



TIP TEKNO'17

TIP TEKNOLOJİLERİ KONGRESİ

12-14 Ekim 2017 / TRABZON

Karadeniz Teknik Üniversitesi, Prof.Dr. Osman Turan Kongre Merkezi



Biyomedikal ve Klinik
Mühendisliği Derneği



Elektrik-Elektronik Mühendisliği Bölümü
Bilgisayar Mühendisliği Bölümü

Biyomedikal Görüntü İşleme 3

14 Ekim 2017 - 09.00-10.30 - Salon A

MR İmgelerinde Doku Analizi Kullanılarak DEHB Hastalığının Sınıflandırılması

Classification of ADHD by Using Textural Analysis of MR Images

Gülây ÇİÇEK¹, Aydın AKAN², Zeynep ORMAN³

¹Biyomedikal Mühendisliği Bölümü, İstanbul Üniversitesi, İstanbul, Türkiye
ebrar_yolcu@hotmail.com

²Biyomedikal Mühendisliği Bölümü, İzmir Katip Çelebi Üniversitesi, İzmir, Türkiye
aydin.akan@ikc.edu.tr

³Bilgisayar Mühendisliği Bölümü, İstanbul Üniversitesi, İstanbul, Türkiye
ormanz@istanbul.edu.tr

Özetçe— Dikkat eksikliği hiperaktivite bozukluğu (DEHB) milyonlarca çocuğu etkileyen zihinsel bir hastalıktır. DEHB, belirtilerinin kişiden kişiye farklılık göstermesi nedeniyle teşhis edilmesi zordur. Bu çalışmanın amacı, insan çabasını en aza indirgeyerek doktorların bu hastalığı teşhis etmesine yardımcı olabilecek nesnel bir araç geliştirmektir. NP İstanbul Nöropsikiyatri hastanesinden 26 kişiye ait beyin MR verileri toplanmıştır. MR imgelerinden öznelik çıkarmak amacıyla iki ayrı veri kümesi oluşturulmuştur. Bunlar gri seviye eş oluşum matrisi veri kümesi (GLCM dataset) ile Haralick doku öznelikleri (Haralick texture feature dataset) veri kümesidir. Temel bileşenler analizi yardımı ile baskın öznelikler belirlenmiş ve kullanılmıştır. Sınıflandırma işlemleri K-en yakın komşu, Naive Bayes ve Karar ağacı algoritması ile yapılmıştır. Sınıflandırma başarımı 5 kat çapraz doğrulama ve dışarda bırakma yöntemleri ile incelenmiş, duyarlılık ve özgüllük değerleri hesaplanarak değerlendirilmiştir.

Anahtar Kelimeler — sınıflandırma; gri seviye eş oluşum matrisi; haralick doku öznelikleri; temel bileşenler analizi; dikkat eksikliği hiperaktivite bozukluğu; k en yakın komşu algoritması.

Abstract— Attention deficit hyperactivity disorder (ADHD) is a mental disorder that affects millions of children. It is difficult to diagnose because symptoms of ADHD differ from person to person. The aim of this study is to develop an objective tool that can help physicians to diagnose this disease by minimizing the human effort. Brain MR images from 26 individuals from NP Istanbul Neuropsychiatry Hospital were collected. Two separated dataset is created in order to extract features from magnetic resonance images. These are gray level co-occurrence matrix dataset and Haralick texture features dataset. The most useful features are determined by Principal Component Analysis. K-nearest neighbor, Naive Bayes and Decision Tree algorithms are used for classification. Performance of the model is tested by cross validation and hold out methods, and evaluated by using sensivity and specificity values.

Keywords — classification; gray level co-occurrence matrix; principle component analysis; attention deficit hyperactive disorder; k nearest neighbor algorithm.

I. GİRİŞ

Dikkat eksikliği hiperaktivite bozukluğu (DEHB) milyonlarca çocuğu etkileyen zihinsel bir bozukluktur [1]. Yapılan çalışmalar bu bozukluğun, sadece çocukluk çağı ile sınırlı kalmayıp yetişkinlik çağında da devam ettiğini tespit etmiştir. DEHB'li çocuklar aşırı hareketli olabilirler, dürtülerini kontrol etmekte zorluk yaşarlar veya dikkatlerini kolayca toparlayamayabilirler. Bazı durumlarda bu üç temel belirti birlikte görülürken, bazılarında herhangi ikisi beraber görülür.

Dünya Sağlık Örgütü'nün yapmış olduğu araştırmaya göre, 2011 yılı itibarıyla 4 ila 17 yaş arasındaki (6,4 milyon) çocuğun yaklaşık %11 ine dikkat eksikliği hiperaktivite tanısı konmuştur [2]. Özellikle bu bozukluğun erkek çocuklarda kızlara nazaran 2-3 kat daha fazla olduğu tespit edilmiştir.

Fiziksel hastalıkların aksine bu hastalığın teşhisi kolay olmamaktadır. Uzmanlar DEHB tanısı koymak için birçok test yaparlar. Öncelikle, kişilerin farklı durumlarda ve zamanlarda ki davranışlarını öğrenmek amacıyla ailelerinden ve öğretmenlerinden bilgiler toplanır [3]. Klinik gözlemler ve muayeneler yapılır. Bu sonuçlar, kişinin yaşına göre yapılan psikometrik testler ile birleştirilerek teşhis konmaya çalışılır. Bu çalışmada dikkat eksikliği hiperaktivite bozukluğunun tespiti için nesnel bir araç geliştirilerek insan çabasını en aza indirecek bir sınıflandırma yöntemi önerilmektedir. Bu amaçla, beyin yapısal manyetik rezonans (MR) imgeleri üzerinde gri seviye eş oluşum matrisi hesaplanarak sınıflandırma yapılmaktadır.

II. LİTERATÜR ÖZETİ

Diğer psikolojik hastalıkların aksine DEHB konusunda son yıllarda birkaç çalışma yapılmıştır. Bu bölümde literatür taramasına dayalı olarak DEHB konusundaki çalışmalarını inceleyeceğiz.

Dikkat eksikliği hiperaktivite bozukluğunun teşhisi için Che-Wei Chang ve Chien-Chang Ho 2012 yılında yapısal ve fonksiyonel manyetik rezonans görüntüleri üzerinde doku analizi yöntemiyle dikkat eksikliği hiperaktivite bozukluğunu sınıflandırmıştır. Beyin görüntülerinden öznelik çıkarmak

Biyomedikal Görüntü İşleme 3

14 Ekim 2017 - 09.00-10.30 - Salon A

İçin yerel ikili örüntü yöntemi kullanılmıştır. Destek Vektör Makine yöntemi ile DEHB'nin sınıflandırılması için çalışmalar yapılmıştır. Bu çalışmada, toplam 436 erkekten beyin görüntüleri alınmıştır. Bu verilerin 210 tanesi DEHB'li kalanı ise sağlıklı kişilere ait beyin görüntüleridir. Sistemde elde edilen en yüksek doğruluk oranı 0.69 olarak tespit edilmiştir [4].

Diğer bir çalışma, J. Anuradha ve N. Jayasri tarafından 2012 yılında gerçekleştirilmiştir. 100 kişiden alınan anket bilgileri ile Weka içerisinde yüklü olan karar ağaçları sınıflandırma algoritması kullanılarak DEHB'nin teşhisi için bir model geliştirilmiştir. Elde edilen başarı oranı 0.98 olarak kaydedilmiştir. Yüksek bir başarı elde edilmesine rağmen oluşturulan model nesnel olmadığı için güvenilir değildir [5].

Bir diğer çalışma, S. Dey, A. Ravishankar ve M. Shah tarafından gerçekleştirilmiştir. Bu çalışmada ADHD-200 veri kümesinden 947 kişiye ait fonksiyonel manyetik rezonans görüntüleri alınmıştır. Eğitim kümesinde 776 kişiye ait beyin görüntüleri mevcut iken, test kümesine 171 kişiye ait beyin görüntülerine yer verilmiştir. Temel bileşenler analizi ve lineer diskriminant analizi yöntemleri kullanılmıştır. Sistemin sınıflandırma başarısı 69.69%'dır [6].

Dikkat Eksikliği Hiperaktivite bozukluğu için özniteliklere dayalı hiyerarşik kümeler algoritma çalışması B. Tripathy ve J. Anuradha tarafından 2014 yılında gerçekleştirilmiştir. Yanlış teşhis ve tanı konulmamış vakaların çok yaygın olması gerekçesiyle böyle bir çalışma gerçekleştirmişlerdir. UCI makine öğrenme havuzundan, 6 ila 13 yaşındaki 100 çocuğa ait anket verileri alınarak hiyerarşik kümeleme algoritmaları yöntemi ile bir model oluşturulmuştur. Sınıflandırma başarısı % 97 olarak tespit edilmiştir. Anket verileri nesnel bir araç oluşturmada başarılı olmadığı için tercih edilen bir yöntem olmayacaktır [7].

L. A. Rohde ve J. R. Sato tarafından 2014 yılında ADHD-200 veri kümesinden 609 kişinin fonksiyonel manyetik rezonans görüntüleri kullanılarak DEHB'lilerin belirlenmesi için bir model geliştirilmiştir. Öznitelik çıkarmak için graf teorisi yöntemine başvurulurken sınıflandırma yapmak için destek vektör makineleri kullanılmıştır. Elde edilen başarı oranı % 61'dir [8].

III. MALZEME VE YÖNTEM


Önerilen yöntemin işlem basamakları Şekil 1. de görülmektedir.



Şekil 1. Yöntemin İşlem Basamakları

A. Veri Toplama

Bu çalışmada, NPIstanbul Nöropsikiyatri Hastanesinde kayıt edilen 26 adet yapısal manyetik rezonans (sMRI) imgeleri kullanılmıştır. Bunlardan 15 tanesi DEHB'li ve 11 tanesi ise sağlıklı çocuklara ait beyin imgeleridir. Şekil 2.a) DEHB, b) Sağlıklı(Kontrol) grubuna ait örnek beyin imgesini temsil etmektedir.



a) DEHB b) Kontrol
Şekil 2. Örnek beyin imgeleri

B. Öznitelik Çıkarma

Öznitelik çıkarma işlemi, orijinal veri kümesinden imgeyi en iyi temsil edecek yeni öznitelikler dizisi oluşturur. Sınıflandırma işleminde ham verinin her bir boyutu da öznitelik olarak kullanılabilir. Ancak bu durumda birçok istenmeyen sonuç ortaya çıkabilmektedir. Örneğin; modelin karmaşıklığı ve işlem yükü artarken, sınıflandırma başarımları azalabilmektedir.

Bu çalışmada gri seviye eş oluşum matrisi (GLCM) ve Haralick Doku öznitelikleri yöntemi ile manyetik rezonans imgelerinde öznitelikler çıkarılmıştır.

1) Gri Seviye Eş Oluşum Matrisi

İmge dokusu, piksel yoğunluklarındaki (gri değerler) mekânsal varyasyonun bir fonksiyonu olarak tanımlanır. Diğer bir deyişle, dokuyu, imge yoğunluğundaki yerel değişimlerin tekrarlanan desenleri olarak tanımlayabiliriz.

Doku analizi ile imgeden öznitelikler çıkartılarak imge karakterize edilir. Bu çalışmada doku analiz yöntemlerinden biri olan gri seviye eş oluşum matrisi (gray level co-occurrence matrix, GLCM) kullanılmıştır. Gri seviye eş oluşum matrisi, ikinci dereceden doku öznitelikleri çıkarmak için kullanılan bir yöntemdir. Gri seviye uzamsal bağımlılık matrisi olarak bilinen GLCM ile imge üzerindeki komşu pikseller arasındaki ilişki açıklanabilmektedir [9]. Şekil 3. te bu ilişki kolayca görülmektedir.

GLCM fonksiyonu ile belli bir değerdeki piksel çiftlerinin belirli bir uzaysal ilişki içerisinde ne kadar sıklıkta meydana geldiği hesaplanarak imgenin dokusu tanımlanır. GLCM matrisinde tutulan bu bilgilerden sınıflandırmada kullanılacak öznitelikler çıkartılmaktadır.

Biyomedikal Görüntü İşleme 3

14 Ekim 2017 - 09.00-10.30 - Salon A



Şekil 3. GLCM

Sekil. 3'te A Matrisinin 1.satır 1. sütununda bulunan 1 değeri ile 1 satırın 2. sütununda bulunan 1 değerlerinin yan yana tekrar etme sayısı GLCM matrisinin 1. satır 1. sütununa yazılır. Diğer bir deyişle, iki sayının beraber bir araya gelme sıklığı GLCM matrisinde tutulur.

Bu çalışmada, gri seviye eş oluşum matrisi yöntemi ile, beyin MR imgelerinden zıtlık, ilinti, enerji ve homojenlik öznelikleri elde edilmiştir.

Zıtlık (Contrast): Gri düzeydeki eş oluşum matrisindeki yerel varyasyonları ölçer.

$$Zıtlık = \sum_{i,j} |i - j|^2 p(i, j) \quad (1)$$

İlinti (Correlation): Bütün bir imge üzerinde ilgili pikselin gri seviye değeri ile belirlenen renk arasındaki lineer bağımlılığı ölçer.

$$İlinti = \sum_{i,j} \left(\frac{(i-M_i)(j-M_j)p(i,j)}{\sigma_i \sigma_j} \right) \quad (2)$$

Enerji (Energy): Açısıl ikinci momentum olarak bilinen bu terim GLCM matrisindeki elemanların karelerinin toplamı olarak hesaplanır.

$$Enerji = \sum_{i,j} p(i, j)^2 \quad (3)$$

Homojenlik (Homogeneity): İmgenin farklı bölgelerindeki benzerliğin ölçüsüdür.

$$Homojenite = \sum_{i,j} \frac{p(i,j)}{1+|i-j|} \quad (4)$$

Denkleme (1-4) de ifade edilen, i ve j matrisin satır ve sütun indislerini, p belirttiği GLCM elemanını ve σ standart sapmayı μ ise ortalamayı gösterir.

2) Haralick Doku Öznelikleri

Haralick doku öznelikleri en çok bilinen ve yaygın olarak kullanılan doku analizi yöntemlerinden biridir. Bu öznelıklar, ilk olarak yapısal manyetik imgeler kullanılarak Alzheimer hastalığının tespitinde kullanılmıştır. Daha sonra, birçok hastalığın teşhisi için bu öznelıklarından yararlanılmıştır. Dokuyu karakterize etmek için kullanılan bu yöntem ile verilen bölgenin gri seviye histogramının ikinci derecede istatistiğine dayanılarak öznelıklar çıkarılır. Bu öznelıklar şunlardır: Açısıl İkinci Moment(Angular Second Moment), Kontrast(Contrast), Korelasyon(Correlation), Kareler Toplamı(Sum of Squares), Varyans(Variance), Ters Fark Momenti(Inverse Difference Moment), Toplam Ortalama(Sum

Average), Toplam Varyans (Sum Variance), Entropi(Entropy), Fark Varyansı (Difference Variance), Fark Entropisi (Difference Entropy), Birinci korelasyon ölçüsünün bilgisi (Info. Measure of Corr. I) ve İkinci korelasyon ölçüsünün bilgisi(Info. Measure of Corr. II) dir.

C. Öznelik Seçme

Öznelik Seçimi, bir veri kümesinin boyutunu küçültmenin bir işlemidir. Yüksek boyutlu verilerin varlığında ya da performans düşüklüğü durumunda çok yararlıdır. Öznelik seçimi ile boyut azaltımına gidilerek alanın daha iyi anlaşılması sağlanır.

Bu çalışmada, Temel Bileşen Analizi (TBA) yardımı ile baskın öznelıklar belirlenmiş ve sınıflandırma aşamasında kullanılmıştır.

Yaygın olarak kullanılan bir istatistiksel teknik olan Temel Bileşenler Analizi, geniş veri kümesindeki öznelıkları azaltmak için kullanılır. Boyut azaltılması sırasında bazı veriler kaybolabilir. Amaç, boyutsal azalma sırasında ilgili bilgileri mümkün olduğunca koruyabilmektir.

D. Sınıflandırma

Sınıflandırma verileri önceden tanımlanmış gruplara eşleştirir.

Bu çalışmada, k-en yakın komşu algoritması, naive Bayes ve karar ağacı algoritmaları kullanılmıştır.

Sınıflandırma problemlerinin çözümünde kullanılan karar ağacı teknikleriyle sınıflandırma sürecini modellemek için bir ağaç oluşturulur. Tekniğin iki temel basamağı vardır; ağaç oluşturulması ve ağacın veritabanına uygulanması. Eğitim kümesindeki nesnelar ile ağaç yani model oluşturulur. Test kümesindeki nesnelar modele uygulanarak nesneların sınıfı bulunur.

Çalışmada kullanılan diğer bir algoritma ise naive Bayes teorime dayanan Naive Bayeste değişkenlerin birbirinden bağımsız olduğu savunulmaktadır [10]. Eğitim kümesindeki her bir nesnenin sınıfı bilinmektedir. Bu veriler üzerinden olasılık işlemleri yapılır. Daha önce elde edilen olasılık işlemlerine göre test nesnesinin hangi sınıfta olduğu tespit edilir.

K En yakın komşu algoritması uygulaması kolay güçlü sınıflandırma algoritmalarından biridir. Veri kümesi içerisinde, nesneların birbirleriyle olan benzerliğini bulmak için, nesnelar arasındaki mesafe bilgisi hesaplanır. K değeri belirlenerek, test nesnesine benzer en yakın kaç tane örneğe bakılması gerektiği belirlenir. Test verisinin, eğitim kümesindeki her bir elaman ile olan uzaklığı bulunur. En yakın k komşuya bakılarak test verisinin sınıfı bulunur.

Çalışmamızda, iki ayrı veri kümesi oluşturulmuştur. Bunlar gri seviye eş oluşum matrisi(GLCM) veri kümesi ile haralick doku öznelikleri veri kümesidir. GLCM veri kümesinde zıtlık, ilinti, enerji ve homojenlik öznelikleri mevcuttur. Haralick veri kümesinde ise açısıl ikinci moment, kontrast, korelasyon, kareler toplamı, varyans, tek fark momenti, toplam ortalama, toplam varyans, tek fark momenti, toplam ortalama, toplam varyans, entropi, fark varyansı, fark entropisi, birinci korelasyon ölçüsünün bilgisi ile İkinci korelasyon ölçüsünün bilgisi öznelikleri mevcuttur.



Biyomedikal Görüntü İşleme 3

14 Ekim 2017 - 09.00-10.30 - Salon A

IV. DENEYSSEL SONUÇLAR

Gri seviye eş oluşum matrisi veri kümesi ile Haralick doku öznelikleri veri kümesi üzerinde Dikkat Eksikliği Hiperaktivite bozukluğunun tespitine yönelik farklı senaryolar tasarlandı.

K en yakın komşu algoritması, Naive Bayes ve Karar Ağacı sınıflandırma algoritmaları kullanılarak her bir algoritmanın performansına bakıldı. Ve aynı zamanda bu algoritmalarla birlikte temel bileşenler analizi kullanılarak, boyut azaltımı yapıldı.

Veri kümelerinde bütün öznelıklar kullanılarak oluşturulan modelde, 5 kat çapraz doğrulama yöntemi ile veri kümesi 5 bölüme ayrılmış. İlk aşamada ilk bölüm test, diğerleri eğitim amacı ile kullanılırken, diğer aşamalarda test için kullanılan bölüm, eğitim amaçlı kullanılmış ve diğer bölümler test amacıyla kullanılmıştır.

Veri kümelerinde seçili öznelıklar kullanılarak oluşturulan modelde, dışarıda bırakma yöntemi ile veri kümesinin yarısı model oluşturulmak için kullanılmıştır. Temel bileşenler analizi ile boyut azaltımına gidilerek, performans artırılmıştır. Tablo I. incelediğinde GLCM veri kümesi üzerinde, temel bileşenler analizi kullanılarak boyut azaltımına gidilmiş ve k en yakın komşu sınıflandırma algoritması kullanılarak dikkat eksikliği hiperaktivite bozukluğunun tespiti için en iyi model oluşturulmuştur.

TABLE I.
DENEY1'İN KARMAŞIKLIK MATRİSİ VE DETAYLI PERFORMANS SONUCU

Çözümleme Yöntemi	Test Veri Kümesi	Doğruluk	Öznelikler	Performans
GLCM	KNN bütün öznelikler ile	0.50%	0.36%	0.60%
	KNN seçil öznelikler ile	1%	1%	1%
	KNN bütün öznelikler ile	0.53%	0.60%	0.45%
	KNN seçil öznelikler ile	0.41%	1%	0%
Naive Bayes	Naive Bayes bütün öznelikler ile	0.27%	0%	0.45%
	Naive Bayes seçil öznelikler ile	0.41%	0%	0.71%
	Naive Bayes bütün öznelikler ile	0.23%	0%	0.45%
	Naive Bayes seçil öznelikler ile	0.66%	0.85%	0.40%
Karar Ağacı	Karar Ağacı bütün öznelikler ile	0.31%	0.31%	0.40%
	Karar Ağacı seçil öznelikler ile	0.41%	0.40%	0.42%
	Karar Ağacı bütün öznelikler ile	0.53%	0.62%	0.36%
	Karar Ağacı seçil öznelikler ile	0.66%	0.71%	0.60%

Tablo I. de görüldüğü gibi, naive bayes ve karar ağaçları algoritmasının sınıflandırma başarımı düşüktür. Naive Bayes ve karar ağacı algoritmalarında sınıflandırma doğruluğunun yüksek olması, eğitim setindeki nesne sayısının fazla olmasına bağlıdır. Bu çalışmada eğitim setindeki veri sayısı bu algoritmalar için yeterli değildir. Aynı zamanda veri kümesinde gürültülü verilerin olması durumu da modelin performansını olumsuz etkilemektedir. Fakat veri kümesinde temel bileşenler analizi uygulanarak performansı olumsuz etkileyen öznelıkların veri kümesinden çıkarılması ile yeni bir veri seti elde edilmiştir. Elde edilen veri setine, k en yakın komşu algoritması uygulanması halinde sınıflandırma

doğruluğu en yüksek sonuçları vermiştir. Bu sonuçlar Tablo I'de verilmiştir.

V. TARTIŞMA VE SONUÇLAR

Dikkat eksikliği hiperaktivite bozukluğu milyonlarca çocuğu etkileyen zihinsel bir hastalıktır. Bu hastalığın yanlış teşhis edilmesi veya tanı konulmaması durumu, kişilerin hayatları tehdit eden komplikasyonlara neden olabilir. Dolayısıyla, teşhisinde kullanılacak yaklaşım, nesnel ve güvenilir bir model olmalıdır. Bu nedenle 26 kişinin yapısal manyetik rezonans imgeleri, NPIstanbul NeuroPsikiyatri Hastanesinden alınmıştır. Nesneların en iyi şekilde karakterize edilmesi için gri seviye eş oluşum matrisi ile haralick doku öznelikleri yöntemi kullanılmıştır. Sınıflandırma performansını olumsuz etkileyen öznelıkların belirlenip elenmesi için Temel Bileşen Analizi yöntemine başvurulmuştur. K en yakın komşu algoritması, Karar Ağacı ve Naive Bayes sınıflandırıcı ile modeller geliştirilmiştir. Önerilen yöntemin başarımının değerlendirilmesi için sınıflandırma oranı, duyarlılık ve özgüllük değerleri hesaplanmıştır. Eğitim ve test kümesinde 5 kat çapraz doğrulama ve dışarıda bırakma yöntemleri kullanılmıştır. En yüksek başarımla, veri setine temel bileşenler analizi uygulandıktan sonra k en yakın komşu sınıflandırıcının kullanımı ile elde edilmiştir. Modelin duyarlılık ve özgüllük oranı 100 % olarak hesaplanmıştır.

KAYNAKLAR

- [1] Hoseini, B. L., Abbasi, M. A., Moghaddam, H., T., Khademi, G., and Saeidi, M., "Attention Deficit Hyperactivity Disorder (ADHD) in Children: A Short Review and Literature", *International Journal of Pediatrics*, Vol.2,2014.
- [2] Visser, S., Danielson, M., Bitsko, R., Holbrook, J., and Michael, D. "Trends in the parent-report of health care provider-diagnosed and medicated attention-deficit/hyperactivity disorder: United States, 2003-2011", *Psychiatry*, 2005.
- [3] Gualtieri, G., and Johnson, G. L., "ADHD: Is Objective Diagnosis Possible?", *Psychiatry*, 2005.
- [4] Chang, C. W., Ho, C. C., and Chen, J. H., "ADHD Classification By a Texture Analysis of Anatomical Brain MRI Data", *Frontier in Systems Neuroscience*, Vol.6,66,2012.
- [5] Anuradha, J., Jayasri, N., and Arulalan, K. V., "Classification Rules for Attention Deficit Hyperactive Disorder using Decision tree", *International Journal of Computer Science & Communication Networks*, Vol.2, 295-303, 2012.
- [6] Dey, S., Rao, A., and Shah, M., "Exploiting the brain's network structure in identifying ADHD subjects", *Frontier in Systems Neuroscience*, Vol. 16:6:75,2012.
- [7] Tripathy, B., and Anuradha, "Hierarchical Clustering Algorithm Based on Attribute Dependency for Attention Deficit Hyperactive Disorder", *International Journal of Intelligent Systems Technologies and Applications*, 2014.
- [8] Siqueira, A. S., Junior, C. E., and Comfort W., E., "Abnormal Functional Resting-State Networks in ADHD: Graph Theory and Pattern Recognition Analysis of fMRI Data", *BioMed Research International*, Vol.2014.
- [9] Yali, H., Xiaoxia, H., Xiuli, T., Zhen, Zhao, Jinhui, Z., and Dongmei, H., "Texture Analysis of Ultrasonic Liver Images based on spation domain methods", *Image and Signal Processing*, 2010.
- [10] Isabelle, G., and Amir, S., "Compression-Based Averaging of Selective Naive Bayes Classifiers", *Journal of Machine Learning*, 2007.