

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI TARIM İÇİN DERİN ÖĞRENME İLE YABANI OT
VE MAHSUL SINIFLANDIRILMASI

ŞEYDANUR EKİNCİ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2022

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKILLI TARIM İÇİN DERİN
ÖĞRENME İLE YABANI OT VE MAHSUL
SINIFLANDIRILMASI

ŞEYDANUR EKİNCİ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
PROF. DR. ERCHAN APTOULA

GEBZE
2022

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

WEED AND CROP CLASSIFICATION
WITH DEEP LEARNING FOR
PRECISION AGRICULTURE

ŞEYDANUR EKİNCİ
A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

THESIS SUPERVISOR
PROF. DR. ERCHAN APTOULA

GEBZE
2022



YÜKSEK LİSANS JÜRİ ONAY FORMU

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 07/02/2022 tarih ve 2022 /08 sayılı kararıyla oluşturulan jüri tarafından 13/05/2022 tarihinde tez savunma sınavı yapılan Şeydanur EKİNCİ'nin tez çalışması Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI)

: Prof. Dr. Erchan Aptoula

ÜYE

: Prof. Dr. Yusuf Sinan Akgül

ÜYE

: Doç. Dr. Ayşe Betül Oktay

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

İMZA/MÜHÜR

ÖZET

Tarım arazilerinde sıkça kullanılan agrokimyasalların biyolojik çeşitlilik, insanlar ve çevre üzerinde birçok çeşitli yan etkisi vardır. Sürdürülebilir tarım bünyesinde agrokimyasalların kullanımının azaltılması amaçlanmaktadır. Tarım arazilerinde kullanılan robotların bu hedef doğrultusunda hassas bir şekilde mahsul ve yabancı otu ayırt etmesi önemli bir ihtiyaçtır. Fakat her mahsulün kendine özgü toprak ve hava koşullarında büyümesinden kaynaklanan ekolojik değişiklikler, yabancı ot ve mahsullerin yetiştirme kademelerinde farklı görünümlere sahip olması, mahsul yakınında yetişen yabancı otlardan dolayı bitkilerin üst üste gelmesi, yabancı ot ve mahsul türlerinden kaynaklanan değişiklikler gibi birçok farklı durum problemi çözülmesi güç hale getirmektedir.

Bu tez kapsamında farklı yaklaşımlar ile yabancı ot ve mahsul sınıflandırma görevi ele alınmıştır. Yaklaşımlar iki grupta sınıflandırılmıştır. İlk grupta referans alınan gözetimsiz alan uyarlaması yaklaşımları ile olasılık dağılım sapma ölçüleri birlikte kullanılarak tür çeşitliliğinden kaynaklanan zorluk ele alınmıştır. İkinci gruptaki yaklaşımlarda ise morfolojik ağ mimarilerinin yabancı ot ve mahsul sınıflandırma görevindeki etkisi incelenmiştir.

Bu tez için yapılan deneylerde şeker pancarı, havuç ve soğan mahsullerinin yetiştiği tarım alanlarından toplanmış görüntülerin bulunduğu veri kümeleri kullanılmıştır. Ele alınan yaklaşımlar ile bu ana kadar görülmeyen yabancı ot ve mahsul cinslerinin sınıflandırılma işleminin genelleştirilme başarımı ve farklı ağ mimarilerinin yabancı ot ve mahsul sınıflandırma görevindeki başarısı karşılaştırılmıştır.

Anahtar Kelimeler: Anlamsal bölütleme, alan uyarlaması, morfolojik ağlar, zirai otomasyon.

SUMMARY

Agrochemicals, which are constantly used in agricultural lands, have many adverse effects on biodiversity, humans and the environment. It is aimed to reduce the use of agrochemicals in sustainable agriculture. In line with this goal, it is an important need for robots used in agricultural lands to distinguish crops and weeds precisely. However, many different situation problems such as ecological changes caused by the growth of each crop in its unique soil and weather conditions, different appearances of weeds and crops at growth stages, overlapping of plants due to weeds growing near the crop, changes due to weeds and crop types render it difficult to solve.

In this thesis, the weed and crop classification task is tackled with different approaches classified into two groups. In the first group, the difficulty arising from species diversity was addressed by using unsupervised domain adaptation approaches and probability distribution divergence measures together. In the second group, the effect of morphological network architectures on the weed and crop classification task was investigated.

Datasets with images collected from agricultural fields where sugar beet, carrot and onion crops grow were used in the experiments for this thesis. With the approaches discussed, the generalization performance of the classification process of hitherto unseen weeds and crops and the success of different network architectures in the task of crop and weed classification were compared.

Key Words: Semantic segmentation, domain adaptation, morphological networks, farming automation.

TEŞEKKÜR

Başta, yüksek lisans eğitimimde ve akademik hayatımda desteğini ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu çalışmanın oluşmasının yolunu açan sayın danışmanım Prof. Dr. Erchan APTOULA'ya teşekkür ederim. Ayrıca bilgi birikimleriyle, her türlü yardımlarıyla bizi her daim ileriye taşıyan, öğreten saygıdeğer hocalarıma teşekkür ediyorum.

Bu çalışmaya Türkiye Bilimler Akademisi'nin GEBİP programı tarafından sağlanan destekleri için teşekkürlerimi sunarım.

Bugünlere gelebilmemi sağlayan, bana her daim yol gösteren, hep yanımda olan sevgili babam Alparslan EKİNCİ'ye, annem Farise EKİNCİ'ye, her daim bana güç veren biricik kardeşlerim Hülya EKİNCİ ve Talha EKİNCİ'ye teşekkürlerimi sunarım.

Zor zamanlarımda hep yanımda olan lisans, yüksek lisans ve iş hayatımda desteklerini esirgemeyen can dostum Hatice Kübra TELOĞLU'na çok teşekkür ediyorum.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
SİMGELER ve KISALTMALAR DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
TABLOLAR DİZİNİ	xii
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	2
1.1. Tezin Düzeni	3
2. LİTERATÜR TARAMASI	4
2.1. Anlamsal Bölütleme	4
2.2. Alan Uyarlaması	5
2.3. Morfolojik Filtrelere Dayalı Ağlar	7
2.4. Yabani Ot ve Mahsul Sınıflandırma	7
3. ALAN UYARLAMASI YAKLAŞIMLARININ YABANI OT VE MAHSUL SINIFLANDIRMAYA UYGULANMASI	11
3.1. Yaklaşımlar	11
3.1.1. MinEnt Ağ Mimarisi	12
3.1.2. AdvEnt Ağ Mimarisi	13
3.1.3. Farklılık Ölçümleri ile AdvEnt Ağ Mimarisi	15
3.1.4. Anlamsal Bölütleme Ağ Mimarisi	17
3.1.4.1. Girdi	17
3.1.4.2. SegNet	18
3.1.4.3. Sınıf Ağırlığı	19
3.1.4.4. Çıktı	20
3.2.2. Başarım Ölçütleri	24
3.2.3. Deney Ayarları	24
3.2.4. Sonuçlar	26

3.2.5. Tartışma	28
3.2.6. Parametre Analizi	29
4. MORFOLOJİK YAKLAŞIMLARIN YABANİ OT VE MAHSUL SINIFLANDIRMAYA UYGULANMASI	30
4.1. Yaklaşımlar	30
4.2. Deneyler	36
4.2.1. Veri Kümeleri	36
4.2.2. Başarım Ölçütleri	36
4.2.3. Deney Ayarları	36
4.2.4. Sonuçlar	37
4.2.5. Tartışma	41
4.2.6. Parametre Analizi	42
5. VARGİ	45
KAYNAKLAR	47
ÖZGEÇMİŞ	54
EKLER	55

SİMGELER VE KISALTMALAR DİZİNİ

<u>Simgeler ve</u>	<u>Açıklamalar</u>
<u>Kısaltmalar</u>	
$\ominus$	: Aşınım
$\oplus$	: Genleşme
$\odot$	: Piksel bazında çarpma
ESA	: Evrişimli Sinir Ağları
IoU	: Intersection over Union
JS	: Jensen-Shannon
KL	: Kullback-Leibler
mIoU	: Mean Intersection over Union
MOT	: Maksimum Ortalama Tutarsızlık

ŞEKİLLER DİZİNİ

<u>Sekil No:</u>	<u>Sayfa</u>
3.1: MinEnt mimarisi.	13
3.2: AdvEnt mimarisi.	15
3.3: AdvEnt_Div mimarisi.	17
3.4: Referans alınan SegNet mimarisi.	18
3.5: SegNet'te kullanılan maksimum havuzlama ve üst örnekleme örneği.	19
3.6: Ayırıştırıcı ağ mimarisi.	20
3.7: SB16 veri kümesinden örnekler.	21
3.8: CA17 veri kümesinden örnekler.	22
3.9: ON17 veri kümesinden örnekler.	23
3.10: Şeker pancarı görüntüsü için yöntem tahminleri.	28
4.1: Morfolojik sinir ağ mimarileri.	32
4.2: SegNet ve benzer yapıya sahip morfolojik sinir ağ mimarileri.	34
4.3: Morfolojik yaklaşım tahminleri.	39
4.4: Morfolojik sinir ağları ve evrişimli sinir ağı tahminleri.	41
4.5: MorphoN_Seg1 filtre grupları.	43

TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
3.1: Gözetimsiz Alan Uyarlaması Yaklaşımındaki Görüntü Sayıları.	25
3.2: Alan Uyarlaması Yaklaşımları Deney 1 Sonuçları.	26
3.3: Alan Uyarlaması Yaklaşımları Deney Seti 2 / Deney Seti 3 Sonuçları.	27
3.4: Katsayı Deneyleri Kappa Sonuçları.	29
3.5: Katsayı Deneyleri mIoU (%) Sonuçları.	29
4.1: Morfolojik Yaklaşımlarda Kullanılan Görüntü Sayıları.	37
4.2: Morfolojik Yaklaşımların Deney Sonuçları.	38
4.3: Morfolojik Sinir Ağları ve Evrişimli Sinir Ağı Deney Sonuçları.	40
4.4: Açma ve Kapama İşlemlerinde Uygulanan Filtre Boyutları.	43
4.5: Filtre Boyutları Deney Sonuçları.	44

1. GİRİŞ

Şimdilerde mahsul üretimi için sıklıkla böcek ilacı (herbisit) ve diğer zirai kimyasalların kullanımı yaygındır. Fakat bu tür kimyasalların biyolojik çeşitlilik ve çevre üzerinde yan etkileri bulunmaktadır. Bu sebeple son senelerde sürdürülebilir ve verimli tarıma olan ilgi artış göstermiştir [1]. Hatta Birleşmiş Milletlerin on yedi sürdürülebilir kalkınma hedeflerinden birisi de sürdürülebilir tarım olarak belirlenmiştir [2]. Bu alanda en önemli amaçlardan biri zirai kimyasalların kullanımını azaltırken mahsul verimliliğinin artırılmasıdır.

Tarım alanlarında kullanılan yabancı ot kontrol sistemleri, alan üzerinde aynı oranda herbisit ve zirai kimyasal uygulamaktadır. Bunlara ek olarak bilgisayarla görü tabanlı yabancı ot sistemleri de vardır [3]. Bu sistemler ise kamera ve yapay zeka gibi teknolojilerden faydalanarak mahsul ve yabancı otu ayırt edip bitki başına özel işlem yapmaktadır. Mekanik ot kontrol veya seçici püskürtme sistemleri, bu cins sistemlere birer örnektir. Bu sistemlerdeki temel fikir, tarım alanı üzerinde yalnızca yabancı ot bulunan bölgelere herbisit uygulayarak kullanılan kimyasal oranın azaltılmasıdır. Mahsul ve yabancı ot sınıflandırma, algı kontrollü yabancı ot ve mahsul sistemleri için önemli bir iştir ve başarılı olarak yerine getirilmesi gerekmektedir. Ama hem tarım alanında bulunan durumlar hem de sistemsel eksiklerden kaynaklanan zorluklar mevcuttur.

Mahsule yakın veya mahsul sırası içinde büyüyen yabancı otlar, verim kaybına sebep olacaktır. Kaybın önlenmesi için tarım sistemleri tarafından bu otlara müdahale edilmesi gerekmektedir. Fakat mahsul ve yabancı otlar arasında bir örtüşme vardır. Dahası her mahsulün kendine özgü toprak ve hava koşullarında yetişmesinden kaynaklanan ekolojik değişiklikler mevcuttur. Bunun yanı sıra yabancı ot ve mahsullerin yetiştirme aşamalarında değişik görünümlere sahip olması ve tarım arazilerindeki yabancı ot yoğunluğunun farklılık göstermesi gibi çeşitli durumlar vardır. Bunlar yabancı ot ve mahsulü sınıflandırma işlemini güçleştiren durumlardır.

Yabancı ot ve mahsulü sınıflandırma alanındaki en umut verici yaklaşımlar genellikle Evrişimli Sinir Ağları (ESA'lar) veya rastgele orman sınıflandırıcıları gibi makine öğrenimi tekniklerinden yararlanmaktadır [1]. Bu tür veriye dayalı yaklaşımların ifade düzeyi, eğitim veri kümesinin boyutuyla ilişkilidir. Tarım arazilerinde büyük bir veri kümesi oluşturmak pahalı bir iştir. Bundan dolayı sınırlı

büyükölükte veri kümeleri üzerinde eğitim yapılmakta bu da sınıflandırma başarısını olumsuz şekilde etkilemektedir.

Ayrıca bu sistemlerin ticari olarak uygulanabilir olması için geliştirilen yaklaşım gerçek zamanlı olarak çalışabilmelidir. Bunun yanı sıra yeryüzü üzerinde yüz binlerce mahsul çeşidi vardır. Bundan dolayı herhangi bir yabancı ot ve mahsul türü için önerilen yaklaşımın, sınıflandırma başarısı sabit kalarak ve seri bir şekilde farklı bir mahsul çeşidi için de uyarlanabilmelidir.

1.1. Tezin Amacı, İçeriği ve Katkısı

Mahsuller önemli gıda ürünleridir, yabancı otlar ise mahsul verimi için zararlıdır. Hassas tarım uygulamalarında bitki özelinde işlem yapılarak zirai kimyasal ve pestisit kullanımının azaltılması amaçlanmaktadır. Bu ise insan gücü ile yapıldığında zaman alıcı ve pahalı bir faaliyettir. Bundan dolayı bu tür görevlerde tarımsal otonom robotlar kullanılmaktadır. Robotların görevlerini yerine getirebilmesi için yabancı ot ve mahsulü başarılı bir şekilde ayırtması gerekmektedir [2]. Tarım alanında kullanılacak sistemlerin öncesinde bahsedilen zorlukların üstesinden gelmesi için literatürde birçok yaklaşım geliştirilmiştir.

Bu çalışmanın birinci kısmında mahsul ve yabancı ot sınıflandırmasında mahsul çeşitliliğinden ötürü oluşan güçlük ele alınmıştır. Sınıflandırıcının farklı yabancı ot ve mahsul çeşitliliğinden ötürü oluşan değişikliklerle gürbüz bir şekilde üstesinden gelmesi için alan uyarlaması yöntemlerinden istifade edilmiştir. Buna ek olarak çekışmeli öğrenme alan uyarlaması yaklaşımının geliştirilmesi için farklı olasılık dağılımı sapma ölçümlerinden faydalanılmıştır. İkinci kısımda ise aşınım ve genişleme tabanlı morfolojik ağ mimarilerinin yabancı ot ve mahsul sınıflandırmadaki uygulaması ele alınmıştır. Önerilen yaklaşımlar tarım alanından toplanılmış görüntülerin bulunduğu şeker pancarı (SB16 [4]), havuç (CA17 [5]) ve soğan (ON17 [5]) veri kümeleri üzerinde doğrulanmıştır.

Tez çalışmasında mahsul ve yabancı ot sınıflandırma görevi çeşitli açılardan ele alınmıştır. Evrişim tabanlı ağ mimarileri ve biçimbilim tabanlı ağ mimarilerinin bu görevdeki başarımları karşılaştırılmıştır. Bununla birlikte tür farklılıklarından kaynaklanan değişikliklerin üstesinden gelmek için alan uyarlaması yöntemleri

uygulanmış ve elde edilen sonuçlar değerlendirilmiştir. Bu tezde sunulan katkılar aşağıdaki gibidir:

- i) Ayrım tabanlı ve farklılık tabanlı alan uyarlaması yaklaşımlarının birleşiminin, bir sınıflandırıcının farklı mahsul çeşitleri için uyarlanabilme yeteneğini geliştirdiği gösterilmiştir.
- ii) Bilindiği kadarıyla çekişmeli öğrenme ile olasılık dağılımı sapma ölçümleri ve morfolojik sinir ağları, ilk kez mahsul ve yabancı ot sınıflandırma görevi için uygulanmıştır.

1.2. Tezin Düzeni

Tezin 1. bölümünde yabancı ot ve mahsul sınıflandırma görevinin genel olarak zorlukları, tezin amacı, katkısı, içeriği üzerinde durulmuş ve tezin düzeni hakkında genel bilgiler verilmiştir. Bölüm 2’de anlamsal bölütleme, gözetimsiz alan uyarlaması ve morfolojik işlemler hakkında bilgi verilmiştir. Bölümün ilerleyen kısmında ise literatürde yabancı ot ve mahsul sınıflandırma ile ilgili yapılmış çalışmalara yer verilmiştir. Bölüm 3’te tez kapsamında uygulanan alan uyarlaması yaklaşımları ve kullanılan veri kümeleri ayrıntılandırılmış, deneylerin ayrıntıları verilmiş, elde edilen sonuçlar paylaşarak karşılaştırılmıştır. Bölüm 4’te ise morfolojik sinir ağ yaklaşımları, gerçekleştirilen deneyler ve sonuçlar paylaşarak karşılaştırılmıştır. Bölüm 5’te yapılan çalışmalardan çıkarımlar ve açık araştırma yönleri bildirilmiştir. Son olarak Ekler bölümünde kodlayıcı – kod çözücü yapısına sahip farklı ağ mimarileri ile yapılmış deneylere ve ayrıntılarına yer verilmiştir.

2. LİTERATÜR TARAMASI

Son zamanlarda sürdürülebilir tarıma ilginin artmasıyla birçok araştırmacı hassas tarım alanına odaklandı. Bu alandaki en önemli görevlerden birisi de yabancı ot ve mahsul sınıflandırmadır [3]. Tarım alanlarında kullanılacak sistemlerin bu görevi başarılı olarak yerine getirebilmesi için birçok farklı açıdan yaklaşımlar denenmiştir.

2.1. Anlamsal Bölütleme

Görüntü sınıflandırma görevinde, bir görüntüye görüntüdeki baskın nesneye göre bir etiket atanmaktadır. Nesne tespitinde, bir görüntüdeki nesneler bulunup sınırlayıcı kutu ile belirtilirken, nesne tanıma görevinde buna ek olarak sınıfları da belirtilir. Görüntü bölütleme, görüntüyü analiz edilmesi daha kolay bir duruma getirmek için görüntüyü farklı nesnelere karşılık gelen bölgelere ayırır, ancak bölgeleri etiketlemez. Anlamsal bölütlemeye, görüntüdeki her bir piksele anlamsal içeriğine göre etiket ataması yapılmaktadır. Bundan dolayı otomatik görsel anlama için gerçekleştirilen diğer görevlerin aksine yoğun bir etiketleme görevi olarak nitelendirilir. Buna karşın görüntü içeriğinin daha derinden anlaşılmasını sağlar.

Sahnelerin daha yüksek ve yoğun düzeyde yorumlanmasını gerektirecek yeni problemlerin ortaya çıkmasıyla birlikte otomatik sahne anlamlandırma için farklı çözümlere ihtiyaç duyulmuştur. Anlamsal bölütleme, görüntünün zenginleştirilmiş bir temsilini oluşturma kabiliyeti sayesinde oluşan bu gereksinimi karşılayabilmiştir. Önerilen yaklaşımlar [6, 7, 8], anlamsal bölütlemenin bu tarz problemlerin çözümündeki başarısının yolunu açmıştır. Bu görevi gerçekleştirmek üzere önerilen en gelişmiş yaklaşımlar kodlayıcı ve kod çözücü olmak üzere iki temel bileşenden oluşan otokodlayıcı yapısına dayanmaktadır [9]. Kodlayıcı kısmı, girdinin boyutunu sıkıştırırken bir yandan da girdiyi temsil edecek daha nitelikli öznitelikler oluşturur. Kod çözücü ise bu özellik gösterimini girdi olarak kabul eder, girdinin boyutlarını büyütür ve ağ çıktısını üretir. Bu yapılarda katman sayısı arttıkça, yani ağ mimarisi derinleştikçe, daha güçlü öznitelikler üretilir. Öte yandan katman sayısı ile birlikte havuzlama katman sayısı da artmaktadır ve bu da görüntü boyutunun çok küçülmesine sebep olmaktadır. Boyutu küçülen görüntü, kod çözücü kısmında üst örnekleme katmanını uygulanarak boyutu büyütüldüğünde kenar isabeti

kötüleşmektedir [10]. Anlamsal bölütleme görevi için uygulanacak bu mimarilerde kenarların isabet düzeyi ile yüksek katman sayısı arasındaki dengeyi sağlama önemli bir problemdir. Bu problemin çözümü için genişletilmiş evrişim, aktarılmış evrişim, atlama bağlantıları gibi yaklaşımlar önerilmiştir ve kodlayıcı - kod çözücü yapısına sahip tanınmış SegNet [6], U-Net [7], FCN [8] ve PSPNet [10] ağ mimarilerinde kullanılmıştır. Bu gibi mimarilerin uygulandıkları farklı problemlerde etkileyici başarımlar gösterdikleri bilinmektedir [9].

2.2. Alan Uyarlaması

Makine öğrenimi yaklaşımlarının birçoğu eğitim için kullanılan veri kümesi ile uygulanacak test veri kümesinin benzer dağılımlar gösterdiğini varsaymıştır. Ancak eğitim ve test veri kümelerinin farklı dağılımlar gösterdiği birçok durum da bulunmaktadır. Alan uyarlaması, tipik olarak modellerin performansını büyük ölçüde düşüren dağıtım değişikliğini veya alan kaymasını ele almaktır [11]. Bir modelin bir veya daha fazla alanda (kaynak alanlar) eğitildiği ve daha sonra farklı, ancak ilgili alanda (hedef alan) uygulandığı yaklaşımlardır [12]. Alan uyarlaması yaklaşımları gözetimli, yarı gözetimli ve gözetimsiz olmak üzere üç ana gruba ayrılır. Gözetimli alan uyarlamasında hedef alandaki tüm veriler için etiketler bulunur, yarı gözetimli alan uyarlamasında hedef alandaki verilerin bir kısmı için etiket mevcut iken kalan kısmı etiketsizdir, gözetimsiz alan uyarlamasında ise hedef alandaki örneklerin tümü etiketsizdir.

Evrişimsel sinir ağı yaklaşımları (ESA), anlamsal bölütleme üzerine yapılan çalışmalarda yüksek başarı göstermiştir [2]. Fakat bu tür yaklaşımların başarısı, üzerinde eğitildikleri veri kümesinin boyutuna bağlıdır. Bununla birlikte bu yaklaşımlar, eğitim için çok büyük miktarda etiketli veriye ihtiyaç duymaktadır [9]. Örneğin kentsel sahnelerin anlamsal bölütlenmesi için Cityscapes [13] ve Mapillary [14] gibi veri kümeleri oluşturulmuştur. Piksel temelinde etiketli veri kümelerinin oluşturulması maliyetli ve zaman alıcı bir görevdir. Cityscapes veri kümesinin tek bir görüntüsü üzerinde etiketleme ve kalite kontrol çalışmasının 1,5 saatten fazla sürdüğü bildirilmiştir [13]. Bilgisayar grafiklerindeki gelişmeler ile birlikte GTA5 [15] ve SYNTHIA [16] gibi gerçek görüntülere benzer görüntülerin bulunduğu, etiketlerinin otomatik olarak üretildiği veri kümeleri oluşturulmuştur.

Veri kümesi oluşturma maliyeti ile başa çıkmak üzere, bölütleme yöntemlerini eğitmek amacıyla grafik motorlarından oluşturulan sentetik veri kümelerinden faydalanılır [1]. Bunun yanı sıra sentetik olan veri kümeleri (kaynak alan) ile eğitilen yöntemlerin gerçek görüntülere (hedef alan) aktarılması güçleşmiştir. Bu güçlüğü çözümlü amacıyla, yöntemlerin doğrudan kaynak veri kümelerinden etiketlenmemiş hedef veri kümelerine uyarlanması için farklı gözetimsiz alan uyarlaması yaklaşımları önerilmiştir [17, 18, 19, 20, 21, 22, 23, 24].

Etki alanı dağılımı tutarsızlığını en aza indirerek etki alanı değişmez temsilleri öğrenilebilmesi önerilmiştir. Bunun gerçekleştirilebilmesi için temsillerin ortalamasını hesaplayan Maksimum Ortalama Tutarsızlık (MOT) kaybı [25], ortalama ve kovaryans [26, 27] gibi bazı özellik dağılım istatistikleri kullanılır. Ne yazık ki, dağılım Gauss tabanlı olmadığında kaynak ve hedef alanı hizalamak için bu yöntemler yeterli değildir [20].

Çekişmeli öğrenme, gözetimsiz alan uyarlamasında anlamsal bölütleme için en çok araştırılan yaklaşımdır [17]. Kaynak ve hedef alandaki görüntüler için bölütleme haritalarını tahmin eden anlamsal bölütleme ağı ve bölütleme ağından çıkan tahmin haritalarını alarak etki alanını tahmin etmeye çalışan ayırıcı ağ olmak üzere iki ağdan oluşur. Bölütleme ağı, ayırıcıyı kandırmaya çalışırken kaynak ve hedef alandaki özelliklerin benzer bir dağılıma sahip olmasını sağlar. Alan kaymasının hizalanması için bu yapıdan faydalanan çeşitli yaklaşımlar önerilmiştir [17, 18, 19].

Alan uyarlama probleminin çözümü için üretici ağlar üzerine kurulmuş, açıklamalı kaynak alan görüntüleri üzerinde koşullandırılmış hedef görüntüleri oluşturan yöntemler mevcuttur. Hem piksel seviyesi hem de özellik seviyesi alan boşluğunu en aza indirmek için döngü tutarlı uyarlama çerçeveleri önerilmiştir [28, 29].

Gözetimsiz alan uyarlaması için önerilen öz eğitim yaklaşımı son yıllarda etkileyici sonuçlar göstermiştir [30]. Evrimsel sinir ağı tabanlı öz eğitim yöntemleri [20, 21, 22, 23, 24], mevcut modeli eğitmek amacıyla etiketlenmemiş hedef alan verileri için sözde etiket olarak önceki model durumundan gelen tahminleri kullanmaktadır. Böylece modeli dolaylı olarak etki alanında değişmez özellikleri çıkarmaya zorlar.

2.3. Morfolojik Filtrelere Dayalı Ağlar

Yapay sinir ağları son zamanlarda görüntü sınıflandırma [31], anlamsal bölütleme [8] ve görüntü oluşturma [32] gibi farklı görevlerde başarıyla kullanılmıştır. Nöronlar, bu ağların temel yapı taşıdır ve girdinin doğrusal kombinasyonunu basitçe hesaplayarak işlem yaparlar. Temel olarak doğrusal işlem yapan bu ağların doğrusal olmayan durumları da genelleyebilmesi için aktivasyon fonksiyonu, toplu normalleştirme [33] ve bırakma [34] gibi özel yöntemler kullanılmaktadır. Buna karşın morfolojik sinir ağlarında, çarpma ve toplama işlemlerinin yerine toplama ve maksimum (veya minimum) işlemleri kullanılmıştır [35]. Bu sayede az sayıda nöron gerektirirken ek aktivasyon fonksiyonu ihtiyacını ortadan kaldıran doğrusal olmayan bir yapı elde edilmiştir [36].

Yapay sinir ağı ile morfolojik sinir ağı arasındaki temel fark, her bir düğümün sayısal bilgiyi cebirsel olarak işleme biçiminden kaynaklanmaktadır. Bu farklılık üzerinden yola çıkılarak morfolojik sinir ağları için teorik bir temel oluşturulmuştur [37]. Farklı problemler için çok katmanlı morfolojik algılayıcı tabanlı yaklaşımlar önerilmiştir [38, 39]. Doğrusal olmayan işlemlerin kolay türevleri yoktur ve bundan dolayı bu yapıları kullanan ağ mimarilerinin optimizasyonundaki zorlukların üstesinden gelmek için yaklaşımlar önerilmiştir [40]. Bunlara ek olarak morfolojik sinir ağlarının, yapay sinir ağlarına benzer veya daha iyi başarımlar göstermesi için öğrenme yeteneğini geliştirmek amacıyla çalışmalar yapılmıştır [41, 42].

2.4. Yabani Ot ve Mahsul Sınıflandırma

Tarımsal alanlarda görüntü işleme kullanılarak bitkilerin konumları ve türleri belirlenebilmektedir. Bu bilgi ise ayıklama, ilaçlama veya hasat etme gibi işlemlerin bitkiye özel olarak yapılmasını sağlar.

Bitki sınıflandırma görevi, bilgisayarla görme teknikleri kullanılarak farklı seviyelerde ele alınmıştır. Yaprakların sınıflandırılması için 10 farklı yaprak türünü şekil ve doku bilgisine bağlı olarak sınıflandıran [43] ve Kuzeydoğu Amerika Birleşik Devletleri'ndeki 184 ağaç türünü, yapraklarını sınıflandırarak karar veren [44] farklı yöntemler önerilmiştir. Yalnızca yaprakların olduğu durumlarda şekil, renk ve dokuya dayalı yöntemlerin farklı yaprak türlerini ayırt etmede etkili olduğu

kanıtlanmıştır. Bu tarz yaprak sınıflandırma çalışmaları genellikle aydınlatma koşulları gibi ortamsal bilgilerin kontrollü olduğu homojen bir arka plan üzerinde gerçekleştirilmiştir [45, 46]. Ancak ticari sahada yabancı ot sınıflandırma için kullanılacak sistemlerde tek yapraklı görüntüler üzerinde yapılan sınıflandırma uygulanabilir değildir. Tarla düzeyinde herbisit kullanımını düzenlemek için uzaktan algılama başarıyla uygulanmıştır [47]. Fakat akıllı tarım faaliyetlerinde bitki sınıflandırma görevi için daha ince ölçekte işlem yapılması gerekmektedir.

Yabancı ot ve mahsul sınıflandırma görevinde küresel ve uyarlanabilir eşikleme [48], yerel bölge tabanlı yaklaşımlar [49] ve makine öğrenimi tekniklerinin [50, 51] kullanıldığı farklı çalışmalar yapılmıştır. Bitki sınıflandırma için yapılan çalışmaları bölge tabanlı [49] ve piksel tabanlı [50, 52] olmak üzere iki gruba ayırabilir. Bölge tabanlı yaklaşımlar, piksel tabanlı yaklaşımlara nazaran daha az maliyetli olup bitkilerin erken büyüme evreleri gibi bitkiler arası örtüşme olmadığı durumlarda iyi çalışır [53]. Bunun yanı sıra bitkiler arası örtüşme sorununun üstesinden gelebilmek için piksel tabanlı yaklaşımlar tercih edilmiştir [53]. Binlerce pikselin sınıflandırma maliyetinin azaltılması için arka plan olan toprağın çıkarılıp ardından görüntüde kalan bitkilerin bölütleme işlemi yapılmıştır [48]. Bunlara ek olarak her iki fikrin avantajlarından yararlanabilmek adına birlikte kullanılması önerilmiştir [54].

Son dönemlerde yabancı ot ve mahsul sınıflandırma görevine yönelik önemli ilerlemeler olmasına rağmen önerilen birçok yaklaşım el yapımı özniteliklere dayanmaktadır [50, 54, 55]. Evrişimli sinir ağları, farklı alanlarda elde ettiği başarılar ve el yapımı özniteliklere göre daha uyarlanabilir olması gibi sebeplerden dolayı yabancı ot ve mahsul sınıflandırma sistemlerine de uygulanmıştır [1, 56, 3, 57]. Mahsul ve yabancı otu piksel bazında sınıflandırmak için bir sıradaki bitkilerin uzamsal düzlem bilgisini kullanan tamamen evrişimli ağ tabanlı bir sınıflandırma modeli önerilmiştir [2]. Böylece bitkinin uzamsal düzlem bilgisi kullanılarak sistemin performans ve genelleme yetenekleri geliştirilmiştir. Yabancı otları topraktan ve görüntülerdeki mahsullerden ayırabilme işlemi kapsamında eğitim verisi eksikliğini gidermek için ön plan ve arka plana dayalı bir veri büyütme yöntemi ve bölütleme görevi için basitleştirilmiş bir U-net yapısı önerilmiştir [57].

Çok sayıda yaklaşım, yüksek sınıflandırma performansı sağlayanlar, yalnızca RGB görüntülere güvenmekle kalmaz aynı zamanda izgesel ipuçları bulunduran yakın kızılötesi bilgisini de kullanır. Tarım alanına ait veri kümelerinin oluşturulması için üç boyutlu, spektral ve termal kameralar gibi farklı donanımlar kullanılmıştır.

Ancak bu tür ekipmanların maliyeti yüksek olduğundan dolayı yaygın olarak kullanılması zordur. Bu zorluğu aşmak için RGB görüntülerden hesaplanan Aşırı Yeşil (ExG), Aşırı Kırmızı (ExR), Bitki Özütlemenin Renk İndeksi (CIVE), Normalleştirilmiş Fark İndeksi (NDI) gibi renk indeksi tabanlı görüntüler [58, 59, 4], farklı renk uzaylarında temsil edilen görüntüler [60, 61] üzerinde çalışmalar yapılmıştır. Gerçek zamanlı olarak farklı toprak, hava ve aydınlatma koşullarına iyi genelleme yapan akıllı yabancı ot kontrolünü sağlamak için eğitiminde çeşitli bitki örtüsü indeksleri ve RGB görüntülerin ön işleme eşlemelerinden faydalanan anlamsal bölütleme ağı yaklaşımı önerilmiştir [3].

Son zamanlarda yabancı ot ve mahsul sınıflandırma için geliştirilen yaklaşımların eğitimi için büyük veri kümelerine ihtiyaç bulunmaktadır [1]. Aynı zamanda bu veri kümeleri mahsulün büyüme aşamaları, değişken toprak ve hava koşulları gibi durumlara ait verileri de içermelidir. Ne yazık ki, tüm alan üzerinde kapsamlı ve periyodik veri toplama zaman alıcı ve pahalı bir faaliyettir [1]. Bu zorluk ile başa çıkmak için açık kaynaklı oyun motorları ve simülatörler kullanılarak sentetik veri kümeleri oluşturulmaktadır. Bunun yanı sıra önerilen bilgi transfer yöntemleri de mevcuttur. Yeni bir mahsul için sınıflandırma sistemlerinin geliştirilmesi süresince gereken etiketli veri oluşturma ve eğitim çabasını azaltmak amacıyla farklı mahsul türleri ile çalışmak üzere basitleştirilmiş SegNet mimarileri arasındaki bilgi transferi yöntemi önerilmiştir [5]. Sentetik tarım alanı görüntüleri oluşturma için yaprağın uzunluğu, genişliği, simetrisi, bitkinin katman sayısı, katmandaki yaprak sayısı ve yaprak boyutu gibi özelliklere dikkat edilerek yaprak modellemesi, bitki modellemesi, sanal veri küme üretimi, yapay etiket üretimi olmak üzere dört adımdan oluşan yaklaşım önerilmiştir [1].

Sentetik veri kullanılarak eğitilen modellerin alanlar arası boşluktan dolayı gerçek dünya verilerine aktarılması güç hale gelmektedir. Alanlar arası boşluğu azaltmak amacıyla yöntemlerin doğrudan kaynak veri kümelerinden hedef veri kümelerine uyarlama yapabilmesi için alan uyarlaması yaklaşımları önerilmiştir. Alan uyarlaması, mahsul ve yabancı ot sınıflandırma görevinde aynı mahsul türünde büyüme aşamaları ve çevresel faktörlerden kaynaklanan veri dağılımındaki farklılaşma [62], yabancı ot ve mahsul türlerinden kaynaklanan zorluk [63, 64] ile başa çıkmak için uygulanmıştır. Yalnızca kaynak alandaki etiketli RGB görüntü verilerini ve hedef alandaki etiketsiz RGB görüntü verilerini kullanan, kaynak görüntüleri hedef alanına çevirmek için CycleGAN [29]'lardan faydalanan ve

anlamsal bölütleme için FCN mimarisinden faydalanan bir yaklaşım önerilmiştir [63].

Bu tez kapsamında referans alınan alan uyarlaması yaklaşımında anlamsal bölütleme için basitleştirilmiş bir SegNet modelinden faydalanılırken, alan kaymasının hizalanması için iki farklı kayıp fonksiyonu kullanılmıştır. Bunlara ek olarak alan kaymasının hizalanmasına yardımcı olması için çekişmeli kayıp fonksiyonun yanı sıra, kaynak ve hedef alanlar arasındaki dağılım farkını ölçen, maksimum ortalama tutarsızlık (MOT), Kullback-Leibler (KL) farklılık ve Jensen-Shannon (JS) farklılık metriklerinden faydalanılması önerilmiştir ve bu metriklerin performansa etkisi incelenmiştir.

3. ALAN UYARLAMASI YAKLAŞIMLARININ YABANI OT VE MAHSUL SINIFLANDIRMAYA UYGULANMASI

Bu bölümde mahsul ve yabancı ot sınıflandırma görevindeki tür farklılığından kaynaklanan zorluğun üstesinden gelmek için gözetimsiz alan uyarlaması yaklaşımları uygulanmıştır. Böylece etki alanı dağılımı farklılığını en aza indirerek etki alanı değişmez temsillerinin öğrenilmesi amaçlanmaktadır.

3.1. Yaklaşımlar

Mahsul ve yabancı ot sınıflandırmasında mahsul çeşitliliği güçlüğünün üstesinden gelmek amacıyla alan uyarlaması yöntemi referans alınmıştır [17]. Farklı mahsul verileri için, etiketli görüntülerden oluşan kaynak alan ile etiketsiz görüntülerden oluşan hedef alan arasındaki dağılım kayması hizalanmıştır. Referans çalışmada önerilen AdvEnt ve MinEnt olmak üzere iki farklı yöntem de kullanılmıştır. Bununla birlikte çekişmeli öğrenme ve etki alanı dağılımı tutarsızlığını ölçen farklı metriklerin birleşimlerinin performansları araştırılmıştır.

Modeller kaynak etki alanında denetimli bir kayıpla eğitilmiştir. $X_s \subset R^{H \times W \times 4}$, kaynak veri kümesi ve $Y_s \subset (1, C)^{H \times W}$, kaynak örneklerin etiketlerinin bulunduğu kümedir. P_x ise anlamsal bölütleme ağı F 'in x görüntüsü için oluşturduğu tahmindir. F 'in θ_F parametreleri, bölütleme kaybını (L_{seg}) en aza indirmek için öğrenilir.

$$L_{seg}(x_s, y_s) = - \sum_{h=1}^H \sum_{w=1}^W \sum_{c=1}^C y_s^{(h,w,c)} \log P_{x_s}^{(h, w, c)} \quad (3.1)$$

Alan uyarlaması olmadan yalnızca kaynak etki alanında eğitim durumunda, optimizasyon Denklem 3.2 'deki gibidir.

$$\min_{\theta_F} \frac{1}{|X_s|} \sum_{x_s \in X_s} L_{seg}(x_s, y_s) \quad (3.2)$$

3.1.1. MinEnt Ağ Mimarisi

Alan uyarlaması yöntemlerinde $X_t \subset R^{H \times W \times 4}$, hedef alan görüntüleri için etiket verisi bulunmadığından dolayı eğitim aşamasında kullanılamamaktadır. Bu durumla başa çıkmak için MinEnt [17] yönteminde hedef alandaki tahmini en üst düzeye çıkarmak amacıyla entropi kaybı kullanılıyor (Şekil 3.1). Referans çalışmada Shannon Entropi [65] kullanılmaktadır.

Hedef veri kümesinden verilen bir x_t görüntüsü için entropi haritası $E_{x_t} \in [0, 1]^{H \times W}$ normalleştirilmiş bağımsız piksel bazında entropilerden oluşur. (h, w) konumlu pikselin entropisi $E_{x_t}^{(h,w)}$ 'dir.


$$E_{x_t}^{(h,w)} = \frac{-1}{\log(C)} \sum_{c=1}^C P_{x_t}^{(h,w,c)} \log P_{x_t}^{(h,w,c)} \quad (3.3)$$

Entropi kaybı ise Denklem 3.4 ile ifade edilir.

$$L_{ent}(x_t) = \sum_{h,w} E_{x_t}^{(h,w)} \quad (3.4)$$

Eğitim aşamasında kaynak alan örnekleri için gözetimli bölütleme kaybı ve hedef alan örnekleri için gözetimsiz entropi kaybı ile beraber (Denklem 3.5) optimize ediliyor. λ_{ent} entropi kaybı L_{ent} 'in ağırlık faktörüdür.

$$\min_{\theta_F} \frac{1}{|X_s|} \sum_{x_s} L_{seg}(x_s, y_s) + \frac{\lambda_{ent}}{|X_t|} \sum_{x_t} L_{ent}(x_t), \quad (3.5)$$



Şekil 3.1: MinEnt mimarisi.

3.1.2. AdvEnt Ağ Mimarisi

Anlamsal bölütleme görevinde gözetimsiz alan uyarlaması için yapılandırılmış çıktı uzayında uyarlamanın faydalı olduğu görülmüştür [18]. Bu ise kaynak ve hedef alanın anlamsal düzende güçlü benzerliklerinin olmasından kaynaklanmaktadır [17]. Entropi kaybı ise bir girdi görüntüsü için bağımsız piksel bazlı tahmin entropilerinin toplamının hesaplanıp yapısal bağımlılıkların ihmaline neden olur. Bu nedenle referans alınan çalışmadaki ikinci yöntem olan AdvEnt [17] ağ mimarisinde üretici ve ayrıştırıcı olmak üzere iki farklı ağ yapısı bulunmaktadır (Şekil 3.2). Bu şekilde kaynağa benzer hedefin entropi dağılımını sağlayarak entropiyi dolaylı olarak en aza indiren birleşik bir çekişmeli eğitim çerçevesi sunuluyor [17]. Kaynak ve hedef alandan gelen özniteliklerin dağılım kaymasını hizalamak amacıyla ayrıştırıcı, iki alanın görüntülerini ayırt etmek için eğitilirken üretici ise ayrıştırıcıyı kandırmak için eğitiliyor.

Ayrıştırıcı D , parametreleri θ_D ile birlikte $I_x^{(h,w)} = -P_x^{(h,w)} \cdot \log P_x^{(h,w)}$ girdi olarak alır ve iki sınıf (kaynak ve hedef) için bir çapraz entropi kaybı L_D 'yi kullanır.

$$L_D(I_x) = -\sum_{h,w} (1 - z) \log(D(I_x)^{(h,w,0)}) + z \log(D(I_x)^{(h,w,1)}) \quad (3.6)$$

Hedef etki alanından alınmış örneklerde $z = 0$ iken kaynak etki alanından alınmış örneklerde $z = 1$ 'dir. Ayırıştırıcının eğitim hedefi Denklem 3.7 ile ifade edilir.

$$\min_{\theta_D} \frac{1}{|X_s|} \sum_{x_s} L_D(I_{x_s}, 1) + \frac{1}{|X_t|} \sum_{x_t} L_D(I_{x_t}, 0) \quad (3.7)$$

P_t dağılımını P_s 'ye daha yakın hale getirmek için çekişme kaybı L_{adv} 'i kullanır.

$$L_{adv}(X_t) = - \sum_{h,w} \log(D(I_{x_t})^{(h,w,1)}) \quad (3.8)$$


Denklem 3.9, anlamsal bölütleme ağıni eğitmek için çekişmeli amaç işlevidir.

$$\min_{\theta_F} \frac{1}{|X_t|} \sum_{x_t} L_D(I_{x_t}, 1) \quad (3.9)$$

Anlamsal bölütleme ağıının, yani üreticinin, eniyileme problemi Denklem 3.10 ile ifade edilir. λ_{adv} çekişme kaybı L_D ' nin ağırlık faktörüdür.

$$\min_{\theta_F} \frac{1}{|X_s|} \sum_{x_s} L_{seg}(x_s, y_s) + \frac{\lambda_{adv}}{|X_t|} \sum_{x_t} L_D(I_{x_t}, 1) \quad (3.10)$$

Eğitim sırasında üretici ağı (3.10) denklemiyle, ayırıcı ağı ise (3.7) denklemi ile optimize ediliyor.



Şekil 3.2: AdvEnt mimarisi.

3.1.3. Farklılık Ölçümleri ile AdvEnt Ağ Mimarisi

Alan kayması problemi ile başa çıkmak amacıyla, genellikle bir üretici ve bir ayırıştırıcıdan oluşan çekişmeli alan uyarlaması yaklaşımları başta olmak üzere birçok alan uyarlaması yöntemi önerilmiştir. Çekişmeli alan uyarlamasına göre daha ideal sonuçlar için Kullback-Leibler farklılığından faydalanılmıştır [66].

AdvEnt'in performansının geliştirilmesi, ayırıştırıcının ayırt etme yeteneğini geliştirmek ve böylece üreticinin performansını artırmak için kaynak ve hedef alanlar arasındaki dağılım farkını ölçen farklı metriklerden faydalanılmıştır.

Ayırıştırıcının öğrenme yeteneğini geliştirmek amacıyla, alanlar arasındaki dağılım farkını ölçmek için ayırıştırıcıdan çıkan öznelilikleri arasında KL farklılığı, JS farklılığı ve MOT hesaplanmıştır. $P(x)$ ve $Q(x)$, rastgele bir x değişkeni üzerindeki iki olasılık dağılımıdır ve aralarındaki KL farklılığı Denklem 3.11 'deki gibidir.

$$KL(P||Q) = \sum P(x). \log \frac{P(x)}{Q(x)} \quad (3.11)$$

JS farklılığı, Denklem 3.12 'deki şekilde hesaplanır ve $M = \frac{P+Q}{2}$ olacak şekilde tanımlanır.

$$JS(P||Q) = \frac{1}{2} KL(P||M) + \frac{1}{2} KL(Q||M) \quad (3.12)$$

MOT ise Denkler 3.13 ile hesaplanır ve μ dağılım ortalamasını ifade eder.

$$MOT^2(P, Q) = \|\mu_P - \mu_Q\|^2 \quad (3.13)$$

Formüllere göre, $P(x)$ ve $Q(x)$ arasındaki benzerlik ne kadar yüksek ise, farklılık değeri o kadar küçüktür.

Alan uyarlama sürecinde, üreticiyi, AdvEnt mimarisinde olduğu gibi bölütleme kaybı dışında çekişmeli kaybın da dahil edildiği çekişmeli eğitim yoluyla eğitiriz. Çekişmeli kayıp, iki bölümden oluşur. İlk kısım, AdvEnt mimarisindeki L_{adv} kaybıdır. Ayrıştırıcının kaynak etki alanı etiketini ($z = 1$) hedef alandan gelen I_{x_t} örneğine hatalı olarak atama olasılığıdır. Diğer kısım ise ayrıştırıcının kaynak etki alanı için oluşturduğu D_{x_s} ve hedef etki alanı için oluşturduğu D_{x_t} arasındaki dağılım farkıdır.

KL için farklılık kaybı, Denklem 3.14 ile ifade edilir.

$$L_{KL}(X_s, X_t) = -\sum D(I_{x_s}) \log \frac{D(I_{x_s})}{D(I_{x_t})} \quad (3.14)$$

JS için farklılık kaybı, Denklem 3.15 ile ifade edilir.

$$L_{JS} = \frac{1}{2} L_{KL}(X_s, X_m) + \frac{1}{2} L_{KL}(X_t, X_m) \quad (3.15)$$


MOT için farklılık kaybı, Denklem 3.16 ile ifade edilir ve $\langle \rangle$ iç çarpımdır.

$$MOT^2(X_s, X_t) = \langle \mu_{X_s}, \mu_{X_s} \rangle - 2\langle \mu_{X_s}, \mu_{X_t} \rangle + \langle \mu_{X_t}, \mu_{X_t} \rangle \quad (3.16)$$

Farklılık kaybı optimizasyonu, ayrıştırıcıdaki I_{x_s} ve I_{x_t} arasındaki dağılım farkı genişletilerek ayrıştırıcının daha fazla alan değişkeni özelliği yakalamasına ve doğruluğunu geliştirmesine yardımcı olabilir. Bu sayede üretici sadece çekişme kaybı ile yapılan eğitime göre daha ideal sonuçlar üretebilir.

Ayrıştırıcının eğitim hedefi AdvEnt mimarisi ile aynı kalırken, üreticinin yani anlamsal bölütleme ağının eğitim hedefi ise Denklem 3.17 'deki gibidir. L_{div} genel olarak farklılık kaybını ifade etmektedir.

$$L(X_s, X_t) = L_{seg}(X_s) + \lambda L_{adv}(X_t) + \beta L_{div}(X_s, X_t) \quad (3.17)$$



Şekil 3.3: AdvEnt_Div mimarisi.

3.1.4. Anlamsal Bölütleme Ağ Mimarisi

MinEnt [17] ve AdvEnt [17]'in üretici ağ mimarisi F, ImageNet'ten [67] eğitilmiş parametreleri olan bir ResNet-101 ağ mimarisidir [68]. Ancak mahsul veri kümelerinin boyutlarının kısıtlı olması sebebiyle, üretici yapısı daha az parametreye sahip referans alınan çalışma SegNet [5] ağ mimarisi olarak değiştirilmiştir.

3.1.4.1. Girdi


Önerilen mimarilerin giriş katmanı, 512×384 boyutunda renkli (RGB) ve yakın kızılötesi (NIR) kanallarından oluşan görüntüleri girdi olarak alan $4 \times 384 \times 512$ olmak üzere üç boyutlu bir tensördür. Veri toplamının ve etiketlemenin zaman alıcı ve pahalı olduğu bir bağlam olduğu için yöntemlerin veri kıtlığı ile başa

ıkabilmesi gerekmektedir. Bundan dolayı girdiler zerinde herhangi bir artırma iřlemi yapılmamıřtır.

3.1.4.2. SegNet

Bltleme erevesi iin bilinmiř SegNet [6] mimarisinden istifade eden bir yntem referans alınmıřtır [5]. SegNet, grntlerin ve videoların piksel dzeyinde anlamsal bltlemesi iin uyarlanmıř olup sırasıyla “kodlayıcı-kod zc” mimarisi ve ardından piksel dzeyinde birden fazla sınıflı bir softmax sınıflandırıcı katmanından oluřmaktadır.


SegNet’in yzlerce sınıfta bařarılı olduėu bilinmekte olup ve oėu zaman yz binlerce veriyle eėitiliyor. Mahsul ve yabani ot sınıflandırma alanında veri kme boyutlarının kısıtlı olması, sadece 3 sınıf (mahsul, yabani ot ve toprak) bulunması ve yksek bir operasyonel hız ihtiyaı gibi kısıtlarımız vardır. Bu sebeple yukarıda belirtilen aė yapısının 13 katmandan 4 katmana sadeleřtirilmesi nerilmiřtir [5] (řekil 3.4).



řekil 3.4: Referans alınan SegNet mimarisi.

Aė yapısında katman katman giderek daha soyut grnt zelliklerini ėrenmekle grevli olan evriřim katmanlarının her biri 7×7 sabit boyutta 64 filtreden oluřmaktadır. Filtre boyutu, merkezdeki pikselin etiketine karar verirken

çevresindeki hangi boyutta piksel alanından etkilenmesi gerektiğini kontrol eder. Eğer filtre boyutu küçük olursa çevredeki yararlı bilgileri kaçırarak yerel bir karar verilecektir. Bunun aksine filtre boyutu büyük olursa da verilecek kararda çevre piksellerin yoğun bir etkisi olacağı için komşu sınıflarla ilişkilendirme riski vardır. Bundan dolayı filtre boyutu, SegNet tasarımcıları tarafından önerilen boyuttur. Her bir evrişim katmanından sonra kararlılığının ve performansını artırması için toplu normalleştirme katmanı, doğrusal olmayan özneteliklerin öğrenilebilmesi için de doğrultulmuş lineer birim (ReLU) katmanı ve son olarak özneteliklerin boyutunu orijinal boyutun yarısına indiren maksimum havuzlama katmanı eklenmiştir.



Şekil 3.5: SegNet'te kullanılan maksimum havuzlama ve üst örnekleme örneği.

Dört kodlama katmanından sonra aynı sayıda kod çözme katmanı gelir. Her bir kod çözme katmanında öncelikle öznetelik boyutu orijinal boyutunun iki katına çıkarılması için üst örnekleme katmanı (Şekil 3.5) eklenir. Ardından kodlama katmanındaki gibi sırasıyla evrişim katmanı, toplu normalleştirme katmanı ve doğrultulmuş lineer birim (ReLU) katmanı gelmektedir. Son olarak mimarının kod çözücü kısmından sonra softmax sınıflandırıcı katmanı gelmektedir.

3.1.4.3. Sınıf Ağırlığı

Evrişimsel sinir ağırları ile görüntü içeriğinin anlaşılması için gerçekleştirilen görüntü sınıflandırma, nesne yerelleştirme gibi görevlere nazaran anlamsal bölütleme daha zordur. Bunun nedenlerinden biri, aynı görüntüde bulunan piksellerin dengesiz dağılımıdır. Herhangi bir tarım alanı görüntüsünde toprak pikselleri, yabani ot ve mahsul piksellerine göre daha yoğundur. Bundan dolayı çapraz entropi kaybı fonksiyonunun, toprak pikseline ait yanlış bir tahmin ile yabani ot ve mahsule ait yanlış bir tahmini farklı ölçeklerde cezalandırmalıdır. Bu amaçla veri kümesinin sınıf yoğunlukları ile ters orantılı sınıf ağırlıklar kullanılmıştır. Böylece yabani ot ve


mahsul için yapılan yanlış bir tahmin toprağa göre daha ağır şekilde cezalandırılacaktır.

3.1.4.4. Çıktı

Görüntüdeki her piksel için pikselin ait olduğu sınıf olasılıklarının temsil edildiği vektörler üretiliyor. Bu vektörler 3 uzunluğunda olup her boyutu sırasıyla toprak, mahsul ve yabancı ot sınıfını belirtmektedir.

3.1.5. Ayrıştırıcı Ağ Mimarisi

Ayrıştırıcı ağ mimarisi D, DCGAN'da [69] kullanılan mimariyle benzer mimariye sahiptir ancak veri küme kısıtından dolayı parametre sayısını azaltacak şekilde düzenlemeler yapılmıştır. Ağ, filtre boyutu 7×7 olan, 5 evrişim katmanından oluşur ve evrişim katmanlarındaki kanal sayısı sırasıyla {32, 64, 128, 256, 1}'dir. Son katman hariç her bir evrişim katmanını, 0.2 sabit negatif eğimli bir sızıntılı-ReLU katmanı takip eder. Ayrıştırıcı küçük bir iş boyutu kullanılarak bölütleme ağıyla birlikte eğitildiği için herhangi bir toplu normalleştirme katmanı kullanılmamıştır.




Şekil 3.6: Ayrıştırıcı ağ mimarisi.

3.2. Deneyler

Bu bölümde bu tez kapsamında alan uyarlaması yöntemler için yapılan bir dizi deneyin ayarları ve sonuçları paylaşılacaktır.


3.2.1. Veri Kümeleri

Şeker Pancarı 2016 (SB16) [4] veri kümesinde NIR ve RGB (Şekil 3.6) olmak üzere dört kanallı 283 tane görüntü ve bu görüntülerin kesin referans etiketli görüntüleri vardır. Veri kümesindeki her görüntü tek sıra mahsul içerir ve 1296×966 boyutlarında olup $24 \times 31 \text{ cm}^2$ alanı temsil eder. Veri kümesindeki sınıf dağılımı ise %68 mahsul, %32 yabancı ot şeklindedir.




Şekil 3.7: SB16 veri kümesinden örnekler. a) RGB görüntüsü, b) NIR görüntüsü, c) Etiket görüntüsü. Tüm etiket görüntülerinde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.

Havu 2017 (CA17) [5] kmesi, NIR ve RGB (ekil 3.7) olacak ekilde drt kanallı 20 adet grnt ve bu grntlerin etiket grntlerinden olumaktadır. Havu veri kmesinde bulunan her grnt drt sıra mahsul ierir ve 2428×1985 boyutunda olup $100 \times 85 \text{ cm}^2$ alanı temsil eder. %65 yabani ot, %35 mahsul oranında sınıf daėılımına sahip olup yabani ot yoėunluėunun daha fazla olduėu bir veri kmesidir.



ekil 3.8: CA17 veri kmesinden rnekler. a) RGB grnts, b) NIR grnts, c) Etiket grnts. Tm etiket grntlerinde mahsuller kırmızı, yabani otlar mavi, toprak siyah olarak gsterilir.

Soğan 2017 (ON17) [5] kümesi, NIR ve RGB olacak şekilde dört kanallı 20 adet görüntü ve bu görüntülerle ilişkili etiket görüntüleri içerir. Her bir görüntü dört sıra mahsul içerir ve 2419×1986 boyutunda olup $100 \times 85 \text{ cm}^2$ alanı temsil eder. Veri kümesi %51 mahsul ve %49 yabancı ot sınıf dağılımına sahiptir.



Şekil 3.9: ON17 veri kümesinden örnekler. a) RGB görüntüsü, b) NIR görüntüsü, c) Etiket görüntüsü. Tüm etiket görüntülerinde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.

3.2.2. Başarım Ölçütleri

Deneylerde mahsul sınıflandırma probleminin başarısını ölçmek için, Cohen'in Kappa katsayısı [70] ve ortalama PASCAL VOC kesişimi-üzerinde-birleşme [71] olmak üzere iki metrik kullanılmıştır.

$$Kappa = \frac{Acc - Acc_{chance}}{1 - Acc_{chance}} \quad (3.18)$$

Acc doğruluk, Acc_{chance} sınıflandırıcının tahminleri ve etiket arasında bir şans anlaşması olasılığıdır.

Ortalama PASCAL VOC kesişimi-üzerinde-birleşme ise Denklem 3.20 ile ifade edilir.

$$IoU = \frac{TP}{(TP + FP + FN)} \quad (3.19)$$

$$mIoU = \frac{1}{C} \sum_{c=1}^C IoU_c \quad (3.20)$$

TP , FP ve FN sırasıyla gerçek pozitif, yanlış pozitif ve yanlış negatif piksellerin sayısıdır, C ise sınıf sayısıdır.

3.2.3. Deney Ayarları

Yabani ot ve mahsul sınıflandırma görevi için uygulanan alan uyarlaması yaklaşımların performanslarını ölçmek adına deney setleri oluşturulmuştur.

Deneylerimiz, yabani ot ve mahsul sınıflandırma için mahsul çeşitliliği güçlüğü ile başa çıkmada alan uyarlamasının faydalarını gözlemlemek için tasarlandı. Hedef, tam olarak herhangi bir yabani ot ve mahsul cinsi için eğitilmiş bir sınıflandırıcıyı, sınıflandırma başarısı sabit kalarak ve hızlı olacak şekilde farklı bir mahsul cinsi için de uyarlanabilmesi açısından gerçekçi şartlar altında alan uyarlaması ile eğitilmiş bir sınıflandırıcıyla karşılaştırmaktır. Veri kümeleri için üç farklı deney gerçekleştirilmiştir:

- i) Etiketli X mahsulü veri kümesi kullanılarak X mahsulü ile eğitip, X mahsulü ile sınanması.
- ii) Etiketli X mahsulü veri kümesi kullanılarak X mahsulü ile eğitip, Y mahsulü ile sınanması.
- iii) Etiketli X mahsulü veri kümesi kullanılarak X mahsulünün kaynak alan, etiketsiz verilerin kullanıldığı Y mahsulünün hedef alan olacak şekilde eğitip, etiketli Y mahsulü ile sınanması.

Görüntüler sol üst köşesinden başlanıp ağ mimarisinin girişine uygun boyutlara parçalanmıştır. Bu sayede CA17 ve ON17 için görüntü başına $4 \times 4 = 16$ örnek elde edilirken, SB16 giriş görüntülerinin her birinden $2 \times 2 = 4$ örnek elde edilmiştir.

AdvEnt [17] ve AdvEnt_Div'in üretici ağ yapısı, aynı zamanda MinEnt [17] mimarisi de aynı ağ yapısına sahiptir, girdi olarak etiketli kaynak alan veri kümesinden ve etiketsiz hedef alan veri kümesinden görüntüleri alır. Üretici ağ mimarisini eğitmek için 0.9 momentum, 10^{-2} öğrenme oranı ve 5×10^{-4} ağırlık azalmasına sahip Rastgele Gradyan İniş iyileştirici [72] uygulanmıştır. Ayırıştırıcı ağ mimarisi ise girdi olarak üretici ağ mimarisinin ürettiği bölütleme haritalarından oluşturulan entropi haritalarını alır. Ayırıcıyı eğitmek için 10^{-4} öğrenme oranına sahip Adam iyileştirici [73] uygulanmıştır.

Tablo 3.1: Gözetimsiz Alan Uyarlaması Yaklaşımındaki Görüntü Sayıları.

Kaynak Alan	Hedef Alan	Kaynak Eğitim Görüntü Sayısı	Hedef Eğitim Görüntü Sayısı	Hedef Sınama Görüntü Sayısı	Hedef Test Görüntü Sayısı
ON17	CA17	320	236	20	64
ON17	SB16	320	793	113	226
CA17	SB16	320	793	113	226
SB16	CA17	1132	236	20	64

Her üç ağ mimarisinde de eğitim aşamasında toplu iş boyutu 1 olarak belirlenmiştir ve kayıp değeri hesabı için kaynak veri kümesinin sınıf yoğunlukları ile ters orantılı ağırlıklar kullanılmıştır. Deneyler Google Colab ortamında gerçekleştirilmiş olup Tesla T4 ekran kartı kullanılmıştır.

3.2.4. Sonuçlar

Alan uyarlaması kısmında bahsedilen birinci deney SegNet [5] ağ mimarisi kullanılarak soğan, şeker pancarı ve havuç veri kümeleri için gerçekleştirilmiştir. Deneyde kullanılan veri kümesinin %80’ni eğitim, %20’si test için kullanılmıştır. Sonuçları Tablo 3.2’te görülmektedir.

Tablo 3.2: Alan Uyarlaması Yaklaşımları Deney 1 Sonuçları.


Yöntem	Eğitim	Sınama	Kappa	mIoU (%)
SegNet [5]	SB16	SB16	0.78	78.29
SegNet [5]	CA17	CA17	0.79	72.34
SegNet [5]	ON17	ON17	0.77	76.91

Deneyin ikinci aşamasında, birinci deney setinde eğitilen ağ mimarileri kullanılmıştır. Ancak sınama işlemi eğitimde kullanılan veri kümesi dışındaki mahsul veri kümeleri için gerçekleştirilmiştir. Sonuçları Tablo 3.3’te gösterilmiştir.

Deneyin üçüncü aşamasında ise AdvEnt [17], MinEnt [17] ve AdvEnt_Div mimarileri kullanılarak şeker pancarı, soğan ve havuç veri kümeleri için denemeler yapılmıştır. Tablo 3.3’te deney sonuçları gösterilmiştir. Örnek bir şeker pancarı görüntüsü için yaklaşımların tahminleri paylaşılmıştır (Şekil 3.9).

Tablo 3.3: Alan Uyarlaması Yaklaşımları Deney Seti 2 / Deney Seti 3 Sonuçları.

Yöntem	Kaynak Alanı / Eğitim	Hedef Alan / Sınama	Kappa	mIoU (%)
SegNet [5]	ON17	CA17	0.5	46.61
MinEnt [17]	ON17	CA17	0.55	44.82
AdvEnt [17]	ON17	CA17	0.56	45.55
AdvEnt+KL	ON17	CA17	0.56	47.56
AdvEnt+JS	ON17	CA17	0.55	45.42
AdvEnt+MOT_rbf	ON17	CA17	0.55	45.28
AdvEnt+MOT_multi	ON17	CA17	0.55	46.3
SegNet [5]	ON17	SB16	0.007	30.58
MinEnt [17]	ON17	SB16	0.31	35.89
AdvEnt [17]	ON17	SB16	0.25	35.7
AdvEnt+KL	ON17	SB16	0.26	33.9
AdvEnt+JS	ON17	SB16	0.19	32.65
AdvEnt+MOT_rbf	ON17	SB16	0.19	33.9
AdvEnt+MOT_multi	ON17	SB16	0.17	32.42
SegNet [5]	CA17	SB16	0.09	32.59
MinEnt [17]	CA17	SB16	0.37	36.83
AdvEnt [17]	CA17	SB16	0.31	34.52
AdvEnt+KL	CA17	SB16	0.41	39.28
AdvEnt+JS	CA17	SB16	0.33	34.98
AdvEnt+MOT_rbf	CA17	SB16	0.40	41.39
AdvEnt+MOT_multi	CA17	SB16	0.32	35.52
SegNet [5]	SB16	CA17	0.44	44.18
MinEnt [17]	SB16	CA17	0.49	39.25
AdvEnt [17]	SB16	CA17	0.59	47.27
AdvEnt+KL	SB16	CA17	0.59	48.63
AdvEnt+JS	SB16	CA17	0.58	48.15
AdvEnt+MOT_rbf	SB16	CA17	0.57	48.23
AdvEnt+MOT_multi	SB16	CA17	0.55	45.51



Şekil. 3.10: Şeker pancarı görüntüsü için yöntem tahminleri. (a) RGB görüntü, (b) Etiket görüntüsü, (c) SB16 veri kümesi ile eğitilmiş SegNet tahmini, (d) CA17 veri kümesi ile eğitilmiş SegNet tahmini, (e) Kaynak alanı CA17, hedef alanı SB16 olan AdvEnt tahmini ve (f) Kaynak alanı CA17, hedef alanı SB16 olan MinEnt tahmini. Tüm etiket görüntülerinde mahsuller kırmızı, yabani otlar mavi, toprak siyah olarak gösterilir.

3.2.5. Tartışma

Tablo 3.3'te görüldüğü gibi AdvEnt[17] ve MinEnt[17] alan uyarlaması yöntemleri karşılaştırıldığında farklılıklar olsa dahi birbirlerine benzer sonuçlar verdikleri görülmüştür. Ancak MinEnt [17] yönteminde ayırıcı ağ yapısı olmadığından dolayı eğitim süresinin daha kısa sürdüğü gözlemlenmiştir.

Kaynak ve hedef alanlar arasındaki dağılım farkını ölçen metrikler karşılaştırıldığında birbirlerine yakın sonuçlar verdiği görülmüştür. Ancak genel olarak KL sonuçlarının daha iyi olduğu görülmüştür. Metriklerin ayrıştırıcının öğrenme yeteneğini geliştirerek üreticinin performansını iyileştirdiğini ve böylece AdvEnt_Div'in AdvEnt mimarisine göre daha iyi sonuçlar verdiği gözlemlenmiştir.

Deney sonuçlarına göre alan uyarlaması yöntemlerinin, bir yabani ot ve mahsul çeşidi için eğitilmiş sınıflandırıcının farklı bir mahsul çeşidi içinde uyarlanabilmesi açısından, SegNet [5] ağ yaklaşımına göre daha iyi sonuçlar verdiği gözlemlenmiştir.

3.2.6. Parametre Analizi

Üretici ağı F'yi optimize ederken, bölütleme ve çekişmeli kayıplar (çekişme kaybı ve farklılık kaybı) arasındaki ağırlığı dengelemek esastır. Bundan dolayı λ ve β 'yi değiştirmenin etkisini gözlemlemek için deneyler yapılmıştır. Deneylerde kaynak alan olarak soğan veri kümesi kullanılırken havuç veri kümesi hedef alan olarak kullanılmıştır. Tablo 3.4 ve Tablo 3.5, daha küçük bir λ 'nın eğitim sürecini önemli ölçüde kolaylaştırmayacağını, daha büyük bir λ 'nın ağıya yanlış gradyanlar yayabileceğini göstermektedir. β değerini, λ değerine benzer yönde değiştirilmesinin eğitim sürecini dengelediği görülmüştür. Buna rağmen daha büyük veya daha küçük β değerlerinin eğitim sürecine etkisinin λ 'ya benzer olduğu gözlemlenmiştir. Bundan dolayı λ , 0.001 olarak seçilirken β , 0.00025 olarak seçilmiştir.

Tablo 3.4: Katsayı Deneyleri Kappa Sonuçları.

λ / β	0.000125	0.00025	0.0005	0.001	0.002	0.004
0.0005	0.37	0.50	0.46	0.47	0.40	0.21
0.001	0.48	0.56	0.54	0.52	0.51	0.41
0.002	0.25	0.27	0.21	0.28	0.37	0.47
0.004	0.30	0.28	0.22	0.35	0.41	0.50

Tablo 3.5: Katsayı Deneyleri mIoU (%) Sonuçları.

λ / β	0.000125	0.00025	0.0005	0.001	0.002	0.004
0.0005	38.29	43.69	42.54	43.15	40.4	35.53
0.001	42.26	47.56	45.0	43.47	44.45	42.83
0.002	37.23	38.24	32.79	39.32	40.63	42.88
0.004	36.13	35.18	34.64	38.88	42.12	43.73

4. MORFOLOJİK YAKLAŞIMLARIN YABANI OT VE MAHSUL SINIFLANDIRMAYA UYGULANMASI

Aşınım veya genleşme işlemi gerçekleştiren morfolojik nöronların bulunduğu ağ mimarisinin yabani ot ve mahsul sınıflandırma görevindeki etkisinin incelenmesi hedeflenmektedir.

4.1. Yaklaşımlar

Genleşme ve aşınım işlemleri görüntü işlemede birçok farklı alanda başarılı bir şekilde kullanılmaktadır. Literatürde farklı problemlerin çözümleri için bu işlemler ile tasarlanan morfolojik sinir ağlar ve bu ağların geliştirilmesi için farklı yaklaşımlar önerilmiştir [39, 42]. Morfolojik sinir ağlar ile yapılan çalışmalarda evrişimli sinir ağları ile çok benzer sonuçlar elde edildiği gözlemlenmiştir [74]. Bu bölümde görüntüyü yağmurdan arındırma görevi için önerilen morfolojik ağ mimarisi [74], yabani ot ve mahsul sınıflandırma görevine uygulanarak performansı incelenmiştir. Bunun yanı sıra morfolojik işlem tabanlı kodlayıcı – kod çözücü yapısına sahip yeni bir ağ mimarisi önerilmiştir.

Mimaride kullanılan girdi, sınıf ağırlıkları ve çıktı bilgileri anlamsal bölütleme ağ mimarisindeki gibi uygulanmıştır, detaylara bölüm 3.1.4'te yer verilmiştir.

Morfolojik sinir ağları ve evrişimsel sinir ağları arasındaki temel fark, her bir düğümün sayısal bilgiyi cebirsel olarak işlemi biçiminde kaynaklanmaktadır. Evrişimsel sinir ağlarında çarpma ve toplama işlemleri kullanılarak bilgi işlenirken morfolojik sinir ağlarında bunların yerini toplama ve maksimum (genleşme) veya minimum (aşınım) işlemleri almıştır. Genleşme ($\oplus$) ve aşınım ($\ominus$) işlemleri I görüntüsü, dört kanallı $m \times n$ boyutlu, üzerinde aşağıdaki şekilde tanımlanmaktadır.


$$(I \oplus W_d)(x, y) = \max_{i \in S_1, j \in S_2} (I(x - i, y - j) + W_d(i, j)) \quad (4.1)$$

$$(I \ominus W_e)(x, y) = \min_{i \in S_1, j \in S_2} (I(x + i, y + j) - W_e(i, j)) \quad (4.2)$$


W_d ve W_e , genişleme ve aşınım işlemlerinin yapılandırma elemanlarıdır ve $W_d \in R^{a \times b}$, $W_e \in R^{a \times b}$, $S_1 = \{1, 2, \dots, a\}$ ve $S_2 = \{1, 2, \dots, b\}$ tanımlanır. Yapılandırma elemanları (W_d , W_e) rastgele başlatılır ve geri yayılım ile optimize edilir.

Genişleme ve aşınım işlemlerinin daha etkin şekilde işlev görebilmeleri için çoklu genişleme ve aşınım işlemlerinden yararlanılmıştır [74]. Genişleme ve aşınım işlemlerinin uygulama sırası farklı sonuçlar verdiği için Path1 (Şekil 4.1.a) ve Path2 (Şekil 4.1.b) olmak üzere iki mimari kullanılmıştır. Path1 mimarisinde, 4 filtreli çoklu genişleme ve aşınım katmanlarından oluşan sırasıyla genişleme ve aşınım katmanının ardından 1 filtreli aşınım katmanı ve son olarak her bir özellik vektörünü istenen sayıda sınıfa eşlemek için bir evrişim katmanı kullanılır. Path2 mimarisi, Path1 mimarisindeki benzer katmanlara sahiptir ancak genişleme ve aşınım katman sırası farklıdır ve aşınım katmanı yerine genişleme katmanı kullanılır. Bu iki mimari birleştirilerek MorphoN (Şekil 4.1.c) mimarisi oluşturulmuştur, her iki mimariden gelen sonuçların birleşme işleminde eşitlik (4.3) kullanılmıştır. MorphoN_Small (Şekil 4.1.d), MorphoN'e nispeten daha az sayıda öğrenilebilir parametre sayısına sahip daha hafif bir mimaridir.

$$\text{Çıktı} = \frac{W_o \odot P1 + W_c \odot P2}{W_o + W_c} \quad (4.3)$$




Şekil 4.1: Morfolojik sinir ağı mimarileri. a) Path1 mimarisi, b) Path2 mimarisi, c) MorphoN mimarisi, d) MorphoN_Small mimarisi.




Şekil 4.1: Devam.

Morfolojik görüntü işlemede, genişleme ve aşınım işlemleri birleştirilerek açma veya kapama işlemi olarak kullanılır. Morfolojik işlemlerin ve evrişim işleminin yabani ot ve mahsul sınıflandırma görevindeki etkisinin karşılaştırılabilmesi için MorphoN_Seg1, MorphoN_Seg2 ve SegNet_Small mimarileri (Şekil 4.2) oluşturulmuştur. SegNet_Small mimarisi, referans alınan SegNet [5] mimarisi ile benzer yapıya sahiptir ancak 64 filtrelili evrişim katmanları yerine 16 filtrelili evrişim katmanları kullanılmıştır (donanımsal sebeplerden dolayı). MorphoN_Seg1 mimarisi, SegNet [5] mimarisi ile aynı yapıdadır fakat evrişim katmanları sırasıyla 16 filtrelili kapama ve açma işlemleri ile yer değiştirmiştir. Ayrıca SegNet [5]'de evrişim katmanlarının ardından gelen aktivasyon fonksiyonları, morfolojik işlemlerin doğrusal olamayan yapıları dayanması sebebiyle kaldırılmıştır. MorphoN_Seg2 mimarisi ise kapama ve açma işlemlerinin sırasının etkisini incelemek için oluşturulmuştur ve yapı olarak MorphoN_Seg1 aynıdır yalnızca kapama, açma işlemlerinin sırası farklıdır.



Şekil 4.2: SegNet ve benzer yapıya sahip morfolojik sinir ağı mimarileri.
a) SegNet_Small, b) MorphoN_Seg1, c) MorphoN_Seg2



Şekil 4.2: Devam.

4.2. Deneyler

Bu bölümde bu tez kapsamında morfolojik yöntemler için yapılan bir dizi deneyin ayarları ve sonuçları paylaşılacaktır.

4.2.1. Veri Kümeleri

Deneyler, alan uyarlaması yaklaşım deneylerinde kullanılan veri kümeleri üzerinde gerçekleştirilmiştir. Ayrıntılara bölüm 3.2.1’de yer verilmiştir.

4.2.2. Başarım Ölçütleri

Deneylerde mahsul sınıflandırma probleminin başarısını ölçmek için alan uyarlaması yaklaşım deneylerinde kullanılan ölçütler kullanılmıştır. Ayrıntılar bölüm 3.2.2’de verilmiştir.

4.2.3. Deney Ayarları

Deneylerimiz, yabancı ot ve mahsul sınıflandırma görevinde morfolojik ağ mimarilerinin performanslarını incelemek için tasarlandı. Amaç, morfolojik işlemlerin yabancı ot ve mahsul sınıflandırma görevindeki etkisini incelemek ve morfolojik işlem tabanlı sinir ağ mimarileri ile evrişim işlemi tabanlı sinir ağ mimarilerinin bu görevindeki etkisini karşılaştırmaktır. Tüm veri kümeleri için deneyler gerçekleştirilmiştir:

- i) Etiketli X mahsul veri kümesi kullanılarak X mahsulü ile eğitip, X mahsulü ile sınanması.

Görüntüleri kullanılacak ağın giriş katmanının boyutlarına göre uygun hale getirmek amacıyla, görüntü sol üst köşesinden başlanarak uygun boyutlara ayrılmıştır. Böylelikle CA17 ve ON17 için görüntü başına $4 \times 5 = 20$ örnek elde edilirken, SB16 giriş görüntülerinin her birinden $2 \times 2 = 4$ örnek elde edilmiştir.

Tablo 4.1: Morfolojik Yaklaşımlarda Kullanılan Görüntü Sayıları.

Veri Kümesi	Görüntü Boyutu	Kanal Sayısı	Eğitim Görüntü Sayısı	Sınama Görüntü Sayısı	Test Görüntü Sayısı
SB16 [4]	512x384	RGB + NIR	852	56	224
CA17 [5]	512x384	RGB + NIR	300	20	80
ON17 [5]	512x384	RGB + NIR	300	20	80

İncelenen morfolojik sinir ağlarının tümünün eğitimi için 10^{-2} öğrenme oranı, 0.9 momentuma sahip Rastgele Gradyan İniş eniyileştirici [72] uygulanıyor. SegNet_Small ağının eğitimi için 10^{-2} öğrenme oranı, 0.9 momentum ve 5×10^{-4} ağırlık azalmasına sahip Rastgele Gradyan İniş eniyileştirici [72] uygulanıyor. Bunu yanı sıra toplu iş boyutu 4 olarak belirlenmiştir.


Tüm mimarilerde eğitim sırasında kayıp değeri hesabı için eğitim veri kümesinin sınıf yoğunlukları ile ters orantılı ağırlıklar kullanılmıştır. Deneyler Google Colab ortamında gerçekleşmiş olup Tesla T4 ekran kartı kullanılmıştır.

4.2.4. Sonuçlar

Referans alınan morfolojik sinir ağları için belirtilen deney, Path1 [74], Path2 [74], MorphoN [74], MorphoN_Small [74] ağ mimarileri kullanılarak soğan, şeker pancarı ve havuç veri setleri için gerçekleştirilmiştir. Deneyde kullanılan veri kümesinin %80'ni eğitim, %20'si test için kullanılmıştır. Sonuçları Tablo 4.2'de gösterilmiştir. Örnek görüntüler için yöntemlerin tahminleri paylaşılmıştır (Şekil 4.3).

Tablo 4.2: Morfolojik Yaklaşımların Deney Sonuçları.

Yöntem	Eğitim	Sınama	Kappa	mIoU (%)
Path1	SB16	SB16	0.62	58.91
Path2	SB16	SB16	0.28	38.39
MorphoN	SB16	SB16	0.58	56.59
MorphoN_Small	SB16	SB16	0.63	58.93
Path1	CA17	CA17	0.33	29.82
Path2	CA17	CA17	0.33	29.95
MorphoN	CA17	CA17	0.58	42.93
MorphoN_Small	CA17	CA17	0.58	42.83
Path1	ON17	ON17	0.56	41.06
Path2	ON17	ON17	0.10	23.26
MorphoN	ON17	ON17	0.45	38.23
MorphoN_Small	ON17	ON17	0.52	40.14




Şekil 4.3: Morfolojik yaklaşım tahminleri. Tüm görüntülerde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.

Evriřimli sinir ađı ve morfolojik sinir ađ modellerinin karřılařtırılması iin yapılan deney sonuları Tablo 4.3 paylařılmıřtır. rnek grntler iin yaklařımların tahminleri paylařılmıřtır (řekil 4.4).

Tablo 4.3: Morfolojik Sinir Ađları ve Evriřimli Sinir Ađı Deney Sonuları.

Yntem	Eđitim	Sınama	Kappa	mIoU (%)
MorphoN_Seg1	SB16	SB16	0.48	51.89
MorphoN_Seg2	SB16	SB16	0.27	37.91
SegNet_Small	SB16	SB16	0.89	73.63
MorphoN_Seg1	CA17	CA17	0.40	34.06
MorphoN_Seg2	CA17	CA17	0.34	30.91
SegNet_Small	CA17	CA17	0.81	75.76
MorphoN_Seg1	ON17	ON17	0.33	34.96
MorphoN_Seg2	ON17	ON17	0.07	20.00
SegNet_Small	ON17	ON17	0.73	70.77



Şekil 4.4: Morfolojik sınır ağları ve evrişimli sınır ağı tahminleri. Tüm görüntülerde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.

4.2.5. Tartışma

Path1 ve Path2 mimarileri ile yapılan deney sonuçlarından (Tablo 4.2) anlaşılacağı gibi genleşme ve aşınım işlemlerinin sırasının yabancı ot ve mahsul sınıflandırma performansını etkilediği gözlemlenmiştir. Bunun yanı sıra MorphoN_Small mimarisinin MorphoN göre daha iyi sonuç verdiği görülmektedir. Bunun ise MorphoN_Small mimarisinin başlangıçtaki çoklu aşınım ve genleşme

katman sayısının daha fazla olması sayesinde daha etkin şekilde işlev görebilmesinden kaynaklandığı düşünülmektedir.

Tablo 4.3'ten anlaşıldığı üzere veri küme büyüklüğünün, evrişimli sinir ağları ile morfolojik sinir ağları üzerinde benzer etkisi bulunmaktadır. Her iki sinir ağının da büyük veri kümesi üzerinde daha iyi sonuçlar verdiği gözlemlenmiştir. Evrişimli sinir ağının yabani ot ve mahsul sınıflandırma performansının morfolojik yaklaşımlara nazaran daha iyi olduğu gözlemlenmiştir. Bunun sebebinin evrişim katmanlarının uzamsal bilgiyi daha iyi kullanabilmesinden kaynaklandığı düşünülmektedir.

4.2.6. Parametre Analizi

Mahsulü ve yabani otu sınıflandırma görevinde morfolojik işlemlerde uygulanan filtre boyutlarının etkisini incelemek ve başarımı geliştirmek için farklı filtre boyutları ile deneyler yapılmıştır. Kapama işlemi ile başlayan MorphoN_Seg1 ağ mimarisinin daha iyi sonuçlar verdiği gözlemlendiği için deneyler bu mimari üzerinde gerçekleştirilmiştir.

Filtre boyutlarında yapılacak değişikliklerde ağ mimarisi kapama ve açma işlem çiftlerinden oluşan dört gruba ayrılmıştır (Şekil 4.5). Böylece her gruptaki kapama ve açma katmanları için uygulanan filtre boyutları aynı kalmıştır. Uygulanan filtre boyut bilgileri Tablo 4.4'te verilmiştir. Tablo 4.5, filtre boyutunun kodlayıcı- kod çözücü mimarisine benzer olarak değişim göstermesinin sonuçları iyileştirdiği ancak filtre boyutunun dengeli bir büyüklüğe sahip olması gerektiği gözlemlenmiştir.

Tablo 4.5: Filtre Boyutları Deney Sonuçları.

Yöntem	Eğitim	Sınama	Kappa	mIoU (%)
MorphoN_Seg1	SB16	SB16	0.48	51.89
MorphoN_Seg3	SB16	SB16	0.53	55.30
MorphoN_Seg4	SB16	SB16	0.47	52.03
MorphoN_Seg5	SB16	SB16	0.51	53.53
MorphoN_Seg6	SB16	SB16	0.52	53.85
MorphoN_Seg1	CA17	CA17	0.40	34.6
MorphoN_Seg3	CA17	CA17	0.48	39.07
MorphoN_Seg4	CA17	CA17	0.33	30.32
MorphoN_Seg5	CA17	CA17	0.48	37.21
MorphoN_Seg6	CA17	CA17	0.42	35.26
MorphoN_Seg1	ON17	ON17	0.33	34.96
MorphoN_Seg3	ON17	ON17	0.34	35.08
MorphoN_Seg4	ON17	ON17	0.08	20.56
MorphoN_Seg5	ON17	ON17	0.11	22.21
MorphoN_Seg6	ON17	ON17	0.34	34.53

5. VARGI

Mahsulü ve yabancı otu sınıflandıran yöntemlerin başarılı kabul edilmesi ve ticari olarak kullanılabilir olması için değişen arazi şartları, mahsulün yetiştirme aşamalarındaki farklı görünüşleri ve mahsul çeşitleri gibi zorluklar için uyarlanabilmesi gerekmektedir. Bu tez kapsamında alan uyarlaması yaklaşımları ve morfolojik sinir ağı yaklaşımları ile yabancı ot ve mahsul sınıflandırma görevi ele alınmıştır.

Alan uyarlaması yöntemleri sayesinde geliştirilen bir yaklaşımın farklı mahsul türlerine gözetimsiz olarak uyarlanabilme yeteneğinin geliştirilmesi hedeflenmiştir. Entropi kaybı ve çekişme kaybı tabanlı referans alınan iki güncel yöntem ile uyarlanabilme yeteneği ölçülmüş ve kıyaslanmıştır. Gerçekleştirilen deneyler ile alan uyarlaması yaklaşımlarının, bir sınıflandırıcının farklı mahsul çeşitleri için uyarlanabilme yeteneğini geliştirdiği görülmüştür. Bunların yanı sıra çekişme kaybı tabanlı gözetimsiz alan uyarlaması yönteminin performansının geliştirilmesi için kaynak ve hedef alanlar arasındaki dağılım farkını ölçen farklı metriklerden faydalanılması önerilmiş ve etkisi incelenmiştir. Üç farklı veri kümesi üzerinde yapılan deneyler sonucunda Kullback-Leibler (KL) farklılık metriğinin, çekişme kaybı tabanlı yaklaşımın performansını geliştirdiği gözlemlenmiştir.

Morfolojik işlem tabanlı sinir ağlarının yabancı ot ve mahsul sınıflandırma görevindeki etkisi incelenmiştir. Referans alınan morfolojik işlem tabanlı dört farklı yöntemin sınıflandırma performansı ölçülmüştür. Farklı mahsul veri kümeleri üzerinde gerçekleştirilen deneyler, aşınım ve genişleme katmanlarının sırasının sınıflandırma performansı üzerinde etkisi olduğu ve çoklu aşınım ve genişleme katmanlarının daha iyi sınıflandırma performansı verdiğini göstermiştir. Bununla birlikte aşınım ve genişleme gibi morfolojik işlemler ile evrişim işleminin yabancı ot ve mahsul sınıflandırma üzerindeki performansının karşılaştırılabilmesi için kodlayıcı – kod çözücü yapısına sahip morfolojik sinir ağı mimarisi önerilmiştir. Evrişimli sinir ağlarının, morfolojik sinir ağlarına göre daha iyi sınıflandırma performansı verdiği görülmüştür. Ancak farklı filtre boyutları ile yapılan deneylerde morfolojik sinir ağlarının sınıflandırma performansının iyileştiği görülmüştür.

Gelecek çalışmalarda üretici ağlar üzerine kurulmuş yaklaşımlar veya öz eğitim yaklaşımları gibi farklı açılardan alan uyarlamasını ele alan yöntemlerin farklı

mahsul eřitleri iin uyarlanabilme yeteneėine etkisi incelenebilir ve iyileřtirilebilir. Ayrıca alan uyarlaması yöntemleri ile farklı mahsul eřitleri iin uyarlanabilme yeteneėinin geliřtirilmesinin yanı sıra mahsullerin yetiřme ařamalarında sahip olduėu farklı grnmler iin de uyarlanabilme yeteneėinin iyileřtirilmesi hedeflenebilir.

KAYNAKLAR

- [1] Di Cicco M., Potena C., Grisetti G., Pretto A., (2017), “Automatic model based dataset generation for fast and accurate crop and weeds detection”, 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 5188-5195, Vancouver, BC, Canada, 24-28 September.
- [2] Lottes P., Behley J., Milioto A., Stachniss C., (2018), “Fully convolutional networks with sequential information for robust crop and weed detection in precision farming”, IEEE Robotics and Automation Letters, 3(4), 2870-2877.
- [3] Milioto A., Lottes P., Stachniss C., (2018), “Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in CNNs”, 2018 IEEE international conference on robotics and automation (ICRA), 2229-2235, Brisbane, QLD, Australia, 21-25 May.
- [4] Chebrolu N., Lottes P., Schaefer A., Winterhalter W., Burgard W., Stachniss C., (2017), “Agricultural robot dataset for plant classification, localization and mapping on sugar beet fields”, The International Journal of Robotics Research, 36(10), 1045-1052.
- [5] Bosilj P., Aptoula E., Duckett T., Cielniak G., (2020), “Transfer learning between crop types for semantic segmentation of crops versus weeds in precision agriculture”, Journal of Field Robotics, 37(1), 7-19.
- [6] Badrinarayanan V., Kendall A., Cipolla R., (2017), “Segnet: A deep convolutional encoder-decoder architecture for image segmentation”, IEEE transactions on pattern analysis and machine intelligence, 39(12), 2481-2495.
- [7] Ronneberger O., Fischer P., Brox T., (2015), “U-net: Convolutional networks for biomedical image segmentation”, International Conference on Medical image computing and computer-assisted intervention, 234-241, Munich, Germany, 5-9 October.
- [8] Long J., Shelhamer E., Darrell T., (2015)., “Fully convolutional networks for semantic segmentation”, Proceedings of the IEEE conference on computer vision and pattern recognition, 3431-3440, Boston, MA, USA, 7-12 June.
- [9] Toldo M., Maracani A., Michieli U., Zanuttigh P., (2020), “Unsupervised domain adaptation in semantic segmentation: a review”, Technologies, 8(2), 35.
- [10] Zhao H., Shi J., Qi X., Wang X., Jia J., (2017), “Pyramid scene parsing network”, Proceedings of the IEEE conference on computer vision and pattern recognition, 2881-2890, Honolulu, Hawaii, USA, 21-26 July.
- [11] Jiang J., (2008), “A literature survey on domain adaptation of statistical classifiers”, URL:http://sifaka.cs.uiuc.edu/jiang4/domain_adaptation/survey, 3(1-12), 3.

- [12]Sun S., Shi H., Wu Y., (2015), “A survey of multi-source domain adaptation”, *Information Fusion*, 24, 84-92.
- [13]Cordts M., Omran M., Ramos S., Rehfeld T., Enzweiler M., Benenson R., Schiele B., (2016), “The cityscapes dataset for semantic urban scene understanding”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3213-3223, Las Vegas, Nevada, USA, 27-30 June.
- [14]Neuhold G., Ollmann T., Rota Bulò S., Kotschieder P., (2017), “The mapillary vistas dataset for semantic understanding of street scenes”, *Proceedings of the IEEE international conference on computer vision*, 4990-4999, Venice, Italy, 22-29 October.
- [15]Richter S. R., Vineet V., Roth S., Koltun V., (2016), “Playing for data: Ground truth from computer games”, *European conference on computer vision*, 102-118, Amsterdam, The Netherlands, 8-16 October.
- [16]Ros G., Sellart L., Materzynska J., Vazquez D., Lopez A. M., (2016), “The synthia dataset: A large collection of synthetic images for semantic segmentation of urban scenes”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3234-3243, Las Vegas, Nevada, USA, 27-30 June.
- [17]Vu T. H., Jain H., Bucher M., Cord M., Pérez P., (2019), “Advent: Adversarial entropy minimization for domain adaptation in semantic segmentation”, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2517-2526, Long Beach, California, USA, 16-20 June.
- [18]Tsai Y. H., Hung W. C., Schuster S., Sohn K., Yang M. H., Chandraker M., (2018), “Learning to adapt structured output space for semantic segmentation”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7472-7481, Salt Lake City, Utah, USA , 18-22 June.
- [19] Kim M., Byun H., (2020), “Learning texture invariant representation for domain adaptation of semantic segmentation”, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 12975-12984, Virtual, 14-19 June.
- [20]Li Y., Yuan L., Vasconcelos N., (2019), “Bidirectional learning for domain adaptation of semantic segmentation”, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 6936-6945, Long Beach, California, USA, 16-20 June.
- [21]Pan F., Shin I., Rameau F., Lee S., Kweon, I. S., (2020), “Unsupervised intra-domain adaptation for semantic segmentation through self-supervision”, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 3764-3773, Virtual, 14-19 June.
- [22]Iqbal J., Ali M., (2020), “Msl: Multi-level self-supervised learning for domain adaptation with spatially independent and semantically consistent labeling”,

Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 1864-1873, Snowmass Village, CO, USA, 1-5 March.

- [23]Zhang Q., Zhang J., Liu W., Tao D., (2019), “Category anchor-guided unsupervised domain adaptation for semantic segmentation”, Advances in Neural Information Processing Systems, Vancouver, BC, Canada, 8-14 December.
- [24] Zou Y., Yu Z., Kumar B. V. K., Wang J., (2018), “Unsupervised domain adaptation for semantic segmentation via class-balanced self-training”, Proceedings of the European conference on computer vision (ECCV), 289-305, Munich, Germany, 8-14 September.
- [25]Geng B., Tao D., Xu C., (2011), “DAML: Domain adaptation metric learning”, IEEE Transactions on Image Processing, 20(10), 2980-2989.
- [26]Maria Carlucci F., Porzi L., Caputo B., Ricci E., Rota Bulò S., (2017), “Autodial: Automatic domain alignment layers”, Proceedings of the IEEE international conference on computer vision, 5067-5075, Venice, Italy, 22-29 October.
- [27]Mancini M., Porzi L., Bulò S. R., Caputo B., Ricci E., (2018), “Boosting domain adaptation by discovering latent domains”, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 3771-3780, Salt Lake City, Utah, USA , 18-22 June.
- [28]Hoffman J., Tzeng E., Park T., Zhu J. Y., Isola P., Saenko K., Darrell T., (2018), “Cycada: Cycle-consistent adversarial domain adaptation”, International conference on machine learning, 1989-1998, Stockholmsmässan, Stockholm SWEDEN, 10-15 July.
- [29]Zhu J. Y., Park T., Isola P., Efros A. A., (2017), “Unpaired image-to-image translation using cycle-consistent adversarial networks”, Proceedings of the IEEE international conference on computer vision, 2223-2232, Venice, Italy, 22-29 October.
- [30]Yu F., Zhang M., Dong H., Hu S., Dong B., Zhang L., (2021), “Dast: Unsupervised domain adaptation in semantic segmentation based on discriminator attention and self-training”, Proceedings of the AAAI Conference on Artificial Intelligence, 10754-10762, Palo Alto, California, USA, 2-9 February.
- [31]Krizhevsky A., Sutskever I., Hinton G. E., (2012), “Imagenet classification with deep convolutional neural networks”, Advances in neural information processing systems, 25, 1097-1105.
- [32]Isola P., Zhu J. Y., Zhou T., Efros A. A., (2017), “Image-to-image translation with conditional adversarial networks”, Proceedings of the IEEE conference on computer vision and pattern recognition, 1125-1134, Honolulu, Hawaii, USA, 21-26 July.

- [33]Ioffe S., Szegedy C., (2015), “Batch normalization: Accelerating deep network training by reducing internal covariate shift”, International conference on machine learning, 448-456, Lille, France, 6-11 July.
- [34]Srivastava N., Hinton G., Krizhevsky A., Sutskever I., Salakhutdinov R., (2014), “Dropout: a simple way to prevent neural networks from overfitting”, The journal of machine learning research, 15(1), 1929-1958.
- [35]Ritter G. X., Sussner P., (1996), “An introduction to morphological neural networks”, Proceedings of 13th International Conference on Pattern Recognition, 709-717, Vienna, Austria, 25-29 August.
- [36]Mondal R., Santra S., Chanda B., (2019), “Dense morphological network: An universal function approximator”, The International Conference on Learning Representations, New Orleans, LA, USA, 6-9 May.
- [37]Davidson J. L., Hummer F., (1993), “Morphology neural networks: An introduction with applications”, Circuits, Systems and Signal Processing, 12(2), 177-210.
- [38]Sussner P., (1998), “Morphological perceptron learning”, Proceedings of the 1998 IEEE International Symposium on Intelligent Control (ISIC) held jointly with IEEE International Symposium on Computational Intelligence in Robotics and Automation (CIRA) Intell, 477-482, Gaithersburg, MD, USA, 17-17 September.
- [39]Pessoa L. F., Maragos P., (2000), “Neural networks with hybrid morphological/rank/linear nodes: a unifying framework with applications to handwritten character recognition”, Pattern Recognition, 33(6), 945-960.
- [40]Nogueira K., Chanussot J., Mura M. D., Schwartz W. R., Santos J. A. D., (2021), “An introduction to deep morphological networks”, IEEE Access, 9, 114308-114324.
- [41]Araújo R. D. A., (2012), “A morphological perceptron with gradient-based learning for brazilian stock market forecasting”, Neural Networks, 28, 61-81.
- [42]Zamora E., Sossa H., (2017), “Dendrite morphological neurons trained by stochastic gradient descent”, Neurocomputing, 260, 420-431.
- [43]Beghin T., Cope J. S., Remagnino P., Barman S., (2010), “Shape and texture based plant leaf classification”, International conference on advanced concepts for intelligent vision systems, 345-353, Sydney, Australia, 13-16 December.
- [44]Kumar N., Belhumeur P. N., Biswas A., Jacobs D. W., Kress W. J., Lopez I. C., Soares J. V., (2012), “Leafsnap: A computer vision system for automatic plant species identification”, European conference on computer vision, 502-516, Firenze, Italy, 7-13 October.

- [45] Du J. X., Wang X. F., Zhang G. J., (2007), "Leaf shape based plant species recognition", *Applied mathematics and computation*, 185(2), 883-893.
- [46] Komi P. J., Jackson M. R., Parkin R. M., (2007), "Plant classification combining colour and spectral cameras for weed control purposes", 2007 IEEE International Symposium on Industrial Electronics, 2039-2042, Vigo, Spain, 4-7 June.
- [47] Thorp K. R., Tian L. F., (2004), "A review on remote sensing of weeds in agriculture", *Precision Agriculture*, 5(5), 477-508.
- [48] Hamuda E., Glavin M., Jones E., (2016), "A survey of image processing techniques for plant extraction and segmentation in the field", *Computers and Electronics in Agriculture*, 125, 184-199.
- [49] Bosilj P., Duckett T., Cielniak G., (2018), "Connected attribute morphology for unified vegetation segmentation and classification in precision agriculture", *Computers in industry*, 98, 226-240.
- [50] Haug S., Michaels A., Biber P., Ostermann J., (2014), "Plant classification system for crop/weed discrimination without segmentation", *IEEE winter conference on applications of computer vision*, 1142-1149, Steamboat Springs, CO, USA, 24-26 March.
- [51] Guerrero J. M., Pajares G., Montalvo M., Romeo J., Guijarro M., (2012), "Support vector machines for crop/weeds identification in maize fields", *Expert Systems with Applications*, 39(12), 11149-11155.
- [52] Binch A., Fox C. W., (2017), "Controlled comparison of machine vision algorithms for Rumex and Urtica detection in grassland", *Computers and Electronics in Agriculture*, 140, 123-138.
- [53] Bosilj P., Duckett T., Cielniak G., (2018), "Analysis of morphology-based features for classification of crop and weeds in precision agriculture", *IEEE Robotics and Automation Letters*, 3(4), 2950-2956.
- [54] Lottes P., Hörferlin M., Sander S., Stachniss, C., (2017), "Effective vision-based classification for separating sugar beets and weeds for precision farming", *Journal of Field Robotics*, 34(6), 1160-1178.
- [55] Lottes P., Khanna R., Pfeifer J., Siegwart R., Stachniss C., (2017), "UAV-based crop and weed classification for smart farming", 2017 IEEE International Conference on Robotics and Automation (ICRA), 3024-3031, Singapore, 29 May-3 June.
- [56] Milioto A., Lottes P., Stachniss C., (2017), "Real-time blob-wise sugar beets vs weeds classification for monitoring fields using convolutional neural networks", *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences*, 4, 41-48.

- [57] Zou K., Chen X., Wang Y., Zhang C., Zhang F., (2021), “A modified U-Net with a specific data argumentation method for semantic segmentation of weed images in the field”, *Computers and Electronics in Agriculture*, 187, 106242.
- [58] Meyer G. E., Neto J. C., (2008), “Verification of color vegetation indices for automated crop imaging applications”, *Computers and electronics in agriculture*, 63(2), 282-293.
- [59] Ponti M. P., (2012), “Segmentation of low-cost remote sensing images combining vegetation indices and mean shift”, *IEEE Geoscience and Remote Sensing Letters*, 10(1), 67-70.
- [60] Bai X., Cao Z., Wang Y., Yu Z., Hu Z., Zhang X., Li C., (2014), “Vegetation segmentation robust to illumination variations based on clustering and morphology modelling”, *Biosystems Engineering*, 125, 80-97.
- [61] Ruiz-Ruiz G., Gómez-Gil J., Navas-Gracia L. M., (2009), “Testing different color spaces based on hue for the environmentally adaptive segmentation algorithm (EASA)”, *Computers and Electronics in Agriculture*, 68(1), 88-96.
- [62] Li Y., Cao Z., Lu H., Xu W., (2020), “Unsupervised domain adaptation for in-field cotton boll status identification”, *Computers and Electronics in Agriculture*, 178, 105745.
- [63] Gogoll D., Lottes P., Weyler J., Petrinic N., Stachniss C., (2020), “Unsupervised Domain Adaptation for Transferring Plant Classification Systems to New Field Environments, Crops, and Robots”, 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2636-2642, Las Vegas, NV, USA, 24 October-24 January.
- [64] Ekinici S., Aptoula E. (2021), “Weed and Crop Classification with Domain Adaptation for Precision Agriculture”, 2021 29th Signal Processing and Communications Applications Conference (SIU), 1-4, Istanbul, Turkey, 9-11 June.
- [65] Shannon C. E., (1948), “A mathematical theory of communication”, *The Bell system technical journal*, 27(3), 379-423.
- [66] Liu M., Zhang P., Shi Q., Liu M., (2021), “An Adversarial Domain Adaptation Framework With KL-Constraint for Remote Sensing Land Cover Classification”, *IEEE Geoscience and Remote Sensing Letters*, 19, 1-5.
- [67] Deng J., Dong W., Socher R., Li L. J., Li K., Fei-Fei L., (2009), “Imagenet: A large-scale hierarchical image database”, 2009 IEEE conference on computer vision and pattern recognition, 248-255, Miami, FL, USA, 20-25 June.
- [68] He K., Zhang X., Ren S., Sun J., (2016), “Deep residual learning for image recognition”, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778, Las Vegas, Nevada, USA, 27-30 June.

- [69]Radford A., Metz L., Chintala S., (2016), “Unsupervised representation learning with deep convolutional generative adversarial networks”, 4th International Conference on Learning Representations, San Juan, Puerto Rico, 2-4 May.
- [70]Cohen J., (1960), “A coefficient of agreement for nominal scales”, Educational and psychological measurement, 20(1), 37-46.
- [71] Everingham M., Eslami S. A., Van Gool L., Williams C. K., Winn J., Zisserman A., (2015), “The pascal visual object classes challenge: A retrospective”, International journal of computer vision, 111(1), 98-136.
- [72]Bottou L., (2010), “Large-scale machine learning with stochastic gradient descent”, Proceedings of COMPSTAT'2010, 177-186, Paris, France, 22-27 August.
- [73]Kingma D. P., Ba J., (2015), “Adam: A method for stochastic optimization”, 3rd International Conference on Learning Representations, 1-15, San Diego, CA, USA, 7-9 May.
- [74]Mondal R., Purkait P., Santra S., Chanda B., (2019), “Morphological networks for image de-raining”, International Conference on Discrete Geometry for Computer Imagery, 262-275, Paris, France, 25-29 March.
- [75]Sodjinou S. G., Mohammadi V., Mahama A. T. S., Gouton P., (2021), “A deep semantic segmentation-based algorithm to segment crops and weeds in agronomic color images”, Information Processing in Agriculture.

ÖZGEÇMİŞ

Şeydanur Ekinci 2013 yılında başladığı Gebze Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünü 2018 yılında başarıyla tamamlayarak aynı yıl yüksek lisans eğitimine Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında başladı. 2018 – 2021 yılları arasında Türkiye Finans Katılım Bankası’nda yazılımcı görevinde çalıştı. 2021 yılından bu yana Kuveyt Türk Katılım Bankası’nda kıdemli yazılım mühendisi olarak çalışmaktadır.

EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Ekinci Ş., Aptoula E., (2021), “Weed and Crop Classification with Domain Adaptation for Precision Agriculture”, In 2021 29th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4), IEEE.

Ek B: Açıklamalar

Bu çalışma kısmi olarak TÜBA GEBİP programı tarafından desteklenmiştir.


Ek C: Anlamsal Bölütleme Ağ Mimarilerinin Mahsul/Yabani Ot Sınıflandırma Başarımına Etkisinin İncelenmesi

C.1. Anlamsal Bölütleme Yaklaşımlarının Uygulanması

Mahsul ve yabani ot sınıflandırma görevinde yabani ot yoğunluğu, yabani ot dağılımı, mahsulün büyüme aşamalarında farklı görünümlere sahip olması gibi çeşitli zorluklar ile başa çıkmak için farklı anlamsal bölütleme ağ mimarileri referans alınmıştır. Bu bölümde benzer şartlar altında, ince ayaları yapılmış ve bu alanda önerilmiş yaklaşımlarda kullanılan U-Net [7] ve FCN [8] mimarilerinin sınıflandırma performansları araştırılmıştır.

C.1.1. U-Net

Başlangıçta biyomedikal görüntü bölütleme için önerilen U-Net mimarisi [7], zamanla farklı anlamsal bölütleme görevlerine de uygulandı ve iyi bir performans gösterdiği gözlemlendi [75]. Bu mimari, uçta uca eğitilmiş olması ve küçük veri kümesi üzerinde iyi performansa göstermesi gibi nedenlerden dolayı yaygın olarak kullanılmaktadır [57]. U-Net, FNC mimarisi üzerinde değişiklikler yapılarak oluşturulmuş olup şeklinin "U" harfine benzemesinden (Şekil C1.1) dolayı bu şekilde isimlendirilmiştir.



Şekil C1.1: U-Net mimarisi.


U-Net, kodlayıcı ve kod çözücü olmak üzere iki aşamadan oluşmaktadır. Kodlama aşaması, ilk olarak tekrarlanan iki evrişim katmanı ile başlar, her bir evrişim katmanından sonra toplu normalleştirme katmanı, doğrultulmuş lineer birim (ReLU) katmanı gelir, ardından alt örnekleme için maksimum havuzlama katmanı takip eder. Her alt örnekleme işleminin ardından evrişim katmanındaki filtre sayısı iki katına çıkarılmıştır. Kod çözme aşamasındaki her adım, üst örnekleme katmanı ile başlar sonrasında kodlama aşamasından karşılık gelen öznetelik haritası ile ardışık olarak birleştirilir ve ardından kodlama aşamasında olduğu iki evrişim katmanı takip eder. Kod çözücü aşamasından sonra son katmanda, her bir öznetelik vektörünü istenen sayıda sınıfa eşlemek için bir evrişim katmanı kullanılır. Bunlara ek olarak, üç sınıflı tahmin problemi için yeterli bir model kapasitesi elde etmek için filtre sayıları değiştirilmiştir.

C.1.2. FCN

Anlamsal bölümlleme görevleri için FCN'lerin farklı uygulamalar için yüksek performans elde ettiđi gösterilmiştir [2]. Sahip kodlayıcı ve kod çözücü yapısından dolayı yatay kum saati gibi olduđu için "kum saati" benzeri modeller olarak isimlendirilmektedir. Bu mimarinin ana fikri tüm katmanlarının evrişim katmanı olmasıdır.

FCN'nin kodlayıcı kısmı VGG-16 modelinin yapısı kullanılmıştır. Kodlayıcı kısım, evrişim katmanlarını takip eden maksimum havuzlama katmanından oluşan yapının beş kere tekrarlaması ile oluşmaktadır. Bu kısımda her evrişim katmanın ardına doğrultulmuş lineer birim (ReLU) katmanı eklenmiştir. Kod çözücü kısmında ise sırasıyla aktarılmış bir evrişim katmanı ve ardından toplu normalleştirme katmanı gelen yapının yine beş kez tekrarlanmasıyla oluşur. Aktarılmış evrişim katmanı, maksimum havuzlama ile boyutları azalan girdinin orijinal boyutlarına erişebilmesi, yani girdi özellik haritasından daha büyük bir uzamsal boyuta sahip bir çıktı özellik haritası oluşturarak ve evrişim işleminin yapılması için eklenmiştir. Bunlara ek olarak sığ katmanlardaki uzamsal bilgiden faydalanabilmek için sığ katmanlar ile bulunduğumuz katmandaki tahminleri eleman bazında toplama ile birleştirilerek aktarılmış evrişim katmanına verilir. Mimarinin son katmanında ise evrişim katmanı bulunmaktadır. U-Net mimarisinde olduđu gibi bu mimaride de filtre sayıları düzenlenmiştir.

En derinde bulunan havuzlama katmanından gelen tahminlerin kullanıldığı mimariye FCN-32 (Şekil C1.2.a), son iki havuzlama katmanından, havuzlama 5 ve havuzlama 4, gelen tahminleri birleştirildiđi mimariye FCN-16 (Şekil C1.2.b), son üç havuzlama katmanında gelen tahminleri birleştirildiđi mimariye FCN-8 (Şekil C1.2.c) ve tüm havuzlama katmanından gelen tahminlerin kullanıldığı mimari ise FCN (Şekil C1.2.d) olarak adlandırılmaktadır.



C.1.3. Anlamsal Bölütleme Deney Ayarları

Deneylerimiz, yabani ot ve mahsul sınıflandırma görevinde kodlayıcı – kod çözücü yapısına dayanan ancak yapısal farklılıkları bulunan ve benzer parametre sayısına sahip anlamsal bölütleme ağ mimarilerinin performanslarını incelemek için tasarlandı. Amaç, kodlayıcı – kod çözücü yapısında daha sık katmanlardaki uzamsal bilgiden faydalanılarak sınıflandırma performansının geliştirilmesi için önerilen yöntemlerin, yabani ot ve mahsul sınıflandırma görevindeki etkisini kıyaslanmaktadır. Şeker pancarı, havuç ve soğan veri kümeleri için deney seti gerçekleştirilmiştir:

- i) Etiketli X mahsul veri kümesi kullanılarak X mahsulü ile eğitip, X mahsulü ile sınanması.

Görüntüleri kullanılacak ağın giriş katmanının boyutlarına göre uygun hale getirmek amacıyla, görüntü sol üst köşesinden başlanarak uygun boyutlara ayrılmıştır. Böylelikle CA17 ve ON17 için görüntü başına $4 \times 5 = 20$ örnek elde edilirken, SB16 giriş görüntülerinin her birinden $2 \times 2 = 4$ örnek elde edilmiştir.

Tablo C1.1: Anlamsal Bölütleme Yaklaşımlarda Kullanılan Görüntü Sayıları.

Veri Kümesi	Görüntü Boyutu	Kanal Sayısı	Eğitim Görüntü Sayısı	Sınama Görüntü Sayısı	Test Görüntü Sayısı
SB16 [4]	512x384	RGB + NIR	852	56	224
CA17 [5]	512x384	RGB + NIR	300	20	80
ON17 [5]	512x384	RGB + NIR	300	20	80

İncelenen ağların tümünün eğitimi için 0.9 momentum, 10^{-2} öğrenme oranı ve 5×10^{-4} ağırlık azalmasına sahip olan Rastgele Gradyan İniş iyileştiricisi [72] uygulanıyor. Öğrenme oranı, veri kümelerinin nispeten sınırlı boyutta olması ve pratik nedenlerden dolayı uzun süreli eğitimin bu bağlamda ilgi çekici olmaması gibi durumlar dikkate alınarak belirlenmiştir [5]. Bunu yanı sıra donanımın izin verdiği toplu iş boyutu 4 olduğundan dolayı 4 olarak belirlenmiştir.


Tüm mimarilerde eğitim sırasında kayıp değeri hesaplamak için eğitim verisinin sınıf yoğunlukları ile ters orantılı ağırlıklar kullanılmıştır. Deneyler Google Colab ortamında gerçekleşmiş olup Tesla T4 ekran kartı kullanılmıştır. Sınıflandırma başarısı için Cohen'in Kappa katsayısı [70] ve ortalama PASCAL VOC kesişimi-üzerinde-birleşme [71] ile ifade edilmiştir.

C.1.4. Anlamsal Bölütleme Deney Sonuçları

Anlamsal bölütleme mimarilerinde belirtilen deney, U-Net [7], FCN [8] mimarileri ile şeker pancarı, soğan ve havuç veri setleri için gerçekleştirilmiştir. Deneyde kullanılan veri kümesinin %80'ni eğitim, %20'si test için kullanılmıştır. Sonuçları Tablo C1.2' de görülmektedir. Örnek soğan görüntüsü için yöntemlerin tahminleri paylaşılmıştır (Şekil C1.3).

Tablo C1.2: Anlamsal Bölütleme Yaklaşımları Deney Sonuçları.

Yöntem	Eğitim	Sınama	Kappa	mIoU (%)
U-Net [7]	SB16	SB16	0.91	75.78
FCN-32 [8]	SB16	SB16	0.84	69.06
FCN-16 [8]	SB16	SB16	0.89	72.34
FCN-8 [8]	SB16	SB16	0.92	77.22
FCN [8]	SB16	SB16	0.90	73.67
U-Net [7]	CA17	CA17	0.81	75.81
FCN-32 [8]	CA17	CA17	0.75	69.47
FCN-16 [8]	CA17	CA17	0.80	74.19
FCN-8 [8]	CA17	CA17	0.80	73.96
FCN [8]	CA17	CA17	0.80	75.20
U-Net [7]	ON17	ON17	0.76	73.57
FCN-32 [8]	ON17	ON17	0.51	54.96
FCN-16 [8]	ON17	ON17	0.73	70.80
FCN-8 [8]	ON17	ON17	0.81	77.37
FCN [8]	ON17	ON17	0.83	79.26



Şekil C1.3: Soğan örnek görüntüsü için anlamsal bölütleme yaklaşım tahminleri. a) Etiket görüntüsü, b) U-Net tahmini, c) FCN tahmini, d) FCN-8 tahmini, e) FCN-16 tahmini, f) FCN-32 tahmini. Tüm görüntülerde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.

C.1.5. Anlamsal Bölütleme Deney Tartışma

Tablo C1.2 ‘de görüldüğü gibi tüm mimariler için en iyi Kappa değerleri şeker pancarı veri kümesinde üzerinde alınmıştır. Bu durumun şeker pancarı veri kümesinin diğer veri kümelerine göre yaklaşık 3 kat daha fazla görüntü içermesinden kaynaklandığı düşünülmektedir.

Tüm veri kümeleri üzerinde FCN-32 [8] mimarisinin, diğer mimarilere göre daha düşük sonuç verdiği gözlemlenmiştir. Bunun sebebinin ise uzamsal bilgiden yeterince faydalanılamadığından kaynakladığı düşünülmektedir.

C.2. Çoklu Alan Yaklaşımının Uygulanması

Bu bölümdeki çalışmalarda yukarıda yapısı anlatılmış SegNet [5] mimarisi kullanılmıştır. Ancak eğitimi sırasında farklı mahsul ve yabancı ot bulunan birden fazla veri kümesi kullanılmıştır.

C.2.1. Çoklu Alan Deney Ayarları

Deneylerimiz, mahsul ve yabancı ot sınıflandırma görevinde mahsul çeşitliliği güçlüğü ile başa çıkmak için ve çoklu alan yaklaşımının etkisini görmek için tasarlandı. Hedef, anlamsal bölütleme ağının çoklu veri kümesi ile eğitimi vasıtasıyla yabancı ot ve mahsul türlerini genelleyebilme yeteneğine etkisini incelemektir. Belirli veri kümeleri için deneyler gerçekleştirilmiştir:

- i) Etiketli X ve Y mahsul veri kümesi kullanılarak bir X mahsulü bir Y mahsulünde görüntü olacak şekilde eğitip, X ve Y mahsulü ile sınanması.
- ii) Etiketli X ve Y mahsul veri kümesi kullanılarak bir X mahsulü bir Y mahsulünde görüntü olacak şekilde eğitip, Z mahsulü ile sınanması.
- iii) Etiketli X ve Y mahsul veri kümesi kullanılarak bir döngü X mahsulü bir döngü Y mahsulü olacak şekilde eğitip, X ve Y mahsulü ile sınanması.
- iv) Etiketli X ve Y mahsul veri kümesi kullanılarak bir döngü X mahsulü bir döngü Y mahsulü olacak şekilde eğitip, Z mahsulü ile sınanması.

Görüntüler yine sol üst köşesinden başlanıp ağ mimarisinin girişine uygun boyutlara parçalanmıştır. Bu sayede CA17 ve ON17 için görüntü başına $4 \times 4 = 16$ örnek elde edilirken, SB16 giriş görüntülerinin her birinden $2 \times 2 = 4$ örnek elde edilmiştir.

Tablo C1.3: Çoklu Alan Yaklaşımında Kullanılan Görüntü Sayıları.

Deney Seti	Eğitim Veri Kümesi	Test Veri Kümesi	Eğitim Görüntü Sayısı	Sınama Görüntü Sayısı	Test Görüntü Sayısı
1	CA17+ON17	CA17+ON17	472	40	128
2	CA17+ON17	SB16	472	40	226
3	CA17	CA17+ON17	236	40	128
	ON17		236		
4	CA17	SB16	236	40	226
	ON17		236		


SegNet [5] eğitimi için 0.9 momentum, 10^{-2} öğrenme oranı sahip Rastgele Gradyan İniş iyileştirici [72] uygulanmıştır ve toplu iş boyutu 1 olarak belirlenmiştir. Eğitim aşamasında kayıp değer hesaplanması için eğitim veri kümesinin sınıf yoğunlukları ile ters orantılı ağırlıklar kullanılmıştır. Deneyler Google Colab ortamında gerçekleşmiş olup Tesla T4 ekran kartı kullanılmıştır. Sınıflandırma başarısı için Cohen'in Kappa katsayısı ve PASCAL VOC kesişimi-üzerinde-birleşme ile ifade edilmiştir.

C.2.2. Çoklu Alan Deney Sonuçları


Çoklu alan yaklaşımı için oluşturulan deney 1 ve deney 2’de eğitim için CA17 ve ON17 veri kümeleri birleştirilmiştir. Eğitim, sırasıyla CA17 veri kümesine ait bir görüntünün ağa verildikten sonra ON17 veri kümesine ait bir görüntünün ağa verilme işleminin tekrarlanmasıyla gerçekleşir. Deney 3 ve deney 4’te ise eğitim, sırasıyla CA17 veri kümesi ile bir döngü tamamladıktan sonra ON17 veri kümesi ile bir döngünün tamamlanma sürecinin yinelenmesiyle gerçekleşir. Deneylere ait sonuçları Tablo C1.4’ te görülmektedir. Örnek görüntüler için deney seti tahminleri paylaşılmıştır (Şekil C1.4 ve Şekil C1.5).

Tablo C1.4: Çoklu Alan Yaklaşımlarının Deney Sonuçları.

Deney Seti	Eğitim	Sınama	Kappa	mIoU (%)
1	CA17+ON17	CA17+ON17	0.41	41.48
2	CA17+ON17	SB16	0.18	36.22
3	CA17 ON17	CA17+ON17	0.65	58.49
4	CA17 ON17	SB16	0.38	50.68



Şekil C1.4: Çoklu Alan yaklaşımı Deney Seti 1 / Deney Seti 3 tahminleri. Tüm görüntülerde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.




Şekil C1.5: Çoklu Alan yaklaşımı Deney Seti 2 / Deney Seti 4 tahminleri. a) Etiket görüntüsü, b) Deney Seti 2 tahmini, c) Deney Seti 4 tahmini. Tüm görüntülerde mahsuller kırmızı, yabancı otlar mavi, toprak siyah olarak gösterilir.


C.2.3. Çoklu Alan Deney Tartışma

SegNet [5] mimarisi, ON17 veri kümesi ile eğitilip SB16 veri kümesi ile sınıandığında deney ve CA17 veri kümesi ile eğitilip SB16 veri kümesi ile sınıandığı deneydeki Kappa değerleri Tablo 3.3 görüldüğü üzere çok düşüktür. ON17 ve CA17 veri kümelerinin birleştirilerek SegNet [5] mimarisinin eğitilip SB16 ile sınıandığı deney sonuçları (Tablo C1.4) ile Tablo 3.3'teki ilgili deney sonuçları karşılaştırıldığında artış olduğu gözlemlenmiştir. Çoklu alan yaklaşımının, SegNet [5] mimarisi için şimdiye kadar görülmeyen yabancı ot ve mahsul türlerinin sınıflandırılması genelleştirilme başarısını artırdığı gözlemlenmiştir.


Ek D: Morfolojik Tabanlı Kodlayıcı - Kod Çözücü Ağ Mimarileri




Şekil D1.1: MorphoN_Seg1 ağ mimarisi.



Şekil D1.2: MorphoN_Seg3 ağ mimarisi.



Şekil D1.3: MorphoN_Seg4 ağ mimarisi.



Şekil D1.4: MorphoN_Seg5 ağ mimarisi.

