

**T.C.  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMADA DERİN ÖĞRENME TABANLI HİPERSPEKTRAL  
UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

**DOKTORA TEZİ**

**Hüseyin FIRAT**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Davut HANBAY**

**TEMMUZ 2022**

**T.C  
İNÖNÜ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**UZAKTAN ALGILAMADA DERİN ÖĞRENME TABANLI HİPERSPEKTRAL  
UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**


**DOKTORA TEZİ**

**Hüseyin FIRAT  
(36183619022)**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Prof. Dr. Davut HANBAY**

**TEMMUZ 2022**



## TEŐEKKÜR VE ÖNSÖZ

Bu tez alıőmasının her aőamasında yardım, öneri, bilgi, tecrübe ve desteklerini esirgemedenden beni her konuda yönlendiren danışman hocam Sayın Prof. Dr. Davut HANBAY'a,

Tez alıőması sürecinde deęerli görüşleriyle tezime katkı sağlayan deęerli hocalarım Prof. Dr. Ali KARCI ve Dr. Öğr. Üyesi Ali ARI hocalarım,

Görev yaptığım üniversitede bulunduđum birimdeki iş yoğunluđuna rağmen doktora alıőması sürecinde bana manevi her türlü desteęi veren tüm akademisyen arkadaşlarıma,

Ayrıca tüm hayatım boyunca olduđu gibi bu alıőmalarım süresince benden her türlü desteklerini esirgemeyen aileme

teőekkür ederim.



## ONUR SÖZÜ

Doktora tezi olarak sunduđum ‘‘Uzaktan Algılamada Derin Öğrenme Tabanlı Hiperspektral Uydu Görüntülerinin Sınıflandırılması’’ başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Hüseyin FIRAT



## İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ .....	i
ONUR SÖZÜ .....	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vii
SEMBOLLER VE KISALTMALAR .....	x
ÖZET .....	xi
ABSTRACT .....	xii
<b>1. GİRİŞ .....</b>	<b>1</b>
1.1 Literatür İncelemesi .....	5
1.2 Tezin Amacı.....	15
1.3 Tezin Gerekçeleri.....	15
1.4 Tezin Çıktıları .....	15
1.5 Tezin Yenilikçi Yönü ve Ar-Ge Niteliği .....	17
1.6 Tezin Organizasyonu .....	17
<b>2. HİPERSPEKTRAL UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI İÇİN KULLANILAN YÖNTEMLER .....</b>	<b>19</b>
2.1 Boyut İndirgeme .....	19
2.1.1 Temel Bileşen Analizi.....	19
2.2 3B / 2B Evrişimsel Sinir Ağı .....	20
2.3 3B ESA Kullanılan Evrişimsel Sinir Ağı Mimarileri .....	26
2.3.1 LeNet5.....	27
2.3.2 AlexNet .....	28
2.3.3 GoogleNet .....	28
2.3.4 3B / 2B Inception modülü.....	30
2.3.5 VGG16.....	35
2.3.6 Residual network (ResNet18-ResNet50) .....	36
2.4 3B/2B Derinlemesine Ayrılabilir Evrişim .....	39
<b>3. LİTERATÜRDE KULLANILAN VERİ SETLERİ.....</b>	<b>44</b>
3.1 Indian Pines Veri Seti .....	44
3.2 Pavia Üniversitesi Veri Seti .....	45
3.3 Salinas Veri Seti .....	46
3.4 Kennedy Uzay Merkezi Veri Seti .....	47
3.5 Botswana Veri Seti .....	49
3.6 HyRANK-Loukia Veri Seti .....	50
3.7 Houston 2013 Veri Seti .....	51
3.8 WHU-Hi Veri Seti .....	52
3.8.1 WHU-Hi-LongKou Veri Seti.....	52
3.8.2 WHU-Hi-HanChuan Veri Seti .....	53
3.8.3 WHU-Hi-HongHu Veri Seti .....	55
<b>4. ÖNERİLEN YÖNTEMLER VE UYGULAMALAR.....</b>	<b>57</b>
4.1 Önerilen Yöntemlerin Genel Çerçevesi .....	57
4.2 Kullanılan Performans Ölçütleri .....	58
4.3 Uygulama 1: Hiperspektral Görüntü Sınıflandırması için Hibrit 3B Evrişim ve 2B Derinlemesine Ayrılabilir Evrişim Sinir Ağı.....	59
4.3.1 Önerilen yöntem.....	59
4.3.2 Sınıflandırma sonuçları .....	63
4.4 Uygulama 2: 4CF-Net: Hiperspektral Uzaktan Algılama Görüntülerinin Spektral Uzamsal Sınıflandırılması için Yeni 3 Boyutlu Evrişimsel Sinir Ağı.....	69

4.4.1 Önerilen yöntem.....	69
4.4.2 Sınıflandırma sonuçları .....	70
4.5 Uygulama 3: 3 Boyutlu Evrişimsel Sinir Ağı Tabanlı LeNet5 Mimarisi Kullanılarak Hiperspektral Uzaktan Algılama Görüntülerinin Uzamsal-Spektral Sınıflandırılması	76
4.5.1 Önerilen yöntem.....	76
4.5.2 Sınıflandırma sonuçları .....	78
4.6 Uygulama 4: Hiperspektral Uzaktan Algılama Görüntü Sınıflandırması için 3 Boyutlu Residual Uzamsal-Spektral Evrişim Ağı .....	86
4.6.1 Önerilen yöntem.....	86
4.6.2 Sınıflandırma sonuçları .....	89
4.7 Uygulama 5: Hiperspektral Uzaktan Algılama Görüntü Sınıflandırması için Hibrit 3B/2B Complete Inception Modülü ve Evrişimsel Sinir Ağı .....	98
4.7.1 Önerilen yöntem.....	98
4.7.2 Sınıflandırma sonuçları .....	102
4.8 Uygulama 6: Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması .....	118
4.8.1 Önerilen yöntem.....	118
4.8.2 Sınıflandırma sonuçları .....	118
4.9. Uygulama 7: Hibrit 3B-2B Derinlemesine Ayrılabilir Evrişim Ağlarına Dayalı Hiperspektral Uzaktan Algılama Görüntü Sınıflandırması için Çok Yollu Özellik Füzyonu .....	125
4.9.1 Önerilen yöntem.....	125
4.9.2 Sınıflandırma sonuçları .....	129
<b>5. SONUÇLAR .....</b>	<b>140</b>
<b>KAYNAKLAR .....</b>	<b>147</b>
<b>ÖZGEÇMİŞ .....</b>	<b>154</b>

## ÇİZELGELER DİZİNİ

<b>Çizelge 2. 1</b> : Complete Inception 3B modülünün ayrıntılı yapısı [34] .....	<b>34</b>
<b>Çizelge 2. 2</b> : Complete Inception 2B modülünün ayrıntılı yapısı [34] .....	<b>34</b>
<b>Çizelge 3. 1</b> : Indian Pines veri seti sınıfları ve her sınıfa ait örnek sayıları.....	<b>45</b>
<b>Çizelge 3. 2</b> : Pavia Üniversitesi veri seti sınıfları ve her sınıfa ait örnek sayıları. ....	<b>46</b>
<b>Çizelge 3. 3</b> : Salinas veri seti sınıfları ve her sınıfa ait örnek sayıları. ....	<b>47</b>
<b>Çizelge 3. 4</b> : Kennedy Uzay Merkezi veri seti sınıfları ve her sınıfa ait örnek sayıları. ...	<b>48</b>
<b>Çizelge 3. 5</b> : Botswana veri seti sınıfları ve her sınıfa ait örnek sayıları.....	<b>49</b>
<b>Çizelge 3. 6</b> : HyRANK-Loukia veri seti sınıfları ve her sınıfa ait örnek sayıları.....	<b>50</b>
<b>Çizelge 3. 7</b> : Houston 2013 veri seti sınıfları ve her sınıfa ait örnek sayıları.....	<b>51</b>
<b>Çizelge 3. 8</b> : WHU-Hi-LongKou veri seti sınıfları ve her sınıfa ait örnek sayıları. ....	<b>52</b>
<b>Çizelge 3. 9</b> : WHU-Hi-HanChuan veri seti sınıfları ve her sınıfa ait örnek sayıları. ....	<b>54</b>
<b>Çizelge 3. 10</b> : WHU-Hi- HongHu veri seti sınıfları ve her sınıfa ait örnek sayıları.....	<b>55</b>
<b>Çizelge 4. 1</b> : PU için önerilen yöntemin özeti. ....	<b>61</b>
<b>Çizelge 4. 2</b> : IP için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%). ....	<b>64</b>
<b>Çizelge 4. 3</b> : PU için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%). ....	<b>66</b>
<b>Çizelge 4. 4</b> : SA için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%). ....	<b>67</b>
<b>Çizelge 4. 5</b> : SA için önerilen yöntemin özeti. ....	<b>70</b>
<b>Çizelge 4. 6</b> : IP kullanılarak elde edilen sınıflandırma doğrulukları (%). ....	<b>71</b>
<b>Çizelge 4. 7</b> : PU kullanılarak elde edilen sınıflandırma doğrulukları (%). ....	<b>72</b>
<b>Çizelge 4. 8</b> : SA kullanılarak elde edilen sınıflandırma doğrulukları (%). ....	<b>74</b>
<b>Çizelge 4. 9</b> : KUM kullanılarak elde edilen sınıflandırma doğrulukları (%). ....	<b>75</b>
<b>Çizelge 4. 10</b> : Indian Pines için önerilen 3BLeNet mimarisinin özeti.....	<b>77</b>
<b>Çizelge 4. 11</b> : IP,PU ve SA veri setinde farklı yöntemlerle elde edilen sınıflandırma sonuçları (%). ....	<b>79</b>
<b>Çizelge 4. 12</b> : IP, PU ve SA'da farklı yöntemlerle elde edilen sınıflandırma sonuçlarının eğitim (dakika) ve test süreleri (saniye). ....	<b>79</b>
<b>Çizelge 4. 13</b> : Sınırlı eğitim örnekleri ile farklı derin öğrenme yöntemlerini kullanan IP, PU ve SA için sınıflandırma doğruluklarının karşılaştırılması (%). ....	<b>85</b>
<b>Çizelge 4. 14</b> : Pencere boyutunun 3BLeNet üzerindeki etkisi. ....	<b>85</b>
<b>Çizelge 4. 15</b> : IP veri seti için önerilen yöntemin ayrıntılı yapısı.....	<b>89</b>
<b>Çizelge 4. 16</b> : IP veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%). ....	<b>91</b>
<b>Çizelge 4. 17</b> : SA veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%). ....	<b>93</b>
<b>Çizelge 4. 18</b> : PU veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%). ....	<b>94</b>
<b>Çizelge 4. 19</b> : IP, PU ve SA veri setlerinde farklı yöntemlerle elde edilen sınıflandırma sonuçlarının eğitim ve test süreleri. ....	<b>96</b>
<b>Çizelge 4. 20</b> : Sınırlı eğitim örnekleri (5, 10, %20) ile farklı derin öğrenme yöntemlerini kullanan IP, PU ve SA için sınıflandırma doğruluklarının karşılaştırılması .....	<b>96</b>
<b>Çizelge 4. 21</b> : Pencere boyutunun önerilen yöntem etkisi (%). ....	<b>97</b>
<b>Çizelge 4. 22</b> : Farklı pencere boyutlarına sahip HybridSN ve ÖY'nin OA'ları (%). ....	<b>97</b>
<b>Çizelge 4. 23</b> : IP için önerilen yöntemin özeti.....	<b>101</b>
<b>Çizelge 4. 24</b> : IP için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%). ....	<b>104</b>
<b>Çizelge 4. 25</b> : SA için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%). ....	<b>106</b>



<b>Çizelge 4. 26</b> : PU için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%).	<b>107</b>
<b>Çizelge 4. 27</b> : IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).	<b>109</b>
<b>Çizelge 4. 28 (devam)</b> : IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).	<b>110</b>
<b>Çizelge 4. 29</b> : Pencere boyutunun ÖY'ye etkisi (%).	<b>111</b>
<b>Çizelge 4. 30</b> : Farklı pencere boyutları ile tüm yöntemlerin OA değerleri (%).	<b>111</b>
<b>Çizelge 4. 31</b> : %10 eğitim örnekleri kullanılarak HL veri kümesi için sınıflandırma sonuçları.	<b>113</b>
<b>Çizelge 4. 32</b> : %10 eğitim örnekleri kullanılarak UH veri kümesi için sınıflandırma sonuçları.	<b>116</b>
<b>Çizelge 4. 33</b> : IP verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).	<b>120</b>
<b>Çizelge 4. 34</b> : BO verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).	<b>121</b>
<b>Çizelge 4. 35</b> : HL verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).	<b>122</b>
<b>Çizelge 4. 36</b> : SA verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).	<b>124</b>
<b>Çizelge 4. 37</b> : WHU-LK için önerilen yöntemin özeti.	<b>128</b>
<b>Çizelge 4. 38</b> : IP'nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>130</b>
<b>Çizelge 4. 39</b> : PU'nun test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>131</b>
<b>Çizelge 4. 40</b> : SA'nın test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>132</b>
<b>Çizelge 4. 41</b> : IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).	<b>134</b>
<b>Çizelge 4. 42</b> : WHU-LK'nın test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>135</b>
<b>Çizelge 4. 43</b> : WHU-HC'nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>136</b>
<b>Çizelge 4. 44</b> : WHU-HH'nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).	<b>138</b>

## ŞEKİLLER DİZİNİ

Şekil 1. 1 : İki uzaktan algılama türü. (a) Havadan ve (b) uzaydan uzaktan algılama [1]. ...	1
Şekil 1. 2 : Hiperspektral görüntü küpü [7].	5
Şekil 2. 1 : Evrişim işleminin matematiksel gösterimi.	20
Şekil 2. 2 : Evrişim işlemi ile ilgili örnek bir uygulama gösterimi (adım (stride) değeri 1).	21
Şekil 2. 3 : Havuzlama işlemleri ile ilgili örnek uygulama gösterimi.	22
Şekil 2. 4 : (a) Standart sinir ağı, (b) Dropout uygulandıktan sonraki sinir ağı	23
Şekil 2. 5 : 1B ESA'nın şematik gösterimi	24
Şekil 2. 6 : 2B ESA'nın şematik gösterimi	25
Şekil 2. 7 : 3B ESA'nın şematik gösterimi	26
Şekil 2. 8 : LeNet5 mimarisi.	27
Şekil 2. 9 : AlexNet mimarisi.	28
Şekil 2. 10 : GoogleNet mimarisi.	30
Şekil 2. 11 : Naive Inception 2B modülü.	32
Şekil 2. 12 : Naive Inception 3B modülü.	32
Şekil 2. 13 : Complete Inception 2B modülü.	33
Şekil 2. 14 : Complete Inception 3B modülü.	33
Şekil 2. 15 : VGG16 mimarisi	36
Şekil 2. 16 : Artık öğrenme bloğu.	37
Şekil 2. 17 : ResNet18 mimarisi	37
Şekil 2. 18 : ResNet50 mimarisi	39
Şekil 2. 19 : (a) 2B Derinlemesine ayrılabilir evrişim, (b) 3B Derinlemesine ayrılabilir evrişim	43
Şekil 3. 1 : Indian Pines veri setinin renkli görüntüsü.	45
Şekil 3. 2 : Pavia Üniversitesi veri setinin renkli görüntüsü.	46
Şekil 3. 3 : Salinas veri setinin renkli görüntüsü.	47
Şekil 3. 4 : Kennedy Uzay Merkezi veri setinin renkli görüntüsü.	48
Şekil 3. 5 : Botswana veri setinin renkli görüntüsü.	50
Şekil 3. 6 : HyRANK-Loukia veri setinin renkli görüntüsü.	50
Şekil 3. 7 : Houston 2013 veri setinin renkli görüntüsü.	51
Şekil 3. 8 : WHU-Hi-LongKou veri setinin renkli görüntüsü.	53
Şekil 3. 9 : WHU-Hi-HanChuan veri setinin renkli görüntüsü.	54
Şekil 3. 10 : WHU-Hi- HongHu veri setinin renkli görüntüsü.	56
Şekil 4. 1 : Önerilen yöntemlerin genel çerçevesi.	58
Şekil 4. 2 : Hiperspektral görüntü sınıflandırma için önerilen Hibrid 3B evrişim ve 2B DAE yöntemi.	62
Şekil 4. 3 : IP için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HibridSN ve (h) Önerilen yöntem.	65
Şekil 4. 4 : PU için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HibridSN ve (h) Önerilen yöntem.	66
Şekil 4. 5 : SA için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HibridSN ve (h) Önerilen yöntem.	68
Şekil 4. 6 : Önerilen 4CF-Net yöntemi.	69

<b>Şekil 4. 7 :</b> IP için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net. ....	<b>71</b>
<b>Şekil 4. 8 :</b> PU için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net. ....	<b>73</b>
<b>Şekil 4. 9 :</b> SA için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net. ....	<b>74</b>
<b>Şekil 4. 10 :</b> KUM için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net. ....	<b>76</b>
<b>Şekil 4. 11 :</b> Önerilen 3B ESA tabanlı LeNet5 mimarisi. ....	<b>78</b>
<b>Şekil 4. 12 :</b> IP için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet. ....	<b>82</b>
<b>Şekil 4. 13 :</b> PU için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet. ....	<b>83</b>
<b>Şekil 4. 14 :</b> SA için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet. ....	<b>84</b>
<b>Şekil 4. 15 :</b> Hiperspektral görüntü sınıflandırması için önerilen 3B ESA tabanlı ResNet18 mimarisi. ....	<b>88</b>
<b>Şekil 4. 16 :</b> (a) Kimlik bloğu (b) Evrişim bloğu. ....	<b>88</b>
<b>Şekil 4. 17 :</b> IP veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY. ....	<b>92</b>
<b>Şekil 4. 18 :</b> SA veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY. ....	<b>93</b>
<b>Şekil 4. 19 :</b> PU veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY. ....	<b>95</b>
<b>Şekil 4. 20 :</b> Önerilen Hibrit 3B/2B Complete Inception ve ESA yöntemi. ....	<b>100</b>
<b>Şekil 4. 21 :</b> IP için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY). ....	<b>103</b>
<b>Şekil 4. 22 :</b> SA için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY). ....	<b>106</b>
<b>Şekil 4. 23 :</b> PU için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY). ....	<b>107</b>
<b>Şekil 4. 24 :</b> HL için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY). ....	<b>114</b>
<b>Şekil 4. 25 :</b> UH için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY). ....	<b>117</b>
<b>Şekil 4. 26 :</b> HL ve UH veri setleri kullanılarak farklı pencere boyutlarında PM, HybridSN, sadece 3B CNN ve sadece 2B CNN yöntemlerinin genel doğruluk değerlerinin karşılaştırılması. ....	<b>118</b>
<b>Şekil 4. 27 :</b> IP veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50. ....	<b>120</b>

<b>Şekil 4. 28</b> : BO veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.....	<b>121</b>
<b>Şekil 4. 29</b> : HL veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.....	<b>123</b>
<b>Şekil 4. 30</b> : SA veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.....	<b>124</b>
<b>Şekil 4. 31</b> : Önerilen hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı.....	<b>127</b>
<b>Şekil 4. 32</b> : IP kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY. ....	<b>130</b>
<b>Şekil 4. 33</b> : PU kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY. ....	<b>132</b>
<b>Şekil 4. 34</b> : SA kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY. ....	<b>133</b>
<b>Şekil 4. 35</b> : WHU-LK kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY.....	<b>135</b>
<b>Şekil 4. 36</b> : WHU-HC kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY.....	<b>137</b>
<b>Şekil 4. 37</b> : WHU-HH kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EresBoF, (e) FuSENet, (f) ÖY.....	<b>139</b>

## SEMBOLLER VE KISALTMALAR

<b>IP</b>	: Indian Pines
<b>PU</b>	: Pavia Üniversitesi
<b>HL</b>	: HyRANK-Loukia
<b>SA</b>	: Salinas
<b>BO</b>	: Botswana
<b>UH</b>	: Houston 2013
<b>KUM</b>	: Kennedy Uzay Merkezi
<b>AVIRIS</b>	: Airborne Visible/Infrared Imaging Spectrometer
<b>ROSIS</b>	: Reflective Optics System Imaging Spectrometer
<b>CASI</b>	: Compact Airborne Spectrographic Imager
<b>TBA</b>	: Temel Bileşen Analizi
<b>µm</b>	: Mikrometre
<b>mpp</b>	: Microns Per Pixel
<b>SNR</b>	: Signal-to-noise ratio
<b>İHA</b>	: İnsansız Hava Aracı
<b>FC</b>	: Fully Connected (Tam Bağlı)
<b>BN</b>	: Batch Normalization
<b>ESA</b>	: Evrimsel Sinir Ağı
<b>B</b>	: Boyut
<b>DE</b>	: Derinlemesine Evrişim
<b>NE</b>	: Noktasal Evrişim
<b>DAE</b>	: Derinlemesine Ayrılabilir Evrişim
<b>ÖY</b>	: Önerilen Yöntem
<b>HG</b>	: Hiperspektral Görüntü
<b>HUAG</b>	: Hiperspektral Uzaktan Algılama Görüntüleri
<b>DVM</b>	: Destek Vektör Makinesi
<b>LR</b>	: Lojistik Regresyon
<b>WHU-LK</b>	: WHU-Hi-LongKou
<b>WHU-HC</b>	: WHU-Hi-HanChuan
<b>WHU-HH</b>	: WHU-Hi-HongHu

# ÖZET

Doktora Tezi

## UZAKTAN ALGILAMADA DERİN ÖĞRENME TABANLI HİPERSPEKTRAL UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Hüseyin FIRAT

İnönü Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı

155+XII sayfa

2022

Danışman: Prof. Dr. Davut HANBAY

Hiperspektral uzaktan algılama görüntülerinde (HUAG) sınıflandırma, görüntü analizinde zorlu bir süreçtir ve en popüler konulardan biridir. Son yıllarda, HUAG sınıflandırma problemini çözmek için birçok yöntem önerilmiştir. Geleneksel makine öğrenme yöntemleriyle karşılaştırıldığında, derin öğrenme, özellikle Evrimsel sinir ağları (ESA), HUAG'lerin sınıflandırılmasında yaygın olarak kullanılmaktadır. ESA'lara dayalı derin öğrenme tabanlı yöntemler, HUAG sınıflandırmasında dikkate değer bir performans sergilemekte ve sınıflandırma teknolojisinin gelişimini büyük ölçüde desteklemektedir.

Bu tez çalışmasında, HUAG sınıflandırma için yedi farklı derin öğrenme tabanlı yöntem geliştirilmiştir. İlk çalışmada, 3B evrişim ile 2B derinlemesine ayrılabilir evrişimin birlikte kullanıldığı hibrit bir yöntem önerilmiştir. İkinci çalışmada, uzamsal-spektral özellikleri çıkarabilmek için yeni bir 3B ESA tabanlı yöntem geliştirilmiştir. Üçüncü çalışmada, daha az eğitilebilir parametreye sahip 3B ESA tabanlı LeNet5 yöntemi geliştirilmiştir. Dördüncü çalışmada, 3B ESA ve ResNet18 mimarisi kullanılarak derin uzamsal-spektral özneliklerin çıkarılması için hibrit bir 3B Residual uzamsal-spektral evrişim ağı önerilmiştir. Beşinci çalışmada, HUAG sınıflandırma problemini çözmek için 3B/2B Complete Inception modülü ve 3B/2B ESA yönteminin birlikte kullanıldığı hibrit bir yöntem önerilmiştir. Önerilen yöntemde Inception modülü ile çoklu evrişim katmanları kullanılarak çok seviyeli öznelik çıkarımı gerçekleştirilmektedir. Altıncı çalışmada, HUAG sınıflandırma problemi için ESA'nın başarılı örnekleri arasında olan LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 mimarilerinden yararlanılmaktadır. Bu mimarileri kullanırken 3B ESA tabanlı hibrit bir yaklaşım kullanılmaktadır. Yedinci çalışmada, çok yönlü özellik füzyonuna dayalı hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı tabanlı derin öğrenme yöntemi geliştirilmiştir.

Önerilen yöntemlerin tamamı sıklıkla kullanılan IP, PU, SA, BO, HL, UH, KUM, son zamanlarda ortaya çıkan WHU-Hi veri setleri üzerinde test edilmiştir. Önerilen yöntemler ile elde edilen sınıflandırma sonuçları, önerilen yöntemlerin son teknoloji yöntemlere göre daha başarılı sınıflandırma performansı sağladığını ortaya koymaktadır.

**Anahtar Kelimeler:** Uzaktan Algılama, Hiperspektral Görüntü Sınıflandırma, Derin Öğrenme, Temel Bileşen Analizi, Evrimsel Sinir Ağları

## ABSTRACT

Phd. Thesis

### CLASSIFICATION OF DEEP LEARNING BASED HYPERSPECTRAL SATELLITE IMAGES IN REMOTE SENSING

Hüseyin FIRAT

Inonu University  
Graduate School of Nature and Applied Sciences  
Department of Computer Engineering

155+XII sayfa

2022

Supervisor: Prof. Dr. Davut HANBAY

Classification in hyperspectral remote sensing images (HRSIs) is a challenging process in image analysis and one of the most popular topics. In recent years, many methods have been proposed to solve the HRSIs classification problem. Compared to traditional machine learning methods, deep learning, especially Convolutional Neural Networks (CNNs), is commonly used in the classification of HRSIs. Deep learning-based methods based on CNNs show remarkable performance in HRSIs classification and greatly support the development of classification technology.


In this thesis, seven different deep learning-based methods have been developed for HRSI classification. In the first study, a hybrid method is proposed in which 3D convolution and 2D depthwise separable convolution are used together. In the second study, a new 3D CNN-based method was developed to extract spatial-spectral features. In the third study, a 3D CNN-based LeNet5 method with less trainable parameters was developed. In the fourth study, a hybrid 3D Residual spatial-spectral convolution network is proposed for extraction of deep spatial-spectral features using 3D CNN and ResNet18 architecture. In the fifth study, a hybrid method in which the 3D/2D Complete Inception module and the 3D/2D CNN method are used together is proposed to solve the HRSI classification problem. In the proposed method, multi-level feature extraction is performed by using multiple convolution layers with the Inception module. In the sixth study, LeNet5, AlexNet, VGG16, GoogleNet and ResNet50 architectures, which are among the successful examples of CNN, are used for the HRSI classification problem. A hybrid approach based on 3D CNN is used when using these architectures. In the seventh study, a hybrid 3D-2D depthwise separable convolutional network based deep learning method based on multipath feature fusion is developed.

All of the proposed methods have been tested on frequently used IP, PU, SA, BO, HL, UH, KUM, and recently emerged WHU-Hi datasets. The obtained classification results with the proposed methods reveal that the proposed methods provide more successful classification performance than the state-of-the-art methods.

**Keywords:** Remote Sensing, Hyperspectral Image Classification, Deep Learning, Principal Component Analysis, Convolutional Neural Network

## 1. GİRİŞ

Herhangi bir fiziksel bağlantı olmaksızın Dünya yüzeyindeki bir alandan ölçülen veriler ile bilgi elde etmek için kullanılan teknoloji uzaktan algılama olarak tanımlanmaktadır. Bilgi, Dünya'dan yayılan veya yansıyan radyasyon/ışınma enerjisinin algılanmasıyla toplanmaktadır. Uzaktan algılama birçok bilimsel ve pratik alanda yaygın olarak kullanılmaktadır. Örneğin, küresel ısınmanın ekosistemler üzerindeki etkisini değerlendirmek için uydudan toplanan görüntüler kullanılmaktadır. Tarımda, uzaktan algılanan veriler, bitki örtüsünün büyüyen durumu hakkında değerli bilgiler sağlamaktadır. Şehir planlamasında, kentsel alanların arazi kullanım durumunu izlemek ve analiz etmek için uçaktan elde edilen kızılötesi veriler kullanılmaktadır. Adından da anlaşılacağı gibi, ilgilenilen bilgiler normalde çok uzak bir mesafeden toplanmaktadır. Uzaktan algılama, gerçek fiziksel temasın olmadığı bir hedef veya olgunun veri toplama sürecidir ve erişilemeyen ve muhtemelen güvenli olmayan bölgelerden veri almamızı sağlamaktadır. Dünya üzerindeki nesnelere algılamak ve sınıflandırmak için genellikle uydu veya uçak tabanlı sensör teknolojileri ile çoğu yer gözlem alanında kullanılmaktadır. Bu nedenle, başlıca iki uzaktan algılama türü, Şekil 1.1'de gösterildiği gibi havadan ve uzaydan uzaktan algılamayı içermektedir.



**Şekil 1. 1:** İki uzaktan algılama türü. (a) Havadan ve (b) uzaydan uzaktan algılama [1].



“Landsat Programı”nda, 1970'lerden beri Dünya'yı gözlemlemek için bir dizi uydu uzaya fırlatılmıştır. Bu uydular farklı türde sensörler taşımakta ve Dünya hakkında bol miktarda veri üretmektedirler. Uzaktan algılama teknolojileri iki kategoriye ayrılabilir: aktif uzaktan algılama ve pasif uzaktan algılama [2]. Aktif uzaktan algılamada, sensörler önce incelenen nesneye doğru enerjiyi aydınlatmaktadır. Ardından nesne, aktif sensör tarafından alınan enerjiyi geri yansıtmaktadır. Aktif uzaktan algılama örnekleri, Synthetic Aperture Radar (SAR) ve Light Detection and Ranging (LIDAR)'dır. Aktif uzaktan algılama, güneş ışığı olmadan veri alabilmekte ve her an çalışabilmektedir. Ayrıca doğal bir enerji kaynağı olmayan elektromanyetik dalga boyundaki nesnelere de algılayabilmektedir. Aktif uzaktan algılamanın dezavantajı, sensörlerin büyük miktarda enerji yayabilmesini gerektirmesidir. Pasif sensörler kendi başlarına enerji yaymazlar ve sadece Güneş gibi doğal kaynaktaki enerjiyi ölçerek çalışmaktadırlar. Ölçülen iki tür enerji vardır: yansıyan ve yayılan enerji. Güneş Dünya'yı aydınlattığında, Dünya'nın yüzeyi, görünür dalga boyundaki elektromanyetik dalga gibi radyasyon enerjisinin bir kısmını geri yansıtabilir. Aynı zamanda, Dünya, Güneş enerjisinin bir kısmını emecek ve daha sonra bunu kızılötesi radyasyon gibi uzaya yeniden yayacaktır. Uzaktan algılamadaki pasif sensörler, pankromatik, multispektral ve hiperspektral sensörleri içermektedir. Pankromatik sensörler, yalnızca tek bir bantta veya birkaç ayrı bantta sinyal almaktadır. Multispektral sensörler, aynı anda birkaç spektral aralıkta veri almaktadır. Her band, bir nesnenin spektral bilgisini taşımakta ve çizilen tüm bandlar, spektrum adı verilen yansıma eğrisini oluşturmaktadır. Spektrum, o nesne ve spektral aralığa özgüdür. Bir sensör ne kadar çok band toplayabilirse, o nesnenin daha fazla spektral bilgisi çıkarılabilmektedir. Son yıllarda, sensörlerin uzamsal ve spektral çözünürlüğünün gelişimi iyileştirilmiştir [3]. Uzamsal çözünürlük, bir uydu sensörü tarafından algılanabilen veya bir uydu görüntüsünde görüntülenebilen en küçük özelliğin boyutunu ifade etmektedir. Genellikle bir karenin bir kenarının uzunluğunu temsil eden tek bir değer olarak sunulmaktadır. Örneğin, 250m'lik bir uzamsal çözünürlük, bir pikselin yerdeki 250x250 metrelik bir alanı temsil ettiği anlamına gelmektedir. Spektral çözünürlük, bir uydu sensörünün elektromanyetik spektrumun belirli dalga boylarını ölçme yeteneğini ifade etmektedir. Spektral çözünürlük ne kadar ince olursa, belirli bir kanal veya band için dalga boyu aralığı o kadar dar olmaktadır. İlk sivil uydu programı, dünyanın doğal kaynakları hakkında bilgi toplamak için Landsat idi. Landsat 1, spektrumları 56 x 79 m uzamsal çözünürlüğe sahip 4 multispektral bantta toplamıştır ve 1972'de fırlatılmıştır. Fransa'dan Satellite Pour l'Observation de la Terre (SPOT) gibi diğer ülkelerden birkaç Landsat uydusu ve diğer uydu sistemleri geliştirilmiştir. Yüksek uzamsal çözünürlüğe sahip

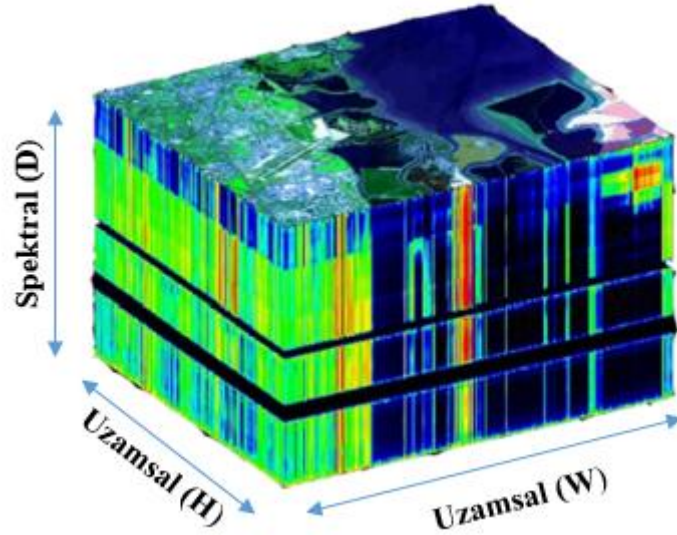
yeni nesil uydu sistemlerinden bazıları ise şu şekildedir: RapidEye (6.5 m uzamsal ve 5 band spektral çözünürlük), Quickbird-2 (2.62 m uzamsal ve 4 band spektral çözünürlük) ve Worldview-2 (1.86 m uzamsal ve 8 band spektral çözünürlük) [3]. Uzaktan algılamada, tipik hiperspektral sensörler arasında Havadan görünür/kızılötesi görüntüleme spektrometresi (AVIRIS), Yansıtıcı optik sistem görüntüleme spektrometresi (ROSIS) ve Dünya gözlem (EO-1) Hyperion görüntüleme spektrometresi bulunmaktadır. AVIRIS, 1980'lerde Jet Propulsion Laboratuvarında tasarlanan hava kaynaklı bir hiperspektral sensördür. 400 ile 2500 nm arasında geniş bir dalga boyu segmentine yanıt verebilmektedir. Toplanan hiperspektral veriler, 10 nm'lik dar aralıklı 224 sürekli banda sahiptir. ROSIS, Avrupa tarafından finanse edilen bir havadan hiperspektral sensör projesinde tasarlanmıştır. ROSIS'in tepki spektrumu 430 ile 960 nm arasındadır. Elde edilen veriler, 5 nm'lik yüksek bir spektral çözünürlüğe ve 100'den fazla banta sahiptir. Hyperion, EO-1 için tasarlanmış NASA tarafından başlatılan bir uydu hiperspektral kamerasıdır. Hyperion sensörünün spektrum aralığı 400 ile 2500 nm arasındadır. Hyperion hiperspektral görüntüleri, 10 nm spektral çözünürlüğe sahip 200'den fazla sürekli banda sahiptir. Uydu ile Dünya yüzeyi arasındaki uzun mesafe nedeniyle, Hyperion'un uzamsal çözünürlüğü yaklaşık 30 m'dir. Bu sensörler dışında, Kompakt havadan spektrografik görüntüleyici (CASI), spektrum aralığı 400 ile 900 nm arasında 288 sürekli banda sahiptir. Hiperspektral görüntüleme kamerası (HySI), spektrum aralığı 400 ile 950 nm arasında 32, Kompakt yüksek çözünürlüklü görüntüleme spektrometresi (CHRIS) spektrum aralığı 400 ile 1050 nm arasında 19, Hiperspektral dijital görüntü toplama deneyi (HYDICE) spektrum aralığı 400 ile 2500 nm arasında 210 sürekli banda sahiptir [4].

Uzak sensörler, Dünya yüzeyi hakkında radyasyon verilerini elde ettikten sonra, bir sonraki adım, ham enerji büyüklüğünü faydalı bilgilere dönüştüren uzaktan algılama veri analizidir. Çoğu uzaktan algılama verisi 2 boyutlu veya daha yüksek boyutludur. Boyutlardan ikisi uzamsal boyutu temsil etmekte ve veriler düşük çözünürlüklü görüntülerdir. Uzaktan algılamada, arazi örtüsü sınıflandırmasıyla ilgili olarak, en son yapılması gereken işlem, uzaktan algılama görüntülerinde her piksel için arazi örtüsü kategorisini tahmin etmektir. Üç farklı uzaktan algılama veri görüntüsü bulunmaktadır. Bunlar: pankromatik, multispektral ve hiperspektral görüntülerdir [5]. Pankromatik bir görüntü yalnızca bir banttan oluşmaktadır. Genellikle gri ve siyah-beyaz ölçekli bir görüntü olarak görüntülenmektedir [6]. Multispektral görüntüler, elektromanyetik spektrumun belirli birkaç bölümünde (band olarak da adlandırılmakta) yansıyan enerjiyi ölçen sensörler

tarafından üretilmektedir. Multispektral görüntüler, hiperspektral görüntülerden daha az, pankromatik görüntülerden daha fazla spektral band içermektedir. Multispektral sensörler, ürettikleri görüntülerin her pikselinde genellikle 3 ile 10 farklı band ölçümüne sahiptir [4]. Hiperspektral görüntüleme, pankromatik ve multispektral görüntülemeye kıyasla çeşitli avantajlara sahiptir. Hiperspektral sensörler, enerjiyi multispektral sensörlerden daha dar ve çok sayıda bantta ölçmektedir. Ultraviyolede kızılötesi bölgeye kadar geniş bir spektrum kullanarak görüntüleri yakalama ile ilgilenmektedir. Hiperspektral görüntüler yüksek spektral çözünürlük gösteren yüzlerce bitişik spektral band içerebilmektedir. Multispektral görüntülerde, spektral bandlar düzensiz ve geniş aralıklı iken, hiperspektral sensörlerin sayısız dar bandları, tüm elektromanyetik spektrum boyunca sürekli bir spektral ölçüm sağlamaktadır. Bu nedenle yansıyan enerjideki ince değişimlere karşı daha hassastır [5]. Hiperspektral sensörlerden üretilen görüntüler, multispektral sensörlerden alınan görüntülerden çok daha fazla veri içermekte ve kara ve su özellikleri arasındaki farklılıkları algılamak için daha büyük bir potansiyele sahiptir. Örneğin, ormanlık alanların haritasını çıkarmak için multispektral görüntüler kullanılabilirken, orman içindeki ağaç türlerinin haritasını çıkarmak için hiperspektral görüntüler kullanılabilir. Bu nedenle, hiperspektral görüntüler uzaktan algılama görüntü sınıflandırmasında yaygın olarak kullanılmaktadır ve uzaktan algılama topluluğundan önemli araştırmaların ilgisini çekmektedir. Ayrıca, donanım teknolojilerinin gelişmesiyle birlikte, hiperspektral uzaktan algılama görüntüsünün çözünürlüğü daha yüksek hale gelmekte, bu da spektral bilgilere ek olarak sınıflandırma için bol miktarda uzamsal bilgi sağlamaktadır. Hiperspektral görüntülerin avantajları şunlardır: Sürekli spektral yansıma eğrisi ve dolayısıyla daha iyi nesne tanımlaması, yüksek spektral çözünürlük, orta uzamsal çözünürlük ve geniş alan kapsamı [4].

Tipik bir hiperspektral görüntü, her biri belirli bir dalga boyundan alınan birçok görüntüden oluşmaktadır. Bu nedenle, küpün yüksekliği ve genişliğinin, her bir dalga boyunda 2 boyutlu görüntünün uzamsal boyutuna (piksel sayısı) karşılık geldiği, derinliği ise hiperspektral görüntünün spektral bandlarının sayısını temsil ettiği bir küp olarak düşünülebilir [1]. Hiperspektral görüntüleme, yalnızca iki uzamsal boyut boyunca değil, aynı zamanda spektral boyut boyunca da hedefler hakkında bilgi edinmeyi sağlamaktadır. Böylece, bu görüntüleme yöntemi, geleneksel kameralar tarafından yakalanan görüntülerden farklı çıktı görüntüleri üretmektedir. Gri ölçekli görüntülerin yalnızca iki uzamsal boyutu vardır, bu nedenle iki boyutlu dizi olarak bulunurlar:  $I_{gray} \in$

$R^{W \times H}$ .  $I_{gray}$ , gri ölçekli bir görüntüyü,  $W$  ve  $H$ , görüntünün genişliğini ve yüksekliğini temsil etmektedir. Renkli görüntüler (RGB), uzamsal boyuta ek olarak üç renk kanalı sunmaktadır. Böylece, renkli bir görüntü  $I_{RGB} \in R^{W \times H \times 3}$  olarak temsil edilmektedir.  $I_{RGB}$  bir renkli görüntüyü ve 3 sayılı renk uzayının boyutunu temsil etmektedir. Hiperspektral görüntüler, uzamsal boyutlara üçüncü bir sürekli spektral boyut eklemektedir. Şekil 1.2'de gösterildiği gibi, hiperspektral bir görüntü bir veri küpü olarak temsil edilebilmektedir. Matematiksel olarak,  $X \in R^{W \times H \times D}$  olarak gösterilmektedir.  $X$ , bir hiperspektral veri küpünü ve  $D$ , spektral boyutu ifade etmektedir. Üç boyutlu  $X$  dizisinin bir elemanı  $(x,y,z)$  olarak ifade edilebilmektedir. Spektral perspektiften, hiperspektral bir görüntünün birçok 2 boyutlu görüntüden oluştuğu düşünülebilmektedir. Her görüntü bir dar spektral banda karşılık gelmektedir. Uzamsal bakış açısından, hiperspektral görüntü de piksellerden oluşmaktadır. Her piksel tek boyutlu bir vektördür:  $p \in R^D$ . Hiperspektral görüntü, hedef nesne hakkında zengin bilgiler sağlamak ve çeşitli alanlarda yaygın olarak kullanılmaktadır [2].



Şekil 1. 2: Hiperspektral görüntü küpü [7].

## 1.1 Literatür İncelemesi

Uzaktan algılama teknolojisindeki gelişmelerle birlikte, hiperspektral uzaktan algılama görüntüleri son zamanlarda çoğu araştırmacının ilgi odağı haline gelmiştir. Hiperspektral görüntüler (HG)'deki en temel sorunlardan biri, HG'lerdeki her pikselin bir sınıfa atandığı sınıflandırmadır. Bu nedenle, HG'lerin sınıflandırılması yoğun olarak çalışılan bir araştırma alanı haline gelmiştir [7]. HG'ler, iki uzamsal ve bir spektral boyuttan oluşan 3 boyutlu görüntü küpleridir. Her HG, zengin uzamsal ve spektral özellik bilgisi sağlamak için yüzlerce sürekli spektral görüntü bandı içermektedir [8]. HG'lerin analizi çoğu

gerçek hayattaki uygulamada oldukça önemlidir. Bu nedenle, mahsul izleme, nesne takibi, madencilik, arazi örtüsü analizi, tarım, askeri gözetim, arazi yangını izleme, astronomi gibi birçok gerçek hayat uygulamasında yaygın olarak kullanılmaktadır [9][10]. HG'lerdeki yüzlerce sürekli spektral bant sayesinde, hedef nesnelere ayırt etme ve doğru bir şekilde tanımlama yeteneği önemli ölçüde iyileştirilmiştir. Öte yandan, HG'lerin yüksek spektral boyutluluğu ve bitişik spektral bantlar arasındaki bilgi fazlalığı, yüksek hesaplama maliyetine neden olmaktadır. HG sınıflandırmasının bir başka zorluğu da girdi örneklerinin olmamasıdır. Örneğin, denetimli sınıflandırma, verilerin yüksek boyutluluğu ile etiketli eğitim örneklerinin sınırlı kullanılabilirliği arasındaki oran nedeniyle genellikle zor bir işittir. Temel kural, gerekli sayıda eğitim örneğinin, verilerin boyutuyla doğrusal olarak ilişkili olmasıdır. Bu problem, boyutsallığın laneti veya sınıflandırma için gerekli eğitim örnekleri setinin boyutunun spektral bantların sayısı ile katlanarak arttığını belirten Hughes fenomeni olarak adlandırılmaktadır [11]. Hughes fenomeni, spektral boyut arttıkça sınıflandırma doğruluğunda önemli bir azalmaya neden olmaktadır. HG sınıflandırma yöntemlerinin çoğu, Hughes fenomeni için bir çözüm olarak boyut indirgeme yöntemlerini kullanmaktadır. Boyut indirgeme yöntemleri, önerilen yöntemin sınıflandırma doğruluğunu azaltan gereksiz spektral özellik bilgilerinin ortadan kaldırılmasını sağladığı için hiperspektral görüntü analizinde oldukça önemli bir süreçtir. HG sınıflandırmada boyut indirgeme iki farklı şekilde gerçekleştirilebilir: spektral band seçimi ve spektral band çıkarımı. Spektral band seçiminde, orijinal HG spektral bandından seçilen en kullanışlı spektral bantlar üzerinde analiz yapılmaktadır. Spektral band çıkarımında, yüksek spektral boyuta sahip HG verilerinin spektral boyutu azaltılmaktadır. Ancak, azalan spektral boyutla HG verilerinin uzamsal boyutu değişmez. Literatürde, Temel bileşen analizi, Doğrusal diskriminant analizi, Bağımsız bileşen analizi, Artımlı temel bileşen analizi , Yerel olarak doğrusal gömme, Çekirdek temel bileşen analizi gibi boyut indirgeme yöntemleri bulunmakta ve orijinal HG verileri uygulanmaktadır. Boyut indirgeme yöntemleri arasında en iyi ve sık kullanılan spektral band çıkarma yöntemlerinden biri Temel Bileşen Analizidir (TBA). TBA ile HG'lerde faydalı spektral bantların çıkarılması amaçlanmıştır. Bu işlem sonucunda veri boyutu küçülmekte ve işlem maliyeti azalmaktadır [12][13].

HG'lerin uzamsal ve spektral özellik bilgileri, HG sınıflandırmada kullanılacak özelliklerdir. K-en yakın komşular [14], lojistik regresyon (LR) [15], destek vektör makinesi (DVM) [16] ve rastgele orman [17] gibi geleneksel HG yöntemleri, genellikle HG sınıflandırma için bol miktarda spektral özellik bilgisinden yararlanmaya dayanmaktadır. Bu

sınıflandırıcılar arasında DVM, basit ama güçlü bir son sınıflandırıcı olarak kabul edilmektedir. Ancak, HG'ler hem spektral band fazlalığına hem de spektral bandlar arasında yüksek korelasyona sahip olduğundan, bu tipik sınıflandırıcılar iyi performans gösteremezler. Çünkü çok sayıda spektral band için yeterli sayıda eğitim örneği olmayabilir. Bu durum, spektral bandların yüksek boyutluluğu ile sınırlı sayıda eğitim örneği arasında bir dengesizliğe neden olmaktadır. Ayrıca, yalnızca spektral band bilgilerini kullanan bu sınıflandırma yöntemleri, yüksek spektral çözünürlüklü veriler için algılanan önemli uzamsal özellikleri elde edememektedir. Bu durum genellikle HG sınıflandırmada daha düşük sınıflandırma performansı ile sonuçlanmaktadır. Sınıflandırma performansını iyileştirmenin en temel yolu, uzamsal-spektral özellikleri birlikte kullanan sınıflandırıcılar tasarlamaktır. Uzamsal özellik bilgisi, süper piksel [18] ve seyrek gösterim [19], çoklu çekirdek öğrenme [20] ve morfolojik profillere dayalı [21] yöntemlerle HG sınıflandırmada spektral bilgilerle birleştirilmektedir. Bu şekilde sınıflandırma doğruluğu arttırılmaktadır. Bununla birlikte, yukarıda açıklanan HG sınıflandırma yöntemlerinin çoğu, uzamsal-spektral özellikleri manuel olarak çıkarmakta ve uzman yardımı gerektirmektedir [22].

Son yıllarda, derin öğrenme tabanlı teknikler, nesne algılama, doğal dil işleme, anlamsal bölümlenme ve görüntü sınıflandırma gibi birçok bilgisayarla görme görevinde büyük ilerlemeler kaydetmiştir. Çünkü orijinal verilerden hiyerarşik bir şekilde otomatik olarak sağlam ve ayırt edici özellikler çıkarabilmektedir. Derin öğrenme tekniklerindeki ilerleme, HG sınıflandırmayı yeni bir düzeye taşımaktadır. Derin öğrenme tekniklerinin eğitim aşaması, özellikleri otomatik olarak çıkarmakta ve bu özellikleri sınıflandırma aşamasında kullanmaktadır. Tipik bir derin öğrenme yöntemi olan yığılanmış otomatik kodlayıcı (Stacked autoencoder -SAE), uzamsal-spektral özellik bilgilerini çıkarabilmektedir. Daha sonra bu bilgileri HG sınıflandırma için birleştirebilmektedir. Chen ve diğ. [23] derin öğrenme kavramını HG sınıflandırma alanına uygulayan ilk araştırmacılarıdır. Uzamsal-spektral özellik çıkarımı ve sınıflandırması için TBA, SAE ve LR'nin birlikte kullanıldığı bir yöntem geliştirmişlerdir. Tao ve diğ. [24], derin spektral özellikleri çıkarmak için SAE ve LR'nin birlikte kullanıldığı SAE tabanlı LR önermişlerdir. Derin inanç ağı (Deep belief network -DBN) tabanlı sınıflandırma, HG sınıflandırma için kullanılan bir diğer derin öğrenme yöntemidir. HG'nin uzamsal özellik bilgisinin spektral özellik bilgisi ile birleştirilmesi için önerilmiştir [25]. Jia ve diğ. [26], DBN'ye dayalı HG analizi için TBA, hiyerarşik öğrenmeye dayalı özellik çıkarımı ve LR'nin birlikte kullanıldığı bir yöntem önermişlerdir. Li ve diğ. [27], optimal doku özelliği geliştirme ve DBN kullanan

yeni bir HG sınıflandırma yöntemi geliştirmişlerdir. DBN ve SAE kullanılarak katman tabanlı bir eğitim sürecinde derin özellikler hiyerarşik olarak çıkarılabilirken, bu modellere girdi olacak görüntü parçalarından oluşan eğitim örneklerinin tek boyuta düzleştirilmesi gerekmektedir. Bu durum, HG'nin uzamsal özelliklerinden tam olarak yararlanılmamasına neden olmaktadır. Ayrıca, DBN ve SAE, denetimsiz öğrenme algoritmalarıdır ve özellikleri öğrenirken doğrudan sınıf bilgilerini kullanmamaktadırlar.

Evrişimsel sinir ağları (ESA), HG sınıflandırmada en sıklıkla kullanılan derin öğrenme yöntemidir. ESA, HG sınıflandırmada daha ayırt edici özellikler sağlaması açısından çok iyi özellik öğrenmesine sahiptir. Öğrenilen özellikler ne kadar ayırt edici olursa, sınıflandırma problemlerini çözmek o kadar kolay olmaktadır [28]. Bu durum sınıflandırma doğruluğunu büyük ölçüde arttırmaktadır. Bu nedenle, HG sınıflandırmada kullanılan ESA tabanlı yöntemler, daha derin uzamsal, spektral veya uzamsal-spektral özellik bilgilerini çıkarmak için kullanılan en verimli yöntemlerden biridir. HG sınıflandırma performansını etkili bir şekilde iyileştirdikleri için ESA tabanlı yöntemler giderek daha fazla uygulanmaktadır.

Roy, Chatterjee ve diğ. [8], HG sınıflandırma için uçtan uca bir spektral-uzamsal, sıkıştırma ve uyarma (SU) tabanlı residual özellik (S3EResBoF) yöntemi önermişlerdir. Bu yöntem, girdi verisi olarak ham 3B görüntü küplerini almakta ve sınıflandırmayı kolaylaştırmak için gereksiz özellik haritalarını kaldırarak dönüştürme özelliğinin bir kod çizelgesi temsilini oluşturmaktadırlar. Sınıflandırma performansını iyileştirmek için, residual blokların her biri, bir SU bloğu tarafından takip edilen bir kimlik eşleme yoluyla 3B evrişim katmanına bağlanmaktadır. Ayrıca, ağın yakınsamasını düzenlemek için her evrişim katmanında BN kullanılmaktadır. Önerilen yöntemin sınıflandırma doğruluğunu test etmek için IP, SA ve PU veri setleri kullanılmıştır. TBA kullanılarak, IP için 30, SA ve PU için 15 temel bileşen seçilmiştir. Uygulamalar 15x15 pencere boyutu ve %10-20 eğitim örneği alınarak yapılmıştır. IP, PU ve SA için %20 eğitim örneğinde %99.87, %99.97, %100, %10 eğitim örneğinde sırasıyla %99.49, %99.77, %99.98 OA değerleri elde edilmiştir.

Mohan ve Meenakshi Sundaram [12], HG sınıflandırma için 3B ve 2B ESA'dan oluşan hibrit bir ESA mimarisi önermişlerdir. Önerilen model, ön işleme adımı olarak TBA'yı kullanmaktadır. 3B ESA, uzamsal-spektral özellikleri aynı anda çıkarmak için kullanılmaktadır. Ardından daha fazla uzamsal özellik çıkarmak için 2B ESA kullanılmaktadır. Ancak, uzamsal özelliklerindeki fazlalık, standart evrişim yerine oktav evrişim (OctConv) ile azaltılmaktadır. 25x25 pencere boyutu, IP için 30 ve SA ile PU için

15 temel bileşen kullanılmıştır. %20 eğitim örneği alınarak gerçekleştirilen uygulamalarda sırasıyla, %99.38, %100 ve %99.95 OA değerleri elde edilmiştir.

Mohan ve diğ. [22], HG sınıflandırma için bir 3B-2B ESA'ya dayanan çok ölçekli bir uzamsal-spektral özellikten oluşan hibrit bir ESA yöntemi önermişlerdir. Spektral band fazlalığını azaltmak için lineer gauss rastgele projeksiyonu ve lineer olmayan çekirdek temel bileşen analizinden oluşan hibrit bir boyut indirgeme yöntemi kullanmışlar. 15x15 pencere boyutu ve tüm veri setlerinde boyut indirgemesi sonucu 15 temel bileşen alınarak uygulamalar gerçekleştirilmiştir. Uygulamalarda IP, PU, SA ve UH veri setleri kullanılmıştır. %20 eğitim örneği alınarak gerçekleştirilen uygulamalar sonucunda sırasıyla %99.80, %99.99, %100 ve %99.12 OA değerleri elde edilmiştir.

Cao ve Guo [29], hibrit genişletilmiş evrişim ile yüksek boyutlu residual ağlar üreterek uzamsal-spektral özellik bilgilerini sürekli olarak çıkaran yeni bir 3B-2B HG sınıflandırma ağı önermişlerdir. Uygulamalar herhangi bir boyut indirgeme yöntemi kullanılmadan IP, KUM ve PU üzerinde yapılmıştır. 7x7 pencere boyutu, IP ve KUM için %20, PU için %10 eğitim örneği kullanılarak yapılan uygulamalarda OA değerleri KUM için %99.89, IP için %99.46 ve PU için %99.81 olarak elde edilmiştir.

Roy, Manna ve diğ. [30] HG sınıflandırma için dikkat temelli uyarlanabilir spektral-uzamsal çekirdek geliştirilmiş residual ağı (A2S2K-ResNet) sunmuşlardır. Önerilen ağ, geliştirilmiş 3B Residual blokları kullanarak uzamsal-spektral özellikleri ortaklaşa çıkarmak için 3B evrişimli çekirdekleri öğrenmekte ve sınıflandırma performansını iyileştirmek için etkili bir özellik yeniden kalibrasyon işlemi kullanmaktadır. Uygulamalar herhangi bir boyut indirgeme yöntemi kullanılmadan KUM, IP ve PU veri setleri kullanılarak yapılmıştır. 9x9 pencere boyutu ve %10 eğitim örneğinin kullanıldığı uygulamalarda OA değerleri KUM için %99.34, IP için %98.66 ve PU için %99.85 olarak elde edilmiştir.

Roy ve diğ. [31], HG sınıflandırma için hibrit bir spektral ESA (HybridSN) önermişlerdir. HybridSN, 3B ESA ve 2B ESA'nın birlikte kullanılmasından oluşmaktadır. 3B ESA, bir spektral bant yığınınından ortak uzamsal-spektral özellikleri çıkarmaktadır. 2B ESA, uzamsal özellikleri çıkarmak için 3B ESA'dan sonra kullanılmaktadır. Uygulamalar IP, SA ve PU veri seti üzerinde gerçekleştirilmiştir. TBA kullanılarak, IP için 30, SA ve PU için 15 temel bileşen seçilmiştir. Uygulamalar 25x25 pencere boyutu ve %30 eğitim örneği alınarak gerçekleştirilmiştir. Önerilen yöntemde IP, PU ve SA için sırasıyla %99.75, %99.98 ve %100 OA değerleri elde edilmiştir.



Ahmad [32], HG sınıflandırmada sınıflandırma doğruluğunu arttırmak için hem uzamsal hem de spektral özelliklerin kullanılmasını sağlayan hızlı bir 3B ESA yöntemi önermiştir. Önerilen yöntemde 3B ESA arka arkaya 4 kez uygulanmıştır. Uygulamalarda boyut indirgeme yöntemi olarak artımlı temel bileşen analizi kullanılmıştır. En kullanışlı 20 temel bileşen alınmıştır. Uygulamalar 11x11 pencere boyutunda ve %10 eğitim örneklemeyle IP, PU, SA veri setleri üzerinde yapıldığında sırasıyla %97.75, %98.40 ve %98.06 OA değerleri elde edilmiştir.

Roy, Dubey ve diğ. [33] maksimum ve global havuzlama gibi farklı sıkıştırma türleri üzerinde çift doğrusal bir füzyon işlemi olan FuseNet'i tasarlamışlardır. FuseNet yönteminde, sigortalı sıkıştırma ve uyarma ağı residual blok ile birleştirilmiştir. IP için 30, PU ve SA için 15 temel bileşen kullanılarak TBA ile yapılan uygulamalarda sırasıyla %20 eğitim örneği ve 15x15 pencere boyutunda, %99.01, %99.42, %99.68 OA değerleri elde edilmiştir.

Iyer ve diğ. [34], daha fazla uzamsal-spektral özellik öğrenmek için 3B ve 2B Inception bloklarını içeren Inception'dan ilham alan mimariyi önermişlerdir. Daha sonra bu mimariyi Inception Residual ağ ve HybridSN mimarileriyle birleştirmişlerdir. 25x25 pencere boyutu, %30 eğitim örneği, TBA boyut indirgeme yöntemi kullanılarak IP için 30, PU ve SA için 15 temel bileşen ile yapılan uygulamalar sonucunda sırasıyla %99.76, %100 ve %100 OA değerleri elde edilmiştir.

Xu ve diğ. [35], çoklu spektral çözünürlük modülünü, spektral genişletilmiş evrişimleri, 3B evrişimi ve residual bağlantıyı birleştirerek HG sınıflandırma için çoklu spektral çözünürlük 3B ESA'yı geliştirmişlerdir. TBA, orijinal HG verilerine ön işleme adımı olarak uygulanmış ve uygulamalar 100 temel bileşen ile gerçekleştirilmiştir. IP, PU, SA, BO veri setleri üzerinde %10 eğitim örneği ve 9x9 pencere boyutu alınarak gerçekleştirilen uygulamalarda sırasıyla %98.10, %99.62, %99.96, %98.80 OA değerleri elde edilmiştir.

Gao ve diğ. [36], HG sınıflandırma için yeni bir çok ölçekli residual ağ yöntemini önermişlerdir. Önerilen yöntemde ilk olarak derinlemesine ayrılabilir evrişim kullanılmıştır. Daha sonra, derinlemesine ayrılabilir evrişimdeki derinlemesine evrişim, çoklu çekirdek boyutlarını karıştıran karışık derinlemesine evrişim ile değiştirilmiştir. Son olarak, çok ölçekli bir residual blok elde etmek için residual bloğa karışık derinlemesine evrişim dahil edilmiştir. Uygulamalarda PU, SA ve Pavia Center veri setleri kullanılmıştır. Eğitim için her

veri setindeki her sınıftan 20 rastgele örnek alınmıştır. TBA kullanılarak SA, PU ve Pavia Center için sırasıyla 15, 10 ve 10 adet temel bileşen alınmış ve uygulamalar gerçekleştirilmiştir. Pencere boyutu PU ve SA için 15x15, Pavia Center için 9x9'dur. Uygulamalar sonucunda Pavia Center, PU ve SA için sırasıyla %98.69, %96.50 ve %96.84 OA değerleri elde edilmiştir.

Fırat ve diğ. [37], HG sınıflandırma için 3B ESA ve 2B derinlemesine ayrılabilir evrişim sürecini birleştiren hibrit bir yöntem önermişlerdir. Önerilen yöntemde TBA kullanılarak IP, PU ve SA için sırasıyla 30, 15 ve 15 temel bileşen alınarak uygulamalar yapılmıştır. IP, PU, SA için sırasıyla 11x11 pencere boyutu ve %20, %10 ve %10 eğitim örnekleri alınmıştır. Uygulamalar sonucunda IP, PU ve SA için sırasıyla %99.32, %99.83 ve %99.90 OA değerleri elde edilmiştir.

Bai ve diğ. [38], HG sınıflandırma için kovaryans havuzuna sahip hibrit bir 3B-2B ESA yöntemini geliştirmişlerdir. Önerilen yöntem, uzamsal-spektral öznitelikleri çıkaran 3B ESA ile başlamakta ve uzamsal öznitelikleri çıkaran 2B ESA ile devam etmektedir. Ek olarak, uzamsal-spektral özellik haritalarından ikinci dereceden bilgileri tam olarak çıkarmak için kovaryans havuzlama tekniği kullanılmıştır. 25x25 pencere boyutu ve %30 eğitim örneği alınarak IP, SA ve PU ile yapılan uygulamalar sonucunda sırasıyla %99.58, %100, %99.85 OA değerleri elde edilmiştir.

Zheng ve diğ. [39], HG sınıflandırma için bir uzamsal-spektral dikkat ağı önermişlerdir. Önerilen yöntem öncelikle basit 3B ESA katmanlarından oluşan uzamsal ve spektral modüllerden oluşmaktadır. Ardından, HG hiperküplerinin daha ayırt edici özelliklerini çıkarmak için dikkat modülü, uzamsal spektral modüllerin belirli konumlarına eklenmiştir. IP, PU ve SA ile ön işlem yapılmadan yapılan uygulamalarda sırasıyla %95.49, %98.02 ve %96.81 OA değerleri elde edilmiştir.

Gong ve diğ. [40], çok ölçekli bir sıkıştırma ve uyarma piramit havuzu ağı geliştirmişlerdir. Geliştirilen yöntem, bir sıkıştırma ve uyarma, çok ölçekli 3B ESA ve 2B ESA ile bir piramit havuzlama modüllerinden oluşmaktadır. IP, SA ve PU veri setleri ve %5, %0.5 ve %0.5 eğitim örnekleri kullanılarak, önerilen yöntemin OA değerleri sırasıyla %96.09, %97 ve %96.56'dır.

Ge ve diğ. [41], HG sınıflandırma için farklı filtre boyutları içeren 2B ve 3B evrişim katmanlarından oluşan çok dallı öznitelik füzyonuna dayalı bir yöntem önermişlerdir. Geliştirdikleri ağ mimarisinde aktivasyon fonksiyonu olarak Mish'i kullanmışlardır. %5

eđitim rneklemi ile IP, SA, PU ve BO zerinde yapılan uygulamalar sonucunda sınıflandırma dođruluđu sırasıyla %96.07, %99.94, %99.52 ve %96.44 olarak bulunmuştur.

Yang ve diđ. [42], HG sınıflandırma iin yeni bir Sinerjik ESA nermiřlerdir. nerilen yntem, hibrit 3B-2B ESA ve uzamsal-spektral zellik bilgilerini birleřtiren veri etkileřim modllerinden oluřmaktadır. Ayrıca, tamamen bađlı katmandan nce, karıřan bilgileri ve zellikleri etkili bir řekilde filtrelemeye yardımcı olan bir 3B dikkat mekanizması sunmuřlardır. Rastgele %30 eđitim rneđi alınarak IP, KUM ve BO kullanılarak elde edilen sınıflandırma dođruluk deđerleri sırasıyla %97.31, %98.92 ve %99.79'dur.

Fırat ve diđ. [43], HG sınıflandırması iin 3D ESA ve ResNet50 ynteminin birleřiminden oluřan bir yntem nermiřlerdir. nerilen yntemde, ađ mimarisi derinleřtiđinde karřılařılan bozulma, gradyanların yok olması probleminin ortadan kaldırılması ve yeterli uzamsal spektral zneliklerin ıkarılması amalanmaktadır. Boyut indirgeme yntemi olarak orijinal HG grntsne TBA uygulanmıřtır. nerilen yntemin sınıflandırma performansını test etmek iin SA ve PU veri setleri kullanılmıřtır. Pencere boyutu 25x25 olarak, TBA sonucunda her iki veri seti iin de 15 temel bileřen ve %30-70 test-eđitim oranı alınarak gerekleřtirilen uygulamalar sonucunda her iki veris etinde de %99.99 OA deđeri elde edilmiřtir.

He ve diđ. [44], HG sınıflandırması iin ortaklařa 1B spektral zelliđi ve 2B ok lekli uzamsal zelliđi đrenebilen ok lekli bir 3B derin ESA (M3B-ESA) nermiřlerdir. Herhangi bir boyut indirgeme yntemi kullanılmadan, 7x7 pencere boyutu alınarak gerekleřtirilen uygulamalarda IP iin %97.61, PU iin %98.49 ve SA iin %97.24 OA deđerleri elde edilmiřtir.

Zhong ve diđ. [45], HG sınıflandırması iin spektral-uzamsal residual ađ (SSRN) nermiřlerdir. SSRN, herhangi bir boyut kltme yntemi kullanmadan 3B hiperspektral kp girdi verisi olarak almaktadır. Residual bloklar, gradyanların geri yayılmasını kolaylařtıran kimlik eřleme yoluyla her 3B evriřim katmanını birbirine bađlamaktadır. 7x7 pencere boyutu, IP ve KUM veri setleri iin %20, PU iin %10 eđitim rneđi alınarak gerekleřtirilen uygulamalarda sırasıyla, %97.81, %99.01 ve %99.54 OA deđerleri elde edilmiřtir.

Meng ve diđ. [46], mevcut diđer derin đrenme tabanlı HG sınıflandırma modellerinden daha geniř olan yeni bir ESA modeli nermiřlerdir. nerilen yntem, katman sayısı arttıka daha derindeki ađın sınıflandırma dođruluđunun kademeli olarak artmasına

neden olduğu problemini çözmek için tasarlanmış yeni bir çok yollu residual ağ (MPRN) olarak adlandırılmaktadır. MPRN, ağda birden çok residual blok kullanarak ağı derinleştirmek yerine paralel olarak çok yollu residual bloklar kullanmaktadır. Bu sayede ağ daha derin değil daha geniş yapılmaktadır. Herhangi bir boyut indirgeme yöntemi kullanılmamaktadır. 11x11 pencere boyutu alınarak uygulamalar yapılmıştır. Uygulamalarda IP ve UH için %10, KUM için %2 eğitim örneği alınmıştır. Uygulamalar sonucunda IP, UH ve KUM için sırasıyla %99.16, 98.88 ve %96.00 OA değerleri elde edilmiştir.

Song ve diğ. [47], HG sınıflandırma için derin bir özellik füzyon ağı önermişlerdir. Önerilen yöntem, derin ağın eğitimini kolaylaştırabilen ve artan derinlikten yararlanabilen kimlik eşleme olarak birkaç evrimsel katmanı optimize etmek için residual öğrenmeyi kullanmaktadır. Bu şekilde, ağ daha derin özellikleri çıkarabilmektedir. Boyut indirgeme yöntemi olarak TBA kullanılmaktadır. TBA sonucunda IP, PU ve SA için, 27, 33 ve 27 temel bileşen uygulamalarda kullanılmaktadır. %10 eğitim örneği alınarak gerçekleştirilen uygulamalarda IP, PU, ve SA için sırasıyla %98.52, %98.73, %98.87 OA değerleri elde edilmiştir.

Liu ve diğ. [48], HG sınıflandırmada sınırlı eğitim örnekleri ile etkili eğitim elde etmek için yeni bir hafif karıştırılmış grup evrimsel sinir ağı önermişlerdir. Önerilen yöntem, farklı gruplarda atrous ve standart evrim kullanan karıştırılmış grup evrim birimlerini, ardından kanal karıştırma işlemi ve kısayol bağlantısını içermektedir. Bu şekilde, karıştırılmış grup ESA'lar daha az eğitilebilir parametrelere sahipken, daha az etiketli örnek ile hala doğru ve verimli bir şekilde eğitilebilmektedirler. Sınıflandırma doğruluğunu daha da iyileştirmek için karıştırılmış grup ESA'larda farklı HG veri setleri arasında transfer learning'de uygulanmaktadır. karıştırılmış grup ESA'ların HG sınıflandırması için etkinliğini değerlendirmek için, farklı sensörlerden HG'ler üzerinde önceden eğitilmiş üç genel HG veri seti üzerinde deneyler yapılmıştır. Deneyler sonucunda BO için %99.65, UH için %99.45 ve DC-Mall veri seti için %97.06 OA değerleri elde edilmiştir.

Roy ve diğ. [49], HG sınıflandırma için yeni bir uçtan uca morfolojik derin öğrenme çerçevesini (MorphConvHyperNet olarak adlandırılır) tanıtmışlardır. Önerilen yöntem, HG'nin eğitim süreci sırasında doğrusal olmayan bilgileri verimli bir şekilde modellemektedir. Ayrıca önerilen yöntem, HG giriş verilerinden ilgili öznelikleri çıkarmak için uzamsal ve spektral morfolojik bloklar içermektedir. Bu morfolojik bloklar, ilgili katmanlardaki iki temel 2 boyutlu morfolojik operatörden (erozyon ve genişleme) ve

ardından özellik haritalarının ağırlıklı bir kombinasyonundan oluşmaktadır. IP, PU ve UH veri setleri kullanılarak geliştirilen uygulamalar sonucunda sırasıyla %87.45, %95.51 ve %86.51 OA değerleri elde edilmiştir.

Ghosh, Roy ve diğ. [50], hiperspektral karıştırma çözme görevini yerine getirmek için bir evrişimli otomatik kodlayıcı ve bir transformatörün bir kombinasyonundan oluşan bir yöntem önermişlerdir. Hiperspektral veriler, evrişimli kodlayıcı tarafından kodlanmaktadır. Transformatör, kodlayıcıdan türetilen gösterimler arasındaki uzun menzilli bağımlılıkları yakalamaktadır. Hiperspektral veriler, bir evrişimli kod çözücü kullanılarak yeniden oluşturulmaktadır. Değerlendirme ölçütleri olarak, ortalama karesel hata ve spektral açı mesafesi kullanılmaktadır. Samson, Apex ve Washington DC Mall veri setleri üzerinde yapılan uygulamalarda, Samson'da 0.0783 ortalama karesel hata ve spektral açı mesafesi olarak da 0.0510 sonucu bulunmuştur. Benzer şekilde diğer veri setlerinde Apex için, 0.1264 ortalama karesel hata ve 0.0867 spektral açı mesafesi, Washington DC Mall için 0.1307 ortalama karesel hata ve 0.1537 spektral açı mesafesi sonuçları elde edilmiştir.

Roy ve diğ. [51], HG sınıflandırma için HG'ye ek olarak diğer çok modlu veri kaynaklarını kullanan yeni bir çok modlu füzyon transformatör ağını tanıtmışlardır. Geleneksel öznitelik birleştirme teknikleri kullanmak yerine, daha iyi genelleme elde edilmesine yardımcı olan, transformatör kodlayıcıda harici bir sınıflandırma belirteci olarak diğer çok modlu veriler kullanılmaktadır. Görüntü dönüştürücü ve diğer benzer dönüştürücü modelleri, rastgele başlatılan bir harici sınıflandırma belirteci kullanır ve iyi genelleme yapamaz. Bununla birlikte, ışık algılama ve mesafe belirleme (LiDAR) gibi diğer çok modlu veri kaynaklarından türetilen bir özellik yerleştirmenin kullanılması, bu modelleri bir harici bir sınıflandırma aracılığıyla geliştirme potansiyeli sunmaktadırlar. Uygulamalar kapsamında UH, Trento ve MUUFL veri setleri kullanılmıştır. 11x11 pencere boyutu alınarak gerçekleştirilen uygulamalarda sırasıyla %88.45, %97.76 ve %94.18 OA değerleri elde edilmiştir.

Ghaderizadeh ve diğ. [52], uzamsal-spektral özellikleri çıkarmak için bir 3B hızlı öğrenme bloğu (derinlemesine ayrılabilir evrişim bloğu ve hızlı bir evrişim bloğu) ve ardından bir 2B ESA kullanmışlardır. Buna ek olarak, aşırı öğrenme sorununu hafifletmek ve sınıflandırma sonuçlarını iyileştirmek için toplu normalleştirme, bırakma, üstel azalma öğrenme oranı ve L2 düzenleme dahil bir dizi optimizasyon yöntemi benimsenmiştir. Bu hibrit yöntemin performansını test etmek için SA, PU ve IP veri setleri üzerinde uygulamalar gerçekleştirilmekte ve sonuçlar aynı sayıda katmana sahip 2B ESA ve 3B ESA

derin öğrenme modelleri ile karşılaştırılmaktadır. Önerilen yöntemde IP için %10, PU ve SA için her sınıftan 100 eğitim örneği alınarak uygulamalar gerçekleştirilmiştir. Ayrıca pencere boyutu olarak 15x15 ve TBA boyut indirgeme yönteminden sonra 15 temel bileşen alınmıştır. Önerilen yöntem ile elde edilen OA değerleri SA, PU ve IP için sırasıyla %99.07, %98.90 ve %97.14'tür.

## 1.2 Tezin Amacı

Bu tez çalışmasının amacı, hiperspektral uydu görüntülerinin yüksek sınıflandırma doğruluğu elde edilerek sınıflandırılması için yeni derin öğrenme tabanlı yöntemler geliştirmektir. Bunun için hiperspektral görüntü sınıflandırma alanıyla ilgili var olan yöntemler detaylı incelenmiş olup, sınıflandırma performansını arttırmak için özgün derin öğrenme tabanlı yöntemler geliştirilerek literatüre katkılar sunulmaktadır.

## 1.3 Tezin Gerekçeleri

Bu tez kapsamında, hiperspektral uydu görüntülerinin hızlı ve etkili sınıflandırılması için farklı derin öğrenme tabanlı yöntemler geliştirilmiştir. Tezin gerekçeleri şu şekildedir:

- Hiperspektral görüntü sınıflandırma ile ilgili literatürde çalışmalar hızla artmaktadır. Bu durum, bu konunun hala popüler olduğunu göstermektedir. Konunun popülerliği tez konusunu seçmede etkili olmuştur.
- Hiperspektral görüntü sınıflandırması için literatürde her geçen gün farklı derin öğrenme tabanlı yöntemler geliştirilmektedir. Tez kapsamında, sınıflandırma performansını arttıracak özgün derin öğrenme tabanlı yöntemler geliştirme isteği tez konusu seçiminde etkili olmuştur.
- Son olarak daha kısa sürede hızlı ve doğru sınıflandırmanın yapılması hiperspektral görüntü sınıflandırma performansı açısından önemli olmasından dolayı yine tez konusu seçiminde etkili olmuştur.

## 1.4 Tezin Çıktıları

Bu tez çalışmasında, hiperspektral uydu görüntülerinin sınıflandırılması için derin öğrenmeye dayalı farklı yöntemler geliştirilmiştir. Geliştirilen yöntemler ile hiperspektral görüntülerin sınıflandırılmasına yönelik uygulamalarda sınıflandırma performansının

arttırılması amaçlanmıştır. Bu sayede hiperspektral görüntülerin daha hızlı ve yüksek sınıflandırma doğruluğu ile sınıflandırılması sağlanmıştır.

Tez çalışması sonucunda, tezin çıktıları daha çok akademik olarak ele alınmıştır. Önerilen derin öğrenme yöntemleri ile gerçekleştirilen uygulamalar sonucunda yapılan bilimsel çalışmalar aşağıda listelenmektedir.

*SCI-Expanded ve ESCI kapsamında olan dergilerde yayınlanan makaleler:*

- Fırat, H., Hanbay, D. (2022). 4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images. Journal of the Faculty of Engineering and Architecture of Gazi University, 2022.
- Fırat, H., Asker, M.E., Bayındır, M.İ., Hanbay, D. (2022). Hybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. Neural processing letters, 2022.
- Fırat, H., Asker, M.E., Hanbay, D. (2022). Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN. Remote Sensing Applications: Society and Environment, 2022.
- Fırat, H., Hanbay, D. (2022). Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması. Journal of the Faculty of Engineering and Architecture of Gazi University, 2022.

*Uluslararası konferanslarda yayınlanan bildiriler:*

- Fırat, H., Hanbay, D. (2021). Classification of Hyperspectral Images Using 3D CNN Based ResNet50. 2021 29th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- Fırat, H., Uçan, M. & Hanbay, D. (2021). Hibrid 3B-2B ESA Mimarisi Kullanılarak Hiperspektral Uzaktan Algılama Görüntülerinin Sınıflandırılması. Computer Science, 5th International Artificial Intelligence and Data Processing Symposium, (pp. 132-140).
- Fırat, H., Uçan, M. & Hanbay, D. (2021). MiniVGGNet Kullanılarak Hiperspektral Görüntü Sınıflandırma. Computer Science, 5th International Artificial Intelligence and Data Processing Symposium, (pp. 295-303).

*TR-Dizin kapsamında yayınlanan makaleler:*

- Fırat, H., Hanbay, D. (2022). 3 Boyutlu Evrişimsel Sinir Ağı Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması. Türk Doğa ve Fen Dergisi, 2022.
- Fırat, H., Asker, M.E., Hanbay, D. (2022). Hybrid 3D Convolution and 2D Depthwise Separable Convolution Neural Network for Hyperspectral Image Classification. Balkan Journal of Electrical and Computer Engineering, 2022.
- Fırat, H., Asker, M.E., Hanbay, D. (2022). Hiperspektral Görüntü Sınıflandırması için Derinlemesine Ayrılabilir Evrişim Tabanlı Artık Ağ Mimarisi. Gazi Üniversitesi-Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 2022.

### **1.5 Tezin Yenilikçi Yönü ve Ar-Ge Niteliği**

Tez çalışması kapsamında geliştirilen derin öğrenme tabanlı yöntemler, literatürde sıklıkla kullanılan veri setleri ile test edilmiştir. Ayrıca literatürdeki son teknoloji yöntemler ile sınıflandırma performansları açısından karşılaştırılmıştır. Sınıflandırma performansları incelendiğinde, geliştirilen yöntemler ile daha başarılı sınıflandırma sonuçlarının elde edildiği görülmektedir. Bu sonuçlar, geliştirilen yöntemlerin etkili, güvenilir, zaman açısından daha iyi ve yüksek sınıflandırma doğruluğunda çalıştığını göstermektedir. Hiperspektral görüntü sınıflandırması için geliştirilen yeni derin öğrenme tabanlı yöntemler tezin en büyük yeniliği olarak görülebilmektedir.

### **1.6 Tezin Organizasyonu**

Bu tez çalışması beş bölümden oluşmaktadır. Bölüm 1’de, tez konusu hakkında bilgiler verilmiş olup, kapsamlı literatür araştırması yapılmıştır. Tezin amacı, gerekçeleri, çıktıları, literatüre yapılmış olan katkıları açıkça belirtilmiştir. Son olarak tezin organizasyonu yine bu bölümde sunulmuştur.

Bölüm 2’de, hiperspektral uydu görüntülerinin sınıflandırılması amacıyla gerçekleştirilen temel adımlar ve bu adımlarda kullanılan boyut indirgeme ve derin öğrenme yöntemleri detaylı bir şekilde ele alınmıştır.

Bölüm 3’te hiperspektral uydu görüntülerinin sınıflandırılması amacıyla tez kapsamında kullanılan veri setleri ele alınmış olup, detaylı bir şekilde açıklanmıştır.



Bölüm 4'te hiperspektral uydu görüntülerinin sınıflandırılması için önerilen derin öğrenme tabanlı yöntemler ve bu yöntemlerle gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçları sunulmuştur.

Bölüm 5'te, tez çalışması kapsamında önerilen yöntemler ile gerçekleştirilen çalışmalardan elde edilen sonuçlar tartışılmış olup, literatüre özgün katkıları belirtilmiştir. Ayrıca, gelecekte yapılması planlanan çalışmalar hakkında da bilgilere yer verilmiştir.



## 2. HİPERSPEKTRAL UYDU GÖRÜNTÜLERİNİN SINIFLANDIRILMASI İÇİN KULLANILAN YÖNTEMLER

### 2.1 Boyut İndirgeme

#### 2.1.1 Temel Bileşen Analizi

Temel Bileşen Analizi (TBA), Hiperspektral görüntü sınıflandırmada sıklıkla kullanılan boyut indirgeme yöntemlerinden biridir. Orijinal hiperspektral görüntü verilerine TBA uygulandıktan sonra, uzamsal boyutlar korunurken, spektral boyutların sayısında önemli bir azalma olmaktadır. Özellikle, TBA, orijinal spektral bandların en büyük varyansa sahip birkaç ortogonal lineer kombinasyonunu (Temel Bileşenler) bularak verilerin boyutunu küçültmeyi ve boyutsal fazlalığı azaltmayı amaçlamaktadır. TBA'nın matematiksel temeli, hiperspektral görüntülerin spektral bandlarının kovaryans matrisinin özdeğer ayrıştırmasına dayanmaktadır. Hiperspektral görüntülerin pikselleri, boyutu spektral bandların sayısı ile aynı olan bir vektör olarak ayarlanmaktadır.  $X_i = [x_1, x_2, x_3, \dots, x_N]^T$ ,  $N$  hiperspektral görüntülerin spektral bandlarının sayısıdır. Tüm piksel vektörlerinin ortalaması Denklem (2.1)'e göre hesaplanmaktadır.

$$m = \frac{1}{M} \sum_{i=1}^M [x_1, x_2, x_3, \dots, x_N]_i^T \quad (2.1)$$

$M = p * q$ , “p” satırları ve “q” sütunlarından oluşan bir hiperspektral görüntü için piksel vektörlerinin sayısını göstermektedir. Kovaryans matrisi Denklem (2.2)'deki gibi hesaplanmaktadır.

$$C = \frac{1}{M} \sum_{i=1}^M (X_i - m)(X_i - m)^T \quad (2.2)$$

Kovaryans matrisinin öz ayrışması, yani öz değerleri, karşılık gelen öz vektörleriyle birlikte Denklem (2.3)'deki gibi gösterilmektedir.

$$C = ADA^T \quad (2.3)$$

$D$ ,  $C$ 'nin öz değerlerinden  $(\lambda_1, \lambda_2, \dots, \lambda_N)$  oluşan köşegen matristir ve  $A = a_1, a_2, a_3, \dots, a_N$ , sütun olarak karşılık gelen özvektörlere ( $N$  boyutunun her biri) sahip ortogonal matristir [57]. Doğrusal dönüşüm  $y_i = A^T X_i, i = 1, 2, \dots, M$ , orijinal hiperspektral görüntünün TBA'ya dönüştürülmüş spektral bandları olan değiştirilmiş piksel

vektörlerini elde etmek için uyarlanmıştır.  $A^T$  matrisinin ilk  $K$  satırı, satırların azalan düzende düzenlenmiş özdeğerlerine uygun özvektörler olacak şekilde seçilmektedir. Seçilen  $K$  satırları, hiperspektral görüntülerin spektral bandlarında yer alan bilgilerin çoğundan oluşan TBA spektral bandlarını vermek için piksel vektörü  $X_i$  ile çarpılmaktadır [51][52].

## 2.2 3B / 2B Evrişimsel Sinir Ağı

Hiperspektral uydu görüntülerinin sınıflandırılması için derin öğrenme teknikleri son zamanlarda yaygın olarak kullanılmaktadır. Evrişimsel sinir ağı (ESA), hiperspektral uydu görüntülerinin sınıflandırılmasında sıklıkla kullanılan derin öğrenme yöntemlerinden biridir. ESA, daha fazla ayırt edici özellik sağlayabilen güçlü bir özellik öğrenmeye sahip olduğundan, daha yüksek kalitede görüntü sınıflandırma işlemini yapabilmektedir. Sınıflandırma probleminde, öğrenilen özellikler ne kadar ayırt edici olursa, problemin çözümü de o kadar kolaylaşmaktadır [56]. Bu durum sınıflandırma performansını oldukça arttırmaktadır. ESA, evrişim (convolution), havuzlama (pooling), düzleştirme (flatten), tam bağlantılı (fully connected-FC) ve softmax katmanlarından oluşan derin bir yapay sinir ağıdır. Evrişim katmanı, girdi verilerine evrişim işlemi uygulayarak öznitelikleri çıkarmak için kullanılan ESA'nın ilk katmanıdır. Görüntü verilerinden faydalı bilgileri çıkarmak için hesaplanmanın gerçekleştiği ESA'nın yapı taşıdır.

Evrişim işlemi Şekil 2.1 ve Şekil 2.2'de gösterildiği gibi, girdi görüntü matrisinin ve çekirdek/filtre matrisinin iç çarpımı tarafından gerçekleştirilmektedir. Bu şekilde, çekirdek matrisi girdi görüntü matrisi üzerine belirtilen adım sayısı kadar sağa-sola, aşağı-yukarı kaydırılarak girdi görüntüsünün çıktısı (özellik haritası) oluşturulmaktadır.

a	b	c
d	e	f
g	h	i

Girdi

\*

w	x
y	z


Çekirdek / filtre

=

aw+bx+dy+ez	bw+cx+ey+fz
dw+ex+gy+hz	ew+fz+hy+iz

Çıktı


Şekil 2. 1: Evrişim işleminin matematiksel gösterimi.



**Şekil 2. 2:** Evrişim işlemi ile ilgili örnek bir uygulama gösterimi (adım (stride) değeri 1).


Havuzlama katmanı, evrişim işlemi sonucunda elde edilen çıktının (özellik haritası) genişliğini ve yüksekliğini özelliklerini kaybetmeden azaltmaktadır. Bu işlemi gerçekleştirmek için bir çekirdek/filtre kullanılmaktadır. Evrişim katmanında olduğu gibi çekirdek, havuzlama katmanında da girdi görüntü matrisi üzerinde hareket etmektedir. Ancak evrişim işlemi yerine belirtilen havuzlama yöntemi uygulanmaktadır. ESA’da genellikle kullanılan iki farklı havuzlama yöntemi vardır. Maksimum ve ortalama havuzlama. Şekil 2.3’te gösterildiği gibi 6x6 boyutundaki görüntü üzerinde 3x3 boyutunda bir filtre kullanıldığında, maksimum havuzlama yapmak istenildiğinde filtrenin kapsadığı alandaki en büyük değer alınıp çıktı matrisine kaydedilmektedir. Ortalama havuzlama yapmak istenildiğinde ise filtrenin kapsadığı alandaki girdi piksel değerlerinin ortalaması alınıp çıktı matrisine kaydedilmektedir. Havuzlama işlemleri ile uzamsal boyut azaltılmakta

ve önemli özellikler korunmaktadır. Havuzlama işlemi bazı verilerin kaybolmasına neden olsa da, havuzlama katmanlarını kullanmanın faydaları, özelliklerin karmaşıklığını azaltmak, aşırı öğrenmeye daha az eğilimli hale getirmek, hesaplamaları hızlandırmak ve ESA'nın verimliliğini arttırmaktır.



**Şekil 2. 3:** Havuzlama işlemleri ile ilgili örnek uygulama gösterimi.

Düzleştirme katmanı, verileri son ve en önemli katman olan tam bağlantılı katmanın girişinde hazırlamaktadır. Genel olarak, sinir ağları, tek boyutlu bir diziden girdi verilerini almaktadır. Bu sinir ağındaki veriler, evrişim ve havuzlama katmanlarından elde edilen tek boyutlu matris dizisidir. Tam bağlantılı katman, verileri düzleştirilmiş katmandan almakta ve öğrenme sürecini sinir ağı üzerinden gerçekleştirmektedir. Tam bağlantılı katman, alt katmandaki her nöronu üst/sonraki katmandaki her nörona bağlamaktadır. Çoğunlukla, evrişim/havuzlama katmanlarından sonra bir modelin son birkaç katmanı olarak kullanılmaktadır. Bu katman, önceki katmanın çıktısını almakta ve sınıf etiketlerinin olasılıklarını tahmin etmek için ağırlıklar atamaktadır. Çok sayıda bağlantı nedeniyle, hesaplama yükünü önemli ölçüde arttıran çok sayıda parametrenin ayarlanması gerekmektedir. Ayrıca, çok sayıda parametre nedeniyle model, aşırı öğrenmeye (overfitting) karşı daha duyarlı hale gelmektedir. Bununla birlikte, aşırı öğrenmenin etkisini azaltmak veya ağın veriyi ezberlemesini önlemek için tam bağlantılı her katmandan sonra bir bırakma (dropout) katmanı kullanılmaktadır [58]. Bu katman Şekil 2.4'te gösterildiği belirli bir bırakma oranına (dropout rate) göre eğitim sırasında bazı nöronları ağdan çıkarmaktadır. Bırakma katmanı, eğitim sırasında, ağıdaki tüm ağırlıkları öğrenme fikri yerine, ağıdaki ağırlıkların yalnızca bir kısmını öğrenmeye zorlamaktadır. Ayrıca, her yinelemeden sonra, bazı nöronların sürece hakim olmasını önlemek için farklı nöron grupları etkinleştirilmektedir. Bu durum, aşırı öğrenme problemini önlemeye yardımcı olmakta ve ağın daha önce görmediği veriler üzerinde iyi tahminler yapabilen daha derin ve daha büyük ağ mimarilerinin oluşmasına izin vermektedir.




**Şekil 2. 4:** (a) Standart sinir ağı, (b) Dropout uygulandıktan sonraki sinir ağı

ESA tabanlı yöntemlerde verilerin doğrusal olmayan özelliklerini öğrenmek için tam bağlantılı ve evrişim katmanlarından sonra bir aktivasyon katmanı kullanılmaktadır. Aktivasyon katmanında, önceki katmanlardan gelen özellik haritaları, bir aktivasyon haritası oluşturmak için bir aktivasyon fonksiyonundan geçirilmektedir. Yaygın olarak kullanılan bazı aktivasyon fonksiyonları sigmoid, hiperbolik tanjant (tanh), ReLU, Leaky ReLU ve softmax'tir. Ancak hiperspektral görüntü sınıflandırma için yaygın olarak kullanılan aktivasyon fonksiyonları softmax ve ReLU'dur. Softmax, hiperspektral görüntü sınıflandırma için son katman olarak kullanılan aktivasyon fonksiyonudur. Softmax fonksiyonu sonucunda sınıflandırma işleminde kullanılacak sınıfların olasılık dağılımları oluşturulmaktadır. Her sınıf için üretilen olasılık değeri 0 ile 1 arasındadır. Tüm sınıfların toplam olasılık değeri 1'e eşittir [22]. ReLU ise, ESA'da en sık kullanılan aktivasyon fonksiyon olduğundan, tüm evrişim katmanlarında kullanılmaktadır. Özellikle eğitim inişi ve eğitim süresi açısından diğer aktivasyon işlevlerinden daha hızlı olma eğilimindedir [9]. ReLU Denklem (2.4)'deki gibi hesaplanmaktadır.

$$ReLU(t) = \max(0, t) \quad (2.4)$$

ESA'lar, Hiperspektral uydu görüntülerinin sınıflandırması için en güçlü derin öğrenme yöntemlerinden biridir. Uygulamalarda uzamsal tabanlı, spektral tabanlı ve hem spektral hem de uzaysal tabanlı olmak üzere 3 farklı biçimde kullanılmaktadırlar [59]. Spektral özelliklere dayalı sınıflandırma yönteminde, Hiperspektral görüntüler çok zengin spektral bilgiye ve son derece yüksek spektral çözünürlüğe sahiptir. Her piksel, tek boyutlu spektral vektörleri çıkarabilmektedir. Bu vektörler spektral bilgilerden oluşmaktadır. Yalnızca tek boyutlu spektral vektörler kullanılarak yapılan sınıflandırmaya, spektral bilgilere dayalı sınıflandırma yöntemi denilmektedir. Spektral bilgiye dayalı sınıflandırma

yönteminde genellikle piksel, spektral bilgiyi çıkarmak veya sınıflandırmak için özellik çıkarımı yoluyla spektral bilgiden belirli spesifik özellikleri elde etmek için kullanılmaktadır. Bu yöntemde, Hiperspektral görüntülerin spektral özellikleri çıkarmak ve sınıflandırmak için 1 boyutlu evrişimsel sinir ağı (1B ESA) mimarisi kullanılmaktadır. 1B ESA mimarileri kullanılarak yalnızca spektral bant özellikleri çıkarılmaktadır. Bu öznelikleri çıkarmak için uygulanan yöntem ise oldukça kolay ve basittir. Bununla birlikte, 1B ESA mimarilerinin kullanımı, spektral bağlamları göz ardı ederek, son derece zayıf sınıflandırma doğruluğuna neden olmaktadır [60]. 1B ESA kullanılarak hiperspektral görüntü sınıflandırma süreci Şekil 2.5'teki gibidir.



**Şekil 2. 5:** 1B ESA'nın şematik gösterimi

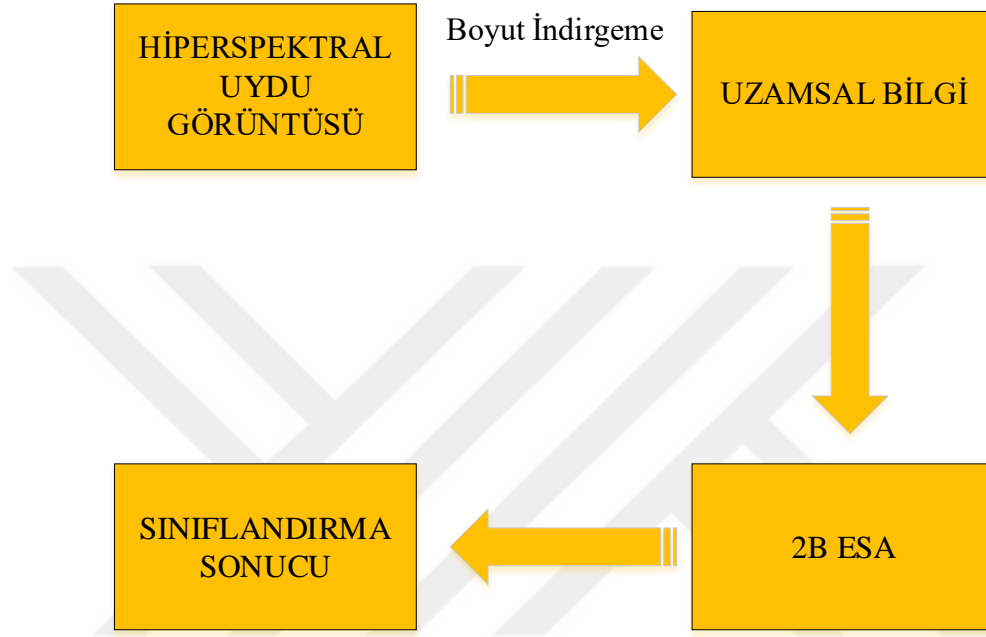
Tek boyutlu evrişim işleminde, tek boyutlu bir özellik vektörü üzerinde bir evrişim işlemi gerçekleştirmek için tek boyutlu bir evrişim çekirdeği kullanılmaktadır. Matematiksel gösterimi Denklem (2.5)'teki gibidir.

$$t_{ij}^x = f\left(\sum_m \sum_{h=0}^{H_l-1} k_{ljm}^h t_{(l-1)m}^{(x+h)} + bias_{lj}\right) \quad (2.5)$$

Denklem (2.5)'de  $k_{ljm}^h$ ,  $h$  konumundaki  $j$ . katmandaki  $l$ . evrişim çekirdeğinin değerini temsil etmektedir. Evrişim çekirdeği,  $(l - 1)$  katman ağındaki  $m$ . özellik vektörüne bağlıdır.  $H_l$ , tek boyutlu evrişim çekirdeğinin uzunluğunu temsil etmektedir.  $t_{(l-1)m}^{(x+h)}$ ,  $(l - 1)$ . katmandaki  $(x + h)$  konumundaki  $m$ . özellik haritasının spesifik değerini,  $f(\cdot)$  aktivasyon fonksiyonunu,  $t_{ij}^x$ ,  $l$ . katmandaki  $j$ . özellik haritasında  $(x)$  konumundaki çıktıyı temsil etmektedir.

Uzamsal tabanlı yöntemlerde, 2B ESA mimarileri kullanılarak, uzamsal öznelik bilgisi çıkarılmaktadır. Uzamsal bilgiye dayalı sınıflandırma yapılırken, belirli bir pikselden çıkarılan spektral bilgi yerine, pikselin komşuluğundan çıkarılan uzamsal bilgi kullanılmaktadır. 2B ESA mimarilerini kullanan çoğu yöntem, hiperspektral görüntülerin boyutunu azaltmak için ön işleme adımı olarak boyut indirgeme kullanılmaktadır. Bu sınıflandırma yönteminde, uzamsal ve spektral öznelik bilgisi ayrı ayrı çıkarıldığından, hiperspektral görüntü sınıflandırması için oldukça önemli olabilecek ortak uzamsal spektral öznelik bilgisinden tam olarak yararlanılamaz. Ayrıca, 2B ESA kullanımı ile spektrumdaki bazı bilgiler kaybolacaktır. Bu durum arazi örtüsü sınıflarının ayırt edilmesini zorlaştıracak

ve sınıflandırma performansı düşecektir [61]. 2B ESA kullanılarak hiperspektral görüntü sınıflandırma süreci Şekil 2.6'daki gibidir. İki boyutlu evrişim işlemi ile tek boyutlu evrişim işlemi arasındaki temel fark, evrişim katmanının ve havuzlama katmanının çekirdek boyutlarıdır. İki boyutlu evrişim işlemi, iki boyutlu veriler üzerinde bir evrişim işlemi gerçekleştirmek için iki boyutlu bir evrişim çekirdeği kullanmaktadır. 2B ESA'nın matematiksel gösterimi Denklem (2.6)'daki gibidir.



Şekil 2. 6: 2B ESA'nın şematik gösterimi

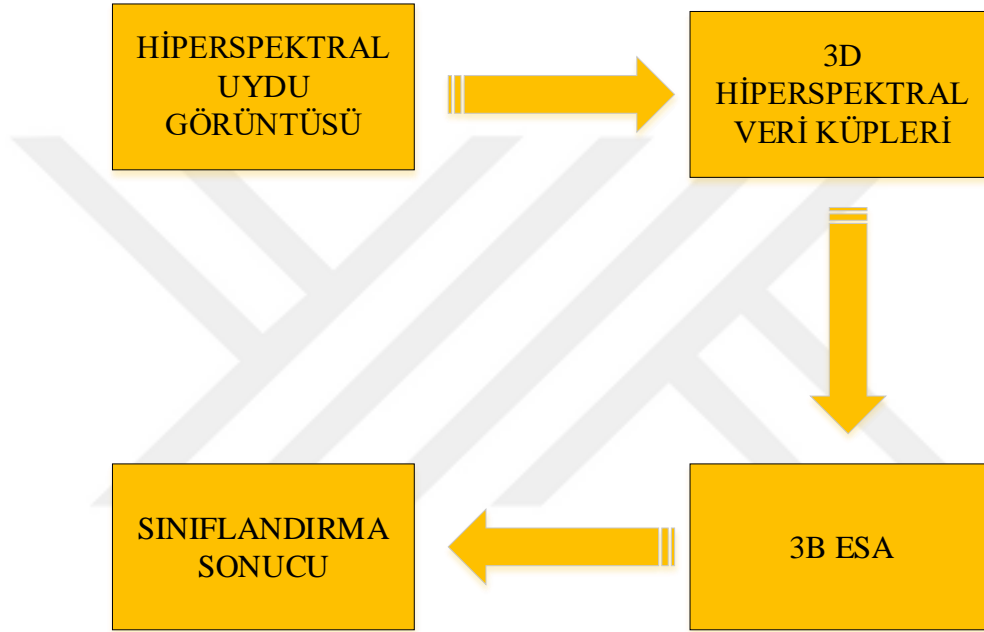
$$t_{ij}^{xy} = f \left( \sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} k_{ljm}^{hw} t_{(l-1)m}^{(x+h)(y+w)} + bias_{lj} \right) \quad (2.6)$$

Denklem (2.6)'da  $k_{ljm}^{hw}$ ,  $l$ . katmandaki  $j$ . evrişim çekirdeğinin  $(h, w)$  konumundaki değerini temsil etmekte ve bu evrişim çekirdeği,  $l - 1$  katmanındaki  $m$ . öznelik haritasına bağlanmaktadır. Sırasıyla  $H_l$  ve  $W_l$ , evrişim çekirdeğinin yüksekliğini ve genişliğini temsil etmektedir.  $t_{(l-1)m}^{(x+h)(y+w)}$ ,  $(l - 1)$ . katmandaki  $(x + h, y + w)$  konumundaki  $m$ . özellik haritasının spesifik değerini,  $f(.)$  aktivasyon fonksiyonunu,  $t_{ij}^{xy}$ ,  $l$ . katmandaki  $j$ . özellik haritasında  $(x, y)$  konumundaki çıktıyı temsil etmektedir.

Hiperspektral veriler, hem tek boyutlu spektral bilgi hem de iki boyutlu uzamsal bilgi içeren üç boyutlu bir yapı sunmaktadır. Bundan dolayı, spektral-uzamsal tabanlı yöntemlerde, hem spektral hem de uzamsal öznelik bilgileri 3B ESA mimarileri kullanılarak birleştirilmektedir. 3B ESA mimarisi, komşuluk çıkarımı ile ağın giriş verileri



için belirli bir pencere boyutu seçmektedir. Ayrıca, 3B ESA ile, daha başarılı sınıflandırma doğruluğu elde etmek için orijinal hiperspektral görüntülerden eş zamanlı olarak spektral-uzamsal özellikler çıkarılmaktadır. 3B ESA mimarileri, hiperspektral küplerin ortak uzamsal-spektral özellik bilgilerini öğrenebildikleri için, hiperspektral görüntü sınıflandırmasının performansını arttırmaktadır. Bu durum bu yöntemin giderek daha fazla ilgi görmesini sağlamaktadır. 3B ESA kullanılarak hiperspektral görüntü sınıflandırma süreci Şekil 2.7'deki gibidir. 3B ESA'nın matematiksel gösterimi ise Denklem (2.7)'deki gibidir.



Şekil 2. 7: 3B ESA'nın şematik gösterimi

$$t_{lj}^{xyz} = f \left( \sum_m \sum_{h=0}^{H_l-1} \sum_{w=0}^{W_l-1} \sum_d^{D_l-1} k_{ljm}^{hwd} t_{(l-1)m}^{(x+h)(y+w)(z+d)} + bias_{lj} \right) \quad (2.7)$$


### 2.3 3B ESA Kullanılan Evrişimsel Sinir Ağı Mimarileri

ESA'ya dayalı pek çok derin öğrenme mimarileri geliştirilmiştir. Bu tez çalışması kapsamında LeNet5, AlexNet, GoogleNet, Inception modülü, VGG16, ResNet18 ve ResNet50 mimari ile çalışmalar yapılmıştır. Bu mimariler genellikle 2B ESA ile birlikte kullanılmaktadır. Hiperspektral görüntüler, 3B olduğundan ve hem uzamsal hem de spektral

boyutlardan eş zamanlı özellikler çıkarılmak istendiğinden dolayı, derin öğrenme mimarileri 3B ESA ile birlikte kullanılmıştır.

### 2.3.1 LeNet5


Bu mimari, 1998 yılında Yann LeCun vd. tarafından geliştirilmiştir. Bu derin öğrenme mimarisi, 'Belge Tanımaya Uygulanan Gradyan Tabanlı Öğrenme' araştırma makalesinde önerilen en eski önceden eğitilmiş modellerden biridir [62]. LeNet5, el yazısı ve makine baskılı karakterleri tanımak için ve MNIST veri setine dayalı olarak bankalar tarafından el yazısıyla yazılan çekleri tespit etmek için kullanılmıştır. Diğer tüm ConvNet'ler için standart şablon olarak kabul edilmektedir. Bu derin öğrenme mimarisinin popüleritesinin arkasındaki ana neden, basit ve anlaşılır bir mimariye sahip olmasıdır. Ayrıca görüntü sınıflandırması için çok katmanlı bir evrişim sinir ağı mimarisi sunmaktadır. LeNet-5 mimarisi Şekil 2.8'de gösterildiği gibi iki evrişim katmanından, iki ortalama havuzlama katmanından, bir düzleştirme katmanından, iki tam bağlantılı katmandan ve elde edilen özellikleri ilgili sınıfa sınıflandıran bir softmax sınıflandırıcıdan oluşmaktadır. Bu tez çalışması kapsamında 3B ESA tabanlı LeNet5 mimarisi kullanıldığı için evrişim ve ortalama havuzlama katmanlarında kullanılan filtre boyutları 3 boyutludur. Birinci evrişim katmanında (5x5x5) filtre boyutuna sahip 6 filtre, ikinci evrişim katmanında (5x5x5) filtre boyutuna sahip 16 filtre kullanılmaktadır. Her iki ortalama havuzlama katmanında da kullanılan filtre boyutu (2x2x2) 'dir. Evrişim katmanlarından sonra, ağı daha düzenli hale getirmek ve öğrenme sürecinin aşırı uyum göstermesini önlemek için batch normalization (BN) kullanılmıştır. Burada doğrusal olmayan aktivasyon fonksiyonu olarak RELU kullanılmıştır. Evrişim ve ortalama havuzlama katmanlarından sonra çıktı düzleştirilir ve sonunda sırasıyla 120 ve 84 nörondan oluşan iki tam bağlantılı katman (Fully connected-FC)'dan geçtikten sonra softmax aktivasyon fonksiyonu ile sınıf sayısına indirgenmektedir. Aşırı öğrenmeyi önlemek için, tamamen bağlı her katmandan sonra %0.4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır.



Şekil 2. 8: LeNet5 mimarisi.

### 2.3.2 AlexNet

Mimari, 2012 yılında Alex Krizhevsky vd. tarafından “Imagenet Classification with Deep Convolution Neural Network” adlı araştırma makalesinde önerilmiştir [63]. Bu mimaride ağıın derinliği LeNet5'e göre arttırılmıştır. AlexNet mimarisi Şekil 2.9'da gösterildiği gibi 5 evrişim katmanından (conv), 3 maksimum havuzlama katmanından (MaxPooling), 2 tam bağlantılı katmandan (FC), düzleştirme (flatten) ve softmax katmanından oluşmaktadır. Her evrişim katmanından sonra, ağı daha düzenli hale getirmek için Batch normalization (BN) ve doğrusal olmayan aktivasyon fonksiyonu olan ReLU kullanılmaktadır. Tezde AlexNet mimarisi 3B ESA ile kullanıldığından, AlexNet mimarisinin ilk evrişim katmanında (11x11x11) filtre boyutuna sahip 96 filtre, ikinci evrişim katmanında (5x5x5) filtre boyutuna sahip 256 filtre, üçüncü, dördüncü ve beşinci evrişim katmanlarında (3x3x3) filtre boyutuna sahip sırasıyla 384, 384 ve 256 filtre kullanılmaktadır. Tüm maksimum havuzlama katmanları (3x3x3) filtre boyutundadır. Üçüncü maksimum havuzlama katmanından sonra elde edilen çıktı düzleştirilmekte ve sonunda sırasıyla 4096 nöronlu oluşan iki tam bağlantılı katman (Fully connected-FC)'dan geçtikten sonra softmax aktivasyon fonksiyonu ile sınıf sayısına indirgenmektedir. Aşırı öğrenmeyi önlemek için, tamamen bağlı her katmandan sonra %0.4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır.

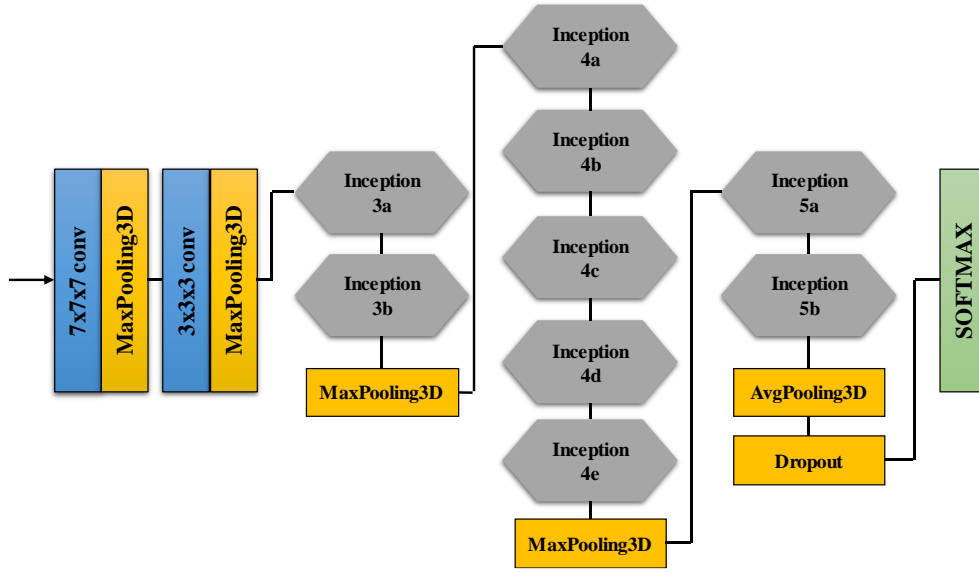


Şekil 2. 9: AlexNet mimarisi.

### 2.3.3 GoogleNet

Bir ağı derinleştikçe aşırı öğrenme problemiyle karşı karşıya kalabilmektedir. Bu problemi çözmek için, "Going deeper with convolutions" araştırma makalesinde Szegedy ve arkadaşları tarafından, aynı düzeyde çalışabilen birden çok boyutta filtrelere sahip olma fikriyle ve geleneksel ESA'lara kıyasla hesaplama karmaşıklığını azaltmak amacıyla 2015 yılında GoogleNet mimarisi önerilmiştir [64]. Bu fikirle, ağı aslında daha derinden daha geniş hale gelmektedir. GoogleNet mimarisi Şekil 2.10'da gösterildiği gibi 22 katman (havuzlama katmanları dahil 27 katman) derinliğindedir. Toplamda doğrusal olarak yığılmış 9 Inception

modülü ağı yapı taşı oluşturmaktadır (Şekil 2.14). Inception modülünün arkasındaki motivasyon, ince bilgileri kaybetmeden alıcı alanı arttırmaktır. Tez kapsamında bu ağı mimarisi 3B ESA ile birlikte kullanılmaktadır. Şekil 2.10'da gösterildiği gibi ağı mimarisinin ilk evrişim katmanında (7x7x7) filtre boyutunda 64 filtre kullanılmaktadır. Ardından (3x3x3) filtre boyutunda maksimum havuzlama işlemi gerçekleştirilmektedir. İkinci evrişim katmanında (3x3x3) filtre boyutunda 192 filtre kullanılmaktadır. Ardından tekrar (3x3x3) filtre boyutunda maksimum havuzlama işlemi gerçekleştirilmektedir. İlk iki evrişim ve maksimum havuzlama katmanlarından sonra ard arda 9 Inception modülü kullanılmaktadır. Inception modülü Şekil 2.14'te gösterildiği gibi (1x1x1), (3x3x3), (5x5x5) evrişim katmanlarından ve bir tane (3x3x3) maksimum havuzlama katmanının birleşiminden oluşmaktadır. Inception modülünün kullanılmasının iki ana avantajı vardır: i) her katmanda farklı boyutlarda filtreler kullanarak daha doğru konumsal bilgileri tutmaktadır; ayrıca ii) ağı serbest parametrelerinin sayısını önemli ölçüde azaltmakta, bu da ağı aşırı öğrenme problemini önlemeye yardımcı olmasına ve daha derin olmasına izin vermektedir. GoogleNet mimarisinde bazı Inception modülleri arasında (3x3x3) filtre boyutunda maksimum havuzlama katmanları kullanılmaktadır. Bu maksimum havuzlama katmanlarının amacı, ağı üzerinden beslenirken girdiyi aşağı örneklemektir. Bu, girdi verilerinin yüksekliğinin ve genişliğinin azaltılmasıyla elde edilmektedir. Inception modülleri arasındaki giriş boyutunun azaltılması, ağı hesaplama yükünü azaltmanın bir başka etkili yöntemidir. En son Inception modülünden (Inception5b) sonra elde edilen tüm özellik haritalarının (1x1x1) filtre boyutunda ortalama havuzlama katmanı (AvgPooling) kullanılarak ortalaması alınmaktadır. Ardından elde edilen özellik haritası çıktısı düzleştirilmekte ve doğrusal katmandan hemen önce %0.4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır. En sonda ise softmax aktivasyon fonksiyonu kullanılarak istenilen sınıf sayısına indirgeme işlemi gerçekleştirilmektedir.



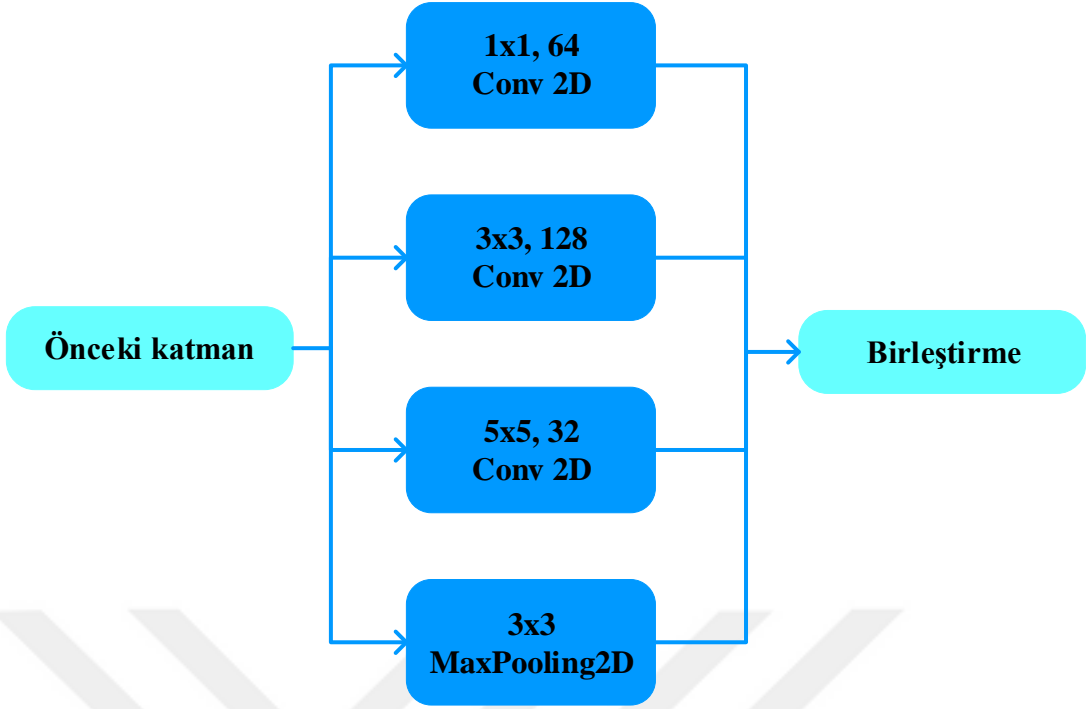
Şekil 2. 10: GoogleNet mimarisi.

### 2.3.4 3B / 2B Inception modülü

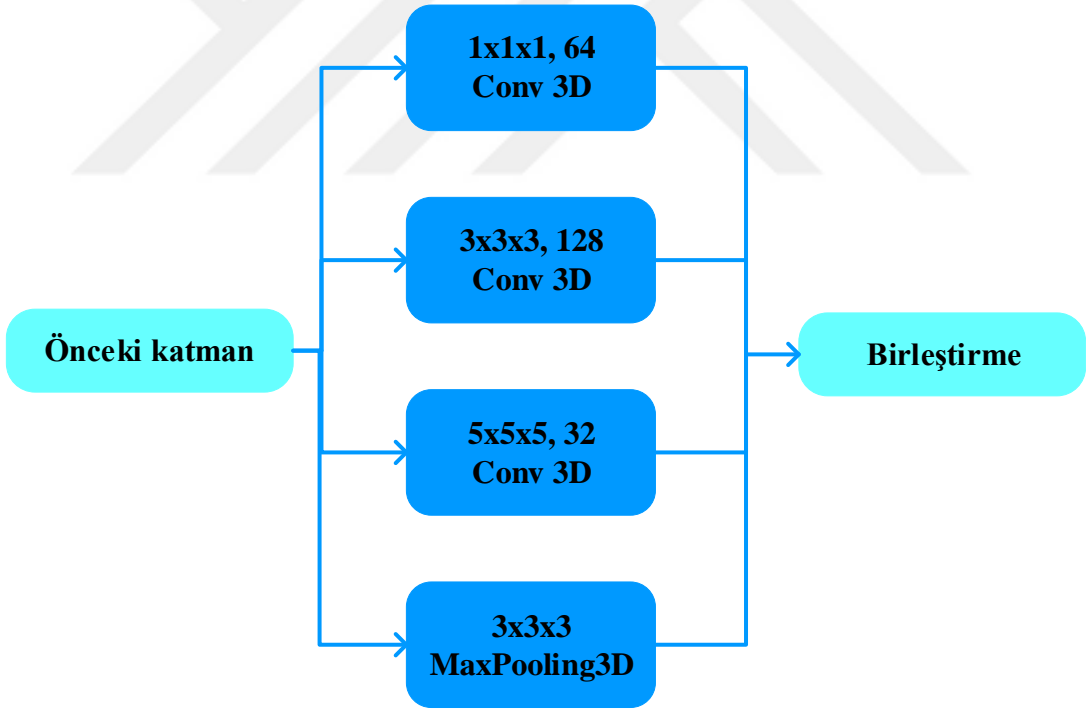
Herhangi bir derin öğrenme mimarisinin performansını iyileştirmenin en temel yolu, daha fazla katman ekleyerek mimariyi daha derin ve daha geniş hale getirmektir. Ancak bu durum, hesaplama karmaşıklığını artırmakta ve aşırı öğrenme problemine neden olmaktadır. Bu nedenle, seyrekliği yerel olarak kullanabilen ve ESA ile değiştirilebilen bir yöntem ihtiyacı vardır. Inception mimarisi kullanılarak bu problemlerin üstesinden gelinmektedir [65]. Inception mimarisi, Inception modülleri adı verilen tekrarlanan bileşenlerden oluşan bir mimari tasarıma sahip sinir ağıdır. Inception modülleri, yığılmış 1x1 evrişim katmanlarını kullanarak boyutsallık azaltma yoluyla daha derin ağ yapılarına ve daha verimli hesaplamalara izin vermek için ESA'larda kullanılmaktadır. Inception modülünde, 1x1, 3x3, 5x5 çekirdek boyutunda 2B evrişim ve 3x3 maksimum havuzlama işlemleri aynı giriş verileri kullanılarak paralel olarak yapılmakta ve çıktıları tek bir çıktıda birleştirilmektedir. 1x1 evrişim katmanları kullanılarak ağdaki giriş verilerinin boyutları küçültülmektedir. Yani 1x1 evrişim sayesinde görüntünün genişlik, yükseklik ve derinlik (kanal) sayısı azaltılmaktadır. 1x1 evrişim ile model, görüntünün derinliği boyunca öğrenilmektedir. 1x1 evrişim yalnızca veri boyutunu küçültmekle kalmaz, aynı zamanda ağı daha fazla öğrenmesini sağlamaktadır. 3x3 ve 5x5 evrişim katmanları ile ağ, uzamsal özellikleri farklı ölçeklerde öğrenmektedir. 3x3 maksimum havuzlama katmanı kullanılarak görüntünün genişliği ve yüksekliği azaltılmaktadır. Ancak, aynı anda farklı özelliklerin çıkarılmasına izin vermektedir. Bu nedenle, girdi verilerinden daha fazla özellik çıkarmak için maksimum havuzlama kullanılmaktadır. ESA'da kullanılan evrişim ve maksimum havuzlama işlemleri

aynı seviyede gerçekleştirilecek şekilde yapılandırıldıkça ağ kademeli olarak genişlemektedir. Farklı çekirdek boyutlarına sahip evrişim katmanlarını paralel olarak kullanmak, nesnelere birden çok ölçekte daha iyi işlenmesini sağlamaktadır. Yalnızca bu evrişim ve maksimum havuz katmanlarını kullanmak, Inception modülünün en basitleştirilmiş sürümünü oluşturmada ve Naive Inception modülü olarak adlandırılmaktadır. Naive inception modülünün 2B ve 3B versiyonları sırasıyla Şekil 2.11 ve Şekil 2.12'de gösterilmiştir. 2B versiyonda, evrişim (1x1, 3x3, 5x5) ve maksimum havuzlama (3x3) katmanlarının çekirdek boyutları 2 boyutludur. 3B versiyonda ise, evrişim (1x1x1, 3x3x3, 5x5x5) ve maksimum havuzlama (3x3x3) katmanlarının çekirdek boyutları 3 boyutludur.

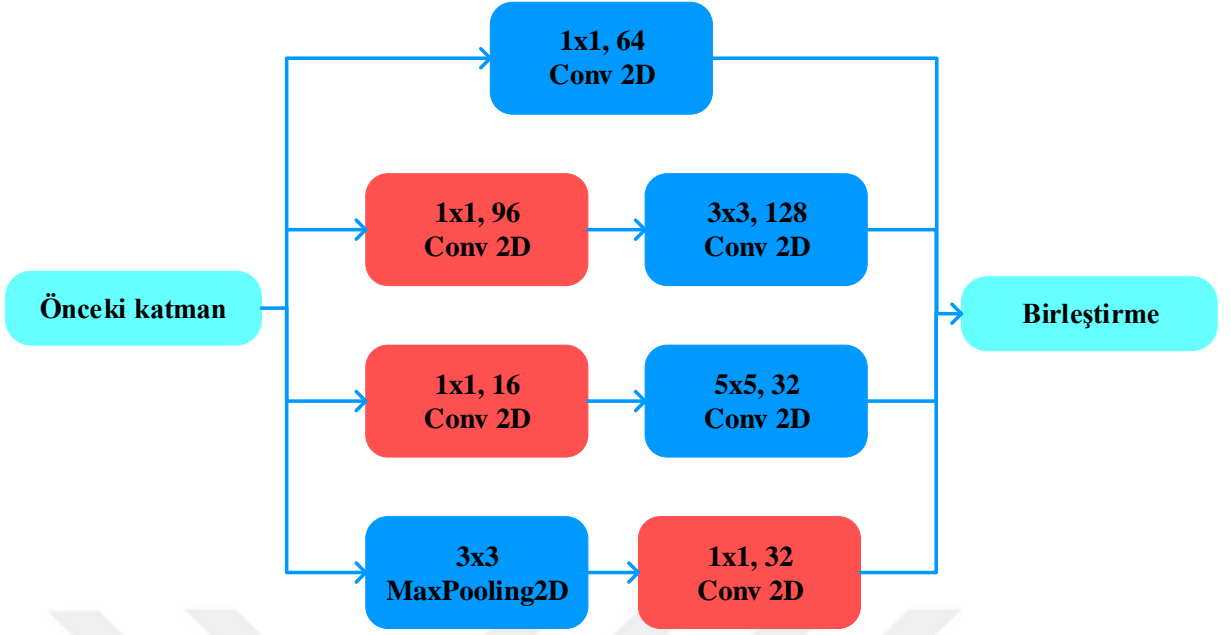
Naive Inception modülü, değişken filtre boyutuna sahip evrişimleri kullanarak farklı ölçelerde uzamsal özelliklerin öğrenilmesini sağlamaktadır. Ancak bu modül ile evrişim katmanlarında gerçekleştirilen matematiksel işlemler sonucunda hesaplama maliyeti (ağdaki eğitilebilir parametre sayısı) artmaktadır. Naive Inception modülü, artan hesaplama maliyeti sorununu çözememektedir. Bu durum, Inception mimarisinin kullanımını dezavantajlı hale getirmektedir. Hesaplama maliyetini düşürmek için naive inception modülüne 3x3 ve 5x5 evrişim katmanlarından önce ve maksimum havuzlama katmanından sonra 1x1 evrişim katmanları eklenmektedir. Inception modülüne eklenen 1x1 evrişim katmanları sayesinde, giriş verilerinin boyutu azaltılmakta ve modelin giriş verilerinin derinliği boyunca öğrenilmesi sağlanmaktadır. Bu modül, Complete Inception modülü olarak adlandırılmaktadır. Complete Inception modülündeki boyut küçültme ve paralel evrişim katmanları, gerçekleştirilen işlem sayısını ve eğitilebilir parametre sayısını önemli ölçüde azaltarak, hesaplama maliyetlerinden ve bellekten verimli bir şekilde tasarruf sağlamaktadır. Tez çalışması kapsamında gerçekleştirilen uygulamalarda Complete Inception modülü kullanılmıştır. Complete Inception modülünün 2B ve 3B versiyonları sırasıyla Şekil 2.13 ve Şekil 2.14'te gösterilmiştir. Ayrıca Complete Inception 3B ve Inception 2B modüllerinin ayrıntılı yapısı sırasıyla Çizelge 2.1 ve Çizelge 2.2'de açıklanmıştır.



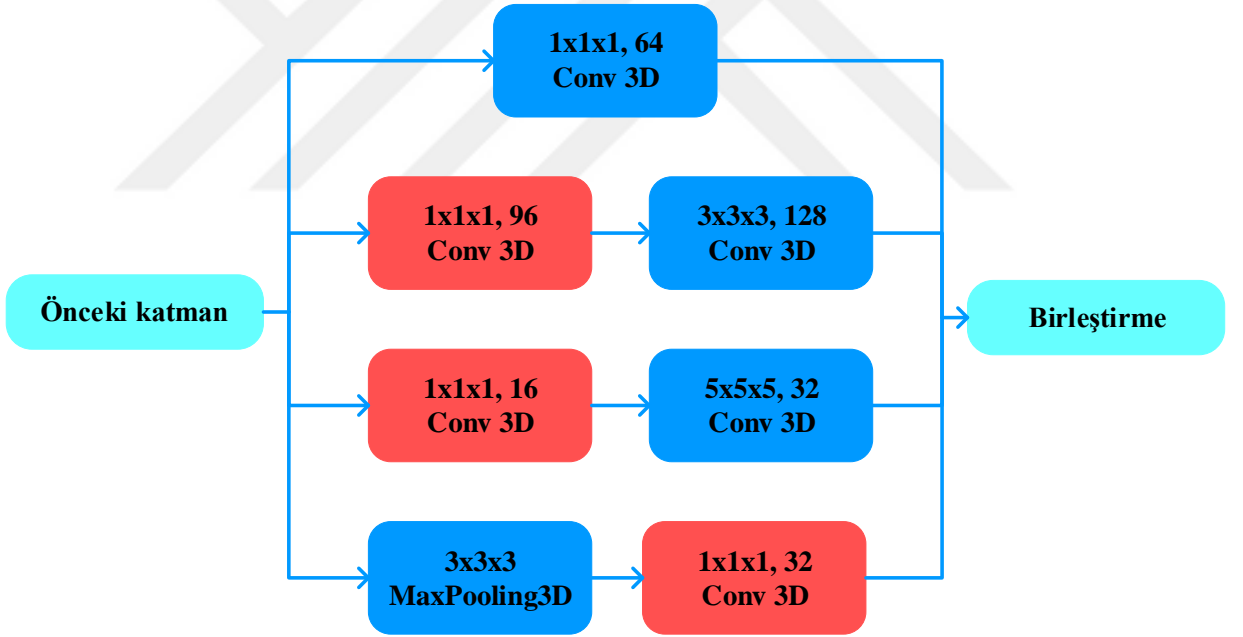
Şekil 2. 11: Naive Inception 2B modülü.



Şekil 2. 12: Naive Inception 3B modülü.



Şekil 2. 13 : Complete Inception 2B modülü.



Şekil 2. 14: Complete Inception 3B modülü.



**Çizelge 2. 1:** Complete Inception 3B modülünün ayrıntılı yapısı [34]

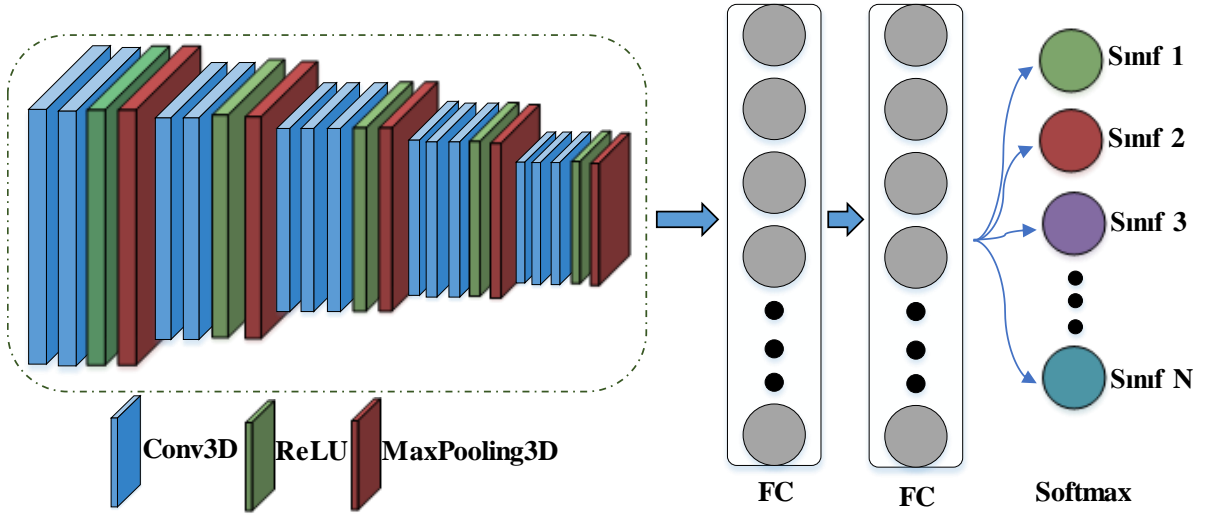
Katman	Katman Detayı	Activation	Bağlı olduğu katman
Conv3D_1a	filters=96, kernel_size=1x1x1, padding='same'	ReLU	Previous Layer
Conv3D_1b	filters=16, kernel_size=1x1x1, padding='same'	ReLU	Previous Layer
Maxpooling3D_1a	kernel_size=3x3x3, stride=1, padding='same'		Previous Layer
Conv3D_1c	filters=64, kernel_size=1x1x1, padding='same'	ReLU	Previous Layer
Conv3D_2a	filters=128, kernel_size=3x3x3, padding='same'	ReLU	Conv3D_1a
Conv3D_2b	filters=32, kernel_size=5x5x5, padding='same'	ReLU	Conv3D_1b
Conv3D_2c	filters=32, kernel_size=1x1x1, padding='same'	ReLU	Maxpooling3D_1a
Concatenate			Conv3D_1c, Conv3D_2a, Conv3D_2b, Conv3D_2c

**Çizelge 2. 2 :** Complete Inception 2B modülünün ayrıntılı yapısı [34]

Katman	Katman Detayı	Activation	Bağlı olduğu katman
Conv2D_1a	filters=96, kernel_size=1x1, padding='same'	ReLU	Previous Layer
Conv2D_1b	filters=16, kernel_size=1x1, padding='same'	ReLU	Previous Layer
Maxpooling2D_1a	kernel_size=3x3, stride=1, padding='same'		Previous Layer
Conv2D_1c	filters=64, kernel_size=1x1, padding='same'	ReLU	Previous Layer
Conv2D_2a	filters=128, kernel_size=3x3, padding='same'	ReLU	Conv2D_1a
Conv2D_2b	filters=32, kernel_size=5x5, padding='same'	ReLU	Conv2D_1b
Conv2D_2c	filters=32, kernel_size=1x1, padding='same'	ReLU	Maxpooling2D_1a
Concatenate			Conv2D_1c, Conv2D_2a, Conv2D_2b, Conv2D_2c

### 2.3.5 VGG16


VGGNet mimarisi, 2014 yılında Oxford'un Görsel Geometri Grubu tarafından çok derin bir evrişimsel sinir ağı oluşturmak ve eğitmek için başarılı bir çaba olarak icat edilmiştir [66]. Bu mimari, bir ağın derinliğinin, evrişimsel sinir ağlarında tanıma veya sınıflandırmada yüksek performans elde etmek için kritik bir bileşen olduğunu göstermiştir. VGG, evrişim çekirdeklerini 3x3'e küçülterek, ancak her bir evrişim katmanındaki evrişimsel katman dizilerinin ve özellik haritalarının sayısını artırarak, tanıma görevleri için AlexNet ile karşılaştırılabilir uygun alıcı alanla daha derin mimariyi eğitebilmektedir. VGG16 Şekil 2.15'te gösterildiği gibi 16 katman derinliğine sahip evrişimli bir sinir ağıdır. VGG16 ile ilgili en benzersiz şey, çok sayıda hiper parametreye sahip olmak yerine, stride değeri 1 olan 3x3 filtre boyutunda evrişim katmanlarına sahip olmaya odaklanmaları ve her zaman aynı dolguyu (padding=same) ve stride değeri 2 olan 2x2 filtre boyutuna sahip maksimum havuzlama (max-pool) katmanını kullanmalarıdır. Tüm mimari boyunca tutarlı bir şekilde bu evrişim ve maksimum havuz katmanları düzenlemesini takip etmektedir. Sonunda 2 FC'ye (tamamen bağlı katmanlar) ve ardından çıktı için bir softmax'a sahiptir. Tez çalışması kapsamında VGG16 mimarisi ile birlikte 3B ESA kullanıldığı için evrişim ve maksimum havuzlama katmanlarının filtre boyutları 3 boyutlu olarak alınmaktadır. Uygulanan VGG16 mimarisi (3x3x3) filtre boyutuna sahip evrişim işlemlerinin gerçekleştirildiği evrişim katmanlarından, stride değeri 2 olan ve (2x2x2) filtre boyutuna sahip 3B maksimum havuzlama katmanı ve evrişim katmanlarından sonra aktivasyon fonksiyonu olarak kullanılan ReLU'dan oluşmaktadır. Evrişim katmanlarının 1 ve 2. katmanında 64 filtre, 3 ve 4. Katmanında 128 filtre, 5, 6 ve 7. katmanında 256 filtre, 8, 9, 10, 11, 12 ve 13. katmanında ise 512 filtre kullanılmaktadır. Evrişim ve havuzlama katmanlarından sonra elde edilen çıktı düzleştirilmektedir. Ardından çıktı 4096 nörona sahip iki tam bağlantılı katmandan geçirildikten sonra girdi, bir softmax aktivasyon fonksiyonu ile sınıf sayısına indirgemektedir. Her tam bağlantılı katmandan sonra aktivasyon fonksiyonu olarak ReLU kullanılmakta ve aşırı öğrenmeyi (overfitting) önlemek için, tamamen bağlı her katmandan sonra %0.4 bırakma oranına (dropout rate) sahip bir bırakma (dropout) katmanı uygulanmaktadır.



Şekil 2. 15: VGG16 mimarisi

### 2.3.6 Residual network (ResNet18-ResNet50)

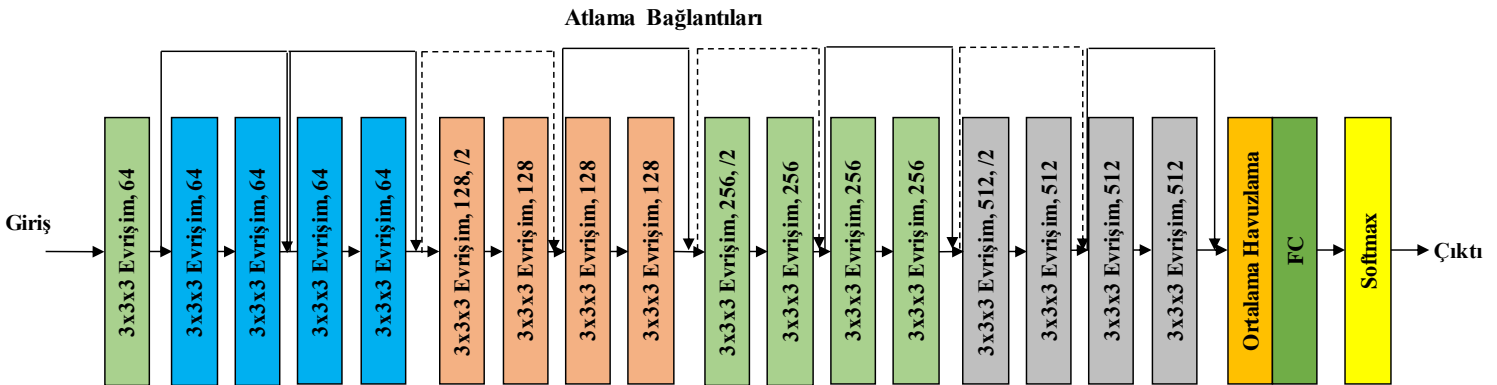
Derin olmayan ağ mimarisiyle (yani LeNet, AlexNet) karşılaştırıldığında, derin ağ mimarileri daha güçlü bir öğrenme ve özellik ifade etme yeteneğine sahiptir. Ağ mimarilerinde katman sayısının belirli bir derinliğe ulaşması, performansın artmasını sağlamayacak, aksine ağın yapısında bozulmaya neden olacaktır. Yani ağ yapısındaki katman sayısının aşırı artması kullanılan eğitim setindeki sınıflandırma doğruluğunu azaltmaktadır. Aynı zamanda, katman sayısı arttıkça oluşan derin ağları eğitmek, kaybolan gradyan problemi nedeniyle çok zordur. Kaybolan gradyan problemi, daha derin ağlardaki eğitim sürecinde ortaya çıkmaktadır. Eğitim ilerledikçe, bir katmandan diğerine geçen gradyan sinyalleri biraz kaybolmakta ve derin olmayan katmanlarda sifira yaklaşmaktadır. Bu durum ağın yakınsamasını en başından engellemektedir. Kaybolan gradyan ve bozunma problemini çözmek için Şekil 2.16'da gösterilen artık öğrenme bloğu He vd. [67] tarafından önerilmektedir. Ağ girişi  $x$  ve çıktı olarak elde edilecek özellik haritası  $H(x)$  olarak ifade edilsin. Artık haritalama  $H(x) = F(x)+x$ , kimlik kısayol bağlantıları eklenerek gerçekleştirilmektedir. Böylece ikinci katmanın çıktısına girdi verileri eklenerek geçmiş katmanın verilerinin ileri katmanlara etkin bir şekilde iletilmesi amaçlanmaktadır. İleriye yayılma sürecinde, artık öğrenme blokları sayesinde derin ağın kimlik haritalaması gerçekleştirilmektedir. Böylece ağ, kaybolan gradyan ve bozulma problemlerinden kaçınırken katman sayısını arttırabilmektedir. ResNet, artık öğrenme blokları adı verilen çok sayıda temel yapısal öğenin istiflenmesiyle oluşturulmaktadır. ResNet mimarisinin en önemli katkılarından biri, yapay sinir ağının katman sayısını artırırken ağın daha hızlı ve başarılı bir şekilde eğitilmesini sağlamasıdır.



Şekil 2. 16: Artık öğrenme bloğu.

Literatürde 18, 34, 50, 101 ve 152 katmanlı ResNet mimarileri bulunmaktadır. Bu tez çalışması kapsamında ResNet18 ve ResNet50 mimarileri kullanılmıştır.

ResNet18 mimarisi, toplam on sekiz katmandan oluşmaktadır (17 evrişimli katman, tam bağlantılı katman ve sınıflandırma görevini gerçekleştirmek için ek bir softmax katmanı). Evrişimli katmanlar 3x3x3 filtreler kullanmaktadır ve ağ, çıktı özellik haritası aynı boyuttaysa katmanlar aynı sayıda filtreye sahip olacak şekilde tasarlanmıştır. Ancak, çıktı özellik haritası yarıya indirilirse, filtreler katmanlarda iki katına çıkmaktadır. Son olarak, bir softmax katmanı ile tam bağlantılı bir katman tarafından takip edilen bir ortalama havuzlama katmanı vardır. Ağ boyunca, atlama bağlantıları katmanlar arasına eklenmektedir. İki tür bağlantı vardır. Kesintisiz çizgilerle gösterilen ilk bağlantı türü, giriş ve çıkış aynı boyutlara sahip olduğunda kullanılmaktadır. Noktalı çizgilerle gösterilen ikinci tip bağlantılar, boyutlar arttığında kullanılmaktadır. Bu bağlantı türü kimlik eşleme gerçekleştirmektedir [68]. Orijinal ResNet18 mimari Şekil 2.17'deki gibidir.



Şekil 2. 17: ResNet18 mimarisi

ResNet50 mimarisi iki ana bloktan oluşmaktadır. Kimlik ve Evrişim blokları [43]. Kimlik bloğu (Identity Block), ResNet'te kullanılan standart bloktur ve giriş aktivasyonunun çıkış aktivasyonu ile aynı boyuta sahip olduğu duruma karşılık gelmektedir. Kimlik bloğu üç bileşenli bir yapıdan oluşmaktadır. Birinci bileşen (1x1x1) filtre boyutu ile (1, 1, 1) stride değerine sahip 3B evrişim katmanından oluşmaktadır. 3B evrişimden sonra, ağırmızı daha

düzenli hale getirmek ve öğrenme sürecinin aşırı uyum göstermesini önlemek için batch normalization (BN) kullanılmıştır. Özellikle gradyan azalması ile eğitim süresi açısından RELU'lar diğer aktivasyon fonksiyonlarından daha hızlı olma eğilimindedir. Burada doğrusal olmayan aktivasyon fonksiyonu olarak RELU kullanılmıştır. İkinci bileşen birincisine benzemektedir. Ancak filtre boyutu (3x3x3)'tür. Üçüncü bileşen, birinci bileşene benzemektedir. Ancak ReLU aktivasyon fonksiyonuna sahip değildir. Son olarak, ReLU aktivasyon fonksiyonu uygulanmadan önce kısayol bağlantısı ile çıkışa giriş verileri eklenmektedir. Evrişim bloğunda giriş ve çıkış boyutları eşleşmemektedir. Kısayol bağlantı yoluna 3B evrişim katmanı eklenerek kimlik bloğundan farkı gösterilmektedir. Evrişimli bloğun yapısı, kısayol bağlantı yolunda ilave bir 3B evrişim katmanına sahip kimlik bloğundakiyle aynı prosedürü takip etmektedir. Bu kısayol bağlantısında, giriş ana yolla eşleşecek şekilde yeniden boyutlandırılmaktadır. Kısayol bağlantısında yer alan 3B evrişim katmanı (1x1x1) filtre boyutuna sahiptir. Bu evrişim katmanı ReLU aktivasyon fonksiyonuna sahip değildir. Son olarak, ReLU aktivasyon fonksiyonu uygulanmadan önce kısayol bağlantısı ile çıkışa giriş verileri eklenmektedir. Kısayol bağlantısına 3B evrişim katmanının eklenmesinin avantajı, kaybolan gradyan problemini kontrol etmektir [69]. Kimlik ve evrişim bloklarının birleştirilmesiyle elde edilen ResNet50 mimarisi Şekil 2.18'de gösterilmektedir. ResNet50 mimarisinin girişinde (3x3x3) filtre boyutunda 3B ZeroPadding işlemi uygulanmaktadır. Diğer işlemler ise şu şekildedir.

**Adım 1:** (7x7x7) filtre boyutuna ve (2, 2, 2) stride değeri ile 64 filtreye sahip 3B evrişimden oluşmaktadır. Daha sonra BN ve Aktivasyon fonksiyonu olarak ReLU kullanılmaktadır. En sonda ise (3x3x3) filtre boyutunda 3B maksimum havuzlama (max-pooling) işlemi gerçekleştirilmektedir.

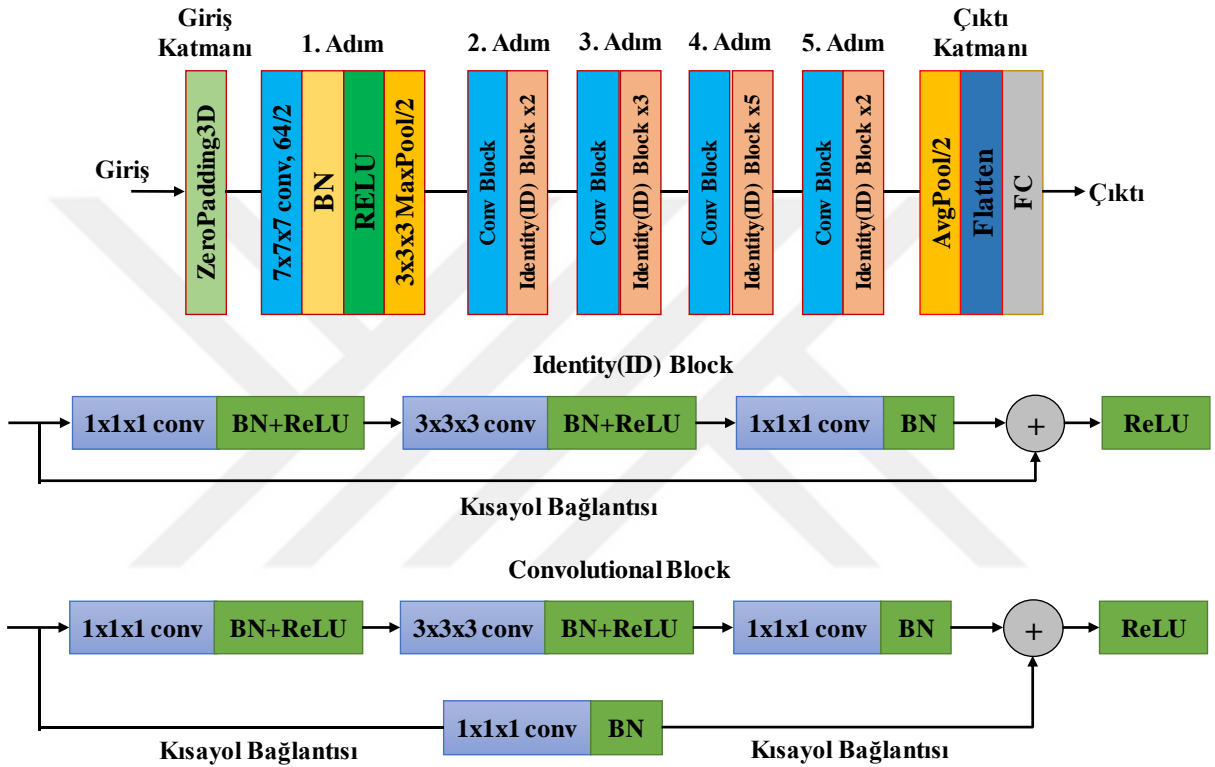
**Adım 2:** Bir 3B evrişim bloğundan ve iki kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (1, 1, 1) stride değerine sahip olan üç filtre seti [64, 64, 256] kullanılmaktadır.

**Adım 3:** Bir 3B evrişim bloğundan ve üç kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [128, 128, 512] kullanılmaktadır.

**Adım 4:** Bir 3B evrişim bloğundan ve beş kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [256, 256, 1024] kullanılmaktadır.

**Adım 5:** Bir 3B evrişim bloğundan ve iki kimlik bloğundan oluşmaktadır. Her iki blokta da (3x3x3) filtre boyutunda ve (2, 2, 2) stride değerine sahip olan üç filtre seti [512, 512, 2048] kullanılmaktadır.

**Adım 6:** (2x2x2) filtre boyutunda 3B ortalama havuzlama (average pooling) işlemi gerçekleştirilir. Ardından çıktı düzleştirilir (flatten) ve sonunda tam bağlantılı katman (Fully connected-FC) girdiyi bir softmax aktivasyon fonksiyonu ile sınıf sayısına indirgemek için kullanılmaktadır.



**Şekil 2. 18:** ResNet50 mimarisi

## 2.4 3B/2B Derinlemesine Ayrılabilir Evrişim

Derinlemesine ayrılabilir evrişim (DAE) kullanımı, eğitilebilir parametre sayısını azaltmanın etkili bir yolu olarak görülebilmektedir. DAE, Derinlemesine evrişim (DE) ve Noktasal evrişim (NE) olmak üzere iki ayrı işlemden oluşmaktadır. NE, 1x1 standart evrişim olarak da bilinmektedir. DAE'de, girişleri tek adımda yeni bir dizi çıkışta hem birleştiren hem de filtreleyen standart evrişimden farklı olarak, DE önce her bir giriş kanalını bağımsız olarak filtreler, ardından NE, DE çıkışını 1x1 evrişim ile filtreleyerek birleştirmektedir. Bu açıdan DAE, çarpanlara ayrılmış evrişim olarak da tanımlanabilmektedir [70]. Derinlemesine ayrılabilir evrişim kullanımı, standart evrişime kıyasla eğitilebilir parametre

sayısını azaltmaktadır. Bu da aşırı öğrenme problemini önleyebilmektedir. Ayrıca daha az hesaplama nedeniyle işlem maliyetini azaltmaktadır [71].

2B DAE'de DE kullanılarak, giriş görüntüsünün her kanalına ayrı ayrı evrişim işlemleri uygulanmakta ve her boyutta uzamsal özellikler çıkarılmaktadır. Ardından, DE sonucunda elde edilen özellik haritalarına  $1 \times 1$  standart evrişimli NE uygulanmaktadır. NE kullanılmasıyla, özellik haritaları kanallar arasında birleştirilmektedir.  $D_f \times D_f \times M$  boyutunda bir giriş görüntüsü olduğunu varsayalım. Burada  $D_f$ , giriş görüntüsünün genişlik ve yüksekliğini,  $M$  ise kanal sayısını ifade etmektedir. Benzer şekilde  $D_k \times D_k \times M$  evrişim çekirdek boyutunda  $N$  tane filtre/çekirdek olduğunu varsayalım. Standart bir evrişim işlemi gerçekleştirildiğinde, çıktı boyutu  $D_p \times D_p \times N$  olsun. Standart evrişim işleminin işlem maliyeti Denklem (2.8)'deki gibidir.

$$Maliyet_{standart\_evrişim} = N \times D_p \times D_p \times D_k \times D_k \times M \quad (2.8)$$

Şekil 2.19'da gösterildiği gibi derinlemesine ayrılabilir evrişim 2 işleme ayrılmaktadır. İlk olarak derinlemesine evrişim işleminde, tüm  $M$  kanalları için yapılan standart evrişim işleminin aksine, bir seferde tek bir kanala evrişim uygulanmaktadır. Burada  $D_k \times D_k \times 1$  evrişim çekirdek boyutunda  $M$  tane filtre gereklidir. Çıktı boyutu,  $D_p \times D_p \times M$  olacaktır. Derinlemesine evrişim işlemi için işlem maliyeti Denklem (2.9)'daki gibi hesaplanmaktadır.

$$Maliyet_{DE} = M \times D_p \times D_p \times D_k \times D_k \quad (2.9)$$

Noktasal evrişimde ise  $D_p \times D_p \times M$  çıktısına  $1 \times 1$  evrişim işlemi uygulanmaktadır. Bu işlemin çekirdek boyutu  $1 \times 1 \times M$  olacaktır.  $N$  tane filtre kullanıldığı varsayıldığında, çıktı boyutu  $D_p \times D_p \times N$  olacaktır. Noktasal evrişim işlemi sonucunda elde edilen maliyet (Denklem 2.10)'daki gibidir.

$$Maliyet_{NE} = M \times D_p \times D_p \times N \quad (2.10)$$

2B DAE işlem maliyeti, derinlemesine ve noktasal evrişim işlemleri sonucunda elde edilen maliyet toplamıdır. Standart evrişim işlemi ile derinlemesine ayrılabilir evrişim sonucunda elde edilen işlem maliyetlerini karşılaştırmak için gerekli olan hesaplama Denklem (2.11)'deki gibidir.

$$\frac{Maliyet_{DE} + Maliyet_{NE}}{Maliyet_{standart\_evrişim}} = \frac{1}{N} + \frac{1}{D_k^2} \quad (2.11)$$

Denklem (2.11)'e göre, 2B DAE işlemi sonucunda elde edilen işlem maliyeti standart evrişimin  $\frac{1}{N} + \frac{1}{D_k^2}$  katı olduğu görülmektedir. DAE'nin kullanılması eğitilebilir parametre sayısını ve hesaplama maliyetini önemli ölçüde azaltmaktadır.

Hiperspektral görüntüler 3 boyutlu olduğundan, hem spektral hem de uzamsal özelliklerin aynı anda çıkarılması istenilmektedir. Bu durumda 3B evrişim işlemleri uygulanmaktadır. 3B evrişimin hesaplama maliyeti yüksektir. 3B DAE kullanılarak maliyetin düşürülmesi hedeflenmektedir. Bu nedenle DAE fikri doğal olarak 3B evrişimlere uyarlanabilmektedir. 2B DAE'deki 2B evrişimleri 3B işlemlerle değiştirmek yeterli olacaktır. 2B DAE'de olduğu gibi, 3B DAE'de, derin ve noktasal evrişim olarak ikiye ayrılabilir. 2B DAE'de 3x3 DE ve 1x1 NE, 3B DAE'de 3x3x3 DE ve 1x1x1 NE katmanları kullanılmaktadır. 3B standart evrişim ve 3B DAE'nin hesaplama maliyetleri aşağıdaki denklemler ile hesaplanmaktadır.

$(l, w, h, c)$  boyutunda 3B özellik matrisi üzerinde evrişim işlemi gerçekleştirilmenin yolu, 3B matrisin üzerinden geçmek için  $k \times k \times k$  boyutunda bir filtre kullanmaktır.  $l, w, h, c$  sırasıyla uzunluk, genişlik, yükseklik ve kanalları belirtirken,  $k$  ise filtrenin kenar uzunluğunu ifade etmektedir.  $l_F \times w_F \times h_F \times c_F$  boyutundaki bir girdi özellik matrisine ( $F$ ) standart bir 3B evrişim işlemi uygulandığında,  $l_G \times w_G \times h_G \times c_G$  boyutunda bir özellik çıktı matrisi ( $G$ ) elde edilmiş olsun.  $c_F$  ve  $c_G$ , 3B evrişimden önceki ve sonraki kanal sayısını göstermektedir. 3B evrişim çekirdeği ( $K$ ),  $k \times k \times k \times c_F \times c_G$  olacaktır. Standart 3B evrişim sürecinin bir sonucu olarak, hesaplama maliyeti Denklem (2.12)'deki gibi olacaktır.

$$Maliyet_{standart\_evrişim} = k \times k \times k \times c_F \times c_G \times l_F \times w_F \times h_F \quad (2.12)$$

Şekil 2.19'de gösterildiği gibi, 3B DAE işlemi, 3B DE ve 3B NE (veya 1x1x1 evrişim) olmak üzere iki işlemden oluşmaktadır. DE ile her kanala ayrı ayrı 3x3x3 çekirdek boyutunda bir evrişim işlemi uygulanmaktadır. Bu işlemin sonucunda hesaplama maliyeti Denklem (2.13)'teki gibidir.

$$Maliyet_{DE} = k \times k \times k \times c_F \times l_F \times w_F \times h_F \quad (2.13)$$

Ayrı kanalları bir araya getirmek ve kanallar arasında yeterli bilgi alışverişini sağlamak için bu kanalları tek bir yeni özellik haritasında birleştirmek gerekmektedir. Bu



işlem NE ile gerçekleştirilmektedir. Yani 1x1x1 filtresi DE çıktısı sonucunda elde edilen özellik haritalarına doğrusal bir kombinasyon uygulamak için kullanılmaktadır. NE'nin hesaplama maliyeti Denklem (2.14)'teki gibidir.

$$Maliyet_{NE} = c_G \times c_F \times l_F \times w_F \times h_F \quad (2.14)$$

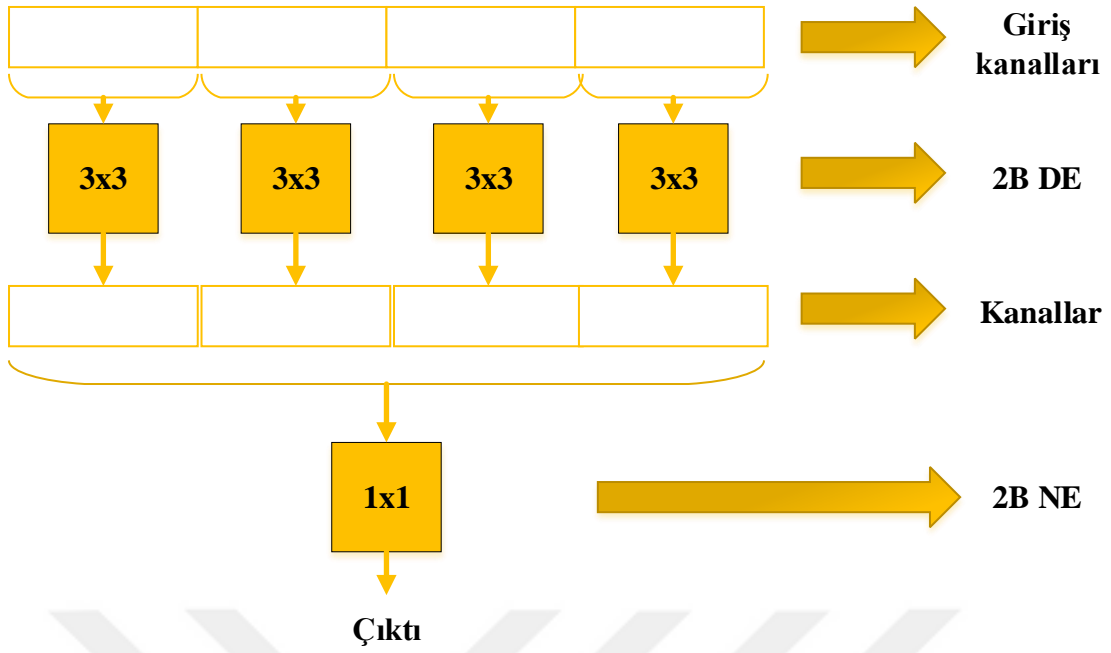
DE ve NE'yi birleştirerek elde edilen toplam hesaplama maliyeti Denklem (2.15)'deki gibidir.

$$\begin{aligned} Maliyet_{DE} + Maliyet_{NE} \\ = k \times k \times k \times c_F \times l_F \times w_F \times h_F \\ + c_G \times c_F \times l_F \times w_F \times h_F \end{aligned} \quad (2.15)$$

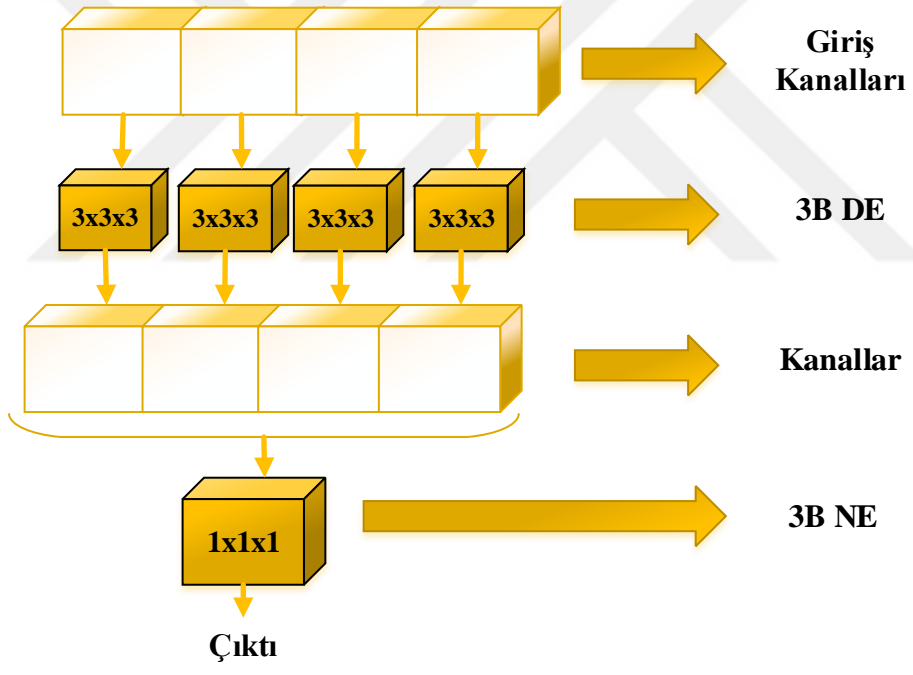
3B DAE'yi standart 3B evrişim ile karşılaştırırken, sonuç Denklem (2.16)'daki gibi elde edilmektedir.

$$\begin{aligned} \frac{Maliyet_{DE} + Maliyet_{NE}}{Maliyet_{standart\_evrişim}} \\ = \frac{k \times k \times k \times c_F \times l_F \times w_F \times h_F + c_G \times c_F \times l_F \times w_F \times h_F}{k \times k \times k \times c_F \times c_G \times l_F \times w_F \times h_F} \\ = \frac{k \times k \times k \times c_F + c_G \times c_F}{k \times k \times k \times c_F \times c_G} = \frac{1}{c_G} + \frac{1}{k^3} \approx \frac{1}{k^3} \end{aligned} \quad (2.16)$$

$c_G$  kanal boyutu büyük bir sayıdır (genellikle 32, 64, 128, 256 vb.). Bu,  $\frac{1}{c_G}$  'yi çok küçük yapmaktadır.  $\frac{1}{k^3}$ , çekirdeğin kenar uzunluğuna bağlıdır. Çekirdek küçük ve kenar uzunluğu 2 olsa bile,  $\frac{1}{k^3}$  zaten 0.1'e yaklaşmaktadır.  $\frac{1}{c_G}$  ve  $\frac{1}{k^3}$  birleştirildiğinde, Denklem (2.16)'daki hesaplama göz önüne alındığında, 0.1'den daha düşük bir değere ulaşmak kolaydır, bu da hesaplama maliyetinin Denklem (2.16)'da yaklaşık 10 kat azaldığı anlamına gelmektedir [72].



(a)



(b)

Şekil 2. 19: (a) 2B Derinlemesine ayrılabilir evrişim, (b) 3B Derinlemesine ayrılabilir evrişim

### 3. LİTERATÜRDE KULLANILAN VERİ SETLERİ

Bu tez çalışmasında, önerilen yöntemlerin sınıflandırma performanslarını test etmek için literatürde sıklıkla kullanılan Indian Pines, Pavia Üniversitesi, Salinas, Kennedy Uzay Merkezi, Botswana [73], HyRANK-Loukia [74], Houston 2013 IEEE GRSS Data Fusion Contest [75], WHU-Hi-LongKou, WHU-Hi-HanChuan ve WHU-Hi-HongHu [76] veri setleri üzerinde çalışmalar gerçekleştirilmiştir. Bu veri setleri ile ilgili detaylı bilgiler alt başlıklar halinde verilmiştir.

#### 3.1 Indian Pines Veri Seti

Indian Pines (IP) veri seti, düzenli geometriye sahip ekinleri ve ayrıca düzensiz orman bölgeleri ile karakterize edilen bir tarım alanı olan NW Indiana'daki Indian Pines test sahası üzerinde Havadan Görünür / Kızılötesi Görüntüleme Spektrometresi (Airborne Visible/Infrared Imaging Spectrometer-AVIRIS) sensörü tarafından 1992'de yakalandı. Bu verisetindeki her spektral görüntü  $145 \times 145$  uzamsal boyutundadır. Sensör, 0.4-2.5 mikrometre dalga boyu aralığında toplam 224 spektral bant elde etmiştir. Bu 224 band'tan, 24 band tam su absorpsiyonu (emme) bölgesindedir ve bunlar sınıflandırma işlemi için yararlı değildir. 24 su emme bandı (özellikle [104–108], [150-163] ve 220) çıkarıldıktan sonra kalan 200 band deneyler için kullanılmıştır. IP veriseti 16 tür arazi örtüsüne/sınıfa bölünmüştür ve verilerin yaklaşık yarısı (toplam 21025'ten 10249 piksel) etiketli örnekler içermektedir. IP veri seti ile ilgili detaylı bilgi Çizelge 3.1'de verilmiştir. Ayrıca, IP veri setinin renkli görüntüsü Şekil 3.1'de yer almaktadır.

**Çizelge 3. 1:** Indian Pines veri seti sınıfları ve her sınıfa ait örnek sayıları.

Indian Pines (IP) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Yonca	46	9	Yulaf	20
2	Mısır-işlenmemiş	1428	10	Soya fasülyesi (işlenmemiş)	972
3	Mısır-az işlenmiş	830	11	Soya fasülyesi (az işlenmiş)	2455
4	Mısır	237	12	Soya fasülyesi	593
5	Çimen-Otlak	483	13	Buğday	205
6	Çimen-Ağaç	730	14	Odun	1265
7	Çimen-Otlak (biçilmiş)	28	15	Bina-çimen-ağaçlar-sürücüler	386
8	Saman	478	16	Taş-çelik-kuleler	93
Toplam Örnek Sayısı					10249



**Şekil 3. 1:** Indian Pines veri setinin renkli görüntüsü.

### 3.2 Pavia Üniversitesi Veri Seti

Pavia Üniversitesi (PU) veri seti, İtalya'nın kuzeyindeki Pavia Üniversitesi kampüsü üzerinden Yansıtıcı Optik Sistem Görüntüleme Spektrometresi (Reflective Optics System Imaging Spectrometer - ROSIS) sensörü tarafından toplanan verilerdir. Veri seti, çoklu katı yapılar, doğal nesnelere ve gölgelere içeren bir kentsel çevreye ait dokuz farklı sınıfa bölünmüştür. Gürültülü bandları atıldıktan sonra, ele alınan veri seti,  $610 \times 340$  piksel boyutunda, 1.3 mpp uzamsal çözünürlüğe sahip ve 0.43 ile 0.86  $\mu\text{m}$  spektral aralığı kapsayan 103 spektral band içermektedir. Son olarak, piksellerin yaklaşık %20'si (toplam 207400'ten 42776 piksel) etiketli örnekler içermektedir. PU veri seti ile ilgili detaylı bilgi Çizelge 3.2'de verilmiştir. Ayrıca, PU veri setinin renkli görüntüsü Şekil 3.2'de yer almaktadır.

**Çizelge 3. 2:** Pavia Üniversitesi veri seti sınıfları ve her sınıfa ait örnek sayıları.

Pavia Üniversitesi (PU) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Asfalt	6631	6	Sade Toprak	5029
2	Çayırlar	18649	7	Zift	1330
3	Çakıl	2099	8	Bloke tuğlalar	3682
4	Ağaçlar	3064	9	Gölgeler	947
5	Boyalı saclar	1345			
Toplam Örnek Sayısı					42776



**Şekil 3. 2:** Pavia Üniversitesi veri setinin renkli görüntüsü.

### 3.3 Salinas Veri Seti

Salinas (SA) veriseti, AVIRIS sensörü tarafından Salinas Valley, California'daki çeşitli tarım alanları üzerinde toplanmıştır. Veriseti, piksel başına 3.7 mpp uzamsal çözünürlüğe sahiptir. 224 bant içeren, 217 piksel genişliğinde ve 512 piksel yüksekliğinde bir uzaktan algılama görüntüsüdür. 20 su emme bandı çıkarıldıktan sonra kalan 204 band uygulamalarda kullanılmıştır. SA veriseti, toplam 16 tür arazi örtüsü ve 54129 örnek içermektedir. SA veri seti ile ilgili detaylı bilgi Çizelge 3.3'de verilmiştir. Ayrıca, SA veri setinin renkli görüntüsü Şekil 3.3'de yer almaktadır.

**Çizelge 3. 3:** Salinas veri seti sınıfları ve her sınıfa ait örnek sayıları.

Salinas (SA) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Brokoli_yeşil_otlar_1	2009	9	Toprak_bağ_gelişen	6203
2	Brokoli_yeşil_otlar_2	3726	10	Mısır_yaşlanmış_yeşil_otlar	3278
3	Nadas	1976	11	Roman_marulu_4 hafta	1068
4	Nadas_kaba_saban	1394	12	Roman_marulu_5 hafta	1927
5	Nadas_düzgün	2678	13	Roman_marulu_6 hafta	916
6	Anız	3959	14	Roman_marulu_7 hafta	1070
7	Kereviz	3579	15	Bağ_yetiştirilmemiş	7268
8	Üzümler_yetiştirilmemiş	11271	16	Bağ_dikey_çardak	1807
Toplam Örnek Sayısı					54129



**Şekil 3. 3:** Salinas veri setinin renkli görüntüsü.

### 3.4 Kennedy Uzay Merkezi Veri Seti

NASA AVIRIS (Havadan Görünür/Kızılötesi Görüntüleme Spektrometresi) cihazı, 23 Mart 1996'da Florida'daki Kennedy Uzay Merkezi (KUM) üzerinden veri almıştır. AVIRIS, merkezi dalga boyları 400 - 2500 nm olan 10 nm genişliğinde 224 bantta veri almaktadır. Yaklaşık 20 km yükseklikten elde edilen KUM verilerinin uzamsal çözünürlüğü 18 m'dir. Su absorpsiyonu ve düşük SNR (Signal-to-noise ratio) bantları çıkarıldıktan sonra analiz için 176 bant kullanılmıştır. Kullanılan veriler, 512 x 614 pikselden oluşmaktadır. Eğitim verileri, Kennedy Uzay Merkezi tarafından sağlanan renkli kızılötesi fotoğrafçılıktan elde edilen arazi örtüsü haritaları ve Landsat Thematic Mapper (TM) görüntüleri kullanılarak

seçilmiştir. Bitki örtüsü sınıflandırma şeması, Landsat ve bu AVIRIS verilerinin uzamsal çözünürlüğünde ayırt edilebilen fonksiyonel tipleri tanımlamak amacıyla KUM personeli tarafından geliştirilmiştir. Bazı bitki türleri için spektral imzaların benzerliği nedeniyle bu ortam için arazi örtüsünün ayırt edilmesi zordur. Sınıflandırma amacıyla, saha için bu ortamda meydana gelen çeşitli arazi örtüsü türlerini temsil eden 13 sınıf tanımlanmıştır. KUM veri seti, toplam 5211 örnek içermektedir. KUM veri seti ile ilgili detaylı bilgi Çizelge 3.4’de verilmiştir. Ayrıca, KUM veri setinin renkli görüntüsü Şekil 3.4’te yer almaktadır.

**Çizelge 3. 4:** Kennedy Uzay Merkezi veri seti sınıfları ve her sınıfa ait örnek sayıları.

Kennedy Uzay Merkezi (KUM) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Çalı	761	8	Otsu Bitki Bataklığı	431
2	Söğüt Bataklığı	243	9	Kordon otu Bataklığı	520
3	Lahana almiyesi hamak	256	10	Hasır otu Bataklığı	404
4	Lahana palmiyesi/meşe hamak	252	11	Tuz Bataklığı	419
5	Kesik Çam	161	12	Çamur Düzlükleri	503
6	Meşe/geniş yapraklı hamak	229	13	Su	927
7	Sertağaç Bataklığı	105			
Toplam Örnek Sayısı					5211



**Şekil 3. 4:** Kennedy Uzay Merkezi veri setinin renkli görüntüsü.


### 3.5 Botswana Veri Seti

Botswana (BO) veriseti, NASA EO-1 uydusu tarafından, 2001-2004 yıllarında Botswana, Okavango Deltası üzerinden elde edilen verilerden oluşmaktadır. EO-1 üzerindeki Hyperion sensörü, 10 nm pencerelerde spektrumun 400-2500 nm bölümünü kapsayan 242 band'ta 7.7 km'lik bir şerit üzerinde 30 m piksel çözünürlükte veri almaktadır. Verilerin ön işleme, kötü dedektörlerin, dedektörler arası yanlış kalibrasyonun ve aralıklı anormalliklerin etkilerini azaltmak için UT Uzay Araştırmaları Merkezi tarafından gerçekleştirilmiştir. Kalibre edilmemiş (Ayarlanmamış) ve su emilimini örten gürültülü bandlar [10-55, 82-97, 102-119, 134-164, 187-220] çıkarıldıktan sonra uygulamalarda sadece 145 band kullanılmıştır. 31 Mayıs 2001'de elde edilen bu çalışmada analiz edilen veriler, Delta'nın uzak kesiminde yer alan mevsimsel bataklıklar, ara sıra bataklıklar ve daha kuru ormanlık alanlardaki arazi örtüsü türlerini temsil eden tanımlanmış 14 sınıftan oluşmaktadır. Kullanılan veriler, 1476 x 256 pikselden oluşmaktadır. Toplam 3248 örnek içermektedir. BO veri seti ile ilgili detaylı bilgi Çizelge 3.5'de verilmiştir. Ayrıca, BO veri setinin renkli görüntüsü Şekil 3.5'de yer almaktadır.

**Çizelge 3. 5:** Botswana veri seti sınıfları ve her sınıfa ait örnek sayıları.

Botswana (BO) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Su	270	8	Ada içi	203
2	Su aygırı otu	101	9	Akasya ormanları	314
3	Taşkın yatağı otları 1	251	10	Akasya çalılıarı	248
4	Taşkın yatağı otları 2	215	11	Akasya otlakları	305
5	Sazlık	269	12	Kısa mopane	181
6	Kıyıdaş	269	13	Karışık mopane	268
7	Yangın izi	259	14	Açıkta kalan topraklar	95
Toplam Örnek Sayısı					3248






**Şekil 3. 5:** Botswana veri setinin renkli görüntüsü.

### 3.6 HyRANK-Loukia Veri Seti

HyRANK-Loukia (HL) veri seti, Hyperion Earth Observing-1 sensörü kullanılarak elde edilen HyRANK veri kümesindeki görüntüleri temsil etmektedir. 30 m uzamsal çözünürlüğe ve 400 ile 2500 nm spektral kapsama alanına sahiptir. Görüntü  $249 \times 945$  piksel boyutunda 176 yüzey yansıtma bandı sağlamaktadır. HL veriseti 14 tür arazi örtüsü ve 13503 örnek içermektedir. HL veri setinin sınıf ve örnek sayısı bilgileri Çizelge 3.6'da listelenirken, renkli görüntüsü Şekil 3.6'da verilmiştir.

**Çizelge 3. 6:** HyRANK-Loukia veri seti sınıfları ve her sınıfa ait örnek sayıları.

HyRANK-Loukia (HL) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Yoğun kentsel yapı	288	8	Karışık orman	1072
2	Mineral çıkarım sahaları	67	9	Yoğun sklerofil bitki örtüsü	3793
3	Sulanmayan ekilebilir arazi	542	10	Seyrek sklerofil bitki örtüsü	2803
4	Meyve ağaçları	79	11	Seyrek bitki örtüsü olan alanlar	404
5	Zeytinlikler	1401	12	Kayalar ve kum	487
6	Geniş yapraklı orman	223	13	Su	1393
7	İğne yapraklı orman	500	14	Kıyı suyu	451
Toplam Örnek Sayısı					13503



**Şekil 3. 6:** HyRANK-Loukia veri setinin renkli görüntüsü.

### 3.7 Houston 2013 Veri Seti

Houston 2013 (UH) veri seti, Kompakt Havadan Spektrografik Görüntüleyici (Compact Airborne Spectrographic Imager-CASI) tarafından Haziran 2012'de Houston Üniversitesi kampüsü ve komşu kentsel alan üzerinde toplanmıştır. Bu veri seti,  $349 \times 1905$  boyutunda 144 band'tan oluşmaktadır. 2.5 m uzamsal çözünürlüğe ve 0.38-1.05  $\mu\text{m}$  aralığında yakalanan spektral bilgilere sahip 15 sınıf ve toplam 15029 örnek içermektedir. Bu anlamda, UH veri seti, ilk olarak 2013 Veri Füzyon Yarışması (Data Fusion Contest) sırasında IEEE Yerbilimi ve Uzaktan Algılama Derneği (Geoscience and Remote Sensing Society) Görüntü Analizi ve Veri Füzyon Teknik Komitesinde sunulan ilginç bir kıyaslama veri seti sağlamaktadır. UH veri setinin sınıf ve örnek sayısı bilgileri Çizelge 3.7'de listelenirken, renkli görüntüsü Şekil 3.7'de verilmiştir.

**Çizelge 3. 7:** Houston 2013 veri seti sınıfları ve her sınıfa ait örnek sayıları.

Houston 2013 (UH) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Sağlam çim	1251	9	Yol	1252
2	Yıpranmış çim	1254	10	Otoyol	1227
3	Sentetik çim	697	11	Demiryolu	1235
4	Ağaç	1244	12	Otopark 1	1233
5	Toprak	1242	13	Otopark 2	469
6	Su	325	14	Tenis kortu	428
7	Konut	1268	15	Koşu parkuru	660
8	Ticari Yapı	1244			
Toplam Örnek Sayısı					15029



**Şekil 3. 7:** Houston 2013 veri setinin renkli görüntüsü.

### 3.8 WHU-Hi Veri Seti

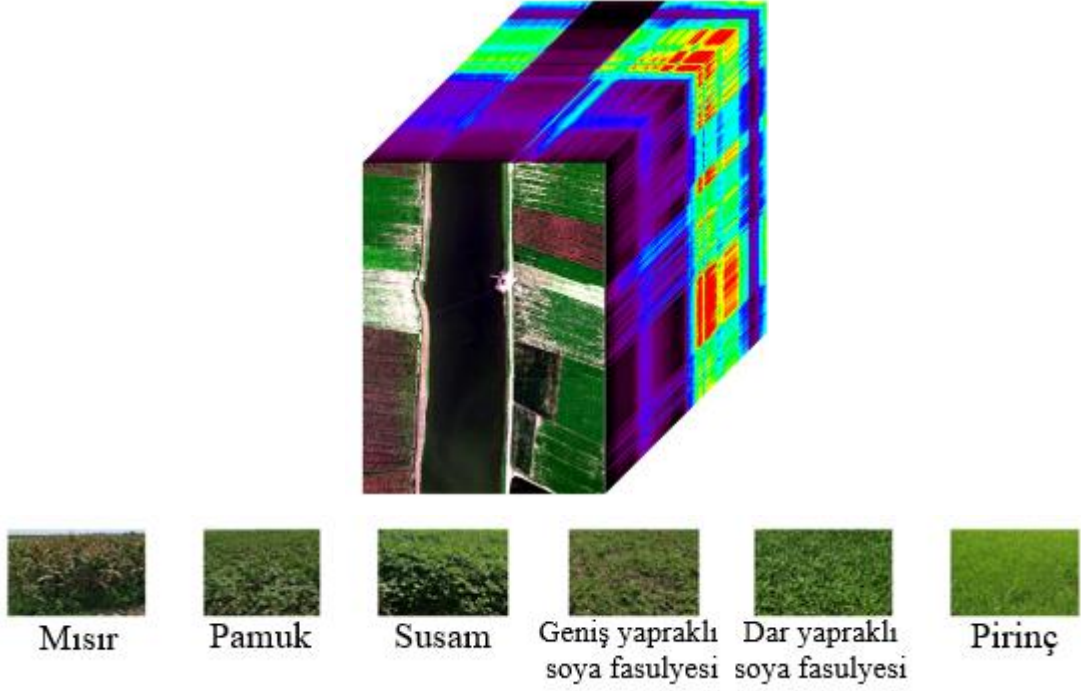
WHU-Hi veri setinin ön işleme, cihaz üreticisi tarafından sağlanan HyperSpec yazılımında gerçekleştirilen radyometrik kalibrasyon ve geometrik düzeltmeyi içermektedir. Radyometrik kalibrasyon için, ham dijital sayı değerleri sensörün laboratuvar kalibrasyon parametreleri ile parlaklık değerlerine dönüştürülmüştür.

#### 3.8.1 WHU-Hi-LongKou Veri Seti

WHU-Hi-LongKou (WHU-LK) veri seti, 17 Temmuz 2018'de Çin'in Hubei eyaleti, LongKou Kasabasında, DJI Matrice 600 Pro İHA platformunda donatılmış 8 mm odak uzaklığına sahip bir Headwall Nano-Hiperspec görüntüleme sensörü ile 13:49 - 14:37 arasında alınmıştır. Veri toplama sırasında hava açık ve bulutsuzdu, sıcaklık yaklaşık 36°C ve bağıl hava nemi yaklaşık %65 idi. Çalışma alanı, mısır, pamuk, susam, geniş yapraklı soya fasulyesi, dar yapraklı soya fasulyesi ve pirinç olmak üzere altı ürün türünü içeren basit bir tarım görüntüsüdür. İHA 500 m yükseklikte uçmuştur, görüntünün boyutu 550 × 400 piksel, 400 ile 1000 nm arasında 270 band içermektedir. İHA kaynaklı hiperspektral görüntülerin uzamsal çözünürlüğü yaklaşık 0.463 m'dir. Bu veri setine genel bir bakış Çizelge 3.8'de ve Şekil 3.8'de verilmiştir.

**Çizelge 3. 8:** WHU-Hi-LongKou veri seti sınıfları ve her sınıfa ait örnek sayıları.

WHU-Hi-LongKou (WHU-LK) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Mısır	34511	6	Pirinç	11854
2	Pamuk	8374	7	Su	67056
3	Susam	3031	8	Yollar ve Evler	7124
4	Geniş yapraklı soya fasulyesi	63212	9	Karışık ot	5229
5	Dar yapraklı soya fasulyesi	4151			
Toplam Örnek Sayısı					204542



Şekil 3. 8: WHU-Hi-LongKou veri setinin renkli görüntüsü.

### 3.8.2 WHU-Hi-HanChuan Veri Seti

WHU-Hi-HanChuan (WHU-HC) veri seti 17 Haziran 2016'da 17:57-18:46 saatleri arasında Çin'in Hubei eyaletinin Hanchuan şehrinde Leica Aibot X6 İHA V1 platformunda bulunan 17 mm odak uzaklığına sahip Headwall Nano-Hyperspec görüntüleme sensörü ile elde edilmiştir. Veri toplama sırasında hava açık ve bulutsuzdu, sıcaklık yaklaşık 30°C ve bağıl hava nemi yaklaşık %70 idi. Çalışma alanı, çilek, börülce, soya fasulyesi, sorgum, su ıspanağı, karpuz ve yeşillik olmak üzere yedi ürün türü içeren binalar, su ve ekili arazi ile kırsal-kentsel bir sınır bölgesidir. İHA 250 m yükseklikte uçmuştur. Elde edilen görüntünün boyutu 1217 × 303 piksel, 400 ile 1000 nm arasında 274 band var ve İHA kaynaklı hiperspektral görüntülerin uzamsal çözünürlüğü yaklaşık 0.109 m'dir. Özellikle, WHU-Hi-HanChuan veri seti, güneş yükselme açısının düşük olduğu öğleden sonraları alındığından, görüntüde birçok gölge kaplı alan vardır. Bu veri setine genel bir bakış Çizelge 3.9 ve Şekil 3.9'da verilmiştir.

**Çizelge 3. 9:** WHU-Hi-HanChuan veri seti sınıfları ve her sınıfa ait örnek sayıları.

WHU-Hi-HanChuan (WHU-HC) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Çilek	44735	9	Çimen	9469
2	Börülce	22753	10	Kırmızı Çatı	10516
3	Soya Fasülyesi	10287	11	Gri Çatı	16911
4	Sorgum	5353	12	Plastik	3679
5	Su Ispanağı	1200	13	Sade Toprak	9116
6	Karpuz	4533	14	Yol	18560
7	Yeşillik	5903	15	Parlak Nesne	1136
8	Ağaçlar	17978	16	Su	75401
Toplam Örnek Sayısı					257530



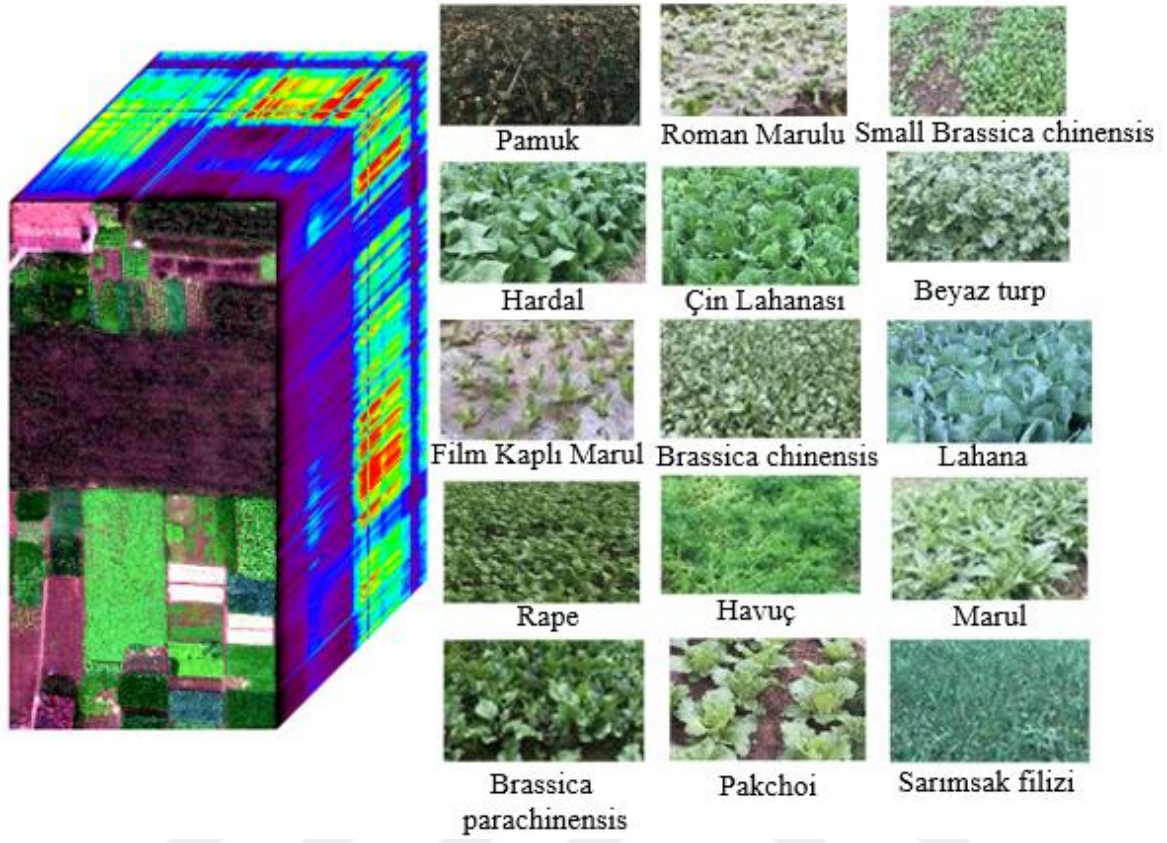
**Şekil 3. 9:** WHU-Hi-HanChuan veri setinin renkli görüntüsü.

### 3.8.3 WHU-Hi-HongHu Veri Seti

WHU-Hi-HongHu (WHU-HH) veri seti, 20 Kasım 2017'de 16:23-17:37 saatleri arasında Çin'in Hubei eyaletinin Honghu Şehrinde, DJI Matrice 600 Pro İHA platformunda bulunan 17 mm odak uzaklığına sahip Headwall Nano-Hyperspec görüntüleme sensörü ile elde edilmiştir. Veri toplama sırasında hava bulutluydu, sıcaklık yaklaşık 8°C ve bağıl hava nemi yaklaşık %55 idi. Deney alanı, birçok ürün sınıfına sahip karmaşık bir tarım sahnesidir ve bölgede Çin lahanası ve lahana dahil olmak üzere aynı mahsulün farklı çeşitleri ekilmektedir. Bölgede, aynı ürün türünden farklı çeşitler ekilmiş olması dikkat çekicidir; örneğin, Çin lahanası/lahana ve brassica chinensis /küçük brassica chinensis. İHA 100 m yükseklikte uçmuştur. Görüntünün boyutu 940 × 475 piksel, 400 ile 1000 nm arasında 270 band içermektedir ve İHA kaynaklı hiperspektral görüntülerin uzamsal çözünürlüğü yaklaşık 0.043 m'dir. Bu veri seti ile ilgili detaylı bilgiler Çizelge 3.10'da ve Şekil 3.10'da verilmiştir.

**Çizelge 3. 10:** WHU-Hi- HongHu veri seti sınıfları ve her sınıfa ait örnek sayıları.

WHU-Hi-HongHu (WHU-HH) Veri Seti					
No	Sınıf Adı	Örnek Sayısı	No	Sınıf Adı	Örnek Sayısı
1	Kırmızı Çatı	14041	12	Brassica chinensis	8954
2	Yol	3512	13	Small Brassica chinensis	22507
3	Sade Toprak	21821	14	Marul	7356
4	Pamuk	163285	15	Kuşkonmaz Marulu	1002
5	Pamuk Yakacak Odun	6218	16	Film Kaplı Marul	7262
6	Rape	44557	17	Roman Marulu	3010
7	Çin Lahanası	24103	18	Havuç	3217
8	Pakchoi	4054	19	Beyaz Turp	8712
9	Lahana	10819	20	Sarımsak Filizi	3486
10	Hardal	12394	21	Bakla	1328
11	Brassica parachinensis	11015	22	Ağaç	4040
Toplam Örnek Sayısı					386693



Şekil 3. 10: WHU-Hi- HongHu veri setinin renkli görüntüsü.

## 4. ÖNERİLEN YÖNTEMLER VE UYGULAMALAR

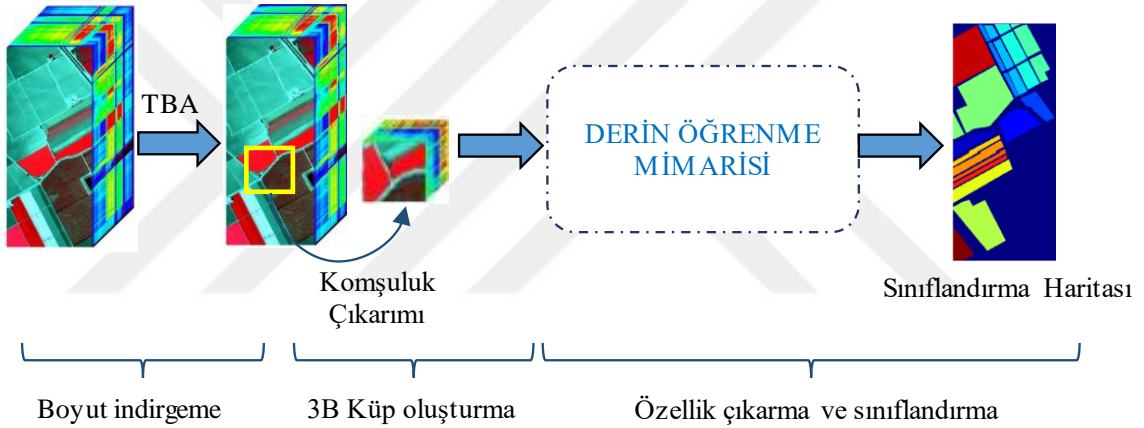
### 4.1 Önerilen Yöntemlerin Genel Çerçevesi

Hiperspektral uydu görüntülerinin sınıflandırılması için önerilen yöntemlerde kullanılan genel çerçeve Şekil 4.1'de gösterilmektedir. Gerçekleştirilen uygulamalarda, önerilen yöntemler 3 bölümden oluşmaktadır. (1) Boyut indirgeme, (2) 3B küp oluşturma ve (3) özellik çıkarma ve sınıflandırma. Önerilen yöntem çerçevesinin ilk aşamasında,  $X$  hiperspektral görüntüsü,  $M \times N \times D$  boyutunda bir spektral ve iki uzamsal boyuta sahip bir 3B veri küpü olarak belirtilmiştir.  $X$  orijinal girdidir.  $M, N$  ve  $D$  sırasıyla hiperspektral görüntüdeki yükseklik, genişlik ve spektral bantların sayısını göstermektedir. Giriş görüntüsünün temel gerçeği (ground truth)  $Y$ , one-hot encoding kullanılarak dönüştürülmekte ve  $Y = (y_1, y_2, \dots, y_C)$  olarak ifade edilmektedir.  $C$ , hiperspektral giriş görüntüsüne dahil edilen arazi örtüsü sınıflarının sayısını belirtmektedir. Bununla birlikte, hiperspektral görüntü pikselleri, herhangi bir sınıflandırma modeli için yoğun çaba gerektiren yüksek sınıf içi değişkenlik, yüksek sınıflar arası benzerlik, iç içe bölgeler ve örtüşme göstermektedir. Bu mevcut sorunları çözmek, herhangi bir model için büyük bir zorluktur. Bu problemlerin çözümü için öncelikle spektral band fazlalığının ortadan kaldırılması gerekmektedir. Spektral band fazlalığını ortadan kaldırmak için, önce spektral bantlar boyunca orijinal hiperspektral görüntü ( $X$ ) verilerine geleneksel boyut indirgeme yöntemi olan TBA uygulanmaktadır. TBA ile, aynı uzamsal boyutlar (yani genişlik  $M$  ve yükseklik  $N$ ) korunurken spektral bantların sayısı  $D$ 'den  $B$ 'ye düşürülmektedir. Yani herhangi bir sınıfı tanımak için çok önemli olan uzamsal öznelik bilgisi TBA kullanılarak korunurken sadece spektral band sayısı azaltılmaktadır. Böylece istenilen band sayısına indirilmektedir. TBA'dan sonra, değiştirilmiş giriş görüntüsü  $X$ ,  $M \times N \times B$  olarak ifade edilmektedir.  $M$  genişlik,  $N$  yükseklik ve  $B$  yeni elde edilen spektral bantların sayısıdır. İkinci aşamada, hiperspektral görüntü sınıflandırma tekniklerini kullanmak için, hiperspektral görüntü küpü, merkezi piksele dayalı gerçek etiketlerin oluşturulduğu küçük 3B uzamsal parçalara bölünmektedir. Oluşturulan 3B komşu parçalar  $S \times S \times B$ , uzamsal konumda  $(a, b)$  ortalanmış ve  $S \times S$  pencere boyutunu veya uzamsal boyutunu ve tüm spektral bantları  $B$  kapsayan hiperspektral görüntü küpünden ( $X$ ) oluşturulmaktadır. Hiperspektral görüntü küpünden ( $X$ ) üretilen toplam 3B parça sayısı  $(n)$ ,  $(M - S + 1) \times (N - S + 1)$  ile bulunmaktadır. Böylece,  $(a, b)$  konumundaki bu 3B parçalar,  $a - (S - 1)/2$  den  $a + (S - 1)/2$  ye kadar olan genişliği,  $b - (S - 1)/2$  den  $b + (S - 1)/2$  ye kadar olan



yüksekliği ve hiperspektral görüntü küpünün ( $X$ ) tüm spektral bantlarını ( $B$ ) kapsamaktadır [32]. Son aşamada, oluşturulan 3B hiperspektral görüntü veri küpleri, özellik çıkarma ve sınıflandırma için önerilen derin öğrenme tabanlı yöntemin girişine verilmektedir. En sonda ise sınıflandırma haritası elde edilmektedir.

Tüm uygulamalar Colaboratory (Colab) notebook kullanılarak gerçekleştirilmektedir. Colab, Google tarafından sunulan ve donanım hızlandırıcıları olarak Grafik işlem birimi'ne (Graphical Processing Unit-GPU) ve Tensör işlem birimlerine (Tensor Processing Units-TPU) ücretsiz erişim sağlayan çevrimiçi bir platformdur. Google Colab, herhangi bir donanım hızlandırıcıda çalışırken iyi bir internet hızına ihtiyaç duymaktadır. Uygulamalarımızı çalıştırırken donanım hızlandırıcı olarak TPU kullanılması tercih edilmektedir. TPU, veri hesaplama için 35 GB RAM ve 107.77 GB depolama alanına sahip bir Python 3 masaüstü bilgisayarda kod çalıştırma olanağı sunmaktadır.



**Şekil 4. 1:** Önerilen yöntemlerin genel çerçevesi.

## 4.2 Kullanılan Performans Ölçütleri

Her yöntemin sınıflandırma sonuçlarını değerlendirmek için genel doğruluk (overall accuracy-OA), ortalama doğruluk (average accuracy-AA) ve Kappa istatistikleri (K) kullanılmıştır. OA, test örneklerinde doğru sınıflandırılmış örnekler ile toplam test örneği sayısı arasındaki oran ile hesaplanmaktadır (Denklem (4.1)). AA, her sınıfın doğruluğunun ortalama değeridir (Denklem (4.2) ). K, temel doğruluk haritası ile sınıflandırma haritası arasında güçlü bir anlaşmaya ilişkin karşılıklı bilgi sağlayan istatistiksel bir ölçüm metriğidir (Denklem (4.3)). Kappa değerini kullanmanın avantajı, sınıflandırma doğruluğunu tahmin ederken belirsizliklerin sınıflandırma doğruluğu üzerindeki etkisini dikkate almaktır. OA, AA ve K ölçümlerinin yanı sıra kesinlik (precision) (Denklem (4.4)), duyarlılık (recall)

(Denklem (4.5)) ve F1-score (Denklem (4.6)) gibi çeşitli istatistiksel testler de dikkate alınmaktadır.

$$OA = \sum_{i=1}^K M_{ii} / N \quad (4.1)$$

$$AA = \sum_{i=1}^K \left( M_{ii} / \sum_{j=1}^K M_{ij} \right) / K \quad (4.1)$$

$$Kappa = \left( N \sum_{i=1}^K M_{ii} - \sum_{i=1}^K (M_{i+} \times M_{+i}) \right) / \left( N^2 - \sum_{i=1}^K (M_{i+} \times M_{+i}) \right) \quad (4.3)$$

$$Kesinlik = TP / (TP + FP) \quad (4.4)$$

$$Duyarlılık = TP / (TP + FN) \quad (4.5)$$

$$F1 - score = 2 * (Kesinlik * Duyarlılık) / (Kesinlik + Duyarlılık) \quad (4.6)$$

Denklem (4.1), (4.2) ve (4.3)'te kullanılan  $K$ , hiperspektral görüntü sınıflandırması için kullanılan sınıf sayısıdır.  $M$ , karışıklık matrisini temsil etmektedir. Karışıklık matrisi, tahmin edilen sınıflandırma haritasının gerçek değer olan temel gerçek (ground truth) ile karşılaştırılmasıyla oluşturulmaktadır.  $M_{ii}$ , karışıklık matrisinin ana köşegen değerlerini göstermekte ve  $i$  sınıfına ait doğru sınıflandırılmış örneklerin sayısıdır.  $N$ , toplam test örnek sayısıdır.  $M_{i+}$ ,  $i$  satırındaki toplam örnek sayısını gösterirken  $M_{+i}$ ,  $i$  sütunundaki toplam örnek sayısını göstermektedir. TP (Gerçek pozitif), FP (Yanlış pozitif), TN (Gerçek negatif) ve FN (Yanlış negatif), karışıklık matrisinden hesaplanan değerlerdir.

### 4.3 Uygulama 1: Hiperspektral Görüntü Sınıflandırması için Hibrit 3B Evrişim ve 2B Derinlemesine Ayrılabilir Evrişim Sinir Ağı

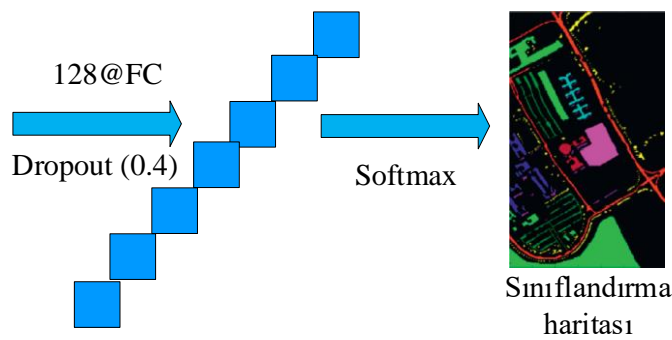



#### 4.3.1 Önerilen yöntem

Önerilen hibrid yöntem Şekil 4.2'de gösterildiği gibi, 3 tane ard arda 3B ESA, 2 tane 2B ESA, derinlemesine ayrılabilir evrişim katmanları (DE + NE katmanları), düzleştirme, 2 tane tam bağlantılı, dropout ve softmax katmanlarından oluşmaktadır. Maksimum uzamsal-

spektral bilgiyi korumak için ESA'daki havuzlama katmanı kullanılmamaktadır. 3B evrişim işlemi, uzamsal-spektral özellik haritalarının sayısını eşzamanlı olarak arttırmak için ard arda üç kez uygulanmakta ve çıkış hacmindeki giriş hiperspektral görüntü verilerinin spektral bilgilerini koruyabilmektedir. Uygulanan 3B evrişim çekirdeklerinin ve kullanılan filtrelerin boyutları şu şekildedir: birinci evrişim katmanında  $3 \times 3 \times 7$  (yani iki uzamsal ve bir spektral boyut) boyutunda 32 filtre, 2. evrişim katmanında  $3 \times 3 \times 3$  boyutunda 64 filtre, 3. evrişim katmanında  $1 \times 1 \times 1$  boyutunda 64 filtre kullanılmaktadır. 2B evrişim, hiperspektral görüntü verileri için çok önemli olan önemli spektral bilgi kaybı olmaksızın farklı spektral bantlardaki uzamsal bilgileri güçlü bir şekilde ayırt ettiği akılda tutularak, düzleştirilmiş katmandan önce iki kez uygulanmaktadır. 2B evrişim çekirdeklerinin boyutları ve kullanılan filtreler şu şekildedir: 1. evrişim katmanında  $3 \times 3$  boyutunda 128 filtre ve 2. evrişim katmanında  $1 \times 1$  boyutunda 128 filtre kullanılmıştır. Benzer şekilde, düzleştirme katmanından önce derin ve noktasal evrişim katmanlarını içeren 2B DAE katmanları uygulanmıştır. 2B ESA katmanında  $3 \times 3$  boyutunda 128 filtre kullanılmıştır. Tüm evrişim katmanlarında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. 3B ve 2B evrişim ile 2B DAE katmanlarından sonra çıkarılan öznelikler düzleştirilmekte ve sınıflandırma için FC katmanlarına girdi olarak verilmektedir. Önerilen yöntemde 256 ve 128 nöronlu iki FC katmanı kullanılmıştır. Aşırı öğrenmeyi önlemek için, her FC katmanından sonra bırakma oranı %0.4 olan bir bırakma katmanı uygulanmıştır. FC katmanının çıktısı, sınıflandırma sonucunu üretmek için basit softmax sınıflandırıcıya verilmektedir. Softmax, sınıflandırma için bir derin öğrenme yönteminin son katmanında sıklıkla kullanılan bir etkinleştirme işlevidir. Bu etkinleştirme işlevi, tüm örneklerin olasılık dağılımını üretmektedir. Önerilen yöntem hakkında daha fazla ayrıntı Çizelge 4.1'de gösterilmektedir. PU veri seti için önerilen yöntemde toplam eğitilebilir ağırlık parametresi sayısı 1.465.481'dir.

**Çizelge 4. 1:** PU için önerilen yöntemin özeti.

Katman	Çıktı	Parametre
Input (InputLayer)	(11, 11, 15, 1)	0
Conv3d	(9, 9, 9, 32)	2048
Conv3d_1	(7, 7, 7, 64)	55360
Conv3d_2	(7, 7, 7, 64)	4160
Reshape	(7, 7, 448)	0
Conv2d	(5, 5, 128)	516224
Separable_conv2d	(5, 5, 128)	17664
Conv2d_1	(5, 5, 128)	16512
Flatten	3200	0
Dense	256	819456
Dropout	256	0
Dense_1	128	32896
Dropout_1	128	0
Dense_2	9	1161
Toplam eğitilebilir parametre sayısı		1.465.481



Şekil 4. 2: Hiperspektral görüntü sınıflandırma için önerilen Hibrid 3B evrişim ve 2B DAE yöntemi.

### 4.3.2 Sınıflandırma sonuçları

Tüm uygulamalarda, 0.001 öğrenme oranlı kategorik çapraz entropi ve optimizasyon için kullanılan 1e-06 bozunma (decay) fonksiyonlu Adam optimizer kullanılmaktadır. Eğitim süreci, 256 batch size ve 100 epochs için tekrarlanmaktadır. ReLU, Softmax katmanı dışındaki tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. Eğitim örneklerinin oranı ve girdinin boyutu, hiperspektral görüntü sınıflandırmanın doğruluğunu etkileyen faktörlerdir. Her üç veri seti de evrişim için 11x11 komşuluk (pencere boyutu) kullanılmaktadır. IP, PU ve SA veri setlerinin eğitim örnek oranları sırasıyla %20, %10 ve %10 olarak alınmıştır. Uygulamalarımızda boyut indirgeme işleminden sonra IP, PU ve SA veri setleri için sırasıyla 30, 15 ve 15 temel bileşen kullanılmaktadır. Diğer derin öğrenme tabanlı yöntemlerle daha iyi bir karşılaştırma yapabilmek için temel bileşen değerleri bu şekilde seçilmiştir. Yani komşuluk çıkarımı sonucunda elde edilen 3B yamaların boyutu sırasıyla IP için 11x11x30, PU ve SA veri setleri için 11x11x15 olarak ayarlanmıştır. Önerilen yöntem (ÖY), SVM-RBF [77], 2B ESA [78], 3B ESA [79], SSRN [45] ve HybridSN [31] gibi literatürden alınan derin öğrenmeye dayalı hiperspektral görüntü sınıflandırma yöntemleri ile karşılaştırılmıştır.

Gerçekleştirilen uygulamalar kapsamında ilk olarak IP veri seti üzerinde çalışmalar yapılmıştır. Her sınıfın sınıf bazında ve OA, AA ve K değerlendirme ölçütlerine göre sınıflandırma doğrulukları Çizelge 4.2'de gösterilmiştir. IP veri seti ile yapılan uygulamalar sonucunda elde edilen temel doğruluk ve sınıflandırma haritaları Şekil 4.3'te verilmiştir. Çizelge 4.2 incelendiğinde önerilen yöntemin OA, AA ve K değerlendirme ölçütlerine göre sırasıyla %99.32, %99.46 ve %99.22 ile en iyi sınıflandırma sonucunu elde ettiği görülmektedir. Önerilen yönteme en yakın sonuçlar %99.19 OA, %98.93 AA ve %99.07 K değerleri ile SSRN, %99.26 OA, %98.98 AA ve %99.09 K değerleri ile HybridSN ile elde edilmiştir. Diğer sınıflandırma yöntemlerinden en düşük OA, AA ve K değerleri sırasıyla %82.83, %80.84 ve %82.23 ile SVM-RBF'de elde edilmiştir. SVM-RBF'deki AA değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. Sınıf bazlı sınıflandırmada önerilen yöntem ile 2., 3., 5., 10., 11., 12. ve 16. sınıflar dışındaki tüm sınıflarda %100 ile en iyi sınıflandırma doğrulukları elde edilmektedir. Sınıf 2 için en iyi sınıflandırma doğruluğu, önerilen yöntemden %0.57 farkla SSRN yönteminde elde edilmiştir. Sınıf 3 için en iyi sınıflandırma doğruluğu, önerilen yöntemden %1.79 farkla SSRN yönteminde elde edilmiştir. Benzer şekilde, en iyi sınıflandırma doğruluğu sınıf 5 için %99.24 ile SSRN, sınıf 10 için %98.76 ile HybridSN,

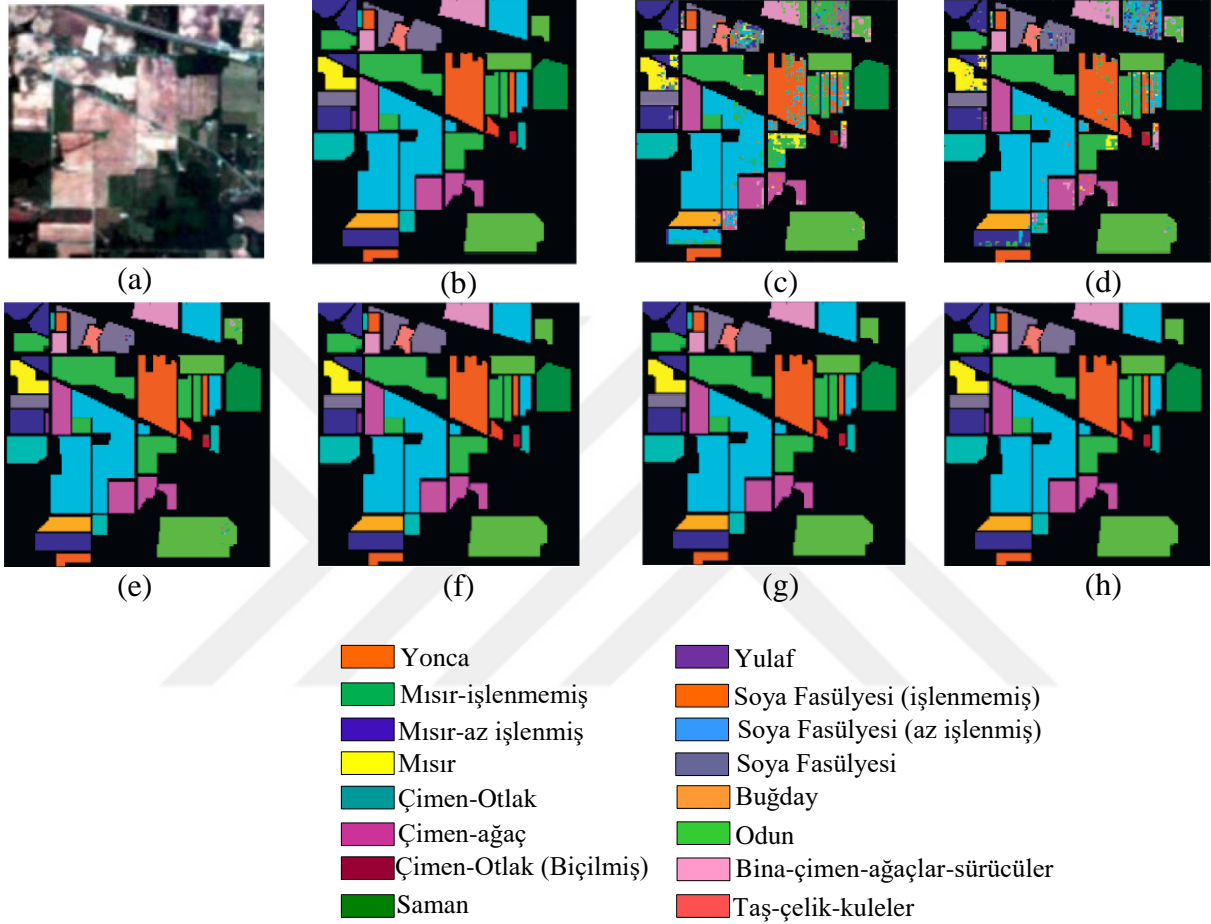
sınıf 11 için %99.75 ile ÖY, sınıf 12 için %99.12 ile HybridSN ve sınıf 16 için %98.65 ile ÖY'de elde edilmiştir.

**Çizelge 4. 2:** IP için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	SVM-RBF	2B ESA	3B ESA	SSRN	HybridSN	ÖY
1	9/37	61.5	85.88	94.63	97.82	97.98	100
2	286/1142	78.68	91.31	93.9	99.17	98.37	98.6
3	166/664	73.41	91.07	94.85	99.53	99.48	97.74
4	47/190	71.58	80.38	93.48	97.79	97.38	100
5	97/386	80.38	91.89	93.56	99.24	99.23	98.96
6	146/584	92.27	99.01	94.2	99.51	99.14	100
7	6/22	79.52	82.59	89.73	98.7	99	100
8	96/382	87.38	100	96.01	99.85	100	100
9	4/16	85.87	66.55	95	98.5	99.01	100
10	194/778	77.58	86.38	94.55	98.74	98.76	98.71
11	491/1964	83.75	90.47	93.87	99.3	99.64	99.75
12	119/474	83.21	82.89	91.52	98.43	99.12	98.95
13	41/164	84.64	99.06	93.89	100	100	100
14	253/1012	98.01	97.86	91.77	99.31	100	100
15	77/309	94.3	90.52	95.03	99.2	99.35	100
16	19/74	61.43	98.94	93.57	97.82	97.26	98.65
OA (%)		82.83	90.89	94.07	99.19	99.26	99.32
AA (%)		80.84	89.68	93.72	98.93	98.98	99.46
K x 100		82.23	88.56	93.87	99.07	99.09	99.22

İkinci uygulama PU veri seti ile yapılmıştır. PU veri seti ile yapılan uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.3'te verilmiştir. Sınıflandırma sonucunda elde edilen sınıflandırma haritaları Şekil 4.4'te gösterilmiştir. Çizelge 4.3 incelendiğinde önerilen yöntemin OA, AA ve K değerlendirme ölçütlerine göre sırasıyla %99.83, %99.70 ve %99.78 ile en iyi sınıflandırma sonucunu elde ettiği görülmektedir. Önerilen yöntem, en gelişmiş yöntemlerden biri olan HybridSN'ye göre sırasıyla OA, AA ve K değerleri açısından sırasıyla %0.11, %0.1 ve %0.14 daha iyi sonuçlar elde etmiştir. Ayrıca önerilen yöntem, en gelişmiş yöntemlerden biri olan SSRN'ye göre sırasıyla OA, AA ve K değerleri açısından sırasıyla %0.21, %0.21 ve %0.28 daha iyi sonuçlar elde etmiştir. En düşük sınıflandırma sonuçları %82.67 OA, %80.84 AA ve %81.21 K değerleri ile SVM-RBF yönteminde elde edilmiştir. Sırasıyla, 2B ESA ile %96.89 OA, %95.79 AA, %96.56 K ve 3B ESA ile %99.07 OA, %98.75 AA, %98.87 K sınıflandırma doğrulukları elde edilmiştir. Sınıf bazlı sınıflandırma doğrulukları karşılaştırıldığında önerilen yöntem %100 ile 5., 6. ve 9. sınıflarda en iyi sınıflandırma performansına sahiptir. Ayrıca en iyi sınıflandırma sonuçlarınının 1. sınıfta %99.95, 2. sınıfta %99.98, 4. sınıfta %99.53 ve 8. sınıfta

%99.46 ile önerilen yöntemde elde edildiği görülmektedir. Sınıf 3 ve sınıf 7 için en iyi sınıflandırma doğrulukları sırasıyla %99.01 ve %99.69 ile HybridSN yönteminde elde edilmiştir. Tüm sınıflandırma doğrulukları dikkate alındığında, önerilen yöntemle elde edilen sınıflandırma haritasının temel gerçeğe (ground truth) oldukça yakın olduğu görülmektedir.

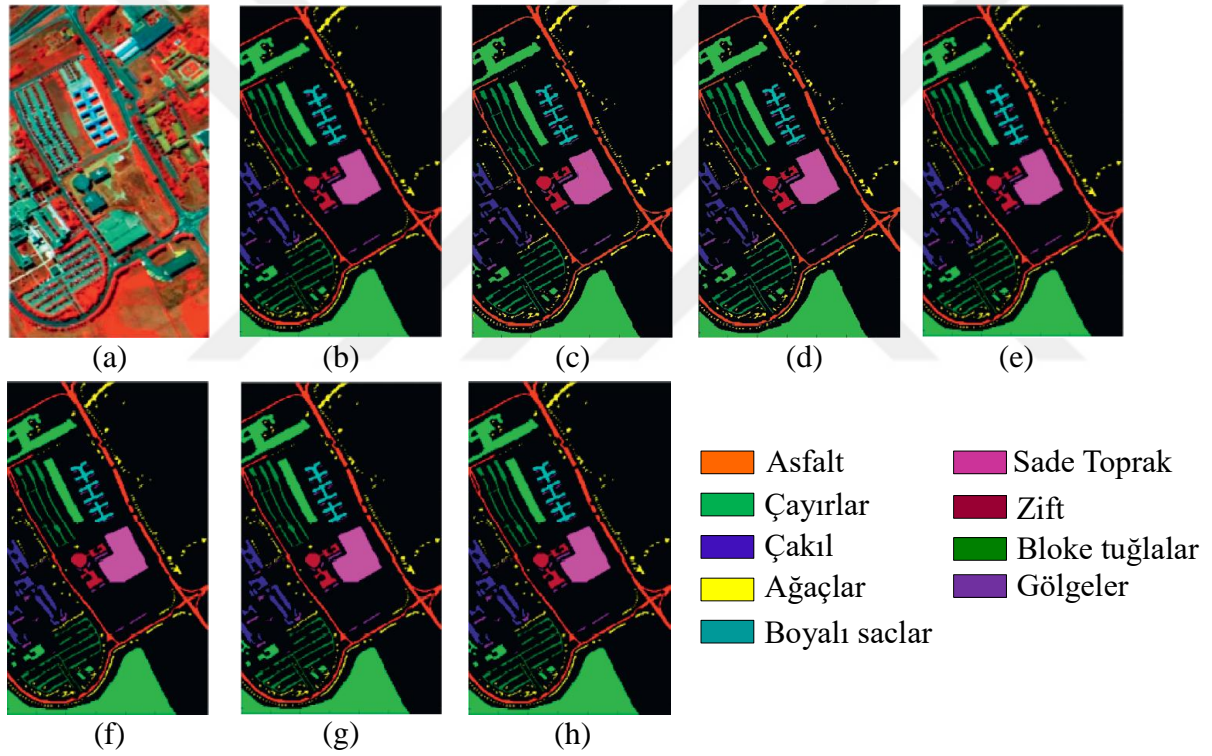


**Şekil 4. 3:** IP için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HybridSN ve (h) Önerilen yöntem.



**Çizelge 4. 3:** PU için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	SVM-RBF	2B ESA	3B ESA	SSRN	HybridSN	ÖY
1	663/5968	93.68	97.37	97.4	99.75	99.76	99.95
2	1865/16784	97.02	99.26	94.73	99.79	99.78	99.98
3	210/1889	82.41	80.73	95.05	98.29	99.01	98.94
4	306/2758	96.51	95.54	98.04	99.52	99.53	99.53
5	135/1211	98.38	99.75	99.01	99.82	99.87	100
6	503/4526	90.01	93.14	98.62	99.77	99.77	100
7	133/1197	85.92	91.65	97.02	99.65	99.69	99.42
8	368/3314	88.08	92.39	98.23	99.05	99.21	99.46
9	95/852	99.85	99.09	99.29	99.78	99.80	100
OA (%)		82.67	96.89	99.07	99.62	99.72	99.83
AA (%)		80.84	95.79	98.75	99.49	99.60	99.70
K x 100		81.21	96.56	98.87	99.50	99.64	99.78

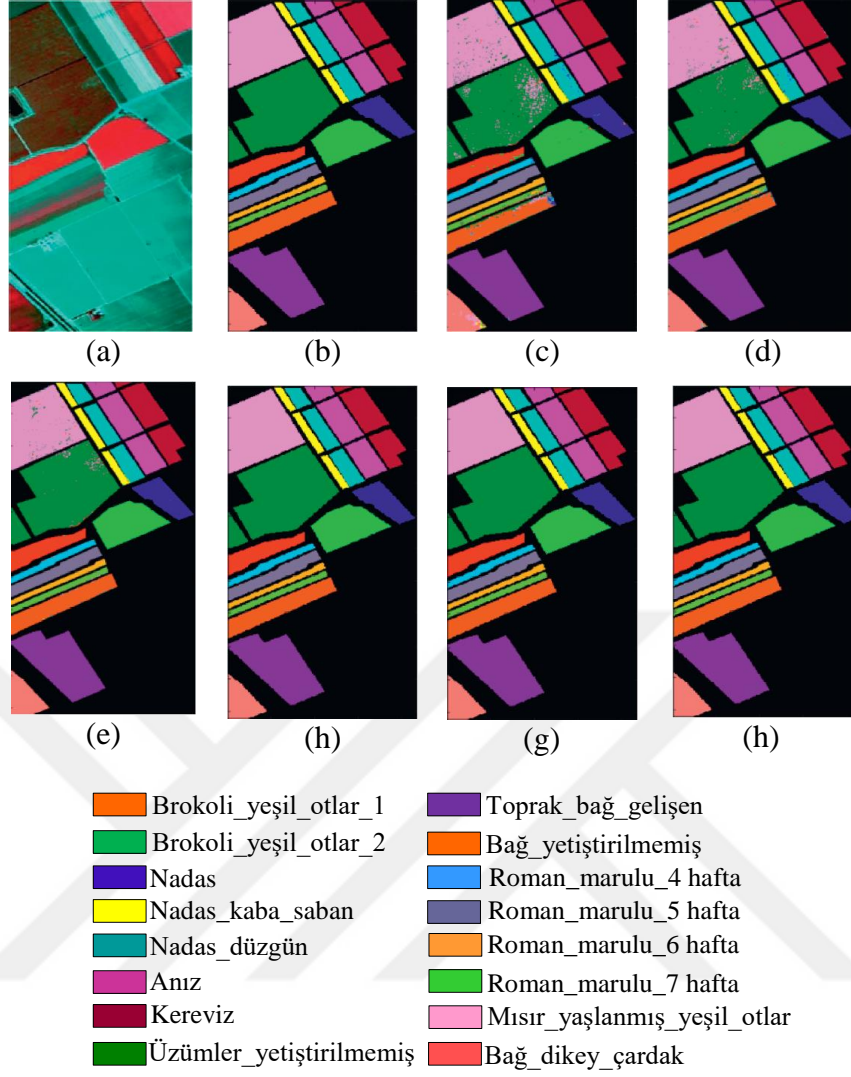


**Şekil 4. 4:** PU için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HybridSN ve (h) Önerilen yöntem.

Üçüncü uygulama SA veri seti ile gerçekleştirilmiştir. SA veri seti ile yapılan uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.4'te verilmiştir. Sınıflandırma sonucunda elde edilen sınıflandırma haritaları Şekil 4.5'de gösterilmiştir. Çizelge 4.4 incelendiğinde, en iyi sınıflandırma doğrulukları %99.90 OA, %99.93 AA ve %99.89 K değerleri ile önerilen yöntemde elde edilmiştir. Önerilen yöntem en yakın sonuçlar tüm değerlendirme metriklerinde %99.80 ile HybridSN ve %99.64 OA, %98.76 AA, %99.60 K değerleri ile SSRN yöntemindedir. Önerilen yöntem, SVM-RBF'den sırasıyla %7.23 OA, %8.32 AA ve %7.68 K, 2B ESA'dan %4.56 OA, %5.18 AA ve %4.96 K, 3B ESA'dan %5.88 OA, %6.44 AA ve %6.32 K değerleri ile daha iyi sınıflandırma performansı göstermektedir. Sınıf bazlı sınıflandırma sonuçları incelendiğinde önerilen yöntem en iyi sınıflandırma doğruluğuna %100 ile 1., 2., 3., 6., 7., 9., 11., 12., 13., 16. sınıflarda ulaşmıştır. 4., 5., 8., 10. ve 14. sınıflar için en iyi sınıflandırma sonuçları %100 ile HybridSN yönteminde elde edilmiştir. 15. sınıf için %99.63 ile önerilen yöntem en iyi sonuçları vermektedir. Çizelge 4.4 ve Şekil 4.5 dikkate alındığında, önerilen yöntem ve HybridSN yöntemleri ile elde edilen sınıflandırma haritaları temel gerçeğe çok benzemektedir.

**Çizelge 4. 4:** SA için eğitim/test örnek sayıları ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	SVM-RBF	2B ESA	3B ESA	SSRN	HybridSN	ÖY
1	201/1808	92.56	95.51	95.19	99.78	100	100
2	373/3353	94.78	95.87	96.12	99.78	100	100
3	198/1778	94.22	95.64	95.89	99.78	100	100
4	139/1255	97.36	99.99	97.18	99.99	100	99.76
5	268/2410	93.38	94.51	94.70	99.78	100	99.92
6	396/3563	95.36	96.71	95.63	99.78	100	100
7	358/3221	95.79	95.51	95.36	99.78	100	100
8	1127/10144	80.21	86.93	86.33	99.78	100	99.85
9	620/5583	97.67	97.42	97.19	99.78	100	100
10	328/2950	88.99	90.93	90.94	92.69	100	99.90
11	107/961	90.20	94.24	90.20	90.68	98.24	100
12	193/1734	96.42	99.91	96.24	99.95	99.61	100
13	92/824	95.53	95.53	95.31	99.85	99.59	100
14	107/963	91.26	92.97	94.18	99.88	100	99.90
15	727/6541	72.67	90.93	81.39	99.12	99.32	99.63
16	181/1626	89.37	93.43	94.09	99.78	100	100
OA (%)		92.67	95.34	94.02	99.64	99.80	99.90
AA (%)		91.61	94.75	93.49	98.76	99.80	99.93
K x 100		92.21	94.93	93.57	99.60	99.80	99.89




**Şekil 4. 5:** SA için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) SVM-RBF, (d) 2B ESA, (e) 3B ESA, (f) SSRN, (g) HybridSN ve (h) Önerilen yöntem.

## 4.4 Uygulama 2: 4CF-Net: Hiperspektral Uzaktan Algulama Görüntülerinin Spektral Uzamsal Sınıflandırılması için Yeni 3 Boyutlu Evrişimsel Sinir Ağı

### 4.4.1 Önerilen yöntem

Önerilen yöntem, Şekil 4.6’da gösterildiği gibi, 4 tane ard arda 3B evrişim (3D Conv) katmanından, düzleştirme ve FC katmanından oluşmaktadır. Maksimum uzamsal-spektral bilgiyi korumak için ESA’daki havuzlama katmanı kullanılmamaktadır. Arda arda kullanılan 3B evrişimlerin filtre boyutları sırasıyla şu şekildedir:  $8@3 \times 3 \times 7$  ( $3 \times 3 \times 7$  iki uzamsal ( $3 \times 3$ ) – bir spektral (7) boyutunda 8 filtre),  $16@3 \times 3 \times 5$ ,  $32@3 \times 3 \times 3$ ,  $64@3 \times 3 \times 3$ . Her 3B evrişim işleminden sonra elde edilen özellik haritası boyutunun azaltılması için, her bir evrişimde padding=”valid” olarak alınmıştır. Ayrıca tüm evrişim katmanlarında aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Ard arda uygulanan 3B evrişimlerden sonra, çıkarılan özellikler düzleştirme katmanından geçirildikten sonra FC katmanına girdi olarak verilmektedir. Önerilen yöntemde 128 nöron içeren bir tane FC katmanı kullanılmaktadır. Ardından sınıflandırma sonucu elde etmek için FC çıktısı softmax sınıflandırıcıya verilmektedir. Önerilen yöntem ile ilgili detaylı bilgi Çizelge 4.5’te gösterilmektedir. SA veri seti için önerilen yöntemde toplam eğitilebilir ağırlık parametresi sayısı 2.445.184’tür.



Şekil 4. 6: Önerilen 4CF-Net yöntemi.

**Çizelge 4. 5:** SA için önerilen yöntemin özeti.

Katman	Çıktı	Parametre
input_1 (Giriş katmanı)	(25,25,15,1)	0
conv3d_1 (Conv3d)	(23,23,9,8)	512
conv3d_2 (Conv3d)	(21,21,5,16)	5776
conv3d_3 (Conv3d)	(19,19,3,32)	13856
conv3d_4 (Conv3d)	(17,17,1,64)	55360
flatten_1 (Flatten)	18496	0
dense_1 (Dense)	128	2367616
dense_2 (Dense)	16	2064
Toplam Eğitilebilir Parametreler : 2.445.184		

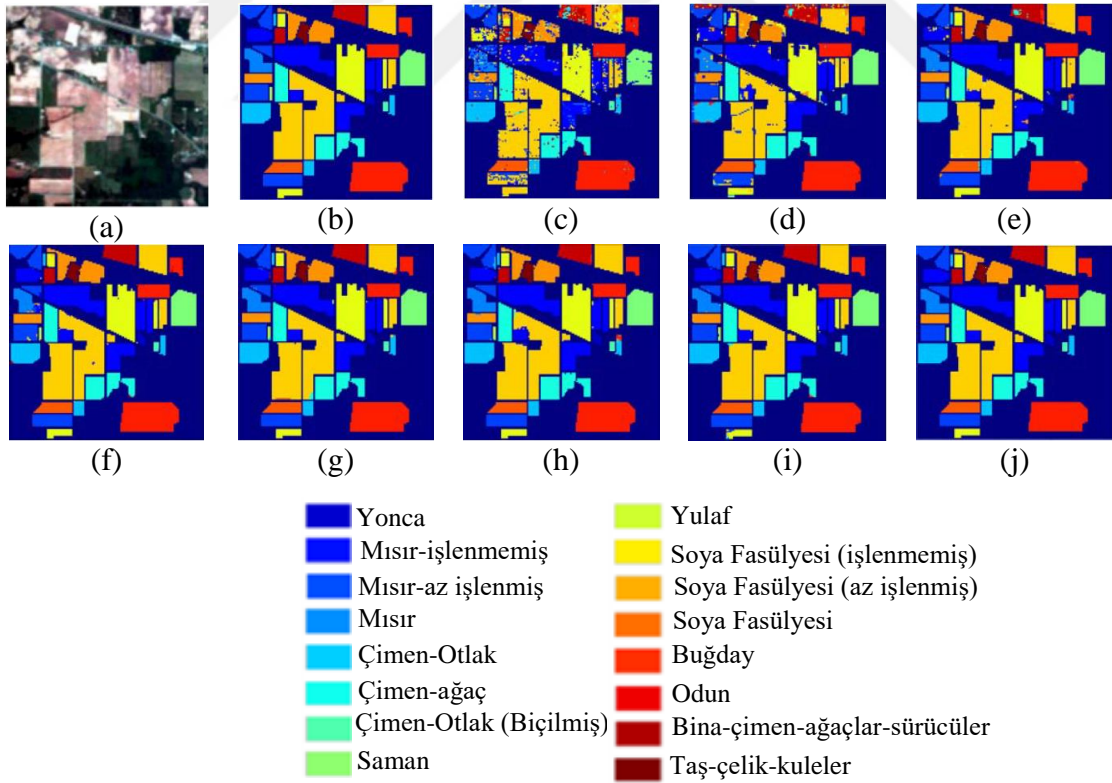
#### 4.4.2 Sınıflandırma sonuçları

Önerilen yöntemin sınıflandırma performansını test etmek için IP, PU, SA ve KUM veri setleri üzerinde uygulamalar gerçekleştirilmiştir. Tüm uygulamalarda eğitim-test oranı %70-30 olarak alınmıştır. 0.001 öğrenme oranına sahip kategorik entropi ve Adam optimizör kullanılmaktadır. Eğitim işlemi, 256 batch size ve 100 epochs boyunca devam etmektedir. Her dört veri seti de evrişim için 25x25 komşuluk (pencere boyutu) kullanılmaktadır. Uygulamalarımızda boyut indirgeme işleminden sonra IP için 30 temel bileşen kullanılırken, PU, SA ve KUM veri setleri için 15 temel bileşen kullanılmaktadır. Diğer derin öğrenme tabanlı yöntemlerle daha iyi bir karşılaştırma yapabilmek için temel bileşen değerleri bu şekilde seçilmiştir. Yani komşuluk çıkarımı sonucunda elde edilen 3B yamaların boyutu sırasıyla IP için 25x25x30, PU, SA ve KUM veri setleri için 25x25x15 olarak ayarlanmıştır. Önerilen yöntem (4CF-Net), DVM (Destek Vektör Makineleri) [80], 3B ESA [79], ResNet [81], SSRN [45], DFFN [47], MPRN [46] ve MSSN [81] gibi literatürden alınan derin öğrenmeye dayalı hiperspektral görüntü sınıflandırma yöntemleri ile karşılaştırılmıştır.

IP veriseti kullanılarak gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.6'da gösterilmektedir. Çizelge 4.6 incelendiğinde, önerilen 4CF-Net yönteminin OA, AA ve K değerlendirme ölçütlerinin hepsinde sırasıyla %99.93, %99.72, %99.92 ile en iyi sonucu verdiği görülmektedir. Sınıf bazlı sınıflandırma doğrulukları incelendiğinde önerilen yöntem 15 ve 16. sınıflar haricinde %100 ile en iyi sonucu vermektedir. 15 ve 16 nolu sınıflar için sırasıyla %100 ve %98.65 ile SSRN yöntemi en iyi sonuçları vermektedir. En kötü sınıflandırma sonuçları geleneksel makine öğrenmesi yöntemlerinden biri olan DVM ile elde edilmiştir. Diğer gelişmiş yöntemler arasında ise %90.38 OA, %88.39 AA ve %89.03 K ile en kötü sınıflandırma sonuçları 3B ESA ile elde edilmiştir. IP sonucunda elde edilen sınıflandırma haritaları Şekil 4.7'de verilmiştir. Şekil 4.7 incelendiğinde, 4CF-Net'in temel gerçeğe oldukça benzediği görülmektedir.

**Çizelge 4. 6:** IP kullanılarak elde edilen sınıflandırma doğrulukları (%).

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	83.33	59.52	94.44	97.37	100	100	97.14	100
2	72.78	91.60	96.03	99.35	98.88	99.39	99.41	100
3	65.19	87.01	98.22	97.62	99.41	97.93	99.45	100
4	63.08	85.98	95.36	79.98	100	98.97	97.93	100
5	90.57	88.51	95.04	98.98	98.43	95.30	100	100
6	95.59	98.93	99.65	98.66	99.99	99.47	99.14	100
7	69.23	84.62	100	90.48	100	100	100	100
8	93.51	100	100	100	100	100	100	100
9	72.22	94.44	66.67	94.44	80	93.33	88.24	100
10	71.09	84	98.45	97.64	99.51	99.74	97.51	100
11	86.11	91.04	95.64	98.66	98.18	97.82	99.2	100
12	72.28	76.03	98.59	98.32	98.15	98.36	98.91	100
13	96.76	99.46	96.43	100	100	100	100	100
14	97.89	97.54	99.71	98.33	100	100	100	100
15	47.71	77.87	85.64	100	99.98	97.71	99.67	99.13
16	80.95	97.62	95.83	98.65	95.83	97.22	91.02	96.42
OA	81.18	90.38	96.92	98.22	99.06	98.71	99.12	99.93
AA	78.64	88.39	96.73	98.08	98.24	98.34	99.23	99.72
K	78.36	89.03	96.49	97.97	98.93	98.34	99.02	99.92

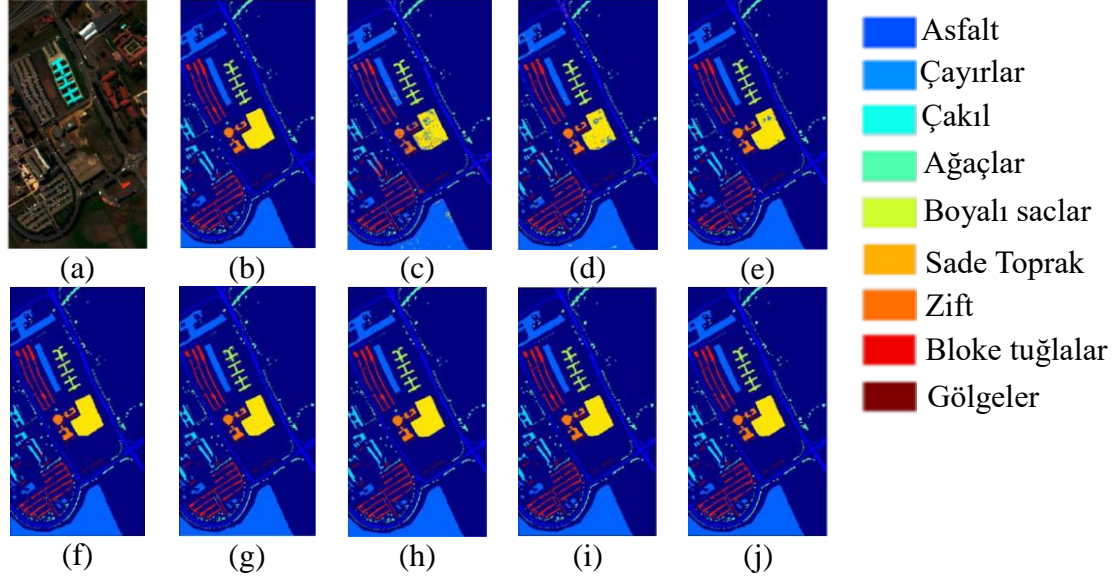


**Şekil 4. 7:** IP için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN, (j) 4CF-Net.

PU veriseti kullanılarak gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.7’de ve sınıflandırma haritaları Şekil 4.8’de gösterilmektedir. Önerilen 4CF-Net yöntemi ile %99.99 OA, %99.96 AA ve %99.99 K değerleri ile en iyi sınıflandırma sonuçları elde edilmiştir. Ayrıca, sınıf bazlı doğruluklar incelendiğinde 9 nolu sınıf haricinde önerilen yöntem ile diğer tüm sınıflarda %100 doğruluk elde edilmiştir. Önerilen yöntemle en yakın sonuçların %99.94 OA, %99.93 AA ve %99.92 K değeri ile MSSN yönteminde elde edildiği görülmektedir. 9 nolu sınıf için MSSN ve SSRN yöntemleri %100 ile en iyi sonucu vermektir. En kötü sınıflandırma sonucunu IP’de olduğu gibi %93.38 OA, %90.93 AA ve %91.18 K ile DVM vermektedir. DVM’deki AA değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. Gelişmiş diğer tüm yöntemlerden %96.26 OA, %94.99 AA ve %95.03 K ile en kötü sonucu 3B ESA vermektedir. Şekil 4.8 incelendiğinde, önerilen 4CF-Net yönteminin sınıflandırma haritasının temek gerçek haritası ile hemen hemen aynı olduğu görülmektedir.

**Çizelge 4. 7:** PU kullanılarak elde edilen sınıflandırma doğrulukları (%).

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	92.87	95.84	98.81	99.94	99.78	99.89	99.98	100
2	98.09	98.79	99.95	100	100	99.98	100	100
3	74.03	87.42	92.93	94.21	98.79	99.68	99.1	100
4	94.68	96.39	99.64	98.26	96.55	98.76	99.96	100
5	99.37	99.14	99.83	99.51	99.01	99.42	100	100
6	85.72	91.27	96.20	100	100	100	100	100
7	83.07	93.35	96.57	99.58	99.49	100	99.92	100
8	90.74	95.77	95.98	99.43	98.46	99.45	99.91	100
9	99.78	97	99.88	100	90.49	98.59	100	99.64
OA	93.38	96.26	98.51	99.51	99.27	99.56	99.94	99.99
AA	90.93	94.99	98.19	99.49	98.63	99.53	99.93	99.96
K	91.18	95.03	98.03	97.97	99.03	99.53	99.92	99.99



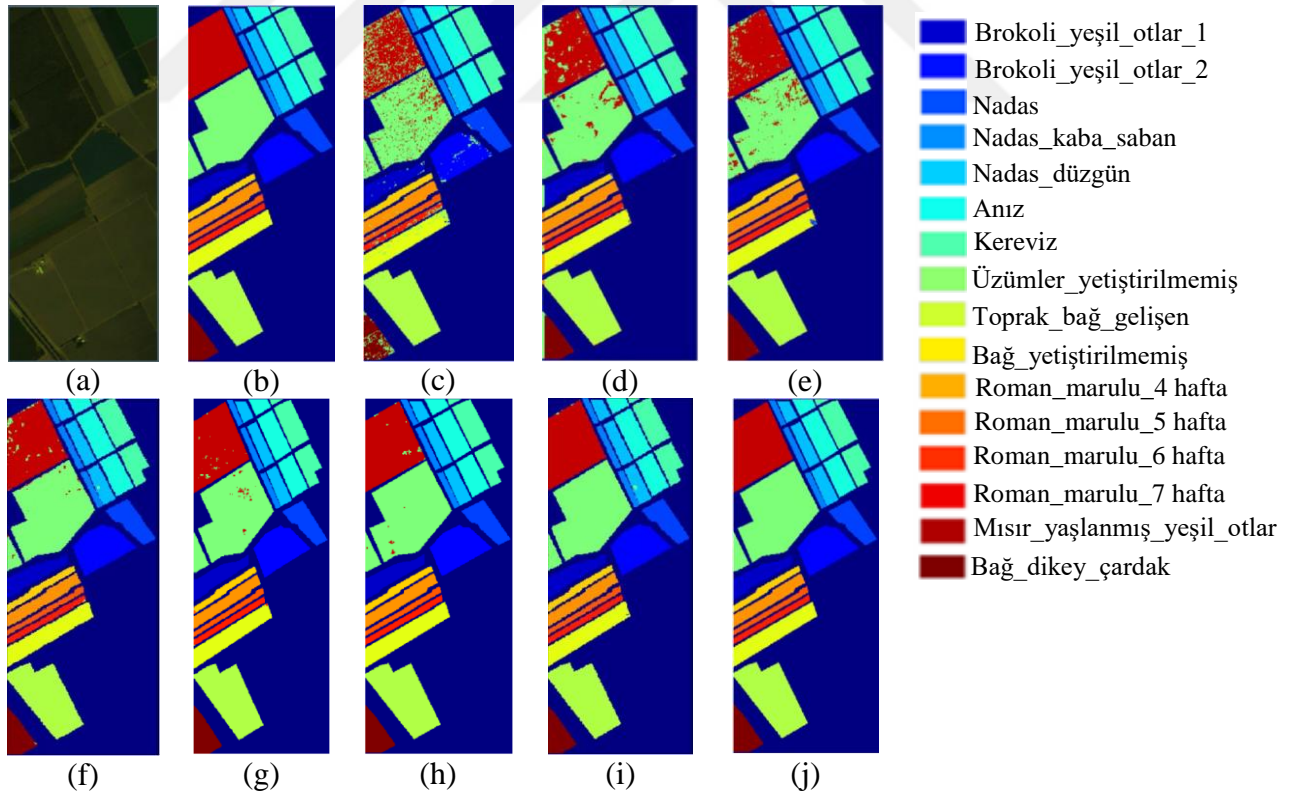
**Şekil 4. 8:** PU için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net.

4CF-Net yönteminin sınıflandırma performansını test etmek için kullanılan bir başka veri seti SA'dır. SA ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.8'de verilmiştir. SA kullanılarak tüm yöntemler için elde edilen sınıflandırma haritaları Şekil 4.9'da gösterilmektedir. Çizelge 4.8'e göre, önerilen yöntemin tüm değerlendirme ölçütlerinde %100 ile en iyi sınıflandırma sonuçlarını verdiği görülmektedir. Aynı zamanda tüm sınıflarda da %100 doğruluk vermektedir. Önerilen yöntemle en yakın sonuçlar %99.84 OA, %99.88 AA, %99.82 ile MSSN, %99.63 OA, %99.79 AA, %99.59 K ile MPRN ve %99.38 OA, %99.51 AA, %99.31 K ile DFFN ile elde edilmiştir. En kötü sınıflandırma sonuçlarının %89.35 OA, %92.34 AA ve %88.09 K ile DVM'de elde edildiği görülmektedir. Şekil 4.9 incelendiğinde, önerilen 4CF-Net yöntemi ile elde edilen sınıflandırma haritasının temel gerçek ile aynı olduğu ve MSSN yöntemi ile elde edilen sınıflandırma haritasının da temel gerçeğe oldukça yakın sonuçlar ürettiği görülmektedir.



**Çizelge 4. 8:** SA kullanılarak elde edilen sınıflandırma doğrulukları (%).

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	96.8	95.29	99.83	100	100	100	100	100
2	97.01	99.80	100	100	100	100	100	100
3	99.31	99.57	100	100	100	100	100	100
4	98.04	97.58	99.87	99.84	99.52	99.36	99.91	100
5	96.58	99.84	99.75	99.29	99.96	99.75	98.3	100
6	95.93	99.04	100	100	100	100	100	100
7	97.03	97.94	99.93	100	100	100	99.97	100
8	82.96	93.68	91.86	98.39	98.73	99.49	99.92	100
9	98.79	98.61	99.85	100	100	100	100	100
10	87.12	94.09	97.15	100	99.39	100	99.73	100
11	91.23	94.98	99.07	99.16	97.51	99.48	99.79	100
12	98.96	99.62	100	100	99.54	100	100	100
13	93.69	96.9	100	100	100	99.88	100	100
14	85.55	94.99	99.47	98.76	99.37	100	99.69	100
15	69.04	87.31	91.38	95.72	98.33	98.37	99.76	100
16	89.34	95.34	99.94	99.69	99.87	100	100	100
OA	89.35	95.56	96.91	99.01	99.38	99.63	99.84	100
AA	92.34	96.54	98.31	99.57	99.51	99.79	99.88	100
K	88.09	95.06	96.55	98.89	99.31	99.59	99.82	100

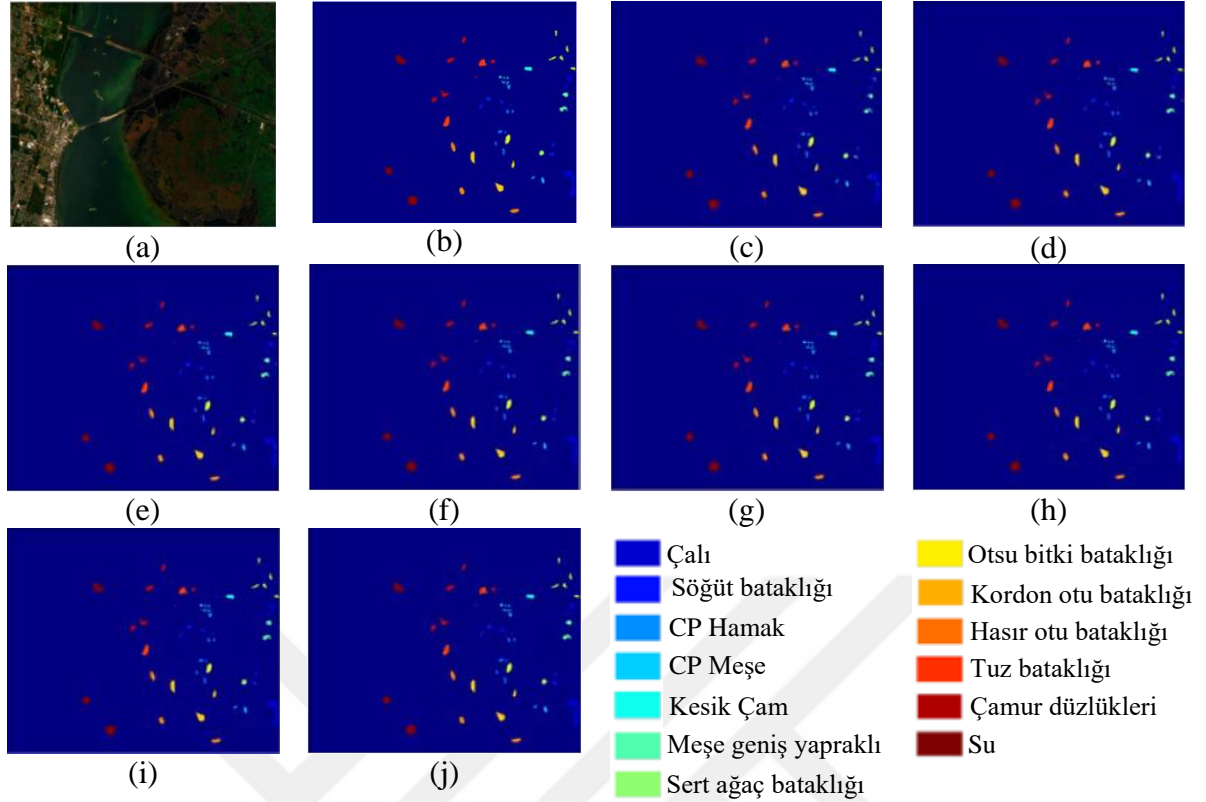


**Şekil 4. 9:** SA için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net.

Önerilen yöntemin performansını test etmek için kullanılan son veri seti KUM'dur. KUM ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.9'da verilmiştir. Bu veri seti kullanılarak gerçekleştirilen uygulamalar sonucunda 4CF-Net yönteminin OA, AA ve K değerlendirme ölçütlerine göre sırasıyla, %99.81, %99.68, %99.78 sonuçlarını elde ettiği görülmektedir. Sınıf bazlı doğruluklar incelendiğinde, 4 ve 6 nolu sınıflar haricinde diğer tüm sınıflarda önerilen yöntem %100 sonucunu vermektedir. 4 nolu sınıf için %100 ile MSSN, 6 nolu sınıf için %100 ile DFFN, MPRN ve MSSN yöntemleriyle en iyi sınıflandırma doğrulukları elde edilmiştir. OA, AA ve K ölçütlerine göre, önerilen yöntem en yakın sonuçlar sırasıyla %99.68, %99.54, %99.65 ile MSSN ve %99.56, %99.23, %99.52 ile DFFN yöntemlerinde elde edilmiştir. Diğer tüm veri setlerinde olduğu gibi bu veri setinde de en kötü performans gösteren yöntem DVM'dir. Tüm yöntemlerin sınıflandırma haritaları Şekil 4.10'da verilmiştir. Şekil 4.10'a göre, temel gerçeğe en çok benzeyen sınıflandırma haritası önerilen 4CF-Net yöntemine aittir. Ardından %99.54 AA değeri ile MSSN yönteminin sınıflandırma haritası temel gerçeğe benzemektedir.

**Çizelge 4. 9:** KUM kullanılarak elde edilen sınıflandırma doğrulukları (%).

Sınıf	DVM	3B ESA	ResNet	SSRN	DFFN	MPRN	MSSN	4CF-Net
1	95.18	97.81	97.26	99.84	98.19	100	100	100
2	86.31	87.21	94.57	100	100	100	100	100
3	83.55	95.24	97.38	94.76	100	100	99.01	100
4	73.57	63.87	75.74	95.05	96.91	93.81	100	97.36
5	59.31	80.69	82.81	87.5	100	99.24	91.41	100
6	69.57	87.92	85.64	97.34	100	100	100	98.55
7	92.63	92.63	91.76	100	100	72.62	100	100
8	93.81	97.68	97.37	100	99.71	100	100	100
9	98.08	96.79	100	100	100	100	100	100
10	91.21	94.23	100	100	100	100	100	100
11	95.77	98.41	100	100	100	100	100	100
12	91.83	95.36	99.01	98.76	100	99.49	100	100
13	99.28	96.29	100	100	100	100	100	100
OA	91.18	93.63	96.39	98.87	99.56	99.08	99.68	99.81
AA	86.93	91.09	93.01	98.14	99.23	98.46	99.54	99.68
K	90.17	92.92	95.98	98.74	99.52	98.98	99.65	99.78



**Şekil 4. 10:** KUM için tahmin edilen sınıflandırma haritaları. (a) Renkli görüntü, (b) temel gerçek, (c) DVM, (d) 3B ESA, (e) ResNet, (f) SSRN, (g) DFFN, (h) MPRN, (i) MSSN (j) 4CF-Net.

### 4.5 Uygulama 3: 3 Boyutlu Evrişimsel Sinir Ağı Tabanlı LeNet5 Mimarisi Kullanılarak Hiperspektral Uzaktan Algılama Görüntülerinin Uzamsal-Spektral Sınıflandırılması

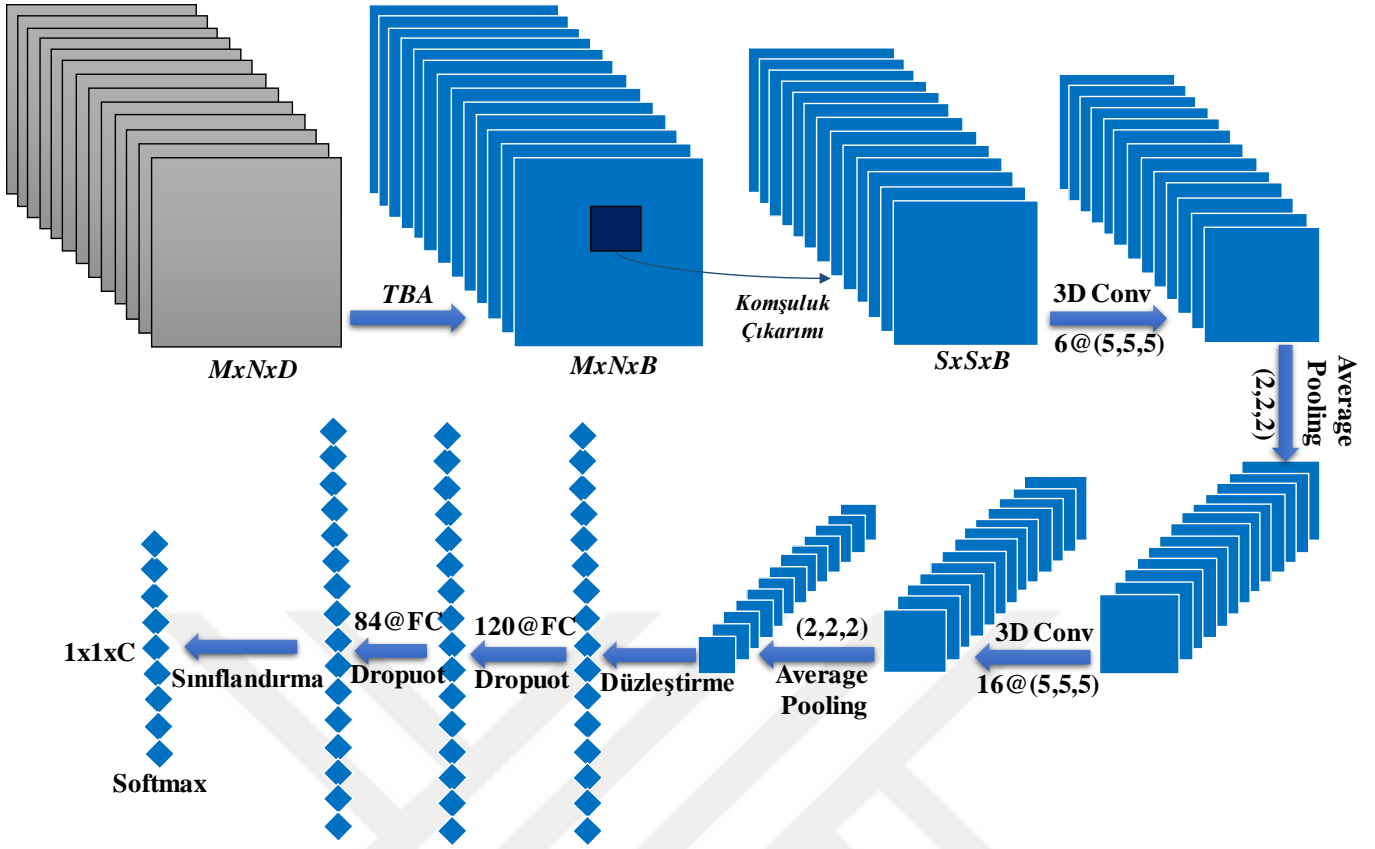
#### 4.5.1 Önerilen yöntem

Önerilen 3B ESA tabanlı LeNet5 (3BLeNet) yönteminin akış şeması Şekil 4.11'de gösterilmektedir. 3BLeNet yöntemi, iki 3B evrişim, iki ortalama havuzlama, düzleştirme, iki tam bağlantılı katman ve softmax katmanından oluşmaktadır. 3BLeNet yönteminin genel çerçevesinde, 3B evrişim çekirdeklerinin boyutları, birinci ve ikinci evrişim katmanları için sırasıyla  $6 \times 5 \times 5 \times 5 \times 1$  ve  $16 \times 5 \times 5 \times 5 \times 6$ 'dir. Burada  $16 \times 5 \times 5 \times 5 \times 6$ , önceki evrişim katmanından çıkarılan 6 özellik haritasına  $5 \times 5 \times 5$  boyutunda 16 3B çekirdeğin uygulanmasını ifade etmektedir. Her evrişim katmanından sonra özellik haritasının boyutunu azaltmak için, 3BLeNet yönteminde kullanılan her iki evrişim katmanında padding = "valid" kullanılmaktadır. Eğitim sürecini düzenlemek ve hızlandırmak için her evrişimden hemen sonra ve aktivasyondan önce Yığın Normalleştirme (Batch Normalization-BN), aktivasyon fonksiyonu olarak da ReLU kullanılmaktadır. Her aktivasyon işleminden sonra  $2 \times 2 \times 2$

çekirdek boyutunda ortalama havuzlama işlemi gerçekleştirilir. Ortalama havuzlama katmanları, evrişim işlemleri sonucunda elde edilen özellik haritalarının uzamsal boyutunu yarı yarıya azaltmaktadır. 2. ortalama havuzlama işleminden sonra, çıkarılan öznelikler düzleştirilmekte ve sınıflandırma için tam bağlantılı katmanlara girdi olarak verilmektedir. Önerilen 3BLeNet yönteminde sırasıyla 120 ve 84 nöronlu tam bağlantılı iki katman kullanılmaktadır. Aşırı öğrenmeyi önlemek için, tamamen bağlantılı her katmandan sonra %0.4 bırakma oranına sahip bir bırakma (dropout) katmanı uygulanmaktadır. 2. bırakma katmanından sonra elde edilen öznelikler, gerekli sınıflandırma sonucunu oluşturmak için basit softmax sınıflandırıcıya verilmektedir. Önerilen 3BLeNet yöntemi için her katmanda kullanılan katman tipi, çıktı boyutu ve elde edilen parametre sayısı Çizelge 4.10'da gösterilmektedir. Çizelge 4.10 incelendiğinde elde edilen parametre sayısının en fazla 1. yoğun katmanda olduğu görülmektedir. Ayrıca, son yoğun katmandaki düğüm sayısının, Indian pines veri setindeki sınıf sayısı ile aynı olan 16 olduğu görülmektedir. Bu nedenle, önerilen 3BLeNet yöntemindeki toplam parametre sayısı, doğrudan bir veri kümesindeki sınıf sayısına bağlıdır. Önerilen yöntemde ise Indian pines veri seti kullanılarak yapılan uygulamalar sonucunda elde edilen toplam eğitilebilir parametre sayısı 93.606'dır. Oldukça düşük sayıda eğitilebilir ağırlık parametresi, 3BLeNet yöntemimizi diğer derin öğrenme tabanlı yöntemlerden ayıran en önemli özelliklerden biridir. Ayrıca eğitim süreci herhangi bir veri artışı olmadan gerçekleştirilmektedir.

**Çizelge 4. 10:** Indian Pines için önerilen 3BLeNet mimarisinin özeti.

Katman	Çıktı	Parametre
input_1 (InputLayer)	(25,25,30,1)	0
conv3d_1 (Conv3D)	(21,21,26,6)	756
bn_conv3d_1 (BatchNormalization)	(21,21,26,6)	104
activation_conv3d_1 (Activation)	(21,21,26,6)	0
average_pooling3d (AveragePooling3D)	(10,10,13,6)	0
conv3d_2 (Conv3D)	(6,6,9,16)	12016
bn_conv3d_2 (BatchNormalization)	(6,6,9,16)	36
activation_conv3d_2 (Activation)	(6,6,9,16)	0
average_pooling3d_1 (AveragePooling3D)	(3,3,4,16)	0
flatten_1 (Flatten)	576	0
dense_1 (Dense)	120	69240
dropout_1 (Dropout)	120	0
dense_2 (Dense)	84	10164
dropout_2 (Dropout)	84	0
dense_3 (Dense)	16	1360
Toplam Parametre Sayısı: 93.676		
Toplam Eğitilebilir Parametre Sayısı: 93.606		
Eğitilemeyen Parametre Sayısı: 70		



Şekil 4. 11: Önerilen 3B ESA tabanlı LeNet5 mimarisi.

#### 4.5.2 Sınıflandırma sonuçları

Önerilen 3BLeNet yöntemin sınıflandırma performansını test etmek için IP, PU ve SA veri setleri üzerinde uygulamalar gerçekleştirilmiştir. Tüm uygulamalarda eğitim/test oranı %85-15'dir. Ayrıca, 0.0001 öğrenme oranına sahip kategorik çapraz entropi ve optimizasyon için kullanılan  $1e-06$  bozunma fonksiyonlu Adam optimizör kullanılmaktadır. Eğitim süreci, 256 yığın boyutu (batch size) ve 100 epochs için tekrarlanmaktadır. ReLU, softmax katmanı dışındaki tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. Her üç veri setinde evrişim için  $25 \times 25$  komşuluk (pencere boyutu) alınmaktadır. Öte yandan, TBA boyut indirgeme yönteminden sonra kullanılan spektral band sayısı her üç veri setinde de farklılık göstermektedir. Uygulamalarda IP, PU ve SA veri setleri için sırasıyla 30, 15 ve 15 temel bileşen kullanılmaktadır. Diğer derin öğrenme tabanlı yöntemlerle daha iyi bir karşılaştırma yapabilmek için temel bileşen değerleri bu şekilde seçilmiştir. Yani komşuluk çıkarımı sonucunda elde edilen 3B parçaların boyutu sırasıyla IP için  $25 \times 25 \times 30$ , PU ve SA veri setleri için  $25 \times 25 \times 15$  olarak ayarlanmıştır.

Önerilen 3BLeNet yöntemi, geleneksel DVM [80] sınıflandırıcıdan 2B ESA [82], 3B ESA [82], Spektral-Uzaysal Birleşik Ağ (Spectral-Spatial Unified Network-(SSUN)) [83],

Spektral-Uzamsal Artık Ağ (Spectral-Spatial Residual Network-(SSRN)) [45], Hibrit Spektral Ağ (Hybrid Spectral Network-(HybridSN)) [31], A Fast 3B ESA [32] ve HybridESA [22] gibi yeni derin öğrenme yöntemlerine kadar sekiz son teknoloji yöntemle karşılaştırılmıştır. 3BLeNet ve IP, PU ve SA veri setlerini kullanan diğer yöntemlerin sınıflandırma performansının bir karşılaştırması Çizelge 4.11'de gösterilmektedir. Önerilen 3BLeNet yöntemini karşılaştırma için kullanılan diğer yöntemlerden ayıran en önemli parametrelerden biri eğitim ve test süreleridir. Eğitim ve test süreleri Çizelge 4.12'de verilmiştir. Çalışmalarda eğitim süresi dakika, test süresi saniye olarak alınmaktadır. Derin öğrenme yöntemlerinin tasarlanmasındaki en önemli sorunlardan bir diğeri de hesaplama karmaşıklığıdır. Bu çalışmada, LeNet kullanımı sayesinde parametre sayısı önemli ölçüde azaltılmıştır. Aynı zamanda TBA boyut indirgeme yöntemi ile hesaplama sayısı azaltılmıştır. Böylece öznetelik çıkarma ve sınıflandırma için eğitim süresi önemli ölçüde kısalmaktadır.

**Çizelge 4. 11:** IP, PU ve SA veri setinde farklı yöntemlerle elde edilen sınıflandırma sonuçları (%).

Method	IP			PU			SA		
	OA	AA	K	OA	AA	K	OA	AA	K
DVM	85.30±2.8	79.03±2.7	83.10±3.2	94.34±0.2	92.98±0.4	92.50±0.7	92.95±0.3	94.60±2.3	92.11±0.2
2B ESA	89.48±0.2	86.14±0.8	87.96±0.5	97.86±0.2	96.55±0.0	97.16±0.5	97.38±0.0	98.84±0.1	97.08±0.1
3B ESA	91.10±0.4	91.58±0.2	89.98±0.5	96.53±0.1	97.57±1.3	95.51±0.2	93.96±0.2	97.01±0.6	93.32±0.5
SSUN	98.40±0.3	98.23±0.3	98.14±0.4	99.46±0.3	99.28±0.3	99.26±0.4	99.83±0.1	99.21±0.2	99.75±0.3
SSRN	99.19±0.3	98.93±0.6	99.07±0.3	99.90±0.0	99.91±0.0	99.87±0.0	99.98±0.1	99.97±0.0	99.97±0.1
HybridSN	99.75±0.1	99.63±0.2	99.71±0.1	99.98±0.0	99.97±0.0	99.98±0.0	100±0.0	100±0.0	100±0.0
A Fast 3B ESA	97.75±0.0	96.17±0.0	97.44±0.0	98.79±0.0	97.67±0.0	98.39±0.0	99.96±0.0	99.93±0.0	99.95±0.0
Hybrid ESA	99.80±0.0	99.71±0.1	99.75±0.1	99.99±0.0	99.98±0.0	99.99±0.0	100±0.0	100±0.0	100±0.0
3BLeNet	100±0.0	100±0.0	100±0.0	100±0.0	100±0.0	100±0.0	100±0.0	100±0.0	100±0.0

**Çizelge 4. 12:** IP, PU ve SA'da farklı yöntemlerle elde edilen sınıflandırma sonuçlarının eğitim (dakika) ve test süreleri (saniye).

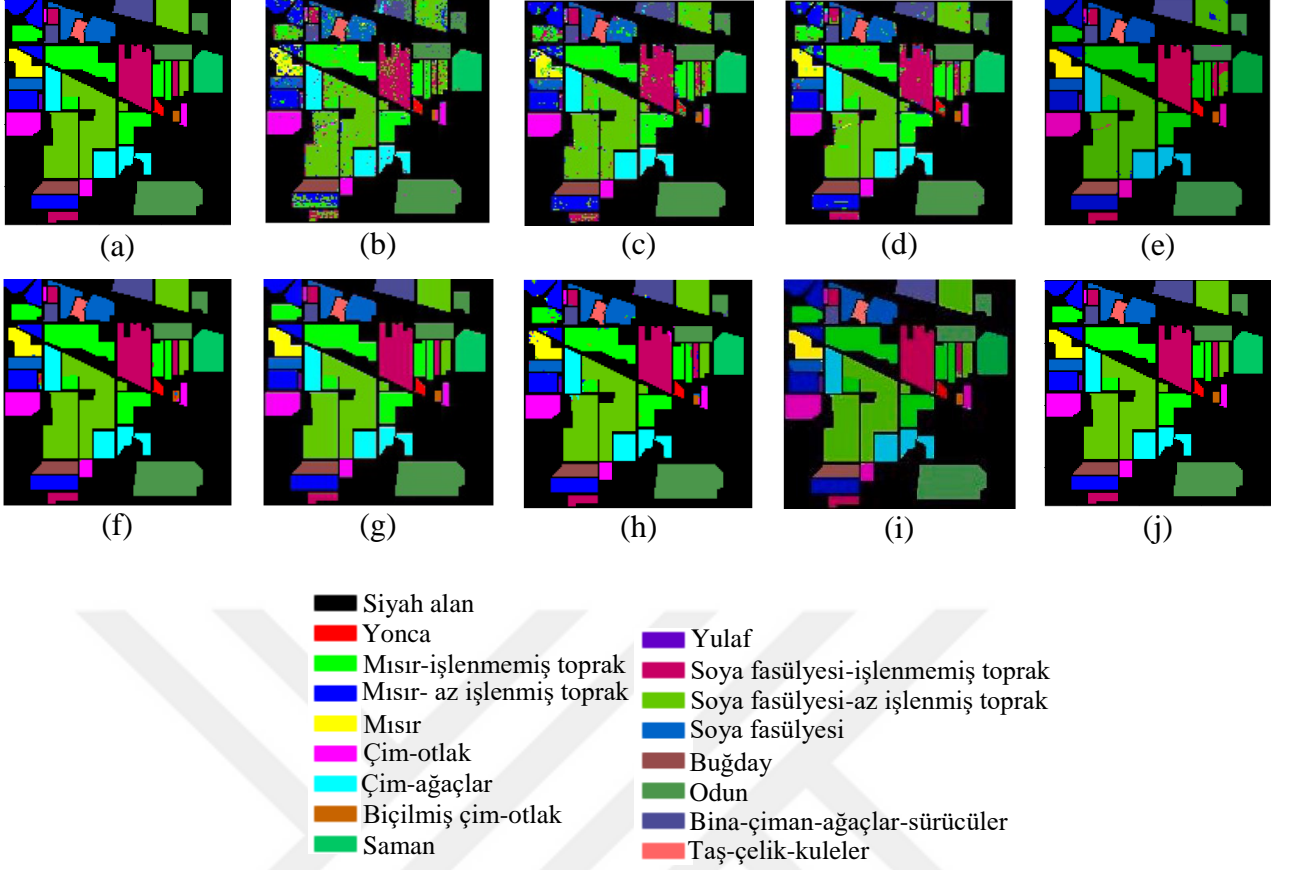
Method	IP		PU		SA	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
DVM	3.5	1.5	10.2	5.1	12.7	7.2
2B ESA	1.27	1	2.5	1.3	2.7	1.7
3B ESA	74.24	11	112.32	23.12	122.15	27
SSUN	22.1	6	33.12	4	29.12	4
SSRN	56	12	86	18	89	18.24
HybridSN	14.1	4.8	20.3	6.6	25.5	9
A Fast 3B ESA	18.3	4.7	24.5	6.77	29.7	7.46
HybridESA	32	1	43.1	11	45.35	12
3BLeNet	4.09	1	11.45	1	12.8	1

Çizelge 4.11'deki sınıflandırma sonuçlarına göre önerilen yöntemin (3BLeNet) IP, PU SA veri setlerinde maksimum OA, AA ve K verdiği görülmektedir. Çizelge 4.12'deki eğitim ve test süreleri incelendiğinde, önerilen yöntemin her üç veri setinde de diğer spektral uzamsal özellik tabanlı derin öğrenme yöntemlerinden daha az olduğu görülmektedir. Bu durum, önerilen 3BLeNet yönteminin hızlı yakınsaması ve hesaplama verimliliği ile sonuçlanmaktadır. Ayrıca, eğitim ve test süreleri büyük ölçüde internetin hızına ve kullanılabilir RAM'e bağlıdır. Aynı zamanda, TPU'nun veri işlemede CPU'dan daha hızlı olduğu sonucuna varılmaktadır.

IP veri setinde en düşük OA, AA ve K değerleri DVM tabanlı sınıflandırmada elde edilmiştir. DVM tabanlı sınıflandırmada AA değeri %80'in altındadır. Bu da her sınıf için doğru sınıflandırma sayısının oldukça düşük olduğunu göstermektedir. 2B ESA yöntemi, ilk adım olarak TBA'yı hiperspektral görüntüye uygulamaktadır. Bu yöntem hiperspektral görüntünün tek bir spektral bandı (ilk temel bileşen) için tasarlandığından ilk temel bileşen alınmaktadır. Giriş verileri olarak ilk temel bileşen için geniş bir komşuluk penceresi (27x27) kullanılmaktadır. 2B ESA yönteminde çekirdek boyutu 4x4, 5x5 ve 4x4 olan ve sırasıyla 32, 64 ve 128 filtreli üç evrişim katmanı kullanılmaktadır. İlk 4x4 evrişim katmanı ve 5x5 evrişim katmanından sonra 2x2 boyutunda havuzlama uygulanmaktadır. 5x5 evrişim katmanı ve ikinci 4x4 evrişim katmanından sonra, düzenleme için %50 bırakma gerçekleştirilmektedir. ReLU, tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. 2B ESA yönteminin OA, AA ve K değerleri geleneksel sınıflandırıcı DVM yönteminden daha iyidir. Ayrıca 2B ESA yönteminde sadece ilk temel bileşen kullanıldığı için eğitim süresinin diğer tüm yöntemlere göre daha iyi olduğu görülmektedir. Test süresi, önerilen 3BLeNet yöntemi ve HybridESA ile aynı görünmektedir. 3B ESA yönteminde boyut indirgeme yöntemi uygulanmamıştır. Giriş verisi olarak pencere boyutu 27x27 kullanılmaktadır. Başka bir ifadeyle, özellik çıkarımı için 27x27x200'lük bir görüntü parçası kullanılmaktadır. Bu yöntem sırasıyla 128, 192, 256 filtre ve 4x4x32, 5x5x32, 4x4x32 çekirdek boyutlarına sahip 3B evrişim katmanlarından oluşmaktadır. Ayrıca ilk 4x4x32 3B evrişim katmanı ve 5x5x32 3B evrişim katmanından sonra 2x2 boyutunda havuzlama işlemi gerçekleştirilmektedir. 5x5x32 3B evrişim katmanından ve ikinci 4x4x32 3B evrişim katmanından sonra, düzenleme için %50 bırakma gerçekleştirilmektedir. ReLU, tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. 3B ESA yönteminin OA, AA ve K değerleri, 2B ESA ve geleneksel sınıflandırıcı DVM yönteminden daha iyidir. Bu yöntemde boyut indirgeme tekniği uygulanmadığı için bu yöntemin eğitim süresi diğer tüm yöntemlere göre daha fazladır. Test süresi açısından SSRN yöntemi dışındaki tüm yöntemlere göre daha

yüksektir. Uzamsal-spektral öznelikleri çıkaran SSUN ve SSRN yöntemlerinin OA, AA ve K değerleri önceki yöntemlere göre daha iyidir. SSRN yönteminde artık blokların kullanılması OA, AA ve K değerlerini SSUN yöntemine göre sırasıyla %0.79, %0.7 ve %0.93 oranında arttırmaktadır. SSRN'nin eğitim süresi, SSUN'un iki katından fazladır. HybridSN yönteminde boyut indirgeme yöntemi olarak TBA kullanılmaktadır. HybridSN yöntemi, üç veri setinin tümünde evrişim için 25x25 komşuluk kullanılmaktadır. Ayrıca, TBA uygulandıktan sonra çıkarılan spektral band sayısı IP için 30, PU ve SA için 15 temel bileşendir. Bu yöntem sırasıyla 8, 16, 32 filtre ve 3x3x7, 3x3x5, 3x3x3 çekirdek boyutlarına sahip 3B evrişim katmanlarından ve 64 filtre ve 3x3 çekirdek boyutlarına sahip 2B evrişim katmanından oluşmaktadır. OA, AA ve K değerlendirme kriterleri dikkate alındığında HybridSN yöntemi, Hybrid CNN yöntemine göre sırasıyla %0.05, %0.08 ve %0.04 daha az değerlere sahiptir. Benzer şekilde, OA, AA ve K değerlendirme kriterleri dikkate alındığında, HybridSN önerilen yönteme göre sırasıyla %0.25, %0.37 ve %0.29 daha azdır. Bu yöntem ile, önerilen yöntem ve HibritESA yöntemi dışındaki tüm yöntemlerden daha iyi sınıflandırma sonuçları elde edilmektedir. Son olarak, eğitim süresi, önerilen yöntem dışındaki diğer uzamsal-spektral tabanlı yöntemlerden daha iyidir. A fast 3B ESA yöntemi için, ilk adım olarak hiperspektral görüntüye artımsal TBA uygulamaktadır. Bu yöntem, üç veri setinin tümünde evrişim için 25x25 komşuluk kullanılmaktadır. Ayrıca, artımsal TBA yöntemiyle en bilgilendirici 20 spektral band alınmaktadır. Bu yöntem sırasıyla 8, 16, 32,64 filtre ve 3x3x7, 3x3x5, 3x3x3,3x3x3 çekirdek boyutlarına sahip 3B evrişim katmanlarından oluşmaktadır. Bu yöntemin OA, AA ve K değerlerine bakıldığında DVM, 2B ESA ve 3B ESA yöntemlerinden daha iyi sonuçlar verdiği görülmektedir. Ancak diğer tüm yöntemlere göre daha kötü sonuçlar vermektedir. Eğitim süresi, HybridSN ve önerilen yöntem dışındaki diğer uzamsal-spektral tabanlı yöntemlerden daha iyidir. HybridESA yönteminin OA, AA ve K değerlerine bakıldığında önerilen yöntem dışındaki tüm yöntemlerden daha iyi performans gösterdiği görülmektedir. Önerilen yönteme göre OA, AA ve K değerleri sırasıyla %0.2, %0.29 ve %0.25 daha azdır. Eğitim süresi önerilen yöntemden daha uzundur ancak test süresi aynıdır. Şekil 4.12, IP veri seti için 8 derin öğrenme yöntemi ile önerilen yöntemin sınıflandırma sonuç haritalarını göstermektedir. Şekil 4.12 incelendiğinde, önerilen yöntemin sınıflandırma haritası temel gerçeği ile aynı olduğu görülmektedir.






**Şekil 4. 12:** IP için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet.

PU veri setindeki görüntülerin uzamsal boyutları IP veri setinden daha büyüktür. Aynı zamanda PU veri setinin eğitim ve test örneklerinin sayısı IP veri setinden daha fazladır. Önerilen yöntem, PU veri setindeki tüm değerlendirme kriterlerinde %100 ile maksimum sonuç vermektedir. Sınıflandırma haritası tam olarak temel gerçek ile aynıdır. PU veri setinde en düşük OA, AA ve K değerleri DVM tabanlı sınıflandırmada elde edilmektedir. PU, çekirdek boyutu, evrişim katmanı sayısı, filtre sayısı ve komşuluk açısından 2B ESA yönteminde IP'ye benzemektedir. 2B ESA için OA, AA ve K değerleri sırasıyla DVM yönteminden yaklaşık %3.52, %3.57 ve %4.66 daha yüksektir. Benzer şekilde eğitim ve test süresi de DVM yöntemine göre daha kısadır. PU kullanan 3B ESA yöntemi, filtre sayısı açısından IP'nin kullanıldığı 3B ESA yönteminden farklıdır. PU veri setinde, 3B ESA yöntemi sırasıyla 4x4x32 çekirdek boyutunda 32 filtre, 5x5x32 çekirdek boyutunda 64 filtre ve 4x4x32 çekirdek boyutunda 128 filtre kullanmaktadır. Diğer tüm işlemler ve parametreler, IP veri setindeki 3B ESA yöntemi ile aynıdır. IP veri setinde olduğu gibi PU veri setinde de 3B ESA yöntemi en yüksek eğitim ve test süresine sahiptir. Çünkü 3B ESA yönteminde herhangi bir boyut indirgeme yöntemi kullanılmamaktadır. Hem uzamsal hem de spektral öznelikleri çıkararak diğer tüm yöntemler karşılaştırıldığında,

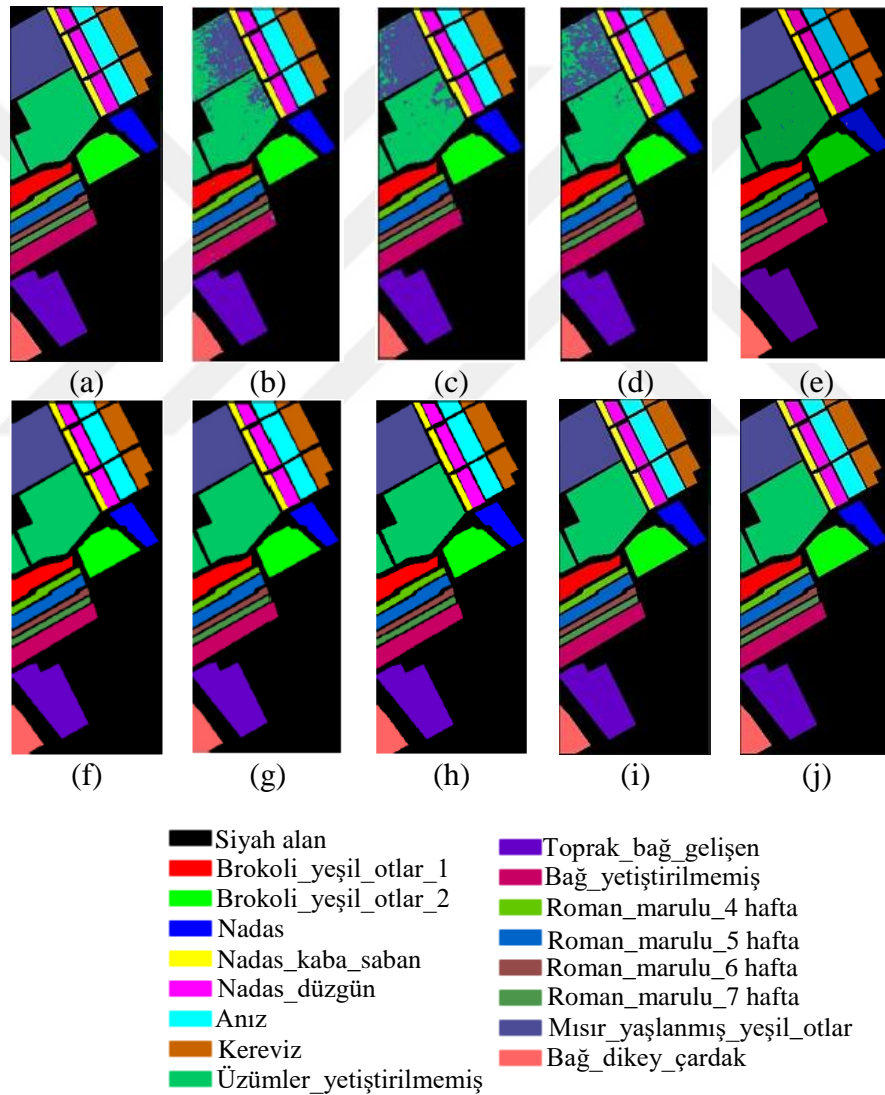
HybridSN, HybridESA ve SSRN yöntemlerinde önerilen 3BLeNet yöntemine en yakın OA, AA ve K değerleri elde edilmiştir. Ancak bu yöntemler arasındaki en büyük fark, eğitim ve test süresidir. Önerilen 3BLeNet yönteminin eğitim ve test süresi, geleneksel sınıflandırıcı DVM'den ve uzamsal-spektral özellikleri çıkaran diğer yöntemlerden daha azdır. 2B ESA yöntemi yalnızca bir temel bileşen kullandığından, eğitim süresi önerilen 3BLeNet yöntemi de dahil olmak üzere tüm yöntemlerden daha kısadır. Şekil 4.13, PU veri setinin sınıflandırma sonuç haritalarını göstermektedir.



**Şekil 4. 13:** PU için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet.

SA veri setinin eğitim ve test örnekleri, hem IP hem de PU veri setlerinden daha fazladır. Bu veri setinde diğer veri setlerinde olduğu gibi en düşük OA, AA ve K değerleri DVM'de elde edilmektedir. 2B ESA ve 3B ESA karşılaştırıldığında, 2B ESA yöntemi daha iyi sınıflandırma doğruluğuna sahiptir. Eğitim ve test süresi yine 3B ESA yönteminde en yüksektir. SSUN yönteminin OA, AA ve K değerleri önerilen 3BLeNet yönteminden sırasıyla yaklaşık %0.17, %0.79 ve %0.25 daha azdır. SSRN yönteminin OA, AA ve K değerleri önerilen 3BLeNet yönteminden sırasıyla yaklaşık %0.02, %0.03 ve %0.03 daha azdır. A Fast 3B ESA yönteminin OA, AA ve K değerleri önerilen 3BLeNet yönteminden

sırasıyla yaklaşık %0.04, %0.07 ve %0.05 daha azdır. SSUN, SSRN ve A Fast 3B ESA yönteminin sınıflandırma doğrulukları incelendiğinde önerilen 3BLeNet yöntemine en çok benzeyen SSRN yöntemidir. Ancak eğitim ve test süresi incelendiğinde bu üç yöntem arasında en fazla eğitim ve test süresine sahip olan SSRN yöntemidir. Önerilen 3BLeNet yöntemi, SA veri setinde %100 OA, AA ve K elde etmektedir. Sınıflandırma haritası tam olarak temel gerçek ile aynıdır. HybridSN ve HybridESA yöntemleri için de %100 OA, AA ve K değerleri elde edilmektedir. Bu iki yöntemdeki sınıflandırma haritası da tam olarak temel gerçek ile aynıdır. Ancak, önerilen 3BLeNet yöntemi eğitim ve test süresi açısından diğer tüm uzamsal-spektral öznelik çıkarma yöntemlerinden daha hızlıdır. Şekil 4.14, SA veri setinin sınıflandırma sonuç haritalarını göstermektedir.



**Şekil 4. 14:** SA için sınıflandırma haritaları. (a) Temel gerçek, (b)-(j) DVM, 2B ESA, 3B ESA, SSUN, SSRN, HybridSN, A Fast 3B ESA, HybridESA ve önerilen 3BLeNet.

Sınırlı eğitim örneklemi üzerinde yapılacak uygulamalar için her sınıftan  $\min(d_i * 20\%, 200)$  formülü kullanılarak eğitim örnekleri rastgele seçilmektedir.  $d_i$  her sınıftaki örnek sayısıdır. Kalan örnekler test için kullanılmaktadır [22]. Bu kriter kullanılarak, önerilen 3BLeNet yönteminin sınıflandırma doğruluğu, sınırlı sayıda eğitim örneği ile kontrol edilmektedir. Sınıflandırma performans sonuçları Çizelge 4.13'de gösterilmektedir. Çizelge 4.13 incelendiğinde her bir yöntemin sınıflandırma doğruluğunun biraz düştüğü ancak önerilen 3BLeNet yönteminin diğer tüm yöntemlerden daha iyi performans gösterdiği görülmektedir. Sınırlı eğitim örneklerinin kullanılması, derin öğrenme ağlarında çoğu parametrenin aşırı öğrenmesine neden olmaktadır. Bu durum sınıflandırma performansını düşürmektedir. Önerilen 3BLeNet yöntemi, diğer yöntemlere göre daha az sayıda eğitim parametresine sahiptir. Aynı zamanda, tüm parametreler daha az örnekte doğru şekilde optimize edilmektedir. Bu durum aşırı öğrenmeyi önlemektedir. Önerilen 3BLeNet yöntemi daha az eğitilebilir parametreye sahip olduğundan, sınırlı eğitim örneklerinde daha iyi sınıflandırma performansına sahiptir.

Uzamsal boyutun önerilen 3BLeNet yönteminin performansı üzerindeki etkisi Çizelge 4.14'te gösterilmektedir. En yüksek sınıflandırma sonuçlarının 17x17 ve 25x25 uzamsal boyutlarda elde edildiği görülmektedir. 25x25 uzamsal boyut, diğer yöntemlerle uygun bir karşılaştırma için seçilmiştir.

**Çizelge 4. 13:** Sınırlı eğitim örnekleri ile farklı derin öğrenme yöntemlerini kullanan IP, PU ve SA için sınıflandırma doğruluklarının karşılaştırılması (%).

Method	IP			PU			SA		
	OA	AA	K	OA	AA	K	OA	AA	K
2B ESA	86.81±0.5	85.37±0.3	85.48±0.3	95.25±0.6	94.46±0.3	95.11±0.3	97.38±0.0	96.26±0.3	96.12±0.3
3B ESA	90.49±0.3	88.39±0.4	89.17±0.3	95.73±0.2	96.43±0.3	94.26±0.4	92.37±0.4	92.32±0.6	92.19±0.4
SSUN	95.27±0.3	94.29±0.3	95.14±0.3	97.49±0.2	97.22±0.5	97.24±0.7	98.39±0.2	98.58±0.3	98.72±0.2
SSRN	97.43±0.4	96.38±0.2	98.17±0.2	97.38±0.3	98.41±0.4	98.17±0.0	98.27±0.4	98.43±0.2	98.12±0.2
HybridSN	98.14±0.3	97.32±0.4	98.15±0.2	98.13±0.0	98.04±0.2	98.11±0.2	98.02±0.3	98.14±0.3	98.26±0.2
HybridESA	99.17±0.2	98.11±0.1	98.75±0.1	99.12±0.2	98.87±0.3	98.45±0.2	98.12±0.2	99.12±0.3	99.35±0.5
3BLeNet	99.21±0.0	98.30±0.0	99.10±0.0	99.67±0.0	99.12±0.0	99.56±0.0	99.94±0.0	99.93±0.0	99.94±0.0

**Çizelge 4. 14:** Pencere boyutunun 3BLeNet üzerindeki etkisi.

Pencere Boyutu	IP			PU			SA		
	OA(%)	AA(%)	K(%)	OA(%)	AA(%)	K(%)	OA(%)	AA(%)	K(%)
11x11	99.48	96.46	99.41	100	100	100	100	100	100
13x13	99.93	99.96	99.93	100	100	100	100	100	100
15x15	100	100	100	99.98	99.98	99.98	100	100	100
17x17	100	100	100	100	100	100	100	100	100
19x19	99.93	99.93	99.92	100	100	100	100	100	100
21x21	99.80	97.86	99.78	100	100	100	100	100	100
23x23	99.74	96.80	99.70	100	100	100	100	100	100
25x25	100	100	100	100	100	100	100	100	100

## 4.6 Uygulama 4: Hiperspektral Uzaktan Algulama Görüntü Sınıflandırması için 3 Boyutlu Residual Uzamsal-Spektral Evrişim Ağı

### 4.6.1 Önerilen yöntem

Şekil 4.1’de önerilen yöntemlerin genel çerçevesi verilmiştir. 3B hiperspektral veri küpleri oluşturulduktan sonra sınıflandırma sonucunu bulmak için geliştirilen derin öğrenme tabanlı yöntemin girişine verilmektedir. Bu bölümde hiperspektral uydu görüntülerinden uzamsal-spektral özellikleri çıkarabilmek için 3B ESA tabanlı ResNet18 mimarisi önerilmiştir. Resnet18 mimarisinin kullanılmasının temel nedeni, diğer derin ESA yöntemlerine kıyasla yüksek sınıflandırma performansı sağlaması ve eğitilebilir parametre sayısının optimal olmasıdır. Önerilen yöntemin akış şeması Şekil 4.15’te gösterilmektedir. Tüm ağ, birden fazla artık öğrenme bloğundan oluşmaktadır. Bu artık öğrenme blokları, atlama bağlantısının türüne göre iki farklı bloğa ayrılmaktadır. Bunlar, Şekil 4.16’da gösterildiği gibi kimlik bloğu ve evrişim bloğudur. ResNet18, beş kimlik bloğu ve üç evrişim bloğundan oluşmaktadır. Kimlik bloğundaki atlama bağlantısı, herhangi bir değişiklik yapmadan önceki özellik haritasının derinliğini korurken, evrişim bloğundaki atlama bağlantısı, 1x1x1 evrişimi uygulayarak önceki özellik haritasının derinliğini arttırmaktadır. Ayrıca, artık öğrenmenin her bloğu, ard arda 3x3x3 filtre boyutuna sahip iki evrişim katmanına sahiptir. Bu filtreler, eğitim süreci sırasında optimize edilen eğitilebilir parametreleri içermektedir. Önerilen 3B ESA tabanlı ResNet18 yöntemi, 20 evrişim, tam bağlantılı, maksimum (max-pool) ve ortalama (avg-pool) havuzlama katmanlarından oluşmaktadır. Komşuluk çıkarımı sonucunda elde edilen SxSxB 3B hiperspektral veri küpü ResNet18 mimarisinin girişine verildikten sonra ResNet18 mimarisinin uygulama aşamaları şu şekildedir:

**Adım 1:** Seçilen ResNet18 mimarisinin ilk katmanında, hiperspektral veri küpünden komşuluk çıkarımı ile elde edilen 3B giriş görüntüsüne 7x7x7 çekirdek boyutuna (conv1) ve 64 filtreye sahip bir 3B ESA uygulanmaktadır. 2B ESA’da, evrişim işlemleri yalnızca uzamsal özellik bilgilerini elde eden 2B özellik haritalarına uygulanmaktadır. 3B görüntülere uygulandığında uzamsal-spektral öznitelik bilgilerinin elde edilmesi istenmektedir. Bununla birlikte, 2B evrişim işlemi, 2B veya 3B görüntülerde gerçekleştirilip gerçekleştirilmediğine bakılmaksızın 2B boyutlu çıktılar üretmektedir. 3B ESA, 3B evrişim çekirdeğini (çekirdek boyutu) kullanarak her 3B hiperspektral veri küpüne evrişim işlemi uygulamakta ve uzamsal-spektral özellikleri çıkarmaktadır. ResNet18 literatürde 2B ESA

ile birlikte kullanılmaktadır. Ancak 3B ESA tabanlı ResNet18 yönteminde 3B evrişim katmanları kullanılarak 3B ESA gerçekleştirilmektedir. İlk 3B evrişim'den (conv1) sonra, eğitim sürecini düzenlemek ve hızlandırmak için BN, ardından ReLU (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmaktadır. ReLU'dan sonra 3x3x3 boyutunda maksimum havuzlama uygulanmaktadır.

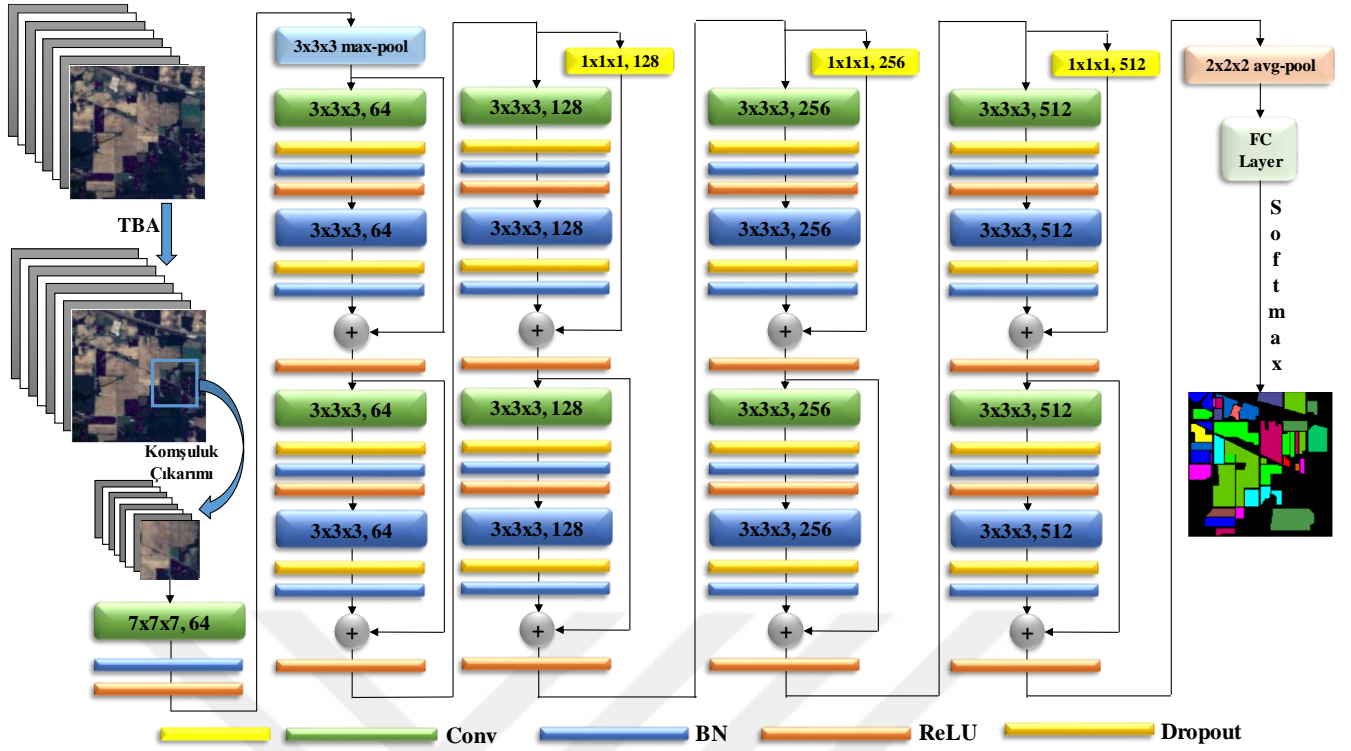
**Adım 2:** Maksimum havuzlama işleminden sonra, elde edilen özellik haritası ardışık olarak iki kimlik bloğundan geçirilmektedir. Her kimlik bloğu, 64 filtrelili iki 3x3x3 evrişim katmanı içermektedir. Aşırı öğrenmeyi önlemek için, her evrişim katmanından sonra %0.5 bırakma oranına sahip bir bırakma (dropout) katmanı, her bırakma katmanından sonra BN ve ReLU katmanları uygulanmaktadır.

**Adım 3:** Bir evrişim bloğu ve bir kimlik bloğundan oluşmaktadır. 3x3x3 evrişim işlemi hem evrişim bloğunda hem de kimlik bloğunda gerçekleştirilmektedir. Evrişim bloğunda 1x1x1 evrişimin uygulanması sonucunda önceki özellik haritasının derinliği artmakta ve 64'ten 128'e çıkmaktadır. Tüm evrişim katmanlarının yeni derinliği 128'dir. Önceki adımda olduğu gibi, bırakma, BN ve ReLU katmanları uygulanmaktadır.

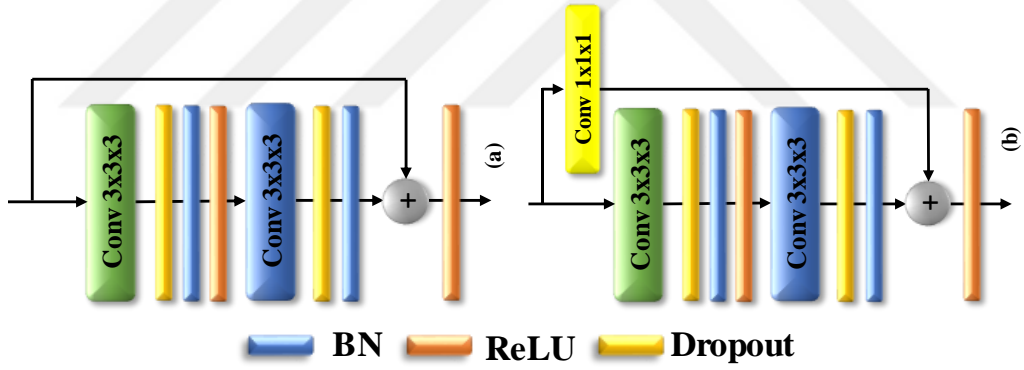
**Adım 4:** Bir evrişim bloğu ve bir kimlik bloğundan oluşmaktadır. Her iki blokta 3x3x3 evrişim katmanları içermektedir. Evrişim bloğunda 1x1x1 evrişimin uygulanması sonucunda önceki özellik haritasının derinliği artmakta ve 128'den 256'ya çıkmaktadır. Tüm evrişim katmanlarının yeni derinliği 256'dır. Önceki adımda olduğu gibi, bırakma, BN ve ReLU katmanları uygulanmaktadır.

**Adım 5:** Bir evrişim bloğu ve bir kimlik bloğundan oluşmaktadır. Her iki blokta 3x3x3 evrişim katmanları içermektedir. Evrişim bloğunda 1x1x1 evrişimin uygulanması sonucunda önceki özellik haritasının derinliği artmakta ve 256'dan 512'ye çıkmaktadır. Tüm evrişim katmanlarının yeni derinliği 512'dir. Önceki adımda olduğu gibi, bırakma, BN ve ReLU katmanları uygulanmaktadır.

**Adım 6:** Arka arkaya üç evrişim bloğu ve beş kimlik bloğu uygulandıktan sonra, elde edilen özellik haritası 2x2x2 ortalama havuzlama katmanından geçirilmektedir. Son olarak, çıkarılan özellikler düzleştirilmekte ve softmax aktivasyonu kullanılarak girdisini sınıf sayısına indirmek için bir FC katmanı kullanılmaktadır. Önerilen 3B ESA tabanlı ResNet18 yönteminin ayrıntılı yapısı Çizelge 4.15'de gösterilmektedir.



Şekil 4. 15: Hiperspektral görüntü sınıflandırması için önerilen 3B ESA tabanlı ResNet18 mimarisi.



Şekil 4. 16: (a) Kimlik bloğu (b) Evrişim bloğu.

**Çizelge 4. 15:** IP veri seti için önerilen yöntemin ayrıntılı yapısı.

Katman	Özellik haritası boyutu	Filtre	Çekirdek boyutu	Stride	Padding
Input	25x25x30	-	-	-	-
Conv1	13x13x15	64	7x7x7	2	3
Max-pooling	6x6x7	1	3x3x3	2	0
Identity Block 1 (Conv2_1, Conv2_2)	6x6x7 6x6x7	64 64	3x3x3 3x3x3	1	1
Identity Block 2 (Conv3_1, Conv3_2)	6x6x7 6x6x7	64 64	3x3x3 3x3x3	1	1
Convolution Block 1 (Conv4_1, Conv4_2)	3x3x4 3x3x4 3x3x4	128 128 128	3x3x3 3x3x3 1x1x1	2 1 1	1 1 0
Identity Block 3 (Conv5_1, Conv5_2)	3x3x4 3x3x4	128 128	3x3x3 3x3x3	1 1	1 1
Convolution Block 2 (Conv6_1, Conv6_2)	2x2x2 2x2x2 2x2x2	256 256 256	3x3x3 3x3x3 1x1x1	2 1 1	1 1 0
Identity Block 4 (Conv7_1, Conv7_2)	2x2x2 2x2x2	256 256	3x3x3 3x3x3	1 1	1 1
Convolution Block 3 (Conv8_1, Conv8_2)	1x1x1 1x1x1 1x1x1	512 512 512	3x3x3 3x3x3 1x1x1	2 1 1	1 1 0
Identity Block 5 (Conv9_1, Conv9_2)	1x1x1 1x1x1	512 512	3x3x3 3x3x3	1 1	1 1
Avg-pooling	1x1x1	1	2x2x2	2	1
Flatten	512	-	-	-	-
FC	16	-	-	-	-
Softmax	16	-	-	-	-

#### 4.6.2 Sınıflandırma sonuçları

Tüm uygulamalarda eğitim/test oranı %70-30'dur. Optimizasyon için 0.001 öğrenme oranlı kategorik çapraz entropi ve 1e-06 bozunma fonksiyonlu Adam optimizasyon kullanılmıştır. Eğitim süreci, 256 yığın boyutu ve 100 epochs için tekrarlanmaktadır. ReLU, Softmax katmanını dışındaki tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. Uygulamalarda kullanılan IP, PU ve SA veri setlerinde evrişim için 25x25 komşuluk (pencere boyutu) kullanılmaktadır. Öte yandan, TBA boyut indirgeme yönteminden sonra kullanılan spektral band sayısı her üç veri setinde de farklılık göstermektedir. Uygulamalarda IP, PU ve SA veri setleri için sırasıyla 30, 15 ve 15 temel bileşen kullanılmaktadır. Yani komşuluk çıkarımı sonucunda elde edilen 3B parçaların boyutu sırasıyla IP için 25x25x30, PU ve SA veri setleri için 25x25x15 olarak ayarlanmaktadır. Önerilen yöntem (ÖY), geleneksel DVM [80] sınıflandırıcısından başlayarak 2B ESA [84],



3B ESA [85], M3B-ESA [44], SSRN [45] ve HybridSN [31] gibi yeni derin öğrenme yöntemlerine kadar altı son teknoloji yöntemle karşılaştırılmıştır.


DVM, hiperspektral görüntü sınıflandırması için kullanılan geleneksel ve klasik bir makine öğrenmesi yöntemidir. Yüksek sınıflandırma doğruluğu sağlar ve eğitim örneklerinin sayısı ile hassasiyeti daha azdır. Bu nedenle gerçekleştirilen uygulamalarda sınıflandırma performansı karşılaştırılırken mevcut yöntemlerden biri olarak DVM seçilmiştir. 2B ESA yöntemi, 2B evrişim çekirdeklerini kullanarak her pikselin yerel uzamsal özelliklerini hiperspektral görüntülerden çıkarmaktadır. 3B ESA, hiperspektral görüntülerin hem uzamsal hem de spektral özelliklerini öğrenmek için geliştirilmiştir. 3B ESA yöntemi, 3B evrişim çekirdeklerini kullanarak hiperspektral görüntülerden aynı anda uzamsal-spektral özellikleri çıkarmaktadır. M3B-ESA yöntemi, hiperspektral görüntü sınıflandırması için 2B çok ölçekli uzamsal özelliği ve 1B spektral özelliği birlikte öğrenebilen çok ölçekli bir 3B derin ESA'dır. SSRN, 3B evrişim ile elde edilen spektral özellikleri ve 2B evrişim ile elde edilen uzamsal özellikleri kademeli olarak birleştirerek, modelin sürekli olarak uzamsal-spektral özellikleri çıkarmasına izin vermektedir. HybridSN, 3B ESA ve 2B ESA'dan oluşmaktadır. Ortak uzamsal-spektral özellikleri çıkarmak için 3B ESA kullanılırken, uzamsal özellikleri çıkarmak için 3B ESA'dan sonra 2B ESA kullanılmaktadır. Adil karşılaştırma yapmak için, IP için 25x25x30, PU ve SA için 25x25x15 gibi farklı veri setleri için giriş hacminin 3B parçalarında aynı uzamsal boyut çıkarılmaktadır.

İlk uygulamada IP veri seti kullanılmıştır. Her sınıfın sınıf bazında ve OA, AA ve K değerlendirme ölçütlerine göre sınıflandırma doğrulukları Çizelge 4.16'da gösterilmiştir. IP veri seti ile yapılan uygulamalar sonucunda elde edilen temel gerçek ve sınıflandırma haritaları Şekil 4.17'de verilmiştir. Çizelge 4.16 incelendiğinde önerilen yöntemin OA, AA ve K değerlerinin klasik sınıflandırma yöntemlerinden biri olan DVM'ye göre sırasıyla %14.63, %20.7 ve %16.82 daha yüksek olduğu görülmektedir. Ayrıca diğer sınıflandırma yöntemlerinden 2B ESA'dan %10.45, %13.59 ve %11.96, 3B ESA'dan ise sırasıyla %8.83, %8.15 ve %9.94 daha yüksektir. En düşük OA, AA ve K değerleri DVM tabanlı sınıflandırmada elde edilmektedir. DVM tabanlı sınıflandırmada AA değeri %80'in altındadır. Bu da her sınıf için doğru sınıflandırma sayısının oldukça düşük olduğunu göstermektedir. Önerilen yöntem, gelişmiş yöntemlerden biri olan M3B ESA ile karşılaştırıldığında, sırasıyla OA, AA ve K değerlerinin sırasıyla %4.61, %3.32 ve %5.22 oranında daha iyi performans gösterdiği görülmektedir. Benzer şekilde, SSRN'ye kıyasla

%0.74, %0.8 ve %0.85 ve HybridSN'ye kıyasla %0.18, %0.1 ve %0.21 daha iyi sınıflandırma performansı sağlamaktadır. OA, AA ve K değerlendirme metrikleri dikkate alındığında, önerilen yöntemin en iyi sınıflandırma doğruluk değerlerine sahip olduğu görülmektedir. Sınıf bazlı sınıflandırmada en iyi sınıflandırma doğrulukları 5. ve 16. sınıflar dışındaki tüm sınıflarda önerilen yöntem ile elde edilmektedir. Sınıf 5 için en iyi sınıflandırma doğruluğu %99.53 ile HybridSN'de elde edilmiştir. Önerilen yöntem ile elde edilen sınıflandırma doğruluğu %99.31'dir. Önerilen yöntem, HybridSN yönteminden %0.22 daha azdır. 16.sınıf için en iyi sınıflandırma doğruluğu %100 ile 2B ESA ve M3B ESA yöntemlerinde elde edilmektedir. Şekil 4.17 incelendiğinde ise, temel gerçek haritasına en çok benzeyen yöntemin önerilen yöntem olduğu görülmektedir.

**Çizelge 4. 16:** IP veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	DVM	2B ESA	3B ESA	M3B ESA	SSRN	HybridSN	ÖY
1	32/14	82.20	75.00	79.23	97.03	97.82	99.38	100
2	1000/428	73.82	81.40	88.60	97.90	99.17	99.58	100
3	581/249	82.15	87.60	85.81	92.41	99.53	99.66	100
4	166/71	77.12	62.04	90.53	93.25	97.79	99.88	100
5	338/145	73.66	92.30	96.11	95.00	99.24	99.53	99.31
6	511/219	93.40	99.21	98.43	99.74	99.51	99.96	100
7	20/8	96.21	75.00	92.36	100	98.70	99.00	100
8	335/143	85.72	100	98.51	99.99	99.85	100	100
9	14/6	97.38	64.28	88.90	96.61	98.50	100	100
10	680/292	71.01	82.79	87.72	96.32	98.74	99.56	100
11	1718/737	76.50	91.27	91.42	97.13	99.30	99.84	100
12	415/178	83.90	82.89	90.04	97.16	98.43	99.52	100
13	143/61	83.56	99.30	99.00	99.60	100	99.86	100
14	886/380	98.63	98.87	97.95	98.42	99.31	100	100
15	270/116	94.21	86.29	82.57	83.31	99.20	99.85	100
16	65/28	69.63	100	98.51	100	97.82	98.46	96.42
OA	7174/3075	85.30±2.8	89.48±0.2	91.10±0.4	95.32±0.1	99.19±0.3	99.75±0.1	99.93±0.0
AA		79.03±2.7	86.14±0.8	91.58±0.2	96.41±0.7	98.93±0.6	99.63±0.2	99.73±0.0
K		83.10±3.2	87.96±0.5	89.98±0.5	94.70±0.2	99.07±0.3	99.71±0.1	99.92±0.0




**Şekil 4. 17:** IP veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY.

İkinci uygulama SA veri seti ile gerçekleştirilmektedir. SA veri seti ile yapılan uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.17'de verilmiştir. Sınıflandırma sonucunda elde edilen sınıflandırma haritaları Şekil 4.18'de gösterilmektedir. Çizelge 4.17 incelendiğinde, önerilen yöntem ve en gelişmiş yöntemlerden biri olan HybridSN ile %100 OA, AA ve K değerleri elde edilmiştir. Önerilen yöntem, SSRN'den sırasıyla %0.02, %0.03 ve %0.03 ve M3B ESA'dan %5.21, %3.75 ve %5.8 daha iyi sınıflandırma doğruluğuna sahiptir. Ayrıca, önerilen yöntemin DVM'den %7.05, %5.4, %7.89, 2B ESA'dan %2.62, %1.16, %2.92, 3B ESA'dan %6.04, %2.99, %6.68 daha iyi sonuçlar elde ettiği görülmektedir. Tüm yöntemler için sınıf bazlı ve OA, AA, K değerleri dikkate alındığında önerilen yöntem ve HybridSN yöntemi en iyi sonuçları vermektedir. Şekil 4.18 incelendiğinde önerilen yöntem ve HybridSN yönteminin sınıflandırma haritası temel gerçeği ile aynı olduğu görülmektedir.

**Çizelge 4. 17:** SA veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	DVM	2B ESA	3B ESA	M3B ESA	SSRN	HybridSN	ÖY
1	1406/603	99.60	100	98.41	97.50	100	100	100
2	2608/1118	99.82	99.96	100	100	100	100	100
3	1383/593	99.26	99.63	99.23	99.43	100	100	100
4	976/418	99.40	99.28	99.90	99.51	99.89	100	100
5	1875/803	99.42	99.20	99.43	99.72	100	100	100
6	2771/1188	100	100	99.55	99.23	100	100	100
7	2505/1074	99.83	100	99.72	99.45	100	100	100
8	7890/3381	85.25	93.62	89.75	92.63	100	100	100
9	4342/1861	99.71	100	99.81	99.70	100	100	100
10	2295/983	97.03	98.82	98.36	97.31	99.91	100	100
11	748/320	98.24	99.73	98.12	98.05	100	100	100
12	1349/578	99.46	100	98.96	98.50	100	100	100
13	641/275	98.77	100	98.93	98.70	100	100	100
14	749/321	97.30	99.86	98.60	98.42	100	100	100
15	5087/2181	72.71	91.52	79.31	87.18	99.96	100	100
16	1265/542	99.41	99.92	94.51	91.11	100	100	100
OA	37890/16239	92.95±0.3	97.38±0.0	93.96±0.2	94.79±0.3	99.98±0.1	100±0.0	100±0.0
AA		94.60±2.3	98.84±0.1	97.01±0.6	96.25±0.6	99.97±0.0	100±0.0	100±0.0
K		92.11±0.2	97.08±0.1	93.32±0.5	94.20±0.2	99.97±0.1	100±0.0	100±0.0




**Şekil 4. 18:** SA veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY.

Üçüncü uygulamada PU veri seti kullanılmıştır. PU veri seti ile yapılan uygulamaların OA, AA, K değerleri ve sınıf bazlı sınıflandırma sonuçları Çizelge 4.18'te verilmiştir. Tüm yöntemlerin sınıflandırma haritalarının sonuçları Şekil 4.19'da gösterilmektedir. Çizelge 4.18 incelendiğinde önerilen yöntemin PU veri setinin tüm sınıflarında en iyi sınıflandırma doğruluğunu sağladığı görülmektedir. Önerilen yöntem, en gelişmiş yöntem olan HybridSN'ye göre sırasıyla OA, AA ve K değerleri açısından %0.01 daha iyi sonuçlar elde etmiştir. Ayrıca 4., 8. ve 9. sınıflarda HybridSN'den sırasıyla %0.05, %0.02 ve %0.1 daha iyi sonuçlar alınmaktadır. Diğer ileri yöntemler olan SSRN'den sırasıyla %0.09, %0.07, %0.12 ve M3B ESA'dan %4.23, %4.9, %5.49 daha iyi sınıflandırma sonuçları elde edilmektedir. OA, AA, K değerleri açısından klasik yöntemlerle karşılaştırıldığında, önerilen yöntemin DVM'den %5.65, %7, %7.49, 2B ESA'dan %2.13, %3.43, %2.83 ve 3B ESA'dan %3.46, %2.41, %4.48 daha iyi sınıflandırma doğruluğu elde ettiği görülmektedir. Karşılaştırılan yöntemlerin OA, AA ve K değerlerine bakıldığında önerilen yöntemin daha başarılı olduğu açıkça görülmektedir.

**Çizelge 4. 18:** PU veri setinin eğitim ve test örnekleri sayısı ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	DVM	2B ESA	3B ESA	M3B ESA	SSRN	HybridSN	ÖY
1	4642/1989	94.72	98.51	98.40	98.31	100	100	100
2	13054/5595	95.15	99.54	96.91	96.10	99.87	100	100
3	1469/630	82.73	84.62	97.05	96.34	100	100	100
4	2145/919	96.82	98.04	98.84	98.82	100	99.84	99.89
5	942/403	99.71	100	100	99.97	100	100	100
6	3520/1509	90.48	97.10	99.32	99.83	100	100	100
7	931/399	87.73	95.05	98.92	99.66	100	100	100
8	2577/1105	88.29	96.39	98.33	99.23	99.34	99.98	100
9	663/284	99.90	99.69	99.90	99.92	100	99.90	100
OA	29943/12833	94.34±0.2	97.86±0.2	96.53±0.1	95.76±0.2	99.90±0.0	99.98±0.0	99.99±0.0
AA		92.98±0.4	96.55±0.0	97.57±1.3	95.08±1.2	99.91±0.0	99.97±0.0	99.98±0.0
K		92.50±0.7	97.16±0.5	95.51±0.2	94.50±0.2	99.87±0.0	99.98±0.0	99.99±0.0



**Şekil 4. 19:** PU veri seti için tahmin edilen sınıflandırma haritaları. (a) Temel Gerçek. (b)-(h) DVM, 2B ESA, 3B ESA, M3B ESA, SSRN, HybridSN ve ÖY.

Önerilen yöntemi, karşılaştırma için kullanılan diğer yöntemlerden ayıran en önemli parametrelerden biri eğitim ve test süreleridir. Tüm yöntemlerin eğitim ve test süreleri Çizelge 4.19'da verilmiştir. Uygulamalarda eğitim süresi dakika, test süresi saniye olarak alınmıştır. Çizelge 4.19'daki eğitim ve test süreleri incelendiğinde, önerilen yöntemin her üç veri setinde de diğer spektral uzamsal öznitelik tabanlı derin öğrenme modellerinden (3B ESA, M3B ESA, SSRN and HybridSN) daha az olduğu görülmektedir. Donanım hızlandırıcı olarak kullanılan özel TPU'da eğitim ve test süreleri azalmakta ve veriler CPU'dan daha hızlı işlenmektedir. Eğitim ve test süreleri analiz edildiğinde önerilen yöntemin daha kısa sürede daha iyi sınıflandırma doğruluğu sağladığı görülmüştür. Ayrıca, eğitim ve test süreleri büyük ölçüde internetin hızına ve kullanılabilir RAM'e bağlıdır. Klasik yöntemlerden biri olan 2B ESA ile sadece uzamsal özellik bilgisi çıkarıldığı için en iyi eğitim ve test süresine sahiptir.

**Çizelge 4. 19:** IP, PU ve SA veri setlerinde farklı yöntemlerle elde edilen sınıflandırma sonuçlarının eğitim ve test süreleri.

Method	IP		PU		SA	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
DVM	3.5	1.5	10.2	5.1	12.7	7.2
2B ESA	1.9	1.1	1.8	1.3	2.2	2
3B ESA	15.2	4.3	58	10.6	74	15.2
SSRN	56	12	86	18	89	18.24
HybridSN	14.1	4.8	20.3	6.6	25.5	9
ÖY	7.2	2.1	9.9	2.4	11.9	2.7

Sınırlı eğitim örnekleri (%5, %10, %20) ile yapılan uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.20'de gösterilmiştir. Çizelge 4.20 incelendiğinde her bir yöntemin sınıflandırma doğruluğunun düştüğü ancak önerilen yöntemin diğer tüm yöntemlerden daha iyi performans gösterdiği görülmektedir. Önerilen yöntem en yakın değerler, en gelişmiş yöntem olan HybridSN yöntemi ile elde edilmektedir.

**Çizelge 4. 20:** Sınırlı eğitim örnekleri (5, 10, %20) ile farklı derin öğrenme yöntemlerini kullanan IP, PU ve SA için sınıflandırma doğruluklarının karşılaştırılması

Method		IP (%)			PU (%)			SA (%)		
		OA	AA	K	OA	AA	K	OA	AA	K
2B ESA	5%	72.83±0.5	69.23±3.1	68.58±0.2	93.82±0.2	92.09±0.4	90.10±0.6	95.26±0.5	97.70±1.5	94.73±0.4
	10%	80.27±1.2	68.32±4.1	78.26±2.1	96.63±0.2	94.84±1.4	95.53±1.0	96.34±0.3	94.36±0.5	95.93±0.9
	20%	86.90±1.3	82.70±1.0	85.01±1.6	96.02±0.4	95.10±0.1	96.04±0.3	96.15±0.6	98.27±0.2	95.71±0.7
3B ESA	5%	71.63±0.3	73.39±3.5	68.07±0.3	92.88±0.3	92.56±2.5	90.70±0.6	92.93±0.2	93.5±2.4	92.26±0.9
	10%	82.62±0.1	76.51±0.1	79.25±0.3	96.34±0.2	97.03±0.6	94.90±1.2	85.0±0.1	89.63±0.2	83.20±0.7
	20%	89.23±0.2	87.87±0.1	87.70±0.3	97.30±0.3	97.02±0.1	96.22±0.1	94.54±0.5	96.79±0.6	93.81±0.3
M3B ESA	5%	75.88±2.2	70.05±3.0	73.6±1.9	93.25±1.3	94.61±2.0	91.3±1.2	93.10±0.5	94.10±1.6	92.31±0.8
	10%	81.39±2.6	75.22±0.7	81.20±2.0	95.95±0.6	97.52±1.0	93.40±0.4	94.20±0.8	96.66±0.5	93.61±0.3
	20%	93.67±0.1	93.60±0.6	92.70±0.3	97.41±0.2	98.22±0.1	96.05±0.6	94.92±0.3	97.28±0.2	94.40±0.1
SSRN	5%	94.39±0.1	83.33±0.9	93.58±0.6	99.10±0.2	98.15±0.0	99.0±0.6	99.53±0.2	99.73±0.0	99.70±0.0
	10%	98.45±0.2	86.19±1.3	98.23±0.3	99.62±0.0	99.49±0.0	99.50±0.0	99.64±0.0	99.76±0.0	99.60±0.0
	20%	99.23±0.1	92.52±0.1	99.12±0.1	99.77±0.1	99.71±0.1	99.69±0.2	99.88±0.0	99.84±0.0	99.87±0.0
Hybrid SN	5%	94.90±1.7	86.81±2.5	93.73±2.1	99.35±1.1	98.65±0.8	98.86±1.4	99.95±0.0	99.94±0.0	99.95±0.0
	10%	98.39±0.4	98.01±0.5	98.16±0.5	99.72±0.1	99.20±0.2	99.64±0.2	99.98±0.0	99.98±0.0	99.98±0.0
	20%	99.47±0.1	99.38±0.1	99.40±0.1	99.86±0.1	99.71±0.1	99.82±0.0	100±0.0	100±0.0	100±0.0
ÖY	5%	94.97±1.1	92.7±1.0	94.26±2.1	99.53±0.1	98.85±0.1	99.38±0.1	99.96±0.0	99.95±0.0	99.96±0.0
	10%	98.46±0.2	98.41±0.1	98.24±0.3	99.81±0.1	99.54±0.1	99.75±0.1	99.98±0.0	99.99±0.0	99.98±0.0
	20%	99.72±0.1	99.15±0.1	99.68±0.1	99.90±0.0	99.81±0.0	99.87±0.0	100±0.0	100±0.0	100±0.0

Derin öğrenme yöntemlerinin sınıflandırma doğruluğu büyük ölçüde pencere boyutuna bağlıdır. Pencere boyutu çok büyük olduğunda, komşuluk çıkarma ile elde edilen parça, farklı sınıflardan pikseller içerebilmektedir. Bu, sınıflandırma performansını

düşürmektedir. Pencere boyutu çok küçük olduğunda, sınıflar arasındaki çeşitlilik azalmaktadır. Bu durum yanlış sınıflandırmaya neden olmaktadır. Uzamsal boyutun (pencere boyutu) önerilen yöntemin sınıflandırma performansı üzerindeki etkisi Çizelge 4.21'de gösterilmektedir. Çizelge 4.21 incelendiğinde PU ve SA veri setleri için optimal pencere boyutunun 25x25 olduğu görülmektedir. IP veri seti için en iyi sınıflandırma sonucu 23x23 pencere boyutu ile elde edilmektedir. Tüm veri setleri göz önüne alındığında en iyi sınıflandırma sonuçları 25x25 pencere boyutunda elde edilmektedir. Ayrıca Çizelge 4.16-4.18 incelendiğinde, önerilen yöntem en yakın sonuçların HybridSN yönteminde elde edildiği görülmektedir. HybridSN ve önerilen yöntemin farklı pencere boyutlarında (15x15, 19x19, 21x21, 23x23 ve 25x25) OA sonuçları Çizelge 4.22'de verilmiştir. Çizelge 4.22'ye göre IP veri seti için tüm pencere boyutlarında en iyi sonuçlar önerilen yöntem ile elde edilmiştir. PU veri seti için 15x15 pencere boyutunda %99.93 ve 19x19 pencere boyutunda %99.98 ile aynı sonuçlar elde edilirken, diğer pencere boyutları için en iyi sonuçlar önerilen yöntem ile elde edilmiştir. SA veri seti için 15x15, 19x19, 21x21 ve 23x23 pencere boyutları için en iyi sonuçlar önerilen yöntem ile elde edilirken, 25x25 pencere boyutu için %100 ile aynı sonuçlar elde edilmiştir.

**Çizelge 4. 21:** Pencere boyutunun önerilen yöntemle etkisi (%).

Pencere boyutu	IP			PU			SA		
	OA	AA	K	OA	AA	K	OA	AA	K
15x15	99.74	99.75	99.70	99.93	99.90	99.91	100	100	100
19x19	99.93	99.82	99.92	99.98	99.97	99.97	100	100	100
21x21	99.96	99.99	99.96	99.98	99.97	99.97	99.94	99.94	99.93
23x23	100	100	100	99.98	99.97	99.98	99.99	99.99	99.99
25x25	99.93	99.73	99.92	99.99	99.98	99.99	100	100	100

**Çizelge 4. 22:** Farklı pencere boyutlarına sahip HybridSN ve ÖY'nin OA'ları (%).

Method	15x15			19x19			21x21			23x23			25x25		
	IP	PU	SA	IP	PU	SA	IP	PU	SA	IP	PU	SA	IP	PU	SA
HybridSN	99.21	99.93	99.99	99.74	99.98	99.99	99.73	99.90	99.69	99.31	99.96	99.71	99.75	99.98	100
ÖY	99.74	99.93	100	99.93	99.98	100	99.96	99.98	99.94	100	99.98	99.99	99.93	99.99	100



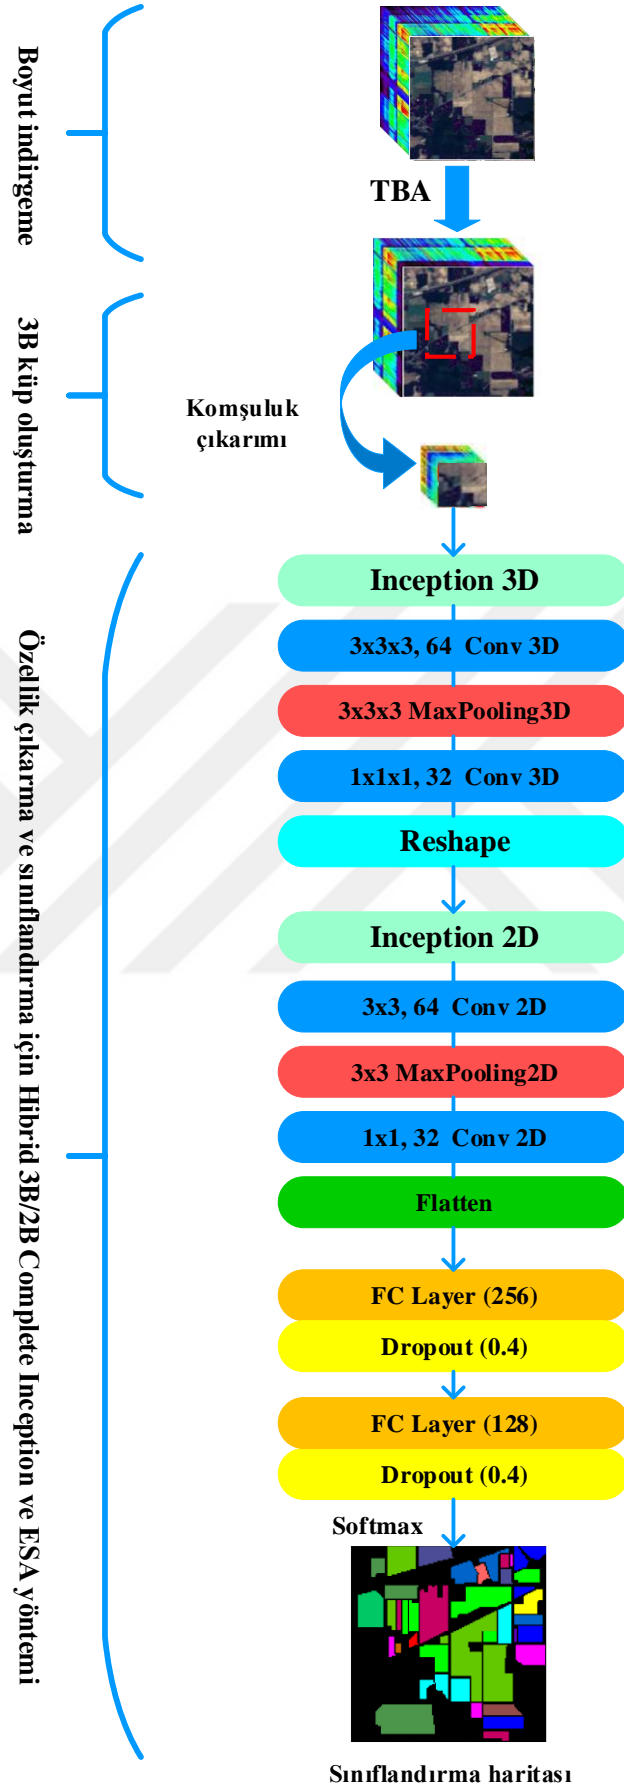
## 4.7 Uygulama 5: Hiperspektral Uzaktan Algılama Görüntü Sınıflandırması için Hibrit 3B/2B Complete Inception Modülü ve Evrişimsel Sinir Ağı

### 4.7.1 Önerilen yöntem

Bu çalışmada, 3B/2B ESA yöntemi ile 3B/2B Complete Inception modülünün birlikte kullanıldığı bir yöntem önerilmiştir. Inception modülü, birden fazla evrişim katmanından oluşan ve ağı daha derin ve daha geniş hale getiren evrişimsel bir ağıdır. Inception modülü kullanılarak ESA'larda eğitilebilir parametre sayısının azaltılması ve yüksek sınıflandırma performansı elde edilmesi amaçlanmaktadır. Ayrıca, hiperspektral görüntüler hacimsel veriler olduğundan ve spektral bir boyuta sahip olduklarından, 2B ESA, spektral boyutlardan iyi ayırt edici sınıflandırma haritaları üretememektedir. Çünkü 2B ESA ile uzamsal özellikler genellikle ayrı ayrı çıkarılmakta, bu da uzamsal-spektral bilgilerin birlikte kullanımını bir dereceye kadar geçersiz kılmaktadır. Artan hesaplama karmaşıklığı nedeniyle 3B ESA çok fazla kullanılmamaktadır. Uzamsal-spektral öznelikler 3B ESA ile eş zamanlı olarak çıkarıldığından, 3B hiperspektral görüntülerin yapısal özelliklerinden tam olarak yararlanılmaktadır. Bu çalışma kapsamında, uzamsal-spektral özellik haritalarından tam olarak yararlanmak ve mümkün olan maksimum doğruluğu elde etmek amacıyla hem Inception modülünde hem de Inception modülünün çıktılarında 3B ve 2B ESA kombinasyonundan oluşan hibrit bir yöntem kullanılmıştır. Şekil 2.13 ve Şekil 2.14'teki modüller, önerilen yöntemde kullanılan Inception modüllerine dahildir. Inception modülleri dışında kullanılan 3B ve 2B evrişim katmanları ile maksimum havuzlama katmanlarının sayısı yapılan uygulamalar sonucunda belirlenmiştir. 2 3B evrişim, 2 2B evrişim, Maxpooling3B ve Maxpooling2B katmanlarının önerilen hibrit yöntem için optimal olduğu bulunmuştur.

Önerilen hibrit 3B/2B Complete Inception ve ESA yöntemi, Şekil 4.20'de gösterildiği gibi, 3B Inception modülü, 2B Inception modülü, 2 3B ESA, 2 2B ESA, 3B maksimum havuzlama (Maxpooling3B), 2B maksimum havuzlama (Maxpooling2B), düzleştirme, 2 tam bağlantılı (FC), 2 bırakma (dropout) ve softmax katmanlarından oluşmaktadır. 3B hiperspektral veri küpleri ilk olarak Inception 3B katmanından geçirilmektedir. Inception 3B katmanının temeli 3B evrişimdir ve Şekil 2.14'te gösterilmiştir. Bu modül yapısının ayrıntılı bir açıklaması Çizelge 2.1'de verilmiştir. Inception 3B modülü içindeki paralel 3B evrişim işlemlerinden sonra elde edilen sonuç birleştirilmektedir. Ardından 64 filtre ve 3x3x3 çekirdek boyutu ile 3B evrişim, 3x3x3

çekirdek boyutu ile maksimum havuzlama ve 32 filtre ve 1x1x1 çekirdek boyutu ile 3B evrişim uygulandıktan sonra yeniden boyutlandırma (Reshape) işlemi gerçekleştirilmektedir. Yeniden boyutlandırmadan sonra elde edilen çıktı, paralel 2B evrişimlerden oluşan Inception 2B modülüne iletilmektedir. Inception 2B modül yapısının ayrıntılı bir açıklaması Çizelge 2.2'de verilmiştir. Inception 2B'den sonra sırasıyla 64 filtre ve 3x3 çekirdek boyutu ile 2B evrişim, 3x3 çekirdek boyutu ile maksimum havuzlama ve 32 filtre ve 1x1 çekirdek boyutu ile 2B evrişim uygulanmaktadır. 3B/2B Complete Inception ve ESA'dan sonra çıkarılan özellikler düzleştirilmekte ve hiperspektral görüntü sınıflandırması için FC katmanlarına girdi olarak verilmektedir. Önerilen yöntemde (ÖY) 256 ve 128 nöronlu iki FC katmanı kullanılmaktadır. Aşırı öğrenmeyi önlemek için, her FC katmanından sonra bırakma oranı %0.4 olan bir bırakma katmanı uygulanmaktadır. FC katmanının çıktısı, sınıflandırma sonucunu üretmek için basit softmax sınıflandırıcıya verilmektedir. Çizelge 4.23'de önerilen yöntem ile ilgili detaylı bilgiler yer almaktadır. IP için ÖY'deki eğitilebilir ağırlık parametrelerinin toplam sayısı 1.447.424'tür.



Şekil 4. 20: Önerilen Hibrit 3B/2B Complete Inception ve ESA yöntemi.

**Çizelge 4. 23:** IP için önerilen yöntemin özeti.


Katman	Çıktı	Parametre	Bağlı olduğu katman
input_1 (InputLayer)	(25, 25, 30, 1)	0	
conv3d_1 (Conv3D)	(25, 25, 30, 96)	192	input_1
conv3d_3 (Conv3D)	(25, 25, 30, 16)	32	input_1
max_pooling3d (MaxPooling3D)	(25, 25, 30, 1)	0	input_1
conv3d (Conv3D)	(25, 25, 30, 64)	128	input_1
conv3d_2 (Conv3D)	(25, 25, 30, 128)	331904	conv3d_1
conv3d_4 (Conv3D)	(25, 25, 30, 32)	64032	conv3d_3
conv3d_5 (Conv3D)	(25, 25, 30, 32)	64	max_pooling3d
concatenate (Concatenate)	(25, 25, 30, 256)	0	conv3d, conv3d_2, conv3d_4, conv3d_5
conv3d_6 (Conv3D)	(23, 23, 28, 64)	442432	concatenate
max_pooling3d_1(MaxPool ing3D)	(12, 12, 14, 64)	0	conv3d_6
conv3d_7 (Conv3D)	(12, 12, 14, 32)	2080	max_pooling3d_1
reshape (Reshape)	(12, 12, 448)	0	conv3d_7
conv2d_1 (Conv2D)	(12, 12, 96)	43104	reshape
conv2d_3 (Conv2D)	(12, 12, 16)	7184	reshape
max_pooling2d (MaxPooling2D)	(12, 12, 448)	0	reshape
conv2d (Conv2D)	(12, 12, 64)	28736	reshape
conv2d_2 (Conv2D)	(12, 12, 128)	110720	conv2d_1
conv2d_4 (Conv2D)	(12, 12, 32)	12832	conv2d_3
conv2d_5 (Conv2D)	(12, 12, 32)	14368	max_pooling2d
concatenate_1 (Concatenate)	(12, 12, 256)	0	conv2d, conv2d_2, conv2d_4, conv2d_5
conv2d_6 (Conv2D)	(10, 10, 64)	147520	concatenate_1
max_pooling2d_1 (MaxPooling2D)	(5, 5, 64)	0	conv2d_6
conv2d_7 (Conv2D)	(5, 5, 32)	2080	max_pooling2d_1
flatten (Flatten)	800	0	conv2d_7
dense (Dense)	256	205056	flatten
dropout (Dropout)	256	0	dense
dense_1 (Dense)	128	32896	dropout
dropout_1 (Dropout)	128	0	dense_1
dense_2 (Dense)	16	2064	dropout_1
Toplam eğitilebilir parametre sayısı: 1.447.424			

#### 4.7.2 Sınıflandırma sonuçları

IP, PU ve SA veri setlerinin kullanıldığı uygulamalarda eğitim/test oranı %30-70'dir. HL ve UH veri setinin kullanıldığı uygulamalarda %10-90 olarak alınmaktadır. Optimizasyon için 0.001 öğrenme oranlı kategorik çapraz entropi ve  $1e-06$  bozunma fonksiyonlu Adam optimizör kullanılmıştır. Eğitim süreci, 256 yığın boyutu ve 100 epochs için tekrarlanmaktadır. ReLU, Softmax katmanı dışındaki tüm katmanlarda aktivasyon işlevi olarak kullanılmaktadır. IP, PU ve SA veri kümeleri evrişim için  $25 \times 25$  komşuluk (pencere boyutu) kullanırken, HL ve UH veri kümeleri  $11 \times 11$  pencere boyutunu kullanılmaktadır. Öte yandan, TBA boyut indirgeme yönteminden sonra kullanılan spektral bandların sayısı beş veri setinin tamamında farklılık göstermektedir. Uygulamalarımızda IP, PU, SA, HL ve UH veri setleri için sırasıyla 30, 15, 15, 20 ve 20 temel bileşen kullanılmaktadır. Yani komşuluk çıkarımı sonucunda elde edilen 3B parçaların boyutları IP için  $25 \times 25 \times 30$ , PU ve SA veri setleri için  $25 \times 25 \times 15$ , HL ve UH için  $11 \times 11 \times 20$  olarak ayarlanmıştır. Önerilen yöntem, 2B ESA [84], 3B ESA [85], FC3B ESA [32], HybridSN [31], S3EResBoF [8], A2S2KRes [30], FuSENet [33] ve DLEM [34] gibi literatürden derin öğrenmeye dayalı hiperspektral görüntü sınıflandırma yöntemleriyle karşılaştırılmıştır.

İlk uygulamada IP veri seti kullanılmıştır. Her sınıfın sınıf bazında ve OA, AA ve K değerlendirme ölçütlerine göre sınıflandırma doğruluğu Çizelge 4.24'te gösterilmiştir. IP veri seti ile yapılan uygulamalar sonucunda elde edilen temel gerçek ve sınıflandırma haritaları Şekil 4.21'de verilmiştir. Çizelge 4.24'e göre ÖY'nin OA, AA ve K'ye göre sırasıyla %99.83, %99.82 ve %99.81 ile en iyi sınıflandırma sonuçlarını elde ettiği görülmektedir. ÖY'ye en yakın sonuçlar %99.76 OA ve %99.73 K değerleri ile DLEM, %99.75 OA, %99.71 K ve %99.63 AA ile HybridSN ile elde edilmiştir. ÖY, gelişmiş yöntemlerden biri olan A2S2KRes ile karşılaştırıldığında, OA, AA ve K değerlerinin sırasıyla %0.19, %1.15 ve %0.21 oranında daha iyi performans gösterdiği görülmektedir. Benzer şekilde, S3EResBoF'a kıyasla %0.35, %0.88 ve %0.4 ve FuSENet'e kıyasla %0.82, %1.18 ve %1.21 daha iyi sınıflandırma performansı sağlamaktadır. Diğer sınıflandırma yöntemlerinden en düşük OA, AA ve K değerleri sırasıyla %89.48, %86.14 ve %87.96 ile 2B ESA'da, %91.10, %91.58 ve %89.98 ile 3B ESA'da ve %92.93, %90.61 ve %91.94 ile FC3B ESA'da elde edilmiştir. 2B ESA'daki AA değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. Sınıf bazlı sınıflandırmada ÖY ile 2., 5., 10., 11. ve 16. sınıflar dışındaki tüm sınıflarda %100'lük en iyi sınıflandırma doğruluğu elde edilmiştir. Sınıf 2 için en iyi sınıflandırma doğruluğu, ÖY'den %0.4'lük bir farkla DLEM

yönteminde elde edilmiştir. Sınıf 5 için en iyi sınıflandırma doğruluğu, ÖY'den %0.3'lük bir farkla S3EResBoF yönteminde elde edilmiştir. Benzer şekilde, en iyi sınıflandırma sonuçları sınıf 10 için %0.15 fark ile S3EResBoF ve DLEM'de, sınıf 11 için %0.06 ile DLEM ve sınıf 16 için %1.54 fark ile FC3B ESA ve 2B ESA'da elde edilmiştir. Ayrıca, Şekil 4.21 incelendiğinde, önerilen yöntem ile tahmin edilen sınıflandırma haritasının temel gerçek haritasına en çok benzeyen yöntem olduğu görülmektedir.



**Şekil 4. 21:** IP için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY).

İkinci uygulamada SA kullanılmıştır. SA ile yapılan uygulamalarda her sınıf için sınıflandırma doğrulukları ve tüm değerlendirme ölçütlerinin sonuçları Çizelge 4.25'de gösterilmektedir. SA kullanılarak yapılan uygulamalar sonucunda elde edilen sınıflandırma haritaları Şekil 4.22'de yer almaktadır. Çizelge 4.25'e göre ÖY, DLEM ve HybridSN yöntemlerinde %100 OA, AA ve K değerleri ile en iyi sınıflandırma doğrulukları elde edilmiştir. ÖY'ye en yakın sonuçlar, tüm değerlendirme metriklerinde %99.99 ile A2S2KRes yöntemindedir. ÖY, FC3B ESA'dan sırasıyla %0.15, %0.1 ve %0.16, S3EResBoF'dan %0.09, %0.1 ve %0.1 ve FuSENet'ten %0.32, %0.31 ve %0.26 daha iyi sınıflandırma doğruluğu elde etmiştir. En düşük sınıflandırma sonuçları %93.96 OA, %97.01 AA ve %93.32 K ile 3B ESA ve %97.38 OA, %98.84 AA ve %97.08 K ile 2B ESA'dadır. 3B ESA'da AA değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. Sınıf bazlı sonuçlar incelendiğinde ÖY, DLEM ve HybridSN yöntemlerinde tüm sınıflarda elde edilen sınıflandırma doğruluğu %100'dür.

**Çizelge 4. 24:** IP için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	A2S2KRes	FuSENet	DLEM	ÖY
1	14/32	75.00	79.23	97.83	99.38	93.55	100.00	100.00	100.00	100.00
2	428/1000	81.40	88.60	94.05	99.58	99.28	99.65	98.47	99.70	99.30
3	249/581	87.60	85.81	90.72	99.66	98.78	99.70	98.53	100.00	100.00
4	71/166	62.04	90.53	81.43	99.88	99.31	98.54	98.56	100.00	100.00
5	145/338	92.30	96.11	98.34	99.53	100.00	99.81	99.95	98.22	99.70
6	219/511	99.21	98.43	99.86	99.96	100.00	99.89	99.60	100.00	100.00
7	8/20	75.00	92.36	78.57	99.00	100.00	92.86	98.75	90.00	100.00
8	143/335	100.00	98.51	100.00	100.00	100.00	100.00	99.40	100.00	100.00
9	6/14	64.28	88.90	85.00	100.00	100.00	94.44	100.00	100.00	100.00
10	292/680	82.79	87.72	96.81	99.56	100.00	99.92	98.54	100.00	99.85
11	736/1719	91.27	91.42	94.75	99.84	99.46	99.63	98.42	99.94	99.88
12	178/415	82.89	90.04	86.34	99.52	98.61	98.92	98.94	99.76	100.00
13	62/143	99.30	99.00	99.51	99.86	100.00	100.00	98.66	100.00	100.00
14	379/886	98.87	97.95	98.97	100.00	99.87	99.87	98.98	100.00	100.00
15	116/270	86.29	82.57	91.71	99.85	100.00	99.61	100.00	100.00	100.00
16	28/65	100.00	98.51	100.00	98.46	94.23	99.07	98.36	95.38	98.46
OA	3074/7175	89.48±0.2	91.10±0.4	92.93 ± 0.2	99.75 ± 0.1	99.48 ± 0.1	99.64 ± 0.1	99.01 ± 0.2	99.76 ± 0.1	99.83 ± 0.0
K		87.96±0.5	89.98±0.5	91.94 ± 0.5	99.71 ± 0.1	99.41 ± 0.0	99.60 ± 0.2	98.60 ± 0.1	99.73 ± 0.1	99.81 ± 0.0
AA		86.14±0.8	91.58±0.2	90.61 ± 0.8	99.63 ± 0.2	98.94 ± 0.0	98.67 ± 0.1	98.64 ± 0.1	99.05 ± 0.1	99.82 ± 0.0


Çizelge 4.25 ve Şekil 4.22 göz önüne alındığında, ÖY, HybridSN ve DLEM yöntemlerinde elde edilen sınıflandırma haritaları temel gerçek haritası ile aynıdır. Diğer yöntemlerden biri olan A2S2KRes ile elde edilen sınıflandırma haritası, temel gerçeğe en çok benzeyen yöntemdir. Kalan 5 derin öğrenme tabanlı yöntemden AA değerinin S3EResBoF ile %99.90, FC3B ESA ile %99.90 ve FuSENet ile %99.69 elde edildiği görülmektedir. Bu yöntemlerin sınıflandırma haritaları temel gerçeğe benzemektedir. 2B ESA ve özellikle 3B ESA yöntemleri ile elde edilen sınıflandırma haritaları incelendiğinde temel gerçeğe en az benzeyenlerin olduğu görülmektedir.

Üçüncü uygulamada PU veri seti kullanılmıştır. PU ile yapılan uygulamaların OA, AA, K değerleri ve sınıf bazında sınıflandırma sonuçları Çizelge 4.26'da verilmiştir. Tüm yöntemlerin sınıflandırma haritalarının sonuçları Şekil 4.23'de gösterilmektedir. Çizelge 4.26'ya göre ÖY ve DLEM'in PU veri setinin tüm sınıflarında %100 ile en iyi sınıflandırma doğruluğunu elde ettiği görülmektedir. Ayrıca ÖY, en gelişmiş yöntemlerden biri olan HybridSN'ye göre sırasıyla OA, AA ve K değerleri açısından sırasıyla %0.02, %0.03, %0.02 daha iyi sonuçlar elde etmiştir. ÖY, FC3B ESA'dan %0.3, %0.63, %0.4, S3EResBoF'dan %0.56, %1, %0.74, A2S2KRes'ten %0.45, %0.22, %0.59 ve FuSENet'ten %0.58, %0.67, %0.79 daha iyi sınıflandırma sonuçları elde etmiştir. SA veri setinde olduğu gibi PU veri setinde de en kötü sınıflandırma performansları 3B ESA ve 2B ESA ile elde edilmiştir. 2B ESA ile %97.86 OA, %97.16 AA ve %96.55 K değerleri elde edilirken, 3B ESA ile %96.53 OA, %97.57 AA ve %95.51 K değerleri elde edilmiştir. Tüm yöntemler incelendiğinde en düşük AA değerini 2B ESA vermektedir. 2B ESA'daki AA değerine bakıldığında her sınıf için doğru sınıflandırma sayısının diğer yöntemlere göre daha az olduğu görülmektedir. Sınıf bazlı sonuçlar karşılaştırıldığında ÖY ve DLEM tüm sınıflarda %100 ile en iyi sonuçları vermektedir. Bu sonuçlardan, ÖY ve DLEM'in sınıflandırma haritalarının temel gerçeği ile aynı olduğu görülmektedir. HybridSN yönteminin sınıflandırma doğruluğu, sınıf 4, 8 ve 9 hariç diğer tüm sınıflarda %100'dür. Ancak %99.97 AA değeri ile elde edilen sınıflandırma haritasının temel gerçeğe oldukça yakın olduğu görülmektedir. A2S2KRes, FC3B ESA, FuSENet, S3EResBoF, 3B ESA, 2B ESA yöntemlerinde sırasıyla %99.78, %99.37, %99.33, %99, %97.57 ve %97.16 AA değerleri elde edilmiştir. Bu yöntemler arasında 2B ESA %97.16 AA değeri ile en kötü sınıflandırma sonucunu vermekte ve sınıflandırma haritası temel gerçeğe en az benzer olan yöntemdir. A2S2KRes sınıflandırma haritası, bu 6 yöntemden temel gerçeğe en çok benzeyen yöntemdir.



**Çizelge 4. 25:** SA için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%).

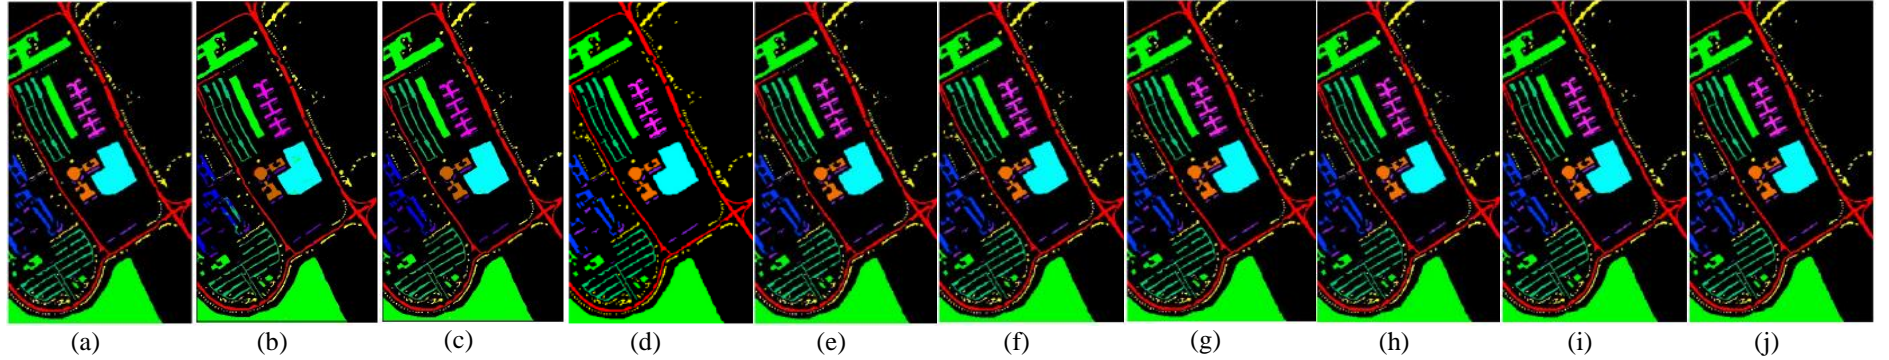
No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	A2S2KRes	FuSENet	DLEM	ÖY
1	603/1406	100.00	98.41	100.00	100.00	100.00	100.00	100.00	100.00	100.00
2	1118/2608	99.96	100.00	100.00	100.00	100.00	100.00	100.00	100.00	100.00
3	593/1383	99.63	99.23	100.00	100.00	100.00	100.00	99.63	100.00	100.00
4	418/976	99.28	99.90	100.00	100.00	99.90	99.94	99.21	100.00	100.00
5	803/1875	99.20	99.43	99.50	100.00	99.95	99.97	100.00	100.00	100.00
6	1188/2771	100.00	99.55	100.00	100.00	99.60	100.00	100.00	100.00	100.00
7	1074/2505	100.00	99.72	100.00	100.00	100.00	100.00	99.61	100.00	100.00
8	3381/7890	93.62	89.75	99.80	100.00	99.99	99.99	99.97	100.00	100.00
9	1861/4342	100.00	99.81	99.80	100.00	100.00	100.00	99.97	100.00	100.00
10	983/2295	98.82	98.36	100.00	100.00	100.00	100.00	99.95	100.00	100.00
11	320/748	99.73	98.12	100.00	100.00	99.87	100.00	100.00	100.00	100.00
12	578/1349	100.00	98.96	99.80	100.00	99.78	100.00	99.84	100.00	100.00
13	275/641	100.00	98.93	100.00	100.00	99.53	100.00	98.88	100.00	100.00
14	321/749	99.86	98.60	100.00	100.00	100.00	100.00	99.96	100.00	100.00
15	2180/5088	91.52	79.31	99.50	100.00	99.75	99.99	99.59	100.00	100.00
16	542/1265	99.92	94.51	99.90	100.00	100.00	100.00	98.59	100.00	100.00
OA	16238/37891	97.38±0.0	93.96±0.2	99.85 ± 0.0	100.00 ± 0.0	99.91 ± 0.0	99.99 ± 0.0	99.68 ± 0.2	100.00 ± 0.0	100.00 ± 0.0
K		97.08±0.1	93.32±0.5	99.84 ± 0.1	100.00 ± 0.0	99.90 ± 0.0	99.99 ± 0.0	99.74 ± 0.1	100.00 ± 0.0	100.00 ± 0.0
AA		98.84±0.1	97.01±0.6	99.90 ± 0.1	100.00 ± 0.0	99.90 ± 0.0	99.99 ± 0.0	99.69 ± 0.1	100.00 ± 0.0	100.00 ± 0.0



**Şekil 4. 22:** SA için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY).

**Çizelge 4. 26:** PU için test ve eğitim örnekleri sayısı ve sınıflandırma doğrulukları (%).

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	A2S2KRes	FuSENet	DLEM	ÖY
1	1989/4642	98.51	98.40	99.98	100.00	98.41	99.89	99.89	100.00	100.00
2	5594/13055	99.54	96.91	99.98	100.00	99.94	99.23	99.93	100.00	100.00
3	630/1469	84.62	97.05	98.95	100.00	99.80	99.92	98.75	100.00	100.00
4	919/2145	98.04	98.84	99.90	99.84	98.79	100.00	98.71	100.00	100.00
5	403/942	100.00	100.00	100.00	100.00	99.26	99.94	98.69	100.00	100.00
6	1509/3520	97.10	99.32	99.96	100.00	100.00	99.98	99.76	100.00	100.00
7	399/931	95.05	98.92	98.42	100.00	99.15	100.00	99.94	100.00	100.00
8	1105/2577	96.39	98.33	98.83	99.98	99.30	99.06	98.31	100.00	100.00
9	284/663	99.69	99.90	99.79	99.90	96.39	100.00	100.00	100.00	100.00
OA	12832/29944	97.86±0.2	96.53±0.1	99.70 ± 0.2	99.98 ± 0.0	99.44 ± 0.0	99.55 ± 0.1	99.42 ± 0.2	100.00 ± 0.0	100.00 ± 0.0
K		96.55±0.0	95.51±0.2	99.60 ± 0.5	99.98 ± 0.0	99.26 ± 0.0	99.41 ± 0.1	99.21 ± 0.3	100.00 ± 0.0	100.00 ± 0.0
AA		97.16±0.5	97.57±1.3	99.37 ± 0.0	99.97 ± 0.0	99.00 ± 0.0	99.78 ± 0.2	99.33 ± 0.2	100.00 ± 0.0	100.00 ± 0.0



**Şekil 4. 23:** PU için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY).

Tüm yöntemlerde %30 eğitim örneği ile birlikte %3, %5, %10 ve %20 eğitim örnekleri alınarak uygulamalar yapılmış ve sınıflandırma sonuçları Çizelge 4.27 ve Çizelge 4.28'de verilmiştir. ÖY'nin tüm veri setlerinde en iyi sınıflandırma sonuçlarını elde ettiği açıkça görülmektedir. Sadece IP veri setinde %10 eğitim örnekleri kullanılarak A2S2KRes'de %98.68 OA değeri, ÖY'de ise %98.66 OA değeri elde edilmiştir. Ayrıca A2S2KRes'de IP veri seti ile %3 eğitim örneği kullanılarak %92.99 OA, %91.99 K değeri ve PU veri setinde %98.90 AA değeri elde edilmiştir. Önerilen yöntem ile IP'de %92.43 OA ve %91.19 K değerleri elde edilirken, PU ile %98.74 AA değerleri bulunmuştur. Hem %3 hem de %10 eğitim örneklerinde, A2S2KRes bazı metriklerde az da olsa önerilen yöntemden daha iyi sonuçlar vermektedir. %20 eğitim örneğinin kullanıldığı IP veri seti için ÖY'ye en yakın değerler %99.46 OA, %98.84 AA, %99.38 K ile A2S2KRes ve %99.23 OA, %98.85 AA, %99.12 K ile DLEM yöntemleriyle elde edilmiştir. SA veri seti için ÖY'ye en yakın değerler %99.99 OA, AA, K ile DLEM ve %99.98 OA, AA, K ile HybridSN yöntemlerinde elde edilmiştir. PU veri seti için ÖY'ye en yakın değerler %99.96 OA, %99.94 AA, %99.95 K ile DLEM ve %99.96 OA, %99.94 AA, %99.94 K ile HybridSN yöntemlerinde elde edilmiştir. %10 eğitim örneğinin kullanıldığı IP veri seti için ÖY'ye en yakın değerler %98.50 OA, %98 AA, %99.30 K ile DLEM ve %98.39 OA, %98.01 AA, %98.16 K ile HybridSN yöntemleriyle elde edilmiştir. SA veri seti için ÖY'ye en yakın değerler %99.99 OA, AA, K ile DLEM ve %99.98 OA, AA, K ile HybridSN yöntemleri ile elde edilmiştir. PU veri seti için ÖY'ye en yakın değerler %99.87 OA, %99.77 AA, %99.83 K ile DLEM, %99.72 OA, %99.20 AA, %99.64 K ile HybridSN, %99.37 OA, %99.20 AA, %99.39 K ile S3EResBoF yöntemleriyle elde edilmiştir. %5 eğitim örneği ile gerçekleştirilen uygulamalarda önerilen yöntemle IP'de %95.73 OA, %95.13 K ve %93.05 AA değerleri elde edilirken, PU ile %99.82 OA, %99.79 K, %99.52 AA ve SA ile %99.96 OA, %99.96 K, %99.95 AA değerleri elde edilmiştir. IP, PU ve SA veri setlerinde önerilen yöntemle en yakın sınıflandırma sonuçlarının DLEM yöntemi ile elde edildiği görülmektedir. %3 eğitim örneği alındığında IP'de A2S2KRes yönteminin önerilen yöntemle göre %92.99 OA ve %91.99 K ile daha yüksek sınıflandırma performansı sağladığı görülmektedir. Önerilen yöntem IP'de %88.86 AA değeri ile en iyi sınıflandırma sonucunu vermektedir. PU'da %99.35 OA ve %99.21 K değerleri ile önerilen yöntemde en iyi sonuçlar alınırken, %98.90 AA değeri ile A2S2KRes yönteminde elde edilmiştir. Son olarak önerilen yöntemin SA'da %99.94 OA, %99.93 K ve %99.93 AA değerleri ile en iyi sınıflandırma sonuçlarını verdiği görülmektedir.

**Çizelge 4. 27:** IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).

Test - Eğitim (%)	Method	IP			PU			SA		
		OA	K	AA	OA	K	AA	OA	K	AA
70-30	2B ESA	89.48 ± 0.1	87.96 ± 0.1	86.14 ± 0.1	97.86 ± 0.2	96.55 ± 0.3	97.16 ± 0.1	97.38 ± 0.1	97.08 ± 0.1	98.84 ± 0.1
	3B ESA	91.10 ± 0.1	89.98 ± 0.1	91.58 ± 0.1	96.53 ± 0.1	95.51 ± 0.2	97.57 ± 1.0	93.96 ± 0.2	93.32 ± 0.5	97.01 ± 0.6
	FC3B ESA	92.93 ± 0.2	91.94 ± 0.5	90.61 ± 0.8	99.70 ± 0.2	99.60 ± 0.5	99.37 ± 0.0	99.85 ± 0.0	99.84 ± 0.1	99.90 ± 0.1
	HybridSN	99.75 ± 0.1	99.71 ± 0.1	99.63 ± 0.2	99.98 ± 0.0	99.98 ± 0.0	99.97 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0
	S3EResBoF	99.48 ± 0.1	99.41 ± 0.0	98.94 ± 0.0	99.44 ± 0.0	99.26 ± 0.0	99.00 ± 0.0	99.91 ± 0.0	99.90 ± 0.0	99.90 ± 0.0
	A2S2KRes	99.64 ± 0.1	99.60 ± 0.2	98.67 ± 0.1	99.55 ± 0.1	99.41 ± 0.1	99.78 ± 0.2	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0
	FuSENet	99.01 ± 0.2	98.60 ± 0.1	98.64 ± 0.1	99.42 ± 0.2	99.21 ± 0.3	99.33 ± 0.2	99.68 ± 0.2	99.74 ± 0.1	99.69 ± 0.1
	DLEM	99.76 ± 0.1	99.73 ± 0.1	99.05 ± 0.1	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0
	ÖY	99.83 ± 0.0	99.81 ± 0.0	99.82 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0
80-20	2B ESA	86.90 ± 1.3	85.01 ± 1.6	82.70 ± 1.0	96.02 ± 0.4	96.04 ± 0.3	95.10 ± 0.1	96.15 ± 0.6	95.71 ± 0.7	98.27 ± 0.2
	3B ESA	89.23 ± 0.2	87.70 ± 0.3	87.87 ± 0.1	97.30 ± 0.3	96.22 ± 0.1	97.02 ± 0.1	94.54 ± 0.5	93.81 ± 0.3	96.79 ± 0.6
	FC3B ESA	87.37 ± 0.2	85.56 ± 0.1	81.24 ± 0.3	99.66 ± 0.1	99.54 ± 0.1	98.32 ± 0.0	99.64 ± 0.0	99.62 ± 0.1	99.82 ± 0.0
	HybridSN	98.88 ± 0.1	98.72 ± 0.1	98.15 ± 0.2	99.96 ± 0.0	99.94 ± 0.0	99.94 ± 0.0	99.98 ± 0.0	99.98 ± 0.0	99.98 ± 0.0
	S3EResBoF	98.89 ± 0.2	98.60 ± 0.2	98.51 ± 0.3	99.36 ± 0.2	99.32 ± 0.1	98.90 ± 0.2	99.89 ± 0.0	99.88 ± 0.0	99.89 ± 0.0
	A2S2KRes	99.46 ± 0.0	99.38 ± 0.0	98.84 ± 0.0	99.49 ± 0.0	98.86 ± 0.0	98.86 ± 0.0	99.94 ± 0.0	99.93 ± 0.0	99.94 ± 0.0
	FuSENet	98.12 ± 0.3	97.93 ± 0.2	98.85 ± 0.2	98.67 ± 0.3	98.35 ± 0.2	98.57 ± 0.4	99.45 ± 0.1	99.83 ± 0.0	99.32 ± 0.2
	DLEM	99.23 ± 0.2	99.12 ± 0.2	98.85 ± 0.2	99.96 ± 0.0	99.95 ± 0.0	99.94 ± 0.0	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0
	ÖY	99.69 ± 0.0	99.65 ± 0.0	99.66 ± 0.0	99.97 ± 0.0	99.96 ± 0.0	99.96 ± 0.0	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0
90-10	2B ESA	80.27 ± 1.2	78.26 ± 2.1	68.32 ± 4.1	96.63 ± 0.2	95.53 ± 1.0	94.84 ± 1.4	96.34 ± 0.3	95.93 ± 0.9	94.36 ± 0.5
	3B ESA	82.62 ± 0.1	79.25 ± 0.3	76.51 ± 0.1	96.34 ± 0.2	94.90 ± 1.2	97.03 ± 0.6	85.00 ± 0.1	83.20 ± 0.7	89.63 ± 0.2
	FC3B ESA	75.13 ± 0.2	71.24 ± 0.1	50.14 ± 0.4	99.28 ± 0.1	99.05 ± 0.1	98.84 ± 0.1	99.50 ± 0.0	99.44 ± 0.0	99.75 ± 0.0
	HybridSN	98.39 ± 0.1	98.16 ± 0.1	98.01 ± 0.2	99.72 ± 0.1	99.64 ± 0.1	99.20 ± 0.1	99.98 ± 0.0	99.98 ± 0.0	99.98 ± 0.0
	S3EResBoF	97.63 ± 0.2	97.30 ± 0.2	95.86 ± 0.1	99.37 ± 0.1	99.39 ± 0.1	99.20 ± 0.1	99.86 ± 0.0	99.85 ± 0.0	99.70 ± 0.0
	A2S2KRes	98.68 ± 0.2	98.29 ± 0.2	97.24 ± 0.2	99.11 ± 0.1	98.60 ± 0.1	98.82 ± 0.2	99.67 ± 0.0	99.63 ± 0.0	99.79 ± 0.0
	FuSENet	97.11 ± 0.2	97.25 ± 0.2	97.32 ± 0.2	97.65 ± 0.3	97.69 ± 0.3	97.68 ± 0.4	99.23 ± 0.1	99.97 ± 0.0	99.16 ± 0.1
	DLEM	98.50 ± 0.1	98.30 ± 0.1	98.00 ± 0.2	99.87 ± 0.1	99.83 ± 0.1	99.77 ± 0.1	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0
	ÖY	98.66 ± 0.0	98.47 ± 0.0	98.79 ± 0.0	99.90 ± 0.0	99.87 ± 0.0	99.79 ± 0.1	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0

**Çizelge 4. 28 (devam):** IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).

Test - Eğitim (%)	Method	IP			PU			SA		
		OA	K	AA	OA	K	AA	OA	K	AA
95-5	2B ESA	72.83 ± 0.5	68.58 ± 0.2	69.23 ± 3.1	93.82 ± 0.2	90.10 ± 0.6	92.09 ± 0.4	95.26 ± 0.5	94.73 ± 0.4	97.70 ± 1.5
	3B ESA	71.63 ± 0.3	68.07 ± 0.3	73.39 ± 3.5	92.88 ± 0.3	90.70 ± 0.6	92.56 ± 2.5	92.93 ± 0.2	92.26 ± 0.9	93.5 ± 2.4
	FC3B ESA	92.51 ± 0.2	91.41 ± 0.4	84.57 ± 0.5	84.51 ± 0.2	79.40 ± 0.3	69.87 ± 0.1	98.90 ± 0.0	98.77 ± 0.1	98.23 ± 0.1
	HybridSN	92.78 ± 1.7	91.75 ± 2.1	86.27 ± 2.5	99.21 ± 1.1	98.95 ± 1.4	98.33 ± 0.8	99.80 ± 0.1	99.78 ± 0.1	99.80 ± 0.1
	S3EResBoF	91.48 ± 1.3	91.27 ± 2.3	91.11 ± 2.1	99.43 ± 0.2	99.24 ± 0.2	99.12 ± 0.2	99.86 ± 0.1	99.83 ± 0.1	99.84 ± 0.1
	A2S2KRes	95.02 ± 0.1	94.46 ± 0.1	92.43 ± 0.1	99.67 ± 0.1	99.57 ± 0.1	99.38 ± 0.1	99.79 ± 0.0	99.77 ± 0.0	99.82 ± 0.0
	FuSENet	91.83 ± 0.4	90.67 ± 0.5	86.59 ± 0.8	99.58 ± 0.2	99.44 ± 0.2	99.36 ± 0.2	99.75 ± 0.1	99.72 ± 0.1	99.63 ± 0.1
	DLEM	95.23 ± 0.0	94.55 ± 0.0	91.15 ± 0.0	99.72 ± 0.0	99.63 ± 0.0	99.31 ± 0.0	99.96 ± 0.0	99.96 ± 0.0	99.95 ± 0.0
	ÖY	95.73 ± 0.0	95.13 ± 0.0	93.05 ± 0.0	99.82 ± 0.0	99.79 ± 0.0	99.52 ± 0.0	99.96 ± 0.0	99.96 ± 0.0	99.95 ± 0.0
97-3	2B ESA	80.00 ± 1.2	76.88 ± 2.1	61.48 ± 3.2	92.55 ± 1.0	89.90 ± 1.4	89.94 ± 1.3	86.31 ± 0.5	84.74 ± 0.4	91.90 ± 1.2
	3B ESA	80.68 ± 0.3	77.58 ± 0.3	70.33 ± 1.0	89.43 ± 1.3	85.61 ± 1.1	86.25 ± 1.2	92.87 ± 0.2	92.05 ± 0.9	96.59 ± 0.4
	FC3B ESA	84.27 ± 0.2	81.82 ± 0.1	75.32 ± 0.3	87.81 ± 0.1	83.68 ± 0.1	72.30 ± 0.1	99.52 ± 0.1	99.46 ± 0.1	99.16 ± 0.1
	HybridSN	87.03 ± 1.1	85.12 ± 0.8	77.80 ± 1.5	98.69 ± 0.4	98.27 ± 0.3	97.43 ± 0.1	99.84 ± 0.0	99.82 ± 0.0	99.85 ± 0.0
	S3EResBoF	91.23 ± 0.5	90.09 ± 0.4	87.86 ± 0.6	98.78 ± 0.2	98.39 ± 0.4	98.26 ± 0.4	99.76 ± 0.1	99.81 ± 0.1	99.78 ± 0.1
	A2S2KRes	92.99 ± 0.2	91.99 ± 0.2	88.55 ± 0.2	99.07 ± 0.1	98.77 ± 0.1	98.90 ± 0.1	99.34 ± 0.0	99.26 ± 0.0	99.62 ± 0.0
	FuSENet	90.52 ± 0.5	89.17 ± 0.4	86.72 ± 0.6	98.71 ± 0.2	98.28 ± 0.4	98.39 ± 0.4	99.36 ± 0.1	99.29 ± 0.1	99.72 ± 0.1
	DLEM	90.98 ± 0.0	89.65 ± 0.0	84.26 ± 0.0	99.29 ± 0.0	99.07 ± 0.0	98.57 ± 0.0	99.93 ± 0.0	99.93 ± 0.0	99.92 ± 0.0
	ÖY	92.43 ± 0.0	91.19 ± 0.0	88.86 ± 0.0	99.35 ± 0.0	99.21 ± 0.0	98.74 ± 0.0	99.94 ± 0.0	99.93 ± 0.0	99.93 ± 0.0

Derin öğrenme yöntemlerinin sınıflandırma doğruluğu büyük ölçüde pencere boyutuna bağlıdır. Uzamsal boyutun (pencere boyutunun) önerilen yöntemin performansı üzerindeki etkisi Çizelge 4.29'da gösterilmektedir. %30-70 eğitim-test oranı için tüm veri setleri göz önüne alındığında, en iyi sınıflandırma sonuçları 25x25 pencere boyutunda elde edilmektedir. Ayrıca farklı pencere boyutlarında (7x7, 15x15, 19x19, 21x21, 23x23 ve 25x25) önerilen yöntemle karşılaştırma için kullanılan yöntemlerin OA sonuçları Çizelge 4.30'da verilmiştir. Çizelge 4.30'daki OA sonuçları %30-70 eğitim-test oranı kullanılarak elde edilmiştir. Çizelge 4.30'a göre IP ve SA kullanılan uygulamalarda tüm pencere boyutlarında en iyi sınıflandırma sonuçlarının ÖY ile alındığı görülmektedir. PU veri seti kullanılarak yapılan uygulamalarda en iyi sınıflandırma sonuçları 7x7 ve 23x23 pencere boyutları dışındaki tüm pencere boyutlarında ÖY ile elde edilmektedir.

**Çizelge 4. 29:** Pencere boyutunun ÖY'ye etkisi (%).

Pencere boyutu	IP			PU			SA		
	OA	AA	K	OA	AA	K	OA	AA	K
7x7	99.07	98.44	98.94	99.85	99.74	99.80	99.95	99.97	99.94
15x15	99.69	99.29	99.65	99.98	99.95	99.97	99.99	99.99	99.98
17x17	99.77	99.85	99.74	99.98	99.93	99.97	99.99	99.99	99.99
19x19	99.75	99.66	99.60	99.98	99.93	99.96	100.00	100.00	100.00
21x21	99.75	99.84	99.71	99.99	99.90	99.94	100.00	100.00	100.00
23x23	99.76	99.83	99.73	99.97	99.91	99.96	99.99	99.90	99.95
25x25	99.83	99.82	99.81	100.00	100.00	100.00	100.00	100.00	100.00

**Çizelge 4. 30:** Farklı pencere boyutları ile tüm yöntemlerin OA değerleri (%).


Pencere boyutu		2B	3B	FC3B	HybridSN	S3EResBoF	FuSENet	DLEM	ÖY
		ESA	ESA	ESA					
7x7	IP	91.31	94.65	92.20	98.78	98.78	96.98	98.94	99.07
	PU	96.12	97.37	99.71	99.79	99.19	99.86	99.95	99.85
	SA	94.08	96.23	99.79	99.87	99.73	99.78	99.92	99.95
15x15	IP	96.21	98.28	93.69	99.21	99.33	98.18	99.69	99.69
	PU	97.18	98.44	99.85	99.93	99.91	99.69	99.83	99.98
	SA	96.56	97.17	99.99	99.99	99.97	99.99	99.99	99.99
17x17	IP	89.12	96.67	91.80	99.76	99.07	97.86	99.55	99.77
	PU	96.37	96.49	99.05	99.96	99.72	99.87	99.98	99.98
	SA	96.85	96.89	99.95	99.98	99.92	99.91	99.99	99.99
19x19	IP	91.44	97.11	93.13	99.74	99.16	96.18	99.67	99.75
	PU	92.11	95.57	99.93	99.98	99.47	99.83	99.96	99.98
	SA	96.35	97.35	98.04	99.99	99.81	99.91	100.00	100.00
21x21	IP	91.62	97.17	94.34	99.73	99.12	98.99	99.69	99.75
	PU	95.42	96.44	99.78	99.90	99.46	99.59	99.99	99.99
	SA	96.42	96.30	99.99	99.69	99.95	99.96	100.00	100.00
23x23	IP	93.51	98.04	93.90	99.31	99.20	98.52	99.63	99.76
	PU	96.37	97.39	99.72	99.96	99.44	99.70	99.99	99.97
	SA	96.12	96.35	99.98	99.71	99.79	99.75	99.99	99.99
25x25	IP	89.48	91.10	92.93	99.75	99.48	99.01	99.76	99.83
	PU	97.86	96.53	99.70	99.98	99.44	99.42	100.00	100.00
	SA	97.38	93.96	99.85	100.00	99.91	99.68	100.00	100.00

Çalışmalarda kullanılan diğer veri setleri HyRANK-Loukia (HL) ve Houston (UH) 2013'tür. Her iki veri setinde de 11x11 pencere boyutu ve TBA sonucunda elde edilen 20 adet temel bileşen kullanılarak çalışmalar yapılmıştır. Ayrıca çalışmalarda eğitim-test oranı %10-90 olarak alınmıştır. HL ile yapılan uygulamaların OA, AA, K değerleri, eğitim-test süresi, sınıf bazlı sınıflandırma sonuçları Çizelge 4.31'de verilmiştir. Tüm yöntemlerin sınıflandırma haritalarının sonuçları Şekil 4.24'te gösterilmektedir. Çizelge 4.31'e göre %10 eğitim örnekleri alınarak gerçekleştirilen uygulamalar sonucunda en iyi sınıflandırma sonuçları %90.47 OA, %88.66 K ve %85.82 AA ile önerilen yöntemde elde edilmiştir. Önerilen yönteme en yakın sonuçlar %86.79 OA, %83.72 K ve %88.13 AA ile A2S2KRes yönteminde elde edilmiştir. FC3B ESA, %73.55 OA, %68.18 F, %55.28 AA ile en kötü sınıflandırma sonucunu vermektedir. Daha sonra 2B ESA'da %75.57 OA, %70.57 K, %60.64 AA ve 3B ESA'da %75.48 OA, %70.79 K, %66.48 ile en kötü sonuçlar elde edilmiştir. Sınıf bazlı sınıflandırma sonuçları incelendiğinde, önerilen yöntemin sonuçları 8. sınıfta %96.37, 9. sınıfta %88.02, 10. sınıfta %89.58, 11. sınıfta %98.35, 13. ve 14. sınıfta %100 olarak bulunmuştur. Önerilen yöntem bu sınıflarda en iyi sonuçları vermektedir. 1, 3, 4, 6 ve 7 nolu sınıflarda en başarılı sınıflandırma sonuçları A2S2KRes yöntemi ile elde edilmiştir. Elde edilen sonuçlar sırasıyla %84.08, %91.74, %72.67, %84.74 ve %89.38'dir. Sınıf 2'de DLEM, FuSENet, S3EResBoF yöntemleri %100 ile en iyi sınıflandırma sonucunu vermektedir. 5. ve 12. sınıflarda en iyi sonuçlar %97.07 ve %94.82 ile DLEM yönteminde elde edilmiştir. Tüm sonuçlar göz önüne alındığında, A2S2KRes sınıflandırma haritası %88.13 AA değeri ile temel gerçeğe en çok benzeyen yöntemdir. Ardından, %85.82 AA değeri ile önerilen yöntemin sınıflandırma haritası temel gerçeğe benzemektedir. HL veri seti ile gerçekleştirilen uygulamalarda önerilen yöntemin eğitim ve test sürelerinin 2B ESA dışındaki tüm yöntemlerden daha iyi olduğu görülmektedir.

**Çizelge 4. 31:** %10 eğitim örnekleri kullanılarak HL veri kümesi için sınıflandırma sonuçları.

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	A2S2KRes	FuSENet	DLEM	ÖY
1	29/259	43.73	39.78	11.68	65.69	83.45	84.08	79.34	73.36	76.45
2	7/60	49.23	83.08	29.69	96.87	100.00	97.88	100.00	100.00	98.33
3	54/488	70.15	68.44	67.96	86.02	88.27	91.74	68.49	86.41	90.98
4	8/71	1.30	15.58	4.00	46.67	48.14	72.67	38.77	26.67	49.30
5	140/1261	88.96	92.42	88.13	89.63	77.46	89.52	82.82	97.07	94.85
6	22/201	7.87	29.63	4.24	28.77	46.90	84.74	73.27	29.72	52.74
7	50/450	45.36	59.59	46.31	64.42	83.62	89.38	88.31	62.74	72.44
8	107/965	57.88	54.90	67.39	78.09	72.71	79.28	65.06	84.38	96.37
9	379/3414	80.97	70.97	74.13	80.07	80.99	81.95	85.27	81.54	88.02
10	280/2523	72.89	80.21	77.81	79.76	64.15	85.29	77.58	84.30	89.58
11	41/363	50.00	52.04	32.29	66.14	77.78	85.12	48.09	69.79	98.35
12	49/438	80.93	85.38	70.41	94.17	90.54	94.79	95.27	94.82	94.06
13	139/1254	100.00	98.67	100.00	100.00	99.91	99.68	99.58	100.00	100.00
14	45/406	99.77	100.00	100.00	100.00	99.08	97.70	99.49	100.00	100.00
OA		75.57	75.48	73.55	82.04	77.46	86.79	80.65	84.83	90.47
K		70.57	70.79	68.18	78.61	73.10	83.72	77.28	81.92	88.66
AA		60.64	66.48	55.28	76.88	79.50	88.13	78.67	77.91	85.82
Eğitim süresi		1.06	3.1	21.40	15.7	8.85	5.1	15.22	38.71	1.45
Test süresi		1.7	1.8	2.83	3.6	12.88	8.1	3.01	6.28	1.5






**Şekil 4. 24:** HL için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY).

UH ile yapılan uygulamaların OA, AA, K değerleri, eğitim-test süresi, sınıf bazlı sınıflandırma sonuçları Çizelge 4.32'de verilmiştir. Tüm yöntemlerin sınıflandırma haritalarının sonuçları Şekil 4.25'te gösterilmektedir. Çizelge 4.32'ye göre en iyi sınıflandırma sonuçları, %10 eğitim örneği alınarak gerçekleştirilen uygulamalar sonucunda %98.93 OA, %98.84 K ve %99.01 AA ile önerilen yöntemde elde edilmiştir. Önerilen yönteme en yakın sonuçlar %98.10 OA, %97.95 K, %98.25 AA ile DLEM, %98.00 OA, %97.83 K, %97.63 AA ile FuSENet, %97.89 OA, %97.72 K, %97.55 AA ile S3EResBoF, %97.44 OA, %97.23 K, %97.63 AA ile A2S2KRes'te elde edilmiştir. FC3B ESA, %89.54 OA, %88.68 K, %88.94 AA ile en kötü sınıflandırma sonucunu vermektedir. Sınıf bazlı sınıflandırma sonuçları incelendiğinde önerilen yöntemin sonuçları 1, 5, 6, 10, 14, 15 nolu sınıflarda %100, 13. sınıfta %96.92 olarak elde edilmiştir. Önerilen yöntem bu sınıflarda en iyi sonuçları vermiştir. 2, 7, 8, 9, 12. sınıflarda en başarılı sınıflandırma sonuçları FuSENet yöntemi ile elde edilmiştir. Elde edilen sonuçlar sırasıyla %100, %98.34, %99.79, %100 ve %99.81'dir. 4. ve 11. sınıflarda en iyi sonuçlar %100 ve %99.49 ile DLEM yönteminde elde edilmiştir. 3. sınıfta ise en iyi sonuçlar %100 ile A2S2KRes ve FuSENet yöntemlerinde elde edilmiştir. Tüm sonuçlar göz önüne alındığında, önerilen yöntemin sınıflandırma haritası %99.01 AA değeri ile temel gerçeğe en çok benzeyen yöntemdir.


ÖY, HybridSN, sadece 3B ESA ve sadece 2B ESA yöntemlerinin farklı pencere boyutlarındaki (7x7, 9x9, 11x11, 13x13 ve 15x15) genel doğruluk değerleri HL ve UH veri setleri kullanılarak karşılaştırılmış ve Şekil 4.26'da gösterilmiştir. Şekil 4.26 incelendiğinde tüm pencere boyutlarında önerilen yöntemin diğer yöntemlere göre başarılı bir sınıflandırma sonucu verdiği görülmektedir.

**Çizelge 4. 32:** %10 eğitim örnekleri kullanılarak UH veri kümesi için sınıflandırma sonuçları.

No	Eğitim/Test	2B ESA	3B ESA	FC3B ESA	HybridSN	S3EResBoF	A2S2KRes	FuSENet	DLEM	ÖY
1	125/1126	94.07	92.17	92.93	97.05	97.93	97.52	98.12	97.22	100.00
2	125/1129	99.59	98.44	97.73	99.92	99.24	99.29	100.00	99.92	99.91
3	70/627	95.41	99.26	95.62	99.70	99.66	100.00	100.00	99.70	99.84
4	124/1120	99.01	94.95	93.15	99.58	97.64	98.36	97.65	100.00	99.02
5	124/1118	99.67	99.75	99.58	100.00	100.00	100.00	100.00	100.00	100.00
6	33/292	86.98	85.08	85.44	99.68	99.63	98.98	100.00	100.00	100.00
7	127/1141	94.06	90.73	92.45	94.77	97.69	96.30	98.34	97.26	94.65
8	124/1120	90.14	73.24	90.27	97.46	99.48	98.59	99.79	96.70	98.21
9	125/1127	90.62	92.92	60.97	86.54	98.43	95.09	100.00	91.08	98.76
10	123/1104	93.36	94.45	91.25	99.40	98.87	97.35	93.09	100.00	100.00
11	123/1112	90.15	97.41	87.98	94.63	95.28	96.30	98.86	99.49	98.56
12	123/1110	94.23	96.32	90.35	96.16	97.68	94.25	99.81	97.61	99.28
13	47/422	54.06	66.15	58.52	93.50	95.42	95.19	89.93	94.84	96.92
14	43/385	69.40	92.05	99.26	100.00	86.99	97.21	95.00	100.00	100.00
15	66/594	97.81	100.00	98.56	100.00	99.46	100.00	93.91	100.00	100.00
OA	1502/13527	92.54	92.58	89.54	96.91	97.89	97.44	98.00	98.10	98.93
K		91.92	91.97	88.68	96.66	97.72	97.23	97.83	97.95	98.84
AA		89.90	91.52	88.94	97.23	97.55	97.63	97.63	98.25	99.01
Eğitim süresi		2.16	5.52	9.43	12.1	13.53	8.72	9.1	15.3	4.34
Test süresi		1.3	3.6	4.8	5.2	6.86	20.4	6.14	13	3.1



**Şekil 4. 25:** UH için tahmin sonucunda elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) 2B ESA, (c) 3B ESA, (d) FC3B ESA, (e) HybridSN, (f) S3EResBoF, (g) A2S2KRes, (h) FuSENet, (i) DLEM, (j) Önerilen yöntem (ÖY).



Şekil 4. 26: HL ve UH veri setleri kullanılarak farklı pencere boyutlarında PM, HybridSN, sadece 3B CNN ve sadece 2B CNN yöntemlerinin genel doğruluk değerlerinin karşılaştırılması.

#### 4.8 Uygulama 6: Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması

##### 4.8.1 Önerilen yöntem

3B ESA, 2B ESA'da 2B evrişim yerine 3B evrişim gerçekleştiren 2B ESA modellerinin değiştirilmiş şeklidir. Evrişim işlemleri, 3B verilere uygulandığında hem uzamsal hem de spektral boyutlardan özelliklerin yakalanması istenilmektedir. Bu amaçla, 3B giriş verilerinden ortak uzamsal spektral özellikleri hesaplamak için 3B evrişim işlemlerinin 3B özellik küplerine uygulandığı 3B ESA kullanılmaktadır. 3B evrişim, 3B spektral görüntülerden uzamsal-spektral özelliklerin çıkarılmasına yardımcı olmaktadır. Şekil 4.1'de önerilen yöntemlerin genel çerçevesi verilmiştir. Genel çerçevede 3B hiperspektral veri küpleri oluşturulduktan sonra, sınıflandırma sonuçlarını elde etmek için derin öğrenme yöntemlerinin girişine verilmektedir. Bu çalışma kapsamında, literatürde var olan LeNet5, AlexNet, GoogleNet, ResNet50 ve VGG16 derin öğrenme mimarilerinin 3B ESA ile birlikte kullanımı ele alınmaktadır.

##### 4.8.2 Sınıflandırma sonuçları


3B ESA tabanlı derin öğrenme mimarilerinin sınıflandırma performanslarını karşılaştırmak için Indian Pines (IP), Salinas (SA), Botswana (B) ve HyRANK-Loukia (HL) veri setlerini içeren dört gerçek hiperspektral veri seti kullanılmıştır. Tüm deneylerde, test-

eđitim seti %30-70 oranına b6l6nm6şt6r. 0.0001 6đrenme oranına sahip kategorik aprazentropi ve optimizasyon iin kullanılan 1e-06 bozunma iřlevine sahip Adam optimizer kullanılmıřtır. Eđitim s6reci, 256 batch size ve 100 epochs boyunca tekrar etmektedir. T6m verisetlerinde, evriřim iin 15x15 komřuluk ıkarımı kullanılmaktadır. Bununla birlikte, TBA tekniđinden sonra ıkarılan bantların sayısı t6m verisetleri iin 15 temel bileřen olarak alınmıřtır.

izelge 4.33, IP veriseti kullanılarak LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 derin 6đrenme mimarilerinin sınıf bazlı ve genel deđerlendirme metriklerinin (OA, AA ve K) sonularını g6stermektedir. OA, AA ve K deđerlendirme metrikleri incelendiđinde en iyi sonucun sırasıyla %99.77, %99.77, %99.74 ile VGG16 ve %99.71, %99.85, %99.67 ile ResNet50 mimarilerinde elde edildiđi g6r6lmektedir. Bu mimarilere en yakın sınıflandırma sonucu %99.58 OA, %99.68 AA ve %99.52 K ile AlexNet'te elde edilmiřtir. 1, 7, 8, 13 ve 16 nolu sınıflarda t6m derin 6đrenme mimarilerinde %100 sınıflandırma sonucu elde edilmiřtir. 2 nolu sınıf iin %99.77 ile VGG16, 3 nolu sınıf iin %100 ile VGG16 ve ResNet50, 4 nolu sınıf iin %100 ile AlexNet, VGG16, GoogleNet, ResNet50, 5 nolu sınıf iin %100 ile LeNet5 ve ResNet50, 6 nolu sınıf iin %100 ile AlexNet, 9 nolu sınıf iin %100 ile AlexNet, VGG16, ResNet50, 10 ve 11 nolu sınıflar iin %100 ile VGG16, 12 nolu sınıf iin %100 ile LeNet5, VGG16, ResNet50, 14 nolu sınıf iin %100 ile AlexNet ve ResNet50, 15 nolu sınıf iin %100 ile LeNet5, AlexNet ve ResNet50 mimarilerinde en iyi sınıflandırma sonucu elde edilmiřtir. IP veriseti iin t6m mimariler g6z 6n6ne alındıđında VGG16 ve ResNet50 gibi derin ađ mimarileri ile daha bařarılı sınıflandırma sonularının elde edildiđi g6r6lmektedir. VGG16, ResNet50'den farklı olarak atlama bađlantıları iermeyen geleneksel evriřim katmanları kullanmaktadır. Bu VGG16'nın tasarımıının kolay olmasını sađlamakta ve model eđitimini kolaylařtırmaktadır. ResNet50 mimarisi VGG16'ya g6re daha fazla katmandan oluřmakta ve daha derindir. Ancak ResNet50 mimarisinde VGG16'dan farklı olarak eđitim s6recini d6zenlemek iin batch normalization katmanları kullanılmaktadır. VGG16 ile ResNet50'de OD deđerleri g6z 6n6ne alındıđında, ResNet50 ile ok az da olsa daha dođru 6z niteliklerin elde edildiđi g6r6lmektedir. řekil 4.27'de t6m derin 6đrenme mimarileri ile gerekleřtirilen uygulamalar sonucunda elde edilen sınıflandırma haritaları g6sterilmektedir. řekil 4.27 incelendiđinde, VGG16 ve ResNet50 ile elde edilen sınıflandırma haritalarının ground truth'a olduka yakın olduđu g6r6lmektedir.

**Çizelge 4. 33:** IP verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	100	100	100	100	100
2	98.36	99.53	99.77	98.83	99.06
3	99.60	99.20	100	99.20	100
4	98.60	100	100	100	100
5	100	98.62	99.31	99.31	100
6	99.54	100	99.54	99.09	99.54
7	100	100	100	100	100
8	100	100	100	100	100
9	16.6	100	100	83.33	100
10	98.63	98.97	100	97.60	99.31
11	99.86	99.73	100	98.78	99.73
12	100	98.88	100	97.19	100
13	100	100	100	100	100
14	99.73	100	99.47	98.68	100
15	100	100	98.27	99.14	100
16	100	100	100	100	100
OA	99.32	99.58	99.77	98.76	99.71
AA	94.44	99.68	99.77	98.20	99.85
K	99.22	99.52	99.74	98.59	99.67




**Şekil 4. 27:** IP veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.

BO verisetini kullanan beş derin öğrenme mimarisinin sınıf bazlı ve genel değerlendirme metriklerinin sınıflandırma sonuçları Çizelge 4.34'te görülmektedir. Çizelge 4.34 incelendiğinde, sınıf bazlı ve OA, AA ve K değerlendirme metriği açısından %100 ile en iyi sonuç VGG16 ve ResNet50 mimarilerinde elde edilmiştir. ResNet50 ve VGG16 ile karşılaştırıldığında, LeNet5 mimarisi ile OA, AA ve K açısından sırasıyla %0.41, %0.35, %0.44, AlexNet ile %0.31, %0.27, %0.33 ve GoogleNet ile %0.1, %0.25, %0.11 daha az sınıflandırma sonucunun elde edildiği görülmektedir. Bu sonuçlara bakıldığında ResNet50 ve VGG16 mimarilerine en yakın sınıflandırma sonuçları GoogleNet ile elde edilmiştir. LeNet5 ve AlexNet mimarileri ile 5 nolu sınıf için sırasıyla %95.06 ve %96.30 ile en kötü ve diğer tüm sınıflarda ise %100 ile en iyi sınıflandırma sonucu elde edilmiştir. GoogleNet

mimarisi ile 14 nolu sınıf için %96.55 ile en kötü ve diğer tüm sınıflarda %100 ile en iyi sınıflandırma sonucu elde edilmiştir. BO verisetinde toplam 3248 örnek bulunmaktadır. Sınıflandırma için kullanılan BO veriseti kolay bir verisetidir. Bu verisetinde de derin ağ mimarileri diğer klasik ağ mimarilerinden daha iyi sonuç verdiği görülmektedir. Düşük örnek sayısına sahip BO veriseti için VGG16 ve ResNet50 ile daha doğru özniteliklerin elde edildiği sonucu çıkarılabilmektedir. Tüm mimariler ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma haritaları Şekil 4.28’de gösterilmektedir. Şekil 4.28’e göre VGG16 ve ResNet50 mimarilerinin sınıflandırma haritası ground truth ile aynı, diğer mimarilerden GoogleNet’in ground truth’a oldukça yakın olduğu görülmektedir.

**Çizelge 4. 34:** BO verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).

Mimari	1	2	3	4	5	6	7	8	9	10	11	12	13	14	OA	AA	K
LeNet5	100	100	100	100	95.06	100	100	100	100	100	100	100	100	100	99.59	99.65	99.56
AlexNet	100	100	100	100	96.30	100	100	100	100	100	100	100	100	100	99.69	99.73	99.67
VGG16	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100
GoogleNet	100	100	100	100	100	100	100	100	100	100	100	100	100	96.55	99.90	99.75	99.89
ResNet50	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100	100



**Şekil 4. 28:** BO veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.


HL veriseti kullanılarak elde edilen sınıflandırma sonuçları Çizelge 4.35’te gösterilmektedir. OA, AA ve K değerlendirme metrikleri göz önüne alındığında sırasıyla %98.86, %97.92 ve % 98.65 ile en iyi sonuçların VGG16 ile elde edildiği görülmektedir. VGG16’ya en yakın sonuçlar %97.93, %97.71 ve %97.54 ile ResNet50 mimarisi ile yapılan uygulamalarda elde edilmiştir. Sınıf bazlı performanslar incelendiğinde ise, 2, 13 ve 14 nolu sınıflar için tüm mimarilerde %100 ile en iyi sınıflandırma sonuçları elde edilmiştir. 1 nolu sınıf için %97.67 ile LeNet5 ve VGG16, 3 nolu sınıf için %99.39 ile ResNet50, 4 nolu sınıf



için %95.83 ile ResNet50, 5 ve 11 nolu sınıflar için %100 ile VGG16, 6, 7, 8, 9 ve 10 nolu sınıflar için sırasıyla %97.01, %98, %99.38, %98.77, %97.98 ile VGG16, 12 nolu sınıf için %100 ile LeNet5, AlexNet, VGG16 ve ResNet50 mimarilerinde en iyi sınıflandırma sonuçları elde edilmiştir. HL verisetinde de BO ve IP verisetlerinde olduğu gibi, derin ağ mimarileri ile daha iyi sonuçların elde edildiği görülmektedir. Derin ağ mimarilerinden VGG16'nın test doğruluğu ResNet50'den %0.93 OA, %0.21 AA ve %1.11 K değeri ile daha yüksek elde edilmiştir. VGG16'nın çok az da olsa ResNet50'den daha iyi sonuç vermesi, katman sayısının az olması ve ResNet50'ye göre daha sığ mimari olması ile açıklanabilmektedir. VGG16 ve ResNet50'de AA değerleri birbirine oldukça yakındır. AA değerlerinde, her iki mimaride de her sınıf için doğru sınıflandırma sayısının birbirine yakın olduğu sonucu çıkarılabilmektedir. Böyle bir veriseti için her iki mimari ile daha doğru ve daha ayırt edici öznitelikler elde edileceğini göstermektedir. Tüm derin öğrenme mimarileri ile elde edilen sınıflandırma haritaları Şekil 4.29'de gösterilmektedir. Ground truth'a en yakın sınıflandırma haritası sonucu VGG16 ve ResNet50 ile elde edilmiştir.

**Çizelge 4. 35:** HL verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	97.67	93.02	97.67	95.35	95.35
2	100	100	100	100	100
3	98.16	96.32	98.77	95.09	99.39
4	62.5	91.66	83.33	87.5	95.83
5	99.29	97.14	100	98.09	98.81
6	76.12	74.63	97.01	80.60	91.04
7	88	88.66	98	90.66	94.67
8	98.14	95.34	99.38	96.58	98.45
9	97.01	96.75	98.77	96.22	97.72
10	94.17	89.89	97.98	97.03	96.67
11	98.35	96.69	100	96.69	100
12	100	100	100	97.94	100
13	100	100	100	100	100
14	100	100	100	100	100
OA	96.49	95.04	98.86	96.64	97.93
AA	93.53	94.29	97.92	95.13	97.71
K	95.84	94.10	98.65	96.02	97.54




**Şekil 4. 29:** HL veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.

Çizelge 4.36, SA veriseti kullanılarak beş farklı derin öğrenme mimarisi ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçlarını göstermektedir. OA, AA ve K değerlendirme metrikleri ve sınıf bazlı performanslar göz önüne alındığında %100 ile en iyi sonuçların LeNet5 ve VGG16’da elde edildiği görülmektedir. Diğer mimarilerden LeNet5 ve VGG16’ya en yakın sınıflandırma sonucu ResNet50 ile elde edilmiştir. Ancak AlexNet ve GoogleNet ile gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçlarının da LeNet5 ve VGG16’ya oldukça yakın olduğu görülmektedir. Sınıf bazlı değerlendirme yapıldığında ise, 4 nolu sınıf için %99.52 ve %99.76 ile AlexNet ve ResNet50, 5 nolu sınıf için %99.87, %99.75 ve %99.87 ile AlexNet, GoogleNet ve ResNet50, 6 nolu sınıf için %99.92 ile GoogleNet, 8 nolu sınıf için %99.97 ile AlexNet ve GoogleNet, 15 nolu sınıf için %99.91 ve %99.95 ile AlexNet ve GoogleNet mimarilerinde en kötü sınıflandırma sonuçları elde edilmiştir. SA veriseti 54129 örnek içermektedir. Ancak, bu veriseti de BO verisetinde olduğu gibi sınıflandırma için kullanılan kolay bir verisetidir. SA verisetinde, beş farklı mimari ile de elde edilen sonuçlar birbirine oldukça yakındır. LeNet5 ile %100 sonuç elde edilmesinin nedeni olarak Bölüm 2.3’de açıklandığı üzere katman sayısının az olması, oldukça basit bir tasarımının olması ve eğitilebilir parametre sayısının oldukça az olmasından kaynaklanmaktadır. Eğitilebilir parametre sayısının az olması eğitimi hızlandırmakta ve sınıflandırma doğruluğunu arttırmaktadır. VGG16 ise LeNet5 ve AlexNet’e göre daha fazla evrişim katmanından oluşmakta ve daha derindir. Ayrıca, ilk birkaç katmanda daha küçük alıcı alanlara (receptive fields) sahip bir evrişimsel katman yığını kullanılmaktadır. Aynı zamanda VGG16’da tüm

evrişim katmanları sıralıdır. Bu modelin daha kolay eğitilmesini sağlamaktadır. SA veriseti kullanılarak elde edilen sınıflandırma haritaları Şekil 4.30’da gösterilmektedir. Şekil 4.30 incelendiğinde LeNet5 ile VGG16 mimarilerinin ground truth ile aynı olduğu, diğer mimariler ile de ground truth’a oldukça yakın sınıflandırma haritaları elde edildiği görülmektedir.

**Çizelge 4. 36:** SA verisetinde farklı derin öğrenme mimarileri kullanılarak elde edilen sınıflandırma sonuçları (%).

Sınıf	LeNet5	AlexNet	VGG16	GoogleNet	ResNet50
1	100	100	100	100	100
2	100	100	100	100	100
3	100	100	100	100	100
4	100	99.52	100	100	99.76
5	100	99.87	100	99.75	99.87
6	100	100	100	99.92	100
7	100	100	100	100	100
8	100	99.97	100	99.97	100
9	100	100	100	100	100
10	100	100	100	100	100
11	100	100	100	100	100
12	100	100	100	100	100
13	100	100	100	100	100
14	100	100	100	100	100
15	100	99.91	100	99.95	100
16	100	100	100	100	100
OA	100	99.96	100	99.97	99.99
AA	100	99.95	100	99.97	99.98
K	100	99.96	100	99.97	99.99



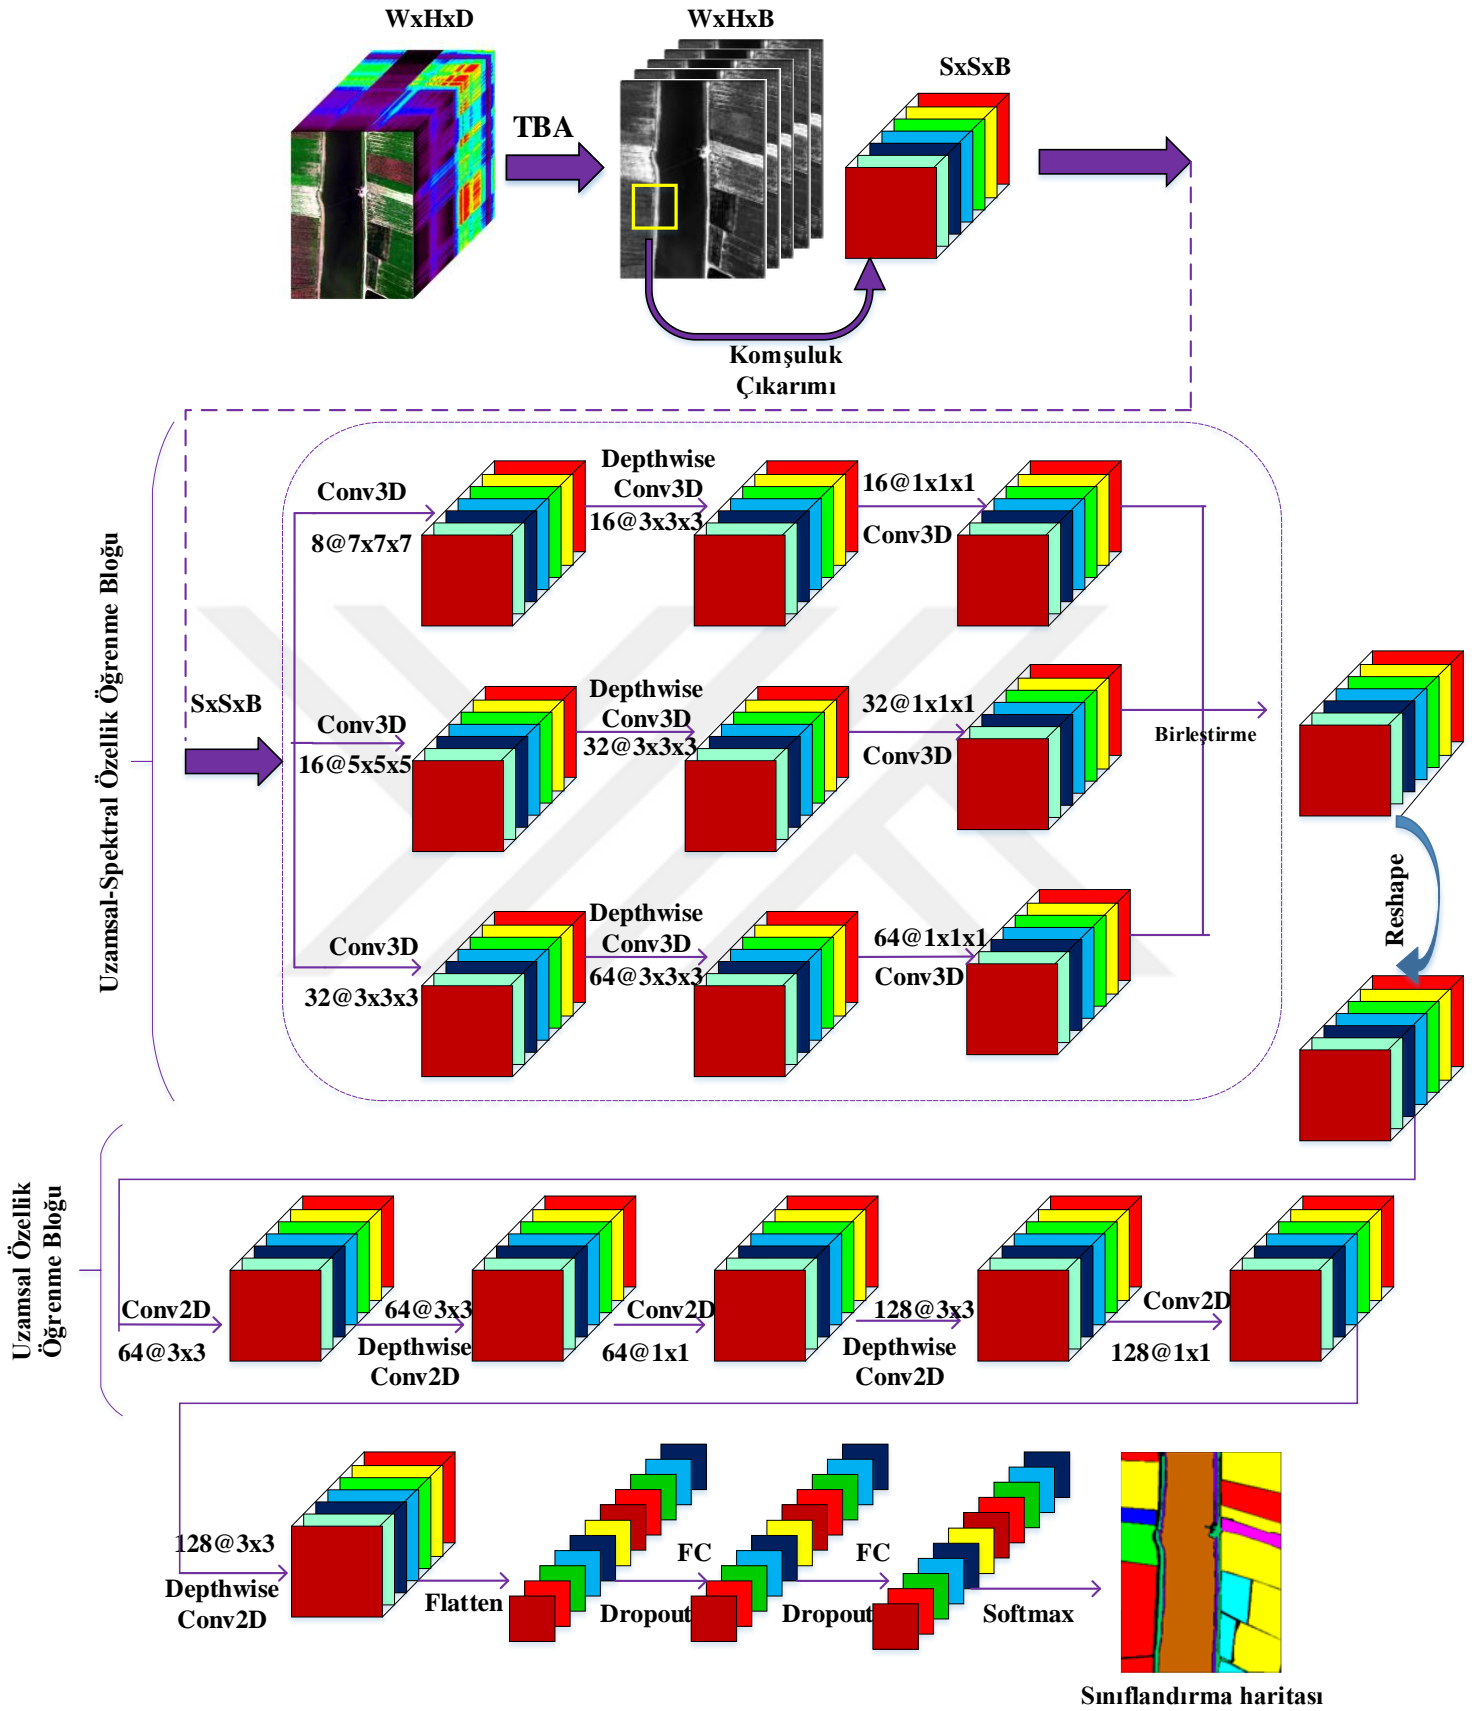
**Şekil 4. 30:** SA veriseti için sınıflandırma haritaları. (a) LeNet5, (b) AlexNet, (c) VGG16, (d) GoogleNet, (e) ResNet50.

## 4.9. Uygulama 7: Hibrit 3B-2B Derinlemesine Ayrılabilir Evrişim Ağlarına Dayalı Hiperspektral Uzaktan Algılama Görüntü Sınıflandırması için Çok Yollu Özellik Füzyonu

### 4.9.1 Önerilen yöntem

Bu çalışmada, hiperspektral görüntü sınıflandırma için çok yollu öznelik füzyonuna dayalı hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı önerilmektedir. Önerilen yöntemde, farklı çekirdek boyutları ile çıkarılan özellikler bir arada kullanılarak hiperspektral görüntülerden daha zengin özellik bilgileri elde edilmiştir. Literatürde hiperspektral görüntü sınıflandırma için genellikle 2B ESA ve 2B derinlemesine ayrılabilir evrişim (DAE) kullanılmaktadır. Ancak, 2B ESA'da olduğu gibi, 2B DAE'de uzamsal özellikleri çıkarmaktadır. Hiperspektral görüntü verileri 3 boyutludur ve spektral özellik bilgisi çok önemlidir. Spektral-uzamsal özellikleri çıkarmak için 3B ESA ile birlikte 3B DAE kullanılmaktadır. Standart 3B evrişim uygulandığında hesaplama karmaşıklığı artmaktadır. Bununla birlikte, 3B DAE, standart evrişimi iki işleme, derinlemesine (depthwise) ve noktasal (pointwise-1x1x1) evrişime bölmektedir. Bu, eğitilebilir parametre sayısını ve hesaplama maliyetlerini büyük ölçüde azaltmaktadır. Şekil 4.31'de gösterildiği gibi önerilen yöntem 2 bloktan oluşmaktadır. Bu bloklar, uzamsal-spektral özellik öğrenme bloğu ve uzamsal özellik öğrenme bloğudur.  $W \times H \times D$  boyutundaki hiperspektral görüntüye, boyut indirgeme yöntemlerinden olan TBA uygulandıktan sonra girdi görüntüsünün uzamsal boyutları değişmezken, sadece spektral band sayısı değişmekte ve  $D$ 'den  $B$ 'ye düşmektedir. Yeni elde edilen görüntünün boyutları  $W \times H \times B$  olmaktadır. Ardından komşuluk çıkarımı ile 3B görüntü küpleri elde edilmektedir. 3B görüntü küplerinin boyutları ise  $S \times S \times B$ 'dir. Elde edilen bu görüntü küpleri öncelikle uzamsal-spektral özellik öğrenme bloğundan geçirilmektedir. Uzamsal-spektral bloğa gelen  $S \times S \times B$  boyutunda 3B hiper küp 3 yola ayrılmaktadır. Her üç yolda da gelen girdiye öncelikle 3B evrişim uygulanmaktadır. Uygulanan 3B evrişimlerin filtre ve çekirdek boyutları sırasıyla  $7 \times 7 \times 7$  boyutunda 8 filtre,  $5 \times 5 \times 5$  boyutunda 16 filtre,  $3 \times 3 \times 3$  boyutunda 32 filtre şeklindedir. Her üç yolda 3B evrişim işlemleri gerçekleştirildikten sonra elde edilen özellik haritalarına 3B derinlemesine evrişim uygulanmaktadır. Uygulanan 3B derinlemesine evrişimlerin filtre ve çekirdek boyutları sırasıyla  $3 \times 3 \times 3$  boyutunda 16 filtre,  $3 \times 3 \times 3$  boyutunda 32 filtre,  $3 \times 3 \times 3$  boyutunda 64 filtre şeklindedir. 3B derinlemesine evrişimlerden sonra  $1 \times 1 \times 1$  boyutunda sırasıyla 16, 32 ve 64 filtreye sahip noktasal evrişimler uygulanmaktadır. Ardından her üç yolda elde edilen özellik haritaları birleştirilmektedir. Birleştirilmiş özellik haritasına  $1 \times 1 \times 1$  boyutunda ve 64 filtreye

sahip 3B evriřim uygulanmakta ve yeniden boyutlandırma iřlemi gerekleřtirilmektedir. Yeniden boyutlandırma iřleminden sonra uzamsal zellik ğrenme bloğundaki iřlemler gerekleřtirilmektedir. Uzamsal zellik ğrenme bloğunda daha fazla uzamsal zellik ğrenmek iin sırasıyla 64 filtre ve 3x3 ekirdek boyutunda 2B evriřim, 64 filtre ve 3x3 ekirdek boyutunda derinlemesine evriřim, 64 filtre ve 1x1 ekirdek boyutunda noktasal evriřim, 128 filtre ve 3x3 ekirdek boyutunda derinlemesine evriřim, 128 filtre ve 1x1 ekirdek boyutunda noktasal evriřim ve son olarak 128 filtre ve 3x3 ekirdek boyutunda derinlemesine evriřim uygulanmaktadır. Her iki zellik ğrenme bloğundan sonra ıkarılan zellikler dzleřtirilmekte ve hiperspektral grnt sınıflandırılması iin FC katmanlarına girdi olarak verilmektedir. nerilen yntemde, 256 ve 128 nronlu iki FC katmanı kullanılmaktadır. Ařırı ğrenmeyi nlemek iin, her FC katmanından sonra bırakma (dropout) oranı %0.4 olan bırakma katmanı uygulanmaktadır. FC katmanının ıktısı, sınıflandırma sonucunu retmek iin basit softmax sınıflandırıcıya verilmektedir. izelge 4.37’de nerilen yntem ile ilgili detaylı bilgiler yer almaktadır. WHU-LK iin nerilen yntemdeki eđitilebilir parametre sayısı 776.089’dur.



Şekil 4. 31: Önerilen hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı.

**Çizelge 4. 37:** WHU-LK için önerilen yöntemin özeti.

Katman	Katman detayı	Parametre	Çıktı	Bağlı olduğu katman
InputLayer	-	0	7x7x20x1	-
Conv3D_1a	filters=8, kernel_size=7x7x7, padding='same'	2752	7x7x20x8	InputLayer
Conv3D_1b	filters=16, kernel_size=5x5x5, padding='same'	2016	7x7x20x16	InputLayer
Conv3D_1c	filters=32, kernel_size=3x3x3, padding='same'	896	7x7x20x32	InputLayer
Depthwise_conv3D_1a	kernel_size=3x3x3, depth_multiplier=2	448	5x5x18x16	Conv3D_1a
Conv3D_2a	filters=16, kernel_size=1x1x1, padding='same'	272	5x5x18x16	Depthwise_conv3D_1a
Depthwise_conv3D_1b	kernel_size=3x3x3, depth_multiplier=2	896	5x5x18x32	Conv3D_1b
Conv3D_2b	filters=32, kernel_size=1x1x1, padding='same'	1056	5x5x18x32	Depthwise_conv3D_1b
Depthwise_conv3D_1c	kernel_size=3x3x3, depth_multiplier=2	1792	5x5x18x64	Conv3D_1c
Conv3D_2c	filters=64, kernel_size=1x1x1, padding='same'	4160	5x5x18x64	Depthwise_conv3D_1c
Concatenate			5x5x18x112	Conv3D_2a, Conv3D_2b, Conv3D_2c
Conv3D_3a	filters=64, kernel_size=1x1x1, padding='same'	7232	5x5x18x64	Concatenate
Reshape	-	0	5x5x1152	Conv3D_3a
Conv2D_1a	filters=64, kernel_size=3x3	663616	3x3x64	Reshape
Depthwise_conv2D_1a	kernel_size=3x3, depth_multiplier=1	640	3x3x64	Conv2D_1a
Conv2D_1b	filters=64, kernel_size=1x1	4160	3x3x64	Depthwise_conv2D_1a
Depthwise_conv2D_1b	kernel_size=3x3, depth_multiplier=2	1280	1x1x128	Conv2D_1b
Conv2D_1c	filters=128, kernel_size=1x1	16512	1x1x128	Depthwise_conv2D_1b
Depthwise_conv2D_1c	kernel_size=3x3, depth_multiplier=1	1280	1x1x128	Conv2D_1c
Flatten	-	0	128	Depthwise_conv2D_1c
FullyConnected1 (FC)	units=256	33024	256	Flatten
Dropout_1	dropout-ratio 0.4	0	256	FullyConnected1 (FC)
FullyConnected2 (FC)	units=128	32896	128	Dropout_1
Dropout_2	dropout-ratio 0.4	0	128	FullyConnected2 (FC)
output_layer	Output_units=9	1161	9	Dropout_2
Toplam eğitilebilir parametre sayısı		776.089		

#### 4.9.2 Sınıflandırma sonuçları


Çok yollu özellik füzyonuna dayalı hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı tabanlı derin öğrenme yönteminin sınıflandırma performansı test etmek için IP, PU, SA, WHU-LK, WHU-HC ve WHU-HH veri setlerini içeren dört gerçek hiperspektral veri seti kullanılmıştır. IP, PU ve SA veri setleri ile ilgili uygulamalarda, test-eğitim seti %70-30, diğer veri setlerinde test-eğitim oranı %95-5 olacak şekilde bölünmüştür. 0.001 öğrenme oranına sahip kategorik çaprazentropi ve optimizasyon için kullanılan  $1e-06$  bozunma işlevine sahip Adam optimizör kullanılmıştır. Eğitim süreci, 256 batch size ve 100 epochs boyunca tekrar etmektedir. IP, PU ve SA'da, evrişim için  $25 \times 25$ , WHU-LK, WHU-HC ve WHU-HH'da  $7 \times 7$  komşuluk çıkarımı kullanılmaktadır. Bununla birlikte, TBA tekniğinden sonra çıkarılan bantların sayısı IP için 30, PU ve SA için 15, WHU-LK, WHU-HC ve WHU-HH için 20 temel bileşen olarak alınmıştır. Önerilen yöntem, S3EResBoF [8], HybridSN [31], FC3B ESA [32], FuSENet [33] gibi literatürden derin öğrenmeye dayalı hiperspektral görüntü sınıflandırma yöntemleriyle karşılaştırılmıştır.

İlk uygulamada IP veri seti kullanılmıştır. Gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçları Çizelge 4.38'de verilmiştir. Önerilen yöntem (ÖY) ile %99.86 OA, %99.84 K ve %99.88 AA değerleri elde edilmiştir. Önerilen yönteme en yakın sonuçlar %99.75 OA, %99.71 K ve %99.63 AA ile HybridSN yöntemi ile elde edilmiştir. Diğer yöntemlerde elde edilen OA, K ve AA sonuçları sırasıyla, S3EResBoF için %99.48, %99.41, %98.94, FuSENet için %99.01, %98.60, %98.64, FC3B ESA için %92.93, %91.94, %90.61 olarak bulunmuştur. Tüm yöntemler göz önüne alındığında, önerilen yöntemin başarılı sonuçlar ürettiği görülmektedir. Sınıfla bazlı değerlendirme sonuçları incelendiğinde, ÖY 1, 4, 6, 7, 8, 9, 11, 13, 14, 15 ve 16 nolu sınıflarda %100 ile en iyi sınıflandırma sonucunu verdiği görülmektedir. 2 ve 3 nolu sınıflar için sırasıyla %99.70 ve %99.83 ile ÖY, 5 ve 10 nolu sınıflar için %100 ile S3EResBoF, 12 nolu sınıf için %99.52 ile HybridSN yöntemlerinde en iyi sınıflandırma doğrulukları elde edilmiştir. Tüm yöntemlerin sınıflandırma haritaları Şekil 4.32'de görülmektedir. Şekil 4.32 incelendiğinde, temel gerçek haritasına en yakın sonucun önerilen yöntem ile elde edilen sınıflandırma haritası olduğu görülmektedir.



**Çizelge 4. 38:** IP'nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).

No	Eğitim/Test	FC3BESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	14/32	97.83	99.38	93.55	100	100
2	428/1000	94.05	99.58	99.28	98.47	99.70
3	249/581	90.72	99.66	98.78	98.53	99.83
4	71/166	81.43	99.88	99.31	98.56	100
5	145/338	98.34	99.53	100	99.95	99.70
6	219/511	99.86	99.96	100	99.60	100
7	8/20	78.57	99.00	100	98.75	100
8	143/335	100	100	100	99.40	100
9	6/14	85.00	100	100	100	100
10	292/680	96.81	99.56	100	98.54	99.85
11	736/1719	94.75	99.84	99.46	98.42	100
12	178/415	86.34	99.52	98.61	98.94	99.04
13	62/143	99.51	99.86	100	98.66	100
14	379/886	98.97	100	99.87	98.98	100
15	116/270	91.71	99.85	100	100	100
16	28/65	100	98.46	94.23	98.36	100
OA	3074/7175	92.93 ± 0.2	99.75 ± 0.1	99.48 ± 0.1	99.01 ± 0.2	99.86 ± 0.0
K		91.94 ± 0.5	99.71 ± 0.1	99.41 ± 0.0	98.60 ± 0.1	99.84 ± 0.0
AA		90.61 ± 0.8	99.63 ± 0.2	98.94 ± 0.0	98.64 ± 0.1	99.88 ± 0.0



**Şekil 4. 32:** IP kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3BESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.


İkinci uygulama için PU veri seti kullanılmıştır. Gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma sonuçları Çizelge 4.39'de verilmiştir. PU veri seti ile gerçekleştirilen uygulamalar sonucunda ÖY ile tüm sınıflarda %100 ve OA, K, AA değerlendirme ölçütlerinde de %100 sınıflandırma doğruluğunun elde edildiği

görülmektedir. ÖY'ye en yakın sonuçlar %99.98 OA ve K, %99.97 AA değeri ile HybridSN yönteminde elde edilmiştir. Diğer yöntemlerden OA, K ve AA değerleri sırasıyla FC3B ESA ile %99.70, %99.60, %99.37, FuSENet ile %99.42, %99.21, %99.33, S3EResBoF ile %99.44, %99.26 ve %99.00 sınıflandırma sonuçları elde edilmiştir. Tüm yöntemler için elde edilen sınıflandırma haritaları Şekil 4.33'te verilmiştir. Şekil 4.33'e göre, ÖY ile elde edilen sınıflandırma haritası temel gerçek haritası ile bire bir aynıdır.

**Çizelge 4.39:** PU'nun test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).

No	Eğitim/Test	FC3B ESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	1989/4642	99.98	100	98.41	99.89	100
2	5594/13055	99.98	100	99.94	99.93	100
3	630/1469	98.95	100	99.80	98.75	100
4	919/2145	99.90	99.84	98.79	98.71	100
5	403/942	100	100	99.26	98.69	100
6	1509/3520	99.96	100	100	99.76	100
7	399/931	98.42	100	99.15	99.94	100
8	1105/2577	98.83	99.98	99.30	98.31	100
9	284/663	99.79	99.90	96.39	100	100
OA	12832/29944	99.70 ± 0.2	99.98 ± 0.0	99.44 ± 0.0	99.42 ± 0.2	100 ± 0.0
K		99.60 ± 0.5	99.98 ± 0.0	99.26 ± 0.0	99.21 ± 0.3	100 ± 0.0
AA		99.37 ± 0.0	99.97 ± 0.0	99.00 ± 0.0	99.33 ± 0.2	100 ± 0.0


Üçüncü uygulama SA veri seti ile gerçekleştirilmiştir. Uygulamalar sonucunda elde edilen sınıflandırma sonuçları Çizelge 4.40'da gösterilmektedir. Çizelge 4.40 incelendiğinde, ÖY ve HybridSN yöntemleri ile tüm sınıflarda ve tüm değerlendirme ölçütlerinde %100 sınıflandırma sonucunun elde edildiği görülmektedir. Diğer yöntemlerden ÖY'ye en yakın sınıflandırma sonuçları, %99.91 OA, %99.90 K ve AA ile S3EResBoF, %99.85 OA, %99.84 K ve %99.90 ile FC3B ESA, %99.68 OA, %99.74 K ve %99.69 ile FuSENet yöntemlerinde elde edilmiştir. Tüm yöntemler ile elde edilen sınıflandırma haritaları Şekil 4.34'te verilmiştir. Şekil 4.34 incelendiğinde, ÖY ve HybridSN yöntemleri ile elde edilen sınıflandırma haritası temel gerçek haritası ile aynı olduğu görülmektedir. Diğer yöntemlerden S3EResBoF ve FC3B ESA yöntemlerinin sınıflandırma haritası temel gerçeğe oldukça yakındır.



**Şekil 4. 33:** PU kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.

**Çizelge 4. 40:** SA'nın test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).

No	Eğitim/Test	FC3B ESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	603/1406	100	100	100	100	100
2	1118/2608	100	100	100	100	100
3	593/1383	100	100	100	99.63	100
4	418/976	100	100	99.90	99.21	100
5	803/1875	99.5	100	99.95	100	100
6	1188/2771	100	100	99.60	100	100
7	1074/2505	100	100	100	99.61	100
8	3381/7890	99.8	100	99.99	99.97	100
9	1861/4342	99.8	100	100	99.97	100
10	983/2295	100	100	100	99.95	100
11	320/748	100	100	99.87	100	100
12	578/1349	99.8	100	99.78	99.84	100
13	275/641	100	100	99.53	98.88	100
14	321/749	100	100	100	99.96	100
15	2180/5088	99.5	100	99.75	99.59	100
16	542/1265	99.9	100	100	98.59	100
OA	16238/37891	99.85 ± 0.0	100 ± 0.0	99.91 ± 0.0	99.68 ± 0.2	100 ± 0.0
K		99.84 ± 0.1	100 ± 0.0	99.90 ± 0.0	99.74 ± 0.1	100 ± 0.0
AA		99.90 ± 0.1	100 ± 0.0	99.90 ± 0.0	99.69 ± 0.1	100 ± 0.0



**Şekil 4. 34:** SA kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.

IP, PU ve SA veri setleri ile tüm yöntemlerde %30 eğitim örneği ile birlikte %10 ve %20 eğitim örnekleri alınarak uygulamalar yapılmış ve sınıflandırma sonuçları Çizelge 4.41’de verilmiştir. ÖY'nin her üç veri setinde en iyi sınıflandırma sonuçlarını elde ettiği açıkça görülmektedir. ÖY'ye en yakın sınıflandırma sonuçları hem %10 hem de %20 eğitim örneklerinde HybridSN yöntemi ile elde edilmiştir.

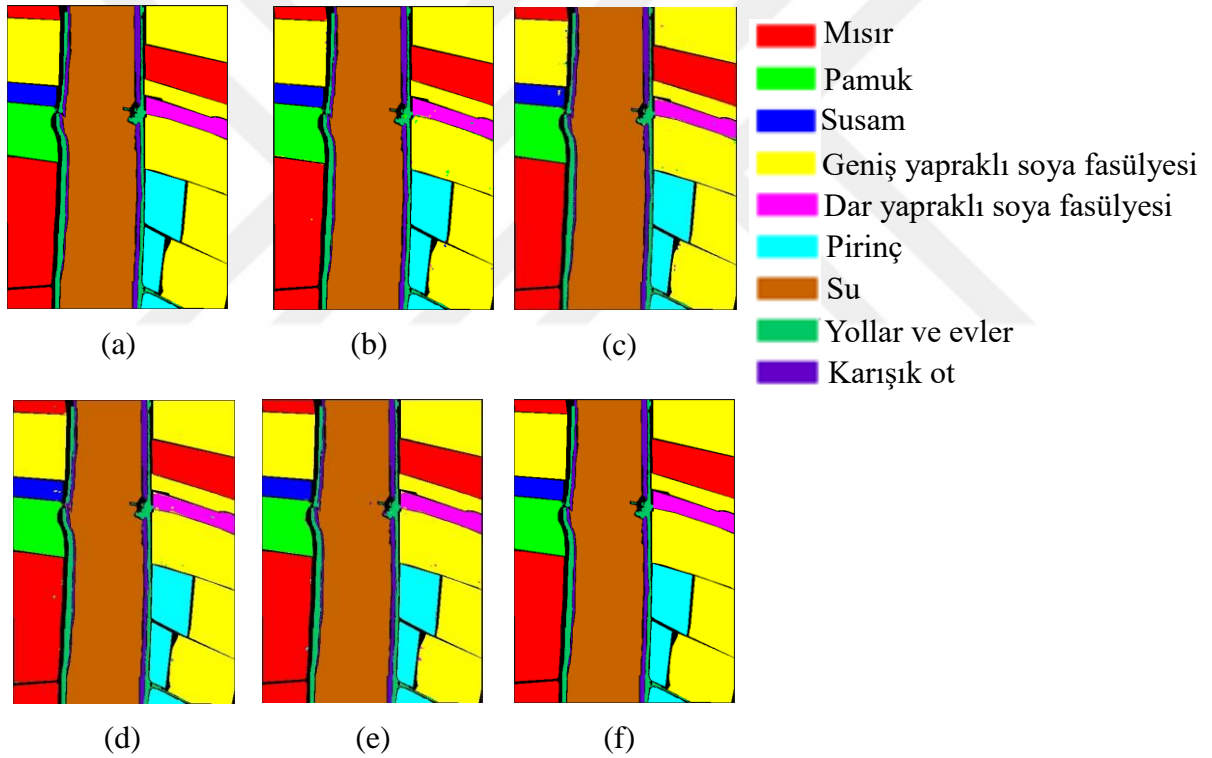
Dördüncü uygulamada, WHU-LK veri seti kullanılmıştır. Gerçekleştirilen uygulamalar sonucunda sınıf bazlı ve OA, K ve AA değerlendirme ölçütlerine göre sonuçlar Çizelge 4.42’de verilmiştir. ÖY, %99.78 OA, %99.72 K ve %99.36 AA değeri ile en başarılı sınıflandırma performansına sahiptir. Tüm yöntemlerin sınıflandırma haritaları Şekil 4.35’te verilmiştir. Tüm yöntemlerin AA değerleri sırasıyla şu şekildedir: ÖY için %99.36, FuSENet için %99.18, HybridSN için %99.11, FC3B ESA için %99.07 ve S3EResBoF için %98.96’dır. Tüm yöntemler ile elde edilen AA değerleri göz önüne alındığında, ÖY ile elde edilen sınıflandırma haritasının temel gerçek haritasına benzer olduğu görülmektedir. Sınıf bazlı sınıflandırma doğrulukları incelendiğinde, 3, 4, 6 ve 8. sınıflarda %100, %99.91, %100 ve %98.76 ile ÖY, 1 ve 2 nolu sınıflarda %99.99 ve %99.87 ile HybridSN, 5 ve 7 nolu sınıflarda %99.54 ve %99.99 ile FuSENet, 9 nolu sınıf için %99.55 ile S3EResBoF yönteminde en iyi sınıflandırma doğrulukları elde edilmiştir.

**Çizelge 4. 41:** IP, PU ve SA kullanan sınırlı eğitim örnekleri için sınıflandırma doğrulukları (%).

Test - Eğitim (%)	Method	IP			PU			SA		
		OA	K	AA	OA	K	AA	OA	K	AA
70-30	FC3B ESA	92.93 ± 0.2	91.94 ± 0.5	90.61 ± 0.8	99.70 ± 0.2	99.60 ± 0.5	99.37 ± 0.0	99.85 ± 0.0	99.84 ± 0.1	99.90 ± 0.1
	HybridSN	99.75 ± 0.1	99.71 ± 0.1	99.63 ± 0.2	99.98 ± 0.0	99.98 ± 0.0	99.97 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0
	S3EResBoF	99.48 ± 0.1	99.41 ± 0.0	98.94 ± 0.0	99.44 ± 0.0	99.26 ± 0.0	99.00 ± 0.0	99.91 ± 0.0	99.90 ± 0.0	99.90 ± 0.0
	FuSENet	99.01 ± 0.2	98.60 ± 0.1	98.64 ± 0.1	99.42 ± 0.2	99.21 ± 0.3	99.33 ± 0.2	99.68 ± 0.2	99.74 ± 0.1	99.69 ± 0.1
	ÖY	99.86 ± 0.0	99.84 ± 0.0	99.88 ± 0.0	100.0 ± 0.0	100.0 ± 0.0	100.0 ± 0.0	100.00 ± 0.0	100.00 ± 0.0	100.00 ± 0.0
80-20	FC3B ESA	87.37 ± 0.2	85.56 ± 0.1	81.24 ± 0.3	99.66 ± 0.1	99.54 ± 0.1	98.32 ± 0.0	99.64 ± 0.0	99.62 ± 0.1	99.82 ± 0.0
	HybridSN	98.88 ± 0.1	98.72 ± 0.1	98.15 ± 0.2	99.96 ± 0.0	99.94 ± 0.0	99.94 ± 0.0	99.98 ± 0.0	99.98 ± 0.0	99.98 ± 0.0
	S3EResBoF	98.89 ± 0.2	98.60 ± 0.2	98.51 ± 0.3	99.36 ± 0.2	99.32 ± 0.1	98.90 ± 0.2	99.89 ± 0.0	99.88 ± 0.0	99.89 ± 0.0
	FuSENet	98.12 ± 0.3	97.93 ± 0.2	98.85 ± 0.2	98.67 ± 0.3	98.35 ± 0.2	98.57 ± 0.4	99.45 ± 0.1	99.83 ± 0.0	99.32 ± 0.2
	ÖY	99.39 ± 0.0	99.30 ± 0.0	99.46 ± 0.0	99.99 ± 0.0	99.99 ± 0.0	99.98 ± 0.0	100.0 ± 0.0	100.0 ± 0.0	100.0 ± 0.0
90-10	FC3B ESA	75.13 ± 0.0	71.24 ± 0.0	50.14 ± 0.0	99.28 ± 0.0	99.05 ± 0.0	98.84 ± 0.0	99.50 ± 0.0	99.44 ± 0.0	99.75 ± 0.0
	HybridSN	98.39 ± 0.1	98.16 ± 0.1	98.01 ± 0.2	99.72 ± 0.1	99.64 ± 0.1	99.20 ± 0.1	99.98 ± 0.0	99.98 ± 0.0	99.98 ± 0.0
	S3EResBoF	97.63 ± 0.2	97.30 ± 0.2	95.86 ± 0.1	99.37 ± 0.1	99.39 ± 0.1	99.20 ± 0.1	99.86 ± 0.0	99.85 ± 0.0	99.70 ± 0.0
	FuSENet	97.11 ± 0.2	97.25 ± 0.2	97.32 ± 0.2	97.65 ± 0.3	97.69 ± 0.3	97.68 ± 0.4	99.23 ± 0.1	99.97 ± 0.0	99.16 ± 0.1
	ÖY	98.49 ± 0.0	98.28 ± 0.0	98.42 ± 0.0	99.89 ± 0.0	99.85 ± 0.0	99.79 ± 0.1	99.99 ± 0.0	99.99 ± 0.0	99.99 ± 0.0

**Çizelge 4. 42:** WHU-LK'nın test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%)

No	Eğitim/Test	FC3B ESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	1725/32786	99.90	99.99	99.97	99.83	99.90
2	419/7955	99.26	99.87	99.01	99.42	99.68
3	152/2879	99.76	98.98	100	99.82	100
4	3161/60051	99.62	99.46	99.88	99.31	99.91
5	207/3944	97.76	97.59	99.46	99.54	98.73
6	593/11261	99.92	99.88	99.99	99.97	100
7	3353/63703	99.98	99.96	99.88	99.99	99.93
8	356/6768	98.41	98.16	92.85	95.79	98.76
9	261/4968	97.06	98.13	99.55	98.91	97.40
OA	10227	99.64	99.63	99.59	99.54	99.78
K	/	99.64	99.52	99.46	99.40	99.72
AA	194315	99.07	99.11	98.96	99.18	99.36



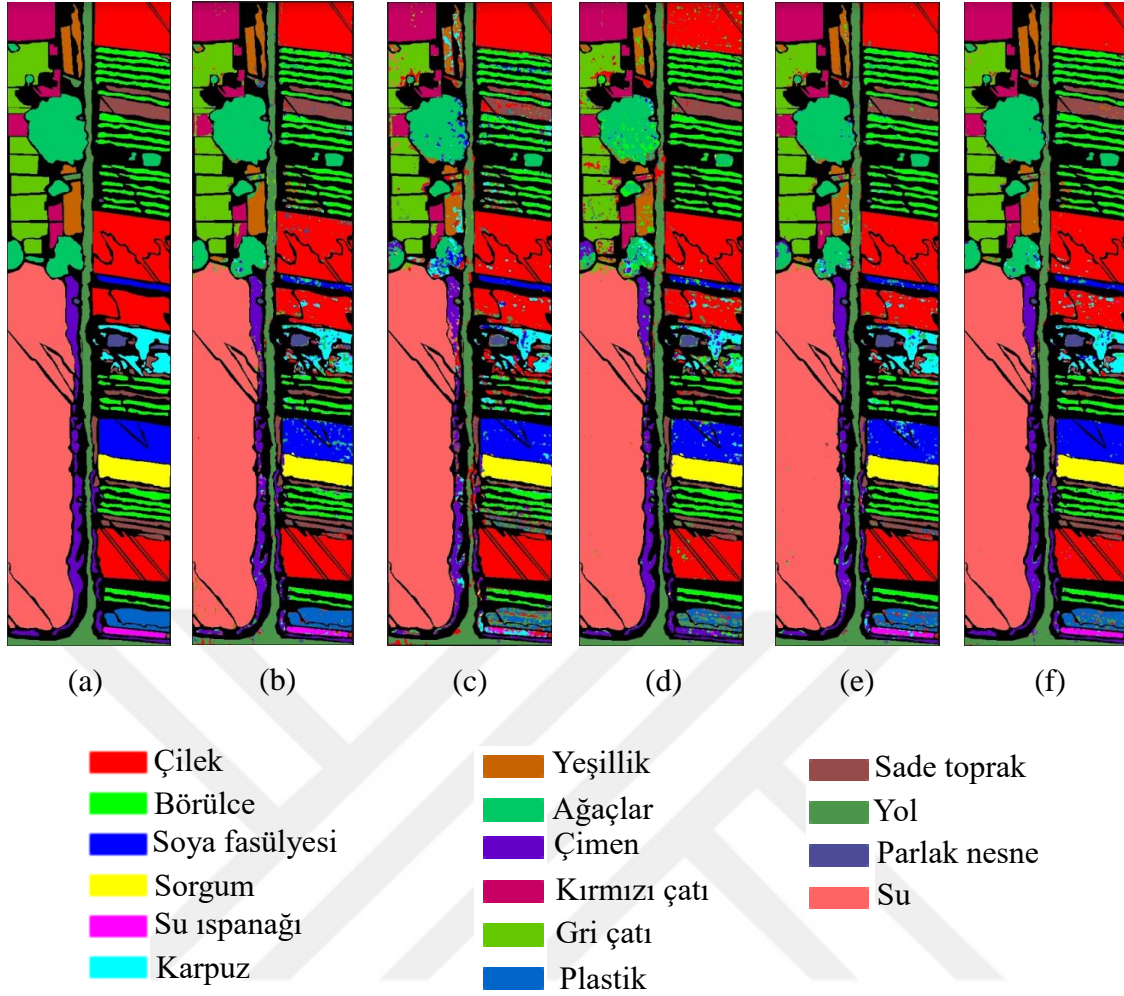
**Şekil 4. 35:** WHU-LK kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.

Beşinci uygulamada WHU-HC veri seti kullanılmıştır. Bu veri seti kullanılarak gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.43'te verilmiştir. Çizelge 4.43'e göre, ÖY ile %97.06 OA, %96.56 K ve %93.30 AA değeri elde edilmiştir. Tüm yöntemlerin sınıflandırma doğrulukları incelendiğinde en başarılı performans ÖY ile elde edildiği görülmektedir. ÖY'ye en yakın sonuçlar, %95.09 OA ve

%94.25 K ile FC3B ESA, %92.06 AA ile S3EResBoF yöntemi ile elde edilmiştir. Sınıf bazlı doğruluklar incelendiğinde, 1 ve 11 nolu sınıflarda %98.46 ve %98.85 ile FC3B ESA, 2, 3, 4, 14 ve 15 nolu sınıflarda %97.16, %99.09, %99.61, %98.74 ve %97.43 ile FuSENet, 5 ve 16 nolu sınıflarda %96.94 ve %99.95 ile S3EResBoF, 6, 7, 8, 9, 10, 12 ve 13 nolu sınıflarda %82.05, %94.65, %96.58, %94.72, %99.01, %87.87 ve %86.81 ile ÖY’de en başarılı sınıflandırma doğrulukları elde edilmiştir. Tüm yöntemler için elde edilen sınıflandırma haritaları Şekil 4.36’da gösterilmektedir. Tüm yöntemler içerisinde AA değeri en yüksek olan %93.30 ile ÖY’dir. Şekil 4.36’a göre, temel gerçek haritasına en çok benzeyen yöntem ÖY’dir.

**Çizelge 4. 43:** WHU-HC’nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).

No	Eğitim/Test	FC3B ESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	2237/42498	98.46	97.19	91.61	97.49	98.24
2	1137/21616	95.73	94.38	95.07	97.16	96.44
3	514/9773	89.49	89.96	92.12	99.09	95.74
4	268/5085	98.46	98.28	98.14	99.61	98.74
5	60/1140	74.74	61.43	96.94	87.30	87.46
6	227/4306	69.82	70.00	79.46	57.36	82.05
7	295/5608	87.53	87.63	93.61	93.58	94.65
8	899/17079	94.72	91.68	94.11	92.87	96.58
9	473/8996	90.58	92.75	92.31	91.03	94.72
10	526/9990	98.13	98.99	98.33	96.78	99.01
11	845/16066	98.85	98.25	92.37	94.90	98.70
12	184/3495	80.44	69.36	84.98	57.56	87.87
13	456/8660	81.08	75.67	76.54	67.25	86.81
14	928/17632	87.45	91.65	91.31	98.74	96.25
15	57/1079	84.94	72.41	96.10	97.43	79.70
16	3770/71631	99.71	99.38	99.95	99.65	99.76
OA	12876	95.09	94.41	94.27	94.05	97.06
K	/	94.25	93.45	93.28	93.05	96.56
AA	244654	89.38	86.94	92.06	89.24	93.30



**Şekil 4. 36:** WHU-HC kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.


Altıncı uygulamada WHU-HH veri seti kullanılmıştır. Bu veri setinde 22 sınıf ve 386693 örnek bulunmaktadır. Bu veri seti kullanılarak gerçekleştirilen uygulamalar sonucunda elde edilen sınıflandırma doğrulukları Çizelge 4.44'te gösterilmiştir. Çizelge 4.44 incelendiğinde, ÖY ile %97.27 OA, %96.54 K ve %93.82 AA değeri elde edilmiştir. ÖY ile karşılaştırılan diğer yöntemlerde elde edilen sınıflandırma doğrulukları şu şekildedir: FC3B ESA ile %95.38 OA ve K, %88.08 AA, HybridSN ile %92.15 OA, %90.05 K, %82.46 AA, S3EResBoF ile %93.54 OA, %91.90 K, %85.76 AA, FuSENet ile %95.51 OA, %94.31 K, %90.79 AA değeri elde edilmiştir. Tüm yöntemler incelendiğinde ÖY'nin diğer yöntemlerden daha başarılı sonuçlar verdiği görülmektedir. Sınıf bazlı sonuçlar incelendiğinde, özellikle 21 nolu sınıfta ÖY'nin %91.52 ile diğer yöntemlerden oldukça iyi sonuç verdiği görülmektedir. Diğer sınıflarda 1, 10, 15, 16, 17, 19 ve 20 nolu sınıflarda sırasıyla %99.34, %94.63, %99.71, %99.13, %92.86, %98.53, %98.01 ile FuSENet, 2, 6, 7, 8, 9 ve 14 nolu sınıflarda %95.38, %98.52, %98.24, %86.02, %100, %99.20 ile S3EResBoF,



3 ve 18 nolu sınıflarda %97.77 ve %97.66 ile FC3B ESA, 4, 5, 11, 12, 13 ve 22 nolu sınıflarda %99.70, %90.89, %91.98, %88.67, %94.31 ve %97.24 ile ÖY’de en başarılı sınıflandırma sonuçları elde edilmiştir. Tüm yöntemler ile ilgili sınıflandırma haritaları Şekil 4.37 verilmiştir. Tüm yöntemlerin AA değerleri incelendiğinde en yüksek AA değeri %93.82 ile ÖY’ye aittir. Şekil 4.37 incelendiğinde temel gerçek haritasına en yakın sonuçların ÖY ile elde edildiği görülmektedir.

**Çizelge 4. 44:** WHU-HH’nin test ve eğitim örneklerinin sayısı ve sınıflandırma doğruluklarının (%).


No	Eğitim/Test	FC3B ESA	HybridSN	S3EResBoF	FuSENet	ÖY
1	702/13339	98.05	97.60	93.77	99.34	98.78
2	176/3336	70.32	86.32	95.38	84.14	94.84
3	1091/20730	97.77	95.38	95.17	96.03	97.76
4	8164/155121	99.12	99.34	99.59	98.15	99.70
5	311/5907	81.22	57.72	52.48	88.43	90.89
6	2228/42329	97.89	96.98	98.52	97.77	98.22
7	1205/22898	95.65	88.30	98.24	94.47	95.80
8	203/3851	76.19	47.30	86.02	83.29	81.04
9	541/10278	99.32	98.11	100	99.38	98.42
10	620/11774	88.96	71.34	90.06	94.63	92.93
11	551/10464	85.93	75.27	82.45	89.65	91.98
12	448/8506	81.22	77.96	73.33	74.18	88.67
13	1125/21382	88.58	78.65	82.91	90.46	94.31
14	368/6988	95.35	90.22	99.20	99.05	95.92
15	50/952	85.18	91.36	50.10	99.71	82.67
16	363/6899	97.61	93.03	98.73	99.13	97.82
17	150/2860	77.12	87.16	76.87	92.86	89.47
18	161/3056	97.66	89.14	91.77	83.03	96.24
19	435/8277	93.35	88.26	89.79	98.53	95.52
20	174/3312	91.36	75.24	91.32	98.01	94.38
21	66/1262	44.72	43.71	50.26	55.78	91.52
22	202/3838	95.25	85.68	90.81	81.42	97.24
OA	19334	95.38	92.15	93.54	95.51	97.27
K	/	95.38	90.05	91.90	94.31	96.54
AA	367359	88.08	82.46	85.76	90.79	93.82



(a)

(b)

(c)



(d)



(e)



(f)

<span style="color: red;">■</span> Kırmızı çatı	<span style="color: purple;">■</span> Lahana	<span style="color: lightcoral;">■</span> Film kaplı marul
<span style="color: green;">■</span> Yol	<span style="color: magenta;">■</span> Hardal	<span style="color: lightgreen;">■</span> Roman marulu
<span style="color: blue;">■</span> Sade toprak	<span style="color: limegreen;">■</span> Brassica parachinensis	<span style="color: blueviolet;">■</span> Havuç
<span style="color: yellow;">■</span> Pamuk	<span style="color: cyan;">■</span> Brassica chinensis	<span style="color: orange;">■</span> Beyaz turp
<span style="color: magenta;">■</span> Pamuk yakacak odun	<span style="color: brown;">■</span> Small Brassica chinensis	<span style="color: lightgreen;">■</span> Sarımsak filizi
<span style="color: cyan;">■</span> Rape	<span style="color: olivegreen;">■</span> Marul	<span style="color: purple;">■</span> Bakla
<span style="color: brown;">■</span> Çin lahanası	<span style="color: darkblue;">■</span> Kuşkonmaz marulu	<span style="color: black;">■</span> Ağaç
<span style="color: green;">■</span> Pakchoi		

Şekil 4. 37: WHU-HH kullanılarak elde edilen sınıflandırma haritaları. (a) Temel gerçek, (b) FC3B ESA, (c) HybridSN, (d) S3EResBoF, (e) FuSENet, (f) ÖY.

## 5. SONUÇLAR

Hiperspektral görüntüleme, uzaktan algılama ve arazi örtüsü sınıflandırması için en güçlü araçlardan biridir. Elektromanyetik dalganın bir dizi dar sürekli bandında yer nesnelere ait ayrıntılı spektral tepkilerini elde etme yeteneğine sahiptir. Toplanan hiperspektral görüntüler, sınıflandırma ve analiz için bol miktarda spektral ve uzamsal bilgi içermektedir. Karmaşıklığı ve yüksek boyutluluğu nedeniyle, hiperspektral görüntü sınıflandırması, RGB veya multispektral görüntülerden daha fazla zorluk içermektedir. Araştırmacılar tarafından hiperspektral görüntü sınıflandırması için hem geleneksel hem de derin öğrenme tabanlı birçok özellik çıkarma ve sınıflandırma yöntemi önerilmiştir. Ama hala sınıflandırma performansının artırılması için çalışmalar yapılmaktadır.

Bu tez çalışması kapsamında, hiperspektral uydu görüntülerinin sınıflandırılması için derin öğrenme tabanlı yöntemler geliştirilmiştir. Geliştirilen yöntemler ile sınıflandırma performanslarının artırılması amaçlanmaktadır. Bu doğrultuda 7 farklı derin öğrenme tabanlı yöntem önerilmiştir. Bu yöntemlerle 7 farklı çalışma yapılmıştır.

Yapılan ilk çalışmada, hiperspektral görüntü sınıflandırma için hibrit derinlemesine ayrılabilir bir ESA yöntemi önerilmiştir. Yöntem, 3B/2B ESA ve uzamsal olarak derinlemesine ayrılabilir evrişim katmanlarını birleştirmektedir. 3B ESA ile uzamsal-spektral özellikler çıkarılırken, uzamsal özellikler 2B ESA kullanılarak sürekli olarak çıkarılmaktadır. Derinlemesine ayrılabilir evrişim ile eğitilebilir parametre sayısı ve hesaplama süresi azaltılmakta ve daha fazla uzamsal özellik çıkarılmaktadır. Ayrıca spektral band fazlalığını gidermek için TBA boyut indirgeme yöntemi kullanılmaktadır. IP, PU ve SA benchmark veri setleri ile gerçekleştirilen uygulamalar dikkate alındığında önerilen yöntemle IP veri setinde %99.32 OA, %99.46 AA, %99.22 K, PU'da %99.83 OA, %99.70 AA, %99.78 K, SA'da %99.90 OA, %99.93 AA, %99.89 K değerleri elde edilmiştir. Tüm bu değerler doğrultusunda önerilen yöntem SVM-RBF, 2B ESA, 3B ESA, SSRN, HybridSN yöntemleri ile karşılaştırılmıştır. Çizelge 4.2-4.3-4.4 incelendiğinde önerilen yöntemle tüm veri setlerinde daha iyi sınıflandırma performansı elde edildiği görülmektedir. Elde edilen sınıflandırma sonuçları göz önüne alındığında, önerilen yöntemin gerçek Dünya uygulamalarında kullanılabilir bir yöntem olduğu sonucuna varılmıştır.

Yapılan ikinci çalışmada, hiperspektral görüntü sınıflandırmasında sınıflandırma sonuçlarını arttırabilmek için hem uzamsal hem de spektral özellik bilgilerinden eş zamanlı

özellik çıkarmak ve bu bilgilerden faydalanmak için yeni bir 3B ESA tabanlı yöntem geliştirilmiştir. Geliştirilen yöntem, arka arkaya 4 tane 3B evrişim katmanından oluşmaktadır. Orijinal hiperspektral görüntüye ön işleme adımı olarak TBA uygulanmakta ve en kullanışlı temel bileşenler çıkarılmaktadır. Önerilen 3B ESA tabanlı yöntem sıklıkla kullanılan IP, PU, KUM ve SA veri setleri ile test edilmiştir. Çizelge 4.6-4.7-4.8-4.9 incelendiğinde, IP veri seti için OA, AA ve K sırasıyla, %99.93, %99.72 ve %99.92 olarak elde edilmiştir. PU için %99.99, %99.96 ve %99.99, SA için tüm değerlendirme ölçütlerinde %100 ve son olarak KUM veri seti için ise %99.81, %99.68 ve %99.78 sınıflandırma sonuçları elde edilmiştir. Yapılan uygulamalar, önerilen 3B ESA tabanlı hiperspektral görüntü sınıflandırma yönteminin dört veri setinin tümünde en iyi OA, AA ve K değerlerini elde ettiğini göstermektedir. Ayrıca, önerilen yöntem, literatürden DVM, 3B ESA, ResNet, SSRN, DFFN, MPRN, MSSN gibi son teknoloji yöntemler ile karşılaştırılmıştır. Tüm yöntemler arasında da önerilen yöntemin oldukça başarılı sınıflandırma sonucu ürettiği gözlemlenmiştir. Elde edilen sınıflandırma sonuçlarına göre, önerilen yöntemin gerçek Dünya uygulamalarında kullanılabilir bir yöntem olduğu sonucuna varılmıştır.

Yapılan üçüncü çalışmada, hiperspektral görüntülerden daha fazla öznetelik çıkarmak ve daha iyi sınıflandırma sonuçları elde etmek için yeni bir 3BLeNet derin öğrenme ağı yöntemi önerilmiştir. Önerilen yöntem LeNet-5 mimarisi ve 3B ESA'dan oluşmaktadır. LeNet-5 mimarisi kullanılarak basit bir model elde edilmiştir. Bu mimarinin kullanılması ile önerilen yöntemdeki eğitilebilir parametre sayısı önemli ölçüde azaltılmıştır. Eğitilebilir parametre sayısının az olması eğitim sürecinin hızlı olmasını sağlayacaktır. Eğitim sürecinin hızlı olması eğitim süresini önemli ölçüde azaltacaktır. Daha sonra, adam optimizyer kullanılarak 3BLeNet ağının daha iyi optimizasyonu sağlanmaktadır. Önerilen yöntemi diğer ESA tabanlı çalışmalardan ayıran en önemli özelliği budur. Hiperspektral görüntü sınıflandırmasında en önemli sorunlardan biri, doğru sonuçlar elde etmek için hem uzamsal hem de spektral özelliklerin dikkate alınması gerektiğidir. Bu sorunu çözmek için 3B ESA kullanılmaktadır. Yani, 3B ESA ile hem spektral hem de uzamsal özellikler hiperspektral görüntülerde aynı anda çıkarılmaktadır. Bu, hem spektral hem de uzamsal bilgiden tam olarak yararlanmayı sağlamaktadır. Ayrıca geliştirilen hiperspektral sınıflandırma yönteminin daha iyi OA ve AA sonuçlarını üretmesine yardımcı olmaktadır. Önerilen 3BLeNet yönteminde spektral boyut fazlalığını azaltmak için kullanılan boyut indirgeme yöntemi TBA'dır. Spektral fazlalığı ortadan kaldırmak için, geleneksel TBA önce orijinal hiperspektral görüntüye spektral bantlar boyunca uygulanmaktadır. TBA ile,

herhangi bir nesneyi tanımak için çok önemli olan uzamsal bilgi korunarak yalnızca spektral bandlar azaltılmaktadır. Böylece istenilen bant sayısına indirgenmiş olunmaktadır. Önerilen 3BLeNet yöntemi, yaygın olarak kullanılan IP, PU ve SA veri setlerinde çeşitli son teknoloji derin öğrenme tabanlı yöntemlerle karşılaştırılmıştır. Önerilen 3BLeNet yönteminin tüm veri setlerinde en iyi sınıflandırma sonuçlarını elde ettiği gözlemlenmiştir. Aynı zamanda eğitim ve test süreleri açısından karşılaştırıldığında önerilen yöntemin diğer tüm yöntemlere göre daha hızlı çalıştığı görülmektedir. Ayrıca sınırlı eğitim örnekleri ile yapılan çalışmalar incelendiğinde önerilen 3BLeNet yönteminin diğer tüm yöntemlere göre daha iyi bir performans gösterdiği görülmektedir.

Yapılan dördüncü çalışmada, hiperspektral görüntülerden daha fazla öznetelik çıkarmak ve daha iyi sınıflandırma sonuçları elde etmek için yeni bir 3B ESA tabanlı ResNet18 derin öğrenme yöntemi önerilmiştir. Hiperspektral görüntü sınıflandırmasında en önemli sorunlardan biri, doğru sonuçlar elde etmek için hem uzamsal hem de spektral özelliklerin dikkate alınması gerektiğidir. Bu sorunu çözmek için 3B ESA kullanılmaktadır. 3B ESA ile spektral-uzamsal bilgiden tam olarak yararlanılmaktadır. Hiperspektral görüntü sınıflandırmasındaki diğer bir problem, derin ESA yapıları inşa edilirken evrişimli katmanların sayısının artmasıyla karşılaşılan bozulma ve gradyanların yok olması problemleridir. ResNet mimarisi, çok derin ESA'lar tarafından ortaya çıkan kaybolan gradyan, bozulma ve özellik yayılımı sorunlarını önlemek için önceki ve sonraki katmanlar arasında daha kısa yollar oluşturan atlamalı bağlantı katmanı sunmaktadır. ResNet mimarisi sayesinde daha derin ESA modelleri eğitilmekte ve daha derin uzamsal spektral özellikler çıkarılmaktadır. Önerilen yöntemin spektral boyut fazlalığını azaltmak için kullanılan boyut indirgeme yöntemi TBA'dır. Önerilen yöntem, yaygın olarak kullanılan IP, PU ve SA veri setlerinde çeşitli son teknoloji derin öğrenme tabanlı yöntemlerle karşılaştırılmıştır. Önerilen yöntemin tüm veri setlerinde en iyi sınıflandırma sonuçlarını elde ettiği gözlemlenmiştir. Aynı zamanda eğitim ve test süreleri açısından karşılaştırıldığında, önerilen yöntemin diğer tüm uzamsal-spektral tabanlı yöntemlere göre daha hızlı çalıştığı görülmektedir. Ayrıca sınırlı eğitim örnekleri ile yapılan çalışmalar incelendiğinde önerilen yöntemin diğer tüm yöntemlere göre daha iyi bir performans gösterdiği görülmektedir. Tüm sonuçlara göre,

önerilen yöntemin gerçek Dünya uygulamalarında kullanılabilir bir yöntem olduğu sonucuna varılmıştır.

Yapılan beşinci çalışmada, hiperspektral görüntülerden daha fazla öznelik çıkarmak ve daha iyi sınıflandırma sonuçları elde etmek için 3B/2B Complete Inception modülü ve 3B/2B ESA yönteminin bir kombinasyonu olan bir derin öğrenme yöntemi önerilmiştir. Başlangıç modülünde temel olarak maksimum havuzlama katmanı ve çoklu evrişim katmanı aynı girdiye uygulanmaktadır. Bu katmanlar daha sonra birleştirilmektedir. 3B Complete Inception modülünde 3B evrişim katmanları ve 3B havuzlama kullanılırken, 2B Complete Inception modülünde 2B evrişim katmanları ve 2B havuzlama kullanılmaktadır. 3B/2B Complete Inception modüllerindeki çoklu evrişim katmanları ile modülün çok seviyeli özellik çıkarımından faydalanması sağlanılmaktadır. Bu, ağın performansını arttırmaktadır. Ayrıca 3B/2B Complete Inception modüllerinde kullanılan 1x1 evrişim katmanları sayesinde eğitilebilir parametre sayısı azaltılmakta ve yüksek sınıflandırma performansı sağlanmaktadır. 3B/2B ESA kullanılarak, hiperspektral görüntü sınıflandırmadaki en önemli problemlerden biri olan uzamsal-spektral öznelikler eş zamanlı olarak çıkarılmaktadır. Önerilen yöntemde spektral boyut fazlalığını azaltmak için kullanılan boyut indirgeme yöntemi TBA'dır. Spektral fazlalığı ortadan kaldırmak için, spektral bandlar boyunca hiperspektral görüntüye geleneksel TBA uygulanmaktadır. TBA uygulanarak, herhangi bir nesneyi tanımak için çok önemli olan uzamsal özellik bilgisi korunurken sadece spektral bandlar azaltılmaktadır. Böylece istenilen band sayısına indirilmektedir. Önerilen yöntem, yaygın olarak kullanılan IP, PU, SA, HL ve UH veri setlerinde son teknoloji derin öğrenme tabanlı çeşitli yöntemlerle karşılaştırılmıştır. Yapılan uygulamalar sonucunda OA, AA ve K değerlendirme ölçütleri dikkate alınarak IP için sırasıyla %99.83, %99.82 ve %99.81 değerleri elde edilmiştir. Benzer şekilde, tüm metriklerde PU ve SA için %100, HL için %90.47, %85.82, %88.66, UH için %98.93, %99.01, %98.84 sınıflandırma sonuçları elde edilmiştir. Önerilen yöntemin tüm veri setlerinde en iyi sınıflandırma sonuçlarını elde ettiği görülmüştür. Sınırlı eğitim örnekleri ile yapılan çalışmalar incelendiğinde önerilen yöntemin diğer tüm yöntemlere göre daha iyi bir performans gösterdiği görülmektedir. Ayrıca farklı pencere boyutlarında elde edilen OA değerleri incelendiğinde, önerilen yöntemin son teknoloji yöntemlere göre daha başarılı sınıflandırma doğruluğu vardır. Tüm sonuçlar göz önüne alındığında, önerilen yöntemin hesaplama açısından daha az karmaşık olduğu ve

hiperspektral görüntü sınıflandırma için daha iyi sınıflandırma doğruluğu sağladığı bulunmuştur.

Yapılan altıncı çalışmada, hiperspektral görüntü sınıflandırması için, 2B evrişim işlemi giriş verilerini uzamsal boyutta evrişim işlemine tabi tutarken, 3B evrişim işlemi giriş verilerini hem uzamsal hem de spektral boyutta eş zamanlı olarak evrişim işlemine tabi tutmaktadır. 2B evrişim işlemi, ister 2B veriye ister 3B veriye uygulanıp uygulanmadığına bakılmaksızın, çıktısı 2B'dir. Hiperspektral görüntüye 2B evrişim işlemleri uygulandığında önemli spektral bilgiler kaybedilirken, 3B evrişim giriş hiperspektral görüntü verilerinin spektral bilgilerini koruyarak bir çıktı hacmi elde edebilmektedir. Bu, zengin spektral bilgi içeren hiperspektral görüntüler için çok önemlidir. Bu durum göz önünde bulundurularak bu çalışmada, hiperspektral görüntülerin sınıflandırılması için 3B ESA tabanlı LeNet5, AlexNet, VGG16, GoogleNet ve ResNet50 derin öğrenme mimarilerinin sınıflandırma performansları karşılaştırılmaktadır. Ayrıca, hiperspektral görüntülerdeki spektral fazlalığı gidermek için TBA boyut indirgeme yöntemi kullanılmaktadır. IP, SA, BO ve HL veri setleri kullanılarak 3B ESA tabanlı bu beş derin öğrenme mimarisi ile uygulamalar gerçekleştirilmiştir. Gerçekleştirilen uygulamalar sonucunda OA, AA ve K değerlendirme ölçütleri göz önüne alınarak, SA veri setinde %100 ile LeNet5 ve VGG16, HL veri setinde sırasıyla %98.86, %97.92, %98.65 ile VGG16, BO veri setinde %100 ile ResNet50, IP veri setinde sırasıyla %99.77, %99.77, %99.74 ile VGG16 derin öğrenme mimarisinde en iyi sınıflandırma doğrulukları elde edilmiştir.

Yapılan yedinci çalışmada, hiperspektral görüntü sınıflandırma için çok yollu öznetelik füzyonuna dayalı hibrit 3B-2B derinlemesine ayrılabilir evrişim ağı önerilmektedir. Önerilen yöntemde, farklı çekirdek boyutları ile çıkarılan özellikler bir arada kullanılarak hiperspektral görüntülerden daha zengin özellik bilgileri elde edilmiştir. ESA, uzamsal-spektral özellik bilgilerini çıkarırken yüksek sınıflandırma doğruluğu sağlamaktadır. Bu yönüyle diğer derin öğrenme tabanlı yöntemlere kıyasla hiperspektral görüntü sınıflandırma alanında sıklıkla kullanılan önemli bir yöntem olduğu kanıtlanmıştır. Bununla birlikte, ESA yönteminin bazı dezavantajları vardır. Örneğin, gradyan iniş sürecinde, sonuçların yerel minimuma yakınsamasını sağlamak kolaydır ve havuz katmanıyla birlikte birçok yararlı bilgi kaybolmaktadır. Hiperspektral görüntü sınıflandırmadaki en önemli sorunlardan biri, uzamsal spektral özellik bilgilerini dikkate almaktır. Son yıllarda, uzamsal özelliklerin bir 2B ESA yöntemiyle uyarlandığı hiperspektral görüntü sınıflandırma için ESA tabanlı

yöntemlerde yoğun bir gelişme olmuştur. Bununla birlikte, 2B ESA ile sadece hiperspektral görüntüdeki uzamsal bilgi korunacağından, spektral boyutlardan iyi ayırt edici özellik haritaları çıkarılamaz. Yani, hiperspektral görüntülere 2B evrişim işlemleri uygulanırsa, önemli spektral bilgiler kaybolmaktadır. 3B ESA kullanarak bu sorunun üstesinden gelinmektedir. Uzamsal-spektral öznelikler 3B ESA ile eş zamanlı olarak çıkarıldığından, bu çalışmada 3B hiperspektral görüntülerin yapısal özneliklerinden tam olarak yararlanılmıştır. Ancak, 3B ESA kullanımı hesaplama karmaşıklığını artırmaktadır. Ayrıca, hiperspektral görüntülerdeki farklı sınıflar birçok spektral band üzerinde benzer dokulara sahip olduğunda, tek başına 3B ESA kullanımı sınıflandırma doğruluğunu azaltabilmektedir. 2B ESA ve 3B ESA ayrı ayrı kullanıldığında ortaya çıkan sorunların üstesinden gelmek için her iki yöntemin birlikte kullanıldığı hibrit 3B-2B ESA yöntemine odaklanılmıştır. Hibrit 3B-2B CNN yöntemi ile hem uzamsal hem de spektral öznelik bilgisinden tam olarak yararlanılması amaçlanmaktadır. Bu, sınıflandırma doğruluğunu arttırmaktadır. Ayrıca 2B ESA ve 3B ESA yöntemlerinin farklı çekirdek boyutlarıyla birleştirilmesi, birden fazla özelliğin bir arada kullanılmasına olanak tanımaktadır. Ek olarak, çok yollu bir ağ yapısının kullanılması, hiperspektral görüntüden çıkarılan özelliklerin daha da zenginleştirilmesini sağlamaktadır. Bu durumda, çok yollu özellik füzyonu ile birleştirilen 3B-2B ESA'nın güçlü özellik çıkarma kapasitesi, ağı az sayıda eğitim verisine bağımlı olmasını sağlamaktadır. Bunlar, hiperspektral görüntü sınıflandırma için çok yollu özellik füzyonuna dayalı bir Hibrit 3B-2B ESA yöntemi önerme konusundaki motivasyonlarımızdır. Çok yollu hibrit yöntemimiz için başka bir motivasyon, 3B ve 2B ESA blokları ile 3B-2B derinlemesine ayrılabilir evrişimin kullanılmasıdır. 3B ve 2B derinlemesine ayrılabilir evrişim blokları eklenerek önerilen hibrit yöntemin daha sağlam ve maksimum doğrulukta sınıflandırılması hedeflenmiştir. Önerilen yöntemin IP, PU, SA, WHU-LK, WHU-CH ve WHU-HH veri setleri üzerinde sınıflandırma sonuçları incelenmiştir. IP, PU, SA, WHU-LK, WHU-CH ve WHU-HH ile sırasıyla %99.86, %100, %100, %99.78, %97.06 ve %97.27 OA değerleri elde edilmiştir. Ayrıca önerilen yöntem literatürden son teknoloji yöntemler ile karşılaştırılmıştır. Önerilen yöntemin başarılı sınıflandırma sonuçları ürettiği gözlemlenmiştir. Elde edilen sınıflandırma sonuçları incelendiğinde, önerilen yöntemin gerçek Dünya uygulamalarında kullanılabilir bir yöntem olduğu sonucuna varılmıştır.

Gelecek çalışmalarda hiperspektral görüntü sınıflandırması için , (1) derin öğrenmenin kodlayıcı-kod çözücü mimarileri ile derinlemesine ayrılabilir evrişim ve dilated



evriřim, (2) derin öğrenme ile birlikte metasezgisel yöntemlerin kullanılması planlanmaktadır.



## KAYNAKLAR

- [1] **Madani, H.** (2020), Scholarship @ Western Hyperspectral Image Classification for Remote Sensing (Doktora tezi).
- [2] **Wang, J.** (2020), Hyperspectral Image Classification Based on Deep Learning and Module Inspired by Human Attention Mechanism (Doktora tezi).
- [3] **Reichmuth, A.** (2013), Detection of forest parameters using imaging spectroscopy (Yüksek Lisans tezi).
- [4] **Sowmya, V., Soman, K. P. ve Hassaballah, M.** (2019), Hyperspectral image: Fundamentals and advances, *Studies in Computational Intelligence*, 804, 401–424, doi: 10.1007/978-3-030-03000-1\_16.
- [5] **Sara, D., Mandava, A. K., Kumar, A., Duela, S. ve Jude, A.** (2021), Hyperspectral and multispectral image fusion techniques for high resolution applications: a review, *Earth Science Informatics*, 14(4), 1685–1705, doi: 10.1007/s12145-021-00621-6.
- [6] **Wang, M., Xie, G., Member, G. S., Zhang, Z., Wang, Y. ve Xiang, S.** (2022), Smoothing Filter-Based Panchromatic Spectral Decomposition for Multispectral and Hyperspectral Image Pansharpening, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 3612–3625, doi: 10.1109/JSTARS.2022.3170488.
- [7] **Chen, C.** (2018), Hyperspectral classification based on spectral–spatial convolutional neural networks, *Engineering Applications of Artificial Intelligence*, 68, 165–171, doi: 10.1016/j.engappai.2017.10.015.
- [8] **Roy, S. K., Chatterjee, S., Bhattacharyya, S., Chaudhuri, B. B. ve Platos, J.** (2020), Lightweight Spectral-Spatial Squeeze-and- Excitation Residual Bag-of-Features Learning for Hyperspectral Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 58(8), 5277–5290, doi: 10.1109/TGRS.2019.2961681.
- [9] **Fırat, H. ve Hanbay, D.** (2021), 4CF-Net: Hiperspektral uzaktan algılama görüntülerinin spektral uzamsal sınıflandırılması için yeni 3B evrişimli sinir ağı, *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 37(1), 439–453, doi: 10.17341/gazimmfd.901291.
- [10] **Ahmad, M., Mazzara, M. ve Distefano, S.** (2021), Regularized cnn feature hierarchy for hyperspectral image classification, *Remote Sensing*, 13(12), 1–11, doi: 10.3390/rs13122275.
- [11] **Ibarrola-Ulzurrun, E., Drumetz, L., Marcello, J., Gonzalo-Martin, C. ve Chanussot, J.** (2019), Hyperspectral Classification Through Unmixing Abundance Maps Addressing Spectral Variability, *IEEE Transactions on Geoscience and Remote Sensing*, 57(7), 4775–4788, doi: 10.1109/TGRS.2019.2892903.
- [12] **Mohan, A. ve Meenakshi Sundaram, V.** (2020), V3O2: hybrid deep learning model for hyperspectral image classification using vanilla-3D and octave-2D convolution, *Journal of Real-Time Image Processing*, doi: 10.1007/s11554-020-00966-z.
- [13] **Gowtham, B., Kumar, I. A., Reddy, T. S., Harikiran, J. ve Chandana, B.S.** (2021), Hyperspectral Image Analysis using Principal Component Analysis and Siamese Network, *Turkish Journal of Computer and Mathematics Education*, 12(7), 1191–

1198.

- [14] **Ahmad, M.** (2019), Spatial prior fuzziness pool-based interactive classification of hyperspectral images, *Remote Sensing*, 11(9), 1–19, doi: 10.3390/rs11091136.
- [15] **Li, J., Bioucas-Dias, J. M. ve Plaza, A.** (2010), Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning, *IEEE Transactions on Geoscience and Remote Sensing*, 48(11), 4085–4098, doi: 10.1109/TGRS.2010.2060550.
- [16] **Wang, Y., Yu, W. ve Fang, Z.** (2020), Multiple Kernel-based SVM classification of hyperspectral images by combining spectral, spatial, and semantic information, *Remote Sensing*, 12(1), doi: 10.3390/RS12010120.
- [17] **Ham, J. S., Chen, Y., Crawford, M. M. ve Ghosh, J.** (2005), Investigation of the random forest framework for classification of hyperspectral data, *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 492–501, doi: 10.1109/TGRS.2004.842481.
- [18] **Fang, L., Li, S., Duan, W., Ren, J. ve Benediktsson, J. A.** (2015), Classification of Hyperspectral Images by Exploiting Spectral-Spatial Information of Superpixel via Multiple Kernels, *IEEE Transactions on Geoscience and Remote Sensing*, 53(12), 6663–6674, doi: 10.1109/TGRS.2015.2445767.
- [19] **Fang, L., Li, S., Kang, X. ve Benediktsson, J.A.** (2014), Spectral-spatial hyperspectral image classification via multiscale adaptive sparse representation, *IEEE Transactions on Geoscience and Remote Sensing*, 52(12), 7738–7749, doi: 10.1109/TGRS.2014.2318058.
- [20] **Camps-Valls, G. ve Bruzzone, L.** (2005), Kernel-based methods for hyperspectral image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 43(6), 1351–1362, doi: 10.1109/TGRS.2005.846154.
- [21] **Palmason, J. A., Benediktsson, J. A. ve Sveinsson, J. R.** (2005), Classification of hyperspectral data from urban areas based on extended morphological profiles, *IEEE Transactions on Geoscience and Remote Sensing*, 43(3), 480–491, doi: 10.1109/TGRS.2004.842478.
- [22] **Mohan, A. ve Venkatesan, M.** (2020), HybridCNN based hyperspectral image classification using multiscale spatio-spectral features, *Infrared Physics & Technology*, 108, doi: 10.1016/j.infrared.2020.103326.
- [23] **Data, H.** (2014), Deep Learning-Based Classification of Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(6), 2094–2107, doi: 10.1109/JSTARS.2014.2329330.
- [24] **Mughees, A. ve Tao, L.** (2017), Efficient deep auto-encoder learning for the classification of hyperspectral images, Proceedings - 2016 International Conference on Virtual Reality and Visualization : ICVRV 2016, 24-26 September, Hangzhou, China, 44–51, doi: 10.1109/ICVRV.2016.16.
- [25] **Zhong, P., Gong, Z., Li, S. ve Schonlieb, C. B.** (2017), Learning to Diversify Deep Belief Networks for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 55(6), 3516–3530, doi: 10.1109/TGRS.2017.2675902.
- [26] **Chen, Y., Zhao, X. ve Jia, X.** (2015), Spectral-Spatial Classification of Hyperspectral Data Based on Deep Belief Network, *IEEE Journal of Selected Topics in Applied*

- Earth Observations and Remote Sensing*, 8(6), 2381–2392, doi: 10.1109/JSTARS.2015.2388577.
- [27] **Li, L., Xi, B., Li, Y., Du, Q. ve Wang, K.** (2018), Hyperspectral classification based on texture feature enhancement and deep belief networks, *Remote Sensing*, 10(3), doi: 10.3390/rs10030396.
- [28] **Zhang, C.** (2019), Joint Deep Learning for land cover and land use classification, *Remote Sensing of Environment*, 221, 173–187, doi: 10.1016/j.rse.2018.11.014.
- [29] **Cao, F. ve Guo, W.** (2020), Deep hybrid dilated residual networks for hyperspectral image classification, *Neurocomputing*, 384, 170–181, doi: 10.1016/j.neucom.2019.11.092.
- [30] **Roy, S. K., Manna, S., Song, T. ve Bruzzone, L.** (2020), Attention-Based Adaptive Spectral-Spatial Kernel ResNet for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 59(9), 7831–7843, doi: 10.1109/TGRS.2020.3043267.
- [31] **Roy, S. K., Krishna, G., Dubey, S. R. ve Chaudhuri, B. B.** (2019), HybridSN: Exploring 3D-2D CNN Feature Hierarchy for Hyperspectral Image Classification, *arXiv*, 17(2), 277–281, 2019.
- [32] **Ahmad, M., Khan, A. M., Mazzara, M., Distefano, S., Ali, M. ve Sarfraz, M. S.** (2020), “A Fast and Compact 3-D CNN for Hyperspectral Image Classification,” *IEEE Geoscience and Remote Sensing Letters*, 1–5, doi: 10.1109/LGRS.2020.3043710.
- [33] **Roy, S. K., Dubey, S. R., Chatterjee, S. ve Chaudhuri, B. B.** (2020), FuSENet: Fused squeeze-and-excitation network for spectral-spatial hyperspectral image classification, *IET Image Processing*, 14(8), 1653–1661, doi: 10.1049/iet-ipr.2019.1462.
- [34] **Iyer, P., A, S. ve Lal, S.** (2021), Deep learning ensemble method for classification of satellite hyperspectral images, *Remote Sensing Applications: Society and Environment*, 23, 100580, doi: 10.1016/j.rsase.2021.100580.
- [35] **Xu, H., Yao, W., Cheng, L. ve Li, B.** (2021), Multiple spectral resolution 3D convolutional neural network for hyperspectral image classification, *Remote Sensing*, 13(7), doi: 10.3390/rs13071248.
- [36] **Gao, H., Yang, Y., Li, C., Gao, L. ve Zhang, B.** (2021), Multiscale Residual Network with Mixed Depthwise Convolution for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 9(4), 3396–3408, doi: 10.1109/TGRS.2020.3008286.
- [37] **FIRAT, H., ASKER, M. E. ve HANBAY, D.** (2022), Hybrid 3D Convolution and 2D Depthwise Separable Convolution Neural Network for Hyperspectral Image Classification, *Balkan Journal of Electrical and Computer Engineering*, 10(1), 35–46, 2022, doi: 10.17694/bajece.1039029.
- [38] **Zheng, J., Feng, Y., Bai, C. ve Zhang, J.** (2021), Hyperspectral Image Classification Using Mixed Convolutions and Covariance Pooling, *IEEE Transactions on Geoscience and Remote Sensing*, 59(1), 522–534, doi: 10.1109/TGRS.2020.2995575.
- [39] **Sun, H., Zheng, X., Lu, X. ve Wu, S.** (2020), Spectral-Spatial Attention Network for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 58(5), 3232–3245, doi: 10.1109/TGRS.2019.2951160.

- [40] **Gong, H.** (2021), Multiscale Information Fusion for Hyperspectral Image Classification Based on Hybrid 2D-3D CNN, *Remote Sensing*, 13(12), doi: 10.3390/rs13122268.
- [41] **Ge, Z., Cao, G., Li, X. ve Fu, P.** (2020), Hyperspectral Image Classification Method Based on 2D-3D CNN and Multibranch Feature Fusion, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 13, 5776–5788, doi: 10.1109/JSTARS.2020.3024841.
- [42] **Yang, X.** (2020), Synergistic 2D/3D convolutional neural network for hyperspectral image classification, *Remote Sensing*, 12(12), 1–19, doi: 10.3390/rs12122033.
- [43] **Firat, H. ve Hanbay, D.** (2021), 3B ESA Tabanlı ResNet50 Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması Classification of Hyperspectral Images Using 3D CNN Based ResNet50, 29th Signal Processing and Communications Applications Conference-SIU 2021, Istanbul-Turkey, June 9-11, 6–9, doi: 10.1109/SIU53274.2021.9477899.
- [44] **Mingyi He, H. C., Li, Bo.** (2017), Multi-scale 3D deep convolutional neural network for hyperspectral image classification, 2017 IEEE International Conference on Image Processing, Beijing, China, 17-20 September, 3904–3908.
- [45] **Zhong, Z., Li, J., Luo, Z. ve Chapman, M.** (2018), Spectral-Spatial Residual Network for Hyperspectral Image Classification: A 3-D Deep Learning Framework, *IEEE Transactions on Geoscience and Remote Sensing*, 56(2), 847–858, doi: 10.1109/TGRS.2017.2755542.
- [46] **Meng, Z., Li, L., Tang, X., Feng, Z., Jiao, L. ve Liang, M.** (2019), Multipath residual network for spectral-spatial hyperspectral image classification, *Remote Sensing*, 11(16), 1–19, doi: 10.3390/rs11161896.
- [47] **Song, L., Li, W., Fang, S.** (2018), Hyperspectral Image Classification with Deep Feature Fusion Network, *IEEE Transactions on Geoscience and Remote Sensing*, 99, 3173–3184, doi: 10.1109/IGARSS.2019.8898520.
- [48] **Liu, Y., Gao, L., Xiao, C., Qu, Y., Zheng, K. ve Marinoni, A.** (2020), Hyperspectral image classification based on a shuffled group convolutional neural network with transfer learning, *Remote Sensing*, 12(11), 1–18, doi: 10.3390/rs12111780.
- [49] **Roy, S., Mondal, R., Paoletti, M. E., Haut, J. M. ve 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, doi: 10.1109/JSTARS.2021.3088228.
- [50] **Ghosh, P., Roy, S. K., Koirala, B., Rasti, B. ve Scheunders, P.** (2022), Deep Hyperspectral Unmixing using Transformer Network, 1–13, 2022.
- [51] **Roy, S. K., Deria, A., Hong, D., Rasti, B., Plaza, A. ve Chanussot, J.** (2022), Multimodal Fusion Transformer for Remote Sensing Image Classification, 1–17, 2022.
- [52] **Ghaderizadeh, S., Abbasi-Moghadam, D., Sharifi, A., Zhao, N. ve Tariq, A.** (2021), Hyperspectral Image Classification Using a Hybrid 3D-2D Convolutional Neural Networks, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 7570–7588, doi: 10.1109/JSTARS.2021.3099118.
- [53] **Firat, H., Uçan, M. and Hanbay, D.** (2021), Classification of Hyperspectral Remote Sensing Images Using Hybrid 3D-2D CNN Architecture, *Journal of Computer*

- Science*, IDAP-2021(Special), 132–140.
- [54] **Firat, H., Uçan, M. ve Hanbay, D.** (2021), Hyperspectral Image Classification Using MiniVGGNet, *Journal of Computer Science*, IDAP-2021(Special), 295–303.
- [55] **Firat, H. ve Hanbay, D.** (2022), 3 Boyutlu Evrişimsel Sınır Ağı Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması Classification of Hyperspectral Images Using 3D Convolutional Neural Network, *Türk Doğa ve Fen Dergisi*, 11(1), 19–28.
- [56] **Firat, H., Asker, M. E. ve Hanbay, D.** (2022), Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN, *Remote Sensing Applications: Society and Environment*, 100694, doi: 10.1016/j.rsase.2022.100694.
- [57] **Ahmad, M., Shabbir, S., Raza, R. A., Mazzara, M., Distefano, S. ve Khan, A. M.** (2021), Artifacts of different dimension reduction methods on hybrid CNN feature hierarchy for Hyperspectral Image Classification, *Optik.*, 246(July), 167757, doi: 10.1016/j.ijleo.2021.167757.
- [58] **Ahmad, M.** (2022), Hyperspectral Image Classification - Traditional to Deep Models: A Survey for Future Prospects, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 15, 968–999, doi: 10.1109/JSTARS.2021.3133021.
- [59] **Paoletti, M. E., Haut, J. M., Plaza, J. ve Plaza, A.** (2018), A new deep convolutional neural network for fast hyperspectral image classification, *ISPRS Journal of Photogrammetry and Remote Sensing*, 145, 120–147, doi: 10.1016/j.isprsjprs.2017.11.021.
- [60] **Li, S., Song, W., Fang, L., Chen, Y., Ghamisi, P. ve Benediktsson, J. A.** (2019), Deep Learning for Hyperspectral Image Classification: An Overview, *IEEE Transactions on Geoscience and Remote Sensing*, 57(9), 6690–6709, doi: 10.1109/tgrs.2019.2907932.
- [61] **Huang, L. ve Chen, Y.** (2020), Dual-Path Siamese CNN for Hyperspectral Image Classification With Limited Training Samples, *IEEE Geoscience and Remote Sensing Letters*, 18(3), 1–5, doi: 10.1109/lgrs.2020.2979604.
- [62] **LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P.** (1998), Gradient-based learning applied to document recognition, *Proceedings of the IEEE*, 86(11), 2278–2323, doi: 10.1109/5.726791.
- [63] **Krizhevsky, A., Sutskever, I. ve Hinton, G. E.** (2012), ImageNet Classification with Deep Convolutional Neural Networks, in *International Conference on Neural Information Processing Systems*, 1097–1105.
- [64] **Szegedy, C.** (2015), Going deeper with convolutions, in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 07-12-June, 1–9, doi: 10.1109/CVPR.2015.7298594.
- [65] **Patel, M., Parmar, M., Doshi, S., Shah, N. ve Patil, H.** (2019), Novel Inception-GAN for Whispered-to-Normal Speech Conversion, 10th ISCA Workshop Speech Synthesis (SSW 10), Vienna, Austria, 20-22 September, 87–92, doi: 10.21437/ssw.2019-16.
- [66] **Simonyan, K. ve Zisserman, A.** (2015), Very deep convolutional networks for large-scale image recognition.

- [67] **He, K., Zhang, X., Ren, S. ve Sun, J.** (2016), Deep residual learning for image recognition, in Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December, 770–778, doi: 10.1109/CVPR.2016.90.
- [68] **Ramzan, F.** (2020), A Deep Learning Approach for Automated Diagnosis and Multi-Class Classification of Alzheimer’s Disease Stages Using Resting-State fMRI and Residual Neural Networks, *Journal of Medical Systems*, 44(2), doi: 10.1007/s10916-019-1475-2.
- [69] **Shehab, L. H., Fahmy, O. M., Gasser, S. M. ve El-Mahallawy, M. S.** (2020), An efficient brain tumor image segmentation based on deep residual networks (ResNets), *Journal of King Saud University - Engineering Science*, 1–9, doi: 10.1016/j.jksues.2020.06.001.
- [70] **Ling, H., Chen, Y., Chen, J., Wu, L., Shi, Y. ve Deng, J.** (2020), XwiseNet: action recognition with Xwise separable convolutions, *Multimedia Tools and Applications*, 79(37–38), 26913–26926, doi: 10.1007/s11042-020-09137-5.
- [71] **Dang, L., Pang, P. ve Lee, J.** (2020), Depth-wise separable convolution neural network with residual connection for hyperspectral image classification, *Remote Sensing*, 12(20), 1–20, doi: 10.3390/rs12203408.
- [72] **Ye, Y., Liu, F. ve Zhang, L.** (2019), 3D Depthwise Convolution: Reducing Model Parameters in 3D Vision Tasks, *Lecture Notes in Computer Science (including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes Bioinformatics)*, 11489 LNAI, 186–199, doi: 10.1007/978-3-030-18305-9\_15.
- [73] **Url-1,** H. R. S. Scenes, “Hyperspectral Remote Sensing Scenes.” [http://www.ehu.es/ccwintco/index.php/Hyperspectral\\_Remote\\_Sensing\\_Scenes](http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes) (accessed Mar. 17, 2021).
- [74] **Url-2,** “The ISPRS HyRANK Benchmark.” <https://www2.isprs.org/commissions/comm3/wg4/hyrank/>.
- [75] **Url-3,** “2013 IEEE GRSS Data Fusion Contest – Fusion of Hyperspectral and LiDAR Data.” [https://hyperspectral.ee.uh.edu/?page\\_id=459](https://hyperspectral.ee.uh.edu/?page_id=459).
- [76] **Url-4,** “WHU-Hi Dataset.” [http://rsidea.whu.edu.cn/resource\\_WHUHi\\_sharing.htm](http://rsidea.whu.edu.cn/resource_WHUHi_sharing.htm).
- [77] **Kuo, B. C., Ho, H. H., Li, C. H., Hung, C. C. ve Taur, J. S.** (2014), A kernel-based feature selection method for SVM with RBF kernel for hyperspectral image classification, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 317–326, doi: 10.1109/JSTARS.2013.2262926.
- [78] **Wang, Q., Gao, J. ve Yuan, Y.** (2018), A Joint Convolutional Neural Networks and Context Transfer for Street Scenes Labeling, *IEEE Transactions on Intelligence Transportation Systems*, 19(5), 1457–1470, doi: 10.1109/TITS.2017.2726546.
- [79] **Li, Y., Zhang, H. ve Shen, Q.** (2017), Spectral-spatial classification of hyperspectral imagery with 3D convolutional neural network, *Remote Sensing*, 9(1), doi: 10.3390/rs9010067.
- [80] **Melgani, F. ve Bruzzone, L.** (2004), Classification of Hyperspectral Remote Sensing Images With Support Vector Machines, *IEEE Transactions on Geoscience and Remote Sensing*, 42(August), 1778–1790, doi: 10.1109/TGRS.2004.831865.
- [81] **Mu, C., Guo, Z. ve Liu, Y.,** A multi-scale and multi-level spectral-spatial feature

- fusion network for hyperspectral image classification, *Remote Sensing*, 12(1), doi: 10.3390/RS12010125.
- [82] **Chen, P. G. Y., Jiang, H., Li, C., Jia, X.** (2016), Deep Feature Extraction and Classification of Hyperspectral Images Based on Convolutional Neural Networks, *IEEE Transactions on Geoscience and Remote Sensing*, 54(10), 6232–6251, doi: 10.1109/TGRS.2016.2584107.
- [83] **Xu, Y., Zhang, L., Du, B. ve Zhang, F.** (2018), Spectral–Spatial Unified Networks for Hyperspectral Image Classification, *IEEE Transactions on Geoscience and Remote Sensing*, 56(10), 5893–5909, doi: 10.1109/TGRS.2018.2827407.
- [84] **Makantasis, K., Karantzalos, K., Doulamis, A. ve Doulamis, N.** (2015), Deep supervised learning for hyperspectral data classification through convolutional neural networks, *International Geoscience and Remote Sensing Symposium*, 2015-November, Milan, Italy, 4959–4962, doi: 10.1109/IGARSS.2015.7326945.
- [85] **Ben Hamida, A., Benoit, A., Lambert, P. ve Ben Amar, C.** (2018), 3-D deep learning approach for remote sensing image classification, *IEEE Transactions on Geoscience and Remote Sensing*, 56(8), 4420–4434, doi: 10.1109/TGRS.2018.2818945.



## ÖZGEÇMİŞ

**Ad-Soyad** : Hüseyin FIRAT

### ÖĞRENİM DURUMU:

- **Lisans** :2014, Çukurova Üniversitesi, Mühendislik-Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü
- **Yüksek Lisans** :2018, İnönü Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bölümü
- **Doktora** :2022, İnönü Üniversitesi, Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Bölümü

### MESLEKİ DENEYİM:

- 2020 – Devam :Dicle Üniversitesi-Teknik Bilimler MYO-Bilgisayar Teknolojileri Bölümü (Öğretim Görevlisi)
- 2019 - 2020 :İskenderun Teknik Üniversitesi-Dört Yol MYO-Bilgisayar Teknolojileri Bölümü (Öğretim Görevlisi)

### DOKTORA TEZİNDEN TÜRETİLEN ÇALIŞMALAR

- **Firat, H., Hanbay, D. (2022).** 4CF-Net: New 3D convolutional neural network for spectral spatial classification of hyperspectral remote sensing images. Journal of the Faculty of Engineering and Architecture of Gazi University, 2022.
- **Firat, H., Asker, M.E., Bayındır, M.İ., Hanbay, D. (2022).** Hybrid 3D/2D Complete Inception Module and Convolutional Neural Network for Hyperspectral Remote Sensing Image Classification. Neural processing letters, 2022.
- **Firat, H., Asker, M.E., Hanbay, D. (2022).** Classification of hyperspectral remote sensing images using different dimension reduction methods with 3D/2D CNN. Remote Sensing Applications: Society and Environment, 2022.
- **Firat, H., Hanbay, D. (2022).** Hiperspektral görüntüler kullanılarak 3B ESA tabanlı derin öğrenme mimarilerinin karşılaştırılması. Journal of the Faculty of Engineering and Architecture of Gazi University, 2022.
- **Firat, H., Hanbay, D. (2022).** 3 Boyutlu Evrişimsel Sinir Ağı Kullanılarak Hiperspektral Görüntülerin Sınıflandırılması. Türk Doğa ve Fen Dergisi, 2022.
- **Firat, H., Asker, M.E., Hanbay, D. (2022).** Hybrid 3D Convolution and 2D Depthwise Separable Convolution Neural Network for Hyperspectral Image Classification. Balkan Journal of Electrical and Computer Engineering, 2022.

- **Fırat, H., Hanbay, D. (2021, June).** Classification of Hyperspectral Images Using 3D CNN Based ResNet50. 2021 29th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE.
- **Fırat, H., Uçan, M. & Hanbay, D. (2021).** Hibrid 3B-2B ESA Mimarisi Kullanılarak Hiperspektral Uzaktan Algılama Görüntülerinin Sınıflandırılması. Computer Science, 5th International Artificial Intelligence and Data Processing Symposium, (pp. 132-140).
- **Fırat, H., Uçan, M. & Hanbay, D. (2021).** MiniVGGNet Kullanılarak Hiperspektral Görüntü Sınıflandırma. Computer Science, 5th International Artificial Intelligence and Data Processing Symposium, (pp. 295-303).
- **Fırat, H., Asker, M.E., Hanbay, D. (2022).** Hiperspektral Görüntü Sınıflandırması için Derinlemesine Ayrılabilir Evrişim Tabanlı Artık Ağ Mimarisi. Gazi Üniversitesi-Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji, 2022.

