



Histopatoloji Görüntülerinde Hücre Tiplerinin Yerel İkili Örüntüler Kullanılarak Sınıflandırması

Classification of Cell Types on Histopathological Images Using Local Binary Patterns

Hatice Sumeyye Ozer, Ceyda Demir ve Gokhan Bilgin

Yıldız Teknik Üniversitesi

Bilgisayar Mühendisliği Bölümü

34220 İstanbul, Turkey

htc.ozr14@gmail.com, ceydademirbolu@gmail.com, gbilgin@yildiz.edu.tr

Özetçe —Son yıllarda sayısal patoloji alanında bilgisayar destekli teşhis (BDT) sistemlerinin kullanımı yüksek bir ivme ile artış göstermektedir. Zamanla genişleyen kullanım ve çalışma alanları arasında ise çekirdeklerin bulunması, sınıflandırılması ve bölütlenmesi yer almaktadır. Bu çalışmada CRC kolon kanseri veri kümesi üzerinde çeşitli geleneksel makine öğrenmesi (k-en yakın komuluk, rastgele ormanlar ve destek vektör makineleri) ve derin öğrenme (evrimsel sinir ağı) karşılaştırmalı olarak kullanılmıştır. Geleneksel makine öğrenmesi algoritmaları evrimsel sinir ağı gibi iki boyutlu bir girdi almadığı için yerel ikili görüntülerden yararlanılmıştır. Sonuç olarak makine öğrenmesi algoritmaları için öznelite çıkarımı yapıldığında KNN ve RF algoritmaları çok başarılı sonuçlar verirken, öznelite çıkarımı yapılmadan CNN algoritması daha iyi sonuç vermiştir.

Anahtar Kelimeler—Histopatolojik görüntüler, evrimsel yapay sinir ağı, sınıflandırma, yerel ikili örüntüler.

Abstract—In recent years, the use of computer aided diagnostic (CAD) systems has been increasing with a high acceleration in the field of digital pathology. Application and study areas are expanding over time include the detection, classification and segmentation of nuclei. In this study, various traditional machine learning methods (k-closest neighborhood, random forests and support vector machines) and deep learning (convolutional neural network) were used comparatively on CRC colorectal adenocarcinomas dataset. Since conventional machine learning algorithms do not receive a two-dimensional input such as convolutional neural network, local binary images are utilized. As a result, when the feature extraction for machine learning algorithms is performed, KNN and RF algorithms provide very successful results, whereas CNN algorithm gave better results without making any feature extraction.


Keywords—Hisopathological images, convolutional neural network, classification, local binary patterns.

I. GİRİŞ


Yüksek çözünürlüklü sayısal histopatolojik görüntülerden hücre özelliklerinin analizi, kanser teşhisi ve prognozu için standart klinik uygulamadır. Ancak, patologların hücresel yapıları bu şekilde manuel olarak incelemeleri oldukça yorucu

bir süreçtir. Bu yorucu ve zaman alıcı sürecin otomatikleştirilmesi, literatürdeki histopatolojik görüntü işleme çalışmaları doğrultusunda yeni ortaya çıkan bir alanı oluşturmaktadır. Histopatoloji, dokuların mikroskopik olarak histolojik teknikler kullanılarak incelenmesidir. Kanser gibi daha birçok hastalığın kesin ve doğru teşhisi için oldukça önem arz etmektedir. Kanser ise günümüzde, dünya çapında, büyük bir sağlık problemidir. Sayısal patoloji, modern tıp alanındaki en büyük gelişmelerden biridir. Bilgisayar destekli teşhis (BDT) sistemleri görüntü işleme ve makine öğrenmesi teknikleri kullanılması ile patologların daha tutarlı ve verimli sonuçlar elde etmelerine imkân verir. Fazla karmaşık olan histopatolojik doku örneklerinin patologlar tarafından incelenmesi, bu görüntüler üzerinde uzmanların teşhis koyması oldukça zorlu ve vakit alıcı bir işlemdir. Bunun yanısıra derin öğrenme yöntemleri ile alanında uzman kişilerin özellik çıkarıcılar tasarlamasına gerek kalmadan verinin ayırt edici bilgileri elde edilebilir ve organizasyonu daha verimli biçimde sağlanabilir [1].

Bu çalışmada CRC kalın bağırsak (kolorektal adenokarsinom) kanserine ait 100 adet boyanmış histoloji görüntüsünü kullanılmıştır [2]. Veri kümesi üzerinde yapılmış olan temel çalışmada çekirdek tanıma ve sınıflandırma işlemleri birlikte yapılmıştır. Çekirdek tanıma için SC-CNN (spatially constrained CNN) ve SR-CNN (structural regression CNN), sınıflandırma işleminde ise softmax CNN SSPP (Standard Single-Patch Predictor) ve NEP (Neighboring Ensemble Predictor) kullanılarak farklı kombinasyonlar üzerinden sonuçlar karşılaştırılmıştır. Çalışmada sunulan verilere göre çekirdek tanıma işleminde SC-CNN, sınıflandırma işleminde ise softmax CNN+NEP uygulanması durumunda en yüksek F1-score değeri elde edilmiştir [2]. Histopatolojik görüntülerde tümörlü bölgelerin sınıflandırılması üzerine çok sayıda çalışma günümüze kadar yapılmıştır ve yapılmaya da devam edilmektedir. CNN kullanılarak yapılan bir çalışmada yapay sinir ağının mimarisi farklı pencere boyutları seçilerek oluşturulmuş ve bu parametrenin sonuçlara etkisi incelenmiştir [3]. Pencere boyutu artırıldığında sınıflandırma başarı oranının azaldığı bunun yanında pencere boyutu düşürüldüğünde CNN modelinin daha hızlı öğrenebildiği gözlemlenmiştir. Birbirinden farklı, düzgün dağılım göstermeyen veri setlerinde sınıflandırma işlemi için çeşitli yapay sinir ağı mimarileri kullanılan çalışmalar incelenmiştir. Özellik çıkarımı sonrasında sınıflandırma



Şekil 1: (a) Orijinal ve (b) hücre çekirdekleri işaretli örnek görüntüler



Şekil 2: Hücre tiplerine ilişkin örnek görüntüler

işlemi gerçekleştirilen bir çalışmada iki farklı sınıftan eşit sayıda örnek alındığı ve alınmadığı durum karşılaştırılmıştır. Dengesiz dağılım olan çalışmada F-ölçütü değeri %67 iken, iki sınıftan eşit sayıda örnek kullanılan durumda F-ölçütü değeri %87 olarak elde edilmiştir [4]. İncelenen bir çalışmada göğüs kanseri görüntülerinde şekil, doku ve çekirdek boyutu ağı eğitmek için özellik olarak kullanılırken [5] - [6] bir diğer çalışmada mitotik ve mitotik olmayan hücreleri ayırt etmek için renk, şekil ve doku özellikleri kullanılarak CNN ağı eğitilmiştir [7]. Başka bir çalışmada ise H&E boyalı kanser hücreleri üzerinde oluşturulan ağın eğitilmesi için morfolojik özellikler kullanılmıştır [8].

II. VERİ KÜMESİ

Kullanılan CRC veri kümesi 100 adet H&E boyalı kolorektal adenokarsinom resminden oluşmaktadır [2]. Tüm görüntüler 500×500 boyutlarındadır ve dokuz farklı hastaya ait 10 adet Omnyx VL120 ile taranmış tüm-slayt (whole-slide) görüntülerden üst üste gelmeyecek şekilde kırılarak elde edilmiştir. Görüntüler üzerindeki çekirdeklerin merkezleri deneyimli bir patoloj tarafından saptanmış ve etiketlenmiştir. Şekil 1'de görüntülerin orijinal hali ve çekirdekli işaretlenmiş hali görülmektedir. Görüntülerde 22444 hücre çekirdeği merkezi sınıf etiketi ile belirtilmiştir [2].

Sınıf etiketleri; epitel, fibroblast, iltihaplı ve farklı tipleri belirtmek için "diğer" olarak belirlenmiştir ve örneklerin sınıflar arası dağılımı Şekil 2'de gösterilmiştir. İltihaplı olarak belirtilen hücre çekirdekleri lenfosit plazma, nötrofil ve eozinofil içerir. "Diğer" olarak belirtilen hücre çekirdekleri ise adiposit, mitotik şekil, ölü hücre çekirdeği vb. olabilir.

Bu görüntüler sınıf etiketlerine göre ait oldukları sınıf

klasörlerinde toplanmıştır ve hücre çekirdeklerinin orijinal resmin kenarlarında bulunma ihtimaline karşı alınan parçalar üzerinde 27×27 boyutuna göre yeniden boyutlandırma (resize) işlemi uygulanmıştır. Veri kümesinde 7722 epitel, 5712 fibroblast, 6971 iltihaplı ve 2039 adet diğer olarak etiketlenmiş hücre çekirdeği vardır. Çalışmada daha çok görüntü ile daha yüksek doğrulukta sonuçlar alınacağından veri büyüme yoluna gidilmiştir. Görüntüler üzerinde 90-180-270 derece döndürme ve yansıtma işlemleri uygulanarak veri kümesinin büyüklüğü beş katına çıkarılmıştır. Bu durumda 112.220 adet görüntü üzerinde çeşitli derin öğrenme algoritmaları uygulanmıştır. Veri arttırımı öncesi ve sonrasında elde edilen görüntü sayısı ve sınıflar arası dağılımı Tablo I'de belirtilmiştir.

Tablo I: Etiketli hücre sayısının sınıflara göre dağılımı

Hücre çeşitleri	Veri arttırımı öncesi	Veri arttırımı sonrası
Epitel	7722	38610
Fibroblast	5712	28560
İltihaplı	6971	34855
Diğer	2039	10195
Toplam	22444	112220

III. ÇALIŞMADA KULLANILAN YÖNTEMLER

A. Evrişimsel Sinir Ağı (Convolutional Neural Networks, CNN)

- Evrişimsel Katmanlar (Convolutional Layers): CNN ağının ilk katmanı evrişimsel katmandır. Çalışmada ağı oluşturulurken dört farklı evrişim katmanı kullanılmıştır. Bu katman, belirtilen boyutta ve sayıda filtreler kullanarak görüntü özniteliklerini öğrenir ve giriş görüntüsü üzerinde pikseller arasındaki ilişkiyi belirleyebilir. Kısaca görüntü üzerinden öznitelikler çıkarılmasını sağlar ve öznitelik haritalarını (feature maps) oluşturur. Kullanılan modelde aktivasyon fonksiyonu olarak "ReLU" fonksiyonu kullanılmıştır. Bu fonksiyon negatif değerlerin 0 değeri olarak, pozitif değerlerin ise oldukları gibi geçmesini sağlar [9].
- Havuzlama Katmanı (Pooling Layer): Bu katman kullanılan evrişimsel katmanlar ile oluşturulan öznitelik haritalarının boyutunun azaltılmasını sağlar. Modelde kullanılmış olan maksimumu-havuzlama (max pooling) katmanı girdi olan içeriğin en büyük değerini bir sonraki katmana aktararak içeriğin indirgenmesini sağlar. Havuzlama katmanı daha çok büyük görüntüler kullanıldığında parametre sayısının azaltılmasını sağlayarak eğitim sürecinin hızlanmasına yardımcı olur. Giriş olarak kullanılan görüntüler büyük boyutlarda olmamasına rağmen eğitimin daha hızlı gerçekleşmesi ve daha anlamlı niteliklerin değerlendirilebilmesi için modelde bu katmanlara yer verilmiştir. Böylece eğitim kümesi üzerinde ezberlemenin (overfitting) engellenmesine de yardımcı olur.
- Tam Bağlı Katman (Fully Connected Layers): Bu katman modelin farklı yerlerinde bulunur. En sonda yer alan tam bağlantı katmanı kendisine gelen özellik haritasından bir vektör oluşturur. Aktivasyon fonksiyonu olarak ise 'softmax' kullanılır. Bu katmana sınıf sayısı parametre olarak verilir ve model için sınıflama işlemi burada gerçekleşir. Çıkış katmanı olarak da söylenebilir [10].

B. Destek Vektör Makineleri (Support Vector Machines, SVM)

SVM, sınıflandırma veya regresyon problemleri için kullanılabilen denetimli bir makine öğrenmesi algoritmasıdır. Çoğunlukla sınıflandırma için kullanılır. Sınıflandırma için bir düzlemde bulunan iki grup arasında bir sınır çizilerek iki gruba ayırmak mümkündür. Bu sınırın çizileceği yer ise iki grubun da üyelerine en uzak olan yer olmalıdır. SVM bu sınırın nasıl çizileceğini belirler. Bu işlemin yapılması için iki gruba da yakın ve birbirine paralel iki sınır çizgisi çizilir ve bu sınır çizgileri birbirine yaklaştırılarak ortak sınır çizgisi üretilir [11].

C. K-En Yakın Komşu (K-Nearest Neighbor, KNN)

KNN, denetimli öğrenmede sınıflandırma ve regresyon için kullanılan algoritmalarından biridir. En basit makine öğrenmesi algoritması olarak kabul edilir. Diğer denetimli öğrenme algoritmalarının aksine, eğitim aşamasına sahip değildir. KNN ile temelde sınıflandırılacak olan noktaya en yakın K adet noktanın sınıf bilgilerine bakılarak sınıf tahmini yapılır.

D. Rastgele Orman (Random Forest, RF)

Rastgele Orman algoritması denetimli bir sınıflandırma algoritmasıdır. Algoritma, rastgele olarak bir orman yaratmaktadır. Algoritmadaki ağaç sayısı ve elde edebileceği sonuç arasında doğrudan bir ilişki bulunmaktadır. Ağaç sayısı arttıkça kesin bir sonuç elde edilir. Hem sınıflandırma hem de regresyon uygulamalarında kullanılabilir [12].

E. Yerel İkili Örüntü (Local Binary Patterns, LBP)

LBP yerel uzamsal yapıyı betimlemede kullanılan bir operatördür ve dokunun yerel olarak gösterimini hesaplar. Bu yerel gösterim, her pikseli, kendisini çevreleyen komşu piksellerle karşılaştırarak oluşturulur. Algoritmada ilk adım olarak görüntü gri seviyelerine (grayscale) dönüştürülür. Gri görüntüdeki her piksel için kendisini çevreleyen r boyutundaki komşuları dikkate alınır. Bu merkez piksel için bir LBP değeri hesaplanır. Giriş görüntüsü ile aynı boyutlarda iki boyutlu bir dizi oluşturulur. Bu LBP stringlerini oluşturma ve daha sonra LBP dizisine kaydetme işlemi görüntüdeki her piksel için tekrarlanır ve LBP dizisinin histogramı oluşturulur [13].

F. k-katlamalı Çarpaz Doğrulama (k-Fold Cross Validation)

Veri setinin eğitim ve test set olarak ayrılmasının amacı, olası ezberlemeden kaçınmak ve modelin daha önceden görmediği veri seti üzerinde nasıl performans gösterdiğini anlamaktır. Fakat modelin eğitim ve test aşamasında dağılımdan kaynaklı bazı hatalar olabilir. Bu hataları minimum seviyeye indirmek için k-fold cross validation tekniği kullanılır. Eğitim veri setini rasgele k parçaya böler. Sonrasında k-1 parça eğitim için kullanılırken, geri kalan bir parçada test seti için kullanılır ve k defa bu işlem tekrar eder ve ortalama alınarak modelin performansı değerlendirilir. Bütün algoritmalarda k-fold (k=5) değeri ile çalıştırılmıştır.

IV. DENEYSEL SONUÇLAR

Algoritmaları çalıştırırken farklı parametre değerleri için çalıştırılabilen algoritmalar için optimizasyonu sağlayabilmek

amacıyla birden fazla değerle denemeler yapılmıştır. Parametreler seçilirken farklı değerlerin sonucu nasıl etkileyebileceğini gözlemlemek adına, algoritmalarda girdi olarak verilebilen değerler küçük ve büyük artışlar yapılarak değiştirilmiş ve parametrelere göre sonuçlar karşılaştırılmıştır. Tablo II'de KNN algoritmasını farklı komşuluk değerlerini ifade eden k değeri üzerinde değişiklik yapıldığında ve öznelik çıkarımı uygulandığında sonucun nasıl değiştiği gösterilmiştir.

Tablo II: KNN algoritması LBP özellik çıkarımı başarı karşılaştırması

	k = 1	k = 3	k = 5	k = 7
KNN	0.54	0.55	0.56	0.57
LBP & KNN	0.99	0.98	0.89	0.69

Tablo III, RF algoritmasının ağaç sayısını ifade eden $n_{estimators}$ parametre değeri değiştirildiğinde sonuçların nasıl değiştiğini göstermektedir ve bu algoritmaya LBP uygulandığında sonuçların nasıl değiştiği gösterilmiştir.

Tablo III: RF algoritması LBP özellik çıkarımı başarı karşılaştırması

	n = 1	n = 10	n = 100	n = 200
RF	0.51	0.65	0.69	0.70
LBP & RF	0.96	0.98	0.99	0.99

CNN algoritmasının ise farklı boyutlar için elde edilen sonuçları Tablo IV'te gösterilmiştir.

Tablo IV: Farklı boyutta görüntülerle eğitilen CNN algoritması başarıları

	9 × 9	13 × 13	17 × 17	27 × 27	32 × 32
CNN	0.68	0.73	0.76	0.83	0.78

Öznelik çıkarımı yapılmadan çalıştırılan makine öğrenme algoritmaları ve CNN algoritmasının başarı oranları Tablo V'te verilmiştir. Bu sonuçlar incelendiğinde en yüksek başarının CNN algoritmasından alındığı görülmektedir.

Tablo V: Başarı oranı karşılaştırma tablosu

Algoritma	Başarı Oranı
CNN	0.82
KNN(N=7)	0.57
SVM	0.70
RF	0.70

Tablo VI ise makine öğrenmesi uygulamalarında LBP kullanılarak elde edilen sonuçlar gösterilmiştir. Sonuçlar incelendiğinde KNN ve RF algoritmalarında %99 gibi yüksek başarıya ulaşılırken SVM algoritmasında bu sayı LBP'siz değere göre oldukça düşük sonuç vermiştir.

Tablo VI: LBP uygulanmış veriler ile RF, SVM, KNN başarıları

Yöntem	LBP uygulanmadan	LBP uygulanarak
SVM	0.70	0.47
RF ($n_{est} = 200$)	0.70	0.99
KNN (k = 1)	0.53	0.99

SVM, RF, KNN algoritmalarının karmaşıklık matrisleri alınmıştır. Tablo VII, Tablo VIII, Tablo IX ve Tablo X'da karmaşıklık matrisleri görülmektedir. Matrisler incelendiği zaman en çok doğru sonucun epitel hücreleri için üretildiği görülmektedir. Diğer etiketli sınıfta hücre tipleri için ise tahminlerin çok başarılı olmadığı görülmektedir. Diğer sınıfta veri sayısı öteki sınıflardan büyük ölçüde az olduğu ve veriler birbirine öteki sınıflardan daha az benzediği için daha az doğru tahmin üretmiş olması muhtemeldir.

Tablo VII: RF sınıf karmaşıklık matrisi

	Epitel	Fibroblast	İltihaplı	Diğer
Epitel	6210	776	601	32
Fibroblast	1283	3517	997	63
İltihaplı	965	860	5005	89
Diğer	373	698	843	132

Tablo VIII: 1-NN sınıf karmaşıklık matrisi

	Epitel	Fibroblast	İltihaplı	Diğer
Epitel	5097	2037	188	297
Fibroblast	566	4266	439	289
İltihaplı	1699	2249	2648	323
Diğer	366	1096	414	170

Tablo IX: 7-NN sınıf karmaşıklık matrisi

	Epitel	Fibroblast	İltihaplı	Diğer
Epitel	5553	1965	73	28
Fibroblast	904	4747	191	18
İltihaplı	2083	2449	2367	20
Diğer	403	1255	366	22

Tablo X: SVM sınıf karmaşıklık matrisi

	Epitel	Fibroblast	İltihaplı	Diğer
Epitel	6305	630	684	0
Fibroblast	961	3780	1082	37
İltihaplı	819	654	5429	17
Diğer	268	811	860	107

Her yöntem her veri kümesi için çok yüksek sonuçlar üretemeyebilmektedir. CRC veri kümesi için en düşük sonuçlar KNN algoritmasıyla elde edilmiştir. Birbirinden farklı algoritmalar, birbirine yakın sonuçlar üretilmektedir. Örneğin, SVM ve RF algoritmaları CRC veri kümesi için birbirine yakın sonuçlar üretmiştir. Bu durumda bu iki algoritmayı farklı bir değerlendirme ölçütüyle karşılaştırmak gerekir. Tablo XI'de algoritmaların çalışma zamanlarına yer verilmiştir. Bu iki algoritmanın çalışma zamanlarına bakıldığında SVM 6 saat gibi büyük bir zaman diliminde sonuç vermiş, RF ise 15 dakika gibi az bir zamanda çalışmasını tamamlamıştır. CNN algoritması ise en yüksek başarı oranını vermektedir ve bir buçuk saat gibi bir sürede çalışmasını tamamlamaktadır. Kullandığımız yöntemler arasında hem başarı oranı hem de çalışma zamanı olarak diğer algoritmaların önüne geçmiştir.

V. SONUÇ

Gerçekleştirilen çalışmada histopatolojik doku görüntüleri üzerinde farklı makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak hücre tipleri sınıflandırılmıştır. Gerçeklenen algoritmaların elde edilen verilerle eğitilmesi ve sınıflandırma

Tablo XI: Kullanılan yöntemlerin ortalama çalışma zamanları

Yöntem	Çalışma zamanı
CNN	90 dakika
KNN(N=1)	150 dakika
KNN(N=7)	150 dakika
SVM	420 dakika
RF	15 dakika

sonuçlarının karşılaştırılması gerçekleştirilmiştir. Çalışma kapsamında CNN, SVM, KNN, RF algoritmaları kullanılmıştır. SVM, KNN ve RF algoritmaları için öznelik çıkarımı yapıp sonuçlar karşılaştırıldığında ise önceki sonuçlarla kıyasla SVM algoritması hariç daha iyi sonuçlar alınmıştır. Sonuç olarak makine öğrenmesi algoritmaları için öznelik çıkarımı yapıldığında KNN ve RF algoritmaları çok başarılı sonuçlar verirken, öznelik çıkarımı yapılmadan CNN algoritması daha iyi sonuç vermiştir.

KAYNAKÇA

- [1] N. Hatipoğlu and G. Bilgin, "Cell segmentation in histopathological images with deep learning algorithms by utilizing spatial relationships," *Medical & Biological Engineering & Computing*, vol. 55, no. 10, pp. 1829–1848, 2017.
- [2] K. Sirinukunwattana, S. E. A. Raza, Y.-W. Tsang, D. R. Snead, I. A. Cree, and N. M. Rajpoot, "Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images," *IEEE Trans. Med. Imaging*, vol. 35, no. 5, pp. 1196–1206, 2016.
- [3] K. Gunduz, A. Albayrak, G. Bilgin, and M. Karsligil, "Classification of tumor regions in histopathological images using convolutional neural networks," in *IEEE 26th Signal Processing and Communications Applications Conference, SIU'18*, 2018, pp. 1–4.
- [4] I. O. Sigirci, A. Albayrak, and G. Bilgin, "Detection of mitotic cells using completed local binary pattern in histopathological images," in *IEEE 23rd Signal Processing and Communications Applications Conference, SIU'15*, 2015, pp. 1078–1081.
- [5] J.-R. Dalle *et al.*, "Nuclear pleomorphism scoring by selective cell nuclei detection," in *IEEE Workshop on Applications of Computer Vision, WACV'09*, 2009.
- [6] E. Cosatto, M. Miller, H. P. Graf, and J. S. Meyer, "Grading nuclear pleomorphism on histological micrographs," in *IEEE 19th International Conference on Pattern Recognition, ICPR'08*, 2008, pp. 1–4.
- [7] C. D. Malon and E. Cosatto, "Classification of mitotic figures with convolutional neural networks and seeded blob features," *Journal of Pathology Informatics*, vol. 4, 2013.
- [8] Y. Yuan *et al.*, "Quantitative image analysis of cellular heterogeneity in breast tumors complements genomic profiling," *Science Translational Medicine*, vol. 4, no. 157, pp. 157ra143–157ra143, 2012.
- [9] L. Zheng, Y. Yang, and Q. Tian, "SIFT meets CNN: A decade survey of instance retrieval," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, vol. 40, no. 5, pp. 1224–1244, 2017.
- [10] T. Connie, M. Al-Shabi, W. P. Cheah, and M. Goh, "Facial expression recognition using a hybrid CNN-SIFT aggregator," in *International Workshop on Multi-disciplinary Trends in Artificial Intelligence*. Springer, 2017, pp. 139–149.
- [11] A. Kannan, V. Mohan, and N. Anbazhagan, "MR images classification using hybrid KNNSVM algorithm," *Signal Processing Research*, vol. 1, no. 1, pp. 7–14, 2012.
- [12] R. O'Brien and H. Ishwaran, "A random forests quantile classifier for class imbalanced data," *Pattern Recognition*, vol. 90, pp. 232–249, 2019.
- [13] S. Banerji, A. Verma, and C. Liu, "Lbp and color descriptors for image classification," in *Cross Disciplinary Biometric Systems*, 2012, pp. 205–225.