmalar tarafından tümörlü bölgenin bulunduğu örnek görüntüler

Şekil 16'da ise yapılan deneysel çalışmaların testi sonucunda algoritmaların tümörlü bölgeyi yanlış olarak tespit ettikleri örnek görüntüler görülmektedir. Bunun sebeplerinden biri, beyin MR görüntüleri üzerinde kafatası kemiği, göz vb. gibi bölgelerin tümörlü bölgenin renk tonlarına çok yakın olmasından kaynaklanmaktadır. Diğer bir sebebi ise görüntüler üzerindeki işaretlenen tümörlü bölge sayılarının az olmasıdır.



Şekil 17. Tümörlü bölgenin yanlış tespit edildiği örnek görüntüler

Şekil 17’de ön işlemlenmiş ve ön işlemlenmemiş çalışmalarda test görüntüleri üzerindeki tümörlü bölgelerin hiç tespit edilemediği örnek görüntüler görülmektedir. Bunun sebebi ise eğitim görüntüleri içerisinde Şekil 17’deki görüntülere yakın özellikte görüntülerin olmamasıdır.



Şekil 18. Tümörlü bölgenin hiç tespit edilemeyen örnek görüntüler

Ön işlemlenmemiş çalışmada tümörlü bölgenin hiç tespit edilemediği görüntü sayısı test görüntülerinin %12’si kadardır. Medyan filtrenin kullanıldığı ön işlemlenmiş çalışmada tümörlü bölgenin hiç tespit edilemediği görüntü sayısı ise test görüntülerinin %8’i iken Kuadratik görüntü filtrenin kullanıldığı ön işlemlenmiş çalışmada tümörlü bölgenin hiç tespit edilemediği görüntü sayısı da test görüntülerinin %6 kadardır.

Ön işlemlenmemiş çalışmada tümörlü bölgenin %100 veya daha düşük oranlarda tespit edildiği görüntü sayısı test görüntülerinin %78’i kadardır. Medyan filtrenin kullanıldığı ön işlemlenmiş çalışmada tümörlü bölgenin %100 veya daha düşük oranlarda tespit edildiği görüntü sayısı ise test görüntülerinin %85 iken Kuadratik görüntü filtrenin kullanıldığı ön işlemlenmiş çalışmada tümörlü bölgenin %100 veya daha düşük oranlarda tespit edildiği görüntü sayısı da test görüntülerinin %87’si kadar olmaktadır.

4. SONUÇLAR

Bu proje çalışmasında Kuadratik görüntü filtrelerinin görüntü işlemenin hemen hemen her alanında kullanılabilir sürelerle GPU kartlar ile indirildiği tespit edilmiştir. Kuadratik görüntü filtrelerinin kullanılmasıyla R-CNN'nin beyin MR görüntülerindeki tümörlü bölgeyi tespit etmedeki başarımları ölçülmüştür. Deneysel çalışma sonucunda Kuadratik görüntü filtrelerinin kullanılması hem tümörlü bölgenin tahmin edildiği test görüntü sayısı artmakta hem de tespit etme oranlarının arttığı görülmektedir.

5. PROJE KAPSAMINDA YÜRÜTÜLEN BİLİMSEL ETKİNLİKLER

Bu proje kapsamında yapılan çalışmalardan “Beyin MR Görüntülerinin İyileştirilmesi İçin Kuadratik Görüntü Filtre Tasarımı” isimli özet bir bildiri hazırlanmıştır. Bu bildiri “*International Conferance On Data Science And Applications (ICONDATA’19)* - <http://www.icondata.org/tr/icondata-19>” konferansında sözlü olarak sunulmuştur. Bu bildirinin özeti EK4.1’de sunulmuştur. Ayrıca Bu özet bildirinin genişletilmiş çalışması makale olarak hazırlanıp ulusal bir dergi olan “*Veri Bilimi*” dergisinde yayınlanmıştır. Bu makalenin özeti EK4.2’de sunulmuştur.

Bunların yanında proje kapsamında bir adet makale çalışması devam etmekte olup ilerleyen süreçte yayınlanması planlanmaktadır.

6. TEŞEKKÜR

Bu bilimsel araştırma proje çalışması Bilecik Şeyh Edebali Üniversitesi BAP Koordinatörlüğü tarafından 2019-01.BŞEÜ.03-06 nolu proje ile desteklenmiştir. Proje ekibi katkılarından Bilecik Şeyh Edebali Üniversitesi ve BAPK'ya teşekkür etmektedir.

Ayrıca proje kapsamında gerçekleştirilen “Beyin MR Görüntülerinin İyileştirilmesi İçin Kuadratik Görüntü Filtre Tasarımı” isimli bildiriye “*International Conferance On Data Science And Aplications (ICONDATA'19)* - <http://www.icondata.org/tr/icondata-19>” isimli sempozyumda sunan Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalında Yüksek Lisans yapan öğrencim Esin KARAGÖZ'e teşekkür ederiz.

KAYNAKLAR

- [1] C. S. Anand and J. S. Sahambi, "Wavelet domain non-linear filtering for MRI denoising," *Magn. Reson. Imaging*, vol. 28, no. 6, pp. 842–861, 2010.
- [2] J. Mohan, V. Krishnaveni, and Y. Guo, "Biomedical Signal Processing and Control A survey on the magnetic resonance image denoising methods," *Biomed. Signal Process. Control*, vol. 9, pp. 56–69, 2014.
- [3] M. B. Meenavathi and K. Rajesh, "Volterra Filtering Techniques for Removal of Gaussian and Mixed Gaussian-Impulse Noise," *Int. J. Electr. Robot.*, vol. 1, no. 2, pp. 1–7, 2007.
- [4] M. Kanamadi, V. Waghmode, and S. Bandekar, "Alpha Weighted Quadratic Filter Based Enhancement for Mammogram," in *Proceedings of International conference on "Emerging Research in Computing, Information, Communication and Applications" (ERCICA)*, pp. 68–74, 2013.
- [5] G. Ramponi, "Edge extraction by a class of second-order nonlinear filters," *Electron. Lett.*, vol. 9, no. 22, pp. 482–484, 1986.
- [6] G. Ramponi and G. L. Sicuranza, "Quadratic Digital Filters for Image Processing," *IEEE Trans. Acoust.*, vol. 36, no. 6, pp. 937–939, Jun. 1988.
- [7] G. Jothilakshmi and E. Gopinathan, "Mammogram Enhancement Using Quadratic Adaptive Volterra Filter A Comparative Analysis In Spatial And Frequency Domain," 2006.
- [8] S. K. Mitra, "Image processing using quadratic volterra filters," in *Computers and Devices for Communication (CODEC)*, pp. 1–2, 2012.
- [9] R. J. P. deFigueiredo and S. Matz, "Exponential nonlinear Volterra filters for contrast sharpening in noisy images," in *1996 IEEE International Conference on Acoustics, Speech, and Signal Processing Conference Proceedings*, vol. 4, pp. 2263–2266, 1996.
- [10] A. Chakrabarty, H. Jain, and A. Chatterjee, "Volterra kernel based face recognition using artificial bee colony optimization," *Eng. Appl. Artif. Intell.*, vol. 26, no. 3, pp. 1107–1114, 2013.
- [11] S. Y. Fakhouri, "Identification of the Volterra kernels of nonlinear systems," *IEE Proc.*, vol. 127-D, no. 6, pp. 296–304, 1980.
- [12] R. D. Nowak and B. D. Van Veen, "Random and Pseudorandom Inputs for Volterra Filter Identification," *IEEE Trans. Signal Process.*, vol. 42, no. 8, pp. 2124–2135, 1994.
- [13] S. Uzun and D. Akgun, "A Literature Review on Quadratic Image Filters," in *ISMSIT 2018 - 2nd International Symposium on Multidisciplinary Studies and Innovative Technologies, Proceedings*, 2018, pp. 1–5.
- [14] S. Uzun and D. Akgün, "An Accelerated Method for Determining the Weights of

Quadratic Image Filters,” *IEEE Access*, vol. 6, 2018.

- [15] Y. Nie, T. Takaki, I. Ishii, and H. Matsuda, “Behavior recognition in laboratory mice using HFR video analysis,” in *Proceedings - IEEE International Conference on Robotics and Automation*, 2011, pp. 1595–1600.

EK 1

T.C.
SAĞLIK BAKANLIĞI
TÜRKİYE KAMU HASTANELERİ KURUMU
İnsan Kaynakları Başkan Yardımcılığı

Sayı : 63430908
Konu : Veri temini

T.C. SAĞLIK BAKANLIĞI
TEHK İNSAN KAYNAKLARI BAŞKAN
YARDIMCILIĞI - TEHK KADRO İŞLEMLERİ
21.03.2013 17:48 -
63430908/907/08083
01180412

ANKARA İKİNCİ BÖLGE KAMU HASTANELERİ BİRLİĞİNE
(Genel Sekreterlik)

Bilecik Şeyh Edebali Üniversitesi Meslek Yüksekokulu Bilgisayar Teknolojileri Bölümü'nde öğretim görevlisi olarak görev yapan Emre DANDIL'ın aynı zaman da Sakarya Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar ve Bilişim Mühendisliği Ana Bilim Dalında Doktora yapmakta olduğu Kurumumuza vermiş olduğu 19/03/2013 tarihli dilekçesinden anlaşılmaktadır.

Doktora aşamasında akademik çalışmada kullanılmak üzere hastalık (*yumurtalık(ovarian), karaciğer(liver), böbrek(kidney-renal), ağız(oral), kemik(bone)*) görüntülerine ihtiyaç duyduğunu ve istenen görüntülerin *MRI(Emar), CT ve PET/CT (Bilgisayarlı Tomografi), Röntgen, X-Ray Görüntüleme, Sintigrafi, Ultrason* gibi farklı görüntüleme cihazlarından alınmış olmasının çalışmada katkı sağlayacağını, dataların ikinci veya üçüncü şahıslarla paylaşılması gibi bir durumun söz konusu olmayacağını, çalışmanın nihai aşamasında sadece "*şu kadar hastadan şu kadarını doğru olarak sınıflandırdık, şu kadarını yanlış sınıflandırdık*" gibi bir ifade yer alacağını, bunun dışında başka bilgi ve kişisel bilgilerin paylaşılması gibi etik kuralların kesinlikle ihlal edilmeyeceğini dilekçesinde belirtmektedir.

Bilim alanında yapılacak olan bu çalışmaya katkı sağlayabilmek için, Ankara Dr.Nafiz Körez Sincan Devlet Hastanesi tarafından hastalara ait kimlik bilgileri belirtilmeden ve etik kurallar çerçevesinde veri temininin sağlanması hususunda gereğini rica ederim.


Dr. Hasan ÇAĞIL
Kurum Başkanı

EK-2

Tablo 12. 392×512 boyutlarındaki b1 referans görüntüsünün GTX 980 ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları

Çalışma Sayısı	Referans Görüntü -1				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı Zaman (sn.)
	MAE	MSE	MAE	MSE	
Çalışma-1	23.212959	745.759460	7.810427	102.677361	102.733740
Çalışma-2	23.212959	745.759460	7.809437	102.622063	103.741138
Çalışma-3	23.212959	745.759460	7.813911	102.853600	102.818672
Çalışma-4	23.212959	745.759460	7.809982	102.649864	103.447332
Çalışma-5	23.212959	745.759460	7.814003	102.897865	103.790722
Çalışma-6	23.212959	745.759460	7.811998	102.757286	103.054380
Çalışma-7	23.212959	745.759460	7.810503	102.674957	102.596890
Çalışma-8	23.212959	745.759460	7.808592	102.601173	103.395990
Çalışma-9	23.212959	745.759460	7.811726	102.703331	103.943906
Çalışma-10	23.212959	745.759460	7.813678	102.805611	103.136694
Çalışma-11	23.212959	745.759460	7.816936	102.918922	102.947899
Çalışma-12	23.212959	745.759460	7.814741	102.880615	103.221099
Çalışma-13	23.212959	745.759460	7.810285	102.623901	102.496156
Çalışma-14	23.212959	745.759460	7.812250	102.810005	102.543638
Çalışma-15	23.212959	745.759460	7.811669	102.767059	102.962304
Çalışma-16	23.212959	745.759460	7.811085	102.689934	103.133366
Çalışma-17	23.212959	745.759460	7.811152	102.612633	103.104184
Çalışma-18	23.212959	745.759460	7.810276	102.610909	103.285931
Çalışma-19	23.212959	745.759460	7.811121	102.673973	102.806098
Çalışma-20	23.212959	745.759460	7.812081	102.750999	102.447203
Çalışma-21	23.212959	745.759460	7.811417	102.703529	103.020142
Çalışma-22	23.212959	745.759460	7.810696	102.647774	102.444997
Çalışma-23	23.212959	745.759460	7.812499	102.784180	103.744654
Çalışma-24	23.212959	745.759460	7.809529	102.560394	102.606223
Çalışma-25	23.212959	745.759460	7.813540	102.869865	103.421713
Çalışma-26	23.212959	745.759460	7.814262	102.932220	103.424110
Çalışma-27	23.212959	745.759460	7.810596	102.681580	103.600523
Çalışma-28	23.212959	745.759460	7.813358	102.777550	103.022479
Çalışma-29	23.212959	745.759460	7.813092	102.720940	102.958007
Çalışma-30	23.212959	745.759460	7.813765	102.849892	102.889405
Ortalama	23.212959	745.759460	7.811954	102.737000	103.091320
Minimum	23.212959	745.759460	7.808592	102.560394	102.444997
Maksimum	23.212959	745.759460	7.816936	102.932220	103.943906

Tablo 13. 728×896 boyutlarındaki b1 referans görüntüsünün GTX 980 ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları

Çalışma Sayısı	Referans Görüntü -1				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
Çalışma-1	21.032328	707.393494	9.165334	124.425941	318.623034
Çalışma-2	21.032328	707.393494	9.164543	124.465965	320.942377
Çalışma-3	21.032328	707.393494	9.168588	124.505257	320.808262
Çalışma-4	21.032328	707.393494	9.168544	124.573860	323.500453
Çalışma-5	21.032328	707.393494	9.166879	124.534630	319.732372
Çalışma-6	21.032328	707.393494	9.165864	124.457741	318.566238
Çalışma-7	21.032328	707.393494	9.170979	124.638634	320.548543
Çalışma-8	21.032328	707.393494	9.165660	124.515572	319.949331
Çalışma-9	21.032328	707.393494	9.165454	124.481529	321.486133
Çalışma-10	21.032328	707.393494	9.165144	124.499023	319.076798
Çalışma-11	21.032328	707.393494	9.163760	124.334984	322.584690
Çalışma-12	21.032328	707.393494	9.165891	124.477898	319.375674
Çalışma-13	21.032328	707.393494	9.165092	124.503113	321.161247
Çalışma-14	21.032328	707.393494	9.164674	124.411964	320.698321
Çalışma-15	21.032328	707.393494	9.165736	124.459328	318.672879
Çalışma-16	21.032328	707.393494	9.171666	124.754265	319.180878
Çalışma-17	21.032328	707.393494	9.163885	124.454460	319.530877
Çalışma-18	21.032328	707.393494	9.173385	124.755493	319.320975
Çalışma-19	21.032328	707.393494	9.166206	124.526207	319.537653
Çalışma-20	21.032328	707.393494	9.163708	124.432716	320.211819
Çalışma-21	21.032328	707.393494	9.165729	124.528587	320.975721
Çalışma-22	21.032328	707.393494	9.169978	124.658081	324.042531
Çalışma-23	21.032328	707.393494	9.164301	124.481972	318.425737
Çalışma-24	21.032328	707.393494	9.165844	124.489464	318.210329
Çalışma-25	21.032328	707.393494	9.166923	124.477539	321.119320
Çalışma-26	21.032328	707.393494	9.164628	124.429535	319.082739
Çalışma-27	21.032328	707.393494	9.165701	124.522278	319.760717
Çalışma-28	21.032328	707.393494	9.166192	124.508514	319.463908
Çalışma-29	21.032328	707.393494	9.165132	124.487114	322.814966
Çalışma-30	21.032328	707.393494	9.165265	124.459198	318.623034
Ortalama	21.032328	707.393494	9.166356	124.508362	320.200919
Minimum	21.032328	707.393494	9.163708	124.334984	318.210329
Maksimum	21.032328	707.393494	9.173385	124.755493	324.042531

Tablo 14. 392×512 boyutlarındaki b1 referans görüntüsünün RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları

Çalışma Sayısı	Referans Görüntü -1				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
Çalışma-1	23.218668	746.931885	7.814318	103.044609	20.138273
Çalışma-2	23.218668	746.931885	7.810206	102.853210	19.947451
Çalışma-3	23.218668	746.931885	7.811052	102.988953	20.014701
Çalışma-4	23.218668	746.931885	7.812425	103.003517	20.098905
Çalışma-5	23.218668	746.931885	7.816261	103.061363	20.080552
Çalışma-6	23.218668	746.931885	7.813858	103.161797	20.083423
Çalışma-7	23.218668	746.931885	7.811895	102.971344	20.189936
Çalışma-8	23.218668	746.931885	7.815181	103.033379	19.961081
Çalışma-9	23.218668	746.931885	7.810703	102.961555	20.100701
Çalışma-10	23.218668	746.931885	7.812907	103.072762	21.142184
Çalışma-11	23.218668	746.931885	7.812027	103.027367	20.019339
Çalışma-12	23.218668	746.931885	7.817328	103.166016	20.024681
Çalışma-13	23.218668	746.931885	7.811687	102.969994	19.727894
Çalışma-14	23.218668	746.931885	7.815279	103.152367	20.070579
Çalışma-15	23.218668	746.931885	7.811728	102.896851	20.518028
Çalışma-16	23.218668	746.931885	7.813363	102.995918	20.649082
Çalışma-17	23.218668	746.931885	7.811454	102.874580	20.651949
Çalışma-18	23.218668	746.931885	7.812487	102.992798	20.333403
Çalışma-19	23.218668	746.931885	7.811706	102.899315	20.406306
Çalışma-20	23.218668	746.931885	7.810558	102.995483	20.604949
Çalışma-21	23.218668	746.931885	7.810492	102.930901	20.652195
Çalışma-22	23.218668	746.931885	7.816059	103.131752	20.540929
Çalışma-23	23.218668	746.931885	7.810791	102.968475	20.644094
Çalışma-24	23.218668	746.931885	7.812168	103.045937	20.053134
Çalışma-25	23.218668	746.931885	7.812852	103.030418	20.713666
Çalışma-26	23.218668	746.931885	7.810152	102.961700	20.608881
Çalışma-27	23.218668	746.931885	7.812780	102.993462	20.686592
Çalışma-28	23.218668	746.931885	7.811948	102.952515	20.578619
Çalışma-29	23.218668	746.931885	7.811723	103.001930	20.620246
Çalışma-30	23.218668	746.931885	7.811584	102.838875	20.644565
Ortalama	23.218668	746.931885	7.812566	102.999305	20.350211
Minimum	23.218668	746.931885	7.810152	102.838875	19.727894
Maksimum	23.218668	746.931885	7.817328	103.166016	21.142184

Tablo 15. 728×896 boyutlarındaki b1 referans görüntüsünün RTX 2080Ti ekran kartında Kuadratik Görüntü Filtreler kullanılarak GPBM yöntemi ile 30 kez çalıştırılma sonuçları

Çalışma Sayısı	Referans Görüntü -1				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
Çalışma-1	21.027927	707.427734	9.153228	124.477692	50.660955
Çalışma-2	21.027927	707.427734	9.151053	124.386467	51.207771
Çalışma-3	21.027927	707.427734	9.157578	124.577415	51.332410
Çalışma-4	21.027927	707.427734	9.151359	124.389893	51.460054
Çalışma-5	21.027927	707.427734	9.152276	124.533875	51.311209
Çalışma-6	21.027927	707.427734	9.151476	124.392853	51.501227
Çalışma-7	21.027927	707.427734	9.152420	124.500977	51.286385
Çalışma-8	21.027927	707.427734	9.153835	124.467796	51.401507
Çalışma-9	21.027927	707.427734	9.152428	124.456055	51.495178
Çalışma-10	21.027927	707.427734	9.154242	124.443810	51.240336
Çalışma-11	21.027927	707.427734	9.157562	124.601051	51.166923
Çalışma-12	21.027927	707.427734	9.153080	124.473816	51.404829
Çalışma-13	21.027927	707.427734	9.155869	124.521812	53.972429
Çalışma-14	21.027927	707.427734	9.151921	124.460793	51.467951
Çalışma-15	21.027927	707.427734	9.150661	124.383301	51.492429
Çalışma-16	21.027927	707.427734	9.151567	124.399452	51.187638
Çalışma-17	21.027927	707.427734	9.150584	124.371910	51.249344
Çalışma-18	21.027927	707.427734	9.150790	124.421776	51.408161
Çalışma-19	21.027927	707.427734	9.152858	124.433525	51.505043
Çalışma-20	21.027927	707.427734	9.150372	124.389076	54.245016
Çalışma-21	21.027927	707.427734	9.151662	124.398041	51.619870
Çalışma-22	21.027927	707.427734	9.154080	124.505562	51.326758
Çalışma-23	21.027927	707.427734	9.154661	124.522972	51.749480
Çalışma-24	21.027927	707.427734	9.153104	124.497932	51.550149
Çalışma-25	21.027927	707.427734	9.152639	124.505768	51.277746
Çalışma-26	21.027927	707.427734	9.151433	124.425537	52.393641
Çalışma-27	21.027927	707.427734	9.153373	124.499390	51.341013
Çalışma-28	21.027927	707.427734	9.154636	124.534485	51.041205
Çalışma-29	21.027927	707.427734	9.154012	124.541046	51.903283
Çalışma-30	21.027927	707.427734	9.150099	124.376717	51.709610
Ortalama	21.027927	707.427734	9.152829	124.463027	51.596985
Minimum	21.027927	707.427734	9.150099	124.371910	50.660955
Maksimum	21.027927	707.427734	9.157578	124.601051	54.245016

EK-3

Tablo 16. 392×512 boyutlarındaki görüntülerin GTX 980 ekran kartında GPBM yöntemi ile filtreleme sonuçları

Referans Görüntü	Ortalama Sonuçlar				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
b1	23.212959	745.759460	7.811954	102.737000	103.091320
b2	21.314375	694.742493	8.348015	121.223326	103.035306
b3	22.804947	730.034363	7.734155	99.741165	98.551440
b4	23.354650	753.052734	7.793245	101.038412	98.536374
b5	23.346487	751.717468	7.672215	97.931055	98.479003
b6	23.045013	742.233093	7.851873	102.349969	98.521361
b7	22.892311	730.594238	7.657575	97.586883	98.503886
b8	22.945986	737.304871	7.799071	100.934488	98.499178
b9	22.000557	706.942200	7.892844	108.588825	98.448810
b10	22.357943	708.008789	7.477479	96.394677	98.506008

Tablo 17. 728×896 boyutlarındaki görüntülerin GTX 980 ekran kartında GPBM yöntemi ile filtreleme sonuçları

Referans Görüntü	Ortalama Sonuçlar				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
b1	21.032328	707.393494	9.166356	124.508362	320.200919
b2	21.139565	704.623718	8.899775	120.255300	320.086338
b3	20.822115	694.432617	8.866483	118.420225	331.569886
b4	21.470327	705.595642	8.400788	110.993002	320.863577
b5	22.207413	691.675293	7.171082	88.723058	321.328793
b6	20.483974	679.733215	8.641557	122.894124	320.399157
b7	21.210541	702.154602	8.643784	115.908943	320.875527
b8	21.009665	702.532776	9.004043	121.626859	305.960251
b9	21.150202	700.911072	8.658703	116.150746	604.969674
b10	21.071907	697.591614	8.636376	116.601631	343.866918

Tablo 18. 392×512 boyutlarındaki görüntülerin RTX 2080Ti ekran kartında GPBM yöntemi ile filtreleme sonuçları

Referans Görüntü	Ortalama Sonuçlar				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
b1	23.218668	746.931885	7.812566	102.999305	20.350211
b2	21.434424	698.391887	8.325851	120.773843	20.344847
b3	22.793894	729.224121	7.721108	99.694466	20.312718
b4	23.331335	751.775330	7.782602	100.799204	20.090583
b5	23.308878	749.526672	7.641728	97.104914	20.462168
b6	23.051245	742.594727	7.853137	102.282598	20.071453
b7	22.893782	730.748962	7.661565	97.494533	20.083484
b8	22.968079	738.557312	7.745981	99.617146	20.102121
b9	21.991156	706.000061	7.888361	108.676343	20.294469
b10	22.331606	706.602234	7.434003	95.446601	20.162470

Tablo 19. 728×896 boyutlarındaki görüntülerin RTX 2080Ti ekran kartında GPBM yöntemi ile filtreleme sonuçları

Referans Görüntü	Ortalama Sonuçlar				
	İlk MAE - MSE		MAE – MSE Değerleri		Hesaplama Zamanı
	MAE	MSE	MAE	MSE	Zaman (sn.)
b1	21.027927	707.427734	9.152829	124.463027	51.596985
b2	21.161049	705.695801	8.928385	120.918549	51.737547
b3	20.853737	696.024963	8.874193	118.643851	52.061929
b4	21.470398	705.843262	8.410303	111.314235	52.624431
b5	22.182251	690.458008	7.150327	88.072630	52.639089
b6	20.461405	678.879333	8.620800	122.146444	52.392587
b7	21.172972	700.266113	8.619108	115.487672	52.446010
b8	21.008596	702.235840	9.005715	121.806988	52.550570
b9	21.163921	701.293945	8.655714	116.197845	52.492173
b10	21.077312	698.052551	8.598975	115.743117	52.660269

EK-4

ICONDATA
INTERNATIONAL CONFERENCE ON DATA SCIENCE & APPLICATIONS

03-06 EKİM 2019



KAZ DAĞLARI
EDREMIT, BALIKESİR



Özet Gönderim Son Tarihi
30 Haziran 2019

Son Kayıt Tarihi
16 Eylül 2019

Erken Kayıt Son Tarihi
31 Mayıs 2019

Tam Metin Gönderim Son Tarihi
30 Eylül 2019



GEMBA akademi
Eğitim ve Danışmanlık Hizmetleri

zenginveri

EK 4.1

Beyin MR Görüntülerinin İyileştirilmesi için Kuadratik Tabanlı Görüntü Filtresi Geliştirilmesi

Süleyman UZUN^{1*}, Emre DANDIL¹, Esin KARAGÖZ²

¹ Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Bilecik, Türkiye

² Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Bilecik, Türkiye

Özet

Volterra filtrelerinin ikinci dereceden açılmış hallerinden Kuadratik tabanlı görüntü filtreleri elde edilir ve bu tip filtreler doğrusal olmayan filtreler sınıfının en iyi bilinenidir. Doğrusal olmayan karakteristiklere sahip görüntülerin temizlenmesinde doğrusal filtrelere göre daha iyi sonuç üretirler. Bu çalışmada, beyin MR görüntülerinin iyileştirilmesi amacıyla Kuadratik tabanlı görüntü filtre temelli yeni bir tasarım gerçekleştirilmiştir. Kuadratik tabanlı görüntü filtrelerin maske ağırlıkları çalışmada kullanılan her bir beyin MRI görüntü için ayrı ayrı Genetik algoritmalar ile eğitiler hesaplanmıştır. Hesaplanan filtre ağırlıkları kullanılarak beyin MR görüntüleri filtrelenmiş ve iyileştirilen görüntüler elde edilmiştir. Aynı beyin MR görüntüleri medyan filtre kullanarak filtrelenmiş ve elde edilen görüntü kaliteleri Kuadratik tabanlı görüntü filtreleri ile karşılaştırılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, Kuadratik tabanlı görüntü filtresinin beyin MR görüntülerindeki tümörlü bölgelerin belirlenmesi ve bu bölgelerinin kenarlarının daha iyi korunduğu görülmüştür.

Anahtar Kelimeler: Kuadratik görüntü filtreleri, MR görüntüleri, beyin tümörleri, genetik algoritmalar, görüntü iyileştirme

Development of Image Filter Based on Quadratic Filter for Enhancement of Brain MR Scans

Abstract

Quadratic-based image filters are determined from the second order of Volterra filters, and such filters are the best known of the nonlinear filters class. They produce better results than linear filters in the removal of noise with non-linear characteristics. In this study, a new design based on Quadratic-based image filter has been realized in order to improve brain MR images. The mask weights of the quadratic-based image filters were calculated by genetic algorithms for each brain MRI image used in the study. The brain MR images were filtered using the computed filter weights and the improved images were obtained. The same brain MR images were filtered using a median filter and the obtained image quality was compared with quadratic-based image filters. According to the results obtained in the experimental studies, it was observed that the quadratic-based image filter detected the tumor regions on the brain MR images and the edges of these regions were better protected.

Keywords: Quadratic image filter, MR images, remove noise, brain tumors, genetic algorithms, image improvement

* İletişim e-posta: suleyman.uzun@bilecik.edu.tr

EK 4.2

Veri Bilim Derg, 2(2), 34-38, 2019

VERİ BİLİMİ DERGİSİ
www.dergipark.gov.tr/veri



Beyin MR Görüntülerinin İyileştirilmesi için Kuadratik Görüntü Filtre Tasarımı

Süleyman UZUN^{1*}, Emre DANDIL¹, Esin KARAGÖZ²

¹ Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Bilecik, Türkiye

² Bilecik Şeyh Edebali Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği, Bilecik, Türkiye

Özet

Doğrusal olmayan filtreler sınıfına ait Volterra filtrelerinin bir alt sınıfı olan Kuadratik görüntü filtreleri, doğrusal olmayan karakteristiklere sahip görüntülerin işlenmesinde doğrusal filtrelere göre daha iyi sonuç üretirler. Bu çalışmada, Kuadratik görüntü filtreleri kullanılarak beyin MR görüntülerin iyileştirilmesi için bir filtre tasarlanmıştır. Çalışmada kullanılan Kuadratik görüntü filtrelerinin maske ağırlıkları farklı eğitim görüntüleri üzerinde Genetik Algoritmalar ile eğitilerek belirlenmiştir. Hesaplanan ağırlıklar kullanılarak beyin MR görüntüleri filtrelenerek iyileştirilen görüntüler elde edilmiştir. Tasarlanan filtrenin başarısını ölçmek için aynı görüntüler medyan filtre ile filtrelenerek görüntü kaliteleri bir birleri ile karşılaştırılmıştır. Deneysel çalışmalarda elde edilen sonuçlara göre, önerilen filtrenin görüntülerdeki tümörlü bölgelerin tespiti ve bu bölgelerinin kenarlarının daha iyi korunduğu görülmüştür.

Anahtar Kelimeler: Kuadratik görüntü filtreleri, MR görüntüleri, beyin tümörleri, genetik algoritmalar, görüntü iyileştirme

Makale Bilgisi

Başvuru:
30/10/2019
Kabul:
13/12/2019

Quadratic Image Filter Design for Improving Brain MRI Images

Abstract

Quadratic image filters, a subclass of Volterra filters belonging to the class of non-linear filters, produce better results than linear filters in the processing of images with non-linear characteristics. In this study, a filter was designed to improve brain MR images using quadratic image filters. The mask weights of the quadratic image filters used in the study were determined by training with Genetic Algorithms on different training images. The brain MR images were filtered using the computed weights to obtain improved images. In order to measure the success of the designed filter, the same images were filtered with a median filter and the image quality was compared with each other. According to the results obtained in the experimental studies, it was seen that the suggested filter was detected and the edges of these regions were better protected.

Keywords: Quadratic image filter, MR images, remove noise, brain tumors, genetic algorithms, image improvement

* İletişim e-posta: suleyman.uzun@bilecik.edu.tr

** Bu çalışmanın bir kısmı ICONDATA 2019 konferansında sözlü olarak sunulmuştur.