

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**





KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ORCID : - - -

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

ORCID : - - -

Trabzon

ÖNSÖZ

“Derin Öğrenme ile Harran Ovası Toprak Tuzluluğunun Tespiti” başlıklı çalışma, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Harita Mühendisliği Anabilim Dalında yüksek lisans tezi olarak hazırlanmıştır.

Danışmanlığımı üstlenen, tez çalışmamda geniş bilgisi ve vizyonu ile katkı sunan sayın Prof. Dr. Oğuz GÜNGÖR’e en içten teşekkürlerimi sunarım.

Katkılarından dolayı tez jüri üyelerim Doç.Dr. Halil AKINCI ve Dr.Öğr. Üyesi Esra TUNÇ GÖRMÜŞ’e teşekkürlerimi sunarım.

Tuzluluk ölçüm verilerini sağlayan Harran Üniversite’si Ziraat Fakültesi’nden Prof. Dr. Mehmet Ali ÇULLU ve Doç. Dr. Ali Volkan BİLGİLİ’ye, verdiği derin öğrenme mimari önerisi için Arş. Gör. Ekrem SARALIOĞLU’na teşekkür ederim.

Her daim beni destekleyen ve bugünlere gelmemde büyük emek veren aileme teşekkür ederim.

Şeyma AKÇA
Şanlıurfa 2020

TEZ ETİK BEYANNAMESİ

Yüksek lisans tezi olarak sunduğum “DERİN ÖĞRENME İLE HARRAN OVASI TOPRAK TUZLULUĞUNUN TESPİTİ” başlıklı bu çalışmayı baştan sona kadar danışmanım olan Prof. Dr. Oğuz Güngör’ün sorumluluğunda tamamladığımı, verileri kendim topladığımı, ilgili kodları kendim yazdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 25/11/2020

Şeyma AKÇA

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	IX
SUMMARY	X
ŞEKİLLER DİZİNİ	XI
TABLolar DİZİNİ.....	XX
SEMBOLLER DİZİNİ.....	XXIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Literatür Çalışması	4
1.3. Problemin Tanımı.....	8
1.4. Çalışmanın Amacı	10
1.5. Metodoloji.....	11
1.6. RapidEye Uydu Özellikleri.....	12
1.7. Tuzluluk İndeksleri.....	15
1.8. Bitki İndeksi.....	18
1.9. Derin Öğrenme.....	18
1.9.1. Yapay Sinir Ağları.....	20
1.9.2. Yapay Sinir Ağı Mimarisi.....	23
1.9.3. İleri Beslemeli Yapay Sinir Ağları	24
1.9.4. Kayıp Fonksiyonu (Loss Function)	25
1.9.5. Maliyet Fonksiyonu	25
1.9.6. Geri Beslemeli Ağlar	26

1.10.	Aktivasyon Fonksiyonları.....	28
1.10.1.	Lineer Aktivasyon Fonksiyonu	29
1.10.2.	Sigmoid Aktivasyon Fonksiyonu	30
1.10.3.	Hard Sigmoid Fonksiyonu	31
1.10.4.	Sigmoid Ağırlıklı Lineer Birim (SiLU).....	31
1.10.5.	Sigmoid Ağırlıklı Doğrusal Birimlerin Türevi (dSiLU).....	32
1.10.6.	Hiperbolik Tanjant Aktivasyon Fonksiyonu (Tanh).....	33
1.10.7.	Rektifiye Edilmiş Lineer Birim (ReLU).....	34
1.10.8.	Sızıntı Rektifiye Edilmiş Lineer Birim (LReLU).....	35
1.10.9.	Softmax.....	36
1.10.10.	Softplus	37
1.10.11.	Maxout Fonksiyonu	38
1.10.12.	Swish Fonksiyonu.....	38
1.10.13.	Üstel Lineer Birimler (ELUs)	39
1.10.14.	Softsign Fonksiyonu	39
1.11.	Aşırı Öğrenme ve Eksik Öğrenme.....	40
1.11.1.	Aşırı Öğrenme (Overfitting).....	40
1.11.1.	Eksik Öğrenme (Underfitting).....	40
1.12.	Gradyan İniş (Gradient Descent).....	41
1.13.	Hiperparametreler (Hyperparameter)	41
1.13.1.	Öğrenme Katsayısı (Learning Rate)	41
1.13.2.	Regülarizasyon	42
1.13.2.1.	L1 Regülarizasyon.....	43
1.13.2.2.	L2 Regülarizasyon.....	43
1.13.3.	Dropout	44
1.14.	Küme Seti (Mini Batch).....	44
1.15.	Epok.....	45

1.16.	İterasyon (Yineleme)	45
1.17.	Derin Öğrenmenin Blokları.....	45
1.17.1.	Kısıtlı Boltzman Makinaları (RBM).....	45
1.17.2.	Oto-Kodlayıcılar	46
1.18.	Normalizasyon.....	49
1.19.	Modelin Değerlendirilmesi	49
1.19.1.	Hata Matrisi.....	49
1.20.	Evrişimsel Yapay Sinir Ağı	50
1.20.1.	CNN Mimarisi.....	52
1.20.2.	Konvolüsyon	53
1.20.3.	Özellik Haritaları	54
1.20.4.	ReLU Katmanı	55
1.20.5.	Havuzlama Katmanı	56
1.20.6.	Doldurma (Padding)	57
1.20.7.	Kaydırma (Stride).....	58
1.20.8.	Sınıflandırma Katmanı.....	59
1.20.8.1.	U-NET Mimarisi	59
2.	YAPILAN ÇALIŞMALAR	63
2.1.	Çalışma Alanı.....	63
2.2.	Yersel Tuzluluk Ölçümü ve Haritalama	65
2.3.	Histogram Eşitleme	68
2.4.	Veri Setinin Düzenlenmesi	69
2.5.	Tuzluluk İndekslerinin Hesaplanması	70
2.6.	Etiket Sınıflarının Belirlenmesi.....	73
2.7.	Ağ Parametrelerinin Belirlenmesi	75
2.8.	Ağ Mimari Yapısı.....	77
2.9.	Bölütleme Performansının Hesaplanması	83

3.	BULGULAR VE İRDELEMELER	85
4.	SONUÇLAR VE ÖNERİLER	138
5.	KAYNAKLAR.....	178
6.	EKLER.....	183
	ÖZGEÇMİŞ.....	186



Yüksek Lisans Tezi

ÖZET

DERİN ÖĞRENME İLE HARRAN OVASI TOPRAK TUZLULUĞUNUN TESPİTİ

Şeyma AKÇA

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Harita Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Oğuz GÜNGÖR
2020, 183 Sayfa, 3 Ek Sayfa

Toprak tuzluluğu kurak ve yarı kurak iklim bölgelerinde, toprağın yapısında olan anyon ve katyonların birleşmesiyle oluşan tuzların, yeraltı sularına karışıp çözünmesiyle oluşur. Oluşan bu tuzlar yüksek taban suyuyla birlikte çözünmüş olarak toprak yüzeyine çıkar ve taban suyunun buharlaşması sonucu toprağın yüzeyinde birikir. Bu durum bitki gelişimini olumsuz etkiler ve verimi düşürür. Toprak tuzluluğu nedeniyle birinci sınıf tarım arazilerinin verimsizleşmesi, yerel ve global çapta birçok ekonomik ve sosyal sorunu beraberinde getirmektedir. Tarım arazilerinin sürdürülebilirliği ve tuz yönetiminin sağlanması için bu tez çalışmasıyla Türkiye'nin en büyük tarım ovalarından biri olan Harran Ovası'ndaki tuzluluk sorununun uzaktan algılama yöntemleriyle tespit edilmesi amaçlanmıştır. Harran Ovası'nda tuzluluk tespiti için literatürde en çok kullanılan tuzluluk indeksleri olan NDSI, SI, SII ve bitki indeksi NDVI kullanılmıştır. Bir derin öğrenme yöntemi olan evrişimsel yapay sinir ağları U-NET mimarisiyle yapılan sınıflandırma işleminde görüntünün sahip olduğu 5 spektral kanala ilaveten tuzluluk indekslerinin her biri ayrı bir spektral bant olacak şekilde görüntüye eklenmiştir. 300 iterasyonda en iyi sınıflandırma doğruluğunu veren SII (%93.78) tuzluluk indeks kombinasyonu olmuştur.

Anahtar Kelimeler: Toprak Tuzluluğu, Harran Ovası, Derin Öğrenme, U-NET

Msc. Thesis

SUMMARY

DETECTION OF HARRAN PLAIN SOIL SALINITY WITH DEEP LEARNING

Seyma AKCA

Karadeniz Technical University
The graduate school of natural and applied sciences
Geomatics engineering department
Supervisor: Prof. Dr. Oguz GUNGOR
2020, 183 Pages, 3 Appendix Pages

Soil salinity occurs in the arid and semi-arid climatic regions by the dissolution of salts formed by the combination of anions and cations in the structure of the soil, by mixing with groundwater. These salts formed dissolve with high ground water to the surface of the soil and accumulate on the surface of the soil as a result of evaporation of the ground water. This affects plant growth negatively and decreases the yield. Harran Plain, one of Turkey's largest agricultural plain, was aimed to identify salinity problem with remote sensing techniques for ensuring sustainability of agricultural land management. NDSI, SI, SII and plant index NDVI, which are the most used salinity indices in the literature, were used for the determination of salinity in Harran Plain. Convolutional Neural Networks, a deep learning method, has been added to the image as a separate spectral band, in addition to the 5 bands of the image, in the classification process made with U-NET architecture. It has been the SII (93.78%) salinity index combination that gave the best classification accuracy in 300 iterations.

Keywords: Soil Salinity, Harran Plate, Deep Learning, U- NET

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 1. EC-Probe ve EM-38 Tuz Ölçüm Cihazı (URL-1 ve URL-2).....	2
Şekil 2. Harran Ovası'nda görülen tuzluluk (URL-3, 2019)	9
Şekil 3. RapidEye Uydu sensör tarama yönü ve perspektifi (URL-9, 2019'dan değiştirilerek)	14
Şekil 4. PlanetScope Orto Karo (URL-9, 2019'dan değiştirilerek).....	14
Şekil 5. Makine öğrenmesi, derin öğrenme ve yapay zeka ilişki diyagramı (Patterson ve Gibson, 2017'den değiştirilerek).....	19
Şekil 6. İstatiksel model, makine öğrenme ve derin öğrenme yöntemleri arasındaki veri boyutu ve model doğruluk ilişkisi (Patterson ve Gibson, 2017'den değiştirilerek)	20
Şekil 7. Dendrit, hücre çekirdeği, soma, akson ve sinapstan oluşan nöron yapısı (URL-10, 2019'dan değiştirilerek).....	21
Şekil 8. Basit bir elektrik devresinin temsili olan McCulloch-Pitts nöronu (Patterson ve Gibson, 2017'den değiştirilerek).....	22
Şekil 9. Girdi katmanı, gizli katmanlar ve çıktı katmanından oluşan bir yapay sinir ağı mimarisi (Patterson ve Gibson, 2017'den değiştirilerek)	23
Şekil 10. Girdi değerleri ve ağırlıkların çarpılıp toplanarak bir aktivasyon fonksiyonundan geçirilen ileri beslemeli yapay sinir ağı (Patterson ve Gibson, 2017'den değiştirilerek).....	24
Şekil 11. İki gizli katmana sahip iki farklı çıktı üreten yapay sinir ağı modeli.....	27
Şekil 12. $f(x) = Wx$ eşitliğiyle tanımlanmış lineer aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek).....	30
Şekil 13. $[0,1]$ kapalı aralığında değer alan Sigmoid aktivasyon fonksiyon grafiği (Ramachandran vd., 2017'den değiştirilerek).....	31
Şekil 14. SiLU ve ReLU aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek).....	32
Şekil 15. dSiLU ve Sigmoid aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek).....	33
Şekil 16. $(-1,1)$ açık aralığında değer alan Tanh aktivasyon fonksiyonu.....	34
Şekil 17. Rektifiye edilmiş lineer birim aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek).....	35

Şekil 18. Softmax aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek)	37
Şekil 19. Softplus ve ReLU aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek).....	37
Şekil 20. Aşırı, uygun ve eksik öğrenme durumlarına göre verinin ayrıştırılması (URL-13, 2019'dan değiştirilerek).....	40
Şekil 21. Optimizasyon metodu olan gradyan inişin üç ve iki boyutta temsili gösterimi (Moolayil, 2019'dan değiştirilerek).....	41
Şekil 22. Büyük ve küçük öğrenme katsayısının iki boyutta model eğitiminde ilerleyişi verilmiştir (Moolayil, 2019'dan değiştirilerek).....	42
Şekil 23. Çok katmanlı bir yapay sinir ağı ve dropout durumunda pasif hale gelen nöronlar (URL-14, 2019'dan değiştirilerek).....	44
Şekil 24. Lineer boyut azaltma yöntemi olan PCA ile nonlineer boyut azaltma yöntemi olan Oto-Kodlayıcıların temsili gösterimi (Patterson ve Gibson, 2017'den değiştirilerek).....	46
Şekil 25. Boyut küçülterek sıkıştırılmış veri üzerinden öğrenen ve çıktıda tekrar aynı boyuta gelen oto-kodlayıcı topolojisi (Patterson ve Gibson, 2017'den değiştirilerek)	47
Şekil 26. Oto-kodlayıcı ile sıkıştırılmış veri ve gürültüsü giderilmiş resim (Patterson ve Gibson, 2017'den değiştirilerek).....	48
Şekil 27. Hata Matrisi (Patterson ve Gibson, 2017'den değiştirilerek)	49
Şekil 28. Makine öğrenmesi sınıflandırıcısı (Patterson ve Gibson, 2017'den değiştirilerek)	51
Şekil 29. CNN mimarisi özellik çıkarıcı ve sınıflandırıcısı (Patterson ve Gibson, 2017'den değiştirilerek).....	51
Şekil 30. Girdi katmanı, özellik çıkarım katmanı ve sınıflandırma katmanı ile bir CNN mimarisi. Özellik çıkarım katmanı konvolüsyon, ReLU ve havuzlama aşamalarını içermektedir (Patterson ve Gibson, 2017'den değiştirilerek) ...	52
Şekil 31. Konvolüsyon işlemi. Bu işlemde girdi katmanı ile kernelin element matris çarpımları yapıp toplanmıştır. Sonuç değeri özellik haritasına atanır (URL-15, 2019'dan değiştirilerek).....	53
Şekil 32. İlk konvolüsyon işlemi sonucu oluşan özellik haritası (a), ikinci konvolüsyon işlemi sonrası oluşan özellik haritası (b), üçüncü konvolüsyon	

işleminde oluşan özellik haritası (c) ve dördüncü konvolüsyon işlemi sonucunda üretilen özellik haritası (d) (Kim, 2017'den değiştirilerek)	54
Şekil 33. Sayısal değerlerin özellik haritası olarak gösterimi (URL-15, 2019'dan değiştirilerek)	55
Şekil 34. 4x4'lük bir görüntü matrisi (URL-15, 2019'dan değiştirilerek)	56
Şekil 35. 4x4'lük görüntü matrisine uygulanan maksimum ve ortalama havuzlama sonucu oluşan uzamsal çözünürlüğü düşen görüntü matrisi (URL-16, 2019'dan değiştirilerek).....	57
Şekil 36. Görüntü matrisi çevresinin sıfırlardan oluşan değerlerle doldurma işlemi- Same doldurma yöntemi (URL-16, 2019'dan değiştirilerek).....	58
Şekil 37. İki hücrede bir kaydırma yapılan temsili matris görüntüsü (URL-15, 2019'dan değiştirilerek).....	58
Şekil 38. Normal görüntü ve anlamsal olarak işaretlenmiş (segmente) görüntü (URL- 17, 2019).....	59
Şekil 39. U-NET mimarisi ve sağ altta belirtilen mimari işlem notasyonu (Ronneberger vd., 2015'ten değiştirilerek).....	60
Şekil 40. U-NET mimarisinin kodlayıcı ve kod çözücü aşamalarında gerçekleşen işlemlerin kavram haritası	61
Şekil 41. Harran Ovası ve çalışma bölgesi olarak seçilen araziler (Google Earth, 2019).....	64
Şekil 42. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü 1981-2018 yılları arası sıcaklık değerleri.....	65
Şekil 43. Çalışma bölgesi üzerinde görülen yersel tuzluluk ölçüm noktaları	66
Şekil 44. Ters mesefa ağırlık yöntemiyle enterpole edilerek oluşturulan Harran Ovası yersel tuzluluk haritası.....	67
Şekil 45. Görüntü (a), Görüntünün histogram grafiği (b), Histogram eşitlemesi yapılmış görüntü (c), Histogram eşitlemesi yapılmış görüntünün histogram grafiği (d).....	68
Şekil 46. Eğitim verisi (a), Test 1 (a), Test 2 (b) ve Test 3 (c) görüntüleri	70
Şekil 47. Görüntü üzerinde hesaplanmış NDSI, NDVI, SI, SII indeksleri ve renklendirilmiş haritaları	72
Şekil 48. Eğitim verisi üzerinde seçilen ROI'ler ve yazılıma aktarılmış hali.....	73
Şekil 49. Test verileri üzerinde seçilen ROI'ler ve yazılıma aktarılmış hali	74

Şekil 50. Görüntüye 100 iterasyonda yapılan eğitim işleminin doğruluk ve kayıp grafiği	76
Şekil 51. Görüntüye NDSI eklenerek 300 iterasyonda alınan doğruluk ve kayıp grafiği	76
Şekil 52. Görüntünün herhangi bir indeks eklenmeden 5000 iterasyonda eğitim grafiği verilmiştir. Deneme amaçlı yapılan bu eğitimde 2. Epoktan sonra ağda kayıp neredeyse sıfır olduğundan bir regülarizasyon yöntemi olarak ağın bu aşamada eğitimi durdurulabilir. Bu eğitim işlemiyle ayrıca çok yüksek iterasyonlara gerek duyulmadığı görülmüştür.	77
Şekil 53. U-NET mimarisinin ara katmanları	78
Şekil 54. Bölütme işlemi sonrasında görüntüye uygulanan medya filtresi ile gürültüsü giderilmiş test sonuç görüntüleri.....	82
Şekil 55. Test 1 verisi (<i>a</i>), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>)	85
Şekil 56. Test 2 verisi (<i>a</i>), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>)	86
Şekil 57. Test 3 verisi (<i>a</i>), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>)	87
Şekil 58. Test 1 verisi (<i>a</i>), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	88
Şekil 59. Test 2 verisi (<i>a</i>), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	89
Şekil 60. Test 3 verisi (<i>a</i>), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	91
Şekil 61. Test 1 verisi (<i>a</i>), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	92
Şekil 62. Test 2 verisi (<i>a</i>), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	93
Şekil 63. Test 3 verisi (<i>a</i>), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	95
Şekil 64. Test 1 verisi (<i>a</i>), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (<i>b</i>).....	96

Şekil 65. Test 2 verisi (a), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	97
Şekil 66. Test 3 verisi (a), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	98
Şekil 67. Test 1 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	99
Şekil 68. Test 2 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	100
Şekil 69. Test 3 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	101
Şekil 70. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)	102
Şekil 71. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)	103
Şekil 72. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)	104
Şekil 73. Test 1 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	105
Şekil 74. Test 2 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	106
Şekil 75. Test 3 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	107
Şekil 76. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	108
Şekil 77. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	109
Şekil 78. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b).....	110
Şekil 79. Test 1 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)	111
Şekil 80. Test 2 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)	112

Şekil 81. Test 3 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)	113
Şekil 82. Test 1 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	115
Şekil 83. Test 2 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	116
Şekil 84. Test 3 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	117
Şekil 85. Test 1 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	118
Şekil 86. Test 2 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	119
Şekil 87. Test 3 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	120
Şekil 88. Test 1 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	121
Şekil 89. Test 2 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	122
Şekil 90. Test 3 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	123
Şekil 91. Test 1 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	124
Şekil 92. Test 2 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	125
Şekil 93. Test 3 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	126
Şekil 94. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	127
Şekil 95. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	128
Şekil 96. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)	129

Şekil 97. Test 1 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	130
Şekil 98. Test 2 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	131
Şekil 99. Test 3 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	132
Şekil 100. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	133
Şekil 101. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	134
Şekil 102. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b).....	135
Şekil 103. Test 1 verisi (a), Test 1 verisi SVM sonucu (b), Test 2 verisi (c), Test 2 verisi SVM sonucu (d), Test 3 verisi (e), Test 3 verisi SVM sonucu (f)....	137
Şekil 104. Test görüntülerinin indeks eklemeyen 100 iterasyondaki kullanıcı doğruluk değerleri sütun grafiği.....	138
Şekil 105. Test görüntülerinin indeks eklemeyen 100 iterasyondaki üretici doğrulukları sütun grafiği.....	139
Şekil 106. Test görüntülerinin NDSI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	140
Şekil 107. Test görüntülerinin NDSI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği.....	141
Şekil 108. Test görüntülerinin NDVI bitki indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	142
Şekil 109. Test görüntülerinin NDVI bitki indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği.....	143
Şekil 110. Test görüntülerinin SI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	144
Şekil 111. Test görüntülerinin SI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği.....	145
Şekil 112. Test görüntülerinin SII tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	146

Şekil 113. Test görüntülerinin SII tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği.....	147
Şekil 114. Test görüntülerinin NDSI, SI, SII ve NDVI eklenerek 100 iterasyondaki kullanıcı doğruluk değerleri sütun grafiği.....	148
Şekil 115. Test görüntülerinin NDSI, SI, SII ve NDVI eklenerek 100 iterasyondaki üretici doğruluk değerleri sütun grafiği.....	149
Şekil 116. Test görüntülerinin SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	150
Şekil 117. Test görüntülerinin SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği	151
Şekil 118. Test görüntülerinin NDSI, SI ve SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği.....	152
Şekil 119. Test görüntülerinin NDSI, SI ve SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği.....	153
Şekil 120. Test görüntülerinin indeks eklenmeden 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	154
Şekil 121. Test görüntülerinin indeks eklenmeden 300 iterasyondaki üretici doğrulukları sütun grafiği.....	155
Şekil 122. Test görüntülerinin NDSI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	156
Şekil 123. Test görüntülerinin NDSI eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	157
Şekil 124. Test görüntülerinin NDVI bitki indeksi eklenerek 300 iterasyonda kullanıcı doğrulukları sütun grafiği	158
Şekil 125. Test görüntülerinin NDVI bitki indeksi eklenerek 300 iterasyonda üretici doğrulukları sütun grafiği.....	159
Şekil 126. Test görüntülerinin SI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	160
Şekil 127. Test görüntülerinin SI eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	161
Şekil 128. Test görüntülerinin SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	162

Şekil 129. Test görüntülerinin SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	163
Şekil 130. Test görüntülerinin NDSI, SI, SII, NDVI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği	164
Şekil 131. Test görüntülerinin NDSI, SI, SII, NDVI eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	165
Şekil 132. Test görüntülerinin SI, SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	166
Şekil 133. Test görüntülerinin SI, SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	167
Şekil 134. Test görüntülerinin NDSI, SI, SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği.....	168
Şekil 135. Test görüntülerinin NDSI, SI, SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği.....	169
Şekil 136. Test görüntülerinin indeks kombinasyonlarının 100 iterasyondaki genel doğrulukları sütun grafiği.....	173
Şekil 137. Test görüntülerinin indeks kombinasyonlarının 300 iterasyondaki genel doğrulukları sütun grafiği.....	174

TABLolar DİZİNİ

Tablo 1. % Tuz ve EC değerlerine göre toprak tuzluluk sınıfları (Richards, 1954).....	2
Tablo 2. Bazı sebzeler için eşik EC değeri ve %10, %25 ve %30 değer kaybına karşılık gelen EC değerleri (Karaođlu, 2018).....	4
Tablo 3. RapidEye Uydu Özellikleri	13
Tablo 4. Tuzluluk indeksleri ve bant eşitlikleri.....	16
Tablo 5. Seçilen tuzluluk ve bitki indeksi eşitlikleri	71
Tablo 6. Mimaride kullanılan parametreler ve parametre değerleri	75
Tablo 7. Gerçek ve tahmini değerler arasındaki hesaplanan DP, DN, YP, YN tablosu	83
Tablo 8. Test 1 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (İndeks eklenmeden, 100 iterasyon)	86
Tablo 9. Test 2 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (İndeks eklenmeden, 100 iterasyon)	87
Tablo 10. Test 3 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (İndeks eklenmeden, 100 iterasyon)	88
Tablo 11. Test1 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDSI eklenerek, 100 iterasyon)	89
Tablo 12. Test 2 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDSI eklenerek, 100 iterasyon)	90
Tablo 13. Test 3 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDSI eklenerek, 100 iterasyon)	92
Tablo 14. Test 1 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDVI eklenerek, 100 iterasyon)	93
Tablo 15. Test 2 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDVI eklenerek, 100 iterasyon)	94
Tablo 16. Test 3 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (NDVI eklenerek, 100 iterasyon)	95
Tablo 17. Test 1 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (SI eklenerek, 100 iterasyon)	96
Tablo 18. Test 2 verisine ait etiket sınıflarının Üretici Doğruluđu ve Kullanıcı Doğruluk Deđerleri (SI eklenerek, 100 iterasyon)	97

Tablo 19. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 100 iterasyon)	98
Tablo 20. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)	99
Tablo 21. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)	100
Tablo 22. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)	101
Tablo 23. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)	102
Tablo 24. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)	103
Tablo 25. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)	104
Tablo 26. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)	105
Tablo 27. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)	106
Tablo 28. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)	107
Tablo 29. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)	108
Tablo 30. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)	110
Tablo 31. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)	111
Tablo 32. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)	112
Tablo 33. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)	113
Tablo 34. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)	114

Tablo 35. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon).....	115
Tablo 36. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon).....	116
Tablo 37. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon).....	117
Tablo 38. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)	118
Tablo 39. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)	119
Tablo 40. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)	120
Tablo 41. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)	121
Tablo 42. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)	122
Tablo 43. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)	123
Tablo 44. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)	124
Tablo 45. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)	125
Tablo 46. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)	126
Tablo 47. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon).127	
Tablo 48. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon).128	
Tablo 49. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon).129	
Tablo 50. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon).....	130

Tablo 51. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon)	131
Tablo 52. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon)	132
Tablo 53. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)	133
Tablo 54. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)	134
Tablo 55. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)	135
Tablo 56. U-Net mimarisi kodlayıcı ve kod çözücü katman detayları	183

SEMBOLLER DİZİNİ

y	: Gerçek değer
\hat{y}	: Tahmini değer
λ	: Regülerizasyon katsayısı
w	: Ağırlık
b	: Bias
W	: Ağırlık matrisi
A	: Giriş matrisi
n	: Piksel sayısı/Girdi verisi sayısı
$\sigma(\cdot)$: Sigmoid fonksiyonu
$\mathcal{L}(\hat{y}, y)$: Kayıp fonksiyonu
$J(w, b)$: Maliyet fonksiyonu
δ_i^l	: l katmanının i. düğümündeki hata
θ	: Oto-Kodlayıcı için ağırlık ve bias matrisi
θ'	: Kod-Çözücü için ağırlık ve bias matrisi
R^2	: Korelasyon katsayısı karesi
C4.5	: Decision Tree
BI	: Brightness Index
EC, EC _e	: Electrical Conductivity
SAR	: Sodium Absorbation Ratio
PLS	: Partial Least Squares Regression
LST	: Land Surface Temperature
SMA	: Spectral Angle Mapper
PCA	: Principle Component Analysis
TC	: Tasselep Cap
RMS	: Root Mean Square
MNDWI	: Modified Normalized Difference Water Index
WI	: Water Index
GPS	: Global Positioning System
NDSI	: Normalized Differential Salinity Index
NDVI	: Normalized Difference Vegetation Index

RMSE : Root Mean Square Error
CI : Color Index
CRSI : Canopy Response Salinity Index
SVM : Support Vector Machine
RVI : Ratio Vegetation Index



1. GENEL BİLGİLER

1.1. Giriş

Toprak, içerisinde bulundurduğu organik ve inorganik maddelerle canlı ekosisteminin temel unsurudur. Toprakta verimin düşmesine sebep olacak her bir sorun besin zincirinin en başından sonuna kadar tüm canlı ekosistemini etkiler. Canlı ekosisteminde vazgeçilmez bir unsur olan toprağın verimini düşürecek en büyük çevresel problemlerden biri de toprak tuzluluğudur. Toprak ve kayalarda bulunan mineraller topraktaki tuzluluğun temel sebeplerindendir (Richards,1954). Toprak tuzluluğuna sebep olan bir başka durum ise, kurak ve yarı kurak iklim bölgelerinde toprağın yapısında olan klor (Cl^-), sülfat (SO_4^{+2}), karbonat (CO_3), sodyum (Na^+), kalsiyum (Ca^{+2}), magnezyum (Mg^{+2}) ve potasyum (K^+) gibi anyon ve kationların birleşmesiyle oluşan tuzların yeraltı sularına karışıp çözünmesidir. Oluşan bu tuzlar yüksek taban suyuyla birlikte çözünmüş olarak toprak yüzeyine çıkar ve taban suyunun buharlaşması sonucu toprağın yüzeyinde birikir. Tuzlu topraklar genel olarak, bitkinin kök bölgesinde oluşan tuzları, yıkayacak miktarda yağış almayan kurak ve yarı kurak iklim bölgelerinde görülür. Tuzlu toprak bölgelerinde, yetiştirilen ürünlerin gelişimi, kök bölgesinde biriken tuzlar tarafından engellendiğinden bitki gelişimi yavaşlar. Bitki gelişiminin yavaşlaması, kök bölgesinde biriken tuz miktarının bitkinin tuza olan direnç sınırını aşması durumunda gerçekleşir (American Society of Civil Engineers,1990; Karim ve ark.1990; Somani,1991).

Toprakta meydana gelen tuzluluk, birincil ve ikincil olmak üzere iki çeşittir. Birincil toprak tuzluluğu doğada kendiliğinden meydana gelen tuzluluktur. Tuz gölleri ve tuz bataklıkları buna örnek olarak verilebilir. İkincil toprak tuzluluğu ise insan faaliyetlerinden kaynaklı tarım ve sulama gibi nedenlerle meydana gelen tuzluluktur (URL-1). Tarım arazilerinde bilinçsiz sulama ve drenaj yetersizliği ikincil toprak tuzluluğunun en önemli sebeplerindendir.

Toprak tuzluluğunun oluşmasında etkili olan diğer önemli faktörlere bakıldığında ise bunların, düşük yağış, çevresine göre çukur topografik yapı, yüksek taban suyu ve yüksek buharlaşma olduğu görülür (Çullu, 2011).

Toprak tuzluluğu, topraktan alınan örneklerle yapılan analizler sonucunda % tuz ve elektriksel iletkenlik (EC/EC_e) ile belirlenmektedir. Topraktaki tuzluluğun belirlenmesi için araziden alınan yaklaşık 500 gr bozulmuş toprak örneği plastik veya bez torbalara konularak

laboratuvar koşullarında kurutulur. Kurutulan örnekler iki mm'lik elekten geçirilir ardından saturasyon çamuru kabına konur. Saturasyon çamuru hazırlandıktan sonra tuzluluk, saturasyon çamurundan vakumla alınan ekstraktan ölçülür. Ayrıca toprak tuzluluğu laboratuvar ortamının dışında pratik olarak arazide doğrudan EC-Probe tuz ölçer aletiyle ve EM-38 cihazıyla da belirlenebilmektedir (Çullu, 2011).



Şekil 1. EC-Probe ve EM-38 Tuz Ölçüm Cihazı (URL-1 ve URL-2)

Birçok bitki çeşidi, toprak saturasyon ekstraktının elektriksel iletkenliği (EC) 2 dS/m'yi (desisimens/metre) geçtiğinde zarar görmeye başlar. Topraktaki tuz miktarı arttıkça, toprak çözeltisinde ölçülen EC değeri de artmaktadır (Çullu, 2011). EC değeri 4 dS/m'den daha fazla olan topraklarda tuzluluk problemi başlar (Richards, 1954). Topraktaki tuzluluğa hassas bitkilerin maksimum 1.5 dS/m EC değerine kadar dayanabildikleri, EC değeri 8 dS/m'e çıktığında verimin sıfıra indiği, dayanıklı bitkilerde ise 10 dS/m'ye kadar verim kaybının olmadığı görülmüştür (Maas, 1985).

Tablo 1. % Tuz ve EC değerlerine göre toprak tuzluluk sınıfları (Richards, 1954)

Elektriksel İletkenlik (EC) (dS/m)	Çözünebilir Tuz (%)	Tuzluluk Dereceleri
0-2	0-0.15	Tuzsuz
2-4	0.15-0.35	Hafif Tuzlu
4-8	0.35-0.65	Orta Tuzlu
8-15	>0.65	Şiddetli Tuzlu

Tuzluluk derecelerinin bilinmesi, tuzlu bölgelerde bitki gelişiminin izlenmesi ve tuzluluğun iyileştirilmesi açısından önemlidir. Ayrıca bitki deseninin belirlenmesini sağlar.

Toprak tuzluluğunun bitkiler üzerindeki etkilerine bakıldığında topraktaki bazı iyonların bitkiler üzerinde doğrudan toksik etki yarattığı, hücrede iyon dengesizliğine ve osmotik basıncın düşmesine sebep olduğu görülmektedir (Cramer ve Lauchi,1986). Buna bağlı olarak bitki kök gelişimi ve fonksiyonları engellenir. Ayrıca sodyum, potasyum ve kalsiyum oranının artışı membran kalitesini etkiler ve hücre ölümüne sebep olur (Cuartero vd., 1992).

Tuzluluk, içinde bulunduğu hücrede su kaybına sebep olduğundan turgor basıncı azalır. Turgor basıncı bitki hücresindeki suyun hücre çeperine yaptığı basınçtır. Bitkinin gaz alışverişi ise stomalar aracılığıyla sağlanır. Stomaların açılıp kapanması turgor basıncı ile ilgilidir. Hücrede turgor basıncı azaldığından, stomalar kapanır ve gaz alışverişi sağlanamamış olur. Böylece bitkide fotosentez yapımı azalır. Bunun sonucu olarak hücre bölünmesi ve gelişimi olumsuz etkilenir (Shannon, 1997).

Bitkiler büyüme mevsiminin değişik zamanlarında tuzluluktan farklı ölçüde etkilenebilir. Bitkinin tuza olan direnci bitki gelişme döneminin son evrelerine doğru artar. Genellikle bitkiler ilk ekim ve gelişme dönemlerinde tuza karşı çok duyarlıdır. Tuzluluk, çimlenme fizyolojisi üzerinde de etkili olmaktadır. Su alımı ve iletimi kısıtladığından çimlenme için uygun koşullar oluşamaz. Ayrıca toksik iyonların embriyoya girmesi çimlenmeyi olumsuz yönde etkilemektedir (Hilhorst ve Toorop, 1997).

Tuzluluğun önemli etkilerinden bir diğeri de toprak içerisinde yaşayan mikroorganizmaların yüksek düzeydeki tuzluluk nedeniyle varlıklarını sürdürememeleridir. Çünkü tuzluluk bu mikroorganizmaların çoğalmalarını olumsuz yönde etkiler. Bunun sonucunda toprakta temel organizma dönüşümleri ve parçalanmaları olmadığından topraktaki elementlerin bitkiye katılımı gerçekleşmez (Sönmez, 2003).

Hızla artan tuzluluk tarımsal üretimi olumsuz yönde etkiler. Tuzluluk şiddeti arttıkça verim kaybı artar. Örneğin, toprak tuzluluğu sonucu Harran Ovası'nda üretilen pamuk ve buğdayda meydana gelen ekonomik kayıp 4.811.347 Türk lirasıdır (Topaloğlu, 2006). Ek olarak, pamuk üretiminde verim kaybı, hafif tuzlu topraklarda 840 kg/ha iken orta tuzlu topraklarda 1.040 kg/ha, şiddetli tuzlu topraklarda ise 1.700 kg/ha'dır (Topaloğlu, 2006). Ayrıca, domates yetiştiriciliğinde, tuz konsantrasyonunun 2.5 dS.m⁻¹ 'den 3.5 dS.m⁻¹ 'ye çıkmasıyla üründe %10 kayıp; 5 dS.m⁻¹ 'ye çıkmasıyla üründe %25 ve 7.6 dS.m⁻¹ 'ye çıkmasıyla üründe %50 oranında azalma olduğu belirlenmiştir (Kotuby-Amacher vd., 2007).

Tablo 2. Bazı sebzeler için eşik EC değeri ve %10, %25 ve %30 değer kaybına karşılık gelen EC değerleri (Karaoğlu, 2018)

Bitki	Eşik Değeri	Topraktaki EC Miktarı		
		Ürün Kaybı (%)		
		10	25	30
Domates	2.5	3.5	5.0	7.6
Biber	1.3	2.2	3.3	5.1
Ispanak	3.7	5.5	7.0	8.0
Marul	1.3	2.1	3.2	5.2
Havuç	1.0	1.7	2.8	4.6
Patates	1.7	2.5	3.8	5.9

Bitkilerin tuza karşı toleransı aşağıdaki eşitlikle tahmin edilebilmektedir (Maas ve Hoffman, 1977).

$$\rho/\rho_m=100-\beta (EC_e-\alpha) \quad (1.1)$$

ρ/ρ_m =Nispi ürün (%)

ρ_m =Maksimum ürün

EC_e =Toprak saturasyon ekstraktının elektriksel iletkenliği ($dS m^{-1}$)

α =Bitkide tuzluluktan dolayı ürün kaybının başladığı eşik değeri

β =Artan her EC birimine karşı bitkideki ürün kaybı (%)

1.2. Literatür Çalışması

Toprak tuzluluğu ile ilgili yapılan ulusal ve uluslararası literatür çalışmaları incelenmiştir. Yapılan çalışmalara bakıldığında;

Eklund, vd., (1998) Güney Avusturya'nın Adelaide ve Jamestown bölgesinde tuz yönetimini sağlamak için yaptıkları çalışmada, EM31 cihazıyla 894 EC örneği toplamıştır. IB1 (Instance Based Learning), IB2, MPIL (Multi-Pass Instance Learning), geri yayılım ve C4.5 yöntemleri kullanılmıştır. IB1 ve IB2 algoritmaları, tek parametrelilik en yakın komşuluk örüntü sınıflandırıcılarıdır. Ancak IB2 algoritması yanlış örnekleri de kaydeder ve gürültüye daha duyarlıdır. MPIL k-boyutlu bir özellik sınıflandırıcısıdır. IB1, IB2 ve MPIL algoritmaları ile EM31 tuzluluk verileriyle yapılan sınıflandırmada sırasıyla %60.1, %56.9, %85.2 doğruluk bulunmuştur. Bir makina öğrenmesi yöntemi olan geri yayılım yönteminde

iki farklı aktivasyon fonksiyonu kullanılmıştır. Sigmoid aktivasyon fonksiyonu ile yapılan sınıflandırma sonucunda %82.4, hiperbolik tanjant aktivasyon fonksiyonunda %80.1 sınıflandırma performansı elde edilmiştir. Ayrıca geri yayılım yönteminde gizli katman sayısının artırılmasıyla sınıflandırma doğruluğunun %90.6 'ya çıktığı görülmüştür. Bir veri madenciliği yöntemi olan C4.5 karar ağacı yöntemiyle yükseklik, Landsat TM Band 4, toprak, eğim, yeraltı suları kriter olarak belirlenmiştir. C4.5 yöntemiyle yapılan işlem sonucunda %94 doğruluk elde edilmiştir. Tuz yönetiminin %50 fazla performans sağladığı ve en iyi öğrenme eğrisinin C4.5 algoritması ile olduğu belirtilmiştir.

Abbas, vd., (2007) Pakistan District of Faisalabad'ta 1992, 1993, 1994 ve 1995 yıllarına ait IRS-1B uydusuna ait LISS-II görüntülerini kullanmıştır. 70 noktadan EC ve SAR (Sodyum Absorbe Oranı) örnekleri alınmıştır. Görüntüler üzerinde tuzluluk indeksleri (bant oranlaması) ve temel bileşen analizi (PCA) yapılmıştır. PCA dönüşümüyle elde edilen birinci bileşen değerleri 1992, 1993, 1994 ve 1995 yılları için sırasıyla %77.3, %80.1, %73.9 ve %88.3'tür. Tuzluluk indeksleri ile EC değerleri arasında yapılan regresyon ile en yüksek korelasyon S3 tuzluluk indeksinde görülmüştür. En çok olabilirlik (Maksimum Likelihood) metoduyla yapılan sınıflandırma da %90' dan yüksek doğruluk bulunmuştur.

Bannari, vd., (2008) Fas'ın Tadla bölgesinde Earth Observing-1 Advance Land Imaging (EO-1 ALI) görüntüsü kullanmıştır. Çalışma bölgesinden toplanan toprak numunelerinden EC ve pH değerleri ölçülmüştür. Tuzluluk indeksleri ve yersel ölçümler ile tuzluluğu tespit etmeye çalışmıştır. Ayrıca toprağın spektral yansıtımına bakılmıştır. Sonuç olarak SWIR (kısa dalga kızılötesi) bandının tuzlu ve sodik alanları yansıtma iyi bir indikatör olduğu belirtilmiştir.

Goldshleger, vd., (2013) İsrail'in Jezreel vadisinde tuzlu su kullanımından dolayı oluşan toprak tuzluluğunu tespit etmek için yansıtım spektroskopisi yöntemini kullanmıştır. Tuzlu toprakta yetişen domatesteki ve domates yaprağındaki Na^+ veya Cl^- içeriğini belirlemek için toprağın yansıtım spektrometresine bakılarak PLS (Partial Least Squares Regression) yöntemi ile R^2 değerleri Na^+ ve Cl^- iyonları için sırasıyla 0.51 ve 0.59 olarak ölçülmüştür.

Masoud, (2014) yaptığı çalışmada Mısır Burc El Arab bölgesinde Landsat ETM+ görüntüsü ile yer yüzey sıcaklığı (Land Surface Temperature), karışım ayarlı eşleme filtresi (Mixture Tuned Matched Filtering), sululuk indeksi (WI), spektral karışım analizi (Spectral Mixture Analysis) ve spektral açı haritalama (Spectral Angle Mapper) yöntemlerini 2003 ve 2010 yıllarına ait görüntülere uygulamıştır. MTMF, LSU ve WI yöntemleri tuzlulukla lineer

ilişki gösterip korelasyon değerleri sırasıyla $R^2 = 0.88, 0.84$ ve 0.87 bulunmuştur. Tuzluluğun toprak yansıtımıyla güçlü negatif korelasyonlu olduğu ve korelasyon katsayısının uzun dalga boylarında arttığını söylemiştir. Çalışma alanından toplanan 21 örnekle uygulanan yöntemler arasındaki ilişkiye bakılmıştır.

Moreira, vd., (2015) yılında Brezilya'nın Morada Nova bölgesinde pirinç hasadı yapılan yarı kurak alanda 12 Eylül 2013 tarihli Landsat OLI görüntüsü ile 3 Ekim 2013 tarihli tuzu absorbe eden bantların (1400-1900 nm) kaldırıldığı Hyperion görüntüsü ve 0-15 cm derinlikten toplanan 53 (24 tuzlu, 29 tuzsuz) EC örneği kullanmıştır. Landsat 8 görüntüsü üzerinde Spectral Mixture Analysis (SMA) yöntemiyle tuzdan etkilenen alanlar bulunmuştur. Landsat 5 ve Hyperion görüntüleri ile 1984-2011 yılları arasında NDVI değişimine bakılmıştır. Landsat 8 ve Hyperion görüntüleri üzerinde Salinity Index I ve II (SI, SII), parlaklık indeksi (Brightness Index), NDSI (Normalized Differential Salinity Index) ve COSRI (Combined Spectral Response Index) indekslerini kullanarak PCA uygulanmıştır. Buradan çıkan PCA₁ bileşeni ile tuzluluk indeksleri ve EC değerleri arasında regresyon ilişkisi kurulmuştur. SAM (Spectral Angle Mapper) ve öklid mesafesi (Euclidean Distance) metrikleri ile Hyperion görüntüsü Landsat OLI'ye göre tuzluluğun ayırt edilmesinde daha iyi sonuç vermiştir. Kappa indisi ve genel doğruluğa bakıldığında OLI görüntüsü Hyperion görüntüsüne göre daha düşük değer vermiştir. Tuzlu ve tuzsuz alanların ayrımı SVM (Support Vector Machine) ile test edilmiştir. Sonuç olarak SMA ve NDVI zamanla artan vejetasyon alanına rağmen düşük bir ortalama ve standart sapma sonucu vermiştir.

Nurmemet, vd., (2015) Sincan Uygur Özerk Cumhuriyeti Keriya Nehri havzasında Landsat ve Palsar görüntülerini kaynaştırıp SVM sınıflandırma algoritmasıyla tuzlu alanları sınıflandırmıştır. Radarsat-2 ve Palsar görüntülerinin gerisaçılım katsayı değişimiyle toprak tuzluluğunun ilişkisi olup olmadığına bakılmıştır. Çok kanallı optik ve SAR görüntülerinin entegrasyonu ile karar ağacı sınıflandırması toprak tuzluluğu tespitinin geliştirilmesi için önerilmiştir. ETM+ ve Palsar görüntülerinin SVM için doğruluğu %91.25 ve kappa katsayısı 0.89 bulunmuştur. Karar ağacının eklenmesi ile bu doğruluk %93.01 ve kappa katsayısı 0.92 bulunmuştur. MNDWI (Modifiye Edilmiş Normalize Fark Su İndeksi) ve SI tuzluluk indeksleri hesaplanmıştır. Aktif ve pasif mikrodalga uzaktan algılamanın toprak tuzluluğu tespitinde iyi sonuç verdiği belirtilmiştir.

Zeduw, vd., (2015) Etiyopya Arba Minch bölgesinde Landsat TM verisinin 1984, 1995 ve 2010 yıllarına ait görüntüleri kullanarak geliştirdiği geospatial tool ile EC_e ve NDSI değerleriyle yaptığı regresyon analizinde % 67.3 ilişki hesaplamıştır.

Yahiaoui, vd., (2015) Cezayir Lower Cheliff ovasında yaptıkları çalışmada 2013 yılına ait Landsat 7 görüntüsü ve ilgili yerin ASTER GDEM (Version 2) 30 m DEM verisi kullanılarak NDVI (Normalize Fark Bitki İndeksi), RVI (Oransal Bitki İndeksi), parlaklık indeksi (BI), CI (renk indeksi) ve tuzluluk indeksleri hesaplamıştır. İndeks değerleri ile yüzey topografyası arasındaki ilişki incelendiğinde özellikle EC değerinin 8 dS/m olduğu alanlarda tuzluluğun yükseklikle korelasyonlu olup eğimle bir ilişki göstermediği belirtilmiştir. Ayrıca SASI adlı yeni bir tuzluluk indeksi önermişlerdir. EC, yükseklik ve yeni önerilen tuzluluk indeksi ile çoklu lineer regresyon analizi yapıp % 45 oranında doğru tahmin gerçekleştirmişlerdir.

Asfaw, vd., (2016) Etiyopya'nın Wonji şeker kamışı sulama çiftliğinde tuzluluk değerleri (EC_e) ve bitki indekslerini kullanmışlardır. Özellikle SI indeksi ile EC_e değerleri arasında yüksek korelasyon bulup $R^2 = 0.78$ olarak hesaplamışlardır.

Rahmati, vd., (2016) ETM+ görüntüleri üzerinde NDVI, NIR/SWIR1 bant oranlaması ve farklı veri azaltma algoritmaları olan fark veri azaltma (different data reduction algorithms), temel bileşen analizi (PCA), minimum gürültü oranı (MNF), saf piksel indeksi (PPI) ve n-boyutlu görselleştirici (nDV) algoritmalarını kullanmışlardır. 188 noktadan alınan EC örneği ile çoklu regresyon analizi yapılmıştır. En iyi sonucun NDVI değeri ile alındığı görülmüş ve $R^2=0.875$ bulunmuştur.

Alexakis, vd., (2016) Yunanistan Timpaki bölgesinde Worldview-2 ve 2015 Landsat-8 görüntüsü kullanarak NDVI, RDVI, Green NDVI, SR, EVI bitki indeksleri ve tuzluluk indeksleri kullanarak PCA, ortogonal transform analizi (OTC) ve toprak özelliklerini kullanarak bir model oluşturmuşlardır. Modelin EC ile ilişki değeri $R^2=0.6-0.65$ 'tir. Tuzlu ve tuzdan etkilenmeyen alanları belirlemek için öklit ve manhattan mesafeleri kullanılmış, Worldview görüntüsü için NIR2/R2 şeklinde tuzluluğu tespit edici indeks geliştirilmiştir.

Elhag, (2017) Arabistan'nın Wadi Al Dawasir bölgesinde zeminden 100 metre aralıklarla alınan 150 örnek ile 2014 yılı Landsat-OLI görüntüsü üzerinde Normalize Edilmiş Fark Tuzluluk İndeksi (NDSI), parlaklık indeksi (BI) ve SI, SI-2, SI-3, SI-4, SI-5, SI-6, SI-7, SI-8, SI-9 tuzluluk indekslerini kullanarak zeminden alınan örneklerle lineer regresyon modeli kurmuştur. SI-9'un diğer indekslere nazaran yersel verilerle daha güçlü lineer ilişki kurduğunu belirtmiştir.

Whitney, vd., (2018) Kaliforniya San Joaquin vadisindeki tarım arazilerindeki tuzluluk tespiti için MODIS görüntüsünde Enhanced Vegetation Index (EVI), NDVI, CRSI (Canopy Response Salinity Index) ve Savitzky–Golay (SG) filtresi uygulamışlardır. 2007-2013 yılları arasındaki zamansal değişime bakarak 267 EC değeri ile kurulan lineer regresyon analizinde $R^2=0.93$ olarak bulunmuştur. Toprak tuzluluğu indekslerinin yansıtım sırasının $CRSI > NDVI > EVI$ olduğu belirtilmiştir.

Peng, vd., (2018) Çin'in Sincan bölgesinde Haziran 2016'da 225 adet EC örneği toplamıştır. Aynı tarihli Landsat 8 görüntüsüne PCA ve Tasseled Cap (TC) dönüşümü uygulamışlardır. EC ve Tasseled Cap dönüşüm öznitelikleri arasında (Piecewise Linear Regression Splines (PLRS) ve kübik yöntemi kullanarak bir ilişki kurmuşlardır. Kurulan kübik ilişkide R^2 , RMSE, MAE ve RPD ölçütleri sırasıyla 0.91, 5.18 dSm⁻¹, 3.76dSm⁻¹ ve 3.15 bulunmuştur. PLSR modeli için de R^2 , RMSE, MAE ve RPD değerleri 0.66, 10.46 dSm⁻¹, 8.21 dSm⁻¹ ve 1.56 bulunmuştur.

Taghadosi, vd., (2019) İran'nın Kuh Sefid bölgesinde Sentinel-2A görüntüsü ile tuzluluk indeksleri ve yüzey sıcaklık değerleri ile oluşturulan modelde çoklu regresyon ve destek vektör makineleri kullanarak tuzluluğu tespit etmişlerdir. EC değerleri ile uydu yansıtımı arasında kurulan regresyon analizi ile $R^2=0.8742$ ve RMSE=5.1962 bulunmuştur.

Taghadosi, vd., (2019) çift polarize Sentinel SAR görüntüsü kullanarak İran Kuh Sefid bölgesinde yapılan çalışmada, SAR görüntülerinde toprağın tuzluluk geri yansıtımı ile ilgili teorik bilgi olmadığından tuzluluğu tespit için radar yoğunluğu ile ilişkili model ileri sürmüşlerdir. SVM, genetik algoritma özellik seçim yöntemleri ve ardışık özellik seçimi yöntemi kullanılmıştır. $R^2 = 0.9783$ ve RMSE = 0.3561 bulunmuş olup GFO; VV ve RVH'nin tuzluluk tespitinde en iyi sonucu verdiği belirtilmiştir.

1.3. Problemin Tanımı

Harran Ovası topografik olarak çevresine göre çukur bir konumdadır. Bu nedenle sulama sonucu biriken fazla suyun tahliye edilmesini zorlaştırmaktadır (Dinç ve ark.,1988; Aydemir ve ark.,2005). 1995 yılında Atatürk Barajı'ndan getirilen suyla, sulu tarım başlamıştır. Ovanın topografik yapısından dolayı sulama sonucu kalan fazla su, güneye doğru akar. Drenaj sisteminin yetersizliğinden dolayı zaman içinde taban suları toprak yüzeyine çıkmaya başlamış ve yüksek buharlaşma sonucunda tuz konsantrasyonu toprak yüzeyinde artmıştır. Uzun süre çok yüksek konsantrasyonlarda tuz içeren bu taban suları ve

devam eden sulamalar neticesinde toprak yüzeyinde çok fazla tuz birikmiştir. Böylece Harran Ovası'nın güney kesimlerinde tuzlu alanların artmasına neden olmuştur (Çullu vd., 2000).



Şekil 2. Harran Ovası'nda görülen tuzluluk (URL-3, 2019)

Aşırı su kullanımı ya da yağma sulamada diyebileceğimiz bilinçsiz sulamalarda Harran Ovası'nın güney kesimlerinde taban suyunun yükselmesine sebep olan bir diğer etkidir (Ağca,1995; Özgür vd., 2001). Harran Ovası'nda tuzluluk başlangıcının en temel faktörlerden biri ise 1978 yılından sonra ova güneyinin yüksek miktarda tuz içeren yeraltı pompaj sularıyla sulanmasıdır. Tuzlu pompaj sularının doğrudan sulamada kullanılması, topraktaki tuz konsantrasyonunu ve taban suyu seviyesinin de artmasına neden olmuştur (Çullu, 2011).

Yeterli önlemler alınmadığı sürece ovada tuzluluğun şiddeti ve tuzluluk alanlarının artışının devam etmesi kaçınılmazdır. Ova geneline bakıldığında artan taban suyu ve tuzluluktan dolayı bitki veriminde de önemli kayıplar meydana gelmektedir (Çullu, 2003). Bu durum tarım arazilerinin veriminin düşmesine sebep olmuştur.

1.4. Çalışmanın Amacı

Dünyada tarım yapılabilen yaklaşık 1.5×10^9 hektar alanın %23'ü tuzlu ve %37'si sodik topraklardan oluşur (Szabolcs,1989). Her yıl tarım arazilerinden toprağa 300.000 ton tuz eklenmektedir (Bıggar vd., 1984).

Türkiye'de sulamaya uygun 12.5 milyon hektarlık arazi vardır. Bu arazilerin 1.5 milyon hektarında tuzluluk ve alkalilik, 2.8 milyon hektarında ise drenaj problemi bulunmaktadır (Güngör ve Erözel,1994). Bu durum, Türkiye'de sulamaya uygun arazilerin yaklaşık %32.5'inde tuzluluk, alkalilik ve drenaj sorunlarının olduğunu göstermektedir (Kanber ve ark., 2005).

Dünya'nın birçok yerinde tarım arazileri tuzluluktan dolayı verimsiz hale gelmektedir. Yeniden meydana gelebilen ve uzun süre çevresel problemlere sebep olan tuzluluk, yıllar içerisinde tarım arazilerinin çoraklaşmasına sebep olur. Artan nüfusla birlikte küresel besin ihtiyacının karşılanması ve endüstrileşen dünyada birçok ürünün ham maddesi olan ticari bitkilerin yetiştirilmesi toprak tuzluluğu nedeniyle zorlaştığından toprak tuzluluğu yerel ve global çapta birçok ekonomik ve sosyal sorunu beraberinde getirmektedir. Bu nedenle, tuzluluk probleminin olduğu alanlarda tuzluluğa çözüm bulmak için tuzluluk şiddeti ve ürünlerdeki azalmanın izlenmesine ihtiyaç vardır (Mikati,1997). Uzaktan algılama prensipleri ile uydu görüntüleri üzerinde bu problemin izlenmesi özellikle geniş alanlarda zaman ve maddi anlamda büyük kazanç sağlayacaktır.

Türkiye'nin en büyük ve verimli ovalarından biri olan Harran Ovası'nda aşırı sulama ve yüksek taban suyu sebebiyle yıllar içinde toprakta tuzlulaşma meydana gelmiştir. Tuzlulaşma nedeniyle ovanın özellikle güney kısımlarında yani Suriye sınırına yakın tarım arazilerinde ciddi tuzlulaşma görülmüştür. Bugün tuzlulaşan bu alanlardan bir kısmı tamamen verimliliğini yitirmiştir ve belediye çöp depolama alanı olarak kullanılmaktadır. Ayrıca, tuzlulaşma ile ovada verim kaybı yaşanmış olup çiftçiler için emek kaybına, GAP kalkınma ajansı içinde bölge halkına uzun yıllar iş sahası oluşturması ve istihdam sağlaması için planlanan ve desteklenen projenin olumsuz etkilenmesine sebep olmuştur. Bu tez çalışmasıyla ovanın tuzluluktan etkilenmiş alanlarının uydu görüntüsü ile uzaktan algılama yöntemleri kullanılarak tespit edilmesi amaçlanmıştır. Bu doğrultuda tuzlulaşan alanların izlenmesi ve zamanla oluşabilecek yeni tuzlu alanların tespitinin kolaylaşmasını sağlanacaktır. Tuzlulaşmanın en şiddetli görüldüğü 2010 yılında Harran Üniversitesi Ziraat Fakültesi'nden bir ekip GAP kalkınma ajansının destekleriyle ovanın çeşitli noktalarından

toprak numuneleri alarak ovanın tuzluluk haritasını oluşturmuştur. Ovadan numuneler alınarak bu işlemin yapılması için çok ciddi zaman ve insan kaynağı gerekir. Yapılan işlemin tamamlanması aylar alabilmektedir. Çelik ve Gülersoy (2013) ovada meydana gelen tarımsal değişimleri incelemek için normalize edilmiş fark bitki indeksi (NDVI) ile uydu görüntüleri üzerinde değişim belirlemiştir. Ancak ovada uydu görüntüleri kullanılarak tuzluluk tespiti için daha önce bir çalışma yapılmamıştır. Ulusal ve uluslararası yapılan literatür çalışmalarına bakıldığında derin öğrenme yöntemi kullanılarak yapılan bir tuzluluk tespit çalışması görülmemiştir. Tuzluluğu belirlemek için literatürde kullanılan tuzluluk indekslerinin yanı sıra, görüntünün semantik olarak bölütlenmesini sağlayan derin öğrenme yöntemi kullanılmıştır. Bu doğrultuda yapılan tez çalışmasıyla hem yerel bazda ova için hem de global çapta önemli bir örnek çalışma sağlayacaktır. Böylelikle büyük alanlarda tuzluluğun tespiti ve izlenmesinin kolaylaşması, zaman ve emek anlamında kazanç sağlaması hedeflenmiştir.

1.5. Metodoloji

Harran Ovası'nda tuzlu arazilerin tespit edilmesi için yapılan çalışma metodolojisi şu şekilde sıralanabilir:

- RapidEye (5 m) orta yüksek çözünürlüğe sahip uydu görüntüsü çalışma bölgesine uygun olarak kesilmiştir.
- Görüntü üzerinde histogram eşitlemesi ön işlemi yapılmıştır.
- Literatürde en çok kullanılan tuzluluk indeksleri NDSI, SI, SII ve normalize edilmiş fark bitki indeksi (NDVI) uydu görüntüsü üzerinde hesaplanmıştır.
- Hesaplanan indekslerin her biri ayrı bir spektral bant olacak şekilde görüntüye eklenmiştir. Ayrıca bu indekslerin birbirleri ile farklı şekillerde kombinasyonları yapılmış ve yine görüntüye eklenmiştir.
- Yersel tuzluluk değerleri (EC) kullanılarak, ovanın ters mesefa ağırlık (IDW) enterpolasyon yöntemiyle tuzluluk haritası yapılmıştır.
- Uygulama görüntüsü eğitim ve test görüntüsü olarak bölünmüştür.
- Tuzluluk sınıfları ve arazi üzerinde olan diğer sınıflar belirlenmiştir. Tuzluluk ölçümleriyle oluşturulan tuzluluk haritası referans alınarak eğitim ve test görüntüsü üzerinde her bir etiket sınıfını temsil eden spektral imzalar (ROI) toplanmıştır.
- Görüntü bir derin öğrenme yöntemi olan konvolüsyonel yapay sinir ağı (CNN)

kullanılarak semantik olarak bölütlenmiştir. Bunun için piksel tabanlı bir görüntü bölütleme mimarisi olan U-NET mimarisi kullanılmıştır.

- Sınıflandırma sonrası doğruluk değerlendirmesi için bölütlenmiş görüntülerin hata matrisi oluşturularak genel doğruluk hesaplanmıştır. Bu işlemler MATLAB ortamında gerçekleştirilmiştir.
- Farklı şekillerde kombinasyonları yapılarak görüntüye eklenen indekslerin bölütleme sonucunda çıktılarını irdelenmiştir.

1.6. RapidEye Uydu Özellikleri

Uzaktan algılama, arada mekanik bir temas olmaksızın cisimden yayılan veya yansıyan elektromanyetik ışınımın nitelik ve nicelik yönünden değerlendirilerek cismin özelliklerinin ortaya konması ve ölçülmesidir (Örmeci,1987). Uzaktan algılamada, cisimle elektromanyetik enerji arasındaki etkileşimi kaydeden uydu ve uçaklardan elde edilen görüntü ve ilgili veriler toplanır, işlenir ve yorumlanır. Bu işlem sırasında yeryüzündeki objelerin yaydığı veya yansıttığı elektromanyetik enerjinin yoğunluğu ölçülür ve enerji yayma ve yansıtma karakteristiğine göre objenin özellikleri bilinmeye çalışılır (Özkan, 2001).

Görüntü bir düzlemde ışınımın konumsal dağılımıdır. Bilgisayarlar sürekli görüntüleri (analog görüntü) işleyemezler. Bilgisayarlarda görüntü noktanın iki boyutlu dizesiyle ifade edilir. Bu iki boyut da ifade edilen noktaların oluşturduğu karesel gridlere piksel ya da pel denir (Jähne,1991). Sayısal görüntü iki boyutlu bir fonksiyon $f(x, y)$ ile tanımlanabilir. $f(x,y)$ fonksiyonunun parametreleri olan x ve y konum (düzlem) koordinatlarıdır. Bu koordinatlar resim elemanı pikselin resim üzerindeki konum değeridir. $f(x,y)$ fonksiyonunun sonucu resimdeki o noktadaki pikselin yoğunluk veya gri düzeyidir (Woods, 2008). Üçüncü boyuta sahip görüntülere voksel denir.

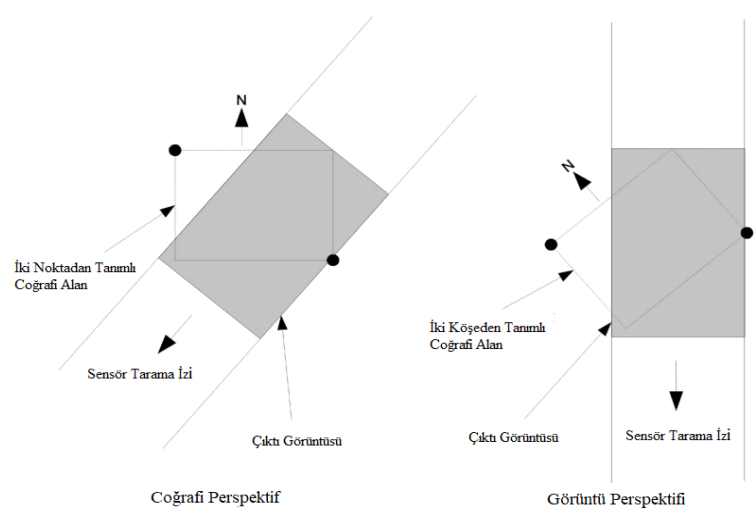
Uydu görüntüleri mekânsal (uzamsal), spektral, radyometrik ve zamansal olmak üzere 4 farklı çözünürlüğe sahiptir. Uydu algılayıcı sistemlerde sensörlerin konumsal çözünürlüğü anlık görüş alanı (IFOV) ile belirlenir. IFOV, sensörün açısal görünürlük konisidir ve Dünya yüzeyinde belirli bir zamanda belirli bir yükseklikten görülen alanı ifade eder. Görüntülenen alanın boyutu, IFOV'un yerden sensöre olan mesafesiyle çarpılarak belirlenir. Yerdeki görüntülenen bu alan çözünürlük hücresi olarak adlandırılır ve bir sensörün maksimum uzamsal çözünürlüğünü belirler. Algılayıcı sistemler yersel örneklem aralığı (GSI) ve

yeryüzü anlık görüş alanı (GIFOV) eşit alınarak tasarlanır. Dolayısıyla uydu görüntülerinde konumsal çözünürlük algılayıcı sistem sensörünün IFOV'un açısal karşılığı olan GIFOV ile belirlenir. Örneğin Sentinel-2 uydu görüntüsünün 2. bandı 10 metre konumsal çözünürlüğe sahiptir. Spektral çözünürlük, algılayıcı cihazın elektromanyetik spektrumunda algılayabildiği aralığı ve sayısını ifade eder. Radyometrik çözünürlük, bir uydu veya sensörün her bir bantta aldığı parlaklığı ne kadar iyi böldüğüdür. Radyometrik çözünürlük arttıkça, sensörün ayırt edebildiği ve kaydedebildiği ışınım yoğunluk aralığı da artar. Radyometrik çözünürlük tipik olarak her bir bant için bit sayısı olarak ifade edilir. Yeni sensörler (Landsat 8 gibi) 12-bit radyometrik çözünürlüğe sahiptir. Görüntünün radyometrik çözünürlüğü hangi aralıkta gri seviye değer alacağını belirler. Bu değer 2^n-1 ile belirlenir, n burada bit sayısıdır. Örneğin 16 bit radyometrik çözünürlüğe sahip Rapideye görüntüsü 2^{16} yani 65,536 adet [0-65,535] aralığında gri seviye değer alır. Görüntünün radyometrik çözünürlüğünü artırmak için sinyal/gürültü oranına bakılmalıdır (Özkan, 2001).

PlanetScope/Rapideye uydu takımı günde 6 milyon metre kareden fazla veri toplayabilen 5 uydu takımından oluşmaktadır. Her bir uydu 150 kg ağırlığındadır. Beş uydu da aynı sensörlerle donatılmış olup aynı yörünge düzleminde bulunmaktadır. Uydulara ait diğer özellikler Tablo 3.'te verilmiştir.

Tablo 3. RapidEye Uydu Özellikleri


RapidEye Uydu Özellikleri	
Uydu Sayısı	5
Yörünge Yüksekliği	Güneş senkronize yörüngeli 650 km
Ekvator'dan Geçiş Zamanı	Yerel saatte 11:00 (yaklaşık)
Sensör Tipi	Multispektral Pushbroom
Spektral Bantlar	Mavi 440- 510 nm Yeşil 520- 590 nm Kırmızı 630- 685 nm Kırmızı Kenar 690- 730 nm NIR 760- 850 nm
Şerit Genişliği	77 km
Zamansal Çözünürlük	5.5 gün (nadir) Günlük (off-nadir)
Görüntü Yakalama Kapasitesi	6 milyon km ² 'den daha fazla
Piksel Boyutu	5 m
Bit Derinliği	16-bit
Datum	WGS-84
Harita Projeksiyonu	UTM
Yeniden Örnekleme Kerneli	Küçük Konvolüsyon



Şekil 3. RapidEye Uydusu sensör tarama yönü ve perspektifi (URL-9, 2019'dan değiştirilerek)

Rapideye uydu orto karoları $25 \times 25 \text{ km}^2$ olarak düzenlenmiş ızgaralardan oluşur. Bölünmüş uydu çerçeve görüntüleri, tek bir geçişte tek bir uydudan üst üste binen çerçeveli sahneler dizisi olarak toplanır. Bu sahnelere daha sonra ortorektifikasyon işlemi yapılır ve arka arkaya gelen genellikle 4-5 görüntüde bir birleştirilip orto karo oluşturulur.

Görüntüler, radyometrik, sensör ve geometrik olarak düzeltilir ve kartografik harita projeksiyonuna hizalanır. Geometrik düzeltme için 30 ile 90 metre arasında olan dijital yükseklik modeli (DEM) kullanılır.



Şekil 4. PlanetScope Orto Karo (URL-9, 2019'dan değiştirilerek)

1.7. Tuzluluk İndeksleri

Literatürde geliştirilen tuzluluk indekslerine bakıldığında toprağın spektral özellikleri dikkate alınıp, bant aritmetiği kullanarak çoğunlukla indeksler oluşturulmuştur.

Laboratuvar koşulları altında Csillag ve ark. (1993) farklı tuzlulaşma ve alkalileşme görülen toprakların tuzluluk durumunu karakterize eden üç farklı spektral aralık bulmuştur. Bu spektral aralıklar, görünür bölge (0.55-0.77 nm), yakın kızılötesi bölge (0.9-1.3 nm) ve orta dalga kızılötesi (1.94- 2.15 nm ve 2.33-2.4 nm) aralıklarıdır.

Genel olarak tuzlu yüzeyler diğer yüzeylere nazaran daha pürüzsüzdür ve yakın kızılötesi ve görünür bölgede mavi ve kırmızı spektral aralıkta yüksek yansıtım gösterir. Düşük nem içeriğine sahip tuzlar, görünür bölgenin özellikle mavi bölgesinde yüksek yansıtım değerine sahiptir (Metternichit ve Zinck, 2003).

Termal kızılötesi yaygın olarak nem ve tuzluluğu tespit etmek için kullanılır. Termal kızılötesi bölge tuz minerallerinin içinde bulunan sülfat, fosfat ve klor, bileşik ve elementlerinin enerji emiliminden kaynaklanan özellikleri kaydeder (Siegal ve Gillespie, 1980; Mulders, 1987).

Tuz bileşiklerinde olan demir oksit emilimi 425-500 nm ve 850-900 nm aralığında belirgindir. Kalsiyum karbonat (CaCO_3) bileşiğinin emilimi 2325 nm'de gerçekleşir (Masoud, 2014).

Khan vd., (2001) tuzdan etkilenen bölgeleri ayırt etmek için bant kombinasyonları önermişlerdir. Tuzluluk indekslerinde kullanılan bantlar, tuzdan etkilenen toprakların spektral yansıtım eğrisine bakılarak seçilmiştir. Tuzdan etkilenen toprağın görünür spektrumda (0.45-0.68 mm) arazi üzerinde olan diğer cisimlerden daha fazla yansıtım yaptığı görülmüştür.

Hiperspektral uydu görüntüleri için Bannari vd. (2008) tuzluluk indeksi önermişlerdir. EO-1 ALI verilerini kullanarak hafif ve orta dereceli toprak tuzluluk etkilerini tespit etmek için geliştirilen üç farklı tuzluluk indeksi aşağıda verilmiştir.

$$SI_1=(ALI9-ALI10) \quad (1.2)$$

$$SI_2=(ALI6-ALI9)/(ALI6+ALI9) \quad (1.3)$$

$$SI_3=(ALI9-ALI10)/(ALI9+ALI10) \quad (1.4)$$

Yahiaoui vd., (2015) yaptığı çalışmada görünür bölgede mavi, kırmızı ve yeşil dalga boylarındaki yansıtımının, EC değerleri ile yüksek korelasyonlu olduğunu belirtmiştir.

Tran vd., (2018) NIR kanalı ile EC değerleri arasında yüksek korelasyon olduğunu belirtmiş ve korelasyon katsayısı değerini $R^2 = 0.7779$ bulmuşlardır.

Literatürde geçen diğer tuzluluk indeksleri Tablo 4.'te verilmiştir.

Tablo 4. Tuzluluk indeksleri ve bant eşitlikleri

Tuzluluk İndeksleri	Eşitlik	Referans
Normalize Edilmiş Diferansiyel Tuzluluk İndeksi	$NDSI = \frac{(R - NIR)}{(R + NIR)}$	(Khan, Rastoskuev vd. 2001)
Tuzluluk İndeksi 1	$SI = \sqrt{B \times R}$	Khan, Rastoskuev vd. 2001)
Tuzluluk İndeksi 2	$SII = \sqrt{G \times R}$	(Douaoui, 2006)
Tuzluluk İndeksi 3	$SIII = \sqrt{G^2 + R^2 + NIR^2}$	(Douaoui, 2006)
Tuzluluk İndeksi 4	$SIV = \sqrt{G^2 + R^2}$	(Douaoui, 2006)
Tuzluluk İndeksi 5	$SV = \frac{B}{R}$	(Abbas, 2007)
Tuzluluk İndeksi 6	$SVI = \frac{(B - R)}{(B + R)}$	(Gonzalez vd.,2006)
Tuzluluk İndeksi 7	$SVII = \frac{(G \times R)}{B}$	(Gonzalez vd.,2006)
Tuzluluk İndeksi 8	$SVIII = \frac{(B \times R)}{G}$	(Gonzalez vd.,2006)
Tuzluluk İndeksi 9	$SIX = \frac{(R \times NIR)}{G}$	(Abbas, 2007)

Normalize diferansiyel tuzluluk indeksi (NDSI), spektrumun kırmızı (R) bandı ve kızılötesi (NIR) kısmının kullanılmasıyla en çok kullanılan tuzluluk endekslerinden biri olarak önerilmiştir. NDSI, yakın kızılötesi ve kırmızı yansıtım arasındaki farkın toplamlarına bölünmesiyle hesaplanır (Bkz. Tablo 4).

Tuzluluk indeksi olan SI mavi ve kırmızın bant değerlerinin çarpılıp, bu değer in karekökü alınmasıyla hesaplanır. Asfaw vd., (2016) yaptığı çalışmada özellikle SI indeksi ile EC_e değerleri arasında yüksek korelasyon bulup $R^2 = 0.78$ olarak hesaplamışlardır.

Tuzluluk indeksi olan SII yeşil ve kırmızın bant değerlerinin çarpılıp, bu değer in karekökü alınmasıyla hesaplanır.

Tuzluluk indeksi olan SIII mavi, yeşil ve kırmızın bant değerlerinin karelerinin alınıp toplanarak elde edilen değerinde karekökünün alınmasıyla hesaplanır.

Tuzluluk indeksi olan SIV yeşil ve kırmızın bant değerlerinin karelerinin alınıp toplanarak elde edilen değerinde karekökünün alınmasıyla hesaplanır. Albed ve Kumar (2011), SIV tuzluluk indeksinin EC ile yüksek korelasyonlu olduğunu belirtmiştir. Harran Ovası tuzluluk tespiti için yapılan bu tez çalışmasında görüntüler üzerinde SIII ve SIV tuzluluk indeksleri deneme amaçlı uygulandığında görüntüde doku bilgisi kaybolmuş ve gürültülü gibi bir sonuç vermiştir. Böyle bir sonuç alındığı için bu çalışma kapsamında SIII ve SIV indeksleri kullanılmamıştır.

Tuzluluk indeksi SV, mavi bandın kırmızı banda oranlanmasıyla bulunur.

Tuzluluk indeksi SVI mavi ve kırmızı bandın farkının toplamına bölünmesiyle bulunur.

Tuzluluk indeksi SVII yeşil ve kırmızı banttaki spektral yansıtım değerlerinin çarpımının mavi banttaki spektral yansıtım değerlerine bölünmesiyle bulunur.

Tuzluluk indeksi SVIII mavi ve kırmızı banttaki spektral yansıtım değerlerinin çarpımının yeşil banttaki spektral yansıtım değerlerine bölünmesiyle bulunur.

Tuzluluk indeksi SVIII yakın kızılötesi ve kırmızı banttaki spektral yansıtım değerlerinin çarpımının yeşil banttaki spektral yansıtım değerlerine bölünmesiyle bulunur.

Uygu algılayıcı sistemler tarafından kaydedilen spektral yansıtımlar cisimlerin benzersiz özelliklerini içerir. Bantlar arasındaki spektral farklılıkları arttırmak ve topografyadan kaynaklı etkileri azaltmak için bant oranlaması kullanılır. Bant oranlaması ile spektral yansıtım değerleri genişletilerek yani yansıtım aralığının yayılmasıyla cisimlere ait özellikler daha iyi ifade edilmesi amaçlanır. Bu noktada görüntü üzerinde tuzluluğu daha iyi tespit etmek için geliştirilen tuzluluk indeksleri (Bkz. Tablo 4.) genellikle elektromanyetik spektrumun yakın kızılötesi ve görünür bölgede mavi, yeşil ve kırmızı dalga boylarına ait spektral aralıktaki yansıtımlar dikkate alınarak bant oranlaması yapılmıştır. Bu indeks değerleri normalize edilirse [-1,1] aralığında değer alır ve indeks değeri 1'e yaklaştıkça tuzluluk en yüksek seviyede olur.

1.8. Bitki İndeksi


Son yarım yüzyılda uzaktan algılama alanında çeşitli vejetasyon indeksleri geliştirilmiştir. Bunların geliştirilmesi ve kullanılmasının temel varsayımı, uzaktan algılanan spektral bantların bazı cebirsel kombinasyonlarının, bitki örtüsü yapısı, bitki örtüsü durumu, fotosentetik kapasite, yaprak yoğunluğu ve dağılımı, yapraklardaki su içeriği ve mineral eksiklikleri gibi değerli bilgileri ortaya çıkarabileceğidir (Jensen 2007; Liang 2005). Bu nedenle spektral bantların cebirsel kombinasyonu, bu faktörlerden bir veya daha fazlasına duyarlı olmalıdır. Aynı zamanda, iyi bir bitki örtüsü indeksi, toprak özellikleri, atmosfer koşulları, güneş aydınlatması ve sensör görüntüleme geometrisi gibi spektral yansıtmayı etkileyen faktörlere daha az duyarlı olmalıdır (Jensen2007; Liang 2005; Purkis ve Klemas 2011). Yeşil yapraklar ışığın mavi ve kırmızı bölgelerinde güçlü bir emilim yapar. Yeşil bölgede emilim daha az gerçekleştiğinden, yeşil rengi yansıtılır (Jensen 2007). 1974'te Rouse vd. tarafından NDVI bitki indeksi geliştirilmiştir. Yakın kızılötesi dalga boyunun kırmızı dalga boyu ile fark ve toplamalarının birbirine oranıdır (Bkz. Denklem 1.5).

$$NDVI = \frac{(NIR-RED)}{(NIR+RED)} \quad (1.5)$$

NDVI bitki örtüsünün değer aralığı $[-1,1]$ 'dir. Pozitif değerler vejetatif bölgelere karşılık gelir, indeks değeri ne kadar yüksek olursa, hedefin klorofil içeriği o kadar fazladır.

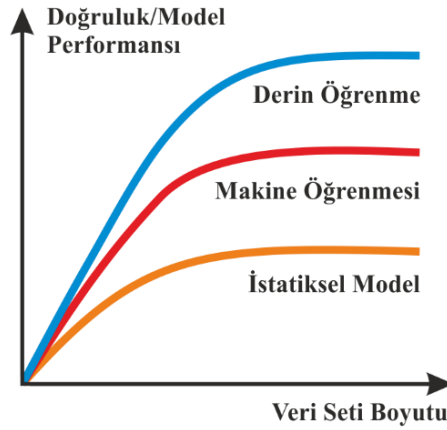
1.9. Derin Öğrenme

Derin öğrenme, biyolojik yapılar ve beynin çalışma prensibi dikkate alınarak geliştirilen algoritmalar ile bu özellikleri makinalara aktarmakla ilgilenen makine öğrenmesinin bir alt dalıdır. Derin öğrenme; robotik, doğal dil işleme, biyoinformatik, medikal görüntü analizi ve görüntü onarma gibi alanlarda kullanılmaktadır.



Şekil 5. Makine öğrenmesi, derin öğrenme ve yapay zeka ilişki diyagramı (Patterson ve Gibson, 2017'den değiştirilerek)

Eğitim için ayrılan veri seti boyutu ile doğruluk/model performansına bakıldığında makine öğrenmesi ve istatistiksel metotlar belli bir eşik değerinden sonra modelin performansını arttırmamaktadır. Derin öğrenme ile bu durum ortadan kalkmıştır. Derin öğrenmeyi, geleneksel istatistiksel yöntemlerden ayıran en önemli fark öğrenmeyi doğrudan veriden yapabilmesidir. İstatistiksel yöntemlerde sistem, verilen kural dahilinde çıktı üretirken, makine öğrenmesi veri üzerinde kendi kuralını oluşturmaktadır ve sonuç makine öğrenmesi ile oluşturulan kural dahilinde üretilmektedir. Stanford Üniversitesi'nde yapay zekanın öncülerinden olan Arthur Samuel makine öğrenmesini “Bilgisayarların açıkça programlanmadan öğrenmelerini sağlayan çalışma alanı” olarak ifade etmiştir (Keskenler, 2017).

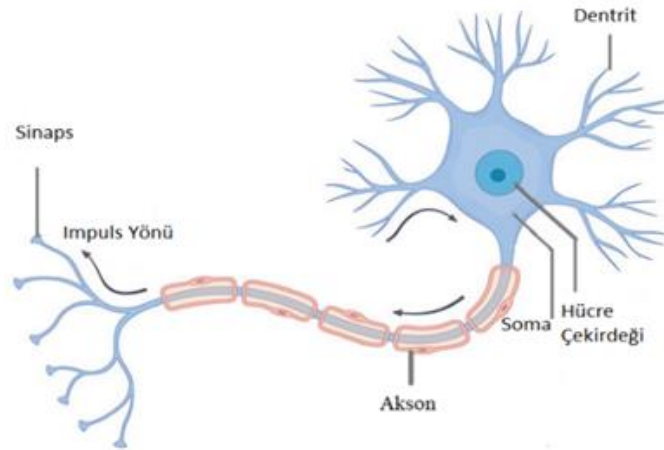


Şekil 6. İstatiksel model, makine öğrenme ve derin öğrenme yöntemleri arasındaki veri boyutu ve model doğruluk ilişkisi (Patterson ve Gibson, 2017’den değiştirilerek)

Derin öğrenmede görüntü n-boyutlu tensör olarak ifade edilir. Tensör, en temel seviyede çok boyutlu bir dizidir. Matris iki boyutlu iken; tensör üç ve üzeri boyutlar için kullanılır. İki boyutlu düzlemde görüntü piksel değerlerini ifade ederken üçüncü boyut görüntünün renk kanal sayısıdır. Örneğin 100 adet 512×512 piksel RGB görüntüsü 4 boyutlu tensör olarak $512 \times 512 \times 3 \times 100$ şeklinde ifade edilir. Videolar ise beş boyutlu tensörlerdir.

1.9.1. Yapay Sinir Ağları

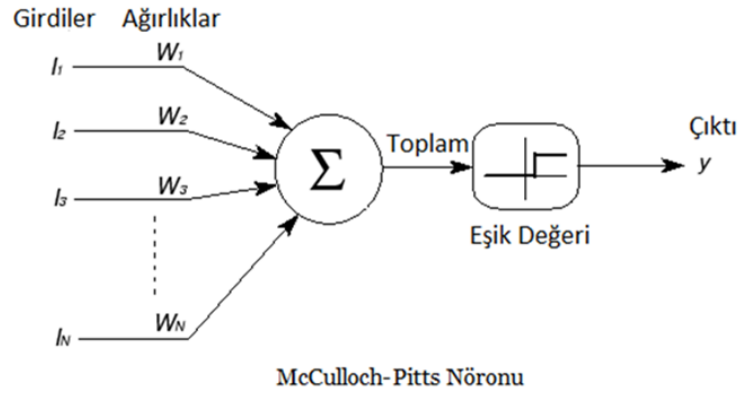
Yapay sinir ağları insan sinir sisteminin en küçük parçası olan nöronlar ilham alınarak geliştirilmiştir. Nöronlar dentrit, soma ve akson olmak üzere üç temel kısımdan oluşur. Nöronların bir elektrokimyasal sinyali iletmesi için sinyalin vücutta belli bir eşik değerini geçmesi gerekir. Belli bir eşik değerini geçen sinyal, dentritler ve aksonlar aracılığıyla sinapslara iletilir. Bu şekilde vücutta sinaptik iletim gerçekleşmiş olur.



Şekil 7. Dendrit, hücre çekirdeği, soma, akson ve sinapstan oluşan nöron yapısı (URL-10, 2019'dan değiştirilerek)

Yapay sinir ağı ilk kez 1943 yılında basit bir elektrik devresinin temsili için nörofizyolog Warren McCulloch ve matematikçi Walter Pitts tarafından önerilmiştir. Donald Hebb 1949 yılında yazdığı *The Organization of Behaviour* (Davranışların Bünyesi) adlı kitabında sinirsel iletimin art arda kullanılmasıyla aynı anda ateşlenmiş nöronların güçlendirilerek özellikle karmaşık işlemlerin ölçülebileceğini önermiştir (Herbian Öğrenme). Ardından ilk Herbian sinir ağı 1954'te MIT'te başarıyla uygulanmıştır. Bu sırada psikolog olan Frank Rosenblatt sineğin gözünde bulunan ve kaçış tepkisini belirleyen basit mekanizmayı anlamak için 1958'te Mark I Perceptron kavramını önermiştir. Perceptron tek katmanlı olup tek çıkışa sahip eğitilebilen yapay sinir ağıdır.

1943'te Warren McCulloch ve Walter Pitts önerilen McCulloch-Pitts nöronu beyindeki karmaşık karar mekanizmasını temsil etmek için doğrusal bir eşik değeri ile basit bir girdi-çıkış ilişkisine sahip sistemdi. Girdi ve kendine ait ağırlık değeri alan bu nöronlar çarpılıp tüm değerler toplandıktan sonra, belirli bir eşik değeri uygulanarak çıktıda 0 veya 1 değeri döndürürdü.



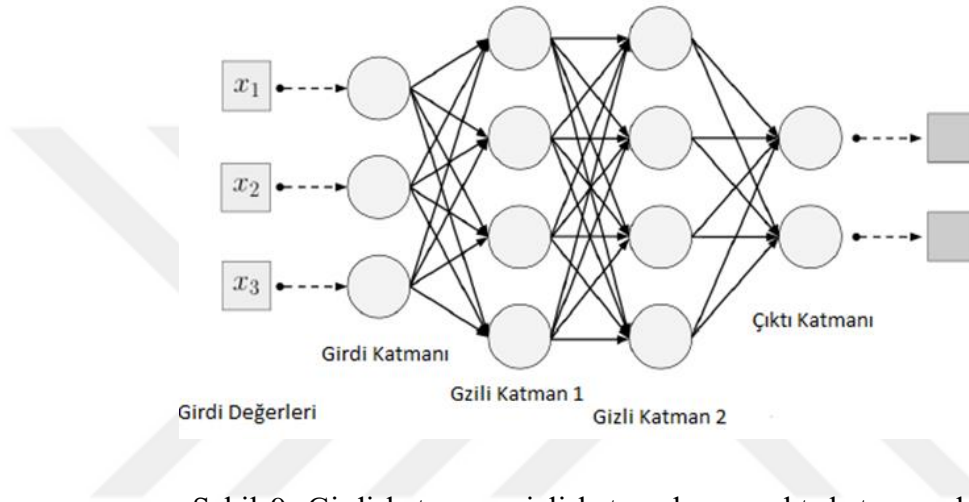
Şekil 8. Basit bir elektrik devresinin temsili olan McCulloch-Pitts nöronu (Patterson ve Gibson, 2017'den değiştirilerek)

1959 yılında Stanford Üniversitesi'nde, Bernard Widrow ve Marcian Hoff yapay sinir ağını gerçek dünya problemlerine uyguladılar. ADALINE ve MADALINE adı verilen sistem telefon hatlarındaki gürültüyü ortadan kaldırmak için özel tasarlanmıştı. Bugün hala bu sistem kullanılmaktadır. 1960'larda araştırmacılar tarafından geri yayılım (backpropagation) yöntemi geliştirildi. Geri yayılım (backpropagation) yöntemi yapay sinir ağı zincirinde bir adım geriye giderken her bir olay için azalan hata değerini gösteren, sezgiye dayalı bir yöntemdir. Denetimli, derin, ileri beslenen, çok katmanlı algılayıcılar için ilk genel çalışma 1965'te Alexey Ivakhnenko ve Lapa tarafından yayınlandı.

1980'lerde iki katmandan daha fazla katmana sahip yapay sinir ağı fikri derin öğrenmenin temelini oluşturmuştur. Derin öğrenme kavramı 1986'da makine öğrenmesi topluluğundan Rina Dechter tarafından tanıtıldı. 1991 yılına kadar, bu sistemler iki boyutlu elle yazılmış basamakları tanımak için kullanıldı. 2006'da derin öğrenme birçok çalışmada kullanıldı. Bu tarihten sonra derin öğrenmenin bu kadar çok tercih edilmesinin sebebi az bir veri seti ile, herhangi bir ön işleme gerek duymadan yapılan eğitim işleminin geleneksel makine öğrenmesi algoritmalarından daha yüksek doğruluk üretmesidir (Keskenler vd., 2017). Yapay sinir ağlarının günümüzde tekrar canlanmasının nedeni ilk ortaya çıktığı yıllara nazaran artan veri setleri, ekran kartı gibi donanımların iyileştirilmesi, bilgisayarların paralel hesaplama yapılabilmesi ve ilgili yazılımların gelişmiş olmasıdır.

1.9.2. Yapay Sinir Ağı Mimarisi

Yapay sinir ağı mimarisi: Nöron sayısı, katman sayısı, katmanların birbirleri arasındaki bağlantı türleri ile ifade edilir. En çok bilinen ileri beslemeli yapay sinir ağı bir giriş katmanı, bir veya birden çok gizli katman ve bir çıktı katmanından oluşur. Her katman farklı sayıda nöron içerebilir ve bu nöronlar node (düğüm) olarak da adlandırılır. Katmanlar birbiri ile bağlantılıdır. Örnek bir yapay sinir ağı katmanları ve katmanlar arasındaki bağlantı aşağıda Şekil 9.'da gösterilmiştir.




Şekil 9. Girdi katmanı, gizli katmanlar ve çıktı katmanından oluşan bir yapay sinir ağı mimarisi (Patterson ve Gibson, 2017'den değiştirilerek)

Derin öğrenmede ağ genellikle geri yayılım (backpropagation) yöntemiyle eğitilir. Geri yayılım, bağlantılı nöronlar arasındaki ağırlıklar üzerinde gradyan iniş (gradient descent) yönteminin kullanılmasıyla çıktıda hatayı yani kaybı en aza düşürür.

1.9.3. İleri Beslemeli Yapay Sinir Ağları

Giriş değerlerinin yapay sinir ağı boyunca tek yönde ileri doğru eğitilmesidir.



Şekil 10. Girdi değerleri ve ağırlıkların çarpılıp toplanarak bir aktivasyon fonksiyonundan geçirilen ileri beslemeli yapay sinir ağı (Patterson ve Gibson, 2017'den değiştirilerek)

İleri beslemeli ağlarda giriş katmanındaki nöron sayısı ağda eğitilecek özellik sayısına eşittir. Örneğin 100×100 piksellik bir görüntüde giriş katman sayısı, toplam piksel sayısına eşittir. Bir sinir ağındaki bağlantıların ağırlıkları, giriş sinyalini ağdaki belirli bir nöronla ölçeklendiren (maksimize veya minimize eden) katsayılarıdır. Bir sonraki aşamada girdi değerleri ağırlıklarla çarpılıp tüm değerler toplanır ve aktivasyon fonksiyonuna iletilir. Bu şekilde ağın eğitimine başlanmış olur.

Tüm girdi değerleri (n boyutlu) bir A matrisi ve tüm ağırlık değerleri W matrisi ile ifade edilecek olursa;

$$A = [x_1, x_2, x_3, x_4, \dots, x_n]_{1 \times n}$$

$$W = [w_1, w_2, w_3, w_4, \dots, w_n]_{1 \times n}$$

İleri beslemeli ağlarda gerçekleşen ilk işlem tüm girdi ve ağırlıkların birbiriyle çarpılıp, toplanmasıdır. (Denklem 1.6'da gösterildiği üzere)

$$\hat{y} = \sigma \left(\sum_{i=1}^n (W_i^{(1)} \times A_i^{(1)} + b) \right) \quad (1.6)$$

Denklem (1.6)'daki b değeri bias'tır. Biaslar ağına aktive edilmesini sağlamak için girişe eklenen skaler değerlerdir. Ayrıca ağda düşük sinyaller olması durumunda ağda öğrenmenin devam etmesini sağlar. Aktivasyon fonksiyonu $\sigma(z)$ ile ifade edilecek olursa, bulunan değerler aktivasyon fonksiyonuna girer ve hesaplama sonucu çıkan tahmini \hat{y} değeri bulunur.

$$\mathcal{L}(a, y) = \hat{y} = a = \sigma(z) \quad (1.7)$$

Burada, a aktivasyon sonucu elde edilen değerdir yani aynı zamanda tahmini \hat{y} değerini ifade eder. $\mathcal{L}(a, y)$ fonksiyonu, y girdi değerlerine bağlı olarak elde edilen \hat{y} tahmini değerini, aynı zamanda a 'ya bağlı üretilen sonuç fonksiyonudur.

1.9.4. Kayıp Fonksiyonu (Loss Function)

Gerçek sınıf değerleri ile derin öğrenme sonucu elde ettiğimiz tahmini çıktılar arasında farkı gösteren fonksiyondur. Kayıp fonksiyonu işlem sonucunda veri de tahmin nedeniyle ne kadar kayıp olduğunu ifade eder.

\hat{y} tahmini değerleri ve y gerçek değerlerine bağlı olarak hesaplanan kayıp fonksiyonu $\mathcal{L}(\hat{y}, y)$, denklem (1.8)'deki gibi hesaplanır.

$$\mathcal{L}(\hat{y}, y) = -(y \log \hat{y} + (1 - y) \log(1 - \hat{y})) \quad (1.8)$$

1.9.5. Maliyet Fonksiyonu

Her bir girdi verisine ait kayıp fonksiyon değerlerinin toplamını ifade eder. Denklem (1.9)'da olduğu üzere her bir giriş verisinin kayıp fonksiyon hesabı sonucu çıkan değerler toplanır ve girdi veri adedine bölünür.

$$J(w, b) = \frac{1}{n} \sum_{i=1}^n \mathcal{L}(\hat{y}_i^{(l)}, y_i^{(l)}) \quad (1.9)$$

Maliyet fonksiyonunu açıkça belirtirsek denklem (1.10) elde edilir.

$$J(w, b) = -\frac{1}{n} \sum_{i=1}^n \left[\left(y_i^{(l)} \log \hat{y}_i^{(l)} \right) + \left(1 - y_i^{(l)} \log(1 - \hat{y}_i^{(l)}) \right) \right] \quad (1.10)$$

1.9.6. Geri Beslemeli Ağlar

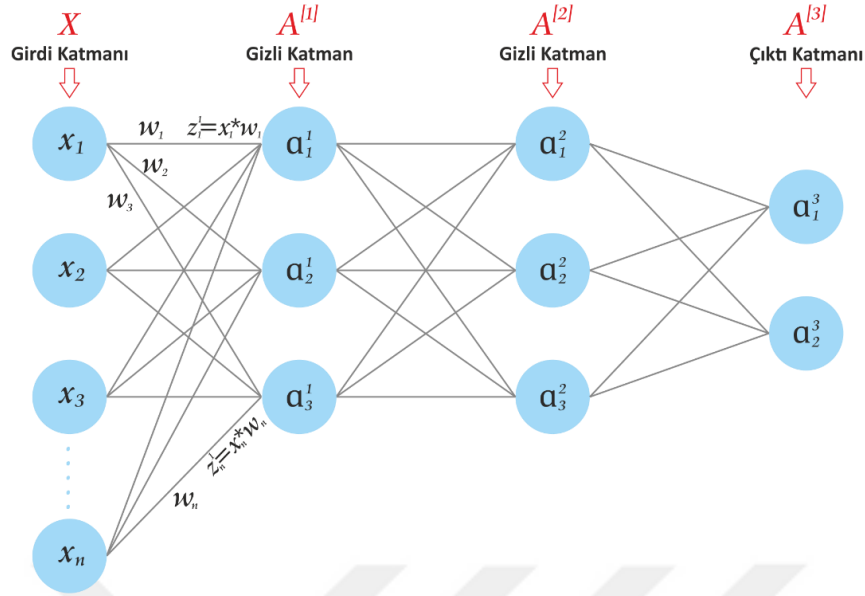
Ağın ileri besleme aşamasında ağırlıklar ve bias değeri rastgele ya da sezgisel olarak belirlenir. Bu yüzden ağa verilen bu başlangıç değerleri maliyet fonksiyonunun ilk değerinin yüksek çıkmasına sebep olabilir. Maliyet fonksiyonu ile hesaplanan hata değerini azaltmak amacıyla geri beslemeli ağlar kullanılır. Geri beslemeli ağ ile ağırlık ve bias değerleri geriye doğru güncellenir. Geriye doğru ağ yayılım yaparken, gradyan iniş (gradient descent) yöntemi kullanılarak ağırlıklar güncellenir. Gradyan iniş bir tür optimizasyon yöntemidir. Gradyan iniş yöntemiyle parametrelerin birbirine göre kısmi türevleri alınarak parametreler optimize edilmeye çalışılır. Türev alma işlemlerinde belirli bir aşamadan sonra değerde bir değişim yoksa minimum noktaya yani optimize için en uygun değere ulaşılmış olur. Bu şekilde maliyet fonksiyonunun düşürülmesi amaçlanır.

Gradyan iniş yöntemiyle maliyet fonksiyonunun ağırlık ve sigmoid fonksiyonuna göre kısmi türevleri (Denklem 1.11), ağırlık ve bias değerlerinin güncellenmesi (Denklem 1.12 ve 1.13) aşağıda verilmiştir.

$$\frac{\partial \mathcal{L}(a,y)}{\partial w} = \frac{\partial \mathcal{L}(a,y)}{\partial y} \frac{\partial y}{\partial z} \frac{\partial z}{\partial w} \quad (1.11)$$

$$w := w - \alpha \frac{\partial J(w,b)}{\partial w} \quad (1.12)$$

$$b := b - \alpha \frac{\partial J(w,b)}{\partial b} \quad (1.13)$$



Şekil 11. İki gizli katmana sahip iki farklı çıktı üreten yapay sinir ağı modeli

Şekil 11.'de verilen yapay sinir ağı modelinin ileri besleme yayılımı ve geri besleme yayılımı yapılırsa;

İleri besleme yayılımı;

$$z^{[1]} = w^{[1]}x^{[1]} + b$$

$$a^{[1]} = \sigma(z^{[1]})$$

$$z^{[2]} = w^{[2]}a^{[1]} + b$$

$$a^{[2]} = \sigma(z^{[2]})$$

$$z^{[3]} = w^{[3]}a^{[2]} + b$$

$$a^{[3]} = \sigma(z^{[3]})$$

Geri Yayılım;

L katmanındaki i. düğümündeki hata δ_i^l ile temsil edilirse,

$$\delta_i^l = \frac{\partial}{\partial z_i^l} \mathcal{L}(a, y)$$

$$\delta^{[3]} = a^{[3]} - y$$

$$\delta^{[2]} = w^{T[3]} \cdot \delta^{[3]} * \sigma'(z^{[2]})$$

$$\delta^{[1]} = w^{T[2]} \cdot \delta^{[2]} * \sigma'(z^{[1]})$$

Not: $\sigma(x) = \frac{1}{1+e^{-x}}$ fonksiyonun türevi $\sigma'(x) = (1 - \sigma(x))\sigma(x)$ ise,

$$w^{[2]} = w^{[2]} - \alpha(\delta^{[3]}(1 - a^{[3]})a^{[3]} \cdot a^{[2]})$$

$$w^{[1]} = w^{[1]} - \alpha(\delta^{[2]}(1 - a^{[2]})a^{[2]}.a^{[1]})$$

Eğitim işleminin vektörize formu yukarıda belirtildiği üzere 1 iterasyon için gerçekleştirilmiştir.

1.10. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, sinir hücreleri arasındaki elektrokimyasal iletim ilham alınarak geliştirilmiştir. Sinir hücreleri arasında bilginin iletilmesi, uyarılma etkisi belli bir eşik değerinden fazla olduğunda gerçekleşir. Karmaşık ve çok parametre içeren olayları modellemek için kullanılan yapay sinir ağlarında, bir ağ katmanındaki belirli nöronların ateşlenmesini (veya aktive edilmesini) sağlamak için kullanılır. Bu nedenle aktivasyon fonksiyonları olarak adlandırılır. Aktivasyon fonksiyonları düğümlerin çıktısını bir sonraki katmana iletmek için kullanılan etkinleştirme fonksiyonlarıdır. Aktivasyon fonksiyonlarına literatürde transfer fonksiyonu da denir (Nwankpa vd., 2018).

Sinir ağlarının çıkışını kontrol etmek için kullanılan aktivasyon fonksiyonları, lineer veya nonlineer olabilir. Nesne tanıma ve sınıflandırma, konuşma tanıma, bölütleme, konuşma sistemleri, kanser algılama, hava durumu tahmini, kendi kendine giden arabalara ve birçok farklı alanda, uygun bir aktivasyon fonksiyon seçimi, nöral ağ hesaplamasındaki sonuçları iyileştirir (Nwankpa vd., 2018).

Yapay sinir ağında ağ eğitim işlemi, ilk olarak ağırlık değerleriyle girdi değerlerinin çarpılıp toplanmasıyla gerçekleşir (ve istenirse bias eklenir).

$$f(x)=wx +b \tag{1.14}$$

Burada, x = giriş, w = ağırlık, b = bias'dır.

Denklem 1.14'e bakıldığında bu işlem sonucu aslında bir lineer model ve çıktı üretilir. Bu lineer çıkışları daha iyi hesaplamak ve özellikle verilerdeki paternleri öğrenmek için lineer olmayan bir çıkışa dönüştürme ihtiyacı vardır (Nwankpa vd., 2018).

Ağın çıktıklarına bakıldığında denklem (1.15) sonucu alınır.

$$y= (w_1 x_1 + w_2 x_2 + \dots + w_n x_n + b) \tag{1.15}$$

Derin yapay sinir ağlarında, gizli katman boyunca son çıktı elde edilene kadar hesaplama yapılır, bu model doğal olarak lineerdir. (Bkz. Denklem 1.15)

Belirli bir ağda beklenen çıktı, kullanılacak olan aktivasyon fonksiyonunun türünü belirler. Ancak, çıktı doğrusal olduğundan, bu doğrusal girişleri, doğrusal olmayan çıkışlara dönüştürmek için doğrusal olmayan aktivasyon fonksiyonları gereklidir. Bu noktada aktivasyon fonksiyonları, dönüştürülmüş doğrusal olmayan çıkışları üretmek için doğrusal modellerin, çıkışlarına uygulanan işlevlerdir. Aktivasyon fonksiyonunun uygulanmasından sonra doğrusal olmayan çıktı şu şekildedir:


$$\hat{y} = \alpha(w_1 x_1 + w_2 x_2 + \dots + w_n x_n + b) \quad (1.16)$$

Burada α aktivasyon fonksiyonudur. Aktivasyon fonksiyonu daha derin ağlarda, yüksek dereceli polinomların belirli bir aşamadan sonra daha fazla öğrenilmesine yardımcı olur. Bu şekilde eğitim işlemi devam ettirilebilir. Bazı lineer olmayan aktivasyon fonksiyonlarının sahip olduğu bir diğer özellik, türevlenebilir olmalarıdır. Aksi durumda, yani türevlenememe söz konusu olduğunda, geri yayılım sırasında işlem yapılamaz.

Literatürde kullanılan aktivasyon fonksiyonları ilerleyen bölümlerde daha detaylı açıklanmıştır.

1.10.1. Lineer Aktivasyon Fonksiyonu

Lineer aktivasyon fonksiyonu temelde $f(x) = Wx$ eşitliğiyle sağlanan fonksiyondur. Burada bağımlı ve bağımsız değişken birbiriyle doğrudan orantılıdır. Lineer aktivasyon fonksiyonu ağda değerler değişmeden geçtiğini ifade eder.




Şekil 12. $f(x) = Wx$ eşitliğiyle tanımlanmış lineer aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek)

1.10.2. Sigmoid Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu literatürde lojistik fonksiyon olarak adlandırılır (Turian, 2009). Sigmoid, çoğunlukla ileri beslemeli sinir ağlarında kullanılan doğrusal olmayan bir fonksiyondur. Sigmoid işlevi, sonsuz aralıktaki bağımsız değişkenleri 0 ile 1 arasına çeker. Yapay sinir ağlarında genellikle sigmoid fonksiyonunun kullanılmasının sebebi olasılıksal bir sonuç üretmesi ve her yerde pozitif türevlenebilmesidir. Sigmoid işlevi, derin öğrenme mimarisinin çıkış katmanlarında görülür ve olasılık tabanlı çıktıyı tahmin etmek için kullanılır. İkili sınıflandırma problemlerinde, lojistik regresyon işlemlerinde uygulanmıştır. Glorot ve Bengio (2010) sinir ağı küçük ağırlık değerleriyle başlatıldığında, sigmoid fonksiyonundan kaçınılması gerektiğini önermişlerdir.

$$f(x) = \sigma(x) = \frac{1}{1+e^{-x}} \quad (0,1) \quad (1.17)$$

Sigmoid fonksiyonunun dezavantajları ise, derin gizli katmanlardan giriş katmanına doğru geri yayılım yaparken keskin gradyan oluşturması, yavaş yakınsama yapması ve gradyanların farklı yönlerde yayılmasıdır. (Nwankpa vd., 2018).



Şekil 13. $[0,1]$ kapalı aralığında değer alan Sigmoid aktivasyon fonksiyon grafiği (Ramachandran vd., 2017'den değiştirilerek)

1.10.3. Hard Sigmoid Fonksiyonu

Sigmoid fonksiyonunun başka bir türüdür. Hard sigmoid fonksiyonu, sigmoid fonksiyonu göre daha az hesaplama maliyeti sağlar. İkili sınıflandırmada işlemlerinde başarılı sonuçlar verdiği görülmüştür (Courbariaux vd., 2015).

$$f(x) = \max(0, \min(1, \frac{(x+1)}{2})) \quad (1.18)$$

1.10.4. Sigmoid Ağırlıklı Linear Birim (SiLU)

SiLU, takviyeli öğrenme tabanlı bir yakınsama fonksiyonudur. SiLU, Elfwing vd., tarafından 2017 yılında önerilmiştir. SiLU aktivasyon fonksiyonu a_k ile ifade edilirse aktivasyon fonksiyon denklemi 1.19'daki gibidir:

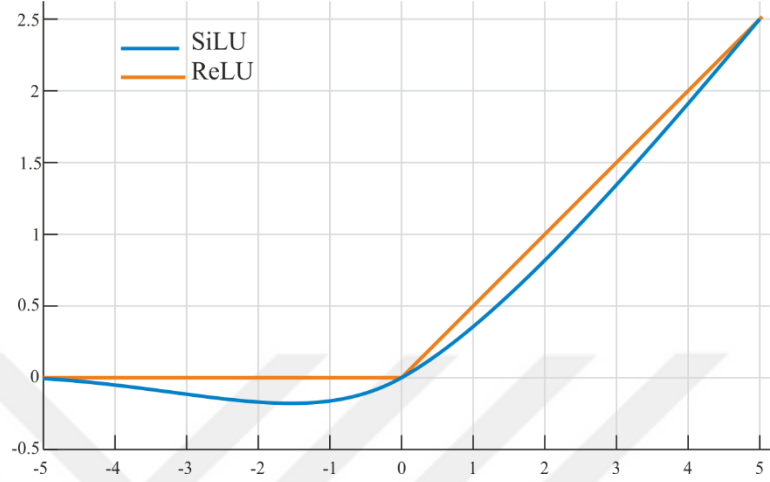
$$a_k(s) = z_k \alpha(z_k) \quad (1.19)$$

Burada, s = giriş vektörü, $z_k = k$ 'nci gizli katman.

Gizli katmanlara girdi şu şekilde verilir:

$$z_k = \sum_i w_{ik} s_i + b_k \quad (1.20)$$

b_k bias, w_{ik} k'inci gizli katmana bağlanan i'inci düğümdeki ağırlıktır. SiLU işlevi yalnızca derin sinir ağlarının gizli katmanlarında ve takviyeli öğrenme tabanlı sistemlerde kullanılır.



Şekil 14. SiLU ve ReLU aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek)

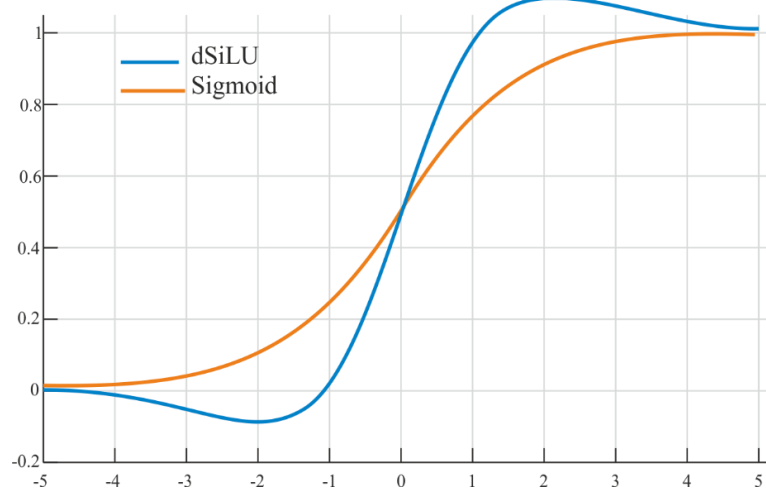
1.10.5. Sigmoid Ağırlıklı Doğrusal Birimlerin Türevi (dSiLU)

Sigmoid ağırlıklı doğrusal birimlerin türevi, SiLU fonksiyonunun gradyanıdır ve dSiLU olarak adlandırılır.

$$a_k(s) = \alpha(z_k)(1 + z_k(1 - \alpha(z_k))) \quad (1.21)$$

Burada, s = giriş vektörü, z_k =k'inci gizli katman, a_k aktivasyon fonksiyonudur.

Elfwing vd., (2017) dSiLU'nun standart Sigmoid fonksiyonundan daha iyi performans gösterdiğini vurgulamışlardır.




Şekil 15. dSiLU ve Sigmoid aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek)

1.10.6. Hiperbolik Tanjant Aktivasyon Fonksiyonu (Tanh)

Tanh fonksiyonu hiperbolik trigonometrik bir fonksiyondur. Değerleri -1 ile 1 arasına çeker. Tanh fonksiyonunun avantajı negatif sayılarla daha kolay başa çıkabilmeyi sağlamasıdır. Tanh fonksiyonu, çok katmanlı sinir ağları için daha iyi bir eğitim performansı sağlaması nedeniyle sigmoid fonksiyona kıyasla daha çok tercih edilir (Karlık, 2011; Neal, 1992)

Tanh fonksiyonu, ağda kaybedilen gradyan problemini çözmemiştir. Fonksiyonun sağladığı temel avantaj, sıfır merkezli çıktı üretmesi ve böylece geri yayılma işlemine yardımcı olmasıdır. Tanh işlevinin diğer bir özelliği, yalnızca giriş değeri 0 olduğunda, yani x girdi değeri 0 olduğunda, eğim bire eşit olur. Bu durum, Tanh fonksiyonunun hesaplama sırasında bazı ölü nöronlar üretmesine neden olur. Tanh fonksiyonunun bu sınırlaması, bu problemi çözmek için rektifiye edilmiş lineer birim (ReLU) aktivasyon fonksiyonunu doğurmuştur.




Şekil 16. (-1,1) açık aralığında değer alan Tanh aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek)

$$f_{\tanh}(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (-1,1) \quad (1.22)$$

1.10.7. Rektifiye Edilmiş Lineer Birim (ReLU)

Rektifiye edilmiş lineer birim (ReLU) aktivasyon işlevi Nair ve Hinton tarafından 2010 yılında önerilmiştir. Çoğunlukla en iyi sonuçları veren ve derin öğrenme uygulamaları içinde en yaygın kullanılan aktivasyon fonksiyonudur (Nair vd., 2010). ReLU, giriş 0'ın altındayken, çıkış 0'dır; ancak giriş değerleri belirli bir eşik değerinin üstüne çıktığında, bağımlı değişkenler, girdi değerlerin maksimum değerini üretir. ReLU aktivasyon fonksiyonlarının pratikte sigmoid aktivasyon fonksiyonundan daha iyi çalıştığı görülmüştür (Patterson vd., 2016).

$$f_{ReLU}(x) = \max(0, x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (1.23)$$



Şekil 17. Rektifiye edilmiş lineer birim aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek)

ReLU, başarılı ve oldukça çok tercih edilen, hızlı öğrenen bir aktivasyon fonksiyonudur (LeCun vd., 2015; Ramachandran vd., 2017). Sigmoid ve Tanh aktivasyon fonksiyonlarına kıyasla derin öğrenmede daha iyi performans ve genelleştirme sağlar (Zeiler vd., 2013; Dahl vd., 2013). ReLU işlevi neredeyse doğrusal bir işlevi temsil etmektedir. Böylece gradyan iniş yöntemiyle optimize edilen lineer modellerin özelliklerini korur (Goodfellow vd., 2013). Aktivasyon fonksiyonları arasında görülen kaybedilmiş gradyan sorununu ortadan kaldırır. ReLU, kısıtlı Boltzman makineleri, konvolüsyonel sinir ağı mimarileri olmak üzere sade ve güvenilirliği nedeniyle birçok derin öğrenme mimarisinde kullanılmıştır (Szegedy vd., 2015; He vd., 2015; Nair ve Hinton, 2010; Zeiler vd., 2013).

ReLU'nun en önemli kısıtlaması, mimarilerin eğitim işlemi esnasında bazı nöronların ölmesine sebep olur. Bu durum diğer katmanlarındaki ağırlıkların güncellenmesini engeller ve böylece eğitim işlemi gerçekleştirilemez. Bu nedenlere bağlı olarak ölü nöron sorununu gidermek için, Sızıntı Rektifiye Edilmiş Lineer Birim geliştirilmiştir.

1.10.8. Sızıntı Rektifiye Edilmiş Lineer Birim (LReLU)

Sızıntı ReLU, ReLU'ya negatif bir eğim getirilerek tüm eğitim boyunca ağırlık güncellenmesini korumak için 2013 yılında geliştirilen bir aktivasyon fonksiyonudur (Maas vd. 2013).

α parametresi, eğitim esnasında gradyanların sıfır olmaması için ReLU'ya bir katsayı olarak eklenmiştir. Bu şekilde ReLU'nun ürettiği ölü nöron problemine çözüm getirmiştir.

$$f_{LReLU}(x) = \alpha x + x = \begin{cases} x, & x > 0 \\ \alpha x, & x \leq 0 \end{cases} \quad (1.24)$$

Sızıntı ReLU eğitim esnası boyunca sıfır olmayan gradyanlar haricinde, ReLU ile karşılaştırıldığında aynı sonuca sahiptir. Sızıntı ReLU'da, Tanh ve ReLU fonksiyonları ile karşılaştırıldığında seyreklik ve dağılım dışında iyi bir iyileşme olmadığı görülmüştür (Maas vd., 2013)

1.10.9. Softmax

Softmax fonksiyonu, nöral hesaplamada kullanılan başka bir aktivasyon fonksiyonudur. Gerçek değerlerin olasılık dağılımını hesaplamak için kullanılır. Softmax işlevi, sınıfların olasılıkları toplamı 1'e eşit olacak şekilde 0 ile 1 değer aralığında bir çıktı üretir. N boyutlu bir girdi vektörü $S(a)$, $\mathbb{R}^N \rightarrow \mathbb{R}^N$ aralığında tanımlarsak;


$$S(a) = \begin{bmatrix} a_1 \\ a_2 \\ \dots \\ a_N \end{bmatrix} \rightarrow \begin{bmatrix} S_1 \\ S_2 \\ \dots \\ S_N \end{bmatrix}$$

Her bir elemanın olasılıksal olarak değeri denklem (1.25) ile hesaplanır:

$$S_j = \frac{e^{a_j}}{\sum_{k=1}^N e^{a_k}} \quad \forall j \in 1 \dots N \quad (1.25)$$

$S_j < 1$ olmak üzere, çıktıda pozitif değerler üretir.

Softmax işlevi, her sınıf değerinin, çıktıda en yüksek olasılığa sahip olacak şekilde hesaplama sonucu verir. Çok sınıflı modellerde kullanılır. Sigmoid ve Softmax aktivasyon fonksiyonları arasındaki temel fark Sigmoid ikili sınıflandırma işlemlerinde, Softmax ise çok değişkenli sınıflandırma işlemlerinde kullanılır. Tez çalışması kapsamında yapılan semantik bölütleme işleminde ikiden fazla sınıf olduğu için sınıflandırma katmanında Softmax aktivasyon fonksiyonu kullanılmıştır.

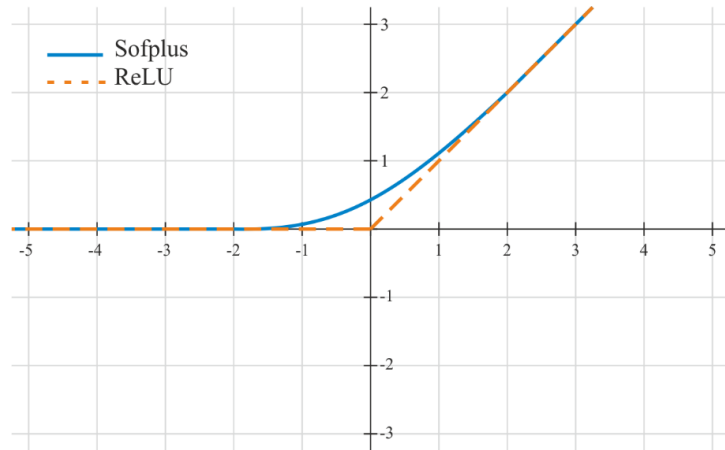


Şekil 18. Softmax aktivasyon fonksiyonu (Ramachandran vd., 2017'den değiştirilerek)

1.10.10. Softplus

Softplus aktivasyon fonksiyonu, sıfır değeri almayan ve gradyan özelliklere sahip ReLU aktivasyon fonksiyonunun yumuşatılmış versiyonudur. Softplus aktivasyon fonksiyonu ile tasarlanan derin sinir ağlarında stabilizasyon ve performans artırılır. Softplus, Dugas vd., (2001) tarafından önerilmiştir. Softplus işlevi, sigmoid işlevinin ilkel halidir.

$$f_{softplus}(x) = \log(1 + e^x) \quad (1.26)$$



Şekil 19. Softplus ve ReLU aktivasyon fonksiyonları karşılaştırılmalı grafiği (Ramachandran vd., 2017'den değiştirilerek)

Zheng ve ark., (2015) Softplus işlevini, ReLU ve Sigmoid işlevleriyle karşılaştırmışlardır. Softplus işlevini kullanılarak yapılan eğitim işlemlerinde daha az epokta yakınsama yaptığı ve iyi bir performans verdiği görülmüştür. Softplus işlevi çoğunlukla istatistiksel uygulamalar ve otomatik konuşma tanıma sistemlerinde kullanılır.

1.10.11. Maxout Fonksiyonu

Maxout fonksiyonu girdi değerleri ile ağırlıklar arasında element çarpım uygulayan nonlineer bir aktivasyon fonksiyonudur. Maxout 2013 yılında Goodfellow vd. tarafından geliştirilmiştir. Maxout ağda doygunluğun (doygunluk ağda eğitim işleminin yavaşlamasına ve aşırı öğrenmeye sebep olur) veya ölü nöronların olmadığı durumlar için ReLU ve sızın ReLU fonksiyonlarının özellikleri dikkate alınarak oluşturulmuştur. Maxout fonksiyonu:

$$f_{maxout}(x) = \max(w_1^T x + b_1, w_2^T x + b_2) \quad (1.27)$$

Burada, w=ağırlıklar, b=bias, T=vektörün transpozudur.

Maxout işlevi telefon tanıma uygulamalarında başarıyla test edilmiştir (Toth, 2015). Maxout fonksiyonunun en büyük dezavantajı, tüm nöronlarda kullanılan parametreleri iki katına çıkardığı için hesaplama olarak iyi donanım gerektirmesidir.

1.10.12. Swish Fonksiyonu

Swish aktivasyon fonksiyonu, girdi değerleri ile Sigmoid aktivasyon fonksiyonun bileşimidir. Swish aktivasyon fonksiyonu Ramachandran vd. tarafından 2017 yılında otomatik arama tekniği tabanlı pekiştirmeli (reinforcement) öğrenme için önerilmiştir. Swish işlevi monotonik olmayan, alt ve üst sınırlarda sonsuz değer alır. Pürüzsüzlük özelliği sayesinde, Swish işlevinin derin öğrenme mimarilerini eğitirken daha iyi optimizasyon ve genelleme sonuçları üretmesini sağlar (Ramachandran, 2017).

$$f_{swish}(x) = x \cdot \text{sigmoid}(x) = \frac{x}{1+e^{-x}} \quad (1.28)$$

Swish işlevinin temel avantajları, Swish'in kaybolan gradyan problemlerine sebep olmadığı, eğitim sırasında iyi yayılım sağladığı ve Swish aktivasyon fonksiyonunun derin

öğrenme sınıflandırma işlemlerinde ReLU aktivasyon işlevinden daha iyi sonuç verdiği görülmüştür (Nwankpa vd., 2018).

1.10.13. Üstel Lineer Birimler (ELUs)

Üstel lineer birimler (ELU'lar), Clevert vd. tarafından 2015'te önerilen bir başka aktivasyon fonksiyonudur. Derin sinir ağlarının eğitimini hızlandırmak için kullanılırlar. ELU'ların temel avantajı, pozitif değerler için benzerlikleri kullanarak kaybolan gradyan problemini (vanishing gradient problem) hafifletebilmesidir. ELU'lar negatif değerlerin sifıra yakınsamasını sağlar. Böylece hesaplama karmaşıklığını azaltır, öğrenme hızı artar (Clevert, 2015). ELU, sifıra yakınsanan aktivasyon birimleri ve bias sebebiyle yönlü değişiklikleri azalttığı için ReLU'ya iyi bir alternatiftir (Nwankpa vd., 2018).

ELU fonksiyonu denklem 1.29'da belirtilmiştir.

$$f_{ELU}(x) = \begin{cases} x, & x > 0 \\ \alpha e^x, & x \leq 0 \end{cases} \quad (1.29)$$

ELU fonksiyonun türevi (gradyanı)

$$f_{ELU}'(x) = \begin{cases} 1, & x > 0 \\ f(x) + \alpha, & x \leq 0 \end{cases} \quad (1.30)$$

Burada α negatif değerler için ağ doyumluk noktasını kontrol eden hiperparametredir. Genellikle 1 alınır (Nwankpa vd., 2018).

ELU aktivasyon fonksiyonu, negatif değerler olduğunda doyumlukla karşılaşma durumu daha sık görülür. Bu durum ReLU ve LReLU'a kıyasla daha sağlam örneklerden daha hızlı öğrenerek daha iyi genelleştirme yapabilmeyi sağlar.

1.10.14. Softsign Fonksiyonu

Softsign yapay sinir ağlarında kullanılan bir başka aktivasyon fonksiyonudur. Turian vd. tarafından 2009 yılında tanıtılan lineer olmayan ikinci dereceden polinomial bir fonksiyondur.

$$f_{softsign}(x) = \left(\frac{x}{|x|+1} \right) \quad (1.31)$$

Burada, $|x|$ girdilerin mutlak değerini ifade eder.

Softsign işlevi ile Tanh işlevi arasındaki temel fark, Softsign fonksiyonunun üstel yakınsama yapması ve polinomial bir formda birleşmesidir.

1.11. Aşırı Öğrenme ve Eksik Öğrenme


Aşırı veya eksik öğrenme verilerin nasıl eğitildiği ile ilgilidir. Ağ ve veriler arasında iyi bir işlem aşaması oluşturulmadığı durumlarda karşılaşılır.

1.11.1. Aşırı Öğrenme (Overfitting)

Eğitim için kullanılan veri seti üzerinde model aşırı ezberleme yapması veya eğitim için kullanılan veri setinin tekdüze olması durumunda karşılaşılan durumdur. Overfitting durumunda modelden yüksek sonuç elde ederken test verisinde sonuç çok düşüktür. Çünkü model eğitim verisinin bire bir kopyasını aramaktadır.

1.11.1. Eksik Öğrenme (Underfitting)

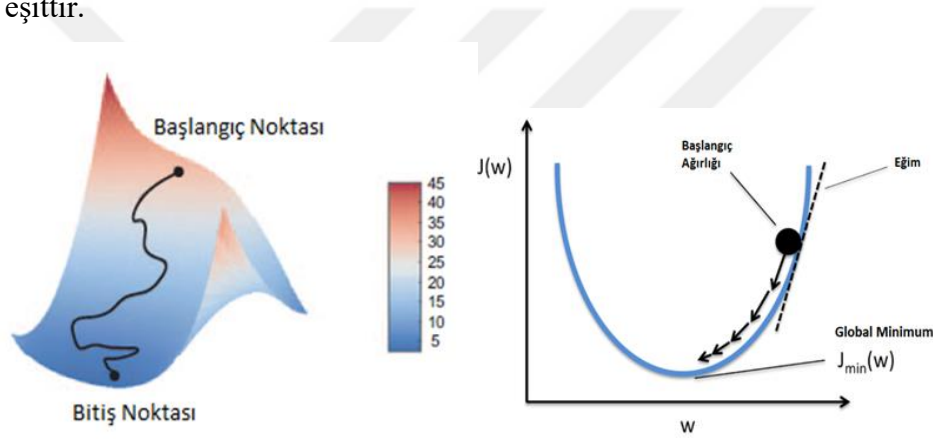
Veri setinin model tarafından iyi öğrenilememesi ve bunun sonucunda girdi verisinin iyi ayrıştırılmaması söz konusudur. Daha fazla girdi verisi veri setine eklenerek bu sorun çözülebilir.



Şekil 20. Aşırı, uygun ve eksik öğrenme durumlarına göre verinin ayrıştırılması (URL-13, 2019'dan değiştirilerek)

1.12. Gradyan İniş (Gradient Descent)

Gradyan iniş, ağın eğitimi için ağırlık değerlerinin güncellenmesinde kullanılan yöntemdir. Bu kademeli inişte ağı tahmin kalitesi en optimum değerin bulunmasıyla sağlanır. Ağırlık değerleri güncellenerek hatanın düşürülmesi amaçlanır. Bu olay bir yüksek vadiden iniş olarak da hayal edilebilir. Şekil 21.'de olduğu gibi bu ağırlık değerlerinin güncellenmesi bir vadiden iniş gibi kademeli olarak küçük adımlarla gerçekleşir. İnişteki bu küçük değişim, -modeli bir eğri olarak ifade edecek olursak- eğrinin eğimi yani o noktaya göre türeviyle ifade edilir. Türev bir nicelikte gerçekleşebilecek en küçük değişimdir. Aynı zamanda bir fonksiyonun birinci türevi yerel (lokal) minimumu verirken ikinci türevi global minimuma eşittir.



Şekil 21. Optimizasyon metodu olan gradyan inişin üç ve iki boyutta temsili gösterimi (Moolayil, 2019'dan değiştirilerek)

1.13. Hiperparametreler (Hyperparameter)

Makine öğreniminde modeli daha iyi ve hızlı eğitmek için değiştirilebilen parametrelerdir. Regülerizasyon, öğrenme oranı gibi.

1.13.1. Öğrenme Katsayısı (Learning Rate)

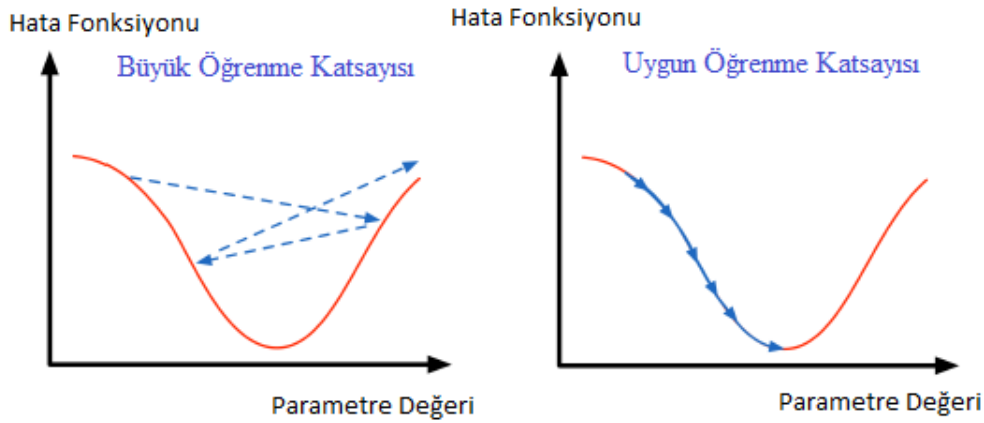
Bir sinir ağının, hata fonksiyon alanını geçerken parametre vektöründe aldığı güncellemelerin boyutunu ölçekleyen bir katsayıdır.

Geri yayılım sırasında hata oranı öğrenme katsayısı ile çarpılır ve sonra yeni bir ağırlığa ulaşmak için bu değer bir önceki ağırlıktan çıkarılır.

$$w := w - \alpha \frac{\partial y}{\partial x}$$

Öğrenme Katsayısı

Büyük bir öğrenme katsayısı (örneğin 1) parametrelerin sıçrama yapmasına sebep olur. Küçük bir öğrenme katsayısı (örneğin 0.00001) parametrelerin daha yavaş bir adımla güncellenmesini sağlar. Büyük sıçramalar başlangıçta ağın eğitilmesinde zaman kazandıracaktır ancak bu durum ağın iyi öğrenmesini engeller. Buna karşılık, küçük öğrenme katsayısı ağı az bir hataya götürür (yerel bir minimum), küçük öğrenme katsayısı ağı eğitilmesi için çok uzun zaman gerektirir ve yoğun bir hesaplama yüküne neden olur. Öğrenme katsayıları her ağ için farklı değer alır, bir ağ için iyi sonuç veren öğrenme katsayısı değeri başka bir ağ için iyi sonuç vermeyebilir. Öğrenme oranı çoğu kez diğer hiper parametrelere de bağlıdır.



Şekil 22. Büyük ve küçük öğrenme katsayısının iki boyutta model eğitiminde ilerleyişi verilmiştir (Moolayil, 2019'dan değiştirilerek)

1.13.2. Regülerizasyon

Regülerizasyon, kontrol dışı parametrelerin etkilerini düzenlemeye yardımcı olur. Regülerizasyonun temel amacı, makine öğreniminde aşırı öğrenmeyi kontrol etmektir. Aşırı öğrenmiş yapay sinir ağında bu durumu öngören bir belirleyici yoktur. Bu durumu aşmak için Dropout, L1 ve L2 regülerizasyon işlemleri yapılır.

Regülerizasyon, ezberlemeyi azaltan bir süreçtir. Model gürültülü bir numuneyle karşılaşabilir. Eğer gürültülü numune ağda eğitilirse, gürültünün ağırlıkları desen olarak

yerleşmiş olur. Böyle bir durumda nörondaki ağırlık değerleri yerine gürültüler ağda güncellenir. Regülerizasyon bu gibi durumlarda ağa müdahale ederek yanlış veya aşırı uç değerlerin ağırlıklara etkisini engeller.

Regülerizasyon işlemini formülize etmek gerekirse;

$$\text{Maliyet değeri}_{(\text{Regülerizasyon})} = \text{Model kayıp fonksiyonu} + \text{Hiperparametreler} \times \text{Ağırlıklar}$$

L1 ve L2 regülerizasyon yöntemleri sinir ağı parametre uzayının bir yönde fazla büyümesini önlerler. Büyük ağırlık değerlerini daha küçük yaparlar. Model karışıklığı arttıkça kayıp fonksiyonuna L1 ve L2 regülerizasyon hiper parametresi olan lamda (λ) eklenerek model değerleri genelleştirilir, böylece ağın aşırı ezberlemesi önlenmiş olur.

1.13.2.1. L1 Regülerizasyon

L1 regülerizasyonu, veri kümesinde gerekli olmayan çok sayıda giriş özelliği varsa, sinir ağının gereksiz özellikleri algılamasına ve yok saymasına yardımcı olur. L1 regülerizasyonunda modeli daha genel hale getirmek için, ağırlıklar sıfıra yakınsanır, ağırlıklar sıfıra yakınsanınca eğitim işleminden düşürülür. Bu sayede ağırlıkların yorumlanmasını kolaylaştırır ve modelin hızlı eğitilmesini sağlar. L1 düzenleme tekniği bir regresyon modeli olan Lasso Regression olarak da adlandırılır. Lasso Regresyonu (En az mutlak büzülme ve seçim operatörü), kayıp fonksiyonuna ağırlıkların “mutlak değerini” ekler. Formüle etmek gerekirse;

$$\text{Maliyet Fonksiyonu} = \text{Kayıp} + \frac{\lambda}{2m} \sum \| \text{Ağırlıklar} \|$$

1.13.2.2. L2 Regülerizasyon


L2 regülerizasyonunda kullanılan model ridge regresyonu olarak adlandırılır. L2 regülasyonunda, ağırlıkların karesi kayıp fonksiyonuna eklenir. Modeli daha genel hale getirmek için, ağırlıkların değerlerini sıfıra yaklaştırır. Bu nedenle buna “ağırlık azalması” yöntemi de denir. L2 regülerizasyonu genellemeyi iyileştirir, giriş değerleri değişikçe

modelin çıktısını düzeltir. Ağın kullanmadığı ağırlıkları görmezden gelmesine yardımcı olur. Formülasyonu aşağıdaki gibidir;

$$\text{Maliyet Fonksiyonu} = \text{Kayıp} + \frac{\lambda}{2m} \|\text{Ağırlıklar}\|^2$$

1.13.3. Dropout

Dropout, sinir ağlarının eğitimini geliştirmek için bir veya daha çok nöronun atlanarak kullanılmasını sağlayan yöntemdir. Eğitimi hızlandırır. Dropout, bir nöronun rastgele kapatılmasıyla gerçekleştirilir. Böylece ağdaki bağlantıların karmaşıklaşmasını sağlayarak aşırı öğrenmeyi engeller.



Şekil 23. Çok katmanlı bir yapay sinir ağı ve dropout durumunda pasif hale gelen nöronlar (URL-14, 2019'dan değiştirilerek)

1.14. Küme Seti (Mini Batch)

Eğitim verisi üzerinde belirlenen verilerin küçük gruplar halinde öğrenme işlemine tabi tutulmasıdır. Bu şekilde eğitilmek üzere birden fazla giriş vektörü gönderilir. Bu yöntem, bilgisayar mimarisi düzeyinde donanım ve kaynakların daha verimli kullanılmasını sağlar. Bu yöntem aynı zamanda belirli lineer cebir işlemlerini (özellikle matris çarpımlarını) vektörel olarak GPU üzerinde hesaplamasına yardımcı olur.

1.15. Epok

Epok, algoritmanın tüm veri kümesinde kaç kez çalışacağını tanımlayan bir hiperparametredir. Veri kümesindeki tüm girdiler bir ileri ve bir geri yayılım yaptığında 1 epok tamamlanır.

1.16. İterasyon (Yineleme)

İterasyonlar, bir epokun tamamlanması için gereken minibatch sayısıdır. Örneğin 2000 veri örneğine sahip bir veriseti 500'lük küme setine bölüldüğünde eğitim işlemini bir epokta yapmak için 4 kez yineleme işlemi gerçekleştirilir.

1.17. Derin Öğrenmenin Blokları

Derin öğrenme yöntemleri olan konvolüsyonel yapay sinir ağları (CNN) ve yinelemeli yapay sinir ağ (RNN) mimarilerine bakıldığında, çoğunlukla ileri beslemeli çok katmanlı yapay sinir ağları, kısıtlı boltzman makineleri (RBM) ve oto-kodlayıcılara dayanır. Bunlar derin öğrenme yöntemleri kullanılarak oluşturulacak mimarilerin yapıtaşlarıdır.

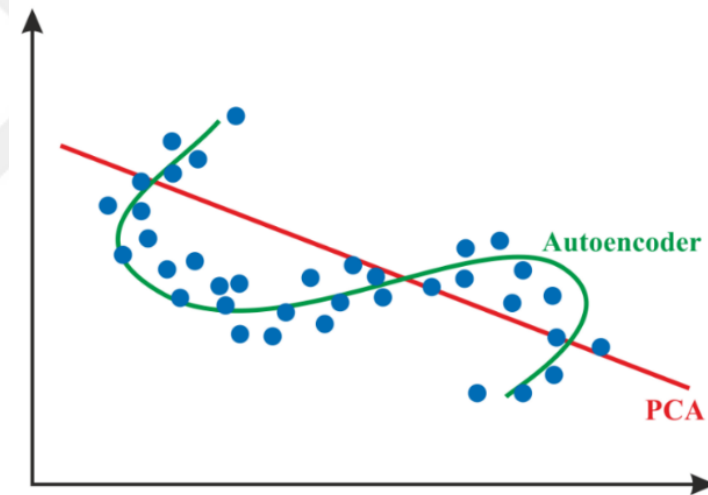
1.17.1. Kısıtlı Boltzman Makinaları (RBM)

Kısıtlı Boltzman Makineleri (RBM) model olasılığı ve özellik çıkarımı için kullanılır. RBM'ler verilerin içlerinde bir biastan ziyade iki bias ile tek yönlü eğitimin yapıldığı ileri beslemeli ağlardır. RBM'ler denetimsiz (unsupervised learning) olarak girdi verisini bir gizli katmana eşleyerek ve ardından gizli katmandan girdiyi yeniden oluşturmaya çalışarak kullanılan bir tür sinir ağıdır. "Kısıtlı Boltzmann Makineleri" adının "kısıtlı" adı, aynı katmandaki düğümlerin birbiri arasındaki bağlantıların yasak olmasından dolayı verilmiştir. RBM'ler özellik çıkarma ve boyut küçültme yöntemleriyle veriyi daha iyi öğrenmek için kullanılır.

1.17.2. Oto-Kodlayıcılar

Oto- kodlayıcılar, ekstra biasa sahip ileri beslemeli sinir ağlarının bir çeşididir. Çıktı katmanında orijinal giriş yeniden oluşturulur. Bu, denetimsiz (unsupervised learning) bir özellik çıkarma işlemidir. Eğitim işleminden sonra, oto kodlayıcılar daha sonraki işlemler için ileri beslemeli bir sinir ağı olarak kullanılabilir. Sinir ağı, etiketleri olan geri yayılım ile oluşturulmuş ağırlıkların (backpropagation) yerine orijinal ağırlıkları, öğrenmek için girdi olarak kullanır. Derin sinir ağları RBM'leri ve otomatik kodlayıcıları daha büyük ağlar için yapı taşları olarak kullanır (ancak, tek bir ağın her ikisini de kullanıldığı nadirdir).

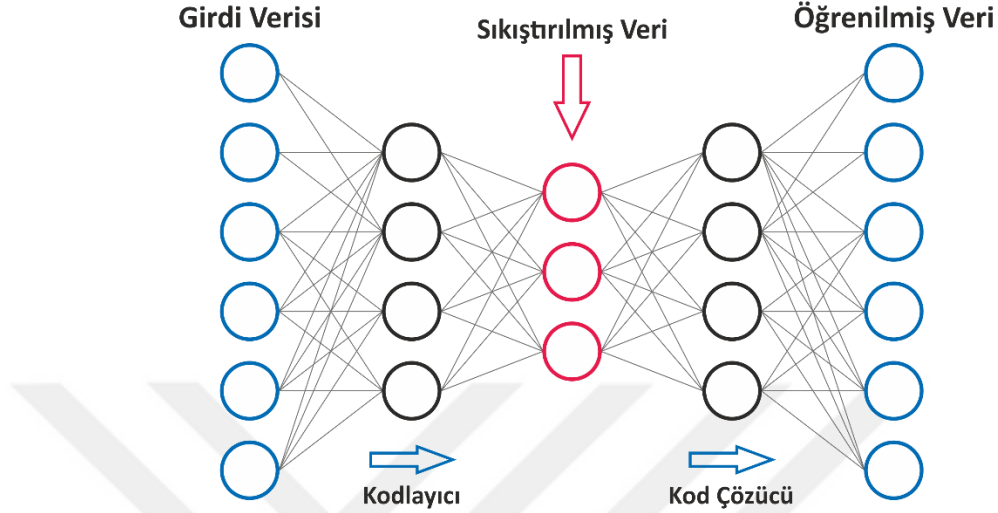
Veri kümelerinde istenilen özelliği çıkarmak ve gürültü gidermek için oto kodlayıcılar kullanılır. Genellikle, bir veri kümesinin boyutunu azaltarak ağın çıkış ve giriş verileri en uygun biçimde yeniden yapılandırılır. Örneğin PCA lineer boyut azaltma işlemiyken oto-kodlayıcılar non-lineer boyut azaltıcılarıdır.



Şekil 24. Lineer boyut azaltma yöntemi olan PCA ile nonlineer boyut azaltma yöntemi olan Oto-Kodlayıcıların temsili gösterimi (Patterson ve Gibson, 2017'den değiştirilerek)

Oto kodlayıcılar, çok katmanlı yapay sinir ağlarıyla bir giriş katmanına, gizli katmanlara ve çıkış katmanına sahip olmaları ile birbirlerine benzemektedir. Çok katmanlı yapay sinir ağı ile oto kodlayıcı ağ şeması arasında dikkat edilmesi gereken en önemli fark, oto kodlayıcıdaki çıktı katmanının, girdi katmanı ile aynı sayıda düğümüne (node) sahip olmasıdır. Oto-kodlayıcılar, çok katmanlı yapay sinir ağlarından birkaç şekilde farklılık gösterir. Veri seti üzerinde doğrudan etiketlenmemiş verilerden öğrenirler. Çok katmanlı bir

ağın amacı, bir sınıf üzerinden tahminler oluşturmakken (örneğin, kedi veya kedi değil) bir oto kodlayıcı kendi girdi verisini çoğaltmak için eğitilmiştir (Patterson vd., 2016).



Şekil 25. Boyut küçülterek sıkıştırılmış veri üzerinden öğrenen ve çıktıda tekrar aynı boyuta gelen oto-kodlayıcı topolojisi (Patterson ve Gibson, 2017'den değiştirilerek)

Oto kodlayıcılar temel olarak mimari ve yapısal olarak ileri beslemeli yapay sinir ağlarına benzeyen denetimsiz bir öğrenme algoritmasıdır. Ağırlıkları güncellemek için geri yayılım yaparlar (Bkz. Denklem 1.32).

$$h = f_{\theta}(x) = \sigma(Wx + b) \quad (1.32)$$

$\theta = \{W, b, \text{oto-kodlayıcı için ağırlık ve bias matrisi}\}$

$\sigma(\cdot)$, Sigmoid veya Tanh gibi oto-kodlayıcılar için doğrusal olmayan bir aktivasyon işlevidir. Kodlama işleminin ardından h çıktısı yeniden yapılandırılmak için kod çözücü aşamasına $h' \in [0,1]$ olacak şekilde iletilir (Denklem 1.33).

$$h' = g_{\theta'}(h) = \sigma'(W'h + b') \quad (1.33)$$

$\theta' = \{W', b' \text{ kod çözücü için ağırlık ve bias matrisi}\}$

$\sigma'(\cdot)$ kod çözücünün doğrusal olmayan bir aktivasyon fonksiyonu ifade eder.

Kod çözücü kısmında yeniden oluşturma (reconstruction) işlemi hatayı en aza indirerek gerçekleştirilir. x girdi verilerine bağlı olarak oto kodlayıcı çıkışını $h = f_{\theta}(x)$ ifade edersek; kod çözücü çıkışı $h' = g_{\theta'}(h)$ şeklinde olur. θ, θ' oto kodlayıcı ve kod çözücü için ağırlık ve bias değerlerini ifade eder. \mathcal{L} , oto-kodlayıcı ve kod çözücü arasındaki karesel ortalama hatayı ifade eden kayıp fonksiyonudur.

$$\mathcal{L}(h, h') = \|h - h'\|^2 = \frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2 \quad (1.35)$$

Denklem 1.35' e bakıldığında h kodlayıcı aşamasından sonra yeniden yapılandırılmak üzere kod çözücü katmanına gönderilen sonuç değerlerini ifade eder. h' kod çözücü katmanında girdi görüntüsüyle aynı ebatlara getirilen çıktı görüntüsüdür. Girdi ve çıktı görüntüleri arasındaki hata minimum olacak şekilde Denklem 1.35'te belirtildiği gibi karesel ortalama değeri hesaplanır.

Oto kodlayıcı için yaygın olarak kullanılan kayıp fonksiyonlardan bir diğeri de Denklem 1.36'da belirtilen çapraz entropidir:

$$\mathcal{L}(h, h') = \sum_i x_i \log \frac{1}{h'_i} = - \sum_i x_i \log x'_i \quad (1.36)$$

Karesel ortalama hata oto kodlayıcılar için uygun olsa da eğer oto kodlayıcı bir sınıflandırma modeli için kullanılıyorsa, bu sınıflandırma işleminin Softmax katmanında çapraz entropi fonksiyonu tercih edilir. Oto kodlayıcılar anomali tespit işlemlerinde sistemleri güçlendirmede iyidir. İki önemli oto kodlayıcı çeşidi vardır: Sıkıştırma oto kodlayıcıları ve denoise edici (gürültü giderici) oto kodlayıcılarıdır.



Şekil 26. Oto-kodlayıcı ile sıkıştırılmış veri ve gürültüsü giderilmiş resim (Patterson ve Gibson, 2017'den değiştirilerek)

1.18. Normalizasyon

Normalizasyon ham verilerin bir vektör temsiline dönüştürüldükten sonra $[0, 1]$, $[-1, 1]$ gibi bir aralıkta ölçeklendirilmesidir. En sık bilinen normalizasyon yöntemi min-max ölçeklendirmesidir.

Min-max normalizasyonu aykırı değerlere karşı daha hassastır. Her bir değerden minimum değer çıkarılarak, en büyük değer ile en küçük değer arasındaki farka bölünerek normalizasyon işlemi yapılır. (Bkz. Denklem 1.37)

$$X_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1.37)$$

1.19. Modelin Değerlendirilmesi

1.19.1. Hata Matrisi

Modelin veya sınıflandırıcının ne kadar iyi performans gösterdiğini anlamak için kullanılır.

	P' (Tahmin)	N' (Tahmin)
P (Gerçek)	Doğru Pozitif	Yanlış Negatif
N (Gerçek)	Yanlış Pozitif	Doğru Negatif

Şekil 27. Hata Matrisi (Patterson ve Gibson, 2017'den değiştirilerek)

Hata matris yukarıda belirtilen sınıflardaki değerlerin sayılmasıyla ölçülür.

•Doğru pozitif

- Tahminin pozitif, etiket sınıfının da pozitif olduğunu ifade eder.

- Yanlış pozitif
 - Tahminin pozitif, etiket sınıfının da negatif olduğunu ifade eder.
- Doğru negatif
 - Tahminin negatif, etiket sınıfının da negatif olduğunu ifade eder.
- Yanlış negatif
 - Tahminin negatif, etiket sınıfının da pozitif olduğunu ifade eder.

Modelin doğruluğu;

$$Doğruluk = \frac{(DP+DN)}{(DP+YP+YN+DN)} \quad (1.38)$$

Aynı koşullar altında tekrarlanan ölçümlerin bize aynı sonuçları verme derecesi, hassasiyet olarak adlandırılır. Hassasiyet, pozitif tahmin değeri olarak da bilinir.

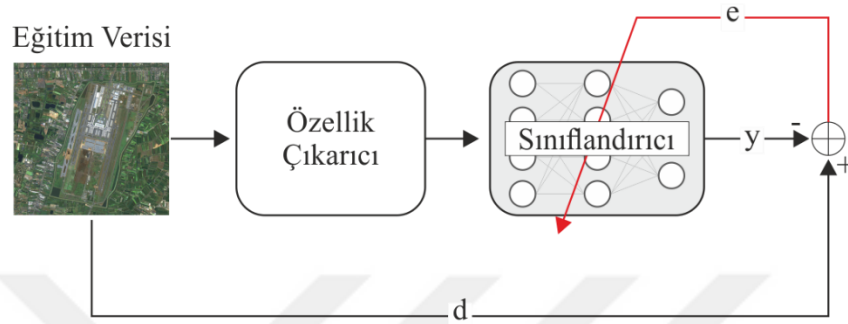
$$Hassasiyet = \frac{DP}{(DP+YP)} \quad (1.39)$$

1.20. Evrişimsel Yapay Sinir Ağı

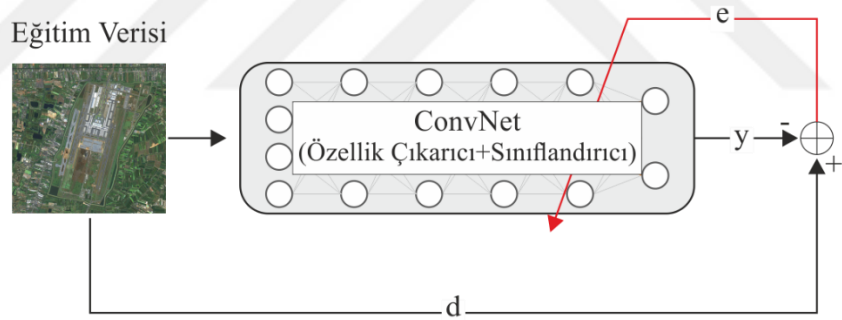
Evrişimsel sinir ağı beynin görsel korteksinin görüntüleri nasıl işlediğini ve tanıdığını taklit eden derin bir ağıdır. ConvNet, 1980'lerde ve 1990'larda geliştirilen eski bir tekniktir. Ancak, büyük veri seti ve donanımsal yetersizlikler dolayı bir süredir unutulmuştur. 2012'den bu yana hızlı bir şekilde yeniden canlanmaya başlayan ConvNet bilgisayarla görü alanında kullanımı hızla artmaktadır. Görüntülerden nesne, yüz, birey, sokak işaretleri tanıyıp, sınıflandırabilirler. Konvolüsyonel yapay sinir ağları (CNN), optik karakter tanıma yoluyla metin ve ses analizinde, kendi kendine hareket edebilen otomobiller, robotlar, dronlar ve görme engellilerin tedavisi için geliştirilen uygulamalara sahip makinelerde kullanılır.

CNN'ler temel olarak, görüntü sınıflandırmada kullanılır. Örneğin, bir resmin görüntüsünün bir kedi mi yoksa köpek mi olduğunu belirlemek, görüntüyü bir kedi veya köpek sınıfına atamakla aynıdır. Bu sınıflandırma durumu harf tanıma için de geçerlidir; bir görüntüdeki harfi tanımak, görüntüyü harf sınıflarından birine sınıflandırmak anlamına gelir.

CovNet mimarisini diğer makine öğrenme yöntemlerinde ayıran en önemli fark sınıflandırmanın yanı sıra özellik çıkarma işlemini de gerçekleştirmesidir. ConvNet, giriş görüntüsünün özelliklerini çıkaran bir sinir ağından ve özellik görüntüsünü sınıflandıran başka bir sinir ağından oluşur



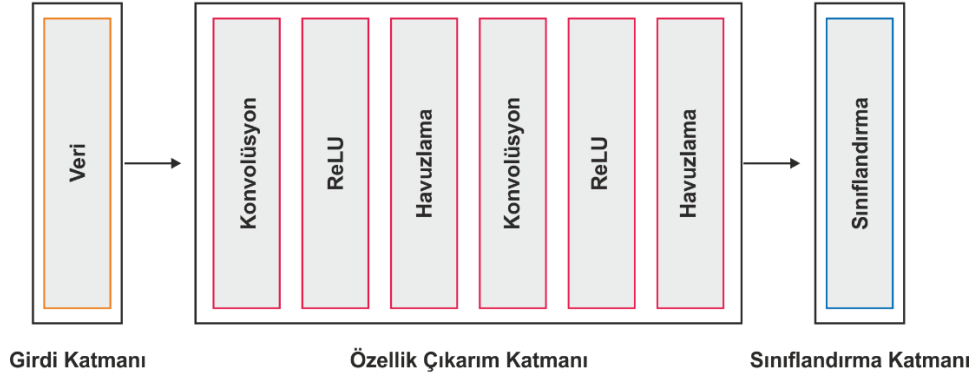
Şekil 28. Makine öğrenmesi sınıflandırıcısı (Patterson ve Gibson, 2017'den değiştirilerek)



Şekil 29. CNN mimarisi özellik çıkarıcı ve sınıflandırıcısı (Patterson ve Gibson, 2017'den değiştirilerek)

Makine öğrenmesi yöntemlerinde özellik çıkarmak için metot ayrıca modele eklenirken ConvNet ile bu işlem bir arada yapılır. ConvNet mimarilerinin makine öğrenmesi yöntemlerine karşı bir üstünlüğü de budur.

1.20.1. CNN Mimarisi



Şekil 30. Girdi katmanı, özellik çıkarım katmanı ve sınıflandırma katmanı ile bir CNN mimarisi. Özellik çıkarım katmanı konvolüsyon, ReLU ve havuzlama aşamalarını içermektedir (Patterson ve Gibson, 2017'den değiştirilerek)

CNN mimarilerinin çalışma prensibine bakacak olursak;

Giriş görüntüsü, özellik çıkarım katmanına girer. Özellik çıkarım katmanı, konvolüsyon, ReLU ve havuzlama katman çiftlerinden oluşur. Evrişim (konvolüsyon) katmanı, adından da anlaşılacağı gibi, evrişim işlemi kullanarak görüntüyü filtreye tabi tutar. Dijital filtreler topluluğu olarak düşünülebilir.

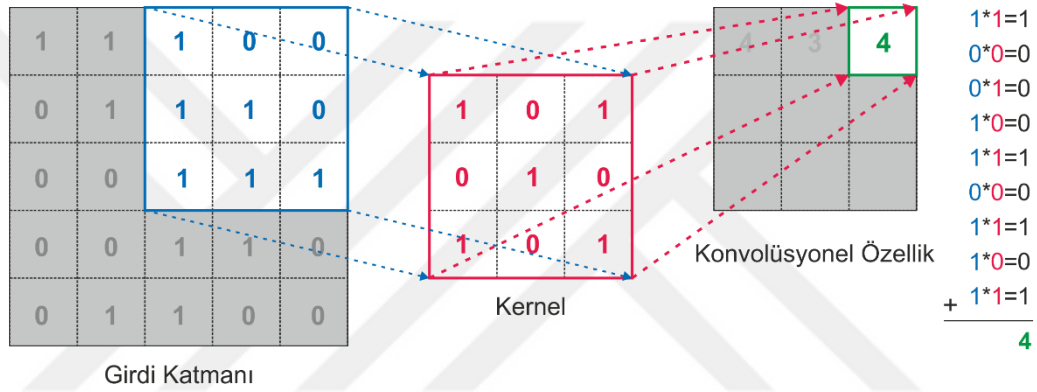
ReLU katmanında konvolüsyon işlemi sonucu değerler bir aktivasyona tabi tutulur.

Havuzlama katmanı, komşu pikselleri tek bir piksel halinde birleştirir. Bu nedenle, havuz katmanı görüntünün boyutunu azaltır. ConvNet; evrişim ve havuzlama işlemlerini kavramsal olarak iki boyutlu bir düzlemde gerçekleştirir. Bu, ConvNet ile diğer sinir ağları arasındaki farklardan biridir. Özet olarak evrişim katmanı, konvolüsyon işlemi yoluyla görüntülere filtre uygular ve havuzlama katmanı görüntünün boyutunu azaltır. Giriş katmanı, (genişlik \times yükseklik) uzamsal olarak alan ve renk kanallarını temsil eden bir derinliğe sahip üç boyutlu bir görüntüdür (Örneğin; bu derinlik RGB renk kanalları için üçtür).

Sınıflandırma katmanında, özellik çıkarım katmanının gelen değerler tek bir sütun olarak (flatten) düzenlenir ve entropi gibi işlemlerle sınıflandırılması yapılır.


1.20.2. Konvolüsyon

Konvolüsyon katmanı görüntüleri dönüştüren filtreler içerir. Bu filtrelere konvolüsyon filtresi veya “kernel” denir. Aldığı girdi değerleri üzerinde bir konvolüsyon kerneli uygulayıp sonuç olarak bir özellik haritası oluşturur. Özellik haritası, orijinal görüntünün benzersiz özelliklerini vurgular. Bu girdi değerleri ham veri ya da bir önceki konvolüsyon işleminden sonra oluşan özellik haritası da olabilir. Konvolüsyon katmanı konvolüsyon filtreleriyle aynı sayıda özellik haritası oluşturur. Örneğin, evrişim katmanı dört filtre içeriyorsa, dört özellik haritası oluşturulur.



Şekil 31. Konvolüsyon işlemi. Bu işlemde girdi katmanı ile kernelin element matris çarpımları yapılıp toplanmıştır. Sonuç değeri özellik haritasına atanır (URL-15, 2019’dan değiştirilerek)

Evrişim filtrelerini daha detaylı incelersek; konvolüsyon tabakasının filtreleri (kernel) iki boyutlu matrislerdir. Genellikle 5×5 'lik veya 3×3 'lük matrislerden oluşurlar. Evrişim katmanının son aşamasında 1×1 evrişim filtreleri de kullanılabilir. Filtre matrisini oluşturan değerler eğitim süreci ile güncellenebilir. Bir görüntünün evrişim filtresi işlemi ile bir özellik haritası üretilirse Şekil 31.’deki gibi bir sonuç üretilir.

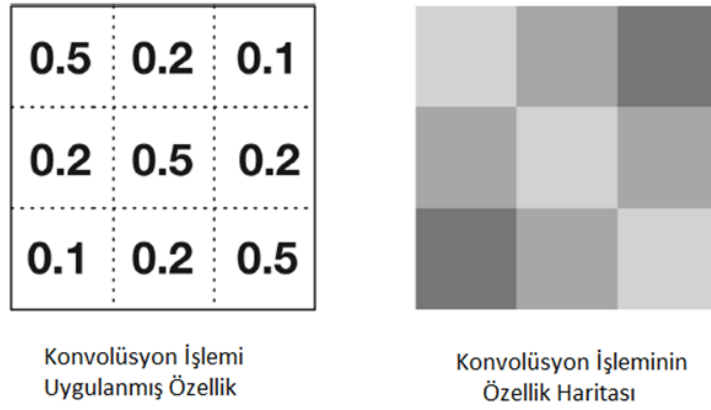


Şekil 32. İlk konvolüsyon işlemi sonucu oluşan özellik haritası (a), ikinci konvolüsyon işlemi sonrası oluşan özellik haritası (b), üçüncü konvolüsyon işlemi sonucu oluşan özellik haritası (c) ve dördüncü konvolüsyon işlemi sonucunda üretilen özellik haritası (d) (Kim, 2017'den değiştirilerek)

Özet olarak, evrişim katmanı giriş görüntüsündeki evrişim filtrelerini çalıştırır ve özellik haritalarını üretir. Evrişim katmanının çıkardığı özellikler, hangi evrişim filtresinin kullanıldığına bağlı olarak değişir. Evrişim filtresinin yarattığı özellik haritası, katman çıkışı vermeden önce aktivasyon fonksiyonu üzerinden işlenir. Konvolüsyon tabakasının aktivasyon işlevi, normal sinir ağınıninkiyle aynıdır.

1.20.3 Özellik Haritaları

Yapay sinir ağlarında bir nöronun bilgini geçmesine izin verildiğinde sonuç sayısal olarak üretilir. Özellik haritaları bu değerlerin etiketlenerek görsel olarak gösterilmesidir.



Şekil 33. Sayısal değerlerin özellik haritası olarak gösterimi (URL-15, 2019'dan değiştirilerek)

Evrişimsel yapay sinir ağlarının yaptığı işlem formüle edilirse;

$$h(t) = x(t) \times w(t) = \sum_{i=-\infty}^{\infty} x(i) \times w(t - i) \quad (1.40)$$

w kernel, x girdi değerleri, h çıktı değerleri (özellik haritaları), t'de zaman bilgisini ifade etmektedir.

İki boyutlu bir veri için örneğin bir görüntünün evrişim işlemi;

$$h(i, j) = x(i, j) \times w(i, j) = \sum_m \sum_n x(i, j) w(i - m, j - n) \quad (1.41)$$

(i, j) görüntü matrisinin konumunu ifade eden x giriş matrisine w filtresi uygulandıktan sonra h(i, j) görüntü çıktısı elde edilmiştir.

1.20.4 ReLU Katmanı

ReLU Katmanı, CNN mimarisindeki ikinci veya dördüncü katmandır, amacı tüm negatif değerleri sıfır olarak değiştirerek ve tüm pozitif değerleri koruyarak görüntünün piksellerini normalleştirmektir.

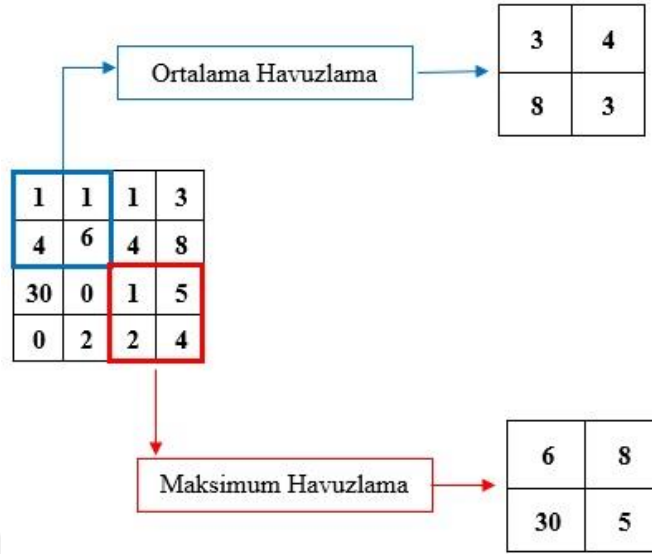
1.20.5 Havuzlama Katmanı

Havuzlama katmanı, görüntü üzerinde belirli bir alanının komşu pikselleri yerine bu komşu piksellerini temsil eden tek bir temsilci değeri atar ve böylece görüntünün boyutunu küçülmüş olur. İşlemleri havuzlama katmanında yürütmek için görüntüdeki havuz piksellerini nasıl seçeceğinizi ve temsilci değerini nasıl ayarlayacağını belirlenmelidir. Komşu pikseller genellikle kare matris seçilir ve birleştirilen piksellerin sayısı probleme göre farklılık gösterir. Temsil değeri, genellikle seçilen piksellerin ortalaması veya maksimum değeridir. İki boyutlu bir işlem olduğundan daha iyi anlaşılması için bir örnekle ifade edilirse;

1	1	1	3
4	6	4	8
30	0	1	5
0	2	2	4

Şekil 34. 4x4'lük bir görüntü matrisi (URL-15, 2019'dan değiştirilerek)

2×2'lik bir ortalama ve maksimum filtresi seçilip havuzlama işlemi gerçekleştirilirse; Şekil 35.'te verilen boyutu küçülmüş matris elde edilir.



Şekil 35. 4x4'lük görüntü matrisine uygulanan maksimum ve ortalama havuzlama sonucu oluşan uzamsal çözünürlüğü düşen görüntü matrisi (URL-16, 2019'dan değiştirilerek)

Aslında, havuzlama işlemi matematiksel anlamda yine bir evrişim işlemidir. Evrişim katmanından farkı, evrişim filtresinin sabit olması ve evrişim bölgelerinin üst üste binmemesidir. Havuzlama katmanı, değişik ve eğik nesnelere bir dereceye kadar da dengelemektedir. Örneğin, havuzlama katmanı, veri de görüntünün merkezinden uzak olan bir kedinin tanınmasını sağlar. Havuzlama işlemi görüntünün boyutunu düşürdüğü için, hesaplama yükünü hafifletir ve ağırlaşmasını engeller.

1.20.6 Doldurma (Padding)

Havuzlama işlemlerinden sonra verideki boyut kaybı ve köşe bilgisinin kaybedilmesinden dolayı verinin çevresine boyutunu artıracak şekilde bir çerçeve oluşturulmasıdır. Örneğin 'Same' doldurma işlemi yapıyorsanız bu girdi görüntüsünün etrafına 0'lardan oluşan bir çerçeve yapmaktır.

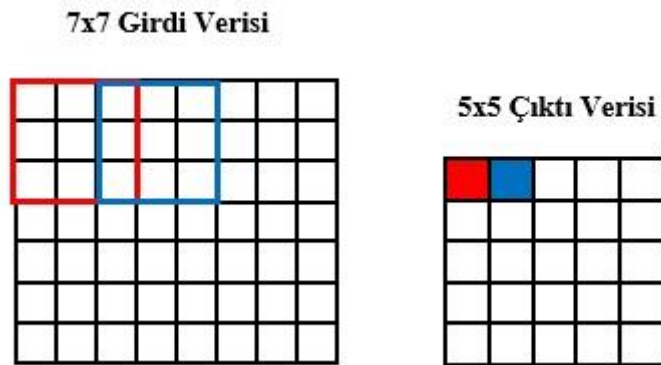
Filtre							
1	0						
0	2						
Girdi	0	0	0	0	0	0	0
	0	1	0	2	2	0	0
	0	0	2	1	0	0	0
	0	0	1	2	1	0	0
	0	1	2	2	1	0	0
	0	0	0	0	0	0	0

Doldurma
↓

Şekil 36. Görüntü matrisi çevresinin sıfırlardan oluşan değerlerle doldurma işlemi-Same doldurma yöntemi (URL-16, 2019'dan değiştirilerek)

1.20.7 Kaydırma (Stride)

Uygulanacak filtrenin kaç adımda bir filtreleme işlemi yapacağını belirtir. Örneğin, kaydırma iki ise her bir evrişim işleminin ardından iki piksel sonra işleme devam edilir.



Şekil 37. İki hücrede bir kaydırma yapılan temsili matris görüntüsü (URL-15, 2019'dan değiştirilerek)

1.20.8. Sınıflandırma Katmanı


1.20.8.1 U-NET Mimarisi

Görüntünün semantik olarak bölütlenmesini sağlayan mimari, ilk olarak biyomedikal görüntüler üzerinde hastalık tanısı tespiti için geliştirilmiştir. U-NET mimarisi adını, yapısı U harfine benzediği için almıştır. Anlamsal görüntü bölütlemesi görüntünün her pikselini kendisine karşılık gelen bir sınıfla etiketlenmesidir.



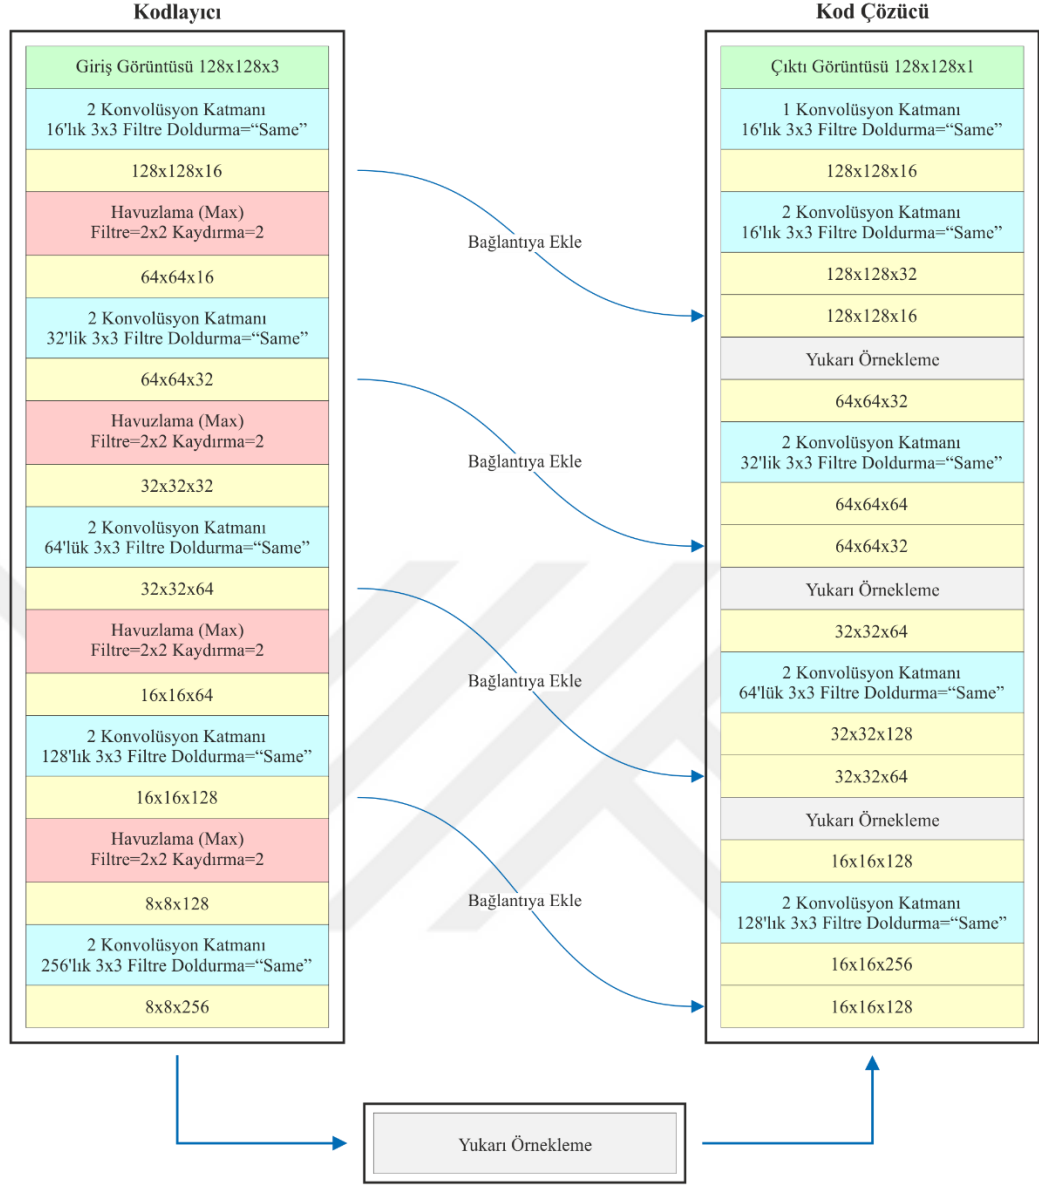
Şekil 38. Normal görüntü ve anlamsal olarak işaretlenmiş (segmente) görüntü (URL-17, 2019)

Mimari üç kısımdan oluşmaktadır: Büzülme, darboğaz ve genişleme. Büzülme, görüntüdeki içeriği yakalamak için kullanılan yöntemdir (kodlayıcı olarak da adlandırılır). Kodlayıcı, geleneksel bir evrişimli ve maksimum havuzlama katmanları yığınıdır. Her bir blok girdi alır ve iki adet 3×3 'lük filtreye sahip evrişim katmanının ardından en fazla 2×2 'lik havuzlama işlemi gerçekleştirilir. Her bloktan sonra özellik haritaları iki katına çıkar ve bu şekilde mimarideki karmaşık yapılar etkili bir şekilde öğrenilebilir. En alttaki darboğaz bölümü daralma katmanı ve genişleme katmanı arasında aracılık eder. Genişleme, devredilen konvolüsyonları kullanarak hassas lokalizasyonu sağlamak için kullanılan simetrik genişleme yoludur (kod çözücü/dekoder olarak da adlandırılır).



Şekil 39. U-NET mimarisi ve sağ altta belirtilen mimari işlem notasyonu (Ronneberger vd., 2015'ten değiştirilerek)

Yukarıdaki Şekil 39.'da görülen U-NET mimarisi için, her mavi kutu çok kanallı bir özellik haritasına karşılık gelir. Kanal sayısı kutunun üstünde gösterilmiştir. $(x \times y)$ boyutu kutunun sol alt kenarında bulunur. Beyaz kutular kopyalanan özellik haritalarını temsil etmektedir. Mimariyi biraz daha açarak inceleyecek olursak;



Şekil 40. U-NET mimarisinin kodlayıcı ve kod çözücü aşamalarında gerçekleşen işlemlerin kavram haritası

Konvolüsyon katmanları, iki ardışık konvolüsyon işlemi uygulanır. Konvolüsyon katmanların sonucu oluşan çıkış tensörleri, maksimum havuzlama (max pooling) havuzlama yapılarak boyutu azaltılır.

Sol kısım, düzenli konvolüsyonlar ve maksimum havuzlama katmanlarının uygulandığı kodlayıcı kısmıdır. Kodlayıcıda, derinlik kademeli olarak artarken görüntünün boyutu yavaş yavaş azalır (128x128x3'ten 8x8x256'ya doğru). Bu temelde ağır görüntüdeki "NE" bilgisini öğrendiği ancak "NEREDE" bilgisini kaybeder.

Sağ kısım, devredilen konvolüsyonlar üzerine yeni konvolüsyonların uygulandığı kod çözücü kısımdır. Bu katmanda yukarı örnekleme yapılarak boyutu küçülen girdi verisinin boyutu tekrar arttırılır ve kod çözücünden gelen aynı boyuttaki görüntü ile birleştirilir. Şekil 40.'daki bağlantıya ekle bunu ifade eder. Kod çözücüde görüntünün boyutu yavaş yavaş arttırılır böylece derinlikte azalma olur. (8x8x256'den 128x128x1'e doğru) Sezgisel olarak, kod çözücü katmanında kademe kademe yukarı örnekleme yapılarak "NEREDE" bilgisi çıkarılır.

Görüntü üzerinde tespit edilen objelerin kesin konumlarını tam anlamıyla belirlemek için, kod çözücünden gelen görüntüler ile yukarı örnekleme yapılarak aktarılan Konvolüsyon katman çıktıları birleştirilir. Her birleştirme işleminden sonra, art arda iki konvolüsyon işlemi daha uygulanarak modelin daha doğru çıktı vermesi sağlanır.

Giriş ile çıkış görüntü arasındaki ilişkiye bakarsak;

Giriş (128x128x3) => Kodlayıcı => (8x8x256) => Kod Çözücü => Çıkış (128x128x1)

2. YAPILAN ÇALIŞMALAR

Bu tez çalışmasıyla Harran Ovası'nda 2010 yılında görülen toprak tuzluluğunun derin öğrenme yöntemiyle tespiti amaçlanmıştır. GAP kapsamında 1995 yılında ovada sulu tarım başlamıştır. Yanlış sulama ve drenaj yetersizliğinden dolayı zamanla ovada tuzlulaşma meydana gelmiştir. Tuzluluğun şiddetli olarak görüldüğü 2010 yılına ait RapidEye uydu görüntüsü kullanılarak bir derin öğrenme yöntemi olan U-NET mimarisi ile ovanın tuzluluğu tespit edilmiştir.

2.1. Çalışma Alanı

Türkiye'nin 3. büyük ovası olan Harran Ovası (diğer adıyla Altınbaşak Ovası) Şanlıurfa merkeze 44 km uzaklıkta olup kuzeyde Urfa dağları, batıda Fatik dağları ve doğuda ise Tektek dağlarıyla çevrilidir. Ovanın toplam alanı 225.000 hektar olup 150.000 hektarlık alanda sulanabilir tarım yapılmaktadır (Akış vd., 2005). Çalışma bölgesi olarak 36° 51' 48.2976" N 39°1'59.5992" E ve 36° 41'25.6056" N ve 39° 10' 50.4444" E coğrafi koordinatlara sahip ovanın en tuzlu arazilerini kapsayan alan seçilmiştir. Yıllık buharlaşma miktarı ~1800 mm / yıl'dır (Bilgili vd., 2011).

GAP projesi kapsamında Harran Ovası'nda sulu tarıma ilk kez Nisan 1995'te Atatürk Barajı sularının ovaya verilmesiyle başlamıştır. 1995'te başlatılan sulama projeleri kademeli olarak devam etmiştir. 2010 yılında ovanın tamamına yakını sulamaya açılmıştır. Ovaya suyun Atatürk Barajı'ndan açık kanallarla gelmesi nedeniyle daha çok yüzey sulama metotları uygulanmıştır. Yüzey sulama metotları sonucu aşırı sulamalar nedeniyle ovanın en çukur alanındaki geçirimsiz zemin ve tahliye alt yapısının eksikliğinden dolayı taban sularında yükselme meydana gelmiştir (Çullu, 2011). 1995'ten beri yapılan yanlış sulama, taban suyu yükselmesi ve yüksek buharlaşma nedenlerinden dolayı ovada 2010 yılına gelindiğinde ciddi toprak tuzluluğu görülmüştür. GAP'la beraber artan tuzlulaşma sonucunda, ovada toplam tuzlu alanın 11.403 ha ulaştığı, genellikle Akçakale, Ekinyazı ve Gürgelen bölgelerinde etkili olduğu görülmüştür (Kanber vd., 2015). Sulama öncesi (1964-1965) yapılan arazi tasnif etüdü çalışmaları sonucunda 8513 hektar arazinin tuzlu, 3289 hektar arazinin tuzlu-sodyumlu ve 33 hektar arazinin de sodyumlu olduğu belirtilmiştir (DSİ, 1971). Özellikle yarı kurak bir iklime sahip Harran Ovası'nın jeomorfolojik yapısı ve iklim

koşulları tuzlulaşmanın artması için zemin hazırlamıştır. Harran Ovası'nın tuzlulaşmasının en önemli etkenlerinden biri olan jeomorfolojik yapının çevreye göre çukur olması ve bunun sonucu olarak taban suyunun birikmesi ovanın en düşük eğime sahip bölümünde görülmektedir (Horneck vd., 2007). Ovanın Suriye sınırına doğru biriken taban suları yüksek buharlaşmadan dolayı toprakta şiddetli tuzluluğuna neden olmuştur.



Şekil 41. Harran Ovası ve çalışma bölgesi olarak seçilen araziler (Google Earth, 2019)

Harran ovasında eğim kuzeyden güneye doğru artmakta olup ortalama yükseklik 500 metreden Akçakale ilçesine doğru 350 metreye kadar düşmektedir.

Şanlıurfa karasal iklimin hakim olduğu yazları sıcak ve kurak, kışları soğuk ve yağışlıdır. Gece ile gündüz arasındaki sıcaklık farkı fazladır. Türkiye'nin yazları en sıcak ili olan Şanlıurfa'nın yıllık güneşlenme süresi 3,033 saattir (URL-2, 2019)

SANLIURFA	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	Yıllık
Ölçüm Periyodu (1929 - 2018)													
Ortalama Sıcaklık (°C)	5.5	7.0	10.8	16.1	22.1	28.1	31.9	31.3	26.8	20.2	12.8	7.5	18.3
Ortalama En Yüksek Sıcaklık (°C)	9.9	11.9	16.4	22.3	28.6	34.6	38.7	38.3	33.9	27.0	18.7	12.0	24.4
Ortalama En Düşük Sıcaklık (°C)	2.0	2.9	5.8	10.3	15.2	20.5	24.2	23.9	19.9	14.5	8.4	3.9	12.6
Ortalama Güneşlenme Süresi (saat)	4.1	5.1	6.4	7.8	10.0	12.1	12.3	11.4	10.0	7.9	5.9	4.0	97.0
Ortalama Yağışlı Gün Sayısı	12.0	10.6	10.3	8.8	6.1	1.4	0.3	0.2	0.8	4.8	7.5	10.7	73.5
Aylık Toplam Yağış Miktarı Ortalaması (mm)	87.7	69.2	62.1	49.4	26.1	3.5	0.6	0.6	2.5	24.6	44.9	80.1	451.3
Ölçüm Periyodu (1929 - 2018)													
En Yüksek Sıcaklık (°C)	21.6	25.5	29.5	36.4	40.0	44.0	46.8	46.2	42.1	37.8	30.8	26.0	46.8
En Düşük Sıcaklık (°C)	-10.6	-12.4	-7.3	-3.2	2.5	8.3	15.0	16.0	10.0	1.9	-6.0	-6.4	-12.4

Şekil 42. Tarım ve Orman Bakanlığı Meteoroloji Genel Müdürlüğü 1981-2018 yılları arası sıcaklık değerleri

Şekil 42.'ye bakıldığında 1981-2018 yılları arasında temmuz ayı ortalama en yüksek sıcaklık değeri 38.7 °C'dir. Yıllık yağış miktarı düşük olup yaz aylarında yok denecek kadar azdır.

2.2. Yersel Tuzluluk Ölçümü ve Haritalama

Yersel tuzluluk verileri Harran Üniversitesi Ziraat Fakültesi'nden temin edilmiştir. Ziraat Fakültesi tarafından 2010 yılında GAP Kalkınma Ajansı'nın desteğiyle gerçekleştirilmiş olan projeye Harran Ovası'nda 509 noktadan 0-30 cm ve 30-60 cm derinlikten olacak şekilde toprak numuneleri alınmıştır. Alınan numunelerin konumları GPS kullanılarak belirlenmiştir. Yersel tuzluluk verileri ters mesafe ağırlıklı enterpolasyon yöntemi kullanılarak ArcGIS ortamında ovanın yersel tuzluluk haritası yapılmıştır.

Ters mesafe ağırlık (IDW) yöntemi çok sık tercih edilen bir enterpolasyon tekniğidir. IDW yöntemi, yalnızca komşu noktalardan tahminler üretmek için kestirim işlemi yapar. Noktaların birbirine olan uzaklıkları belirli bir ağırlıkla (dereceyle) ifade edilir. Noktalar birbirine yakınsa daha yüksek bir ağırlık değeri verilir.

Noktaların ters mesafe ilişki fonksiyonu denklem (2.1)'deki gibidir.


$$f(x, y) = \sum_{n=1}^k w_n r_n \quad (2.1)$$

Burada n, referans alınan nokta sayısı ve r bu noktadaki yağış, nem gibi değerlerdir. Noktaların birbirine göre ağırlıkları w_i Denklem 2.2’de olduğu gibi Shepard yöntemine göre hesaplanır. (Shepard,1968)

$$w_m = \frac{\frac{1}{d_{mn}^p}}{\sum_{i=1}^k \frac{1}{d_{mn}^p}} \quad (2.2)$$


Burada p, kullanıcı tarafından belirlenen 0 ile 5 arasında değer alan güç katsayısıdır (Kazancı ve Tanır, 2014). d_{mn} , enterpole edilecek noktaların, referans noktalarına olan uzaklığını ifade eder. Üç boyutlu uzayda bu uzaklık denklem 2.3’teki gibi hesaplanır.

$$d_{mn} = \sqrt{(x_m - x_n)^2 + (y_m - y_n)^2 + (z_m - z_n)^2} \quad (2.3)$$



Şekil 43.Çalışma bölgesi üzerinde görülen yersel tuzluluk ölçüm noktaları

Harran Ovası Tuzluluk Haritası



0,1,5,3 6 9 12
Kilometers

Legend

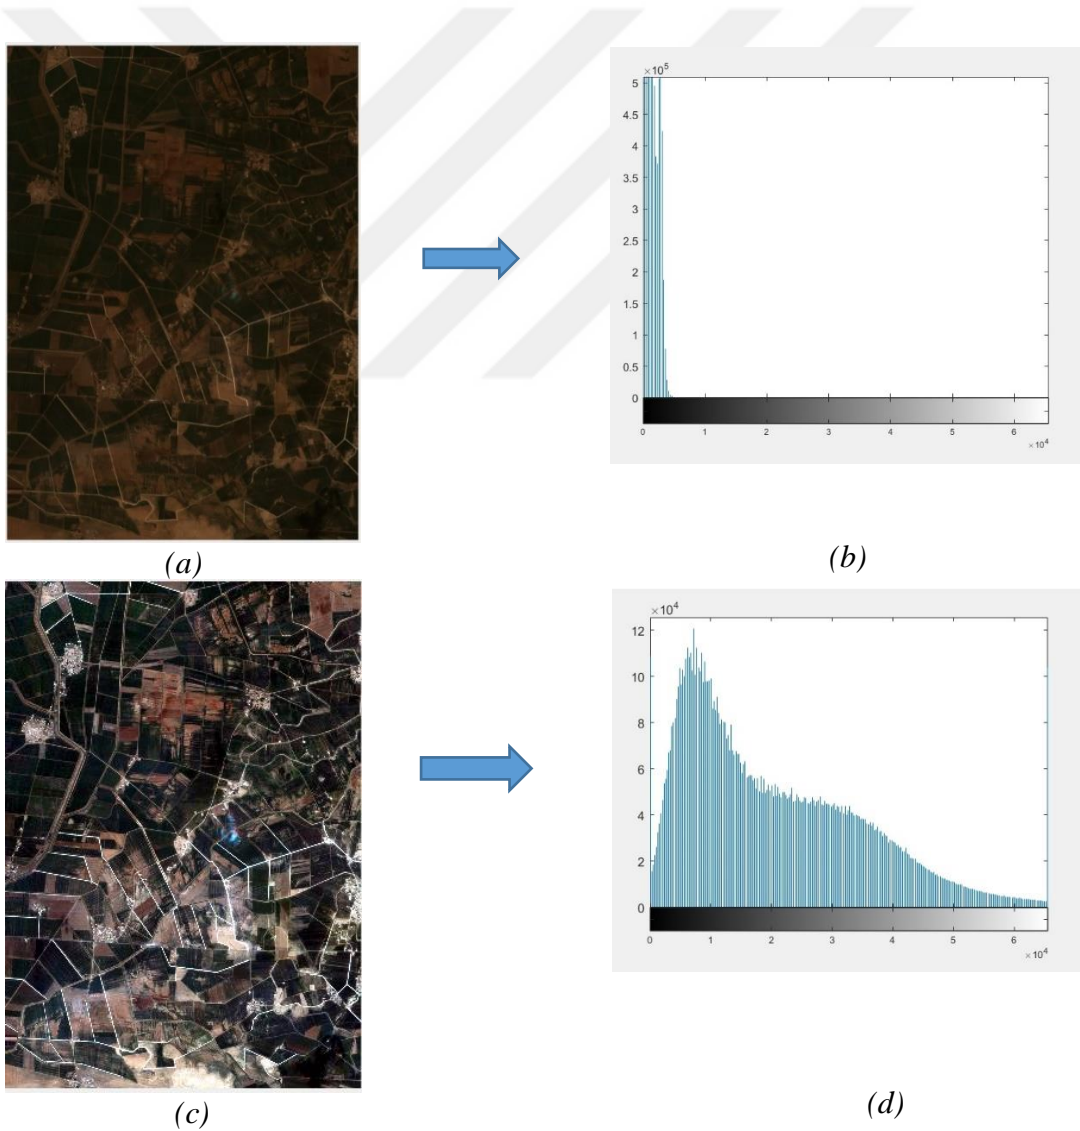
Tuzluluk Değerleri
<VALUE>

0,27510649 - 6,902849253
6,902849254 - 18,31729512
18,31729513 - 36,72769169
36,7276917 - 94,16812897

Şekil 44. ArcGIS ortamında ters mesafa ağırlık yöntemiyle enterpole edilerek oluşturulan Harran Ovası yersel tuzluluk haritası

2.3. Histogram Eşitleme

Histogram eşitleme bir görüntü ön işleme yöntemidir. Görüntü üzerinde işlem yapmadan önce sensör kaynaklı, görüntü alınma zamanına bağlı olarak atmosfer kaynaklı yahut görüntü radyomedüğinden dolayı hatalar olabilir. Bu durumlar görüntü üzerinden özellik çıkarmamızı zorlaştırır. Görüntü üzerinde özellik çıkarmadan önce bu hataların düzeltilmesi gerekir. Histogram eşitleme ile görüntünün belirli bir aralığı sıkışmış olan gri seviye değerleri yayılır. Bu sayede görüntü üzerindeki özellikler arasında kontrast artırılır. İyi kontrasta sahip bir görüntünün siyah ve beyaz değerleri arasındaki fark fazladır. Kontrastı yüksek olan görüntülerde vurgular daha parlak, gölgeler ise daha koyudur.




Şekil 45. Görüntü (a), Görüntünün histogram grafiği (b), Histogram eşitlemesi yapılmış görüntü (c), Histogram eşitlemesi yapılmış görüntünün histogram grafiği (d)

Şekil 45.(a)'da görüntünün MATLAB ortamındaki sonucu verilmiştir. Şekil 45.(b)'deki histogram grafiğinde görüldüğü üzere görüntü gri seviye değerleri çok dar bir aralıkta sıkışmıştır. Şekil 45.(c)'de histogram eşitlemesi gerçekleştirilmiş uydu görüntüsünün sonucudur. Şekil 45.(d) histogram grafiğinde görüldüğü üzere değerlerin yayılması uydu görüntüsü üzerindeki arazi örtüsünün daha belirgin olmasını sağlamıştır. Uydu görüntüsü sağlayıcısı tarafından uydu görüntüsü üzerindeki geometrik, radyometrik ve atmosferik düzeltme otomatik olarak yapıldığından başka bir ön işlem yapılmamıştır.

2.4. Veri Setinin Düzenlenmesi

Uygulama verisi olarak Harran Ovası'nın tuzluluktan en çok etkilenmiş tarım arazileri seçilmiştir. Harran Ovası'ndan senede 2-3 defa hasat alınabilmektedir. Bu yüzden hasat mevsimi ekim ayına kadar devam eder. Hasat mevsiminin bitmesi ve yüksek buharlaşmanın olduğu yaz aylarından sonra ovada tuzluluk daha belirgindir. Hasat mevsiminin bitmesi ovanın daha yalın olmasını sağlamak ve tuzluluk tespiti için uygun hale gelmektedir. Bu nedenle uygulama görüntüsü olarak 2010 yılının Ekim ayı seçilmiştir. Uydu görüntüsü olarak Rapideye (5 m) görüntüsü kullanılmıştır. Eğitim görüntüsü $1200 \times 1207 \times 5$ boyutunda olup 16 bit radyometrik çözünürlüğe sahiptir. Ova üzerinde 3 farklı tuzlu alan test verisi olarak seçilmiştir. Test verilerinin boyutları $500 \times 600 \times 5$ boyutunda 16 bit radyometrik çözünürlüktedir.



Şekil 46. Eğitim verisi (a), Test 1 (a), Test 2 (b) ve Test 3 (c) görüntüleri

2.5. Tuzluluk İndekslerinin Hesaplanması


Literatür çalışmalarına bakıldığında Dünya'nın birçok yerinde toprak tuzluluğuyla ilgili çeşitli çalışmalar yapılmıştır. Bu çalışmalara bakıldığında, çoğunlukla NDSI, SI, SII, SIII tuzluluk indeksleri kullanılmıştır (Bannari vd., 2008; Zhang vd., 2014; Peng vd., 2019; Elhag, 2016; Ennaji vd.,2018). Toprak tuzluluğunun bir diğer göstergesi, bitki vegetasyonundaki düşüş olduğundan NDVI bitki indeksi kullanılarak tuzluluk tespiti yapılan çalışmalarda vardır (Whitney vd.,2018; Ivushkin vd.,2018; Alexakis vd.,2018; Emami vd.,2017). Hem bitki hem de tuzluluk indekslerinin birlikte kullanıldığı çalışmalarda vardır. (Harti vd.,2016; Asfaw vd.,2018; Dehni vd.,2012; Samiee vd.,2018; Madani vd.,2013). Asfaw vd., (2016) yaptığı çalışmada özellikle SI tuzluluk indeksi ile EC_e değerleri arasında

yüksek korelasyon hesaplamıştır. Tuz görünür bölgede en çok mavi dalga boyunda yüksek yansıtıma sahiptir (Matternicht ve Zick, 1997). Yu vd., (2018) yaptığı çalışmada EC değerlerinin NIR ile pozitif ve en düşük korelasyon katsayısına ($R = 0.348$) sahip olduğunu belirtmiştir. Ayrıca kırmızı, yeşil ve mavi dalga boylarının, EC ile NIR dalga boyuna nazaran daha yüksek ($R = 0.810, 0.826$ ve 0.818) korelasyon katsayısı sonucu verdiğini belirtmiştir. Yukarıda belirtilen çalışmalar doğrultusunda tuzluluk tespiti için NDSI, SI, SII ve NDVI indeksleri seçilmiştir.

Tablo 5. Seçilen tuzluluk ve bitki indeksi eşitlikleri

Normalize Edilmiş Fark Tuzluluk İndeksi (NDSI)	Tuzluluk İndeksi SI	Tuzluluk İndeksi SII	Normalize Edilmiş Fark Bitki İndeksi (NDVI)
$NDSI = \frac{(R - NIR)}{(R + NIR)}$	$SI = \sqrt{B \times R}$	$SII = \sqrt{G \times R}$	$NDVI = \frac{(NIR - R)}{(NIR + R)}$


RapidEye uydu görüntüsü üzerinde hesaplanan tuzluluk indeksleri ve bitki indeksi (Bkz. Şekil 47'de) verilmiştir. Bu indekslerin her biri ayrı bir spektral kanal olarak görüntüye eklenmiştir. 5 banda sahip olan görüntüye indekslerin ayrı ayrı eklenerek 6, 7, 8 ve 9 bantlı görüntüler elde edilmiştir. Bu şekilde spektral yansıtımın artırılması sağlanarak tuzluluğun daha iyi tespit edilmesi amaçlanmıştır.




Şekil 47. Görüntü üzerinde hesaplanmış NDSI, NDVI, SI, SII indeksleri ve renklendirilmiş haritaları

2.6. Etiket Sınıflarının Belirlenmesi

Etiket sınıfları tuzlu alanlar için orta ve şiddetli tuzluluk olacak şekilde yersel ölçüm tuzluluk haritası referans alınarak etiketlenmiştir. Ova üzerinde olan hafif tuzlu alanlar çoğunlukla toprağın alt katmanlarındadır. Hafif tuzlu alanlarda dirençli bitkiler gelişimi sürdürebilmektedir. Örneğin, pamuk bitkisi hafif tuzlu alanlarda yetişmektedir. Bu nedenle hafif tuzlu alanlar etiket sınıfı (ROI) olarak seçilmemiştir. Ovada hakim olan tarım arazisi, kahverengi toprak, orta tuzlu ve şiddetli tuzlu olarak toplamda 4 adet etiket sınıfının ROI'leri çizilmiştir. Eğitim görüntüsü üzerinde 7103 tarım, 1869 kahverengi toprak, 1410 orta tuz, 917 şiddetli tuz etiket sınıflarına ait toplamda 11299 spektral imza toplanmıştır. Hem test hem de eğitim görüntüsü üzerinde çizilen ROI'ler, eğitim verisi için U-NET mimarisine verilen girdi değerlerini oluşturur. Test verisi üzerinde çizilen etiket sınıfları ise eğitim sonrası derin öğrenme mimarisinin ürettiği sonucun doğruluğu ölçmek için kullanılacak referans veridir. Test 1 verisi 5382, Test 2 verisi 3987 ve Test 3 verisi 3492 noktadan sınıflandırma sonrası doğruluk analizi yapılmıştır. Etiket sınıfları MATLAB yazılımı içerisinde olan görüntü etiketleme araç kutusuyla yapılmıştır. ROI'lerin çizimi ENVI veya Erdas Imagine gibi paket programlarla da yapılabilir.



Şekil 48. Eğitim verisi üzerinde seçilen ROI'ler ve yazılıma aktarılmış hali



Şekil 49. Test verileri üzerinde seçilen ROI'ler ve yazılıma aktarılmış hali


2.7. Ağ Parametrelerinin Belirlenmesi

Ağ parametrelerinin belirlenmesi eğitim işleminin en önemli aşamasını oluşturur. Eğitimin ne kadar iyi bir ağırlık modeli oluşturacağı parametrelerle ilişkilidir. Parametreler sezgisel olarak yani birçok deneme sonucu edinilen tecrübeler dahilinde de belirlenebileceği gibi diğer yapılan çalışmalar referans alınarak da belirlenebilir. Daha önce yapılan çalışmalar ve denemeler sonucu ağda belirlenen parametreler Tablo 6.'da verilmiştir. Eğitim işlemi MATLAB ortamında gerçekleştirilmiştir. Eğitim için Dell marka 8.Nesil i7 işlemcili NVIDIA 4 GB 1050Ti ekran kartına sahip bilgisayar kullanılmıştır. 100 iterasyon için 65 dk, 300 iterasyon için 190-200 dk eğitim işlemi yapılmıştır. Bu süre kullanılan donanıma bağlı olarak değişir.

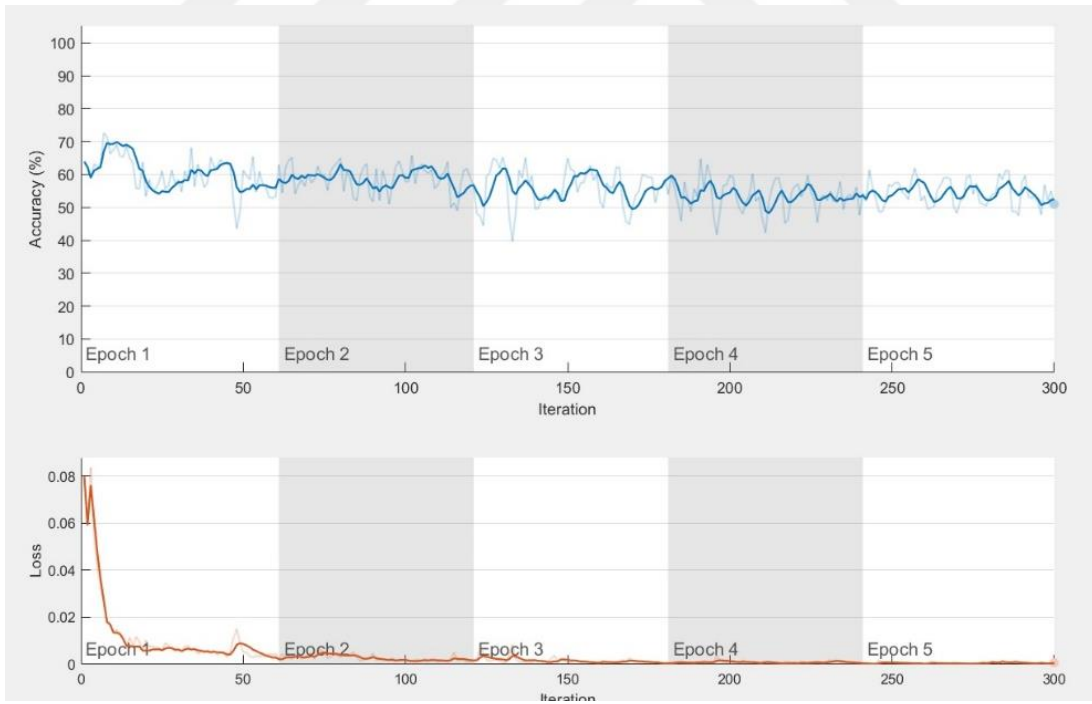
Tablo 6. Mimaride kullanılan parametreler ve parametre değerleri

Parametre	Parametre Değeri
Optimizasyon Yöntemi	Stokastik Gradyan İniş
Öğrenme Katsayısı	0.05
L2 Regülerizasyon Katsayısı	0.0001
Minimum Küme Seti	16
Maksimum Epok	10
İterasyon	100/300
Momentum	0.9
Çalışma Yeri	GPU


100 ve 300 iterasyonda gerçekleştirilen eğitim işlemlerinin kayıp ve doğruluk grafikleri Şekil 50. ve Şekil 51.'de verilmiştir.



Şekil 50.Görüntüye 100 iterasyonda yapılan eğitim işleminin doğruluk ve kayıp grafiği



Şekil 51.Görüntüye NDSI eklenerek 300 iterasyonda alınan doğruluk ve kayıp grafiği



Şekil 52. Görüntünün herhangi bir indeks ekmeden 5000 iterasyonda eğitim grafiği verilmiştir. Deneme amaçlı yapılan bu eğitimde 2.Epoktan sonra ağıda kayıp neredeyse sıfır olduğundan bir regülarizasyon yöntemi olarak ağın bu aşamada eğitimi durdurulabilir. Bu eğitim işlemiyle ayrıca çok yüksek iterasyonlara gerek duyulmadığı görülmüştür.


2.8. Ağ Mimari Yapısı

Görüntünün anlamsal olarak bölütlenmesini sağlayan U-NET mimarisi 58 katmandan oluşmaktadır. Kemker vd., (2017) yaptığı çalışma dikkate alınarak kodlayıcı, köprü ve kod çözücü olarak üç ana katmana sahip olan bir mimari oluşturulmuştur.

Kodlayıcı 8 konvolüsyon, 8 ReLU, 4 maksimum havuzlama ve 1 Dropout katmanına sahiptir.

Köprü kısmında 2 Konvolüsyon, 2 ReLU ve 1 Dropout katmanı vardır.

Kod-Çözücü kısım ise 9 konvolüsyon, 4 aktarılmış konvolüsyon (transposed konvolüsyon veya yukarı örnekleme), 4 derinlik birleştirme, 1 Softmax ve 1 sınıflandırma katmanından oluşmaktadır. Ağın eğitim işleminden sonra bulunduğu en uygun ağırlık değerleriyle test görüntü üzerinde bölütleme işlemi yapılmıştır.



Şekil 53. U-NET mimarisinin ara katmanları

Konvolüsyon katmanı belirli bir boyuta sahip filtrelerden (veya kernelden) oluşur. $H_i \times W_i \times D_i$ boyutunda olan bir görüntü için H_i ve W_i uzamsal boyutları ve D_i ise kanal sayısını ifade eder. Filtrelerin her biri, giriş görüntüsü kullanılarak kernelin özelliğine göre evrişim işlemine tabi tutulur. Evrişim işlemi, girdi değerleri ile filtrelerin element matris çarpımının toplamını ifade eder. Buna göre, her bir katmanda tek bir filtre bulunan bir evrişim işlemi ile belirli bir uzamsal boyutta 2 boyutlu bir çıktı üretilir. Bu çıktı o konvolüsyon katmanı sonucu üretilen özellik haritasıdır. Konvolüsyon katmanlarında N tane kullanılan filtre için N adet özellik haritası üretilir. Bunlar, N tane filtre sonucu oluşan N tane özellik haritası tek bir evrişimsel katmanın çıktısını oluşturmak için 3. boyuta eklenir.

Belirli bir katmanın bir filtresindeki tek bir nöron, evrişim işlemiyle önceki katmanlardaki diğer bağlı nöronlara eşlenir. Alt konvolüsyon katmanları, girdi görüntüsünün küçük alanlarını temsil etmeyi öğrenirken, daha yüksek konvolüsyon katmanlarında, giriş görüntüsünün daha alt bölgesine ait belirgin anlamlar kurulur. s kaydırma, filtrenin görüntü üzerinde ne kadar aralıkla hareket ettiğini ifade eder. p_h, p_w görüntünün dışına yapılacak doldurma işleminin boyutunu ifade etmektedir. Katmanda $f_h \times f_w$ boyutlu bir kernel ile konvolüsyon işlemi sonucunda üretilen özellik haritalarının çıktı boyutu H_0, W_0, D_0 denklem (2.4), (2.5) ve (2.6) eşitleri ile hesaplanır.

$$H_0 = \frac{H_i - f_h + 2p_h}{s} + 1 \quad (2.4)$$

$$W_0 = \frac{W_i - f_w + 2p_w}{s+1} + 1 \quad (2.5)$$

$$D_0 = N \quad (2.6)$$

CNN mimarilerinde, evrişim işlemlerinden sonra, sıklıkla lineer olmayan (nonlinear) aktivasyon fonksiyon işlemleri takip edilir. Aktivasyon fonksiyonları düğümlerdeki değerlerin diğer katmana iletilmesini sağlayan sinirsel ilettime benzer şekilde ateşleyici fonksiyonlardır. Ağırlık katmanlarından sonra doğrusal olmayan bir aktivasyon fonksiyonunun uygulanması oldukça önemlidir, çünkü sinir ağının doğrusal olmayan eşlemeleri öğrenmesi sağlanır. Aktivasyon fonksiyonları kullanılmazsa model lineer regresyondan farksız olacaktır. Örneğin, sigmoid aktivasyon fonksiyonu, başlangıç ağırlıkları çok büyük olduğunda, eğitim işlemini hızlıca sonlandırma eğilimindedir. Diğer yandan, eğim küçükse, eğitim işlemi sürdürülemez ve böylelikle ağ oluşturulamaz. ReLU ise gradyanları azaltma eğilimindedir (Muruganandham, 2016).

ReLU aktivasyon fonksiyonu, gradyan inişte eğitim süresi açısından Tanh ve Sigmoid fonksiyonuna göre daha hızlıdır. ReLU aktivasyon fonksiyonu kullanılan derin konvolüsyonel yapay sinir ağların, Tanh fonksiyonuna göre birçok kez daha hızlı eğitildiği ve ReLU birimlerinin etkili olduğu bulunmuştur (Krizhevsky, 2012). Mc.Pheron vd., (2016) yaptıkları çalışmada ReLU aktivasyon fonksiyonunu önermiştir. Çok katmanlı sinir ağların işlem hızını artıran ReLU aktivasyon fonksiyonu negatif değerleri sıfıra eşitlerken, pozitif

değerlerin aynen geçmesini sağlar. ReLU aktivasyon fonksiyonu eşitliği denklem (2.7) ve (2.8) gösterildiği gibidir.

$$f_{relu}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.7)$$

$$f_{relu}(x) = \max(0, x) \quad (2.8)$$

Havuzlama işleminde, girdi özellik haritaları aşağı örneklem işlemine tabi tutulur (piksel sayısının azaltılarak görüntünün küçültülmesi). Aşağı örnekleme işlemi ile görüntü üzerinde nesne ölçeği, yön ve dönüklük ile kompakt özellikler elde edilir (Goodfellow vd., 2016)

Yoğun piksel tahminleri gerektiren problemler tipik olarak kodlayıcı-kod çözücü mimarisine giderilir (Wojna vd.,2019). Normal konvolüsyon katmanında, uzamsal olarak büyük boyutlu bir girdi filtreleme operatörlerinden sonra daha küçük boyutta bir çıktı üretir. Bu durum görüntüde çözünürlüğün düşmesine sebep olur. Süper çözünürlükte olduğu gibi, düşük çözünürlükten yüksek çözünürlüğe geçmek istediğimizde aktarılmış konvolüsyon işlemi kullanılır. Bu katman, “fraksiyonel olarak gerilmiş konvolüsyon katmanı” veya “yukarı örnekleme katmanı” (up-sampling) olarak da adlandırılır. Kod çözücü katmanında çıktı orijinal giriş boyutuna yeniden örneklenir. Kavramsal olarak, kod çözücü katmanı kodlayıcıların yaptığı işlemleri tersine çevirme işlemi olarak görülür. Bir kod çözücü modülü, yukarı örnekleme katmanı olarak adlandırılan uzamsal çözünürlüğü arttıran veya uzamsal çözünürlüğü koruyan en az bir katmandan oluşur. Kod çözücüde uzamsal çözünürlüğü koruyan katmanlar, literatürde görüntü sınıflandırması için Szegedy vd. (2016); Chollet (2017); Alvarez ve Petersson (2016); He vd. (2016) tarafından incelenmiştir. Yaygın olarak kod çözücüler aktarılmış konvolüsyon yöntemiyle, özellik öğrenme için kullanılır (Zeiler vd.,2010; Matthew D. Zeiler ve Fergus, 2011), görüntü segmentasyonu gibi piksel bazlı tahmin işlemleri (Ronneberger vd., 2015), anlamsal segmentasyon (Long vd., 2015), derinlik tahmini (Laina vd., 2016), özellik gösterimi ile görüntü rekonstrüksiyonu (Dosovitskiy ve Brox, 2016) ve görüntü sentezi (Dosovitskiy vd., 2015b) alanlarında kullanılmıştır.

Derinlik birleştirme birçok kod çözücü mimarisinde kullanılmıştır (Lin vd., 2017a; Ronneberger vd., 2015; Pinheiro vd., 2016; Lin vd., 2017b, Kendall vd., 2015). Bu yöntem

ile aynı uzamsal çözünürlüğe sahip kodlayıcıdan gelen özellikler, kod çözücü kısmında birleştirilir.

Softmax işlevi çoğunlukla derin öğrenme mimarilerinin neredeyse tüm çıktı katmanlarında görülür (Krizhevsky vd., 2012; Badrinarayanan vd., 2015; Lin vd., 2013).

Kayıp fonksiyonu, modelin tahmini çıktısı (tahmin) ile gerçek değer (temel gerçek) arasındaki farkın belirlenmesidir. Çok sınıflı, sınıflandırma için uygun olan kayıp fonksiyonları, ikili sınıflandırma için de kullanılır. Çok sınıflı bir problem, bir ikili sınıflandırma kaybı kullanılarak her bir durum için, ayrı sınıfların eğitildiği ikili sınıflandırma gruplarına bölünerek hesaplanır. Çok sınıflı segmentasyon için en uygun kayıp fonksiyonu çapraz entropidir (soft-max loss) (Khan vd., 2018; Thang, 2015).

Çapraz entropi denklemi (2.9)'daki gibi hesaplanır:

$$\mathcal{L}(p, y) = -\sum_n y_n \log(p_n) \quad n \in [1, N] \quad (2.9)$$


Burada y , istenen çıktıyı belirtir, p ise her çıktı kategorisi için gerçekleşme olasılığıdır. Çıktı katmanında toplam N nöron varken $p, y \in \mathbb{R}^N$ 'dir (Khan vd., 2018). Burada p_n Softmax fonksiyonuna bağlı olarak her bir sınıfın kendi sınıfına ait olup olmama durumunun olasılıksal hesabıdır. Softmax işlemi denklem (2.10)'da verilmiştir.

$$p_n = \frac{e^{n_j}}{\sum_{k=1}^N e^{n_k}} \quad \forall j \in 1 \dots N \quad (2.10)$$

Yapılan birçok çalışmada derin öğrenme mimarisinin gizli katmanında aktivasyon fonksiyonu olarak ReLU, sınıflandırma katmanında Softmax yöntemini kullanılmıştır (Krizhevsky vd., 2012; Lin vd., 2013; Zeiler ve Fergus, 2013; Simonyan ve Zisserman, 2015; Badrinarayanan vd., 2015; Szegedy vd., 2015; Golkov vd., 2016; He vd., 2016; Xie vd., 2017; Howard vd., 2017; Fu vd., 2017). Daha önce yapılan çalışmalar doğrultusunda U-NET mimarisinin ara katmanlarında ReLU ve sınıflandırma katmanında Softmax tercih edilmiştir. Mimarinin daha detaylı bilgisi için EKLER kısmına bakabilirsiniz.

Görüntü bölütlenmesinden sonra çıktı üzerindeki gürültüleri gidermek için medyan (ortanca) filtresi uygulanmıştır. Medyan filtre, sinyal yumuşatma için kullanılan doğrusal olmayan bir filtredir. Özellikle bir sinyalden gelen gürültüyü gidermek için iyidir (James, 2009). Medyan bir dizideki değerlerin küçükten büyüğe doğru sıralandığında ortadaki değeri

ifade eder. Medyan filtresi pikselin komşu piksel değerlerine bakarak onları küçükten büyüğe sıralar ve ortadaki değeri alır.



Şekil 54. Bölütme işlemi sonrasında görüntüye uygulanan medya filtresi ile gürültüsü giderilmiş test sonuç görüntüleri

Bölütleme işleminin ardından etiket sınıflarının sahip olduğu renge göre, renk ataması yapılır.

2.9. Bölütleme Performansının Hesaplanması

Kullanılan U-NET mimarisi sınıflandırma doğruluğunu belirlemek için etiket sınıfları ile kendi tahmin ettiği sınıflar arasında karşılaştırma yaparak bir doğruluk sonucu oluşturmaktadır. Test görüntüsünde etiket sınıfları ile yine ağı test verisi üzerinde bulunduğu değerle (sınıflar) arasında karşılaştırma yapılarak doğruluk belirlenir. Bölütleme işlemine ait sınıflandırma ölçütleri Fawcett'in (2005) sunduğu yöntemle belirlenmiştir. Bu yöntemle göre genel doğruluk, kullanıcı doğruluğu (geri çağırma) ve üretici doğruluğu (kesinlik) aşağıda belirtildiği gibi hesaplanır.

Tablo 7. Gerçek ve tahmini değerler arasındaki hesaplanan DP, DN, YP, YN tablosu

		Tahmini	
		Pozitif	Negatif
Gerçek	Pozitif	Doğru Pozitif	Yanlış Negatif
	Negatif	Yanlış Pozitif	Doğru Negatif

Genel doğruluk test verisi içinde doğru olarak tahmin edilen tüm piksellerin, toplam piksel sayısına oranlamasıyla bulunur. Doğruluk, tahmin edilen bir büyüklüğün, o büyüklüğün gerçek değerine olan yakınlık derecesidir.

$$\text{Genel Doğruluk (Accuracy)} = \frac{DP+DN}{(DP+YP+YN+DN)} \quad (2.11)$$

Kullanıcı doğruluğu, modelin yanlış negatiflerden ne kadar iyi kaçındığını belirler. Doğru gerçek değerlerin tüm gerçek değerlere olan oranıdır. Kullanıcı doğruluğu sınıflandırma sonucu oluşan çıktı görüntüsünün güvenilirliğini ölçer. Kullanıcı doğruluğu tahmin edilen değerlerin gerçekte ne kadarının yeryüzünde kendi sınıfına ait olup olmadığının ölçütüdür.

$$\text{Kullanıcı Doğruluğu (Recall)} = \frac{DP}{(DP+YN)} \quad (2.12)$$


Üretici doğruluğu eğitim ve test verilerinin kaç tanesinin doğru bir şekilde sınıflandırıldığıнын ölçütüdür. Diğer bir deyişle üretici doğruluğu tahmin edilen değerlerin gerçekte kaç tanesinin doğru tahmin edildiğini gösterir.

$$\text{Üretici Doruluğu (Precision)} = \frac{DP}{(DP+YP)} \quad (2.13)$$



3. BULGULAR VE İRDELEMELER

Harran Ovası'nda tuzluluk tespiti için literatürde en çok kullanılan tuzluluk indeksleri olan NDSI, SI, SII ve bitki indeksi NDVI kullanılmıştır. Bir derin öğrenme yöntemi olan evrişimsel sinir ağları U-NET mimarisiyle yapılan bölütleme işleminde görüntünün sahip olduğu 5 kanala ilaveten tuzluluk indekslerinin her biri ayrı bir spektral bant olarak görüntüye eklenmiştir. 100, 300 iterasyonda eğitim işlemi yapılmıştır. Bu indekslerin birbirleriyle yapılan 6, 7, 8 ve 9 spektral kanal kombinasyonları sonucunda tuzluluk tespiti için en iyi sonucu 300 iterasyonda %93.78 ile SII tuzluluk indeksinin eklendiği görüntüden alınmıştır. U-NET mimarisi ile yapılan bölütleme sonuçları aşağıda verilmiştir.




Şekil 55. Test 1 verisi (a), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 55.'te indeks eklenmeden eğitilen Test 1 verisinin bölütleme sonuçları verilmiştir. Tablo 8.'de belirtilen bölütleme işleminin hata matrisine bakıldığında şiddetli tuzun büyük bir kısmının orta tuz sınıfı ile karıştığı görülmektedir. Bu nedenle şiddetli tuz sınıfının kullanıcı doğruluğu, orta tuz sınıfının üretici doğruluğu düşüktür. Tarım, kahverengi toprak ve orta tuz sınıfının kullanıcı doğrulukları yüksektir. Kahverengi toprağın bir kısmı tarım ve orta tuz olarak eğitilmiştir. Bu nedenle üretici doğruluğu %86.65'te kalmıştır. İterasyon

sayısı 100 olduğundan eğitim verileri tam olarak öğrenilememiş genel doğruluk %83.48'te kalmıştır.

Tablo 8. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1211	51	66	0	%91.19
Kahverengi Toprak	25	435	5	0	%93.55
Orta Tuzlu	0	16	1756	34	%97.23
Şiddetli Tuzlu	0	0	692	1091	%61.19
Üretici Doğruluğu	%97.98	%86.65	%69.71	%96.98	
Genel Doğruluk	%83.48				




Şekil 56. Test 2 verisi (a), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 56.'da indeks eklenmeden Test 2 verisinin 100 iterasyonda yapılan bölütleme sonucu verilmiştir. Tablo 9.'da verilen hata matrisine bakıldığında; orta tuzun bir kısmı

şiddetli tuz olarak, şiddetli tuz sınıfının bir kısmı orta tuz olarak eğitilmiştir. Bu nedenle orta tuz sınıfının kullanıcı doğruluğu %84.31'te kalmıştır. Kahverengi toprak sınıfının bir kısmı tarım sınıfı olarak atandığından üretici doğruluğu %76.84 sonucunu vermiştir. Genel doğruluk %88.84 bulunmuş olup düşük iterasyon sayısına rağmen iyi bir bölütleme sonucu alınmıştır.

Tablo 9. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	938	37	52	1	%91.25
Kahverengi Toprak	36	146	19	0	%72.64
Orta Tuzlu	0	7	860	153	%84.31
Şiddetli Tuzlu	0	0	140	1598	%91.94
Üretici Doğruluğu	%96.30	%76.84	%80.30	%91.21	
Genel Doğruluk	%88.84				




Şekil 57. Test 3 verisi (a), indeks eklenmeden 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 57.'de indeks eklenmeden 100 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 10.'da verilen hata matrisine bakıldığında; orta tuz sınıfı tarım, kahverengi toprak ve şiddetli tuz olarak atanmıştır. Bu nedenle orta tuz sınıfının üretici doğruluğu %78.06'da kalmıştır. Diğer etiket sınıflarının üretici doğrulukları %90'dan fazladır. Genel doğruluk %91.09 bulunmuştur. Düşük iterasyon sayısına rağmen iyi bir genel doğruluk sonucu alınmıştır.

Tablo 10. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	571	24	17	0	%93.30
Kahverengi Toprak	29	368	13	0	%89.76
Orta Tuzlu	1	1	733	50	%93.38
Şiddetli Tuzlu	0	0	176	1509	%89.55
Üretici Doğruluğu	%93.76	%93.64	%78.06	%96.79	
Genel Doğruluk	%91.09				




Şekil 58. Test 1 verisi (a), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 58.'de NDSI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 11.'de verilen hata matrisine bakıldığında; orta tuz sınıfın yaklaşık 1/3'ü şiddetli tuz sınıfı olarak eğitilmiştir. Bu nedenle kullanıcı doğruluğu %64.78'de kalmıştır. Şiddetli tuz sınıfının büyük çoğunluğu orta tuz olarak atandığından üretici doğruluğu %74.72 sonuç vermiştir. Orta tuz ve tarım sınıfının üretici doğrulukları %90'dan fazladır. Kahverengi toprak sınıfı tüm etiket sınıflarına atandığından üretici doğruluğu %82.09'da kalmıştır. Genel doğruluk %85.45 bulunmuştur.

Tablo 11. Test1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1236	58	34	0	%93.07
Kahverengi Toprak	23	440	2	0	%94.62
Orta Tuzlu	9	34	1170	593	%64.78
Şiddetli Tuzlu	4	4	22	1753	%98.32
Üretici Doğruluğu	%97.17	%82.09	%95.28	%74.72	
Genel Doğruluk					%85.45




Şekil 59. Test 2 verisi (a), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 59.'da NDSI eklenerek Test 2 verisinin 100 iterasyondaki bölütleme sonucu verilmiştir. Tablo 12.'deki hata matrisine bakılırsa; bu eğitim işleminde orta tuz sınıfı daha çok şiddetli tuz olarak öğrenilmiştir. Bu nedenle kullanıcı doğruluğu %38.04'te kalmıştır. NDSI tuzluluk indeksinin eklenmesi orta tuz sınıfının elemine edilmesine sebep olup şiddetli tuz sınıfı olarak öğrenilmiştir. Bu nedenle genel doğruluk %80.54'te kalmıştır. Kahverengi toprak sınıfı tarım, orta tuz ve şiddetli tuz sınıfı ile karıştığından üretici doğruluğu %70.48'de kalmıştır. Şiddetli tuz sınıfının büyük çoğunluğu orta tuz olarak atandığından üretici doğruluğu %73.48'de kalmıştır. Tuzluluk hassas olarak tespit edilememiştir. Tarım sınıfının üretici ve kullanıcı doğruluğu %90'dan fazladır.

Tablo 12. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	940	50	35	3	%91.44
Kahverengi Toprak	30	160	11	0	%79.60
Orta Tuzlu	7	6	388	619	%38.04
Şiddetli Tuzlu	0	11	4	1723	%99.14
Üretici Doğruluğu	%96.21	%70.48	%88.58	%73.48	
Genel Doğruluk	%80.54				




Şekil 60. Test 3 verisi (a), NDSI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 60.'da NDSI eklenerek eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 13.'deki hata matrisine bakıldığında; orta tuz sınıfının büyük çoğunluğu şiddetli tuz olarak öğrenilmiştir. Bu nedenle orta tuz sınıfının kullanıcı doğruluğu %43.06 olup düşük sonuç alınmıştır. Şiddetli tuz sınıfı iyi öğrenilmiş olup kullanıcı doğruluğu %99.70'dir. Şiddetli tuz sınıfı olarak atanan test verisinin büyük çoğunluğu orta tuz sınıfına ait olduğundan üretici doğruluğu %79.55'te kalmıştır. Tarım, kahverengi toprak ve orta tuz sınıflarının üretici doğrulukları %90'dan fazladır. Orta tuz sınıfı büyük çoğunlukla şiddetli tuz sınıfı ile karıştığından genel doğruluk % 84.85 olarak bulunmuştur.

Tablo 13. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	578	27	7	0	%94.44
Kahverengi Toprak	30	367	13	0	%89.51
Orta Tuzlu	7	8	338	432	%43.06
Şiddetli Tuzlu	0	2	3	1680	%99.70
Üretici Doğruluğu	%93.98	%90.84	%93.63	%79.55	
Genel Doğruluk	%84.85				




Şekil 61. Test 1 verisi (a), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 61.'de NDVI eklenerek 100 iterasyonda eğitilen görüntünün bölütleme sonucu verilmiştir. Tablo 14.'teki hata matrisine bakıldığında; şiddetli tuz ile orta tuz arasında küçük bir karışma olmuştur. Kahverengi toprak sınıfı tarım ve orta tuz olarak atandığından üretici doğruluğu %82.58' de kalmıştır. Tarım, kahverengi toprak, orta ve şiddetli tuz sınıflarının

kullanıcı doğrulukları %90'dan fazladır. Tarım, orta ve şiddetli tuz sınıfları iyi bir şekilde test verisi üzerinde tahmin edilmiştir. Bu etiket sınıflarının üretici doğrulukları %90'dan fazladır. Genel doğruluk %93.01 bulunup başarılı bir sonuç alınmıştır.

Tablo 14. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1241	61	26	0	%93.45
Kahverengi Toprak	22	441	2	0	%94.84
Orta Tuzlu	0	32	1652	122	%91.47
Şiddetli Tuzlu	0	0	111	1672	%93.77
Üretici Doğruluğu	%98.26	%82.58	%92.24	%93.20	
Genel Doğruluk	%93.01				




Şekil 62. Test 2 verisi (a), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 62.'de NDVI eklenerek 100 iterasyonda eğitilen görüntünün bölütleme sonucu verilmiştir. Tablo 15.'teki hata matrisine bakıldığında; orta tuz sınıfı ile şiddetli tuz sınıfı karışmıştır. Kahverengi toprak sınıfı tarım ve orta tuz sınıf ile karıştığından kahverengi toprak sınıfının üretici doğruluğu %76.56'da kalmıştır. Kahverengi toprak ile orta tuz sınıfı bu kombinasyonda iyi öğrenilememiştir. Tarım ve şiddetli tuz sınıfının kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %88.76 bulunmuştur.

Tablo 15. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	974	34	18	2	%94.75
Kahverengi Toprak	47	147	7	0	%73.13
Orta Tuzlu	2	11	799	208	%78.33
Şiddetli Tuzlu	0	0	119	1619	%93.15
Üretici Doğruluğu	%95.21	%76.56	%84.73	%88.52	
Genel Doğruluk	%88.76				




Şekil 63. Test 3 verisi (a), NDVI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 63.'te NDVI bitki indeksi eklenerek eğitilen Test 3 görüntünün bölütleme sonucu verilmiştir. Tablo 16.'daki hata matrisine bakıldığında orta tuz sınıfının üretici ve kullanıcı doğrulukları %87'lerde kalmıştır. Diğer etiket sınıflarının üretici ve kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %92.70 bulunup başarılı bir bölütleme sonucu elde edilmiştir.

Tablo 16. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	580	24	8	0	%94.77
Kahverengi Toprak	32	370	8	0	%90.24
Orta Tuzlu	0	3	686	96	%87.39
Şiddetli Tuzlu	0	0	84	1601	%95.01
Üretici Doğruluğu	%94.77	%93.20	%87.28	%94.34	
Genel Doğruluk	%92.70				




Şekil 64. Test 1 verisi (a), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 64.'te SI tuzluluk indeksi eklenerek eğitilen Test 1 verisinin 100 iterasyondaki bölütleme sonucu verilmiştir. Tablo 17.'deki hata matrisine bakıldığında kahverengi toprak sınıfı diğer tüm etiket sınıfları ile karışmıştır. Bu nedenle üretici doğruluğu %78.86'da kalmıştır. Şiddetli tuz sınıfı bu kombinasyonda daha çok orta tuz sınıfı olarak öğrenildiğinden şiddetli tuz sınıfının kullanıcı doğruluğu %69.32 olarak sonuç alınmıştır. Diğer etiket sınıflarının kullanıcı doğrulukları %90'dan fazladır.

Tablo 17. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1216	84	28	0	%91.57
Kahverengi Toprak	21	444	0	0	%95.48
Orta Tuzlu	6	31	1695	74	%93.85
Şiddetli Tuzlu	4	4	539	1236	%69.32
Üretici Doğruluğu	%97.51	%78.86	%74.93	%94.35	
Genel Doğruluk	%85.30				




Şekil 65. Test 2 verisi (a), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 65.'te SI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 18.'deki hata matrisine bakıldığında; orta tuz ile şiddetli tuz sınıfı karışmıştır. Şiddetli tuz sınıfının büyük çoğunluğu orta tuz sınıfı olarak öğrenildiğinden şiddetli tuz sınıfının kullanıcı doğruluğu %71.40'da kalmıştır. Orta tuz sınıfı bütün etiket sınıfları ile karıştığından üretici doğruluğu düşüktür. Kahverengi toprak sınıfının üretici doğruluğu %64.05'tir. Bu eğitimden çok da iyi bir sonuç alınamamıştır. Genel doğruluk %80.59'da kalmıştır.

Tablo 18. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	914	80	34	0	%88.91
Kahverengi Toprak	38	155	8	0	%77.11
Orta Tuzlu	8	7	903	102	%88.53
Şiddetli Tuzlu	0	0	497	1241	%71.40
Üretici Doğruluğu	%95.21	%64.05	%62.62	%92.41	
Genel Doğruluk					%80.59




Şekil 66. Test 3 verisi (a), SI tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 66.'da SI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 3 görüntüsünün bölütleme sonucu verilmiştir. Tablo 19.'daki hata matrisine bakıldığında; orta ve şiddetli tuz sınıflarında karışma vardır. Orta tuz sınıfı özellikle tüm diğer etiket sınıfları ile karıştığından üretici doğruluğu %63.09'da kalmıştır. Şiddetli tuz sınıfının bir kısmı orta tuz olarak öğrenildiğinden kullanıcı doğruluğu %76.85'te kalmıştır. Tarım sınıfının kullanıcı ve üretici doğrulukları %90'dan fazladır. Genel doğruluk %83.68 bulunmuştur.

Tablo 19. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	558	47	7	0	%91.18
Kahverengi Toprak	28	370	12	0	%90.24
Orta Tuzlu	9	5	699	72	%89.04
Şiddetli Tuzlu	0	0	390	1295	%76.85
Üretici Doğruluğu	%93.78	%87.68	%63.09	%94.73	
Genel Doğruluk	%83.68				




Şekil 67. Test 1 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 67.'de SII tuzluluk indeksi eklenerek 100 iteraasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 20.'deki hata matrisine bakıldığında orta tuz sınıfı tüm etiket sınıflarına karıştığından iyi öğrenilememiştir. Orta tuz sınıfının kullanıcı doğruluğu %74.31'dir. Kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Şiddetli tuz sınıfı orta tuz sınıfıyla karışmasından dolayı üretici doğruluğu %81.86'da kalmıştır. Diğer etiket sınıflarının üretici doğrulukları %90'dan fazladır.

Tablo 20. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1220	63	45	0	%91.87
Kahverengi Toprak	35	425	5	0	%91.40
Orta Tuzlu	7	18	1342	439	%74.31
Şiddetli Tuzlu	10	0	34	1739	%97.53
Üretici Doğruluğu	%95.91	%83.99	%94.11	%79.84	
Genel Doğruluk	%87.81				




Şekil 68. Test 2 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 68.'de SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 21.'deki hata matrisine bakıldığında; orta tuz sınıfı yarı yarıya şiddetli tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluğu %49.51 ile düşüktür. Kahverengi toprak sınıfı şiddetli tuz sınıfı hariç diğer bütün sınıflarla karıştığından üretici doğruluğu %68.22'de kalmıştır. Tarım sınıfının kullanıcı ve üretici doğruluğu iyidir. Genel doğruluk %82.37 olup özellikle kahverengi toprak ve orta tuz sınıfı iyi eğitilememiştir.

Tablo 21. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	915	65	46	2	%89.01
Kahverengi Toprak	39	146	16	0	%72.64
Orta Tuzlu	4	3	505	508	%49.51
Şiddetli Tuzlu	0	0	20	1718	%98.85
Üretici Doğruluğu	%95.51	%68.22	%86.03	%77.11	
Genel Doğruluk	%82.37				




Şekil 69. Test 3 verisi (a), SII tuzluluk indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 69.'de SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 22.'deki hata matrisine bakıldığında; orta tuz sınıfının neredeyse yarısı şiddetli tuz olarak öğrenilmiştir. Bu nedenle orta tuz sınıfının kullanıcı doğruluğu düşüktür. Tarım, kahverengi toprak ve orta tuz sınıflarının üretici doğrulukları %90'dan fazladır. Tarım sınıfı kahverengi toprakla, orta tuz sınıfı şiddetli tuz sınıfı ile karışmalar olsa da genel doğruluk %86.66 olup iyi bir eğitim sonucu alınmıştır.

Tablo 22. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	564	37	11	0	%92.16
Kahverengi Toprak	28	367	15	0	%89.51
Orta Tuzlu	5	2	428	350	%54.52
Şiddetli Tuzlu	0	0	18	1667	%98.93
Üretici Doğruluğu	%94.47	%90.39	%90.68	%82.65	
Genel Doğruluk	%86.66				




Şekil 70. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 70.'de NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 23.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı orta tuz ve tarım sınıfı ile karışmıştır. Orta tuz sınıfı eğitim esnasında her sınıfla ait olarak eğitilmiştir. Kahverengi toprak sınıfı iyi öğrenilemediğinden test verisi üzerinde de farklı sınıflar olarak tahmin edilmiştir. Bu nedenle üretici doğruluğu düşüktür. Kahverengi toprak sınıfı hariç diğer etiket sınıflarının kullanıcı ve üretici doğrulukları % 80'den fazladır. Genel doğruluk %89.13 olup iyidir.

Tablo 23. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1197	98	33	0	%90.14
Kahverengi Toprak	65	368	32	0	%79.14
Orta Tuzlu	3	19	1485	299	%82.23
Şiddetli Tuzlu	0	8	28	1747	%97.98
Üretici Doğruluğu	%94.62	%74.65	%94.11	%85.39	
Genel Doğruluk	%89.13				




Şekil 71. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 71.'de NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 24.'deki hata matrisine bakıldığında; kahverengi toprak ve orta tuz sınıfı iyi öğrenilememiştir. Bu nedenle kullanıcı doğrulukları düşüktür. Kahverengi toprak sınıfı tarım sınıfı olarak tahmin edildiğinden üretici doğruluğu %58.18'de kalmıştır. Şiddetli tuz sınıfının bir kısmı orta tuz olarak tahmin edilmiştir. Genel doğruluk %83.60'tır.

Tablo 24. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	928	65	33	2	%90.27
Kahverengi Toprak	72	96	33	0	%47.76
Orta Tuzlu	0	4	588	428	%57.65
Şiddetli Tuzlu	0	0	17	1721	%99.02
Üretici Doğruluğu	%92.80	%58.18	%87.63	%80.01	
Genel Doğruluk	%83.60				




Şekil 72. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 72.'de NDSI, SI, SII tuzluluk indeks ve NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 25.'deki hata matrisine bakıldığında; orta tuz sınıfı şiddetli tuz olarak öğrenilmiştir. Bu nedenle kullanıcı doğruluğu %68.66 'da kalmıştır. Tarım ve kahverengi toprak sınıflarında karışmalar vardır. Genel olarak üretici ve kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %90.06 olarak bulunmuştur.

Tablo 25. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	576	31	5	0	%94.12
Kahverengi Toprak	29	368	13	0	%89.76
Orta Tuzlu	0	7	539	239	%68.66
Şiddetli Tuzlu	0	0	23	1662	%98.64
Üretici Doğruluğu	%95.21	%90.64	%92.93	%87.43	
Genel Doğruluk	%90.06				




Şekil 73. Test 1 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 73.'de SI, SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 26.'deki hata matrisine bakıldığında; orta tuz sınıfı diğer etiket sınıflarıyla karışmıştır. Bu nedenle orta tuz sınıfının kullanıcı doğruluğu %83.39'da kalmıştır. Diğer etiket sınıflarının genel olarak üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %91.42 bulunup başarılı bir sonuç alınmıştır.

Tablo 26. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1263	33	32	0	%95.11
Kahverengi Toprak	26	434	5	0	%93.33
Orta Tuzlu	4	24	1506	272	%83.39
Şiddetli Tuzlu	4	0	62	1717	%96.30
Üretici Doğruluğu	%97.38	%88.39	%93.83	%86.32	
Genel Doğruluk	%91.42				




Şekil 74. Test 2 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 74.'te SI, SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 27.'deki hata matrisine bakıldığında, kahverengi toprak sınıfı orta tuz ve tarım sınıfı olarak öğrenilmiştir. Orta tuz sınıfının neredeyse yarısı şiddetli tuz sınıfı olarak öğrenilmiştir. Bu nedenle kullanıcı doğruluğu %53.14'tür. Tarım ve şiddetli tuz sınıfının kullanıcı doğruluğu %90'dan fazladır. Kahverengi toprak sınıfının üretici doğruluğu %78.65'te kalmıştır. Genel doğruluk %83.95'tir.

Tablo 27. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	963	31	34	0	%93.68
Kahverengi Toprak	42	140	19	0	%69.65
Orta Tuzlu	1	7	542	470	%53.14
Şiddetli Tuzlu	0	0	36	1702	%97.93
Üretici Doğruluğu	%95.73	%78.65	%85.90	%78.36	
Genel Doğruluk					%83.95




Şekil 75. Test 3 verisi (a), SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 75.'te SI, SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 28.'deki hata matrisine bakıldığında, orta tuz sınıfı şiddetli tuz sınıfı olarak eğitilmiştir. Bu nedenle orta tuz sınıfının kullanıcı doğruluğu % 68.03'te kalmıştır. Diğer etiket sınıflarının kullanıcı doğrulukları %90'dan fazladır. Şiddetli tuz sınıfı orta tuz olarak tahmin edildiğinden şiddetli tuz sınıfının üretici doğruluğu %86.89'dur. Diğer etiket sınıflarının üretici doğrulukları %90'dan fazladır. Genel doğruluk %89.66 olarak bulunmuştur.

Tablo 28. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	583	25	4	0	%95.26
Kahverengi Toprak	27	370	13	0	%90.24
Orta Tuzlu	0	3	534	248	%68.03
Şiddetli Tuzlu	0	0	41	1644	%97.57
Üretici Doğruluğu	%95.57	%92.96	%90.20	%86.89	
Genel Doğruluk					%89.66




Şekil 76. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 76.'da NDSI, SI ve SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 29.'daki hata matrisine bakıldığında, etiket sınıflarının kullanıcı doğrulukları %90'dan fazladır. Orta tuz sınıfı şiddetli tuz sınıfı ile karıştığından orta tuz sınıfının üretici doğruluğu %90.01'dir. Kahverengi toprak sınıfı diğer etiket sınıfları olarak tahmin edildiğinden üretici doğruluğu %87.13'te kalmıştır. Genel doğruluk 92.66 olup başarılı bir sonuç alınmıştır.

Tablo 29. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1251	40	37	0	%94.20
Kahverengi Toprak	17	440	8	0	%94.62
Orta Tuzlu	3	21	1667	115	%92.30
Şiddetli Tuzlu	0	4	150	1629	%91.36
Üretici Doğruluğu	%98.43	%87.13	%90.01	%93.41	
Genel Doğruluk	%92.66				




Şekil 77. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 77.'de NDSI, SI ve SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 30.'daki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım sınıfıyla, orta tuz sınıfı şiddetli tuz sınıfıyla karışmıştır. Tarım sınıfının üretici ve kullanıcı doğruluğu %90'dan fazladır. Kahverengi toprak, orta ve şiddetli tuz sınıfları iyi öğrenilememiştir. Bu nedenle test verisi üzerinden sınıf tahminlerinde karışmalar olduğundan kahverengi toprak ve orta tuz sınıfının üretici doğrulukları %70'lerde kalmıştır. Genel doğruluk %84.93'tür.

Tablo 30. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	931	56	41	0	%90.56
Kahverengi Toprak	32	157	12	0	%78.11
Orta Tuzlu	0	1	851	168	%83.43
Şiddetli Tuzlu	0	0	291	1447	%83.26
Üretici Doğruluğu	%96.68	%73.36	%71.21	%89.60	
Genel Doğruluk	%84.93				




Şekil 78. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda yapılan bölütleme sonucu (b)

Şekil 78.'de NDSI, SI ve SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 31.'deki hata matrisine bakıldığında; orta tuz sınıfı şiddetli tuz sınıfı ile karışmıştır. Bu nedenle üretici doğruluğu % 74.92'dir. Diğer etiket sınıflarının üretici ve kullanıcı doğrulukları %85'den fazladır. Genel doğruluk 89.03 bulunmuştur.

Tablo 31. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 100 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	566	38	8	0	%92.48
Kahverengi Toprak	25	374	11	0	%91.22
Orta Tuzlu	0	5	699	81	%89.04
Şiddetli Tuzlu	0	0	215	1470	%87.24
Üretici Doğruluğu	%95.77	%89.69	%74.92	%94.78	
Genel Doğruluk	%89.03				




Şekil 79. Test 1 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 79.'da indeks eklenmeden 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 32.'deki hata matrisine bakıldığında; orta tuz sınıfı tüm etiket sınıfları olarak tahmin edildiğinden üretici doğruluğu %83.31'de kalmıştır. Şiddetli tuz sınıfının bir kısmı orta tuz olarak eğitilmiştir. Bu nedenle kullanıcı doğruluğu %84.74'te

kalmıştır. Genel olarak etiket sınıflarının kullanıcı ve üretici doğrulukları iyidir. Genel doğruluk %91.66 olup iyi bir bölütleme sonucu alınmıştır.

Tablo 32. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1219	57	52	0	%91.79
Kahverengi Toprak	35	407	23	0	%87.53
Orta Tuzlu	2	3	1796	5	%99.45
Şiddetli Tuzlu	0	0	272	1511	%84.74
Üretici Doğruluğu	%97.05	%87.15	%83.81	%99.67	
Genel Doğruluk	%91.66				




Şekil 80. Test 2 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 80.'da indeks eklenmeden 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 33.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım

ve orta tuz sınıfıyla karışmıştır. Şiddetli tuz sınıfı orta tuz sınıfı olarak eğitildiğinden kullanıcı doğruluğu %71.17'de kalmıştır. Genel doğruluk orta tuz sınıfının iyi tahmin edilememesinden dolayı %83.15'te kalmıştır.

Tablo 33. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	951	24	53	0	%92.51
Kahverengi Toprak	35	148	18	0	%73.63
Orta Tuzlu	1	0	979	40	%95.98
Şiddetli Tuzlu	0	0	501	1237	%71.17
Üretici Doğruluğu	%96.35	%86.05	%63.12	%96.87	
Genel Doğruluk	%83.15				




Şekil 81. Test 3 verisi (a), indeks eklenmeden 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 81.'de indeks eklenmeden 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 34.'deki hata matrisine bakıldığında; Orta tuz sınıfı diğer etiket sınıflarıyla karışmıştır. Bu nedenle üretici doğruluğu %61.35'te kalmıştır. Diğer etiket sınıflarının üretici doğrulukları %90'dan fazladır. Şiddetli tuz sınıfı orta tuz sınıfı ile karıştığından Kullanıcı doğruluğu %73.12'de kalmıştır. Genel doğruluk %84.11 olarak bulunmuştur.

Tablo 34. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (İndeks eklenmeden, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	575	24	13	0	%93.95
Kahverengi Toprak	31	360	19	0	%87.80
Orta Tuzlu	5	0	770	10	%98.09
Şiddetli Tuzlu	0	0	453	1232	%73.12
Üretici Doğruluğu	%94.11	%93.75	%61.35	%99.19	
Genel Doğruluk	%84.11				




Şekil 82. Test 1 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 82.'de NDSI indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 35.'deki hata matrisine bakıldığında; şiddetli tuz sınıfı orta tuz sınıfıyla karıştığından şiddetli tuz sınıfının kullanıcı doğruluğu %84.52'de kalmıştır. Orta tuz sınıfı tüm diğer etiket sınıflarıyla karıştığından üretici doğruluğu %84.33 olarak sonuç alınmıştır. Genel doğruluk %91.55 olup başarılı bir sonuç alınmıştır.

Tablo 35. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1245	49	34	0	%93.75
Kahverengi Toprak	25	420	20	0	%90.32
Orta Tuzlu	6	13	1755	32	%97.18
Şiddetli Tuzlu	4	0	272	1507	%84.52
Üretici Doğruluğu	%97.27	%87.14	%84.33	%97.92	
Genel Doğruluk	%91.55				




Şekil 83. Test 2 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 83.'de NDSI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 36.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıfı olarak eğitildiğinden kullanıcı doğruluğu %71.64'te kalmıştır. Orta tuz sınıfı diğer tüm etiket sınıfları ile karışmıştır. Bu nedenle üretici doğruluğu %69.78'te kalmıştır. Diğer etiket sınıflarının üretici doğrulukları yüksektir. Genel doğruluk %86.31'dir.

Tablo 36. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	963	28	37	0	%93.68
Kahverengi Toprak	32	144	25	0	%71.64
Orta Tuzlu	1	1	942	76	%92.35
Şiddetli Tuzlu	0	0	346	1392	%80.09
Üretici Doğruluğu	%96.69	%83.24	%69.78	%94.82	
Genel Doğruluk					%86.31




Şekil 84. Test 3 verisi (a), NDSI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 84.'de NDSI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 37.'deki hata matrisine bakıldığında; orta tuz sınıfı ile şiddetli tuz sınıfında karışmalar vardır. Bu nedenle şiddetli tuz sınıfının kullanıcı doğruluğu %75.55'te kalmıştır. Orta tuz sınıfı diğer etiket sınıflarıyla karıştığından üretici doğruluğu %63.90'dır. Diğer etiket sınıflarının üretici ve kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %85.60 olarak bulunmuştur.

Tablo 37. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	586	22	4	0	%95.75
Kahverengi Toprak	27	369	14	0	%90
Orta Tuzlu	0	1	761	23	%96.94
Şiddetli Tuzlu	0	0	412	1273	%75.55
Üretici Doğruluğu	%95.60	%94.13	%63.90	%98.23	
Genel Doğruluk	%85.60				




Şekil 85. Test 1 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 85.'de NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 38.'deki hata matrisine bakıldığında; genel olarak etiket sınıflarının kullanıcı ve üretici doğrulukları yüksektir. Kahverengi toprak sınıfı diğer etiket sınıflarıyla karıştığından kullanıcı doğruluğu %81.08'de kalmıştır. Genel doğruluk %91.66 olup iyi bir bölütleme sonucu elde edilmiştir.

Tablo 38. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1256	32	40	0	%94.58
Kahverengi Toprak	53	377	35	0	%81.08
Orta Tuzlu	3	6	1586	211	%87.82
Şiddetli Tuzlu	4	0	65	1714	%96.13
Üretici Doğruluğu	%95.44	%90.84	%91.89	%89.04	
Genel Doğruluk					%91.66




Şekil 86. Test 2 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 86.'da NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 39.'daki hata matrisine bakıldığında; orta tuz sınıfı şiddetli tuz sınıfıyla karışmalar göstermiştir. Kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karıştığından kullanıcı doğruluğu %67.65'tir.

Tablo 39. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	966	33	29	0	%93.97
Kahverengi Toprak	36	121	44	0	%60.20
Orta Tuzlu	0	3	690	327	%67.65
Şiddetli Tuzlu	0	0	15	1723	%99.14
Üretici Doğruluğu	%96.41	%77.07	%88.69	%84.05	
Genel Doğruluk	%87.79				




Şekil 87. Test 3 verisi (a), NDVI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 87.'de NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 40.'daki hata matrisine bakıldığında; orta tuz sınıfı şiddetli tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluğu %72.10'da kalmıştır. Diğer etiket sınıflarının genel olarak üretici ve kullanıcı doğrulukları iyidir. Genel doğruluk %91.01 olup iyi bir bölütleme sonucu alınmıştır.

Tablo 40. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	579	22	11	0	%94.61
Kahverengi Toprak	32	363	15	0	%88.54
Orta Tuzlu	2	4	566	213	%72.10
Şiddetli Tuzlu	0	0	15	1670	%99.11
Üretici Doğruluğu	%94.45	%93.32	%93.25	%88.69	
Genel Doğruluk	%91.01				




Şekil 88. Test 1 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 88.'de SI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 41.'deki hata matrisine bakıldığında; genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları %85' den fazladır. Orta tuz sınıfı ile şiddetli tuz sınıflarında karışmalar vardır. Kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışmıştır. Genel doğruluk %92.07 olup iyi bir bölütleme sonucu alınmıştır.

Tablo 41. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1214	64	50	0	%91.42
Kahverengi Toprak	14	445	6	0	%95.70
Orta Tuzlu	3	12	1730	61	%95.79
Şiddetli Tuzlu	0	0	217	1566	%87.83
Üretici Doğruluğu	%98.62	%85.41	%86.37	%96.25	
Genel Doğruluk	%92.07				




Şekil 89. Test 2 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 89.'da SI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 42.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluğu %74.63'tür. Orta tuz ve kahverengi toprak sınıflarının üretici doğrulukları düşüktür. Genel doğruluk %85.35 bulunmuştur.

Tablo 42. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	918	64	46	0	%89.30
Kahverengi Toprak	35	150	16	0	%74.63
Orta Tuzlu	0	0	938	82	%91.96
Şiddetli Tuzlu	0	0	341	1397	%80.38
Üretici Doğruluğu	%96.33	%70.09	%69.95	%94.46	
Genel Doğruluk					%85.35




Şekil 90. Test 3 verisi (a), SI tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 90.'da SI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 43.'deki hata matrisine bakıldığında; orta tuz sınıfı diğer etiket sınıflarıyla karışmıştır. Bu nedenle üretici doğruluğu %72.94'tür. Genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %88.92 bulunmuştur.

Tablo 43. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	561	39	12	0	%91.67
Kahverengi Toprak	31	364	15	0	%88.78
Orta Tuzlu	3	0	744	38	%94.77
Şiddetli Tuzlu	0	0	249	1436	%85.22
Üretici Doğruluğu	%94.29	%90.32	%72.94	%97.42	
Genel Doğruluk	%88.92				




Şekil 91. Test 1 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 91.'de SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 44.'deki hata matrisine bakıldığında; etiket sınıflarının çoğunun üretici ve kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %93.78 olup başarılı bir bölütleme sonucu alınmıştır.

Tablo 44. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1266	23	39	0	%95.33
Kahverengi Toprak	28	417	20	0	%89.68
Orta Tuzlu	6	15	1658	127	%91.81
Şiddetli Tuzlu	0	0	77	1706	%95.68
Üretici Doğruluğu	%97.38	%91.65	%92.42	%93.07	
Genel Doğruluk	%93.78				




Şekil 92. Test 2 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 92.'de SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 45.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluğu %72.14'tür. Orta tuz sınıfı diğer etiket sınıflarının hepsiyle karışmıştır. Bu nedenle kullanıcı doğruluğu %75.39'dur. Diğer etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %89.94 bulunmuştur.

Tablo 45. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	979	14	35	0	%95.23
Kahverengi Toprak	32	145	24	0	%72.14
Orta Tuzlu	2	1	769	248	%75.39
Şiddetli Tuzlu	0	0	45	1693	%97.41
Üretici Doğruluğu	%96.64	%90.63	%88.09	%87.22	
Genel Doğruluk	%89.94				




Şekil 93. Test 3 verisi (a), SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 93.'de SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 46.'daki hata matrisine bakıldığında; orta tuz sınıfıyla şiddetli tuz sınıfı arasında karışmalar vardır. Kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışsa da kullanıcı ve üretici doğrulukları yüksektir. Genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %92.70 olup iyi bir bölütleme sonucu bulunmuştur.

Tablo 46. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	594	13	5	0	%97.06
Kahverengi Toprak	27	364	19	0	%88.78
Orta Tuzlu	0	2	658	125	%83.82
Şiddetli Tuzlu	0	0	64	1621	%96.20
Üretici Doğruluğu	%95.65	%96.04	%88.20	%92.84	
Genel Doğruluk	%92.70				




Şekil 94. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 94.'de NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 47.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %92.70 bulunup başarılı bir bölütleme sonucu alınmıştır.

Tablo 47. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1256	55	17	0	%94.58
Kahverengi Toprak	21	429	15	0	%92.26
Orta Tuzlu	4	31	1615	156	%89.42
Şiddetli Tuzlu	0	0	94	1689	%94.73
Üretici Doğruluğu	%98.05	%83.30	%92.76	%91.54	
Genel Doğruluk	%92.70				




Şekil 95. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 95.'de NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 48.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karıştığından kullanıcı ve üretici doğruluğu diğer etiket sınıflarına nazaran düşüktür. Genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %91.75 olup iyi bir bölütleme sonucu alınmıştır.

Tablo 48. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	976	33	19	0	%94.94
Kahverengi Toprak	38	146	17	0	%72.64
Orta Tuzlu	0	7	852	161	%83.53
Şiddetli Tuzlu	0	0	54	1684	%96.89
Üretici Doğruluğu	%96.25	%78.49	%90.45	%91.27	
Genel Doğruluk	%91.75				




Şekil 96. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 96.'da NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 49.'daki hata matrisine bakıldığında; orta tuz sınıfı şiddetli tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluğu %81.02'dir. Diğer etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %92.70 bulunmuş olup iyi bir bölütleme sonucu elde edilmiştir.

Tablo 49. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII ve NDVI eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	578	31	3	0	%94.44
Kahverengi Toprak	29	367	14	0	%89.51
Orta Tuzlu	0	3	636	146	%81.02
Şiddetli Tuzlu	0	0	29	1656	%98.28
Üretici Doğruluğu	%95.22	%91.52	%93.26	%91.90	
Genel Doğruluk	%92.70				

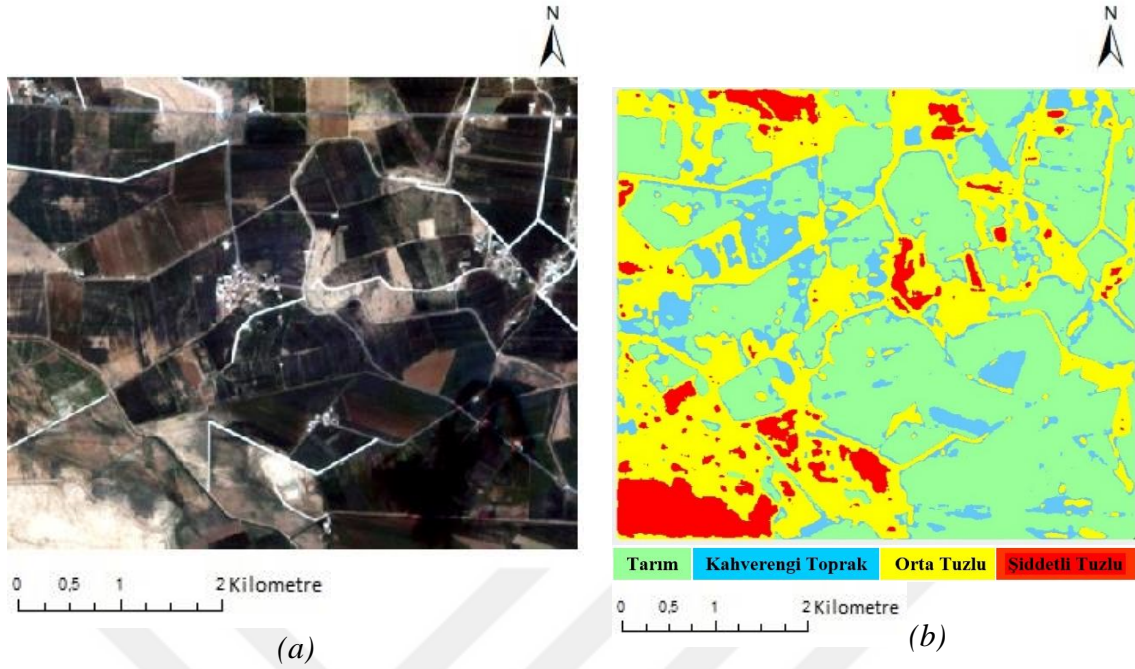


Şekil 97. Test 1 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 97.'de SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 50.'deki hata matrisine bakıldığında; şiddetli tuz sınıfı orta tuz sınıfıyla karıştığından kullanıcı doğruluğu %78.69'da kalmıştır. Kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışmıştır. Genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %89.52 bulunmuştur.

Tablo 50. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1210	68	50	0	%91.11
Kahverengi Toprak	21	444	0	0	%95.48
Orta Tuzlu	4	24	1761	17	%97.51
Şiddetli Tuzlu	0	0	380	1403	%78.69
Üretici Doğruluğu	%97.98	%82.84	%80.37	%98.80	
Genel Doğruluk	%89.52				




Şekil 98. Test 2 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 98.'de SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 51.'deki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karıştığından kullanıcı doğruluğu %74.13'te kalmıştır. Orta tuz sınıfı şiddetli tuz ile karıştığından üretici doğruluğu %76.38'de kalmıştır. Tarım ve şiddetli tuz sınıflarının üretici ve kullanıcı doğrulukları iyidir. Genel doğruluk %88.01 bulunmuştur.

Tablo 51. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	954	52	20	2	%92.80
Kahverengi Toprak	43	149	9	0	%74.13
Orta Tuzlu	0	4	928	88	%90.98
Şiddetli Tuzlu	0	2	258	1478	%85.04
Üretici Doğruluğu	%95.69	%71.98	%76.38	%94.26	
Genel Doğruluk					%88.01




Şekil 99. Test 3 verisi (a), SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 99.'da SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 52.'deki hata matrisine bakıldığında; orta tuz diğer etiket sınıfları olarak tahmin edildiğinden üretici doğruluğu düşüktür. Diğer etiket sınıflarının üretici doğrulukları %90'dan fazladır. Şiddetli tuz sınıfı orta tuz sınıfıyla karıştığından kullanıcı doğruluğu %81.60'da kalmıştır. Diğer etiket sınıflarının kullanıcı doğrulukları %90'dan fazladır. Genel doğruluk %88 bulunmuştur.

Tablo 52. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	571	33	8	0	%93.30
Kahverengi Toprak	29	373	8	0	%90.98
Orta Tuzlu	0	7	754	24	%96.05
Şiddetli Tuzlu	0	0	310	1375	%81.60
Üretici Doğruluğu	%95.17	%90.31	%69.81	%98.28	
Genel Doğruluk	%88.00				




Şekil 100. Test 1 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 100.'de NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 1 verisinin bölütleme sonucu verilmiştir. Tablo 53.'teki hata matrisine bakıldığında; genel olarak etiket sınıflarının üretici ve kullanıcı doğrulukları yüksektir. Genel doğruluk %93.31 bulunmuş olup başarılı bir bölütleme sonucu elde edilmiştir.

Tablo 53. Test 1 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	1245	45	38	0	%93.75
Kahverengi Toprak	22	435	8	0	%93.55
Orta Tuzlu	4	14	1620	168	%89.70
Şiddetli Tuzlu	0	0	61	1722	%96.58
Üretici Doğruluğu	%97.95	%88.06	%93.80	%91.11	
Genel Doğruluk	%93.31				




Şekil 101. Test 2 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 101.'de NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 2 verisinin bölütleme sonucu verilmiştir. Tablo 54.'teki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karıştığından kullanıcı doğruluğu %78.11'de kalmıştır. Orta tuz sınıfı şiddetli tuz olarak eğitildiğinden kullanıcı doğruluğu %70.10'da kalmıştır. Etiket sınıflarının üretici doğrulukları genel olarak iyidir. Genel doğruluk %88.94 bulunmuştur.

Tablo 54. Test 2 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	969	26	33	0	%94.26
Kahverengi Toprak	27	157	17	0	%78.11
Orta Tuzlu	0	3	715	302	%70.10
Şiddetli Tuzlu	0	0	33	1705	%98.10
Üretici Doğruluğu	%97.29	%84.41	%89.60	%84.95	
Genel Doğruluk					%88.94







Şekil 102. Test 3 verisi (a), NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda yapılan bölütleme sonucu (b)

Şekil 102.'de NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen Test 3 verisinin bölütleme sonucu verilmiştir. Tablo 55.'teki hata matrisine bakıldığında; orta tuz sınıfının şiddetli tuz sınıfıyla karıştığı görülmektedir. Tarım sınıfı az da olsa kahverengi toprak ve orta tuz sınıflarıyla karışmıştır. Etiket sınıflarının üretici doğrulukları %90'dan fazladır. Genel doğruluk %92.90 olup iyi bir bölütleme sonucu alınmıştır.

Tablo 55. Test 3 verisine ait etiket sınıflarının Üretici Doğruluğu ve Kullanıcı Doğruluk Değerleri (NDSI, SI, SII eklenerek, 300 iterasyon)

	Tarım	Kahverengi Toprak	Orta Tuzlu	Şiddetli Tuzlu	Kullanıcı Doğruluğu
Tarım	588	20	4	0	%96.08
Kahverengi Toprak	31	367	12	0	%89.51
Orta Tuzlu	0	2	633	150	%80.64
Şiddetli Tuzlu	0	0	29	1656	%98.28
Üretici Doğruluğu	%94.99	%94.34	%93.36	%91.69	
Genel Doğruluk	%92.90				






Şekil 103. Test 1 verisi (a), Test 1 verisi SVM sonucu (b), Test 2 verisi (c), Test 2 verisi SVM sonucu (d), Test 3 verisi (e), Test 3 verisi SVM sonucu (f)

Bilgisayarla görü alanında derin öğrenme mimarilerinden biri olan U-NET mimarisıyla yapılan bölütleme işlemlerinde iyi sonuçlar alınmıştır. Bu sonuçların performansı diğer bir makine öğrenmesi yöntemi olan destek vektör makinaları ile karşılaştırılmıştır. Destek vektör makineleri ile yapılan sınıflandırmada Test 1, Test 2 ve Test 3 verileri için genel doğruluklar sırasıyla %59.46, %63.03 ve %54.53 bulunmuştur. (Bkz. Şekil 103.) Derin öğrenme yöntemi tuzluluk gibi hassas çalışma isteyen alanlarda daha iyi sonuç verdiği görülmüştür. Çünkü kısıtlı şartlarda ve zemin üzerinde farklı arazi örtüsünün olduğu durumlarda tuz vb. minerallerin bulunması zorlaşmaktadır. Derin öğrenme yöntemlerindeki veri setleri çoğunlukla yüksek çözünürlüğe sahip görüntülerdir. Orta-yüksek çözünürlüğe sahip bir görüntüde mineral tespiti diğer bir kısıtlı durumdur. Fakat U-NET mimarisıyla yapılan bölütleme ile bu kısıtlı şartlarda tuzluluğun başarılı bir şekilde tespit edilebildiği görülmüştür.

4. SONUÇLAR VE ÖNERİLER


Çalışma kapsamında, Harran Ovası'nda 2010 yılında görülen tuzluluk probleminin tespiti için RapidEye (5 m) uydu görüntüsü kullanılarak bir derin öğrenme mimarisi olan U-NET mimarisiyle tuzlu alanların semantik bölütlemesi yapılmıştır. Tuzlu alanların tespit etmek için görüntünün sahip olduğu 5 spektral kanala ilaveten literatürde en çok geçen NDSI, SI ve SII tuzluluk indeksleri ile NDVI bitki indeksi görüntüye spektral bant olarak eklenmiştir. Yersel tuzluluk verileriyle oluşturulan tuzluluk haritası referans alınarak görüntü üzerinde orta ve şiddetli tuz sınıflarına ait spektral imzalar toplanmıştır. Arazi örtüsü üzerinde olan kahverengi toprak ve tarım alanları da etiket sınıfı olarak belirlemiştir. Görüntü üzerinde toplanan 11299 adet spektral imza eğitim verisi olarak kullanılmıştır. Test görüntülerinin doğrulukları Test 1 görüntüsü için 5382, Test 2 görüntüsü için 3987, Test 3 görüntüsü için 3492 adet noktadan yapılmıştır. Eğitim işlemleri 100 ve 300 iterasyonda 5 epokta gerçekleştirilmiştir.



Şekil 104. Test görüntülerinin indeks eklenmeden 100 iterasyondaki kullanıcı doğruluk değerleri sütun grafiği

Şekil 104.'te indeks eklenmeden 5 bant olarak 100 iterasyonda eğitilen Test 1, Test 2 ve Test 3 verilerine ait etiket sınıflarının kullanıcı doğruluk değerleri verilmiştir. Test 1 verisinde tarım sınıfı %91.19, kahverengi toprak sınıfı %93.55, orta tuz sınıfı %97.23 ve şiddetli tuz sınıfı %61.19 olarak bulunmuştur. Test 2 verisi üzerinde şiddetli tuz sınıfı daha


iyi öğrenilememiştir. Bunun sebebi Tablo 8.'deki hata matrisi incelendiğinde şiddetli tuz sınıfının orta tuz sınıfına büyük oranda karışmasından dolayı kaynaklanmaktadır. Test 2 verisinde tarım sınıfı %91.25, kahverengi toprak sınıfı %72.64, orta tuz sınıfı %84.31 ve kahverengi toprak sınıfı Tablo 9.'daki hata matrisi incelendiğinde tarım ve orta tuz sınıfı olarak öğrenildiğinden kullanıcı doğruluk diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait kullanıcı doğrulukları tarım %93.30, kahverengi toprak %89.76 orta tuz %93.38 ve şiddetli tuz %89.55'tir. Genel itibariyle tüm etiket sınıflarının kullanıcı doğrulukları yüksektir. Test 3 verisi için 100 iterasyonda iyi sonuç alınmıştır.



Şekil 105. Test görüntülerinin indeks eklemeyen 100 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 105.'te 5 bant 100 iterasyonda eğitilen Test 1, Test 2 ve Test 3 verilerine ait üretici doğrulukları verilmiştir. Test 1 verisinde tarım sınıfına ait üretici doğruluğu %97.98'dir. Kahverengi toprak sınıfı %86,65, orta tuz sınıfı %69.71 ve şiddetli tuz sınıfı %96.98 bulunmuştur. Tablo 8.'deki hata matrisi incelendiğinde; orta tuz sınıfı daha çok şiddetli tuz sınıfı olarak atandığından üretici doğruluğu diğer etiket sınıflarına nazaran düşüktür. Test 2 verisine ait üretici doğrulukları tarım sınıfı için %96.30, kahverengi toprak sınıfı %76.84, orta tuz sınıfı %80.30 ve şiddetli tuz sınıfı %91.21'dir. Tarım ve şiddetli tuz sınıfları iyi tahmin edilmiştir. Tablo 9.'daki hata matrisine bakıldığında; kahverengi toprak sınıfı tarım ve orta tuz sınıfları ile karışmıştır. Orta tuz sınıfı ise diğer tüm etiket sınıfları ile karışmıştır. Bu nedenle kahverengi toprak ve orta tuz sınıflarının üretici doğrulukları tarım


ve şiddetli tuz sınıfına nazaran düşüktür. Test 3 verisine ait üretici doğrulukları tarım için %93.76, kahverengi toprak %93.64, orta tuz sınıfı %78.06 ve şiddetli tuz sınıfı %96.79'dur. Tablo 10.'daki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıfları olarak tahmin edilmiştir. Bu nedenle üretici doğruluğu diğer etiket sınıflarına nazaran düşüktür. 5 bant 100 iterasyonda eğitilen veri setlerinin genel değerlendirilmesi yapıldığında tarım ve şiddetli tuz sınıfına ait üretici doğrulukları her bir veri setinde yüksek sonuç alınmıştır. Kahverengi toprak sınıfının en düşük üretici doğruluğu Test 2 verisinden ve orta tuz sınıfının en düşük üretici doğruluğu Test 1 verisinden alınmıştır. 5 bant 100 iterasyonda şiddetli tuzluluk iyi tespit edilebilirken orta tuz gibi daha hassas tuz tespiti için yetersiz kalmıştır.



Şekil 106. Test görüntülerinin NDSI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği

Şekil 106.'da NDSI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğruluk değerleri verilmiştir. Test 1 verisine ait kullanıcı doğrulukları tarım sınıfı için %93.07, kahverengi toprak %94.62, orta tuz %64.78 ve şiddetli tuz %98.32'dir. Tablo 11.'deki hata matrisine bakıldığında orta tuz sınıfının diğer tüm etiket sınıfları ile karıştığından kullanıcı doğruluğu düşüktür. Test 2 verisine ait kullanıcı doğrulukları tarım sınıfı için %91.44, kahverengi toprak %79.60, orta tuz %38.04 ve şiddetli tuz sınıfı %99.14'tür. Tablo 12.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıfları ile karışmıştır. Bu nedenle kullanıcı doğruluğu düşüktür. Test 3 verisine ait kullanıcı doğrulukları tarım sınıfı için %94.44, kahverengi toprak %89.51, orta tuz %43.06 ve şiddetli


tuz %99.70'tir. Veri setlerinin kullanıcı doğrulukları genel olarak incelendiğinde orta tuz sınıfının iyi öğrenilemediği görülmüştür. Her 3 veri setinde de orta tuz sınıfı büyük oranda şiddetli tuz sınıfıyla karışmıştır. NDSI tuzluluk indeksi şiddetli tuz sınıfının iyi vurgularken orta tuz sınıf iyi öğrenilememiştir.



Şekil 107. Test görüntülerinin NDSI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 107.'de NDSI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisi için üretici doğrulukları tarım için %97.17, kahverengi toprak %82.09, orta tuz %95.28 ve şiddetli tuz %74.72'dir. Tablo 11.'deki hata matrisine bakıldığında; şiddetli tuz sınıfının büyük oranda orta tuz sınıfı ile karıştığı görülmektedir. Bu nedenle üretici doğruluğu diğer etiket sınıflarına nazaran düşüktür. Test 2 verisine ait üretici doğruluklarına bakıldığında tarım sınıfı %96.21, kahverengi toprak %70.48, orta tuz %88.58 ve şiddetli tuz sınıfı %73.48'dir. Kahverengi toprak sınıfı en düşük test 2 verisinde iyi tahmin edilememiştir. Test 2 verisinin Tablo 12.'deki hata matrisine bakıldığında şiddetli tuz sınıfı büyük oranda orta tuz sınıfıyla karışmıştır. Bu nedenle üretici doğruluğu düşüktür. Test verisine ait üretici doğruluklarına bakıldığında tarım sınıfı %93.98, kahverengi toprak %90.84, orta tuz %93.63 ve şiddetli tuz sınıfı %79.55'tir. Tarım, kahverengi toprak ve orta tuz sınıfının üretici doğrulukları yüksektir. Test 3 verisinin Tablo 13.'deki hata matrisine bakıldığında şiddetli tuz sınıfı büyük oranda orta tuz sınıfıyla karışmıştır. Bu nedenle üretici doğruluğu düşüktür. NDSI tuzluluk indeksi her üç veri setinde


orta tuz sınıfını iyi tahmin edilmesini sağlamıştır. Şiddetli tuz sınıfı orta tuz sınıfıyla karışmış olup şiddetli tuzlu sınıfı iyi tahmin edilememiştir.



Şekil 108. Test görüntülerinin NDVI bitki indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği


Şekil 108.'de NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test1 verisine ait kullanıcı doğrulukları tarım sınıfı için %93.45, kahverengi toprak %94.84, orta tuz %91.47 ve şiddetli tuz sınıfı %93.77'dir. Bütün etiket sınıflarının kullanıcı doğrulukları %90'dan fazladır bu durum iyi bir eğitim işleminin gerçekleştiğini göstermektedir. Test 2 verisine ait kullanıcı doğruluklarına bakıldığında tarım %94.75, kahverengi toprak %73.13, orta tuz %78.33 ve şiddetli tuz %93.15'tir. Kahverengi toprak sınıfı tarım ve orta tuz sınıfına karıştığından kullanıcı doğruluk değeri düşüktür. Orta tuz sınıfı da büyük oranda şiddetli tuz sınıfı olarak eğitilmiştir. Bu nedenle orta tuz sınıfının kullanıcı doğruluk değeri düşüktür. Şiddetli tuz sınıfı iyi eğitilmiştir. Test 3 verisine ait kullanıcı doğruluklarına bakıldığında tarım %94.77, kahverengi toprak %90.24, orta tuz %87.39 ve şiddetli tuz sınıfı %95.01'dir. NDVI eklenerek eğitilen veri setleri genel olarak etiket sınıflarını iyi öğrenmişlerdir. NDVI eklenerek yapılan eğitim, indeks eklenmeden ve NDSI eklenerek yapılan eğitime nazaran orta tuz sınıfını daha iyi öğrenmiştir. Etiket sınıfları tüm veri setleri için genel olarak iyidir sadece Test 2 verisinin

orta tuz ve kahverengi toprak etiket sınıflarının kullanıcı doğrulukları diğer etiket sınıflarına nazaran düşüktür. Genel olarak iyi bir eğitim işlemi gerçekleştirilmiştir.




Şekil 109. Test görüntülerinin NDVI bitki indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 109.'da NDVI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait üretici doğrulukları tarım sınıfı için %98.26, kahverengi toprak %82.58, orta tuz %92.24 ve şiddetli tuz %93.20'dir. Genel olarak etiket sınıfları iyi tahmin edilmiş olup üretici doğrulukları yüksektir. Test 2 verisine ait üretici doğrulukları tarım sınıfı için %95.21, kahverengi toprak %76.56, orta tuz %84.73 ve şiddetli tuz %88.52'dir. Test 2 verisinin Tablo 15.'teki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Orta tuz sınıfı da şiddetli tuz ile karıştığından üretici doğruluğu %84.73'tür. Test 3 verisine ait üretici doğrulukları tarım için %94.77, kahverengi toprak %93.20, orta tuz %87.28 ve şiddetli tuz %94.34'tür. Test 3 verisinden etiket sınıflarına ait üretici doğrulukları genel olarak yüksektir. Tüm veri setleri incelendiğinde orta ve şiddetli tuz sınıfları düşük iterasyon sayısına rağmen iyi tahmin edilmiştir.




Şekil 110. Test görüntülerinin SI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği

Şekil 110.'da SI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait kullanıcı doğrulukları tarım için %91.57, kahverengi toprak %95.48, orta tuz %93.85 ve şiddetli tuz %69.32'dir. Test 1 verisine ait Tablo 17.'deki hata matrisine bakıldığında şiddetli tuz sınıfı büyük oranda orta tuz sınıfı ile karışmıştır bu nedenle kullanıcı doğruluğu düşüktür. Test 2 verisine ait kullanıcı doğrulukları tarım için %88.91, kahverengi toprak %77.11, orta tuz %88.53 ve şiddetli tuz %71.40'tır. Test 2 verisine ait Tablo 18.'deki hata matrisine bakıldığında şiddetli tuz sınıfı orta tuz sınıfı ile karıştığından kullanıcı doğruluk değeri düşüktür. Kahverengi toprak sınıfı da tarım ve orta tuz sınıflarıyla karışmıştır. Test 3 verisinin kullanıcı doğrulukları tarım sınıfı için %91.18, kahverengi toprak %90.24, orta tuz %89.04 ve şiddetli tuz sınıfı %76.85'tir. Veri setlerine genel olarak bakıldığında, orta tuz sınıfı şiddetli tuz sınıfına nazaran daha iyi öğrenilmiştir. Şiddetli tuz sınıfları orta tuz sınıfı olarak öğrenildiğinden üç farklı veri setinde de şiddetli tuz sınıfının kullanıcı doğruluğu orta tuz sınıfının kullanıcı doğruluğundan düşüktür. SI tuzluluk indeksi şiddetli tuz sınıfını, orta tuz sınıfı olarak öğrenmiştir.




Şekil 111. Test görüntülerinin SI tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 111.'de SI tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait üretici doğrulukları tarım için %97.51, kahverengi toprak %78.86, orta tuz %74.93 ve şiddetli tuz sınıfı %94.35'tir. Test 1 verisine ait Tablo 17.'deki hata matrisine bakıldığında, orta tuz sınıfı tarım ve şiddetli tuz sınıflarına karışmıştır. Kahverengi toprak sınıfı diğer tüm etiket sınıflarıyla karıştığından orta tuz ve kahverengi toprak sınıflarının üretici doğrulukları düşüktür. Test 2 verisine ait üretici doğrulukları tarım için %95.21, kahverengi toprak %64.05, orta tuz %62.62 ve şiddetli tuz sınıfı %92.41'dir. Test 2 verisine ait Tablo 18.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karışmıştır. Kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Bu nedenle kahverengi toprak ve orta tuz sınıflarının üretici doğrulukları düşüktür. Test 3 verisine ait üretici doğruluklarına bakıldığında tarım sınıfı %93.78, kahverengi toprak %87.68, orta tuz %63.09 ve şiddetli tuz sınıfı %94.73'tür. Test 3 verisine Tablo 19.'daki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karıştığından üretici doğruluk değeri düşüktür. SI tuzluluk indeksi eklenerek oluşturulan kombinasyonda test verileri üzerinde şiddetli tuz sınıfı daha iyi tahmin edilmiştir. Orta tuz sınıfının üretici doğruluğu, her bir veri seti için şiddetli tuz sınıfından daha düşüktür.




Şekil 112. Test görüntülerinin SII tuzluluk indeksi eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği

Şekil 112.'de SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %91.87, kahverengi toprak %91.40, orta tuz %74.31 ve şiddetli tuz %97.53'tür. Test 1 verisine ait Tablo 20.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karıştığından kullanıcı doğruluk değeri diğer tüm etiket sınıflarına nazaran düşüktür. Tarım, kahverengi toprak ve şiddetli tuz sınıflarının kullanıcı doğruluk değerleri %90'dan fazladır. Test 2 verisine ait kullanıcı doğruluk değerlerine bakıldığında tarım sınıfı %89.01, kahverengi toprak %72.64, orta tuz %49.51 ve şiddetli tuz sınıfı %98.85'tir. Test 2 verisine ait Tablo 21.'deki hata matrisine bakıldığında orta tuz sınıfı ciddi oranda şiddetli tuz sınıfına karışmıştır. Kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karıştığı görülmüştür. Test 3 verisine ait kullanıcı doğruluklarına bakıldığında tarım sınıfı %92.16, kahverengi toprak sınıfı %89.51, orta tuz sınıfı %54.52 ve şiddetli tuz sınıfı %98.93'tür. Test 3 verisine ait Tablo 22.'deki hata matrisine bakıldığında orta tuz sınıfı diğer etiket sınıflarıyla karıştığından kullanıcı doğruluk değeri düşüktür. SII tuzluluk indeksi eklenerek oluşturulan kombinasyonda tüm veri setlerinde orta tuz sınıfı iyi öğrenilememiş olup çoğunlukla şiddetli tuz sınıfıyla karışmıştır. Şiddetli tuz sınıfları her bir veri için iyi öğrenilmiş olup kullanıcı doğrulukları genel olarak %95'ten fazladır.




Şekil 113. Test görüntülerinin SII tuzluluk indeksi eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 113.'te SII tuzluluk indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.91, kahverengi toprak %83.99, orta tuz %94.11 ve şiddetli tuz %79.84'tür. Test 1 verisine ait Tablo 20.'deki hata matrisine bakıldığında şiddetli tuz sınıfı büyük oranda orta tuz sınıfı ile karıştığından üretici doğruluk değeri diğer etiket sınıflarına nazaran düşüktür. Test 2 verisine ait üretici doğruluklarına bakıldığında tarım sınıfı %95.51, kahverengi toprak %68.22, orta tuz %86.03 ve şiddetli tuz sınıfı %77.11'dir. Test 2 verisine ait Tablo 20.'deki hata matrisine bakıldığında şiddetli tuz sınıfı orta tuz sınıfıyla karışmıştır. Kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Kahverengi toprak ve şiddetli tuz sınıflarının bu nedenle üretici doğrulukları düşüktür. Test 3 verisine ait üretici doğruluk değerleri tarım için %94.47, kahverengi toprak %90.39, orta tuz %90.68 ve şiddetli tuz %82.65'tir. Test 3 verisine ait etiket sınıflarının üretici doğrulukları iyidir. Veri setlerine ayrı ayrı bakıldığında orta tuz sınıfı şiddetli tuz sınıfına göre daha doğru tespit edilmiştir. SII tuzluluk indeksi eklenerek oluşturulan bu kombinasyonda şiddetli tuz etiket sınıfı daha iyi öğrenilse de orta tuz sınıfı daha doğru tespit edilmiştir.




Şekil 114. Test görüntülerinin NDSI, SI, SII ve NDVI eklenerek 100 iterasyondaki kullanıcı doğruluk değerleri sütun grafiği

Şekil 114.'te NDSI, SI, SII tuzluluk indeksleri ve NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %90.14, kahverengi toprak %79.14, orta tuz %82.23 ve şiddetli tuz %97.98'dir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %90.27, kahverengi toprak %47.76, orta tuz %57.65 ve şiddetli tuz %99.02'dir. Test 2 verisine ait Tablo 22.'deki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz ile karışmıştır. Orta tuz sınıfı ise şiddetli tuz sınıfıyla karıştığından kullanıcı doğruluk değeri düşüktür. Test 3 verisine ait kullanıcı doğruluklarına bakıldığında tarım %94.12, kahverengi toprak %89.76, orta tuz %68.66 ve şiddetli tuz sınıfı %98.64'tür. Test 3 verisine ait Tablo 25.'teki hata matrisine bakıldığında orta tuz sınıfı şiddetli tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluk değeri düşüktür. NDSI, SI, SII ve NDVI indeks kombinasyonunda şiddetli tuz sınıfı iyi öğrenilmiştir. Orta tuz sınıfının kullanıcı doğruluğu şiddetli tuz sınıfına göre daha düşüktür. 3 tuzluluk indeksi ve bitki indeksi eklenerek oluşturulan kombinasyonda orta tuz elemine olup şiddetli tuz sınıfı daha çok vurgulanmıştır.




Şekil 115. Test görüntülerinin NDSI, SI, SII ve NDVI eklenerek 100 iterasyondaki üretici doğruluk değerleri sütun grafiği

Şekil 115.'te NDSI, SI, SII tuzluluk indeksleri ve NDVI bitki indeksi eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %94.62, kahverengi toprak %74.65, orta tuz %94.11 ve şiddetli tuz %85.39'dur. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %92.80, kahverengi toprak %58.18, orta tuz %87.63 ve şiddetli tuz %80.01'dir. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.21, kahverengi toprak %90.64, orta tuz %92.93 ve şiddetli tuz %87.43'tür. Test 1 ve Test 2 veri setlerine ait etiket sınıflarının üretici doğrulukları bakıldığında kahverengi toprak sınıfı değeri diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları genel olarak iyi tahmin edilmiştir. Veri setleri ayrı ayrı incelendiğinde orta tuz sınıfının orta tuz sınıfı şiddetli tuz sınıfına nazaran daha iyi tahmin edilmiştir. NDSI, SI, SII tuzluluk indeksleri ve NDVI bitki indeks kombinasyonu orta tuz sınıfının tespit edilmesinde iyi bir kombinasyon olmuştur.




Şekil 116. Test görüntülerinin SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği

Şekil 116.'da SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %95.11, kahverengi toprak %93.33, orta tuz %83.39 ve şiddetli tuz %96.30'dur. Test 1 verisine ait etiket sınıfları genel olarak iyi öğrenilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.68, kahverengi toprak %69.95, orta tuz %53.14 ve şiddetli tuz %97.93'tür. Test 2 verisine ait Tablo 26.'daki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Orta tuz sınıfı şiddetli tuz sınıflarıyla karıştığından kahverengi toprak ve orta tuz sınıflarının kullanıcı doğrulukları düşüktür. Test 3 verisine ait kullanıcı doğrulukları incelendiğinde tarım %95.26, kahverengi toprak %90.24, orta tuz %68.03 ve şiddetli tuz %97.57'dir. 3 farklı veri seti incelendiğinde SI, SII indeks kombinasyonu ile şiddetli tuz sınıfı daha iyi öğrenilmiştir. Orta tuz sınıfı Test 1 verisi haricinde iyi öğrenilememiştir. SI, SII kombinasyonun şiddetli tuzluluğu iyi vurguladığı görülmüştür.




Şekil 117. Test görüntülerinin SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 117.'de SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.38, kahverengi toprak %88.9, orta tuz %93.83 ve şiddetli tuz %86.32'dir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.73, kahverengi toprak %78.65, orta tuz %85.90 ve şiddetli tuz %78.36'dır. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.57, kahverengi toprak %92.96, orta tuz %90.20 ve şiddetli tuz %86.89'dur. Her 3 veri seti birlikte incelendiğinde orta tuz sınıfı şiddetli tuz sınıfına göre daha iyi tahmin edilmiştir. Orta tuz sınıflarının üretici doğrulukları şiddetli tuz sınıflarına göre daha yüksektir.




Şekil 118. Test görüntülerinin NDSI, SI ve SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen kullanıcı doğrulukları sütun grafiği

Şekil 118.'de NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.20, kahverengi toprak %94.62, orta tuz %92.30 ve şiddetli tuz %91.36'dır. Test 1 verisine ait etiket sınıfları genel olarak iyi öğrenilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %90.56, kahverengi toprak %78.11, orta tuz %83.43 ve şiddetli tuz %83.26'dır. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %90.56, kahverengi toprak %78.11, orta tuz %83.43 ve şiddetli tuz %83.26'dır. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %92.48, kahverengi toprak %91.22, orta tuz %89.04 ve şiddetli tuz %87.24'tür.




Şekil 119. Test görüntülerinin NDSI, SI ve SII tuzluluk indeksleri eklenerek 100 iterasyonda elde edilen üretici doğrulukları sütun grafiği

Şekil 119.'da NDSI, SI, SII tuzluluk indeksleri eklenerek 100 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %98.43, kahverengi toprak %87.13, orta tuz %90.01 ve şiddetli tuz %93.41'dir. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.68, kahverengi toprak %73.36, orta tuz %71.21 ve şiddetli tuz %89.60'dır. Test 2 verisine ait Tablo 30.'daki hata matrisine bakıldığında kahverengi toprak sınıfı tarım sınıfıyla, orta tuz sınıfı diğer tüm etiket sınıflarıyla karışmıştır. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.77, kahverengi toprak %89.69, orta tuz %74.92 ve şiddetli tuz %94.78'dir. Test 3 verisine ait Tablo 31.'deki hata matrisine bakıldığında yine orta tuz sınıfının diğer tüm etiket sınıflarıyla karıştığı görülmektedir. Bu nedenle üretici doğruluk değeri düşüktür. Her 3 veri seti birlikte incelendiğinde şiddetli tuz sınıfı orta tuz sınıfına nazaran daha iyi tahmin edilmiştir.




Şekil 120. Test görüntülerinin indeks eklenmeden 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 120.'de indeks eklenmeden 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %91.79, kahverengi toprak %87.53, orta tuz %99.45 ve şiddetli tuz %84.74'tür. Test 1 verisine ait etiket sınıfları genel olarak iyi eğitilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %92.51, kahverengi toprak %73.63, orta tuz %95.98 ve şiddetli tuz %71.17'dir. Test 3 verisine ait Tablo 33.'deki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz, şiddetli tuz sınıfı da orta tuz sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluk değerleri düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.95, kahverengi toprak %87.80, orta tuz %98.09 ve şiddetli tuz %94.78'dir. Test 3 verisine ait etiket sınıfları genel olarak iyi öğrenilmiştir. Her 3 veri seti birlikte incelendiğinde orta tuz sınıfı şiddetli tuz sınıfına göre daha iyi öğrenilmiştir.




Şekil 121. Test görüntülerinin indeks eklenmeden 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 121.'de indeks eklenmeden 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.05, kahverengi toprak %87.15, orta tuz %83.81 ve şiddetli tuz %99.67'dir. Test 1 verisine ait etiket sınıfları genel olarak iyi öğrenilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.35, kahverengi toprak %86.05, orta tuz %63.12 ve şiddetli tuz %96.87'dir. Test 2 verisine ait Tablo 33.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karıştığından üretici doğruluk değeri düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %94.11, kahverengi toprak %93.75, orta tuz %61.35 ve şiddetli tuz %99.19'dur. Test 3 verisine ait Tablo 34.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karıştığından üretici doğruluk değeri düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğruluk değeri orta tuz sınıfı hariç yüksektir. Tüm veri setleri birlikte incelendiğinde şiddetli tuz sınıfı orta tuz sınıfına göre daha yüksek doğrulukla tespit edilmiştir.




Şekil 122. Test görüntülerinin NDSI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 122.'de NDSI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.75, kahverengi toprak %90.32, orta tuz %97.18 ve şiddetli tuz %84.52'dir. Test 1 verisine ait etiket sınıfları genel olarak iyi eğitilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.68, kahverengi toprak %71.64, orta tuz %92.35 ve şiddetli tuz %80.09'dur. Test 2 verisine ait Tablo 36.'daki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karıştığından kullanıcı doğruluk değeri diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %95.75, kahverengi toprak %90, orta tuz %96.94 ve şiddetli tuz %75.55'dir. Tüm veri setleri bir arada incelendiğinde orta tuz sınıfı NDSI eklenerek oluşturulan kombinasyonda (300 iterasyon) iyi öğrenilmiştir.




Şekil 123. Test görüntülerinin NDSI eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 123.'te NDSI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.27, kahverengi toprak %87.14, orta tuz %84.33 ve şiddetli tuz %97.92'dir. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.69, kahverengi toprak %83.24, orta tuz %69.78 ve şiddetli tuz %94.82'dir. Test 2 verisine ait Tablo 36.'daki hata matrisine bakıldığında orta tuz sınıfı diğer etiket sınıflarıyla karıştığından üretici doğruluk değeri diğer etiket sınıflarına göre düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.60, kahverengi toprak %94.13, orta tuz %63.90 ve şiddetli tuz %98.23'tür. Test 3 verisine ait Tablo 37.'daki hata matrisine bakıldığında orta tuz sınıfı diğer etiket sınıflarıyla karıştığından üretici doğruluk değeri diğer etiket sınıflarına göre düşüktür. Tüm veri setleri birlikte incelendiğinde şiddetli tuz sınıfı daha iyi tespit edilmiştir. Orta tuz sınıfının Test 1 verisi hariç üretici doğruluğu düşüktür. Tarım sınıfı çok iyi, kahverengi toprak sınıfı iyi bir üretici doğruluk sonuçları vermiştir.




Şekil 124. Test görüntülerinin NDVI bitki indeksi eklenerek 300 iterasyonda kullanıcı doğrulukları sütun grafiği

Şekil 124.'te NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.58, kahverengi toprak %81.08, orta tuz %87.82 ve şiddetli tuz %96.13'tür. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.97, kahverengi toprak %60.20, orta tuz %67.65 ve şiddetli tuz %99.14'tür. Test 2 verisine ait Tablo 39.'daki hata matrisine bakıldığında orta tuz sınıfı şiddetli tuz sınıflarıyla karıştığından kullanıcı doğruluk değeri düşüktür. Kahverengi toprak sınıfı tarım ve orta tuz sınıfıyla karışmıştır. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.61, kahverengi toprak %88.54, orta tuz %72.10 ve şiddetli tuz %99.11'dir. Test 3 verisine ait Tablo 40.'daki hata matrisine bakıldığında orta tuz sınıfı şiddetli tuz sınıfıyla karıştığından kullanıcı doğruluk değeri diğer etiket sınıflarına göre düşüktür. Tüm veri setleri birlikte incelendiğinde şiddetli tuz sınıfı daha iyi öğrenilmiştir. Orta tuz sınıfı en iyi Test 1 verisinde öğrenilmiştir. Tarım sınıfı çok iyi, kahverengi toprak sınıfı Test 2 verisi hariç iyi bir kullanıcı doğruluk sonucu vermiştir.




Şekil 125. Test görüntülerinin NDVI bitki indeksi eklenerek 300 iterasyonda üretici doğrulukları sütun grafiği

Şekil 125.'te NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.44, kahverengi toprak %90.84, orta tuz %91.89 ve şiddetli tuz %89.04'tür. Test 1 verisine ait etiket sınıfları çok iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.41, kahverengi toprak %77.07, orta tuz %88.69 ve şiddetli tuz %84.05'tir. Test 2 verisine ait Tablo 39.'daki hata matrisine bakıldığında kahverengi toprak sınıfı tarım sınıfıyla karıştığından üretici doğruluk değeri diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %94.45, kahverengi toprak %93.32, orta tuz %93.25 ve şiddetli tuz %88.69'dur. Test 3 verisine ait etiket sınıfları yüksek doğrulukta tahmin edilmiştir. Tüm veri setleri birlikte incelendiğinde orta tuz sınıfı daha iyi öğrenilmiştir. Orta tuz sınıfı en iyi Test 3 verisinde öğrenilmiştir. Bu kombinasyonda tüm veri setleri için üretici doğruluk genel olarak yüksektir. Tarım sınıfı çok iyi, kahverengi toprak sınıfı Test 2 verisi hariç iyi bir üretici doğruluk sonucu vermiştir.




Şekil 126. Test görüntülerinin SI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 126.'da SI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %91.42, kahverengi toprak %95.70, orta tuz %95.79 ve şiddetli tuz %87.83'tür. Test 1 verisine ait etiket sınıfları çok iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %89.30, kahverengi toprak %74.63, orta tuz %91.96 ve şiddetli tuz %80.38'dir. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %91.67, kahverengi toprak %88.78, orta tuz %84.77 ve şiddetli tuz %85.22'dir. Test 3 verisine ait etiket sınıfları iyi öğrenilmiştir. Her üç veri seti birlikte incelendiğinde Test 1 ve Test 2 verileri orta tuz sınıfını şiddetli tuz sınıfına göre daha iyi öğrenmiştir. Test 3 verisi için orta tuz ve şiddetli tuz kullanıcı doğrulukları yakındır. Tarım sınıfı her veri seti için yüksek kullanıcı doğruluğuna sahiptir. Kahverengi toprak sınıfı Test 1 verisinde en iyi öğrenilmiştir.




Şekil 127. Test görüntülerinin SI eklenecek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 127.'de SI tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %98.62, kahverengi toprak %85.41, orta tuz %86.37 ve şiddetli tuz %96.25'tir. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.33, kahverengi toprak %70.09, orta tuz %69.95 ve şiddetli tuz %94.46'dır. Test 2 verisine ait Tablo 42.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karışmıştır. Kahverengi toprak sınıfı tarım sınıfıyla karışmıştır. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %94.29, kahverengi toprak %90.32, orta tuz %72.94 ve şiddetli tuz %97.42'dir. Her üç veri seti birlikte incelendiğinde tüm veriler şiddetli tuz sınıfı orta tuz sınıfına göre daha iyi tahmin edilmiştir. Tarım sınıfı her veri seti için yüksek kullanıcı doğruluğuna sahiptir. Kahverengi toprak sınıfı Test 3 verisinde en iyi öğrenilmiştir.




Şekil 128. Test görüntülerinin SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 128.'de SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %95.33, kahverengi toprak %89.68, orta tuz %91.81 ve şiddetli tuz %95.68'dir. Test 1 verisine ait etiket sınıfları iyi öğrenilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %95.23, kahverengi toprak %72.14, orta tuz %75.39 ve şiddetli tuz %97.41'dir. Test 2 verisine ait Tablo 45.'teki hata matrisine bakıldığında kahverengi toprak tarım ve orta tuz sınıflarıyla, orta tuz sınıfı şiddetli tuz sınıflarıyla karışmıştır. Bu nedenle kahverengi toprak ve orta tuz sınıflarının kullanıcı doğrulukları diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %97.06, kahverengi toprak %88.78, orta tuz %83.82 ve şiddetli tuz %96.20'dir. Test 2 verisi genel olarak iyi öğrenilmiştir. Tüm veri setleri birlikte incelendiğinde şiddetli tuz sınıfı orta tuz sınıfına göre daha iyi öğrenilmiştir. Tarım sınıfının kullanıcı doğrulukları her veri seti için %95'ten fazladır. Kahverengi toprak sınıfının kullanıcı doğrulukları genel olarak iyidir.




Şekil 129. Test görüntülerinin SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 129.'da SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.38, kahverengi toprak %91.65, orta tuz %92.42 ve şiddetli tuz %93.07'tir. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.64, kahverengi toprak %90.63, orta tuz %88.09 ve şiddetli tuz %87.22'dir. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.65, kahverengi toprak %96.04, orta tuz %88.20 ve şiddetli tuz %92.84'tür. Test 1, Test 2, Test 3 verilerine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Her 3 veri setinde de şiddetli tuz sınıfı orta tuz sınıfından daha doğru tahmin edilmiştir. Kahverengi toprak sınıfının en iyi tahmin edildiği kombinasyon SII indeksinin eklendiği kombinasyondur. Tarım sınıfının üretici doğruluğu her 3 veri seti içinde %95'ten fazladır.




Şekil 130. Test görüntülerinin NDSI, SI, SII, NDVI eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 130.'da NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.58, kahverengi toprak %92.26, orta tuz %89.42 ve şiddetli tuz %94.73'tür. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.94, kahverengi toprak %72.64, orta tuz %83.53 ve şiddetli tuz %96.89'dur. Test 2 verisine ait Tablo 48.'deki hata matrisi incelendiğinde; kahverengi toprak sınıfı tarım sınıfıyla karışmıştır. Bu nedenle kullanıcı doğruluk değeri düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.44, kahverengi toprak %89.51, orta tuz %81.02 ve şiddetli tuz %98.28'dir. NDSI, SI, SII ve NDVI ile yapılan bu kombinasyonda her 3 veri seti içinde şiddetli tuzluluk sınıfı orta tuz sınıfına göre daha iyi öğrenilmiştir. Tarım sınıfının kullanıcı doğruluk değerleri yüksektir. Kahverengi toprak sınıfı Test 2 verisi hariç iyi öğrenilmiştir.




Şekil 131. Test görüntülerinin NDSI, SI, SII, NDVI eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 131.'de NDSI, SI, SII tuzluluk indeksi ve NDVI bitki indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %98.05, kahverengi toprak %83.30, orta tuz %92.76 ve şiddetli tuz %91.54'tür. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %96.25, kahverengi toprak %78.49, orta tuz %90.45 ve şiddetli tuz %91.27'dir. Test 2 verisine ait Tablo 48.'deki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve az da olsa orta tuz sınıfıyla karışmıştır. Bu nedenle üretici doğruluk değeri diğer etiket sınıflarına nazaran düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.22, kahverengi toprak %91.52, orta tuz %93.26 ve şiddetli tuz %91.90'dır. Test 3 verisine ait etiket sınıfları bu kombinasyonda çok iyi tahmin edilmiştir. Her üç veri seti birlikte incelendiğinde Test 1 ve Test 3 verilerinde orta tuz sınıfı şiddetli tuz sınıfından daha iyi tahmin edilmiştir.




Şekil 132. Test görüntülerinin SI, SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 132.'de SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %91.11, kahverengi toprak %95.48, orta tuz %97.51 ve şiddetli tuz %78.69'dur. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %92.80, kahverengi toprak %74.13, orta tuz %90.98 ve şiddetli tuz %85.04'tür. Test 2 verisine ait Tablo 51.'deki bakıldığında kahverengi toprak sınıfı tarım ve orta tuz sınıflarıyla karışmıştır. Bu nedenle kullanıcı doğruluk değeri düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.30, kahverengi toprak %90.98, orta tuz %96.05 ve şiddetli tuz %81.60'dır. Test 3 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Her üç veri seti birlikte incelendiğinde SI, SII kombinasyonunda orta tuz sınıfı şiddetli tuz sınıfına göre daha iyi öğrenilmiştir. Test 1 ve Test 3 verilerinde kahverengi toprak sınıfının kullanıcı doğruluk değerleri yüksektir. Tarım sınıfı her üç veri setinde de çok iyi öğrenilmiştir.




Şekil 133. Test görüntülerinin SI, SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 133.'te SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.98, kahverengi toprak %82.48, orta tuz %80.37 ve şiddetli tuz %98.80'dir. Test 1 verisine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Test 1 verisine ait Tablo 50.'deki hata matrisine bakıldığında kahverengi toprak tarım ve orta tuz, orta tuz sınıfı şiddetli tuz sınıfıyla karışmıştır. Bu nedenle üretici doğruluk değerleri %80'lerde kalmıştır. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.69, kahverengi toprak %71.98, orta tuz %76.38 ve şiddetli tuz %94.26'dır. Test 2 verisine ait Tablo 51.'deki hata matrisine bakıldığında kahverengi toprak ve orta tuz sınıfları diğer tüm etiket sınıflarıyla karışmıştır. Bu nedenle üretici doğruluğu diğer etiket sınıflarına göre daha düşüktür. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %95.17, kahverengi toprak %90.31, orta tuz %69.81 ve şiddetli tuz %98.28'dir. Test 3 verisine ait Tablo 52.'deki hata matrisine bakıldığında orta tuz sınıfı diğer tüm etiket sınıflarıyla karışmıştır. Bu nedenle orta tuz sınıfının üretici doğruluk değeri düşüktür. Tüm veri setleri birlikte incelendiğinde şiddetli tuz sınıfı orta tuz sınıfına göre daha iyi tahmin edilmiştir. SI, SII kombinasyonu orta tuzun elemine edilmesine sebep olmuştur. Tarım sınıfı çok iyi tahmin edilmiştir.



Şekil 134. Test görüntülerinin NDSI, SI, SII eklenerek 300 iterasyondaki kullanıcı doğrulukları sütun grafiği

Şekil 134.'te NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin kullanıcı doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %93.75, kahverengi toprak %93.55, orta tuz %89.70 ve şiddetli tuz %96.58'dir. Test1 verisine ait etiket sınıfları iyi öğrenilmiştir. Test 2 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %94.26, kahverengi toprak %78.11, orta tuz %70.10 ve şiddetli tuz %98.10'dur. Test 2 verisine ait Tablo 54.'teki hata matrisine bakıldığında kahverengi toprak sınıfı tarım ve orta tuz, orta tuz sınıfı da şiddetli tuz sınıflarıyla karışmıştır. Bu nedenle kullanıcı doğruluk değerleri düşüktür. Test 3 verisine ait etiket sınıflarının kullanıcı doğrulukları tarım için %96.08, kahverengi toprak %89.51, orta tuz %80.64 ve şiddetli tuz %98.28'dir. Her 3 veri seti birlikte incelendiğinde şiddetli tuz sınıfı orta tuz sınıfına göre daha iyi öğrenilmiştir. Test 1 ve Test 2 verilerine ait etiket sınıfları iyi öğrenildiğinden kullanıcı doğruluk değerleri genel olarak iyidir.



Şekil 135. Test görüntülerinin NDSI, SI, SII eklenerek 300 iterasyondaki üretici doğrulukları sütun grafiği

Şekil 135.'te NDSI, SI, SII tuzluluk indeksi eklenerek 300 iterasyonda eğitilen veri setlerinin üretici doğrulukları verilmiştir. Test 1 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.95, kahverengi toprak %88.06, orta tuz %93.80 ve şiddetli tuz %91.11'dir. Test 2 verisine ait etiket sınıflarının üretici doğrulukları tarım için %97.29, kahverengi toprak %84.41, orta tuz %89.60 ve şiddetli tuz %84.95'dir. Test 3 verisine ait etiket sınıflarının üretici doğrulukları tarım için %94.99, kahverengi toprak %94.34, orta tuz %93.36 ve şiddetli tuz %91.69'dur. Her 3 veri setine ait etiket sınıfları genel olarak iyi tahmin edilmiştir. Her 3 veri setinde de orta tuz sınıfı şiddetli tuz sınıfına göre daha iyi tahmin edilmiştir. Tarım sınıfı iyi tahmin edilmiştir.

Her 3 veri setine ait etiket sınıflarının üretici ve kullanıcı doğruluk sonuçlarına bakıldığında, Test 1 verisine ait tarım sınıfı 100 iterasyonda en düşük kullanıcı doğruluğu %90.14 ile NDSI+SI+SII+NDVI, en yüksek kullanıcı doğruluğu %95.11 ile SI+SII indeks kombinasyonuna aittir. Test 1 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %79.14 ile NDSI+SI+SII+NDVI, en yüksek kullanıcı doğruluğu %95.48 ile SI kombinasyonuna aittir. Test 1 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %64.78 ile NDSI tuzluluk indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %97.23 ile indeks eklenmemiş görüntüye aittir. Test 1 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %61.19 ile indeks

eklenmemiş görüntüye aittir. Test 1 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek kullanıcı doğruluğu %98.32 ile NDSI tuzluluk indeksi eklenmiş görüntüye aittir.

Test 1 verisine ait tarım sınıfı 100 iterasyonda en düşük üretici doğruluğu %94.62 ile NDSI+SI+SII+NDVI, en yüksek kullanıcı doğruluğu %98.43 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 1 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük üretici doğruluğu %74.65 ile NDSI+SI+SII+NDVI, en yüksek üretici doğruluğu %88.39 ile SI+SII kombinasyonuna aittir. Test 1 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %69.71 ile indeks eklenmemiş kombinasyona, en yüksek üretici doğruluğu %95.28 ile NDSI eklenmiş görüntüye aittir. Test 1 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %74.72 ile NDSI eklenmiş görüntüye aittir. Test 1 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek üretici doğruluğu %96.98 ile indeks eklenmemiş görüntüye aittir.

Test 2 verisine ait tarım sınıfı 100 iterasyonda en düşük kullanıcı doğruluğu %88.91 ile SI, en yüksek kullanıcı doğruluğu %96.68 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 2 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %47.76 ile NDSI+SI+SII+NDVI, en yüksek kullanıcı doğruluğu %79.60 ile NDSI kombinasyonuna aittir. Test 2 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %38.04 ile NDSI tuzluluk indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %88.53 ile NDVI eklenmiş görüntüye aittir. Test 2 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %71.40 ile SI eklenmiş görüntüye aittir. Test 1 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek kullanıcı doğruluğu %99.14 ile NDSI tuzluluk indeksi eklenmiş görüntüye aittir.

Test 2 verisine ait tarım sınıfı 100 iterasyonda en düşük üretici doğruluğu %92.80 ile NDSI+SI+SII+NDVI, en yüksek üretici doğruluğu %96.68 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 2 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük üretici doğruluğu %58.18 ile NDSI+SI+SII+NDVI, en yüksek üretici doğruluğu %78.65 ile SI+SII kombinasyonuna aittir. Test 2 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %71.21 ile NDSI+SI+SII kombinasyona, en yüksek üretici doğruluğu %88.58 ile NDSI eklenmiş görüntüye aittir. Test 2 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %73.48 ile NDSI eklenmiş görüntüye aittir. Test 2 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek üretici doğruluğu %92.41 ile SI eklenmiş görüntüye aittir.

Test 3 verisine ait tarım sınıfı 100 iterasyonda en düşük kullanıcı doğruluğu %91.18 ile SI, en yüksek kullanıcı doğruluğu %95.26 ile SI+SII indeks kombinasyonuna aittir. Test 3 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %89.51 ile NDSI, en yüksek kullanıcı doğruluğu %91.22 ile NDSI+SI+SII kombinasyonuna aittir. Test 3 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %43.06 ile NDSI tuzluluk indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %93.38 ile indeks eklenmemiş görüntüye aittir. Test 3 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük kullanıcı doğruluğu %79.85 ile SI eklenmiş görüntüye aittir. Test 3 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek kullanıcı doğruluğu %99.70 ile NDSI tuzluluk indeksi eklenmiş görüntüye aittir.

Test 3 verisine ait tarım sınıfı 100 iterasyonda en düşük üretici doğruluğu %93.76 ile indeks eklenmemiş görüntüye, en yüksek üretici doğruluğu %95.77 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 3 verisine ait kahverengi toprak sınıfı için 100 iterasyonda en düşük üretici doğruluğu %87.68 ile SI, en yüksek üretici doğruluğu %93.64 ile indeks eklenmemiş kombinasyonuna aittir. Test 3 verisine ait orta tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %63.09 ile SI kombinasyona, en yüksek üretici doğruluğu %93.63 ile NDSI eklenmiş görüntüye aittir. Test 3 verisine ait şiddetli tuz sınıfı için 100 iterasyonda en düşük üretici doğruluğu %79.55 ile NDSI eklenmiş görüntüye aittir. Test 3 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek üretici doğruluğu %96.79 ile indeks eklenmemiş görüntüye aittir.

Test 1 verisine ait tarım sınıfı 300 iterasyonda en düşük kullanıcı doğruluğu %91.11 ile SI+SII, en yüksek kullanıcı doğruluğu %95.33 ile SII indeks kombinasyonuna aittir. Test 1 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %81.08 ile NDVI, en yüksek kullanıcı doğruluğu %95.70 ile SI kombinasyonuna aittir. Test 1 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %87.82 ile NDVI bitki indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %99.45 ile indeks eklenmemiş görüntüye aittir. Test 1 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %78.69 ile SI+SII indeks kombinasyonuna aittir. Test 1 ait şiddetli tuz sınıfı için 100 iterasyonda en yüksek kullanıcı doğruluğu %96.58 ile NDSI+SI+SII tuzluluk indeksi eklenmiş görüntüye aittir.

Test 1 verisine ait tarım sınıfı 300 iterasyonda en düşük üretici doğruluğu %95.44 ile NDVI, en yüksek üretici doğruluğu %98.62 ile SI indeks kombinasyonuna aittir. Test 1 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük üretici doğruluğu %82.84

ile SI+SII, en yüksek üretici doğruluğu %91.65 ile SII kombinasyonuna aittir. Test 1 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %80.37 ile SI+SII kombinasyonuna, en yüksek üretici doğruluğu %93.80 ile NDSI+SI+SII eklenmiş görüntüye aittir. Test 1 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %89.04 ile NDVI eklenmiş görüntüye aittir. Test 1 ait şiddetli tuz sınıfı için 300 iterasyonda en yüksek üretici doğruluğu %99.67 ile indeks eklenmemiş görüntüye aittir.


Test 2 verisine ait tarım sınıfı 300 iterasyonda en düşük kullanıcı doğruluğu %89.30 ile SI, en yüksek kullanıcı doğruluğu %95.23 ile SII indeks kombinasyonuna aittir. Test 2 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %60.20 ile NDVI, en yüksek kullanıcı doğruluğu %78.11 ile NDSI+SI+SII kombinasyonuna aittir. Test 2 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %67.65 ile NDVI bitki indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %95.98 ile indeks eklenmemiş görüntüye aittir. Test 2 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %71.17 ile indeks eklenmemiş görüntüye aittir. Test 1 ait şiddetli tuz sınıfı için 300 iterasyonda en yüksek kullanıcı doğruluğu %99.14 ile NDVI bitki indeksi eklenmiş görüntüye aittir.

Test 2 verisine ait tarım sınıfı 300 iterasyonda en düşük üretici doğruluğu %95.69 ile SI+SII, en yüksek üretici doğruluğu %97.29 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 2 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük üretici doğruluğu %70.09 ile SI, en yüksek üretici doğruluğu %90.63 ile SII kombinasyonuna aittir. Test 2 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %63.12 ile indeks eklenmemiş görüntüye, en yüksek üretici doğruluğu %90.45 ile NDSI+SI+SII+NDVI eklenmiş görüntüye aittir. Test 2 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %84.05 ile NDVI eklenmiş görüntüye aittir. Test 2 ait şiddetli tuz sınıfı için 300 iterasyonda en yüksek üretici doğruluğu %96.87 ile indeks eklenmemiş eklenmiş görüntüye aittir.


Test 3 verisine ait tarım sınıfı 300 iterasyonda en düşük kullanıcı doğruluğu %91.67 ile SI indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %97.06 ile SII indeks kombinasyonuna aittir. Test 3 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %87.80 ile indeks eklenmemiş görüntüye, en yüksek kullanıcı doğruluğu %90.98 ile SI+SII kombinasyonuna aittir. Test 3 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %72.10 ile NDVI bitki indeksi eklenmiş kombinasyona, en yüksek kullanıcı doğruluğu %98.09 ile indeks eklenmemiş görüntüye

aittir. Test 3 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük kullanıcı doğruluğu %73.12 ile indeks eklenmemiş görüntüye aittir. Test 3 ait şiddetli tuz sınıfı için 300 iterasyonda en yüksek kullanıcı doğruluğu %99.11 ile NDVI bitki indeksi eklenmiş görüntüye aittir.

Test 3 verisine ait tarım sınıfı 300 iterasyonda en düşük üretici doğruluğu %94.11 ile indeks eklenmemiş görüntüye, en yüksek üretici doğruluğu %95.65 ile NDSI+SI+SII indeks kombinasyonuna aittir. Test 3 verisine ait kahverengi toprak sınıfı için 300 iterasyonda en düşük üretici doğruluğu %87.68 ile SI, en yüksek üretici doğruluğu %93.64 ile indeks eklenmemiş kombinasyonuna aittir. Test 3 verisine ait orta tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %90.31 ile SI+SII kombinasyonuna, en yüksek üretici doğruluğu %96.04 ile SII eklenmiş görüntüye aittir. Test 3 verisine ait şiddetli tuz sınıfı için 300 iterasyonda en düşük üretici doğruluğu %88.69 ile NDVI eklenmiş görüntüye aittir. Test 3 ait şiddetli tuz sınıfı için 300 iterasyonda en yüksek üretici doğruluğu %99.19 ile indeks eklenmemiş görüntüye aittir.



Şekil 136. Test görüntülerinin indeks kombinasyonlarının 100 iterasyondaki genel doğrulukları sütun grafiği



Şekil 137. Test görüntülerinin indeks kombinasyonlarının 300 iterasyondaki genel doğrulukları sütun grafiği

Şekil 136. ve Şekil 137.'de indeks kombinasyonlarının 100 ve 300 iterasyondaki genel doğruluk değerleri sütun grafiği üzerinde verilmiştir. Verilen indeks kombinasyonlarının sonuçlarına bakıldığında en iyi sonuç %93.78 ile 300 iterasyonda gerçekleştirilen Test 1 verisine eklenmiş SII indeks kombinasyonundan alınmıştır. Ardından onu %93.31 ile Test 1 verisine eklenmiş NDSI, SI, SII tuzluluk indekslerinin 300 iterasyondaki eğitim işlemi takip etmektedir.

Şekil 136.'da 100 iterasyonda gerçekleştirilen eğitim sonuçlarına bakıldığında Test 1 verisi için en yüksek genel doğruluk %93.01 ile NDVI eklenmiş kombinasyondan alınmıştır. Ardından onu %92.66 ile NDSI, SI ve SII indeksleri eklenmiş kombinasyon takip etmektedir. 100 iterasyonda Test 2 verisinin genel doğruluk sonuçlarına bakarsak; en iyi sonuç %88.84 ile indeks eklenmeden görüntünün doğrudan eğitildiği sonuçtur. Ardından onu %88.76 ile NDVI bitki indeksi eklenmiş kombinasyon takip etmektedir. Test 3 verisinin genel doğruluk sonuçlarına bakıldığında en yüksek doğruluk %92.70 NDVI eklenmiş kombinasyondan alınmıştır. Ardından onu %91.09 ile indeks eklenmemiş görüntü takip etmektedir.

Şekil 137.'de 300 iterasyonda gerçekleştirilen eğitim sonuçlarına bakıldığında Test 1 verisi için en yüksek genel doğruluk %93.78 ile SII tuzluluk indeksi eklenmiş kombinasyondan alınmıştır. Ardından onu %93.31 ile NDSI, SI ve SII indeks kombinasyonu takip etmektedir. Test 1 verisine ait genel doğruluklar SI, SII indeks kombinasyonu hariç %90'dan fazladır. İterasyon sayısının artırılması genel doğruluk değerlerinin artmasını

sağlamıştır. 300 iterasyonda Test 2 verisine ait en yüksek genel doğruluk %91.75 ile NDSI, SI, SII ve NDVI indeks kombinasyonundan alınmıştır. Ardından onu %89.94 ile SII eklenmiş indeks kombinasyonu takip etmektedir. Test 2 verisinin genel doğruluk değerleri 100 ve 300 iterasyonda değişkenlik göstermektedir. Bazı kombinasyonlarda iterasyon sayısının artırılması genel doğruluk değerini artırsa da bazı kombinasyonlarda genel doğruluk değeri düşmüştür. Test 3 verisinin genel doğruluk değerlerine bakıldığında; en yüksek genel doğruluk %92.90 değeri ile NDSI, SI ve SII indeks kombinasyonundan alınmıştır. Ardından onu %92.70 değeri ile, SII ve SI, SII, NDSI, NDVI indeks kombinasyonları takip etmektedir. Test 3 verisi içinde iterasyon sayısının artırılması çoğunlukla genel doğruluk değerinin artmasını sağlamıştır.

İndeks kombinasyonlarının 100 ve 300 iterasyondaki sonuçları karşılaştırıldığında iterasyon sayısının artması her 3 veri seti için etiket sınıflarının genel doğruluklarını artırmıştır. Özellikle orta ve şiddetli tuz sınıflarının iterasyon sayısının artırılmasıyla mimari daha iyi bu sınıfları öğrenmiştir. Ayrıca şiddetli tuz sınıfı her iki iterasyonda da en iyi indeks eklenmemiş görüntüde sonuç vermiştir. Bu durum görüntü üzerinde tuz sınıfının belirlenebildiğini ancak orta tuz gibi daha hassas tuz tespiti için tuzluluk indekslerinin kullanılması farklı tuzluluk derecelerinin ayrıştırılabildiğini göstermiştir. 100 ve 300 iterasyonda gerçekleştirilen eğitim işlemleri sonucunda elde edilen üretici doğruluklarına bakarsak; NDSI tuzluluk indeksi şiddetli tuz sınıfını iyi tahmin etmiştir. NDVI orta tuz sınıfının iyi bir şekilde tahmin edilip ayrıştırılmasını sağlamıştır. SI tuzluluk indeksi orta tuz sınıfına nazaran şiddetli tuz sınıfının daha iyi tahmin edilmesini sağlamıştır. SII tuzluluk indeksi orta ve şiddetli tuz sınıflarının yakın üretici doğruluklarında tahmin edilmesini sağlamıştır. NDSI, SI, SII ve NDVI indekslerinin yapıldığı kombinasyonda orta ve şiddetli tuz sınıfları %90 ve daha fazla doğrulukla tahmin edilmiştir. SI, SII tuzluluk indeks kombinasyonu şiddetli tuz sınıfına iyi tahmin edip orta tuz sınıfının tahmin edilmesinde çok iyi sonuç vermemiştir. NDSI, SI ve SII indeks kombinasyonu şiddetli ve orta tuz sınıflarının her ikisi içinde iyi tahmin değerleri vermiştir.

Yapılan bu eğitimler neticesinde genel doğruluk sonuçlarına bakıldığında toprak tuzluluğunun tespit edilmesinde en yüksek sonuç 300 iterasyonda Test 1 verisinden %93.78 ile SII tuzluluk indeksinin eklendiği kombinasyondan alınmıştır. Aynı sınıflandırma işlemi destek vektör makineleri ile yapıldığında genel doğruluk %59.46'da kalmıştır. Orta yüksek çözünürlüğe sahip görüntüler üzerinde toprak tuzluluğunun tespiti gibi hassas çalışmalar için

derin öğrenme U-NET mimarisi, makine öğrenmesi yöntemlerinden biri olan destek vektör makinelerinden daha yüksek sonuç vermiştir.

Yapılan bu çalışmaya göre büyük ve geniş alanları kapsayan görüntülerde ve konumsal çözünürlüğün, çok yüksek çözünürlüklü görüntülere nazaran daha düşük olduğu durumlarda sınıflandırmanın doğru yapılması için iyi bir sınıflandırma veya bölütleme yöntemine ihtiyaç vardır. Yapılan çalışma sonucunda, bir derin öğrenme mimarisi olan U-NET mimarisinin bu anlamda güçlü yöntemlerden birisi olduğu görülmüştür. Çoğunlukla medikal görüntülerde hastalık tanısı gibi hassas çalışmalar için kullanılmaktadır. Tuzluluk gibi çok ciddi bir çevre sorunu, ekonomik ve sosyal problemleri de beraberinde getirdiğinden uzaktan algılama ile belirlenmesi için hassas bir çalışma gerektirmektedir. Hafif tuzluluğun çoğu zaman toprağın alt kısmında olması ve çoğu kez çiftçiler tarafından dahi görülememesi bu durumun önemini göstermektedir. Bu nedenle, eğitim ve test verileri üzerinde belirtilen etiket sınıfları tam anlamıyla o sınıfı temsil edecek olan piksellerden seçilmelidir. ROI'lerin çevrilmesi bu anlamda hassasiyet gerektirmektedir. Etiket sınıflarını temsil eden ROI'ler doğru çevrilmediği takdirde mimaride yanlış eğitim yapılmış olur ve iyi bir bölütleme işlemi gerçekleştirilemez. Mümkün olduğu kadar arazi üzerinde olan farklı nesnelere mimariye verilmesi gerekmektedir. Böylelikle birbirine benzer sınıfların aynı nesnelere olarak atanmasını önlenmiş olur.

Harran Ovası'nda toprak tuzluluğunun tespiti için birçok kısıt vardır. Tuzlu alanlar tarım arazilerinin iç bölgelerinde olduğu için tespit edilmesi bu noktada güçtür. Ayrıca orta yüksek çözünürlüklü bir görüntü üzerinde tuz gibi bir mineralin tespiti konumsal çözünürlük anlamında bir başka kısıttır. Bu nedenle görüntüye tuzluluk indekslerinin eklenerek spektral bant sayısının artırılması, tuz sınıflarının ayırt edilebilirliğini arttırmıştır. Görüntü üzerinden doğrudan şiddetli tuzlu alanlar tespit edilse de orta tuz sınıfının tespiti güçtür. Bu yüzden tuzluluk indekslerinin görüntüye eklenmesi orta tuz sınıfının tespit edilebilirliğini arttırmıştır.

11299 adet pikselin eğitim işlemi gerçekleştirildiği çalışmada eğitim işlemi sonrası ağın bulduğu en uygun ağırlık değerleriyle test görüntü üzerinde bölütleme işlemi yapılmıştır. Bu kadar büyük bir verinin işlenmesi için yeterli donanıma sahip bir bilgisayarın kullanılması gerekmektedir. Bilgisayarın kendi bünyesinde olan işlemci (CPU) ile bu işlem çok zordur. Paralel işlem yapabilen ve yüksek ekran kartına sahip bilgisayar gerekmektedir. Neticede derin öğrenme yöntemleri büyük veriler için geliştirilmiştir.

Derin öğrenme mimarisinde kullanılacak aktivasyon fonksiyonu yapılan işleme göre seçilmelidir. Sınıflandırma, tahmin veya zaman serisi problemleri gibi farklı alanlarda yapılacak çalışmalar için mimariye uygulanacak aktivasyon fonksiyonu da farklıdır. Ağın eğitim işleminin devam etmesi, ölü nöronların oluşmasının engellenmesi buna bağlıdır. Verideki değerlerin hangi aralıkta olduğu ya da çok büyük veya küçük olması, aktivasyon fonksiyonu seçiminde dikkate alınmalıdır. Örneğin veri seti büyük değerler içeriyorsa sigmoid fonksiyonu kullanıldığı takdirde ağ doyma durumuna çabuk gelir ve iyi bir eğitim gerçekleştirilemez. Bu nedenle mimariye en uygun aktivasyon fonksiyonu seçilmelidir.

Doğru sonucu ulaşmak için farklı iterasyon değerleriyle birçok kez eğitim işlemi denenmiştir. Genel olarak iterasyon sayısının artırılması bilgisayarın gördüğü verileri daha iyi öğrenmesini sağlamıştır. Ancak her veri seti için bu durum söz konusu değildir. En uygun iterasyon sayısı ile ağda en uygun ağırlıklar bulunur. Yüksek iterasyon sayılarında ağ aynı ağırlıkları güncellediğinden ezberleme durumu söz konusu olabilir. Ayrıca doğru hiperparametrelerin belirlenmesi ağın en doğru ağırlıkları bulması için önemlidir. Hiperparametreler metasezgisel olarak yani deneme yanılma yoluyla belirlenir. Derin öğrenme mimarilerinde ağın eğitim işlemi boyunca doğru ağırlık katsayılarının bulunması için etken birçok rassal parametre vardır. Eğitim başlangıcında rastgele belirlenen ilk ağırlık değeri veya öğrenme katsayısı vb. parametreler ağın oluşturacağı ağırlık modeline ait hata miktarının az veya çok olmasıyla doğrudan ilişkilidir.

Bu tez çalışmasıyla Harran Ovası toprak tuzluluğu uydu görüntüleri üzerinden tespit edilmiştir. Tuzluluk indeksleri ve güçlü bir sınıflandırma yöntemi olan derin öğrenme U-NET mimarisi kullanılarak yapılan çalışmada %93.78 genel doğruluk elde edilmiştir. Başarılı bir sonuç veren yöntem ülkemiz ve Dünya üzerinde görülen tuzluluk probleminin tespiti ve izlenmesi için iyi bir kaynak sağlayacaktır.

5. KAYNAKLAR

- Abbas, A. S. K., 2007. Using remote sensing techniques for appraisal of irrigated soil salinity. International Congress on Modelling and Simulation" CONFERENCE MODELLING AND SIMULATION SOCIETY of Australia and New Zealand Christchurch, New Zealand. 2632-8.
- Akış, A., Kaya, B., Seferov, R. ve Başkan, H. O., 2005. "Harran Ovası ve Çevresindeki Tarım Arazilerinde Tuzluluk Problemi ve Bu Problemin İklim Özellikleriyle İlişkisi," Selçuk Üniversitesi Sos. Bilim. Enstitüsü Derg., 14, 21–38.
- Badrinarayanan, V., Kendall, A. ve Cipolla, R. 2015. "SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation," arXiv, [Online]. Available: <http://arxiv.org/abs/1511.00561>
- Bilgili, A. V., Cullu, M. A., Es, H., Aydemir, A. ve Aydemir, S., 2011. The Use of Hyperspectral Visible and Near Infrared Reflectance Spectroscopy for the Characterization of Salt-Affected Soils in the Harran Plain, Turkey, Arid Land Research and Management, 25:1, 19-37, DOI: 10.1080/15324982.2010.528153.
- Brosch, J. D., 2009. Digital Signal Processing, isbn 978-0-7506-8976-2
- Chollet, F., 2018. Deep Learning with Python, Manning Publication, New York
- Clevert, D. A., Unterthiner, T. ve Hochreiter, S. 2015. "Fast and Accurate Deep Network Learning by Exponential Linear Units (ELUs)," arXiv, 2015. [Online]. Available: <http://arxiv.org/abs/1511.07289>.
- Courbariaux, M., Bengio, Y. Ve David, J. P., 2015. "BinaryConnect: Training Deep Neural Networks with binary weights during propagations." arXiv, pp. 3123–3131. [Online]. Available: <https://arxiv.org/pdf/1511.00363.pdf>.
- Çullu, M. A., 1999. Gap'ta tuzlulaşma ve Harran Ovasının durumu. Toprak tuzlulaşması, Workshop Tema Vakfı Yayınları, İstanbul, 30: 56-64.
- Dahl, G. E., Sainath, T. N. ve Hinton, G. E. 2013. "Improving deep neural networks for LVCSR using rectified linear units and dropout," in International Conference on Acoustics, Speech and Signal Processing. IEEE.
- Deliboran, A., 2015. "Toprak Tuzluluğu ve Tuzluluğa Bitkilerin Dayanım Mekanizmaları," Türk Bilimsel Derlemeler Dergisi, vol. 8, 1, 57–61.
- Douaoui, A. E. K., Nicolas, H. ve Walter, C. 2006. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. Geoderma;134,1, 217-30.
- DSİ, 1971. Aşağı Fırat Projesi Urfa-Harran Ovası Planlama Arazi Tasnif Raporu. DSİ 10. Bölge Müd. Proje No:2108.03.01, Diyarbakır

- Elfwing, S., Uchibe, E. ve K. Doya, 2017. "Sigmoid-Weighted Linear Units" arXiv, [Online]. Available: <http://arxiv.org/abs/1702.03118>.
- Elmacı, M., 2018. Derin Öğrenme Yöntemiyle Çok Bantlı Görüntülerde Anlamsal Bölütleme, Yüksek Lisans Tezi, ERÜ, Fen Bilimleri Enstitüsü, Kayseri.
- Glorot, X. ve Bengio, Y., 2010. "Understanding the difficulty of training deep feedforward neural networks," in International Conference on Artificial Intelligence and Statistics, 9. 249-256. [Online]. Available: http://proceedings.mlr.press/v9/glorot10a/glorot10a.pdf?hc_location=ufi, 20 Ekim 2019.
- Goodfellow, I. J., Warde-Farley, D., Mirza, M., Courville, A., ve Bengio, Y., 2013. "Maxout networks" p. 1319. [Online]. Available: <https://dl.acm.org/citation.cfm>
- He, K., Zhang, X., Ren, S. ve Sun, J., 2015 "Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification," arXiv, [Online]. Available: <http://arxiv.org/abs/1502.01852>
- Horneck, D.A., Ellsworth, J.W., Hopkins, B.G., Sullivan, D.M. ve Steven, R.G., 2007. Managing salt-affected soils for crop production. A Pacific Northwest Extension. Oregon State University.
- Kanber, R., Çullu, M.A., Kendirli, B., Antepi, S. ve Yılmaz, S., 2005. Sulama, Drenaj ve Tuzluluk. VI. Türkiye Ziraat Mühendisliği Kongresi, Ankara, 213-253.
- Karlık, B. ve Vehbi, A., 2011. "Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks," International Journal of Artificial Intelligence and Expert Systems (IJAE), vol. 1, no. 4, pp. 111–122. [Online] Available: <http://www.cscjournals.org/library/manuscriptinfo.php>.
- Kazancı S. Z., ve Kayıkçı E. T., 2014. Konumsal Enterpolasyon Yöntemleri Uygulamalarında Optimum Parametre Seçimi Doğu Karadeniz Bölgesi Günlük Ortalama Sıcaklık Verileri Örneği, Yayın Yeri:7. Ulusal Mühendislik Ölçmeleri Sempozyumu.
- Kemker, R., C. Salvaggio, and C. Kanan, 2017. "High-Resolution Multispectral Dataset for Semantic Segmentation." CoRR, abs/1703.01918.
- Keskenler, M.F. ve Keskenler, E.F., 2017. "Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi", Takvim-i Vekayi, 5, 2, 8-18.
- .
- Khan, N. M., Rastoskuev, V. V., Shalina, E. V., ve Sato, Y., 2001. Mapping salt-affected soils using remote sensing indicators-a simple approach with the use of GIS IDRISI. Paper presented at the 22nd Asian Conference on Remote Sensing5, 9.

- Khan, S., Rahmani, H., Shah, S. A.A., ve Bennamoun, M., 2018. A Guide to Convolutional Neural Networks for Computer Vision. SYNTHESIS LECTURES ON COMPUTER VISION, Series ISSN Print 2153-1056 Electronic 2153-1064.
- Kim, P., 2017. MATLAB Deep Learning, Apress Publication, Seoul.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E., 2012. "Imagenet classification with deep convolutional neural networks" [Online]. Available: <http://citeseerx.ist.psu.edu/viewdoc/summary>, 17 Haziran 2020.
- LeCun, Y., Bengio, Y. ve Hinton, G., 2015. "Deep learning," Nature, vol. 521, no. 7553, pp. 436–444.[Online]. Available: <https://doi.org/10.1038/nature14539>
- Lin, M., Chen, Q. ve Yan, S. 2013. "Network In Network," arXiv, [Online]. Available: <http://arxiv.org/abs/1312.4400>
- Maas, A., Hannun, A. ve Ng, A., 2013. "Rectifier Nonlinearities Improve Neural Network Acoustic Models," in International Conference on Machine Learning (icml),.
- McPherson, R., Shokri, R., ve Shmatikov, V., 2016. Defeating Image Obfuscation with Deep Learning, Cryptography and Security (cs.CR); Computer Vision and Pattern Recognition (cs.CV), arXiv:1609.00408.
- Moolayil, J., 2019. Learn Keras for Deep Neural Networks, Apress Publication, Vancouver.
- Muruganandham, S., 2016. Semantic Segmentation of Satellite Images using Deep Learning, Space Engineering, masters level, Luleå University of Technology Department of Computer Science, Electrical and Space Engineering.
- Nair V. ve Hinton, G. E. 2010. "Rectified linear units improve restricted boltzmann machines," Haifa, 807–814. [Online]. Available: <https://dl.acm.org/citation.cfm>, 16 Haziran 2020.
- Neal, R. M., "Connectionist learning of belief networks," Artificial Intelligence, vol. 56, no. 1, pp. 71–113, [Online]. Available: [https://doi.org/10.1016/0004-3702\(92\)90065-6](https://doi.org/10.1016/0004-3702(92)90065-6), 18 Haziran 2020.
- Örmeci, C., 1987.Uzaktan Algılama: Temel Esaslar ve Algılama Sistemleri, İTÜ MATBASİ, Cilt I
- Özkan, C., 2001. Uydu görüntülerinin Yapay Sinir Ağıyla Sınıflandırılması, Doktora Tezi İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Patterson, J. ve Gibson, A., 2017. Deep Learning, O'Reilly Media, United State of America.
- Ramachandran, P., Zoph, B. ve Le, Q. V., 2017. "Searching for Activation Functions," ArXiv, [Online]. Available: 1710.05941, <http://arxiv.org/abs/1710.05941>

- Sönmez, B., ve Beyazgül, M., 2008. Türkiye’de tuzlu ve sodyumlu toprakların ıslahı ve yönetimi. Toprak Gübre ve Su kaynakları Merkez Araştırma Enstitüsü Müdürlüğü, teknik Yayın No:33, Ankara.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. ve Rabinovich, A., 2015. “Going deeper with convolutions”, in Conference on Computer Vision and Pattern Recognition (CVPR), vol. 2015. IEEE, pp. 1–9.
- Tóth, L., 2015. “Phone recognition with hierarchical convolutional deep maxout networks” EURASIP J. Audio, Speech, Music Process, vol. 2015, no. 1, p. 25, 12 2015
- URL-1, <https://en.eijkelkamp.com/products/field-measurement-equipment/ec-probe-for-salinity-measurements.html>, EC-probe for soil salinity measurement . 15 Haziran 2019.
- URL-2, <https://www.georeva.eu/en/produit/em38-mk2/>, EM38-MK2. 12 Haziran 2019.
- URL-3, <http://haberciniz.biz/tarlalari-tuzlanan-ciftciler-caresiz-kaldi-sanliurfa730383h.htm>, Tarlaları tuzlana çiftçiler çaresiz kaldı. 25 Ekim 2019.
- URL-4, <https://towardsdatascience.com/understanding-semantic-segmentation-with-unet-6be4f42d4b47>, Understanding Semantic Segmentation. 15 Aralık 2019
- URL-5, <https://towardsdatascience.com/epoch-vs-iterations-vs-batch-size-4dfb9c7ce9c9> , Epoch and Iteration ,14 Aralık 2019
- URL-6, <https://physics.stackexchange.com/questions/171144/do-electromagnetic-waves-occupy-varying-amounts-of-space-or-do-they-simply-vary>, Electromagnetic Waves, 8 Eylül 2019.
- URL-7, http://gsp.humboldt.edu/OLM/Courses/GSP_216_Online/lesson3-1/resolution.html, HumboltState University Lesson, 2 Eylül 2019
- URL-8, <http://www.kuark.org/2012/07/jeomanyetik-firtinalar/> Jeomanyetik Fırtınalar ve Oluşum Biçimleri. 21 Mart 2014.
- URL-9, https://www.planet.com/products/satellite-imagery/files/1610.06_Spec%20Sheet_Combined_Imagery_Product_Letter_ENGv1.pdf, Planet Product. 14 Mayıs 2019.
- URL-10, <https://medicalxpress.com/news/2018-07-neuron-axons-spindly-theyre-optimizing.html>, Why are neuron and axons long and spindly?. 15 Mayıs 2019.
- URL-11, <http://www.koeri.boun.edu.tr/sismo/personel/comoglu/deprennedir/index.htm> Depremle İlgili Teknik Bilgiler. 15 Mart 2014.

- URL-12, <https://www.qld.gov.au/environment/land/management/soil/salinity/types> ,Types of Salinity. 12 Haziran 2019.
- URL-13, <https://medium.com/greyatom/what-is-underfitting-and-overfitting-in-machine-learning-and-how-to-deal-with-it-6803a989c76>, What is Underfitting and Overfitting in machine learning and how to deal with it. 16 Haziran 2019.
- URL-14, <https://medium.com/konvergen/understanding-dropout-ddb60c9f98aa>, Understanding Dropout. 17 Haziran 2019.
- URL-15, <https://medium.com/@tuncerergin/convolutional-neural-network-convnet-yada-cnn-nedir-nasil-calisir-97a0f5d34cad>, Convolutional Neural Network. 18 Haziran 2019.
- URL-16, <https://maniksonituts.medium.com/max-pooling-in-convolutional-neural-network-cnn-ea3d82e86b9>, Max Pooling in Convolutional Neural Network. 18 Haziran 2019.
- URL-17, <https://www.colabug.com/2019/0605/6370525/>, Semantic Segmentation using torchvision. 20 Haziran 2019.
- Yu, H., Liu, M., Du, B., Wang, Z., Hu, L. ve Zhang, B., 2018. *Mapping Soil Salinity/Sodicity by using Landsat OLI Imagery and PLSR Algorithm over Semiarid West Jilin Province, China. Sensors, 18(4), 1048.* doi:10.3390/s18041048
- Zeiler M. D. ve Fergus, R., 2013. “Visualizing and Understanding Convolutional Networks,” arXiv, [Online]. Available: <http://arxiv.org/abs/1311.2901>
- Zeiler, M. D., Ranzato, M., Monga, R., Mao, M., Yang, K., Le, Q. V. ve Hinton, G. E. 2013. “On rectified linear units for speech processing,” in International Conference on Acoustics, Speech and Signal Processing. IEEE, pp. 3517–3521, IEEE. <https://doi.org/10.1109/ICASSP.2013.6638312>.
- Zheng, H., Yang, Z., Liu, W., Liang, J. ve Li, Y., 2015. “Improving deep neural networks using softplus units,” in International Joint Conference on Neural Networks (IJCNN), vol. 2015. IEEE, pp. 1–4
- Pulinets, S., A., 1998. Strong Earthquakes Prediction Possibility with the Help of Top Side Sounding from Satellites, Advances in Space Research, 21, 3, 455–458.

6. EKLER

Tablo 56. U-Net mimarisi kodlayıcı ve kod çözücü katman detayları

1	'ImageInputLayer'	Image Input	256x256x7 images with 'zerocenter' normalization
2	'Encoder-Section-1-Conv-1'	Convolution	64 3x3x7 convolutions with stride [1 1] and padding [1 1 1 1]
3	'Encoder-Section-1-ReLU-1'	ReLU	ReLU
4	'Encoder-Section-1-Conv-2'	Convolution	64 3x3x64 convolutions with stride [1 1] and padding [1 1 1 1]
5	'Encoder-Section-1-ReLU-2'	ReLU	ReLU
6	'Encoder-Section-1-MaxPool'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0 0 0]
7	'Encoder-Section-2-Conv-1'	Convolution	128 3x3x64 convolutions with stride [1 1] and padding [1 1 1 1]
8	'Encoder-Section-2-ReLU-1'	ReLU	ReLU
9	'Encoder-Section-2-Conv-2'	Convolution	128 3x3x128 convolutions with stride [1 1] and padding [1 1 1 1]
10	'Encoder-Section-2-ReLU-2'	ReLU	ReLU
11	'Encoder-Section-2-MaxPool'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0 0 0]
12	'Encoder-Section-3-Conv-1'	Convolution	256 3x3x128 convolutions with stride [1 1] and padding [1 1 1 1]
13	'Encoder-Section-3-ReLU-1'	ReLU	ReLU
14	'Encoder-Section-3-Conv-2'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
15	'Encoder-Section-3-ReLU-2'	ReLU	ReLU
16	'Encoder-Section-3-MaxPool'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0 0 0]
17	'Encoder-Section-4-Conv-1'	Convolution	512 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
18	'Encoder-Section-4-ReLU-1'	ReLU	ReLU
19	'Encoder-Section-4-Conv-2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1 1 1]

20	'Encoder-Section-4- ReLU-2'	ReLU	ReLU
21	'Encoder-Section-4- DropOut'	Dropout	50% dropout
22	'Encoder-Section-4- MaxPool'	Max Pooling	2x2 max pooling with stride [2 2] and padding [0 0 0 0]
23	'Mid-Conv-1'	Convolution	1024 3x3x512 convolutions with stride [1 1] and padding [1 1 1 1]
24	'Mid-ReLU-1'	ReLU	ReLU
25	'Mid-Conv-2'	Convolution	1024 3x3x1024 convolutions with stride [1 1] and padding [1 1 1 1]
26	'Mid-ReLU-2'	ReLU	ReLU
27	'Mid-DropOut'	Dropout	50% dropout
28	'Decoder-Section-1- UpConv'	Transposed Convolution	512 2x2x1024 transposed convolutions with stride [2 2] and output cropping [0 0]
29	'Decoder-Section-1- UpReLU'	ReLU	ReLU
30	'Decoder-Section-1- DepthConcatenation'	Depth concatenation	Depth concatenation of 2 inputs
31	'Decoder-Section-1- Conv-1'	Convolution	512 3x3x1024 convolutions with stride [1 1] and padding [1 1 1 1]
32	'Decoder-Section-1- ReLU-1'	ReLU	ReLU
33	'Decoder-Section-1- Conv-2'	Convolution	512 3x3x512 convolutions with stride [1 1] and padding [1 1 1 1]
34	'Decoder-Section-1- ReLU-2'	ReLU	ReLU
35	'Decoder-Section-2- UpConv'	Transposed Convolution	256 2x2x512 transposed convolutions with stride [2 2] and output cropping [0 0]
36	'Decoder-Section-2- UpReLU'	ReLU	ReLU
37	'Decoder-Section-2- DepthConcatenation'	Depth concatenation	Depth concatenation of 2 inputs
38	'Decoder-Section-2- Conv-1'	Convolution	256 3x3x512 convolutions with stride [1 1] and padding [1 1 1 1]
39	'Decoder-Section-2- ReLU-1'	ReLU	ReLU
40	'Decoder-Section-2- Conv-2'	Convolution	256 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
41	'Decoder-Section-2- ReLU-2'	ReLU	ReLU

42	'Decoder-Section-3-UpConv'	Transposed Convolution	128 2x2x256 transposed convolutions with stride [2 2] and output cropping [0 0]
43	'Decoder-Section-3-UpReLU'	ReLU	ReLU
44	'Decoder-Section-3-DepthConcatenation'	Depth concatenation	Depth concatenation of 2 inputs
45	'Decoder-Section-3-Conv-1'	Convolution	128 3x3x256 convolutions with stride [1 1] and padding [1 1 1 1]
46	'Decoder-Section-3-ReLU-1'	ReLU	ReLU
47	'Decoder-Section-3-Conv-2'	Convolution	128 3x3x128 convolutions with stride [1 1] and padding [1 1 1 1]
48	'Decoder-Section-3-ReLU-2'	ReLU	ReLU
49	'Decoder-Section-4-UpConv'	Transposed Convolution	64 2x2x128 transposed convolutions with stride [2 2] and output cropping [0 0]
50	'Decoder-Section-4-UpReLU'	ReLU	ReLU
51	'Decoder-Section-4-DepthConcatenation'	Depth concatenation	Depth concatenation of 2 inputs
52	'Decoder-Section-4-Conv-1'	Convolution	64 3x3x128 convolutions with stride [1 1] and padding [1 1 1 1]
53	'Decoder-Section-4-ReLU-1'	ReLU	ReLU
54	'Decoder-Section-4-Conv-2'	Convolution	64 3x3x64 convolutions with stride [1 1] and padding [1 1 1 1]
55	'Decoder-Section-4-ReLU-2'	ReLU	ReLU
56	'Final-ConvolutionLayer'	Convolution	7 1x1x64 convolutions with stride [1 1] and padding [0 0 0 0]
57	'Softmax-Layer'	Softmax	softmax
58	'Segmentation-Layer'	Pixel Classification Layer	Cross-entropy loss

ÖZGEÇMİŞ

1995 yılında Gaziantep'te doğdu. 2013 yılında Ayten Kemal Akınal Anadolu Lisesi'nden mezun oldu. Aynı yıl Erciyes Üniversitesi Harita Mühendisliği'ni kazandı. Lisans eğitimini 3.5 yılda bölüm üçüncüsü olarak Ocak 2017'de tamamladı. Aynı yıl KTÜ Harita Mühendisliği bölümünde yüksek lisans eğitimine başladı. 2018 yılında Macaristan Envirosense Kft. şirketinde 2.5 ay staj deneyimi olmuştur. 2018 Ekim ayından itibaren Harran Üniversitesi Mühendislik Fakültesi Harita Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaktadır. İngilizce bilmektedir.

