

T.C.
BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM
DALI



MEDİKAL GÖRÜNTÜLERİN ETKİLİ BİR ŞEKİLDE
SINIFLANDIRILMASI İÇİN DİKKAT TABANLI TEMSİL
ÖĞRENİMİ

YÜKSEK LİSANS TEZİ

SELİM ARSLAN

TEZ DANIŞMANI
Prof. Dr. KEMAL POLAT

BOLU, TEMMUZ - 2024

KABUL VE ONAY SAYFASI

SELİM ARSLAN tarafından hazırlanan “**Medikal Görüntülerin Etkili Bir Şekilde Sınıflandırılması İçin Dikkat Tabanlı Temsil Öğrenimi**” adlı tez çalışması jürimiz tarafından Elektrik Elektronik Mühendisliği Anabilim Dalı’nda Yüksek Lisans olarak oy birliği/ oy çokluğuyla kabul edilmiştir.
22/07/2024

Jüri Üyeleri

İmza

Danışman
Prof. Dr. Kemal POLAT
Bolu Abant İzzet Baysal Üniversitesi

.....

Üye
Doç. Dr. Uğurhan KUTBAY
Gazi Üniversitesi

.....

Üye
Dr. Öğr. Üyesi Ümit ŞENTÜRK
Bolu Abant İzzet Baysal Üniversitesi

.....

Lisansüstü Eğitim Enstitüsü Onayı

Prof. Dr. İbrahim KÜRTÜL

Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYAN

Bolu Abant İzzet Baysal Üniversitesi, Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu bildirir,

aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Teze ilişkin Turnitin adlı programında enstitü müdürlüğünce belirlenen filtrelemeler uygulanarak alınmış olan benzerlik raporuna göre, tezin benzerlik oranı %30'u geçmemektedir.

.....
SELİM ARSLAN

ÖZET

MEDİKAL GÖRÜNTÜLERİN ETKİLİ BİR ŞEKİLDE SINIFLANDIRILMASI İÇİN DİKKAT TABANLI TEMSİL ÖĞRENİMİ YÜKSEK LİSANS TEZİ

SELİM ARSLAN

BOLU ABANT İZZET BAYSAL ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

(TEZ DANIŞMANI: PROF. DR. KEMAL POLAT)

BOLU, TEMMUZ - 2024

XVI + 69

Cilt kanseri dünya genelinde görülen en yaygın ve ölüm oranı en yüksek kanser türlerinden birisidir. Ölüm oranını düşürmek için en önemli etmen erken teşhistir. Yapay zeka ve görüntü işleme çalışmaları ile erken teşhis için kanseri saptamak adına çalışmalar yapılmaktadır. Bu tez çalışmasında HAM10000 veri setini kullanarak etkili bir sınıflandırma için temsili derin öğrenme modelleri geliştirilmiştir. HAM10000 veri seti, çeşitli cilt lezyon türlerini içeren yüksek çözünürlüklü görüntülerden oluşmaktadır ve dermatolojik araştırmalarda yaygın olarak kullanılmaktadır.

Bu çalışmanın ana hedefi, farklı ağ yapıları geliştirip sınıflandırma performansına olan etkisini değerlendirmek ve en uygun sınıflandırma modelini belirlemektir. Bu modellerde aktivasyon fonksiyonu ReLU ve bırakma katmanı 0.3 olarak seçildi, özellik haritaları 16,32,64,128,256 denenerek öncelikle normalizasyon ve bırakma katmanları olmadan daha sonra normalizasyon ve bırakma katmanı eklenerek eğitildi ve en etkili tesil öğrenme ağı testpit edildi. Modelin en iyi doğruluk sonucunu normalizasyon ve bırakma işlemi uygulandıktan sonra 30 evre 2 evrişim katmanı ve 256 özellik haritasına sahip modelden %97.43 elde edilmiştir. En düşük kayıp değeri 0.0764 yine aynı modelden elde edilmiştir.

ANAHTAR KELİMELE: Derin öğrenme, Medikal görüntü, Temsil öğrenme, HAM10000

ABSTRACT

ATTENTION-BASED REPRESENTATION LEARNING FOR EFFECTIVE CLASSIFICATION OF MEDICAL IMAGES

MSC THESIS

SELIM ARSLAN

BOLU ABANT IZZET BAYSAL UNIVERSITY

INSTITUTE OF GRADUATE STUDIES

DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING

(SUPERVISOR: PROF. DR. KEMAL POLAT)

BOLU, JULY 2024

XVI + 69

Skin cancer is one of the most common cancers worldwide and has one of the highest mortality rates. The most important factor to reduce mortality is early diagnosis. Artificial intelligence and image processing studies are being conducted to detect cancer for early detection. In this thesis, representative deep learning models are developed for effective classification using the HAM10000 dataset. The HAM10000 dataset consists of high-resolution images of various types of skin lesions and is widely used in dermatological research.

The main objective of this study is to develop different network structures, evaluate their effect on classification performance and determine the most appropriate classification model. In these models, the activation function was chosen as ReLU and the dropout layer was chosen as 0.3, feature maps 16,32,64,128,256 were trained first without normalization and dropout layers and then with the addition of normalization and dropout layers and the most effective random learning network was tested. The best accuracy result of the model was 97.43% for the model with 30 stage 2 convolution layers and 256 feature maps after normalization and dropout. The lowest loss value of 0.0764 was obtained from the same model.

KEYWORDS: Deep learning, Medical image, Representation learning, HAM10000

İÇİNDEKİLER

Sayfa

KABUL VE ONAY SAYFASI	iii
ETİK BEYAN.....	iv
ÖZET.....	v
ABSTRACT	vi
İÇİNDEKİLER	vii
ŞEKİL LİSTESİ.....	ix
TABLO LİSTESİ	xiv
KISALTMA VE SEMBOLLER LİSTESİ	xv
TEŞEKKÜR	xvi
1. GİRİŞ.....	1
2. GENEL BİLGİLER	3
2.1 Çalışmanın Amacı	3
2.2 Literatür Taraması	4
2.3 Cilt Kanseri Nedir?	8
2.4 Görüntü İşleme Nedir?	9
2.5 Yapay Zeka	9
2.5.1 Makine Öğrenmesi	10
2.5.2 Derin Öğrenme	11
3. MATERYAL VE YÖNTEM	12
3.1 Yapay Sinir Ağları	12
3.2 Evrimsel Sinir Ağları	12
3.2.1 Giriş Katmanı	13
3.2.2 Evrişim katmanı.....	14
3.2.3 Havuzlama Katmanı	15
3.2.4 Düzleştirme Katmanı	17
3.2.5 Tam Bağlantı Katmanı.....	18
3.2.6 Bırakma Katmanı.....	18
3.2.7 Veri Arttırma	19
3.2.8 Aktivasyon Fonksiyonları	19
3.2.8.1 ReLU Fonksiyonu	20
3.2.8.2 Sigmoid Fonksiyonu	21
3.2.8.3 Hiperbloik Tanjant Fonksiyonu	21
3.2.8.4 Basamak Fonksiyonu	22
3.2.8.5 Doğrusal (Lineer) Fonksiyonu	22
3.2.8.6 Softmax Fonksiyonu	22
3.2.8.7 Sızıntı (Leaky) ReLU Fonksiyonu	23
3.2.8.8 ELU Fonksiyonu	23

3.2.9 Optimizasyon Algoritmaları	24
3.2.10 Öğrenme Oranı	25
3.2.11 Kayıp fonksiyonları	26
3.2.12 Kod Derleme ve çalışma ortamı 26	
3.3 Kullanılan Derin Öğrenme Modelleri.....	12
3.3.1 Normalizasyon ve bırakma katmanı olmayan temsil modeli	24
3.3.2 Normalizasyon ve bırakma katmanı eklenen temsil modeli.....	24
4. BULGULAR	29
5. SONUÇ VE ÖNERİLER	65
5.1 Sonuç	65
5.2 Öneriler.....	65
6. KAYNAKLAR.....	67

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1. Deri üzerinde bulunan kanser türleri(18).....	8
Şekil 2.2. Yapay zeka, makine öğrenmesi ve derin öğrenmenin bir biri ile olan ilişkisi	10
Şekil 3.1. Temel yapay sinir ağı modeli(20).....	12
Şekil 3.2. Evrişimsel sinir ağı genel yapısı(21)	13
Şekil 3.3. Tek kanal ve üç kanal giriş görüntüsü örneği(22)	13
Şekil 3.4. Tek kanallı bir görüntüde evrişim işlemi.....	14
Şekil 3.5. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile maksimum havuzlama sonucu.....	16
Şekil 3.6. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile ortalama havuzlama sonucu	16
Şekil 3.7. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile küçük kareler havuzlama sonucu.....	17
Şekil 3.8. 5x5 boyutundaki matrisin düzleştirme katmanından sonra 20x1 boyutundaki vektör çıktısı.....	17
Şekil 3.9. Tam bağlantı katmanı genel yapısı(23)	18
Şekil 3.10. Normal ESA modeli ve seyreltme işleminden sonra oluşan ESA modeli(24)	19
Tablo 3.1. Aktivasyon fonksiyonlarının matematiksel gösterimi	20
Şekil 3.11. ReLU aktivasyon fonksiyonu grafik gösterimi	20
Şekil 3.12. Sigmoid aktivasyon fonksiyonu grafik gösterimi.....	21
Şekil 3.13. Tanh aktivasyon fonksiyonu grafik gösterimi	21
Şekil 3.14. Softmax aktivasyon fonksiyonu grafik gösterimi.....	22
Şekil 3.15. Şekil (1,1) Basamak, Şekil (1,2) Doğrusal, Şekil (2,1) Sızıntı ReLU, Şekil (2,2) ELU aktivasyon fonksiyonlarının grafik gösterimi.....	23
Şekil 3.16. Gradyan azalma algoritmalarının şekil üzerinde gösterimi (26)	25
Şekil 3.17. Normalizasyon ve bırakma katmanı olmayan temsil öğrenme algoritması akış diyagramı	27
Şekil 3.18. Normalizasyon ve bırakma katmanı eklenen temsil öğrenme algoritması akış diyagramı	28
Şekil 4.1. HAM10000 Veri setinde bulunan 7 farklı kanser grubunun görselleri	29
Şekil 4.2. Tez çalışmasında kullanılan cilt kanseri görüntülerinin %80 eğitim ve %20 test adet dağılım grafiği	30
Şekil 4.3. Tez çalışmasında kullanılan cilt kanseri görüntülerinin %50 eğitim ve %50 test adet dağılım grafiği	30
Şekil 4.4. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok, %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	31
Şekil 4.5. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok, %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	31
Şekil 4.6. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği	31

Şekil 4.7. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği	32
Şekil 4.8. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	32
Şekil 4.9. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	33
Şekil 4.10. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği	33
Şekil 4.11. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği	33
Şekil 4.12. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	34
Şekil 4.13. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	34
Şekil 4.14. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği	35
Şekil 4.15. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği	35
Şekil 4.16. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	36
Şekil 4.17. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	36
Şekil 4.18. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği	36
Şekil 4.19. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği	37
Şekil 4.20. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	37
Şekil 4.21. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	38
Şekil 4.22. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği	38

Şekil 4.23.	20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği	38
Şekil 4.24.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	39
Şekil 4.25.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	39
Şekil 4.26.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği	40
Şekil 4.27.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği	40
Şekil 4.28.	30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	41
Şekil 4.29.	30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	41
Şekil 4.30.	30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği	41
Şekil 4.31.	30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği	42
Şekil 4.32.	30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	42
Şekil 4.33.	30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	43
Şekil 4.34.	30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği	43
Şekil 4.35.	30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği	43
Şekil 4.36.	30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	44
Şekil 4.37.	30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	44
Şekil 4.38.	30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği	45
Şekil 4.39.	30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği	45
Şekil 4.40.	10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	46
Şekil 4.41.	10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	46

Şekil 4.42.	10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği	46
Şekil 4.43.	10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği	47
Şekil 4.44.	10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	47
Şekil 4.45.	10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	48
Şekil 4.46.	10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği	48
Şekil 4.47.	10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği	48
Şekil 4.48.	10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	49
Şekil 4.49.	10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	49
Şekil 4.50.	10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği	50
Şekil 4.51.	10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği	50
Şekil 4.52.	20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	51
Şekil 4.53.	20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	51
Şekil 4.54.	20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği	51
Şekil 4.55.	20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği	52
Şekil 4.56.	20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	52
Şekil 4.57.	20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	53
Şekil 4.58.	20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği	53
Şekil 4.59.	20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği	53
Şekil 4.60.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği	54
Şekil 4.61.	20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği	54

- Şekil 4.62.** 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği 55
- Şekil 4.63.** 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği 55
- Şekil 4.64.** 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği 56
- Şekil 4.65.** 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği 56
- Şekil 4.66.** 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği 56
- Şekil 4.67.** 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği 57
- Şekil 4.68.** 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği 57
- Şekil 4.69.** 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği 58
- Şekil 4.70.** 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği 58
- Şekil 4.71.** 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği 58
- Şekil 4.72.** 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği 59
- Şekil 4.73.** 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği 59
- Şekil 4.74.** 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği 60
- Şekil 4.75.** 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği 60

TABLO LİSTESİ

Sayfa

Tablo 3.1. Aktivasyon fonksiyonlarının matematiksel gösterimi	20
Tablo 4.1. Normalizasyon ve bırakma katmanı yok, %80 eğitim %20 test en iyi sonuç veren 3 model.....	61
Tablo 4.2. Normalizasyon ve bırakma katmanı var, %80 eğitim %20 test en iyi sonuç veren 3 model.....	62
Tablo 4.3. Normalizasyon ve bırakma katmanı yok, %50 eğitim %50 test en iyi sonuç veren 3 model.....	63
Tablo 4.4. Normalizasyon ve bırakma katmanı var, %50 eğitim %50 test en iyi sonuç veren 3 model.....	64

KISALTMA VE SEMBOLLER LİSTESİ

AKIEC	: Aktinik Keratoz (Actinic Keratoses)
IA	: Yapay Zeka (Artificial Intelligence)
ANN	: Yapay Sinir Ağı (Artificial Neural Network)
BCC	: Bazal Hücreli Karsinom (Basal Cell Carcinoma)
BKL	: Benign Keratoz Benzeri Lezyon (Benign Keratosis-Like Lezyon)
CNN	: Evrişimsel Sinir Ağı (Convolutional Neural Network)
CNN-PSO	: Evrişimsel Sinir Ağı-Parçacık Sürü Optimizasyonu (Convolutional Neural Network- Particle Swarm Optimization)
DF	: Dermatofibrom (Dermatofibroma)
ISIC	: Uluslar Arası Cilt Görüntüleme İşbirliği (International Skin Imaging Collaboration)
MEL	: Melanom (Melanoma)
NV	: Melanositik Nevüs (Melanocytic Nevi)
SCC	: Skuamöz Hücreli Kanser (Squamous Cell Carcinoma)
UV	: Ultraviyole (Ultraviolet)
VASC	: Vascular Lezyon (Vascular Lesion)
WCRFI	: Uluslararası Dünya Kanser Araştırma Fonu (World Cancer Research Fund International)

TEŞEKKÜR

Tez sürecimde ve yüksek lisans eğitimim boyunca yardımlarını esirgemeyen, her konuda destek olan başta değerli danışmanım Prof. Dr. Kemal POLAT’a sonra, iyi günde kötü günde her zaman yanımda olan sevgili aileme teşekkür ederim.



1. GİRİŞ

Cilt (deri) kanseri, genel olarak cildin güneşe yoğun maruz kalması sonucu ultraviyole (UV) ışınların cildin doğrudan DNA hasarından kaynaklanan anormal, kontrolsüz ve düzen dışı büyümesidir(1). Yaşanan bu durum sonrası oluşan büyüme cilt hücrelerinin hızla çoğalmasına ve kötü huylu tümörler oluşturmalarına sebebiyet verir(2). Cilt kanseri dünya genelinde görülen en yaygın kanser türlerinden birisidir(3). Son yıllarda yeni vaka oranları daha da artmaktadır(4). Cilt kanseri temel olarak üç ana türde incelenir. Bunlar, melanom, bazal hücreli kanser (BCC) ve skuamöz hücreli kanser (SCC). Bazal hücreli kanser ve skuamöz hücreli kanserler genellikle daha az ölümcül olup, tedaviye daha iyi yanıt verirler. Melanom cilt kanserleri en ölümcül olanıdır ve erken teşhis edilmediğinde ciddi sonuçlara yol açabilir(5).

Melanom en ölümcül tür olduğu için dünya genelinde kanser kayıtlarında melanom ve melanom dışı kanser diye kayıt altına alınır(6). Uluslararası Dünya Kanser Araştırma Fonu(WCRFI) 2020 verilerine göre dünya genelinde 324,635 melanom ve 1,198.073 kişide melanom dışı kanser vakası kayıt altına alınmıştır. Bu vakalardan 57,043 melanom ve 63,731 kişi melanom dışı cilt kanserlerinden vefat etmiştir(7).

Vefat oranını düşürmek için en önemli etmen erken teşhistir. Cilt kanseri teşhisinde doktorlar öncelikle kanserli bölgeyi çıplak göz ile incelerler. Bu bilgiler doğrultusunda teşhisler konulur. Fakat uzman kişiler arasında bile çoğu kez yanlış teşhis konulabilmektedir(8). Hem yanlış teşhis riskini azaltmak hemde uzman kişilere hızlı bir şekilde teşhis koyabilecek otomatik analiz içeren yapay zeka ve görüntü işleme çalışmaları yapılmaktadır(9). Güncel araştırmalara göre uzman kişiler tarafından cilt kanserinin teşhis edilme oranının %75-%81,5 arasında olduğu görülmektedir. Ancak, yapay zeka yardımıyla teşhis konulan durumlarda bu oranlar önemli ölçüde artmaktadır. Yapay zeka kullanımı ile doktorların teşhis doğruluğu %86,1'e kadar çıkmaktadır (10).

Yapay zekanın kullanım alanı gün geçtikçe daha da çok artmaktadır. En çok kullanım alanlarından biriside sağlık sektörüdür(11). Makine öğrenmesi ve derin öğrenme yapay zekanın alt dallarıdır. Her ikiside veriyi analiz etme ve model oluşturma süreçlerinde kullanılır(12). Makine öğrenimi, bir yapı işlevi olarak verilere dayalı tahminler yapabilen algoritmalar oluşturma sistemidir. Veriye dayalı

tahminler ve kararlar almak için örnek girdilerden modeller oluşturarak çalışır(13). Derin öğrenme makine öğrenmesinin bir alt dalıdır. Makine öğrenmesinde büyük verilerin analizinde zorlanılmasından kaynaklı derin öğrenme algoritmaları geliştirilmiştir. Derin öğrenme de özellik çıkarma ve dönüştürme için birçok doğrusal olmayan işlem birimi katmanlarını kullanılır. Her ardışık katman, önceki katmandaki çıktıyı girdi olarak alır(14). Bir veya birden fazla gizli katmanı sayesinde özellik çıkarımı ve öğrenme işlemi yapılır. Büyük verilerde, görün ve resim gibi verilerin bulunduğu veri setlerinde çoğunlukla kullanılır(15). Görüntü analizi işlemlerinde günümüze kadar en çok başarı gösteren derin öğrenme mimarileri, evrimsel sinir ağlarıdır(16).

Bu çalışma kapsamında Kaggle çalışma platformundan alınan veri seti ile derin öğrenme çalışması yapılmıştır(17). Hastalardan alınan cilt kanseri veri seti ile birlikte derin öğrenme ve görüntü işleme teknolojileri ile eğitilerek ağlar oluşturulmuştur. Bu ağlar analiz edilerek en etkili sonucu veren ağ tespit edilmeye çalışılmıştır. Ayrıca bu ağlar sayesinde cilt kanseri hangi türe ait olduğunu saptamak adına çalışılmıştır.

2. GENEL BİLGİLER

2.1 Çalışmanın Amacı

Yapay zeka çalışmalarında, makine öğrenmesi çalışmalarında ve derin öğrenme çalışmalarında en önemli konuların başında sınıflandırma doğruluğu, kayıp değerleri ve süre gelmektedir. Çalışmalarda her zaman beklenti doğruluk değeri en yüksek olması kayıp değeri en düşük olması ve en kısa sürede hesaplanmasıdır(18). Bu sonucu elde edebilmek için model üzerinde uygun normalizasyon tekniklerini ve değişkenleri deneyerek sonuçları incelenerek ve en iyi sonuç veren model bulunmalıdır. HAM10000 veri setini kullanarak deri lezyonlarını otomatik olarak sınıflandırabilmek ve bu süreci en iyi değerlere sahip bir model geliştirmek için bir çok çalışma yapılmıştır.

Bu tez çalışmasında Kaggle'den alınan medikal görüntüler için HAM10000 veri seti kullanılmıştır. Bu veri setinde 6705 adet Melanocytic nevi(nv), 1113 adet Melanoma(mel), 1099 adet Benign keratosis-like lezyon(bkl), 514 adet Basal cell carcinoma(bcc), 327 adet Actinic keratoses(akiec), 142 adet Vascular lezyon(vasc) ve 115 adet Dermatofibroma(df) kanser görselleri bulunmaktadır. Bu görseller %80 eğitim verisi ve %20 test verisi olabilmesi için rasgele seçilerek veri seti oluşturuldu. Tüm görüntüler 32x32x3 boyutuna sahip olabilmesi için tekrar boyutlandırma işlemi yapıldı. Model ilk önce normalizasyon ve bırakma katmanı olmadan eğitildi. Bu eğitim süresince evre(epoch) sayısı ve evrişim katmanı sayısı değiştirildi ve model her bir evre ve evrişim katmanından elde edilen sonuçlara göre en iyi değere sahip 3 modeli bizlere gösterdi. Daha sonra modele normalizasyon işlemleri ve bırakma katmanı eklerək tekrar eğitim ve test işlemleri uygulandı. Modellerden elde edilen bu değerlere göre en iyi sonucu veren 3 modeli bizlere gösterdi. Normalizasyon ve bırakma katmanı işlemi olmayan model ile normalizasyon ve bırakma katmanı eklendikten sonra elde edilen doğruluk, kayıp ve süre değerlerini kontrol edip en iyi değere sahip modelleri bize gösteren bir algoritma geliştirilerek en iyi sonucu sağlayan modeller elde edilmiştir.

2.2 Literatür Taraması

Y. Doğan ve ark. Çalışmasında, HAM10000 veri setini kullanarak yedi farklı cilt lezyon tipini (Melanocytic Nevi, Melanoma, Benign Keratosis, Basal Cell Carcinoma, Actinic Keratoses, Vascular Lesions, Dermatofibroma) kullanarak tahmin etme ve sınıflandırma çalışması yapmıştır. Veri setindeki görüntüleri rastgele olacak şekilde %80 eğitim (8912) ve %20 test seti (1103) olarak iki kısma ayırmıştır. Giriş görüntü boyutu 224x224x3 olacak şekilde ResNet50, MLP-Mixer ve Vision Transformer modellerinde eğitilmiştir. Eğitim detayları olarak öğrenme aktarma uygulanmamıştır. Her bir derin öğrenme modeli 20 evre(epoch) boyunca eğitilmiş ve optimizasyon algoritması olarak adam kullanılmıştır. Veri arttırma tekniği kullanılmamıştır. ResNet50 modelinde eğitim doğruluğu %89.21 test doğruluğu %86.22, MLP-Mixer modelinde Eğitim doğruluğu %87.45 test doğruluğu %84.96 ve Vision Transformer modelinde eğitim doğruluğu %86.92 test doğruluğu %83.87 olarak sonuçlanmıştır. ResNet50 modelinin diğer derin öğrenme modellerine göre daha iyi performans sağladığı gözlenmiştir(19).

A. Karlı ve ark. Çalışmasında, HAM10000 veri seti ile EfficientNet-B3 mimarisinde hiperparametre seçiminin sınıflandırma performansına etkisini incelemiştir. Veri setinde yedi farklı sınıftan oluşan görüntüler dengesiz adetlere sahip oldukları için homojen bir dağılım olması adına her bir kanser grubu için 300 adet görüntü olacak şekilde görüntü arttırma ve azaltma işlemi uygulanmış ve toplamda 2100 görüntü ile çalışılmıştır. Öğrenme oranı 0,001 , evre(epoch) 10 ve batch size 30 olarak alınmıştır. 11 dakika 58,36 saniye süren eğitimin sonucunda %75,85 doğruluk performansı görülmüştür. Daha sonra görüntü sayısını her bir kanser grubu için 700 görüntü olacak şekilde ayarlayarak öğrenme oranlarını 0,002 , 0,0022 , 0,0025 yaparak eğitmiş ve en iyi sonuç olarak %81,04 olarak görmüştür. Son olarak her bir kanser grubu için görüntü sayısını 600 olarak ayarlayıp öğrenme oranını 0,002 evre(epoch) olarak 15 seçmiştir ve en yüksek doğruluk değerini %82,34 olarak elde etmiştir(20).

Ö. Özcan ve ark. Çalışmasında, HAM10000 veri setinde dengesiz adetlere sahip olan kanser gruplarının görüntülerini dengeli olacak şekilde veri arttırma teknikleri olan rastgele silme, görüntü arttırma, kırpma ve renk uzayı dönüşümleri metotlarını uygulayarak ResNet50, DenseNet201 ve MobileNet modellerinde eğitmiştir. Elde edilen sınıflandırma sonuçlarına göre doğruluk oranı en yüksek

ResNet50 %96,7 olarak gözlenmiştir. DenseNet201 %96,5 ve MobileNet %97,4 olarak gözlenmiştir(21).

E. Özbay ve ark. Çalışmasında, ISIC-2019 ve Asian-dermoscopy veri setlerini kullanarak, eğitim performansını arttırmak adına kanser görüntülerine maskeleye uygulamışlardır. Daha sonra tüm görüntüleri 20x28 boyutunda olacak şekilde tekrar boyutlandırmışlardır. Veri setinde bulunan örnek görüntülerin yeterli sayıda olmadığını ve dengesiz dağılımdan dolayı modelin performansının düştüğünü gözlemlemişlerdir. Model performansını arttırmak adına görüntü dönüştürme teknikleri uygulamışlardır. Bu görüntüler için 0-360° (90°, 180°, 270° vb.) arasında rastgele döndürmelerle ya da istenen sayıda örnek oluşturulana kadar rastgele dikey ve yatay çevirmelerle gerçekleştirmişlerdir. Döndürülmüş veya çevrilmiş görüntüler sırasıyla 0,5 ve 1,5'e ölçeklendirilmiştir. Toplam veri setinde %60 eğitim %40 test ve 0,001 öğrenme oranı ile eğitim yapılmıştır. Sınıflandırma olarak Evrişimsel Sinir Ağı-Parçacık Sürü Optimizasyonu CNN-PSO modeli kullanılmış ve ortalama %98,63 doğruluk elde etmişlerdir(22).

A. Fatima çalışmasında, HAM10000 veri seti ile öncelikle performansı arttırmak için görüntülerin boyutunu azaltma işlemini yapmıştır. Oluşan bu yeni görselleri sırasıyla Yapay Sinir Ağı (ANN) , Evrişimsel Sinir Ağı (CNN) ve Görsel Geometri Grubu (VGG-16) modelleri ile eğitmiştir. Her bir model için eğitim sırasında 10 evre(epoch) kullanmıştır. ANN modelinde %70,5 , CNN modelinde %71,5 ve VGG-16 modelinde %75,6 doğruluk elde etmiştir. Bu üç model arasında en yüksek doğruluk VGG-16 da olduğu gözlemlenmiştir(23).

U. Khasanah ve ark. çalışmasında, Genişlemiş Evrişimli Yapay Sinir Ağı (DCNN) modeli ve HAM10000 veri setini kullanarak öncelikle görselleri 224x224 olacak şekilde tekrar boyutlandırmışlardır. Kullanılan mimari 8 katmandan oluşmaktadır. 1 giriş katmanı, 2 genişletilmiş evrişim katmanı, 1 ortalama havuzlama katmanı, 3 ReLu katmanı ve bir bırakma katmanı. Eğitim parametreleri olarak evre(epoch) 100, minibatch size 8 , öğrenme oranı 0.1 ve bırakma oranı 0.5 olarak seçilmiş. Genişleme faktörü ve katlama metodu değiştirilerek eğitimler gerçekleştirilmiş. En iyi sonucu genişleme faktörü 2 seçildiğinde elde etmişler. Doğruluk olarak %85,67 gözlemlenmiştir. Aynı modeli evrişimli sinir ağı ve VGG-19 modellerinde de test etmişlerdir. Evrişimli sinir ağıları modelinde %83,04 ve VGG-19 modelinde %65,33 doğruluk elde etmişlerdir(24).

A. Milton çalışmasında, Uluslar arası deri görüntüleri işbirliği (International Skin Imaging Collaboration-ISIC) 2018 meydan okuma veri setini kullanarak PNASNet-5-Large, InceptionResNetV2, SENet154, InceptionV4 ve Ensemble modellerini kullanarak derin sinir ağları ile cilt kanseri sınıflandırma çalışması yapmıştır. Her bir model için ilk 2 epokda öğrenme oranı 0.0001 ve daha sonraki epoklarda öğrenme oranını 0.01 olarak ayarlamış. Toplamda 50 evre(epoch) süren eğitim çalışmasında her bir epoktan sonra doğrulama oranları kontrol edilip erken durdurma için kontrol mekanizmaları konumlandırmış. Optimizasyon için adam, sınıflandırma için softmax kullanmıştır. Hatayı geriye doğru yayarak ağırlıkları güncellemek için çapraz entropi kaybı yöntemini kullanmıştır. Tüm adımlardan sonra sırasıyla PNASNet-5-Large %76, InceptionResNetV2 %70, SENet154 %74, InceptionV4 %67, Ensemble %73 modellerinden doğrulama sonuçlarını elde etmiştir. Büyük farklılık gösteren dengesiz veri seti nedeniyle düşük doğruluk oran sonuçlarına ulaşmıştır. En iyi doğruluk oranı PNASNet-5-Large modelinden %76 olarak gözlemlenmiştir(25).

Ingle Y. ve ark. çalışmasında, HAM10000 veri seti ile CNN ve VGG-16 modellerini kullanarak cilt kanseri sınıflandırması çalışması yapmıştır. Bu çalışmada kanser görüntülerinin tamamını aynı piksel değerine getirmek için bütün görselleri 71x71 piksel olacak şekilde tekrar boyutlandırmışlardır. Eğitim sonucu olarak, CNN modelinde %66 ve VGG-16 modelinde %88,83 doğruluk değeri elde edilmiştir(26).

E. Kırğıl ve ark. çalışmasında, ISIC 2019 veri setinde bulunan 8 farklı sınıf ile toplam 25331 dermoskopik görüntüden yararlanarak Xception, DenseNet ve EfficientNet derin öğrenme modelleri ile çalışma gerçekleştirmişlerdir. Veri kümesinde melanom (MEL) hastalığına ait 4522 görüntü, melanositik nevüs (MN) hastalığına ait 12875 görüntü, aktinik keratoz (AK) hastalığına ait 867 görüntü, dermatofibrom (DF) hastalığına ait 239 görüntü, vasküler lezyon (VL) hastalığına ait 253 görüntü, skuamöz hücreli karsinom (SHK) hastalığına ait 628 görüntü, bazal hücreli karsinom (BHK) hastalığına ait 3323 görüntü ve iyi huylu keratoz (İHK) hastalığına ait 2624 görüntü bulunmaktadır. Eğitim görüntülerini 224x224 olacak şekilde tekrardan boyutlandırmışlardır. Çalışma sonucunda 8 sınıfın sırasıyla Xception modelinde doğruluk %80,4, DenseNet modelinde doğruluk %78,4 ve EfficientNet modelinde doğruluk %83,5 olarak gözlemlenmiştir(27).


B. Gungor ve ark. çalışmasında, ISIC 2018 veri setini kullanarak görüntüleri farklı ön işlemlere tabi tutup, kullanılan mimari performansına etkisini incelemiştir. ResNet50 mimarisi için iki farklı görüntü ön işleme yöntemi uygulanmıştır. Bunlardan ilki sırasıyla ikili ve ostu eşitleme, CLAHE dönüşümü uygulanırken, ikincisinde morfolojik filtreleme, renk normalizasyonu ve dolgu işlemleri uygulanmıştır. Çalışmada kullanılan iyi huylu 1216 ve kötü huylu 1627 görsel 224x224 piksel olacak şekilde %80 eğitim %20 test verisi olmak üzere tekrar boyutlandırılmıştır. Veri setinde bulunan görsellerin adetini yükseltmek için kırpma, yakınlaştırma, çevirme ve parlaklık değişikliği gibi yöntemler ile veri setinde bulunan görsel adetleri iki katına çıkarılmıştır. Sınıflandırmak için softmax, öğrenme oranı için 0.0001, optimizasyon için adam, parça boyutu için 32, unutma için %50 ve 10 evre(epoch) olacak şekilde ağ ayarlanmıştır. Ön işleme kullanılmadan %80,4 sonucuna, birinci ön işleme kullanıldıktan sonra %82,4 ve ikinci ön işleme kullanıldıktan sonra %81,9 doğruluk sonucunu elde etmişlerdir(28).

E. Ergün ve ark. çalışmasında, HAM10000 veri setini kullanarak veri artırma yöntemi ile AlexNet, DenseNet-121, ResNet-18, ResNet-34, SqueezeNet ve VGGNet-16 mimarilerinin sonuçlarını analiz etmişlerdir. Veri setini artırmak için görüntülere yatay ve dikey çevirmeler, maksimum 355 dereceye kadar açı değiştirme, maksimum 1,5 değerinde yakınlaştırma, maksimum 0,3 değerinde rastgele kontrast ve parlaklık artırma gibi teknikler uyarlanmıştır. Bu tekniklerin bir diğer amacında performansı artırmaktır. Veri artırmadan önceki eğitim verisi, kötü huylu 1176 adet ve iyi huylu 4739 adettir. Veri artırma işleminden sonra kötü huylu 11495 ve iyi huylu 14178 adet olmuştur. Çalışmada doğrulama için ise kötü huylu 778, iyi huylu 1981 görüntü kullanılmıştır. Giriş görüntüleri yeniden boyutlandırılmış ve 224x224x3 piksel olacak şekilde yeniden boyutlandırılmış. Aktivasyon fonksiyonu ReLU optimizasyon algoritması adam seçilmiştir. Küme boyutu 64 ve 20 evre(epoch) sayısı belirlenmiştir. 20 evre sonunda veri artırma yöntemi kullanılmadan elde edilen doğruluk sonucu sırasıyla AlexNet %64,38, DenseNet-121 %77,58, ResNet-18 %77,09, ResNet-34 %85,14, SqueezeNet %56,9 ve VGGNet-16 %81,49'dur. Veri artırma yönteminden sonra sonuçlar sırasıyla AlexNet %83,03, DenseNet-121 %85,93, ResNet-18 %86,61, ResNet-34 %87,51, SqueezeNet %76,87 ve VGGNet-16 %86,95'dur. En iyisi sonucu ResNet-34 %87,51 doğruluk oranı ile vermiştir(29).

2.3 Cilt Kanseri Nedir?

Melanom olarak da adlandırılan cilt (deri) kanseri; genel olarak cildin güneşe yoğun maruz kalması sonucu cildin en dış tabakası olan epidermisteki anormal hücrelerin, onarılmamış DNA hasarından kaynaklanan anormal, kontrolsüz ve düzen dışı büyümesidir. Yaşanan bu durum sonrası oluşan büyüme cilt hücrelerinin hızla çoğalmasına ve kötü huylu tümörler oluşturmalarına sebebiyet verir(30).

Yaygın görülen kanser çeşidi olan cilt kanseri, Bazal Hücreli Kanser (BCC), Skuamöz Hücreli Kanser (SCC) ve Melanom olmak üzere üç farklı türe sahiptir. Yaygın belirtisi cilt üzerinde gözle görülür ben değişimleri, yaralar, kanamalar ve derideki soyulmalar olan cilt kanseri, ciltteki şüpheli değişimlerin kontrol edilmesi sonrası cilt kanserinin en erken aşamalarında tespit edilmesine yardımcı olabilir. Cilt kanserinin erken teşhisi, başarılı cilt kanseri tedavisi için size oldukça fayda sağlar(30).



Şekil 2.1. Deri üzerinde bulunan kanser türleri(18)

Bazal Hücreli Kanser: Cildin en üst katmanında bulunan bazal hücrelerde görülen kanser türüdür. Cilt kanserleri arasında en yaygın olan türdür. Çoğunlukla cildin güneş etkisine maruz kalan bölgelerinde oluşur. Bu kanser türü için risk grubunda bulunanlar, açık ten rengine sahip olanlardır. Hastalık ilerleyen yaşlarda, cilt üzerindeki yaralar, kabarıklıklar ve kırmızı lekeler şeklinde kendini gösterebilir(31).

Skumöz Hücreli Kanser: Skumöz hücreli kanser, bazal hücreli kansere benzer özellikler gösterir. Farkları Skumöz hücreli kanserin cildin orta ve dış katmanlarını oluşturan skumöz hücrelerinde gelişmesidir. Çoğunlukla UV ışınlarına maruz kalan yüz, saç derisi, boyun ve ellerde görülür. Ancak güneşe maruz kalmayan vücut bölgelerinde de ortaya çıkabilir. Belirtileri ve risk grubu bazal hücreli kansere benzerdir. Skumöz hücreli kanserin yayılma ihtimali olduğundan erken tanı ve tedavisi önemlidir(31).

Melanom: Melanom cilt kanserlerinin en tehlikelisi ve en nadir görülen türüdür. Cilde rengini veren melanosit hücrelerinin kontrolsüzce çoğalması sonucu görülür. Genetik yatkınlık, UV ışınlarına maruz kalmak hastalığın nedenlerindendir. Tedavi edilmediğinde tüm vücuda yayılım gösterebilir. Vücudun herhangi bir yerinde siyah, kahverengi, mavi, mor lekeler şeklinde görülebilir(31).

2.4 Görüntü İşleme Nedir?

Görüntü işleme en temel anlamı ile dijital bir görüntünün bilgisayar algoritmaları ve matematiksel işlemler ile görüntünün içindeki bilgiyi çıkartarak onu daha anlamlı bir hale getirmektir. Bu işlem sırasında piksel renkleri, parlaklık, görüntü boyutu, görüntü şekli gibi bir çok bilgi elde edilebilecek değişkenler sayesinde matematiksel işlemlere tabi tutularak elde edilen veriler analiz edilir. Elde edilen bu veriler sayesinde görüntü işleme metotları ile nesne tanımlama, görüntüden özellik tanıma gibi bir çok çalışma yapılmaktadır.

Yaygın olarak görüntü işleme yöntemleri ile nesne algılama, nesne takibi, yüz algılama, görüntü iyileştirme, görüntü bölütleme gibi bir çok farklı türde işlem yapılabilir. Görüntü işlemenin en yaygın kullanıldığı alanlar tıp, otomatik, askeri, robotik, güvenlik, endüstri, trafik, eğlence ve daha bir çok alan örnek olarak gösterilebilir.

2.5 Yapay Zeka

Yapay zeka tıpkı insanların deneyimler ile öğrendiği gibi geliştirilen yazılımsal programların da eğitilerek insansı yeteneklere sahip olma teknolojisidir. Tıpkı insanların bir konuda öğrenmesi yada uzmanlaşması için çok fazla bilgiye ihtiyaç duyduğu gibi, yapay zeka teknolojisinde çok fazla bilgiye ihtiyacı vardır. Yapay zeka, genellikle karmaşık algoritmalar ve büyük miktarda veri kullanılarak geliştirilen bir dizi teknik ve yöntemi içerir. Bu teknikler arasında makine öğrenimi, derin öğrenme, doğal dil işleme ve genetik algoritmalar gibi birçok yaklaşım bulunur.

Yapay zeka günümüzde çok fazla alanda kullanılmaktadır. Bunlara başlıca askeri, sağlık, endüstri, otomasyon, güvenlik, finans ve daha bir çok alanda kullanılmaktadır.



Şekil 2.2. Yapay zeka, makine öğrenmesi ve derin öğrenmenin bir biri ile olan ilişkisi

2.5.1 Makine Öğrenmesi

Makine öğrenimi yapay zekanın bir alt dalıdır. Makine öğrenmesinde önce bilginin bulunduğu veriler verilir ve öğrenme işlemi yapılır. Bu öğrenme işlemi tamamlandıktan sonra makine öğrenmesi algoritması verilerden bilgileri çıkarır ve öğrenme işlemini tamamlar. Makine öğrenmesi üç temel kategoride sınıflandırılabilir.

Denetimli Öğrenme: Denetimli öğrenmede, bir model, girdi verileri ve bu verilere karşılık gelen çıktıları içeren etiketli bir veri kümesi kullanılarak eğitilir. Model, girdi verilerinden çıktıları tahmin etmek için bu veri setindeki algoritmayı öğrenir. Örnek olarak sınıflandırma ve regresyon problemleri verilebilir.

Denetimsiz Öğrenme: Denetimsiz öğrenmede, bir model, etiketlenmemiş veri kümesi üzerindeki algoritmayı veya yapıları bulmak için eğitilir. Bu tür öğrenme, veri setinde gizli kalıpları veya kümeleri bulmak için kullanılır. Örnek olarak kümeleme ve boyut indirgeme verilebilir.

Pekiştirmeli Öğrenme: Pekiştirmeli öğrenmede, bir model, çevresel bir ortamla etkileşime girer ve belirli bir hedefi başarmak için en uygun eylemleri

öğrenir. Model, ödöl ve ceza değlerlerini alarak eylemlerinin sonuçlarını değlendirir ve bu geri bildirimlere dayanarak en iyi eylemleri öğrenir.

2.5.2 Derin Öğrenme

Derin öğrenme, yapay sinir ağıları adı verilen çok katmanlı yapay ağılar kullanarak karmaşık veri yapılarını analiz etmek ve öğrenmek için kullanılan bir makine öğrenimi tekniğidir. Kullanılan bu yapay sinir ağlarının çok katmanlı ve karmaşık yapısı sayesinde, daha önceki yöntemlere göre daha yüksek seviyede özelliklerin otomatik olarak çıkarılmasına olanak tanır. Bu özellikler, veri içindeki karmaşıklığı temsil etmek için kullanılır.


Derin öğrenmenin daha sağlıklı sonuçlar vermesi için büyük verilere ihtiyaç duyarlar. Büyük verilerin eğitimi ve hesaplama süresi daha yoğun olabilir. Bu sebeple derin öğrenme çalışmalarında yüksek performanslı bilgisayarlar veya özel donanımlar kullanılır.

3. MATERYAL VE YÖNTEM

3.1 Yapay Sinir Ağları

Yapay sinir ağları(YSA) tıpkı insan beyinde olduğu gibi öğrenme yolu ile yeni bilgiler üretebilme, yeni bilgiler oluşturabilme ve keşfedebilme yeteneklerini yardım olmadan otomatik bir şekilde gerçekleştirebilen bilgisayar sistemir.


Yapay sinir ağları, genellikle bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanından oluşur. Her katman, sinir adı verilen birimlerden oluşur. Bu sinirler, giriş verilerini alır, gizli katmanda hesaplamalar yapar ve sonunda bir çıktı üretir. Her sinir, gelen sinyalleri ağırlıklandırır, bunları bir aktivasyon fonksiyonuna sokar ve ardından bir sonraki katmana aktarır.



Şekil 3.1. Temel yapay sinir ağı modeli

3.2 Evrişimsel Sinir Ağları

Evrişimli sinir ağları girdi olarak görüntüleri alan ve görüntü işleme çalışmalarında kullanılan bir derin öğrenme algoritmasıdır. ESA, en az bir adet evrişim katmanından oluşmaktadır. Bu evrişim katmanında filtreler ile birlikte girdilerden özellikler çıkarılmaktadır. Basit bir ESA modeli giriş katmanı, evrişim katmanı, düzleştirme katmanı ve çıktı katmanından oluşmaktadır.




Şekil 3.2. Evrişimsel sinir ağı genel yapısı(32)

3.2.1 Giriş Katmanı

Giriş katmanı ESA'nın ilk katmanıdır. Bu katman genel olarak çalışmalarda tek boyutlu yada üç boyutlu olacak şekilde düzenlenir. Tek boyutlu giriş katmanı genişlik ve yükseklikten oluşmaktadır. Örneğin giriş görüntüsünü 224x224 (genişlik x yükseklik) piksel değerine sahip olacak şekilde çalışma yapılabilir.

Üç boyutlu giriş katmanı genişlik, yükseklik ve kanal sayısından oluşmaktadır. Üç boyutlu giriş görüntüsüne örnek olarak 224x224x3 (genişlik x yükseklik x kanal sayısı) piksel değerlerine sahiptir.




Şekil 3.3. Tek kanal ve üç kanal giriş görüntüsü örneği

3.2.2 Evrişim katmanı

Evrişim katmanı Temel olarak girdi görüntüsünün düşük veya yüksek seviyeli filtreler ile özelliklerin çıkarıldığı katmandır. Bu filtreler tek boyutlu veya çok boyutlu olabilir. Evrişim işleminde filtre belirlenen adım aralığına göre görüntünün sol üst köşesinden başlayarak adım adım ilerler. Bu ilerleme aşamasında filtre ile filtrenin içerisinde bulunan görüntü değerleri çarpılıp sonuçlar toplama işlemi yapılarak toplanır. Toplama işlemlerinden elde edilen sonuçlar özellik matrisini oluşturur.

Genellikle eğitim sonucun daha sağlıklı çalışması için birden fazla özellik çıkarılır. Bu sebeple evrişim katmanında birden fazla filtreleme işlemi yapılır.



Şekil 3.4. Tek kanallı bir görüntüde evrişim işlemi

Filtreler (Kernels): Filtreler, küçük boyutlu matrislerdir (örneğin, 3x3 veya 5x5). Bu filtreler, giriş görüntüsü üzerinde kaydırılarak evrişim işlemi gerçekleştirilir. Her bir filtre, belirli özellikleri (kenarlar, köşeler vb.) tanımlamak üzere eğitilir.

Özellik Haritaları (Feature Maps): Evrişim işlemi sonucunda, her bir filtre için bir özellik haritası oluşturulur. Bu haritalar, görüntüdeki belirli özelliklerin yerini ve yoğunluğunu gösterir.

Özellik haritasının matrisi denklem 3.1 ve 3.2 de bulunan formüller ile hesaplanabilir.

$$\text{Özellik matrisi genişliği} = \frac{\text{Görüntüsü Genişliği} - \text{Filtre Genişliği} + (2 \times \text{Dolgu})}{\text{Adım}} + 1 \quad (3.1)$$

$$\text{Özellik matrisi yüksekliği} = \frac{\text{Görüntüsü Yüksekliği} - \text{Filtre Yüksekliği} + (2 \times \text{Dolgu})}{\text{Adım}} + 1 \quad (3.2)$$

Adım (Stride): Bu değer giriş görüntüsünün üzerinde kaç piksel boyunca hareket edeceğini belirler. Adım aralığı 1 seçilirse birer birer, 2 seçilirse ikişer ikişer kaydırma işlemi gerçekleşir. Eğer adım aralığı yüksek seçilirse özellik matrisi boyutu daha küçük olur. Adım aralığını çok büyük seçmek özellik matrisinin boyutunu küçültür fakat daha az özellik çıkarma işlemi yapılacağı için çok büyük adım aralığı seçmemek de dikkat edilmesi gereken bir noktadır.


Dolgu (Padding): Görüntüye filtre uygulandıktan sonra özellik matrisinin boyutunun giriş görüntüsü boyutuna göre daha küçük oluşmaktadır. Bu nedenle eğer boyutu korumak istersek dolgu işlemi yapılır. Dolgu işlemi için giriş görüntüsünün etrafına özellik haritasının boyutunu koruyacak şekilde 0 ekleme işlemi ile yapılır. Bu eklemeyen sonra filtre işlemi tamamlanınca özellik haritasının boyutu ile giriş görüntüsünün boyutu aynı kalır.

3.2.3 Havuzlama Katmanı

Havuzlama katmanının amacı ağda kullanılacak girdinin boyutunu azaltma, hesaplama maliyetini azaltma ve özellik haritasından belirli özelliklerin ön plana çıkmasını sağlamaktır. Bu sayede ağın performansı artmaktadır. Daha az parameter ile çalışıldığı için aşırı öğrenmenin önüne geçilir. Bu sayede özellik haritasında bulunan önemli bilgiler korunur. Havuzlama katmanı ile birlikte boyut azaltma işlemide yapılabilir.


En çok kullanılan havuzlama türlerine örnek olarak maksimum havuzlama, ortalama havuzlama ve küçük kareler havuzlama verilebilir.

Maksimum Havuzlama (Max Pooling): Genellikle filtre 2x2 veya 3x3 olarak seçilir. Bu filtreler giriş matrisi üzerinde adım aralığı kadar kaydırılarak maksimum değeri alır. Burada da adım aralığı değişkenlik gösterebilir. 1 veya 2 gibi seçimler yapılabilir.



Şekil 3.5. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile maksimum havuzlama sonucu


Ortalama Havuzlama (Average Pooling): Maksimum havuzlamada olduğu gibi filtre ve adım aralığı ayarlanabilir. Filtre adım aralığı kadar kaydırılarak matris üzerindeki seçili bölümde bulunan değerler toplanır. Toplam sonucu, kullanılan filtrenin genişlik ve yükseklik değerlerinin çarpımından çıkan sonuca bölünür. Bu sonuç ortalama havuzlama değerini verir.



Şekil 3.6. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile ortalama havuzlama sonucu

Küçük Kareler Havuzlama (L2-norm Pooling): Bu yöntemde de filtre ve adım aralığı ayarlanabilir. Küçük kareler havuzlama yönteminde, filtre matris üzerinde adım aralığı kadar kaydırılır ve seçili bölümde bulunan değerlerin kareleri

alınır. Karelerin toplam sonucu filtre matrisinin genişlik ve yükseklik değerinin çarpımının sonucuna bölünür ve ortalaması alınır. Daha sonra karekök alınarak sonuç bulunur.




Şekil 3.7. 4x4 boyutundaki matrise adım aralığı 2 olan 2x2 boyutunda uygulanan filtre ile küçük kareler havuzlama sonucu

3.2.4 Düzleştirme Katmanı

Evrişim katmanları ve havuzlama katmanları, görüntüdeki önemli özellikleri çıkarır. Tam bağlantı katmanı bu katmanlardan gelen çok boyutlu çıktıyı alır (2D, 3D vb.) ve tek boyutlu vektöre dönüştürür. Bu vektör daha sonra tam bağlantı katmanında kullanılır hale gelir.


Son katmandan gelen özellik haritasını Şekil 3.8’de bulunan matrisi örnek alırsak 5x5 boyutundaki matrisin 20 adet özellik haritası çıkmaktadır. Buradaki sonucun hesaplanması için matrisin genişlik, yükseklik ve boyut değerlerinin çarpılması sonucu özellik haritası adeti çıkarılır.



Şekil 3.8. 5x5 boyutundaki matrisin düzleştirme katmanından sonra 20x1 boyutundaki vektör çıktısı

3.2.5 Tam Bağlantı Katmanı

Birçok yapay sinir ağı modelinde, son katman olarak kullanılarak nihai çıktılar üretilir. Tam bağlantı katmanından sonra başka katman yoktur. Her nöron, bir önceki katmandaki tüm nöronlara bağlıdır. Katmanlar arası maksimum bilgi akışını sağlar. Her bağlantının bir ağırlığı vardır ve bu ağırlıklar model eğitimi sırasında optimize edilir. Genellikle doğrusal olmayan aktivasyon fonksiyonları kullanılır (ReLU, Sigmoid, Tanh vb.), bu da ağı daha karmaşık ve doğrusal olmayan ilişkileri öğrenmesini sağlar. Girdi ve çıktı arasında bir veya daha fazla gizli katman olarak yer alabilir, öğrenme kapasitesini artırır. Çıkış nöron sayısı sınıflandırma sayısı kadardır.




Şekil 3.9. Tam bağlantı katmanı genel yapısı(33)

3.2.6 Bırakma Katmanı

ESA’larda en büyük problemlerden biriside ezberleme ve aşırı uydurmadır. Bu ezberleme veya aşırı uydurma tüm ağı ve sonucu doğrudan etkilemektedir. Ezberleme veya aşırı uydurmanın en temel sebeplerinden birisi dengesiz veri setidir. Bu sebeple çalışılan veri setinde dengeli eğitim verilerinin bulunması çok önemlidir. Bu problemi anlamanın en basit yolu modelin eğitim sırasında doğrulama başarı oranı yükselmiyor ve doğrulama hata oranı yükseliyorsa ezberleme veya aşırı uydurma durumu olduğu anlaşılabilir.

Derin öğrenme çalışmalarında sıklıkla kullanılan bir katmandır. Bu katmanda eğitilen nöronlar rasgele olacak şekilde devre dışı bırakılmaktadır.



Şekil 3.10. Normal ESA modeli ve seyreltme işleminden sonra oluşan ESA modeli(34)

3.2.7 Veri Arttırma

Derin öğrenme çalışmalarında en önemli etmenlerden biriside eğitim verisinde bulunan sayının dengesidir. Eğer veri seti içerisinde sınıflandırma yapılacak veriler dengesiz adetlere sahipse sınıflandırma doğruluğu sağlıklı sonuçlar vermez. Dengesiz veri setinde ezberle problemleride meydana gelir. Bu problemlerin önüne geçmek için veri arttırma yöntemi sıklıkla kullanılır. Veri arttırma yöntemi uygulandıktan sonra modelde eğitim verisinin aşırı uyum sağlaması engellenir. Daha fazla eğitim verisi ile çalışılmış olur ve daha iyi bir model eğitimi sağlanır.

Yaygın olarak kullanılan veri arttırma tekniklerine örnek olarak görüntüleri belirli açılar ile döndürme, görüntüleri yatay ve dikey olarak çevirme, yakınlaştırma, patlaklık değişikliği, görüntü ekleme ve kesme gibi yöntemler uygulanır.

3.2.8 Aktivasyon Fonksiyonları


ESA'ların içindeki aktivasyon fonksiyonları, ağıın her katmanındaki nöronların girişlerine göre ne kadar aktif olacağını belirleyen matematiksel işlemlerdir. Bu fonksiyonlar, doğrusal olmayan özellikleri modele ekleyerek ağıın karmaşık veri ilişkilerini öğrenebilmesini sağlar. Eğer aktivasyon fonksiyonsuz bir yapay sinir ağıı yapılırsa, bu ağı basit bir doğrusal regresyona benzeyecektir. YSA'larda çeşitli aktivasyon fonksiyonları kullanılmaktadır. Veriye ve problemlere göre kullanılan aktivasyon fonksiyonları değişkenlik göstermektedir. Tüm veriler doğrusal veri türü olamayacağından sistemimizin de doğrusal olmayan problemleri de öğrenmesi gerekmektedir.

Tablo 3.1. Aktivasyon fonksiyonlarının matematiksel gösterimi

Aktivasyon Fonksiyonu	Matematiksel Gösterim
ReLU	$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases}$
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$
Hiperbolik Tanjant	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$
Basamak	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$
Doğrusal(Lineer)	$f(x) = x$
Softmax	$f(x) = \frac{e^x}{\sum_{j=1}^n e^x}$
Sızıntı ReLU	$f(x) = \begin{cases} 0.01 \cdot x, & x < 0 \\ x, & x \geq 0 \end{cases}$
ELU	$f(\alpha, x) = \begin{cases} \alpha(e^x - 1), & x < 0 \\ x, & x \geq 0 \end{cases}$


3.2.8.1 ReLU Fonksiyonu

ReLU günümüz çalışmalarında en çok kullanılan aktivasyon fonksiyonudur. Doğrusal bir fonksiyon değildir. Değer sıfırdan küçükse veya sıfırsa çıksıtı 0, sıfırdan büyükse kendisi olacak şekilde çıktı verir. Sıfırdan küçük değerler ile çalışmadığı için aktivasyon işlemi basit ve hızlıdır.

**Şekil 3.11.** ReLU aktivasyon fonksiyonu grafik gösterimi

3.2.8.2 Sigmoid Fonksiyonu


Sigmoid aktivasyon fonksiyonu her zaman çıktı olarak 0 ile 1 arasında değer üretir. En yaygın kullanım alanı ikili sınıflandırma çalışmalarıdır.



Şekil 3.12. Sigmoid aktivasyon fonksiyonu grafik gösterimi

3.2.8.3 Hiperbolik Tanjant Fonksiyonu

Sigmoid fonksiyonuna çok benzer yapıya sahiptir fakat hiperbolik tanjant aktivasyon fonksiyonu -1 ile +1 aralığında çıktı üretir. Sigmoid fonksiyonuna göre avantajı ise türevinin daha dik olması yani daha çok değer alabilmesidir. Buda daha hızlı öğrenme ve sınıflama işlemi ile daha verimli olacağı anlamına gelmektedir.



Şekil 3.13. Tanh aktivasyon fonksiyonu grafik gösterimi

3.2.8.4 Basamak Fonksiyonu


Basamak aktivasyon fonksiyonu, giriş değerinin belirli bir eşik değerini aşıp aşmamasına bağlı olarak iki farklı çıktı verir. Sıfırdan küçük değerlerde 0, sıfır veya daha büyük değerlerde ise 1 sonucunu vermektedir. Gizli katmanlarda çok tercih edilmeyen basamak aktivasyon fonksiyonu çoğunlukla çıkış katmanında ikili sınıflayıcı olarak kullanılır.

3.2.8.5 Doğrusal (Linear) Fonksiyonu

Doğrusal bir yapıya sahip olduğu için giriş değeri ile çıkış değeri aynıdır. Türevlenebilir fonksiyon olmadığı için ve doğrusal olduğu için, öğrenme işleminde geriye besleme yapıldığında sabit bir sayı olacağından öğrenme gerçekleşmeyecektir. Bu da çalışmalarda tercih edilen bir yöntem değildir.

3.2.8.6 Softmax Fonksiyonu

Softmax aktivasyon fonksiyonu, genellikle çok sınıflı sınıflandırma problemlerinde kullanılır ve bir dizi girdi değerini, toplamaları 1 olan olasılıklara dönüştürür. Çok sınıflı sınıflandırma problemlerinde, her sınıf için ayrı bir olasılık değeri hesaplar. Bu, sınıflar arasında daha doğru ve karşılaştırmalı bir değerlendirme yapmayı sağlar. Sigmoid aktivasyon fonksiyonuna çok benzer bir yapıya sahiptir. Çıkış değeri olarak 0 ile 1 arasında değer almasına rağmen sınıflandırma çalışmalarında sıklıkla kullanılmaktadır.




Şekil 3.14. Softmax aktivasyon fonksiyonu grafik gösterimi

3.2.8.7 Sızıntı (Leaky) ReLU Fonksiyonu

ReLU aktivasyon fonksiyonunda bulunan negatif değerlerin yok olması sorununa karşı çözüm olmak için geliştirilmiştir. ReLU aktivasyon fonksiyonuna çok benzemektedir. Pozitif ve 0 değerleri için değerini korurken negatif değerler için 0.01 ile çarparak kısmen negatif değerleri korumaya çalışır. Bu sayede ReLU'dan farklı olarak ReLU'nun türevlenemez olduğu noktaları türevlenebilir hale getirebilmektedir.

3.2.8.8 ELU Fonksiyonu

ELU aktivasyon fonksiyonu ReLU fonksiyonunun çözemediği problemleri çözmek ve dezavantajlarını ortadan kaldırmak için oluşturulan modern bir aktivasyon fonksiyonudur. ELU aktivasyon fonksiyonu, pozitif girişler için lineer, negatif girişler için ise üstel bir fonksiyon kullanır. ELU fonksiyonu ve türevi süreklidir, bu da geri yayılım algoritması sırasında daha düzgün ve stabil güncellemeler sağlar.



Şekil 3.15. Şekil (1,1) Basamak, Şekil (1,2) Doğrusal, Şekil (2,1) Sızıntı ReLU, Şekil (2,2) ELU aktivasyon fonksiyonlarının grafik gösterimi

3.2.9 Optimizasyon Algoritmaları

Optimizasyon algoritmaları derin öğrenme modellerinin eğitim sürecindeki en önemli bölümlerinden birisidir. Modelin performansını artırma, eğitim süresini azaltma ve doğru tahminler yapmak için optimizasyon algoritmaları sıklıkla kullanılır. Optimizasyon algoritmalarının temel amacı, modelin tahmin ettiği çıktılar ile gerçek değerler arasındaki farkı (kayıp fonksiyonu) minimize etmektir. Bu, modelin doğru tahminler yapma yeteneğini artırır. Modelin her katmanındaki ağırlıkları ve bias'ları güncelleyerek öğrenme sürecini gerçekleştirir. Bu güncellemeler, modelin eğitim verisi üzerinde daha iyi performans göstermesini sağlar. Farklı optimizasyon algoritmaları ile modelin öğrenme sürecini hızlandırmak ve daha verimli hale getirmek için çeşitli teknikler kullanılır. Optimizasyon algoritmaları, modelin genel performansını ve genelleme yeteneğini artırır. Bu, modelin yeni, görülmemiş veriler üzerinde de iyi performans göstermesini sağlar. Daha karmaşık ve yüksek boyutlu problem uzaylarında, optimizasyon algoritmaları etkin çözümler bulmaya yardımcı olur.

Gradyan Azalma


Gradyan azalma modelinde rastgele seçilmiş olan parametre değerleri ile global minimuma ulaşmak hedeflenir. Büyük öğrenme oranı seçilirse çözümden uzaklaşma olabilirken, küçük öğrenme oranı seçilirse yine aynı durum yaşanabilir. Doğru bir öğrenme oranı bulmak çok önemlidir. Hesaplama açısından verimli ve minimum noktaya kararlı bir yakınsama yapar. Dezavantaj olarak da bütün veri setini kullandığı içinse biraz yavaştır(35).

Stochastic Gradyan Azalma

Gradyan azalmaya çok benzer yapıya sahiptir fakat gradian azalma gibi tüm veri setini kullanmaz. Sadece seçilen veri üzerinde işlem yaptığı için model parametreleri her evre(epoch)'da küçük küçük güncellenir. Bu sayede global minimuma daha kararlı ilerler. Bu kararlı ilerleyiş gradyan azalmaya göre daha gürültülü bir grafik çizmesine sebep olur. Tüm verileri kullanmadı için büyük veri setlerinde minimuma daha hızlı ulaşmaktadır.

MiniBatch Gradyan Azalma

MiniBatch gradyan azalmada 1 ile veri setinin uzunluğu arasında değer olarak hesaplama yapılır. SGD'de bir veri üzerinde çalışılıyordu. Bunda tüm veri üzerinde çalışılmaktadır.



Şekil 3.16. Gradyan azalma algoritmalarının şekil üzerinde gösterimi (35)

RMSprop Optimizasyon Algoritması

Gradyanların büyüklüğüne göre öğrenme oranı ayarlanabilir, bu da daha kararlı bir optimizasyon süreci sağlar. Ayrıca dikey salınımları minimize ederek yatay boyutta daha hızlı hareket ederek minimuma daha hızlı ulaşır.

Adam Optimizasyon Algoritması

Adam optimizasyon algoritması momentum ve RMSprop optimizasyon algoritmalarının avantajlarının birleştirir. Adam, her parametre için adaptif öğrenme oranları kullanarak ilk ortalama ve ikinci olarak varyans tahminleri sayesinde daha dengeli bir güncelleme yapmaktadır.

3.2.10 Öğrenme Oranı

Öğrenme oranı derin sinir ağlarında en çok kullanılan hiperparametrelerden birisidir. Bu parametre, modelin her adımda ağırlıklarını ne kadar güncelleyeceğini belirler. Yüksek bir öğrenme oranı, büyük adımlar atarak ağırlıkları hızlı bir şekilde günceller. Düşük bir öğrenme oranı ise küçük adımlarla daha yavaş ve ince ayar yaparak güncellemeler yapar. Öğrenme oranı çok yüksek seçilirse ağırlıklar çok hızlı güncellenir ve model minimum noktaya kaçarsa öğrenme süreci kararsız hale gelebilir. Eğer öğrenme oranı çok düşük seçilirse öğrenme süreci yavaş ilerleyecektir ve model minimuma ulaşmasında yavaş olacağı için eğitim süresi gereksiz yere uzayacaktır. Doğru öğrenme oranını bulmak için bazen birden fazla kez model eğitilip en ideal değere ulaşınca kadar eğitimlere devam edilmesi gerekmektedir. Adam, RMSprop gibi optimizasyon algoritmaları, öğrenme oranını

otomatik olarak ayarlar ve adaptif öğrenme oranları kullandıkları için çok tercih edilmektedir.

3.2.11 Kayıp fonksiyonları

Derin öğrenme ve makine öğrenmesi çalışmalarında modelin performansını değerlendirmek için kullanılır. Kayıp fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer ve bu farkın minimize edilmesi amaçlanır. Kayıp fonksiyonları, modelin öğrenme sürecini yönlendiren ve ağırlıkların güncellenmesini sağlayan temel bileşenlerdir. En yaygın kullanılan kayıp fonksiyonlarına örnek olarak Categorical Cross-Entropy ve Binary Cross-Entropy verilebilir.

3.2.12 Kod Derleme Ve Çalışma Ortamı


Python: 1991 yılında ilk sürümü geliştirilen python standart kütüphanesi ve dinamik yapısı nedeniyle günümüzde en yaygın olarak kullanılan dillerden birisidir. Özgür ve açık kaynak kod mantığına dayanan Python'ın standart kütüphanesi, geliştirme araçları ve diğer birçok kütüphane, lisansa gerek duyulmaksızın açık kaynak kod olarak ücretsiz şekilde indirilebilmektedir(36).

TensorFlow: Değişik seviyelerde yapay zeka sistemi oluşturma imkanı sunan yazılım kütüphanesidir. Açık kaynaklı sistem, derin öğrenme teknolojisiyle kolaylık sağlıyor. Masaüstü ve mobil platformlarda kullanılabilir. Komut işleme, veri toplama, bilgi değerlendirme donanımıyla öne çıkıyor. Sistemin derin sinir ağları gelişmiştir(37).

Tensorboard ve Keras: TensorBoard, TensorFlow kütüphanesi ile birlikte kullanılan bir görselleştirme aracıdır. Makine öğrenimi modellerinin performansını izlemek, hata ayıklamak ve optimize etmek için kullanılır. Keras ise, açık kaynaklı bir yapay sinir ağı kütüphanesidir ve özellikle yapay sinir ağı konusunda deneyimi olmayan geliştiriciler için ideal bir seçimdir. Keras, TensorBoard ile birlikte kullanılabilir ve model eğitimi sırasında TensorBoard'a veri gönderebilir. Bu sayede, modelin eğitim performansı izlenebilir, model yapıları görselleştirilebilir ve hata ayıklama yapılabilir. TensorBoard ve Keras kütüphaneleri birlikte kullanıldığında, yapay sinir ağı projeleri daha verimli bir şekilde geliştirilebilir(38).

3.3 Kullanılan Derin Öğrenme Modelleri


3.3.1 Normalizasyon ve bırakma katmanı olmayan temsil modeli



Şekil 3.17. Normalizasyon ve bırakma katmanı olmayan temsil öğrenme algoritması akış diyagramı

Normalizasyon ve bırakma katmanı eklenmeyen temsil öğrenme algoritmasında öncelikle tüm giriş görüntüleri tekrar 32x32x3 olacak şekilde yeniden boyutlandırılmaktadır (Resize). Daha sonra sırasıyla 1 evrişim katmanı, 2 evrişim katmanı ve 3 evrişim katmanına sahip modeller ile eğitim ve test işlemi gerçekleştirilmektedir. Evrişim katmanında (Conv2D) 3x3 filtre ve sırasıyla [16,32,64,128,256] özellik haritası (Layer size) ile evrişim işlemi gerçekleştirilir. Evrişim işleminden sonra aktivasyon (Activation) fonksiyonu 'ReLU' kullanılarak aktivasyon işlemi gerçekleştirilir. Havuzlama katmanında 2x2 filtre kullanılarak (MaxPooling) işlemi gerçekleştirilir. 2 ve 3 evrişim katmanına sahip modellerde bu işlemler sırasıyla 2 ve 3 katman olarak çalışmaktadır. Düzleştirme katmanı (512) ve aktivasyon fonksiyonu 'ReLU' olarak tam bağlantı katmanına geçmektedir. Tam bağlantı katmanında veri setinde bulunan sınıf adeti 7 sınıfı sınıflandırmaktadır.

3.3.2 Normalizasyon ve bırakma katmanı eklenen temsil modeli




Şekil 3.18. Normalizasyon ve bırakma katmanı eklenen temsil öğrenme algoritması akış diyagramı

Normalizasyon ve bırakma katmanı eklenen temsil öğrenme algoritmasında normalizasyon ve bırakma katmanı olmayan temsil öğrenme algoritmasına benzer bir yapıda tüm giriş görüntüleri tekrar 32x32x3 olacak şekilde yeniden boyutlandırılmaktadır (Resize). Daha sonra sırasıyla 1 evrişim katmanı, 2 evrişim katmanı ve 3 evrişim katmanına sahip modeller ile eğitim ve test işlemi gerçekleştirilmektedir. Evrişim katmanında (Conv2D) 3x3 filtre ve sırasıyla [16,32,64,128,256] özellik haritası (Layer size) ile evrişim işlemi gerçekleştirilir. Evrişim işleminden sonra aktivasyon (Activation) fonksiyonu 'ReLU' kullanılarak aktivasyon işlemi gerçekleştirilir. Normalizasyon işlemi için 'BatchNormalization' kullanılmıştır. Bırakma (Dropout) katmanı işleminde %30 bırakma işlemi uygulanmıştır. Havuzlama katmanında 2x2 filtre kullanılarak (MaxPooling) işlemi gerçekleştirilir. 2 ve 3 evrişim katmanına sahip modellerde bu işlemler sırasıyla 2 ve 3 katman olarak çalışmaktadır. Düzleştirme katmanı (512) ve aktivasyon fonksiyonu 'ReLU' olarak tam bağlantı katmanına geçmektedir. Tam bağlantı katmanında veri setinde bulunan sınıf adeti 7 sınıfı sınıflandırmaktadır.


4. BULGULAR VE TARTIŞMA

Bu tez çalışmasında medikal görüntülerin etkin bir şekilde sınıflandırılması için temsil öğrenme çalışması yapılmıştır. Medikal görüntüler için HAM10000 veri seti kullanılmıştır. Bu veri setinde 6705 adet Melanocytic nevi(nv), 1113 adet Melanoma(mel), 1099 adet Benign keratosis-like lezyon(bkl), 514 adet Basal cell carcinoma(bcc), 327 adet Actinic keratoses(akiec), 142 adet Vascular lezyon(vasc) ve 115 adet Dermatofibroma(df) kanser görselleri bulunmaktadır. Bu görseller %80 eğitim, %20 test ve %50 eğitim, %50 test olarak giriş görüntü boyutu 32x32x3 olacak şekilde ayarlanmıştır. Çalışmada öncelikle 10,20 ve 30 evre(epoch) ve her evrede evrişim katmanına yeni bir evrişim eklenerek, normalizasyon katmanı ve bırakma katmanı olmadan eğitim ve test yapılmıştır. Daha sonra aynı evre(epoch) değerleri ile normalizasyon ve bırakma katmanı eklenerek tekrar eğitim ve testler yapılmıştır.


Bu çalışma boyunca Lenovo ThinkPad 13. nesil i5 işlemci ve 16GB ram özelliklerine sahip laptop kullanılmıştır. GPU kullanılmamıştır.



Şekil 4.1. HAM10000 Veri setinde bulunan 7 farklı kanser grubunun görselleri




Şekil 4.2. Tez çalışmasında kullanılan cilt kanseri görüntülerinin %80 eğitim ve %20 test adet dağılım grafiği




Şekil 4.3. Tez çalışmasında kullanılan cilt kanseri görüntülerinin %50 eğitim ve %50 test adet dağılım grafiği


- 10 Evre(Epoch) ve 1 evriřim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.4. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok, %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.5. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok, %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiğı




Şekil 4.6. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiğı




Şekil 4.7. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği

10 evre, 1 evrişim katmanına sahip (%80 eğitim, %20 test) ve (%50 eğitim, %50 test) modellerin eğitim sonuçları iyi bir değere sahip olsada kayıp değerleri çok yüksek gelmektedir. Şekil 4.5’de görüldüğü gibi (%50 eğitim, %50 test) modelinin hem doğruluk hem de kayıp değerleri şekil 4.4’de bulunan (%80 eğitim, %20 test) modeline göre çok daha iyi sonuçlar vermiştir.


- 10 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.8. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.9. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.10. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.11. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği

10 evre, 2 evriřim katmanına sahip modeller eğitildikten sonra 10 evre, 1 evriřim katmanına sahip modellerin eğitim sonuçlarına göre doğruluk değerleri düşüş olduğu gözlemlenmiş olsada kayıp değerlerinde daha iyi sonuçlar elde edilmiştir. Şekil 4.9’de görüldüğü gibi (%50 eğitim, %50 test) modelinin doğruluk değerleri şekil 4.8’da bulunan (%80 eğitim, %20 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 10 Evre(Epoch) ve 3 evriřim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.12. 10 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.13. 10 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.14. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.15. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği


10 evre, 3 evrişim katmanına sahip (%80 eğitim, %20 test) ve (%50 eğitim, %50 test) modellerin eğitim sonuçlarında Şekil 4.12’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.13’de bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat kayıp değerlerinde şekil 4.13’de bulunan (%50 eğitim, %50 test) modeli en iyi sonuçları vermiştir.

Genel 10 evre normalizasyon ve bırakma katmanı yok modellerinin eğitim ve test sonuçları incelendiğinde; 10 evre ve 3 evrişim katmanına sahip modelin eğitim doğruluk sonuçları diğer 10 evre 1 evrişim ve 10 evre 2 evrişim katmanına sahip modellere göre düşüş göstermiş olsada kayıp değerlerinde diğer modellere göre daha da iyi sonuçlar gözlenmiştir.


- 20 Evre(Epoch) ve 1 evriřim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.16. 20 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiđi



Şekil 4.17. 20 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiđi




Şekil 4.18. 20 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiđi




Şekil 4.19. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği

20 evre ve 1 evrişim katmanına sahip modelin eğitim sonuçları 10 evre 1 evrişim katmanına sahip modelin değerlerine göre hem doğruluk hemde kayıp değerleri çok daha iyi sonuca sahiptir. Şekil 4.17’de görüldüğü gibi (%50 eğitim, %50 test) modelinin doğruluk değerleri şekil 4.16’de bulunan (%80 eğitim, %20 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat kayıp değerlerinde şekil 4.16’de bulunan (%80 eğitim, %20 test) modeli en iyi sonuçları vermiştir.


- 20 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.20. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.21. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.22. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.23. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok modelinin %50 eğitim %50 test modelinin Tensorboard grafiği

20 evre, 2 evriřim katmanına sahip modeller eğitildikten sonra 20 evre, 1 evriřim katmanına sahip modellerin eğitim sonuçlarına göre doğruluk değerleri düşüş olduğu gözlemlenmiş olsada kayıp değerlerinde daha iyi sonuçlar elde edilmiştir. Şekil 4.20’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.21’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat kayıp değerleri olarak en iyi sonucu (%50 eğitim, %50 test) modelinden elde edilmiştir.


- 20 Evre(Epoch) ve 3 evriřim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.24. 20 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.25. 20 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.26. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.27. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği


20 evre, 3 evrişim katmanına sahip (%80 eğitim, %20 test) ve (%50 eğitim, %50 test) modellerin eğitim sonuçlarında Şekil 4.24’de görüldüğü gibi (%80 eğitim, %20 test) modelinin hem doğruluk hemde kayıp değerleri şekil 4.25’de bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir.

Genel olarak 20 evre normalizasyon ve bırakma katmanı yok modellerinin eğitim ve test sonuçları incelendiğinde; 20 evre ve 3 evrişim katmanına sahip modelin eğitim doğruluk sonuçları diğer 20 evre 1 evrişim ve 20 evre 2 evrişim katmanına sahip modellere göre düşüş göstermiş olsada kayıp değerlerinde diğer modellere göre daha da iyi sonuçlar gözlenmiştir.


- 30 Evre(Epoch) ve 1 evriřim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.28. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiđi



Şekil 4.29. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiđi




Şekil 4.30. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiđi




Şekil 4.31. 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği

30 evre ve 1 evrişim katmanına sahip modelin eğitim sonuçları 20 evre 1 evrişim katmanına sahip modelin değerlerine göre hem doğruluk hemde kayıp değerleri çok daha iyi sonuca sahiptir. Şekil 4.29’de görüldüğü gibi (%50 eğitim, %50 test) modelinin doğruluk değerleri şekil 4.28’de bulunan (%80 eğitim, %20 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat kayıp değerlerinde şekil 4.28’de bulunan (%80 eğitim, %20 test) modeli en iyi sonuçları vermiştir.


- 30 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.32. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.33. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.34. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.35. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği

Şekil 32’de 30 evre ve 2 evrişim katmanına sahip modelin eğitim sonuçlarını Şekil 28 30 evre 1 evrişim katmanına sahip modele göre düşüş olsada kayıp değerlerinde dahada iyi sonuçlar gözlenmiştir. (%50 eğitim, %50 test) modeline göre şekil 33 ve şekil 29 kıyaslandığında en iyi sonucu şekil 33’de bulunan modelin verdiği gözlenmiştir.


- 30 Evre(Epoch) ve 3 evrişim katmanı var, normalizasyon ve bırakma katmanı yok (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.36. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.37. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.38. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.39. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı yok %50 eğitim %50 test modelinin Tensorboard grafiği


30 evre, 3 evrişim katmanına sahip (%80 eğitim, %20 test) ve (%50 eğitim, %50 test) modellerin eğitim sonuçlarında Şekil 4.36’de görüldüğü gibi (%80 eğitim, %20 test) modelinin hem doğruluk hemde kayıp değerleri Şekil 4.37’de bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir.

Genel olarak 30 evre normalizasyon ve bırakma katmanı yok modellerinin eğitim ve test sonuçları incelendiğinde; 30 evre ve 3 evrişim katmanına sahip modelin eğitim doğruluk sonuçları diğer 30 evre 1 evrişim ve 30 evre 2 evrişim katmanına sahip modellere göre düşüş göstermiş olsada kayıp değerlerinde diğer modellere göre daha da iyi sonuçlar gözlenmiştir.


- 10 Evre(Epoch) ve 1 evriřim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.40. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.41. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiğı




Şekil 4.42. 10 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiğı




Şekil 4.43. 10 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

Normalizasyon ve bırakma katmanı eklendikten sonra 10 evre 1 evrişim katmanına sahip normalizasyon katmanı ve bırakma katmanı olmayan model ile kıyaslandığında doğruluk ve kayıp değerlerinde bir artış gözlenmedi. Ayrıca eğitim süresinde de azalma gözlemlendi. 10 evre, 1 evrişim katmanına sahip (%80 eğitim, %20 test) ve (%50 eğitim, %50 test) modellerin eğitim sonuçlarında Şekil 4.40’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.41’de bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Fakat Şekide 4.41’de bulunan modelin kayıp değeri şekil 4.40’da bulunan modele göre daha iyi sonuç elde edildi.


- 10 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.44. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.45. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.46. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.47. 10 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

10 evre, 2 evriřim katmanına sahip normalizasyon ve bırakma katmanı var modelleri eğitildikten sonra 10 evre, 1 evriřim katmanına sahip modellerin eğitim sonuçlarına göre doğruluk değerleri düşüş olduđu gözlemlenmiş olsada kayıp değerlerinde artış gözlenmiştir. Şekil 4.44’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.45’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 10 Evre(Epoch) ve 3 evriřim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.48. 10 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiğı



Şekil 4.49. 10 Evre (Epoch) ve 3 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiğı




Şekil 4.50. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.51. 10 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

10 evre 3 evrişim katmanına sahip model ile normalizasyon ve bırakma katmanı eklenmeyen 10 evre 3 evrişim katmanına sahip modeller kıyaslandığında, normalizasyon ve bırakma katmanı işlemi uygulandıktan sonra hem doğruluk hemde kayıp değerlerinde iyileşme olduğu gözlemlenmiştir. Ayrıca eğitim ve test süreleride incelendiğinde normalizasyon ve bırakma katmanı işlemi uygulandıktan sonra düşüş yaşandığı gözlemlenmiştir.


- 20 Evre(Epoch) ve 1 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.52. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.53. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.54. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.55. 20 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

Normalizasyon ve bırakma işlemi yapıldıktan sonra 20 evre 1 evrişim katmanına sahip model, 10 evre ve tüm evrişim katmanlarına sahip modellere göre kıyaslandığında hem doğruluk hemde kayıp değerlerinde hepsinden daha iyi sonuç verdiği gözlemlenmiştir. Şekil 4.52’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.53’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 20 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.56. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.57. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.58. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.59. 20 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği


Normalizasyon ve bırakma katmanına sahip 20 evre ve 2 evrişim katmanlı model incelendiğinde, 20 evre ve 1 evrişim katmanına sahip modele kıyasla hem doğruluk hemde kayıp değerlerinde çok daha iyi sonuçlar verdiği gözlemlenmiştir. Eğitim süreleride bir birine çok yakın değerlere sahiptir. En iyi doğruluk değerine

sahip özellik haritası ile en iyi doğruluk değerine sahip kayıp değerleri incelendiğinde aslında en iyi doğruluk değerine sahip modelin en iyi kayıp değerine sahip olmadığı gözlemlenmiştir. Şekil 4.56’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.57’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 20 Evre(Epoch) ve 3 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.60. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.61. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.62. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.63. 20 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

Normalizasyon ve bırakma katmanı işlemi uygulanmış 20 evre 3 evrişim katmanına sahip model ile 20 evre 2 evrişim katmanına sahip modeller kıyaslandığında, hem doğruluk hemde kayıp değerlerinde daha kötü performansa sahip olduğu gözlemlenmiştir. Şekil 4.60’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.61’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 30 Evre(Epoch) ve 1 evriřim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.64. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiđi



Şekil 4.65. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiđi




Şekil 4.66. 30 Evre (Epoch) ve 1 Evriřim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiđi




Şekil 4.67. 30 Evre (Epoch) ve 1 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

Normalizasyon ve bırakma işlemi uygulanan ve uygulanmayan 30 evre ve 1 evrişim katmanına sahip modeller incelendiğinde, normalizasyon ve bırakma katmanı uygulanan modelin hem doğruluk hemde kayıp değerlerinin çok daha iyi sonuç verdiği gözlemlenmiştir. Şekil 4.64’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.65’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.


- 30 Evre(Epoch) ve 2 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.68. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.69. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği




Şekil 4.70. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği




Şekil 4.71. 30 Evre (Epoch) ve 2 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

Normalizasyon ve bırakma katmanı işlemi uygulanmış 30 evre 2 evrişim katmanına sahip model ile işlem uygulanmamış 30 evre 2 evrişim katmanına sahip modeller kıyaslandığında, hem doğruluk hemde kayıp değerlerinde daha iyi performansa sahip olduğu gözlemlenmiştir.


- 30 Evre(Epoch) ve 3 evrişim katmanı var, normalizasyon ve bırakma katmanı var (%80 eğitim, %20 test) ve (%50 eğitim,%50 test) modelinin eğitim sonuçları




Şekil 4.72. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.73. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin en iyi 3 eğitim doğruluk grafiği



Şekil 4.74. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %80 eğitim %20 test modelinin Tensorboard grafiği



Şekil 4.75. 30 Evre (Epoch) ve 3 Evrişim katmanı var, normalizasyon ve bırakma katmanı var %50 eğitim %50 test modelinin Tensorboard grafiği

30 evre 3 evrişim katmanına sahip model ile normalizasyon ve bırakma katmanı eklenmeyen 30 evre 3 evrişim katmanına sahip modeller kıyaslandığında, normalizasyon ve bırakma katmanı işlemi uygulandıktan sonra hem doğruluk hemde kayıp değerlerinde iyileşme olduğu gözlemlenmiştir. Şekil 4.72’de görüldüğü gibi (%80 eğitim, %20 test) modelinin doğruluk değerleri şekil 4.73’da bulunan (%50 eğitim, %50 test) modeline göre çok daha iyi sonuçlar vermiştir. Ayrıca kayıp değerleri olarak en iyi sonucu (%80 eğitim, %20 test) modelinden elde edilmiştir.

Tablo 4.1. Normalizasyon ve bırakma katmanını yok, %80 eğitim %20 test en iyi sonuç veren 3 model

Evre (Epoch)	Evrişim Katman Sayısı	Özellik Haritası Sayısı	Doğruluk	Kayıp	Süre
10	1	256	%89.88	0.3090	9.013 dk
		16	%87.53	0.3472	53.07 sn
		64	%86.73	0.3640	2.919 dk
	2	32	%77.50	0.6138	38.2 sn
		128	%71.98	0.7903	2.849 dk
		16	%71.36	0.8005	38.05 sn
	3	256	%74.46	0.6814	7.734 dk
		32	%73.94	0.7023	31.78 sn
		64	%72.57	0.7340	57.11 sn
20	1	64	%97.22	0.1022	6.56 dk
		16	%95.63	0.1463	2.256 dk
		256	%93.93	0.1685	19.22 dk
	2	16	%95.61	0.1339	1.247 dk
		32	%94.80	0.1469	1.681 dk
		128	%79.54	0.5712	8.038 dk
	3	256	%83.30	0.4447	18.62 dk
		64	%80.20	0.5335	1.786 dk
		16	%78.98	0.5502	40.62 sn
30	1	256	%95.77	0.1414	25.41 dk
		128	%94.98	0.1999	14.94 dk
		32	%94.75	0.1557	4.19 dk
	2	16	%95.42	0.1281	1.243 dk
		128	%91.09	0.2382	9.144 dk
		64	%89.83	0.2801	3.438 dk
	3	64	%93.47	0.1797	3.058 dk
		256	%89.44	0.2839	26.31 dk
		128	%88.35	0.3167	8.583 dk

Tablo 4.1’de normalizasyon ve bırakma katmanları olmaksızın, %80 eğitim ve %20 test oranları ile eğitilmiş derin öğrenme modellerinin performansını göstermektedir. 10 Evre 1 katman için en iyi doğruluk %89.88 (256 özellik haritası ile), 2 katman için en iyi doğruluk %77.50 (32 özellik haritası ile), 3 katman için en iyi doğruluk %74.46 (256 özellik haritası ile) gözlemlenmiştir. 20 Evre 1 katman için en iyi doğruluk %97.22 (64 özellik haritası ile), 2 katman için en iyi doğruluk %95.61 (16 özellik haritası ile), 3 katman için en iyi doğruluk %83.30 (256 özellik haritası ile) gözlemlenmiştir. 30 Evre 1 katman en iyi doğruluk: %95.77 (256 özellik haritası ile), 2 katman için en iyi doğruluk %95.42 (16 özellik haritası ile), 3 katman için en iyi doğruluk %93.47 (64 özellik haritası ile) gözlemlenmiştir. En iyi sonuç 20 evre, 1 evrişim katmanını ve 64 özellik haritası ile %97.22 doğruluk elde edilmiştir.

Tablo 4.2. Normalizasyon ve bırakma katmanı var, %80 eğitim %20 test en iyi sonuç veren 3 model

Evre (Epoch)	Evrişim Katman Sayısı	Özellik Haritası Sayısı	Doğruluk	Kayıp	Süre
10	1	16	%87.88	0.3358	53.93 sn
		32	%85.78	0.3912	1.565 dk
		64	%85.71	0.3987	2.971 dk
	2	32	%82.44	0.4711	50.4 sn
		16	%82.31	0.4772	34.89 sn
		64	%81.71	0.4987	1.612 dk
	3	64	%79.16	0.5573	2.243 dk
		128	%78.61	0.5698	4.857 dk
		32	%78.03	0.5930	1.356 dk
20	1	16	%92.40	0.2216	2.665 dk
		32	%91.81	0.2345	4.306 dk
		64	%91.66	0.2377	7.448 dk
	2	128	%93.43	0.1906	8.21 dk
		16	%92.89	0.1966	1.408 dk
		32	%92.86	0.1948	2.047 dk
	3	128	%91.77	0.2173	11.54 dk
		256	%91.58	0.2346	26.99 dk
		64	%88.87	0.2992	5.339 dk
30	1	32	%96.14	0.1134	7.179 dk
		64	%95.91	0.1226	12.73 dk
		16	%95.44	0.1297	4.563 dk
	2	256	%97.43	0.0764	29.63 dk
		128	%96.06	0.1170	11.5 dk
		32	%95.98	0.1082	3.28 dk
	3	128	%96.68	0.0950	10.57 dk
		256	%96.66	0.0950	26.47 dk
		64	%95.21	0.1232	4.798 dk

Tablo 4.2’de normalizasyon ve bırakma katmanları var, %80 eğitim ve %20 test oranları ile eğitilmiş derin öğrenme modellerinin performansını göstermektedir. 10 Evre 1 katman için en iyi doğruluk: %87.88 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %82.44 (32 özellik haritası ile), 3 katman için en iyi doğruluk: %79.16 (64 özellik haritası ile) gözlemlenmiştir. 20 Evre 1 katman için en iyi doğruluk: %92.40 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %93.43 (128 özellik haritası ile), 3 katman için en iyi doğruluk: %91.77 (128 özellik haritası ile), 30 Evre 1 katman için en iyi doğruluk: %96.14 (32 özellik haritası ile), 2 katman için en iyi doğruluk: %97.43 (256 özellik haritası ile), 3 katman için en iyi doğruluk: %96.68 (128 özellik haritası ile) gözlemlenmiştir. En iyi sonuç 30 evre, 2 evrişim katmanı ve 256 özellik haritası ile %97.43 doğruluk elde edilmiştir.

Tablo 4.3. Normalizasyon ve bırakma katmanı yok, %50 eğitim %50 test en iyi sonuç veren 3 model

Evre (Epoch)	Evrişim Katman Sayısı	Özellik Haritası Sayısı	Doğruluk	Kayıp	Süre
10	1	32	%94.37	0.1816	46.13 sn
		64	%94.15	0.1982	1.375 sn
		128	%86.73	0.3712	2.48 dk
	2	32	%79.87	0.5473	23.75 sn
		16	%76.39	0.6363	12.4 sn
		256	%73.28	0.7301	4.61 dk
	3	64	%73.38	0.7223	35.87 sn
		128	%73.34	0.7212	1.429 dk
		32	%72.60	0.7424	19.83 sn
20	1	16	%97.12	0.0960	48.64 sn
		64	%96.31	0.1158	2.346 dk
		32	%95.33	0.1530	1.332 dk
	2	256	%89.26	0.2846	11.21 dk
		32	%87.34	0.3393	53.89 sn
		16	%85.60	0.3928	35.33 sn
	3	128	%82.58	0.4799	3.607 dk
		256	%82.07	0.4837	11.21 dk
		64	%78.85	0.5541	1.541 dk
30	1	16	%97.74	0.0730	1.869 dk
		32	%96.98	0.0883	2.889 dk
		256	%94.87	0.1490	11.98 dk
	2	16	%99.98	0.0053	45 sn
		32	%98.96	0.0356	1.184 dk
		128	%91.23	0.2389	5.467 dk
	3	256	%88.04	0.3287	14.44 dk
		128	%86.68	0.3587	4.55 dk
		16	%84.34	0.4142	46.8 sn

Tablo 4.3’de normalizasyon ve bırakma katmanları olmaksızın, %50 eğitim ve %50 test oranları ile eğitilmiş derin öğrenme modellerinin performansını göstermektedir. 10 Evre 1 katman için en iyi doğruluk: %94.37 (32 özellik haritası ile), 2 katman için en iyi doğruluk: %79.87 (32 özellik haritası ile), 3 katman için en iyi doğruluk: %73.38 (64 özellik haritası ile). 20 Evre 1 katman için en iyi doğruluk: %97.12 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %89.26 (256 özellik haritası ile), 3 katman için en iyi doğruluk: %82.58 (128 özellik haritası ile). 30 Evre 1 katman için en iyi doğruluk: %97.74 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %99.98 (16 özellik haritası ile), 3 katman için en iyi doğruluk: %88.04 (256 özellik haritası ile) gözlemlenmiştir. En iyi sonuç 30 evre, 2 evrişim katmanı ve 16 özellik haritası ile %99.98 doğruluk elde edilmiştir.

Tablo 4.4. Normalizasyon ve bırakma katmanı var, %50 eğitim %50 test en iyi sonuç veren 3 model

Evre (Epoch)	Evrişim Katman Sayısı	Özellik Haritası Sayısı	Doğruluk	Kayıp	Süre
10	1	16	%84.22	0.4484	33.84 sn
		32	%84.06	0.4549	51.66 sn
		64	%81.73	0.5078	1.687 dk
	2	32	%77.95	0.6109	36.68 sn
		64	%77.67	0.6011	1.112 dk
		128	%76.81	0.6267	2.395 dk
	3	256	%75.05	0.6722	6.188 dk
		128	%75.03	0.6701	2.247 dk
		64	%74.62	0.6944	1.085 dk
20	1	32	%89.79	0.2807	2.275 dk
		16	%89.29	0.2951	1.507 dk
		64	%87.98	0.3237	3.898 dk
	2	64	%85.44	0.3974	2.962 dk
		128	%83.66	0.4321	5.912 dk
		256	%83.58	0.4330	15.29 dk
	3	256	%79.39	0.5436	16.16 dk
		128	%78.79	0.5793	6.089 dk
		60	%78.31	0.5867	3.373 dk
30	1	16	%93.93	0.1733	1.93 dk
		32	%93.69	0.1848	3.133 dk
		64	%93.45	0.2086	5.794 dk
	2	32	%88.46	0.3203	2.381 dk
		64	%88.42	0.3060	4.463 dk
		128	%87.24	0.3526	8.768 dk
	3	256	%85.56	0.3946	23.9 dk
		128	%82.58	0.4678	9.4 dk
		64	%81.21	0.5085	5.117 dk

Tablo 4.4’de normalizasyon ve bırakma katmanları var, %50 eğitim ve %50 test oranları ile eğitilmiş derin öğrenme modellerinin performansını göstermektedir. 10 Evre 1 katman için en iyi doğruluk: %84.22 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %77.95 (32 özellik haritası ile), 3 katman için en iyi doğruluk: %75.05 (256 özellik haritası ile). 20 Evre 1 katman için en iyi doğruluk: %89.79 (32 özellik haritası ile), 2 katman için en iyi doğruluk: %85.44 (64 özellik haritası ile), 3 katman için en iyi doğruluk: %79.39 (256 özellik haritası ile). 30 Evre 1 katman için en iyi doğruluk: %93.93 (16 özellik haritası ile), 2 katman için en iyi doğruluk: %88.46 (32 özellik haritası ile), 3 katman için en iyi doğruluk: %85.56 (256 özellik haritası ile) gözlemlenmiştir. 30 evre, 1 evrişim katmanı ve 16 özellik haritası ile %93.93 doğruluk elde edilmiştir.

5. SONUÇ VE ÖNERİLER

5.1 Sonuç

Bu tez çalışmasından elde edilen sonuçlara göre, farklı evre ve evrişim katmanlarında eğitilen derin öğrenme modelinden elde edilen doğruluk, kayıp ve süre değerleri analiz edilmiştir. Bu model önce normalizasyon ve bırakma katmanı eklenmeden eğitilip analiz edilmiş daha sonra modele normalizasyon işlemi ve bırakma katmanı eklenmiştir. Bu ikişer ana işlem boyunca model farklı evrelerde eğitilmiş ve her bir evre grubu için farklı evrişim katmanları eklenmiştir. Eklenen evrişim katmanlarında özellik haritası 16,32,64,128 ve 256 adet olacak şekilde eğitime sokularak analizler yapılmıştır. Daha sonra modele normalizasyon ve bırakma katmanı eklenerek bu işlemler tekrar gerçekleştirilmiştir. Modelde (%80 eğitim %20 test) ve (%50 eğitim %50 test) olacak şekilde çalışma yapılmıştır.

Normalizasyon ve bırakma katmanı eklenmeden elde edilen sonuçlar kontrol edildiğinde 10 evre de eğitilen modellerin doğruluk değeri iyi sonuç gösterirken kayıp değerleri kötü olduğu gözlenmiştir. 20 evre ve 30 evrede eğitilen modellerin doğruluk değeri birbirine çok yakın olsada kayıp değeri 30 evrede en iyi sonuçları vermektedir. 30 evrede eğitim süreleri 20 evreye göre biraz daha yüksek olsada ideal analiz yaklaşımlarında tercih edilen sonuç olabileceği söylenebilir.

Normalizasyon ve bırakma katmanı eklendikten sonra elde edilen sonuçlar kontrol edildiğinde 30 evre hem en iyi doğruluk değerlerine sahip hemde en az kayıp değerlerine sahip model olarak sonuç vermiştir. Ayrıca normalizasyon ve bırakma katmanı eklendikten sonra kayıp değerinde azalma ve modelin eğitilme süresinde de artma gözlenmiştir.

Modelin en iyi doğruluk sonucunu normalizasyon ve bırakma işlemi uygulandıktan sonra 30 evre 2 evrişim katmanı ve 256 özellik haritasına sahip modelden %97.43 elde edilmiştir. En düşük kayıp değeri 0.0764 yine aynı modelden elde edilmiştir.

5.2 Öneriler

1. Veri setinde bulunan kanser türlerinin görsel adetleri dengesiz olduğu için aynı çalışma dengeli bir verisetinde tekrar gerçekleştirilebilir.
2. Evrişim katman sayısı arttırılarak aynı çalışmalar tekrarlanıp incele yapılabilir.

3. Bırakma katmanı eklendikten sonra eğitim doğruluđu, kayıp değeri ve eğitim süresi performansıda iyileřtme gözlemlenmiřti. Farklı kayıp fonksiyonlarıda eklenerek alıřma analiz edilebilir.



6. KAYNAKLAR

(Bu tez çalışmasında Vancouver atıf sistemi kullanılmıştır.)

1. SÜMEN A, ÖNCEL S. Türkiye'de Cilt Kanseri ve Güneşten Korunmaya Yönelik Yapılan Araştırmaların İncelenmesi. Türkiye Klinikleri Journal of Nursing Sciences. 2018 Jan 1;10(1).
2. "Cilt (Deri) Kanseri Nedir? Belirtileri ve Tedavi Yöntemleri" [İnternet]. [Erişim Tarihi: 15 Mayıs 2024]. <https://www.memorial.com.tr/hastaliklar/cilt-deri-kanseri-belirtileri-tedavisi-ve-korunma-yontemleri>
3. Demir F. Derin öğrenme tabanlı yaklaşımla kötü huylu deri kanserinin dermatoskopik görüntülerden saptanması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi. 2021;33(2):617-24.
4. Uslu M, Karaman G, Şavk E, Şendur N. Adnan Menderes Üniversitesi hekimlerinin deri kanserleri ve güneşin etkileri konusundaki bilgi düzeyleri ile güneşten korunma davranışlarının değerlendirilmesi.
5. Dildar M, Akram S, Irfan M, Khan HU, Ramzan M, Mahmood AR, Alsaiari SA, Saeed AH, Alraddadi MO, Mahnashi MH. Skin cancer detection: a review using deep learning techniques. International journal of environmental research and public health. 2021 May 20;18(10):5479.
6. Yavuz İH, Yavuz GÖ, Bilgili SG, Demir H, Demir C. DERİ KANSERİ HASTALARININ SERUM OKSİDATİF STRES PARAMETRELERİNİN DEĞERLENDİRİLMESİ Evaluation of Serum Oxidative Stress Parameters of Skin Cancer Patients. Bozok Tıp Dergisi. 2018;8(4):134-8.
7. "Cilt kanseri istatistikleri | Dünya Kanser Araştırma Fonu Uluslararası (wcrf.org)" [İnternet]. [Erişim Tarihi:20 Mayıs 2024]. <https://www.wcrf.org/cancer-trends/skin-cancer-statistics/>
8. Dedeturk BA, Taşdemir K, Bakır-gungor B. Cilt Kanseri Görüntü Sınıflandırması için Görüntü Ön İşlemenin Evrimsel Sinir Ağları Performansı Üzerindeki Etkileri. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi. 2022 Aug 23;38(2):190-200.
9. Göreke V. Cilt lezyonlarının sınıflandırılmasında derin öğrenme tabanlı bir yöntem. Türk Doğa ve Fen Dergisi. 2021;10(1):30-6.
10. "AI improves accuracy of skin cancer diagnoses in Stanford Medicine-led study | News Center | Stanford Medicine" [İnternet]. [Erişim Tarihi: 20 Mayıs 2024]. <https://med.stanford.edu/news/all-news/2024/04/ai-skin-diagnosis.html>
11. CANBAY P. SAĞLIKTA YAPAY ZEKA: DERİN ÖĞRENME TEKNİKLERİ VE UYGULAMALARI.
12. Çivilibal S, Çevik KK, Bozkurt A. Derin Öğrenme Yardımıyla Aktif Termogramlar Üzerinden Meme Lezyonlarının Sınıflandırması. Süleyman Demirel University Faculty of Arts and Science Journal of Science. 2023 Jul 1;18(2):140-56.
13. Zilyas D, Yılmaz A. Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi. 2023 Sep 1;14(3):437-47.
14. Şeker A, Diri B, Balık HH. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. Gazi Mühendislik Bilimleri Dergisi. 2017 Nov;3(3):47-64.

15. Eker AG, Duru N. Medikal görüntü işlemede derin öğrenme uygulamaları. *Acta Infologica*. 2021;5(2):459-74.
16. Karakurt M, İşeri İ. Patoloji görüntülerinin derin öğrenme yöntemleri ile sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*. 2022 Jan 31(33):192-206.
17. Kaggle Skin Cancer MNIST: HAM10000 dataset. [Internet]. [Erişim Tarihi: 7 Eylül 2023]. <https://www.kaggle.com/datasets/kmader/skin-cancer-mnist-ham10000>
18. Toğaçar M, Ergen B. Biyomedikal görüntülerde derin öğrenme ile mevcut yöntemlerin kıyaslanması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2019 Mar 11;31(1):109-21.
19. Doğan Y, Özdemir C, Ataş M. Derin Öğrenme Yöntemleriyle Cilt Lezyonlarının Sınıflandırması: CNN, MLP-MIXER ve VIT. III. International Siirt Scientific Research Congress 18-19 Kasım 2022 Siirt, Türkiye.
20. Karli AB, Kaya B. Cilt Kanseri Görüntüleri Kullanılarak Eğitilen EfficientNet-B3 Mimarisinde Hiperparametre Seçiminin Sınıflandırma Performansına Etkisinin İncelenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2024 Mar 28;36(1):499-507.
21. Özcan Ö, Karaaltun M. Görüntü artırma tekniklerinin cilt kanseri türleri üzerinde evrimsel sinir ağları ile sınıflandırma başarılarının karşılaştırılması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*. 2023 Oct 10;12(4):1-.
22. ÖZBAY E, ÖZBAY FA. Parçacık Sürüş Optimizasyon Algoritması ile Optimize Edilmiş Evrimsel Sinir Ağı Kullanılarak Dermoskopik Görüntülerden Cilt Kanserinin Sınıflandırılması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*. 2023 Mar 3;35(1):261-73.
23. Fatima A. The Skin Lesion Detection and Classification Using Deep Learning. *International Journal for Electronic Crime Investigation*. 2023 Mar 3;7(1):39-48.
24. Khasanah U, Surarso B, Farikhin F. Dilated Convolutional Neural Network for Skin Cancer Classification Based on Image Data. *JTAM (Jurnal Teori dan Aplikasi Matematika)*. 2023 Jan 12;7(1):196-207.
25. Milton MA. Automated skin lesion classification using ensemble of deep neural networks in isic 2018: Skin lesion analysis towards melanoma detection challenge. *arXiv preprint arXiv:1901.10802*. 2019 Jan 30.
26. Ingle Y, Shaikh NF. Deep Learning for Skin Cancer Classification: A Comparative Study of CNN and Vgg16 on HAM10000 Dataset. Available at SSRN 4787463.
27. Kırğıl EN, Erdaş ÇB. Dermoskopik Görüntüler ile Beslenen Derin Öğrenme Teknikleri Kullanılarak Cilt Kanseri Teşhisi Skin Cancer Diagnosis Using Deep Learning Techniques Feed by Dermoscopic Images. *Tıptekno23 Medikal Teknoloji Kongresi 10-12 Kasım 2023, Ankara, Türkiye*.
28. DEDETURK BA, TAŞDEMİR K, BAKİR-GUNGOR B. Cilt Kanseri Görüntü Sınıflandırması için Görüntü Ön İşlemenin Evrimsel Sinir Ağları Performansı Üzerindeki Etkileri. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi*. 2022;38(2):190-200.
29. Ergün E, Kılıç K. Derin öğrenme ile artırılmış görüntü seti üzerinden cilt kanseri tespiti. *Black Sea Journal of Engineering and Science*. 2021 Jan 10;4(4):192-200.
30. "Cilt (Deri) Kanseri Nedir? Belirtileri ve Tedavi Yöntemleri" [Intenet]. [Erişim Tarihi: 15 Mayıs 2024]. <https://www.memorial.com.tr/hastaliklar/cilt-deri-kanseri-belirtileri-tedavisi-ve-korunma-yontemleri>
31. "Cilt (Deri) Kanseri Nedir? Cilt Kanseri Belirtileri ve Tedavisi" [Internet]. [Erişim Tarihi: 15 Mayıs 2024]. <https://www.acibadem.com.tr/ilgi-alani/cilt-deri-kanseri/>

32. "Convolutional Neural Network (CNN) Machine Learning" [Internet]. [Eriřim Tarihi: 15 Mart 2024]. <https://batuhandaz.medium.com/convolutional-neural-network-cnn-machine-learning-2e4bed816948>
33. "ESA(Evriřimsel Sinir Aęları)" [Internet]. [Eriřim Tarihi: 17 Mart 2024]. <https://zeysert.medium.com/esa-evriřimsel-sinir-aęları-87d9bd986579>
34. "Dropout" [Internet]. [Eriřim Tarihi: 19 Mart 2024]. <https://paperswithcode.com/method/dropout>
35. "Yapay Sinir Aęlarında Kullanılan Optimizasyon Algoritmaları" [Internet]. [Eriřim Tarihi: 27 Mayıs 2024]. <https://medium.com/machine-learning-türkiye/yapay-sinir-aęlarında-kullanılan-optimizasyon-algoritmaları-3e87cd738cb5>
36. "Python Programlama Dili Nedir ve Ne İře Yarar?" [Internet]. [Eriřim Tarihi: 07 Mayıs 2024]. <https://www.isnet.net.tr/blogicerik/Phyton-Programlama-Nedir-isnetblog>
37. "TensorFlow Nedir" [Internet]. [Eriřim Tarihi: 07 Mayıs 2024]. <https://www.techcareer.net/blog/tensor-flow-nedir>
38. "Tensorboard ve Keras Kütüphaneleri" [Internet]. [Eriřim Tarihi: 07 Mayıs 2024]. <https://datakapital.com/blog/tensorboard-ve-keras-kutuphaneleri/>