

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇÖLYAK HASTALIĞININ TEŞHİS EDİLMESİ VE  
SINIFLANDIRILMASINDA YAPAY ZEKÂ  
ALGORİTMALARININ KULLANILMASI**

**DOKTORA TEZİ**

**Manarbek SAKEN**

**Enstitü Anabilim Dalı** : **BİLGİSAYAR VE BİLİŞİM  
MÜHENDİSLİĞİ**  
**Tez Danışmanı** : **Prof. Dr. Nejat YUMUŞAK**

**Kasım 2020**

T.C.  
SAKARYA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**ÇÖLYAK HASTALIĞININ TEŞHİS EDİLMESİ VE  
SINIFLANDIRILMASINDA YAPAY ZEKÂ  
ALGORİTMALARININ KULLANILMASI**

**DOKTORA TEZİ**

**Manarbek SAKEN**

**Enstitü Anabilim Dalı : BİLGİSAYAR VE BİLİŞİM  
MÜHENDİSLİĞİ**

**Bu tez 18 / 11 /2020 tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile kabul edilmiştir.**

**Prof. Dr.  
Nejat YUMUŞAK  
Jüri Başkanı**

**Prof. Dr.  
Celal ÇEKEN  
Üye**

**Prof. Dr.  
Ayhan İSTANBULLU  
Üye**

**Doç. Dr.  
Metin VARAN  
Üye**

**Doç. Dr.  
Numan ÇELEBİ  
Üye**

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Manarbek SAKEN

23.10.2020

## TEŐEKKÜR

Doktora eđitimim boyunca deđerli bilgi ve deneyimlerinden yararlandığım, her konuda bilgi ve desteđini almaktan ekinmediđim, araŐtırmanın planlanmasından yazılmasına kadar tm aŐamalarında yardımlarını esirgemeyen, teŐvik eden, aynı titizlikte beni ynlendiren deđerli danıŐman hocam Prof. Dr. Nejat YUMUŐAK'a teŐekkrlerimi sunarım.

lyak hastalığı grnt verisetinin oluŐturulması, pataloji ve seroloji test sonularının elde edilmesi konusunda anlayıŐ ve yardımlarını esirgemeyen Darıca Farabi Eđitim ve AraŐtırma Hastanesi İ Hastalıkları Blm Doktoru Uz. Dr. Munkhtsetseg BANZRAGCH YAĐCI'ya, Endoskopik nite ve Pataloji Blmnn hekimler, hemŐireler ve tm diđer alıŐanlara destekleri ve yardımları iin sonsuz teŐekkr ederim.

# İÇİNDEKİLER

TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
SİMGELER VE KISALTMALAR LİSTESİ .....	v
ŞEKİLLER LİSTESİ .....	vi
TABLolar LİSTESİ .....	viii
ÖZET .....	ix
SUMMARY .....	x
BÖLÜM 1.	
GİRİŞ .....	1
BÖLÜM 2.	
KAYNAK ARAŞTIRMASI .....	8
2.1. Çölyak Hastalığı Endoskopik Görüntülerde Özellik Çıkartma ve Sınıflandırma Yöntemleri .....	8
2.1.1. Uzamsal alan özellikleri .....	8
2.1.2. Dönüşüm alan özellikleri .....	11
2.1.3. Ölçek değişmezliği özellikler .....	12
2.1.4. Uzaysal-zamansal özellikler .....	13
2.2. Çölyak Hastalığının Teşhisinde Derin Öğrenme Yöntemleri ve Güncel Çalışmalar.....	15
BÖLÜM 3.	
MATERYAL VE YÖNTEM .....	18
3.1. İnsan Hakları Beyanı .....	18
3.2. Materyal ve Endoskopik Görüntü Veri Seti .....	18

3.3. Yöntem .....	21
3.3.1. Endoskopik görüntüleme CAD sistemlerinin temel metodolojisi .....	21
3.3.2. ÇH'nın otomatik teşhisi için önerilen görüntü işleme yöntemleri .....	23
3.4. Analizler .....	24
3.4.1. Görüntü elde etme ve ön işleme .....	24
3.4.2. Bağlam tabanlı görüntü bölütleme .....	25
3.4.2.1. Enerji eğrisi .....	29
3.4.2.2. Otsu yöntemi .....	30
3.4.2.3. Guguk kuşu arama algoritması .....	31
3.4.3. Dalgacık dönüşüm tabanlı özellik çıkartma, seçme ve sınıflandırma .....	32
3.4.3.1. Ayrık dalgacık dönüşümü .....	33
3.4.3.2. Özellik çıkartma .....	47
3.4.3.3. Yerel ikili örüntüler .....	48
3.4.3.4. Yönlendirilmiş gradyanların histogramı .....	49
3.4.3.5. Hızlandırılmış sağlam özellikler .....	51
3.4.3.6. Özellik azaltma .....	54
3.4.3.7. Sınıflandırma .....	55
BÖLÜM 4.	
ARAŞTIRMA BULGULARI .....	57
4.1. Sınıflandırıcılar Performanslarının Karşılaştırılması .....	57
BÖLÜM 5.	
TARTIŞMA VE SONUÇ .....	60
5.1. Sonuç .....	60
5.2. Tartışma .....	62
5.2.1. Çalışmanın sınırlamaları .....	62
5.2.2. Tartışma ve gelecekteki çalışmalar .....	63

KAYNAKLAR .....	66
EKLER .....	78
ÖZGEÇMİŞ .....	83



## SİMGELER VE KISALTMALAR LİSTESİ

ÇH	: Çölyak hastalığı
CAD	: Bilgisayar destekli teşhis
DWT	: Ayrık dalgacık dönüşümü
CNN	: Evrişimli sinir ağı
HOS	: Yüksek dereceli spektral
GI	: Gastrointestinal
OCR	: Tüm sınıflandırma oranı
LBP	: Yerel ikili örüntüler
HOG	: Yönlendirilmiş gradyanların histogramı
SURF	: Hızlandırılmış sağlam özellikler
SFE	: Standart esnek endoskopi
WCE	: Kablosuz kapsül endoskopi
DL	: Derin öğrenme
CNN	: Evrişimsel sinir ağları
MIT	: Modifiye daldırma tekniği
WL	: Beyaz ışık aydınlatma
NBI	: Dar bantlı görüntüleme
SVM	: Destek vektör makineleri
MTH	: Çoklu seviyeli eşikleme
ECA	: Evrimsel hesaplama algoritması
CS	: Guguk arama algoritması
PCA	: Temel bileşenler analizi
HOS	: Yüksek dereceli spektral



## ŞEKİLLER LİSTESİ

Şekil 1.1. Sağlıklı ve hasarlı villusların temsili .....	2
Şekil 1.2. Çölyak buздаğı ve ÇH spektrumu .....	3
Şekil 1.3. Glüten yutulmasından bağırsak hasarına kadar çölyak hastalığında glütene uyarlanabilir bağışıklık yanıtının basitleştirilmiş şeması.....	4
Şekil 3.1. Gastroendoskopi ile elde edilen normal ve hasarlı duodenal mukoza görüntülerinden örnekler .....	20
Şekil 3.2. Endoskopik görüntü bozulmalarına örnekler .....	21
Şekil 3.3. Çölyak hastalığının otomatik teşhisinde mevcut CAD şemasının tipik metodolojisi .....	22
Şekil 3.4. Önerilen CAD algoritmasının şematik diyagramı .....	23
Şekil 3.5. Görüntü bölütlemeye uzamsal bağlam temelli optimal çok seviyeli enerji eğrisi eşiği .....	32
Şekil 3.6. Bir delta fonksiyonunun dalgacık dönüşümünün (a) büyüklüğü ve (b) fazı .....	38
Şekil 3.7. 2-Boyutlu, 1-oktavlı DWT .....	41
Şekil 3.8. Aşağı ve yukarı örnekleyici .....	42
Şekil 3.9. Filtre bankası .....	43
Şekil 3.10. Üç seviyeli 2D dalgacık dönüşümü için alt bant etiketleme şeması .....	43
Şekil 3.11. 1D ileri DWT'nin çalışma şeması .....	44
Şekil 3.12. 2-Boyutlu, 1-oktavlı DWT .....	45
Şekil 3.13. Görüntünün DWT ile piramidal ayrışması .....	46
Şekil 3.14. Bölütlenmiş görüntü üzerinde (a) normal ve (b) çölyak hastalığı örneklerinin üç seviyeli piramidal DWT alt bantlarının ayrışması ile elde edilen görüntü örnekleri .....	46

Şekil 3.15. Bölütlenmemiş görüntü üzerinde (a) normal ve (b) çölyak hastalığı örneklerinin üç seviyeli piramidal DWT alt bantlarının ayrışması ile elde edilen görüntü örnekleri .....	47
Şekil 3.16. KTH-TIPS2 veri tabanından tam buğday ve beyaz ekmek örnekleri ...	52
Şekil 4.1. (A) normal ve (b) çölyak hastalığının DWT alt bantlarının HOS bispektrum temsilleri .....	59



## TABLolar LİSTESİ

Tablo 2.1. Çölyak hastalığı için bilgisayar destekli tespit/tanılama sistemlerinde en çok kullanılan özellik çıkartma tekniklerine genel bakış .....	9
Tablo 2.2. ÇH'nın otomatik tanısında kullanılan özellik gösterimlerinin doğrulukları .....	15
Tablo 2.3. Güncel yaklaşımların karşılaştırılması .....	17
Tablo 3.1. Görüntü veritabanındaki görüntülerin ve hastaların dağılımı .....	19
Tablo 3.2. Tam buğday ve beyaz ekmeklerin 10 kat çapraz doğrulama stratejisini kullanan çeşitli sınıflandırıcıların performansları .....	53
Tablo 4.1. Mevcut görüntü veri setinde önerilen ve en güncel yöntemlerin karşılaştırılması .....	58

## ÖZET

Anahtar kelimeler: Çölyak hastalığının bilgisayar destekli teşhisi, tıbbi görüntü işleme, görüntü bölütlemesi, özellik çıkartımları, sınıflandırma

Yüksek bir oranda yaygınlık gösteren çölyak hastalığı (ÇH), tahıllardaki glüten ve diğer tahıl proteinlerine kalıcı bir intolerans olarak gelişen proksimal ince bağırsak hastalığıdır. Teşhis edilmesi en zor hastalıklardan biri olarak kabul edilir. Seroloji testi ve endoskopi sırasında alınan ince bağırsak biyopsilerinin histopatolojik kanıtı tanı için altın standart olmaya devam etmektedir. Bu nedenle, endoskopide bilgisayar destekli teşhis (CAD) sistemleri, hastalığın tanısal doğruluğunu artırmak ve zamandan ve insan gücünden tasarruf etmek için yeni ortaya çıkan bir teknolojidir. Bu çalışmada çölyak hastalığının CAD sistemi için hibrit bir makine öğrenme yöntemi uygulanmıştır.

Sunulan CAD sisteminde ilk olarak, görüntüleri bölütlemek için uzamsal bağlam temelli optimal çok düzeyli eşikleme tekniği kullanılmıştır. Daha sonra, görüntüler ayrık dalgacık dönüşümü (DWT) ile alt bantlara ayrıştırılmış ve ayırt edici özellikler ölçekle değişmeyen doku tanımlayıcı ile çıkartılmıştır.

Sınıflandırma doğruluğu, duyarlılığı ve özgüllük oranı sırasıyla %94,79, %94,29 ve %95,08 olarak elde edilmiştir. Önerilen modellerin sonuçları, evrişimli sinir ağı (CNN) ve yüksek dereceli spektral (HOS) analizi gibi diğer güncel yöntemlerin sonuçlarıyla karşılaştırılmıştır. Sonuçlar, önerilen hibrit yaklaşımların doğru, hızlı ve kabul edilebilir düzeyde olduğunu göstermiştir.

# **APPLICATION OF ARTIFICIAL INTELLIGENCE ALGORITHMS IN THE DIAGNOSIS AND CLASSIFICATION OF CELIAC DISEASE**

## **SUMMARY**

**Keywords:** Computer-aided diagnosis (CAD) of celiac disease, Multilevel thresholding, Image segmentation, Feature extractions, Classification.

Celiac disease (CD) is quite common and is a proximal small bowel disease that develops as a permanent intolerance to gluten and other cereal proteins in cereals. It is considered as one of the most difficult diseases to diagnose. Histopathological evidence of small bowel biopsies taken during endoscopy remains the gold standard for diagnosis. Therefore, computer-aided detection (CAD) systems in endoscopy are a newly emerging technology to enhance the diagnostic accuracy of the disease and to save time and manpower. For this reason, a hybrid machine learning methods have been applied for the CAD of celiac disease.

Firstly, spatial context-based optimal multilevel thresholding technique was employed to segment the images. Afterwards, images were decomposed into subbands with discrete wavelet transform (DWT), and the distinctive features were extracted with scale invariant texture recognition.

Classification accuracy, sensitivity and specificity ratio are 94.79%, 94.29% and 95.08% respectively. The results of the proposed models are compared with the result of other state-of-the-art methods such as convolutional neural network (CNN) and higher order spectral (HOS) analysis. The results demonstrate that the proposed hybrid approaches are accurate, fast and robust.

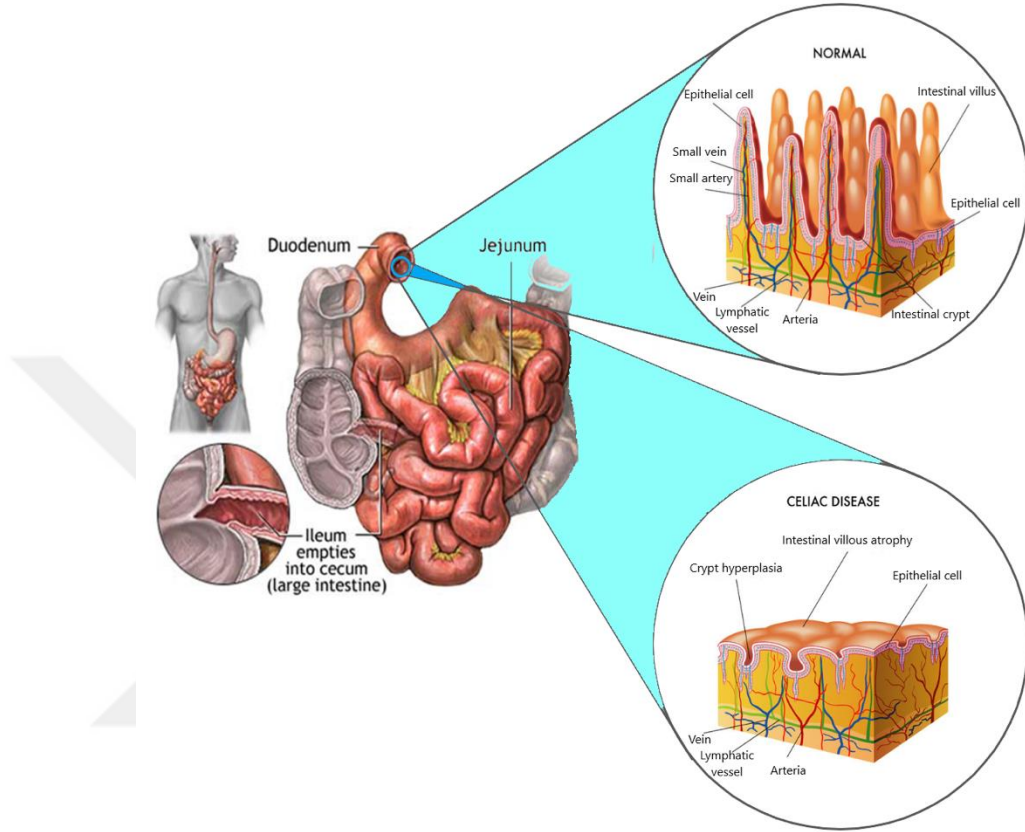
## BÖLÜM 1. GİRİŞ

Çölyak hastalığı (ÇH, gluten enteropatisi), dünya çapında genetik olarak duyarlı bireyleri etkileyen ince barsakta yaşam boyu süren, özellikle arpa, çavdar ve yulaf gibi tahıllarda gluten ve diğer gluten benzeri tahıl proteinlerine kalıcı bir toleranssızlık olarak gelişen otoimmün bir hastalıktır [1]. Yaşam boyu hastalıkların en sık görülen hastalıklarından biri olarak kabul edilir. Aynı zamanda oldukça yaygın ve teşhis edilmesi de zordur. Çölyak hastalığında klinik bulgular çok çeşitli gastrointestinal (GI) ve ekstraintestinal semptomlarda görülebilir veya semptom göstermeyebilir. Oldukça yaygın olduğu göz önüne alındığında, ÇH popülasyonun yaklaşık %0.7'sini (%95 güven aralığı (CI), %0.5-0.9;  $P<0.001$ ) [2] etkiler ve artan mortalite ve önemli morbidite ile ilişkili görünmektedir [3], bunların çoğu glutensiz diyet (gluten-free diet – GFD) tarafından önlenir veya geri döndürülebilir.

Kolay ve hızlı tanı yöntemlerinin gelişimine paralel olarak, ÇH sıklığı tüm dünyada artmaktadır. Nedeni bilinmemekle birlikte, prevalans kadınlarda erkeklerden daha yüksektir (%0,6'ya karşılık %0,4). Çocukların erişkinlerden anlamlı olarak daha yüksek prevalansa sahip oldukları (%0,9 ve % 0,5) da görülmektedir. Aynı zamanda, hastalığın sıklığı bölgeye göre değişmektedir. ÇH'nın bölgesel prevalansı Avrupa ve Okyanusya'da %0,8, Asya'da %0,6, Kuzey Amerika ve Afrika'da %0,5 ve Güney Amerika'da % 0,4'tür [2].

ÇH'nın patogenezi, genetik yatkınlığı olan bireylerde gluten alımının tetiklediği immünolojik reaksiyonların neden olduğu düşünülmektedir. Çölyak hastalığı ile insan lökosit antijenleri (HLA) sınıf II D arasında güçlü bir ilişki olduğu gösterilmiştir. HLA DQ2 ve HLA DQ8 pozitifleri, çölyak hastalığı ile ilişkili HLA alelleridir [4]. Genetik ve çevresel faktörler hastalığın ilerlemesini teşvik eder [5]. Şekil 1.1.'de gösterildiği gibi, ÇH'lı hastalarda, glutenin sindirim sistemine girmesi, glutene karşı immün bir


reaksiyon başlatır ve mukoza zarının iltihaplanmasının bir sonucu olarak villus kısalır (villus atrofi) [4]. Besinlerin malabsorpsiyonunun nedeni budur.



Şekil 1.1. Sağlıklı ve hasarlı villusların temsili. Kaynak: <https://www.bupa.com.au/health-and-wellness/health-information/az-health-information/coeliac-disease> ve <https://medlineplus.gov/ency/imagepages/19221.htm> sitelerinden modifiye edilmiştir.

Çölyak hastalığında klinik bulgular oldukça farklı ve değişkendir. Klinik polimorfizm nedeniyle, ÇH geniş bir gastrointestinal (klasik veya tipik) ve ekstraintestinal (atipik) semptomlara sahiptir. ÇH'ı, Dünya Gastroenteroloji Örgütü (World Gastroenterology Organisation – WGO) tarafından belirtildiği gibi klasik, klasik olmayan veya sessiz olarak bölünebilir [6]. Klasik grup kilo kaybı ve ishali içeren belirgin emilim belirtileri ve semptomları sunar. Klasik olmayan grup açıkça malabsorpsiyon belirtileri göstermeden hafif gastrointestinal semptomlar yaşar veya ilişkisiz semptomlar ile ortaya çıkar. Sessiz grup aynı zamanda asemptomatik çölyak hastalığı olduğu olarak da adlandırılır. Net semptomlar gösterilmez ancak hastalar ince bağırsaklarında villuz atrofi yaşarlar. Serolojik testler ve biyopsi bu grupta uyumludur demektir. *Latent:*

asemptomatik bireylerde seroloji pozitifdir ancak biyopside villuz atrofisi yoktur. *Potansiyel hastalık*: semptomatik hastalarda seroloji pozitifdir, ancak biyopsi negatiftir [7]. Semptomatik vakalara göre, asemptomatik olarak teşhis edilen vakaların daha fazla sayısı hastalığın “Buzdağı” modeline benzer olmasına neden olmuştur (Şekil 1.2.) [8].




Şekil 1.2. Çölyak buzdağı ve ÇH spektrumu.

ÇH'nın patogenezi geniş bir yelpazede bilinmektedir. ÇH'ı, genetik olarak yatkın kişilerde gliadin ve diğer ilgili prolamınlerin alınması ile tetiklenen intestinal bir enteropatidir [1]. İmmün mekanizmalar ÇH'nın patogenezinde ağırlıklı olarak vurgulanmaktadır ve Şekil 1.3.'te basitleştirilmiş şema şeklinde gösterilmiştir [4]. Gliadin peptidleri, gastrointestinal enzime dirençli oldukları için zararlı etkiler sergilerler, sınıf II majör histo-uyumluluk kompleksi olan *HLA DQ2/8*'e özgü amino asit dizilerine sahiptirler. Ayrıca, doku transglütaminaz (*tTG*) kaynaklı deamidasyon için tercih edilen glutamin kalıntıları vardır ve son olarak, bağırsak geçirgenliğini etkilerler. (1) Gliadin peptidleri epitel hücrelerinin tahrip olmasına neden olur, böylece interlökin-15 (*IL-15*) ekspresyonunu artırır ve bu artan epitelyal *IL-15* ekspresyonu intraepitelyal lenfositleri aktive eder. (2) Glüten peptidlerinin doku transglütaminaz (*tTG*) ile deamidasyonu edilmesi, (3) antijen sunan hücrelerin (*APC*) yüzeyindeki *HLA DQ2* veya *HLA DQ8*'e bağlanan güçlü immünostimülasyon epitoplara oluşturur ve (4)



$CD4+T$  hücrelerini aktif hale getirir. (5) Aktif hale getirilmiş  $CD4+T$  hücreleri, meofopblastlar tarafından metaloproteazların salınımını ve aktivasyonunu indükleyen ve (6) sonunda mukozanın yeniden modellenmesi ve villus atrofsisi ile sonuçlanan gamma interferon  $IFN-\gamma$  gibi esas olarak  $Th1$  sitokinleri salgılar. (7)  $CD4+T$  hücreleri ayrıca intraepitelyal lenfositlerin ( $IEL$ 'ler) veya doğal öldürücü ( $NK$ )  $T$  hücrelerinin sitotoksitesini de artırır, böylece enterosit apoptotik ölümüne neden olur. (8)  $Th2$  sitokinlerinin üretilmesiyle, aktive edilmiş  $CD4+T$  hücreleri aynı zamanda, plazma hücrelerine ( $P$ ) farklılaşan ve bağırsak hasarına katkıda bulunan glüten ve transglütaminaza karşı antikorlar üreten  $B$  hücrelerinin aktivasyonunu ve klonal genişlemesini de tahrik eder. Sonuç olarak,  $Th1$  ve  $Th2$  bağışıklık tepkileri tetiklenir ve bu da otoimmünite, mukozal iltihaplanma ve elverişsiz mikrobiyota büyümesi ile hastalığın prognozunu kötüleştirir [4].



Şekil 1.3. Glüten yutulmasından bağırsak hasarına kadar çölyak hastalığında glütene uyarlanabilir bağışıklık yanıtının basitleştirilmiş şeması (Lionetti ve Catassi, 2011).

ÇH tanısı, halihazırda modifiye Marsh sınıflandırması ve skorlaması kullanılarak Dünya Gastroenteroloji Örgütü Küresel İlkeleri'nin (2016) [6] önerilerine uygun olarak yapılmaktadır. Serolojik antikorların pozitif ve endoskopik duodenum biyopsisi yapıldıktan ve tipik histopatolojik özellikleri incelendikten sonra tanı konur [7]. Biyopsi materyalindeki karakteristik histopatolojik bulgular hala tanı için altın standarttır [1].

- Evre 0: İnfiltrasyon öncesi mukoza ve biyopsi normal belirlenir.
- Evre 1: Normal villus yapısına sahip artmış intraepitelyal lenfosit (*IEL+*).
- Evre 2: Artmış intraepitelyal lenfositler (*IEL+*) ve kript hiperplazisi ile ilişkili kısaltılmış villus yapısı.
- Evre 3: Bu evrede, artmış intraepitelyal lenfositlere kript hiperplazisi ve villusun büzülmesi (villus atrofi) eşlik eder. Bu evre 3 alt kategoriye ayrılır: 3a- hafif (light), 3b- belirgin (marked) 3c-düzleştirilmiş (flattened) mukoza.

Pozitif seroloji veya negatif serolojik testler sonucunda ancak güçlü klinik şüphe varsa, ince barsak biyopsisi önerilir. Endoskopide, duodenumda dairesel kıvrım sayısında azalma, mukozada mozaik ve nodüler kadife görünümünde azalma vardır [2], [9].

Doku analizi (texture analysis), görüntü işleme ve makine görme sistemlerinde önemli bir alandır. Bir sistem veya model, ölçeği ve yönlendirmeyi belirli bir miktarda değiştirerek sistemin şeklini veya özelliklerini değiştirmezse, ölçek değişmezliği varsayılır [10]. Mevcut doku analiz yöntemlerinin çoğu, doku görüntülerinin eşit bir perspektiften elde edildiği belirli veya kesin bir ortamda çalışır [11]. Bu, dokuların farklı çevirilerde, döndürmelerde veya ölçeklendirmede gerçekleştiği uygulamalar için bu yöntemlerin kullanışlı olmadığı bir sınırlama sağlar. Bazı ortamlarda, dokunun ölçeği ve yönü sürekli değişebilir. Bu nedenle ölçeklendirme ve yönlendirme değişmezliği metotlar hem teorik hem de pratik açıdan oldukça önemlidir ve bu tür yaklaşımlar önerilmiştir. Zhang ve Tan, 2002 [11] konuyla ilgili mevcut çalışmalarını sınıflandırmışlardır.

Çölyak hastalığının teşhisi için endoskopi yapılır, ardından 3-6 duodenal biyopsi alınır. Dahası, biyopsi ile endoskopi de dahil olmak üzere ÇH'nın tüm tanısallık çalışması zaman alıcı, maliyeti-yoğun ve hastalar için oldukça invaziftir. Bununla birlikte, ÇH'nın semptomları değişkendir ve bu nedenle doğru tanı koymak nispeten zordur [12]. Bu yüksek oranda yanlış tanı ile sonuçlanır [1]. Tüm hastaların yarısından fazlası tanı konmamış ve hastalığın farkında değildir. Teşhis ve tedavi oranını arttırmak için biyopsi dışında daha az maliyetle daha hızlı sonuç veren, kolay uygulanabilen (easy-to-perform) bir yöntem ihtiyacı vardır. Bu nedenle, zorlukların üstesinden gelmek için

bir CAD sistemi önerilmiştir. CAD desteği özellikle tıpta ve endoskopide yeni ortaya çıkan bir seçenektir. Sonuç olarak, prosedürün güvenliğini artırmak için zaman, maliyet ve işgücünü önleyen biyopsilerden kaçınarak minimum invaziv yöntemler kullanılması beklenir.

Endoskopi tarafından sağlanan görüntüler üzerinde görsel analiz yapmak mümkündür ve bu otomatik olarak bir CAD sistemi oluşturularak yapılabilir. Sonuç olarak, ÇH'nın teşhisinde ve sınıflandırılmasında kullanılan CAD sistemleri duodenal dokunun örüntü analizine (pattern analysis) dayanmaktadır [13].

Bu tür endoskopik teknikleri araştıran Cammarota ve ark., [12], [14] tarafından yapılan son çalışmalar güvenilir sonuçlar bildirmişlerdir. Mevcut teşhis yöntemleri tamamen gözlemciye bağlıdır ve önemli bilgi, uzmanlık ve zaman gerektirir. ÇH'nın teşhisi için mevcut altın standardının bir başka kısıtlaması, normal mukozanın ortasında ÇH'dan etkilenen bağırsak mukozası alanlarının düzensiz (patyetik) dağılımından kaynaklanmaktadır [15]. Eğer biyopsiler sadece duodenum içindeki sağlıklı mukoza bölgelerinden alınırsa, örnekleme hatasından dolayı ÇH'nın doğru teşhisi maalesef özlenecektir. Endoskopik video kliplerin bilgisayar destekli örüntü analizine (computer-aided pattern analysis) dayanan bir tanı aracı, tarafından zarar gören alanları gösterebilir ve böylelikle biyopside hedefleme doğruluğunu (targeting accuracy) geliştirebilir. Ek olarak, böyle bir sistem gastroenterologlara rutin olarak duodenal biyopsiler almasını ve biyopsi kararını tetikleyen mukozal değişimleri ayırt etmesini sağlar. Dolayısıyla, biyopsileri içeren bir teşhis senaryosunda bile, bilgisayar destekli video analizi daha güvenilir bir teşhise katkıda bulunur.

Endoskopik görüntüler çoğunlukla çeşitli ölçeklerde ve bakış açılarında elde edilir, bu nedenle değişmeyen doku analizleri tıbbi görüntü işleme için son derece önemlidir. Çünkü, endoskopist tarafından seçilen metodolojiye bağlı olarak, endoskopik görüntüler farklı açılardan ve ölçeklerden elde edilir. Çölyak hastalığının teşhis edilmesi ve sınıflandırılması için ölçek değişmezliği doku tanımlayıcılarını kullanan bir dizi çalışma aşağıdaki literatürlerde mevcuttur [13], [16]–[18].

Bu arařtırmalar sonucunda lek deęişmezlięi doku (scale invariant texture) sınıflandırma yaklaşımlara odaklanıyoruz ve H'nın CAD sistemini endoskopik görüntüler üzerinde makine ęrenme algoritmalarına dayanan bir hibrit sistemle öneriyoruz.



## **BÖLÜM 2. KAYNAK ARAŞTIRMASI**

### **2.1. Çölyak Hastalığı Endoskopik Görüntülerde Özellik Çıkartma ve Sınıflandırma Yöntemleri**

Tıbbi görüntü analizinde örüntü tanımada en sık karşılaşılan sorunlardan biri, bir dizi özelliklerin doğru sınıfa sınıflandırılmasıdır. Özellik çıkartımı ve seçimi çölyak hastalığı tespiti ve sınıflandırılmasında önemli adımlardır. Özellik çıkartımı, bir görüntünün kendi özellik kümesine dönüşümü olarak bilinir. Görüntünün yararlı özellikleri, sınıflandırma amacı için görüntüden çıkartılır. En iyi özellik kümesi etkili ve ayırt edici özelliklere sahip olmalıdır. Tablo 2.1.'de, 2008–2019 yılları arasında yayınlanan çölyak hastalığının özellik çıkartma ve sınıflandırma otomatik teknikleri üzerine bir anketi göstermektedir.

#### **2.1.1. Uzamsal alan özellikleri**

Esnek endoskopide, uzamsal alandaki görüntü gösterimlerine özel önem verilmiştir. ÇH'nın sınıflandırılması için özel olarak geliştirilmiş bir yöntem ise kenarları boyunca lokal eğriliği tarif eden ve duodenal villusun şeklini yakalaması beklenen sağlam şekil tabanlı özelliğe sahip olan Şekil-Eğrilik-Histogram (Shape-Curvature-Histogram (SCH)) metottur [19], [20] (tüm sınıflandırma oranına göre – overall classification rate OCR 85–87).

Ciaccio [21], yarı otomatik bir sistemde (OCR 64) endoskopik görüntülerde çatlak uzunluğunu açıkça ölçmüştür. El ile seçilen alt görüntülere dayanarak, morfolojik iskeletizasyon gerçekleştirilmiş. İskeletlenmiş çatlakların toplam uzunluğu daha sonra tek boyutlu bir özellik olarak kullanılmıştır.

Başka bir uygulanan daha genel amaçlı görüntü temsilleri kenar bilgisini açıklayan Edge Co-Occurrence Matrix'i içerir [19], [22] (OCR 86).

Tablo 2.1. Çölyak hastalığı için bilgisayar destekli tespit/tanımlama sistemlerinde en çok kullanılan özellik çıkarma tekniklerine genel bakış.

<b>Özellik çıkartma yöntemleri</b> (Feature Extraction Methods)			
<b>Uzamsal alan özellikleri</b>	<b>Dönüşüm alan özellikleri</b>	<b>Ölçek değişmezliği özellikler</b>	<b>Uzaysal-zamansal özellikler</b>
<b>(Spatial domain features)</b>	<b>(Transform domain features)</b>	<b>(Scale-invariant features)</b>	<b>(Spatio-temporal features)</b>
Local binary patterns (LBP) (OCR 83-86)	Wavelet-based LBP (OCR 88)	Local Fractal Dimension-MR8 (OCR 92)	Shape-from-shading
Extended Local Binary Patterns (ELBP)	Pyramidal wavelet transform (WPC)	Multi-Fractal-Spectrum (OCR 89)	Basis Image Statistics (OCR 71)
Local Ternary Patterns (LTP)	Best-Basis Centroids Base (WT-BBC)	Scale- and Orientation-Adaptive LBP	Volumetric Statistics (OCR 64)
Gray level Co-occurrence Matrix (GLCM)	Local Discriminant Basis (WT-LDB) (OCR 79.5-82.5)	Dense SIFT Features (OCR 83.5)	Wall Motility (OCR 59)
Shape-Curvature Histogram (SCH) (OCR 85-87)	Wavelet-Based GMRF (WT- GMRF Gaussian Markov Random Fields) (OCR 78.5-80.5)	Multiscale Blob Features (OCR 86)	Low-Discriminative Feature
Edge Co-occurrence Matrix (ECM)	Wavelet-Based Gabor Statistics	SCM (Spiking Cortical Model)	
Spatial Size Distribution (SSD) (OCR 90)	Correlation Signatures (OCR 82)	ICM (Intersecting Cortical Model)	
Gaussian Markov Random Fields (GMRF)	Fourier Statistics (OCR 82)	Matching of Gabor Features	
Joint-Color LBP (JC-MB-LBP)	MRF-Gaussian Markov Random Fields	DT-CWT	
Local Color Vector patterns (LCVP)		D <sup>3</sup> T-CWT	
Fractal Features (FRACTAL)			
Local Image Statistics (OCR 65)			
Pyramidal LBP (OCR 92)			

Klasik Haralick [19], [23] özellikleri ise Gri-düzey Ortak Oluşumu Matrisi (Gray-level Co-Occurrence Matrices) (OCR 87) ile hesaplanan ve görüntü ile aynı görüntünün Mekansal Boyut Dağılımı (Distribution of Spatial Size (SSD)) (OCR 90) kullanılarak morfolojik olarak dönüştürülmüş versiyonu arasındaki otokorelasyona dayanan özelliklerdir.

Uzamsal görüntü temsillerinin çok umut verici bir sınıfı, Yerel İkili Örüntüler (Local Binary Patterns (LBP)) dayanıyordu [24]. LBP, ikili örüntüler olarak kodlanan piksel komşularının dağılımı olarak görüntüleri temsil eder ve ÇH'nın sınıflandırılmasında (OCR 83) çok sağlam ve doğru olduğu gösterilmiştir [16], [25]–[29].

ÇH'nın bilgisayar destekli tanısı için çeşitli özel LBP varyasyonları geliştirilmiştir. Vécsei ve arkadaşları [30], özellikle endoskopik ortamlar için optimize edilmiş iki yeni LBP tabanlı metodoloji önermiştir. WT-LBP (OCR 88) yöntemi, farklı dalgacık alt bantlarını (wavelet subbands) uygun LBP tabanlı operatörler ile birleştirmek için tasarlanırken, ELTP (OCR 86) yöntemi ise sağlam Yerel Üçlü Örüntüler (Local Ternary Patterns (LTP [31])) faydalarını, yerel görüntü istatistiklerine dayanan adaptif bir eşikleme (adaptive thresholding) kullanarak, yüksek düzeyde ayırmacı (highly discriminative) Genişletilmiş Yerel İkili Örüntüler (ELBP [32]) ile birleştirir.

LBP tabanlı görüntü temsilleriyle [25] birlikte uygun kesme frekansları kullanılarak açık frekanslı filtreleme de araştırılmıştır (OCR 83-86). Hegenbart ve arkadaşları, [26] ölçek- (scale) ve oryantasyon- adaptif LBP-temsili hesaplanırken Gadermayr ve ark., [27] örtülü distorsiyon düzeltmesi için adaptif bir komşuya dayanan LBP'yi kullanarak, çok değişken oryantasyonları ve ölçekleri olan senaryolarda güvenilir özellikler sağlamışlar. Son olarak, Grisan ve ark. [29] CLE görüntülerinin piramidal görüntü ayrışması ile LBP (OCR 93) kullandılar.

Uzamsal alan özellikleri ÇH'nın görsel sınıflandırması için çok uygun görünmektedir. Yüksek bir sınıflandırma doğruluğu sağlamanın yanı sıra, bu kategorideki yöntemlerin çoğu, çarpıklıkların sağlam aralıklarına sahip ve hesaplaması da hızlıdır. Bu güçlü

yönlerin her ikisi de endoskopide gerçek zamanlı uygulamalar için gerekli şartlardır [13].

### 2.1.2. Dönüşüm alan özellikleri

Esnek endoskopide ÇH'nın sınıflandırılması için kullanılan çeşitli özellik çıkartma yöntemleri, görüntü alan dönüşümlerine dayanmaktadır. Dönüştürme alanlarında bilgi işlem özelliklerinin bir yararı Dalgacık alt bantlarında çok-ölçekli ve çok-yönelim bilgisi ya da Fourier alanındaki frekans ve faz bilgisi gibi farklı bilgi kategorilerinin kullanılması olasılığıdır [13].

Dalgacık tabanlı yöntemler, literatürde ÇH'nın sınıflandırılması için sıklıkla kullanılmaktadır. En temel özellikler [19], [33], alt bant katsayılı enerjilerin ortalaması, standart sapması veya entropisi gibi klasik istatistiklere (OCR 70) dayanır. Bu tip özelliklerin düşük ayırt edici gücü nedeniyle, dalgacık paket ayrışmasına dayanan daha sofistike yaklaşımlar kullanılmıştır. En iyi temel sentroid yönteminin (best basis centroids (BBC)) [19], [30], [34], [35] (OCR 77–82) yanı sıra yerel diskriminant temel (local discriminant basis (LDB)) algoritması [19], [30], [33], [35], [36] (OCR 79.5–82.5) kullanılarak, temel istatistiksel özelliklerin ayırt edici gücü daha da geliştirilebilir.

Uygulanan diğer dalgacık tabanlı görüntü temsilleri ise klasik Gabor istatistiklerini [30], [37], [38] (OCR 80) ve dalgacık alanlarındaki Gaussian Markov Rastgele Alanlarını (Gaussian Markov Random Fields (MRF)) [19], [30], [39] temel alan (OCR 78.5–80.5) özellikleri içerir.

Standart dalgacık dönüşümüne ek olarak, çölyak hastalığının sınıflandırılması için çift-ağaç kompleks dalgacık dönüşümü (dual-tree complex wavelet transform (DT-CWT)) [40] uygulanmıştır. Ayrımsal özellikler (Discriminative features), karmaşık dalgacık katsayılarının (complex wavelet coefficients) [30], [38], [41] (OCR 77–82) marjinal dağılımının Weibull parametrelerinin yanı sıra korelasyon imzalarını [30], [42] (OCR 82) içerir.



Dalgacık dönüşümüne tamamlayıcı bir şekilde, Fourier tabanlı özellikler de önerilmiştir. Değişken genişliğe sahip halka şekilli filtreler, evrimsel bir çerçevede optimize edilmiş ki frekans bölgesi katsayılarının temel istatistiklerini hesaplamak için kullanılmıştır [30], [38], [43] (OCR 82).

Dönüşüm alanında hesaplanan özellikler ile elde edilen sınıflandırma performansının uzamsal özellikler (spatial features) oranları (OCR 81–90) ile karşılaştırılmasında dönüşüm alan (OCR 70–82.5) özellikleri kullanılırken daha düşük bir doğruluk elde edilmiştir.

Bu endoskopik çarpıtmalarla potansiyel olarak düşünülebilir ve dönüşüm sürecini olumsuz yönde veya genel olarak görüntü temsillerinin daha düşük ayırt edici gücüne de etkileyebilir.

### 2.1.3. Ölçek değişmezliği özellikler

Son derece değişken olan kamera perspektifleri ve endoskopik sırasındaki ölçekler nedeniyle bu tür dönüşümlerden etkilenen özelliklerden ölçeklendirme ve rotasyona göre değişmeyen görüntü temsili daha üstündür. Sonuç olarak, esnek endoskopiden elde edilen verilere ölçek-değişmezliği görüntü gösterimleri uygulanmıştır [17], [18], [26]. En umut verici ölçek-değişmezliği özellikleri arasında MR8 filtrelemeye dayalı Çok Fraktal-Spektrum [17], [44] (Multi-Fractal-Spectrum) (OCR 89) ve Yerel fraktal özellikleri [17], [45] (Local Fractal Features) (OCR 92) bulunmaktadır. Ölçek- ve Oryantasyon- Adaptif LBP (Scale- and Orientation- Adaptive LBP) [26] ise çok değişken kamera ölçekleri ve oryantasyonları olan ortamlar için özel olarak tasarlanmıştır ve endoskopi için umut verici bir başka görüntü temsildir.

Ölçek değişmezliği yöntemlerin büyük çoğunluğu, değişmez görüntü temsillerine benzer şekilde gerçekleştirir. Bu, DT-CWT ve D<sup>3</sup>T-CWT [18], [46] (OCR 66-88), yoğun SIFT özelliklerine [17], [26], [47] (OCR 83.5) ve Çoklu Ölçekli Blob Özelliklerine [17], [48] (OCR 86) dayanan yöntemler için geçerlidir.

Sınıflandırma doğruluğunun en kötü yöntemleri arasında, SCM (spiking cortical model) [17], [49] (OCR 64) ve ICM (Intersecting Cortical Model) [17], [50] (OCR 67) gibi nabız eşlemeli yapay sinir ağlarına (pulse coupled neural networks) ve aynı zamanda Gabor özelliklerinin [17], [51] (OCR 71-75) ve Yerel Afin Bölgelerin (Local Affine Regions) [17], [52] (OCR 71) kaydırmasının eşleştirilmesine dayanan özellik çıkartma yöntemler de vardı.

Ölçek-değişmezliği özellik çıkartma yöntemlerinin yüksek derecede değişken performansı endoskopi gibi zor ortamlarda bu görüntü temsillerinin her zaman uygun olmadığını göstermektedir. Speküler yansımalar, bulanıklık veya kabarcıklar, anahtar noktaların tanımlanmasını veya affine şekillerinin tahmin edilmesini potansiyel olarak yanıltıcı kılar. Dahası, çok sayıda yöntemlerin ölçek-değişmezliği özellikleri, pratikte nadiren geçerli olan teorik kavram ve varsayımlara dayanmaktadır. Sonuç olarak, ölçek değişmezliği için özel olarak tasarlanmış özelliklerin çoğu, ölçeklemeden etkilenen özelliklere benzer şekilde performans gösterir. Genel olarak, ölçeğin değişmez görüntü temsillerini daha temel özelliklerle karşılaştırıldığında, hesaplama açısından daha talepkardır. Bu nedenle, bu tür yöntemlerin kullanılabilirliği bilgisayar destekli tanılamada potansiyel olarak çevrimdışı senaryolarla kısıtlanabilir.

#### 2.1.4. Uzaysal-zamansal özellikler

Uzaysal-zamansal özellikler, WCE tarafından üretilen görüntüler veya videoların dizilerini analiz etmek için güçlü bir araçtır. Bu tip görüntü temsilinin genel yararları, endoskopik dışı bozulmalar ve hastalıktaki gastrointestinal bulguları kaydedilen verilerde doğrudan görüntülenmemiş olsa bile çölyak hastalığını tanımlamada olasılık açısından daha yüksek bir sağlamlıktır.

WCE dizilerinden hesaplanan uzaysal-zamansal özellikler üzerinde ilk çalışma [53] (OCR65), 10×10 piksel alt görüntüleri üzerinde ölçülen temel yerel istatistiklere (piksel parlaklığı ve görüntü dokusu gibi (image texture)) dayanıyordu ve daha sonra her kare için 56×56 alt görüntü ortalaması alındı. Yazarlar, kontrollere kıyasla çölyak

görüntülerinin parlaklığında ve dokusunda uzaysal-zamansal farklılıklarını rapor etmişler.

Çölyak hastalarında, bağırsak hareketliliğini düzenleyen hormonlar üreten azalan sayıda enterochromaffine hücresinden kaynaklanan gastrointestinal hareketlilik anormallikleri bildirilmiştir [54], [55]. Ciaccio ve diğ. [56] lümen şekli ve pozisyonundaki çerçeve-çerçeve (frame-to-frame) değişikliklerine göre motiliteyi karakterize ederek görüntü sınıflandırması için dinamik duvar motiliteyi (Wall Motility) tahmin etmişler (OCR 59).

Çölyak hastalığında azalmış gastrointestinal motilitenin sağınımı (bağırsakların yutma hareketleri (peristalsis)) etkilediği varsayımına dayanarak, Ciaccio ve diğerleri [57]–[59] (OCR 71), ortalama bir güç spektrumundaki en yüksek tepe noktası olan WCE görüntülerinin bir dizisinde baskın dönemi tahmin ederler; bu, daha sonra bir dizi temel görüntüye (Basis Image Statistics) dayanan göze çarpan bilgileri hesaplamak için kullanılır. Sonuçlar, çölyak görüntülerinin kontrollerden (control) daha ayrıntılı bir dokuya (texture) sahip olduğunu ve parlaklıkta daha fazla çeşitlilik sergilediğini göstermektedir. Çölyaklarda, daha uzun baskın dönemlere karşı daha büyük dokusal değişimler arasında korelasyonlar vardı.

Şekil-den-gölgeleme (Shape-from-shading), bir nesnenin üç boyutlu yapısının yeniden yapılandırılması için aydınlatma bilgisine dayanan bir tekniktir. Ciaccio ve arkadaşlarının diğer bir [60] çalışmada (OCR 64), lümen makro-mimarisinin analizi için WCE görüntülerinden duodenal yapıyı yeniden oluşturmasına yönelik şekil-den-gölgeleme yöntemi uygulandı. Sözdizimsel bir analize dayanarak, hacimsel istatistikler (volumetric statistics) hesaplamak için çıkıntılar belirlendi ve kullanıldı. Çölyak hastaları ve kontroller arasındaki bu istatistiklerin önemli farklılıkları rapor edilmiştir.

Sunulan özelliklerin nispeten düşük doğruluğu ancak tamamlayıcı karakteristiği nedeniyle, WCE analizinde çölyak hastalığını öngörmek için bir seçim protokolü, çeşitli özelliklerin [61] kullanıldığı bir çoğunluk oylama şemasına dayanılarak

sunulmuştur. Deneyle, hassas bir sınıflandırma sistemi oluşturmak için tamamlayıcı, düşük ayrımsal özelliklerin (low-discriminative feature) bir kombinasyonunun kullanılabilceğini göstermiştir (OCR 88). Bu etkileyicidir çünkü WCE dizilerinin manuel bölümlendirilmesi gerçekleştirilmemiştir ve endoskopik görüntü bozulmaları tam olarak ele alınmıştır. Dene sırasında kullanılan az sayıdaki dizilerin bir sonucu olarak, bu sistemin bağımsız veriler üzerindeki genel performansı hala belirsizdir.

Tablo 2.2. ÇH'nın otomatik tanısında kullanılan özellik gösterimlerinin doğrulukları (OCR) [13].

<b>Standart Esnek Endoskopi (SFE)</b>			
Spatial Size Distribution	90	LDB	79.5–82.5
Wavelet-based LBP	88	MRF	78.5–80.5
Local Binary Patterns	83–86	Correlation signatures	82
Shape-Curvature-Histogram	85–87	Fourier statistics	82
Local Fractal Dimension - MR8	92	Multi-Fractal-Spectrum	89
Multiscale Blob Features	86	Dense SIFT	83.5
<b>Kablosuz Kapsül Endoskopi (WCE)</b>			
Basis Image Statistics	71	Local Image Statistics	65
Volumetric statistics	64	Wall Motility	59
<b>Konfokal Lazer Endomikroskopi (CLE)</b>			
Pyramidal LBP	93		

Hegenbart ve ark. [13], 2008-2015 arası literatürlerde kullanılan farklı veri setleri ve değerlendirme metodolojileri sayesinde elde edilen sonuçları karşılaştırmıştır. Ancak her bir çalışmanın sınıflandırma doğruluğunu tüm sınıflandırma oranına (OCR) göre karşılaştırmaktadır ve Tablo 2.2.'de ise raporlanan sonuçların özeti sunulmaktadır.

## 2.2. Çölyak Hastalığının Teşhisinde Derin Öğrenme Yöntemleri ve Güncel Çalışmalar

Villus atrofininin endoskopik bulgularının otomatik tespiti ve daha doğru karar verme üzerine derin öğrenme (deep learning – DL) tabanlı en son yapılan çalışmaları, daha sağlam ve son derece hassas sonuçlar üretebilir [62]. Convolutional neural network (CNN – Evrişimsel Sinir Ağları) 'nin son zamanlarda özofagogastroduodenoskopi (EGD), kolonoskopi ve kablosuz kapsül endoskopi (WCE) dahil olmak üzere endoskopi alanında oldukça faydalı olduğu bildirilmiştir [63]–[65].

SFE ve WCE alanında, çölyak hastalığını ve ince bağırsak motilite karakterizasyonunu tanımak için birkaç CNN tabanlı tanısal CAD sistemi tasarlanmıştır [63]–[66]. Wimmer ve ark. [67] çölyak hastalığının CNN transfer öğrenmesinin otomatik tanısını geliştirmişler. Esnek endoskoplar yoluyla 353 hastadan alınan  $128 \times 128$  piksellik toplam 1661 RGB görüntü yamalarında 5 kat çapraz doğrulama gerçekleştirerek test setinde AlexNet ve VGG-f için %86,6 ve %90,5 doğruluk elde etmişler. Zhou ve ark. [66] tarafından eğitim seti için 11 çölyak hastalığı hastası ve 10 kontrol WCE klipi kullanılarak GoogLeNet çölyak hastalığı ağı tasarlanmıştır ve çölyak hastalığı hastalarını kontrollerden ayırmak için bir t-testi ile güvenini doğrulamıştır. Test seti için %100 duyarlılık ve özgüllük elde edilmiştir.

Son zamanlarda yapılan bir çalışmada, Wang ve ark. [68], yeni bir derin özellik öğrenme (deep feature learning) algoritması geliştirmişler. Veritabanı, WCE tarafından elde edilen  $576 \times 576$  piksel ile 1100 sağlıklı ve 1040 hasarlı mukoza sınıfının görüntülerini içermektedir. Sonuçlar, çölyak hastalığında villöz atrofinin saptanmasının, %95,94'lük bir doğrulukla kontrollerden başarıyla ayrıldığını göstermiştir. Min ve ark. [62], gastrointestinal endoskopide derin öğrenmeye genel bir bakış sağlamıştır.

Son 10 yılda yayınlanan farklı veri tabanlarında (SFE ve WCE) çölyak hastalığı anormalliklerinin tespiti ve sınıflandırılmasına yönelik güncel yaklaşımlar karşılaştırılmıştır. Karşılaştırmanın sonuçları Tablo 2.3.'de listelenmiştir.

Son yıllarda önemli ilerlemeler kaydedilmiş olmasına rağmen, daha etkin CAD sistemlerinin geliştirilmesi için çok fazla çalışmanın yapılması gerekmektedir. Mevcut

CAD sisteminin çoğu, özellik vektörünün yüksek boyutsallığı, yüksek hesaplama karmaşıklığı ve genelleme kabiliyetinden yoksundur.

Tablo 2.3. Güncel yaklaşımların karşılaştırılması.

#	Yazarlar	Yıl	Yöntemler	Görüntüleme sistemi	ACC (%)	SEN (%)	SPE (%)
1	Ciaccio ve ark. [57]	2010	Mean and SD in brightness	WCE	-	92.7	93.5
2	Uhl ve ark. [18]	2011	DT-CWT + KNN for classification	SFE	88	-	-
3	Hegenbart ve ark. [17]	2013	Fractal analysis using MR8 filter banks	SFE	91.7	-	-
4	Ciaccio ve ark. [60]	2013	Shape-from-shading transformation	WCE	88.1	83.9	92.9
5	Wimmer ve ark. [67]	2016	CNN Transfer Learning for (AlexNet, VGG-f, VGG-m and VGG-s)	SFE	86.9-90.5	-	-
6	Zhou ve ark. [66]	2017	CNN (22-Layer GoogLeNet)	WCE	-	100	100
7	Koh ve ark. [69]	2018	DWT and nonlinear features + PSO + SVM	WCE	86.47	88.43	84.6
8	Ciaccio ve ark. [70]	2019	Color masking + LDA for classification	WCE	80	-	-
9	Vicnesh ve ark. [71]	2019	DAISY Descriptors + Shannon Entropy + PSO + SVM	WCE	89.82	94.35	83.2
10	Wang ve ark. [68]	2019	BCSE Residual learning and deep feature extraction (ResNet50) + SVM, KNN, LDA	WCE	95.94	97.2	95.63
11	Saken ve ark.	2020	Context-based optimal multilevel thresholding DWT + (Scale invariant texture descriptors LBP-HOG-SURF) + FA + SVM	SFE	94.79	94.29	95.08

Bu tez çalışmasında bu eksiklikleri gidermeye yönelik hibrit bir yaklaşım içeren derin öğrenmeli bir CAD sistemi geliştirmek amaçlanmıştır.

## **BÖLÜM 3. MATERYAL VE YÖNTEM**

### **3.1. İnsan Hakları Beyanı**

Etik onayı: Çalışmada insan katılımcıları içeren tüm prosedürler, katılımcı hastanesinin (Darıca Farabi Eğitim ve Araştırma Hastanesi) onayı ile Sakarya Üniversitesi Klinik Araştırmalar Etik Kurulu'nun etik standartlarına uygun ve Helsinki anlaşması 1986 (2004'de tadil edilmiştir) uyarınca yürütülmüştür. Etik Kurul Kararı ve Katılımcı Hastanesinin Onayı tezin ek kısmında mevcuttur.

Hasta Onamı: Deneyleerin doğasının tam olarak açıklanmasının ardından tüm deneklerden hasta onamı alınmıştır.

### **3.2. Materyal ve Endoskopik Görüntü Veri Seti**

Gastroenterologların rutin standart üst endoskopi sırasında çölyak hastalığını teşhis etmeyi amaçladığı iki duodenal bölge (bulbus ve duodenum'un inen bölümü) vardır ve bu bölgelerden biyopsi örnekleri alınır. Genel olarak, bu tür endoskopilerin çoğu büyütme özelliklerine (magnification features) sahip değildir, bu nedenle doktor bu iki bölgenin uzak ve yakın görüşlerine dayanarak ÇH'nin ön tanısını koyarlar. Yakın çekim görüntüleri villusun mukozal yüzeyinde su altında yapılır ve buna modifiye daldırma tekniği (modified immersion technique – MIT) denir. Bu tekniklerde, ÇH'nin görsel onayını geliştirmek için geleneksel beyaz ışık aydınlatması  $WL_{MIT}$  (white light illumination) yerine dar bantlı görüntüleme  $NBI_{MIT}$  (narrow band imaging) altında uygulanır.

Bu tezde, deneyler için oluşturulan görüntü veri seti, büyütme olmaksızın yetişkin gastroskopileri (Fujinon EG-530WR) kullanılarak Darıca Farabi Eğitim ve Araştırma Hastanesi'nde özofagogastroduodenoskopi (EGD) sırasında alınan duodenumun iniş

ikinci kıtasının (pars descendens duodeni) uzak görüşlerinin görüntülerini içerir. Orijinal görüntü çözünürlüğü 1280×1024 pikseldir.

Çölyak hastalığının standart esnek endoskopi (SFE) görüntüleri her modifiye Marsh aşaması arasında ayırt edilemez. Çünkü villöz atrofisi olmayan düşük modifiye Marsh evresi 0 ila 2. evrede regüler endoskopi ile teşhis edilemez [30], [72]. Ancak çölyak tanısı ile ilgili CAD çalışmalarında, hastaların normal (Evre 0-2) ve çölyak (Evre 3a-3c) olarak iki sınıfa ayrılması uygun görülmüştür.


Tüm hastalara daha önce ÇH tanısı konmamış ve hepsi ilk tanı olarak kaydedilmiştir. Ayrıca, hastalara serbest bir diyet altında endoskopi yapılmıştır (glüten içeren diyet). Deneyler, bağımsız olarak dağıtılmış eğitim ve test veri setlerine dayanmaktadır (eğitim ve test veri setinin oranı yaklaşık %70 ve %30 olarak belirlenmiştir) ve Tablo 3.1.'de görüntü veritabanındaki görüntülerin ve hastaların dağıtım listesini göstermektedir.

Tablo 3.1. Görüntü veritabanındaki görüntülerin ve hastaların dağılımı

	Evre 0-2	Evre 3a-3c	Toplam
<b>Görüntüler</b>			
Eğitim seti	143	91	234
Test seti	61	35	96
<b>Hastalar</b>			
Training set	53	8	61
Eğitim seti	23	3	26

Üst GI endoskopi öncesinde her hasta için anti-tTG (Anti-Tissue-Transglutaminase) veya AGA (Anti-gliadin Antikorları) gibi en az 1 spesifik serolojik test yapılmıştır. Çölyak hastalarına sadece serolojisi pozitif olan hastalar dahil edilmiştir. Görüntülerin kapsadığı mukozal bölgelerin biyopsileri alınmıştır ve veri setini oluşturan tüm endoskopik görüntülerin temel gerçekliğini belirlemek için modifiye Marsh sınıflandırması tıbbi patoloji tarafından yapılmıştır.






Şekil 3.1. Gastroendoskopi ile elde edilen normal ve hasarlı duodenal mukoza görüntülerinden örnekler. Modifiye Marsh sınıflaması histopatoloji ile doğrulanmıştır.

Şekil 3.1.'de eğitim ve test veri setinden bazı normal ve hasarlı (çölyak) duodenal mukoza örneklerini göstermektedir. Burada, şeklin üst ve alt tarafları eğitim ve test veri setinden örnek görüntüleri gösterir ve aynı şekilde sol taraf normal ve sağ taraf çölyak hastalığını temsil eder. Gördüğümüz gibi bu görüntülerin insan gözüyle normal ve çölyak olarak sınıflandırılması zordur. Ayrıca, görüntü kalitesindeki bozulma büyük ölçüde speküler yansımalar, kabarcıklar ve bulanıklık gibi faktörlerden kaynaklandığından endoskopi görüntü analizi son derece zordur. Şekil 3.2.'de gösterildiği gibi, görüntü bozulması da veritabanımızdaki her görüntü için değişen derecelerde etkilendir. Bu nedenle, farklı zorlu durumlardan bazı örnek görüntüler Şekil 3.1.'de dahil edilmiştir. Bu şekildeki 1, 5, 8, 9, 10, 11 numaralı görüntüler kabarcıklar içerirken, 1, 7, 8, 10, 11, 14 numaralılar speküler yansımalara maruz kalmıştır. Bunun yanı sıra 7, 9, 14 numaralı görüntüler, bulanık görüntü örneklerini temsil eder. Çölyak

ile normal arasında ayırım yapmak zor olsa da yukarıda ifade edilen görüntü bozulması da görüntüleri olumsuz etkilemektedir.



Şekil 3.2. Endoskopik görüntü bozulmalarına örnekler.

Speküler yansımalar, görüntünün yüksek yoğunluklu alanlarını oluşturarak görüntünün bilgi kaybına neden olur. Dolayısıyla speküler yansımaların giderilmesi önemli bir konudur. Hegenbart ve ark. [73] LBP tabanlı özellik çıkartma ve SVM sınıflandırma yöntemlerini kullanarak bu tür görüntü bozulmalarının önerilen sınıflandırma hattı üzerindeki etkilerinin ciddiyetini araştırmıştır. Araştırma sonucunda, baloncukların ve yansımaların ötesinde, görüntülerin bulanıklığı ve gürültüsü sistemin doğruluğu üzerinde en büyük etkiyi gösteriyor. Bununla birlikte, bu tür görüntü bozulmasının etkilerinin şiddeti hala belirsizdir.


Bu tür sorunları önlemek için MIT kullanılır ve mukozal yüzey yakın bir perspektiften incelenir. Ancak bu çalışmada oluşturulan görüntü veri setinde MIT yönteminin kullanılması mukozal yüzeylerin uzaktan yakalanması nedeniyle mümkün değildir.

### 3.3. Yöntem

#### 3.3.1. Endoskopik görüntüleme CAD sistemlerinin temel metodolojisi

Otomatikleştirilmiş CAD sistemlerinin geliştirilmesi, doktorların hastalığı doğru şekilde teşhis etmeleri, hedef bölgeyi doğru bir şekilde yönlendirmeleri ve daha az

zaman gerektirmeleri için çok önemli katkıda bulunur. Otomatik analiz için birçok güçlü görüntü işleme yöntemi mevcuttur ve uygun kombinasyonların seçimi, endoskopik görüntüler yoluyla ilişkili hastalıkları etkin bir şekilde teşhis edebilir. Görüntüyü manuel olarak yorumlamak ve anormal görüntüyü veri depolarından taramak neredeyse imkansızdır, bunlar otomatik sistemlerin geliştirilmesini gerektirir.



Şekil 3.3. Çölyak hastalığının otomatik teşhisinde mevcut CAD şemasının tipik metodolojisi.

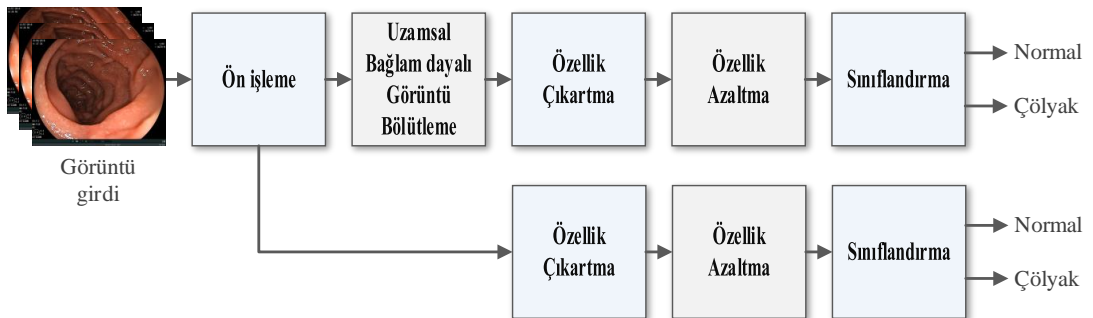
Şekil 3.3.'de çölyak hastalığı için mevcut CAD programının tipik sistem detaylarını göstermektedir. İlk aşamada, endoskopi ile elde edilen görüntü sisteme girilir, ardından ön işleme yöntemleri uygulanır. İkinci adımda, özellikler (features) doku analizi için mukozal görüntülerinden çıkartılır. Son olarak, çıkartılan özellikler sınıflandırma adı verilen son aşamada normal ve ÇH arasında bağımsız olarak ayırt edilir. Endoskopik görüntü, çok çeşitli sınıflandırıcılara göre sınıflandırılabilir.

Hegenbart ve ark., 2015 yılı yayınlarına [13] göre, çölyak teşhisi için bilgisayar destekli teşhisi CAD sistemleri konu üzerindeki araştırmalarına kapsamlı bir genel bakış sağlanmıştır. Bilgisayar destekli teşhisi sistemlerine odaklanan çölyak hastalığının otomatik teşhisi üzerinde yapılan araştırmalar, 2008 yılında başlamıştır ve ilk yayınlanmasından bu yana, tam otomatik sistemler için çok ilerleme kaydedilmiştir. O zamandan beri, 50'den fazla yayın yayınlanmıştır ve bu ortamda, standart esnek endoskopiye (standard flexible endoscopy – SFE) dahil olmak üzere, kablosuz kapsül endoskopi (wireless capsule endoscopy – WCE), dar bant yüksek yoğunluklu kontrast görüntüleme endoskopi (chromo endoscopy) ve konfokal lazer endomikroskopi (CLE) gibi çeşitli endoskopi verileri kullanılmıştır. Normal endoskopiden elde edilen sınırlı veri setlerinden elde edilen çölyak hastalığı şu anda %92'ye kadar bir doğruluk gösterirken, WCE %88 oranında bir sınıflandırma doğruluğuna sahiptir [13].

Kısıtlanmamış gastrointestinal ortam görsel analiz için zorlu bir senaryo sunar. Bulanıklık, kabarcıklar, speküler yansımalar, berrak olmayan akışkanlar gibi endoskopik görüntü bozunmaları, hızla değişen görüş noktaları ve kamera mesafeleri, gelişmiş metodolojilerin sistematik analizini karmaşıktır. Bu tür bozulmaların (degradations) neden olduğu istenmeyen yan etkilerden kaçınmak için, ÇH'nın etkilediği bağırsak mukozasının görsel sınıflandırmasına odaklanan güncel araştırma, tanımlanmış bir dizi (muhtemelen gerçekçi olmayan) kısıtlamaya dayanmaktadır.

### 3.3.2. ÇH'nın otomatik teşhisi için önerilen görüntü işleme yöntemleri

CAD sistemleri, özellikle endoskopide, hekimlerin doğru tanı koyma yeteneğini artırmak için tasarlanmış yeni bir teknolojidir. Bu çalışmanın amacı, en son yayınlanan çalışmalardan elde edilen tıbbi görüntüler için görüntü bölütleme, özellik çıkartma ve sınıflandırma tekniklerinin araştırılmasıdır. Yapılan araştırmalar endoskopik görüntülerin bilgisayar destekli teşhisi sistemlerinin hala önemli bir sorun olduğunu ortaya koymaktadır. Bir CAD sisteminin oluşturulması için, görüntü bölütleme, özellik çıkartımı / seçimi ve son olarak sınıflandırma işlevi gören çok çeşitli görüntü işleme yaklaşımlarının entegrasyonu önemlidir. Bu çalışmada, medikal görüntüler için özellikle endoskopide kullanılan teknikleri ve yöntemleri incelenmiştir. Bu araştırmalar sonucunda, endoskopik görüntülerle ÇH'nın otomatik CAD için makine öğrenme algoritmalarına dayanan bir hibrit sistem tasarlanmıştır. Tasarlanmış CAD algoritmasının şeması, Şekil 3.4.'te gösterilmektedir.



Şekil 3.4. Önerilen CAD algoritmasının şematik diyagramı.

Önerilen sistem aşağıdaki hesaplama tekniklerinden oluşur: (i.a) Kenar bilgisini maskeleye ve görüntü geliştirme. (i.b) Görüntü bölütleme için enerji eğrisi üzerinde bağlam tabanlı (context-based) optimal çok seviyeli eşikleme (multilevel thresholding – MTH) tekniği kullanılmıştır. (ii) Daha sonra, görüntülerin nispi ayırık dalgacık dönüşümü (DWT) katsayıları, DWT yöntemi uygulanarak alt bölümlere ayrılır ve görüntüler, uzamsal alandan frekans alanına dönüştürülür. (iii) DWT ile ayrılmış katsayılardan önemli özellikleri çıkartılması için çeşitli özellik çıkartım yöntemleri kullanılır ve bunlar sınıflandırma oranına göre değerlendirilir. Bu çalışmada, iki sınıfı farklılaştıran özelliklerinden karakteristik ifadeler elde etmek için farklı ölçek değişmezliği doku tanımlayıcıları kullanılmıştır. Görüntünün yararlı özellikleri, sınıflandırma amacı için görüntüden çıkartılır. (iv) Özellik çıkarma ve özellik azaltma (PCA) algoritmaları arasındaki entegrasyon, özellik vektörlerinin sınıflandırılması için optimal bir dizi özelliklerin seçilmesi için uygulanmıştır. (v) Son olarak, önerilen tekniklerin tespit kabiliyetini doğrulamak için 10-kat çapraz-doğrulama (10-fold cross-validation strategy) stratejisi ile çok çeşitli sınıflandırma yöntemleri uygulanmıştır.

### **3.4. Analizler**

#### **3.4.1. Görüntü elde etme ve ön işleme**

Endoskopi, ultrason, bilgisayarlı tomografi (CT) ve manyetik rezonans görüntüleme (MRI) gibi görüntü elde etme teknikleri, dijital tıbbi görüntüler üretmek için bilgisayarlı vizyon sistemleriyle yakından ilişkilidir. Çölyak hastalığının gerçek bir endoskopik görüntüsünü elde etmek ve araştırma yapmak gizlilik kaygıları nedeniyle karmaşıktır. Dolayısıyla çalışmada özel veriler toplanılmıştır ve veri setleri katılımcı hastane müdürlüğünün ve klinik araştırmalar etik kurulu'nun izniyle elde edilmiştir. Her hastanın kabulü ile onam formu doldurulmuştur.

ÇH'nın kamuya açık veri setleri arařtırmacılar için mevcutsa, uygulandıkları yöntemleri ve sonuçları karşılařtırmak mümkündür. Bir başka açıdan, bilgisayar destekli tanısında çölyak hastalığı arařtırmasının ilerlemesini ve ilgisinin gelişmesine etkilecektir. Buna baėlı olarak ÇH'nın kamuya açık veri setlerini saėlamak genel bir istek olmalıdır [13].

Modern görüntü elde etme tıbbi teknikleri önemli ölçüde iyileřtirilmiřtir ve yoğun çözünürlükte görüntüler saėlıyor, ancak görüntüler hala gürültü taşıyor. Bu nedenle, görüntü gürültüsünü önleme genellikle ön işleme aşamasında gerçekleştirilir ve görüntü işleme için önemli bir prosedürdür. Bu aşama gürültüyü azaltmak ve görüntüyü iyileřtirmek daha sonra elde edilen görüntülerin ifade kenarlığı ve görüntüyü sınırlayan diėer ifadeleri maskelemek için kullanılır.

Bu aşama gürültüyü azaltmak ve görüntünün çözünürlüğü, kontrastı iyileřtirmek daha sonra elde edilen görüntülerin ifade kenarlığı, görüntüyü sınırlayan ifadeleri kaldırmak için kullanılır. Görüntülerin kenar bilgilerini korumak ve geliřtirmek için çok çeřitli filtre yaklařımları [74] kullanılabilir. Bu aşamada veri setlerindeki görüntülerin original boyutları küçültülmemiřtir ve görüntülerin gürültüsünü gidermesi için medyan filtresi kullanılmıřtır.

### **3.4.2. Baėlam tabanlı görüntü bölütleme**

Bu çalışmanın bir diėer amacı, görüntü bölütleme yöntemlerinin endoskopik görüntünün sınıflandırılması üzerindeki etkisini deėerlendirmektir. Bu amaçla, Şekil 3.4.'deki önerilen CAD sistemi, görüntü bölütleme işlemleri ve işlemsiz iki tip model olarak uygulanmıřtır ve sonuçlar arařtırma bulguları bölümünde rapor edilecektir. Bölütleme tekniklerinin etkileri iki küme olarak belirlenmiřtir: temel gerçek (ground truth) görüntüsü ve bölütlenmiř görüntü. Bu aşamada, bölütleme yöntemlerinin endoskopik görüntüler için gerçekten yararlı olup olmadığı ve sonraki aşamalar için olumlu bir etkisinin olup olmadığı arařtırılmıřtır.

Görüntüler endoskopiden alındıktan sonra ön işleme aşaması başlar ve görüntüler geliştirilir. Görüntünün geliştirilme ve gürültünün azaltılma yöntemleri ile birlikte bölütleme teknikleri aynı aşamada kullanılabilir ve çalışmamızda bu şekilde yapılmıştır. Bölütleme teknikleri tıbbi görüntüleme uygulamalarında önemli bir rol oynar ve özellikle beyin ve karaciğer görüntüleri üzerinde sıkça araştırılmaktadır [75]–[79]. Tıbbi görüntüleme uygulamalarında birçok bölütleme tekniği kullanılmıştır ve bunlar aşağıdaki gruplara ayrılmıştır [80]: eşikleme (thresholding), kümeleme (clustering), bölgeye dayalı (region-based), kenar algılama (edge detection) ve hibrit yaklaşımlar.

Boschetto ve ark., [81] basit doğrusal yinelemeli kümeleme (simple linear iterative clustering – SLIC) süper piksel bölütleme tekniği kullanılarak irritabl barsak hastalığında villusların bölütlenmesi ve saptanması için otomatik bir yöntem sundu.

Son on yılda bilgisayarlı görsel sistemlerinde artan talep nedeniyle, farklı alanlardaki araştırmacıların dikkatini çeken görüntü eşiği (image thresholding) devam etmektedir. Eşik, görüntüleri parçalara ayırmanın en kolay ve en hızlı yöntemidir. Eşik, eşik değerlerinin kullanılmasından oluşur ve optimal bir kriter karşılanana kadar bu işlemler görüntülerin histogramına uygulanır. Birden fazla eşik tespit ederek görüntüyü farklı bölgelere ayıran sürece çok seviyeli eşikleme (MTH) adı verilir.

Hammouche'a göre [82], en iyi eşik değerlerini (*th*) tahmin etmek için farklı yaklaşımlar önerilmiştir; bu tür yöntemler parametrik ve parametrik olmayan olarak ayrılabilir. İlk grupta, histogramın bir yaklaşımını oluşturmak için bir dizi parametre kullanılmıştır ve bu tür parametreler de piksel bölütleme için sınıfların oluşturulmasına yardımcı olur. Ancak bu işlem büyük miktarda hesaplama çabası gerektirir. Bunun aksine, parametrik olmayan teknikler daha az hesaplama ve daha az yoğun işlemlere sahiptir. Sonuç olarak daha sık kullanılmaktadır. Parametrik olmayan yaklaşımlar, yalnızca bir ölçütün en üst düzeye çıkarılması veya en aza indirilmesiyle en iyi eşik değerlerini bulmak için eşik değerini ve görüntünün histogramını gerektirir. Literatürlerde iki nonparametrik yaklaşım yaygın olarak kullanılmaktadır: Bu da 1) Otsu'nun sınıflar arası varyansı [83] ve 2) Kapur'un entropisidir [84]. Otsu'nun

yöntemi, görüntünün iki nesne, nesne ve arka plandan oluştuğunu varsayar. En iyi gri eşik değeri, görüntüdeki nesnelerin ağırlıklı sınıflar arası varyans değeri en aza indirilerek bulunur. Benzer şekilde, Kapur'un metodu sınıfların homojenliğini ölçmek için görüntüyü iki nesneye sınıflandırır ve nesnelerin toplam entropisini hesaplar. Her iki nesnenin toplam entropisinin maksimum noktaya ulaştığı gri seviyeye Kapur eşiği denir. Böylece hem Otsu hem de Kapur başlangıçta iki seviyeli eşik (bi-level thresholding) için önerilmiştir. Ancak, çok seviyeli bölütleme için kolayca genişletilebilir.

Çoklu seviyeli eşik (MTH), görüntülerde bölütleme gerçekleştirmek için en çok kullanılan yaklaşımlardan biridir [85]. Bununla birlikte, çoğu yöntem bölütlere ayrılacak görüntünün histogramına dayanıyorsa, çok seviyeli eşikleme yöntemleri sadece tüm uzamsal bilgileri göz ardı ederek belirli yoğunluk seviyelerinin oluşum sıklığını dikkate alır. Uzamsal bağlamsal bilgiler (spatial contextual information), yalnızca pikselin değil, çevresinin değerini de göz önünde bulundurarak, bölütlenmiş görüntünün kalitesini artırmaya yardımcı olabilir. Enerji eğrisi (energy curve), mekansal bilgileri histogramla aynı özelliklere sahip bir eğriye getirmek için tasarlanmıştır. Histogram, pikselin konumu hakkında bilgi sağlamaz. Mekansal bilgileri dahil etmek için, enerji eğrisine eşikleme işlemi uygulanabilir.

Görüntü histogramı uzamsal ayrıntıları dikkate almaz, bu nedenle bölütlenmiş bölgelerin komşu olduğunu garanti edemez. Bu, histogramın eğrisinin, pikselin bulunduğu konum hakkında uzamsal bilgi sağlayamayacağını açıklar. Enerji eğrisi tasarımının avantajı histogramın özelliklerine benzer, ancak piksel konumunun uzamsal bilgisini içerir [86], [87].

Görüntünün histogramına dayanan geleneksel eşikleme teknikleri, iki ana sınırlamaya maruz kalmıştır [87]: (i) Optimum eşiği seçmek için bağlamsal bilgiler dikkate alınamıyor. (ii) Hesaplama zorunluluğu olan ve uygulamak için karmaşık olan çok düzeyli eşikleme için verimsiz. İlk sınırlamayı azaltmak için bir Enerji Fonksiyonu (EF) önerilmektedir. Bu enerji fonksiyonu, görüntünün uzamsal bağlamsal bilgisini hesaba katarak her bir gri değerindeki görüntünün enerjisini hesaplar. Bu süreç,



histogramın aynı özelliklere sahip olan enerji eğrisini üretir. Örneğin, enerji eğrisi bazı pikler içerebilir, bu durumda, bir takım modlara göre ayrılabilir [88]. Başka bir deyişle, iki mod arasındaki vadide bir eşik bulmak mümkündür [89].

Klasik yaklaşımların ikinci dezavantajı, piksellerin en iyi sınıflandırmasını bulmak için kullanılan bilgilerle ilgilidir. Çünkü hesaplama açısından zordur ve uygulamasının karmaşıklığı verimsizdir. İlgili literatürde, bu iki sınırlamanın önüne geçmek için görüntü bölütlemesi için optimizasyon yaklaşımlarıyla enerji fonksiyonlarının kullanılması önerilmiştir. MTH yapmak için önerilen birkaç evrimsel hesaplama algoritması (evolutionary computational algorithms – ECA) vardır. Bu tür yaklaşımlarla ilgili son çalışmalarda guguk arama algoritması (cuckoo search – CS) [88], genetik algoritmalar (GA) [87] ile enerji eğrisini kullanarak en iyi eşikleri bulmak için bir bölütleme yaklaşımı önerilmiştir. Otsu veya Kapur mekanizmaları objektif fonksiyon olarak kullanılmıştır.

ECA'lar karmaşık optimizasyon problemlerini çözmek için tasarlanmış ilginç arama stratejilerindedir. Bu bağlamda, çok seviyeli eşikleme için birkaç ECA uygulaması başlatılmıştır. Bu yaklaşımların bazı örnekleri genetik algoritmalar (GA) [90]–[92], parçacık sürü optimizasyonu (particle swarm optimization – PSO) [93]–[98], diferansiyel evrim (differential evolution – DE) [98]–[101], guguk arama (CS) [98], [102], rüzgar tahrikli optimizasyon (wind driven optimization – WDO) [98], [102], ateş böceği algoritma (firefly algorithm – FFA) [103], elektromanyetizma gibi optimizasyon (electromagnetism-like optimization – EMO)) [104], [105], sosyal örümcek optimizasyonu (social spider optimization – SSO)) [106], çiçek tozlaşma algoritması (flower pollination algorithm – FPA) [102], [106], karga arama algoritması (crow search algorithm – CSA) [107] gibi algoritmaların kullanımınıdır. Sonuç olarak, teşhis edilmesi gerektiren nesnelere tıbbi bir görüntüdeki arka planından eşik olarak adlandırılan uygun bir gri-seviye değeri kullanarak ayırır.

Sonuç olarak, en uygun eşiği seçmek için uzamsal bağlamsal bilgileri göz ardı ederek, yalnızca iki seviyeli eşikler için geleneksel histograma dayalı eşikleme yöntemleri tercih edilir. Kandhway ve ark. [108], Oliva ve ark. [85], ve Agarwal ve ark. [102],

tarafından elde edilen sonuçlara baktığımızda, tıbbi görüntüler üzerindeki gelecekteki çalışmalar evrimsel hesaplama algoritmalarının enerji eğrisi ile uygulanmasını önermiştir.

Kandhway ve ark. [108], çalışmalarında Enerji-Otsu-CS şeması optimizasyon teknikleri için objektif bir fonksiyon olarak kabul edilmiştir. Bu aşamada, çölyak hastalığının görüntü bölütlemesi, yukarıdaki iki dezavantajı önlemek için Otsu'nun fitness fonksiyonundaki enerji eğrisinde tasarlanan guguk kuşu arama algoritmasını kullanarak en uygun eşikleme tekniğini öneren çalışmaya uygulanmıştır.

### 3.4.2.1. Enerji eğrisi

Bu aşamada, çölyak hastalığının görüntü bölütlemesi, yukarıdaki iki dezavantajı önlemek için Otsu'nun fitness fonksiyonundaki enerji eğrisinde tasarlanan guguk kuşu arama algoritmasını kullanarak en uygun eşikleme tekniğini öneren çalışmaya uygulandı. Eşik değerleri, orijinal görüntünün enerji eğrisine bağlı olarak Otsu yönteminin (sınıflar arası varyans) değerini en üst düzeye çıkarılmasıyla oluşturulmuştur ve renkli görüntülerin bölütlemesini gerçekleştirmek için çok düzeyli eşikle birleştirilmiştir.

Örneğin  $E_g, I$  görüntüsünün bir enerji eğrisi olarak düşünün, burada,  $I$ 'nin büyüklüğü  $I = \{g_{ij}, 1 \leq i \leq M, 1 \leq j \leq N\}$ . Burada  $g_{ij}$ ,  $I$  renk görüntüsünün veya RGB kanallarının her biri için  $[0, L - 1]$  aralığında tanımlanan piksel konumundaki görüntü  $I$ 'nin  $(i, j)$  görüntü değeridir.  $L$ ,  $I$  görüntüsünün maksimum gri değeri olsun,  $L$  genellikle 256 olarak kabul edilir. Görüntünün gri yoğunluk noktalarının olasılık dağılımının  $P$  olduğunu varsayalım. Enerji tabanlı Otsu yönteminde Denklem 3.1.'in  $P$ 'yi hesapladığı düşünülmektedir [87].

$$E_g^f = - \sum_{i=1}^M \sum_{j=1}^N \sum_{pq \in N_{ij}^2} b_{ij} b_{pq} + C \quad (3.1)$$

$$f = \begin{cases} 1, & \text{Gri seviye görüntüsü} \\ 1, 2, 3 & \text{RGB görüntü} \end{cases}$$

burada  $I$  görüntüsünün enerjisi gri düzey  $g$ 'de hesaplanır ( $0 \leq g \leq L - 1$ )  $b_{ij}$  iki boyutlu bir ikili matris  $B_g$ 'nin elemanlarıdır.  $B_g = \{b_{ij}, 1 \leq i \leq M, 1 \leq j \leq N\}$ ,  $b_{ij} = 1$ , eğer  $g_{ij} > g$ ; başka türlü  $b_{ij} = -1$ .  $E_g > 0$  olduğundan emin olmak için Eşitlik 3.1'e  $C$  sabiti eklenir. Bir görüntü  $I$ 'in çevredeki pikselleri arasındaki uzamsal korelasyon, verilen endeks konumu  $(i, j)$  için komşu sistem  $N$  ve bunun sırası  $d$ ,  $N_{ij}^d = \{(i + u, j + v), (u, v) \in N^d\}$  olarak modellenir.  $d$  değerine göre, komşu sistem çeşitli konfigürasyonları göz önünde bulundurur. Bu çalışmada, sadece ikinci sıradaki bitişik sistemler dikkate alınmıştır, yani,  $(u, v) \in \{(\pm 1, 0), (0, \pm 1), (1, \pm 1), (-1, \pm 1)\}$ .

### 3.4.2.2. Otsu yöntemi

Görüntünün bölütlemesi için parametrik olmayan bir bölütleme işlemi olan Otsu'nun yöntemi nesne ve arka plan piksellerinin ağırlıkları, en iyi eşik değerini belirlemek için belirlenen sınıflar arası varyans değeri en aza indirilerek belirlenir. Bu yöntem, dijital görüntüyü çeşitli sınıflara ayırır ve bunların ardındaki fikir varyanslarını en üst düzeye çıkarmak içindir. Başka bir deyişle, sınıftaki varyans değerini en aza indiren değer, sınıflar arasındaki varyans değerini en üst düzeye çıkarır. Giriş görüntüsünü ikiden fazla sınıfa ayırmak için  $TH = \{th_1, th_2, \dots, th_k\}$  olarak belirtilen  $k$  eşik değerlerinin gerekli olduğunu düşünün.  $\mathbf{h}(\mathbf{i})$ , gri tonlamalı düzeydeki piksel sayısını temsil eder. Görüntünün varyansını bulmak için aşağıdakiler eşitlik (Denklem 3.2) kullanılır:

$$\sigma_B^{2c} = \sum_{i=0}^{L-1} \sigma_i^c = \sum_{i=0}^{L-1} w_i^c (\mu_i^c - \mu_{TH}^c)^2 \quad (3.2)$$

Burada  $w_i^c$  her sınıfın olasılığını temsil eder.  $\mu_i$ , aşağıdaki gibi tanımlanacak her sınıfın ortalama seviyesi olarak belirlenir:

$$w_i^c = \sum_{i=0}^{th_k-1} P_i^c, \quad \mu_i^c = \sum_{i=th_k}^{th_k-1} \frac{iP_i^c}{w_i^c} \quad (3.3)$$

$\mu_{TH}^c$ , görüntünün ortalama yoğunluğu olarak tanımlanır ve aşağıdaki gibi hesaplanır.

$$\mu_{TH}^c = \sum_{i=0}^{L-1} iP_i^c$$

Görüntü bölütleme için optimum eşik değerleri, aşağıdaki objektif fonksiyonun en üst düzeye çıkarılmasıyla (Denklem 3.4) gerçekleştirilecektir.

$$f_{otsu}(th_1^c, th_2^c, \dots, th_k^c) = \arg \max \{ \sigma_B^{2^c}(th_1^c, th_2^c, \dots, th_k^c) \} \quad (3.4)$$

### 3.4.2.3. Guguk kuşu arama algoritması

Guguk kuşu araştırma (CS) algoritması doğadan ilham alan algoritmalarından biridir ve 2009 yılında Yang ve Deb [109] tarafından optimizasyon ile ilgili sorunların çözümü için uygun olduğu düşünülerek geliştirilmiştir. Bu algoritma, bazı guguk türlerin kuluçka parazit doğasına dayanan bir yaklaşımdır. Guguk yumurtalarını uygun gördükleri farklı kuşların yuvalarına bırakırlar ve yumurtalarının yumurtadan çıkma olasılığını artırmak için yuvadaki diğer yumurtaları atarlar. Herhangi bir optimizasyon probleminde olduğu gibi, guguk kuşu arama algoritmasını tanımlarken bazı kısıtlamalar göz önünde bulundurulur:

- Her guguk kuşu her seferinde bir yumurta bırakır ve rastgele seçilen bir yuvaya koyulacağı varsayılmaktadır.
- Yüksek kalitede yumurta (en iyi solüsyon) içeren en iyi yuvalar, fitness değerlendirmesinden sonra aktif kalacaktır ve gelecek nesillere taşınacaktır.
- Toplam kullanılabilir evsahibi yuvası sayısı sabittir. Dolayısıyla ev sahibi kuş davetsiz misafir yumurtasını  $p_a \in [0, 1]$  olasılığı ile bulabilir. Yabancı bir


yumurta bulduğundan sonra, ev sahibi kuş bundan kurtulabilir veya yeni yuvalar oluşturmak için tüm yuvayı terk edebilir.

CS yöntemi, guguk kuşu  $i$  için  $x_i(t + 1)$  gibi yeni çözümler (yuva) üretmek üzere Lévy uçuşunu gerçekleştirir [88], [108].

$$x_i(t + 1) = x_i(t) + \alpha \oplus \text{Lévy}(\lambda) \quad (3.5)$$

burada  $\alpha$ , adım büyüklüğüdür,  $\alpha$  ( $\alpha > 1$ ) problem boyutunu açıklar ve bu durumda  $\alpha = 1$  olduğu varsayılır.  $\oplus$  Sembolü, giriş-çarpma işlemi ile ilgilidir [88].

Şekil 3.4.'te objektif fonksiyon olarak Otsu'nun yöntemini kullanarak görüntü bölütleme için enerji eğrisine dayanan uzamsal alanın optimum Enerji-Otsu-CS tabanlı çok seviyeli eşikleme şemasının çerçevesi gösterilmektedir.



Şekil 3.5. Görüntü bölütlemeye uzamsal bağlam temelli optimal çok seviyeli enerji eğrisi eşiği

Görüntüdeki desenleri netleştirmek amacıyla, enerji eğrisinde daha sonraki bir aşamada görüntüyü keskinleştirebilecek 3 eşik (üç seviyeli) kullanılmıştır. Tüm görüntü veri tabanı için, eşitlik ve kolaylığı sağlamak için popülasyon boyutu ve yineleme sayısı 20 ve 500 olarak ayarlanmıştır.

### 3.4.3. Dalgacık dönüşüm tabanlı özellik çıkartma, seçme ve sınıflandırma

Çölyak hastalığının teşhis edilmesi ve sınıflandırılmasında özellik çıkartımı en önemlisidir. Tıbbi görüntü analizinde çıkartılan özellikleri uygun sınıfa sınıflandırmak

için çeşitli örüntü tanıma (pattern recognition) yöntemlerini incelemektir. Bu yöntemler görüntüdeki önemli özellikleri tanımlar ve bir özellik vektörü oluşturur. 2- $D$  görüntüler daha sonra sınıflandırıcılar için uygun bir boyuta ayarlanır ve 1-den- $N$  boyutlu vektör setine dönüştürülür. Çıkarılan özellik vektörü etkili ve ayırt edici özellikler içermelidir.

### 3.4.3.1. Ayrık dalgacık dönüşümü

Dalgacık dönüşümü (wavelet transform), ölçek değişmezliği doku ayrımcılığı için çok güçlü bir modeldir. Dalgacık tabanlı yöntemler literatürde çölyak hastalığı sınıflandırmasında [17], [18], [111], [19], [30], [35], [38], [39], [41], [69], [110] sıklıkla kullanılmaktadır.

Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform – DWT) alt-bant kodlama prensibi ile çalışır. Çeşitli özellikleri ve karakteristikleri nedeniyle görüntü işleme için iyi bir teknik sağlar. Ayrık dalgacık dönüşümünün temel özelliklerinden bazıları aşağıdaki gibidir:

- Bu algoritma, görüntüyü daha net hale getirmek ve netliğini artırmak için düşük frekanslı alt bantları büyütür.
- Hem uzaysal hem de frekans alanında görüntü işlemeyi destekler, bu da görüntü analizinin verimliliğini artırır.
- Ayrık dalgacık dönüşümünün uygulanması kolaydır. Daha az kaynak gerektirir ve veri işleme hızlıdır.

Dalgacıklar, bir sinyalin koordinat sistemini bir temsil alanından diğerine dönüştürmek için sayısal bir analitiktir, bu da kolay işleme için esnek bir veri temsili verir. Dalgacık dönüşümleri ve kodlama şemaları, hataları ve veri aktarımlarını çözmek için bir dizi güçlü araçtır. Dalgacıklar, kendilerine özgü çok çözünürlük özelliğine sahiptir, bu da onları makul düzeyde distorsiyon (çarpıtma) ile ölçeklenebilirlik gerektiren uygulama için en uygun hale getirir. Dalgacıklar

görüntüleri ve diğer sinyalleri çok seviyeli sinyal çözünürlüğüne ayrıştırmak için kullanılır. Daha yüksek çözünürlük seviyesi, daha yüksek görüntü ayrıntıları sağlar.

Genel olarak, dalgacık herhangi bir nesne kenarını atmadan karakteristik çok katmanlı yüksek çözünürlüklü bir görüntü oluşturur. Düşük geçiş filtresinin ortaya çıkan çıktısı sıkıştırılmış görüntüdür. Dalgacıkların katsayılarının boyutu, dalgacıkların koşulsuz temel işlevi nedeniyle hızla azalır. Dalgacık katsayıları doğal bileşeni etkili bir şekilde gösterdiğinden, veri yorumlaması daha az çaba gerektirir. Dalgacıklar özelleştirilebilir, kolay değiştirilebilir ve daha sonra her türlü uygulama için uygun olacak şekilde yapılandırılabilir. DWT'de kullanılan dalgacık, bilgisayarlı işlemeye uygundur. İşlemcinin karmaşıklığı ve hesaplama yükü, bu tür çarpma ve toplama gibi temel matematiksel işlemlerin kullanımı nedeniyle oldukça düşüktür.

Dalgacık teorisi, sayısal ve aritmetik analizlerin ilginç gelişimi ve ilerlemesi nedeniyle matematiksel ve mühendislik alanına büyük ilgi göstermiştir. En son gelişme, dalgacık teorisinin Fourier dönüşümleri (FT) ile devam eden zorluklara çözüm olarak görülebmesidir. Fourier dönüşümleri ile karşılaşılan genel zorluklardan biri, Fourier dönüşümünün katsayılarını işlevin yerel ve küresel özelliği ile ilişkilendirmek için uygun bir yöntem bulmaktır.

Genel olarak, 1931'deki Littlewood-Paley teorisinin çalışması, dalgacık teorisinin gelişimi için bir ilham kaynağı olarak kabul edilir. O sırada geçerli olan bazı sorunları ele almak için yeni teknikler sunmak için tanıtıldı. Bununla birlikte, yakın zamanda geliştirilen dalgacık teorisinin birleştirici çerçevesi, dalgacıkların popülaritesinin ana nedenidir. Harmonik analiz, operatör teorisi vb. ile ilgili sorunlara çözüm bulma konusunda yetkindi.

#### **3.4.3.1.1. Dalgacık teorisinin temelleri**

Herhangi bir sinyal sinüzoidal sinyallerin bir toplamı olarak tasvir edilebilir. Yaygın olarak kullanılan Fourier analizinin temelini oluşturur.  $f(t)$  sinyalin temsili için dalgacık fonksiyonlarının doğrusal bir kombinasyonunun kullanıldığı dalgacık

dönüşümüdür. Fourier dönüşümünün aksine, dalgacıklar zaman ve frekans alanında lokalizedir. Bu nedenle süreksizliği olan sinyallerle başa çıkmak için uygundur. Bir Dalgacık analizi, aşağıdaki kriterleri yerine getirmesi gereken karmaşık değerli bir işlev  $\psi$  (complex-valued function) tarafından yönlendirilir.

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (3.6)$$

$$c_{\psi} = 2\pi \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega < \infty \quad (3.7)$$

Burada  $\psi$  ana dalgacık fonksiyonudur.  $\Psi$ ,  $\psi$  'nin Fourier dönüşümüdür. Denklem 3.7'deki kriterler  $\psi$  fonksiyonunun sonlu enerjisini temsil eder ve Denklem 3.7.'deki kriterler,  $\Psi(\omega)$  düzgünse  $\Psi(0) = 0$  olduğunu gösteren kabul edilebilirlik koşulunu temsil eder.

#### 3.4.3.1.2. Sürekli Dalgacık Dönüşümü

$\psi$ , yukarıda açıklanan koşulları karşılıyorsa, gerçek bir sinyalin  $s(t)$  dalgacık fonksiyonuna  $\psi(t)$  göre dalgacık dönüşümü şöyle tanımlanır:

$$S(b, a) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi' \left( \frac{t-b}{a} \right) s(t) dt \quad (3.8)$$

burada  $\psi'$ ,  $\psi$  'nin karmaşık konjugatını belirtir ve bu açık  $(b, a)$  yarım düzlemde ( $b \in R$ ,  $a > 0$ ) tanımlanır.  $b$  parametresi, zaman kaydırmasına karşılık ve  $a$  parametresi ise analiz dalgacısının ölçeğine karşılık gelir.

Eğer  $\psi_{a,b}(t)$  'yi tanımlarsak

$$\psi_{a,b}(t) = a^{-1/2} \psi \left( \frac{t-b}{a} \right) \quad (3.9)$$



yani  $a$  ile yeniden ölçekleme ve  $b$  ile kaydırma anlamına gelir, o zaman Denklem 3.8 gerçek  $s(t)$  sinyalinin  $\psi_{a,b}(t)$  fonksiyonu ile bir skaler veya iç çarpımı olarak yazılabilir:

$$S(b, a) = \int_{-\infty}^{\infty} \psi'_{a,b}(t) s(t) dt \quad (3.10)$$

$\psi(t)$  fonksiyonu kabul edilebilirlik koşulunu, denklem 3.7.'yi karşıladığında, orijinal sinyal  $s(t)$ , aşağıdaki ters formülle dalgacık dönüşümü  $S(b, a)$  'dan elde edilebilir:

$$s(t) = \frac{1}{c_{\psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} S(b, a) \psi_{a,b}(t) \frac{dad b}{a^2} \quad (3.11)$$

### 3.4.3.1.3. Ayrık dalgacık dönüşümü

Kesikli alandaki kaydırma ve ölçek parametreleri  $a = a_0^m$  ve  $b = nb_0$  olarak ayrılmıştır. Ayrıca, analiz dalgaları aşağıda verildiği gibi ayrıştırılır:

$$\Psi_{m,n}(t) = a_0^{-m/2} \psi\left(\frac{t - nb_0}{a_0^m}\right) \quad (3.12)$$

Denklem 3.7.'de  $m$  ve  $n$  tamsayılardır. Ayrık dalgacık dönüşümü ve ters ayrık dalgacık dönüşümü aşağıda verilen formülle hesaplanır:

$$S_{m,n} = \int_{-\infty}^{\infty} \psi'_{m,n}(t) s(t) dt \quad (3.13)$$

$$s(t) = k_{\psi} \sum_m \sum_n S_{m,n} \Psi_{m,n}(t) \quad (3.14)$$

Burada,  $k_{\psi}$  normalleştirme için sabit bir değerdir.

Yukarıdaki fonksiyondaki  $\psi_{m,n}(t)$ , zaman ölçeği düzleminde örnekleme noktaları oluşturur.  $a$ -ekseni ölçek düzlemi logaritma birimlerini gösterir ve  $b$ -ekseni zaman çizgisi doğrusal örnekleme gösterir.

Genel olarak  $a_0$  aşağıdaki gibi seçilir:

$$a_0 = 2^{1/\nu} \quad (3.15)$$

Burada,  $\nu$  bir tamsayıdır. Fonksiyonda,  $\Psi_{m,n}(t)$ , işleme  $\nu$  parçalarının bir grubu olarak gerçekleşir. Bu tür gruplara ses denir. Tamsayı  $\nu$ , tek bir oktavdaki seslerin miktarını ifade eder. Sesli notlar içinde dengeli bir ölçek ve tonu karakterize eder. İşlem, geleneksel Fourier dönüşüm analizinde dar bantlı filtrelerin kullanılmasına benzer.

Dalgacık analizinin uygulanması sadece ikili ölçek değerlendirmesiyle sınırlı değildir. Oktav başına kesin sayıda sesin uygun şekilde kullanılmasıyla, dalgacık araştırması  $1/3 - oktav$ ,  $1/6 - oktav$  veya  $1/12 - oktav$  uygulamasını ve akustiğin incelemelerini yeterli şekilde yapabilir.

Herhangi bir dalgacık dönüşümünde, birincil hedef, ilgili dalgacık dönüşümlerini tahmin etmek için etkili algoritmik hesaplamaların yanı sıra ideal bir dalgacık temel fonksiyonunun tahmin edilmesinde kalır. İhtiyaç duyulan istenen özelliklere göre, dalgacık temelli fonksiyonun uygulanması için sonsuz dürtü yanıtı (infinite impulse response – IIR) veya sonlu dürtü yanıtı (finite impulse response – FIR) filtreleri kullanılır.

#### 3.4.3.1.4. Grafik Gösterimi

Bu bölümde,  $s(t)$  sinyali hakkında faydalı bilgilerin vurgulanabilmesi için 3.8 ve 3.13 Denklemleri gibi karmaşık değerli fonksiyonların nasıl görüntüleneceği açıklanmaktadır. Dikkate alınması gereken iki husus vardır.

Dalgacık dönüşümünün tanımlandığı açık  $(b, a)$  yarım düzlem, tam düzleme  $(b, -\log(a))$  eşlenebilir. Tek bir görüntüde, çok çeşitli ölçek parametrelerine sahip bilgileri görüntülemek istiyorsak, bu temsil vazgeçilmezdir. Örneğin, işitilebilir aralıktaki ses sinyalleri için on oktav yayılması yaygındır. Bu gösterimin bir

dezavantajı, açık  $(b, a)$  yarım düzlemdeki düz çizgilerin logaritmik gösterimde üstel eğriler haline gelmesidir.

3.13 denklemi, analiz dalgacık  $y$ 'nin seçimine bağlıdır.  $S(b, a)$  üzerinde dönüşüm gerçekleştirilerek elde edilen  $s(t)$  sinyalinin kantitatif analizi hakkında tam veri elde etmek için, analiz dalgası  $y$ 'yi bilmemiz gerekir. Bununla birlikte, sinyalin  $\psi$  seçiminden bağımsız birçok özelliği vardır. Bu özellikler, karmaşık değerli fonksiyonların fazını içerir. Bu nedenle, tarif edilecek karmaşık değerli fonksiyonun  $S(b, a)$  modülünü ve fazını ayrı ayrı temsil etmek yararlıdır.

Şekil 3.5'de, bir delta fonksiyonuna yaklaşan lokalize bir pulsun dalgacık dönüşümünün bir örneği gösterilmektedir.



Şekil 3.6. Bir delta fonksiyonunun dalgacık dönüşümünün (a) büyüklüğü ve (b) fazı.

Yatay b-eksenleri, zaman içinde hem büyüklük gösterimi hem de faz gösterimidir. Dikey a-eksenler, küçük ölçek üstte olacak şekilde ölçeklerdir.

Şekil 3.5. (a)'da, büyüklük grafiğinin üst kısmına doğru artar. Ayrıca, bu büyüklük  $|S(a, b)|$  daha sonra maksimum değerine normalize edilen gri tonlama sinyaline dönüştürülür. Bu grafik  $x$ 'i gösterir,

$$x = \frac{|S|}{|S_{max}|} \leq 1 \quad (3.16)$$

$S(a, b)$  fazı, 0 fazının beyaza ve  $2\pi$  fazının siyaha karşılık geldiği gri tonlamalı bir görüntü ile verilir. Bu düzen, ortaya çıkan resmin yorumlanmasında oldukça faydalıdır. Faz  $2\pi$  değerine ulaştığında, elde edilen değer 0 değerine sarılır. Yoğunluğun aniden sıfıra düştüğü çizgiler görüntü üzerinde açıkça görülebilir ve yorumda sabit fazın görünür çizgisi olarak önemli bir rol oynar. Şekil 3.5. (b)'de, delta fonksiyonunun yerini gösteren sabit faz çizgileri gözlenebilir.

### 3.4.3.1.5. Temel 1D DWT ayırık dalgacık dönüşümü

DWT'nin çalışması oldukça basittir, bu da girdinin dalgacın kaydırma ve ölçeği ile çarpılmasını içerir. Vardıya, zaman içindeki dönüşümdür ve ölçek, genişlemeler veya daralmalardır.

Yüksek geçiren filtre çıkışı şu şekilde verilir:

$$W_h(n, j) = \sum_{m=0}^{2n} W(mj - 1) \cdot highfilter(2n - m) \quad (3.17)$$

Alçak geçiren filtre çıkışı şu şekilde verilir:

$$W_l(n, j) = \sum_{m=0}^{2n} W(mj - 1) \cdot lowfilter(2n - m) \quad (3.18)$$

Dalgacık teorisi belirli değişkenler gerektirir bunlar aşağıda verildiği gibidir.

$W(n, 0)$ : giriş sinyali.

$N$ : toplam girdi örneği sayısı.

$J$ : toplam oktav miktarı.

$j$ : mevcut oktav, burada  $1 \leq j \leq J$

$L$ : filtrenin genişliği.

$n$ : şimdiki giriş örneği, burada  $1 \leq n \leq N$

$k$ : mevcut dalgacık katsayısı.

$W(n, j)$ : DWT sinyali.

Stephanie Mallat ve Yves Meyer [112], 1D dalgacık dönüşümlerini hızlı bir şekilde hesaplayan hızlı piramit algoritması sunmuştur. Metodolojinin etkinliği, her aşamada, genellikle aşağı örnekleme olarak da bilinen çıktı tarafından belirlenir. Metodolojinin genel karmaşıklığı  $O(N)$  olarak belirtilir, burada  $N$  toplam girdi örneği sayısıdır. Bu, karmaşıklığı  $O(N^2)$  olarak verilen diğer algoritmalara kıyasla çok etkilidir. Hızlı Fourier Dönüşümü için gereken hesaplama sayısı  $O(N * \log N)$  'dir. Dalgacık dönüşümü için gereken süreyi etkileyen faktörlerden biri, dalgacık katsayılarının toplam miktarıdır. Dalgacık katsayıları, her bir giriş örneği ile çarpılmalıdır. Bu nedenle, katsayıların sayısını minimumda tutmanız tavsiye edilir. Tersine, daha fazla sayıda dalgacık katsayısı daha iyi yaklaşıklık (approximation) oluşturur. Daha yüksek yaklaşımla, görüntünün ters dalgacık dönüşümü yoluyla yeniden yapılandırılması doğru olacak ve yeniden oluşturulan görüntünün ve orijinal görüntünün verileri kesin olacaktır. Bununla birlikte, yeniden yapılanma için geçen süre sıkıştırma ile aynıdır.

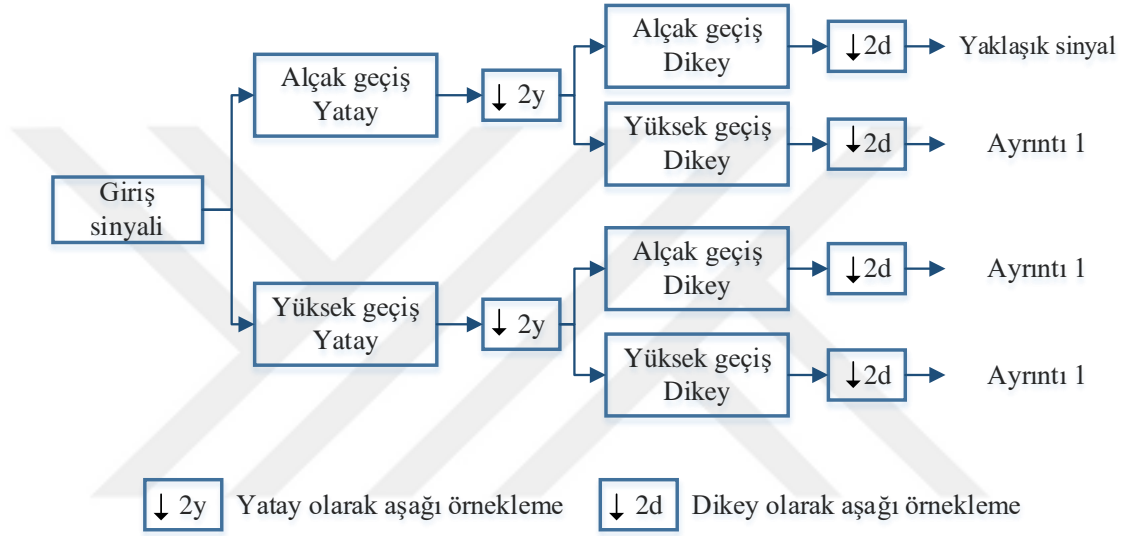
#### 3.4.3.1.6. 2D ayrık dalgacık dönüşümü

Sinyal 1D objesi olarak değerlendirilebildiğinde 2D DWT kullanımı hakkında sorulabilir. Ancak gerçekte, 2D DWT iyi düzeyde sıkıştırma sunar. Ayrıca, 1D düzleminde 2D bilginin temsil edilmesi, bozulmalara, süreksizliğe ve kenar etkilerine neden olacaktır. 1D DWT çoğunlukla ses ve müzik işlemede uygulanırken, 2D DWT ağırlıklı olarak görüntü işleme için kullanılır. Herhangi bir 2D verinin temsili ve işlenmesi için sağlam bir 2D DWT gerekir. 1D DWT'den farklı olarak, 2D DWT verileri hem  $X$  hem de  $Y$  eksenini boyunca işler. Şekil 3.6, tek bir oktav 2D DWT'yi göstermektedir. Dahası, 3D bilgi, örneğin videolar 2D DWT yöntemi kullanabilir.

Bir 2D DWT'nin karmaşıklığına gelince,  $m$  düzeyinde 2 boyutlu bir dalgacık için gereken ortalama filtreleme hesaplama sayısı,

$$2 + 2/4 + 2/16 + \dots + 2/4^{(m-1)} = (8/3)(1 - 4^{(-m)}) \quad (3.19)$$

Yukarıdaki Denklem 3.15, 2D dalgacının uygulanması için gerekli olan yüksek geçiren filtre ve alçak geçiren filtre miktarının üst sınırının  $8/3$  olduğunu göstermektedir. Yüksek geçiren filtrelerin ve alçak geçiren filtrelerin miktarı aynı olduğundan, kanallarındaki üst sınır  $4/3$  olarak kabul edilebilir. Kısacası, 2D DWT'nin uygulanması için 2 adet yüksek geçiren filtre ve 2 adet alçak geçiren filtre gerekir. Girdinin sınırları kenar etkilerinin ana nedenidir.  $N$  giriş numunesi olduğunda, FIR filtresinin sonuçları  $N + L - 1$  numunelerine sahip olacaktır. DWT'nin kenarlardaki hareket tarzı hala net değil. Ancak, bu konuda çok sayıda yaklaşımlar vardır.



Şekil 3.7. 2-Boyutlu, 1-oktavlı DWT

DWT'nin 2 boyutlu bir görüntü üzerinde çalışması Şekil 3.6.'da gösterilmektedir. Başlangıç olarak, veri sinyali yüksek geçiren filtreye ve düşük geçiren filtreye girdi olarak sunulur. Görüntü boyutu  $X$  ve  $Y$  koordinatları ile ölçülür.  $X$  görüntünün uzunluğuna,  $Y$  ise genişliğine karşılık gelir. Sinyal yatay çalışan ilk filtreden geçerken, görüntü  $Y$  uzunluğundaki vektörler olarak ele alınacaktır. Bir sonraki adımda, diğer tüm kolonlar yatay aşağı örnekleme ile atılır.

Bu sinyal daha sonra ikinci filtre grubuna iletilir. İkinci filtre setleri, giriş görüntü sinyallerini,  $Y$  genişliğinde  $X/2$  transpozisyonlu vektörler olarak algılar. Bir sonraki adımda, diğer her satır dikey aşağı örnekleme ile atılır. Bir seviye 2D DWT uygulanmasının sonucunda 3 ayrıntılı ve tek bir sinyal yaklaşımı ile 4 görüntü ortaya çıkar. Nihai görüntünün boyutu giriş görüntüsünün  $1/4$ 'i olacaktır. Bununla birlikte, ortaya çıkan bu görüntüler negatif veya irrasyonel sayılar gibi bazı geçersiz


değerlerden oluştuğu için hatalı olarak kabul edilir. Gri tonlamalı bir görüntü pikselinin değeri 0 ila 255 arasında olmalıdır. Ancak, bu tür geçersiz veri sinyalleri, uygun değerleri elde etmek için çaba göstermeden ilişkilendirilebilir. Sinyal yaklaşımını yeni bir giriş sinyali olarak algılayarak çok seviyeli DWT kolayca uygulanabilir. DWT her uygulandığında, bir sonraki sıkıştırma seviyesinin sonucu bir öncekinin  $1/4$ 'i olacaktır.

### 3.4.3.1.7. Çoklu çözünürlük kavramı ve analizi

Sinyallerin doğru bir şekilde temsil edilebilmesi için çoklu çözünürlük kavramı fikri tasarlanmıştır. Bu teknikte, sinyal daha küçük ve daha ince ayrıntılara bölünmelidir. Genel yaklaşım, daha ince detaylara sahip bir sinyali temsil eden model olarak benimsenmiştir. Bu detaylar ve genel yaklaşımlar birbirine ortogonaldır. Giriş sinyali, ardışık yaklaşım yardımı ile ardışık detay alanları ile çoklu çözünürlüklerle genişletilmelidir ve bunlar tekrarlı uygulanır.

### 3.4.3.1.8. Örnek seyreltici (decimator) ve aradeğerleyici (interpolator)

Örnekleme oranı baskın olarak iki temel işlemle, yani desimatör ve enterpolatör tarafından belirlenir. Decimator, örnekleme oranını azaltan aşağı örnekleyci olarak da bilinir. Öte yandan, yukarı örnekleyci olarak da bilinen enterpolatör örnekleme oranını artırır. Şekil 3.7.(a)'de, decimator aşağı giriş sinyalini  $x(n)$ , 2 katıyla örnekler. Benzer şekilde, Şekil 3.7.(b)'de ise gösterilen enterpolatör, giriş sinyalini  $x(n)$  2 katına kadar yukarıya örnekler. Yani interpolasyon ile veri sinyalindeki toplam numune miktarı artar.




Şekil 3.8.a. Seyreltici veya aşağı örnekleyci

b. Aradeğerleyici veya yukarı örnekleyci

Yukarıdaki şekil 3.7.(b)'de, örnek sayısı orijinal dizisinden iki kat artar. Boşluklar sıfırlarla doldurulur.

### 3.4.3.1.9. Filtre bankası

Filtre bankası, filtrelerin birleşiminden oluşur. Kurucu bankalar analiz bankası ve sentez bankasıdır. Bu tür filtre bankaları iki kanal için uygundur. Şekil 3.8.'de filtre bankası mimarisini göstermektedir

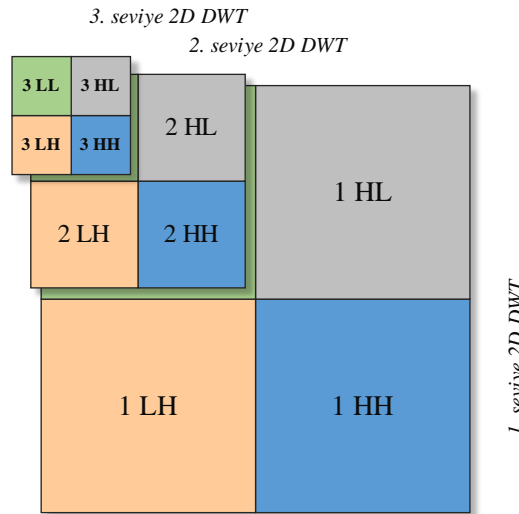


Şekil 3.9. Filtre bankası

Analiz bankası iki tür filtreleri içerir:

- Alçak geçiren filtre
- Yüksek geçiren filtre

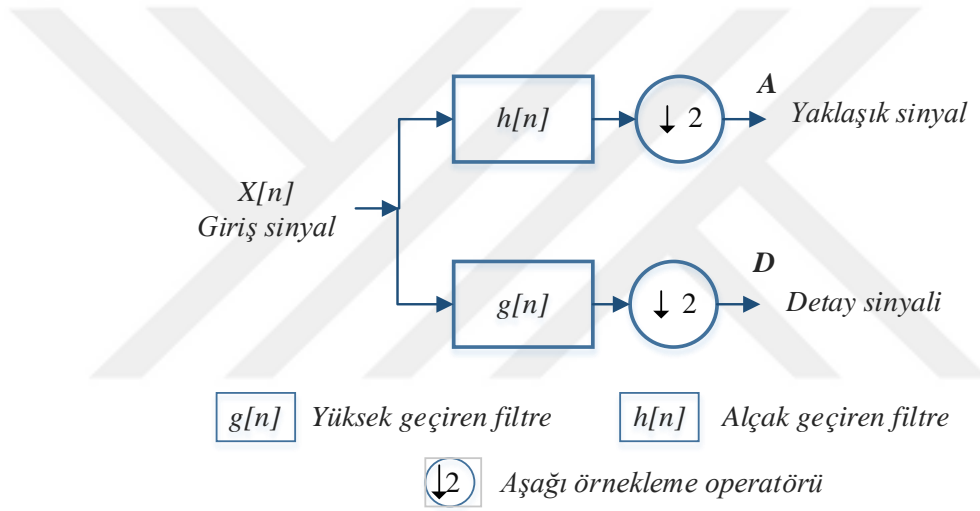
Bu filtreler giriş sinyali üzerinde çalışır ve frekans bantlarına ayırır. Sinyalin bu filtrelerden geçtiği noktada, sinyal HH – yüksek yüksek, HL – yüksek alçak, LH – alçak yüksek ve LL – alçak alçak olmak üzere dört frekans bandına ayrılır. Şekil 3.9'da gösterilmiştir. Bu işleme 1. ayrışma seviyesi denir. Sinyal katsayılarının detaylı setini gösterir.



Şekil 3.10. Üç seviyeli 2D dalgacık dönüşümü için alt bant etiketleme şeması



DWT, görüntüyü temsil etmek için bu tür dalgacıkları içeren bir ek işlev olarak faydalanılan dalgacıkları kullanır. Bu dalgacıklar bireysel ölçek ve konum içerir. Veriler, yaklaşık katsayılar olarak bilinen bir dizi alçak geçiş sinyali ve ayrıntı katsayıları olarak bilinen başka bir yüksek geçiş sinyalleri kümesi olarak temsil edilecektir. Daha sonra, veriler bir dizi yüksek geçişli ve alçak geçişli filtrelere girdi olarak verilecektir. Alçak ve yüksek geçişli filtrelerin sonuçta elde edilen sonuçları, bir sonraki adımda 2 katına kadar aşağı örneklenecektir. Sonra tekrardan, yüksek geçiş filtresinin çıkışı detay katsayı ve alçak geçiş filtresinin çıkışı yaklaşık katsayısı olur. 1D DWT'nin çalışmasını tasvir eden süreci Şekil 3.10'da gösterilmektedir.

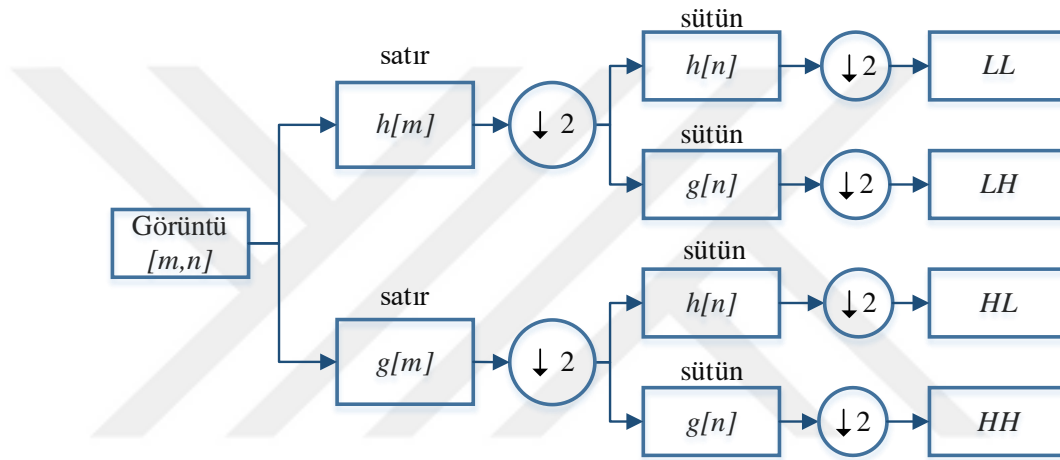


Şekil 3.11. 1D ileri DWT'nin çalışma şeması

Veri sinyalden geçtiğinde, sinyal örneklerinin miktarı iki katına çıkarılacak, diğer taraftan, desimatör bunu 2'ye böler. Basitçe, gerçek birincil sinyalin geri kazanılmasının bir olasılık olduğunu belirtir. Daha düşük seviye sinyali yardımıyla, yüksek ölçeğin örtüşmesi geçersiz kılınabilir. Bu, sinyal restorasyon filtre bankası fikri olarak ortaya çıkıyor.


Yukarıdaki ölçeklendirme katsayılarının sinyallerini filtreleme, bölme ve azaltma prosedürleri filtre bankalarının yinelemesi olarak bilinir. 2D DWT'deki filtre bankaları yinelemesi Şekil 3.11.'de gösterilmektedir. 2D DWT'yi elde etmek için, verilen giriş sinyalinin yatay satırları ve dikey sütunları, karşılıklı yönlerde hem yüksek geçişli hem

de alçak geçişli filtreye beslenir. Daha sonra elde edilen sekans, her iki yön için 2 faktör ile örneklenir. Şekil 3.9 ile ilgili olarak, çıktı görüntüsü HH, LH, HL ve LL olmak üzere dört frekans katsayısı içerir. İlk karakter satırın dönüşümünü gösterirken, sonraki karakter sütunun dönüşümünü gösterir. H harfi yüksek geçiş sinyali, L alçak geçiş sinyali anlamına gelir. Bu nedenle LL, hem satırların hem de sütunların alçak geçiş sinyallerini belirtir. Benzer şekilde HH, hem satırların hem de sütunların yüksek geçiş sinyaline karşılık gelir. HL, satırların yüksek geçiş sinyalini ve sütunların alçak geçiş sinyalini içerir. LH, HL'nin tam tersidir.




Şekil 3.12. 2D DWT'nin çalışma şeması

Bu çalışmada, Haar dalgacık alçak ile yüksek geçiren filtreleri ile 3 farklı ayrışma seviyesi olarak alt bantlara görüntüleri ayırıştırmak için baba Daubechies dik ayrık dalgacık dönüşümü (discrete wavelet transform – DWT) [112] tercih edilmiştir. Her üç seviyede de yaklaşık (approximation), çapraz, yatay ve dikey katsayılar üretilmiştir. Şekil 3.5.'te DWT yöntemi kullanılarak endoskopik duodenum görüntüsünün piramidal ayrışmasını göstermektedir. Bu uygulamalar, görüntü bölütleme tekniklerinin etkisini karşılaştırmak amacıyla gelişmiş görüntüler (enhanced images) ve bölütlenmiş görüntüler üzerinde gerçekleştirilmiştir.




Şekil 3.13. Görüntünün DWT ile piramidal ayrışması. Alt bantlar: alçak-alçak (LL), yüksek-alçak (HL), alçak-yüksek (LH) ve yüksek-yüksek (HH).

Şekil 3.6.'da bölütlenmiş görüntü ile sağlıklı (normal) ve çölyak hastalığı örneklerinin üç seviyeli piramit şeklinde DWT ayrışmasını göstermektedir. Şekil 3.7. benzer şekilde bölütleme olmadan gösterilmektedir. Haar dalgacık DWT ile alçak ve yüksek geçişli filtreleme sırasında, görüntü piksellerinin yaklaşık, çapraz, yatay ve dikey katsayıları gerçekleşir, bu da normal ve hasarlı villusun kenar bilgilerinin doğru bir şekilde algılanmasına sebep olur.



Şekil 3.14. Bölütlenmiş görüntü üzerinde (a) normal ve (b) çölyak hastalığı örneklerinin üç seviyeli piramidal DWT alt bantlarının ayrışması ile elde edilen görüntü örnekleri.



Şekil 3.15. Bölütlenmemiş görüntü üzerinde (a) normal ve (b) çölyak hastalığı örneklerinin üç seviyeli piramidal DWT alt bantlarının ayrışması ile elde edilen görüntü örnekleri.

DWT ile elde edilen görüntü piksellerinin yaklaşık, yatay, çapraz ve dikey katsayılarını kullanarak sağlıklı ve çölyak hastalığı görüntülerinin temsili gösterilmiştir. Burada, bölütlenmiş görüntü kategorisinin bölütlere ayrılmamış görüntüden daha net bir şekilde ayırt edilebileceği ifade edilebilir. Sonuç olarak, üçüncü düzey ölçeğinde birleştirilmiş dört alt bant görüntüsüyle ( $[LL, LH; HH, HL]$ ) oluşturulan DWT alt bant katsayıları özellik çıkartma için kullanılır.

### 3.4.3.2. Özellik çıkartma

En iyi özellik kümesi etkili ve ayırt edici özelliklere sahip olmalıdır, dolayısıyla DWT yöntemini ölçek ve döndürmeye duyarlı özellik çıkartma yöntemlerle birleştirerek birkaç özellik çıkartma kombinasyonları oluşturduk. Çölyak hastalığı tanısında özellik çıkartımı olarak belirlenen bu aşamada, çeşitli ölçek değişmezliği doku analiz yöntemleri uygulanmıştır ve bu yöntemler sınıflandırma oranına göre değerlendirilmiştir. Ölçek değişmezliği doku tanımlayıcıları olarak tanımlanan Lokal İkili Örüntüler (LBP), Yönlendirilmiş Gradyanların Histogramı (HOG) ve Hızlandırılmış Sağlam Özellikler (SURF) bu algoritmalar, normal ve çölyak hastalığı arasında ayırım yapmak için incelenmiştir.

### 3.4.3.3. Yerel ikili örüntüler

Yerel İkili Örüntüler (LBP) tanımlayıcısı [24], ikili örüntülerle temsil edilen ortalama gri piksel yoğunluğu farkı seviyesi arasındaki farkı hesaplayarak bir dokuyu tanır. Bu yöntem, çölyak hastalığının sınıflandırılmasında sıklıkla kullanılmaktadır, çünkü mekansal görüntü gösterimleri çok umut vericidir ve literatürde [16], [25]–[30], [113] çok sağlam ve doğru oldukları gösterilmiştir. Giriş görüntüsünün koşulu gerçek ve seyrek olmayan bir  $M$ -den- $N$  boyutunda  $2$ - $D$  gri tonlamalı görüntüdür.

LBP özellik çıkartma operatörü eşik seviyesi olarak  $3 \times 3$  pencerelerin ortasındaki piksel değerini seçerek görüntünün birbirine göre karşılaştırılması sonucunda ikili değerlerin atanmasına dayanır. Burada tanımlanacak iki parametre vardır. Bunlar, simetrik dairesel komşuluk bölgesinin numune noktalarının  $p$  sayısı ve yarıçapı  $r$  olarak belirlenir. Oradan, merkez piksel için LBP değerini hesaplanmasını gerektirir. Komşu piksellerden başlayabilir ve saat yönünde veya saat yönünün tersine çalışabilir, ancak siparişler, görüntüdeki tüm pikseller ve veri setindeki tüm görüntüler için tutarlı tutulmalıdır. Komşu pikseller, çift piksel enterpolasyonu kullanılarak yarıçapı  $r$  olan merkez piksel etrafındaki bir daire üzerinde eşit mesafede konumlara yerleştirilir. Örneğin,  $3 \times 3$  komşu göz önüne alındığında, ikili bir test yapılması gereken 8 komşusu vardır. Bu ikili testin sonuçları, daha sonra ondalık sayıya dönüştürüldüğü 8 bitlik bir dizide saklanır.

$$LBP_{p,r}(x_c, y_c) = \sum_{p=0}^{p-1} s(i_p, i_c) 2^p \quad (3.20)$$

Burada  $(x_c, y_c)$ , verilen piksel  $i_p$ 'sinin konumunu ve merkez piksel  $i_c$ 'nin gri seviyesini ifade eder.  $s$  fonksiyonu aşağıdaki gibi tanımlanır:

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

Komşu piksellerin gerçek sıralaması çıkartılan bilgilerle ilgili değildir.  $s$  fonksiyonu işaret fonksiyonu olarak işlev görür, burada farkı 0'dan küçük veya ona eşitse 1'e ve değilse 0'a eşlenir. Uygulamada, LBP algoritması parametrelerinin kombinasyonunu sekiz dairesel örnek, 32 hücre boyutu ve iki piksel yarıçapı ile yapılandırılmıştır.

#### 3.4.3.4. Yönlendirilmiş gradyanların histogramı

Yönlendirilmiş Gradyanların Histogramı (HOG), SIFT tanımlayıcılarına benzer şekilde, yerel nesne görünümü ve şekli, bir doku tanımlamak için yerel yoğunluk gradyanlarının veya kenar yönlerinin dağılımı ile hesaplanır [114]. Bu bağlamda, çölyak hastalığının bilgisayar destekli teşhisinde HOG benzeri Şekil Eğrilik Histogram (Shape Curvature Histogram – SCH) yöntemi [20], [115], [116] araştırılmıştır.

HOG özellik tanımlayıcısı uygulanmadan önce renk seviyesi doku görüntüleri gri seviyeye indirilir. Gri seviyeli görüntünün türev maskeleri kullanılarak, yatay gradyan  $f_x$  ve dikey gradyan  $f_y$  hesaplanır. Her pikselin yatay  $f_x$  ve dikey  $f_y$  görüntü gradyanı aşağıdaki gibi hesaplanır (Denklem 3.7).

$$\begin{cases} f_x(x, y) = I(x + 1, y) - I(x - 1, y) \\ f_y(x, y) = I(x, y + 1) - I(x, y - 1) \end{cases} \quad \forall x, y \quad (3.21)$$

Bu denklemlerde  $I(x, y)$ , görüntünün  $(x, y)$  noktadaki piksel yoğunluğunu (gri değeri) gösterir. Gradyan büyüklüğü ( $m$ ) (Denklem 3.8) ve gradyan yönelimleri ( $\theta$ ) (Denklem 3.9), yatay  $f_x$  ve dikey  $f_y$  görüntü gradyanları kullanılarak aşağıdaki şekilde hesaplanır.

$$m(x, y) = \sqrt{f_x(x, y)^2 + f_y(x, y)^2} \quad (3.22)$$

$$\theta(x, y) = \arctan \frac{f_y(x, y)}{f_x(x, y)} \quad (3.23)$$

burada  $f_x(x, y)$ , x eksenindeki ve  $f_y(x, y)$ , y eksenindeki bitişik piksellerin farkı olarak hesaplanan gradyanlardır. Her bir hücrede hesaplanan yönelim  $\theta(x, y)$ ,  $c_b$  yönlendirme kutularına nicelenir. Her bölmedeki tüm  $m(x, y)$  büyüklükleri toplanır ve sonra bir histogram oluşturur. Açıkçası, görüntü  $8 \times 8$  piksellik hücrelere bölünür ve her hücre için yön histogramları hesaplanır. Histogram bölmelerini üretmek için  $0-180^\circ$  aralığı eşit olarak bölünür (genellikle 9 parçaya). Her piksel için, gradyan yönelimi  $\theta(x, y)$  kutuyu (bin) belirler ve gradyanın büyüklüğü  $m(x, y)$ , pikselin o kutuya katkısını hesaplamak için kullanılır. Örtüşümden kaçınmak için en yakın iki bölmeler de güncellenir. Piksel  $b$  bölmesine aitse,  $v_b$  katkısı  $b$  bölmesine ve en yakın kutulara  $v_{b\pm 1}$  katkılar şu şekilde belirlenir: Piksel kutu  $b$ 'ye aitse  $v_b$ 'nin kutu  $b$ 'ye katkısı ve en yakın  $v_{b\pm 1}$  kutulara olmak üzere katkıları şu şekilde (Denklem 3.10) belirlenir:

$$v_b = (1 - \alpha) \cdot m(x, y), \quad v_{b\pm 1} = \alpha \cdot m(x, y) \quad (3.24)$$

burada  $\alpha$ , aşağıdaki (Denklem 3.11) gibi hesaplanan pikselin ağırlığıdır:

$$\alpha = (b + 0.5) - \frac{n \cdot \theta(x, y)}{\pi} \quad (3.25)$$

burada  $n$  toplam kutu sayısını gösterir (genellikle 9'dur).

Daha sonra, ekstrakte edilen her hücre ve daha büyük bloklar  $[n \times m]$  için blok normalizasyonu gerçekleştirilir. Normalize özellik vektörü  $h$ , Normalleştirilmemiş özellik vektörü  $v$ 'nin Denklem 3.12.'deki gibi  $L2 - norm$  yöntemiyle normalleştirilmesiyle elde edilir.

$$h = \frac{v}{\sqrt{\|v\|^2 + \epsilon^2}} \quad (3.26)$$

HOG algoritmasının parametrelerini şu şekilde ayarladık: 9 histogram bölmesi, 20 derecelik açılal çözünürlüğe karşılık gelen aralığa yönlendirilmiştir. HOG hücrenin boyutu 32 pikseldir.

### 3.4.3.5. Hızlandırılmış sağlam özellikler

Hızlandırılmış Sağlam Özellikler (SURF) yöntemi ilk olarak Bay ve ark. [117] tarafından 2006 yılında tanıtıldı. Sınıflandırma görevleri için güçlü çalıştıklarını, test setlerinde rakiplerinden daha iyi performans gösterdiklerini ve hızlı hesaplamalara sahip olduklarını kanıtladılar. Kısmen SIFT'den ilham alınan bu yöntem, ölçek ve yönelimdeki değişikliklerden etkilenmeyen bir tanımlayıcıdır. Birinci derece Haar dalgacık yanıtlarının gradyan yerine  $x$  ve  $y$  yönünde dağıtılması ve hızı da integral görüntülerden faydalanılması için tasarlanmıştır. SURF tanımlayıcısı çölyak hastalığının teşhisi edilmesi ve sınıflandırılmasında henüz incelenmemiştir. Fakat SIFT yönteminde tanıtılan birkaç çalışma [17], [18], [110], [111], [115], [118], [119] bulunmuştur.

SURF detektörü, Hessian  $H(X, \sigma)$  matrisinin determinantını kullanarak özellik vektörleri elde eder. Hessian matrisinin determinantının maksimum olduğu yer, görüntü bölgelerini (lekeler) elde etmek için kullanılır. Ölçek ve yer seçimi için iki farklı yöntem kullanılır ve her ikisi için Hessian matrisinin determinantı kullanılır. Görüntünün  $I(x, y)$  noktası için Hessian matrisi aşağıdaki gibi tanımlanır.

$$H(I(x, y)) = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial y \partial x} \\ \frac{\partial^2 I}{\partial x \partial y} & \frac{\partial^2 I}{\partial y^2} \end{bmatrix} \quad (3.27)$$

Hessian matrisinin determinant aşağıdaki eşitlikte (Denklem 3.14) gösterilmiştir.

$$\det(H(I(x, y))) = \frac{\partial^2 I}{\partial x^2} \frac{\partial^2 I}{\partial y^2} - \left( \frac{\partial^2 I}{\partial x \partial y} \right)^2 \quad (3.28)$$



Gauss Laplacian (LoG) ile görüntünün ikinci derece türevi elde edilir ve ölçek alanında sürekli olarak değiştirilmeyen anahtar noktalar elde edilir.  $I$  görüntüsünde ölçekli  $P(x, y)$  noktasındaki Hessian matrisi aşağıdaki gibi hesaplanır.


$$H(P, \sigma) = \begin{bmatrix} L_{xx}(P, \sigma) & L_{xy}(P, \sigma) \\ L_{xy}(P, \sigma) & L_{yy}(P, \sigma) \end{bmatrix} \quad (3.29)$$

SURF algoritmasında, Gauss ikinci dereceden kısmi türev değerleri, hesaplama hızını arttırmak için kullanılan kutu filtresi yardımıyla elde edilir.  $L_{xx}(P, \sigma)$ , Gaussian ikinci dereceden  $I$  görüntüsündeki  $P$  noktasından  $\frac{\partial^2}{\partial x^2} g(\sigma)$  evrişim türevi alınarak elde edilir. Diğerleri için de aynı şekilde devam eder. Denklem (3.16) yardımıyla elde edilen yeni Hessian matrisi için determinant değer hesaplanır.

$$\det(H_{approx}) = D_{xx}D_{yy} - (wD_{xy})^2 \quad (3.30)$$

burada  $w$ , 0.912 olarak tanımlanan izafi ağırlıktır [117]. Denklem 3.14.'te  $D_{xx}$ ,  $D_{yy}$  ve  $D_{xy}$  yaklaşık değerleri bir kutu filtresi yardımıyla hesaplanan  $L_{xx}$ ,  $L_{yy}$  ve  $L_{xy}$  Hessian matris elemanlarını temsil eder.

Uygulama aşamasında parametre ayarları olarak, çoklu ölçek boyutlarına sahip 16 grid adımında bir nokta konumu seçtik.



Şekil 3.16. KTH-TIPS2 veri tabanından tam buğday ve beyaz ekmek örnekleri.

Bu çalışma kapsamında, KTH-TIPS2 [120] kamu veritabanına dayalı olarak tüm ölçek değişikliğe duyarlı doku tanımlayıcılarının veya önerilen hibrit makine öğrenme algoritmalarının değerlendirilmesi için deneysel testler gerçekleştirilmiştir. Dolayısıyla, çölyak hastalığının ayırt edilmesi ve önerilen algoritmalarının optimize edilmesine yönelik olarak KTH-TIPS2 veritabanından çölyak hastalığı görüntülerine daha benzer görüntülü materyaller seçtik bunlar siyah ve beyaz ekmeklerin görüntü veri setlerinden oluşmuştur (Şekil 3.16.). Bu görüntüler ölçek değişkenliği ve desen benzerliği gibi özelliklere mümkün olduğunca yakındır.

Tablo 3.2. Tam buğday ve beyaz ekmeklerin 10 kat çapraz doğrulama stratejisini kullanan çeşitli sınıflandırıcıların performansları. Tablodaki kısaltmalar: 1L-tek seviyeli, DP-doğru pozitif, TN-doğru negatif, YP-yanlış pozitif, YN-yanlış negatif.

No.	Modeller / Sınıflandırıcılar	DP	DN	YP	YN	ACC (%)	SEN (%)	SPE (%)
<b>Bölütlenmiş görüntü veri seti</b>								
1	1L DWT-LBP-Doğrusal Ayrımcı	287	266	8	25	94.37	91.99	97.08
2	1L DWT-HOG-KNN (k=10)	288	282	7	9	97.27	96.97	97.58
3	1L DWT-SURF-KNN (k=10)	275	257	20	34	90.78	89.00	92.78
<b>Toplam / Ortalamalar</b>		<b>850</b>	<b>805</b>	<b>35</b>	<b>68</b>	<b>94.14</b>	<b>92.65</b>	<b>95.81</b>
<b>Bölütlenmemiş görüntü veri seti</b>								
1	1L DWT-LBP-Doğrusal Ayrımcı	288	261	7	30	93.69	90.57	97.39
2	1L DWT-HOG-KNN (k=10)	287	281	8	10	96.93	96.63	97.23
3	1L DWT-SURF-KNN (k=10)	270	257	25	34	89.93	88.82	91.13
<b>Toplam / Ortalamalar</b>		<b>845</b>	<b>799</b>	<b>40</b>	<b>74</b>	<b>93.52</b>	<b>92.00</b>	<b>95.25</b>

KTH-TIPS2 veritabanı, 11 malzemedan oluşan iki oktav üzerinde logaritmik olarak 9 aralıkta görüntüler içerir ve ölçeklerin her biri 12 görüntüden oluşur. Her görüntü materyali 4 örnekle oluşturulmuş ve her örnek toplam 108 görüntü içermektedir. Tüm görüntüler manuel olarak  $200 \times 200$  piksele kırpılmıştır. Görüntü verileri KTH-TIPS2 veritabanında 864 siyah ve beyaz ekmek görüntüsünden rastgele %30'lik eğitim seti ve %70'lik test seti olarak seçilmiştir.

Karar ağaçları (decision trees-DT), destek vektör makineleri (support vector machines-SVM), ayırma analizi (discriminant analysis-DA), en yakın komşu sınıflandırıcılar (nearest neighbor classifiers-KNN) ve takım sınıflandırıcılar

(ensemble classifiers-EC) gibi çeşitli sınıflandırıcı yöntemlerinde test veri kümesinden elde edildiği deneysel sonuçlar tam buğday ve beyaz ekmek olmak üzere iki sınıfa ayırt edilmiştir ve en yüksek performansları (doğruluk-ACC, duyarlılık-SEN ve özgüllük-SPE) kaydedilerek Tablo 3.2.'de gösterilmiştir.

### 3.4.3.6. Özellik azaltma

Aşırı özellikler, hesaplama süresini ve bellek depolamasını artırır, bu da bazen sınıflandırma sürecinde bazı komplikasyonlara (boyutluluk fazlalığı) neden olur ve bu nedenle özelliklerin sayısını azaltmak gerekir.

En yeni ve daha verimli çölyak hastalığı CAD sistemleri, farklı seviyelerde dalgacık katsayılarını elde etmek için endoskopik görüntülerinin ayırık dalgacık dönüşümü ayrıştırmasını gerçekleştirmiştir [17], [18], [111], [19], [30], [35], [38], [39], [41], [69], [110]. Verilerin boyutunu azaltmak için temel bileşenler analizi (PCA), bağımsız bileşenler analizi (ICA) ve doğrusal diskriminant analizi (LDA) kullanılmıştır [63], [68], [121].

Endoskopik görüntülerinden bir grup son derece önemli özellikler çıkartılmıştır ve bunları normal, anormal sınıflara doğru bir şekilde sınıflandırmak için SVM sınıflandırıcılarda kullanılmıştır. Özellik çıkartma (LBP, HOG, SURF) ve özellik azaltma (PCA) algoritmaları arasındaki entegrasyon, daha az hesaplama maliyetiyle ince bağırsağı klinik olarak kabul edilebilir doğrulukla sınıflandırabilen bir CAD tekniğinin geliştirilmesine yol açtı. Geliştirilen CAD sistemi, klinisyenin çölyak hastalığına ilişkin ilk teşhisine ek güven sağlayan otomatik, basit, objektif, hızlı ve uygun maliyetli bir ikincil teşhis aracı olarak kullanılabilir.

Temel bileşen analizi, düşük hesaplama maliyeti ve hesaplama karmaşıklığı ile optimum altı bir çözüm sağladığı için en iyi bilinen ve kullanılan altuzay projeksiyon tekniğidir. PCA, çok sayıda birbiriyle ilişkili değişkenden oluşan bir veri setinin mevcut girdi özelliklerini, varyasyonların çoğunu korurken yeni bir daha düşük boyutlu özellik alanına dönüştürmek için etkili bir stratejidir.

Girdi özellik alanı, korelasyon matrisinin en büyük özvektörleri kullanılarak daha düşük boyutlu bir özellik uzayına dönüştürülür ve varyanslarına veya önemlerine göre yeni bir sıralı değişken seti oluşturur [122]. PCA, verileri daha hızlı ve etkili bir şekilde işlemek ve veri boyutlarını azaltmak için kullanılan veri setinde mevcut olan varyasyonu olabildiğince tutan istatistiksel bir yöntemdir [123].

Bu tekniğin üç aşaması vardır: girdi vektörlerinin bileşenlerini birbiriyle ilişkisiz olacak şekilde dikey hale getirir, ortaya çıkan ortogonal bileşenleri sıralar, böylece en büyük varyasyona sahip olanlar önce gelir ve verilerdeki varyasyona en az katkıda bulunan bileşenleri ortadan kaldırır. PCA'ya dayalı bir özellik azaltma sistemi kullanmak, özellik vektörlerini PCA tarafından seçilen bileşenle sınırlandırarak verimli bir sınıflandırma algoritmasına yol açar. Dolayısıyla, yaklaşımımızda PCA kullanmanın arkasındaki ana fikir, dalgacık katsayıları ile çıkan LBP, HOG ve SURF özellik vektörlerinin boyutsallığını azaltmaktır, bu da daha verimli ve doğru bir sınıflandırıcı ile sonuçlanır.

#### **3.4.3.7. Sınıflandırma**

Özellik seçimi ve azaltma aşamasında görüntünün ayırt edici özellikleri seçildikten sonra, sınıflandırma işlemi başlar. Seçilmiş olan en iyi  $k$  özellikleri, normal ve çölyak hastalığı arasında ayırım yapmak için bağımsız olarak sınıflandırma amacıyla kullanılır. Örüntü tanıma yöntemleri tıbbi görüntü analizi için, özellikle seçilen özelliklerin doğru sınıflara dağıtılması için önemlidir. Endoskopik sistemlerden elde edilen verilerin doğası, daha klasik doku sınıflandırma senaryolarından farklıdır. Çünkü insan sindirim sistemi çok karmaşık bir ortam sunar.

Bu çalışmada, bir takım SVM sınıflandırıcıları ile çeşitli gözetimli makine öğrenme modelleri eğitilmiştir. Doğrusal, kuadratik ve kübik çekirdek fonksiyonlarına sahip SVM sınıflandırıcıları eğitim veri seti ile eğitilmiş ve bu çalışmada performansları 10 kat çapraz doğrulama stratejisi kullanılarak doğrulanmıştır.

Bu tezde önerilen tüm yöntem ve algoritmalar, Intel i3 işlemci ve 8 GB RAM ile Microsoft Windows 10 64-bit ortamında MATLAB 9.4'te uygulanmıştır.



## BÖLÜM 4. ARAŞTIRMA BULGULARI

### 4.1. Sınıflandırıcılar Performanslarının Karşılaştırılması

Önerilen piramidal DWT esaslı LBP, HOG ve SURF özellik çıkartma modelleri, bölütlenmiş ve geliştirilmiş (bölütlenmemiş) görüntü setleri üzerinde ayrı ayrı olarak uygulanmış ve elde edilen performanslar biyopsi sonuçlarına göre karşılaştırılarak kaydedilmiştir. Bölütlenmiş ve bölütlenmemiş görüntü performansları, 10-kat çapraz-doğrulama stratejisi kullanılarak çeşitli SVM sınıflandırıcılarda değerlendirilmiş ve sonuçları Tablo 4.1-4.6.'da gösterilmiştir. Her sınıflandırma modeli için iki sonuç verilmiştir (örneğin, bölütlenmiş ve bölütlenmemiş görüntü veri setleri). Tüm bu değerlendirme setleri, eğitilmiş sınıflandırıcıların parametreleriyle aynı şekilde sınıflandırılmıştır.

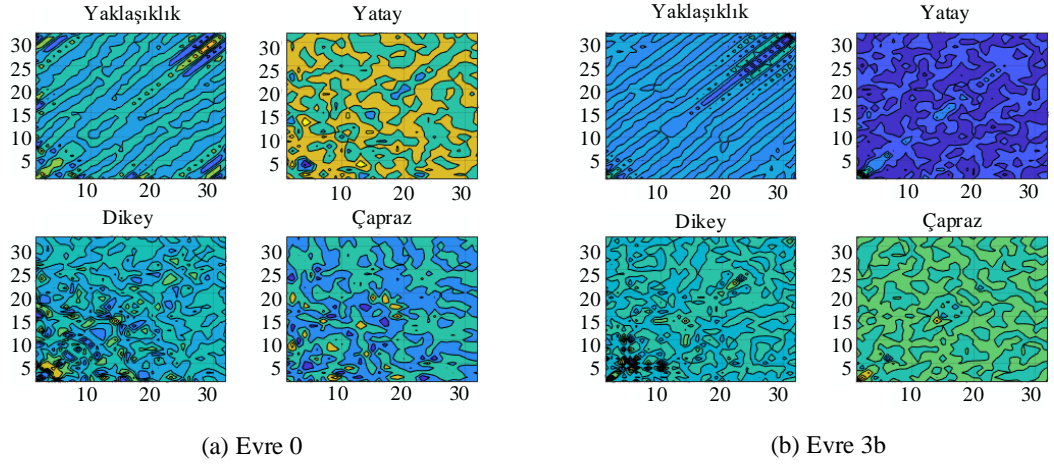
Önerilen yöntemleri CNN ve DWT ile özellikle çölyak hastalığını ayırt etmek için geliştirilen HOS nonlineer özelliklerle karşılaştırılmıştır. DWT alt bantlarından oluşan HOS bispektrumunun bir örneği Şekil 4.1.'de gösterilmiştir. Spektrumdaki farklılıklar, “normal” ve “çölyak hastalığı” olarak iki sınıf arasında ayırım yapmayı mümkün kılmıştır.

MatConvNet çerçevesi kullanılarak Shallow (sığ) ağların mimarisinde CNN sonuçları elde edilmiştir [64]. Sığ ağ, iki ardışık evrişimli katmandan oluşur ve bu  $11 \times 11$  ve  $7 \times 7$  boyutlarında  $N = 48$  filtreli olarak ayarlanmıştır.

Önerilen yöntemlerin performansı aynı görüntü veri seti üzerinde en güncel yaklaşımlarla karşılaştırılmıştır ve sonuçları Tablo 4.1.'nin 10.-11. satırlarda gösterilmektedir.

Tablo 4.1. Mevcut görüntü veri setinde önerilen ve güncel yöntemlerin karşılaştırılması

<i>No.</i>	<i>Modeller / Sınıflandırıcılar</i>	<i>DP</i>	<i>DN</i>	<i>YP</i>	<i>YN</i>	<i>ACC (%)</i>	<i>SEN (%)</i>	<i>SPE (%)</i>
<b><i>Bölütlenmiş görüntü veri seti</i></b>								
DWT-LBP-SVM models								
1	Lineer SVM	32	59	2	3	94.79	91.43	96.72
2	Karesel SVM	32	58	3	3	93.75	91.43	95.08
3	Kübik SVM	33	58	3	2	94.79	94.29	95.08
DWT-HOG-SVM models								
4	Lineer SVM	29	59	2	6	91.67	82.86	96.72
5	Karesel SVM	30	59	2	5	92.71	85.71	96.72
6	Kübik SVM	28	59	2	7	90.63	80.00	96.72
DWT-SURF-SVM models								
7	Lineer SVM	31	58	3	4	92.71	88.57	95.08
8	Karesel SVM	30	58	3	5	91.67	85.71	95.08
9	Kübik SVM	29	58	3	6	90.63	82.86	95.08
<b><i>En güncel yöntemlerle karşılaştırma</i></b>								
10	CNN	33	57	4	2	93.75	94.29	93.44
11	DWT-HOS-SVM	31	55	6	4	89.58	88.57	90.16
<b>Toplam / Ortalamalar</b>		<b>338</b>	<b>638</b>	<b>33</b>	<b>47</b>	<b>92.43</b>	<b>87.79</b>	<b>95.08</b>
<b><i>Bölütlenmemiş görüntü veri seti</i></b>								
DWT-LBP-SVM models								
1	Lineer SVM	32	57	4	3	92.71	91.43	93.44
2	Karesel SVM	31	59	2	4	93.75	88.57	96.72
3	Kübik SVM	31	58	3	4	92.71	88.57	95.08
DWT-HOG-SVM models								
4	Lineer SVM	29	56	5	6	88.54	82.86	91.8
5	Karesel SVM	31	55	6	4	89.58	88.57	90.16
6	Kübik SVM	32	55	6	3	90.63	91.43	90.16
DWT-SURF-SVM models								
7	Lineer SVM	29	53	8	6	85.42	82.86	86.89
8	Karesel SVM	30	52	9	5	85.42	85.71	82.86
9	Kübik SVM	29	53	8	6	85.42	82.86	86.89
<b><i>En güncel yöntemlerle karşılaştırma</i></b>								
10	CNN	28	52	9	7	83.33	80.00	85.25
11	DWT-HOS-SVM	27	49	12	8	79.17	77.14	80.33
<b>Toplam / Ortalamalar</b>		<b>329</b>	<b>599</b>	<b>72</b>	<b>56</b>	<b>87.88</b>	<b>85.45</b>	<b>89.05</b>



Şekil 4.1. (A) normal ve (b) çölyak hastalığının DWT alt bantlarının HOS bispektrum temsilleri. Spektrumdaki farklılıklar, sınıflar arasında ayırt edilmesine izin verir

DWT'den elde edilen HOS bispektrum grafiklerinin bir temsili Şekil 4.1'de gösterilmektedir. Görülebileceği gibi spektrumdaki farklılıklar, sınıflar arasında ayırt edilmesine izin verebilecek düzeydedir. Dört yöndeki (yaklaşık, yatay, dikey ve çapraz) bu çizimler farklı ve benzersizdir.



## BÖLÜM 5. TARTIŞMA VE SONUÇ

### 5.1. Sonuç

Çölyak hastalığındaki klinik bulgular oldukça farklı ve değişkendir. Bu nedenle, çölyak hastalığının doğru bir şekilde teşhis edilmesi nispeten zordur. Hastalığın tanısı yüksek oranda yanlış tanı ile sonuçlanabilmektedir. Ayrıca, tüm hastaların yarısından fazlası teşhis edilmemiştir ve hastalığın farkında değildir. Bu nedenle, asemptomatik vakaların daha fazla teşhisi, hastalığın buzdağı modeline benzemesine neden olmuştur. Hastalık teşhis edilemezse, ciddi sağlık sorunlarına neden olur. Tedavisi, ömür boyu süren katı glutensiz bir diyetdir ve tedaviye başlamadan önce güvenilir bir tanı önemlidir. Çölyak hastalığının mevcut teşhis yöntemleri, tamamen gözlemciye bağlı olan altın standarttır. Hedef bölgelerden üst endoskopi ile biyopsi yapılması oldukça invaziv olduğu için kısa sürede tanı konmalıdır. Bunu yerine getirmek gözlemcilerin ilgili çabalarını ve uzmanlıklarını gerektirir. Bu nedenle, bu çalışmada, çölyak hastalığının standart endoskopi görüntüsü ile otomatik olarak tespit edilmesini sağlayan akıllı makine öğrenme tekniğine dayanan hibrit bir algoritma önerilmiştir.

Çölyak hastalığının teşhisinde üst endoskopi kullanılmaktadır ve sıklıkla standart esnek endoskopi ile karşılaşılmaktadır. Genel olarak, hekimler üst endoskopi ile duodenumun birinci (üst kısım) ve ikinci kısmının (inen kısım) uzak görüşlerine göre (örneğin, Şekil 3.1.) çölyak hastalığının ön tanısını koyarlar.

Rutin endoskopi sırasında tamamen aynı görünümlere göre görüntü veri seti oluşturulmuş ve sınıflandırma prosedürleri sadece görüntü verileri kullanarak uygulanmıştır. Bu yaklaşımlarla zamanı ve fazladan işlem gereksinimini azaltmak için amaçlanmıştır. ÇH tanısının doğrulanması biyopsi bulgularına ve serolojik testlere dayanmaktadır.

Önerilen teknik ilk önce esnek hesaplama teknikleri kullanarak görüntü bölütleme için uzamsal bağlama dayalı optimal çok seviyeli enerji eğrisi eşikleme ve daha sonra endoskopik görüntülerden özellikler çıkartmak amaçla LBP, HOG ve SURF operatörlerinin DWT ile kombinasyonu uygulanmıştır. Ayrıca, özellik vektörlerinin boyutsallığını azaltarak daha verimli ve doğru bir sınıflandırıcı ile sonuç elde edilmiştir.

Endoskopik seans sırasında görsel görünüm, ölçekler ve rotasyonlar nedeniyle oldukça değişkendir. Sonuç olarak, esnek endoskopi görüntülerinden ÇH'nin otomatik teşhisine dalgacık dönüşümlü ölçek değişmezliği (ölçek ve yönden bağımsız) doku tanımlayıcıları uygulanmıştır.

Test veri setindeki deney sonuçlarına göre, önerilen algoritmalar çölyak hastalığının otomatik teşhisi için etkilidir. Bununla birlikte, bölütlere ayrılmamış ve bölütlenmiş görüntüler karşılaştırıldığında, uzamsal bağlam dayalı görüntü bölütleme yönteminin daha verimli doğruluk sağladığı bulunmuştur. Önerdiğimiz yöntemler segmentlere ayrılmamış görüntüler için aşağıdaki sınıflandırma performanslarını üretmiştir: Piramidal DWT-LBP-Kübik SVM modeli sırasıyla %94,79 doğruluk, %94,29 duyarlılık ve %95,08 özgüllükte en yüksek sınıflandırma performansını göstermiştir. Görüntü bölütlemeyi gerçekleştiren Energy-Otsu-CS yönteminin en yüksek etkisi Piramidal DWT-SURF-SVM modellerindeydi. Bu yöntemin etkisiyle sınıflandırıcı modellerin sınıflandırma oranı (doğruluk) %7,29'a kadar çıkarılmıştır. Bu deneylerin sonuçları, önerilen sınıflandırma tekniğinin normal ve çölyak hastalığını başarılı bir şekilde ayırt edebildiğini ve duodenumda çölyak hastalığının tanısal doğruluğunu artırabildiğini göstermektedir.

## 5.2. Tartışma

### 5.2.1. Çalışmanın sınırlamaları

Kamuya açık bir ÇH veri tabanı olmadığından, bu çalışmanın sonuçları özel bir veri tabanı oluşturularak elde edilmiştir. Veri setine Tablo 3.1.'de gösterildiği gibi 87 hastanın toplam 330 görüntüsü dahil edildi. 87 hastadan 11'i ÇH olarak ve geri kalanı normal hasta olarak kabul edilmiştir. Görüntü veri setinin oluşması için her bir hastada ÇH'nin altın standart tanısı uygulanmıştır.

Veri setinin dağılım listesine göre, Evre 0-2 grubunun Evre 3a-3c grubuna göre daha yüksek önyargıya sahip olduğu anlaşılmaktadır. Bunun nedeni veri tabanımızın belirli bir süre içinde oluşturulması ve bu dönemde gelen tüm hastalardan üst GI endoskopik görüntülerin alınmasından kaynaklanmaktadır. Tüm bu hastalara seroloji ve patoloji testleri yapılarak görüntülerin temel gerçeği sağlanmıştır. Ayrıca sadece ilk defa ÇH tanısı konulan hastalardan çölyak hastalığı görüntüleri alınmıştır. Bunun yanı sıra hekimin ön tanısı ile yanlış pozitif bulunan hastaların verileri de Evre 0-2 grubuna dahil edilmiştir. Diğer bir deyişle, ÇH şüphesi olan tüm hastaların verileri veri tabanına eklenmiştir. Böylece önerilen CAD sisteminin doğruluğunun artırılması hedeflenmiştir.

Sağlam bir karar destek sistemi oluşturmak üzere ilk aşamanın garanti altına alınması için burada daha fazla veri kullanılmıştır. CAD sistemi daha az veri ile daha doğru sonuçlar verebilir. Çünkü yapay zekâ yöntemlerinde veri setinin minimum bir değerden çok ortalama bir değere ihtiyacı vardır. Doğruluktaki artış, doğru örneklerle paralel olarak %100'e varan doğruluk oranlarına ulaşabilmektedir. Bu aşamadaki başarı durumu, ilerleyen aşamalardaki başarı oranının yükseltecektir.

Bir diğer sınırlama da mevcut veri tabanını oluşturan görüntülerin, kaçınılmaz olarak düzlemsel olmayan geometrilere ve organların deformasyonlarına maruz kalmasıdır. Ayrıca yansımalar, kabarcıklar, bulanıklık ve lens distorsiyonu da GI endoskopi görüntü analizinde farklı etki dereceleri sağlar. Lens distorsiyonu, cihaz hazırlama aşamasında çözülebilir. Bulanıklığın görüntü kalitesini en olumsuz şekilde etkileyen

olduğu bilinmektedir. Gastrointestinal ortamın ve kamera mesafelerinin hızla değişen perspektifleri, ölçek değişmezliği doku analizini olumsuz etkilemediğinden bu tür yöntemlerin etkinliğini artırmaktadır. Aynasal yansımalar görüntünün yüksek yoğunluğa sahip alanlarını oluşturarak görüntünün bilgi kaybına neden olabilmektedir. Bu amaçla, aynasal yansımaları kaldırmak önemli bir konudur. Bu tür problemlerden kaçınmak için modifiye daldırma tekniği (modified immersion technique – MIT) kullanılmakta ve mukozal yüzey yakın bir perspektiften incelenmektedir. Bununla birlikte, bu tür yaklaşımlar endoskopik sekansın süresini daha da uzatmaktadır [12], [13], [118].

Son olarak, kullanılan ÇH görüntü veri tabanına bir karşılaştırma yaklaşımı uygulamak iyi olacaktır. Farklı ÇH veritabanlarının farklı zorlukları vardır, bu nedenle bir karşılaştırma yalnızca karşılaştırma yöntemleri aynı veritabanına uygulandığında belirleyici olacaktır. Bunu yapmak için derin öğrenme ve daha yüksek dereceli spektrumlar (HOS) gibi en son yapılan çalışma yöntemleri aynı veri tabanına uyguladık. Karşılaştırma sonuçları Tablo 4.1.'de verilmiştir.

### 5.2.2. Tartışma ve gelecekteki çalışmalar

Önceki çalışmalarda, Koh ve ark. [69] 1. seviye DWT katsayılarına göre doğrusal olmayan HOS (Higher Order Spectra) yöntemini kullanmış ve çıkartılan özellikleri ayırt etmek için SVM uygulamıştır. 10 kat çapraz doğrulama stratejisi ile %86,47 doğruluk seviyesi elde etmişler.

Son zamanlarda, villus atrofisinin otomatik tespiti için daha doğru kararlar vermek amaçla derin öğrenme (DL) tabanlı çalışmalar kullanılmıştır. Wimmer ve ark. [63] çölyak hastalığının otomatik teşhisi için bir Evrişimli Sinir Ağı (CNN) mimarileri geliştirmiştir. 353 hastadan esnek endoskoplar aracılığıyla toplanan 128×128 piksellik 1661 RGB görüntü yaması üzerinde çapraz doğrulama (%80 eğitim ve %20 test seti) ile gerçekleştirerek test setindeki en derin mimari için  $\approx$ %97 sınıflandırma oranına ulaşmıştır. Zhou ve ark. [66] eğitim seti için 11 çölyak ve 10 kontrol hastası WCE klipi kullanılarak GoogLeNet çölyak hastalığı ağı tasarlanmış ve çölyak hastalarını

kontrollerden ayırmak için bir t-testi ile güvenini doğrulamıştır. Test seti için %100 duyarlılık ve özgüllük elde edilmiştir. Yakın zamanda yapılan başka bir çalışmada Wang ve ark. [68] yeni bir derin özellik öğrenme algoritması geliştirmişler. Veritabanı, WCE tarafından elde edilen  $576 \times 576$  piksel ile 1100 sağlıklı ve 1040 hasarlı mukoza sınıfının görüntüsünü içermektedir. Sonuçlar çölyak hastalığında villöz atrofi tespitinin %95,94 doğrulukla kontrollerden başarılı bir şekilde ayırt ettiğini göstermiştir.

Önerilen yöntemlerimizin sonuçları, Wimmer ve ark. tarafından bildirilen sonuçlardan biraz daha düşük görünmektedir. Bunun arkasındaki nedenlerin eğitim ve test setlerinin durumu, görüntülerin sayısı ve dağılımı, toplam veri sayısı ve görüntülerin niteliği gibi çeşitli nedenlerden kaynaklandığı düşünülmektedir. Görüntüleri  $WL_{MIT}$  ve  $NBI_{MIT}$  tekniklerinde mevcuttur, bu tür endoskopik teknikler ÇH'nin görsel onayını iyileştirmede önemli bir rol oynar. Bu nedenle, görüntülerin doğasında büyük bir fark yaratabilir. Ayrıca, farklı CNN parametreleri, karar eğrilerinde yerel min/maks değerlerine tam olarak ulaşılmaması, veritabanının farklı sırayla ağa eğitilmesi, donanımdaki farklılık veya Matlab ortamının yorulması gibi faktörler etkiler.

Deneysel sonuçlar, DWT ve çok seviyeli eşik ile birleştirilmiş doku tanımlayıcılarının derin öğrenme yöntemlerinden ziyade güvenilir bir şekilde teşhis ve sonuç verebileceğini göstermiştir. Çölyak hastalığının otomatik teşhisinde derin öğrenmenin gelişmesi için en önemli faktörler, büyük miktarlarda yüksek kaliteli endoskopik görüntülerin varlığıdır. Ölçeğe ve yönelime değişmez doku tanımlayıcıları, küçük veri setlerinde derin öğrenme modellerinden daha etkilidir ve daha az zaman ve maliyet gerektirir.

Algoritmanın doğruluğu, çalışmaya daha fazla hasta dahil edilerek artırılabilir. Gelecekteki çalışmalar, çok seviyeli eşikleme sorununu çözmek yerine, görüntü bölütleme için kümeleme (clustering), kenar algılama (edge detection), bölge tabanlı (region-based) ve hibrit yaklaşımlar gibi diğer yaklaşımları keşfedilebilir.

Bu çalışmanın yeniliği, görüntü bölütlemenin çölyak hastalığı (ÇH) görüntülerine uygulanmasıdır. Dolayısıyla ÇH ile ilgili diğer çalışmalarla elde edilen sonuçları

karşılaştırmak mümkün olmasa da sonuçları tıbbi görüntü bölütleme ile ilgili son literatür ile karşılaştırabiliriz. Kavur AE, Gezer NS, ve ark. [124] karaciğer bölütlemesi için çeşitli yarı otomatik ve derin öğrenmeye dayalı otomatik yöntemler kullanarak canlı hastaların karaciğer hacmi tahminlerini elde etmiştir. Her bir bölütlemenin sonuçlarını bir puanlama sistemine eşleyerek, füzyon sonuçlarının çoğunluk oylaması (MV, %86,70) ve eşzamanlı doğruluk ve performans düzeyi tahmini (STAPLE, %88,74) algoritmalarıyla elde edildiğini göstermişler. Çalışmalarımızda bölütlemesiz veri setindeki ortalama sınıflandırma değeri doğrulukta %87,88 iken, bölütlemeli veri setinde bu değer 92.43'e ulaşmıştır.

Tablo 4.1.'deki karşılaştırma sonuçlarına göre, önerdiğimiz yöntemlerimiz aynı veri setinde CNN ve doğrusal olmayan HOS yöntemlerine göre daha etkilidir ve daha az zaman ve maliyet gerektirir. Çölyak hastalığının otomatik teşhisinde derin öğrenmenin gelişmesi için en önemli faktörler, büyük miktarlarda yüksek kaliteli endoskopik görüntülerin varlığıdır. Sonuç olarak, DWT ile birleştirilmiş doku tanımlayıcılarının normal ve hasarlı villusları güvenilir bir şekilde ayırt edebildiği ve yüksek doğrulukta tanı koyabildiği deneysel sonuçlarla gösterilmiştir. Ayrıca, bölütlenmiş görüntü veri kümesinde gerçekleştirilen bilgisayar tabanlı doku analizi yöntemlerinin, teşhis doğruluğunu önemli ölçüde artırdığını da bildirdik.

## KAYNAKLAR

- [1] N. Gujral, H. J. Freeman, and A. B. Thomson, "Celiac disease: Prevalence, diagnosis, pathogenesis and treatment," *World J. Gastroenterol.*, vol. 18, no. 42, p. 6036, 2012.
- [2] P. Singh et al., "Global Prevalence of Celiac Disease: Systematic Review and Meta-analysis," *Clin. Gastroenterol. Hepatol.*, vol. 16, no. 6, pp. 823-836.e2, Jun. 2018.
- [3] J. D. Godfrey et al., "Morbidity and Mortality Among Older Individuals With Undiagnosed Celiac Disease," *Gastroenterology*, vol. 139, no. 3, pp. 763–769, Sep. 2010.
- [4] E. Lionetti and C. Catassi, "New clues in celiac disease epidemiology, pathogenesis, clinical manifestations, and treatment," *Int. Rev. Immunol.*, vol. 30, no. 4, pp. 219–231, 2011.
- [5] V. M. Wolters and C. Wijmenga, "Genetic Background of Celiac Disease and Its Clinical Implications," *Am. J. Gastroenterol.*, vol. 103, no. 1, pp. 190–195, Jan. 2008.
- [6] World Gastroenterology Organisation, "World Gastroenterology Organisation Global Guidelines for Celiac Disease," 2016. [Online]. Available: <https://www.worldgastroenterology.org/guidelines/global-guidelines/ceeliac-disease/ceeliac-disease-english.>, Erişim Tarihi: 01.12.2019.
- [7] R. J. Farrell and C. P. Kelly, "Diagnosis of celiac sprue," *Am. J. Gastroenterol.*, vol. 96, no. 12, pp. 3237–3246, 2001.
- [8] M. Mäki and P. Collin, "Coeliac disease," *Lancet*, vol. 349, no. 9067, pp. 1755–1759, Jun. 1997.
- [9] S. Husby et al., "European Society for Pediatric Gastroenterology, Hepatology, and Nutrition Guidelines for the Diagnosis of Coeliac Disease," *J. Pediatr. Gastroenterol. Nutr.*, vol. 54, no. 1, pp. 136–160, Jan. 2012.
- [10] B. Zohuri, "Dimensional Analysis," in *Dimensional Analysis and Self-Similarity Methods for Engineers and Scientists*, Cham: Springer International Publishing, 2015, pp. 1–92.

- [11] J. Zhang and T. Tan, "Brief review of invariant texture analysis methods," *Pattern Recognit.*, vol. 35, no. 3, pp. 735–747, Mar. 2002.
- [12] G. CAMMAROTA et al., "High accuracy and cost-effectiveness of a biopsy-avoiding endoscopic approach in diagnosing coeliac disease," *Aliment. Pharmacol. Ther.*, vol. 23, no. 1, pp. 61–69, Jan. 2006.
- [13] S. Hegenbart, A. Uhl, and A. Vécsei, "Survey on computer aided decision support for diagnosis of celiac disease," *Comput. Biol. Med.*, vol. 65, pp. 348–358, 2015.
- [14] G. Cammarota et al., "Reliability of the 'immersion technique' during routine upper endoscopy for detection of abnormalities of duodenal villi in patients with dyspepsia," *Gastrointest. Endosc.*, vol. 60, no. 2, pp. 223–228, Aug. 2004.
- [15] A. Hopper, S. Cross, and D. Sanders, "Patchy villous atrophy in adult patients with suspected gluten-sensitive enteropathy: is a multiple duodenal biopsy strategy appropriate?," *Endoscopy*, vol. 40, no. 03, pp. 219–224, Dec. 2007.
- [16] S. Hegenbart, A. Uhl, and A. Vécsei, "Impact of Histogram Subset Selection on Classification using Multi-scale LBP-Operators," in Springer, Springer, Berlin, Heidelberg, 2011, pp. 359–363.
- [17] S. Hegenbart, A. Uhl, A. Vécsei, and G. Wimmer, "Scale invariant texture descriptors for classifying celiac disease," *Med. Image Anal.*, vol. 17, no. 4, pp. 458–474, May 2013.
- [18] A. Uhl, A. Vécsei, and G. Wimmer, "Complex Wavelet Transform Variants in a Scale Invariant Classification of Celiac Disease," in Springer, Springer, Berlin, Heidelberg, 2011, pp. 742–749.
- [19] M. Gadermayr, M. Liedlgruber, A. Uhl, and A. Vécsei, "Evaluation of different distortion correction methods and interpolation techniques for an automated classification of celiac disease," *Comput. Methods Programs Biomed.*, vol. 112, no. 3, pp. 694–712, Dec. 2013.
- [20] M. Gadermayr, M. Liedlgruber, A. Uhl, and A. Vécsei, "Shape Curvature Histogram: A Shape Feature for Celiac Disease Diagnosis," in Springer, Springer, Cham, 2014, pp. 175–184.
- [21] E. J. Ciaccio, G. Bhagat, C. A. Tennyson, S. K. Lewis, L. Hernandez, and P. H. R. Green, "Quantitative Assessment of Endoscopic Images for Degree of Villous Atrophy in Celiac Disease," *Dig. Dis. Sci.*, vol. 56, no. 3, pp. 805–811, Mar. 2011.



- [22] R. Rautkorpi and J. Iivarinen, "A Novel Shape Feature for Image Classification and Retrieval," in Springer, Berlin, Heidelberg: Springer, Berlin, Heidelberg, 2004, pp. 753–760.
- [23] R. M. Haralick, K. Shanmugam, and I. Dinstein, "Textural Features for Image Classification," *IEEE Trans. Syst. Man. Cybern.*, vol. SMC-3, no. 6, pp. 610–621, Nov. 1973.
- [24] T. Ojala, M. Pietikäinen, and D. Harwood, "A comparative study of texture measures with classification based on featured distributions," *Pattern Recognit.*, vol. 29, no. 1, pp. 51–59, Jan. 1996.
- [25] S. Hegenbart, S. Maimone, A. Uhl, A. Vécsei, and G. Wimmer, "Customised Frequency Pre-filtering in a Local Binary Pattern-Based Classification of Gastrointestinal Images," in Springer, Springer, Berlin, Heidelberg, 2013, pp. 99–109.
- [26] S. Hegenbart and A. Uhl, "A scale- and orientation-adaptive extension of Local Binary Patterns for texture classification," *Pattern Recognit.*, vol. 48, no. 8, pp. 2633–2644, Aug. 2015.
- [27] M. Gadermayr, A. Uhl, and A. Vécsei, "Feature Extraction with Intrinsic Distortion Correction in Celiac Disease Imagery: No Need for Rasterization," Springer, Cham, 2014, pp. 196–204.
- [28] M. Gadermayr, A. Uhl, and A. Vécsei, "Is a Precise Distortion Estimation Needed for Computer Aided Celiac Disease Diagnosis?," 2014, pp. 620–628.
- [29] E. Grisan, H. Mirzaei, and R. Leong, "Computer-assisted automated image recognition of celiac disease using confocal endomicroscopy," in 2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI), 2014, pp. 121–124.
- [30] A. Vécsei, G. Amann, S. Hegenbart, M. Liedlgruber, and A. Uhl, "Automated Marsh-like classification of celiac disease in children using local texture operators," *Comput. Biol. Med.*, vol. 41, no. 6, pp. 313–325, Jun. 2011.
- [31] X. Xiaoyang Tan and B. Triggs, "Enhanced Local Texture Feature Sets for Face Recognition Under Difficult Lighting Conditions," *IEEE Trans. Image Process.*, vol. 19, no. 6, pp. 1635–1650, Jun. 2010.
- [32] Xiangsheng Huang, S. Z. Li, and Yangsheng Wang, "Shape Localization Based on Statistical Method Using Extended Local Binary Pattern," in Third International Conference on Image and Graphics (ICIG'04), 2004, pp. 184–187.

- [33] M. Hafner, M. Liedlgruber, F. Wrba, A. Gangl, A. Vecsei, and A. Uhl, "Pit pattern classification of zoom-endoscopic colon images using wavelet texture features," in IET 3rd International Conference MEDSIP 2006. Advances in Medical, Signal and Information Processing, 2006, vol. 2006, pp. 37–37.
- [34] M. Liedlgruber and A. Uhl, Statistical and structural wavelet packet features for pit pattern classification in zoom-endoscopic colon images. StevensPoint, Wisconsin, USA: WSEAS, 2007.
- [35] A. Vecsei, T. Fuhrmann, and A. Uhl, "Towards automated diagnosis of celiac disease by computer-assisted classification of duodenal imagery," in 4th IET International Conference on Advances in Medical, Signal and Information Processing (MEDSIP 2008), 2008, pp. P21–P21.
- [36] N. Saito and R. R. Coifman, "Local discriminant bases and their applications," *J. Math. Imaging Vis.*, vol. 5, no. 4, pp. 337–358, Dec. 1995.
- [37] B. S. Manjunath and W. Y. Ma, "Texture features for browsing and retrieval of image data," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 18, no. 8, pp. 837–842, 1996.
- [38] S. Hegenbart, R. Kwitt, M. Liedlgruber, A. Uhl, and A. Vecsei, "Impact of duodenal image capturing techniques and duodenal regions on the performance of automated diagnosis of celiac disease," in 2009 Proceedings of 6th International Symposium on Image and Signal Processing and Analysis, 2009, pp. 718–723.
- [39] M. Hafner, A. Gangl, M. Liedlgruber, A. Uhl, A. Vecsei, and F. Wrba, "Combining Gaussian Markov random fields with the discrete-wavelet transform for endoscopic image classification," in 2009 16th International Conference on Digital Signal Processing, 2009, pp. 1–6.
- [40] I. W. Selesnick, R. G. Baraniuk, and N. C. Kingsbury, "The dual-tree complex wavelet transform," *IEEE Signal Process. Mag.*, vol. 22, no. 6, pp. 123–151, Nov. 2005.
- [41] R. Kwitt and A. Uhl, "Modeling the Marginal Distributions of Complex Wavelet Coefficient Magnitudes for the Classification of Zoom-Endoscopy Images," in 2007 IEEE 11th International Conference on Computer Vision, 2007, pp. 1–8.
- [42] G. Van de Wouwer, S. Livens, P. Scheunders, and D. Van Dyck, "Color texture classification by wavelet energy correlation signatures," in Springer, Berlin, Heidelberg: Springer, Berlin, Heidelberg, 1997, pp. 327–334.

- [43] A. Vécsei, T. Fuhrmann, M. Liedlgruber, L. Brunauer, H. Payer, and A. Uhl, “Automated classification of duodenal imagery in celiac disease using evolved Fourier feature vectors,” *Comput. Methods Programs Biomed.*, vol. 95, no. 2, pp. S68–S78, Aug. 2009.
- [44] Y. Xu, H. Ji, and C. Fermüller, “Viewpoint Invariant Texture Description Using Fractal Analysis,” *Int. J. Comput. Vis.*, vol. 83, no. 1, pp. 85–100, Jun. 2009.
- [45] M. Varma and A. Zisserman, “A Statistical Approach to Texture Classification from Single Images,” *Int. J. Comput. Vis.*, vol. 62, no. 1–2, pp. 61–81, Apr. 2005.
- [46] E. H. S. Lo, M. R. Pickering, M. R. Frater, and J. F. Arnold, “Query by example using invariant features from the double dyadic dual-tree complex wavelet transform,” in *Proceeding of the ACM International Conference on Image and Video Retrieval - CIVR '09*, 2009, p. 1.
- [47] F. Perronnin and C. Dance, “Fisher Kernels on Visual Vocabularies for Image Categorization,” in *2007 IEEE Conference on Computer Vision and Pattern Recognition*, 2007, pp. 1–8.
- [48] Qi Xu and Yan Qiu Chen, “Multiscale Blob Features for Gray Scale, Rotation and Spatial Scale Invariant Texture Classification,” in *18th International Conference on Pattern Recognition (ICPR'06)*, 2006, pp. 29–32.
- [49] K. Kun Zhan, H. Hongjuan Zhang, and Y. Yide Ma, “New Spiking Cortical Model for Invariant Texture Retrieval and Image Processing,” *IEEE Trans. Neural Networks*, vol. 20, no. 12, pp. 1980–1986, Dec. 2009.
- [50] Y. Ma, L. Liu, K. Zhan, and Y. Wu, “Pulse-coupled neural networks and one-class support vector machines for geometry invariant texture retrieval,” *Image Vis. Comput.*, vol. 28, no. 11, pp. 1524–1529, Nov. 2010.
- [51] Z. Li, G. Liu, X. Qian, and C. Wang, “Scale and rotation invariant Gabor texture descriptor for texture classification,” *SPIE*, vol. 7744, no. 60903121, pp. 77441T–1, 2010.
- [52] S. Lazebnik, C. Schmid, and J. Ponce, “A sparse texture representation using affine-invariant regions,” in *2003 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2003. *Proceedings.*, 2003, vol. 2, pp. II-319-II–324.

- [53] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. Green, "Classification of videocapsule endoscopy image patterns: comparative analysis between patients with celiac disease and normal individuals," *Biomed. Eng. Online*, vol. 9, no. 1, p. 44, Sep. 2010.
- [54] A. Tursi, "Gastrointestinal Motility Disturbances in Celiac Disease," *J. Clin. Gastroenterol.*, vol. 38, no. 8, pp. 642–645, Sep. 2004.
- [55] G. Bassotti et al., "Abnormal gastrointestinal motility in patients with celiac sprue," *Dig. Dis. Sci.*, vol. 39, no. 9, pp. 1947–1954, Sep. 1994.
- [56] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. Green, "Quantitative Estimates of Motility from Videocapsule Endoscopy Are Useful to Discern Celiac Patients from Controls," *Dig. Dis. Sci.*, vol. 57, no. 11, pp. 2936–2943, Nov. 2012.
- [57] E. J. Ciaccio, C. A. Tennyson, S. K. Lewis, S. Krishnareddy, G. Bhagat, and P. H. R. Green, "Distinguishing patients with celiac disease by quantitative analysis of videocapsule endoscopy images," *Comput. Methods Programs Biomed.*, vol. 100, no. 1, pp. 39–48, Oct. 2010.
- [58] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. R. Green, "Transformation of videocapsule images to detect small bowel mucosal differences in celiac versus control patients," *Comput. Methods Programs Biomed.*, vol. 108, no. 1, pp. 28–37, Oct. 2012.
- [59] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. Green, "Use of basis images for detection and classification of celiac disease.," *Biomed. Mater. Eng.*, vol. 24, no. 6, pp. 1913–23, 2014.
- [60] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. R. Green, "Use of shape-from-shading to estimate three-dimensional architecture in the small intestinal lumen of celiac and control patients," *Comput. Methods Programs Biomed.*, vol. 111, no. 3, pp. 676–684, Sep. 2013.
- [61] E. J. Ciaccio, C. A. Tennyson, G. Bhagat, S. K. Lewis, and P. H. Green, "Implementation of a polling protocol for predicting celiac disease in videocapsule analysis," *World J. Gastrointest. Endosc.*, vol. 5, no. 7, p. 313, 2013.
- [62] J. K. Min, M. S. Kwak, and J. M. Cha, "Overview of deep learning in gastrointestinal endoscopy," *Gut and Liver*, vol. 13, no. 4. Editorial Office of Gut and Liver, pp. 388–393, 2019.

- [63] G. Wimmer, S. Hegenbart, A. Vecsei, and A. Uhl, "Convolutional neural network architectures for the automated diagnosis of celiac disease," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2017, vol. 10170 LNCS, pp. 104–113.
- [64] A. Vedaldi and K. Lenc, "MatConvNet: Convolutional neural networks for MATLAB," in *MM 2015 - Proceedings of the 2015 ACM Multimedia Conference*, 2015, pp. 689–692.
- [65] J. Y. He, X. Wu, Y. G. Jiang, Q. Peng, and R. Jain, "Hookworm Detection in Wireless Capsule Endoscopy Images with Deep Learning," *IEEE Trans. Image Process.*, vol. 27, no. 5, pp. 2379–2392, May 2018.
- [66] T. Zhou et al., "Quantitative analysis of patients with celiac disease by video capsule endoscopy: A deep learning method," *Comput. Biol. Med.*, vol. 85, pp. 1–6, Jun. 2017.
- [67] G. Wimmer, A. Vecsei, and A. Uhl, "CNN transfer learning for the automated diagnosis of celiac disease," in *2016 Sixth International Conference on Image Processing Theory, Tools and Applications (IPTA)*, 2016, pp. 1–6.
- [68] X. Wang et al., "Celiac disease diagnosis from videocapsule endoscopy images with residual learning and deep feature extraction," *Comput. Methods Programs Biomed.*, p. 105236, 2019.
- [69] J. E. W. Koh et al., "Automated diagnosis of celiac disease using DWT and nonlinear features with video capsule endoscopy images," *Futur. Gener. Comput. Syst.*, vol. 90, pp. 86–93, Jan. 2019.
- [70] E. J. Ciaccio, S. K. Lewis, G. Bhagat, and P. H. Green, "Color masking improves classification of celiac disease in videocapsule endoscopy images," *Comput. Biol. Med.*, vol. 106, pp. 150–156, Mar. 2019.
- [71] J. Vicnesh et al., "Automated diagnosis of celiac disease by video capsule endoscopy using DAISY Descriptors," *J. Med. Syst.*, vol. 43, no. 6, Jun. 2019.
- [72] M. Gadermayr, A. Uhl, and A. Vecsei, "Fully automated decision support systems for celiac disease diagnosis," *IRBM*, vol. 37, no. 1, pp. 31–39, Feb. 2016.
- [73] A. V. Sebastian Hegenbart, Andreas Uhl, "Impact of endoscopic image degradations on LBP based features using one-class SVM for classification of celiac disease - IEEE Conference Publication," in *2011 7th International Symposium on Image and Signal Processing and Analysis (ISPA)*, 2011.

- [74] R. C. Gonzalez and R. E. Woods, *Digital image processing*. Prentice Hall, 2008.
- [75] J. Sachdeva, V. Kumar, I. Gupta, N. Khandelwal, and C. K. Ahuja, "A novel content-based active contour model for brain tumor segmentation," *Magn. Reson. Imaging*, vol. 30, no. 5, pp. 694–715, Jun. 2012.
- [76] J. C. Fu, C. C. Chen, J. W. Chai, S. T. C. Wong, and I. C. Li, "Image segmentation by EM-based adaptive pulse coupled neural networks in brain magnetic resonance imaging," *Comput. Med. Imaging Graph.*, vol. 34, no. 4, pp. 308–20, Jun. 2010.
- [77] K. Gasmı, A. Kharrat, M. Ben Messaoud, and M. Abid, "Automated Segmentation of Brain Tumor Using Optimal Texture Features and Support Vector Machine Classifier," Springer, Berlin, Heidelberg, 2012, pp. 230–239.
- [78] A. Ortiz, J. M. Górriz, J. Ramírez, and D. Salas-González, "Improving MRI segmentation with probabilistic GHSOM and multiobjective optimization," *Neurocomputing*, vol. 114, pp. 118–131, Aug. 2013.
- [79] E.-S. A. El-Dahshan, H. M. Mohsen, K. Revett, and A.-B. M. Salem, "Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm," *Expert Syst. Appl.*, vol. 41, no. 11, pp. 5526–5545, Sep. 2014.
- [80] D. D. Patil, S. G. Deore, and S. Bhusawal, "Medical Image Segmentation: A Review," *Ijcsmc*, vol. 2, no. 1, pp. 22–27, 2013.
- [81] D. Boschetto, H. Mirzaei, R. W. L. Leong, and E. Grisan, "Superpixel-based automatic segmentation of villi in confocal endomicroscopy," in *2016 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*, 2016, pp. 168–171.
- [82] K. Hammouche, M. Diaf, and P. Siarry, "A comparative study of various meta-heuristic techniques applied to the multilevel thresholding problem," *Eng. Appl. Artif. Intell.*, vol. 23, no. 5, pp. 676–688, Aug. 2010.
- [83] N. Otsu, "A Threshold Selection Method from Gray-Level Histograms," *IEEE Trans. Syst. Man. Cybern.*, vol. 9, no. 1, pp. 62–66, Jan. 1979.
- [84] J. N. Kapur, P. K. Sahoo, and A. K. C. Wong, "A new method for gray-level picture thresholding using the entropy of the histogram," *Comput. Vision, Graph. Image Process.*, vol. 29, no. 3, pp. 273–285, Mar. 1985.

- [85] D. Oliva, S. Hinojosa, M. A. Elaziz, and N. Ortega-Sánchez, "Context based image segmentation using antlion optimization and sine cosine algorithm," *Multimed. Tools Appl.*, vol. 77, no. 19, pp. 25761–25797, Oct. 2018.
- [86] S. Ghosh, L. Bruzzone, S. Patra, F. Bovolo, and A. Ghosh, "A Context-Sensitive Technique for Unsupervised Change Detection Based on Hopfield-Type Neural Networks," *IEEE Trans. Geosci. Remote Sens.*, vol. 45, no. 3, pp. 778–789, Mar. 2007.
- [87] S. Patra, R. Gautam, and A. Singla, "A novel context sensitive multilevel thresholding for image segmentation," *Appl. Soft Comput.*, vol. 23, pp. 122–127, Oct. 2014.
- [88] S. Pare, A. Kumar, V. Bajaj, and G. K. Singh, "A multilevel color image segmentation technique based on cuckoo search algorithm and energy curve," *Appl. Soft Comput.*, vol. 47, pp. 76–102, Oct. 2016.
- [89] H. D. Cheng, X. H. Jiang, and J. Wang, "Color image segmentation based on homogram thresholding and region merging," *Pattern Recognit.*, vol. 35, no. 2, pp. 373–393, Feb. 2002.
- [90] K. Hammouche, M. Diaf, and P. Siarry, "A multilevel automatic thresholding method based on a genetic algorithm for a fast image segmentation," *Comput. Vis. Image Underst.*, vol. 109, no. 2, pp. 163–175, Feb. 2008.
- [91] K. Tang, X. Yuan, T. Sun, J. Yang, and S. Gao, "An improved scheme for minimum cross entropy threshold selection based on genetic algorithm," *Knowledge-Based Syst.*, vol. 24, no. 8, pp. 1131–1138, Dec. 2011.
- [92] J. Zhang, H. Li, Z. Tang, Q. Lu, X. Zheng, and J. Zhou, "An Improved Quantum-Inspired Genetic Algorithm for Image Multilevel Thresholding Segmentation," *Math. Probl. Eng.*, vol. 2014, pp. 1–12, Apr. 2014.
- [93] Hao Gao, Wenbo Xu, Jun Sun, and Yulan Tang, "Multilevel Thresholding for Image Segmentation Through an Improved Quantum-Behaved Particle Swarm Algorithm," *IEEE Trans. Instrum. Meas.*, vol. 59, no. 4, pp. 934–946, Apr. 2010.
- [94] H. Gao, C.-M. Pun, and S. Kwong, "An efficient image segmentation method based on a hybrid particle swarm algorithm with learning strategy," *Inf. Sci. (Ny)*, vol. 369, pp. 500–521, Nov. 2016.
- [95] M. Maitra and A. Chatterjee, "A hybrid cooperative–comprehensive learning based PSO algorithm for image segmentation using multilevel thresholding," *Expert Syst. Appl.*, vol. 34, no. 2, pp. 1341–1350, Feb. 2008.

- [96] R. Poli, J. Kennedy, and T. Blackwell, "Particle swarm optimization," *Swarm Intell.*, vol. 1, no. 1, pp. 33–57, Oct. 2007.
- [97] Y. Zhao, Z. Fang, K. Wang, and H. Pang, "Multilevel Minimum Cross Entropy Threshold Selection Based on Quantum Particle Swarm Optimization," in *Eighth ACIS International Conference on Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing (SNPD 2007)*, 2007, pp. 65–69.
- [98] A. K. Bhandari, A. Kumar, S. Chaudhary, and G. K. Singh, "A novel color image multilevel thresholding based segmentation using nature inspired optimization algorithms," *Expert Syst. Appl.*, vol. 63, pp. 112–133, Nov. 2016.
- [99] M. Ali, P. Siarry, and M. Pant, "An efficient Differential Evolution based algorithm for solving multi-objective optimization problems," *Eur. J. Oper. Res.*, vol. 217, no. 2, pp. 404–416, Mar. 2012.
- [100] E. Cuevas, D. Zaldivar, and M. Pérez-Cisneros, "A novel multi-threshold segmentation approach based on differential evolution optimization," *Expert Syst. Appl.*, vol. 37, no. 7, pp. 5265–5271, Jul. 2010.
- [101] R. Storn and K. Price, "Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces," *J. Glob. Optim.*, vol. 11, no. 4, pp. 341–359, 1997.
- [102] P. Agarwal and S. Mehta, "Empirical analysis of five nature-inspired algorithms on real parameter optimization problems," *Artif. Intell. Rev.*, vol. 50, no. 3, pp. 383–439, Oct. 2018.
- [103] M.-H. Horng and R.-J. Liou, "Multilevel minimum cross entropy threshold selection based on the firefly algorithm," *Expert Syst. Appl.*, vol. 38, no. 12, pp. 14805–14811, Nov. 2011.
- [104] D. Oliva, E. Cuevas, G. Pajares, D. Zaldivar, and V. Osuna, "A Multilevel Thresholding algorithm using electromagnetism optimization," *Neurocomputing*, vol. 139, pp. 357–381, Sep. 2014.
- [105] G. Sandhya, G. Babu Kande, and T. S. Savithri, "Multilevel Thresholding Method Based on Electromagnetism for Accurate Brain MRI Segmentation to Detect White Matter, Gray Matter, and CSF.," *Biomed Res. Int.*, vol. 2017, p. 6783209, 2017.
- [106] S. Ouadfel and A. Taleb-Ahmed, "Social spiders optimization and flower pollination algorithm for multilevel image thresholding: A performance study," *Expert Syst. Appl.*, vol. 55, pp. 566–584, Aug. 2016.



- [107] D. Oliva, S. Hinojosa, E. Cuevas, G. Pajares, O. Avalos, and J. Gálvez, “Cross entropy based thresholding for magnetic resonance brain images using Crow Search Algorithm,” *Expert Syst. Appl.*, vol. 79, pp. 164–180, Aug. 2017.
- [108] P. Kandhway and A. K. Bhandari, “Spatial context-based optimal multilevel energy curve thresholding for image segmentation using soft computing techniques,” *Neural Comput. Appl.*, Jul. 2019.
- [109] X. S. Yang and S. Deb, “Cuckoo search via Lévy flights,” in *2009 World Congress on Nature and Biologically Inspired Computing, NABIC 2009 - Proceedings, 2009*, pp. 210–214.
- [110] M. Gadermayr, S. Hegenbart, R. Kwitt, A. Uhl, and A. Vecsei, “Narrow band imaging versus white-light: What is best for computer-assisted diagnosis of celiac disease?,” in *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI), 2016*, pp. 355–359.
- [111] G. Wimmer, A. Uhl, and A. Vecsei, “Evaluation of domain specific data augmentation techniques for the classification of celiac disease using endoscopic imagery,” in *2017 IEEE 19th International Workshop on Multimedia Signal Processing (MMSp), 2017*, pp. 1–6.
- [112] S. G. Mallat, “A theory for multiresolution signal decomposition: the wavelet representation,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 11, no. 7, pp. 674–693, Jul. 1989.
- [113] M. Gadermayr, A. Uhl, and A. Vecsei, “Degradation Adaptive Texture Classification: A Case Study in Celiac Disease Diagnosis Brings New Insight,” *Springer, Cham*, 2014, pp. 263–273.
- [114] N. Dalal and B. Triggs, “Histograms of Oriented Gradients for Human Detection,” in *2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR’05)*, vol. 1, pp. 886–893.
- [115] M. Gadermayr, H. Kogler, M. Karla, A. Vecsei, A. Uhl, and D. Merhof, “Incorporating human knowledge in automated celiac disease diagnosis,” in *2016 Sixth International Conference on Image Processing Theory, Tools and Applications (IPTA), 2016*, pp. 1–6.
- [116] M. Gadermayr, A. Uhl, and A. Vecsei, “Quality Based Information Fusion in Fully Automated Celiac Disease Diagnosis,” *Springer, Cham*, 2014, pp. 666–677.

- [117] H. Bay, A. Ess, T. Tuytelaars, and L. Van Gool, “Speeded-Up Robust Features (SURF),” *Comput. Vis. Image Underst.*, vol. 110, no. 3, pp. 346–359, Jun. 2008.
- [118] M. Gadermayr, H. Kogler, M. Karla, D. Merhof, A. Uhl, and A. Vécsei, “Computer-aided texture analysis combined with experts’ knowledge: Improving endoscopic celiac disease diagnosis,” *World J. Gastroenterol.*, vol. 22, no. 31, p. 7124, 2016.
- [119] R. Kwitt, S. Hegenbart, N. Rasiwasia, A. Vécsei, and A. Uhl, “Do We Need Annotation Experts? A Case Study in Celiac Disease Classification,” Springer, Cham, 2014, pp. 454–461.
- [120] P. Mallikarjuna, A. T. Targhi, M. Fritz, E. Hayman, B. Caputo, and J. Eklundh, “THE KTH-TIPS2 database,” pp. 1–10, 2006.
- [121] B. N. N. Li et al., “Celiac Disease Detection from Videocapsule Endoscopy Images Using Strip Principal Component Analysis,” *IEEE/ACM Trans. Comput. Biol. Bioinforma.*, pp. 1–1, 2019.
- [122] A. K. Jain, R. P. W. Duin, and J. Mao, “Statistical pattern recognition: A review,” *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 22, no. 1, pp. 4–37, Jan. 2000.
- [123] I. T. Jolliffe, “Principal Component Analysis,” in *Principal Component Analysis*, Second Edi., New York, USA: Springer-Verlag, 2006, pp. 1–9.
- [124] A. E. Kavur et al., “Comparison of semi-automatic and deep learning-based automatic methods for liver segmentation in living liver transplant donors,” *Diagnostic Interv. Radiol.*, vol. 26, no. 1, pp. 11–21, 2020.

## **EKLER**

**EK 1: Katılımcı Hastanesinin Onay Belgesi**



**EK 2: Saęlık Etik Kurul Onay Belgesi**

**EK 2: (Devamı 1)**

**EK 2: (Devamı 2)**



**EK 2: (Devamı 3)**

## ÖZGEÇMİŞ

Manarbek Saken, ...

