

T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü

# **Çok Etiketli Sınıflandırma Problemi İçin İkili Alaka Düzeyi Algoritması Geliştirilmesi**

Ahmet GÜRBÜZ

Danışman : Prof. Dr. M. Serdar KORUKOĞLU  
İkinci Danışman : Doç. Dr. Aytuğ ONAN

Bilgisayar Mühendisliği Anabilim Dalı  
Bilgisayar Mühendisliği Yüksek Lisans Programı

İzmir  
2021



# EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

## ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “Çok Etiketli Sınıflandırma Problemi İçin İkili Alaka Düzeyi Algoritması Geliştirilmesi” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

20 / 09 / 2021

Ahmet Gürbüz

**ÖZET****Çok Etiketli Sınıflandırma Problemi İçin İkili Alaka Düzeyi Algoritması Geliştirilmesi**

GÜRBÜZ, Ahmet

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. M. Serdar KORUKOĞLU

İkinci Tez Danışmanı: Doç. Dr. Aytuğ ONAN

Ağustos 2021, 55 sayfa

Günümüzde teknolojinin gelişmesiyle birlikte veri boyutlarında ve veri çeşitliliğinde ciddi bir artış görülmektedir. Artan verinin analizi ve kullanımı makine öğrenmesi yöntemlerinin yardımıyla kolaylaşmaktadır. Bu veri çeşitliliği ile ortaya çıkan veri türlerinden biri de çok etiketli verilerdir. Çok etiketli veriler çok etiketli sınıflandırma problemini ortaya çıkarmıştır. Sınıflandırma, bir veriyi özelliklerini analiz ederek önceden belirlenmiş bir etiket ile ilişkilendirme işlemidir. Çok etiketli sınıflandırma ise bir verinin aynı anda özellikleriyle ilişkili birden çok etiket ile ilişkilendirilebildiği bir sınıflandırma türüdür. Bu tez çalışması kapsamında var olan çok etiketli sınıflandırma yöntemleri incelenmiş ve bir problem dönüşüm metodu olan ikili alaka (*binary relevance*) yöntemini iyileştiren BRS, BRA, BRLP ve topluluk öğrenmesi (*ensemble learning*) yöntemleri olmak üzere toplamda 4 yöntem ortaya konulmuştur. Çalışma kapsamında ortaya koyulan yöntemler ile literatürde var olan yöntemler deneysel olarak 17 adet veri seti ile 13 metrik bakımından karşılaştırılmıştır. Deneyler sonucunda çalışma kapsamında ortaya koyulan bazı yöntemlerin literatürde var olan yöntemleri geride bıraktığı gözlemlenirken bazılarının ise var olan yöntemler ile kıyaslanabilecek düzeyde sonuçlar ortaya koyduğu gözlemlenmiştir.

**Anahtar sözcükler:** Makine öğrenimi, çok etiketli sınıflandırma, ikili alaka düzeyi, topluluk öğrenmesi



**ABSTRACT****Improving Binary Relevance Algorithm For Multilabel Classification Problem**

GÜRBÜZ, Ahmet

MSc, Computer Engineering

Supervisor: Prof. M. Serdar KORUKOĞLU

Supervisor: Assoc. Prof. Aytuğ ONAN

August 2021, 55 pages

Nowadays with the technological improvements a serious increase on size and variety of data can be observed. Machine learning makes it easier to analysis and usage of this data. One of the data types that emerges with the increasing variety of data is multi label data. With the multilabel data, multilabel classification problem arises. Classification is process of associating an instance with a predefined label by analyzing its attributes. Multilabel classification is type of classification that an instance can be associated with multiple labels based on its attributes. In this thesis study existing multi label classification methods are studied and 4 methods such as BRS, BRA, BRLP and ensemble methods that improves binary relevance method which is a problem transformation method for multi label classification problem are suggested. In the scope of this study proposed methods and methods that exists in the literature experimentally compared using 17 datasets based on 13 metrics. In the results of experiments, it is observed that some of suggested methods passed the existing methods performance wise and some suggested methods can compete existing methods performance wise.

**Keywords:** Machine learning, multi label classification, binary relevance, ensemble learning



## ÖNSÖZ

Son yıllardaki teknolojik gelişmeler ile ortaya çıkan verilerin boyutu ve çeşitliliği hızla artmaktadır. Bu artış beraberinde verilerin analizi ve anlamlandırma ihtiyacını da arttırmaktadır. Yüksek lisans ve lisans sürecinde aldığım yapay zekâ ve makine öğrenmesi dersleri süresince bu ihtiyacı daha iyi bir şekilde gözlemledim. Değerli danışmanım Prof. Dr. M. Serdar Korukoğlu ile görüşerek ve önerilerini dinleyerek çok etiketli sınıflandırma problemi hakkında bilgi edindim ve bu alanda çalışmak üzere karar aldık.

Çok etiketli sınıflandırma problemi için yapılan çalışmaları incelediğimde anlaşılması ve uygulaması oldukça basit olan ikili alaka düzeyi (*binary relevance*) yönteminin etiketler arası ilişkileri önemsemediği için göz ardı edildiğini gözlemledim. Bu sebeple tez çalışmam kapsamında ikili alaka düzeyi (*binary relevance*) yönteminin bu dezavantajını ortadan kaldıran iyileştirmeler üzerine çalışmaya karar verdik. Bu iyileştirmeleri bir destek modeli oluşturma, veri seti özellik uzayı genişletme ve topluluk öğrenimi yöntemleri ile gerçekleştirmeyi ve bu yöntemleri deneysel bir şekilde var olan yöntemler ile karşılaştırmaya karar verdik.

Çalışma süresince çok etiketli sınıflandırma hakkında yapılmış çalışmaları inceledim ve bu araştırmalarım bana bu alanda birçok yeni bilgi kattı. Ben de gerçekleştirdiğim çalışmaların ve ortaya koyduğum yöntemlerin gelecekte yapılacak olan çalışmalara ve bilime katkı sağlamasını umuyorum.

İZMİR

20/08/2021

Ahmet Gürbüz



## İÇİNDEKİLER

Sayfa

ÖZET .....	iv
ABSTRACT .....	vi
ÖNSÖZ .....	viii
ŞEKİLLER DİZİNİ .....	xiii
TABLolar DİZİNİ .....	xiv
KISALTMALAR DİZİNİ .....	xv
1 GİRİŞ .....	1
2 ÖNCEKİ ÇALIŞMALAR .....	3
3 MAKİNE ÖĞRENMESİ .....	6
3.1 Tek Etiketli Sınıflandırma .....	6
3.2 Çok Etiketli Sınıflandırma .....	6
4 ÇOK ETİKETLİ SINIFLANDIRMA YÖNTEMLERİ .....	7
4.1 Problem Dönüşüm Metotları .....	8
4.1.1 İkili Alaka Düzeyi (Binary Relevance) .....	8
4.1.2 Label Powerset .....	9
4.1.3 Sınıflandırıcı Zinciri (Classifier Chain) .....	9
4.1.4 Rasgele k-Etiket Kümeleri (Random k-Labelsets) .....	10
4.1.5 İstifleme (Stacking) .....	11
4.1.6 Bağımlı İkili Alaka Düzeyi (Dependent Binary Relevance) .....	12
4.2 Algoritma Adaptasyon Metotları .....	12
4.2.1 AdaBoost.MH .....	12
4.2.2 Çok Etiketli C4.5 (Multi-Label C4.5) .....	13
4.2.3 ML-kNN .....	13
4.3 Karşılaştırma .....	14
5 GELİŞTİRİLEN YÖNTEMLER .....	15
5.1 Binary Relevance Support .....	15
5.2 Binary Relevance Association .....	16

5.3	BRLP .....	17
5.4	Topluluk Öğrenmesi (Ensemble) Yöntemleri .....	18
6	DENEYSEL SONUÇLAR .....	19
6.1	DeneySEL Çerçeve .....	19
6.2	Veri Setleri.....	19
6.2.1	Emotions .....	20
6.2.2	Yeast .....	20
6.2.3	CAL500 .....	20
6.2.4	Medical .....	20
6.2.5	Scene.....	20
6.2.6	Genbase.....	20
6.2.7	Birds.....	20
6.2.8	Water Quality.....	21
6.2.9	PlantPseAAC .....	21
6.2.10	PlantGO.....	21
6.2.11	Image.....	21
6.2.12	HumanPseAAC.....	21
6.2.13	HumanGO .....	22
6.2.14	GpositivePseAAC .....	22
6.2.15	GpositiveGO .....	22
6.2.16	GnegativePseAAC .....	22
6.2.17	GnegativeGO .....	22
6.3	Başarı Değerlendirme Metrikleri.....	23
6.3.1	Alt Küme Doğruluğu (Subset Accuracy) .....	23
6.3.2	Hamming Kaybı (Hamming Loss) .....	24
6.3.3	Örnek Tabanlı Doğruluk (Example Based Accuracy).....	24
6.3.4	Kesinlik (Precision) .....	24
6.3.5	Duyarlılık (Recall) .....	24
6.3.6	F-Puanı (F-Measure).....	25
6.4	Deney Parametreleri .....	25
6.5	Deney Sonuçları.....	25
7	TARTIŞMA VE SONUÇ.....	50
	KAYNAKLAR DİZİNİ.....	52



## ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
Şekil 4-1 Binary Relevance Yöntemi Örneği (Tsoumakas et al. ,2009) .....	8
Şekil 4-2 Label Powerset Yöntemi Örneği (Tsoumakas et al., 2009) .....	9
Şekil 4-3 Classifier Chain Yöntemi Örneği.....	10
Şekil 4-4 İstifleme (Stacking) Yöntemi Örneği.....	11
Şekil 4-5 AdaBoost.MH Yöntemi Dönüşüm Örneği.....	12
Şekil 5-1 Binary Relevance Support Destek Modeli Örneği.....	16
Şekil 5-2 Binary Relevance Association Yöntemi Örneği .....	17
Şekil 5-3 BRLP Yönteminin Örnek Veri Seti Dönüşümü.....	17
Şekil 5-4 Bir Ensemble Yöntem ile Çıkarım Örneği.....	18
Şekil 6-1 Normalize Örnek Tabanlı Ortalamalı Kesinlik ( <i>Precision</i> ) Grafiği .....	40
Şekil 6-2 Normalize Makro Ortalamalı Kesinlik ( <i>Precision</i> ) Grafiği.....	40
Şekil 6-3 Normalize Mikro Ortalamalı Kesinlik ( <i>Precision</i> ) Grafiği.....	41
Şekil 6-4 Normalize Örnek Ortalamalı Tabanlı Duyarlılık ( <i>Recall</i> ) Grafiği.....	41
Şekil 6-5 Normalize Makro Ortalamalı Duyarlılık ( <i>Recall</i> ) Grafiği .....	42
Şekil 6-6 Normalize Mikro Ortalamalı Duyarlılık ( <i>Recall</i> ) Grafiği.....	42
Şekil 6-7 Normalize Örnek Tabanlı Ortalamalı F-Puanı ( <i>F-Measure</i> ) Grafiği.....	43
Şekil 6-8 Normalize Makro Ortalamalı F-Puanı ( <i>F-Measure</i> ) Grafiği .....	43
Şekil 6-9 Normalize Mikro Ortalamalı F-Puanı ( <i>F-Measure</i> ) Grafiği.....	44
Şekil 6-10 Normalize Örnek Ortalamalı Doğruluk ( <i>Accuracy</i> ) Grafiği .....	44
Şekil 6-11 Normalize Alt Küme Doğruluğu ( <i>Subset Accuracy</i> ) Grafiği.....	45
Şekil 6-12 Normalize Hamming Kaybı ( <i>Hamming Loss</i> ) Grafiği.....	45
Şekil 6-13 Normalize Çalışma Süresi Grafiği .....	46

## TABLOLAR DİZİNİ

Tablo	Sayfa
Tablo 3-1 Çok Etiketli Veri Seti Örneği.....	7
Tablo 4-1 Random k-Labelsets Yöntemi Çıkarım Örneği (Tsoumakas et al., 2009) .....	10
Tablo 6-1 Veri setleri istatistikleri tablosu .....	19
Tablo 6-2 Örnek tabanlı ortalama kesinlik ( <i>precision</i> ) metriği için deneysel sonuçlar.....	27
Tablo 6-3 Makro ortalama kesinlik ( <i>precision</i> ) metriği için deneysel sonuçlar ..	28
Tablo 6-4 Mikro ortalama kesinlik ( <i>precision</i> ) metriği için deneysel sonuçlar ..	29
Tablo 6-5 Örnek tabanlı ortalama duyarlılık ( <i>recall</i> ) metriği için deneysel sonuçlar.....	30
Tablo 6-6 Makro ortalama duyarlılık ( <i>recall</i> ) metriği için deneysel sonuçlar ....	31
Tablo 6-7 Mikro ortalama duyarlılık ( <i>recall</i> ) metriği için deneysel sonuçlar.....	32
Tablo 6-8 Örnek tabanlı ortalama F-puanı ( <i>F-measure</i> ) metriği için deneysel sonuçlar.....	33
Tablo 6-9 Makro ortalama F-puanı ( <i>F-measure</i> ) metriği için deneysel sonuçlar	34
Tablo 6-10 Mikro ortalama F-puanı ( <i>F-measure</i> ) metriği için deneysel sonuçlar .....	35
Tablo 6-11 Örnek tabanlı doğruluk metriği için deneysel sonuçlar .....	36
Tablo 6-12 Alt Küme Doğruluğu ( <i>Subset accuracy</i> ) metriği için deneysel sonuçlar .....	37
Tablo 6-13 Hammin kaybı ( <i>Hamming loss</i> ) metriği için deneysel sonuçlar .....	38
Tablo 6-14 Çalışma süresi metriği için deneysel sonuçlar .....	39
Tablo 6-15 Metriklere göre en iyi performans gösteren yöntemler.....	49

**KISALTMALAR DİZİNİ**Kısaltmalar

BR	Binary Relevance
LP	Label Powerset
CC	Classifier Chain
DBR	Dependent Binary Relevance
RAKEL	Random k-Labelsets
BRS	Binary Relevance Support
BRA	Binary Relevance Association
BRLP	Binary Relevance Label Powerset



## 1 GİRİŞ

Günümüzde insanlar tarafından her saat, her dakika çok büyük miktarlarda veri üretilmektedir. Verinin sınıflandırılması, veri üzerinden tahmin ve analiz yapılması insanlar için bir ihtiyaç haline almıştır. Bu tür tahmin ve analiz işlemleri insanların veya firmaların stratejik ve kritik kararlarında yapılabilecek birçok hatanın önüne geçilmesini sağlayabilmektedir ve geleceğe yönelik alınacak kararlarda yol gösterici olmaktadır.

Verilerin büyümesi ve karmaşılaşması bu tür tahmin ve analiz işlemlerinin insanlar tarafından gerçekleştirilmesini zorlaştırmaktadır. Bu yüzden bu tür işlemler için bilgisayarların kullanımı oldukça yaygınlaşmıştır. Makine öğrenmesi yöntemlerinin de yaygınlaşması ve gelişmesi ile veri üzerinden tahmin yapmak için makine öğrenmesi yöntemlerinin kullanılması günümüzde oldukça popülerdir.

Makine öğrenmesinde bilgisayar programının veri seti girişinden bir öğrenme gerçekleştirip sonrasında yeni gözlemleri sınıflandırmak için bu öğrenmeyi kullandığı denetimli öğrenme yaklaşımına sınıflandırma adı verilmektedir. Kotsiantis et al. (2006) çalışmalarında sınıflandırmanın amacını tahmin edici özellikler kullanarak sınıf etiketlerinin dağılımının bir modelini oluşturmak ve ortaya çıkan sınıflandırıcı ile tahmin edici özelliklerin bulunduğu fakat sınıf etiketi değerlerinin bilinmediği test örneklerine sınıf etiketleri atamak olarak tanımlamıştır. Klasik bir sınıflandırma işleminde girdi olarak verilen veri setinin her bir örneği bir adet sınıfa sahiptir. Her bir örnek için örnek içerisindeki veriler, örneğin sınıfı ile ilişkilendirilir. Bu ilişkilendirmeler sonucunda bir model ortaya çıkar. Sınıfı bilinmeyen bir örnek bu model aracılığı ile incelenerek bu örneğin sınıfı hakkında bir tahmin yapılır.

Günlük hayatta karşımıza çıkan birçok veri aynı anda birden çok kategoriye veya etikete sahip olabilmektedir. Bu durum çok etiketli sınıflandırma problemini ortaya çıkarmıştır. Tsoumakas and Katakis (2007) kaynağında çok etiketli sınıflandırma probleminin metin sınıflandırma ve medikal tanı alanlarında ortaya çıktığı belirtilmiştir. Çok etiketli sınıflandırma probleminde veri setinin her bir örneği aynı anda birden çok sınıf ile ilişkili olabilmektedir yani birden çok etikete sahip olabilmektedir. Klasik sınıflandırma yöntemleri bu işlem için uygun değildir. Bu sebeple çok etiketli sınıflandırma yöntemleri ortaya çıkmıştır.

Çok etiketli sınıflandırma yöntemleri arasında ortaya atılan en basit ve kolay anlaşılır yöntem ikili alaka (*binary relevance*) yöntemidir. Bu yöntemin en büyük dezavantajı etiketler arası ilişkileri değerlendirememesidir. Bu sebeple daha karmaşık yöntemler ortaya çıkmıştır.

Bu çalışma kapsamında ikili alaka düzeyi yönteminin bir dezavantajı olan etiketler arası ilişkileri değerlendiremememe durumunu ortadan kaldıran çeşitli

iyileştirmeler yaparak yeni yöntemler geliştirilmiş ve bu yöntemler literatürde var olan diğer yöntemler ile deneysel olarak karşılaştırılmıştır. Bu şekilde çeşitli metrikler ve veri setleri ile ortaya koyulan yöntemlerin var olan yöntemler karşısındaki performansının gözlemlenmesi hedeflenmiştir.

Tez çalışmasının ikinci bölümünde bu konuda daha önce yapılmış çalışmalara değinilmiştir. Üçüncü bölümde makine öğrenmesi, tek etiketli sınıflandırma, çok etiketli sınıflandırma konuları anlatılmıştır. Dördüncü bölümde çok etiketli sınıflandırma yöntemleri, problem dönüşüm metotları ve algoritma adaptasyon metotları hakkında bilgi verilmiştir. Beşinci bölümde ortaya çıkartılan yöntemler ve deneyler için geliştirilen uygulama hakkında bilgi verilmiştir. Altıncı bölümde deney koşulları, kullanılan veri setleri, kullanılan başarı değerlendirme metrikleri, deney parametreleri ve deney sonuçları açıklanmış ve yorumlanmıştır.



## 2 ÖNCEKİ ÇALIŞMALAR

Bu bölümde ikili alaka düzeyi yöntemini iyileştiren çalışmalara ve bu çalışmaların sonuçlarına yer verilmiştir.

Read et al. (2009) çalışmalarında BR yönteminin etiketler arası bağımsız bir şekilde değerlendirme yaptığından dolayı literatürde göz ardı edilmesi, mevcut yöntemlerin etiketler arası ilişkileri kullanarak değerlendirme yapmak için yüksek karmaşıklığa sahip modeller oluşturması sebepleriyle büyük veri setleriyle ölçeklenebilir olan sınıflandırıcı zinciri (*classifier chain*) yöntemini sunmuşlardır. Çalışmada ortaya koyulan yöntemin etiketler arası ilişkileri modellerken karmaşıklığı da kabul edilebilir seviyede tuttuğu belirtilmiştir. Çeşitli veri setleri ve metrikler kullanarak yaptıkları deneysel değerlendirmelerde yöntemin mevcut yöntemler ile rekabet gücünü göstermişlerdir.

Tsoumakas et al. (2009) çalışmalarında BR yönteminin lineer karmaşıklığa sahip olduğunu fakat etiketler arası ilişkileri hesaplama dahil etmediğinden dolayı etiket kombinasyonlarının doğru bir şekilde tahmin edilemeyebileceğine değinilmiş ve bu problemin istifleme (*stacking*) yöntemiyle hafifleyebileceğine değinmişlerdir. Çalışma içerisinde istifleme yönteminin makine öğreniminde kullanım geçmişine dair bilgiler verilmiş ve çok etiketli sınıflandırma için bir istifleme yöntemini 2BR olarak isimlendirmişlerdir. Ayrıca çalışmalarında istifleme yönteminin ilk katmanı (base-level) için budama uygulanmasını önermişlerdir. Bu sayede özellik uzayının boyutu azalırken sistem etkinliğinin ve performansının arttığını belirtmişlerdir.

Montañes et al. (2014) çalışmalarında zincirleme ve istifleme yöntemleri gibi bir başka meta-öğrenme yöntemi olan bağımlı ikili alaka düzeyi (*dependent binary relevance*) yöntemini ortaya koymuşlardır. DBR yönteminin hem zincirleme hem de istifleme yöntemlerinin özelliklerini barındırdığını belirtmişlerdir. Çalışma kapsamında önerilen yöntem ile mevcut yöntemler deneysel olarak çok etiketli veri setleri ve çok etiketli sınıflandırma yaygın olarak kullanılan metrikler ile karşılaştırılmışlar ve DBR yönteminin iyi bir performans sergilediğini kanıtlamışlardır.

Chen et al. (2021) çalışmalarında DBR yönteminin performansını arttırmak amacıyla istifleme yönteminin yanı sıra etiket seçimi işlemi de yapan Etiket Seçimli İstifleme (*Stacking Model with Label Selection*) isimli yöntemi ortaya koymuşlardır. Yöntem ilk katmanda aynı BR yöntemi gibi çalışmakta fakat ikinci katmanda her bir etiket için bir etiket seçim işlemi yaparak her bir etiket için en alakalı etiketlerin kümesini seçerek ikinci katmanın özellik kümesini bu etiketler ile genişletmektedir. Çalışma kapsamında ortaya koyulan yöntem deneysel olarak diğer yöntemlerle karşılaştırılmış ve yöntemin mevcut yöntemlerle rekabet edebileceği doğrulanmıştır. Çalışmada ortaya koyulan yöntemin hem etkili hem de güçlü olduğu belirtilmiştir.

Alazaidah et al. (2015) çalışmalarında hem problem dönüşüm metotlarını hem de algoritma adaptasyon yöntemlerini kullanarak etiketler arası ilişkilere dayalı MLC-ACL isimli bir yöntem ortaya koymuşlardır. Ortaya koydukları yöntem ilk olarak çok etiketli veri setini sık görülen etiket kriterine göre tek etiketli veri setine çevirmekte ardından PART (Frank and Witten, 1998) algoritması ile tek etiketli veri seti üzerinden sınıflandırma kuralları oluşturmaktadır. Son olarak apriori algoritması ile etiketler arasındaki pozitif ilişkiler bulunarak tek etiketli kurallar çok etiketli kurallara dönüştürülmektedir. Ortaya koyulan yöntem iki adet veri seti ve üç adet metrik ile deneysel olarak test edilmiş ve mevcut diğer yöntemler ile karşılaştırılmıştır. Deneyler sonucunda ortaya koyulan yöntemin mevcut yöntemlere göre makul bir performans gösterdiği açıklanmıştır.

Cherman et al. (2011) çalışmalarında BR yönteminin bir uzantısı olarak BR+ adlı bir yöntem ortaya koymuşlardır. Ortaya koydukları yöntemin iki adet varyasyonu bulunmaktadır. İlk varyasyon *BR+ No Update*, DBR yöntemiyle çok benzerlik göstermektedir. Yöntem içerisinde iki adet sınıflandırıcı katman bulunmakta, ilk katman BR yöntemiyle aynı, ikinci katmanda ise her bir etiket için diğer tüm etiketler kullanılarak özellik uzayını genişleten bir model oluşturulmuştur. İkinci varyasyon *BR+ Update Order* ise bu yöntem ile zincirleme yaklaşımını birleştirerek ikinci katmandaki her bir modelden elde edilen tahminler ile bir sonraki model içerisindeki etiket değeri güncellenerek başarıyı arttırmak amaçlanmıştır. Çalışma kapsamında ortaya koyulan yöntem ile iki diğer çok etiketli sınıflandırma yöntemi karşılaştırılmış ve ortaya koyulan yöntemin diğer iki yönteme göre iyileştirme sağladığı açıklanmıştır.

Li and Zhang (2014) çalışmalarında kontrollü etiket ilişkilerinden yararlanmayı gerçekleştirmek için, iki aşamalı bir filtreleme prosedürüne dayalı olarak BR için yeni bir geliştirme önerilmiştir. Önerilen yöntemin ilk aşamasında veri setinin geçirme için ayrılmış bir parçası ve F-puanı (*F-measure*) metriği kullanılarak bir budama işlemi gerçekleştirilir. İkinci adımda ise budanmamış etiketler özellik olarak kullanılır ve öznelik seçimi yöntemi ile yakın ilişkili etiketler belirlenir. Çalışma kapsamında on dört çok etiketli veri setinde kapsamlı deneyler gerçekleştirilmiş, özellikle etiket alanında çok sayıda sınıf etiketi bulunduğu, kontrollü etiket ilişkilerinden yararlanmanın üstünlük sağladığı açıklanmıştır.

Tenenboim et al. (2010) çalışmalarında çok etiketli veri seti etiketli arasındaki ilişkileri bulan ve modelleyen bir yaklaşım ortaya koymuşlardır. Çalışmalarında ilk olarak etiketler arası ilişkileri bulan ardından etiket kümesini birbirini dışlayan birkaç alt kümeye bölen ve son olarak elde edilen etiketler arası ilişkiler ile çok etiketli sınıflandırma işlemi gerçekleştiren bir algoritma geliştirmişlerdir. Çalışmada bağımsız etiketleri tespit etmek için ki-kare testi kullanılmıştır. Keşfedilen ilişkileri içeren çok etiketli sınıflandırma için İkili

alaka düzeyi (*binary relevance*) ve *label powerset* yöntemlerinin bir kombinasyonu kullanılmıştır.



### 3 MAKİNE ÖĞRENMESİ

Makine öğrenimi bilgisayar sistemlerinin açıkça programlanmadan belirli bir görevi gerçekleştirmek için kullandığı algoritmaların ve istatistiksel modellerin bilimsel çalışmasıdır. (Mahesh,2019) Makine öğrenmesi, bilgisayarların veriler üzerinden öğrenme işlemi gerçekleştirerek çeşitli çıkarımlar yapabilmesini sağlayan, yapay zekanın bir alt dalıdır. Makine öğrenmesi, bilgisayarların insanlar gibi veriler üzerinden deneyim yoluyla herhangi bir dış etki olmadan öğrenme gerçekleştirerek tahminler yapması ile ilgilenir. Bu öğrenme işlemi genellikle bilgisayar yazılımları ile gerçekleştirilir. Makine öğrenmesi sanal asistanlarda, hava tahminlerinde, medikal tanılarda, arama motorlarında, çeviri araçlarında, dolandırıcılık tespitinde, biyometrik sistemlerde, öneri sistemlerinde, e-mail filtrelemede ve birçok farklı alanda uygulanmakta ve her geçen gün makine öğrenmesi için yeni kullanım alanları ortaya çıkmaktadır.

Makine öğrenmesi yöntemleri gözetimli öğrenme, gözetimsiz öğrenme, yarı gözetimli öğrenme, destekli öğrenme olmak üzere dört kategoride incelenmektedir. Gözetimli öğrenme eğitimde kullanılan veri örneklerinin etiketlere sahip olduğu öğrenme şeklidir. Sınıflandırma gözetimli öğrenme kategorisi altındadır. Gözetimsiz öğrenme etiketsiz veri seti ile öğrenme gerçekleştirilen bir öğrenme şeklidir. Kümeleme ve birliktelik kural madenciliği gözetimsiz öğrenme kategorisi altında incelenir. Yarı gözetimli öğrenmede veri örneklerinin büyük bir kısmının etiketli, küçük bir kısmının da etiketsiz olduğu durumlardaki öğrenme şeklidir. Destekli öğrenme deneme yanılma ile doğru çıktıların ödüllendirildiği, yanlış çıktıların ise cezalandırıldığı ilerlemeli bir öğrenme şeklidir.

#### 3.1 Tek Etiketli Sınıflandırma

Sınıflandırma, her bir veri örneğinin bir etikete sahip olduğu bir veri seti üzerinden öğrenme işlemi gerçekleştirerek ileride verilen etiketsiz veri örneklerinin hangi sınıfın üyesi olduğunu tahmin etme işlemidir. Bu işlemde kullanılan algoritmaya bağlı olarak önce veri seti ile bir model oluşturulup öğrenme işlemi gerçekleştirip daha sonra yeni verilen örnek üzerinden tahmin yapılacağı gibi öğrenme ve tahmin işlemleri aynı anda da gerçekleştirilebilir. Tek etiketli sınıflandırmada her bir veri örneği sadece bir adet etikete sahiptir, yani tek bir sınıfın üyesidir.

#### 3.2 Çok Etiketli Sınıflandırma

Çok Etiketli Sınıflandırma verilen bir veri setini önceden belirlenmiş etiketler dahilinde etiketleri veri örneği ile alakalı (pozitif) ve alakasız (negatif) olarak iki kümeye ayırma işlemidir. Zhang et al. (2017) çalışmalarında çok etiketli öğrenmeyi birden çok semantik anlama sahip gerçek dünya nesnelerini modellemek için kullanılan popüler bir öğrenme çerçevesi olarak

tanımlamışlardır. Tek etiketli sınıflandırmada her bir veri örneği sadece bir sınıfın üyesi olabilirken çok etiketli sınıflandırmada bir veri örneği aynı anda birden çok sınıf ile ilişkilendirilebilir.

Tablo 3-1 Çok Etiketli Veri Seti Örneği

Örnek	Özellikler	Etiket1	Etiket2	Etiket3	Etiket4	Etiket5
1	$X_1$	1	1	0	0	1
2	$X_2$	1	1	1	0	0
3	$X_3$	0	1	0	1	0
4	$X_4$	1	1	1	1	1

Çok etiketli veri seti örneği Tablo 3-1 de verilmiştir. Çok etiketli bir veri setinde bir etiketin bir örnek ile alakalı olması durumunda örneğin o etiket ile ilişki değeri 1, alakasız olması durumunda 0 ile ifade edilebilir. Çok etiketli sınıflandırmada eğitim bu tür bir veri seti ile gerçekleştirilir. Sınıflandırma için yeni bir örnek verildiğinde, verilen örneğin sadece özellik değerleri mevcuttur, etiket değerleri boştur. Sınıflandırıcı yeni verilen örneği değerlendirerek her bir etiket için bir ilişki değeri üretir.

Tsoumakas et al. (2009) kaynağına göre çok etiketli sınıflandırma genellikle metin sınıflandırma, multimedya sınıflandırma, biyoinformatik, protein fonksiyon sınıflandırması, ses sınıflandırma, sorgu sınıflandırması, ilaç keşfi, medikal tanı, pazarlama, etiket öneri sistemleri gibi alanlarla kullanılır. Jain and Kambli (2020) çalışmalarında çok etiketli sınıflandırmayı müşteri yorumları sınıflandırması kullanmışlardır. Gururani et al. (2019) çalışmalarında müzik enstrümanı tanımda çok etiketli sınıflandırma kullanmışlardır. Trochidis et al. (2008) çalışmalarında çok etiketli sınıflandırma ile müzik duygu çıkarımı yapmışlardır. Boutell et al. (2004) çalışmalarında çok etiketli sınıflandırma ile görsel sınıflandırma yapmışlardır. Katakis et al. (2008) çalışmalarında otomatik etiket öneri sistemi için çok etiketli metin sınıflandırması yapmışlardır. Rivolli et al. (2017) çalışmalarında çok etiketli sınıflandırma kullanarak seyyar büfe öneri sistemi geliştirmişlerdir.

#### 4 Çok Etiketli Sınıflandırma Yöntemleri

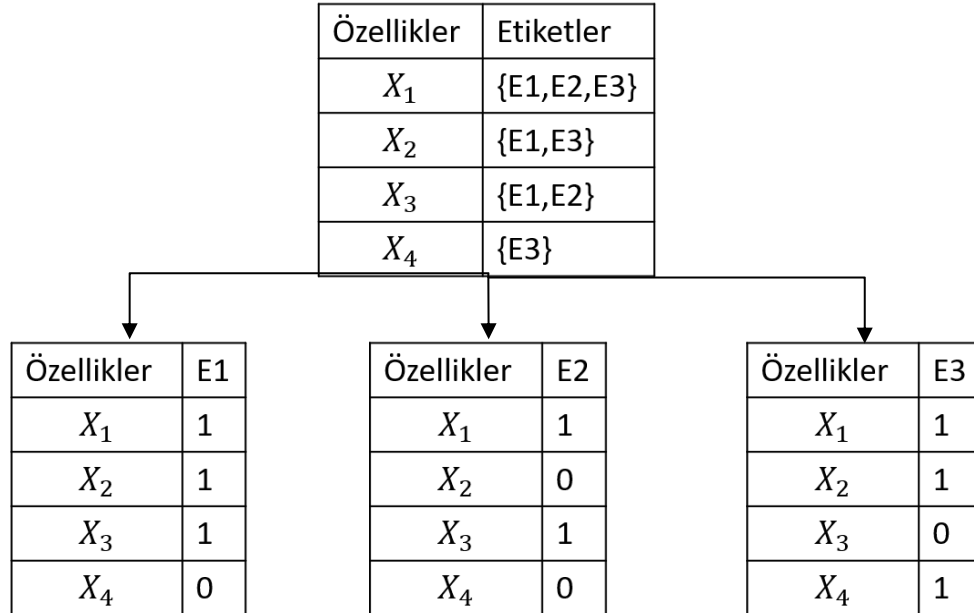
Tek etiketli veri setleri ve çok etiketli veri setleri arasındaki farklılıklardan dolayı, tek etiketli sınıflandırma yöntemleri çok etiketli sınıflandırma probleminde direkt olarak kullanılamamaktadır. Bu sebeple tek etiketli yöntemler ile çok etiketli veri setlerinin birlikte kullanılabilmesini sağlayan bazı metotlar geliştirilmiştir. Bu metotlar problem dönüşüm metotları ve algoritma adaptasyon metotları olmak üzere iki başlık altında incelenmektedir. Problem dönüşüm metotları, çok etiketli sınıflandırma problemini bir veya daha fazla tek etiketli

sınıflandırma veya regresyon problemine çeviren yöntemleri içerir. Algoritma adaptasyon metotları ise tek etiketli sınıflandırma algoritmalarını çok etiketli veri setleri ile direkt çalışacak şekilde uyarlayan yöntemleri içerir (Tsoumakas and Katakis, 2007).

#### 4.1 Problem Dönüşüm Metotları

##### 4.1.1 İkili Alaka Düzeyi (Binary Relevance)

İkili alaka düzeyi yöntemi çok etiketli sınıflandırma problemini ele alan basit bir yaklaşımdır. Bu yöntem genellikle ortaya koyulan yeni çok etiketli sınıflandırma yöntemleri ile karşılaştırılır. Bu yöntem çok etiketli sınıflandırma problemi için kullanılan en basit stratejidir fakat görüldüğünden daha etkili bir yöntemdir. Bu yöntem çok etiketli sınıflandırma problemini etiket sayısı kadar tek etiketli ikili öğrenme problemine dönüştürür. Her bir etiket bağımsız olarak değerlendirilir (Luaces et al., 2012). Çok etiketli veri setindeki özellikler, veri setindeki sınıf sayısı kadar kopyalanır fakat her bir kopyaya sadece bir etiket dahil edilmektedir. Bu şekilde çok etiketli veri seti birden çok tek etiketli veri setine dönüştürülür ve her bir veri seti ile bir sınıflandırıcı modeli oluşturulur. Etiketleri bilinmeyen yeni bir örnek için çıkarım yapılacağı zaman her bir sınıflandırıcıdan ayrı ayrı çıkarımlar elde edilir ve her bir modelin çıktıları birleştirilerek final çıktısı oluşturulur. Bu yöntemin dezavantajı oluşturulan modelde sınıflar arası ilişkilerin göz ardı edilmesidir.



Şekil 4-1 Binary Relevance Yöntemi Örneği (Tsoumakas et al. ,2009)

BR yönteminin veri seti dönüşüm işlemi Şekil 4-1 üzerinde gösterilmiştir. Şekildeki gösterimde çok etiketli veri setinde toplamda 3 adet etiket bulunmaktadır ve her bir etiket için bir veri seti oluşturulmuştur. Oluşturulan veri

setleri herhangi bir tek etiketli sınıflandırma algoritması aracılığı ile birer model oluşturulmak için kullanılabilir. Ardından oluşturulan modeller ile çok etiketli sınıflandırma işlemi gerçekleştirilebilir.

#### 4.1.2 Label Powerset

Bu yöntemde çok etiketli veri setindeki etiketler tek bir etiket altında birleştirilerek çok etiketli veri seti tek etiketli bir veri setine dönüştürülür (Tsoumakas and Katakis, 2007). Her bir örnekte 1 ve 0 değerleri ile ifade edilen örneğin etiket ile olan ilişkileri tek bir etiket altında, etiketlerin veri setindeki sırasına birleştirilir. Ardından oluşturulan yeni veri seti ve bir tek etiketli sınıflandırma algoritması kullanılarak bir sınıflandırma modeli oluşturulur. Yeni bir veri örneği sınıflandırılma işleminde ise bu model üzerinden sınıflandırma tahmini elde edilir ve elde edilen birleştirilmiş etiket değeri parçalanarak her bir etiketin veri örneği ile olan ilişkisi 0 veya 1 değerleri şeklinde elde edilir. Bu yöntemin dezavantajı eğitim sırasında karşılaşılmamış etiket kombinasyonları için çıkarım yapamamasıdır.

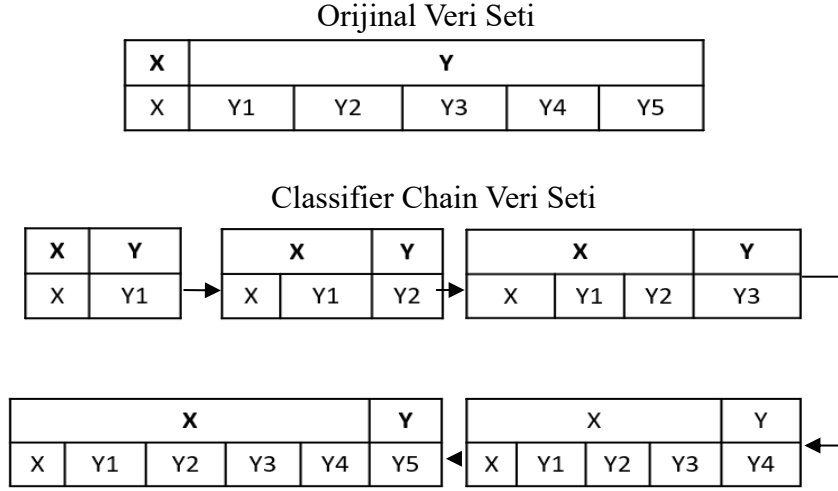
Özellikler	Etiketler		Özellikler	Etiket
$X_1$	{E1,E2,E3}	→	$X_1$	111
$X_2$	{E1,E3}		$X_2$	101
$X_3$	{E1,E2}		$X_3$	110
$X_4$	{E3}		$X_4$	001

Şekil 4-2 Label Powerset Yöntemi Örneği (Tsoumakas et al., 2009)

LP yönteminin veri seti dönüşüm işlemi Şekil 4-2 üzerinde gösterilmiştir. Şekilde 3 adet etiket barındıran çok etiketli veri seti 3 uzunluğunda ikili dize formatında etikete sahip olan tek etiketli bir veri setine dönüştürülmüştür.

#### 4.1.3 Sınıflandırıcı Zinciri (Classifier Chain)

Sınıflandırıcı zinciri modeli, ikili alaka düzeyi yöntemi gibi etiket sayısı kadar sınıflandırıcı içerir. Zincirdeki her bir bağlantının özellik alanı, önceki tüm bağlantıların 0/1 etiket ilişkileriyle genişletilir (Read et al., 2009). Her bir etiket için bir tek etiketli bir veri seti oluşturulur. Bu veri setleri belirli bir sıraya göre oluşturulur ve her bir sınıflandırıcının veri setinin özellik kümesine bir önceki sınıflandırıcının etiket sütunu dahil edilir. Bu şekilde etiket sayısı kadar sınıflandırıcı model eğitilir. Yeni bir veri örneğinin sınıflandırılması sırasında ilk olarak veri örneği için birinci sıradaki modelden çıkarım elde edilir ardından bu çıkarım veri örneğinin özellik kümesine dahil edilerek ikinci model üzerinden bir çıkarım elde edilir. Bu şekilde tüm modellerden çıkarım elde edilene kadar devam edilir ve son modelden çıkarım alındıktan sonra çok etiketli sınıflandırma işlemi tamamlanmış olur. Bu yöntemde sınıflandırıcıların sırası doğruluk performansı üzerine etkilidir. Optimal etiket sırası belirlenmelidir.



Şekil 4-3 Classifier Chain Yöntemi Örneği

Sınıflandırıcı zinciri yönteminde kullanılan veri seti dönüşüm işlemi ve modellerin birbirleriyle ilişkileri Şekil 4-3 üzerinde gösterilmiştir.

#### 4.1.4 Rasgele k-Etiket Kümeleri (Random k-Labelsets)

Tsoumakas and Vlahavas (2007) çalışmalarında ortaya koyulan bu yöntem LP yönteminin bir iyileştirmesi olarak görülebilir. Bu yöntemde etiketler kümesi elemanlarından rasgele k boyutunda n adet alt kümeler oluşturulur. Her bir alt küme için alt küme elemanlarının etiket kümesini oluşturduğu bir veri seti oluşturulur. Ardından her bir veri seti ile bir LP sınıflandırıcı modeli oluşturulur. Etiketsiz yeni bir veri örneği sınıflandırılacağı zaman bu veri örneği için her bir LP modeli üzerinden çıkarım elde edilir. Bu çıktılar oylama yöntemi ile oylanarak çok etiketli sınıflandırma çıktısı elde edilir. Bu şekilde LP yönteminin dezavantajı olan eğitimde karşılaşılmayan kombinasyonlar için çıkarım yapamaması durumu iyileştirilmiş olur. Bu yöntemde optimum n ve k sayılarını belirlemek doğruluk ve performans açısından önemlidir.

Tablo 4-1 Random k-Labelsets Yöntemi Çıkarım Örneği (Tsoumakas et al., 2009)

Model	Altkümeler	Çıkarımlar				
		E1	E2	E3	E4	E5
m1	{E1,E3,E4}	1	-	0	1	-
m2	{E2,E4,E5}	-	0	-	1	1
m3	{E1,E2,E3}	0	1	1	-	-
m4	{E2,E3,E5}	-	0	1	-	1
Oylama		1/2	1/3	2/3	2/2	2/2
Çıkarım		1	0	1	1	1

RAKEL yönteminde LP modellerinden elde edilen çıktıların oylanarak çok etiketli çıkarımın elde edilişi Tablo 4-1 üzerinde gösterilmektedir. Tablo 4-1 incelendiğinde n sayısı (model sayısı) 4 ve k sayısı (etiket alt kümesi boyutu) 3 olarak seçilmiştir. LP çıktıları parçalanmış ve oylama yoluyla çok etiketli çıkarım elde edilmiştir.

#### 4.1.5 İstifleme (Stacking)

Bu yöntem Wolpert (1992) çalışmasındaki yığılmış genelleme (*stacked generalization*) paradigması kullanılarak ortaya çıkmıştır. Toplam etiket sayısının 2 katı kadar sınıflandırıcı oluşturulur. Bunların yarısı temel katman (base-level) diğer yarısı ise üst katman (meta-level) sınıflandırıcılardır. Her bir üst katman sınıflandırıcı tüm temel katman sınıflandırıcıların çıktıları ile oluşturulur (Tsoumakas et al., 2009). Temel katman sınıflandırıcılar ikili alaka düzeyi (*binary relevance*) yöntemindeki gibi oluşturulurlar. Ardından her bir etiket için üst katman sınıflandırıcı oluşturulur. Üst katman sınıflandırıcıların veri setlerinde orijinal veri setindeki tüm özelliklerin üzerine tüm temel katman sınıflandırıcılardan elde edilen çıktılar özellik olarak eklenir. Üst katman eğitilirken kullanılan veriler temel katman üzerinde k-katlamalı çapraz doğrulama yöntemi kullanılarak elde edilir. Yeni bir veri örneği sınıflandırılmak için verildiğinde ilk olarak tüm temel katman sınıflandırıcılarda işlenir ve çıktılar oluşturulur ardından bu yeni verinin üzerine bu çıktılar eklenerek üst katman sınıflandırıcılarda işlenir ve son çıkarım elde edilir.

Orijinal Veri Seti

X	Y		
X	Y1	Y2	Y3

Base Level

X	Y	X	Y	X	Y
X	Y1	X	Y2	X	Y3

Meta Level

X				Y	X				Y
X	Y1	Y2	Y3	Y1	X	Y1	Y2	Y3	Y2

X				Y
X	Y1	Y2	Y3	Y3

Şekil 4-4 İstifleme (Stacking) Yöntemi Örneği

Temel katman ve üst katman oluşturulması örneği Şekil 4-4 üzerinde verilmiştir.

#### 4.1.6 Bağımlı İkili Alaka Düzeyi (Dependent Binary Relevance)

Montañes et al. (2014) çalışmalarında ortaya koydukları bir yöntemdir. İstifleme (*stacking*) yöntemine benzer bir yöntemdir. İstifleme (*stacking*) yönteminin üst katman (meta-level) sınıflandırıcılar orijinal özellik uzayının üzerine temel katman (base-level) sınıflandırıcıların çıkarımları eklenmiş veri setleri ile eğitilirken, DBR yöntemi üst katman sınıflandırıcıları eğitirken orijinal özellik uzayının üzerine (üst katman sınıflandırıcının kendi çıktı etiketi hariç) orijinal veri setindeki etiketlerin eklendiği veri setleri kullanılır. Etiketleri olmayan yeni bir örnek için çıkarım yapılacağı zaman ilk olarak temel katman çıkarımları elde edilir ardından bu çıkarımlar ile özellik uzayı genişletilir. Genişletilmiş özellik uzayına sahip veri örneği üst katman sınıflandırıcılara girdi olarak verilerek son çıkarımlar elde edilir.

## 4.2 Algoritma Adaptasyon Metotları

### 4.2.1 AdaBoost.MH

Schapire and Singer (2000) çalışmalarında ortaya koydukları bir yöntemdir. Bu yöntemde bir tek etiketli sınıflandırma algoritması olan *AdaBoost*, çok etiketli veri seti üzerinde sınıflandırma işlemi yapabilecek şekilde uyarlanır. İlk olarak veri seti örnekleri üzerinde bir dönüşüm işlemi uygulanır. Her birçok etiketli veri örneği, etiket sayısı kadar tek etiketli veri örneğine dönüştürülür. Dönüşüm işleminden sonra *AdaBoost* yöntemi uygulanır ve dönüştürülmüş veri seti ile model eğitimi gerçekleştirilir. Etiketsiz bir veri örneği için çıkarım yapılacağı zaman da bu örnek üzerinde aynı dönüşüm işlemi uygulanır ve çıkarım elde edilir.

Orijinal Veri Seti						Dönüştürülmüş Veri Seti		
X	Y					X	Y	Y
X	Y1	Y2	Y3	Y4	Y5	X <sub>1</sub>	y	Y
X <sub>1</sub>	1	1	0	0	1	X <sub>1</sub>	Y1	+1
						X <sub>1</sub>	Y2	+1
						X <sub>1</sub>	Y3	-1
						X <sub>1</sub>	Y4	-1
						X <sub>1</sub>	Y5	+1

Şekil 4-5 AdaBoost.MH Yöntemi Dönüşüm Örneği

*AdaBoost.MH* yönteminde gerçekleştirilen veri dönüşümü örneği Şekil 4-5 üzerinde verilmiştir.

### 4.2.2 Çok Etiketli C4.5 (Multi-Label C4.5)

Clare and King (2001) çalışmaların popüler C4.5 karar ağacı algoritmasının çok etiketli veri seti ile sınıflandırma yapabilecek şekilde uyarlamıştır. C4.5 algoritmasında yapılan entropi hesaplaması çok etiketli entropi olarak uyarlanmıştır. Çok etiketli entropi hesaplanarak klasik C4.5 algoritmasındaki gibi tekrarlı olarak karar ağacı oluşturulmaktadır.

$$S = \{(x_i, Y_i) \mid 1 \leq i \leq m\} \quad (4.1)$$

$p(y)$  = S içerisindeki bir örneğin  $y$  etiketini içermesi olasılığı

$$MLEnt(S) = \sum_{y \in Y} Ent_y(S) = \sum_{y \in Y} p(y) \log(p(y)) + (1 - p(y)) \log(1 - p(y)) \quad (4.2)$$

Çok etiketli veri seti eşitlik 4.1 ile temsil edilmektedir ve bu çok etiketli veri seti üzerinde entropi hesaplaması eşitlik 4.2 ile yapılmaktadır.

### 4.2.3 ML-kNN

Zhang and Zhou (2005) çalışmalarında popüler kNN algoritmasının çok etiketli veriyi sınıflandırabilmesini sağlayacak şekilde uyarlamışlardır. Komşu örneklerden toplanan istatistiksel bilgilerden yola çıkarak çıkarım yapılır. Etiket kümesi bilinmeyen bir örnek için MAP prensibi kullanılarak çıkarım yapılır.

Verilen bir  $x$  örneği için ilgili etiket kümesi  $Y$  şu şekilde oluşturulur:

#### *Algoritma 1 ML-kNN*

##### **Girdiler:**

$D$ : çok etiketli veri seti  $\{(x_i, Y_i) \mid 1 \leq i \leq N\}$

$x$ : test örneği ( $x \in X$ )

##### **Çıktılar:**

$Y$ :  $x$  örneği için tahmin edilen etiket kümesi

##### **İşlem:**

1:  $x$  örneği için eğitim kümesi içerisindeki  $k$  adet en yakın komşular  $N(x)$  belirlenir.

2:  $N(x)$  kullanılarak üyelik sayma vektörü  $\vec{c}_x$  oluşturulur.

3:  $\vec{c}_x$  kullanılarak MAP prensibi ile etiket kümesi oluşturulur.

MAP prensibi : EĞER  $P(H_1^l \mid E_{\vec{c}_x(l)}^l) > P(H_0^l \mid E_{\vec{c}_x(l)}^l)$  ise  $l \in Y$  (4.3)

$N(x)$  :  $x$  örneğine en yakın  $k$  adet komşu

$\vec{c}_x(l)$  :  $N(x)$  içerisindeki  $l$ 'ninci etiketi içeren örneklerin sayısını sayar.

$H_1^l$  : Örneğin  $l$ 'ninci etiketi bulundurma durumu

$E_j^l$  :  $N(x)$  içerisinde  $l$ 'ninci etiketi bulunduran  $j$  adet örnek olma durumu

### 4.3 Karşılaştırma

İkili alaka düzeyi (*binary relevance*) yöntemi çok etiketli sınıflandırma problemi için ortaya koyulmuş en sade yöntemdir, her bir etiketi bağımsız olarak değerlendirmektedir bu yüzden etiketler arası ilişki göz önünde bulundurulmaz. Sınıflandırıcı zinciri (*classifier chain*) yöntemi ikili alaka (*binary relevance*) yönteminin biraz daha karmaşık bir uzantısı olarak görülebilir. Sınıflandırıcı zinciri (*classifier chain*) yönteminde her bir etiket için bir sınıflandırıcı oluşturulur fakat her bir sınıflandırıcının özellik uzayı bir önceki sınıflandırıcıya bağlı olarak genişletildiği için etiketler zincir şeklinde bir bağlılık kurulmaktadır. *Label powerset* yöntemi ikili alaka yönteminin tam zıttı olarak görülebilir çünkü etiketler birleştirilerek tek bir etiket haline getirilmektedir ve bu durum daha önce görülmemiş etiket kombinasyonlarını sınıflandırmayı imkânsız kılmaktadır. Bu dezavantajı Rasgele  $k$ -Etiket Kümeleri (*Random k-Labelsets*) yöntemi ortadan kaldırmaktadır. Bu yöntemde küçük etiket alt kümeleri oluşturularak *label powerset* yöntemi oluşturulduğu için bu yöntem ikili alaka düzeyi (*binary relevance*) ve *label powerset* yöntemlerinin orta noktası olarak düşünülebilir. İstifleme (*stacking*) yöntemi ikili alaka düzeyi (*binary relevance*) yönteminin çok daha karmaşık bir uzantısı olarak değerlendirilebilir. Temel katman ikili alaka düzeyi (*binary relevance*) yöntemi ile birebir aynı olmasına rağmen üst katmanda etiketler arası ilişkiyi öne çıkarmak amacıyla her bir etiket için olan sınıflandırıcıların özellik kümesi tüm etiketler ile  $k$ -katmanlı çapraz doğrulama yoluyla genişletildiği için karmaşıklığı yüksek bir yöntemdir. Bağımlı ikili alaka düzeyi (*dependent binary relevance*) yöntemi istifleme (*stacking*) yöntemine çok benzese de üst katmandaki etiket genişletme işlemi direkt olarak orijinal veri setinden yapıldığı için daha düşük karmaşıklığa sahip bir yöntemdir. Algoritma adaptasyon metotları incelendiğinde klasik sınıflandırma algoritmalarının yapısı değiştirilmeden çok etiketli sınıflandırma problemine uyarlanmaktadır. Oluşturulan model sayısı farklılık göstermemekte, model oluşturulurken yapılan hesaplamalar değişmektedir ve karmaşıklık da buna bağlı olarak değişmektedir.

## 5 GELİŞTİRİLEN YÖNTEMLER

### 5.1 Binary Relevance Support

Binary Relevance yönteminin etiketler arası ilişkileri önemsememesi dezavantajını ortadan kaldırmak amacıyla önerilen bir yöntemdir. İkili alaka düzeyi (*binary relevance*) yöntemine ek olarak etiketler arası ilişkileri temsil eden bir destek modeli oluşturulmaktadır. Modelin oluşturulmasında frekans sayımı kullanılmaktadır. Destek modeli iki temel değer hesaplanması üzerine kurulur. Bu değerlerden ilki etiketin veri setine görülme oranı olan  $c$  değeri, diğeri ise bir etiketlerin ikili olarak birlikte bulunma oranı olan  $p$  değeridir. Ardından bu iki değer kullanılarak her etiket ikilisi için bir  $S$  destek değeri hesaplanır.  $S$  destek değeri hesaplanırken  $c$  değerinin modele ne kadar katkı sağlayacağını belirleyen bir güven katsayısı (*confidence coefficient*) değişkeni kullanılır.

$$c_i = \frac{\sum_{j=1}^m Y_j(i)}{m} \quad Y_j(i) = \begin{cases} 1, & y_i \in Y_j \\ 0, & y_i \notin Y_j \end{cases} \quad (5.1)$$

$$p_{i,j} = \frac{\sum_{k=1}^m T_k(i,j)}{m \sum_{k=1}^m Y_k(i)} \quad Y_k(i,j) = \begin{cases} 1, & y_i \in Y_k \cap y_j \in Y_k \\ 0, & y_i \notin Y_k \cup y_j \notin Y_k \end{cases} \quad (5.2)$$

$$S_{i,j} = c_i * \text{confidence coefficient} + p_{i,j} * (1 - \text{confidence coefficient}) \quad (5.3)$$

Önerilen yöntemde kullanılan destek modelinin oluşturulması Şekil 5-1 üzerinde örneklenmiştir. İlk olarak etiketlerin her bir örnekte bulunma sayısının örnek sayısına bölümüyle her bir etiket için bir  $c$  değeri hesaplanmıştır. Bu değer hesaplanması eşitlik 5.1 ile yapılmaktadır. Ardından her bir  $i,j$  etiket çifti için  $i$  ve  $j$  numaralı etiketin birlikte bulunma sayısının  $i$  etiketinin bulunma sayısına bölünmesiyle her bir etiket çifti için  $p$  değeri hesaplanmıştır. Bu değer ise eşitlik 5.2 ile hesaplanmaktadır. Ardından  $c$  ve  $p$  değerleri kullanılarak her bir etiket için  $S$  destek değeri hesaplanmıştır. Bu değer eşitlik 5.3 ile hesaplanmaktadır. Yeni bir etiketsiz örnek için çıkarım elde edilirken ilk olarak BR modelinden çıkarımlar elde edilir ardından BR çıkarımında bulunan her bir etiket için destek modelinin satırları incelenir. Eğer BR çıkarımında bulunan bir etiketin satırındaki herhangi bir etiketin destek değeri 0,5 değerinin üzerindeyse o etiket de örneğin pozitif ilişkili olduğu etiketler kümesine dahil edilir.

Etiketler				
L1	L2	L3	L4	L5
1	1	0	1	0
1	0	0	0	1
0	0	1	1	1

$c_i$				
L1	L2	L3	L4	L5
2/3	1/3	1/3	2/3	2/3

L1	L2	L3	L4	L5
0,6	0,3	0,3	0,6	0,6

$p_{i,j}$					
	L1	L2	L3	L4	L5
L1	0	0,5	0	0,5	0,5
L2	1	0	0	1	0
L3	0	0	0	1	1
L4	0,5	0,5	0,5	0	0,5
L5	0,5	0	0,5	0,5	0

$S_{i,j}$					
	L1	L2	L3	L4	L5
L1	0	0,53	0	0,53	0,53
L2	0,79	0	0	0,79	0
L3	0	0	0	0,79	0,79
L4	0,53	0,53	0,53	0	0,53
L5	0,53	0	0,53	0,53	0

Şekil 5-1 Binary Relevance Support Destek Modeli Örneği

## 5.2 Binary Relevance Association

İkili alaka düzeyi (*binary relevance*) yönteminin dezavantajını ortadan kaldırma amacıyla geliştirilen bir başka yöntem ise *Binary Relevance Association* yöntemidir. Bu yöntemde de ikili alaka düzeyi (*binary relevance*) modelinin yanında bir destek modeli oluşturulmaktadır fakat bu destek modeli bir birliktelik kural çıkarımı (*association rule mining*) algoritması yardımıyla oluşturulmaktadır. İkili alaka düzeyi (*binary relevance*) modeli eğitilirken *FPGrowth* algoritması ile etiketler arası ilişkileri ortaya çıkarmak amacıyla kurallar oluşturulmaktadır. *FPGrowth* algoritmasına girdi olarak özellik kümesi çıkarılmış ve her bir örnek için sadece etiket değerlerini barındıran bir veri seti girdi olarak verilir. Etiketsiz bir veri örneği sınıflandırılmak istendiğinde ilk olarak ikili alaka düzeyi (*binary relevance*) yöntemi ile çıkarımlar elde edilir ve ardından bu çıkarımla elde edilen kurallar bir oylama yöntemi ile uygulanarak son çıkarımlar oluşturulur. *FPGrowth* algoritmasından elde edilen kuralların ikili alaka düzeyi (*binary relevance*) çıkarımlarına uygulanması Şekil 5-2 üzerinde gösterilmiştir. Çıkarımda bulunan her bir etiket +1 oy ile başlamaktadır. Eğer bir kural bir etiketin çıkarımlarda bulunmasını belirtiyorsa o etikete +1 oy, bulunmamasını belirtiyorsa o etikete -1 oy eklenir. Tüm kurallar incelendikten sonra son çıkarım elde edilir.

Binary Relevance Çıkarımı					Kurallar					Oylama					
L1	L2	L3	L4	L5	IF L1=1,L2=1 THEN L5=1	L1	L2	L3	L4	L5	L1	L2	L3	L4	L5
1	1	0	1	0	IF L2=1,L3=0 THEN L4 = 0	+1	+1	0	0	+2					
					IF L1=1,L4=1 THEN L5 = 1										
Son Çıkarım															
L1	L2	L3	L4	L5											
1	1	0	0	1											

Şekil 5-2 Binary Relevance Association Yöntemi Örneği

### 5.3 BRLP

İkili alaka düzeyi (*binary relevance*) yönteminin dezavantajını *label powerset* yönteminin yardımıyla veri seti özellik uzayında genişletme yaparak ortadan kaldırmayı amaçlayan bir yöntemdir. Bu yöntemde çok etiketli veri seti ile ilk olarak bir LP modeli oluşturulmaktadır. Ardından çok etiketli veri setinin özellik uzayı LP adlı bir özellik ile genişletilmektedir. Bu özellik her bir örneğin etiketlerinin LP yöntemine göre birleştirilmiş halini içermektedir. Ardından özellik uzayı genişletilmiş bu veri seti ile BR modeli eğitilir. Etiksiz yeni bir örnekten çıkarım yapılacağı zaman ilk olarak bu örneğin LP modeli üzerinden çıkarımı elde edilir ardından bu çıkarım ile örneğin özellik uzayı genişletilir ve özellik uzayı genişletilmiş veri örneği ile BR modeli üzerinden çıkarımı elde edilerek final çok etiketli çıkarım elde edilir.

Orijinal Veri Seti							BRLP Veri Seti							
I	X	L1	L2	L3	L4	L5	I	X	LP	L1	L2	L3	L4	L5
1	X <sub>1</sub>	1	1	0	1	0	1	X <sub>1</sub>	110 10	1	1	0	1	0

Şekil 5-3 BRLP Yönteminin Örnek Veri Seti Dönüşümü

BRLP yöntemi kapsamında yapılan veri seti dönüşüm işlemi Şekil 5-3 üzerinde örneklenmiştir. Orijinal veri setinin özellik uzayı LP adlı bir özellik ile genişletilmiştir. LP özelliği ikili değerlere sahip etiketlerdeki değerlerin birleştirilerek ikili dizeye çevrilmesiyle oluşturulmaktadır. Bu şekilde bir özellik uzayı genişletmesi yardımıyla etiketler arası ilişkilerin dikkate alınması amaçlanmaktadır.

## 5.4 Topluluk Öğrenmesi (Ensemble) Yöntemleri

İkili alaka düzeyi (*binary relevance*) yöntemi ile diğer çok etiketli problem dönüşüm metotlarını topluluk öğrenmesi (*ensemble*) içerisinde birleştirerek sınıflandırma performansının artırılması amaçlanmıştır. Bu amaç doğrultusunda BR yönteminin dahil edildiği çeşitli topluluk öğrenmesi (*ensemble*) kombinasyonları denenmiştir. Eğitim aşamasında topluluk öğrenmesi (*ensemble*) modeline dahil edilen tüm modeller aynı veri seti ile ayrı ayrı eğitilmiştir. Etiketsiz bir örneğin etiket çıkarımı yapılırken ilk olarak topluluk öğrenmesi (*ensemble*) modeline dahil edilen tüm modellerden çok etiketli çıkarım sonucu elde edilir. Ardından elde edilen tüm çıkarımlar oylama yöntemi ile işlenerek son çıkarım elde edilir. Oylama yöntemi sırasında her bir etiket için her bir modelden elde edilen sonuçlar sayılır. Her bir pozitif ilişki için +1 oy sayılırken negatif ilişkiler 0 olarak sayılır. Tüm oylar toplandıktan sonra topluluk öğrenmesi (*ensemble*) modeli içerisindeki modellerin sayısına bölünerek ortalaması alınır. Eğer bir etiketin ortalama değeri 0.5 ve üzerinde ise bu etiket son çıkarıma pozitif ilişkili olarak dahil edilir, aksi halde negatif ilişkili olarak dahil edilir.

Binary Relevance Çıkarımı

L1	L2	L3	L4	L5
1	1	0	1	0

Label Powerset Çıkarımı

L1	L2	L3	L4	L5
0	1	0	1	1

Classifier Chain Çıkarımı

L1	L2	L3	L4	L5
1	1	0	0	1

Oylama

L1	L2	L3	L4	L5
2/3	3/3	0/3	2/3	2/3
0,6	1	0	0,6	0,6

Ensemble Çıkarımı

L1	L2	L3	L4	L5
1	1	0	1	1

Şekil 5-4 Bir Ensemble Yöntem ile Çıkarım Örneği

Üç adet çok etiketli sınıflandırıcı içeren bir topluluk öğrenmesi (*ensemble*) modelinin oylama yöntemi ile final çıkarımının elde edilmesi Şekil 5-4 üzerinde örneklenmektedir. Her bir etiket için her bir modelden elde edilen çıkarımlar sayılarak ortalamaları hesaplanmıştır ve 0.5 ve üzeri değerde olan etiketler son çıkarıma pozitif ilişkili olarak dahil edilmiştir.

## 6 DENEYSEL SONUÇLAR

### 6.1 Deneysel Çerçeve

Geliştirilen yöntemlerin performansını mevcut yöntemlerle karşılaştırmak amacıyla belirlenen 17 adet veri seti ve 13 adet metrik üzerinden 5 katlamalı çapraz doğrulama kullanarak deneysel olarak değerlendirmesi yapılmıştır. Deneyler yapılırken Java programlama dili ve Mulan kütüphanesi kullanılmıştır. Mulan kütüphanesi bir makine öğrenmesi kütüphanesi olan Weka kütüphanesinin üzerine geliştirilmiş çok etiketli makine öğrenmesi kütüphanesidir. İçerisinde birçok popüler çok etiketli makine öğrenmesi yöntemini ve çok etiketli makine öğrenmesi performans ölçüm metriklerini barındırmaktadır. Bu çalışma kapsamında geliştirilen yeni yöntemler bu kütüphane ile uyumlu şekilde geliştirilmiştir. Deneylerin daha hızlı gerçekleşmesi açısından her bir yöntem-veri seti çifti ayrı bir iş parçacığı üzerinde (*multithread*) şeklinde çalıştırılmıştır.

### 6.2 Veri Setleri

Çalışmada yapılan deneylerde toplam 17 adet veri seti kullanılmıştır. Bu bölümde Tablo 6-1 üzerinde kullanılan veri setlerinin örnek sayısı, özellik sayısı ve etiket sayısı bilgileri verilmiş olup kullanılan her bir veri seti hakkında genel bilgiler verilmiştir.

Tablo 6-1 Veri setleri istatistikleri tablosu

Veri Seti	Örnek Sayısı	Özellik Sayısı	Etiket Sayısı
Emotions	593	72	6
Yeast	2417	103	14
CAL500	502	68	174
Medical	978	1449	45
Scene	2407	294	6
Genbase	662	1186	27
Birds	645	260	19
Water Quality	1060	16	14
PlantPseAAC	978	440	12
PlantGo	978	3091	12
Image	2000	294	5
HumanPseAAC	3106	440	14
HumanGo	3106	9844	14
GpositivePseAAC	519	440	4
GpositiveGo	519	912	4
GnegativePseAAC	1392	440	8
GnegativeGo	1392	1717	8

### 6.2.1 Emotions

Trochidis et al. (2008) çalışmalarında bu veri setini oluşturmuşlardır. Müziği, Tellegen-Watson-Clark ruh hali modeline göre uyandırdığı duygulara göre sınıflandırmayı amaçlayan küçük bir veri setidir. Toplamda 593 şarkı kullanılarak oluşturulmuştur.

### 6.2.2 Yeast

Elisseff and Weston (2001) çalışmalarında oluşturdukları bir veri setidir. Veri seti, 2417 maya geni için mikro-dizi ifadeleri ve filogenetik profiller içerir. Her gen, işlevsel kataloğun en üst seviyesinin 14 işlevsel kategorisinin (metabolizma, enerji, vb.) bir alt kümesiyle açıklanır.

### 6.2.3 CAL500

Turnbull et al. (2008) çalışmalarında bu veri setini oluşturmuştur. 502 şarkıdan oluşan bir müzik veri setidir. Her biri, anlamsal kavramlarla ilgili 174 etiketlik bir kelime dağarcığı kullanan en az üç insan yorumcu tarafından manuel olarak açıklandı. Bu etiketler enstrümantasyon, vokal karakteristikler, türler, duygular, şarkının akustik kalitesi ve kullanım terimleri olmak üzere 6 semantik kategoriye kapsar.

### 6.2.4 Medical

Pestian et al. (2007) çalışmaları kapsamında bu veri setini oluşturmuştur. Veri seti, 10. Hesaplama Tıp Merkezleri 2007 Tıbbi Doğal Dil İşleme Yarışması sırasında kullanıma sunulan verilere dayanmaktadır. 45 hastalık kodundan bir veya daha fazlasıyla etiketlenmiş 978 klinik serbest metin raporundan oluşur.

### 6.2.5 Scene

Boutell et al. (2004) çalışmalarında oluşturulmuştur. 2407 görüntü verisi içeren bir görüntü veri setidir. Veri seti plaj, gün batımı, sonbahar yaprakları, tarla, dağ ve kentsel olmak üzere 6 adet etiket içermektedir. Her görüntü, LUV alanındaki uzamsal renk anlarına karşılık gelen 294 görsel sayısal özellik ile tanımlanır.

### 6.2.6 Genbase

Diplaris et al. (2005) çalışmalarında bu veri setini oluşturmuşlardır. Bir protein fonksiyonu sınıflandırma veri setidir. Her bir örnek bir proteini ve her bir etiket bir protein sınıfını temsil etmektedir.

### 6.2.7 Birds

Briggs et al. (2013) çalışmalarında bu veri setini oluşturmuşlardır. Bu veri seti kuşlara ait 10 saniyelik ses kayıtlarının verisini içermektedir. Etiket olarak kuş türlerini içermektedir. Ses kayıtları verisi üzerinden kuş türünü tahmin etmek amaçlanmaktadır.

### 6.2.8 Water Quality

Blockeel et al. (2004) çalışmalarında bu veri setini oluşturmuşlardır. Bu veri seti, sıcaklık, pH, sertlik, NO<sub>2</sub> veya CO<sub>2</sub> gibi 16 özelliği kullanarak Sloven nehirlerindeki suyun kalitesini tahmin etmek için kullanılmaktadır.

### 6.2.9 PlantPseAAC

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. Bu veri seti, protein dizilerine göre proteinlerin hücre altı konumlarını tahmin etmek için kullanılır. Veri seti içerisinde toplamda 978 bitki protein dizisi içerir. Özellik uzayında 20 amino asit, 20 psödo-amino asit ve 400 dipeptit bileşeni bilgilerini içeren PseAAC özelliklerini barındırmaktadır. Etiket kümesinde hücre zarı, hücre duvarı, kloroplast, sitoplazma, endoplazmik retikulum, hücre dışı, golgi aygıtı, mitokondri, çekirdek, peroksizom, plastid ve vakuol olmak üzere 12 adet hücre altı lokasyon içermektedir.

### 6.2.10 PlantGO

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. PlantPseAAC veri setinden farkı özellik kümesidir. PseAAC özellikleri yerine GO (Gene Ontology) özelliklerini içermektedir. Aynı şekilde GO özellikleri üzerinden proteinlerin hücre altı konumlarını tahmin etmek için kullanılmaktadır.

### 6.2.11 Image

Zhang and Zhou (2007) çalışmalarında bu veri setini oluşturmuşlardır. Bu veri seti 2.000 görüntüden oluşmaktadır. Somut olarak, her renkli görüntü ilk olarak algılanan renk farklılıklarının bu renk uzayındaki Öklid mesafelerine yakından karşılık geldiği şekilde algısal olarak daha düzgün bir renk uzayı olan CIE Luv uzayına dönüştürülür. Bundan sonra, görüntü  $7 \times 7$  ızgara kullanılarak 49 bloğa bölünür, burada her blokta her bir bandın ortalama ve varyansı hesaplanır. Son olarak, her görüntü  $49 \times 3 \times 2 = 294$  boyutlu bir öznitelik vektörüne dönüştürülür.

### 6.2.12 HumanPseAAC

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. Bu veri seti, protein dizilerine göre proteinlerin hücre altı konumlarını tahmin etmek için kullanılır. Veri seti içerisinde toplamda 3106 insan protein dizisi içerir. Özellik uzayında 20 amino asit, 20 psödo-amino asit ve 400 dipeptit bileşeni bilgilerini içeren PseAAC özelliklerini barındırmaktadır. Etiket kümesinde sentriyol, sitoplazma, hücre iskeleti, endoplazmik retikulum, endozom, hücre dışı, golgi aygıtı, lizozom, mikrozom, mitokondri, çekirdek, peroksizom, plazma zarı ve sinaps olmak üzere 14 adet hücre altı lokasyon içermektedir.

### 6.2.13 HumanGO

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. HumanPseACC veri setinden farkı özellik kümesidir. PseAAC özellikleri yerine GO (Gene Ontology) özelliklerini içermektedir. Aynı şekilde GO özellikleri üzerinden proteinlerin hücre altı konumlarını tahmin etmek için kullanılmaktadır.

### 6.2.14 GpositivePseAAC

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. Bu veri seti, protein dizilerine göre proteinlerin hücre altı konumlarını tahmin etmek için kullanılır. Veri seti içerisinde toplamda 519 gram pozitif türlere ait protein dizisi içerir. Özellik uzayında 20 amino asit, 20 psödo-amino asit ve 400 dipeptit bileşeni bilgilerini içeren PseAAC özelliklerini barındırmaktadır. Etiket kümesinde hücre zarı, hücre duvarı, sitoplazma ve hücre dışı olmak üzere 4 adet hücre altı lokasyon içermektedir.

### 6.2.15 GpositiveGO

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. GpositivePseACC veri setinden farkı özellik kümesidir. PseAAC özellikleri yerine GO (Gene Ontology) özelliklerini içermektedir. Aynı şekilde GO özellikleri üzerinden proteinlerin hücre altı konumlarını tahmin etmek için kullanılmaktadır.

### 6.2.16 GnegativePseAAC

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. Bu veri seti, protein dizilerine göre proteinlerin hücre altı konumlarını tahmin etmek için kullanılır. Veri seti içerisinde toplamda 1392 gram negatif bakterilere ait protein dizisi içerir. Özellik uzayında 20 amino asit, 20 psödo-amino asit ve 400 dipeptit bileşeni bilgilerini içeren PseAAC özelliklerini barındırmaktadır. Etiket kümesinde hücre iç zarı, hücre dış zarı, sitoplazma, hücre dışı, fimbrium, flagellum, nükleoid ve periplazma olmak üzere 8 adet hücre altı lokasyon bulunmaktadır.

### 6.2.17 GnegativeGO

Xu et al. (2016) çalışmalarında bu veri setini oluşturmuştur. GnegativePseACC veri setinden farkı özellik kümesidir. PseAAC özellikleri yerine GO (Gene Ontology) özelliklerini içermektedir. Aynı şekilde GO özellikleri üzerinden proteinlerin hücre altı konumlarını tahmin etmek için kullanılmaktadır.

### 6.3 Başarı Değerlendirme Metrikleri

Bu bölümde bu çalışma kapsamında gerçekleştirilen deneylerde performans ölçümü amacıyla kullanılan başarı değerlendirme metrikleri açıklanacaktır. Çok etiketli sınıflandırma probleminde yöntemlerin veri seti üzerindeki performansını değerlendirmek için çeşitli metrikler bulunmaktadır. Bu metrikler her ne kadar tek etiketli sınıflandırma metriklerine benzeseler de çok etiketli sınıflandırmanın getirdiği farklılıklar bulunmaktadır. Bir metrik mikro ortalama, makro ortalama ve örnek tabanlı ortalama olmak üzere 3 farklı şekilde hesaplanabilmektedir. Örnek tabanlı ortalama ile hesaplanırken her bir örnek için metrik değeri bulunarak örnek sayısına bölünür. Makro ortalama ile hesaplanırken metrik her bir etiket için hesaplanarak etiket sayısına bölünür. Mikro ortalama ile hesaplanırken metrik her bir örnek ve etiket için hesaplanarak ortalaması alınır. Bu bölümde metrik hesaplama formüllerinde kullanılacak notasyonlar şu şekildedir :

$P_i$  :  $x_i$  örneği için tahmin edilen etiketler kümesi

$Y_i$  :  $x_i$  örneğinin gerçek etiketler kümesi

$m$  : veri setindeki örnek sayısı

$q$  : veri setindeki etiket sayısı

#### 6.3.1 Alt Küme Doğruluğu (Subset Accuracy)

Tahmin sonucu çıkan çok etiketli sınıflandırma etiket kümesi ile gerçek etiket kümesinin birebir aynı olmasını değerlendiren bir metriktir. Etiketleri ayrı olarak değerlendirmeyip tüm kümeyi karşılaştırmasından dolayı acımasız bir metrik olarak değerlendirilebilir.  $I(true) = 1$  ve  $I(false) = 0$  olarak tanımlanan bir fonksiyon olsun.

$$Acc = \frac{1}{m} \sum_{i=1}^m I(P_i = Y_i)$$

(6.1)

Alt Küme Doğruluğu (*subset accuracy*) metriği eşitlik 6.1 ile hesaplanmaktadır.

### 6.3.2 Hamming Kaybı (Hamming Loss)

Her bir örnek için tahmin etiket kümesi ile gerçek etiket kümelerinin birbirinden farklı olan elemanların sayısını etiket sayısına bölerek hesaplanan bir kayıp metriğidir. Bu metrik eşitlik 6.2 ile hesaplanmaktadır.

$$Loss = \frac{1}{m} \sum_{i=1}^m \frac{|P_i \Delta Y_i|}{q} \quad (6.2)$$

$\Delta$ : XOR işlemini temsil etmektedir.

### 6.3.3 Örnek Tabanlı Doğruluk (Example Based Accuracy)

Tahmin ve gerçek etiket kümelerinde aynı olan elemanların sayısının yani doğru tahmin sayısının iki kümedeki elemanların birleşiminin sayısına bölümünden elde edilen bir metriktir. Alt küme doğruluğu (*subset accuracy*) metriğine göre daha bağışlayıcı bir metriktir. Bu metrik eşitlik 6.3 ile hesaplanmaktadır.

$$Acc = \frac{1}{m} \sum_{i=1}^m \frac{|P_i \cap Y_i|}{|P_i \cup Y_i|} \quad (6.3)$$

### 6.3.4 Kesinlik (Precision)

Tahmin ve gerçek etiket kümelerinde aynı olan elemanların sayısının yani doğru tahmin sayısının tahmin kümesinin eleman sayısına bölünmesiyle elde edilen bir metriktir. Yapılan tahminlerin ne kadar yerinde olduğunu gösterir. Bu metrik eşitlik 6.4 ile hesaplanmaktadır.

$$P = \frac{1}{m} \sum_{i=1}^m \frac{|P_i \cap Y_i|}{|P_i|} \quad (6.4)$$

### 6.3.5 Duyarlılık (Recall)

Tahmin ve gerçek etiket kümelerinde aynı olan elemanların sayısının yani doğru tahmin sayısının gerçek etiket kümesinin eleman sayısına bölünmesiyle elde edilen bir metriktir. Gerçek etiketlerden ne kadarının doğru tahmin edildiğini gösterir. Bu metrik eşitlik 6.5 ile hesaplanmaktadır.

$$R = \frac{1}{m} \sum_{i=1}^m \frac{|P_i \cap Y_i|}{|Y_i|} \quad (6.5)$$

### 6.3.6 F-puanı (F-Measure)

Kesinlik (Precision) ve duyarlılık (*recall*) metriklerinin harmonik ortalamasından elde edilen bir metriktir. Bu metrik eşitlik 6.6 ile hesaplanmaktadır.

$$F = \frac{1}{m} \sum_{i=1}^m \frac{2|P_i \cap Y_i|}{|P_i| + |Y_i|}$$

(6.6)

## 6.4 Deney Parametreleri

Deneylerde kullanılan yöntemler problem dönüşüm metotları olduğundan ve problem dönüşüm yöntemleri birer temel öğreniciye ihtiyaç duyduğundan dolayı bir temel öğrenici parametresi seçilmesi gereklidir. Temel öğrenicinin çok etiketli sınıflandırma üzerindeki etkisini ölçmek amacıyla *yeast* veri seti üzerinde farklı çok etiketli sınıflandırma yöntemleri içerisinde farklı temel öğreniciler kullanılmış ve çeşitli metrikler ile değerlendirme yapılmıştır. Değerlendirmeler sonucunda en iyi performansın SMO öğrenicisi ile alındığı gözlemlenmiştir fakat bu öğrenici çalışma süresi açısından diğerlerine göre biraz daha yavaş kalmaktadır. Diğer tüm parametreler için Mulan kütüphanesi içerisinde varsayılan olarak seçilen parametreler kullanılmıştır. Sınıflandırıcı zinciri (*classifier chain*) yöntemi için etiket sırası varsayılan sıra olan etiketlerin veri setindeki sırası olarak seçilmiştir. RAKEL yöntemi için model sayısı varsayılan değer olan etiket sayısının iki katı ve etiket alt kümesi boyutu varsayılan değer olan 3 olarak seçilmiştir. BRS yönteminde güven katsayısı (*confidence coefficient*) değeri 0,3 olarak, BRA yöntemine *FPGrowth* algoritmasında minimum güven (*confidence*) değeri 0,5 olarak seçilmiştir.

## 6.5 Deney Sonuçları

Yöntemleri karşılaştırmak amacıyla gerçekleştirilen deneylerde elde edilen deney sonuçları tablolara çevrilmiştir. Deney sonuçları metrikler için 5 katlamalı çapraz doğrulama ortalaması ve standart sapma değerlerini içermektedir. Her bir metrik üzerinde her bir veri seti için yöntemlerin metrik değerine göre yöntemlere birer sıra numarası verilmiştir. Sıralama işlemi ortalama değerleri üzerinden yapılmıştır, standart sapma değeri göz ardı edilmiştir. Tablonun her bir hücresinde parantez içerisinde yazan değerler yöntemin bahsi geçen metrik ve veri seti için olan sıra numarasını vermektedir. En son satır ise her bir yöntemin bahsi geçen metrik için olan sıralamalarının ortalamasının değerini içermektedir. En iyi sonuçlar koyulaştırma ile belirginleştirilmiştir. Her bir tablodaki değerler yöntemlerin aralarındaki farkın daha iyi anlaşılabilmesi amacıyla her bir veri seti için 0-1 aralığında min-max normalizasyon yöntemiyle normalize edilerek her bir tablodan bir grafik oluşturulmuştur. Tablo 6-2 içeriğinde örnek tabanlı ortalama kesinlik metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-1 bu tablonun

değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-3 içeriğinde makro ortalamalı kesinlik metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-2 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-4 içeriğinde mikro ortalamalı kesinlik metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-3 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-5 içeriğinde örnek tabanlı ortalamalı duyarlılık metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-4 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-6 içeriğinde makro ortalamalı duyarlılık metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-5 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-7 içeriğinde mikro ortalamalı duyarlılık metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-6 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-8 içeriğinde örnek tabanlı ortalamalı F-Puanı metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-7 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-9 içeriğinde makro ortalamalı F-Puanı metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-8 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-10 içeriğinde mikro ortalamalı F-Puanı metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-9 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-11 içeriğinde örnek tabanlı doğruluk metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-10 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-12 içeriğinde alt küme doğruluğu metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-11 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-13 içeriğinde hamming kaybı metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-12 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir. Tablo 6-14 içeriğinde çalışma süresi metriğine ait deneysel sonuçlar bulunmakta ve Şekil 6-13 bu tablonun değerlerinin normalize edilmiş hali kullanılarak oluşturulmuş yüzey grafiğini içermektedir.

Tablo 6-2 Örnek tabanlı ortalamalı kesinlik (*precision*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,6560±0,048 3 (8)	0,6455±0,034 0 (10)	0,6739±0,030 5 (4)	<b>0,6992±0,028</b> <b>0 (1)</b>	0,6871±0,0535 (2)	0,6356±0,0303 (11)
yeast	0,7151±0,023 2 (1)	0,6732±0,027 6 (10)	0,6786±0,036 1 (8)	0,6939±0,026 7 (6)	0,7147±0,0232 (3)	0,6730±0,0226 (11)
CAL500	<b>0,6217±0,015</b> <b>2 (1)</b>	0,5392±0,021 7 (7)	0,3209±0,046 0 (12)	0,6139±0,016 9 (3)	0,5975±0,0126 (4)	0,5175±0,0332 (9)
medical	0,8128±0,011 5 (6)	0,8196±0,019 7 (4)	0,8101±0,033 1 (7)	0,7899±0,017 2 (12)	0,8023±0,0164 (9)	<b>0,8424±0,0520</b> <b>(1)</b>
scene	0,6196±0,020 4 (10)	0,7223±0,011 3 (6)	0,7667±0,016 3 (1)	0,7034±0,014 2 (7)	0,6696±0,0140 (8)	0,6255±0,0172 (9)
genbase	0,9947±0,005 6 (5)	0,9945±0,005 6 (11)	0,9965±0,002 4 (2)	0,9947±0,005 2 (5)	0,9947±0,0056 (5)	0,9947±0,0056 (5)
birds	0,6929±0,033 7 (8)	0,7020±0,044 8 (5)	0,6851±0,033 0 (10)	0,6262±0,105 7 (12)	0,6818±0,0446 (11)	<b>0,7621±0,1241</b> <b>(1)</b>
Water-quality	<b>0,6367±0,024</b> <b>8 (1)</b>	0,5871±0,077 3 (6)	0,4249±0,037 7 (11)	0,4903±0,016 8 (10)	0,6343±0,0226 (3)	0,5837±0,0509 (7)
PlantPseAAC	0,2130±0,009 7 (11)	0,2832±0,012 6 (6)	0,3267±0,015 6 (2)	0,2219±0,021 5 (8)	0,2155±0,0306 (10)	0,2417±0,0107 (7)
PlantGO	0,7571±0,020 8 (12)	0,7696±0,023 8 (8)	<b>0,8076±0,027</b> <b>2 (1)</b>	0,7751±0,016 4 (6)	0,7613±0,0167 (9)	0,7816±0,0184 (5)
Image	0,5400±0,028 3 (10)	0,6605±0,018 1 (7)	0,6828±0,013 0 (3)	<b>0,6889±0,016</b> <b>7 (1)</b>	0,5409±0,0254 (9)	0,5817±0,0200 (8)
HumanPseAAC	0,2111±0,016 7 (10)	0,3923±0,012 8 (6)	0,4131±0,013 4 (4)	0,2510±0,015 2 (8)	0,2275±0,0198 (9)	0,2635±0,0083 (7)
HumanGO	0,7613±0,023 9 (6)	0,7694±0,022 8 (2)	<b>0,7879±0,016</b> <b>8 (1)</b>	0,7564±0,013 2 (7)	0,7361±0,0099 (12)	0,7639±0,0094 (4)
GpositivePseAAC	0,5681±0,050 8 (9)	0,6426±0,037 4 (3)	0,6376±0,037 9 (4)	0,6251±0,028 9 (6)	0,5904±0,0438 (8)	0,5466±0,0441 (12)
GpositiveGO	0,9291±0,010 6 (9)	0,9357±0,042 2 (7)	0,9415±0,022 3 (1)	0,9400±0,022 2 (3)	0,9362±0,0149 (6)	0,9277±0,0145 (12)
GnegativePseAAC	0,5861±0,014 4 (11)	0,6338±0,018 7 (6)	<b>0,6835±0,022</b> <b>4 (1)</b>	0,6293±0,015 9 (7)	0,5912±0,0113 (10)	0,5970±0,0159 (9)
GnegativeGO	0,9545±0,011 1 (10)	0,9570±0,008 4 (7)	0,9666±0,008 3 (2)	0,9570±0,008 8 (7)	<b>0,9695±0,0183</b> <b>(1)</b>	0,9540±0,0096 (11)
Avg. Rank	7,53	6,53	4,35	6,41	7,00	7,59
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6739±0,030 5 (4)	0,6560±0,048 3 (8)	0,6238±0,030 4 (12)	0,6643±0,034 6 (7)	0,6833±0,0329 (3)	0,6690±0,0300 (6)
yeast	0,6631±0,025 6 (12)	0,7064±0,021 8 (4)	<b>0,7151±0,023</b> <b>2 (1)</b>	0,6742±0,019 8 (9)	0,6980±0,0170 (5)	0,6862±0,0239 (7)
CAL500	0,3585±0,010 4 (11)	0,5927±0,021 2 (5)	0,6186±0,015 4 (2)	0,3718±0,012 0 (10)	0,5845±0,0188 (6)	0,5386±0,0367 (8)
medical	0,8175±0,016 7 (5)	0,8023±0,024 0 (9)	0,8066±0,018 1 (8)	0,8009±0,015 2 (11)	0,8217±0,0123 (2)	0,8207±0,0124 (3)
scene	<b>0,7667±0,016</b> <b>3 (1)</b>	0,6196±0,020 4 (10)	0,6196±0,020 4 (10)	0,7360±0,018 0 (5)	0,7559±0,0121 (3)	0,7444±0,0123 (4)
genbase	<b>0,9967±0,004</b> <b>0 (1)</b>	0,9857±0,009 2 (12)	0,9951±0,005 5 (4)	0,9956±0,001 5 (3)	0,9947±0,0056 (5)	0,9947±0,0056 (5)
birds	0,7112±0,028 3 (3)	0,6941±0,038 3 (7)	0,6895±0,042 2 (9)	0,6955±0,038 2 (6)	0,7033±0,0355 (4)	0,7216±0,0295 (2)
Water-quality	0,4038±0,014 8 (12)	0,6359±0,024 3 (2)	0,5493±0,013 1 (8)	0,5161±0,023 9 (9)	0,6066±0,0301 (5)	0,6186±0,0313 (4)
PlantPseAAC	<b>0,3270±0,015</b> <b>4 (1)</b>	0,2118±0,011 4 (12)	0,2194±0,011 8 (9)	0,3048±0,034 6 (5)	0,3243±0,0033 (3)	0,3153±0,0106 (4)
PlantGO	0,7749±0,014 9 (7)	0,7584±0,020 1 (10)	0,7584±0,018 9 (10)	0,7880±0,014 4 (4)	0,7888±0,0210 (3)	0,7890±0,0168 (2)
Image	0,6828±0,013 0 (3)	0,5400±0,028 3 (10)	0,5400±0,028 3 (10)	0,6715±0,008 2 (6)	0,6861±0,0103 (3)	0,6748±0,0115 (5)
HumanPseAAC	0,4173±0,008 3 (2)	0,2111±0,016 7 (10)	0,2111±0,016 7 (10)	0,4156±0,003 3 (3)	<b>0,4190±0,0054</b> <b>(1)</b>	0,4085±0,0080 (5)
HumanGO	0,7622±0,010 5 (5)	0,7447±0,012 3 (11)	0,7460±0,013 4 (10)	0,7554±0,010 0 (9)	0,7557±0,0073 (8)	0,7656±0,0121 (3)
GpositivePseAAC	0,6361±0,041 0 (5)	0,5681±0,050 8 (9)	0,5681±0,050 8 (9)	0,6197±0,036 0 (7)	<b>0,6822±0,0815</b> <b>(1)</b>	0,6496±0,0250 (2)
GpositiveGO	0,9280±0,020 9 (11)	0,9290±0,016 6 (10)	0,9309±0,018 4 (8)	0,9395±0,018 2 (4)	<b>0,9415±0,0212</b> <b>(1)</b>	0,9383±0,0256 (5)
GnegativePseAAC	0,6711±0,030 3 (3)	0,5981±0,016 3 (8)	0,5861±0,014 4 (11)	0,6605±0,014 8 (5)	0,6720±0,0153 (2)	0,6608±0,0111 (4)
GnegativeGO	0,9657±0,009 3 (3)	0,9566±0,008 9 (9)	0,9534±0,010 9 (12)	0,9617±0,008 0 (5)	0,9641±0,0100 (4)	0,9608±0,0093 (6)
Avg. Rank	5,24	8,59	8,41	6,35	<b>3,41</b>	4,41

Tablo 6-3 Makro ortalamalı kesinlik (*precision*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,6855±0,031 6 (3)	0,6177±0,052 0 (11)	0,6676±0,028 4 (6)	0,7074±0,032 2 (2)	<b>0,7077±0,0430</b> (1)	0,6099±0,0180 (12)
yeast	0,3499±0,012 2 (11)	0,4800±0,052 5 (5)	0,5352±0,031 6 (2)	0,4627±0,045 0 (6)	0,4066±0,0890 (8)	0,3536±0,0126 (10)
CAL500	0,1182±0,015 1 (10)	0,1823±0,019 4 (2)	0,1589±0,006 9 (8)	0,1278±0,015 2 (9)	0,1618±0,0255 (6)	<b>0,2392±0,1512</b> (1)
medical	0,6293±0,056 5 (12)	0,7331±0,035 3 (2)	0,6800±0,135 4 (7)	<b>0,7694±0,107</b> <b>9 (1)</b>	0,7016±0,0230 (4)	0,7277±0,1530 (3)
scene	0,7448±0,014 0 (5)	0,7307±0,011 7 (9)	0,7696±0,016 8 (2)	<b>0,7706±0,011</b> <b>6 (1)</b>	0,7539±0,0153 (4)	0,4572±0,0185 (12)
genbase	0,9351±0,020 6 (4)	0,9242±0,034 6 (10)	0,9354±0,023 1 (2)	0,9252±0,029 7 (9)	0,9351±0,0206 (4)	0,9351±0,0206 (4)
birds	0,5255±0,058 6 (4)	0,5342±0,071 8 (3)	0,5145±0,080 7 (6)	0,5060±0,107 2 (7)	0,4855±0,0673 (10)	<b>0,6163±0,1798</b> (1)
Water-quality	0,2846±0,012 4 (10)	0,3835±0,031 6 (4)	0,3318±0,049 0 (7)	0,3244±0,021 7 (8)	0,3372±0,0325 (6)	<b>0,4291±0,0449</b> (1)
PlantPseAAC	0,2062±0,037 3 (8)	0,2116±0,043 5 (5)	0,2241±0,031 8 (2)	<b>0,2302±0,054</b> <b>6 (1)</b>	0,2228±0,0393 (3)	0,1481±0,0308 (12)
PlantGO	0,7298±0,026 0 (7)	0,7262±0,038 5 (9)	0,7473±0,052 6 (3)	0,7434±0,026 0 (4)	0,7219±0,0356 (10)	0,7516±0,0274 (2)
Image	0,7118±0,023 8 (2)	0,6744±0,015 4 (8)	0,6819±0,013 6 (6)	0,6915±0,010 3 (5)	<b>0,7126±0,0235</b> (1)	0,4274±0,0140 (12)
HumanPseAAC	0,1940±0,019 0 (7)	0,1774±0,026 0 (11)	0,2075±0,020 0 (2)	0,1998±0,011 1 (5)	0,1912±0,0250 (10)	0,1040±0,0145 (12)
HumanGO	0,6992±0,032 4 (3)	<b>0,7207±0,057</b> <b>4 (1)</b>	0,7148±0,041 7 (2)	0,6703±0,090 5 (9)	0,6588±0,0330 (12)	0,6861±0,0268 (7)
GpositivePseAAC	0,5430±0,124 8 (8)	0,5659±0,095 0 (4)	0,5722±0,098 1 (2)	0,5619±0,093 2 (6)	0,5693±0,0833 (3)	0,4542±0,0481 (12)
GpositiveGO	0,8979±0,063 6 (9)	0,9236±0,057 8 (2)	0,8931±0,054 7 (10)	0,9080±0,026 2 (6)	0,8809±0,0898 (12)	0,8829±0,0164 (11)
GnegativePseAAC	0,4519±0,061 5 (7)	0,4473±0,054 0 (9)	0,4775±0,035 7 (2)	<b>0,4822±0,075</b> <b>4 (1)</b>	0,4129±0,0161 (11)	0,3559±0,0643 (12)
GnegativeGO	0,9390±0,019 5 (10)	0,9556±0,025 3 (5)	<b>0,9716±0,012</b> <b>1 (1)</b>	0,9391±0,021 2 (9)	0,9601±0,0306 (3)	0,9566±0,0139 (4)
Avg. Rank	7,06	5,88	<b>4,12</b>	5,24	6,35	7,53
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6676±0,028 4 (6)	0,6855±0,031 6 (3)	0,6327±0,025 9 (10)	0,6547±0,030 0 (8)	0,6747±0,0259 (5)	0,6503±0,0236 (9)
yeast	0,5304±0,032 1 (3)	0,3603±0,034 0 (9)	0,3499±0,012 2 (11)	<b>0,5408±0,024</b> <b>0 (1)</b>	0,4603±0,0208 (7)	0,4811±0,0219 (4)
CAL500	0,1730±0,005 0 (3)	0,1172±0,015 2 (12)	0,1180±0,014 9 (11)	0,1608±0,006 2 (7)	0,1620±0,0124 (5)	0,1671±0,0197 (4)
medical	0,6370±0,063 1 (11)	0,6833±0,022 6 (5)	0,6656±0,021 7 (10)	0,6759±0,043 3 (8)	0,6662±0,0253 (9)	0,6811±0,0621 (6)
scene	0,7696±0,016 8 (2)	0,7448±0,014 0 (5)	0,7448±0,014 0 (5)	0,7047±0,019 2 (11)	0,7424±0,0126 (8)	0,7223±0,0138 (10)
genbase	<b>0,9405±0,017</b> <b>8 (1)</b>	0,9168±0,021 7 (12)	0,9352±0,020 5 (3)	0,9191±0,034 5 (11)	0,9351±0,0206 (4)	0,9351±0,0206 (4)
birds	0,4967±0,086 1 (8)	0,4875±0,063 2 (9)	0,4811±0,069 0 (11)	0,4540±0,032 1 (12)	0,5229±0,0713 (5)	0,5815±0,0944 (2)
Water-quality	0,3216±0,096 6 (9)	0,2843±0,012 3 (11)	0,2558±0,010 5 (12)	0,3596±0,039 7 (5)	0,4257±0,0462 (2)	0,3987±0,0310 (3)
PlantPseAAC	0,2201±0,031 3 (4)	0,2042±0,038 1 (9)	0,2101±0,032 2 (6)	0,1923±0,026 7 (11)	0,2095±0,0463 (7)	0,1983±0,0452 (10)
PlantGO	0,7383±0,016 3 (5)	<b>0,7532±0,018</b> <b>9 (1)</b>	0,7278±0,042 2 (8)	0,7218±0,037 6 (11)	0,7130±0,0245 (12)	0,7310±0,0411 (6)
Image	0,6819±0,013 6 (6)	0,7118±0,023 8 (2)	0,7118±0,023 8 (2)	0,6483±0,012 9 (10)	0,6656±0,0158 (9)	0,6459±0,0131 (11)
HumanPseAAC	<b>0,2117±0,014</b> <b>8 (1)</b>	0,1940±0,019 0 (7)	0,1940±0,019 0 (7)	0,2044±0,016 0 (4)	0,2071±0,0234 (3)	0,1954±0,0288 (6)
HumanGO	0,6873±0,031 0 (6)	0,6718±0,050 8 (8)	0,6975±0,030 4 (4)	0,6672±0,023 0 (10)	0,6643±0,0161 (11)	0,6923±0,0282 (5)
GpositivePseAAC	0,5639±0,102 0 (5)	0,5430±0,124 8 (8)	0,5430±0,124 8 (8)	0,5295±0,108 8 (11)	<b>0,5933±0,0987</b> <b>(1)</b>	0,5520±0,0998 (7)
GpositiveGO	0,9014±0,097 0 (8)	0,9144±0,054 7 (4)	<b>0,9293±0,056</b> <b>9 (1)</b>	0,9062±0,052 8 (7)	0,9219±0,0508 (3)	0,9131±0,0647 (5)
GnegativePseAAC	0,4730±0,032 6 (3)	0,4533±0,068 4 (6)	0,4519±0,061 5 (7)	0,4645±0,061 2 (4)	0,4634±0,0489 (5)	0,4469±0,0537 (10)
GnegativeGO	0,9617±0,013 9 (2)	0,9413±0,022 5 (7)	0,9392±0,019 8 (8)	0,9361±0,021 0 (12)	0,9373±0,0216 (11)	0,9513±0,0259 (6)
Avg. Rank	4,88	6,94	7,29	8,41	6,29	6,35

Tablo 6-4 Mikro ortalamalı kesinlik (*precision*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	<b>0,7326±0,045</b> 9 (1)	0,6560±0,033 4 (10)	0,6712±0,026 0 (7)	0,7106±0,023 8 (4)	0,7132±0,0420 (3)	0,6079±0,0188 (12)
yeast	<b>0,7149±0,021</b> 8 (1)	0,6751±0,030 4 (9)	0,6825±0,033 7 (8)	0,6914±0,024 9 (6)	0,7140±0,0217 (3)	0,6655±0,0224 (12)
CAL500	<b>0,6176±0,016</b> 1 (1)	0,5103±0,016 8 (8)	0,3355±0,011 5 (12)	0,6095±0,017 2 (3)	0,5884±0,0132 (4)	0,4978±0,0362 (9)
medical	0,8457±0,017 0 (2)	0,8403±0,019 7 (4)	0,8354±0,041 6 (6)	0,8285±0,014 3 (8)	0,8378±0,0255 (5)	<b>0,8720±0,0657</b> (1)
scene	0,7416±0,014 3 (5)	0,7172±0,010 3 (9)	<b>0,7622±0,016</b> 6 (1)	0,7612±0,009 1 (3)	0,7492±0,0139 (4)	0,4538±0,0188 (12)
genbase	0,9951±0,006 0 (2)	0,9938±0,008 0 (8)	0,9897±0,009 1 (11)	0,9943±0,005 5 (7)	0,9951±0,0060 (2)	0,9951±0,0060 (2)
birds	<b>0,6182±0,018</b> 1 (1)	0,6161±0,027 4 (5)	0,5878±0,039 7 (7)	0,5862±0,107 7 (8)	0,5793±0,0342 (10)	0,4693±0,2359 (12)
Water-quality	0,6498±0,019 9 (4)	0,6409±0,027 1 (8)	0,4314±0,046 0 (11)	<b>0,6873±0,021</b> 7 (1)	0,6484±0,0156 (5)	0,6520±0,0158 (3)
PlantPseAAC	0,3259±0,023 4 (3)	0,2865±0,011 3 (11)	0,3244±0,015 0 (5)	0,3345±0,036 2 (2)	<b>0,3439±0,0324</b> (1)	0,1921±0,0045 (12)
PlantGO	0,7736±0,017 8 (11)	0,7743±0,013 0 (10)	<b>0,8036±0,025</b> 2 (1)	0,7894±0,007 2 (3)	0,7763±0,0163 (8)	0,7832±0,0216 (5)
Image	0,7115±0,023 8 (2)	0,6549±0,017 3 (9)	0,6734±0,015 8 (6)	0,6826±0,011 3 (5)	<b>0,7122±0,0232</b> (1)	0,4282±0,0148 (12)
HumanPseAAC	<b>0,4525±0,012</b> 5 (1)	0,3891±0,013 6 (10)	0,4098±0,012 8 (7)	0,4472±0,019 8 (4)	0,4452±0,0311 (5)	0,1454±0,0018 (12)
HumanGO	0,7560±0,022 8 (2)	0,7426±0,018 5 (4)	<b>0,7728±0,017</b> 1 (1)	0,7390±0,018 5 (6)	0,7399±0,0148 (5)	0,7388±0,0171 (7)
GpositivePseAA C	0,6145±0,041 6 (8)	0,6398±0,034 1 (3)	0,6376±0,037 9 (4)	0,6334±0,025 3 (5)	0,6603±0,0364 (2)	0,5487±0,0445 (12)
GpositiveGO	0,9408±0,016 7 (7)	0,9339±0,042 2 (10)	<b>0,9477±0,031</b> 2 (1)	0,9430±0,020 5 (4)	0,9427±0,0125 (5)	0,9288±0,0262 (12)
GnegativePseAA C	0,6662±0,028 6 (4)	0,6124±0,039 7 (11)	<b>0,6795±0,023</b> 0 (1)	0,6554±0,047 8 (7)	0,6704±0,0129 (3)	0,4891±0,0351 (12)
GnegativeGO	0,9540±0,009 9 (6)	0,9494±0,009 4 (9)	0,9630±0,008 4 (2)	0,9553±0,009 8 (4)	<b>0,9683±0,0168</b> (1)	0,9446±0,0089 (12)
Avg. Rank	<b>3,59</b>	8,12	5,35	4,71	3,94	9,35
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6712±0,026 0 (7)	0,7326±0,045 9 (1)	0,6750±0,022 7 (6)	0,6588±0,028 2 (9)	0,6769±0,0240 (5)	0,6559±0,0229 (11)
yeast	0,6668±0,023 9 (11)	0,7043±0,020 4 (4)	0,7149±0,021 8 (1)	0,6695±0,018 4 (10)	0,6933±0,0169 (5)	0,6838±0,0241 (7)
CAL500	0,3573±0,008 6 (11)	0,5865±0,019 6 (5)	0,6141±0,016 0 (2)	0,3670±0,011 2 (10)	0,5783±0,0190 (6)	0,5203±0,0477 (7)
medical	0,8148±0,027 6 (11)	0,8251±0,015 3 (9)	0,8419±0,023 2 (3)	0,7865±0,021 0 (12)	0,8307±0,0233 (7)	0,8223±0,0195 (10)
scene	0,7622±0,016 6 (1)	0,7416±0,014 3 (5)	0,7416±0,014 3 (5)	0,6918±0,020 0 (11)	0,7291±0,0134 (8)	0,7055±0,0137 (10)
genbase	0,9936±0,012 8 (9)	0,9554±0,039 9 (12)	<b>0,9959±0,005</b> 1 (1)	0,9901±0,003 1 (10)	0,9951±0,0060 (2)	0,9951±0,0060 (2)
birds	0,5842±0,038 8 (9)	0,6167±0,013 2 (3)	0,6049±0,024 2 (6)	0,5426±0,027 1 (11)	0,6177±0,0243 (2)	0,6164±0,0276 (4)
Water-quality	0,4023±0,023 4 (12)	0,6483±0,019 1 (6)	0,5558±0,011 0 (9)	0,5206±0,018 5 (10)	0,6663±0,0332 (2)	0,6423±0,0257 (7)
PlantPseAAC	0,3226±0,015 9 (7)	0,3234±0,025 5 (6)	0,3247±0,024 2 (4)	0,3003±0,007 7 (9)	0,3186±0,0034 (8)	0,2911±0,0121 (10)
PlantGO	0,7898±0,024 6 (2)	0,7781±0,021 7 (6)	0,7724±0,020 5 (12)	0,7746±0,006 0 (9)	0,7764±0,0045 (7)	0,7842±0,0327 (4)
Image	0,6734±0,015 8 (6)	0,7115±0,023 8 (2)	0,7115±0,023 8 (2)	0,6389±0,014 6 (10)	0,6557±0,0167 (8)	0,6323±0,0161 (11)
HumanPseAAC	0,4152±0,008 1 (6)	0,4525±0,012 5 (1)	0,4525±0,012 5 (1)	0,3982±0,006 2 (9)	0,4095±0,0077 (8)	0,3766±0,0092 (11)
HumanGO	0,7462±0,018 2 (3)	0,7312±0,010 2 (11)	0,7363±0,017 3 (8)	0,7198±0,009 6 (12)	0,7335±0,0130 (10)	0,7339±0,0111 (9)
GpositivePseAA C	0,6331±0,046 8 (6)	0,6145±0,041 6 (8)	0,6145±0,041 6 (8)	0,5853±0,032 9 (11)	<b>0,6682±0,0869</b> (1)	0,6236±0,0177 (7)
GpositiveGO	0,9409±0,010 6 (6)	0,9459±0,009 2 (3)	0,9467±0,013 2 (2)	0,9307±0,020 8 (11)	0,9360±0,0228 (9)	0,9373±0,0247 (8)
GnegativePseAA C	0,6740±0,023 4 (2)	0,6598±0,023 8 (6)	0,6662±0,028 6 (4)	0,6188±0,016 2 (9)	0,6464±0,0165 (8)	0,6179±0,0100 (10)
GnegativeGO	0,9614±0,008 7 (3)	0,9546±0,007 4 (5)	0,9513±0,009 2 (8)	0,9469±0,010 8 (11)	0,9531±0,0122 (7)	0,9486±0,0102 (10)
Avg. Rank	6,59	5,47	4,82	10,24	6,06	8,12

Tablo 6-5 Örnek tabanlı ortalamalı duyarlılık (*recall*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,5929±0,026 4 (11)	0,6321±0,023 8 (10)	0,6993±0,032 5 (5)	0,6706±0,020 2 (7)	0,6391±0,0234 (9)	<b>0,7817±0,0366</b> (1)
yeast	0,5789±0,014 1 (10)	0,5719±0,018 5 (12)	0,6146±0,018 4 (6)	0,6293±0,020 1 (4)	0,5812±0,0136 (9)	0,5987±0,0156 (7)
CAL500	0,2347±0,007 0 (10)	0,2259±0,013 7 (11)	0,3073±0,067 3 (3)	0,2431±0,006 4 (8)	0,2461±0,0073 (7)	0,2018±0,0503 (12)
medical	0,8038±0,009 3 (9)	0,7990±0,022 2 (10)	0,7888±0,021 1 (12)	0,7932±0,034 6 (11)	0,8067±0,0124 (8)	0,8208±0,0241 (4)
scene	0,6547±0,023 3 (10)	0,7052±0,008 1 (8)	0,7542±0,013 6 (5)	0,7207±0,010 3 (7)	0,6890±0,0144 (9)	0,7727±0,0138 (4)
genbase	0,9897±0,007 8 (4)	0,9893±0,007 7 (10)	0,9922±0,002 7 (2)	0,9830±0,018 4 (12)	0,9897±0,0078 (4)	0,9897±0,0078 (4)
birds	0,6483±0,041 7 (10)	0,6625±0,052 6 (6)	0,6613±0,046 8 (7)	0,5801±0,130 1 (12)	0,6519±0,0528 (8)	<b>0,7456±0,1321</b> (1)
Water-quality	0,3185±0,022 2 (4)	0,2729±0,038 8 (9)	0,2352±0,080 9 (10)	0,1723±0,013 1 (12)	0,3241±0,0234 (3)	0,2773±0,0351 (8)
PlantPseAAC	0,2556±0,013 4 (9)	0,2897±0,012 5 (7)	0,3170±0,011 4 (6)	0,2495±0,022 3 (12)	0,2525±0,0347 (11)	<b>0,4995±0,0598</b> (1)
PlantGO	0,7488±0,097 8 (12)	0,7773±0,017 3 (11)	0,7914±0,024 4 (7)	0,7931±0,022 1 (5)	0,8025±0,0211 (4)	0,7923±0,0117 (6)
Image	0,5123±0,019 4 (9)	0,6053±0,019 4 (8)	0,6386±0,013 3 (6)	0,6606±0,016 5 (5)	0,5121±0,0157 (12)	<b>0,7408±0,0068</b> (1)
HumanPseAAC	0,2120±0,015 6 (10)	0,3568±0,015 7 (7)	0,3823±0,015 8 (6)	0,2533±0,013 8 (8)	0,2307±0,0201 (9)	<b>0,6997±0,0272</b> (1)
HumanGO	0,7642±0,015 5 (12)	0,7918±0,047 2 (8)	0,7726±0,015 1 (11)	0,7935±0,029 9 (6)	0,7856±0,0095 (9)	0,7924±0,0212 (7)
GpositivePseAA C	0,6310±0,057 4 (8)	0,6484±0,042 7 (4)	0,6347±0,036 1 (7)	0,6232±0,025 3 (12)	0,6376±0,0522 (6)	0,6272±0,0302 (11)
GpositiveGO	0,9393±0,013 8 (5)	0,9340±0,041 4 (10)	0,9370±0,022 5 (7)	0,9356±0,019 3 (9)	0,9438±0,0159 (3)	0,9338±0,0150 (11)
GnegativePseAA C	0,6196±0,008 1 (11)	0,6434±0,013 8 (8)	0,6731±0,026 7 (5)	0,6535±0,015 3 (7)	0,6307±0,0190 (10)	0,6969±0,0314 (4)
GnegativeGO	0,9594±0,009 8 (10)	0,9605±0,005 5 (6)	0,9576±0,006 5 (12)	0,9605±0,007 6 (6)	0,9705±0,0155 (2)	0,9577±0,0106 (11)
Avg. Rank	9,06	8,53	6,88	8,41	7,24	5,53
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6993±0,032 5 (5)	0,5929±0,026 4 (11)	0,6425±0,028 9 (8)	0,7372±0,023 6 (3)	0,7338±0,0248 (4)	0,7397±0,0288 (2)
yeast	0,6173±0,022 1 (5)	0,5914±0,017 2 (8)	0,5789±0,014 1 (10)	<b>0,6680±0,027</b> 5 (1)	0,6431±0,0143 (2)	0,6306±0,0185 (3)
CAL500	0,3383±0,002 7 (2)	0,2761±0,006 9 (5)	0,2419±0,007 5 (9)	<b>0,4223±0,007</b> 5 (1)	0,2620±0,0056 (6)	0,2763±0,0323 (4)
medical	0,8104±0,013 7 (6)	0,8185±0,021 3 (5)	0,8101±0,009 2 (7)	0,8280±0,013 2 (2)	0,8262±0,0093 (3)	<b>0,8294±0,0173</b> (1)
scene	0,7542±0,013 6 (5)	0,6547±0,023 3 (10)	0,6547±0,023 3 (10)	<b>0,8018±0,011</b> 0 (1)	0,7802±0,0068 (3)	0,7885±0,0091 (2)
genbase	0,9856±0,012 1 (11)	0,9912±0,008 9 (3)	0,9897±0,007 8 (4)	<b>0,9941±0,003</b> 0 (1)	0,9897±0,0078 (4)	0,9897±0,0078 (4)
birds	0,6965±0,034 7 (3)	0,6494±0,048 9 (9)	0,6476±0,049 3 (11)	0,6980±0,050 6 (2)	0,6715±0,0539 (5)	0,6949±0,0365 (4)
Water-quality	0,1774±0,017 3 (11)	0,3185±0,022 2 (4)	0,4164±0,019 6 (2)	<b>0,4387±0,052</b> 2 (1)	0,2826±0,0333 (7)	0,3116±0,0371 (6)
PlantPseAAC	0,3286±0,029 5 (5)	0,2541±0,011 7 (10)	0,2612±0,010 6 (8)	0,3730±0,057 5 (3)	0,3538±0,0085 (4)	0,3822±0,0190 (2)
PlantGO	0,7899±0,021 3 (8)	0,7876±0,016 8 (10)	0,7893±0,017 1 (9)	0,8161±0,016 8 (2)	<b>0,8164±0,0241</b> (1)	0,8059±0,0464 (3)
Image	0,6386±0,013 3 (6)	0,5123±0,019 4 (9)	0,5123±0,019 4 (9)	0,6843±0,014 5 (4)	0,6848±0,0177 (3)	0,6892±0,0144 (2)
HumanPseAAC	0,3881±0,010 3 (5)	0,2120±0,015 6 (10)	0,2120±0,015 6 (10)	0,4306±0,005 3 (3)	0,4101±0,0066 (4)	0,4601±0,0155 (2)
HumanGO	0,7844±0,014 5 (10)	0,7946±0,023 5 (5)	0,7972±0,010 7 (4)	<b>0,8198±0,014</b> 2 (1)	0,8039±0,0057 (3)	0,8080±0,0126 (2)
GpositivePseAA C	0,6411±0,023 6 (5)	0,6310±0,057 4 (8)	0,6310±0,057 4 (8)	<b>0,7080±0,049</b> 4 (1)	0,7015±0,0716 (3)	0,7023±0,0319 (2)
GpositiveGO	0,9316±0,020 4 (12)	0,9363±0,018 8 (8)	0,9388±0,019 1 (6)	<b>0,9525±0,017</b> 6 (1)	0,9466±0,0223 (2)	0,9418±0,0257 (4)
GnegativePseAA C	0,6669±0,026 5 (6)	0,6315±0,019 1 (9)	0,6196±0,008 1 (11)	<b>0,7318±0,035</b> 7 (1)	0,7000±0,0177 (3)	0,7076±0,0221 (2)
GnegativeGO	0,9619±0,007 5 (5)	0,9603±0,009 1 (8)	0,9602±0,009 7 (9)	<b>0,9710±0,008</b> 3 (1)	0,9686±0,0080 (3)	0,9675±0,0087 (4)
Avg. Rank	6,47	7,76	7,94	<b>1,71</b>	3,53	2,88

Tablo 6-6 Makro ortalamalı duyarlılık (*recall*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,5720±0,013 9 (11)	0,6225±0,017 2 (9)	0,6929±0,022 5 (5)	0,6552±0,009 3 (7)	0,6155±0,0085 (10)	<b>0,7708±0,0231</b> (1)
yeast	0,3219±0,003 5 (11)	0,3444±0,008 9 (7)	0,3830±0,018 9 (3)	0,3694±0,004 8 (6)	0,3237±0,0040 (10)	0,3390±0,0036 (8)
CAL500	0,1075±0,011 5 (12)	0,1159±0,009 9 (8)	0,1481±0,034 8 (4)	0,1108±0,011 5 (10)	0,1149±0,0131 (9)	<b>0,1970±0,1633</b> (1)
medical	0,5960±0,071 6 (12)	0,7138±0,049 4 (2)	0,6593±0,147 2 (8)	<b>0,7535±0,128</b> <b>4 (1)</b>	0,6851±0,0347 (5)	0,7038±0,1662 (3)
scene	0,6546±0,021 9 (10)	0,7006±0,009 2 (8)	0,7495±0,009 6 (5)	0,7175±0,010 1 (7)	0,6872±0,0124 (9)	0,7645±0,0132 (4)
genbase	0,9375±0,031 5 (4)	0,9302±0,038 2 (11)	0,9454±0,028 1 (2)	0,9134±0,055 4 (12)	0,9375±0,0315 (4)	0,9375±0,0315 (4)
birds	0,3510±0,071 6 (9)	0,3692±0,077 2 (7)	0,3948±0,108 1 (4)	0,3575±0,069 3 (8)	0,3477±0,0909 (10)	<b>0,5253±0,2218</b> (1)
Water-quality	0,2303±0,006 9 (5)	0,2050±0,029 7 (8)	0,2033±0,053 2 (9)	0,1285±0,007 4 (12)	0,2394±0,0122 (3)	0,2032±0,0206 (10)
PlantPseAAC	0,1683±0,044 2 (9)	0,1956±0,048 0 (7)	0,2110±0,043 3 (6)	0,1647±0,043 8 (12)	0,1682±0,0457 (10)	<b>0,3203±0,0289</b> (1)
PlantGO	0,7176±0,051 7 (4)	0,6987±0,021 0 (12)	0,7037±0,032 7 (11)	0,7168±0,029 2 (5)	0,7110±0,0408 (10)	0,7159±0,0242 (7)
Image	0,4913±0,022 9 (9)	0,5743±0,019 3 (8)	0,6063±0,013 0 (6)	0,6312±0,013 4 (5)	0,4912±0,0203 (12)	<b>0,7129±0,0105</b> (1)
HumanPseAAC	0,0843±0,007 2 (10)	0,1500±0,013 0 (7)	0,1740±0,014 5 (6)	0,1043±0,002 6 (8)	0,0926±0,0093 (9)	<b>0,4935±0,0376</b> (1)
HumanGO	0,6398±0,023 8 (9)	0,6878±0,071 7 (3)	0,6513±0,041 8 (8)	0,6542±0,095 3 (7)	0,6186±0,0309 (12)	<b>0,7183±0,0616</b> (1)
GpositivePseAAC	0,5214±0,094 1 (8)	0,5415±0,069 3 (4)	0,5322±0,043 5 (7)	0,5130±0,025 4 (11)	0,5086±0,0540 (12)	0,5366±0,0664 (6)
GpositiveGO	0,8806±0,047 1 (9)	0,8996±0,041 3 (6)	<b>0,9261±0,051</b> <b>5 (1)</b>	0,9161±0,031 6 (3)	0,8468±0,0884 (12)	0,9009±0,0355 (5)
GnegativePseAAC	0,3740±0,035 0 (10)	0,3882±0,016 4 (8)	0,4419±0,042 9 (5)	0,4327±0,052 5 (7)	0,3649±0,0133 (12)	0,4564±0,0437 (4)
GnegativeGO	0,9530±0,012 1 (9)	0,9545±0,012 6 (7)	0,9419±0,027 3 (12)	0,9552±0,011 0 (6)	0,9606±0,0208 (4)	0,9571±0,0127 (5)
Avg. Rank	8,88	7,18	6,00	7,47	9,00	3,71
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6929±0,022 5 (5)	0,5720±0,013 9 (11)	0,6240±0,007 5 (8)	0,7263±0,017 2 (3)	0,7213±0,0169 (4)	0,7275±0,0219 (2)
yeast	0,3929±0,020 9 (2)	0,3291±0,005 2 (9)	0,3219±0,003 5 (11)	<b>0,4179±0,024</b> <b>5 (1)</b>	0,3763±0,0023 (5)	0,3777±0,0063 (4)
CAL500	0,1648±0,007 9 (3)	0,1198±0,011 9 (7)	0,1092±0,011 4 (11)	0,1843±0,009 2 (2)	0,1201±0,0111 (6)	0,1210±0,0119 (5)
medical	0,6181±0,072 5 (11)	0,6746±0,024 8 (6)	0,6459±0,019 5 (10)	0,6909±0,048 2 (4)	0,6540±0,0327 (9)	0,6699±0,0581 (7)
scene	0,7495±0,009 6 (5)	0,6546±0,021 9 (10)	0,6546±0,021 9 (10)	<b>0,7978±0,009</b> <b>5 (1)</b>	0,7755±0,0065 (3)	0,7819±0,0091 (2)
genbase	<b>0,9480±0,029</b> <b>8 (1)</b>	0,9387±0,030 9 (3)	0,9375±0,031 5 (4)	0,9310±0,037 9 (10)	0,9375±0,0315 (4)	0,9375±0,0315 (4)
birds	0,3922±0,108 6 (5)	0,3361±0,077 2 (11)	0,3323±0,080 1 (12)	0,4171±0,035 0 (3)	0,3916±0,0937 (6)	0,4428±0,0891 (2)
Water-quality	0,1611±0,006 0 (11)	0,2303±0,006 9 (5)	0,2962±0,004 4 (2)	<b>0,3496±0,033</b> <b>8 (1)</b>	0,2072±0,0238 (7)	0,2318±0,0269 (4)
PlantPseAAC	0,2180±0,042 3 (5)	0,1673±0,044 3 (11)	0,1751±0,039 0 (8)	0,2333±0,059 5 (3)	0,2212±0,0478 (4)	0,2478±0,0532 (2)
PlantGO	0,7182±0,018 0 (3)	0,7119±0,021 4 (9)	0,7135±0,022 7 (8)	<b>0,7499±0,026</b> <b>4 (1)</b>	0,7168±0,0577 (5)	0,7215±0,0565 (2)
Image	0,6063±0,013 0 (6)	0,4913±0,022 9 (9)	0,4913±0,022 9 (9)	0,6549±0,017 8 (3)	0,6546±0,0189 (4)	0,6552±0,0163 (2)
HumanPseAAC	0,1772±0,010 3 (5)	0,0843±0,007 2 (10)	0,0843±0,007 2 (10)	0,1987±0,013 0 (3)	0,1865±0,0109 (4)	0,2092±0,0123 (2)
HumanGO	0,6378±0,012 7 (10)	0,6602±0,051 8 (5)	0,6596±0,029 5 (6)	0,6983±0,032 1 (2)	0,6312±0,0214 (11)	0,6668±0,0246 (4)
GpositivePseAAC	0,5367±0,040 8 (5)	0,5214±0,094 1 (8)	0,5214±0,094 1 (8)	<b>0,6012±0,090</b> <b>1 (1)</b>	0,5931±0,0850 (2)	0,5830±0,0653 (3)
GpositiveGO	0,8810±0,094 1 (8)	0,8772±0,049 3 (10)	0,8665±0,038 7 (11)	0,9160±0,040 0 (4)	0,9178±0,0480 (2)	0,8955±0,0671 (7)
GnegativePseAAC	0,4351±0,035 2 (6)	0,3877±0,047 6 (9)	0,3740±0,035 0 (10)	<b>0,5421±0,098</b> <b>3 (1)</b>	0,4603±0,0344 (3)	0,4675±0,0492 (2)
GnegativeGO	0,9480±0,020 4 (11)	0,9540±0,012 9 (8)	0,9529±0,012 2 (10)	<b>0,9646±0,016</b> <b>1 (1)</b>	0,9631±0,0148 (2)	0,9613±0,0147 (3)
Avg. Rank	6,00	8,29	8,71	<b>2,59</b>	4,76	3,35

Tablo 6-7 Mikro ortalamalı duyarlılık (*recall*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,5909±0,017 3 (11)	0,6377±0,021 5 (9)	0,7040±0,025 3 (5)	0,6706±0,012 1 (7)	0,6373±0,0153 (10)	<b>0,7818±0,0288</b> (1)
yeast	0,5701±0,014 2 (11)	0,5702±0,015 6 (10)	0,6065±0,016 9 (6)	0,6191±0,017 8 (4)	0,5717±0,0139 (9)	0,5870±0,0164 (7)
CAL500	0,2279±0,008 7 (10)	0,2189±0,015 2 (11)	0,3056±0,069 4 (3)	0,2361±0,008 4 (8)	0,2405±0,0072 (7)	0,1953±0,0494 (12)
medical	0,7795±0,010 4 (10)	0,7788±0,034 1 (11)	0,7701±0,007 6 (12)	0,7819±0,037 7 (9)	0,7892±0,0144 (7)	0,7949±0,0243 (5)
scene	0,6437±0,022 7 (10)	0,6917±0,005 6 (8)	0,7397±0,013 7 (5)	0,7091±0,010 7 (7)	0,6754±0,0132 (9)	0,7582±0,0137 (4)
genbase	0,9858±0,008 6 (4)	0,9853±0,008 5 (10)	0,9875±0,003 9 (3)	0,9684±0,037 2 (12)	0,9858±0,0086 (4)	0,9858±0,0086 (4)
birds	0,3936±0,051 8 (10)	0,4148±0,061 3 (6)	0,4459±0,075 3 (5)	0,3854±0,067 1 (11)	0,4038±0,0637 (7)	0,3661±0,1836 (12)
Water-quality	0,3210±0,012 7 (4)	0,2723±0,038 0 (8)	0,2186±0,075 4 (10)	0,1687±0,007 7 (11)	0,3255±0,0135 (3)	0,2697±0,0289 (9)
PlantPseAAC	0,2492±0,014 3 (9)	0,2861±0,016 1 (7)	0,3091±0,014 3 (6)	0,2464±0,023 1 (11)	0,2452±0,0369 (12)	<b>0,4925±0,0599</b> (1)
PlantGO	0,7389±0,103 1 (12)	0,7617±0,017 6 (10)	0,7759±0,023 1 (9)	0,7792±0,024 3 (6)	0,7924±0,0219 (3)	0,7795±0,0134 (5)
Image	0,4864±0,023 4 (9)	0,5750±0,018 2 (8)	0,6025±0,012 6 (6)	0,6290±0,013 3 (5)	0,4860±0,0210 (12)	<b>0,7088±0,0105</b> (1)
HumanPseAAC	0,1988±0,013 6 (10)	0,3434±0,013 8 (7)	0,3670±0,015 3 (6)	0,2413±0,014 9 (8)	0,2216±0,0197 (9)	<b>0,6911±0,0288</b> (1)
HumanGO	0,7305±0,016 1 (12)	0,7555±0,033 6 (8)	0,7358±0,016 7 (11)	0,7578±0,037 4 (7)	0,7524±0,0096 (9)	0,7626±0,0233 (6)
GpositivePseAAC	0,6292±0,058 2 (8)	0,6464±0,042 7 (4)	0,6326±0,035 1 (7)	0,6213±0,024 5 (12)	0,6364±0,0514 (6)	0,6274±0,0297 (11)
GpositiveGO	0,9384±0,013 4 (4)	0,9319±0,040 7 (9)	0,9327±0,023 9 (8)	0,9316±0,017 8 (10)	0,9415±0,0198 (3)	0,9288±0,0187 (12)
GnegativePseAAC	0,6085±0,007 0 (11)	0,6317±0,015 5 (8)	0,6615±0,026 8 (5)	0,6443±0,014 9 (7)	0,6161±0,0146 (10)	0,6863±0,0305 (4)
GnegativeGO	0,9520±0,011 3 (8)	0,9519±0,007 1 (9)	0,9464±0,006 0 (12)	0,9526±0,008 7 (7)	<b>0,9641±0,0181</b> (1)	0,9472±0,0111 (11)
Avg. Rank	9,00	8,41	7,00	8,35	7,12	6,24
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,7040±0,025 3 (5)	0,5909±0,017 3 (11)	0,6407±0,021 1 (8)	0,7427±0,017 4 (3)	0,7384±0,0163 (4)	0,7438±0,0197 (2)
yeast	0,6101±0,023 0 (5)	0,5804±0,018 8 (8)	0,5701±0,014 2 (11)	<b>0,6588±0,030</b> <b>8 (1)</b>	0,6305±0,0145 (2)	0,6229±0,0188 (3)
CAL500	0,3361±0,002 3 (2)	0,2681±0,008 4 (5)	0,2347±0,009 0 (9)	<b>0,4178±0,008</b> <b>1 (1)</b>	0,2552±0,0076 (6)	0,2694±0,0339 (4)
medical	0,7866±0,012 3 (8)	0,8023±0,021 9 (4)	0,7912±0,001 8 (6)	0,8086±0,016 7 (2)	0,8063±0,0113 (3)	<b>0,8137±0,0197</b> (1)
scene	0,7397±0,013 7 (5)	0,6437±0,022 7 (10)	0,6437±0,022 7 (10)	<b>0,7896±0,012</b> <b>4 (1)</b>	0,7668±0,0100 (3)	0,7734±0,0104 (2)
genbase	0,9769±0,021 1 (11)	0,9882±0,010 4 (2)	0,9858±0,008 6 (4)	<b>0,9901±0,005</b> <b>0 (1)</b>	0,9858±0,0086 (4)	0,9858±0,0086 (4)
birds	0,4688±0,047 1 (2)	0,4008±0,042 4 (8)	0,3949±0,046 0 (9)	<b>0,5046±0,041</b> <b>5 (1)</b>	0,4501±0,0653 (4)	0,4673±0,0190 (3)
Water-quality	0,1594±0,010 3 (12)	0,3210±0,012 7 (4)	0,4126±0,010 2 (2)	<b>0,4258±0,050</b> <b>9 (1)</b>	0,2752±0,0304 (7)	0,3066±0,0328 (6)
PlantPseAAC	0,3211±0,030 6 (5)	0,2476±0,012 7 (10)	0,2548±0,013 7 (8)	0,3653±0,055 1 (3)	0,3471±0,0113 (4)	0,3735±0,0148 (2)
PlantGO	0,7555±0,065 6 (11)	0,7766±0,019 2 (7)	0,7764±0,019 2 (8)	<b>0,8061±0,016</b> <b>1 (1)</b>	0,8046±0,0217 (2)	0,7845±0,0603 (4)
Image	0,6025±0,012 6 (6)	0,4864±0,023 4 (9)	0,4864±0,023 4 (9)	0,6514±0,016 0 (3)	0,6514±0,0173 (3)	0,6531±0,0145 (2)
HumanPseAAC	0,3731±0,012 2 (5)	0,1988±0,013 6 (10)	0,1988±0,013 6 (10)	0,4130±0,007 4 (3)	0,3937±0,0071 (4)	0,4429±0,0153 (2)
HumanGO	0,7485±0,014 7 (10)	0,7660±0,024 3 (5)	0,7671±0,012 1 (4)	<b>0,7930±0,013</b> <b>4 (1)</b>	0,7708±0,0073 (3)	0,7779±0,0100 (2)
GpositivePseAAC	0,6390±0,022 7 (5)	0,6292±0,058 2 (8)	0,6292±0,058 2 (8)	<b>0,7054±0,049</b> <b>4 (1)</b>	0,6993±0,0726 (3)	0,6999±0,0327 (2)
GpositiveGO	0,9308±0,019 8 (11)	0,9358±0,018 5 (7)	0,9383±0,018 7 (5)	<b>0,9513±0,016</b> <b>9 (1)</b>	0,9432±0,0234 (2)	0,9382±0,0256 (6)
GnegativePseAAC	0,6552±0,025 5 (6)	0,6205±0,016 6 (9)	0,6085±0,007 0 (11)	<b>0,7208±0,036</b> <b>6 (1)</b>	0,6875±0,0166 (3)	0,6950±0,0197 (2)
GnegativeGO	0,9515±0,008 0 (10)	0,9528±0,011 4 (6)	0,9534±0,010 9 (5)	0,9637±0,009 2 (2)	0,9602±0,0091 (3)	0,9596±0,0099 (4)
Avg. Rank	7,00	7,24	7,47	<b>1,59</b>	3,53	3,00

Tablo 6-8 Örnek tabanlı ortalamalı F-puanı (*F-measure*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,5922±0,034 7 (11)	0,6087±0,028 1 (9)	0,6604±0,029 6 (5)	0,6527±0,023 0 (7)	0,6314±0,0355 (8)	0,6689±0,0301 (4)
yeast	0,6114±0,018 9 (9)	0,5890±0,020 6 (12)	0,6222±0,022 6 (5)	0,6341±0,023 7 (3)	0,6124±0,0188 (8)	0,6061±0,0200 (11)
CAL500	0,3355±0,009 1 (9)	0,3038±0,015 6 (10)	0,3015±0,066 9 (11)	0,3426±0,008 6 (5)	0,3418±0,0061 (7)	0,2776±0,0612 (12)
medical	0,7941±0,008 2 (9)	0,7964±0,011 1 (6)	0,7889±0,022 4 (11)	0,7774±0,023 7 (12)	0,7910±0,0134 (10)	<b>0,8185±0,0374</b> <b>(1)</b>
scene	0,6252±0,020 7 (10)	0,7072±0,009 0 (6)	0,7543±0,014 9 (2)	0,7019±0,011 8 (7)	0,6687±0,0135 (8)	0,6407±0,0152 (9)
genbase	0,9907±0,006 1 (4)	0,9904±0,006 1 (9)	0,9927±0,001 9 (2)	0,9859±0,014 3 (11)	0,9907±0,0061 (4)	0,9907±0,0061 (4)
birds	0,6539±0,037 0 (9)	0,6644±0,048 6 (6)	0,6611±0,039 9 (7)	0,5899±0,121 2 (12)	0,6511±0,0470 (11)	<b>0,7399±0,1351</b> <b>(1)</b>
Water-quality	0,3997±0,024 1 (4)	0,3411±0,043 4 (9)	0,2759±0,064 2 (10)	0,2363±0,013 0 (11)	0,4022±0,0240 (3)	0,3497±0,0373 (8)
PlantPseAAC	0,2227±0,009 0 (11)	0,2798±0,009 9 (6)	0,3182±0,012 2 (5)	0,2273±0,020 7 (9)	0,2241±0,0301 (10)	0,2784±0,0142 (7)
PlantGO	0,7383±0,061 5 (12)	0,7646±0,020 0 (9)	<b>0,7938±0,025</b> <b>0 (1)</b>	0,7749±0,019 2 (6)	0,7710±0,0172 (8)	0,7775±0,0118 (5)
Image	0,5101±0,023 1 (10)	0,6166±0,018 6 (7)	0,6451±0,010 9 (5)	0,6542±0,012 9 (4)	0,5104±0,0201 (9)	0,5859±0,0142 (8)
HumanPseAAC	0,2047±0,015 7 (10)	0,3653±0,013 7 (6)	0,3881±0,014 2 (5)	0,2436±0,013 4 (8)	0,2210±0,0194 (9)	0,2998±0,0081 (7)
HumanGO	0,7458±0,020 7 (11)	0,7621±0,027 2 (4)	0,7655±0,015 4 (3)	0,7565±0,019 1 (7)	0,7419±0,0092 (12)	0,7592±0,0115 (6)
GpositivePseAAC	0,5880±0,052 6 (9)	0,6436±0,039 0 (4)	0,6357±0,036 7 (6)	0,6235±0,027 1 (7)	0,6055±0,0460 (8)	0,5637±0,0409 (12)
GpositiveGO	0,9316±0,011 0 (10)	0,9341±0,041 6 (7)	0,9381±0,022 1 (3)	0,9362±0,019 6 (6)	0,9375±0,0153 (5)	0,9282±0,0154 (12)
GnegativePseAAC	0,5932±0,010 9 (11)	0,6310±0,015 8 (6)	0,6756±0,024 7 (3)	0,6298±0,005 8 (7)	0,6015±0,0128 (10)	0,6105±0,0147 (8)
GnegativeGO	0,9529±0,010 0 (10)	0,9546±0,006 2 (8)	0,9590±0,006 7 (6)	0,9548±0,006 7 (7)	<b>0,9671±0,0181</b> <b>(1)</b>	0,9514±0,0098 (12)
Avg. Rank	9,35	7,29	5,29	7,59	7,71	7,47
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6604±0,029 6 (5)	0,5922±0,034 7 (11)	0,5973±0,022 7 (10)	0,6718±0,027 8 (3)	<b>0,6811±0,0285</b> <b>(1)</b>	0,6749±0,0256 (2)
yeast	0,6168±0,018 7 (6)	0,6133±0,019 5 (7)	0,6114±0,018 9 (9)	<b>0,6484±0,017</b> <b>9 (1)</b>	0,6429±0,0166 (2)	0,6295±0,0219 (4)
CAL500	0,3402±0,003 3 (8)	0,3696±0,008 2 (2)	0,3422±0,009 0 (6)	<b>0,3880±0,008</b> <b>4 (1)</b>	0,3553±0,0078 (3)	0,3515±0,0134 (4)
medical	0,8007±0,014 9 (4)	0,7955±0,020 6 (7)	0,7943±0,012 9 (8)	0,7983±0,011 8 (5)	0,8100±0,0093 (3)	0,8116±0,0137 (2)
scene	0,7543±0,014 9 (2)	0,6252±0,020 7 (10)	0,6252±0,020 7 (10)	0,7512±0,014 1 (5)	<b>0,7565±0,0104</b> <b>(1)</b>	0,7514±0,0106 (4)
genbase	0,9887±0,006 9 (10)	0,9855±0,005 7 (12)	0,9910±0,006 1 (3)	<b>0,9934±0,002</b> <b>2 (1)</b>	0,9907±0,0061 (4)	0,9907±0,0061 (4)
birds	0,6879±0,029 1 (3)	0,6545±0,041 8 (8)	0,6515±0,044 3 (10)	0,6801±0,041 4 (4)	0,6719±0,0438 (5)	0,6915±0,0324 (2)
Water-quality	0,2298±0,014 9 (12)	0,3994±0,023 8 (5)	<b>0,4514±0,016</b> <b>0 (1)</b>	0,4486±0,043 4 (2)	0,3589±0,0326 (7)	0,3823±0,0337 (6)
PlantPseAAC	0,3219±0,014 3 (3)	0,2213±0,009 7 (12)	0,2286±0,010 2 (8)	0,3215±0,040 5 (4)	0,3290±0,0020 (2)	<b>0,3327±0,0107</b> <b>(1)</b>
PlantGO	0,7740±0,013 9 (7)	0,7635±0,018 8 (10)	0,7629±0,018 5 (11)	0,7925±0,015 9 (2)	0,7923±0,0222 (3)	0,7872±0,0299 (4)
Image	0,6451±0,010 9 (5)	0,5101±0,023 1 (10)	0,5101±0,023 1 (10)	0,6563±0,008 8 (3)	<b>0,6646±0,0093</b> <b>(1)</b>	0,6581±0,0111 (2)
HumanPseAAC	0,3932±0,008 7 (4)	0,2047±0,015 7 (10)	0,2047±0,015 7 (10)	0,4068±0,003 5 (2)	0,4017±0,0051 (3)	<b>0,4143±0,0092</b> <b>(1)</b>
HumanGO	0,7563±0,011 0 (8)	0,7496±0,015 7 (10)	0,7520±0,010 2 (9)	0,7666±0,009 7 (2)	0,7610±0,0056 (5)	<b>0,7679±0,0113</b> <b>(1)</b>
GpositivePseAAC	0,6368±0,034 6 (5)	0,5880±0,052 6 (9)	0,5880±0,052 6 (9)	0,6479±0,039 9 (3)	<b>0,6877±0,0784</b> <b>(1)</b>	0,6662±0,0269 (2)
GpositiveGO	0,9334±0,015 0 (8)	0,9309±0,016 9 (11)	0,9333±0,018 2 (9)	<b>0,9433±0,017</b> <b>5 (1)</b>	0,9415±0,0200 (2)	0,9376±0,0241 (4)
GnegativePseAAC	0,6652±0,028 4 (5)	0,6053±0,016 7 (9)	0,5932±0,010 9 (11)	<b>0,6810±0,022</b> <b>3 (1)</b>	0,6766±0,0163 (2)	0,6721±0,0146 (4)
GnegativeGO	0,9601±0,007 5 (4)	0,9545±0,008 6 (9)	0,9528±0,010 0 (11)	0,9619±0,007 1 (3)	0,9622±0,0077 (2)	0,9597±0,0080 (5)
Avg. Rank	5,82	8,94	8,53	<b>2,53</b>	2,76	3,06

Tablo 6-9 Makro ortalamalı F-puanı (*F-measure*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,6062±0,017 7 (10)	0,5982±0,031 6 (12)	0,6744±0,023 9 (5)	0,6647±0,017 8 (7)	0,6462±0,0245 (8)	0,6746±0,0172 (4)
yeast	0,3256±0,005 2 (11)	0,3532±0,010 4 (7)	0,3940±0,016 5 (3)	0,3656±0,010 3 (6)	0,3275±0,0063 (10)	0,3291±0,0077 (8)
CAL500	0,1046±0,012 8 (12)	0,1217±0,012 2 (6)	0,1475±0,024 0 (4)	0,1083±0,012 8 (10)	0,1182±0,0151 (8)	<b>0,1981±0,1658</b> (1)
medical	0,6020±0,065 3 (12)	0,7115±0,042 9 (2)	0,6585±0,145 5 (8)	<b>0,7539±0,122</b> <b>4 (1)</b>	0,6843±0,0294 (4)	0,7091±0,1634 (3)
scene	0,6946±0,015 4 (9)	0,7133±0,009 5 (8)	0,7584±0,012 5 (1)	0,7421±0,009 1 (6)	0,7170±0,0113 (7)	0,5697±0,0144 (12)
genbase	0,9354±0,024 8 (4)	0,9258±0,035 8 (9)	0,9386±0,024 1 (2)	0,9160±0,042 7 (12)	0,9354±0,0248 (4)	0,9354±0,0248 (4)
birds	0,3896±0,051 8 (9)	0,4039±0,064 1 (7)	0,4195±0,084 1 (3)	0,3904±0,072 6 (8)	0,3781±0,0692 (10)	<b>0,5509±0,2314</b> (1)
Water-quality	0,2367±0,006 6 (7)	0,2389±0,020 0 (6)	0,1700±0,065 6 (10)	0,1557±0,007 7 (11)	0,2525±0,0164 (3)	0,2363±0,0128 (9)
PlantPseAAC	0,1785±0,038 1 (11)	0,1905±0,042 6 (6)	0,2088±0,033 1 (3)	0,1835±0,044 0 (9)	0,1869±0,0424 (7)	0,1799±0,0145 (10)
PlantGO	0,7080±0,023 8 (6)	0,6948±0,023 6 (11)	0,7076±0,042 7 (7)	0,7147±0,009 3 (4)	0,7004±0,0294 (10)	<b>0,7218±0,0130</b> (1)
Image	0,5786±0,023 5 (9)	0,6155±0,016 1 (7)	0,6394±0,011 4 (5)	<b>0,6578±0,010</b> <b>2 (1)</b>	0,5787±0,0219 (8)	0,5324±0,0109 (12)
HumanPseAAC	0,1114±0,008 9 (10)	0,1480±0,017 9 (7)	0,1810±0,017 2 (5)	0,1327±0,001 6 (8)	0,1203±0,0120 (9)	0,1555±0,0080 (6)
HumanGO	0,6570±0,023 3 (7)	0,6858±0,055 7 (2)	0,6686±0,035 1 (4)	0,6468±0,080 5 (10)	0,6280±0,0248 (12)	<b>0,6892±0,0264</b> (1)
GpositivePseAAC	0,5157±0,086 8 (9)	0,5378±0,065 7 (4)	0,5359±0,048 1 (5)	0,5206±0,035 0 (8)	0,5215±0,0510 (7)	0,4832±0,0489 (12)
GpositiveGO	0,8761±0,035 8 (11)	0,9089±0,047 0 (2)	0,8881±0,051 1 (8)	0,9050±0,022 3 (4)	0,8546±0,0869 (12)	0,8887±0,0223 (7)
GnegativePseAAC	0,3925±0,035 2 (8)	0,3918±0,021 1 (10)	0,4478±0,039 3 (2)	0,4395±0,060 7 (6)	0,3827±0,0116 (12)	0,3830±0,0397 (11)
GnegativeGO	0,9421±0,015 6 (11)	0,9535±0,017 1 (5)	0,9537±0,018 3 (4)	0,9431±0,017 0 (10)	<b>0,9588±0,0254</b> (1)	0,9556±0,0098 (2)
Avg. Rank	9,18	6,53	4,65	7,12	7,76	6,12
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6744±0,023 9 (5)	0,6062±0,017 7 (10)	0,6075±0,013 2 (9)	0,6824±0,021 4 (2)	<b>0,6896±0,0212</b> (1)	0,6796±0,0181 (3)
yeast	0,4016±0,015 2 (2)	0,3279±0,006 4 (9)	0,3256±0,005 2 (11)	<b>0,4143±0,016</b> <b>0 (1)</b>	0,3692±0,0050 (5)	0,3743±0,0115 (4)
CAL500	0,1647±0,006 5 (3)	0,1092±0,013 3 (9)	0,1050±0,012 7 (11)	0,1665±0,006 9 (2)	0,1190±0,0126 (7)	0,1234±0,0148 (5)
medical	0,6154±0,068 7 (11)	0,6698±0,023 9 (6)	0,6472±0,018 6 (10)	0,6739±0,047 7 (5)	0,6509±0,0288 (9)	0,6664±0,0608 (7)
scene	<b>0,7584±0,012</b> <b>5 (1)</b>	0,6946±0,015 4 (9)	0,6946±0,015 4 (9)	0,7469±0,013 2 (5)	0,7576±0,0094 (3)	0,7492±0,0101 (4)
genbase	<b>0,9434±0,022</b> <b>0 (1)</b>	0,9244±0,023 7 (10)	0,9355±0,024 8 (3)	0,9233±0,035 9 (11)	0,9354±0,0248 (4)	0,9354±0,0248 (4)
birds	0,4089±0,084 9 (6)	0,3715±0,056 7 (11)	0,3676±0,059 8 (12)	0,4144±0,028 7 (5)	0,4179±0,0679 (4)	0,4648±0,0756 (2)
Water-quality	0,1201±0,012 1 (12)	0,2365±0,006 3 (8)	0,2458±0,004 8 (4)	<b>0,3027±0,024</b> <b>9 (1)</b>	0,2398±0,0163 (5)	0,2599±0,0171 (2)
PlantPseAAC	<b>0,2113±0,033</b> <b>1 (1)</b>	0,1772±0,038 3 (12)	0,1844±0,032 6 (8)	0,2036±0,035 0 (5)	0,2075±0,0407 (4)	0,2109±0,0432 (2)
PlantGO	0,7176±0,010 5 (2)	0,7147±0,010 2 (4)	0,7009±0,027 0 (9)	0,7165±0,015 1 (3)	0,6901±0,0315 (12)	0,7064±0,0178 (8)
Image	0,6394±0,011 4 (5)	0,5786±0,023 5 (9)	0,5786±0,023 5 (9)	0,6487±0,011 8 (3)	0,6571±0,0125 (2)	0,6468±0,0112 (4)
HumanPseAAC	0,1857±0,011 4 (4)	0,1114±0,008 9 (10)	0,1114±0,008 9 (10)	<b>0,1947±0,011</b> <b>9 (1)</b>	0,1892±0,0121 (2)	0,1889±0,0144 (3)
HumanGO	0,6533±0,017 3 (8)	0,6478±0,040 6 (9)	0,6613±0,020 3 (6)	0,6706±0,014 3 (3)	0,6329±0,0216 (11)	0,6641±0,0175 (5)
GpositivePseAAC	0,5347±0,048 8 (6)	0,5157±0,086 8 (9)	0,5157±0,086 8 (9)	0,5422±0,072 8 (3)	<b>0,5768±0,0736</b> (1)	0,5502±0,0601 (2)
GpositiveGO	0,8872±0,097 4 (9)	0,8832±0,032 2 (10)	0,8904±0,046 8 (6)	0,9056±0,048 3 (3)	<b>0,9128±0,0539</b> (1)	0,8970±0,0704 (5)
GnegativePseAAC	0,4418±0,031 8 (4)	0,4021±0,048 2 (7)	0,3925±0,035 2 (8)	<b>0,4908±0,068</b> <b>1 (1)</b>	0,4471±0,0379 (3)	0,4408±0,0474 (5)
GnegativeGO	0,9527±0,017 3 (6)	0,9439±0,018 4 (9)	0,9420±0,015 5 (12)	0,9480±0,017 5 (7)	0,9464±0,0186 (8)	0,9548±0,0167 (3)
Avg. Rank	5,06	8,88	8,59	<b>3,59</b>	4,82	4,00

Tablo 6-10 Mikro ortalamalı F-puanı (*F-measure*) metriği için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,6537±0,0246 (10)	0,6467±0,0272 (12)	0,6872±0,0245 (5)	0,6899±0,0158 (4)	0,6729±0,0269 (8)	0,6838±0,0199 (7)
yeast	0,6343±0,0169 (9)	0,6180±0,0190 (12)	0,6419±0,0207 (5)	0,6533±0,0207 (3)	0,6349±0,0169 (8)	0,6238±0,0189 (11)
CAL500	0,3329±0,0104 (9)	0,3061±0,0166 (11)	0,3158±0,0486 (10)	0,3403±0,0100 (7)	0,3412±0,0063 (6)	0,2772±0,0594 (12)
medical	0,8112±0,0117 (7)	0,8078±0,0210 (8)	0,8009±0,0204 (10)	0,8040±0,0211 (9)	0,8126±0,0159 (6)	<b>0,8310±0,0401 (1)</b>
scene	0,6889±0,0161 (9)	0,7042±0,0074 (8)	0,7507±0,0144 (1)	0,7342±0,0082 (6)	0,7103±0,0103 (7)	0,5675±0,0140 (12)
genbase	0,9904±0,0028 (2)	0,9895±0,0039 (8)	0,9886±0,0044 (9)	0,9808±0,0191 (11)	0,9904±0,0028 (2)	0,9904±0,0028 (2)
birds	0,4791±0,0425 (9)	0,4937±0,0525 (7)	0,5046±0,0601 (6)	0,4643±0,0810 (12)	0,4743±0,0555 (11)	<b>0,6112±0,1951 (1)</b>
Water-quality	0,4296±0,0147 (4)	0,3796±0,0364 (9)	0,2865±0,0756 (10)	0,2707±0,0085 (11)	0,4333±0,0148 (3)	0,3803±0,0275 (8)
PlantPseAAC	0,2815±0,0058 (10)	0,2863±0,0133 (6)	0,3165±0,0143 (5)	0,2832±0,0260 (9)	0,2860±0,0359 (7)	0,2754±0,0104 (12)
PlantGO	0,7497±0,0632 (12)	0,7677±0,0105 (11)	0,7894±0,0225 (3)	0,7841±0,0127 (4)	0,7841±0,0150 (4)	0,7810±0,0097 (7)
Image	0,5777±0,0238 (8)	0,6123±0,0170 (7)	0,6359±0,0119 (5)	<b>0,6546±0,0085 (1)</b>	0,5777±0,0220 (8)	0,5337±0,0118 (12)
HumanPseAAC	0,2762±0,0153 (9)	0,3648±0,0135 (6)	0,3872±0,0140 (5)	0,3134±0,0172 (7)	0,2959±0,0243 (8)	0,2401±0,0023 (12)
HumanGO	0,7429±0,0189 (12)	0,7482±0,0118 (7)	0,7538±0,0164 (3)	0,7474±0,0135 (9)	0,7460±0,0085 (11)	0,7500±0,0064 (6)
GpositivePseAAC	0,6214±0,0477 (9)	0,6430±0,0377 (4)	0,6351±0,0364 (7)	0,6272±0,0244 (8)	0,6476±0,0413 (3)	0,5850±0,0357 (12)
GpositiveGO	0,9393±0,0097 (6)	0,9334±0,0414 (11)	0,9367±0,0226 (8)	0,9367±0,0179 (8)	0,9418±0,0139 (2)	0,9278±0,0172 (12)
GnegativePseAAC	0,6358±0,0146 (9)	0,6209±0,0195 (11)	<b>0,6704±0,0249 (1)</b>	0,6477±0,0193 (6)	0,6421±0,0127 (7)	0,5696±0,0184 (12)
GnegativeGO	0,9529±0,0073 (9)	0,9506±0,0048 (11)	0,9546±0,0058 (5)	0,9539±0,0047 (7)	<b>0,9662±0,0174 (1)</b>	0,9459±0,0083 (12)
Avg. Rank	8,41	8,76	5,76	7,18	6,00	8,88
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,6872±0,0245 (5)	0,6537±0,0246 (10)	0,6571±0,0169 (9)	0,6981±0,0224 (2)	<b>0,7062±0,0194 (1)</b>	0,6969±0,0177 (3)
yeast	0,6368±0,0170 (6)	0,6363±0,0182 (7)	0,6343±0,0169 (9)	<b>0,6634±0,0155 (1)</b>	0,6604±0,0154 (2)	0,6519±0,0208 (4)
CAL500	0,3463±0,0032 (5)	0,3679±0,0093 (2)	0,3395±0,0102 (8)	<b>0,3907±0,0086 (1)</b>	0,3540±0,0090 (3)	0,3514±0,0164 (4)
medical	0,8004±0,0184 (11)	0,8134±0,0162 (5)	0,8157±0,0117 (4)	0,7970±0,0074 (12)	0,8181±0,0131 (2)	0,8178±0,0163 (3)
scene	<b>0,7507±0,0144 (1)</b>	0,6889±0,0161 (9)	0,6889±0,0161 (9)	0,7374±0,0144 (5)	0,7474±0,0110 (3)	0,7378±0,0104 (4)
genbase	0,9845±0,0100 (10)	0,9709±0,0182 (12)	<b>0,9908±0,0025 (1)</b>	0,9901±0,0024 (7)	0,9904±0,0028 (2)	0,9904±0,0028 (2)
birds	0,5191±0,0388 (4)	0,4846±0,0342 (8)	0,4770±0,0412 (10)	0,5224±0,0321 (3)	0,5183±0,0476 (5)	0,5314±0,0198 (2)
Water-quality	0,2283±0,0141 (12)	0,4293±0,0144 (5)	<b>0,4735±0,0099 (1)</b>	0,4675±0,0395 (2)	0,3876±0,0270 (7)	0,4132±0,0266 (6)
PlantPseAAC	0,3211±0,0172 (4)	0,2795±0,0058 (11)	0,2844±0,0010 (8)	0,3273±0,0242 (2)	<b>0,3321±0,0050 (1)</b>	0,3271±0,0123 (3)
PlantGO	0,7695±0,0279 (10)	0,7773±0,0192 (8)	0,7743±0,0174 (9)	0,7900±0,0067 (1)	<b>0,7900±0,0095 (1)</b>	0,7816±0,0184 (6)
Image	0,6359±0,0119 (5)	0,5777±0,0238 (8)	0,5777±0,0238 (8)	0,6450±0,0120 (3)	0,6533±0,0116 (2)	0,6424±0,0122 (4)
HumanPseAAC	0,3930±0,0102 (4)	0,2762±0,0153 (9)	0,2762±0,0153 (9)	0,4054±0,0061 (2)	0,4014±0,0067 (3)	<b>0,4070±0,0111 (1)</b>
HumanGO	0,7471±0,0116 (10)	0,7481±0,0145 (8)	0,7511±0,0073 (5)	0,7545±0,0053 (2)	0,7516±0,0058 (4)	<b>0,7552±0,0087 (1)</b>
GpositivePseAAC	0,6358±0,0351 (6)	0,6214±0,0477 (9)	0,6214±0,0477 (9)	0,6397±0,0396 (5)	<b>0,6832±0,0797 (1)</b>	0,6595±0,0242 (2)
GpositiveGO	0,9345±0,0129 (10)	0,9407±0,0122 (4)	<b>0,9431±0,0135 (1)</b>	0,9408±0,0182 (3)	0,9395±0,0209 (5)	0,9377±0,0240 (7)
GnegativePseAAC	0,6645±0,0244 (3)	0,6392±0,0152 (8)	0,6358±0,0146 (9)	0,6641±0,0158 (4)	0,6662±0,0140 (2)	0,6541±0,0135 (5)
GnegativeGO	0,9564±0,0054 (3)	0,9536±0,0064 (8)	0,9523±0,0073 (10)	0,9552±0,0063 (4)	0,9566±0,0061 (2)	0,9540±0,0060 (6)
Avg. Rank	6,41	7,71	7,00	3,47	<b>2,71</b>	3,71

Tablo 6-11 Örnek tabanlı doğruluk metiri için deneysel sonuçlar

Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,5156±0,0345 (10)	0,5281±0,0276 (9)	0,5795±0,033 9 (4)	0,5712±0, 0242 (7)	0,5506±0,0347 (8)	0,5758±0,0317 (6)
yeast	0,5013±0,0184 (9)	0,4877±0,0213 (12)	0,5262±0,019 7 (5)	0,5292±0, 0243 (3)	0,5025±0,0180 (8)	0,4923±0,0200 (11)
CAL500	0,2055±0,0064 (9)	0,1850±0,0108 (11)	0,1882±0,041 9 (10)	0,2109±0, 0061 (6)	0,2108±0,0049 (7)	0,1669±0,0397 (12)
medical	0,7642±0,0067 (10)	0,7694±0,0142 (5)	0,7670±0,014 3 (6)	0,7479±0, 0265 (12)	0,7620±0,0137 (11)	<b>0,7914±0,0394 (1)</b>
scene	0,6014±0,0204 (10)	0,6942±0,0083 (6)	0,7418±0,015 6 (1)	0,6816±0, 0119 (7)	0,6480±0,0141 (8)	0,6044±0,0162 (9)
genbase	0,9874±0,0064 (4)	0,9868±0,0066 (9)	0,9887±0,003 1 (2)	0,9810±0, 0173 (11)	0,9874±0,0064 (4)	0,9874±0,0064 (4)
birds	0,6197±0,0344 (8)	0,6281±0,0434 (7)	0,6296±0,040 0 (6)	0,5598±0, 1206 (12)	0,6180±0,0431 (11)	<b>0,7104±0,1497 (1)</b>
Water-quality	0,2768±0,0207 (4)	0,2340±0,0286 (9)	0,1873±0,049 9 (10)	0,1586±0, 0104 (11)	0,2793±0,0214 (3)	0,2408±0,0256 (8)
PlantPseAAC	0,2043±0,0069 (11)	0,2665±0,0068 (6)	0,3107±0,011 0 (2)	0,2115±0, 0192 (8)	0,2060±0,0256 (10)	0,2335±0,0089 (7)
PlantGO	0,7078±0,0769 (12)	0,7460±0,0211 (9)	<b>0,7825±0,025 1 (1)</b>	0,7544±0, 0187 (6)	0,7469±0,0175 (8)	0,7614±0,0145 (5)
Image	0,4768±0,0241 (10)	0,5839±0,0198 (7)	0,6134±0,011 2 (2)	0,6123±0, 0092 (4)	0,4772±0,0216 (9)	0,5221±0,0183 (8)
HumanPseAAC	0,1919±0,0146 (10)	0,3482±0,0127 (6)	0,3697±0,014 0 (5)	0,2267±0, 0121 (8)	0,2044±0,0182 (9)	0,2436±0,0084 (7)
HumanGO	0,7128±0,0209 (10)	0,7244±0,0164 (4)	<b>0,7362±0,014 8 (1)</b>	0,7179±0, 0185 (8)	0,7031±0,0103 (12)	0,7226±0,0091 (5)
GpositivePseAAC	0,5652±0,0516 (9)	0,6397±0,0373 (3)	0,6347±0,036 1 (4)	0,6222±0, 0272 (6)	0,5885±0,0437 (8)	0,5437±0,0458 (12)
GpositiveGO	0,9275±0,0096 (9)	0,9329±0,0414 (6)	0,9360±0,022 1 (3)	0,9340±0, 0183 (5)	0,9327±0,0168 (7)	0,9254±0,0152 (12)
GnegativePseAAC	0,5743±0,0126 (11)	0,6208±0,0180 (6)	<b>0,6701±0,024 8 (1)</b>	0,6116±0, 0067 (7)	0,5826±0,0115 (10)	0,5859±0,0159 (9)
GnegativeGO	0,9448±0,0107 (10)	0,9462±0,0064 (9)	0,9529±0,006 0 (3)	0,9470±0, 0061 (7)	<b>0,9614±0,0208 (1)</b>	0,9432±0,0099 (12)
Avg. Rank	9,18	7,29	3,88	7,53	7,88	7,59
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,5795±0,0339 (4)	0,5156±0,0345 (10)	0,5150±0,019 6 (12)	0,5860±0, 0313 (3)	<b>0,5972±0,0343 (1)</b>	0,5864±0,0269 (2)
yeast	0,5218±0,0179 (6)	0,5032±0,0186 (7)	0,5013±0,018 4 (9)	<b>0,5473±0, 0189 (1)</b>	0,5398±0,0178 (2)	0,5279±0,0231 (4)
CAL500	0,2132±0,0013 (5)	0,2311±0,0062 (2)	0,2103±0,006 4 (8)	<b>0,2474±0, 0061 (1)</b>	0,2206±0,0057 (3)	0,2183±0,0101 (4)
medical	0,7728±0,0159 (4)	0,7644±0,0185 (9)	0,7645±0,011 9 (8)	0,7647±0, 0102 (7)	0,7797±0,0093 (3)	0,7819±0,0136 (2)
scene	<b>0,7418±0,0156 (1)</b>	0,6014±0,0204 (10)	0,6014±0,020 4 (10)	0,7169±0, 0178 (5)	0,7332±0,0133 (3)	0,7203±0,0123 (4)
genbase	0,9838±0,0103 (10)	0,9799±0,0069 (12)	0,9879±0,006 4 (3)	<b>0,9897±0, 0033 (1)</b>	0,9874±0,0064 (4)	0,9874±0,0064 (4)
birds	0,6528±0,0278 (3)	0,6196±0,0407 (9)	0,6183±0,041 6 (10)	0,6406±0, 0368 (4)	0,6390±0,0415 (5)	0,6557±0,0319 (2)
Water-quality	0,1531±0,0126 (12)	0,2764±0,0203 (5)	<b>0,3164±0,010 5 (1)</b>	0,3155±0, 0335 (2)	0,2465±0,0229 (7)	0,2634±0,0240 (6)
PlantPseAAC	<b>0,3114±0,0111 (1)</b>	0,2025±0,0086 (12)	0,2094±0,008 7 (9)	0,2927±0, 0340 (5)	0,3100±0,0028 (3)	0,3004±0,0078 (4)
PlantGO	0,7542±0,0180 (7)	0,7444±0,0182 (10)	0,7403±0,021 1 (11)	0,7714±0, 0168 (2)	0,7706±0,0223 (3)	0,7660±0,0266 (4)
Image	0,6134±0,0112 (2)	0,4768±0,0241 (10)	0,4768±0,024 1 (10)	0,6105±0, 0095 (5)	<b>0,6200±0,0091 (1)</b>	0,6083±0,0125 (6)
HumanPseAAC	0,3750±0,0090 (3)	0,1919±0,0146 (10)	0,1919±0,014 6 (10)	0,3762±0, 0038 (2)	<b>0,3765±0,0040 (1)</b>	0,3715±0,0074 (4)
HumanGO	0,7213±0,0110 (7)	0,7102±0,0121 (11)	0,7129±0,012 0 (9)	0,7247±0, 0076 (3)	0,7215±0,0042 (6)	0,7283±0,0116 (2)
GpositivePseAAC	0,6332±0,0392 (5)	0,5652±0,0516 (9)	0,5652±0,051 6 (9)	0,6168±0, 0355 (7)	<b>0,6727±0,0700 (1)</b>	0,6467±0,0246 (2)
GpositiveGO	0,9268±0,0196 (10)	0,9262±0,0174 (11)	0,9300±0,017 4 (8)	0,9380±0, 0172 (2)	<b>0,9388±0,0211 (1)</b>	0,9351±0,0251 (4)
GnegativePseAAC	0,6577±0,0303 (2)	0,5867±0,0162 (8)	0,5743±0,012 6 (11)	0,6518±0, 0193 (4)	0,6577±0,0177 (2)	0,6475±0,0124 (5)
GnegativeGO	0,9528±0,0072 (4)	0,9468±0,0093 (8)	0,9447±0,010 7 (11)	0,9528±0, 0067 (4)	0,9538±0,0076 (2)	0,9510±0,0079 (6)
Avg. Rank	5,06	9,00	8,76	3,41	<b>2,82</b>	3,82

Tablo 6-12 Alt Küme Doğruluğu (*Subset accuracy*) metriği için deneysel sonuçlar

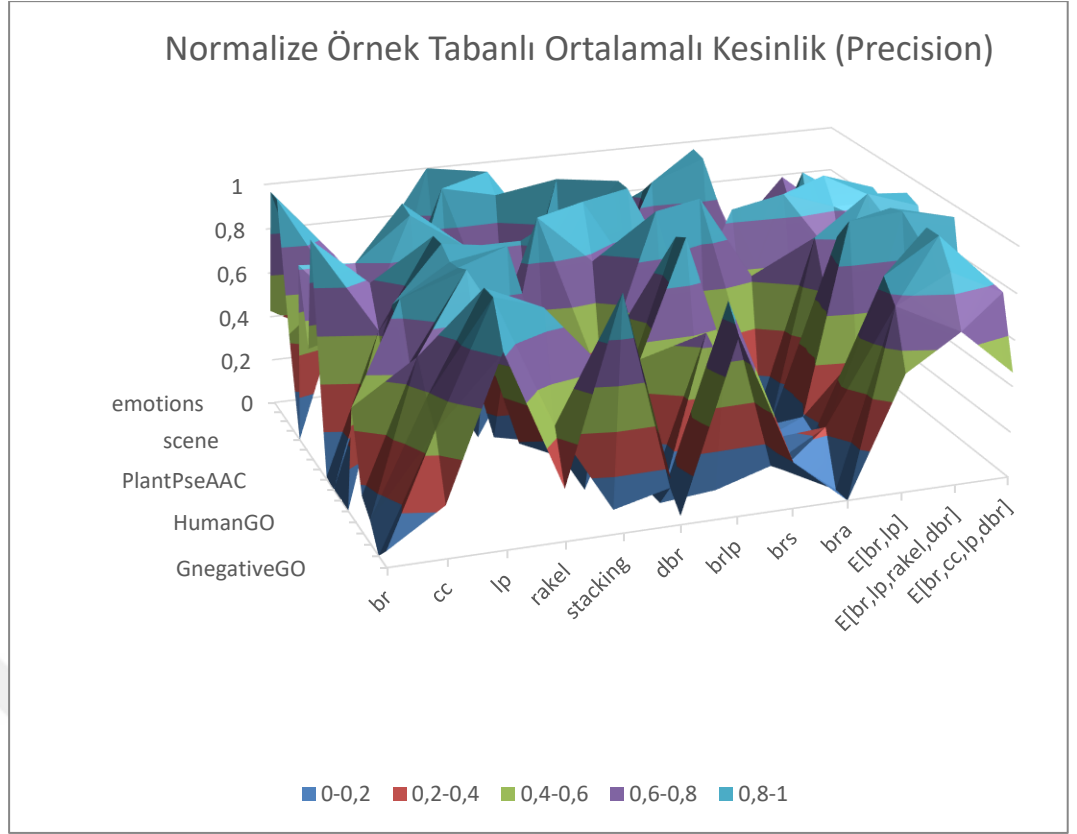
Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,2782±0,0337 (10)	0,2882±0,028 3 (9)	0,3405±0,05 06 (2)	0,3237±0,03 26 (5)	0,3018±0,0359 (7)	0,2961±0,0381 (8)
yeast	0,1489±0,0077 (10)	0,1924±0,021 0 (7)	0,2349±0,02 57 (2)	0,1943±0,01 48 (6)	0,1536±0,0066 (8)	0,1527±0,0113 (9)
CAL500	<b>0,0000±0,0000 (1)</b>	<b>0,0000±0,000 0 (1)</b>	<b>0,0000±0,00 00 (1)</b>	<b>0,0000±0,00 00 (1)</b>	<b>0,0000±0,0000 (1)</b>	<b>0,0000±0,0000 (1)</b>
medical	0,6756±0,0040 (9)	0,6886±0,028 8 (6)	0,7016±0,02 99 (2)	0,6593±0,04 32 (12)	0,6768±0,0146 (8)	<b>0,7110±0,0477 (1)</b>
scene	0,5314±0,0237 (10)	0,6552±0,009 4 (4)	0,7046±0,01 90 (1)	0,6207±0,01 36 (6)	0,5866±0,0180 (8)	0,5355±0,0187 (9)
genbase	0,9758±0,0073 (2)	0,9731±0,010 9 (8)	0,9696±0,01 54 (9)	0,9663±0,02 31 (11)	0,9758±0,0073 (2)	0,9758±0,0073 (2)
birds	0,5242±0,0302 (8)	0,5311±0,033 5 (6)	0,5334±0,03 33 (5)	0,4743±0,11 08 (12)	0,5206±0,0312 (10)	<b>0,6233±0,1931 (1)</b>
Water-quality	0,0066±0,0048 (7)	0,0038±0,005 5 (10)	0,0117±0,00 74 (2)	0,0113±0,00 57 (3)	0,0085±0,0069 (5)	0,0094±0,0073 (4)
PlantPseAAC	0,1554±0,0075 (10)	0,2280±0,011 2 (4)	<b>0,2883±0,00 84 (1)</b>	0,1677±0,01 97 (7)	0,1554±0,0147 (10)	0,1605±0,0079 (8)
PlantGO	0,6185±0,1256 (12)	0,6914±0,024 5 (8)	<b>0,7477±0,02 70 (1)</b>	0,6935±0,01 76 (7)	0,6766±0,0230 (10)	0,7114±0,0219 (2)
Image	0,3795±0,0287 (10)	0,4880±0,024 7 (5)	<b>0,5200±0,01 43 (1)</b>	0,4902±0,01 49 (4)	0,3800±0,0273 (9)	0,3805±0,0284 (8)
HumanPseAAC	0,1555±0,0129 (10)	0,2980±0,011 1 (4)	0,3158±0,01 51 (2)	0,1784±0,01 04 (7)	0,1568±0,0160 (9)	0,1579±0,0107 (8)
HumanGO	0,6162±0,0241 (4)	0,6168±0,033 8 (3)	<b>0,6510±0,01 65 (1)</b>	0,6046±0,01 79 (8)	0,5876±0,0146 (12)	0,6161±0,0130 (5)
GpositivePseAAC	0,4972±0,0529 (10)	0,6282±0,033 0 (3)	0,6319±0,03 46 (2)	0,6184±0,02 79 (5)	0,5375±0,0422 (7)	0,5049±0,0571 (9)
GpositiveGO	0,9165±0,0067 (12)	0,9299±0,040 9 (2)	<b>0,9301±0,02 39 (1)</b>	0,9283±0,01 65 (3)	0,9195±0,0234 (10)	0,9196±0,0132 (9)
GnegativePseAAC	0,5194±0,0202 (11)	0,5935±0,021 8 (4)	<b>0,6537±0,02 59 (1)</b>	0,5597±0,00 95 (7)	0,5280±0,0119 (10)	0,5377±0,0170 (8)
GnegativeGO	0,9202±0,0128 (10)	0,9210±0,006 9 (9)	0,9346±0,00 42 (2)	0,9231±0,00 44 (8)	<b>0,9442±0,0290 (1)</b>	0,9189±0,0099 (12)
Avg. Rank	8,59	5,47	<b>2,12</b>	6,59	7,47	6,12
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,3405±0,0506 (2)	0,2782±0,033 7 (10)	0,2681±0,02 32 (12)	0,3321±0,04 12 (4)	<b>0,3473±0,0527 (1)</b>	0,3186±0,0296 (6)
yeast	<b>0,2382±0,0208 (1)</b>	0,1454±0,013 8 (12)	0,1489±0,00 77 (10)	0,2247±0,02 11 (3)	0,2138±0,0130 (4)	0,2099±0,0198 (5)
CAL500	<b>0,0000±0,0000 (1)</b>	<b>0,0000±0,000 0 (1)</b>	<b>0,0000±0,00 00 (1)</b>	<b>0,0000±0,00 00 (1)</b>	<b>0,0000±0,0000 (1)</b>	<b>0,0000±0,0000 (1)</b>
medical	0,6909±0,0201 (4)	0,6725±0,016 1 (10)	0,6769±0,01 37 (7)	0,6656±0,01 39 (11)	0,6906±0,0106 (5)	0,6943±0,0133 (3)
scene	<b>0,7046±0,0190 (1)</b>	0,5314±0,023 7 (10)	0,5314±0,02 37 (10)	0,6166±0,02 90 (7)	0,6639±0,0218 (3)	0,6282±0,0181 (5)
genbase	0,9681±0,0204 (10)	0,9601±0,015 8 (12)	<b>0,9769±0,00 68 (1)</b>	0,9753±0,00 63 (7)	0,9758±0,0073 (2)	0,9758±0,0073 (2)
birds	0,5488±0,0270 (2)	0,5196±0,032 9 (11)	0,5208±0,03 19 (9)	0,5260±0,02 74 (7)	0,5387±0,0358 (4)	0,5468±0,0329 (3)
Water-quality	<b>0,0132±0,0055 (1)</b>	0,0066±0,004 8 (7)	0,0028±0,00 23 (11)	0,0025±0,00 21 (12)	0,0075±0,0064 (6)	0,0047±0,0073 (9)
PlantPseAAC	0,2810±0,0173 (2)	0,1546±0,008 7 (12)	0,1600±0,01 13 (9)	0,2144±0,02 04 (5)	0,2566±0,0102 (3)	0,2065±0,0053 (6)
PlantGO	0,6985±0,0221 (6)	0,6874±0,016 1 (9)	0,6734±0,02 86 (11)	0,7086±0,02 03 (3)	0,7061±0,0247 (4)	0,7031±0,0209 (5)
Image	0,5200±0,0143 (1)	0,3795±0,028 7 (10)	0,3795±0,02 87 (10)	0,4785±0,01 62 (6)	0,4915±0,0149 (3)	0,4640±0,0203 (7)
HumanPseAAC	<b>0,3216±0,0123 (1)</b>	0,1555±0,012 9 (10)	0,1555±0,01 29 (10)	0,2891±0,00 97 (5)	0,3036±0,0049 (3)	0,2486±0,0086 (6)
HumanGO	0,6189±0,0116 (2)	0,5946±0,008 8 (11)	0,5984±0,01 81 (10)	0,6032±0,00 65 (9)	0,6050±0,0066 (7)	0,6128±0,0152 (6)
GpositivePseAAC	0,6224±0,0535 (4)	0,4972±0,052 9 (10)	0,4972±0,05 29 (10)	0,5240±0,02 51 (8)	<b>0,6543±0,0944 (1)</b>	0,5883±0,0178 (6)
GpositiveGO	0,9242±0,0164 (6)	0,9184±0,011 9 (11)	0,9204±0,01 56 (8)	0,9221±0,01 65 (7)	0,9270±0,0205 (4)	0,9243±0,0252 (5)
GnegativePseAAC	0,6353±0,0377 (2)	0,5328±0,014 5 (9)	0,5194±0,02 02 (11)	0,5665±0,01 89 (6)	0,6020±0,0227 (3)	0,5748±0,0092 (5)
GnegativeGO	0,9307±0,0062 (3)	0,9238±0,011 7 (7)	0,9201±0,01 29 (11)	0,9255±0,00 63 (5)	0,9287±0,0074 (4)	0,9245±0,0079 (6)
Avg. Rank	2,88	9,53	8,88	6,24	3,41	5,06

Tablo 6-13 Hamming kaybı (*Hamming loss*) metriği için deneysel sonuçlar

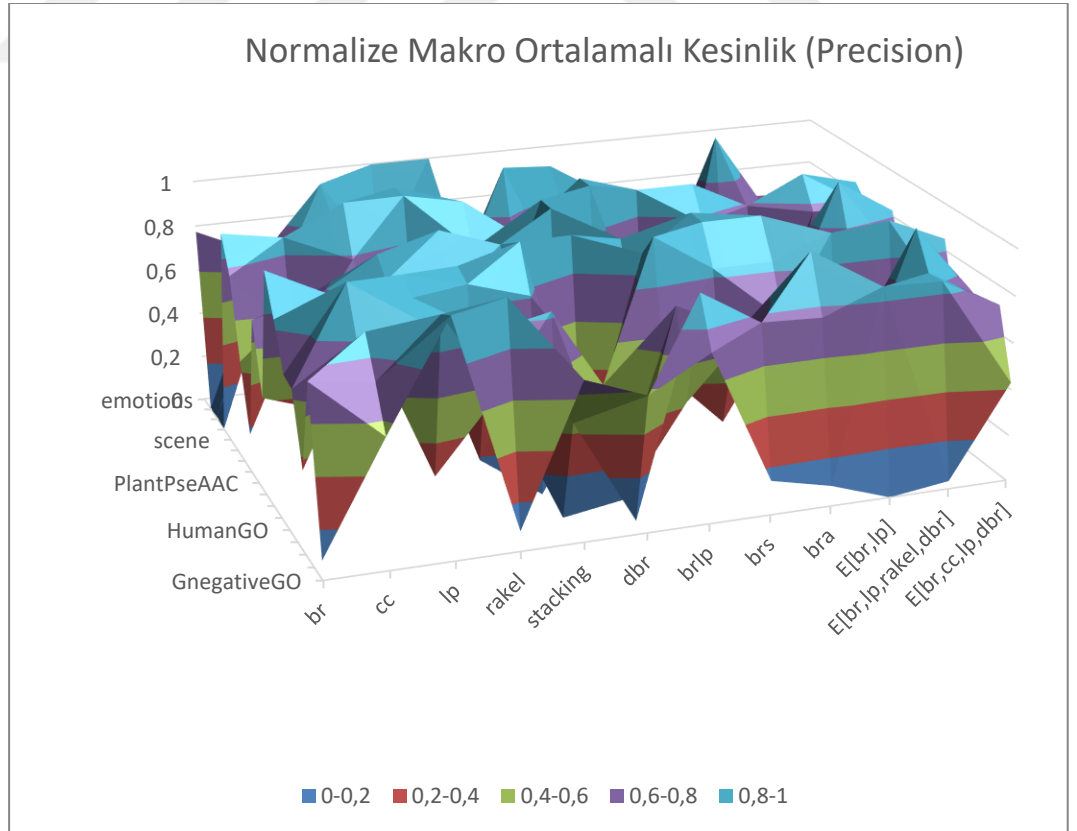
Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	0,1954±0,0181 (4)	0,2170±0,01 61 (11)	0,1996±0,0154 (6)	<b>0,1878±0,01 06 (1)</b>	0,1934±0,0197 (3)	0,2244±0,0140 (12)
yeast	0,1990±0,0094 (4)	0,2134±0,01 08 (11)	0,2051±0,0131 (9)	0,1989±0,01 18 (3)	0,1988±0,0094 (2)	0,2143±0,0110 (12)
CAL500	<b>0,1367±0,0039 (1)</b>	0,1484±0,00 54 (7)	0,1947±0,0098 (11)	0,1370±0,00 35 (3)	0,1389±0,0033 (5)	0,1527±0,0095 (9)
medical	0,0102±0,0007 (5)	0,0102±0,00 11 (5)	0,0111±0,0006 (11)	0,0105±0,00 14 (9)	0,0102±0,0009 (5)	<b>0,0090±0,0022 (1)</b>
scene	0,1039±0,0041 (8)	0,1040±0,00 23 (11)	<b>0,0879±0,0054 (1)</b>	0,0919±0,00 24 (3)	0,0986±0,0030 (6)	0,2071±0,0115 (12)
genbase	<b>0,0009±0,0003 (1)</b>	0,0010±0,00 04 (8)	0,0011±0,0006 (9)	0,0017±0,00 17 (11)	<b>0,0009±0,0003 (1)</b>	<b>0,0009±0,0003 (1)</b>
birds	0,0459±0,0036 (6)	0,0449±0,00 37 (4)	0,0461±0,0047 (9)	0,0488±0,01 07 (11)	0,0474±0,0045 (10)	<b>0,0400±0,0115 (1)</b>
Water-quality	0,3088±0,0115 (2)	0,3200±0,00 71 (7)	0,3819±0,0160 (11)	0,3292±0,00 43 (8)	<b>0,3084±0,0109 (1)</b>	0,3171±0,0046 (6)
PlantPseAAC	0,1143±0,0058 (3)	0,1282±0,00 13 (9)	0,1200±0,0028 (6)	0,1121±0,00 58 (2)	<b>0,1096±0,0030 (1)</b>	0,2319±0,0180 (12)
PlantGO	0,0443±0,0113 (12)	0,0418±0,00 21 (10)	<b>0,0373±0,0040 (1)</b>	0,0387±0,00 17 (4)	0,0390±0,0028 (5)	0,0390±0,0021 (5)
Image	0,1757±0,0096 (6)	0,1800±0,00 88 (11)	0,1706±0,0068 (2)	<b>0,1642±0,00 46 (1)</b>	0,1756±0,0091 (5)	0,3065±0,0156 (12)
HumanPseAAC	<b>0,0881±0,0014 (1)</b>	0,1009±0,00 20 (9)	0,0986±0,0023 (7)	0,0895±0,00 23 (5)	0,0892±0,0029 (4)	0,3700±0,0131 (12)
HumanGO	0,0429±0,0030 (4)	0,0433±0,00 17 (8)	<b>0,0407±0,0026 (1)</b>	0,0434±0,00 25 (9)	0,0434±0,0018 (9)	0,0426±0,0012 (2)
GpositivePseAAC	0,1927±0,0228 (8)	0,1806±0,01 80 (3)	0,1831±0,0178 (5)	0,1860±0,01 14 (7)	0,1739±0,0174 (2)	0,2249±0,0243 (12)
GpositiveGO	0,0305±0,0052 (6)	0,0339±0,02 07 (11)	<b>0,0258±0,0160 (1)</b>	0,0313±0,00 92 (9)	0,0291±0,0073 (2)	0,0357±0,0083 (12)
GnegativePseAAC	0,0912±0,0049 (5)	0,1011±0,00 94 (11)	<b>0,0850±0,0065 (1)</b>	0,0922±0,00 94 (8)	0,0898±0,0030 (3)	0,1361±0,0131 (12)
GnegativeGO	0,0123±0,0019 (9)	0,0129±0,00 13 (11)	0,0118±0,0015 (4)	0,0120±0,00 12 (6)	<b>0,0088±0,0045 (1)</b>	0,0142±0,0022 (12)
Avg. Rank	5,00	8,65	5,59	5,88	<b>3,82</b>	8,53
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	0,1996±0,0154 (6)	0,1954±0,01 81 (4)	0,2083±0,0130 (10)	0,2001±0,01 63 (8)	0,1914±0,0144 (2)	0,2015±0,0131 (9)
yeast	0,2099±0,0099 (10)	0,2008±0,00 93 (7)	0,1990±0,0094 (4)	0,2024±0,00 81 (8)	<b>0,1965±0,0092 (1)</b>	0,2006±0,0117 (6)
CAL500	0,1899±0,0020 (10)	0,1379±0,00 38 (4)	<b>0,1367±0,0039 (1)</b>	0,1950±0,00 24 (12)	0,1394±0,0040 (6)	0,1487±0,0115 (8)
medical	0,0108±0,0011 (10)	0,0102±0,00 09 (5)	0,0100±0,0008 (3)	0,0113±0,00 05 (12)	0,0099±0,0008 (2)	0,0101±0,0010 (4)
scene	0,0879±0,0054 (1)	0,1039±0,00 41 (8)	0,1039±0,0041 (8)	0,1007±0,00 64 (7)	0,0928±0,0045 (4)	0,0984±0,0043 (5)
genbase	0,0013±0,0007 (10)	0,0026±0,00 15 (12)	<b>0,0009±0,0003 (1)</b>	<b>0,0009±0,00 02 (1)</b>	<b>0,0009±0,0003 (1)</b>	<b>0,0009±0,0003 (1)</b>
birds	0,0459±0,0038 (6)	0,0457±0,00 34 (5)	0,0460±0,0035 (8)	0,0492±0,00 42 (12)	0,0441±0,0036 (2)	0,0441±0,0019 (2)
Water-quality	0,3903±0,0055 (12)	0,3092±0,01 12 (3)	0,3323±0,0075 (9)	0,3487±0,01 02 (10)	0,3140±0,0088 (4)	0,3154±0,0097 (5)
PlantPseAAC	0,1216±0,0040 (7)	0,1145±0,00 61 (4)	0,1154±0,0060 (5)	0,1335±0,00 83 (10)	0,1254±0,0013 (8)	0,1381±0,0029 (11)
PlantGO	0,0422±0,0067 (11)	0,0397±0,00 34 (8)	0,0409±0,0037 (9)	0,0384±0,00 12 (3)	0,0382±0,0016 (2)	0,0394±0,0021 (7)
Image	0,1706±0,0068 (2)	0,1757±0,00 96 (6)	0,1757±0,0096 (6)	0,1773±0,00 73 (9)	0,1709±0,0069 (4)	0,1798±0,0078 (10)
HumanPseAAC	0,0976±0,0021 (6)	<b>0,0881±0,00 14 (1)</b>	<b>0,0881±0,0014 (1)</b>	0,1025±0,00 19 (10)	0,0994±0,0016 (8)	0,1092±0,0019 (11)
HumanGO	0,0430±0,0020 (6)	0,0437±0,00 20 (12)	0,0429±0,0016 (4)	0,0434±0,00 12 (9)	0,0431±0,0014 (7)	0,0428±0,0015 (3)
GpositivePseAAC	0,1849±0,0215 (6)	0,1927±0,02 28 (8)	0,1927±0,0228 (8)	0,2000±0,02 08 (11)	<b>0,1642±0,0428 (1)</b>	0,1819±0,0117 (4)
GpositiveGO	0,0311±0,0051 (8)	0,0296±0,00 60 (4)	0,0292±0,0065 (3)	0,0301±0,00 93 (5)	0,0306±0,0105 (7)	0,0314±0,0120 (10)
GnegativePseAAC	0,0865±0,0064 (2)	0,0915±0,00 41 (7)	0,0912±0,0049 (5)	0,0942±0,00 51 (9)	0,0901±0,0041 (4)	0,0960±0,0034 (10)
GnegativeGO	0,0114±0,0014 (2)	0,0121±0,00 17 (7)	0,0125±0,0019 (10)	0,0118±0,00 17 (4)	0,0114±0,0016 (2)	0,0121±0,0016 (7)
Avg. Rank	6,76	6,18	5,59	8,24	<b>3,82</b>	6,65

Tablo 6-14 Çalışma süresi metriği için deneysel sonuçlar

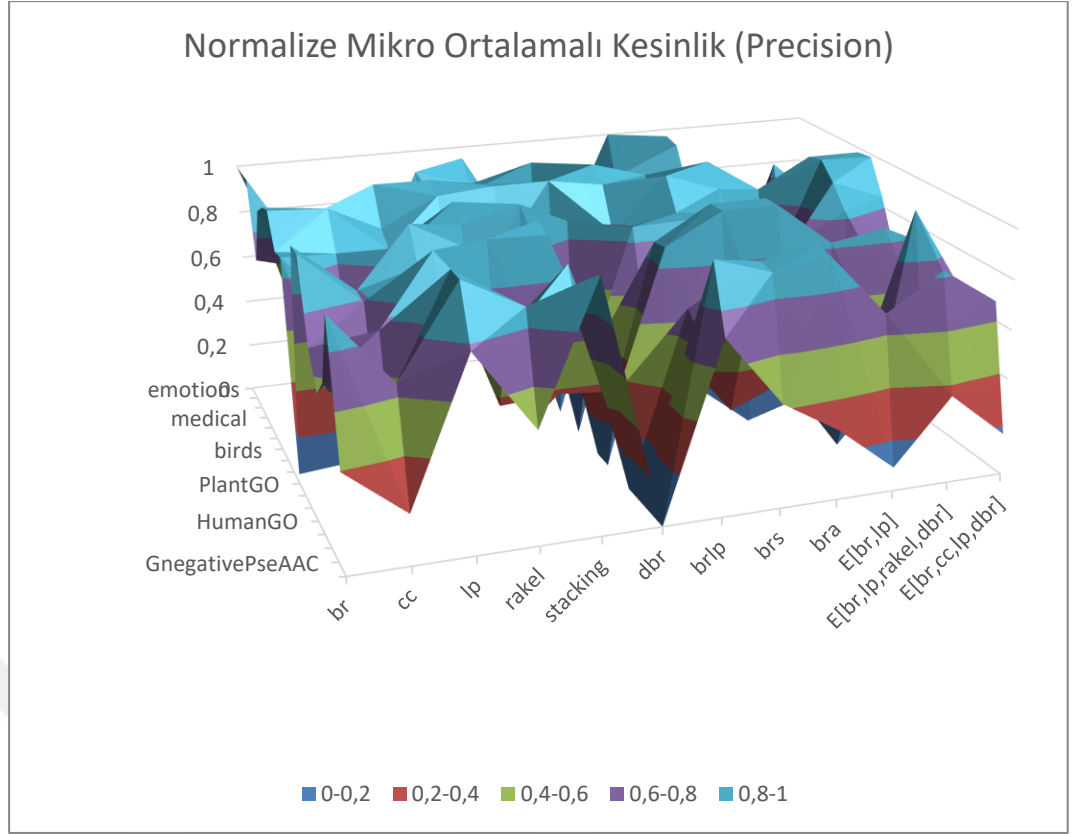
Veri Setleri	br	cc	lp	rakel	stacking	dbr
emotions	00:00:02,1 (2)	00:00:02,3 (3)	00:00:12,2 (6)	00:00:18,4 (9)	00:00:18,9 (10)	00:00:04,9 (5)
yeast	<b>00:00:54,6 (1)</b>	00:01:29,6 (2)	00:08:50,4 (6)	00:10:26,2 (8)	00:24:35,2 (11)	00:03:56,8 (5)
CAL500	<b>00:01:01,5 (1)</b>	00:01:50,6 (2)	00:34:43,2 (9)	00:06:06,5 (5)	00:16:00,3 (7)	00:07:51,4 (6)
medical	00:00:47,2 (3)	00:00:57,3 (4)	00:01:08,9 (5)	00:03:07,6 (9)	00:06:32,5 (12)	00:01:36,7 (7)
scene	00:01:42,0 (7)	00:01:22,2 (6)	<b>00:00:16,3 (1)</b>	00:03:30,3 (10)	00:08:55,3 (12)	00:02:05,3 (8)
genbase	00:00:39,5 (2)	00:00:42,6 (4)	<b>00:00:20,5 (1)</b>	00:03:43,6 (10)	00:06:59,2 (12)	00:01:19,6 (8)
birds	<b>00:00:10,7 (1)</b>	00:10:59,0 (12)	00:03:28,3 (7)	00:01:20,2 (5)	00:02:26,2 (6)	00:00:24,3 (4)
Water-quality	00:00:08,0 (2)	00:00:18,4 (4)	01:54:58,2 (9)	00:00:51,8 (6)	00:01:54,1 (7)	00:00:48,9 (5)
PlantPseAAC	00:01:50,5 (7)	00:01:15,8 (4)	<b>00:00:39,3 (1)</b>	00:06:15,9 (11)	00:10:01,9 (12)	00:02:37,5 (8)
PlantGO	00:00:12,2 (4)	00:00:19,7 (6)	<b>00:00:08,9 (1)</b>	00:00:55,3 (9)	00:02:10,2 (12)	00:00:25,9 (7)
Image	00:00:55,8 (7)	00:00:49,9 (5)	<b>00:00:18,0 (1)</b>	00:02:06,5 (9)	00:06:29,6 (12)	00:01:14,6 (8)
HumanPseAAC	00:07:05,0 (5)	00:05:33,4 (2)	<b>00:03:27,4 (1)</b>	00:31:18,3 (10)	00:57:22,4 (12)	00:11:45,4 (8)
HumanGO	00:02:05,7 (2)	00:03:02,6 (5)	<b>00:01:12,0 (1)</b>	00:09:54,6 (9)	00:21:29,8 (12)	00:04:43,5 (8)
GpositivePseAAC	00:00:03,9 (4)	00:00:03,9 (3)	<b>00:00:02,1 (1)</b>	00:00:08,4 (9)	00:00:47,8 (12)	00:00:08,3 (8)
GpositiveGO	00:00:02,0 (5)	00:00:02,2 (6)	00:00:01,4 (3)	00:00:03,3 (9)	00:00:09,9 (12)	00:00:03,1 (8)
GnegativePseAAC	00:00:24,3 (5)	00:00:22,3 (2)	<b>00:00:13,2 (1)</b>	00:01:53,5 (10)	00:04:00,8 (12)	00:00:43,2 (8)
GnegativeGO	00:00:04,4 (3)	00:00:06,6 (5)	<b>00:00:03,3 (1)</b>	00:00:19,3 (9)	00:00:56,0 (12)	00:00:08,8 (7)
Avg. Rank	3,59	4,41	3,24	8,65	10,88	6,94
Veri Setleri	brlp	brs	bra	E[br,lp]	E[br,lp,rakel,dbr]	E[br,cc,lp,dbr]
emotions	00:00:20,0 (11)	00:00:02,3 (4)	<b>00:00:01,7 (1)</b>	00:00:15,0 (7)	00:00:29,6 (12)	00:00:15,8 (8)
yeast	00:18:09,6 (10)	00:02:07,1 (4)	00:01:55,0 (3)	00:09:51,9 (7)	00:31:16,5 (12)	00:17:47,4 (9)
CAL500	00:56:49,0 (10)	00:02:05,0 (4)	00:01:51,9 (3)	00:33:50,4 (8)	01:26:58,6 (12)	00:59:38,2 (11)
medical	00:02:15,3 (8)	<b>00:00:36,6 (1)</b>	00:00:40,9 (2)	00:01:35,8 (6)	00:05:07,0 (11)	00:03:35,7 (10)
scene	00:00:33,0 (2)	00:00:58,5 (5)	00:00:47,3 (3)	00:00:56,5 (4)	00:04:42,6 (11)	00:02:57,2 (9)
genbase	00:01:17,5 (7)	00:00:40,9 (3)	00:00:44,6 (5)	00:01:06,9 (6)	00:05:01,9 (11)	00:02:53,3 (9)
birds	00:04:30,8 (9)	00:00:18,2 (3)	00:00:14,1 (2)	00:04:12,2 (8)	00:08:11,6 (11)	00:05:39,3 (10)
Water-quality	01:57:17,1 (10)	<b>00:00:06,8 (1)</b>	00:00:09,8 (3)	01:49:39,9 (8)	02:01:11,8 (12)	01:59:20,4 (11)
PlantPseAAC	00:01:19,9 (5)	00:01:10,3 (2)	00:01:10,3 (3)	00:01:40,3 (6)	00:04:54,0 (10)	00:02:48,9 (9)
PlantGO	00:00:26,6 (8)	00:00:10,5 (2)	00:00:11,9 (3)	00:00:19,3 (5)	00:01:30,0 (11)	00:00:58,4 (10)
Image	00:00:36,3 (2)	00:00:38,9 (4)	00:00:36,8 (3)	00:00:51,0 (6)	00:04:01,5 (11)	00:02:37,8 (10)
HumanPseAAC	00:05:43,7 (3)	00:07:18,7 (6)	00:06:53,9 (4)	00:09:36,7 (7)	00:46:02,4 (11)	00:23:31,6 (9)
HumanGO	00:04:06,5 (7)	00:02:19,9 (4)	00:02:12,2 (3)	00:03:23,3 (6)	00:15:20,5 (11)	00:10:00,6 (10)
GpositivePseAAC	00:00:05,3 (6)	00:00:03,8 (2)	00:00:04,2 (5)	00:00:06,3 (7)	00:00:21,3 (11)	00:00:17,2 (10)
GpositiveGO	00:00:02,7 (7)	<b>00:00:01,1 (1)</b>	00:00:01,2 (2)	00:00:01,8 (4)	00:00:04,5 (11)	00:00:04,0 (10)
GnegativePseAAC	00:00:27,6 (6)	00:00:23,3 (4)	00:00:22,8 (3)	00:00:37,8 (7)	00:02:56,7 (11)	00:01:51,2 (9)
GnegativeGO	00:00:10,6 (8)	00:00:05,6 (4)	00:00:04,3 (2)	00:00:07,5 (6)	00:00:39,5 (11)	00:00:25,6 (10)
Avg. Rank	7,00	3,18	<b>2,94</b>	6,35	11,18	9,65



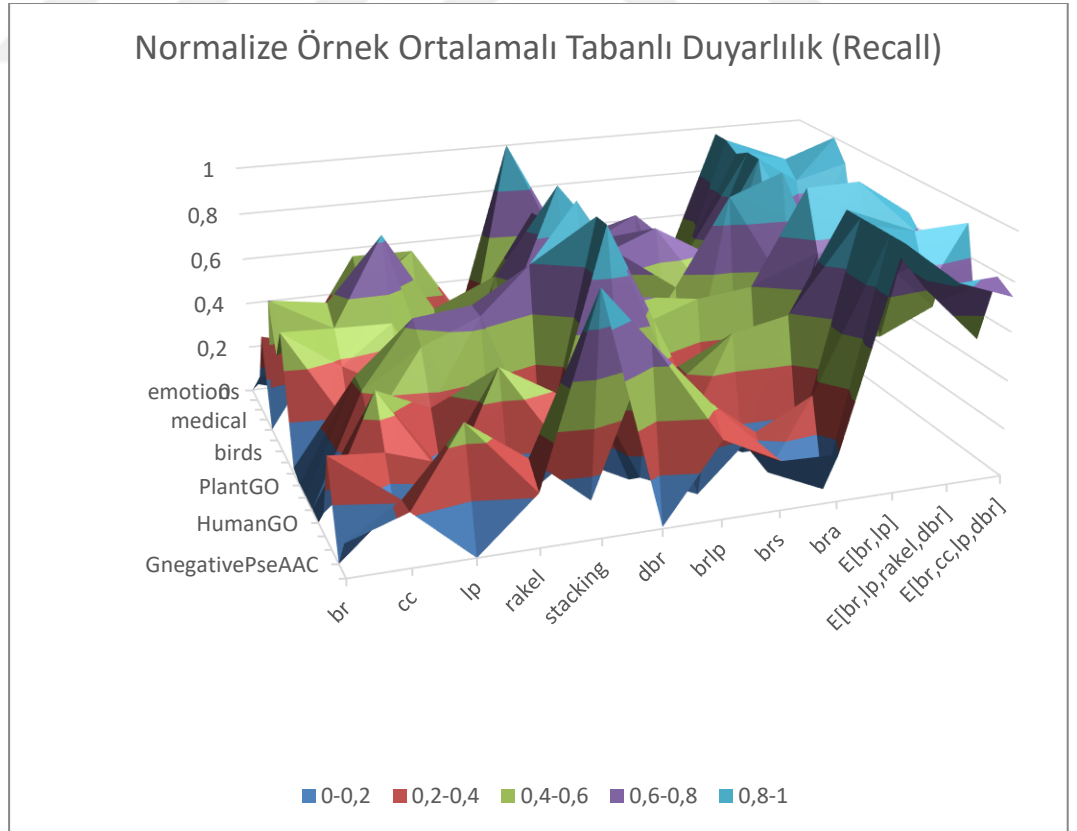
Şekil 6-1 Normalize Örnek Tabanlı Ortalamalı Kesinlik (*Precision*) Grafiği



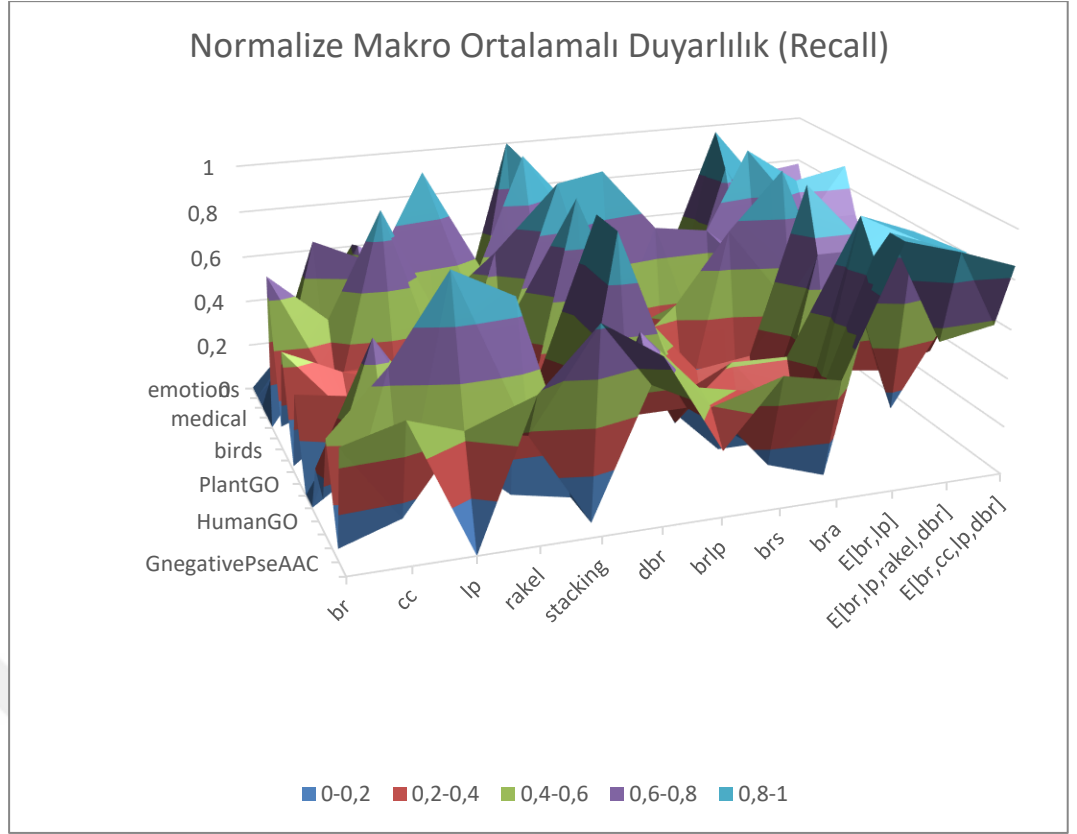
Şekil 6-2 Normalize Makro Ortalamalı Kesinlik (*Precision*) Grafiği



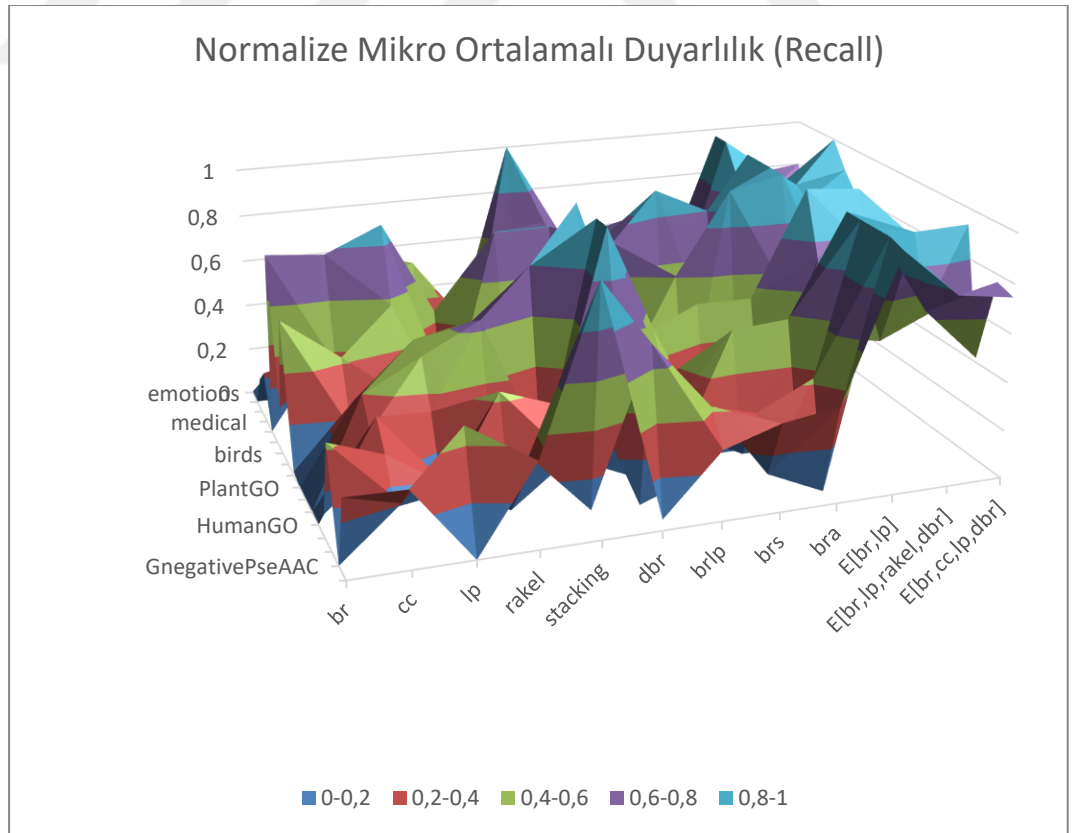
Şekil 6-3 Normalize Mikro Ortalamalı Kesinlik (*Precision*) Grafiği



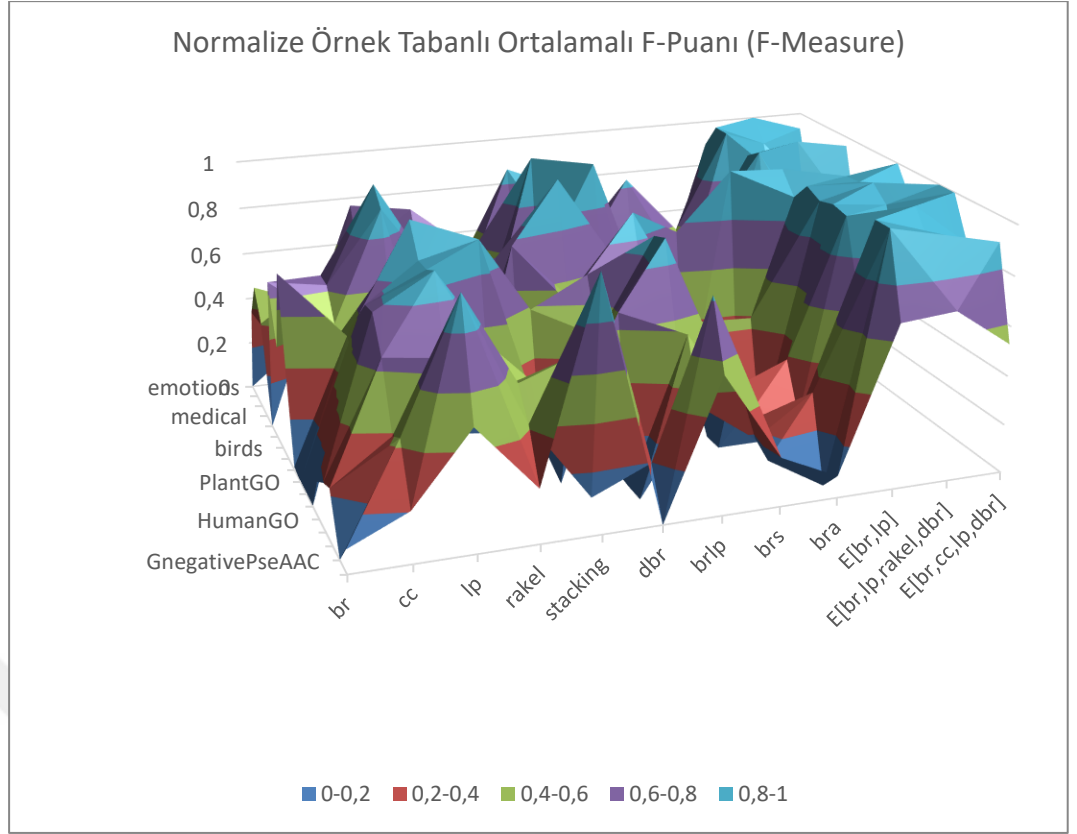
Şekil 6-4 Normalize Örnek Ortalamalı Tabanlı Duyarlılık (*Recall*) Grafiği



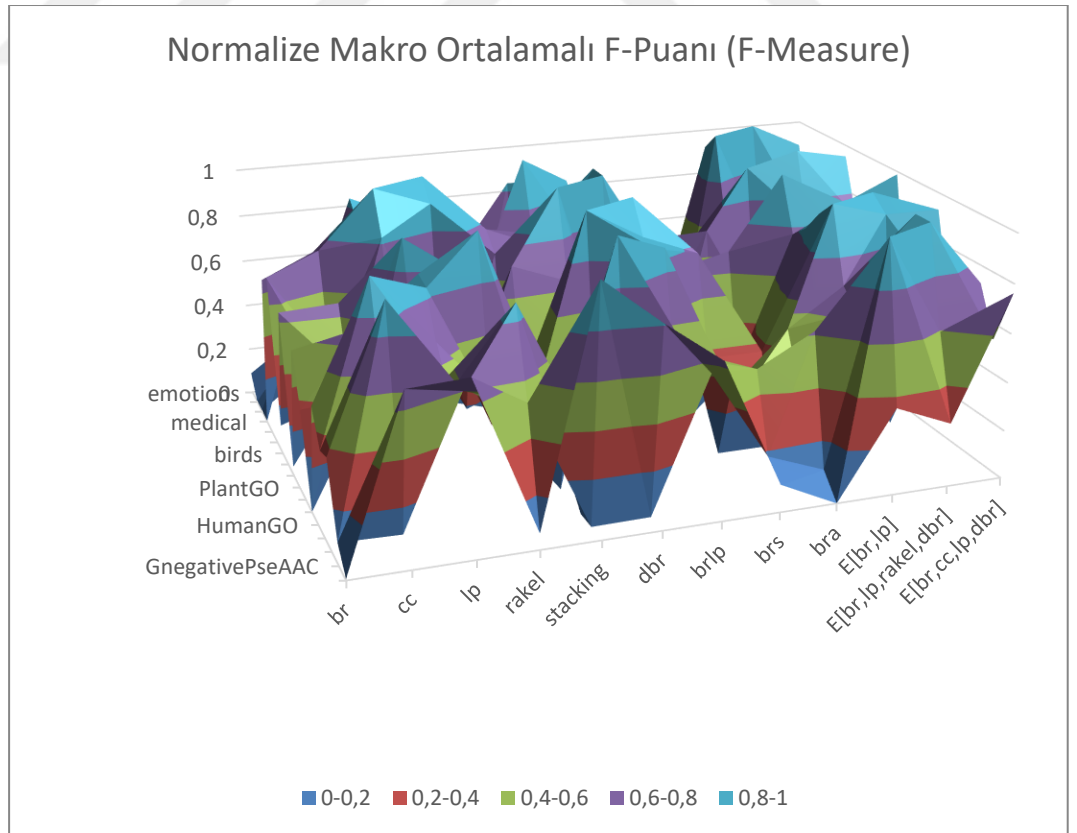
Şekil 6-5 Normalize Makro Ortalamalı Duyarlılık (Recall) Grafiği



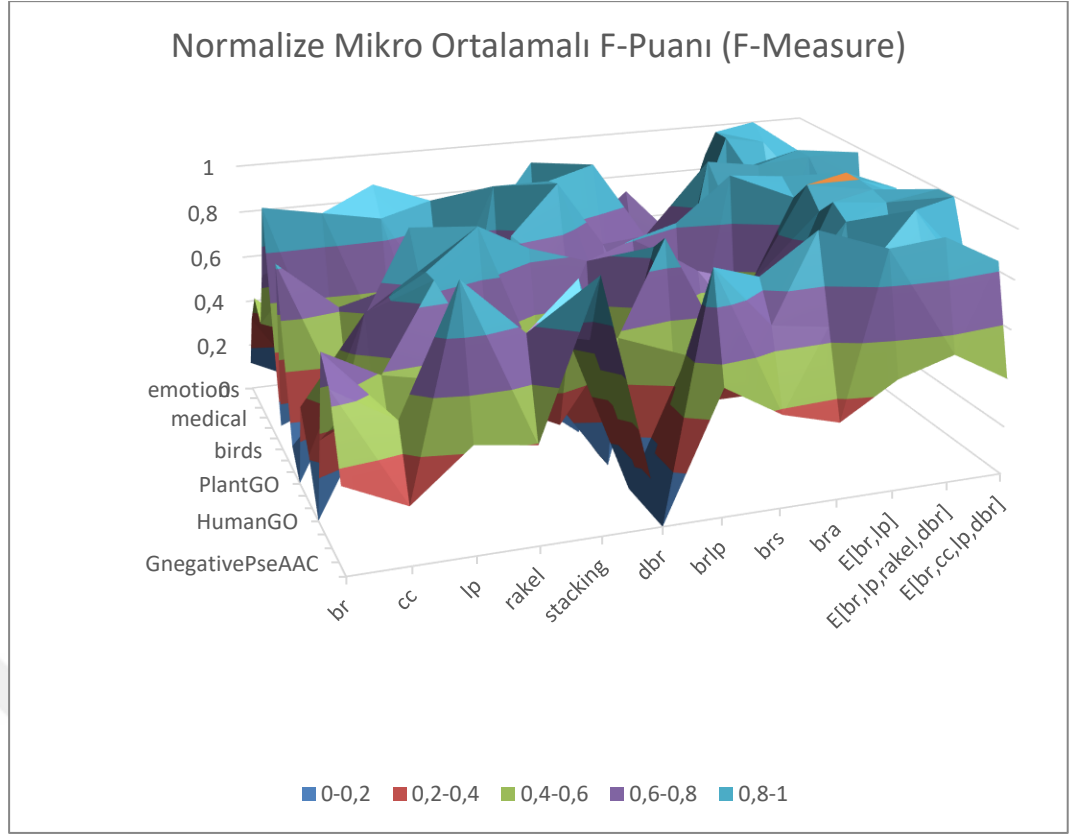
Şekil 6-6 Normalize Mikro Ortalamalı Duyarlılık (Recall) Grafiği



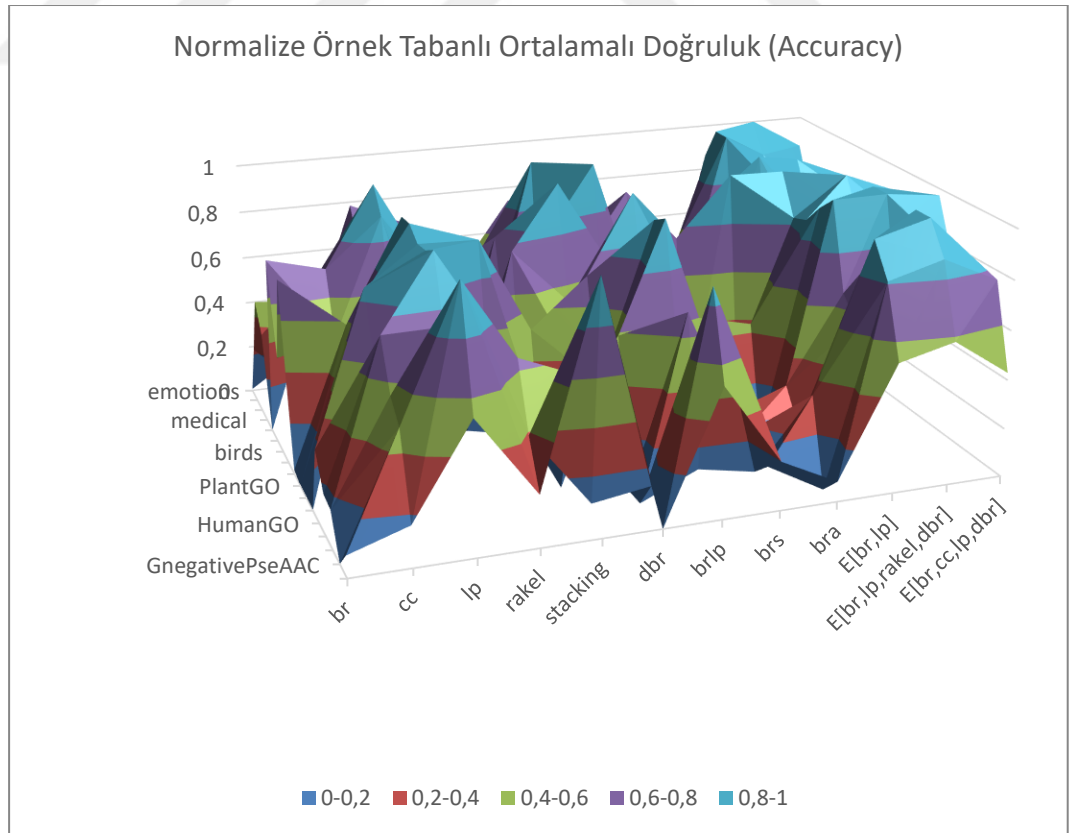
Şekil 6-7 Normalize Örnek Tabanlı Ortalamalı F-Puanı (*F-Measure*) Grafiği



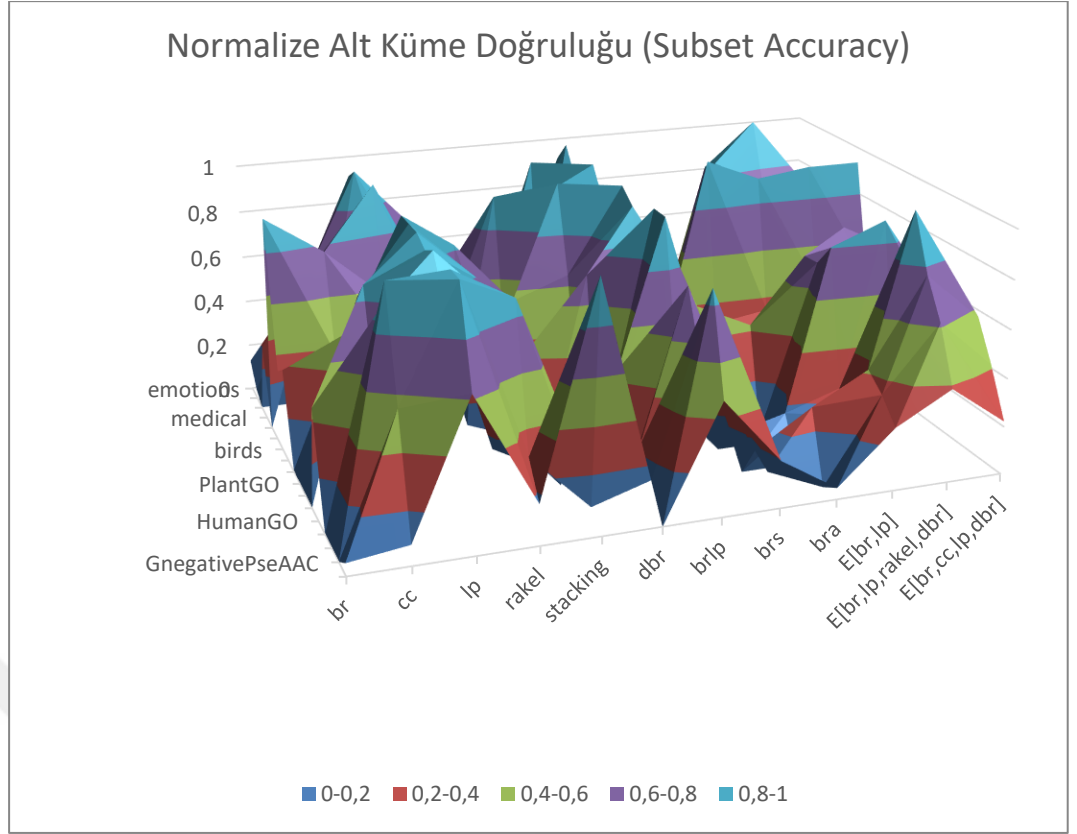
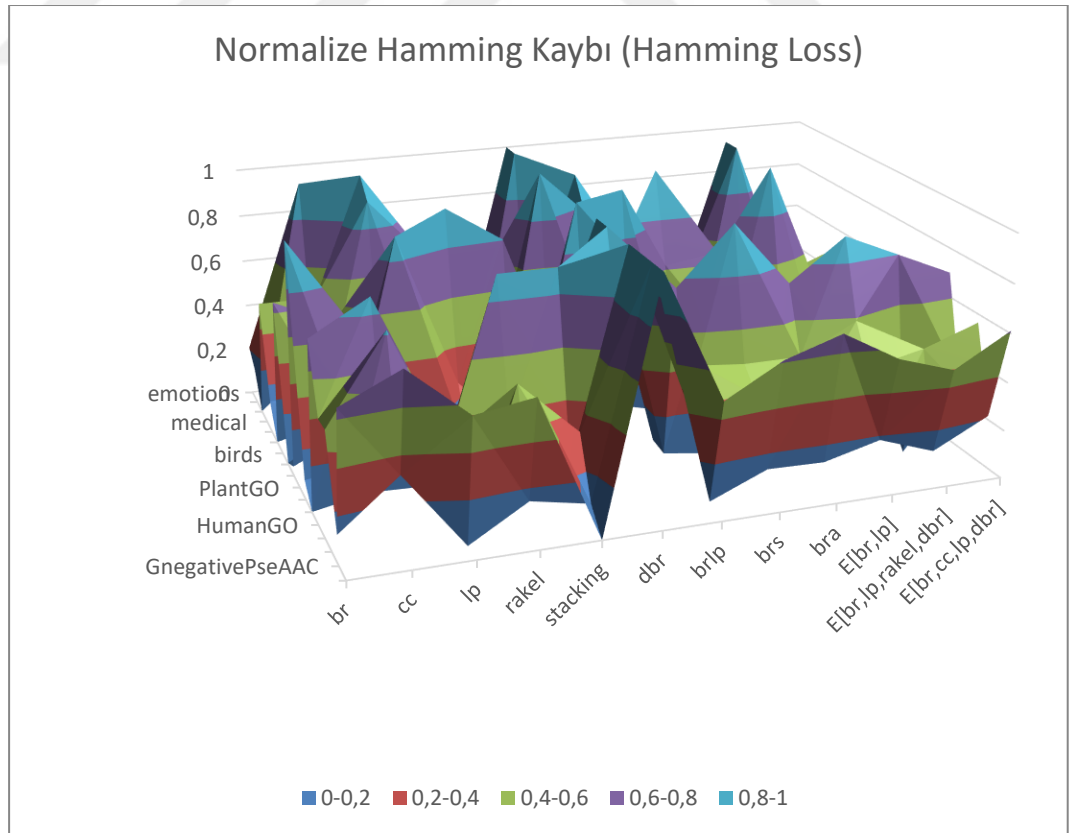
Şekil 6-8 Normalize Makro Ortalamalı F-Puanı (*F-Measure*) Grafiği

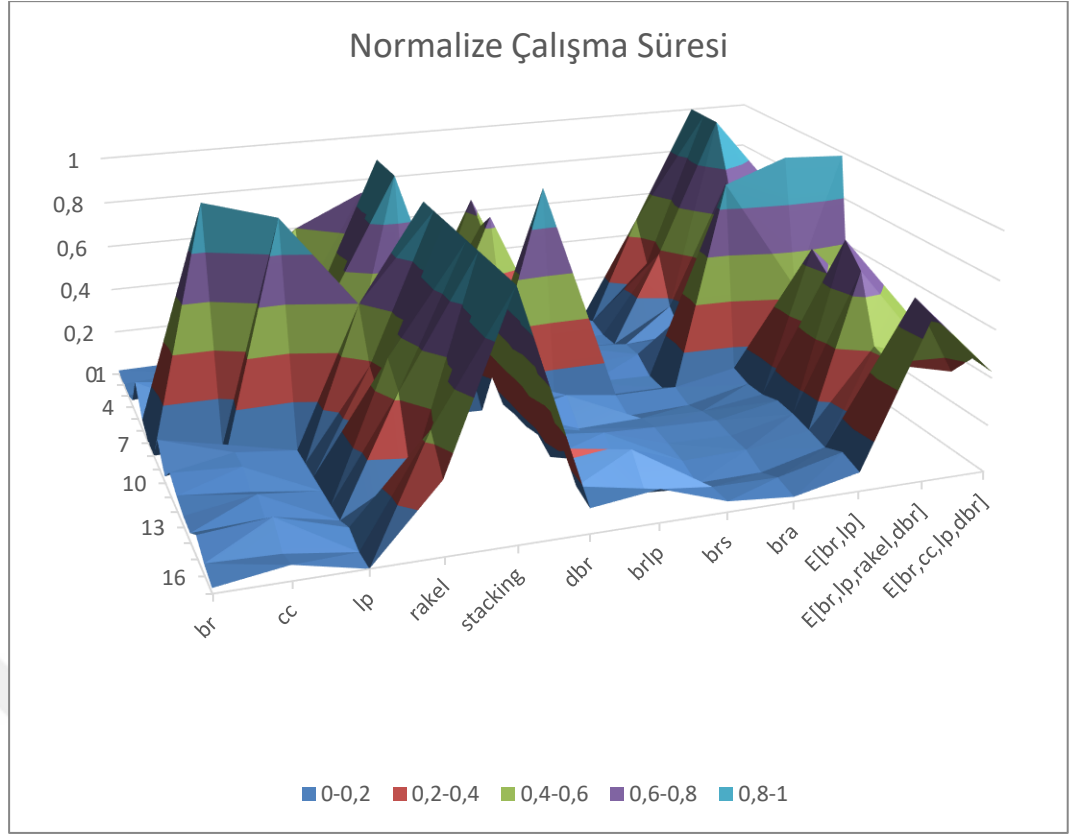


Şekil 6-9 Normalize Mikro Ortalamalı F-Puanı (*F-Measure*) Grafiği



Şekil 6-10 Normalize Örnek Ortalamalı Doğruluk (*Accuracy*) Grafiği

Şekil 6-11 Normalize Alt Küme Doğruluğu (*Subset Accuracy*) GrafiğiŞekil 6-12 Normalize Hamming Kaybı (*Hamming Loss*) Grafiği



Şekil 6-13 Normalize Çalışma Süresi Grafiği

Deneyel sonuçlarda Tablo 6-2 incelendiğinde örnek tabanlı ortalamalı kesinlik (*precision*) metriği için en iyi sonuçların BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yönteminde alındığı görülmektedir. Bu yöntemi sırasıyla LP yöntemi, BR, CC, LP, DBR yöntemlerini bileştiren ensemle yöntem, BRLP yöntemi, BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yöntemi takip etmektedir. Bu durum Şekil 6-1 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde örnek tabanlı ortalama bakımından bu yöntemlerin yaptığı etiket kümesi tahminlerinin doğru olma oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Makro ortalamalı kesinlik (*precision*) metriği için Tablo 6-3 incelendiğinde en iyi sonuçların LP yönteminde alındığı görülmektedir. Bu yöntemi sırasıyla BRLP yöntemi, RAKEL yöntemi, CC yöntemi ve BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi takip etmektedir. Bu durum Şekil 6-2 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde etiket tabanlı ortalama bakımından bu yöntemlerin yaptığı etiket tahminlerinin yani her bir etiket için yapılan tüm tahminlerin doğru olma oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Mikro ortalamalı kesinlik (*precision*) metriği için Tablo 6-4 incelendiğinde en iyi sonuçların BR yönteminde alındığı görülmektedir. Bu yöntemi sırasıyla istifleme (*stacking*) yöntemi, RAKEL yöntemi, BRA yöntemi, LP yöntemi ve BRS yöntemleri takip etmektedir. Bu durum Şekil 6-3 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde bu yöntemlerle her bir örnek etiket çifti için yapılan tahminlerin doğru olma oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Örnek tabanlı ortalamalı duyarlılık (*recall*) metriği için Tablo 6-5 incelendiğinde en iyi sonuçların BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, DBR yöntemi ve BRLP yöntemi takip etmektedir. Bu durum Şekil 6-4 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde örnek tabanlı ortalama bakımından bu yöntemlerin gerçek sonuçları doğru tahmin etme oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Makro ortalamalı duyarlılık (*recall*) metriği için Tablo 6-6 incelendiğinde en iyi sonuçların BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, DBR yöntemi, BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi ve BRLP yöntemi takip etmektedir. Bu durum Şekil 6-5 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde etiket tabanlı ortalama bakımından bu yöntemlerin gerçek sonuçları doğru tahmin etme oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Mikro ortalamalı duyarlılık (*recall*) metriği için Tablo 6-7 incelendiğinde en iyi sonuçların BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, DBR yöntemi, BRLP ve LP yöntemi takip etmektedir. Bu durum Şekil 6-6 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde her bir etiket örnek çifti için yapılan tahminlerde bu yöntemlerin gerçek sonuçları doğru tahmin etme oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Örnek tabanlı ortalamalı F-puanı (*F-measure*) metriği için Tablo 6-8 incelendiğinde en iyi sonuçların BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, LP yöntemi, BRLP yöntemi takip etmektedir. Bu durum Şekil 6-7 grafiğinde de gözlemlenebilmektedir.

Makro ortalamalı F-puanı (*F-measure*) metriği için Tablo 6-9 incelendiğinde en iyi sonuçların BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, LP yöntemi, BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi ve BRLP yöntemi takip etmektedir. Bu durum Şekil 6-8 grafiğinde de gözlemlenebilmektedir.

Mikro ortalamalı F-puanı (*F-measure*) metriği için Tablo 6-10 incelendiğinde en iyi sonuçların BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, LP yöntemi ve istifleme (*stacking*) yöntemi takip etmektedir. Bu durum Şekil 6-9 grafiğinde de gözlemlenebilmektedir.

Örnek tabanlı doğruluk metriği için Tablo 6-11 incelendiğinde en iyi sonuçların BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, LP yöntemi ve BRLP yöntemi takip etmektedir. Bu durum Şekil 6-10 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde bu yöntemlerin tahmin ettiği etiket kümelerinin gerçek etiket kümeleriyle olan benzerlik oranının diğer yöntemlere göre daha yüksek olduğu görülmektedir.

Alt küme doğruluğu (*subset accuracy*) metriği için Tablo 6-12 incelendiğinde en iyi sonuçların LP yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BRLP yöntemi, BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, CC yöntemi takip etmektedir. Bu durum Şekil 6-11 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde bu yöntemlerin tahmin ettiği etiket kümelerinin gerçek etiket kümeleriyle birebir aynı olma durumunun daha yüksek olduğu görülmektedir. LP yönteminin tüm etiketleri tek bir etiket altında birleştirme özelliğinden dolayı bu metrik için bu şekilde bir sonuçla karşılaşmak oldukça normaldir.

Hammin kaybı (*hamming loss*) metriği için Tablo 6-13 incelendiğinde en iyi sonuçların istifleme (*stacking*) ve BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yönteminde elde edildiği görülmektedir. Bu yöntemleri sırasıyla BR yöntemi, LP yöntemi, BRA yöntemi ve RAKEL yöntemi takip etmektedir. Bu durum Şekil 6-12 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde bu yöntemlerin tahmin ettiği etiket kümelerinin gerçek etiket kümeleri ile farklılık oranının diğer yöntemlere göre daha düşük olduğu görülmektedir.

Çalışma süresi için Tablo 6-14 incelendiğinde en iyi sonuçların BRA yönteminde elde edildiği görülmektedir. Bu yöntemi sırasıyla BRS yöntemi, LP yöntemi, BR yöntemi ve CC yöntemi takip etmektedir. Bu durum Şekil 6-13 grafiğinde de gözlemlenebilmektedir. Bu sonuçlar incelendiğinde bu yöntemlerin diğer yöntemlerden daha hızlı bir şekilde sınıflandırma işlemi yaptığı görülmektedir. Çalışma süreleri ölçümü 5 katlamalı çapraz doğrulama sürecinin tamamını kapsamaktadır. 5 katlamalı çapraz doğrulama yönteminin getirdiği rasgelelik ve deneylerin çoklu iş parçacığı (*multi-thread*) şeklinde gerçekleştirilmesinden dolayı çalışma süresi hesaplamasında beklenenden sonuçlara göre küçük farklılıklar görülebilmektedir.

Tablo 6-15 Metriklere göre en iyi performans gösteren yöntemler

Metrik	1.	2.	3.	4.	5.
Örnek Tabanlı Ortalamalı Kesinlik ( <i>Precision</i> )	E[BR, LP, RAKEL, DBR]	LP	E[BR, CC, LP, DBR]	BRLP	E[BR,LP]
Makro Ortalamalı Kesinlik ( <i>Precision</i> )	LP	BRLP	RAKEL	CC	E[BR, LP, RAKEL, DBR]
Mikro Ortalamalı Kesinlik ( <i>Precision</i> )	BR	İstifleme ( <i>Stacking</i> )	RAKEL	BRA	LP / BRS
Örnek Tabanlı Ortalamalı Duyarlılık ( <i>Recall</i> )	E[BR,LP]	E[BR, CC, LP, DBR]	E[BR, LP, RAKEL, DBR]	DBR	BRLP
Makro Ortalamalı Duyarlılık ( <i>Recall</i> )	E[BR,LP]	E[BR, CC, LP, DBR]	DBR	E[BR, LP, RAKEL, DBR]	BRLP
Mikro Ortalamalı Duyarlılık ( <i>Recall</i> )	E[BR,LP]	E[BR, CC, LP, DBR]	E[BR, LP, RAKEL, DBR]	DBR	BRLP / LP
Örnek Tabanlı Ortalamalı F-Puanı ( <i>F-Measure</i> )	E[BR,LP]	E[BR, LP, RAKEL, DBR]	E[BR, CC, LP, DBR]	LP	BRLP
Makro Ortalamalı F-Puanı ( <i>F-Measure</i> )	E[BR,LP]	E[BR, CC, LP, DBR]	LP	E[BR, LP, RAKEL, DBR]	BRLP
Mikro Ortalamalı F-puanı ( <i>F-Measure</i> )	E[BR, LP, RAKEL, DBR]	E[BR,LP]	E[BR, CC, LP, DBR]	LP	İstifleme ( <i>Stacking</i> )
Örnek Tabanlı Ortalamalı Doğruluk	E[BR, LP, RAKEL, DBR]	E[BR,LP]	E[BR, CC, LP, DBR]	LP	BRLP
Alt Küme Doğruluğu ( <i>Subset Accuracy</i> )	LP	BRLP	E[BR, LP, RAKEL, DBR]	E[BR, CC, LP, DBR]	CC
Hamming Kaybı ( <i>Hamming Loss</i> )	İstifleme ( <i>Stacking</i> ) / E[BR, LP, RAKEL, DBR]	BR	LP	BRA	RAKEL
Çalışma Süresi	BRA	BRS	LP	BR	CC

Her bir değerlendirme metriği için en iyi beş yöntem Tablo 6-15 üzerinde listelenmiştir. Tablo incelendiğinde genel olarak bu çalışma kapsamında ortaya koyulan topluluk öğrenmesi yöntemlerinin diğer yöntemlere göre daha iyi performans gösterdiği görülmektedir. Tablodaki sıralamada BR, LP, RAKEL, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi dikkat çekmektedir bu yöntem hem hamming kaybı hem örnek tabanlı ortalama doğruluk hem de F-puanı metriklerinde yüksek derece elde ederek diğer yöntemleri geride bırakmıştır. Bir diğer göze çarpan BR ve LP yöntemlerini birleştiren topluluk öğrenmesi yöntemi de F-puanı ve örnek tabanlı ortalama doğruluk metriklerinde yüksek derecelere elde etmiştir. BR, CC, LP, DBR yöntemlerini birleştiren topluluk öğrenmesi yöntemi, BRLP yöntemi ve LP yöntemi de birçok metrik için ilk 5 dereceye girdiği gözlemlenmiştir. Çalışma süreleri incelendiğinde karmaşıklığı düşük ve daha az sayıda model oluşturan yöntemlerin daha hızlı çalıştığı gözlemlenmiştir.

## 7 TARTIŞMA VE SONUÇ

Bu tez çalışmasında çok etiketli sınıflandırma problem dönüşüm yöntemlerinin incelenmesi, karşılaştırılması ve ikili alaka düzeyi (*binary relevance*) yönteminin bir dezavantajı olan etiketler arası ilişkileri göz ardı etme durumunu ortadan kaldıran ve performans artışı sağlayan yöntem geliştirmeleri yapmak amaçlanmıştır. Bu kapsamda var olan çok etiketli sınıflandırma problem dönüşüm metotları araştırılmış, çalışma şekilleri incelenmiştir. İkili alaka düzeyi (*binary relevance*) yöntemi için etiketler arası ilişkileri ortaya çıkararak ikili alaka düzeyi (*binary relevance*) yöntemini destekleyecek yöntem iyileştirmeleri ortaya konulmuştur. Ortaya koyulan yöntem iyileştirmelerinde temel amaç ikili alaka düzeyi (*binary relevance*) yönteminin dezavantajı olan etiketler arası ilişkileri görmezden gelme durumu ortadan kaldırmak olmuştur. Bu kapsamda 4 temel iyileştirme ortaya konulmuştur.

Binary relevance support iyileştirmesi ikili alaka düzeyi (*binary relevance*) yönteminin yanına etiketler arası ilişkileri frekans sayımı yoluyla bir destek modeli oluşturmaktadır. Bu destek modelinin oluşturulmasında etiketlerin birlikte bulunma sayıları ve etiketlerin veri setinde görülme sayıları kullanılmıştır. Eğitim sürecinde ikili alaka düzeyi (*binary relevance*) modelinin yanında destek modeli oluşturulmaktadır ve sınıflandırma sürecinde ilk olarak ikili alaka düzeyi (*binary relevance*) çıktısı elde edilmekte ve ardından bu çıktı destek modelinde kullanılarak çıkarım kümesi genişletilmektedir.

Binary relevance association iyileştirmesi ikili alaka düzeyi (*binary relevance*) yönteminin yanında bir birliktelik kural çıkarımı (*association rule mining*) yöntemi olan *FPGrowth* yöntemini kullanmaktadır. *FPGrowth* algoritması ile etiketler arası ilişkiler belirlenmekte ve ikili alaka düzeyi (*binary*

*relevance*) çıkarımları bu ilişkiler üzerinden yapılan oylama yoluyla genişletilmekte veya daraltılmaktadır.

BRLP iyileştirmesi ikili alaka düzeyi (*binary relevance*) yönteminin veri setinin özellik kümesini *label powerset* yönteminde oluşturulan etiketler ile genişletmektedir ve bu şekilde ikili alaka düzeyi (*binary relevance*) veri setin içerisine etiketler arası ilişkileri temsil eden bir özellik eklenmektedir. Bu yöntemde hem bir ikili alaka düzeyi (*binary relevance*) hem de bir *label powerset* modeli oluşturulmaktadır fakat *label powerset* çıkarımları sadece özellik uzayını genişletmek için kullanılmakta olup ikili alaka düzeyi (*binary relevance*) çıkarımları son çıkarım olarak kullanılmaktadır.

Topluluk öğrenmesi yöntemleri kapsamında ikili alaka düzeyi (*binary relevance*) yöntemi ile diğer yöntemleri birlikte kullanan ve son çıkarımları oylama yoluyla oluşturan yöntemler ortaya konulmuştur. Birçok farklı topluluk öğrenmesi kombinasyonu denenmiş ve en iyi sonuç veren üç yöntem ana deneylere dahil edilmiştir.

Bu yöntem iyileştirmeleri var olan yöntemlerle deneysel olarak karşılaştırılmıştır. Bu deneysel karşılaştırmalar 17 adet veri setinin ortaya koyulan yöntemler ve mevcut yöntemler ile çalıştırılmasıyla gerçekleştirilmiştir. Deneyler kapsamında 13 adet metrik için sonuçlar üretilmiştir ve deney sonuçları değerlendirilmiştir.

Deney sonuçları incelendiğinde ortaya koyulan topluluk öğrenmesi yöntemlerin diğer problem dönüşüm yöntemlerini geride bıraktığı gözlemlenmiştir. BRLP yönteminin ise literatürdeki diğer yöntemlerle rekabet edebilecek düzeyde olduğu gözlemlenmiştir. BRS ve BRA yöntemleri deneyler kapsamında performans bakımından yüksek dereceler elde edemese de hızlı bir şekilde model eğitimi ve sınıflandırma yapabildikleri gözlemlenmiştir.

İleriki çalışmalarda ortaya koyulan yöntemlerin hem performansının artması hem de çalışma zamanının azalmasını sağlamak amacıyla öznitelik seçimi veya etiket seçimi yöntemleri ile geliştirmeler yapılması mümkündür. Bu yöntemler çok etiketli sınıflandırma probleminde uyarlanarak bu yöntemlerin model performansı üzerindeki etkileri deneysel olarak incelenebilir.

Farklı topluluk öğrenmesi teknikleri çok etiketli sınıflandırmaya uyarlanarak kullanılabilir ve bu tekniklerin performans üzerindeki etkisi deneysel olarak incelenebilir.

## KAYNAKLAR DİZİNİ

- Alazaidah, Raed; Thabtah, Fadi and Al-Radaideh, Qasem. 2015. "A Multi-Label Classification Approach Based on Correlations Among Labels." *International Journal of Advanced Computer Science and Applications*6: 52–9.
- Blockeel, Hendrik; Džeroski, Sašo and Grbović, Jasna. 2004. *Simultaneous Prediction of Multiple Chemical Parameters of River Water Quality with TILDE*.
- Boutell, Matthew R et al. 2004. "Learning multi-label scene classification." *Pattern Recognition* no. 937: 1757–71.
- Briggs, Forrest et al. 2013. "The 9th annual MLSP competition: New methods for acoustic classification of multiple simultaneous bird species in a noisy environment." In *2013 IEEE International Workshop on Machine Learning for Signal Processing (MLSP)* 1–8. 2013 IEEE International Workshop on Machine Learning for Signal Processing (MLSP).
- Chen, Yan-Nan et al. 2021. "An efficient stacking model with label selection for multi-label classification." *Applied Intelligence* no. 151: 308–25.
- Cherman, Everton Alvares; Monard, Maria Carolina and Metz, Jean. 2011. "Multi-label Problem Transformation Methods: a Case Study." *CLEI ELECTRONIC JOURNAL* no. 114: 10.
- Clare, Amanda and King, Ross D. 2001. "Knowledge Discovery in Multi-label Phenotype Data." In *Principles of Data Mining and Knowledge Discovery Lecture Notes in Computer Science* ed. Luc De Raedt and Arno Siebes, 42–53. Berlin, Heidelberg: Springer.
- Diplaris, Sotiris et al. 2005. *Protein Classification with Multiple Algorithms*.
- Elisseeff, André and Weston, Jason. 2001. "A Kernel Method for Multi-Labelled Classification." In *In Advances in Neural Information Processing Systems 14* 681–7. MIT Press.
- Frank, Eibe and Witten, Ian H. 1998. "Generating Accurate Rule Sets Without Global Optimization." In *In: Proc. of the 15th Int. Conference on Machine Learning* Morgan Kaufmann.
- Gururani, Siddharth; Sharma, Mohit and Lerch, Alexander. 2019. *An Attention Mechanism for Musical Instrument Recognition*.
- Jain, Vineet and Kambli, Mayur. 2020. "Categorizing Multilingual Customer Feedback."
- Katakis, Ioannis; Tsoumakas, Grigorios and Vlahavas, Ioannis. 2008. "Multilabel text classification for automated tag suggestion." In *In: Proceedings of the ECML/PKDD-08 Workshop on Discovery Challenge*.

- Kotsiantis, SB; Zaharakis, ID and Pintelas, PE. 2006. "Machine learning: a review of classification and combining techniques." *Artificial Intelligence Review* no. 326: 159–90.
- Li, Yu-Kun and Zhang, Min-Ling. 2014. *Enhancing Binary Relevance for Multi-label Learning with Controlled Label Correlations Exploitation*.
- Luaces, Oscar et al. 2012. "Binary relevance efficacy for multilabel classification." *Progress in Artificial Intelligence* no. 41: 303–13.
- Mahesh, Batta. 2019. *Machine Learning Algorithms -A Review*.
- Montañes, Elena et al. 2014. "Dependent binary relevance models for multi-label classification." *Pattern Recognition* no. 347: 1494–508.
- Pestian, John P et al. 2007. "A shared task involving multi-label classification of clinical free text." In *Proceedings of the Workshop on BioNLP 2007: Biological, Translational, and Clinical Language Processing BioNLP '07* 97–104. USA: Association for Computational Linguistics.
- Read, Jesse et al. 2009. "Classifier Chains for Multi-label Classification." In *Machine Learning and Knowledge Discovery in Databases Lecture Notes in Computer Science* ed. Wray Buntine et al., 254–69. Berlin, Heidelberg: Springer.
- Rivolli, Adriano; Parker, Larissa and de Carvalho, Andre. 2017. *Food Truck Recommendation Using Multi-label Classification*.
- Schapire, Robert E and Singer, Yoram. 2000. "BoosTexter: A Boosting-based System for Text Categorization." *Machine Learning* no. 239: 135–68.
- Tenenboim, Lena; Rokach, Lior and Shapira, Bracha. 2010. *Identification of label dependencies for multi-label classification*.
- Trochidis, Konstantinos et al. 2008. *Multi-label classification of music into emotions*.
- Tsoumakas, Grigorios; Dimou, Anastasios; et al. 2009. "Correlation-based pruning of stacked binary relevance models for multi-label learning." In *MLD 2009*.
- Tsoumakas, Grigorios and Katakis, Ioannis. 2007. "Multi-Label Classification: An Overview." *International Journal of Data Warehousing and Mining (IJDWM)* no. 33: 1–13.
- Tsoumakas, Grigorios and Vlahavas, I. 2007. *Random k -Labelsets: An Ensemble Method for Multilabel Classification*.
- Tsoumakas, Grigorios; Zang, Min-Ling and Zhou, Zhi-Hua. 2009. "Learning from Multi-Label Data."

- Turnbull, D et al. 2008. "Semantic Annotation and Retrieval of Music and Sound Effects." *IEEE Transactions on Audio, Speech, and Language Processing*.
- Wolpert, David. 1992. "Stacked Generalization." *Neural Networks*5: 241–59.
- Xu, Jianhua et al. 2016. "A multi-label feature extraction algorithm via maximizing feature variance and feature-label dependence simultaneously." *Knowledge-Based Systems*98: 172–84.
- Zhang, Min-Ling et al. 2017. "Binary relevance for multi-label learning: an overview." *Frontiers of Computer Science*12.
- Zhang, Min-Ling and Zhou, Zhi-Hua. 2005. "A k-nearest neighbor based algorithm for multi-label classification." In *2005 IEEE International Conference on Granular Computing* 718-721 Vol. 2. 2005 IEEE International Conference on Granular Computing.
- . 2007. "ML-KNN: A lazy learning approach to multi-label learning." *Pattern Recognition* no. 740: 2038–48.

## TEŐEKKÜR

Öncelikle yüksek lisans öğrenimim ve tez çalışmam boyunca danışmanlığımı yapan tecrübesiyle bana yol gösteren ve yardımcı olan Sayın Prof. Dr. M. Serdar Korukođlu'na ve tez çalışmam boyunca ikinci danışmanım olarak tecrübesi ve önerileriyle büyük katkı sağlayan Sayın Doç. Dr. Aytuđ ONAN' a teşekkürü borç bilirim. Ayrıca yüksek lisans öğrenimim boyunca bilgi birikimimin gelişmesine destek olan hocalarıma, hiçbir zaman desteklerini esirgemeyen ve yüksek lisans öğrenimi almam için beni teşvik eden tüm aile fertlerime ve arkadaşlarıma teşekkür ederim.

20/08/2021

Ahmet Gürbüz

## **ÖZGEÇMİŞ**

Ahmet Gürbüz

### **EĞİTİM**

Yüksek Lisans, Ege Üniversitesi, Bilgisayar Mühendisliği, 2019 – günümüz

Lisans, Celal Bayar Üniversitesi, Yazılım Mühendisliği, 2014-2018

### **DENEYİM**

Ege Üniversitesi – Araştırma Görevlisi, İzmir - Türkiye, 04/2020 – günümüz

Freelance Yazılım Geliştiricisi, Aydın - Türkiye, 09/2018 – 04/2020

Kentkart – Yazılım Stajyeri, İzmir - Türkiye, 03/2018 – 08/2018