

**T.C.  
GEBZE TEKNİK ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**ÇOKLU-ZAMANLI UZAKTAN ALGILANMIŞ  
GÖRÜNTÜLERİN ÇÖZÜMLENMESİ**

**HATİCE KÜBRA TELOĞLU  
YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**GEBZE  
2022**

**T.C.**  
**GEBZE TEKNİK ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**ÇOKLU-ZAMANLI UZAKTAN**  
**ALGILANMIŞ GÖRÜNTÜLERİN**  
**ÇÖZÜMLENMESİ**

**HATİCE KÜBRA TELOĞLU**  
**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**

**ANALYSIS OF MULTITEMPORAL  
REMOTE SENSED IMAGES**

**HATİCE KÜBRA TELOĞLU**

**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 .....16/02/2022...tarihinde tez savunma sınavı yapılan Hatice Kübra TELOĞLU'nun tez çalışması Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

### JÜRİ

ÜYE  
(TEZ DANIŞMANI) : PROF. DR. ERCHAN APTOULA

ÜYE : PROF. DR. YUSUF SİNAN AKGÜL

ÜYE : DOÇ.DR. ALP ERTÜRK

### ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun  
...../...../..... tarih ve ...../..... sayılı kararı.

İMZA/MÜHÜR

## ÖZET

Tarım faaliyetlerinin izlenmesi ve denetlenebilmesi için çeşitli uydulardan herhangi bir konuma ait farklı spektral bantlarda ve farklı zamanlarda görüntüler elde edilmektedir. Bu görüntü verileri, arazi örtüsü, arazi kullanım haritası hesaplanması ve tarım alanlarında mahsul sınıflandırma gibi birçok uygulamada kullanılmaktadır. Bu spektral ve zamansal bilgilerden nasıl fayda sağlanacağı ve nasıl analiz edileceği, bu alanda hala açık bir sorundur. Bu çalışmada bu soruna, yani çoklu zamanlı uzaktan algılanmış mahsul görüntülerinin sınıflandırılması üzerine odaklanılmıştır.

Bu tez kapsamında mahsul sınıflandırma için uzaktan algılama alanında önemli problemlerden biri olan etiketli veri azlığına ve derin morfolojik ağların katkısı üzerine çalışmalar yapılmış ve iki farklı yöntem önerilmiştir. İlk yöntemde, her ne kadar uydulardan sürekli veri algılansa da ne yazık ki etiket üretimi son derece zahmetli ve pahalı bir süreçtir. Bu yüzden bol miktarda ulaşabildiğimiz etiketsiz verilerden azami derecede yararlanılması önemlidir. Bu amaç doğrultusunda, etiketsiz çoklu-zamanlı verileri mahsul sınıflandırma bağlamında kıymetlendirmek adına, yarı gözetimli uzun kısa vadeli bellek oto kodlayıcıları yaklaşımı önerilmiştir. İkinci yöntemde ise eğitilebilir morfolojik operatörlerin katkısını görmek için klasik morfolojik filtrelemeyi taklit eden morfolojik ağları kullanarak morfolojik uzun kısa vadeli bellek yaklaşımı önerilmiştir.

Bu tez için yapılan deneylerde literatürde zorlu bir zaman serisi olan Breizhcrops veri kümesi ve Türkiye'ye ait bir veri kümesi olan Sakarya kullanılmış ve önerilen yöntemler literatürde yapılan diğer çalışmalar ile karşılaştırılmıştır. Çalışmalar sonucunda mahsul sınıflandırma alanında önerdiğimiz yarı gözetimli uzun kısa vadeli bellek oto kodlayıcılar yaklaşımının literatürdeki en iyi başarımı veren yaklaşımın başarısına ulaştığı gözlemlenmiştir. Sonuçlar mahsul sınıflandırma alanında etiketsiz verilerin kullanım potansiyeline ışık tutmaktadır.

**Anahtar Kelimeler: Uzaktan algılama, mahsul sınıflandırma, multispektral, zaman serisi, Sentinel-2, uzun kısa-vadeli bellek oto kodlayıcısı, morfolojik uzun kısa vadeli bellek ağları.**

## SUMMARY

In order to monitor and control agricultural activities, images are obtained from various satellites in different spectral bands and at different times of any location. This image data is used in many applications such as land cover, land use map calculation and crop classification in agricultural areas. How to exploit and analyze this spectral and temporal information is still an open challenge in the field. This study focuses on the problem of classification of multi-temporal remotely sensed crop images.

Within the scope of this thesis, studies have been carried out on the contribution of deep morphological networks and the lack of labeled data, which is one of the important problems in the field of remote sensing for crop classification and two different methods have been proposed. In the first method, as satellites continuously detect data, label production is an extremely laborious and expensive process. That's why it's important to make the most of the unlabeled data that we have ample access to. For this purpose, a semi-supervised long-short-term memory autoencoder approach is proposed to evaluate unlabeled multi-temporal data in the context of crop classification. In the second method, a deep morphological long-short-term memory approach is proposed using morphological operators that mimics classical morphological filtering to study the contribution of trainable morphological operators.

In the experiments conducted for this thesis, the Breizhcrops dataset, which is a challenging time series in the literature, and Sakarya, a dataset from Turkey, were used and the proposed methods were observed and compared with other studies in the state-of-the-art. As a result of the studies, it has been observed that the proposed semi-supervised lstm autoencoder approach leads to performances comparable to the state-of-the-art. The results shed light on the potential for use of unlabeled data in the field of crop classification.

**Key Words: Remote sensing, crop classification, multispectral, time series, Sentinel-2, long short-term memory autoencoder, morphological long short-term memory networks.**

## TEŞEKKÜR

Bu çalışmanın gerçekleşmesinde rehberliği, motivasyonu, önerileri, üstün desteği ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu çalışmanın oluşmasının yolunu açan sayın danışmanım Prof. Dr. Erchan APTOULA'ya içten teşekkürlerimi sunarım. Bilgi birikimleriyle, her türlü yardımlarıyla bizi her daim ileriye taşıyan ve hayatları ile örnek olan saygıdeğer hocalarıma teşekkürlerimi sunarım.

Bu çalışmanın oluşmasında TUBİTAK 118E258 numaralı projeden sağlanan desteklerinden TÜBİTAK'a teşekkürlerimi sunarım.

Zor zamanlarımda hep yanımda olan hem lisans hem de yüksek lisans hayatımda desteğini esirgemeyen dostum Şeydanur EKİNCİ'ye teşekkürlerimi sunarım.

Son olarak, her zaman yanımda olan, kaybolduğumda doğru yolu gösteren ve bana her zaman inanan TELOĞLU ailesine sabrı, koşulsuz sevgisi ve desteği için teşekkürlerimi sunarım.

# İÇİNDEKİLER

	<b><u>Sayfa</u></b>
ÖZET	v
SUMMARY	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
1. GİRİŞ	1
1.1. Tezin Amacı ve Katkısı	1
1.2. Tezin Düzeni	2
2. LİTERATÜR TARAMASI	4
2.1. Literatür Değerlendirmesi	11
3. YÖNTEM	12
3.1. Uzun Kısa Vadeli Bellek Oto Kodlayıcıların Yarı Gözetimli Mahsul Sınıflandırmaya Uygulanması	12
3.1.1. Uzun Kısa Vadeli Bellek	13
3.1.2. Oto Kodlayıcılar	14
3.1.3. Uzun Kısa Vadeli Bellek Oto Kodlayıcılar	16
3.1.4. Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar	16
3.2. Morfolojik Uzun Kısa Vadeli Bellek Ağının Gözetimli Mahsul Sınıflandırmaya Uygulanması	19
3.2.1. Evrişimsel Sinir Ağı Uzun Kısa Vadeli Bellek (ESA-UVKB)	19
3.2.2. Morfolojik Uzun Kısa Vadeli Bellek (MSA-UVKB)	20
4. DENEYLER	24
4.1. Veri Kümeleri	24
4.1.1. Breizhcrops	24
4.1.2. Sakarya	26
4.2. Ayarlar	28
4.2.1. Veri Kümesi Eğitim/Test Bölümü Seçimi	28

4.2.2. Başarım Ölçütleri	28
4.2.3. Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar	29
Deney Ayarları	
4.2.4. Morfolojik Uzun Kısa Vadeli Bellek Ağı Deney Ayarları	31
4.3. Sonuçlar	32
4.4. Tartışma	42
5. VARGI	45
KAYNAKLAR	47
ÖZGEÇMİŞ	54
EKLER	55



# SİMGELER VE KISALTMALAR DİZİNİ

## Simgeler ve Açıklamalar Kısaltmalar

CCE	: Kategorik Çapraz Entropi
DVM	: Destek Vektör Makineleri
ESA	: Evrişimsel Sinir Ağı
GTÜ	: Gebze Teknik Üniversitesi
GAN	: Çekişmeli Üretici Ağı
GRU	: Kapılı Yinelemeli Üniteler
KA	: Karar Ağaçları
MsResNet	: Multi-Scale 1D Residual Network
MSA	: Morfolojik Sinir Ağı
MSE	: Ortalama Kare Hata
RO	: Rastgele Orman
sn	: Saniye
TSA	: Tekrarlayan Sinir Ağları
TempCnn	: Temporal CNN
UVKB	: Uzun Kısa Vadeli Bellek
YSA	: Yapay Sinir Ağları

# ŞEKİLLER DİZİNİ

<b><u>Sekil No:</u></b>	<b><u>Sayfa</u></b>
2.1:	Mahsullerin Gelişim Süreçleri. 5
2.2:	Standart bir tekrarlayan sinir ağı mimarisi, (a) standart birimdir ve (b), (a)'nın genişletilmiş bir şeklidir. 7
2.3:	Zamansal evrimsel sinir ağı (TempCNN). 9
2.4:	Transformer modeli. 10
3.1:	Oto Kodlayıcı. 13
3.2:	Önerilen Yaklaşım (Yarı-Gözetimli). 14
3.3:	ESA-UVKB Mimarisi. 17
3.4:	Önerilen Yaklaşım (MSA-UVKB). 18
3.5:	MSA içeriği. 19
4.1:	Breizhcrops bölgeleri: Cotes-d'Armor(FRH01), Finistere(FRH02), Ille-et-Vilaine(FRH03) ve Morbihan (FRH04). 19
4.2:	Breizhcrops bölgelere göre sınıf dağılımı. 20
4.3:	Türkiye Sakarya Havzası (beyaz ile gösterilmiştir). 21
4.4:	Sakarya Bölgeleri; etiketsiz eğitim (Sakarya3), etiketli eğitim(Sakarya2), doğrulama(Sakarya1), sınaama(Sakarya4). 22
4.5:	Sakarya bölgelere göre sınıf dağılımı. 23
B.1.1:	Yarı Gözetimli Yaklaşım (GRU ile). 59
B.1.2:	ESA-UVKB. 60
B.1.3:	ESA içeriği. 61
B.1.4:	morphoN. 62
B.1.5:	morphoN(small). 62
B.1.6:	MorphoN-path1. 62
B.1.7:	MorphoN-path2. 63
B.1.8:	morphoN-UVKB. 64
B.1.9:	morphoN(small)-UVKB. 65
B.1.10:	MorphoN-path1-UVKB. 66
B.1.11:	MorphoN-path2-UVKB. 66

## TABLULAR DİZİNİ

<b><u>Tablo No:</u></b>	<b><u>Sayfa</u></b>
4.1: Breizhcrops veri kümesindeki örneklerin bölgelere göre sınıf dağılımı.	20
4.2: Sakarya veri kümesindeki örneklerin bölgelere göre sınıf dağılımı.	21
4.3: Etiketsiz eğitim parametreleri (1.aşama).	38
4.4: Etiketli eğitim parametreleri (2.aşama).	39
4.5: MSA-UVKB parametreleri.	40
4.6: Breizhcrops Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar(Yarı Gözetimli) Sonuçları.	45
4.7: Breizhcrops Literatür Yaklaşımları ile Karşılaştırma.	45
4.8: Breizhcrops Eğitim Süresi ve Parametre Sayıları.	46
4.9: Sakarya Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar(Yarı Gözetimli) Sonuçları.	47
4.10: Sakarya Literatür Yaklaşımları ile Karşılaştırma.	48
4.11: Sakarya Eğitim Süresi ve Parametre Sayıları.	48
4.12: Breizhcrops Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Sonuçları.	49
4.13: Breizhcrops Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Eğitim Süresi ve Parametre Sayıları.	50
4.14: Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Sonuçları.	51
4.15: Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Eğitim Süresi ve Parametre Sayıları.	52
4.16: Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Farklı Yama Boyutları (5 × 5, 7 × 7, 9 × 9) Sonuçları	53

# 1. GİRİŞ

Uzaktan algılama, gözlemlenen nesneye fiziksel bir temas olmaksızın, belirli bir mesafeden algılayıcılar yardımıyla bilgi toplama ve yorumlamanın bilimi olarak tanımlanabilir. Böyle bir bilginin nasıl verimli bir şekilde analiz edileceği, uzaktan algılama alanında hala açık bir sorundur. Modern dünya gözlem programları, coğrafi bölgeleri zaman içinde izlemek için yararlı olabilecek yüksek çözünürlüklü, çoklu zamanlı uzaktan algılanmış görüntüler üretmektedir. Özellikle yer bilimleri, su bilimleri, haritacılık, zirai uygulamalar ve çevre gibi insan hayatında önemli yeri olan konularda bilgi kaynağı olarak kullanılan temel bir teknolojidir.

Sentinel-2 gibi uydular, birkaç gün aralık ile tüm yeryüzünün, düzenli şekilde, yüksek uzamsal çözünürlüklü multispektral görüntülerini elde etmektedir. Bu görsel veriler, arazi örtüsü, arazi kullanım haritası hesaplanması ve tarım alanlarında mahsul sınıflandırma gibi birçok uygulamada kullanılmaktadır [1]. Uzaktan algılanmış veriler, mahsul sınıflandırma, yanlış çiftçi beyanlarının tespit edilmesi, tarım faaliyetlerinin izlenmesi, rekolte tahmini yapılması, denetlenebilmesi ve genel olarak hassas tarım bağlamında ulusal düzeyde önem arz etmektedir.

Uzaktan algılama teknikleri, tarım arazilerinin mekânsal-zamansal değişkenliği hakkında hızlı ve verimli bir şekilde bilgi toplama yetenekleriyle uzun süredir önemli tarımsal izleme araçları olmuştur. Tarımsal yönetim, çevresel izleme ve politika oluşturma için değerli bir kaynaktır.

Geçmişe göre günümüzde uydular sayesinde çok daha fazla multispektral ve çoklu zamanlı görüntüler elde edilmektedir [2]. Bu spektral ve zamansal görsel verilerin birleşik olarak nasıl kıymetlendirileceği ise bu konuda çalışan araştırmacıları belli bir süredir meşgul etmektedir. Bu durum bu alanda yayınlamış birçok çalışmaya yol açmıştır [3-20].

## 1.1. Tezin Amacı, Katkısı ve İçeriği

Mahsul sınıflandırma, yanlış çiftçi beyanlarının tespit edilmesi, tarım faaliyetlerinin izlenmesi ve denetlenebilmesi gibi hassas tarım için önemlidir. Bu tez çalışmasının amacı çoklu zamanlı ve çoklu bantlı uzaktan algılanmış görüntüler arasındaki uzamsal ve zamansal bilgiyi derin öğrenme ile kıymetlendirerek mahsul

sınıflandırma yapmaktır. Tez kapsamında, etiketli veri oluşturmanın olağanüstü zaman ve insan gücü gerektirmesi nedeniyle mahsul sınıflandırma alanında etiketsiz verilerin kullanılabilmesine de odaklanılmıştır.

Bu tez çalışmasının literatüre katkısı, uzaktan algılanmış çoklu zamanlı görüntülerin, mahsul sınıflandırması bağlamında, etiketsiz verilerin kıymetlendirilmesi için uzun kısa vadeli bellek oto kodlayıcıların yarı gözetimli kullanımının ve morfolojik ağlar ile uzun kısa vadeli belleklerin birleşik kullanımının araştırılmasıdır.

Daha ayrıntılı olarak, etiketli veri oluşumu pahalı ve zahmetli bir süreç olduğundan bol miktarda etiketsiz verilerden azami derecede yararlanılması önemlidir. Bu bağlamda uzun kısa vadeli bellek oto kodlayıcıları yarı gözetimli kullanmak için ilk olarak etiketsiz veriler ile uzun kısa vadeli bellek oto kodlayıcılar eğitilmiştir ve bu şekilde verilerin sıkıştırılmış halini öğrenmesi sağlanmıştır. Ardından öğrenilen ağırlıklar ile uzun kısa vadeli bir sınıflandırıcı ilklendirip etiketli veriler ile eğitimi sağlanmıştır.

Diğer yaklaşımda ise zamansal bağımlılıklardan yararlanmaya çalışan uzun kısa vadeli bellek ile mevcut evrişimli uzun kısa vadeli bellek (ESA-UVKB) mimarilerinin aksine, evrişim ile benzerliklerinden esinlenerek eğitilebilir morfolojik operatörlerin katkısını görmek için klasik morfolojik filtrelemeyi taklit eden morfolojik ağlar [3] birleştirilmiştir. Sınıflandırma için kategorik çapraz entropi kaybı kullanılmıştır.

Önerilen yaklaşımlar Sentinel-2 uydusundan elde edilen tarımsal zaman serisi Fransa'nın Britanya bölgesine ait Breizhcrops ve Türkiye'ye ait Sakarya veri kümeleri aracılığıyla doğrulanmıştır. Yapılan çalışmaların sonucunda yarı gözetimli uzun kısa vadeli bellek oto kodlayıcıların gözetimli yaklaşıma göre başarıyı arttırdığı, literatürdeki en iyi başarıyı veren yaklaşımın başarısını yakaladığı gözlemlenmiştir. Morfolojik uzun kısa vadeli bellek yaklaşımı ise evrişimli uzun kısa vadeli bellek (ESA-UVKB) yöntemine göre başarıyı artırdığı, literatürdeki başarılarla yaklaştığı gözlemlenmiştir.

## 1.2. Tezin Düzeni

Tezin 1. bölümünde tezin amacı ve katkısı üzerinde durulmuş, uzaktan algılanmış görüntülerde mahsul sınıflandırmanın genel hatları, tezin düzeni hakkında

bilgiler verilmiştir. Bölüm 2’de literatürde bu alanda yapılmış çalışmalardan bahsedilmiştir. Bölüm 3’de tez kapsamında önerilen yöntemler sunulmuştur. Bölüm 4’de ise önerilen yöntemler literatürdeki çalışmalarla kıyaslanmıştır, kullanılan veri kümeleri ayrıntılandırılmış ve deney ayarları açıklanmış ve deney sonuçları tartışılmıştır. Bölüm 5’de, tezin genel değerlendirilmesi yapılmış, sonuçlar yorumlanmış ve gelecekteki olası araştırma yönlerinden bahsedilmiştir.



## 2. LİTERATÜR TARAMASI

Uzaktan algılanmış görüntülerin sınıflandırılması çok geniş bir alandır ve bu konuda uzun zamandır çeşitli çalışmalar yapılmaktadır [4–8]. İlk olarak sığ yöntemlere bakılırsa, sığ yöntemler genellikle ilk olarak öznitelik çıkarımı için boyut küçültme yöntemlerini kullanırlar [4]. Veri boyutu azaldıktan ve nitelikli bilgiler korunduktan sonra eğitim için kullanılırlar. Bu alanda ise rastgele orman sınıflandırıcısı, kümeleme algoritmaları, destek vektör makineleri ve karar ağaçları gibi çeşitli makine öğrenme yöntemleri eğitim için kullanılmıştır [4, 9–12]. Sığ yöntemler girdi olarak spektral piksel imzalarını ve belirli parametreleri alırlar. Sığ yöntem algoritmalarının sınıflandırma doğrulukları, elle tasarlanmış özelliklerin kalitesine oldukça bağlıdır [12]. Çoğunlukla sığ yaklaşımlarda boyut küçültme teknikleri kullanılır. Bu teknikler veri boyutunu azaltırken ilgili bilgileri korur ve böylece eğitimi hızlandırır.[13]

Sığ olarak gözetimli olduğu gibi gözetimsiz/yarı-gözetimli yaklaşımlar da kullanılmıştır [13–15]. Gözetimli yaklaşımların dezavantajı, modeli öğrenmek için etiketli eğitim verilerine bağımlı olmasıdır. Gözetimsiz yaklaşımlar ise etiketsiz veriler ile çalışırlar. Örnek olarak bir çalışmada mahsul sınıflandırması için gözetimli bir yaklaşım olan Rastgele orman ile gözetimsiz olan Gauss karışım modeli ve K-ortalama modeli karşılaştırılmıştır [16]. Gauss Karışım Modeli (GMM), örneklerin bilinmeyen parametrelerle Gauss dağılımından üretildiğini varsayan olasılıksal bir modeldir. Sonuçlara göre Gauss karışım modeli, bir bölgedeki ürün çeşitliliği düşük olduğunda örnekleri yüksek doğrulukla ürün türlerine ayırır ancak bazen yüksek ürün çeşitliliği kümelenmeyi engellediğinde Rastgele orman daha iyi performans göstermez. K-ortalama ise ikisinin de gerisinde başarı göstermiştir. Sonuçlar uygun koşullar altında, bu yöntemlerin, dünya çapında çok az veya hiç zemin etiketi olmayan bölgelerde mahsul sınıflandırma için seçenekler sunar. Daha kapsamlı bir inceleme için [17] çalışmasına bakınız.

Morfolojik hiyerarşiler görüntü modelleme ve işleme için güçlü bir yöntemdir [7]. Uzaktan algılama alanında morfolojik yaklaşımlar olarak ağaç tabanlı temsillerle görüntü dizilerinin analiz edilip sınıflandırılması için bir çalışmada mekânsal, zamansal ve zamansal-mekânsal yöntemler önerilmiştir [18]. Bu mekânsal, zamansal ve zamansal-mekânsal yöntemler görüntü dizisinden hiyerarşinin çıkarılmasını

amaçlar. Yeni görüntüler eklendiğinde de ağaçları güncellemek için bazı algoritmalar önerilmiştir. Sınıflandırma ve betimleme için, öznitelik profilleri kullanılmıştır [19]. Mekânsal hiyerarşide, çoklu zamanlı görüntülerde her piksel için bir vektör oluşturulur ve vektörlere dayalı olarak bir max/min-ağaç yapısı oluşturulur. Bu vektörler sözlük sıralaması yöntemi ile önce ilk değerlere göre sıralanır, ilk değerler eşitse ikinci değerlere bakılarak sıralanarak ağaç oluşturulur. Zamansal hiyerarşide, her görüntü için ayrı ayrı bir ağaç yapısı oluşturulur ve bu ağaçlar isteğe bağlı olarak birleştirilir. Zamansal-mekânsal hiyerarşide, zaman serisi görüntüsü 3 boyutlu bir görüntü olarak kabul edilir ve üç boyutlu bir ağaç yapısı oluşturulur. Önerilen yöntemler 2016 yılında Fransa'nın Dordogne kentinde elde edilen Sentinel-2 görüntüleri ile doğrulanmıştır. Zamansal-mekânsal yönteminin diğerlerine göre daha iyi sonuç elde ettiği gözlemlenmiştir.

Matematiksel morfoloji, doğrusal olmayan filtreleme işlemlerinin kombinasyonlarını kullanarak görüntülerdeki belirli yapıları analiz etme ve kurtarma kapasitesi ile iyi bilinir [20]. Evrişimli sinir ağları (ESA), uzaktan algılama veri işlemede birçok farklı görevi çözmek için oldukça popüler hale gelmiştir [5, 21]. Evrişim, girdi verilerinden özellikleri çıkaran doğrusal bir işlemdir. Her ne kadar Evrişimli sinir ağları da aktivasyon fonksiyonu ile doğrusal olmayan modeller üretilebiliyor olsa da morfolojik ağların, hiperspektral görüntüler gibi karmaşık uzaktan algılama verileri içindeki iç ilişkileri ve gizli kalıpları daha iyi karakterize edebildiği görülmüştür [22, 23]. Morfolojik işlemler, görüntünün sınırları, şekil ve yapısal bilgiler gibi temel özelliklerini koruyan özellik çıkarımı için güçlü doğrusal olmayan dönüşümlerdir. Bir çalışmada [22] hiperspektral görüntülerin sınıflandırılması için spektral ve uzamsal morfolojik bloklardan oluşan birkaç evrişim ve morfolojik katman içeren derin bir morfolojik evrişim sinir ağı önerilmiştir. Yaygın olarak kullanılan 5 veri kümesi; Indian Pines (IP), University of Pavia (UP), University of Houston (UH), Salinas Valley (SV) ve Botswana (BW) ile deneyler gerçekleştirilmiştir. Deneysel sonuçlar, önerilen yaklaşımın 2-D ve 3-D ESA'lara kıyasla karşılaştırılabilir performans sunduğunu ortaya koymaktadır.

Aktif öğrenme (AL) gözetimli bir modelin eğitiminde, en yüksek etkiye sahip olması için etiketlenmesi gereken verilerin önceliklendirilmesi için kullanılır. Veri miktarının etiketlenemeyecek kadar büyük olduğu ve verileri akıllı bir şekilde etiketlemek için bazı önceliklerin yapılması gerektiği konularda umut verici bir yaklaşımdır [24]. Etiketleme maliyetini düşürürken sınıflandırma performansını

iyileştirmek için hem aktif öğrenmeyi hem de derin öğrenmeyi birleşik bir çerçeveye entegre eden hiperspektral görüntü sınıflandırması için çalışmalar bulunmaktadır [25, 26]. Bir çalışmada [27] aktif bir derin öğrenme yaklaşımı önerilmiştir. Sınırlı sayıda etiketlenmiş piksele sahip bir evrişimsel sinir ağı eğitilip ardından etiketleme için en uygun pikseller aktif olarak seçilir. Ardından evrişimsel sinir ağı yeni etiketlenmiş pikseller de dahil edilerek eğitilir. Deneyle 3 hiperspektral veri kümesi Indian Pines, Pavia University ve Pavia Center ile gerçekleştirilmiştir. Sonuçlara göre önerilen yaklaşımın diğer son teknoloji ürünü geleneksel ve derin öğrenme tabanlı Destek vektör makinası, otokodlayıcılar ve üç boyutlu evrişimsel sinir ağı yöntemlerine göre daha başarılı olduğu gözlemlenmiştir.

Mahsullerin spektral benzerliği sebebiyle mahsul sınıflandırması için tek zamanlı uzaktan algılanmış görüntülerin uygun olmadığı yönünde bilgiler vardır [28]. Çoklu zamanlı uzaktan algılanmış görüntüler, mahsullerin fenolojik gelişimini göz önünde bulundurdıkları için mahsul sınıflandırmasına daha uygundur. Bu fenolojik gelişim tarımsal alanların dinamik yapılarına göre oluşmaktadır. Mahsul fenolojisinin incelendiği bir çalışmada [29] Gediz ovasında yetiştirilen mahsullerin sınıflandırılması için Karar ağacı (KA), Rastgele orman (RO) ve Destek Vektör Makineleri (DVM) makine öğrenme yöntemleri karşılaştırılmıştır.

Biber										
Buğday										
Domates										
Mısır										
Mısır 2	Buğday									
	Mısır									
Pamuk										
Patlıcan										
Üzüm	Üzümün anlamlı gösterdiği tek dönem yaprak dökme dönemidir.									
Yonca	Yonca hasadı birkaç haftada bir yapıldığından tabloda gösterilmemiştir.									
Zeytin	Zeytinin değerleri yapraklarını dökmediği için belirgin değişim göstermemektedir.									
		Nisan	Mayıs	Haziran	Temmuz	Ağustos	Ekim	Eylül	Kasım	Aralık
			Ekim	Gelişim		Hasat		Yaprak Dökme		

Şekil 2.1: Mahsullerin Gelişim Süreçleri.

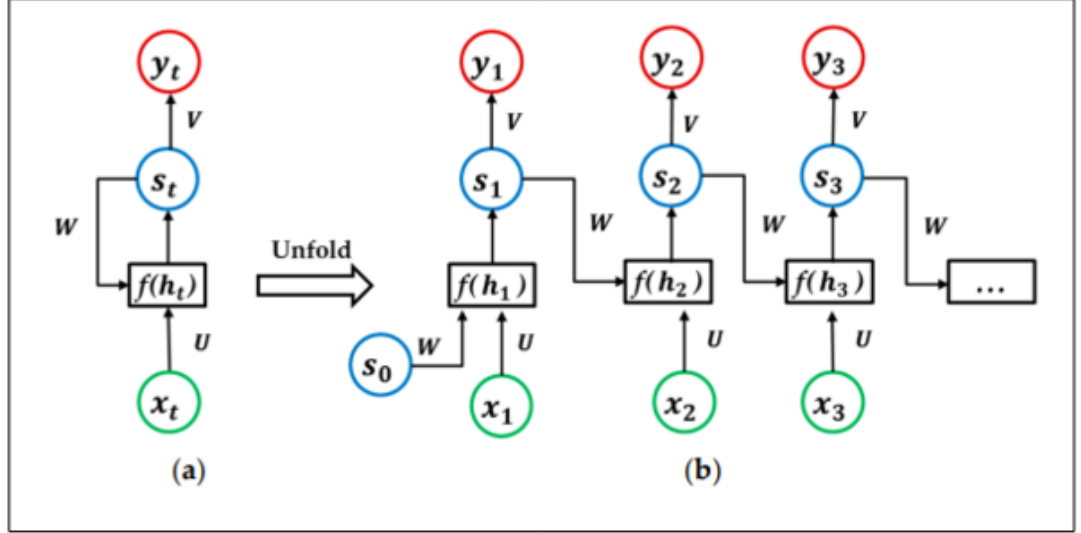
Şekil 2.1’de [29] görüldüğü gibi mahsullerin fenolojik özelliklerine göre uygun tarihli veriler belirlenmiştir. Bu sebeple Gediz ovasında yetiştirilen mahsullerin fenolojik gelişim süreçleri çıkarılmıştır. Şekil 1’de mahsullerin ekim, gelişim, hasat ve

yaprak dökme zamanları gösterilmektedir. Bu bilgilere göre en verimli olarak Nisan-Kasım ayları aralığındaki görüntüler kullanılmıştır. Sonuçlara göre en yüksek doğruluğu DVM 'in elde ettiği görülmüştür [29].

Uydu verilerinin artması ve derin öğrenme yöntemlerinin yaygınlaşması ile derin yöntemler kullanılmaya başlanmıştır [5, 21, 30–34]. Uzaktan algılanan verilerin mekânsal tahminleri için her biri ilgili bölgenin mekânsal özelliğini belirli bir zamanda anında modelleyen çok katmanlı bir algılayıcı yığınının oluştuğu derin bir istifleme ağından türetilen derin bir öğrenme yaklaşımı (Deep-STEP) önerilmiştir [30]. Önerilen yöntem, milyonlarca piksel/kayıt içeren uydu tabanlı uzaktan algılama görüntülerinden türetilen normalleştirilmiş fark bitki örtüsü indeksi (NDVI) veri kümelerinde test edilmiştir. Deneysel sonuçlar (NDVI tahmini ile ilgili olarak) önerilen mimarinin umut verici öğrenme yetenekleri ile oldukça tatmin edici bir performans sergilediğini ortaya koymuştur [30].

Mahsul gelişiminin dinamiklerini karakterize etmek için üç boyutlu (3B) evrişimsel sinir ağları (ESA) tabanlı yöntem önerilmiştir [21]. Veri seti olarak Çin'e ait GF1 ve GF2 uydusundan elde edilen veriler kullanılmıştır. İki boyutlu ESA ve diğer geleneksel yöntemlerle (K-En Yakın Komşu ve Destek Vektör Makineleri) kıyaslandığında daha başarılı olduğu görülmüştür. İki boyutlu ve üç boyutlu ESA karşılaştırmasına göre, 3D evrişimsel sinir ağları uzaysal-zamansal uzaktan algılanmış veriler için daha iyi bir özellik çıkarıcı olabilirken, 2D evrişimsel sinir ağları kendi matematiksel kısıtlaması nedeniyle geçici bilgileri kaybederler. Mahsul sınıflandırması için iki boyutlu evrişimsel sinir ağı (ESA) ve bir boyutlu evrişimsel sinir ağı (ESA) önerilmiştir [5]. Önerilen yöntem Rastgele orman sınıflandırıcısı ile karşılaştırılmıştır. Sonuç olarak ESA'ların daha yüksek başarı elde ettiği gözlemlenmiştir. Bir boyutlu evrişimsel sinir ağları, girdi serisinin zamansal modelini veya şeklini yakalamak için tek boyutlu filtreler kullanırlar. Katmanları, alt katmanların yerel özelliklere odaklanması ve üst katmanların daha genel kalıpları daha büyük ölçüde özetlemesi için istiflenir. Bir çalışmada belirli zaman kalıplarını yakalayan, gerçek dünya zaman serilerini temsil etmek için basit kalıpları karmaşık halde toplayan bir boyutlu ESA yöntemi önerilmiştir [31]. Bu yöntem sınıflandırma girdileri olarak zaman serilerini kullanır ve model eğitimi sırasında mahsul büyüme dinamiklerinin özelliklerini otomatik olarak çıkarır. Bu çalışmalar uzamsal pikseller arası ilişkilerden yararlanma konusunda Evrişimsel sinir ağlarının (ESA) başarılı olduğunu göstermektedir. Zamansal veriler arası ilişkilerden yararlanma konusunda en

yaygın kullanılanı tekrarlayan sinir ağı olmuştur [35]. Tekrarlayan sinir ağı, sıralı verileri işlemek için uzmanlaşmış sinir ağıdır. Standart bir Tekrarlayan sinir ağı mimarisi Şekil 2.2'de [35] gösterilmektedir.



Şekil 2.2 Standart bir tekrarlayan sinir ağı mimarisi, (a) standart gösterim ve (b), (a)'nın genişletilmiş bir şeklidir.

Ağın her zaman noktasındaki durumu hem mevcut girişe hem de ağda depolanan önceki bilgilere bağlıdır.

$$\begin{aligned}
 h_t &= Ux_t + Ws_{t-1} \\
 s_t &= f(h_t + b) \\
 y_t &= g(Vs_t + c)
 \end{aligned}
 \tag{2.1}$$

Bir  $\{x_1, x_2, \dots, x_t\}$  giriş dizisi verildiğinde, birimin  $t$  zamanındaki çıkışı  $y_t$  dir. Denklem 2.1' de  $s_t$  ağın o andaki durumudur;  $U, V$  ve  $W$  ağırlık matrisleridir;  $b$  ve  $c$  sapma ağırlık vektörleridir ve  $f$  ve  $g$  genellikle sırasıyla  $\tanh$  ve  $\text{softmax}$  aktivasyon fonksiyonlarıdır.  $t = 1$  olduğunda,  $s_0$  0 olarak başlatılır [35].


Bir çalışmada Landsat verilerinde zamansal spektral varyansı en aza indirmek ve eğitim örneği azlığı problemi için tekrarlayan sinir ağı ile bir aktarma stratejisi önerilmiştir [32]. Sonuçlara göre önerilen yöntem sadece tekrarlayan ağlara göre daha başarılı sonuç vermiştir. Önerilen yöntem sınırlı eğitim verisi olan büyük uzaktan algılama verilerinde umut verici bir araç olmuştur. Yine başka bir çalışmada bulutlu ve yağışlı bölgelerde mahsul sınıflandırması için tekrarlayan sinir ağı kullanılmıştır

[33]. Uzaktan algılama görüntüleri için tekrarlayan sinir ağı tabanlı bir sınıflandırıcı takımı oluşturulmuştur. Sonuçlar yöntemin, bulutlu bölgelerdeki mahsullerin sınıflandırılmasını gerçekleştirebileceğini ve bu tür alanlardaki mahsullerin sürekli optik veri eksikliği nedeniyle hızlı ve geniş bir şekilde sınıflandırılma sorununu bir dereceye kadar çözebileceğini göstermektedir. Tekrarlayan ağların tıkanıdığı nokta ise kaybolan gradyan problemidir. Bunun çözümü için de bu problemi ortadan kaldıran uzun kısa vadeli bellek (UVKB) ağları önerilmiştir [34, 36]. Uzun kısa vadeli bellek (UVKB) ağları, bir hücre durumu ve 3 kapıdan oluşur. Bunlar, giriş kapısı, unut kapısı ve çıkış kapısı. Bellek hücresi, ağın belleği olarak işlev görür. Kapılar hafıza hücresini kontrol etmek için kullanılır. Bir hücrenin mevcut durumu, geçmiş verilerin ilgili bağlamına ve diziden gelen girdi verilerine bağlıdır; alakasız bağlam, bilgiyi unutmaya veya geçmesine izin vermeye karar veren kapı mekanizması tarafından kontrol edilir [34]. Bir çalışmada yüksek sınıf içi varyans ve sınıflar arası benzerlikleri ayırt edebilmek için UKVB'lerin metrik öğrenme ile birleştirildiği bir yaklaşım önerilmiştir. Mimari üçlü kayıpla birleştirilen, her biri bir UVKB modülü içeren, paylaşılan ağırlıklara sahip üç dalı barındırır. Bu şekilde alt ağların daha ayırt edici derin özellikler üretmesi sağlanmıştır. Breizhcrops veri kümesi ile doğrulanmıştır. Literatürde aynı veri kümesini kullanan diğer yöntemler ile karşılaştırılmıştır. Diğer yöntemlerden daha iyi sonuç verdiği bildirilmiştir [37].

Tekrarlayan sinir ağları zamansal veri bağımlılıklarını açıkça yönetirler, çünkü  $t - 1$  zamanında bir nöronun çıkışı, bir sonraki girişle birlikte,  $t$  zamanında nöronun kendisini beslemek için kullanır. Tekrarlayan sinir ağlarının (TSA), özellikle uzun kısa süreli bellek (UVKB) modelinin, bir dizi uydu görüntüsünden türetilen çok yönlü uzamsal verileri dikkate alarak arazi örtüsü sınıflandırması için 2 yöntem önerilmiştir [22]. UVKB tabanlı zaman serisi sınıflandırma yöntemi ve zaman serisi verileri için UVKB ile temsili öğrenme. İki farklı veri kümesi Thau ve Reunion üzerinde deneyler gerçekleştirilmiştir. Elde edilen sonuçlar, UVKB'lerin son teknoloji sınıflandırıcılara kıyasla rekabetçi olduğunu ve düşük oranda temsil edilen ve / veya yüksek oranda karışık sınıfların varlığında klasik yaklaşımlardan daha iyi performans gösterebileceğini göstermektedir. Başka bir çalışmada, uzaktan algılanmış zaman serilerinde arazi sınıflandırması için çift yönlü uzun vadeli ve kısa vadeli bellek ağı (Bi-LSTM) [38] kullanılmıştır. Rastgele orman, destek vektör makineleri (DVM), evrişimsel sinir ağları (ESA) ve uzun kısa vadeli bellek (UVKB) modelleri ile

karşılaştırılmıştır. Sonuçlar, Bi-LSTM 'in diğerlerine göre daha başarılı olduğunu göstermiştir [39].

Mahsul sınıflandırma için geçici bir gözlem dizisine dayalı sınıf olasılıklarını tahmin etmek için TSA, UVKB, ESA ve destek vektör makineleri (DVM) modelleri karşılaştırılarak zamansal özelliklerin katkısı üzerine çalışılmıştır [40]. Sonuçlara göre TSA ve UVKB modellerinin ESA ve destek vektör makinelerine göre daha iyi sonuç verdiği görülmüştür. Başka bir çalışmada, mahsul sınıflandırması için uzamsal zamansal özellikleri çıkararak ESA ve GRU'nun birleştirildiği hibrit bir yaklaşım önerilmiştir. Sadece ESA, GRU ve ConvLstm ile karşılaştırılmıştır. ConvLstm, gizli ve hücre durumları için UVKB katmanlarında evrişim işlemleri gerçekleştiren bir modeldir. GRU ise, iki kapılı tekrarlayan bir ağıdır. Herhangi bir dahili belleğe ve UVKB'de bulunan bir çıkış kapısına sahip değildirler. UVKB'de giriş kapısı ve hedef kapısı bir güncelleme kapısı ile birleştirilir GRU'da ise sıfırlama kapısı doğrudan önceki gizli duruma uygulanır. Önerilen yaklaşımın başarısı, verideki zamansal boyutun önemini ve tekrarlayan sinir ağlarının çoklu gözlemleri birleştiren bir bellek görevi gördüğünü göstermiştir [41]. Uzamsal alandan ziyade zamansal alanda evrişim uygulama için evrişimlerin zamansal boyutta uygulandığı zamansal evrişimsel sinir ağları (TempCNN) önerilmiştir [42]. Ağın girişi çok değişkenli bir zaman serisi alır. Şekil 2.3' de [42] gösterildiği gibi mimari, arka arkaya üç evrişim katmanından (64 birim  $5 \times 5$  filtre boyutunda), bir tam bağlantılı katmandan (256 birim) ve bir Softmax katmanından oluşur.



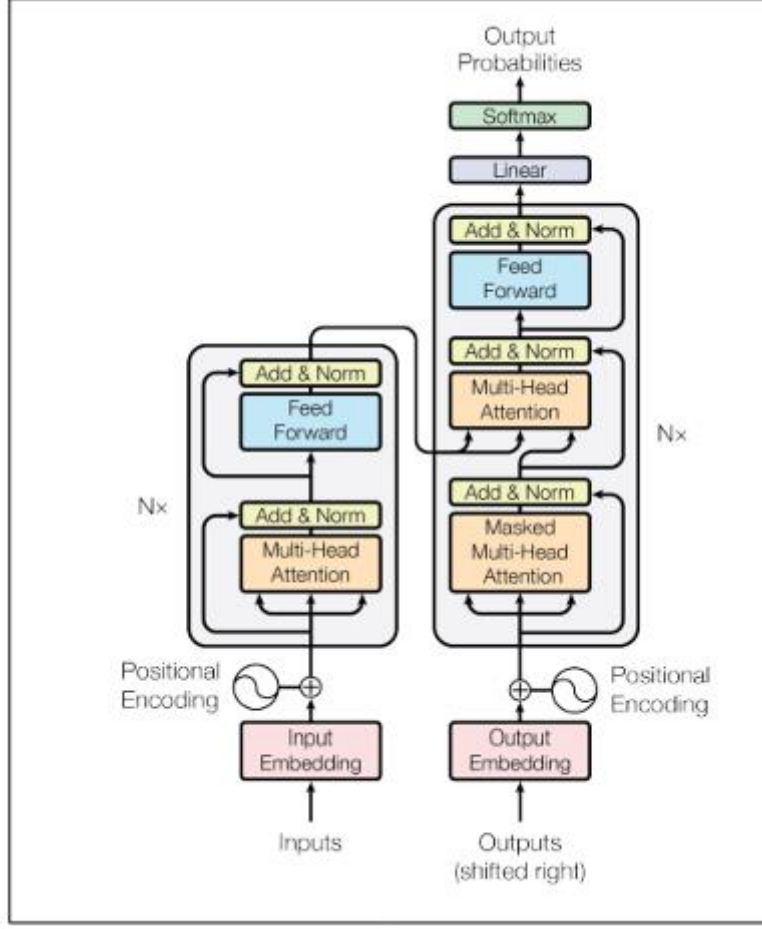
Şekil 2.3 Zamansal evrişimsel sinir ağı (TempCNN).

Bu mimari uydu görüntüsü zaman serilerinin arazi görüntülerinin sınıflandırılması için 3 kapılı tekrarlayan birimi (GRU) ve TempCNN'ler Rastgele orman sınıflandırıcısı ile karşılaştırılmıştır. Hem genel doğruluk hem de süre açısından

TempCNN'nin 3 kapılı GRU 'dan ve Rastgele ormandan daha başarılı olduğu gözlenmiştir [43].

Son yıllarda mahsul sınıflandırması için özellikle zamansal bilgileri kullanmaya odaklı 128 birimli üç katman ve 768 birimli bir yoğun katmandan oluşan UKVB, 128 birimli üç katman, 128 birim bir yoğun katman ve bir softmax katmanından oluşan yığılanabilir tekrarlayan hücre (StarRNN) ve 64 birimli üç bir boyutlu evrişim katmanı, 256 birimli bir yoğun katman ve bir softmax katmanından oluşan TempCNN, 32 birimli MS-ResNet, 128 gizli vektör boyutuna sahip InceptionTime, OmniscCNN, 64 vektör boyutlu, üç katman ve tek bir kendi kendine dikkat başlığına sahip Transformer ağları [43] kullanılmıştır [44, 45]. MSResNet ağı, ilk evrişim katmanını, ardından bir maksimum havuz oluşturma işlemini uygular. Sonuç daha sonra farklı uzunluklarda ardışık altı evrişim filtresi ve nihai bir küresel ortalama havuzlamayı öğrenen üç daldan geçirilir. Her dal için, kaybolan ve patlayan gradyan sorunlarını sınırlamak için her üç evrişim katmanında bir artık bağlantılar kullanılır. Son olarak, sonuçlar birleştirilir ve tamamen bağlı ve softmax katmanlarından oluşan ağın sonundan geçirilir. InceptionTime ağı [46], bir global ortalama havuzlama işlemi ve softmax aktivasyonu ile yoğun bir katman tarafından takip edilen altı başlangıç modülünden oluşan bir diziden oluşur. Ayrıca, her üç Inception modülünde bir artık bağlantıların kullanımını sağlar. OmniscaleCNN ağı [47], üç evrişim katmanından, ardından küresel ortalama havuzlama ve softmax aktivasyonlu yoğun bir katmandan oluşur. Amacı, uzunluğu bir artı zaman serisi uzunluğunun iki ila dörtte biri arasındaki tüm asal sayılar olan birkaç evrişim filtresinin çıktılarını birleştirmektir. Transformer ağları, ESA'ları dikkat modelleriyle birlikte kullanır. Şekil 2.4'de [44] görüldüğü gibi bir kodlayıcı-kod çözücü mimarisidir. Kodlayıcı, kendi kendine dikkat eden bir ağdan ve ileri beslemeli bir ağdan oluşur. Kod çözücü bu katmanların her ikisine de sahiptir; ek olarak, bu iki katman arasında kodlayıcılar tarafından oluşturulan kodlamalardan ilgili bilgileri alan bir kodlayıcı-kod çözücü dikkat katmanına sahiptir.

Dikkat mekanizması, belirli bir belirtecin kodlanması için girdideki diğer belirteçlerin önemini gösterir. Kodlayıcı katmanı, girdinin hangi bölümlerinin birbiriyle ilişkili olduğu bilgisi ile bir sonraki kodlayıcıya girdi olarak girdi kodlamalarından geçer. Kod çözücü katmanı bu bilgiyi girdi olarak alır ve çıktıyı üretir. Uzaktan algılama alanında derin yöntemlerin daha kapsamlı bir incelemesi için [48] çalışmasına bakınız.



Şekil 2.4 Transformer modeli.

Gözetimsiz öğrenmenin ve özellikle seyrek otomatik kodlayıcıların temel amacı, büyük miktarda mevcut etiketlenmemiş uydu verisine dayalı olarak verilerin gizli bir temsilini öğrenmektir. Bu bağlamda uzaktan algılama alanında yalnızca uydu verilerine dayalı seyrek otomatik kodlayıcı kullanan bir derin öğrenme yaklaşımı önerilmiştir [49]. Bu model, bir giriş katmanı, bir gizli katman ve çıkış katmanından oluşur. Otomatik kodlayıcının temel amacı, girişi yeniden oluşturmaktır. Otomatik kodlayıcı, kodlayıcı ve kod çözücü olmak üzere iki bölümden oluşur. Gizli katmanda en popüler ve verimli aktivasyon fonksiyonu olan doğrultulmuş doğrusal birim (ReLU) kullanılmıştır ve çıkış katmanında sigmoid fonksiyonu kullanılmıştır. Önerilen yöntem, Ukrayna'ya ait 2 farklı büyük ölçekli veri ile doğrulanmıştır. Sonuçların her yıl ve geniş bölgenin her bölümü için yerinde veri toplama gerekliliğini önlemeyi veya azaltmayı mümkün kılabileceği görülmüştür.

Son olarak, son zamanlarda popüler olan denetimsiz bir üretici model olarak, çekişmeli üretici ağlar (GAN), tarımsal uygulamalar için sınıflandırma görevlerini

tamamlamak için nadiren kullanılır. Çelişkili üretim ağı iki bölümden oluşur: G üreticisi ve D ayırıcısı. G üreticisinin amacı, verilen verilerin olasılık dağılımını öğrenmektir. D ayırıcısının özü bir sınıflandırıcıdır ve amaç, verileri G'den veya eğitim setinden doğru bir şekilde ayırt etmektir. Bir çalışmada, GAN ayırıcısının son sınıflandırıcı olarak kullanıldığı uzaktan algılama zaman serisi görüntülerinden mısır ve soya fasulyesi mahsullerini sınıflandırmak için GAN, ESA ve UVKB modellerini birleştiren yeni bir yöntem önerilmiştir [50]. Yöntemdeki temel fikir, ESA ve UVKB'yi GAN modeline yerleştirmektir. GAN Ayırıcısı, sınıflandırma görevini yapar ve ESA ve UVKB, ayırıcının yardımcı girişi olarak uzaktan algılama görüntüsünün uzamsal ve zamansal özelliklerini çıkarmak için özellik çıkarıcılarıdır. Önerilen yöntemin etkinliğini doğrulamak için SVM, SegNet, ESA, UVKB ve farklı kombinasyonların modelleri ile karşılaştırmalar yapılmıştır. Sonuçlar, önerilen yöntemin diğerlerine göre en iyi sınıflandırma sonuçlarına ulaştığını göstermektedir.

## 2.1. Literatür Değerlendirmesi

Uzaktan algılama alanında yapılan çalışmaların nihai amaçları uzaktan algılanan verilerdeki zamansal ve uzamsal bilgileri kıymetlendirmektir. Başta sığ yaklaşımlara değinildi. Sığ yöntemler literatürde mahsul sınıflandırması için yaygın olarak kullanılmış ve mahsul sınıflandırma alanında başlangıç için yeterli sonuçları elde etmiştir. Gözetimli olarak birçok çalışma bulunmaktadır [11, 52–54]. Derin yöntemlerin yaygınlaşmasıyla uzaktan algılama alanında da derin yöntemler kullanılmaya başlanmıştır. Bir boyutlu, iki boyutlu ve üç boyutlu evrişimsel sinir ağlarının bu alanda denendiği ve sığ yöntemlerin başarısını geride bıraktığı gözlemlenmiştir. Özellikle bir boyutlu evrişimsel sinir ağlarının spektral özellikleri sınıflandırmada başarılı olduğu gözlemlenmiştir [5, 31]. Sonrasında zamansal veriler arasındaki ilişkileri yakalayabilen tekrarlayan sinir ağlarının uzaktan algılanmış çoklu zamanlı veriler için faydalı olabileceği görülmüştür [32, 33]. Özellikle uzun kısa vadeli bellek (UVKB) mimarileri üzerine yoğun çalışılmıştır [34, 36, 37, 40, 55]. Daha sonra evrişimsel sinir ağları ile birleştirilerek hibrit mimariler çalışılmıştır [41, 56]. Evrişimsel sinir ağlarının zamansal verileri sınıflandırmadaki eksikliklerini gidermek, zamansal bağlamları yakalayabilmeleri için zamansal evrişim sinir ağları (TempCNN) önerilmiştir [42]. Dikkate dayalı transformer ağlarının, tekrarlayan modellerden biraz

daha iyi performans gösterdiği görülmüştür [44]. Bunun sebebinin Transformer ağlarının, değişen zamansal bağımlılıklarından yararlanma yeteneklerinden kaynaklandığı gözlemlenebilir. Evrişim tabanlı yaklaşımların tekrarlayan yaklaşımlara göre biraz daha kötü performansı, her örnek için farklı bir zamansal örnekleme kullanılmasıyla kaynaklanabilir. Son olarak mahsul sınıflandırma alanında derin yaklaşımlarda da gözetimsiz sınıflandırma üzerine çalışıldığı ama bu çalışmaların azınlıkta kaldığı görülmektedir [49, 50]. Sonuç olarak literatürde mahsul sınıflandırma alanında derin gözetimsiz/yarı-gözetimli yaklaşımlar konusunda çalışmalar artırılarak hem performansları yükseltilebilir hem de etiket maliyetinin azaltılıp, etiketsiz verilerin kıymetlendirilmesi sağlanabilir.



## 3. YÖNTEM

Bu bölümde tez kapsamında gerçekleştirilen yöntemlerle ilgili detaylar verilecektir. İlk olarak uzaktan algılanmış çoklu zamanlı görüntülerde mahsul sınıflandırması bağlamında etiketsiz verilerin kıymetlendirilmesi için Yarı-Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar yaklaşımından bahsedilecektir. İkinci olarak ise morfolojik ağlar ile uzun kısa vadeli belleklerin birleştirildiği Morfolojik Uzun Kısa Vadeli Bellek yaklaşımından bahsedilecektir. İki yöntemde de çoklu zamanlı mahsullerin sınıflandırmasında görüntüler arasındaki uzamsal ve izgesel bağlamın yakalanması hedeflenmektedir.

### 3.1. Uzun Kısa Vadeli Bellek Oto Kodlayıcıların Yarı Gözetimli Mahsul Sınıflandırmaya Uygulanması

#### 3.1.1. Uzun Kısa Vadeli Bellek Ağı

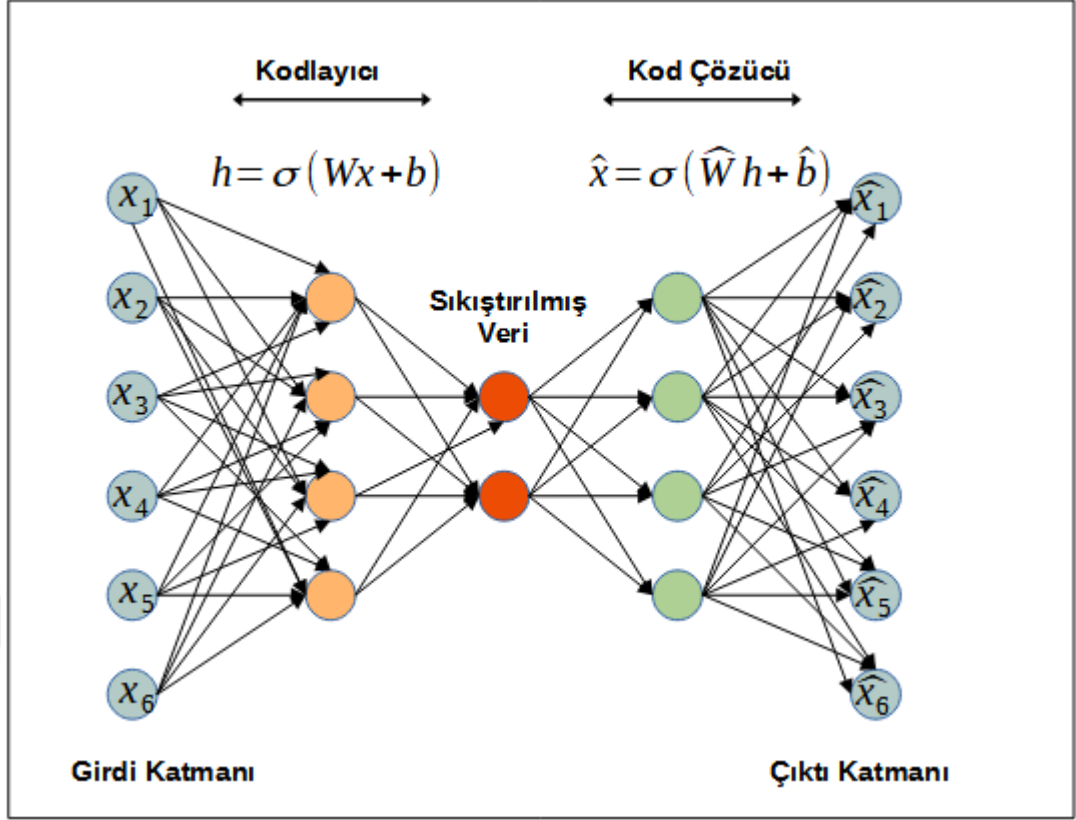
Uzun kısa vadeli bellek ağları (UKVB), hem uzun hem de kısa vadeli bağımlılıkları yakalama kapasiteleri sayesinde zamansal veriler için kullanılmaktadır [37]. Kaybolan gradyan sorununu çözmek için TSA üzerinde bir iyileştirme ile UVKB geliştirilmiştir [34]. UVKB, uzun vadeli bağımlılıkları öğrenebilen bir TSA türüdür. TSA'larla karşılaştırıldığında, UVKB'ler, kaybolan gradyan probleminin üstesinden gelmek için bağlamsal bilgiyi parametreleştiren kapılar kullanırlar. Standart bir UVKB ağı, bir hücre durumu ve kapılardan oluşur. Bunlar, giriş kapısı, unut kapısı ve çıkış kapısı. Bellek hücresi, ağın belleği olarak işlev görür. Kapılar hafıza hücresini kontrol etmek için kullanılır. Bir hücrenin mevcut durumu, geçmiş verilerin ilgili bağlamına ve diziden gelen girdi verilerine bağlıdır; alakasız bağlam, bilgiyi unutmaya veya geçmesine izin vermeye karar veren kapı mekanizması tarafından kontrol edilir. Bir UVKB'nin mimarisi şu şekilde ifade edilir:

$$\begin{aligned}i_t &= \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i), \\f_t &= \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f), \\c_t &= f_t c_{t-1} + i_t \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \\o_t &= \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_t + b_o), \\h_t &= o_t \tanh(c_t).\end{aligned}\tag{3.1}$$

$c_t$  bir hücre durumudur ve her UVKB birimi,  $t$  anında  $c_t$  durumuna sahip bir hücredir. Bu hücre bir hafıza birimi olarak düşünülebilir. Okumak veya değiştirmek için bellek birimine erişim kapılar aracılığı ile kontrol edilir. Denklem 3.1'de giriş kapısı  $i_t$ , unut kapısı  $f_t$ , çıkış kapısı  $o_t$  dir. Kapılar temel olarak sigmoid fonksiyonlardır.  $\sigma$  sigmoid fonksiyonunu ifade etmektedir. Her zaman adımında iki kaynaktan girdi alır. Birincisi,  $x_t$  giriş vektörüdür. İkincisi, aynı katmandaki tüm birimlerin önceki gizli durumlarıdır ( $h_{t-1}$ ). Toplam giriş, doğrusal olmayan tanh içinden geçirilir. Elde edilen aktivasyon, giriş kapısının aktivasyonu ile çarpılır. Bu daha sonra hücre durumunu unut kapısının aktivasyonu  $f_t$  değeri ile çarptıktan sonra hücre durumuna eklenir.  $h_t$ 'den gelen nihai çıktı, çıkış kapısının aktivasyonunun bir *tanh*'dan geçen güncellenmiş hücre durumu ile çarpılmasıyla hesaplanır. Bir UVKB biriminin temel avantajı, birimdeki hücre durumunun zaman içindeki aktiviteleri toplamasıdır. Türevler toplamlar üzerinde dağıldığı için, hata türevleri zamana geri gönderildiklerinde hızlı bir şekilde kaybolmazlar. Bu, uzun diziler üzerinde uzun menzilli özellikleri keşfetmeyi kolaylaştırır [56].

### 3.1.2 Oto Kodlayıcılar

Oto kodlayıcılar, gözetimsiz şekilde verinin sıkıştırılmış temsilini öğrenmeyi hedefler. Girdi verisinin sıkıştırılmış gösterimi aracılığı ile etkili özniteliklerin öğrenilmesini hedefleyen bir ileri beslemeli sinir ağıdır. Şekil 3.1'de görüldüğü gibi bir otomatik kodlayıcının iki ana parçası vardır: girdiyi koda işleyen bir kodlayıcı ve kodu girdinin yeniden yapılandırılmasına eşleyen bir kod çözücü. Bir otomatik kodlayıcı, bir giriş katmanı, bir veya birden fazla kodlayıcı ve kod çözücü katmanlar ve bir çıkış katmanından oluşur. Çıkış katmanı, giriş katmanı ile aynı sayıda düğüm (nöron) sahiptir. Amacı, girdilerden verilen bir hedef değeri tahmin etmek yerine girdilerini yeniden yapılandırmaktır (giriş ve çıktı arasındaki farkı en aza indirmektir).



Şekil 3.1 Oto Kodlayıcı.

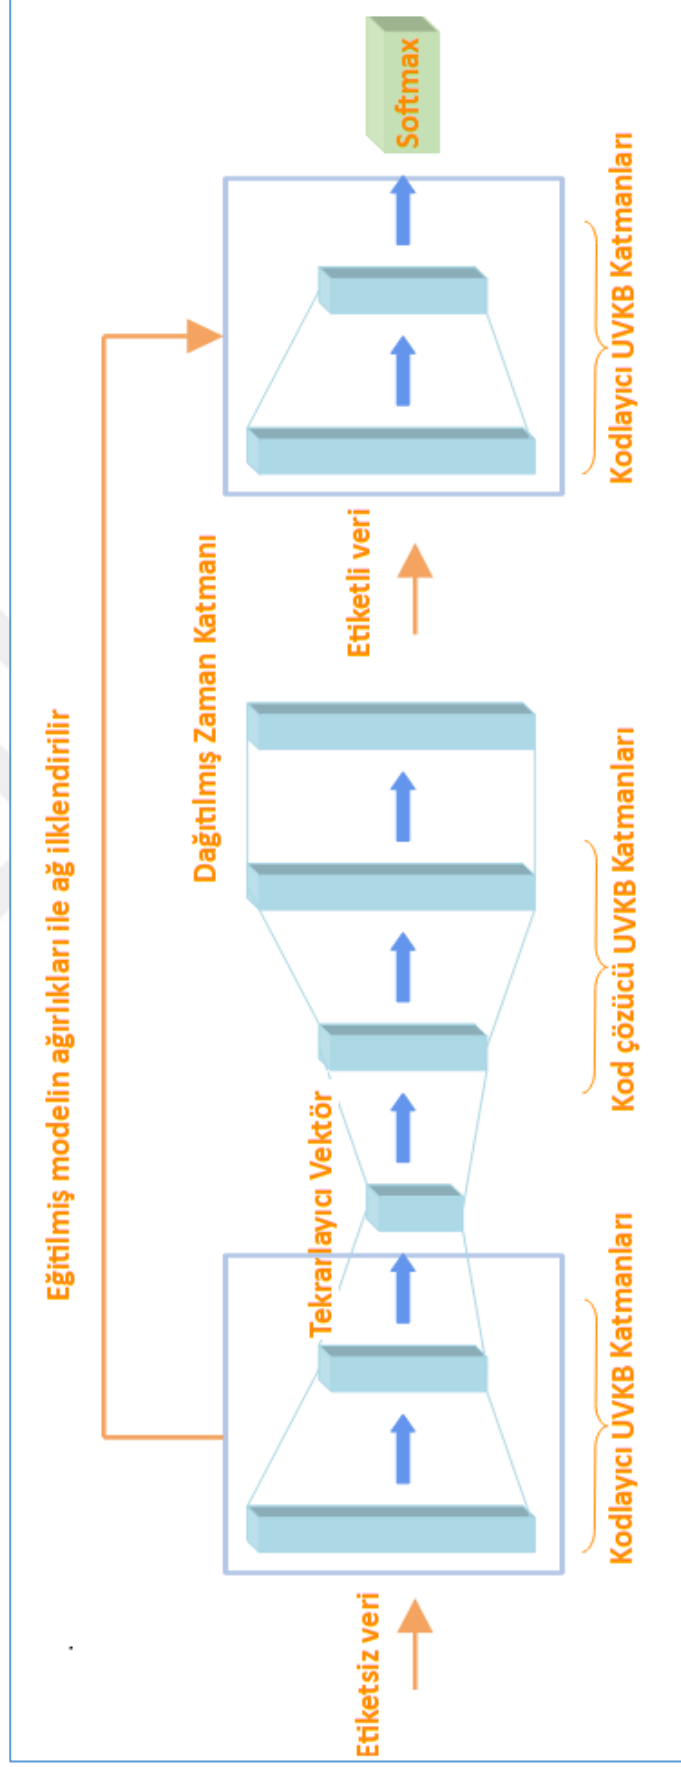
Girdiye en benzer çıktıyı üretebilen fonksiyonu bulmaya çalışır. Giriş katmanında bir dizi  $\{x_1, x_2, x_3, \dots, x_n\}$  n boyutlu  $x$  giriş verisini alarak,  $\hat{x}, \{\hat{x}_1, \hat{x}_2, \hat{x}_3, \dots, \hat{x}_n\}$  n boyutlu çıkış verisini oluşturmaya çalışır. Kodlayıcı katman  $x$  girdisini alır ve kodlar.  $h$  öğrenilen gizli temsili ifade eder.  $\sigma$ , sigmoid işlevi veya doğrultulmuş bir doğrusal birim gibi öge bazında bir etkinleştirme işlevidir.  $W$  ve  $b$  kodlayıcı ağırlık matrisi ve sapma vektörüdür. Ağırlıklar ve sapmalar genellikle rastgele başlatılır ve ardından eğitim sırasında geri yayılım yoluyla yinelemeli olarak güncellenir. Otomatik kodlayıcının kod çözücü aşaması da  $h$ 'yi  $x$  ile aynı şekle sahip  $\hat{x}$  yeniden yapılandırmasına eşlemeye çalışır. Burada da  $\hat{W}$  ve  $\hat{b}$ , kod çözücü ağırlık matrisi ve sapma vektörüdür. Girdi ve çıktı arasındaki farkın minimum olması başarılı bir fonksiyonun bulunduğunu gösterir. Oto kodlayıcılar hakkında daha fazla ayrıntı için [57, 58] çalışmalarına bakınız.

### 3.1.3 Uzun Kısa Vadeli Bellek Oto Kodlayıcılar

UVKB ağları sıralı verileri işlemek için tasarlanmıştır ve otomatik kodlayıcı mimarisi verilen verilerin gizli temsilini öğrenir. Her ikisi birlikte, sıralı verilerin temsilini öğrenebilen bir model oluşturur. Uzun Kısa Vadeli Bellek Oto Kodlayıcılar mimarisi verinin zaman alanındaki bağımlılığı ile sıkıştırılmış temsilini öğrenmeyi hedefler. Normal oto kodlayıcılardan avantajı ise uzun vadeli bağımlılık sorunundan kaçınıp uzun süreli bilgileri hatırlamasıdır [56, 59–61]. Kodlayıcı UVKB ve kod çözücü UVKB katmanlarından oluşur. Modelin girişi bir dizi vektördür. Önce kodlayıcı UVKB bu sırayla okur. Tüm girdi dizisini okuduktan sonra, model, sabit uzunlukta bir vektör olarak tüm girdi dizisinin dahili öğrenilmiş bir temsilini temsil eder. Sabit uzunluklu vektör, çıkış dizisindeki her adım oluşturulurken onu yorumlayan Kod çözücü UVKB modelinin bir girişi olarak çalışır. Kod çözücü LSTM hedef dizi için bir tahmin verir. Bu şekilde ağ giriş dizisini yeniden yapılandırmaya çalışır.

### 3.1.4 Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar

Bu çalışmada, uzaktan algılama topluluğundaki en önemli sorunlardan biri olan etiketli veri azlığına odaklanılmıştır. Her ne kadar uydular sürekli veri algılasa da, ne yazık ki etiket üretimi son derece zahmetli ve pahalı bir süreçtir. Bu yüzden bol miktarda erişebildiğimiz etiketsiz verilerden azami derecede yararlanılması önemlidir. Bu amaç doğrultusunda, etiketsiz çoklu zamanlı verileri mahsul sınıflandırma bağlamında kıymetlendirmek adına, yarı gözetimli uzun kısa vadeli bellek oto kodlayıcılar yaklaşımını öneriyoruz. Önerilen yaklaşım Şekil 3.2’de gösterilmiştir. Mimari kodlayıcı UKVB ve kod çözücü UKVB katmanlarından oluşur. Giriş olarak 2 boyutlu bir dizi alır.



Şekil 3.2: Önerilen Yaklaşım (Yarı-Gözetimli).

Dönüş dizileri her hücrenin zaman adımı başına bir sinyal yaymasını sağlar. Bir katmandaki zaman adımı hücresi bir sonraki katmandaki aynı zaman adımındaki hücre tarafından alınır. Kodlayıcı katmanın son çıktısı girdinin sıkıştırılmış temsili, yani öznitelik vektörüdür.

İlk Kod çözücü UKVB katmanı için 2 boyutlu dizi elde etmek için Tekrarlayıcı vektör kullanarak zaman adımı kadar kopyalama işlemi yapılır. Kod çözücü katman kodlamayı açmak için tasarlanmıştır. Bu sebeple kod çözücü katmanlar kodlayıcı katmanların tersine göre istiflenir. Kodlayıcı katmanının ayna görüntüleridir. Son olarak Dağıtılmış Zaman katmanı çıktıyı almak için sonuna eklenir. Bu katman önceki katmandan çıkarılan özniteliklerin sayısına eşit uzunlukta bir vektör oluşturur. Buradaki amaç ağın çıktısını girdiye yakın hale getirmektir. Bu şekilde ağ girdi ve çıktısının eşlenmesini sağlayarak yeniden yapılandırma kaybını hesaplayabilir. Kullandığımız mimari 3 kodlayıcı UKVB ve 3 kod çözücü UKVB'den oluşmaktadır. Bu mimari zaman serilerinin gözetimsiz şekilde özniteliklerini öğrenmeye uygulanmıştır. Mimari için ilk olarak [56] çalışması baz alınmıştır. Daha sonradan genişletilerek deneylere göre en iyi sonuç verdiği için bu tasarım ile devam edilmiştir. Şekil 3.2 'de gösterildiği gibi 2 aşamadan oluşmaktadır. İlk olarak etiketsiz veri ile Uzun Kısa Vadeli Bellek Oto Kodlayıcılar eğitilmektedir. Yitim fonksiyonu olarak da [56]'da önerildiği için ortalama kare hata (MSE) fonksiyonu kullanılmıştır.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.2)$$

Denklemler 3.2 'de gösterilen bu fonksiyonda  $\hat{y}$  tahmin edilen değeri,  $y$  gerçek değeri temsil etmektedir. Ağın doğrulama yitimi azalmayana kadar eğitilir. Bu şekilde etkili öznitelik çıkarmayı öğrenince de ağın kodlayıcı katman ağırlıkları kaydedilir. İkinci aşama olarak otokodlayıcının sadece kodlayıcı kısmı ile sürece devam edilip, eğitilmiş modelin ağırlıkları ile ağ ilklendirilir. Ağın sonuna bir sınıflandırıcı (Softmax) katmanı dahil edilmiştir (Şekil 3.2).

$$Softmax \sigma(\bar{z})_i = \frac{\exp^{z_i}}{\sum_{j=1}^K \exp^{z_j}} \quad (3.3)$$

Denklem 3.3'de gösterilen bu fonksiyonda  $z$  giriş vektörünü,  $K$  sınıf sayısını ifade etmektedir. Her ne kadar sınıflandırma katmanı rastgele ağırlıklara sahip olsa da, ağın öznelik çıkarma katmanları (yani oto kodlayıcının kodlayıcı kısmı), etiketsiz verilerden öğrenilen ağırlıklara sahiptir. Bu noktadan sonra da tüm ağ etiketli verileri kullanarak gözetimli şekilde eğitilir. Bu aşamada yitim fonksiyonu olarak kategorik çapraz entropi (CCE) fonksiyonu kullanılmıştır.

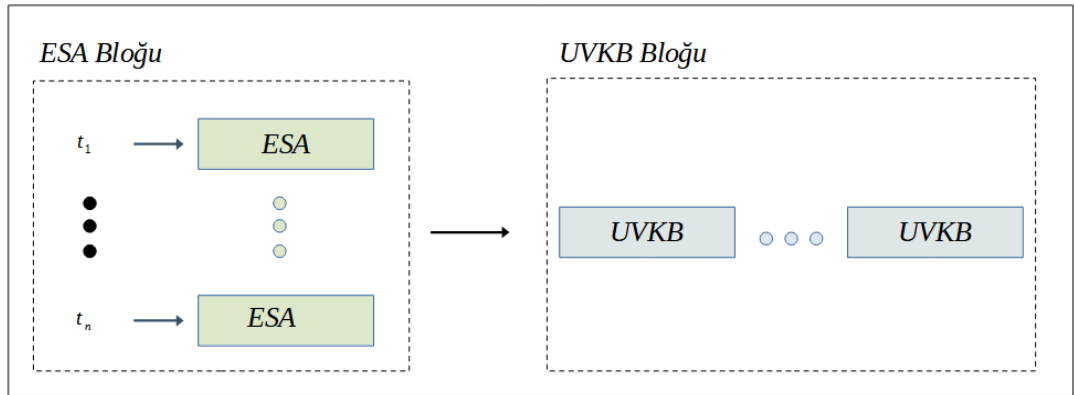
$$CCE = -\frac{1}{N} \sum_{i=1}^N \sum_{t=1}^K y_{it} \log(\hat{y}_{it}) \quad (3.4)$$

Denklem 3.4 'de gösterilen bu fonksiyonda  $N$  örnek sayısını,  $\hat{y}$  tahmin edilen değeri,  $y$  gerçek değeri ifade etmektedir.

## 3.2. Morfolojik Uzun Kısa Vadeli Bellek Ağının Mahsul Sınıflandırmaya Uygulanması

### 3.2.1 Evrişimsel Sinir Ağı Uzun Kısa Vadeli Bellek (ESA-UVKB)

ESA-UVKB ağları, dizi tahminini desteklemek için uzun kısa vadeli bellek ağları ile derin hiyerarşik özellik çıkarıcı evrişimsel ağların birleştirilmesidir [62]. Hem uzamsal hem de zamansal olarak derin olan ve sıralı girdi ve çıktıları içeren çeşitli görme görevlerine uygulama esnekliğine sahip bir modeldir. ESA'lar uzaysal-spektral özellikleri üretirken, UVKB'ler zamansal bağımlılığın kıymetlendirilmesine odaklanırlar [63].



Şekil 3.3 ESA-UVKB Mimarisi.

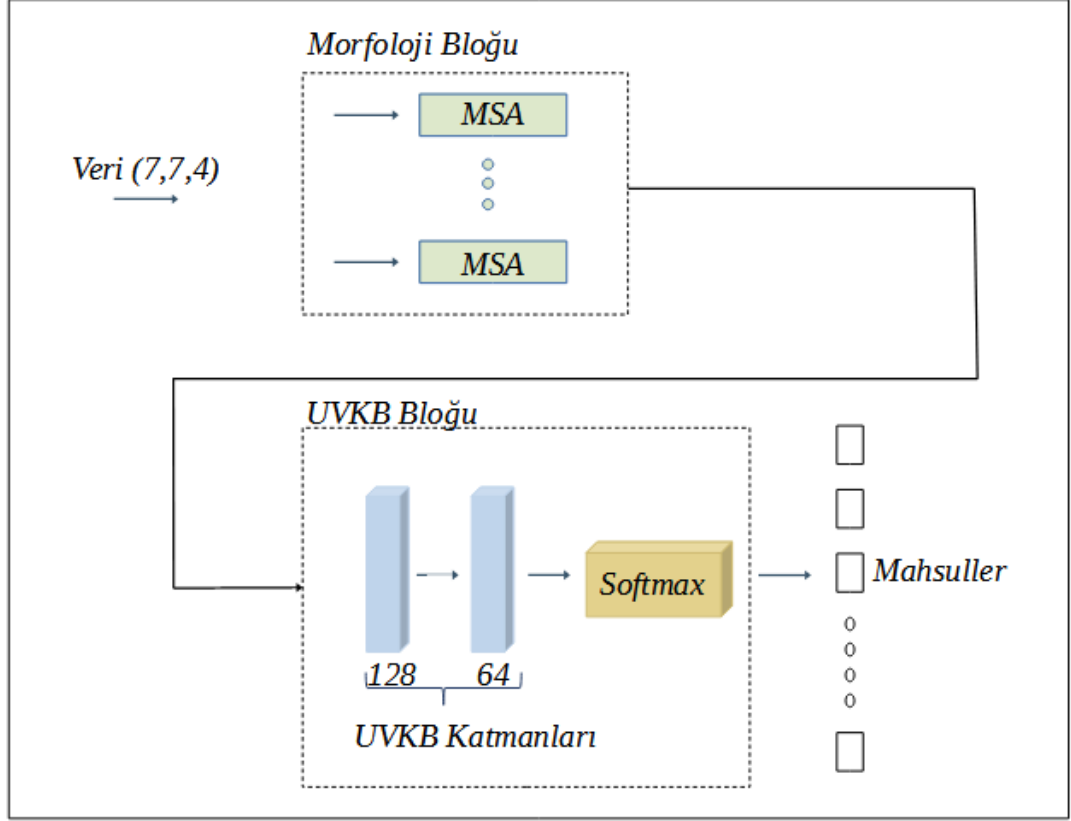
ESA-UVKB'nin arkasındaki genel fikir, ESA'ların özellik çıkarma yeteneğinden yararlanmak, bunları her bir zaman dilimine (veya geçici örneğe) uygulamak ve ardından zamansal kalıpları tespit etmek ve kullanmak için ortaya çıkan özellik dizisini bir UVKB'ye beslemektir [64]. Şekil 3.3'de bir ESA-UVKB mimarisi gösterilmiştir. Burada gösterilen  $\{t_1, t_2, \dots, t_n\}$  zaman adımlarını temsil etmektedir. Her bir zaman adımı ESA'lara verilerek özellik çıkarılır. Daha sonra bu çıktı zamansal özellikleri ortaya çıkarmak için UVKB'ye verilir. ESA-UVKB'ler hakkında daha fazla ayrıntı için [64–67] çalışmalarına bakınız.

### 3.2.2 Morfolojik Uzun Kısa Vadeli Bellek (MSA-UVKB)

Klasik morfolojik algoritmalar, genişleme ve aşınım operatörleri kullanarak tanımlanır. Morfolojik filtreleme de bu operatörlerin kombinasyonları ile oluşur ve yapılandırma öğeleri kullanılır. Bu işlemler görüntü işlemede birçok farklı uygulamada başarıyla kullanılmaktadır [68, 69]. Yapılandırma elemanlarının şekli ve boyutu akıllıca seçilerek birçok problem çözülebilir. Yapılandırma elemanlarının özelleştirilmiş boyut ve şeklini ayrıca genişleme ve aşınım işlemlerinin hangi sırayla uygulanacağını bulmak hala büyük bir zorluk olmaya devam etmektedir. Uzman problem örneklerine bağlı olarak operatörü tasarlamak zorunda kalabilmektedir. Bu konuda, Evrişimli ağların evrişim ve morfolojik genişleme ve aşınım arasındaki benzerlikten esinlenerek iki boyutlu gri tonlamalı morfolojik ağlar kullanılmıştır [3]. Biçimbilimsel işlemler uzamsal bilgiyi kıymetlendirmek ile bilinirler. Doğrusal evrişim yerine doğrusal olmayan bir işlem ortaya koyarlar. Her ne kadar ESA'larda aktivasyon fonksiyonu ile doğrusal olmayan modeller de üretilebiliyor olsa da literatürde [20, 22, 71–73] daha üstün sonuçlar sağladıklarına dair yayınlar mevcuttur. Bu yüzden onları da araştırdık.

Evrişimli sinir ağları, görüntü anlamsal bölümlenme için en popüler ağlardan biridir [73]. Aksine, tekrarlayan sinir ağları tipik olarak konuşma ve metin işlemede kullanılır. Bununla birlikte, ürün sınıflandırmasında tekrarlayan sinir ağları kullanılmasının birkaç nedeni vardır. İlk olarak, mahsul büyümesi aşamalı ve zamana duyarlıdır. Büyüme mevsimi boyunca ekinlerin zamansal varyasyon modelini keşfetmek için UVKB'lerden yararlandık. UVKB, zaman adımlarında ardışık pikseller

arasındaki tutarlılığı tespit edebilir ve farklı büyüme aşamalarındaki mahsullerin özelliklerini tanıyabilir.




Şekil 3.4: Önerilen Yaklaşım (MSA-UVKB).

Uzamsal özellikleri yakalayabilmek için de morfolojik sinir ağlarını kullandık. Bu çalışmada zamansal bağımlılıklardan yararlanmaya çalışan uzun kısa vadeli bellek ile mevcut ESA-UVKB mimarilerinin aksine, evrişim ile benzerliklerinden esinlenerek eğitilebilir morfolojik operatörlerin katkısını görmek için klasik morfolojik filtrelemeyi taklit eden morfolojik ağların birleştirildiği Morfolojik uzun kısa vadeli bellek yaklaşımını öneriyoruz. Bu çalışmanın farkı, ESA'lar yerine aynı roldeki MSA'ların araştırılmasıdır. Keşfedilen yaklaşımın ana hatları Şekil 3.4'de gösterilmektedir. Bu yaklaşım, ESA-UVKB mimarisinin morfolojik ağlar ile ilk gerçekleşmesidir. Yaklaşım, Morfolojik ve UVKB bloklarından oluşur. Morfoloji bloğu, ESA'ların evrişimli katmanlarının ağırlıklarını eğitime şekline çok benzer şekilde, belirli bir görev için geri yayılım kullanılarak yapılandırma elemanlarının eğitildiği bir dizi genişleme-aşınım operatörlerinden oluşur.

$$(I \oplus W_d)(x, y) = \max_{i \in S_1, j \in S_2} (I(x - i, y - j) + W_d(i, j)) \quad (3.5)$$

$$(I \ominus W_e)(x, y) = \min_{i \in S_1, j \in S_2} (I(x + i, y + j) - W_e(i, j)) \quad (3.6)$$

Denklem 3.5 genişleme ( $\oplus$ ), Denklem 3.6 aşınımı ( $\ominus$ ) göstermektedir.  $I$  gri bir görüntü,  $W_d, W_e \in R^{a \times b}$ ,  $S_1 = \{1, 2, \dots, a\}$  ve  $S_2 = \{1, 2, \dots, b\}$  genişleme ve aşınım yapılandırma elemanlarıdır. Yapılandırma elemanları  $W_d$  ve  $W_e$  rastgele ağırlıklar ile başlatılır ve sonrasında geri yayılım ile optimize edilir [3]. MSA'ların ana fikri, doğrusal evrişimleri morfolojik operatörler ve filtrelerle değiştirmektir. Spesifik olarak, verilen bir görüntü  $I$ , evrişim yerine iki temel morfolojik operatörü, genişleme ( $\oplus$ ) ve aşınım ( $\ominus$ ) kullanır. Sonrasında ağırlık, rastgele başlatılan ağırlıklar ile optimize edilir.



Şekil 3.5. MSA içeriği.

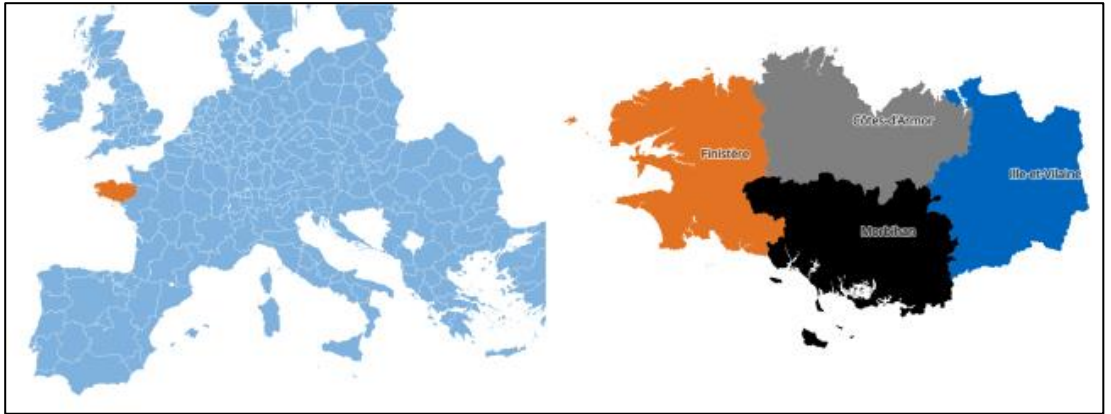
Çalışmamızda kullanılan MSA, Şekil 3.5'de gösterilmiştir. 4 filtrelilik,  $3 \times 3$  piksel sabit çekirdek boyutu ile çeşitli sayılarda art arda aşınım ve genişlemelerden oluşur. Giriş görüntü yaması  $5 \times 5$ ,  $7 \times 7$  ve  $9 \times 9$  piksel kadar küçük olacağından havuzlama katmanı kullanılmaz. Mimari için ilk olarak [3] çalışması baz alınmıştır. Daha sonradan genişletilerek deneylere göre en iyi sonuç verdiği için bu tasarım ile devam edilmiştir. Her multispektral zamansal örnek MSA'dan geçer ve daha sonra elde edilen düzleştirilmiş ve birleştirilmiş özellik haritaları LSTM bloğuna beslenir. LSTM bloğu, relu aktivasyonu ile donatılmış iki lstm katmanından (128 ve 64 düğümlü), ardından sınıf olasılıklarını üretmek için yoğun bir katman ve softmax'tan oluşur (Denklem 3.3). Yitim fonksiyonu olarak kategorik çapraz entropi (CCE) fonksiyonu kullanılmıştır (Denklem 3.4). Bu mimari çoklu zamanlı görüntülerin gözetimli şekilde mahsul sınıflandırmasına uygulanmıştır.

## 4. DENEYLER

### 4.1. Veri Kümeleri

#### 4.1.1. Breizhrops

Breizhcrops veri kümesi, Fransa'nın Britanya bölgesine aittir. 2017 yılı boyunca düzenli olarak elde edilmiştir. 27200  $km^2$ 'lik bir alanı kapsamaktadır. Sentinel-2 L1C ve L2A verilerini içermektedir (Deneylerimizde herhangi bir ön işleme olmaksızın sağlandığı için doğrudan L1C seviyesi verileri kullanılmıştır). Bölgede ılıman okyanus iklim hakimdir ve yıllık ortalama sıcaklık kışın 5,6 derece ile 17,5 arasında değişir. Yıllık ortalama 650 milimetre yağış alır. Veri kümesi, işleme seviyesi başına yaklaşık 610 bin etiketli gözlem içerir. Her gözlem, bir tarladaki mahsulünün zamansal profilini tanımlar ve Sentinel-2 görüntülerinden çıkarılan mahsul alanı seviyesindeki yansıma değerlerinin ortalaması alınarak elde edilen çok değişkenli bir zaman serisine karşılık gelir. 9 tarım sınıfı ile 13 spektral banda sahiptir (Tablo 4.1). Veri kümesindeki her örnek bir tarla parselinin uzamsal ortalamasını temsil eden çoklu zamanlı multispektral bir yapıdadır. Örnekler 45 sekans uzunluğundadır. Şekil 4.1 'de gösterildiği gibi 4 coğrafi bölgeden oluşmaktadır.



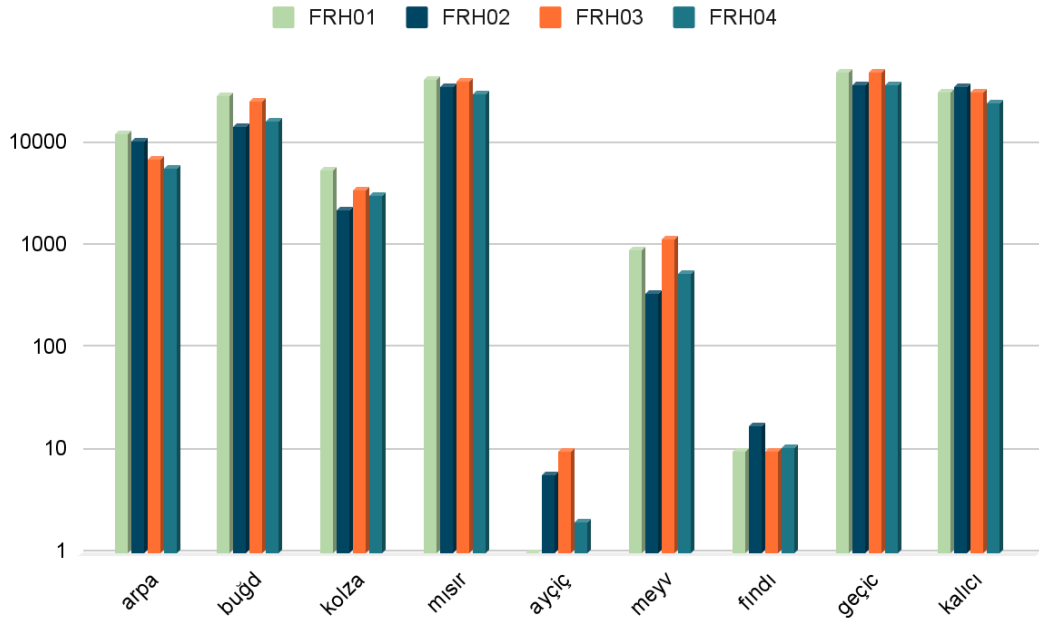
Şekil 4.1 Breizhcrops bölgeleri: Cotes-d'Armor(FRH01), Finistere(FRH02), Ille-et-Vilaine(FRH03) ve Morbihan (FRH04).

Bölgelere göre sınıf dağılımları Tablo 4.1'de gösterilmektedir. Sınıf dağılımı açık bir şekilde dengesiz olmakla birlikte, her bölge aynı şekilde tüm mahsul türlerine

sahiptir [44]. Mahsullerin her bölge için sınıf dağılımı Şekil 4.2'de görsel bir grafik olarak gösterilmektedir.

Tablo 4.1 Breizhcrops veri kümesindeki örneklerin bölgelere göre sınıf dağılımı.


Mahsul	FRH01	FRH02	FRH03	FRH04
Arpa	13046	10733	7148	5978
Buğday	30368	15005	27189	16993
Kolza	5593	2346	3557	3236
Mısır	43990	36593	41992	31333
Ayçiçeği	1	6	10	2
Meyve bahçeleri	944	350	1223	553
Fındık	10	18	10	11
Geçici çayırlar	52011	39082	52728	38391
Kalıcı çayırlar	32650	36512	32534	26117
Toplam	178613	140645	166391	122614




Şekil 4.2 Breizhcrops bölgelere göre sınıf dağılımı.

### 4.1.2. Sakarya

Sakarya veri kümesi, Türkiye'nin Sakarya havzasına aittir. Şekil 4.3'de gösterilmiştir. Copernicus Açık Erişim Merkezi aracılığıyla Sentinel-2-L2 uydusundan elde edilmiş, 2019 yılına ait 13 aylık 4 spektral banda (optik ve yakın kızılötesi) sahip uydu görüntülerinden oluşmaktadır. Orman, tarım ve kentsel alanlardan oluşan yaklaşık  $170 \times 60$  km büyüklüğünde bir kıta bölgesidir. Şekil 4.3'de görüldüğü gibi görüntü  $17000 \times 6000$  km<sup>2</sup> piksel boyutlarındadır [74]. 7 tarım sınıfına sahiptir. Etiketsiz eğitim, etiketli eğitim, doğrulama ve sınaama kümelerini oluşturmak için görüntü yatay olarak eşit bir şekilde 4 bölgeye ayrılmıştır. Şekil 4.4'de bölgeler gösterilmiştir. Sınıfların dengesiz olması sebebiyle etiketli eğitim kümesi her sınıftan eşit miktarda veri içerecek şekilde ayarlanmıştır. Ayrılan bölgelere göre sınıf dağılımı Tablo 4.2'de gösterilmiştir. Mahsullerin her bölge için sınıf dağılımı Şekil 4.5'de görsel bir grafik olarak gösterilmektedir.



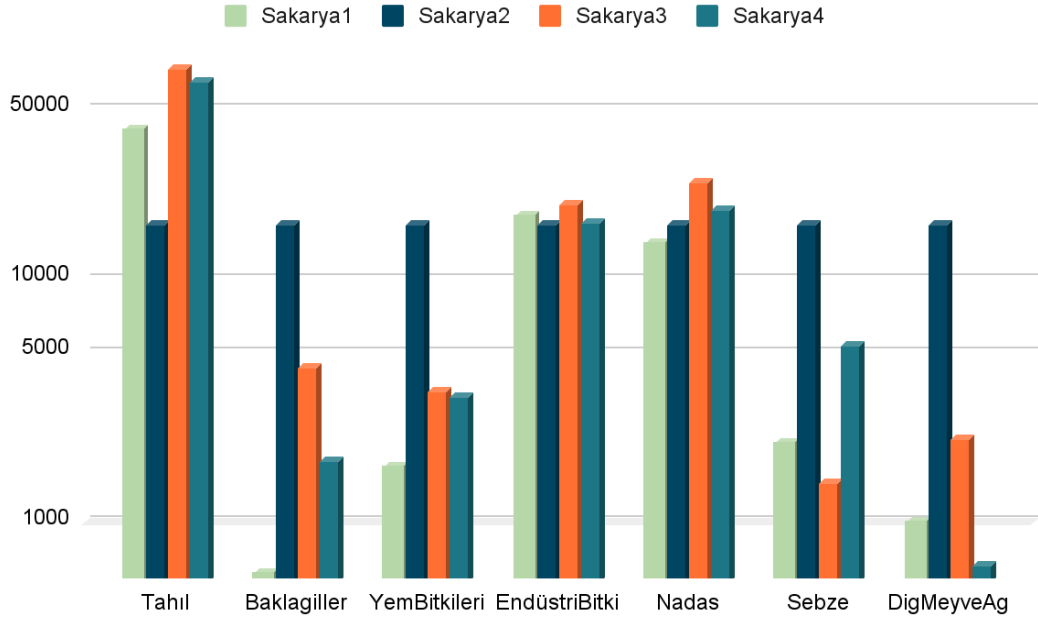
Şekil 4.3 Türkiye Sakarya Havzası (beyaz ile gösterilmiştir).



Şekil 4.4 Sakarya Bölgeleri; etiketsiz eğitim (Sakarya3), etiketli eğitim (Sakarya2), doğrulama (Sakarya1), sınaama (Sakarya4).

Tablo 4.2 Sakarya veri kümesindeki örneklerin bölgelere göre sınıf dağılımı.

<b>Mahsul</b>	<b>Sakarya1</b>	<b>Sakarya2</b>	<b>Sakarya3</b>	<b>Sakarya4</b>
Tahıl	40976	16500	72833	64140
Baklagiller	608	16499	4303	1763
YemBitkileri	1679	16498	3440	3226
EndüstriBitki	18182	16498	20226	16956
Nadas	14047	16498	24975	19216
Sebze	2087	16498	1426	5263
DigMeyveAg	1000	16498	2184	654
<b>Toplam</b>	<b>78579</b>	<b>115489</b>	<b>129387</b>	<b>111218</b>



Şekil 4.5 Sakarya bölgelere göre sınıf dağılımı.

## 4.2. Ayarlar

### 4.2.1 Veri Kümesi Eğitim/Test Bölümü Seçimi

Yarı gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar yaklaşımında Breizhcrops veri kümesinde, FRH01 bölgesi etiketsiz eğitim, FRH02 bölgesi etiketli eğitim, doğrulama için FRH03 bölgesi ve sınama için FRH04 bölgesi kullanılmıştır. Sakarya veri kümesi için Tablo 4.2'de gösterilen Sakarya3 bölgesi etiketsiz eğitim, Sakarya2 bölgesi etiketli eğitim, Sakarya1 bölgesi doğrulama ve Sakarya4 bölgesi sınama için kullanılmıştır. Morfolojik Uzun Kısa Vadeli Bellek (MSA-UVKB) yaklaşımında ise Breizhcrops veri kümesinde FRH02 eğitim için, FRH03 doğrulama için ve FRH04 test için kullanıldı. Sakarya veri kümesinde de Sakarya2 eğitim (sınıflar arasında dengeli sayıda piksel içeren), doğrulama için Sakarya1 ve son olarak da test için Sakarya4 bölgesi kullanılmıştır.

### 4.2.2 Başarım Ölçütleri

Deneylerde mahsul sınıflandırma probleminin başarısını ölçmek için, iki metrik kullanılmıştır:

- Genel Doğruluk (OA): Genel doğruluk, doğru sınıflandırılmış veri noktalarının toplamının toplam veri noktası sayısına bölünmesiyle hesaplanır. Doğru sınıflandırılmış örneklerin oranını gösterir.

$$\text{Genel doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

- Cohen's kappa score (K): Cohen'in kappa puanı, kategorik elemanlar arasındaki uyuşma miktarını ölçmek için kullanılır. Anlaşmanın tesadüfen meydana gelme olasılığını hesaba kattığı için, genel doğruluktan daha sağlam bir ölçümdür. Kappa puanı -1 ile 1 arasında değişmektedir. Kappa 0 ise anlaşmanın şansa dayalı olduğu anlamına gelir; kappa 1 ise mükemmel anlaşma anlamına gelir.

$$Cohen's\ kapp\ score = \frac{Gözlemlenen\ uyuşma - Şans\ uyuşması}{1 - Şans\ uyuşması} \quad (4.2)$$

### 4.2.3 Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar Deney Ayarları

Deneylerimiz iki aşamadan oluşmaktadır: Etiketsiz veri ile Uzun Kısa Vadeli Bellek Oto Kodlayıcılar ağının eğitimi ve etiketsiz modelin kodlayıcı katman ağırlıkları ile Uzun Kısa Vadeli Bellek Oto Kodlayıcıların kodlayıcı kısmının eğitimi. Etiketsiz eğitimde 0,001 öğrenme oranına sahip Adam eniyileştiricisi kullanılmıştır. Grup boyutu 256 olarak kullanılmıştır. Eğitimler doğrulama kaybı azalmayana kadar sürmüştür. Yitim fonksiyonu olarak ortalama kare hata (MSE) (Denklem 3.1) kullanılmıştır. Tablo 4.3' de eğitim parametreleri gösterilmiştir.

Tablo 4.3 Etiketsiz eğitim parametreleri (1.aşama).

Parametreler	Değeri
İyileştirici	Adam
Öğrenme Oranı	0.001
Grup Boyutu	256
Durdurma ölçütü	30 (min val_loss)
Yitim Fonksiyonu	Ortalama kare hata (MSE)

Etiketli eğitimde 0,001 öğrenme oranı, 0.9 gradyan indirgemesine sahip RMSprop eniyileştiricisi kullanılmıştır. Deneylerde başarısını gözlemlemek için Adam iyileştiricisi de denenmiştir. Grup boyutu olarak 32, 256 gibi farklı boyutlar ile deneyler gerçekleştirilmiştir. Aktivasyon fonksiyonu olarak relu kullanılmıştır. Eğitimler doğrulama kaybı azalmayana kadar sürmüştür. Yitim fonksiyonu olarak kategorik çapraz entropi (CCE) (Denklem 3.2) kullanılmıştır. Modeller Keras kütüphanesi ile gerçekleştirilmiştir ve 16 GB belleğe sahip P100 GPU üzerinde eğitilmiştir. Tüm çalışmalar boyunca sınıflandırma sonuçları, genel doğruluk overall accuracy (OA) ve Cohen'in kappa skoru ile ölçülmüştür. Tablo 4.4'de eğitim parametreleri gösterilmiştir.

Tablo 4.4 Etiketli eğitim parametreleri (2.aşama).

Parametreler	Değeri
İyileştirici	RMSprop/adam
Öğrenme Oranı	0.001
Grup Boyutu	32/256
Durdurma ölçütü	15 (min val_loss)
Yitim Fonksiyonu	Kategorik Çapraz Entropi (CCE)

Önerilen yöntemin (Yarı-gözetimli) başarısını ölçmek adına, aynı kodlayıcı UKVB mimarisine sahip sadece gözetimli olarak eğitilmiş model (Gözetimli) ile karşılaştırılmıştır. Önerilen yöntemin başarısını doğrulamak adına farklı bir ağ ile de denenmiştir. UVKB katmanlarının yerine Kapılı Tekrarlayan Hücre (GRU)'ların kullanıldığı aynı mimariye sahip model ile deneyler gerçekleştirilip karşılaştırılmıştır. Model şekli ekler kısmında bulunmaktadır (Şekil B.1). Ek olarak iki veri kümesi için de etiketli eğitim ve sınama kümeleri ile sığ yaklaşım olarak Rastgele Orman sınıflandırıcısı ile sonuçlar üretilmiştir. 5 kat çapraz doğrulama ile ızgara arama kullanılarak hiper parametre ayarlaması yapılmıştır. 100 ağaç kullanılmıştır. Rastgele orman modeli için Python'ın scikit-learn kütüphanesi kullanılmıştır. Kütüphane temel olarak veri modellemeye odaklanır; ayrıca veri analizi ve veri madenciliği için basit ve etkili fonksiyonlara sahiptir. Son olarak 2 veri kümesi ile de [44]'de kullanılan  $7 \times 7$  boyutunda 128 filtrelili TempCNN,  $3 \times 3$ ,  $5 \times 5$  ve  $7 \times 7$  boyutlarında 32 filtrelili MSResNet, 128 filtrelili InceptionTime, OmniscaleCNN, 128 birim üç katmanlı LSTM, 128 birim üç katmanlı StarRNN ve 4 katmanlı Transformer [43] yaklaşımları grup boyutu 256 kullanılarak RMSprop eniyileştiricisi ile etiketli eğitim, doğrulama ve sınama kümeleri ile denenmiştir. Deney Sonuçları bir sonraki bölümde Tablo 4.6 ve Tablo 4.7'de gösterilmiştir.

#### 4.2.4 Morfolojik Uzun Kısa Vadeli Bellek Ağı Deney Ayarları

Deneyler, 0,001'lik bir öğrenme oranı ve 256'lık bir batch size kullanılarak 0.9 gradyan indirgemesine sahip RMSprop ile gerçekleştirilmiştir. Deneylerde başarısını gözlemlemek için Adam eniyileştiricisi de denenmiştir. Aktivasyon fonksiyonu olarak

relu kullanılmıştır. Eğitim sırasında doğrulama kaybına dayalı bir erken durdurma kriteri kullanılmıştır. Modeller Keras kütüphanesi ile gerçekleştirilmiştir ve 16 GB belleğe sahip P100 GPU üzerinde eğitilmiştir. Performans, genel doğruluk (OA) ve Cohen'in kappa istatistiği (kappa) açısından ölçülmüştür. Tablo 4.5'de MSA-UVKB eğitim parametreleri gösterilmiştir.

Tablo 4.5 MSA-UVKB parametreleri.

Parametreler	Değeri
İyileştirici	RMSprop/adam
Öğrenme Oranı	0.001
Grup Boyutu	256
Durdurma ölçütü	15 (min val_loss)
Yitim Fonksiyonu	Kategorik Çapraz Entropi (CCE)

Önerilen Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) yaklaşımının başarısını ölçmek adına MSA-UVKB ile aynı mimariye sahip bir ESA-UVKB (16 filtre  $3 \times 3$  boyutunda) ile karşılaştırılmıştır. Karşılaştırılan ESA-UVKB modeli ekler kısmında bulunmaktadır (Şekil B.2). Morfolojik sinir ağlarını baz aldığımız [3]'de önerilen morfolojik yöntemler sonuna bir softmax sınıflandırıcı eklenerek denenmiştir. Daha sonra [3]'daki yöntemlerin sonuna UVKB bloğu eklenerek denenmiştir. Modellerin şekilleri Ekler kısmında bulunmaktadır. Ayrıca, [44]'teki son teknoloji alternatif yaklaşımlarla da karşılaştırılmıştır: [44]'teki ile aynı kurulum/mimarilere sahip  $7 \times 7$  boyutunda 128 filtrelili TempCNN,  $3 \times 3$ ,  $5 \times 5$  ve  $7 \times 7$  boyutlarında 32 filtrelili MSResNet, 128 filtrelili InceptionTime, OmniscaleCNN, 128 birim üç katmanlı LSTM, 128 birim üç katmanlı StarRNN ve 4 katmanlı Transformer [43] yaklaşımları grup boyutu 256 kullanılarak RMSprop eniyileştiricisi ile denenmiştir. Ek olarak iki veri kümesi için de etiketli eğitim ve sınav kümeleri ile sığ yaklaşım olarak Rastgele Orman sınıflandırıcısı ile sonuçlar üretilmiştir. Rastgele orman (RF), en popüler ağaç tabanlı topluluk öğrenme sınıflandırıcılarından biridir [75]. 5 kat çapraz doğrulama ile ızgara arama kullanılarak hiper parametre ayarlaması yapılmıştır. 100 ağaç kullanılmıştır. Rastgele orman modeli için Python'ın scikit-learn kütüphanesi kullanılmıştır. Kütüphane temel olarak veri modellemeye odaklanır;

ayrıca veri analizi ve veri madenciliği için basit ve etkili fonksiyonlara sahiptir. Deney Sonuçları bir sonraki bölümde Tablo 4.8 ve Tablo 4.9'da gösterilmiştir.

### 4.3. Sonuçlar

Bu bölüm, Yarı gözetimli uzun kısa vadeli bellek oto kodlayıcılar yaklaşımının ve Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) yaklaşımının mahsul sınıflandırma alanındaki performansı iyileştirip iyileştirmediğini ve ne kadar geliştirdiğini ölçmeyi amaçlayan bir dizi deneyin sonuçlarını sunar.

Yarı gözetimli uzun kısa vadeli bellek yaklaşımımız, aynı mimariye sahip etiketsiz veri kullanılmadan gözetimli yaklaşım ile karşılaştırılmıştır. Bu şekilde etiketsiz verinin başarımının gözlenmesi hedeflenmiştir. Son teknoloji yaklaşımlarından karşılaştırmalarımızda üç ESA tabanlı yaklaşım yer aldı. Bunlar geçici alanda evrişimler uygulayan bir TempCNN (128 filtre  $7 \times 7$  boyutunda), 32 filtreli MsResNet ve 128 filtreli InceptionTime. ESA tabanlı yaklaşımlara ek olarak girdi ve çıktı arasındaki bağımlılıkları ele almak için bir dikkat mekanizması ile birlikte ESA katmanları da kullanan Transformer modeli kullanılmıştır. Üç evrişim katmanından, küresel ortalama havuzlama ve softmaxten oluşan OmniscaleCNN kullanılmıştır. Tekrarlayan Sinir Ağları tabanlı yaklaşımlar söz konusu olduğunda, evrişim modülü olmayan düz bir LSTM (3 katmanlı) ve StarRNN (3 katmanlı) kullanılmıştır. Sığ bir yaklaşım olan Rastgele orman ile karşılaştırılmıştır. Son olarak UVKB katmanları yerine Kapılı Tekrarlayan Hücre (GRU) katmanları koyarak oluşturduğumuz Yarı gözetimli (GRU) modeli ile karşılaştırılmıştır. Yarı Gözetimli yaklaşımın sınıflandırma sonuçları Breizhcrops için sınıflandırma sonuçları Tablo 4.6'da Literatürdeki yöntemler ile karşılaştırma sonuçları 4.7'de, eğitim süresi ve parametre sayıları 4.8'de verilmiştir. Sakarya veri kümesi için de sınıflandırma sonuçları Tablo 4.9'da verilmiştir. Literatürdeki yöntemler ile karşılaştırma sonuçları Tablo 4.10'da eğitim süresi ve parametre sayıları 4.11'de verilmiştir.

Tablo 4.6 Breizhcrops Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar(Yarı Gözetimli) Sonuçları.

Mimari	Genel Doğruluk	Kappa	Batch Size	İyileştirici
Gözetimli (UVKB)[76]	0,71	0,63	32	RMSprop
Yarı Gözetimli (UVKB)[76]	0,75	0,68	32	RMSprop
Gözetimli (UVKB)	0,77	0,70	256	RMSprop
<b>Yarı Gözetimli (UVKB)</b>	<b>0,79</b>	<b>0,73</b>	256	RMSprop
Yarı Gözetimli (UVKB)	0,78	0,71	256	Adam
Gözetimli (GRU)	0,77	0,70	256	RMSprop
Yarı Gözetimli (GRU)	0,78	0,71	256	RMSprop
Yarı Gözetimli (GRU)	0,76	0,70	256	Adam

Tablo 4.7 Breizhcrops Literatür Yaklaşımları ile Karşılaştırma.

Mimari	Genel Doğruluk	Kappa	Batch Size	İyileştirici
<b>Yarı Gözetimli (UVKB)</b>	<b>0,79</b>	<b>0,73</b>	256	RMSprop
TempCNN[44]	0,76	0,68	256	RMSprop
<b>MSResNet[44]</b>	<b>0,79</b>	<b>0,73</b>	256	RMSprop
InceptionTime[44]	0,78	0,71	256	RMSprop
OmniscaleCNN[44]	0,76	0,69	256	RMSprop
LSTM[44]	0,78	0,71	256	RMSprop
StarRNN[44]	0,76	0,70	256	RMSprop
Transformer[44]	0,79	0,72	256	RMSprop
Rastgele Orman	0,66	0,56	-	-

Tablo 4.8 Breizhcrops Eğitim Süresi ve Parametre Sayıları.

Model	Süre (dk)	Parametre Sayısı
<b>Yarı Gözetimli (UVKB)</b>	40(etiketsiz veri eğitimi) +32	523.849
TempCNN[44]	30	3.197.449
<b>MSResNet[44]</b>	33	535.785
InceptionTime[44]	28	338.697
OmniscaleCNN[44]	36	2.738.053
LSTM[44]	43	1.335.331
StarRNN[44]	46	71.587
Transformer[44]	39	168.969
Rastgele Orman	42	-

Tablo 4.9 Sakarya Yarı Gözetimli Uzun Kısa Vadeli Bellek Oto Kodlayıcılar(Yarı Gözetimli) Sonuçları.

Mimari	Genel Doğruluk	Kappa	Batch Size	İyileştirici
Gözetimli (UVKB)[76]	0,60	0,43	32	RMSprop
Yarı Gözetimli (UVKB)[76]	0,62	0,46	32	RMSprop
Gözetimli (UVKB)	0,62	0,46	256	RMSprop
<b>Yarı Gözetimli (UVKB)</b>	<b>0,65</b>	<b>0,48</b>	256	RMSprop
Yarı Gözetimli (UVKB)	0,64	0,47	256	Adam
Gözetimli (GRU)	0,61	0,44	256	RMSprop
Yarı Gözetimli (GRU)	0,62	0,45	256	RMSprop
Yarı Gözetimli (GRU)	0,61	0,44	256	RMSprop

Tablo 4.10 Sakarya Literatür Yaklaşımları ile Karşılaştırma.

Mimari	Genel Doğruluk	Kappa	Batch Size	İyileştirici
<b>Yarı Gözetimli (UVKB)</b>	<b>0,65</b>	<b>0,48</b>	256	RMSprop
TempCNN[44]	0,58	0,40	256	RMSprop
MSResNet[44]	0,60	0,43	256	RMSprop
InceptionTime[44]	0,58	0,40	256	RMSprop
OmniscaleCNN[44]	0,58	0,40	256	RMSprop
LSTM[44]	0,61	0,43	256	RMSprop
StarRNN[44]	0,59	0,40	256	RMSprop
Transformer[44]	0,61	0,45	256	RMSprop
Rastgele Orman	0,55	0,39	-	-

Tablo 4.11 Sakarya Eğitim Süresi ve Parametre Sayıları.

Model	Süre (dk)	Parametre Sayısı
<b>Yarı Gözetimli (UVKB)</b>	40(etiketsiz veri eğitimi) +28	383.751
TempCNN[44]	22	3.624.423
<b>MSResNet[44]</b>	25	512.327
InceptionTime[44]	20	315.111
OmniscaleCNN[44]	38	324.239
LSTM[44]	35	1.300.969
StarRNN[44]	42	48.233
Transformer[44]	31	128.071
Rastgele Orman	44	-

Sonuçlara bakıldığında, önerdiğimiz yarı gözetimli yaklaşım 32'lik grup boyutu ve RMSprop iyileştiricisi ile gözetimli yaklaşımı Breizhcrops veri kümesinde 5 kappa puanı, Sakarya veri kümesinde 3 kappa puanı geçmiş ve Breizhcrops'da 0.68'lik, Sakarya'da 0.46'lık bir kappa puanı elde etmiştir. 256'lık grup boyutu ve

adam eniyileştiricisi ile de Breizhcrops ve Sakarya veri kümesinde 1 kappa puan ile gözetimli yaklaşımdan daha iyi performans göstererek Breizhcrops'da 0.71'lik, Sakarya'da 0.47'lik bir kappa puanı elde etmiştir. 256'lık grup boyutu ve RMSprop iyileştiricisi ile denendiğinde Breizhcrops'da 3, Sakarya'da 2 kappa puanı ile gözetimli yaklaşımı geçerek Breizhcrops'da 0.73, Sakarya'da 0.48 kappa puanı elde etmiştir. Önerdiğimiz yaklaşımı UVKB katmanları yerine Kapılı Tekrarlayan Hücre (GRU) katmanları koyarak oluşturduğumuz Yarı gözetimli (GRU) modeli ile karşılaştırdığımızda, Yarı gözetimli (GRU) etiketsiz veri kullanılmadan gözetimli (GRU) ya göre iki veri kümesinde de 1 kappa puanlık bir başarı elde etmiştir ancak Yarı gözetimli (UVKB) yaklaşımını geçememiştir. Sonuç olarak iki veri kümesinde de en iyi başarı 256'lık grup boyutu ve RMSprop iyileştirici parametreleri kullanılan yarı gözetimli uzun kısa vadeli bellek oto kodlayıcılardır. Sonuçlar, bu çalışmadaki amacımız olan etiketsiz verilerin kullanımının, etiketli verilerin sınıflandırılmasında bir iyileşme sağladığını göstermektedir. Bu iyileşme önerdiğimiz Yarı gözetimli (UVKB) yaklaşımının sınıflandırma için rastgele ağırlıklar yerine etiketsiz verilerden öğrenilen ağırlıklara sahip olmasından kaynaklanmaktadır.

Literatürdeki diğer yöntemlerle karşılaştırıldığında (Tablo 4.7 ve Tablo 4.9) Rastgele orman, girdinin sıralı yapısını hesaba katmadığı ve bunun yerine onu bir vektör olarak ele aldığı için beklendiği gibi en düşük performansı göstermiştir. ESA tabanlı yaklaşımlar ise klasik makine öğrenimi tekniklerine göre derin özellikleriyle üstünlüğünü ortaya koyan, Rastgele orman yüksek oranda daha iyi performans göstermiştir. MSResNet ve Transformer modeli, literatürdeki tekrarlayan modellerden biraz daha iyi performans göstermiştir. Önerilen Yarı Gözetimli yaklaşım ise 0.73'lik kappa puanı ile Breizhcrops veri kümesinde literatürdeki başarıyı yakalamıştır. Sakarya veri kümesinde de 0.48'lik kappa puanı ile literatürdeki başarıları geçmiştir. Sakarya kümesindeki bu başarımın literatürdeki yaklaşımların Breizhcrops verikümesine göre tasarlanmasından kaynaklı olabilir. Tablo 4.8 ve 4.11'e bakıldığında hem eğitim süreleri açısından iki veri kümesinde de sürelerin birbirlerine nispeten yakın olduğu, yalnızca önerdiğimiz Yarı Gözetimli yaklaşımın 1. aşamasındaki etiketsiz veri eğitim süresinden kaynaklı daha uzun sürdüğü görülmektedir. Ağ parametrelerinin sayısı açısından da farklılaştıkları görülmüştür.

Tablo 4.12 Breizhcrops Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Sonuçları.

Mimari	Genel Doğruluk	Kappa	İyileştirici
ESA-UVKB	0,73	0,65	RMSprop
<b>MSA-UVKB</b>	<b>0,77</b>	<b>0,70</b>	RMSprop
MSA-UVKB	0,76	0,69	Adam
morphoN[3]	0,68	0,59	RMSprop
morphoN(small)[3]	0,67	0,57	RMSprop
MorphoN-path1[3]	0,67	0,57	RMSprop
MorphoN-path2[3]	0,67	0,57	RMSprop
morphoN-UVKB	0,71	0,63	RMSprop
morphoN(small)-UVKB	0,67	0,57	RMSprop
MorphoN-path1-UVKB	0,67	0,57	RMSprop
MorphoN-path2-UVKB	0,75	0,68	RMSprop
TempCNN[44]	0,76	0,68	RMSprop
<b>MSResNet[44]</b>	<b>0,79</b>	<b>0,73</b>	RMSprop
InceptionTime[44]	0,78	0,71	RMSprop
OmniscaleCNN[44]	0,76	0,69	RMSprop
LSTM[44]	0,78	0,71	RMSprop
StarRNN[44]	0,76	0,70	RMSprop
Transformer[44]	0,79	0,72	RMSprop
Rastgele Orman	0,66	0,56	-

Tablo 4.13 Breizhcrops Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Eğitim Süresi ve Parametre Sayıları.

<b>Model</b>	<b>Süre (dk)</b>	<b>Parametre Sayısı</b>
ESA-UVKB	56	2.459.993
<b>MSA-UVKB</b>	36	130.697
morphoN[3]	32	82.054
morphoN(small)[3]	31	60.112
MorphoN-path1[3]	31	65.887
MorphoN-path2[3]	31	65.887
morphoN-UVKB	30	139.477
morphoN(small)-UVKB	30	129.665
MorphoN-path1-UVKB	30	130.377
MorphoN-path2-UVKB	30	130.377
TempCNN[44]	30	3.197.449
<b>MSResNet[44]</b>	33	535.785
InceptionTime[44]	28	338.697
OmniscaleCNN[44]	36	2.738.053
LSTM[44]	43	1.335.331
StarRNN[44]	46	71.587
Transformer[44]	39	168.969
Rastgele Orman	42	-

Tablo 4.14 Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Sonuçları.

Mimari	Genel Doğruluk	Kappa	İyileştirici
ESA-UVKB	0,72	0,52	RMSprop
<b>MSA-UVKB</b>	<b>0,74</b>	<b>0,55</b>	RMSprop
MSA-UVKB	0,73	0,54	Adam
morphoN[3]	0,63	0,46	RMSprop
morphoN(small)[3]	0,64	0,46	RMSprop
MorphoN-path1[3]	0,59	0,40	RMSprop
MorphoN-path2[3]	0,60	0,41	RMSprop
morphoN-UVKB	0,67	0,49	RMSprop
morphoN(small)-UVKB	0,62	0,45	RMSprop
MorphoN-path1-UVKB	0,66	0,47	RMSprop
MorphoN-path2-UVKB	0,70	0,50	RMSprop
TempCNN[44]	0,60	0,42	RMSprop
MSResNet[44]	0,62	0,45	RMSprop
InceptionTime[44]	0,61	0,44	RMSprop
OmniscaleCNN[44]	0,60	0,42	RMSprop
LSTM[44]	0,68	0,49	RMSprop
StarRNN[44]	0,69	0,49	RMSprop
Transformer[44]	0,71	0,50	RMSprop
Rastgele Orman	0,55	0,39	RMSprop

Tablo 4.15 Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Eğitim Süresi ve Parametre Sayıları.

<b>Model</b>	<b>Süre (dk)</b>	<b>Parametre Sayısı</b>
ESA-UVKB	48	525.271
<b>MSA-UVKB</b>	38	343.079
morphoN[3]	30	10.269
morphoN(small)[3]	15	65.071
MorphoN-path1[3]	15	63.859
MorphoN-path2[3]	15	63.859
morphoN-UVKB	32	330.668
morphoN(small)-UVKB	32	328.362
MorphoN-path1-UVKB	32	324.423
MorphoN-path2-UVKB	32	324.423
TempCNN[44]	28	3.644.423
<b>MSResNet[44]</b>	31	532.327
InceptionTime[44]	24	335.111
OmniscaleCNN[44]	42	344.239
LSTM[44]	39	1.320.969
StarRNN[44]	43	68.233
Transformer[44]	35	168.071
Rastgele Orman	44	-

Tablo 4.16 Sakarya Morfolojik Uzun Kısa Vadeli Bellek Ağı (MSA-UVKB) Farklı Yama Boyutları ( $5 \times 5$ ,  $7 \times 7$ ,  $9 \times 9$ ) Sonuçları.

Mimari	Genel Doğruluk	Kappa	İyileştirici
ESA-UVKB ( $5 \times 5$ )	0,73	0,53	RMSprop
MSA-UVKB ( $5 \times 5$ )	0,74	0,54	RMSprop
ESA-UVKB ( $7 \times 7$ )	0,72	0,52	RMSprop
<b>MSA-UVKB (<math>7 \times 7</math>)</b>	<b>0,74</b>	<b>0,55</b>	RMSprop
ESA-UVKB ( $9 \times 9$ )	0,71	0,52	RMSprop
MSA-UVKB ( $9 \times 9$ )	0,74	0,54	RMSprop

Morfolojik Uzun Kısa Vadeli Bellek Ağı yaklaşımımız, aynı mimariye sahip ESA-UVKB ( $3 \times 3$  boyutunda 16 filtrelili) ile karşılaştırılmıştır. Morfolojik sinir ağlarını baz aldığımız [3]' de önerilen morfolojik yöntemler sonuna bir softmax sınıflandırıcı eklenerek denenmiştir. Daha sonra [3]' daki yöntemlerin sonuna UVKB bloğu eklenerek denenmiştir. Modellerin şekilleri Ekler kısmında bulunmaktadır. Son teknoloji yaklaşımlarından karşılaştırmalarımızda üç ESA tabanlı yaklaşım yer aldı. Bunlar geçici alanda evrişimler uygulayan bir TempCNN (128 filtre  $7 \times 7$  boyutunda), 32 filtrelili MsResNet ve 128 filtrelili InceptionTime. ESA tabanlı yaklaşımlara ek olarak girdi ve çıktı arasındaki bağımlılıkları ele almak için bir dikkat mekanizması ile ESA katmanları da kullanan Transformer modeli kullanılmıştır. Üç evrişim katmanından, küresel ortalama havuzlama ve softmaxten oluşan OmniscaleCNN kullanılmıştır. Tekrarlayan Sinir Ağları tabanlı yaklaşımlar söz konusu olduğunda, evrişim modülü olmayan düz bir LSTM (3 katmanlı) ve StarRNN (3 katmanlı) kullanılmıştır. Sığ bir yaklaşım olan Rastgele orman ile karşılaştırılmıştır. Karşılaştırılan tüm yaklaşımlar için sınıflandırma sonuçları Breizhcrops için Tablo 4.10'da Sakarya için Tablo 4.11'de verilmiştir. Son olarak Sakarya veri kümesinde  $5 \times 5$ ,  $7 \times 7$  ve  $9 \times 9$ 'luk farklı görüntü yama boyutlarında deneyler gerçekleştirilip sonuçları Tablo 4.16'da verilmiştir. Yama boyutu  $5 \times 5$ 'lik kadar küçük olduğunda, kararın çok daha yerel olup, çevredeki yararlı bilgileri kaçırabildiği. Öte yandan,  $9 \times 9$ 'luk kadar çok büyüdüğünde, incelenen pikseli komşu farklı sınıflarla ilişkilendirme riskinden başarımın geride kaldığı sonuçların birbirine yakın olmasına rağmen en iyi performansın  $7 \times 7$ 'lik yama boyutlarında elde edildiği görülmüştür.

Rastgele orman, girdinin sıralı yapısını hesaba katmadığı ve bunun yerine onu bir vektör olarak ele aldığı için beklendiği gibi iki veri kümesinde de en düşük performansı göstermiştir. ESA tabanlı yaklaşımlar ise klasik makine öğrenimi tekniklerine göre derin özellikleriyle üstünlüğünü ortaya koyan, Rastgele orman'dan yüksek oranda daha iyi performans göstermiştir. Transformer modeli, literatürdeki tekrarlayan modellerden biraz daha iyi performans göstermiştir. [3]'deki yöntemlere baktığımızda sonuçların iki veri kümesinde de diğer yöntemlere göre geride kaldığını sadece morphoNpath2-UVKB modelinin literatürdeki yöntemleri yakaladığı ya da yaklaştığı görülmüştür. [3]'deki Morfolojik yöntemlerin sonuna UVKB bloğu koyduğumuz model sonuçlarının UVKB'siz sonuçlara göre daha başarılı olduğu görülmüştür. Bu durum zamansal ilişkileri yakalamada uzmanlaşan tekrarlayan sinir ağlarının önemini göstermektedir. Tablo 4.13 ve 4.15'e bakıldığında hem eğitim süreleri açısından iki veri kümesinde de sürelerin birbirlerine nispeten yakın olduğu, ağ parametrelerinin sayısı açısından da farklılıkları görülmüştür.

Önerdiğimiz MSA-UVKB yaklaşımı ise adam iyileştiricisi ile Breizhcrops veri kümesinde 4, Sakarya da 2 kappa puanı ile ESA-UVKB'den daha iyi performans göstermiştir. RMSprop iyileştiricisi ile de adam iyileştiricisine göre daha iyi performans göstermiş Breizhcrops da 5, Sakarya'da 3 kappa puanı ile ESA-UVKB'den daha iyi performans göstererek Breizhcrops'da 0.70'lik, Sakarya'da 0.55'lik bir kappa başarısı elde etmiştir. Breizhcrops veri kümesinde MSA-UVKB'nin ESA-UVKB'den daha iyi performans gösterirken, StarRNN ile aynı performansta ve Transformers'ın biraz gerisindedir. Breizhcrops, 1 boyutlu bir zaman serisidir, bu nedenle sümürülecek hiçbir uzamsal bilgi yoktur. Sonuç olarak, şaşırtıcı olmayan bir şekilde, MSA-UVKB'nin alternatiflerine benzer şekilde performans gösterdiği gözlemlenebilirken, performans farklılıkları çoğunlukla MSResNet'in şaşırtıcı bir şekilde hepsinden daha iyi performans göstermesi dikkat çekmekte ve onu takip eden Transformer'ın başarısı değişen zamansal bağımlılıktan yararlanma yeteneklerinden kaynaklanmaktadır. Öte yandan iki boyutlu çok zamanlı/spektral görüntü parçalarından oluşan Sakarya veri kümesinde, MSA-UVKB muadillerinden daha iyi performans gösteriyor. Daha zorlu bir veri kümesi olduğu için genel performans seviyeleri Breizhcrops'a göre daha düşüktür. Yine de zamansal yaklaşımlar (StarRNN, Transformer, LSTM) çoğunlukla benzer performans seviyelerindeyken, hem ESA-UVKB hem de MSA-UVKB bunları aşıyor, böylece iki boyutlu çok zamanlı/spektral verilerle uğraşırken uzamsal bilginin potansiyelinin altını çiziyor. Son olarak farklı görüntü yama boyutlarında da MSA-

UVKB'nin ESA-UVKB'yi geride bıraktığı ve  $7 \times 7$ 'lik boyutlardaki yamaların değerlerine göre daha başarılı olduğu gözlemlenmiştir.

#### 4.4. Tartışma

Bu tezde çoklu zamanlı zaman serisi verilerinin sınıflandırılması için iki farklı yaklaşım önerdik ve bunları mahsul sınıflandırmasına uyguladık. Önerdiğimiz ilk yaklaşımda, uzaktan algılama topluluğundaki en önemli sorunlardan biri olan etiketli veri azlığına odaklandık. Her ne kadar uydular sürekli veri algılasa da ne yazık ki etiket üretimi son derece zahmetli ve pahalı bir süreçtir. Bu yüzden bol miktarda erişebildiğimiz etiketsiz verilerden azami derecede yararlanılması önemlidir. Bu amaç doğrultusunda, etiketsiz çoklu-zamanlı verileri mahsul sınıflandırma bağlamında kıymetlendirmek adına, yarı gözetimli bir yaklaşım önerdik. Önce uzun kısa-vadeli bellek oto kodlayıcısını etiketsiz veriler ile bu verilerin sıkıştırılmış halini öğrenmesi için eğittik. Ardından da öğrenilen ağırlıklar ile kodlayıcı uzun kısa-vadeli bir sınıflandırıcıyı ilklendirip, etiketli veriler ile eğittik.

Deney sonuçları, Yarı Gözetimli uzun kısa vadeli bellek oto kodlayıcıların (Yarı-gözetimli) aynı kodlayıcı UKVB mimarisine sahip sadece gözetimli (Gözetimli) olarak eğitilmiş modelden daha başarılı olduğunu göstermektedir. Bunun sebebi önerdiğimiz Yarı gözetimli (UVKB) yaklaşımın sınıflandırma için rastgele ağırlıklar yerine etiketsiz verilerden öğrenilen ağırlıklara sahip olmasından kaynaklanmaktadır. Buradaki nihai amaç etiketsiz verilerin başarımının gözlenmesidir. En düşük başarımı Rastgele orman'nın elde ettiği görülmüştür. Bunun sebebi muhtemelen sığ bir yaklaşım olup zamansal bilgiyi kullanmamasından kaynaklıdır.

Son teknoloji yaklaşımlarına bakıldığında, ESA tabanlı yaklaşımlar ise klasik makine öğrenimi tekniklerine göre derin özellikleriyle üstünlüğünü ortaya koyan, Rastgele orman'dan yüksek oranda daha iyi performans göstermiştir. MSResNet ve dikkat mekanizmasını kullanan Transformer modeli, literatürdeki tekrarlayan modellerden biraz daha iyi performans göstermiştir. Veriler çoklu zamanlı olduğundan, yineleme ve dikkat tabanlı modeller, verilerdeki zamansal bilgileri çıkararak ve kullanarak ESA tabanlı modellere göre daha üstün bir performans göstermektedir. Fakat tekrarlayan bir model olmayıp MSResNet'in en yüksek başarı oranına sahip olması dikkat çekmektedir. Son olarak UVKB yerine farklı bir tekrarlayan ağ modeli

Kapılı tekrarlayan hücre (GRU) ile başarımların sonuçları gözlemlendiğinde, Yarı gözetimli (GRU) modeli Gözetimli (GRU)'ya göre daha yüksek bir başarı elde etmiştir. Bu durum etiketsiz verilerin başarımlarını desteklemektedir. Çünkü Yarı gözetimli (GRU) da etiketsiz verilerden öğrenilen ağırlıklar vardır. Lakin Yarı gözetimli uzun kısa vadeli bellek oto kodlayıcıların gerisinde kalmaktadır. Bunun sebebi ise veri kümelerimizin büyüklüğünden kaynaklı olabilir. Performans sürelerine bakıldığında hem eğitim süreleri açısından iki veri kümesinde de sürelerin birbirlerine nispeten yakın olduğu, yalnızca önerdiğimiz Yarı Gözetimli yaklaşımın 1. aşamasındaki etiketsiz veri eğitim süresinden kaynaklı daha uzun sürdüğü görülmektedir. Performans açısından uzun süresinde sonuçlar, bu çalışmadaki amacımız olan etiketsiz verilerin kullanımının, etiketli verilerin sınıflandırılmasında bir iyileşme sağladığı göstermektedir ve etiketsiz verilerin uzaktan algılama alanında kullanıma potansiyelini vurgulamaktadır. Yine de bazı sorular bulunmaktadır. Etiketsiz verilerden öğrenim nasıl artırılabilir, sınıflandırma başarımlarını daha fazla nasıl artırılabilir vb.

Önerdiğimiz ikinci yaklaşımda, Morfolojik sinir ağların ve UVKB'lerin birleştirilmesiyle MSA-UVKB modelini önerdik. Bu çalışma morfolojik ve uzun-kısa süreli bellek ağlarının bir kombinasyonunun ilk uygulamasını gerçekleştirmiştir. Deneysel sonuçlarına göre Breizhcrops veri kümesi durumunda, tüm derin öğrenme tabanlı yaklaşımlar, beklendiği gibi Random Forest sınıflandırıcısını aşmaktadır. Daha ayrıntılı olarak, MSA-UVKB, ESA-UVKB'den daha iyi performans gösterirken, StarRNN ile aynı performansta ve Transformer'ın biraz gerisindedir. Breizhcrops, bir boyutlu bir zaman serisidir, bu nedenle sömürülecek hiçbir uzamsal bilgi yoktur. Sonuç olarak, şaşırtıcı olmayan bir şekilde, MSA-UVKB'nin alternatiflerine benzer şekilde performans gösterdiği ve performans farklılıklarının çoğunlukla Transformer'ın hepsinden daha iyi performans gösterdiği değişen zamansal bağımlılıktan yararlanma yeteneklerinden kaynaklandığı gözlemlenebilir.

Öte yandan, gerçek iki boyutlu çok zamanlı/spektral görüntü parçalarından oluşan Sakarya örneğinde, MSA-UVKB tüm muadillerinden daha iyi performans gösteriyor. Daha zorlu bir veri kümesi olduğu için genel performans seviyeleri Breizhcrops'dan daha düşüktür. Yine de zamansal yaklaşımlar (StarRNN, Transformer, LSTM) çoğunlukla benzer performans seviyelerindeyken, hem ESA-UVKB hem de MSA-UVKB bunları aşıyor, böylece iki boyutlu çok zamanlı/spektral verilerle uğraşırken zamansal bilginin potansiyelinin altını çizmektedir. [3]'deki yöntemlere baktığımızda

sonuların iki veri kumesinde de ok bařarılı olmadıęını sadece path2-UVKB modelinin literatürdeki yöntemleri yakaladıęı ya da yaklařtıęı görölmüřtür. [3]'deki Morfolojik yöntemlerin sonuna UVKB bloęu koyduęumuz model sonularının UVKB'siz sonulara göre daha bařarılı olduęu görölmüřtür. Bu durum zamansal iliřkileri yakalamada uzmanlařan tekrarlayan sinir aęlarının önemini göstermektedir. MSA-UVKB ise ESA-UVKB'den daha umut vaat ediyor gibi görünse de, cevaplanmamıř sorular var; Örneęin, erozyonları ve geniřlemeleri nasıl sıralamalıyız, ünkü girdideki ilgilenilen nesnelere çevrelerinde daha parlak veya daha karanlık olmasına baęlı olarak bir fark yaratacaktır. Bu nedenle, morfolojik operatörlerin kontrastla deęiřmeyen bir uygulaması ok deęerli olacaktır. Gelecekteki alıřmaların ok ilgin ama aynı derecede zorlayıcı yönü, bu baęlamda nesne tabanlı görüntü analiz yetenekleriyle donatılmıř güçlü öznitelik filtreleri ailesinin entegrasyonunu içerebilir.

## 5. VARGI

Bu tezde tarım faaliyetlerinin izlenmesi ve denetlenebilmesi için çeşitli uydulardan herhangi bir konuma ait farklı spektral bantlarda ve farklı zamanlarda elde edilen görüntülerin mahsul sınıflandırma konusu ele alınmıştır. Çoklu zamanlı uzaktan algılanmış mahsul görüntülerinin sınıflandırılması üzerine odaklanılmıştır. Bu tez kapsamında bu sorun için iki farklı yöntem önerilmiştir. İki yaklaşımda da tekrarlayan sinir ağları kullanılmıştır. Bunun nedeni, tekrarlayan sinir ağlarının zaman serilerinde saklı olan içsel karakterlerin tekrarlayan bağlantılar yardımıyla çıkarabilme yeteneklerindedir.

İlk yaklaşım, etiketsiz verileri mahsul sınıflandırma bağlamında kıymetlendirmek adına Uzun Kısa Vadeli Bellek Oto Kodlayıcıların yarı gözetimli uzaktan algılanmış çoklu zamanlı görüntülerde mahsul sınıflandırmasına uygulanmasıdır. Etiketsiz verilerin sınıflandırma başarısına katkısı incelenmiştir. Elde edilen sonuçlar iki farklı veri kümesinde de etiketliye ek olarak etiketsiz veri kullanımının, sadece etiketli veri ile sınıflandırmadan daha başarılı olduğunu göstermiştir. Önerilen yaklaşım etiketsiz verilerin uzaktan algılamada mahsul sınıflandırma alanında kullanılmasına katkı sağlayabileceğine dair güçlü bir işaret vermektedir. Gelecek çalışmalarda hem sınıflandırma başarımlarının artışı hem de farklı algılayıcılardan gelen verinin kıymetlendirilmesi üzerine çalışılması hedeflenmektedir.

İkinci yaklaşım, çok zamanlı/spektral görüntülerden mahsul sınıflandırması bağlamında morfolojik ve uzun-kısa süreli bellek ağlarının bir kombinasyonudur. Önerilen yöntem, ilkinin uzamsal özellik çıkarımından ve ikincisinin zamansal bağımlılıktan yararlanılmasından sorumlu olduğu, sıralı olarak bağlanan iki modülden oluşur. Modern yöntemlerle karşılaştırıldığında, gerçek görüntü yamaları ile uğraşırken rekabetçi performans sağladığını, bir boyutlu zaman serilerine karşı avantajının azaldığını göstermiştir.

Gelecekteki çalışmalar, morfolojik ağların potansiyelini daha iyi anlamaya, daha gelişmiş morfolojik filtrelerin entegrasyonuna ve morfolojik ağlar için en iyi mimari araştırmasına odaklanılabilir. Evrişimleri işlemlerini gerçekleştiren UVKB katmanları morfolojik operatörleri kullanacak şekilde ConvLstm [77] ağları morfolojik olarak gerçekleştirilebilir. Morfolojik oto kodlayıcılar mimarisi üzerine

alıřılabilir. Mahsul byme mevsimi boyunca ekinlerin zamansal varyasyonlarını keřfetmek ve mahsul verimini tahmin etmek iin iklim katsayısı, nem ve gemiř veri setleri gibi grnt parametreleri arařtırılabilir. Tarım faaliyetlerinin izlenmesi ve denetlenmesi iin farklı algılayıcılardan gelen verilerin kıymetlendirilmesi zerine alıřılması hedeflenebilir. Bylece dnya apında tarımın refahına nemli bir katkıda bulunabiliriz.



## KAYNAKLAR

- [1] Zhou Y., Luo J., Feng L., Yang Y., Chen Y., Wu W., (2019), “Long-short-term-memory-based crop classification using high-resolution optical images and multi-temporal SAR data”, *GIScience Remote Sensing*, 56(8), 1170–1191.
- [2] Pelletier C., Webb G. I., Petitjean F., (2019), “Deep learning for the classification of Sentinel-2 image time series”, In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 461–464). Yokohama, Japan, 28 July-2 Aug.
- [3] Mondal R., Purkait P., Santra S., Chanda B., (2019), “Morphological networks for image de-raining”, In *International Conference on Discrete Geometry for Computer Imagery* (pp. 262–275). Paris, France, 25-29 March.
- [4] Loveland T. R., Reed B. C., Brown J. F., Ohlen D. O., Zhu Z., Yang L., Merchant J. W., (2000), “Development of a global land cover characteristics database and IGBP DISCover from 1 km AVHRR data”, *International journal of remote sensing*, 21(6–7), 1303–1330.
- [5] Kussul N., Lavreniuk M., Skakun S., Shelestov A., (2017), “Deep learning classification of land cover and crop types using remote sensing data”, *IEEE Geoscience and Remote Sensing Letters*, 14(5), 778–782.
- [6] Kizilirmak F., Aptoula E., (2021), “Crop Classification from Multi-Temporal and Multi-spectral Remote Sensing Images”, In *2021 29th Signal Processing and Communications Applications Conference (SIU)* (pp. 1–4). Istanbul, Turkey, 9-11 Jun.
- [7] Demirpolat C., Teke M., (2017), “Crop classification with morphological profiles derived from SAR and electro-optical satellite data”, In *2017 8th International Conference on Recent Advances in Space Technologies (RAST)* (pp. 119–124). Istanbul, Turkey, 19-22 Jun.
- [8] 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.
- [9] Zhang Z., Tang P., Corpetti T., (2016), “Satellite image time series clustering via affinity propagation”, In *2016 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)* (pp. 2419–2422). Beijing, China, 10-15 July.
- [10] Gebhardt S., Wehrmann T., Ruiz M. A. M., Maeda P., Bishop J., Schramm M., ... others, (2014), “MAD-MEX: Automatic wall-to-wall land cover monitoring for the Mexican REDD-MRV program using all Landsat data”, *Remote Sensing*, 6(5), 3923–3943.
- [11] Pelletier C., Valero S., Inglada J., Champion N., Dedieu G., (2016), “Assessing the robustness of Random Forests to map land cover with high resolution satellite image time series over large areas”, *Remote Sensing of Environment*, 187, 156–168.

- [12] Inglada J., Vincent A., Arias M., Tardy B., Morin D., Rodes I., (2017), “Operational high resolution land cover map production at the country scale using satellite image time series”, *Remote Sensing*, 9(1), 95.
- [13] Solano-Correa Y. T., Bovolo F., Bruzzone L., (2019), “A semi-supervised crop-type classification based on sentinel-2 NDVI satellite image time series and phenological parameters”, In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 457–460). Yokohama, Japan, 28 July-2 Aug.
- [14] Gómez L., Calpe J., Martn J. D., Soria E., Camps-Valls E., Moreno J., (2002), “Semi-supervised method for crop classification using hyperspectral remote sensing images”, In *1st International Symposium. Recent Advantages in Quantitative Remote Sensing, RAQRS* (pp. 488–495).
- [15] Gómez-Chova L., Calpe J., Camps-Valls G., Martin J. D., Soria E., Vila J., ... Moreno J., (2003), “Semi-supervised classification method for hyperspectral remote sensing images.”, In *International Geoscience and Remote Sensing Symposium* (Vol. 3, pp. III–1776). Toulouse, France, 21-25 July.
- [16] Wang S., Azzari G., Lobell D. B., (2019), “Crop type mapping without field-level labels: Random forest transfer and unsupervised clustering techniques”, *Remote sensing of environment*, 222, 303–317.
- [17] Gómez C., White J. C., Wulder M. A., (2016), “Optical remotely sensed time series data for land cover classification: A review”, *ISPRS Journal of Photogrammetry and Remote Sensing*, 116, 55–72.
- [18] Tuna C., Mirmahboub B., Merciol F., Lefèvre S., (2020), “Component trees for image sequences and streams”, *Pattern Recognition Letters*, 129, 255–262.
- [19] Dalla Mura M., Benediktsson J. A., Waske B., Bruzzone L., (2010), “Morphological attribute profiles for the analysis of very high resolution images”, *IEEE Transactions on Geoscience and Remote Sensing*, 48(10), 3747–3762.
- [20] Mondal R., Santra S., Chanda B., (2018), “Dense morphological network: An universal function approximator”.
- [21] Ji S., Zhang C., Xu A., Shi Y., Duan Y., (2018), “3D convolutional neural networks for crop classification with multi-temporal remote sensing images”, *Remote Sensing*, 10(1), 75.
- [22] Roy S. K., Mondal R., Paoletti M. E., Haut J. M., Plaza A., (2021), “Morphological convolutional neural networks for hyperspectral image classification”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 8689–8702.
- [23] Kumar V., Singh R. S., Dua Y., (2022), “Morphologically dilated convolutional neural network for hyperspectral image classification”, *Signal Processing: Image Communication*, 101, 116549.

- [24] Joshi A. J., Porikli F., Papanikolopoulos N., (2009), “Multi-class active learning for image classification”, In 2009 IEEE Conference on Computer Vision and Pattern Recognition (pp. 2372–2379). Miami, FL, USA, 20-25 Jun.
- [25] Li J., (2015), “Active learning for hyperspectral image classification with a stacked autoencoders based neural network”, In 2015 7th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS) (pp. 1–4). Tokyo, Japan, 2-5 Jun.
- [26] Liu P., Zhang H., Eom K. B., (2016), “Active deep learning for classification of hyperspectral images”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(2), 712–724.
- [27] Cao X., Yao J., Xu Z., Meng D., (2020), “Hyperspectral image classification with convolutional neural network and active learning”, *IEEE Transactions on Geoscience and Remote Sensing*, 58(7), 4604–4616.
- [28] Fuller D. O., (1998), “Trends in NDVI time series and their relation to rangeland and crop production in Senegal, 1987-1993”, *International Journal of Remote Sensing*, 19(10), 2013–2018.
- [29] Dizdaroğlu T., (2019), “Sentinel-1 ve Sentinel-2 Verilerinden Tarımsal Ürün Sınıflandırması İçin Makine Öğrenme Algoritmalarının Karşılaştırılması”, Yüksek Lisans Tezi, Hacettepe Üniversitesi.
- [30] Das M., Ghosh S. K., (2016), “Deep-STEP: A deep learning approach for spatiotemporal prediction of remote sensing data”, *IEEE Geoscience and Remote Sensing Letters*, 13(12), 1984–1988.
- [31] Zhong L., Hu L., Zhou H., (2019), “Deep learning based multi-temporal crop classification”, *Remote sensing of environment*, 221, 430–443.
- [32] Lyu H., Lu H., Mou L., Li W., Wright J., Li X., ... others, (2018), “Long-term annual mapping of four cities on different continents by applying a deep information learning method to landsat data”, *Remote Sensing*, 10(3), 471.
- [33] Sun Y., Luo J., Wu T., Yang Y., Liu H., Dong W., ... Hu X., (2019), “Geo-parcel based Crops Classification with Sentinel-1 Time Series Data via Recurrent Neural Network”, In 2019 8th International Conference on Agro-Geoinformatics (Agro-Geoinformatics) (pp. 1–5). Istanbul, Turkey, 16-19 July.
- [34] Hochreiter S., Schmidhuber J., (1997), “Long short-term memory”, *Neural computation*, 9(8), 1735–1780.
- [35] Zhao H., Chen Z., Jiang H., Jing W., Sun L., Feng M., (2019), “Evaluation of three deep learning models for early crop classification using Sentinel-1A imagery time series—A case study in Zhanjiang, China”, *Remote Sensing*, 11(22), 2673.
- [36] Sun Z., Di L., Fang H., (2019), “Using long short-term memory recurrent neural network in land cover classification on Landsat and Cropland data layer time series”, *International journal of remote sensing*, 40(2), 593–614.

- [37] Bozo M., Aptoula E., Çataltepe Z., (2020), “A discriminative long short term memory network with metric learning applied to multispectral time series classification”, *Journal of Imaging*, 6(7), 68.
- [38] Schuster M., Paliwal K. K., (1997), “Bidirectional recurrent neural networks”, *IEEE Transactions on Signal Processing*, 45(11), 2673–2681.
- [39] Wang H., Zhao X., Zhang X., Wu D., Du X., (2019), “Long time series land cover classification in China from 1982 to 2015 based on Bi-LSTM deep learning”, *Remote Sensing*, 11(14), 1639.
- [40] Rußwurm M., Korner M., (2017), “Temporal vegetation modelling using long short-term memory networks for crop identification from medium-resolution multi-spectral satellite images”, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops* (pp. 11–19). Honolulu, HI, USA, 21-26 July.
- [41] Garnot V. S. F., Landrieu L., Giordano S., Chehata N., (2019), “Time-space tradeoff in deep learning models for crop classification on satellite multi-spectral image time series”, In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 6247–6250). Yokohama, Japan, 28 July - 2 August.
- [42] Pelletier C., Webb G. I., Petitjean F., (2019), “Temporal convolutional neural network for the classification of satellite image time series”, *Remote Sensing*, 11(5), 523.
- [43] Vaswani A., Shazeer N., Parmar N., Uszkoreit J., Jones L., Gomez A. N., ... Polosukhin I., (2017), “Attention is all you need”, *Advances in neural information processing systems*, 30.
- [44] Rußwurm M., Pelletier C., Zollner M., Lefèvre S., Körner M., (2019), “Breizhcrops: A time series dataset for crop type mapping”, *arXiv preprint arXiv:1905.11893*.
- [45] Rußwurm M., Lefèvre, S., Körner M., (2019), “Breizhcrops: A satellite time series dataset for crop type identification”, In *Proceedings of the International Conference on Machine Learning Time Series Workshop* (Vol. 3). Long Beach, CA, USA, 10-15 Jun.
- [46] Ismail Fawaz H., Lucas B., Forestier G., Pelletier C., Schmidt D. F., Weber J., ... Petitjean F., (2020), “Inceptiontime: Finding alexnet for time series classification”, *Data Mining and Knowledge Discovery*, 34(6), 1936–1962.
- [47] Tang W., Long G., Liu L., Zhou T., Jiang J., Blumenstein M., (2020), “Rethinking 1d-CNN for time series classification: A stronger baseline”, *arXiv preprint arXiv:2002.10061*.
- [48] Ma L., Liu Y., Zhang X., Ye Y., Yin G., Johnson B. A., (2019), “Deep learning in remote sensing applications: A meta-analysis and review”, *ISPRS journal of photogrammetry and remote sensing*, 152, 166–177.

- [49] Lavreniuk M., Kussul N., Novikov A., (2018), “Deep learning crop classification approach based on coding input satellite data into the unified hyperspace”, In 2018 IEEE 38th International Conference on Electronics and Nanotechnology (ELNANO) (pp. 239–244). Kyiv, Ukraine, 24-26 April.
- [50] Li J., Shen Y., Yang C., (2021), “An adversarial generative network for crop classification from remote sensing timeseries images”, *Remote Sensing*, 13(1), 65.
- [51] Sharma R. C., Tateishi R., Hara K., Iizuka K., (2016), “Production of the Japan 30-m land cover map of 2013–2015 using a Random Forests-based feature optimization approach”, *Remote Sensing*, 8(5), 429.
- [52] Rodriguez-Galiano V. F., Ghimire B., Rogan J., Chica-Olmo M., Rigol-Sanchez J. P., (2012), “An assessment of the effectiveness of a random forest classifier for land-cover classification”, *ISPRS journal of photogrammetry and remote sensing*, 67, 93–104.
- [53] Eisavi V., Homayouni S., Yazdi A. M., Alimohammadi A., (2015), “Land cover mapping based on random forest classification of multitemporal spectral and thermal images”, *Environmental monitoring and assessment*, 187(5), 1–14.
- [54] Ienco D., Gaetano R., Dupaquier C., Maurel P., (2017), “Land cover classification via multitemporal spatial data by deep recurrent neural networks”, *IEEE Geoscience and Remote Sensing Letters*, 14(10), 1685–1689.
- [55] Avolio C., Tricomi A., Mammone C., Zavagli M., Costantini M., (2019), “A deep learning architecture for heterogeneous and irregularly sampled remote sensing time series”, In *IGARSS 2019-2019 IEEE International Geoscience and Remote Sensing Symposium* (pp. 9807–9810). Yokohama, Japan, 28 July - 2 August.
- [56] Srivastava N., Mansimov E., Salakhudinov R., (2015), “Unsupervised learning of video representations using lstms”, In *International conference on machine learning* (pp. 843–852). Lille, France, 6-11 July.
- [57] Zhang X., Chen G., Wang W., Wang Q., Dai F., (2017), “Object-based land-cover supervised classification for very-high-resolution UAV images using stacked denoising autoencoders”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(7), 3373–3385.
- [58] Özdemir A. O. B., Gedik B. E., Çetin C. Y. Y., (2014), “Hyperspectral classification using stacked autoencoders with deep learning”, In *2014 6th Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS)* (pp. 1–4). Lausanne, Switzerland, 24-27 Jun.
- [59] Principi E., Rossetti D., Squartini S., Piazza F., (2019), “Unsupervised electric motor fault detection by using deep autoencoders”, *IEEE/CAA Journal of Automatica Sinica*, 6(2), 441–451.
- [60] Nguyen H. D., Tran K. P., Thomassey S., Hamad M., (2021), “Forecasting and Anomaly Detection approaches using LSTM and LSTM Autoencoder

techniques with the applications in supply chain management”, *International Journal of Information Management*, 57, 102282.

- [61] Provotar O. I., Linder Y. M., Veres M. M., (2019), “Unsupervised anomaly detection in time series using LSTM-based Autoencoders”, In 2019 IEEE International Conference on Advanced Trends in Information Theory (ATIT) (pp. 513–517). Kyiv, Ukraine, 18-20 Dec.
- [62] Zhao H., Duan S., Liu J., Sun L., Reymondin L., (2021), “Evaluation of Five Deep Learning Models for Crop Type Mapping Using Sentinel-2 Time Series Images with Missing Information”, *Remote Sensing*, 13(14), 2790.
- [63] Li Z., Chen G., Zhang T., (2020), “A CNN-transformer hybrid approach for crop classification using multitemporal multisensor images”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 847–858.
- [64] Donahue J., Anne Hendricks L., Guadarrama S., Rohrbach M., Venugopalan S., Saenko K., Darrell T., (2015), “Long-term recurrent convolutional networks for visual recognition and description”, In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2625–2634). Boston, MA, 7-15 Jun.
- [65] Vinyals O., Toshev A., Bengio S., Erhan D., (2015), “Show and tell: A neural image caption generator”, In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 3156–3164). Boston, MA, 7-12 Jun.
- [66] Sainath T. N., Vinyals O., Senior A., Sak H., (2015), “Convolutional, long short-term memory, fully connected deep neural networks”, In 2015 IEEE international conference on acoustics, speech and signal processing (ICASSP) (pp. 4580–4584). South Brisbane, QLD, Australia, 19-24 April.
- [67] Shi X., Chen Z., Wang H., Yeung D.-Y., Wong W.-K., Woo W., (2015), “Convolutional LSTM network: A machine learning approach for precipitation nowcasting”, *Advances in neural information processing systems*, 28.
- [68] Perret B., Cousty J., Ura J. C. R., Guimarães S. J. F., (2015), “Evaluation of morphological hierarchies for supervised segmentation”, In *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing* (pp. 39–50). Reykjavik, Iceland, 27-29 May.
- [69] Wdowiak M., Markiewicz T., Osowski S., Swiderska Z., Patera J., Kozłowski W., (2015), “Hourglass shapes in rank grey-level hit-or-miss transform for membrane segmentation in HER2/neu images”, In *International Symposium on Mathematical Morphology and Its Applications to Signal and Image Processing* (pp. 3–14). Reykjavik, Iceland, 27-29 May.
- [70] Davidson J. L., Hummer F., (1993), “Morphology neural networks: An introduction with applications”, *Circuits, Systems and Signal Processing*, 12(2), 177–210.

- [71] Nogueira K., Chanussot J., Dalla Mura M., dos Santos J. A., (2021), “An introduction to deep morphological networks”, *IEEE Access*, 9, 114308–114324.
- [72] Ritter G. X., Sussner P., (1996), “An introduction to morphological neural networks”, In *Proceedings of 13th International Conference on Pattern Recognition (Vol. 4, pp. 709–717)*. Vienna, Austria, 25-29 Aug.
- [73] LeCun Y., Bengio Y., others, (1995), “Convolutional networks for images, speech, and time series”, *The handbook of brain theory and neural networks*, 3361(10), 1995.
- [74] Aptoula E., Kahraman F., Ozbulak G., Aydemir S., Imamoglu M., Yilmaz I., others, (2020), “Segmentation networks reinforced with attribute profiles for large scale land-cover map production”, In *2020 28th Signal Processing and Communications Applications Conference (SIU)* (pp. 1–4). Gaziantep, Turkey, 5-7 Oct.
- [75] Breiman L., (2001), “Random forests”, *Machine learning*, 45(1), 5–32.
- [76] Teloğlu H. K., Aptoula E., (2021), “LSTM AutoEncoders Applied to Semi-Supervised Crop Classification”, In *2021 29th Signal Processing and Communications Applications Conference (SIU)* (pp. 1–4). Istanbul, Turkey, 9-11 Jun.
- [77] de Macedo M. M. G., Mattos A. B., Oliveira D. A. B., (2020), “Generalization of convolutional LSTM models for crop area estimation”, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 1134–1142.

## ÖZGEÇMİŞ

Hatice Kübra TELOĞLU orta öğretimini İstanbul Fen Lisesinde tamamladı. 2018 yılında Gebze Teknik Üniversitesi Bilgisayar Mühendisliği bölümünden mezun olup, yine aynı üniversitede 2018 yılında yüksek lisansa başladı. Şu anda Türk Hava Yolları Teknoloji şirketinde yazılımcı olarak görevine devam etmektedir.



## EKLER

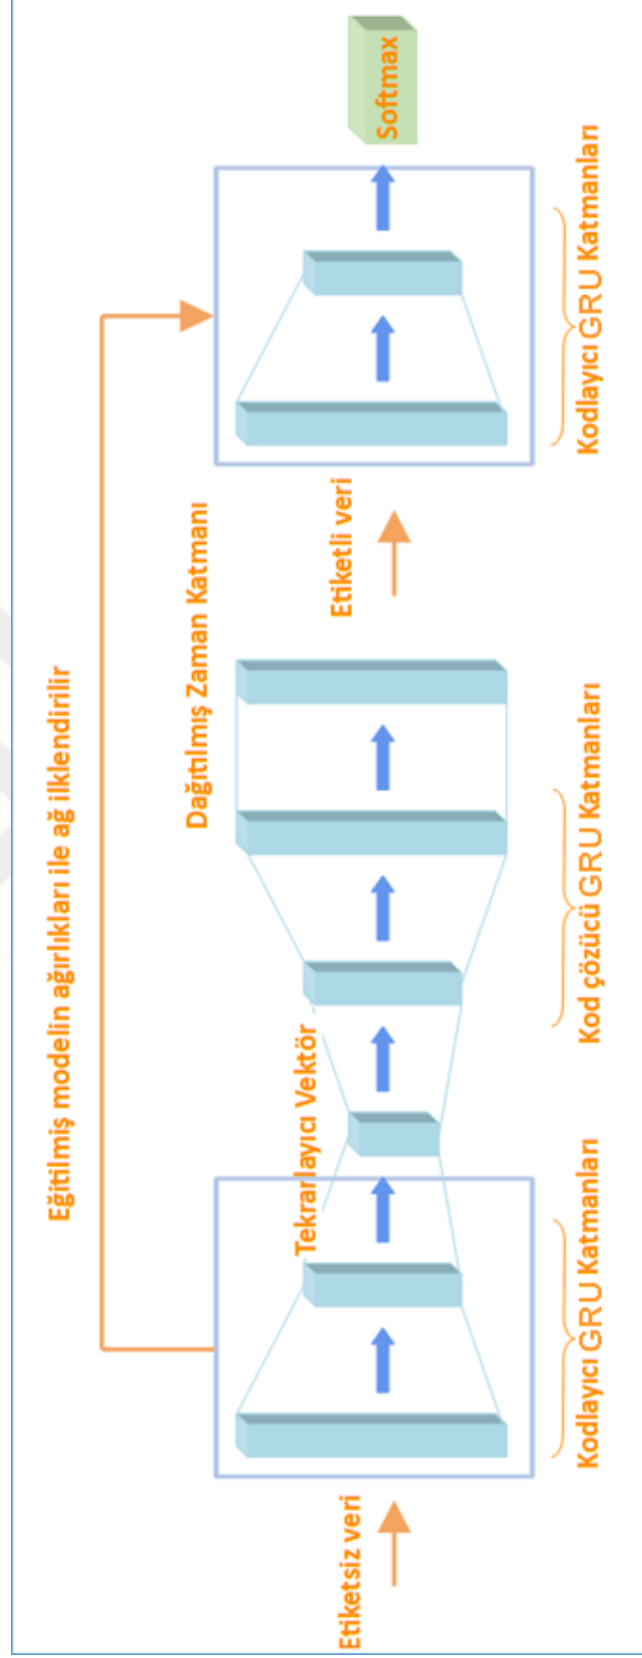
### Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Telođlu H. K., Aptoula E., (2021), "LSTM AutoEncoders Applied to Semi-Supervised Crop Classification", In 2021 29th Signal Processing and Communications Applications Conference (SIU) (pp. 1–4). Istanbul, Turkey, 9-11 Jun.

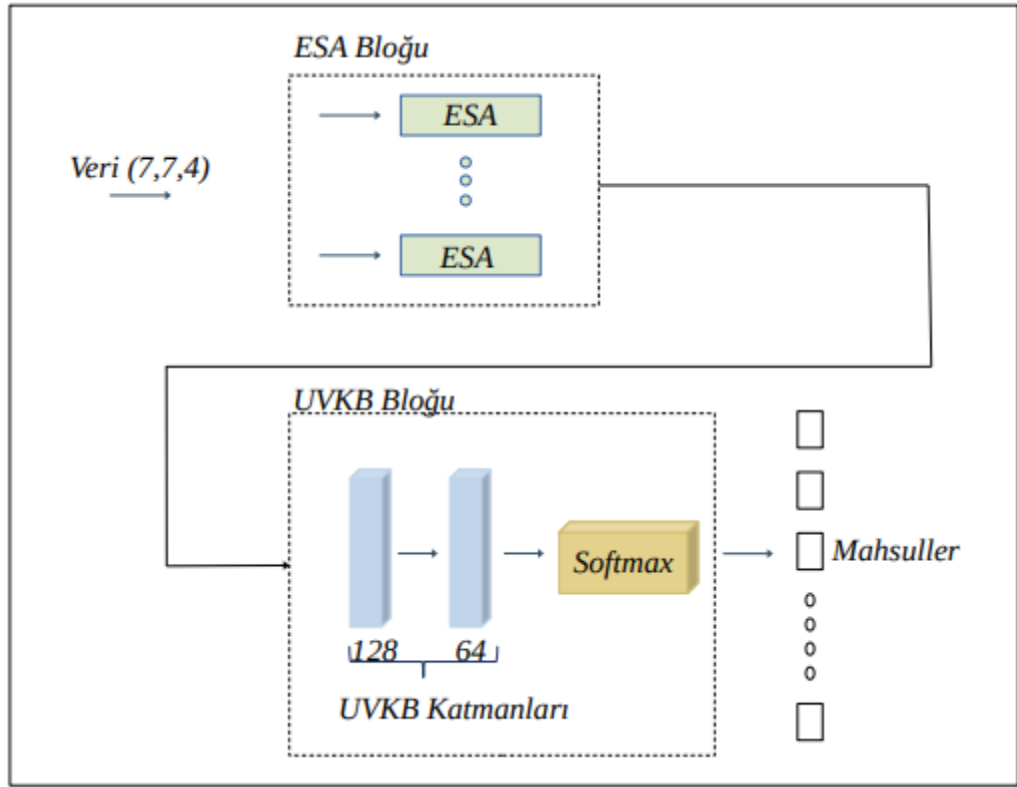
Telođlu H. K., Aptoula, E. "A MORPHOLOGICAL-LONG SHORT TERM MEMORY NETWORK APPLIED TO CROP CLASSIFICATION" In IGARSS 2022. 2022 IEEE International Geoscience and Remote Sensing Symposium. Kuala Lumpur, Malaysia, 17 - 22 July. **(Hazırlık aşamasında)**

### Ek B: Açıklamalar


Yapılan bu çalışma TÜBİTAK tarafından desteklenmiştir (Proje numarası: 118E258).



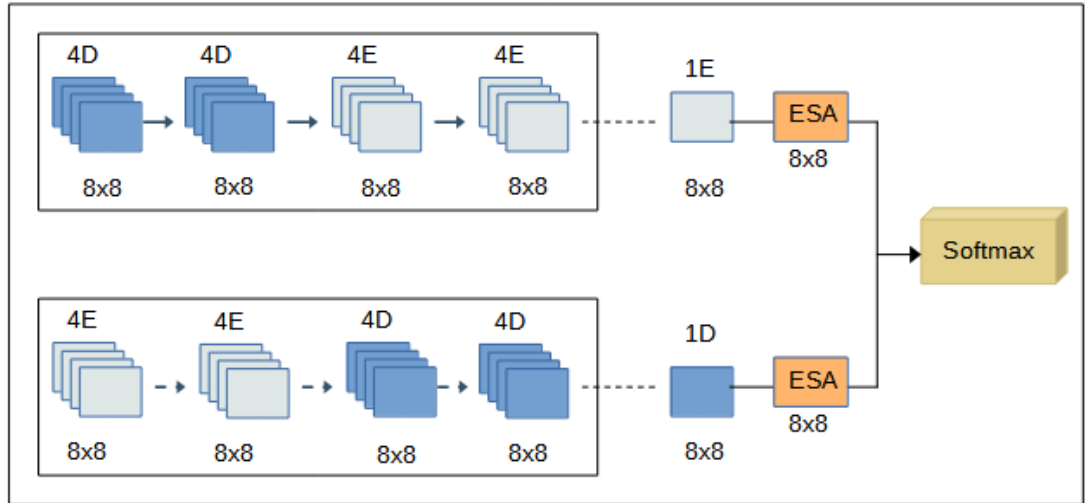
Şekil B.1.1: Yarı Gözetimli Yaklaşım (GRU ile).



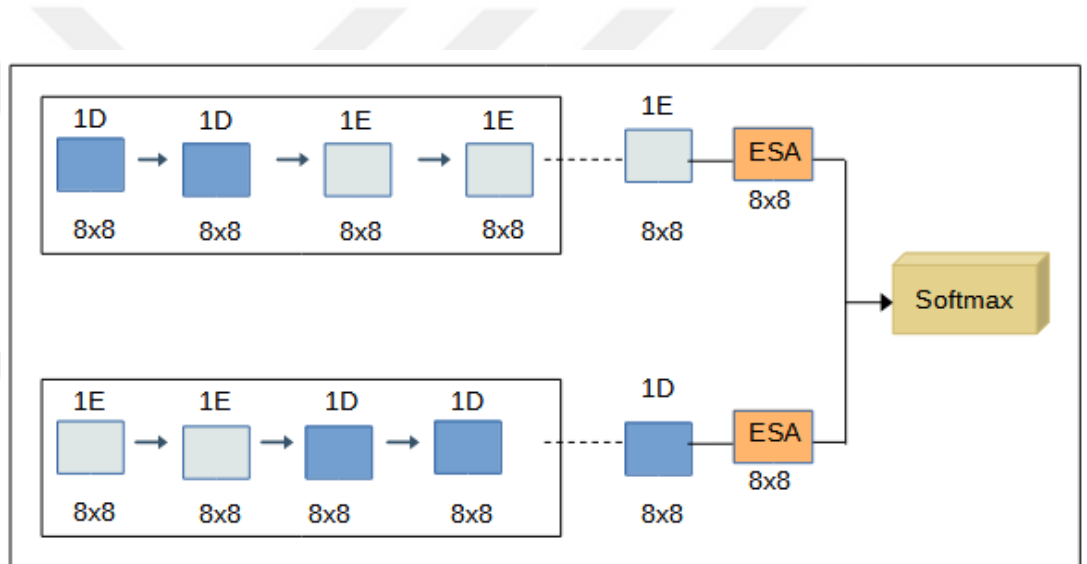
Şekil B.1.2: ESA-UVKB.




Şekil B.1.3: ESA içeriği.




Şekil B.1.4: morphoN.



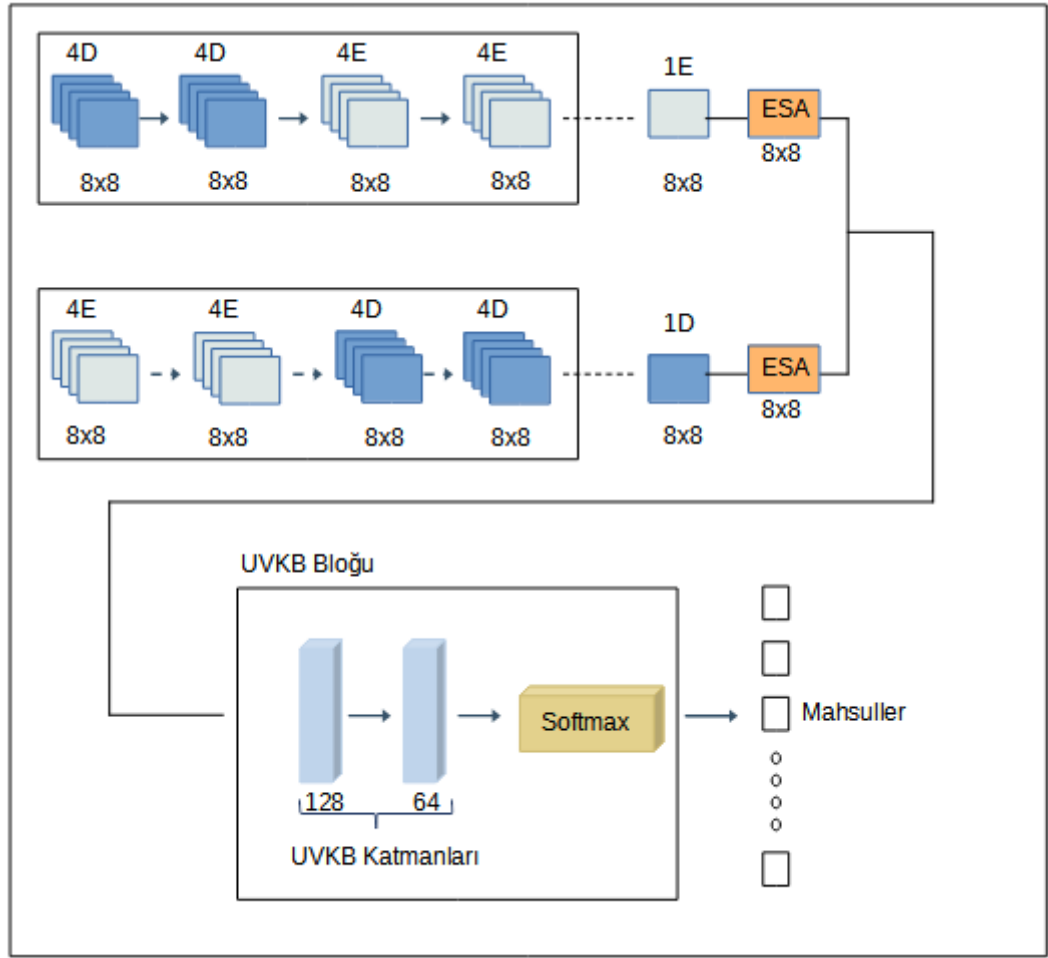
Şekil B.1.5: morphoN(small).



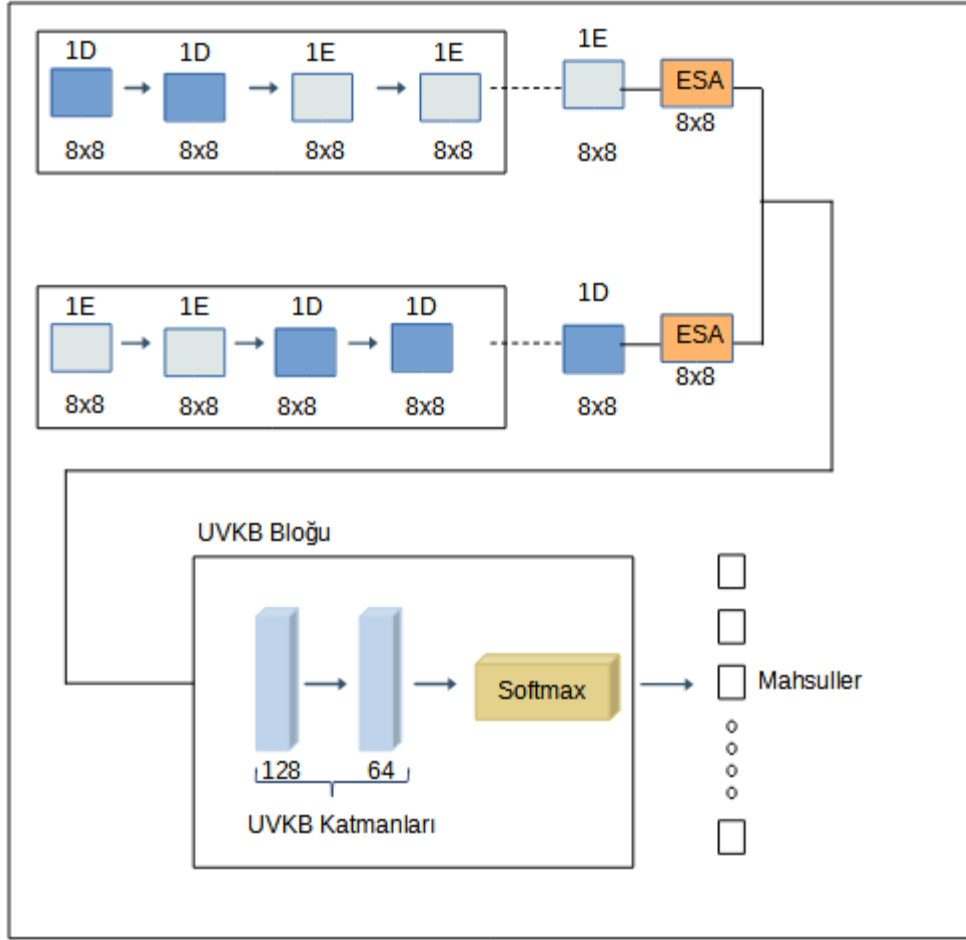
Şekil B.1.6: morphoN-path1.



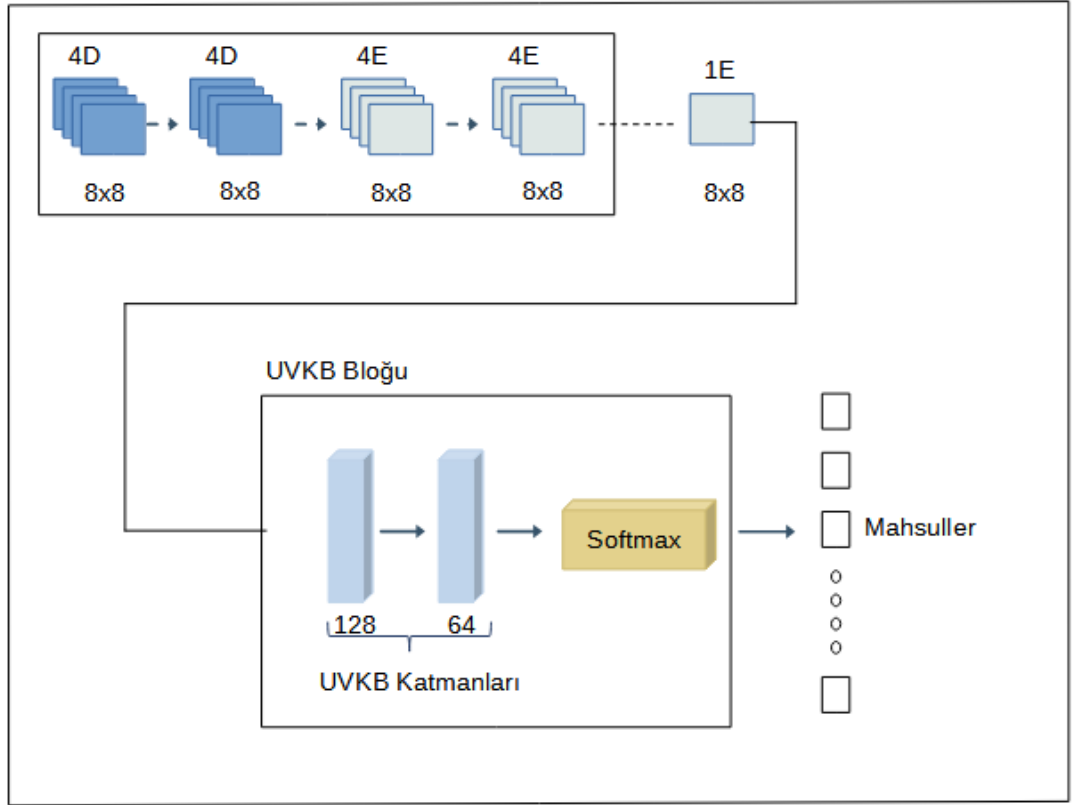
Şekil B.1.7: morphoN-path2.



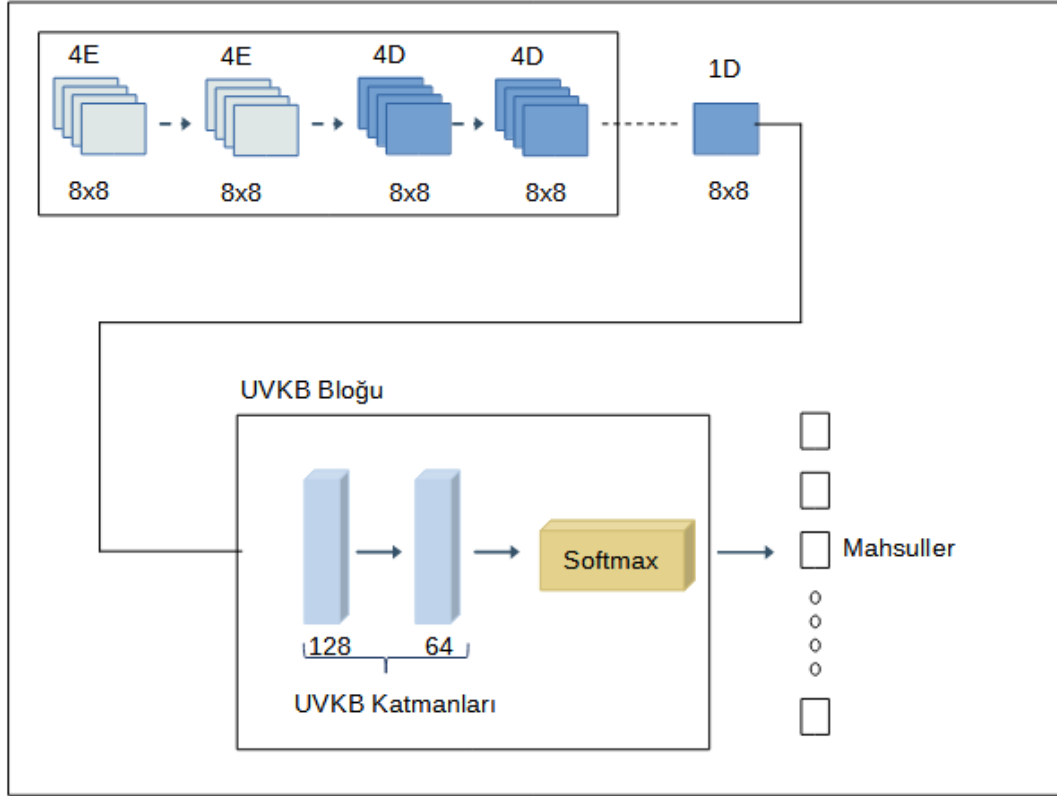
Şekil B.1.8: morphoN-UVKB.



Şekil B.1.9: morphoN(small)-UVKB.



Şekil B.1.10: morphoN-path1-UVKB.



Şekil B.1.11: morphoN-path2-UVKB.