



**TAM OTOMATİK VE METASEZGİSEL TABANLI YENİ
BİR DERİN ÖĞRENME MİMARİSİ ÜRETECİNİN
GELİŞTİRİLMESİ VE CİLT KANSERİ TEŞHİSİ İÇİN
ETKİNLİĞİNİN GÖSTERİLMESİ**

Mustafa Furkan KESKENLER

Danışman: Doç. Dr. Deniz DAL

Doktora Tezi

Bilgisayar Mühendisliği Ana Bilim Dalı

2024

(Her hakkı saklıdır.)

T.C.
ATATÜRK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI

**TAM OTOMATİK VE METASEZGİSEL TABANLI YENİ BİR DERİN ÖĞRENME
MİMARİSİ ÜRETECİNİN GELİŞTİRİLMESİ VE CİLT KANSERİ TEŞHİSİ İÇİN
ETKİNLİĞİNİN GÖSTERİLMESİ**

(Development of a Novel, Fully Automatic and Metaheuristic-based Deep Learning
Architecture Generator and Demonstration of Its Effectiveness Through Skin Cancer
Diagnosis)

DOKTORA TEZİ

Mustafa Furkan KESKENLER

Danışman: Doç. Dr. Deniz DAL

Erzurum
Mayıs, 2024

KABUL VE ONAY TUTANAĐI

Mustafa Furkan KESKENLER tarafından hazırlanan “**Tam Otomatik ve Metasezgisel Tabanlı Yeni Bir Derin Öğrenme Mimarisi Üreticinin Geliştirilmesi ve Cilt Kanseri Teşhisi İçin Etkinliğinin Gösterilmesi**” başlıklı çalışması 10 / 05 / 2024 tarihinde yapılan tez savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Bilgisayar Mühendisliği Ana Bilim Dalı, Bilgisayar Mühendisliği Bilim Dalında doktora tezi olarak kabul edilmiştir.

Jüri Başkanı:	Prof. Dr. Süleyman TOSUN <i>Hacettepe Üniversitesi</i>	Aslı ıslak imzalıdır
Danışman:	Doç. Dr. Deniz DAL <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Prof. Dr. Suat ÖZDEMİR <i>Hacettepe Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Prof. Dr. Bülent ÇAVUŞOĞLU <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır
Jüri Üyesi:	Dr. Öğr. Üyesi Tolga AYDIN <i>Atatürk Üniversitesi</i>	Aslı ıslak imzalıdır

Bu tezin Atatürk Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddelerinde belirtilen şartları yerine getirdiğini onaylarım.

Prof. Dr. Saltuk Buğrahan CEYHUN

Enstitü Müdürü

Aslı ıslak imzalıdır

Bu çalışma TÜBİTAK 2211-A Genel Yurtiçi Doktora Burs Programı kapsamında desteklenmiştir.

Proje No: 2019/3 - 1649B031905055

Not: Bu tezde kullanılan özgün ve başka kaynaklardan yapılan bildiriş, çizelge, şekil ve fotoğrafların kaynak olarak kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU

Doktora Tezi olarak Doç. Dr. Deniz DAL danışmanlığında sunulan “**Tam Otomatik ve Metasezgisel Tabanlı Yeni Bir Derin Öğrenme Mimarisi Üretecinin Geliştirilmesi ve Cilt Kanseri Teşhisi İçin Etkinliğinin Gösterilmesi**” başlıklı çalışmanın tarafımızdan bilimsel etik ilkelere uyularak yazıldığını, yararlanılan eserlerin kaynakçada gösterildiğini, Fen Bilimleri Enstitüsü tarafından belirlenmiş olan Turnitin Programı benzerlik oranlarının aşılmadığını ve aşağıdaki oranlarda olduğunu beyan ederiz.

Tez Bölümleri	Tezin Benzerlik Oranı (%)	Maksimum Oran (%)
Giriş	2	30
Kuramsal Temeller	9	30
Materyal ve Metot	3	35
Araştırma Bulguları ve Tartışma	3	20
Sonuçlar	4	20
Tezin Geneli	8	25

Not: Yedi kelimeye kadar benzerlikler ile Başlık, Kaynakça, İçindekiler, Teşekkür, Dizin ve Ekler kısımları tarama dışı bırakılabilir. Yukarıdaki azami benzerlik oranları yanında tek bir kaynaktan olan benzerlik oranlarının %5'den büyük olmaması gerekir.

Beyan edilen bilgilerin doğru olduğunu, aksi halde doğacak hukuki sorumlulukları kabul ve beyan ederiz.

Tez Yazarı (Öğrenci)	Tez Danışmanı
Mustafa Furkan KESKENLER	Doç. Dr. Deniz DAL
10.5.2024	10.5.2024
İmza: Aslı ıslak imzalıdır	İmza: Aslı ıslak imzalıdır

* Tez ile ilgili YÖKTEZ'de yayınlamasına ilişkin bir engelleme var ise aşağıdaki alanı doldurunuz.

☐ Tezle ilgili patent başvurusu yapılması / patent alma sürecinin devam etmesi sebebiyle Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 2 (iki) yıl süreyle engellenmiştir.

☐ Enstitü Yönetim Kurulunun/....../.... tarih ve sayılı kararı ile teze erişim 6 (altı) ay süreyle engellenmiştir.

TEŞEKKÜR

Bu tezin araştırma konusunun belirlenmesinde danışmanlık yaparak yol gösteren, daima kıymetli zamanını ayırarak hiçbir desteğini esirgemeyen danışman hocam Sayın Doç. Dr. Deniz DAL’a en içten dileklerimle saygı ve teşekkürlerimi sunarım.

Yürüttüğüm çalışmalar sürecinde bilgi ve deneyimleri ile yol göstererek değerli görüşlerini paylaşan ve başvurduğum birçok konuda yardımcı olan Sayın Prof. Dr. Bülent ÇAVUŞOĞLU’na ve Sayın Dr. Öğr. Üyesi Tolga AYDIN’a teşekkür ederim.

Ayrıca hiçbir zaman bana desteklerini esirgemeyen aileme; her türlü katkılarından dolayı babama, anneme, kardeşlerime özellikle abim Prof. Dr. Eyüp Fahri KESKENLER’e, kıymetli eşim Zehra Sena’ya ve oğlum Ali Osman’a teşekkürlerimi sunuyorum.

Lisansüstü eğitimim boyunca beni destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu’na (TÜBİTAK) 2211-A Genel Yurtiçi Doktora Burs Programı (2019/3 - 1649B031905055) kapsamında yapmış olduğu katkılarından dolayı teşekkür ederim.

Mustafa Furkan KESKENLER

ÖZET

DOKTORA TEZİ

TAM OTOMATİK VE METASEZGİSEL TABANLI YENİ BİR DERİN ÖĞRENME MİMARİSİ ÜRETECİNİN GELİŞTİRİLMESİ VE CİLT KANSERİ TEŞHİSİ İÇİN ETKİNLİĞİNİN GÖSTERİLMESİ

Mustafa Furkan KESKENLER

Danışman: Doç. Dr. Deniz DAL

Amaç: Bu çalışmanın öncelikli amacı evrişimli sinir ağları (CNNs) formundaki derin öğrenme mimarilerinin tüm bileşenleriyle birlikte bütünsel bir optimizasyonu için metasezgisel ve makine öğrenmesi tabanlı, yeni ve tamamen otomatik bir mimari üretici geliştirmektir. Bu yenilikçi üretici sayesinde, bir derin öğrenme mimarisinin hiperparametrelerinin, katman sayısının, türlerinin ve dizilimlerinin bütüncül bir yaklaşımla optimize edilmesi hedeflenmiştir. İkinci olarak, söz konusu üreticinin dermoskopik görüntülerden oluşan bir veri seti aracılığıyla cilt kanserinin non-invaziv teşhisi noktasındaki etkinliğinin gösterilmesi amaçlanmıştır.

Yöntem: Derin öğrenme modellerinin optimizasyonu, ilgili modellerin performansını ve etkinliğini önemli ölçüde etkileyen kritik bir süreçtir. Optimizasyon işleminin amacı, modelin doğruluğunu, genelleme kabiliyetini ve hesaplama verimliliğini maksimize eden en uygun yapılandırmayı bulmaktır. Arama uzayının büyüklüğü ve karmaşıklığı göz önüne alındığında, yeni bir derin öğrenme mimarisinin etkinliğini sıfırdan eğiterek değerlendirmek pratik bir yaklaşım değildir. Bu motivasyonla, bu çalışma kapsamında öncelikle benzetilmiş tavlama metasezgiseli kullanılarak sınırlı sayıda derin öğrenme mimarisi içeren bir veri seti oluşturulmuştur. Bu mimari veri setindeki her bir mimari, seyreltilmiş cilt kanseri veri seti ile eğitilerek bir doğruluk değeri elde edilmiş ve bu değer her bir veriye etiket olarak atanmıştır. Ardından, regresyon tabanlı bir makine öğrenmesi modeli bu mimari veri seti ile eğitilmiştir. Bu model, karşılaştığı bir mimarinin etkinliğini, mimarinin sıfırdan eğitilmesi ve ölçülmesi yerine, doğrudan tahmin etmek amacıyla kullanılmıştır. Bu sayede, yine benzetilmiş tavlama tabanlı metasezgisel bir yöntem kullanılarak, arama uzayında yeni mimarilerin keşfedilebilmesi, bir başka deyişle derin öğrenme modeli optimizasyonu, çok daha kısa sürede gerçekleştirilebilmiştir.

Bulgular: Bu tez kapsamında geliştirilen mimari üretici kullanılarak 10 farklı derin öğrenme modeli oluşturulmuştur. Bu modellerin cilt kanseri teşhisindeki etkinlikleri, HAM10000 veri seti üzerinde test edilmiştir. Modellerin performansları, doğruluk, kesinlik, duyarlılık, F1-skor ve AUC gibi beş farklı başarı ölçüm metriği kullanılarak değerlendirilmiştir. Yürütülen testlerin sonuçlarına göre, tüm modellerin ortalama başarıları %95,26 doğruluk, %95,19 kesinlik, %94,82 duyarlılık, %95,01 F1-skor ve %98,74 AUC olarak belirlenmiştir.

Sonuç: Bu tez çalışması, derin öğrenme modellerinin optimizasyonu sürecine odaklanmıştır. Bu amaçla, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı yeni bir derin öğrenme mimarisi üretici geliştirilmiştir. Ardından, bu üreticinin etkinliği cilt kanseri teşhisi problemi üzerinde gösterilmiştir. Elde edilen bulgular, önerilen üreticinin ürettiği modellerin literatürdeki benzer çalışmalara kıyasla cilt kanserini daha yüksek başarımla tespit edebildiğini ortaya koymuştur. Ayrıca, üretilen modellerin eğitim sürelerinin de mevcut derin öğrenme modellerine göre daha kısa olduğu belirlenmiştir.

Anahtar Kelimeler: Derin öğrenme, optimizasyon, hiperparametre ve mimari optimizasyonu, otomatik derin öğrenme ağı üretme, evrişimli sinir ağı, CNN.

Mayıs 2024, 111 sayfa

ABSTRACT

DOCTORAL DISSERTATION

DEVELOPMENT OF A NOVEL, FULLY AUTOMATIC AND METAHEURISTIC-BASED DEEP LEARNING ARCHITECTURE GENERATOR AND DEMONSTRATION OF ITS EFFECTIVENESS THROUGH SKIN CANCER DIAGNOSIS

Mustafa Furkan KESKENLER

Supervisor: Assoc. Prof. Dr. Deniz DAL

Purpose: The primary objective of this study is to develop a novel and fully automated architecture generator based on metaheuristic and machine learning methods for the holistic optimization of deep learning architectures in the form of convolutional neural networks (CNNs). This innovative generator aims to optimize the hyperparameters, the number of layers, layer types, and layer orderings of a deep learning architecture using a comprehensive approach. Secondly, the study aims to demonstrate the effectiveness of the proposed generator in the non-invasive diagnosis of skin cancer using a dataset of dermoscopic images.

Method: The optimization of deep learning models is a critical process that significantly impacts the performance and effectiveness of the respective models. The objective of the optimization process is to find the most suitable configuration that maximizes the model's accuracy, generalization capability, and computational efficiency. Considering the vastness and complexity of the search space, evaluating the effectiveness of a new deep learning architecture by training it from scratch is not a practical approach. Motivated by this, in the scope of this study, a dataset containing a limited number of deep learning architectures was initially generated using the simulated annealing metaheuristic. Each architecture in this architectural dataset was trained on the sparse skin cancer dataset, yielding an accuracy value, which was then assigned as a label to each instance. Subsequently, a regression-based machine learning model was trained on this architectural dataset. This model aimed to predict the effectiveness of an encountered architecture directly, instead of training and evaluating the architecture from scratch. Consequently, by employing a simulated annealing-based metaheuristic approach, the discovery of new architectures within the search space, or in other words, the optimization of deep learning models, could be achieved in a significantly shorter time frame.

Findings: In this thesis, the developed architecture generator was utilized to create 10 different deep learning models. The effectiveness of these models in skin cancer diagnosis was evaluated using the HAM10000 dataset. The performance of the models was assessed using five different success measurement metrics, including accuracy, precision, recall, F1-score, and AUC. According to the results of the conducted tests, the models achieved an average performance of 95.26% accuracy, 95.19% precision, 94.82% recall, 95.01% F1-score, and 98.74% AUC.

Results: This thesis focused on the optimization process of deep learning models. To this end, a novel deep learning architecture generator, which is fully automated, metaheuristic-based, and machine learning-driven, was developed. Subsequently, the effectiveness of this generator was demonstrated on the skin cancer diagnosis. The findings revealed that the models generated by the proposed generator could detect skin cancer with higher performance compared to similar studies in the literature. Additionally, it was determined that the training times of the generated models were shorter than those of the existing deep learning models.

Keywords: Deep learning, optimization, hyperparameter and architecture optimization, automatic deep learning network generation, convolutional neural network, CNN.

May 2024, 111 pages

İÇİNDEKİLER

KABUL VE ONAY TUTANAĞI.....	i
ETİK BİLDİRİM VE İNTİHAL BEYAN FORMU	ii
TEŞEKKÜR	iii
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vi
TABLolar DİZİNİ.....	viii
ŞEKİLLER DİZİNİ	ix
KISALTMALAR VE SİMGELER DİZİNİ	xi
GİRİŞ.....	1
KURAMSAL TEMELLER.....	6
Derin Öğrenme ve Evrişimli Sinir Ağları	6
Derin öğrenme modelleri oluşturma ve eğitme	7
Derin öğrenme katman türleri.....	8
Derin öğrenme modellerinin hiperparametreleri	9
Benzetilmiş Tavlama Yöntemi	12
Derin Öğrenme Modellerinin Optimizasyonu Çalışmaları	14
Bilgisayarlı Görü ve Sağlık Alanındaki Uygulamaları	17
Cilt Kanseri ve Teşhisi	19
Cilt Kanseri Türleri ve Teşhisinin Önemi	20
Yapay Zekâ ile Cilt Kanseri Teşhisi Literatür Çalışmaları	23
Dermoskopik görüntülerde yapay zekâ çalışmaları.....	24
Klinik görüntülerde yapay zekâ çalışmaları	26
Histopatoloji görüntülerinde yapay zekâ çalışmaları	27
Cilt Kanseri Teşhisinde Kullanılan Görüntü Temelli Diğer Yapay Zekâ Teknikleri	28
Makine Öğrenmesi Tekniklerinin Cilt Kanseri Teşhisinde Uygulanması: MLML Modeli.....	32
HAM10000 cilt kanseri veri seti.....	32
MLML mimarisinde veri ön işleme ve öznitelik çıkarma yöntemleri.....	34
Çok katmanlı makine öğrenmesi (MLML) mimarisi	35
Bulgularla ispat	39
MATERYAL VE METOT	46

Veri Önışleme.....	46
Benzetilmiş Tavlama ile Derin Öğrenme Modeli Optimizasyonu	48
Çözüm temsilinin gerçekleştirilmesi	49
Pertürbasyon	50
Çözüm temsilinden derin öğrenme modelinin elde edilmesi	54
SA ile Tam Otomatik, Metasezgisel ve Makine Öğrenmesi Tabanlı Derin Öğrenme Modeli Üretecinin Geliştirilmesi	56
Makine Öğrenmesi Yöntemleri İçin Mimari Veri Setinin Oluşturulması.....	57
Maliyet fonksiyonu	60
Derin Öğrenme Modellerinin Üretilmesi	60
Maliyet fonksiyonu	62
VGG16 modelinin SA içerisinde başlangıç çözümü olarak kullanılması	62
Makine öğrenmesi algoritmaları ile regresyon yapılarak maliyet hesaplanması.....	64
Üretilen Derin Öğrenme Modellerinin Etkinliğinin Test Edilmesi	66
Performans ölçüm metrikleri	67
ARAŞTIRMA BULGULARI VE TARTIŞMA.....	71
Optimizasyon ile Elde Edilen Deneysel Sonuçlar	74
Deneysel Çalışmalarda Üretilen Derin Öğrenme Modelleri	79
SONUÇLAR VE ÖNERİLER	84
KAYNAKLAR.....	87
ÖZGEÇMİŞ.....	98

TABLÖLAR DİZİNİ

Tablo 1. Çok Katmanlı Makine Öğrenimi (MLML) Yönteminde Kullanılan Öznitelik Çıkarma ve Veri Ön İşleme Adımlarının Ayrıntıları	35
Tablo 2. Bireysel Makine Öğrenimi Algoritmaları Kullanıldığında Ölçülen Performans Değerleri	40
Tablo 3. MLML Mimarisinin Tüm Katmanları İçin Ölçülen Performans Değerleri	42
Tablo 4. MLML Yönteminin Literatürdeki Diğer Sınıflandırma Algoritmalarıyla Performans Karşılaştırması	43
Tablo 5. Derin Öğrenme Modellerinin Optimizasyonu Süreçlerinde Kullanılan ve %3 Oranına Seyreltilmiş Veri Sayıları	47
Tablo 6. Keşfedilen Derin Öğrenme Modellerinin Eğitim ve Test Süreçlerinde Kullanılan Veri Sayıları	47
Tablo 7. Cilt Kanseri Teşhisi İçin Derin Öğrenme Algoritması Optimizasyonunda Kullanılan SA Sözde Kodu	48
Tablo 8. Çözüm Temsilindeki Değerlerin Gerçek Karşılıkları	49
Tablo 9. Pertürbasyon Yöntemine Ait Sözde Kod	52
Tablo 10. Derin Öğrenme Modeli Oluşturma Sürecine Ait Sözde Kod	55
Tablo 11. Tam Otomatik Derin Öğrenme Modeli Üreticinin (KES-DAL-GEN) Sözde Kodu	56
Tablo 12. Maliyet Fonksiyonu I Sözde Kodu	60
Tablo 13. Maliyet Fonksiyonu II Sözde Kodu	62
Tablo 14. Metasezgisel Algoritma ile Optimum Derin Öğrenme Mimarisi Keşfi İçin Çalışma Zamanı Hesaplamaları	71
Tablo 15. Çalışma Ortamının Özellikleri	72
Tablo 16. SA Yönteminde <i>Maliyet Fonksiyonunu</i> Hızlandırmak İçin Kullanılan Makine Öğrenmesi Yöntemlerinin Başarı Oranları	73
Tablo 17. Keşfedilen KES-DAL-CNN Modellerinin Eğitim ve Test Sonuçları	75
Tablo 18. Keşfedilen KES-DAL-CNN Modellerinin Literatürdeki Diğer Modellerle Başarı Karşılaştırmaları (Tüm Çalışmalarda HAM10000 Veri Seti Kullanılmıştır.)	77
Tablo 19. Literatürde Kullanılan Diğer Derin Öğrenme Modelleri ile Bu Çalışmada Elde Edilen Derin Öğrenme Modellerinin Eğitim Sürelerinin Kıyaslanması (Tablodaki Çalışmalarda Aynı Veri Seti Kullanılmıştır.)	78

ŞEKİLLER DİZİNİ

Şekil 1. Bir dizi birbirine bağlı düğümden oluşan katmanlar halinde düzenlenmiş sinir ağları örneği.....	7
Şekil 2. SA tekniğinin akış şeması.	14
Şekil 3. Biyopsi için cilt örneği alma işlemi	20
Şekil 4. a. Melanom kanseri örnek görüntüleri, b. Bazal hücreli karsinom örnek görüntüleri	22
Şekil 5. Aktinik keratoz ve intraepitelyal karsinom hastalık görüntüleri.....	22
Şekil 6. Cilt kanseri tanılarına oldukça benzeyen cilt hastalıkları görüntüleri; a. İyi huylu keratoz, b. Dermatofibrom, c. Melanositik nevi, d. Vasküler lezyonlar	23
Şekil 7. Cilt kanseri teşhisine yönelik yapay zekâ çalışmalarının yürütüldüğü görüntü türlerine dair örnekler; a. dermoskopik görüntüler, b. klinik görüntüler c. histopatoloji görüntüleri (Goyal et al., 2020).	24
Şekil 8. HAM10000 veri setindeki hastalık türleri ve sınıflandırması.....	33
Şekil 9. Hastalık türleri görüntüleri a. Melanom, b. Bazal hücreli karsinom, c. Aktinik keratoz, d. İntraepitelyal karsinom, e. İyi huylu keratoz, f. Dermatofibrom, g. Melanositik nevi, h. Vasküler lezyonlar.....	33
Şekil 10. MLML mimarisi ve iş akış şeması.....	38
Şekil 11. MLML yönteminin veri kümesi kullanım akış şeması	40
Şekil 12. MLML katmanlarının başarı performanslarının karşılaştırılması.....	42
Şekil 13. Çözüm temsili	50
Şekil 14. Pertürbasyon işlemlerinin gerçekleştirildiği örnek çözüm temsili.....	51
Şekil 15. I. Bölge pertürbasyon örneği.....	51
Şekil 16. III. Bölge Swap pertürbasyon örneği	53
Şekil 17. III. Bölge Yeni Düğüm Ekleme pertürbasyon örneği	53
Şekil 18. II. Bölge katman sayısı azaltma pertürbasyon örneği	54
Şekil 19. II. Bölge katman sayısı artırma pertürbasyon örneği	54
Şekil 20. Yenilikçi, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı derin öğrenme modeli üretici KES-DAL-GEN sisteminin genel tasarımı	56
Şekil 21. Tam otomatik derin öğrenme modeli üreticinin (KES-DAL-GEN) akış şeması	57
Şekil 22. Makine öğrenmesi yöntemleri için mimari veri setinin oluşturulması süreci iş akış şeması	58

Şekil 23. Doğruluk tahmini için kullanılan makine öğrenmesi algoritmalarının eğitimlerinde kullanılan mimari veri seti örneği.....	60
Şekil 24. Derin öğrenme modellerinin üretilmesi süreci iş akış şeması.....	61
Şekil 25. VGG16 Derin Öğrenme Mimarisi	63
Şekil 26. VGG16 modelinin çözüm temsilindeki gösterimi	64
Şekil 27. Üretilen derin öğrenme modellerinin etkinliğinin test edilmesi süreci iş akış şeması.....	67
Şekil 28. SA ile bulunan optimum çözüme ait derin öğrenme eğitim sürecini gösteren Spyder konsol ekran görüntüsü.....	73
Şekil 29. KES-DAL-CNN1 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 15 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).	79
Şekil 30. KES-DAL-CNN1 mimari çizimi	80
Şekil 31. KES-DAL-CNN1 derin öğrenme modelinin eğitim sürecindeki <i>doğruluk</i> ve <i>loss</i> değerlerinin değişimi	80
Şekil 32. KES-DAL-CNN6 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 9 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).	81
Şekil 33. KES-DAL-CNN6 mimari çizimi (Spyder konsol çizimi örneği)	81
Şekil 34. KES-DAL-CNN6 derin öğrenme modelinin eğitim sürecindeki <i>doğruluk</i> ve <i>loss</i> değerlerinin değişimi	82
Şekil 35. KES-DAL-CNN9 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 8 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).	82
Şekil 36. KES-DAL-CNN9 mimari çizimi	83
Şekil 37. KES-DAL-CNN9 derin öğrenme modelinin eğitim sürecindeki <i>doğruluk</i> ve <i>loss</i> değerlerinin değişimi	83

KISALTMALAR VE SİMGELER DİZİNİ

BHK	: Bazal Hücreli Karsinom
CAD	: Computer-Aided Diagnosis (Bilgisayar Destekli Tanı)
CNN	: Convolutional Neural Networks (Evrışimli Sinir Ağları)
DEF	: Dünya Ekonomik Forumu
FN	: False Negative (Yanlış Negatif)
FP	: False Positive (Yanlış Pozitif)
GA	: Genetik Algoritma (Genetic Algorithm)
KA	: Karar Ağacı (Decision Tree)
KES-DAL-CNN	: Keskenler & Dal Convolutional Neural Network
KES-DAL-GEN	: Keskenler & Dal Generator
KNN	: K-Nearest Neighbor (K-En Yakın Komşu)
L	: Luminance (Parlaklık)
LBP	: Local Binary Pattern (Yerel İkili Örüntü)
LR	: Lojistik Regresyon
MEL	: Melanom
MLML	: Multi-Layer Machine Learning (Çok Katmanlı Makine Öğrenmesi)
MÖ	: Makine Öğrenmesi
NB	: Naive Bayes Algoritması
NN	: Neural Network (Yapay Sinir Ağı)
RGB	: Red Green Blue (Kırmızı, Yeşil ve Mavi Renk Yelpazesi Kodu)
RO	: Rastgele Orman (Random Forest)
SA	: Simulated Annealing (Benzetilmiş Tavlama)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TN	: True Negative (Doğru Negatif)
TP	: True Positive (Doğru Pozitif)
YZ	: Yapay Zekâ

GİRİŞ

Yapay zekâ ve makine öğrenmesi, karar verme süreçlerinde sağladıkları iyileştirmeler, verimliliğe olan katkıları, kişiselleştirilmiş deneyimler sunma yetenekleri, tıbbi teşhislerde sundukları kolaylıklar, otomasyon ve güvenlik alanlarında getirdikleri önemli avantajlar nedeniyle günümüz dijital çağının vazgeçilmez bir parçası olmuştur. Yapay zekâ, bilgisayar sistemlerinin insan benzeri karar verme yetenekleri sergileyebilmesini sağlayan bir alan olarak tanımlanırken, makine öğrenmesi ise bilgisayarların veri analizi ve örüntü tanıma yoluyla öğrenmelerini sağlayan yapay zekânın alt bir alanı olarak kabul edilmektedir (Ri, Kang, & Choe, 2024). Bu alanlar, büyük veri analizi, otomasyon, sağlık hizmetleri, finans ve birçok endüstride devrim oluşturmaktadır. Derin öğrenme ise bu disiplinler içerisinde önemli bir gelişme olarak öne çıkmaktadır. Derin öğrenme, yapay sinir ağları adı verilen çok katmanlı ve karmaşık matematiksel modelleri kullanarak, veriler üzerinde otomatik olarak öznitelikler çıkarmak suretiyle sınıflandırma ve tahmin yapabilen bir makine öğrenmesi yöntemidir (Archana & Eliahim, 2024). Derin öğrenme algoritmaları, büyük veri setlerinde karmaşık ilişkileri keşfedebilme ve özniteliklerin otomatik olarak çıkarılması gibi işlemleri gerçekleştirebilme yetenekleriyle öne çıkmaktadır. Bu özellikleriyle son yıllarda bilgisayar bilimleri ve yapay zekâ alanında bir ilgi odağı haline gelmiştir. Ayrıca, görüntü, ses ve doğal dil işleme gibi yüksek boyutlu ve yapısal verilerde etkili performans sergileyebilmektedirler. Bu nedenle, görüntü ve ses tanıma, doğal dil işleme, tıbbi görüntü analizi, otonom araçlar, finansal analiz ve öneri sistemleri gibi geniş uygulama alanlarında yaygın olarak kullanılmaktadırlar. Bu uygulamalar için araştırmacılar bazen transfer öğrenme modellerini kullanmakta, bazen de sıfırdan kendileri modeller geliştirmektedirler.

Derin öğrenme modelleri sıfırdan geliştirilseler veya hazır modeller şeklinde kullanılsalar bile, yaygın kullanımlarının ve popülerliklerinin yanında bazı zorluklara sahiptir. Bu zorluklar arasında, büyük miktarda veri gereksinimi, yüksek hesaplama gücü ve zaman gereksinimi, aşırı öğrenme ve genelleme zorlukları, yüksek boyutluluk ve anlamsız çıktılar gibi sorunlar sıralanabilir (Z. Wang, Luo, Li, & Cao, 2024). Bunların yanı sıra, derin öğrenme modellerinin yüksek derecede karmaşık olmaları ve anlaşılması zor olabilen iç mekanizmalara sahip olmaları da implementasyonlarını zorlaştırmaktadır. Ayrıca derin öğrenme temelli araştırmalar genellikle kişisel deneyimlere ve uzmanlıklara bağlı olarak deneme-yanılma yöntemlerine dayanmaktadır (Knijnenburg & Willemsen, 2016; Luger & Sellen, 2016). Yüksek tecrübe gerektiren bu durum araştırmacılar için aşılması gereken zor bir süreçtir. Bu zorluklar derin öğrenme modellerinin istenilen etkinlikte ve verimlilikte kullanılamamasına neden

olmaktadır. Bu sorunları aşmak için araştırmacılar her defasında yapay sinir ağları ve derin öğrenmenin farklı bir boyutunu ele alarak geliştirmeye devam etmişlerdir. Son yıllarda belirli bir başarıya ulaşan derin öğrenme çalışmalarında optimizasyon süreci önem kazanmaya başlamıştır. Eğer derin öğrenme modelleri gerekli şekilde optimize edilirse, beklenen verimlilik ve etkinliğe ulaşılabilir. Bunun için birçok çalışma yapılmış ve derin öğrenme modelleri hiperparametrelerindeki ve mimarilerindeki bazı ayrıntılarıyla optimize edilebilmiştir. Ancak güncel birçok çalışmada belirtildiği gibi, henüz aynı anda tüm bileşenleri ile derin öğrenme modellerine yönelik bir optimizasyon gerçekleştirilememiştir (Kaveh & Mesgari, 2023). Bunun birçok sebebi olmakla birlikte en önemlileri, donanımsal limitler ve problemin imlementasyonunun zorluğudur.

$$5 \cdot 6 \cdot 5 \cdot 5 \cdot 18 \cdot \sum_{k=1}^{33} k! \cdot 6^k = 5,626 \cdot 10^{66} \quad (1)$$

Bu problemde bir çözümün hesaplanma süresi doğrudan eğitim süresine bağlıdır ve bu çalışmada ölçülen ortalama bir eğitim süresi (seyreltilmiş görüntü veri seti için) 0,9 dakikadır. (3) ile toplam eğitim süresi dakika cinsinden hesaplanmaktadır.

(4) ile (3)'de dakika olarak ifade edilen toplam eğitim süresi yıla dönüştürülmektedir.

Bu çalışmada yenilikçi, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı optimum derin öğrenme modeli üretebilen ve KES-DAL-GEN (KESkenler & DAL GENerator) isimli bir sistem geliştirilmiştir. Bu sistemde, derin öğrenme modellerinin optimizasyon süreçlerinde yer alan zorlukların aşılması için bazı yenilikçi yöntemlerden faydalanılmıştır. Öncelikle, metasezgisel olarak, literatürde optimizasyon problemleri için başarılı sonuçlar verdiği belirtilen benzetilmiş tavlama algoritması seçilmiştir (Dal & Celik, 2023). Sonra maliyet fonksiyonu, derin öğrenme algoritmasının eğitilmesi ve doğruluk oranının tespitiyle hesaplanmıştır. Oldukça zaman alan bu hesaplama sürecinde stratejik bir şekilde elde edilen çeşitli çözüm kombinasyonlarından bir mimari veri seti oluşturulmuştur. Daha sonra, geleneksel makine öğrenmesi algoritmaları bu veri setiyle eğitilerek maliyet fonksiyonu olarak kullanılmıştır. Böylece, dakikalar süren maliyet fonksiyonunun çalışma zamanı mili saniyelere düşürülmüştür. Daha sonra benzetilmiş tavlama algoritması ile optimizasyon süreci hızlı ve etkili bir şekilde tamamlanarak hiperparametreleri, katman sayısı, katman türleri ve katmanların sıralanışları optimize edilmiş derin öğrenme modelleri elde edilmiştir. Bu çalışma bildiğimiz kadarıyla derin öğrenme modellerini tüm bileşenleri ile aynı anda optimize etme girişiminde bulunan ilk çalışmadır.

Metasezgisellerle optimizasyon sonucunda oldukça verimli bir yapıya kavuşan derin öğrenme modelleri, birçok alanda uygulama potansiyeline sahiptir. Bu alanlardan önemli ve ihtiyaç duyulandan biri de sağlık sektörüdür. Sağlık sektöründe, kardiyovasküler, dermatolojik, gastrointestinal, enfeksiyon, metabolik, nörolojik/psikiyatrik, pediatrik, pulmoner ve ürogenital gibi hastalıkların teşhislerine yönelik görüntü işleme tabanlı araştırmalarda yapay zekâ destekli çalışmalar sıklıkla kullanılır. Cilt hastalıkları da yapay zekâ araştırmalarının önemli bir odak noktasıdır (Mirbabaie, Stieglitz, & Frick, 2021). Bu çalışmada, optimize edilmiş derin öğrenme modellerinin cilt kanseri teşhisi üzerindeki etkinliği gösterilmektedir. Cilt kanseri görüntülerini içeren HAM10000 veri seti bu araştırma alanında referans veri seti olma özelliğindedir ve model performansının ölçülmesi ve karşılaştırılması için önemlidir. Yapılan deneysel çalışmalarda tam otomatik olarak üretilen derin öğrenme modellerinin literatürdeki diğer çalışmalara göre daha yüksek başarı gösterdiği doğruluk, kesinlik, duyarlılık, F1-skor ve AUC metrikleri yardımıyla tespit edilmiştir. Bu çalışmanın özgün değerleri aşağıda listelenmiştir.

1. Derin öğrenme mimarisinin optimize edilmesi, hiperparametrelerin yanı sıra katman türleri, katman sıralaması ve katman sayısının da dikkate alındığı bir optimizasyon sürecini içermektedir. Bu çalışma, bildiğimiz kadarıyla derin

öğrenme mimarisinin tüm bileşenlerinin aynı anda optimize edilmesine yönelik ilk çalışmadır.

2. Otomatik olarak geliştirilen bir sistem tarafından, derin öğrenme modelleri optimum verimliliğe dayalı olarak üretilmektedir; bu da literatürdeki mevcut yaklaşımlardan farklı bir metodolojidir. KES-DAL-GEN, her seferinde yeni ve orijinal derin öğrenme modelleri oluşturabilmektedir.
3. Literatürde genellikle 3-4 parametrenin kullanıldığı görülen derin öğrenme hiperparametrelerinin optimizasyonu, bu çalışmada daha kapsamlı bir şekilde ele alınmaktadır.
4. Tüm bileşenlerin aynı anda optimize edilmesi, geleneksel makine öğrenmesi algoritmalarıyla geliştirilen yeni bir stratejiyle ele alınarak literatürde belirtilen zorlukların üstesinden gelinmiştir. Bu yaklaşım özgündür.
5. Bu çalışmada, cilt kanseri teşhisi için literatürde henüz kullanılmamış bir metasezgisel olan benzetilmiş tavlama yönteminden faydalanılmıştır.
6. Bu çalışmada, üç bölgeden oluşan toplam 42 indisli özgün bir çözüm temsili sunulmuştur. I. Bölgede yer alan ilk beş indis hiperparametreleri temsil etmekte, II. Bölgede yer alan 6. indiste katman sayısı saklanmakta ve III. bölgede yer alan son 36 indiste ise 36 adet katman, türlerine göre temsil edilmektedir.
7. Cilt kanserinin teşhisi noktasında önerilen bu yeni yöntemin başarısı, literatürdeki diğer çalışmalarla kıyaslandığında oldukça yüksektir ve beş metrikte de (doğruluk, kesinlik, duyarlılık, F1-skor, AUC) yüksek sonuçlar vererek başarısını ispatlamaktadır. Böylece, geliştirilen optimum derin öğrenme modelleri, bilgisayar destekli otomatik tanı sistemlerinde güvenle kullanılabilir seviyede başarı göstermektedir.
8. Geliştirilen yöntem, herhangi bir başka probleme yönelik derin öğrenme modelleri için de uygulanabilir ve herhangi bir uygulama alanı için otomatik olarak optimum derin öğrenme modelleri oluşturulabilir.
9. Geliştirilen tam otomatik sistem, daha az katmanlı modellerle yüksek başarı oranlarına ulaşılmasını sağlamaktadır, böylece daha basit modellerle daha iyi performans elde edilmektedir.
10. Geliştirilen sistem, eğitim süreleri açısından, literatürdeki diğer modellere göre daha az maliyetli çalışma zamanı gerektiren modeller üretebilmektedir.

Bu tezin devamı aşağıdaki gibi düzenlenmiştir. Kuramsal Temeller bölümü, konuyla ilgili literatür taramasını ve tez konusuyla ilgili temel konu ve kavramları sunmaktadır. Materyal ve Metot bölümünde materyalden ve önerilen yöntemden bahsedilmektedir. Bulgular

ve Tartışma bölümünde çalışmalarda elde edilen sonuçlar analiz edilmiş ve benzer çalışmaların sonuçlarıyla karşılaştırılmıştır. Son olarak Sonuçlar ve Öneriler bölümü, bu alanda gelecekte yapılacak çalışmalara ışık tutan bir tartışma ile tezi sonlandırmaktadır.



KURAMSAL TEMELLER

Derin Öğrenme ve Evrişimli Sinir Ağları


Derin öğrenme (Deep Learning, DL), dijital sistemlerin yapılandırılmamış, etiketlenmemiş verilere dayalı olarak öğrenmesini ve kararlar almasını sağlamak üzere yapay sinir ağlarını kullanan bir makine öğrenmesi türüdür. Derin öğrenme, son zamanlarda yapay zekâ çalışmalarında daha önce mümkün olmayan sonuçlara ulaşılmasına yardımcı olması nedeniyle, gün geçtikçe üzerinde daha fazla araştırma yapılan bir alan haline gelmektedir (Shorten & Khoshgoftaar, 2019).

Derin öğrenmede, bir bilgisayar modeli sınıflandırma görevlerini doğrudan görüntüden, metinden veya sestten gerçekleştirmeyi öğrenir. DL modelleri, bazen insan performansını aşarak daha fazla doğruluk elde edebilir. Modeller, çok sayıda katman içeren sinir ağı mimarileri ve çok sayıda etiketli veri seti kullanılarak eğitilmektedir. Derin öğrenmenin en büyük avantajı, her zamankinden daha yüksek seviyelerde tanıma doğruluğu sağlamasıdır (Xia, Zhou, & Zhang, 2022).

DL, yapay zekâ ve makine öğrenmesi alanında devrim niteliği taşıyan bir alt alanı temsil eder. CNN (Convolutional Neural Network), derin öğrenme alanında özellikle görüntü tanıma ve işleme konularında büyük öneme sahiptir. CNN'ler, sinir ağlarının bir türü olarak tasarlanmış ve özellikle görüntü tanıma, nesne tespiti, yüz tanıma, tıbbi görüntü analizi gibi alanlarda çığır açan sonuçlar elde etmiştir. CNN'lerin önemi, özellikle büyük veri setlerinden karmaşık desenleri öğrenme yeteneğinde yatar. Geleneksel sinir ağlarından farklı olarak, CNN'ler görüntü verilerinin yapısını anlamak için tasarlanmıştır. Bu yapay sinir ağı mimarisi, verilerdeki uzamsal yapıyı dikkate alır ve girdi verisini hiyerarşik olarak işler. Filtrelerin ve evrişim katmanlarının kullanımı, bir görüntünün özelliklerini belirlemek ve sınıflandırmak için son derece etkili bir yöntem sağlar (Zhang, Zuo, Chen, Meng, & Zhang, 2016).

CNN'lerin yaygın kullanımı, otomasyon, tıbbi teşhis, güvenlik sistemleri, otonom araçlar gibi birçok alanda ilerlemelere ön ayak olmuştur. Örneğin, derin öğrenme ile eğitilmiş bir CNN, tıbbi görüntülerde kanser tespiti yapabilir veya bir otonom araç, çevresindeki nesneleri tanımlamak için CNN tabanlı bir sistem kullanabilir. Bu gibi uygulamalar, CNN'nin derin öğrenme alanındaki önemini ve etkisini vurgular (Alzubaidi et al., 2021).

Çoğu derin öğrenme yöntemi sinir ağı mimarilerini kullanır, bu nedenle derin öğrenme modelleri genellikle derin sinir ağları olarak adlandırılır (Link, 2022). Şekil 1'de bir derin öğrenme modeli ve nöronların bağlantısı gösterilmiştir.



Şekil 1. Bir dizi birbirine bağlı düğümden oluşan katmanlar halinde düzenlenmiş sinir ağı örneği.

CNN'ler manuel öznitelik çıkarma ihtiyacını ortadan kaldırır, böylece görüntüleri sınıflandırmak için kullanılan özniteliklerin çıkarılması gerekmemektedir. Bu otomatik öznitelik çıkarma, derin öğrenme modellerini nesne sınıflandırma gibi bilgisayarlı görme görevleri için son derece kullanışlı hale getirmektedir (Xia et al., 2022).

Bu tez çalışmasında derin öğrenme modeli tasarımında CNN tabanlı yaklaşım kullanılmıştır. Python programlama dili ile kodlama gerçekleştirilmiş olup Keras ve Tensorflow kütüphanelerinden faydalanılmıştır.

Derin öğrenme modelleri oluşturma ve eğitme

Araştırmacıların nesne tespiti ve sınıflandırması yapmak için derin öğrenmeyi kullanmalarının en yaygın iki yolu sıfırdan eğitim ve transfer öğrenmedir.

Sıfırdan eğitim

Derin bir ağı sıfırdan eğitmek için, çok büyük etiketli bir veri kümesi toplanır ve öznitelikleri ve modeli öğrenecek bir ağ mimarisi tasarlanır. Bu, yeni uygulamalar veya çok sayıda çıktı kategorisine sahip olacak uygulamalar için iyi bir yol olarak vurgulanmaktadır. Bu yöntem daha az yaygın bir yaklaşımdır, çünkü büyük miktarda veri ve öğrenme hızı ile bu ağların eğitilmesi genellikle günler veya haftalar alır.

Transfer öğrenme

Çoğu derin öğrenme uygulaması, önceden eğitilmiş bir modele ince ayar yapmayı içeren bir süreç olan transfer öğrenme yaklaşımını kullanır. AlexNet veya GoogLeNet gibi mevcut bir ağ ile başlanır ve daha önce bilinmeyen sınıfları içeren yeni verilerle ağ beslenir. Ağda bazı ince ayarlar yaptıktan sonra, artık 1000 farklı nesne yerine yalnızca köpekleri veya kedileri kategorize etmek gibi yeni bir görev gerçekleştirilebilir. Bu aynı zamanda çok daha

az veriye ihtiyaç duyma avantajına sahiptir (milyonlarca yerine binlerce görüntüyü işleme), bu nedenle hesaplama süresi dakikalara veya saatlere düşmektedir.

Derin öğrenme katman türleri

Derin öğrenme, yapay zekâ alanında büyük bir atılım gerçekleştirerek bilgisayarlı görü, doğal dil işleme ve konuşma tanıma gibi çeşitli alanlarda dikkate değer ilerlemeler sağlamıştır. Derin öğrenme modellerinin merkezinde birden çok katmandan oluşan sinir ağları bulunur. Her katman belirli hesaplamalar yapar ve genel öğrenme sürecine katkıda bulunur (Cai, Wu, & Zhang, 2019). Bu tez çalışmasında optimizasyonu gerçekleştirilen katman yapılarına dair derin öğrenme mimarilerinde kullanılan farklı katman türleri aşağıda detaylandırılmıştır.

Giriş katmanı (InputLayer)

Giriş/girdi katmanı, model ile giriş verileri arasındaki ilk temas noktasıdır. Verilerin sinir ağına akması için bir kanal görevi görür. Girdi katmanı, ham verileri sonraki katmanlar tarafından işlenmeye daha uygun bir formata dönüştürmekten sorumludur. Örneğin, bilgisayarlı görme görevlerinde, giriş katmanı piksel değerlerini önceden işleyebilir, normalleştirebilir veya öznitelik çıkarımını geliştirmek için görüntü dönüşümleri uygulayabilir (Feng, Shen, Chen, Wang, & Li, 2020).

Evrişimli katman (Conv)

Evrişimli katmanlar, bilgisayarla görme görevlerinde esastır. Girdi verilerinden yerel öznitelikleri çıkarmak için evrişimli işlemler kullanırlar. Bu katmanlar, girdi üzerinde kayan, uzamsal bilgileri yakalayan ve öznitelikleri hiyerarşik olarak öğrenen küçük filtreler kullanmaktadır (Chen, Papandreou, Kokkinos, Murphy, & Yuille, 2016). Evrişimli katmanlar tipik olarak, modele doğrusal olmama özelliği kazandıran ve karmaşık kalıpları öğrenmesine izin veren ReLU (Düzeltilmiş Doğrusal Birim) gibi aktivasyon fonksiyonları kullanmaktadır (Nwankpa, Ijomah, Gachagan, & Marshall, 2018).

Havuzlama katmanı (MaxPooling, AveragePooling)

Havuzlama katmanları, bilgisayarla görme mimarilerinde evrişimli katmanların yanında çalışır. Öznitelik haritalarının uzamsal boyutlarını azaltarak alt örnekleme işlemleri gerçekleştirirler. Havuzlama, hesaplama karmaşıklığını azaltmaya, aşırı öğrenmeyi kontrol etmeye ve çeviri değişmezliğini geliştirmeye yardımcı olur. Yaygın havuzlama teknikleri, sırasıyla bir bölge içindeki maksimum veya ortalama değerini seçildiği maksimum havuzlama ve ortalama havuzlamayı içermektedir (Park, Park, & Kim, 2022).

Tam bağlantılı katman (Dense)

Yoğun katmanlar olarak da bilinen tam bağlantılı katmanlar, verilerdeki genel kalıpları ve ilişkileri yakalamaktan sorumludur. Geçerli katmandaki her nöronu bir sonraki katmandaki her nörona bağlayarak ağ boyunca bilgi yayılmasını sağlarlar. Tamamen bağlantılı katmanlar, sınıflandırma veya regresyon görevleri için derin öğrenme modellerinin son aşamalarında sıklıkla kullanılır. Sınıflandırma için *softmax* veya regresyon için *lineer aktivasyon* gibi aktivasyon fonksiyonları tipik olarak bu katmanların çıktılarına uygulanır (Prihatno et al., 2021; Q. Wang, Zhang, Ji, & Ran, 2020).

Bırakma katmanı (Dropout)

Bırakma katmanı, aşırı uyumu önlemek için sinir ağlarında yaygın olarak kullanılan bir düzenleme tekniğidir. Aşırı uyum, bir model eğitim verileri üzerinde iyi performans göstermeyi öğrendiğinde, ancak yeni ve görünmeyen verilere genelleme yapamadığında ortaya çıkmaktadır. Bırakma katmanı, bu sorunu çözmenin bir yoludur. Bir sinir ağında, bırakma işlemi tipik olarak eğitim sırasında gizli katmanlara uygulanmaktadır. Buradaki temel nokta, her eğitim yinelemesi sırasında katmandaki belirli bir nöron veya birim yüzdesini rastgele olarak "bırakmaktır" (görmezden gelmektir) (Choe & Shim, 2019).

Düzleştirme katmanı (Flatten)

Düzleştirme katmanı, toplam öge sayısını korurken girdi verilerini yeniden şekillendirmek için kullanılan basit bir katmandır. Genellikle bir sinir ağında evrişimli katmanlar ile tamamen bağlı (yoğun) katmanlar arasında bir geçiş olarak kullanılır. Düzleştirme katmanının amacı, görüntüler veya öznitelik haritaları gibi çok boyutlu girdi verilerini tek boyutlu bir vektöre dönüştürmektir. Bu, verilerin 1D girişi bekleyen sonraki yoğun katmanlara beslenmesine izin verir. Temelde, düzleştirme katmanı, giriş tensörünü tek bir uzun vektöre düzleştirmektedir (Anand et al., 2022).

Derin öğrenme modellerinin hiperparametreleri

Derin öğrenme modellerinde belirli bir mimari tasarım bulunmaktadır. Bu tasarım sürecinde katman sayıları, katman türleri ve katmanların hangi sıra ile bağlanacağı tespit edilmektedir. Ayrıca tasarlanan derin öğrenme modellerinde birçok hiperparametre mevcuttur. Bunlardan en önemlileri;

- hedef boyutu (target size),
- parti boyutu (batch size),
- aktivasyon fonksiyonu,

- optimizasyon fonksiyonu,
- eğitim tur sayısı (epoch)

olarak sıralanabilir. Bu hiperparametreler ağıın performansını belirlemede ve verimliliğinde oldukça önemli bir yere sahiptir (Dalli, 2022; Sun, Wu, Shang, & He, 2022).

Derin öğrenme modellerinde kullanılan dropout (bırakma) oranı, katman sayısı ve nöron sayısı gibi tasarım parametreleri, modeli oluşturan kişi tarafından belirlenir. Genellikle bu parametrelerin belirlenmesi, başlangıçta kesin ve açık bir yönerge içermez; bu seçim, problem özelliklerine, veri setine ve diğer etkenlere bağlı olarak değişebilir. Bu nedenle, bu parametrelerin seçimi model tasarımcısına bırakılmıştır. Modelin performansını belirleyen bu hiperparametreler, tasarımcının tercihinine göre şekillenen, probleme ve veri setine özgü ayarlanan değerlerdir.

Farklı hiperparametre grupları, modelin yüksek başarı elde etmesi için kullanılabilir. Bu grupların her birinin model tasarımında kullanılması genellikle uygun kabul edilir. Ancak, en uygun hiperparametre grubunun seçilmesi, karşılaşılan önemli zorluklardan biridir. Hiperparametre seçimi genellikle tasarımcının sezgisine, önceki deneyimlerine, farklı uygulama alanlarındaki başarı öykülerine, güncel eğilimlere ve model içindeki tasarım bağımlılıklarına dayanır. Son zamanlarda, problemin çözümü için en uygun hiperparametre grubunu seçmek için çeşitli teknikler geliştirilmeye çalışılmaktadır. Aşağıda bu hiperparametreler açıklanmaktadır.

Hedef boyutu

Keras kütüphanesi bu işleve sahiptir ve bu parametre *hedef boyutu* olarak adlandırılmaktadır. Bu parametre çözünürlük azaltma işlemini gerçekleştirmektedir. Girişteki görüntüyü aynı veya daha düşük çözünürlükte ağı aktarmaya yardımcı olmaktadır. Bu işlemi yaparken orijinal görüntüde nispeten veri kaybı oluşturmaktadır. Ama ağıın daha hızlı eğitilmesi ve daha hızlı karar vermesini sağlamaktadır. Görüntüden önemli değerlerin kaybolması ile hantallaşarak çalışmak durumunda kalan bir ağı arasında bu parametre ile denge sağlanmalıdır.

Parti boyutu

Derin öğrenme uygulamalarında, tüm veri setini aynı anda işlemek öğrenme sürecini hem zaman hem de bellek açısından maliyetli hale getirebilir. Çünkü her öğrenme iterasyonunda geriye yayılım (backpropagation) ve gradyan inişi (gradient descent) işlemleri gerçekleştirilerek ağırlık değerleri güncellenir ve bu işlemler veri sayısı arttıkça daha uzun sürebilir. Bu zorluğu aşmak için veri seti küçük gruplara bölünerek öğrenme işlemi bu küçük gruplar üzerinde yapılır. Bu parçalı öğrenme süreci "parti boyutu" olarak adlandırılır. Model

tasarımında belirlenen *parti boyutu* parametresi, modelin aynı anda işleyeceği veri sayısını belirler.

Çeşitli çalışmalar, verilerin gruplar halinde işlenmesinin (*parti boyutu*) loss değerini artırabileceğini, ancak zamandan tasarruf sağlayabileceğini ortaya koymuştur.

Parti boyutu değeri, genellikle $[1, \text{eğitim_kümesindeki_tüm_verilerin_sayısı}]$ aralığında bir değer alabilir. Eğer *parti boyutu* değeri 1 olarak belirlenirse, bu durum "stochastic gradient descent" ile aynı işlevi görür; yani her iterasyonda sadece bir veri üzerinde işlem yapılır.

Aktivasyon fonksiyonu

Aktivasyon fonksiyonları, modelin içine nonlineerlik ekleyen temel bileşenlerden biridir. Gizli katmanlarda, $y = f(x, w)$ formülüyle ifade edilen lineer fonksiyonun matris çarpımı ve nöron ağırlıklarının hesaplanmasının ardından elde edilen çıktı, nonlineer bir formata dönüştürülür. Derin öğrenme yöntemleri genellikle nonlineer yapıdaki problemleri çözmek için kullanıldığından, matris çarpımı sonrası elde edilen değeri nonlineer bir hale getirmek amacıyla aktivasyon fonksiyonları kullanılır. Bu fonksiyonlar, çok katmanlı yapay sinir ağlarında nonlineer dönüşüm işlemleri için temel bir rol oynar. Gizli katmanlarda geri türev alınabilmesi (gradient descent hesaplanabilmesi) için, gizli katman çıktıları bazı aktivasyon fonksiyonları ile normalize edilir. Sigmoid, tanh, ReLu, PReLu gibi aktivasyon fonksiyonlarından bazıları tercih edilebilir. ReLu genellikle en çok tercih edilen aktivasyon fonksiyonu olup, sigmoid'e göre daha hızlı öğrenmeyi destekler (Gong, Kang, & Fahroo, 2023).

Optimizasyon fonksiyonu

Öğrenme işleminin derin öğrenme uygulamalarında temel bir optimizasyon problemi olduğu vurgulanmaktadır (Mai, Lieu, Kang, & Lee, 2023). Doğrusal olmayan problemlerde optimum değeri bulmak için farklı optimizasyon yöntemleri kullanılmaktadır. Stochastic gradient descent, adagrad, adadelta, adam, adamax gibi çeşitli optimizasyon algoritmaları derin öğrenme uygulamalarında yaygın olarak tercih edilmektedir (Cho, Kwon, & Hong, 2019). Bu algoritmalar arasında performans ve hız açısından belirgin farklılıklar bulunmaktadır.

Eğitim tur sayısı

Eğitim sürecinde, verilerin tamamı aynı anda değil, belirli sayıda parçaya bölünerek kullanılır. İlk parça eğitildikten sonra, modelin başarımı test edilir ve elde edilen başarıya göre geriye yayılım ("backpropagation") yöntemiyle ağırlıklar güncellenir. Daha sonra, yeni bir eğitim kümesiyle model tekrar eğitilir ve ağırlıklar tekrar güncellenir. Bu adımlar, modelin en

uygun ağırlık değerlerini bulmak amacıyla her eğitim adımında tekrarlanır ve her bir tekrara "*eğitim tur sayısı*" denir.

Derin öğrenme bağlamında, en uygun ağırlık değerleri adım adım hesaplandığı için başlangıçta başarı düşük olabilir; ancak *eğitim tur sayısı* arttıkça başarı da artar. Ancak, belli bir noktadan sonra modelin öğrenme hızı önemli ölçüde azalır.

Modelin eğitimi genellikle uzun bir süre alır; bazı modellerin eğitimi günler hatta aylar sürebilir. Bu durum, derin öğrenme uygulamalarında oldukça yaygındır. Dolayısıyla, eğitim sürecini mümkün olduğunca kısaltmak için diğer hiperparametrelerle birlikte çeşitli stratejiler kullanılır.

Eğitim tur sayısı, problem türüne bağlı olarak değişir. Örneğin, örüntü öğrenen RNN'lerde (Recurrent Neural Network) *eğitim tur sayısı* diğer modellere kıyasla genellikle daha büyük tutulmalıdır. *Eğitim tur sayısı* arttıkça, modelin başarımı belirgin bir şekilde artar. Ancak belirli bir *eğitim tur sayısı*'ndan sonra başarı artışı çok azaldığı için eğitim bu noktalarda sonlandırılabilir. Bazen de *eğitim tur sayısı* değerinin gerekenden fazla olması aşırı öğrenmeye neden olarak modelin test verisi üzerindeki başarısının düşmesine sebep olabilmektedir.

Benzetilmiş Tavlama Yöntemi


Benzetilmiş Tavlama (Simulated Annealing, SA) yöntemi, optimizasyon problemlerini çözmek için sıklıkla tercih edilen metasezgisel yöntemlerden birisidir (Dal & Celik, 2023). Kirkpatrick ve ark., metal işlemenin tavlama prosedürüne ilham vererek SA'yı tanıtmışlardır. Tavlama prosedürü, kütlenin potansiyel enerjisinin en aza indirildiği metal parçacıklarının optimal moleküler düzenlemelerini tanımlar ve metallerin yüksek ısıya maruz kaldıktan sonra kademeli olarak soğutulmasını ifade eder. Genel olarak, SA yöntemi, metallerin tavlama işlemini taklit eden değişken sıcaklık parametresine göre yinelemeli bir hareket benimsemektedir (Netsanet, Zheng, Zhang, & Teshager, 2022).

Bir optimizasyon algoritması, etki alanındaki mevcut ve komşu nokta ile çalışan objektif (maliyet) fonksiyonlarının çıktılarını yinelemeli olarak karşılaştırır, böylece komşu nokta geçerli olandan daha iyi sonuç üretirse, bir sonraki yineleme için temel çözüm olarak kaydedilir. Aksi takdirde, algoritma daha iyi sonuçlar için daha geniş etki alanını aramadan prosedürü sonlandırır. Böylece, algoritma yerel minimumda veya maksimumda sıkışıp kalmaya eğilimlidir. Bunun yerine, SA yöntemi, tavlama işlemi için soğutma prosedürü ve Metropolis kriteri (Anita Singhrova, 2022; Ramli & Ab Rashid, 2022) olarak bilinen iki yinelemeli döngüyü işleme dahil ederek bu soruna etkili bir çözüm önermektedir. Metropolis

kriterinin arkasındaki temel fikir, yerel uç noktalara sıkışıp kalmamak adına aday çözümün alanını fazladan aramak için rastgele yürütmektir. Bu nedenle, Metropolis kriteri, mevcut adımın hareketine belirli bir dereceye kadar izin verir, hatta nesnel fonksiyonun yörüngesi potansiyel yerel maksimum nokta boyunca yakınsamaktadır.

Öte yandan, Metropolis algoritması sabit bir sıcaklık için çözüm önermektedir. Böylece, daha büyük değerler için algoritma daha geniş arama alanı gerektirir. Bunun yanı sıra, algoritmanın yinelemeli hareketi rastgele başlatıldığından, küresel maksimayı atlayabilir veya aşırı noktadan hassas olmayan yaklaşımı benimseyebilir. Aksine, daha büyük değerler için, daha büyük arama alanı gerektirir ve bu durum yerel maksimada sıkışıp kalmaya neden olabilir. Bu handikabı kaldırmak için SA, sıcaklık parametresini ve çözüm noktasını değiştirmek için iç içe geçmiş döngüleri içeren yinelemeli bir çözüm sunar. SA yönteminin hareketi, iç döngü ile yinelemeyi yürütmek için daha büyük bir sıcaklık değeri ile başlar ve hemen, mevcut iç döngüdeki en iyi nesnel fonksiyona yol açan nokta yeni aday çözüm olarak atanır. Daha sonra, dış döngü sıcaklığı artırarak ve başlangıç noktasını güncelleyerek çalıştırılır. Bu yinelemeli işlem, en düşük sıcaklık sınırına ulaşana veya önceden belirlenmiş yineleme sayısını gerçekleştirene kadar devam eder. Bu prosedürün özeti Şekil 2'deki akış diyagramı ile gösterilmiştir.

Dış döngüdeki sıcaklık değiştirme adımlarını ve iç döngünün rastgele adım boyutlarını seçmenin çok kritik olduğu unutulmamalıdır. Ayrıca, sıcaklık değişim derecesinin seçilmesi, çözeltinin kalitesi üzerinde çok önemli bir etkiye sahiptir (Al-Shahri et al., 2021). Bu engellerin önlenmesi için SA yöntemi, büyük sıcaklık değeri ile optimizasyon problemiyle ilgilenir ve objektif fonksiyon alanında çok sayıda nokta kat eder. Sonraki adımlar için, sıcaklığı kademeli olarak düşürür ve önceki iç döngüdeki yerel minimum noktayı benimseyerek arama sektörünü daraltır. Bu sayede arama alanında yerel minimum noktaları ortadan kaldırır ve ayrıca global minimum noktaya hassas bir şekilde yakınsar (Celik & Dal, 2021). Sonuç olarak, SA'nın diğer sezgisel yaklaşımlar arasında, yerel aşırı noktalardan kaçınmak için araştırmaya pratik rastgelelik sağlaması açısından çok tercih edilen bir teknik olduğu söylenebilir (Bagherian et al., 2021). Öte yandan, SA, hesaplama zamanı ile çözümün duyarlılığı arasında bir denge içerir.



Şekil 2. SA tekniğinin akış şeması.

Derin Öğrenme Modellerinin Optimizasyonu Çalışmaları

DL yöntemlerinin çeşitli uygulamalarda kullanılmasının önemi göz önüne alındığında, zayıflıkların belirlenmesi ve bu algoritmaların iyileştirilmesi makine öğrenimindeki güncel

konulardan birisidir. DL mimarilerinin öğrenme süreci, en zor makine öğrenimi zorluklarından biri olarak kabul edilmektedir. Son yirmi yılda, DL'lerin yapısını ve parametrelerini optimize etmek, araştırmacıların ana ilgi alanlarından birisi olmuştur (Darwish, Hassanien, & Das, 2020; F. Han, Jiang, Ling, & Su, 2019; Ojha, Abraham, & Snášel, 2017). DL'lerin optimizasyonu genellikle çeşitli yönlerden ele alınır: ağırlıkların optimizasyonu, hiperparametreler, mimarideki bazı detaylar, aktivasyon düğümleri vb. (Ojha et al., 2017). Fakat derin öğrenme mimarileri henüz aynı anda tüm bileşenleri ile optimize edilememiştir (Kaveh & Mesgari, 2023).

Ağırlıkları ve hiperparametreleri optimize etmek, DL mimarilerinin en önemli konularından birisidir. Aslında, DL'ler, mimari ve hiperparametreler olmak üzere iki sütun ile ayırt edilebilmektedirler. Geçmişte yapılan birçok çalışmada model eğitimi için gradyan tabanlı yöntemler kullanılmıştır. Bununla birlikte, gradyan tabanlı algoritmaların sınırlamaları nedeniyle, metasezgisel tabanlı optimizasyon algoritmalarının kullanılması ihtiyacı tespit edilmiştir (Darwish et al., 2020; F. Han et al., 2019; Ojha et al., 2017).

Bir derin öğrenme algoritmasının eğitim sürecinde zamanın çoğunu hiperparametre optimizasyonu almaktadır. Bu da modelin geliştirilme süresinin uzaması gibi bir problemi ortaya çıkarmaktadır. Buna karşılık, Han ve vd. yapmış oldukları bir çalışmada (J. H. Han, Choi, Park, & Hong, 2020), hiperparametre optimizasyonu için genetik algoritma kullanan bir yöntem önermişlerdir. Algoritma, maliyet fonksiyonunu modelin doğrulama süresi ve doğruluğu aracılığıyla ürettiğinden, algoritma hiperparametrelerin optimal değerini bulabilmektedir. Ayrıca bu çalışmada, derin öğrenmede eğitim süreci için gereken süreyi azaltmak adına genetik algoritma popülasyonlarının sayısı ayarlanmıştır. Sonuç olarak ilgili çalışmada, önerilen algoritmanın performansını değerlendirmek için, motor arızasını teşhis etmeye dayalı X, Y eksenli titreşim veri seti kullanılmıştır.

Cilt kanseri tespiti için de Han ve vd.'nin yapmış oldukları çalışmaya yakın bazı çalışmalar bulunmaktadır. Bu kapsamda Nagaoka'nın yapmış olduğu bir çalışmada isteğe bağlı olarak ayarlanması gereken ve hiperparametre adı verilen bazı parametrelerin öneminden ve ayarlanmasının güçlüklerinden bahsedilmektedir (Nagaoka, 2020). Bu çalışmada veri tabanındaki dermoskopik görüntüler GoogLeNet üzerinde eğitilmiştir. Bu çalışmada optimizasyonu gerçekleştirilen hiperparametreler random seed, optimizasyon fonksiyonu, temel öğrenme oranı, eğitim tur sayısı ve parti boyutu olarak sıralanabilir. Genetik bir algoritma kullanılarak, bu hiperparametreler, kaba kuvvet veya Bayesian optimizasyonu gibi diğer yöntemlerden daha yüksek doğrulama başarısı elde etmek için optimize edilmiştir. En yüksek doğruluk oranı %89,75 olarak ölçülmüştür. En iyi hiperparametre ayarlarının şunlar

olduğu belirtilmiştir: random seed için 2, optimizasyon fonksiyonu için RMSProp, temel öğrenme oranı için 0.0001, eğitim tur sayısı için 30 ve parti boyutu için 32. Bu çalışmada geliştirilen sistem kullanılarak, daha geniş bir hiperparametre aralığı araştırmak ve Melanom dışındaki lezyonları içeren çoklu grupları tanımlamak gibi planlardan bahsedilmektedir.

Metasezgisel tabanlı derin öğrenme optimizasyonu konusunu ele alan bir diğer çalışmada da, Alzheimer hastalığının, nüfusun yaşlanmasının en büyük zorluklarından birisi olduğundan ve hastalığın çeşitli biyobelirteçler aracılığıyla teşhisinin ve öngörülmesinin kaçınılmaz olduğundan bahsedilmektedir (Lee, Kim, Kang, Kang, & Park, 2021). Derin öğrenmenin görüntüleme teknolojileri olarak uygulanması son zamanlarda tıp endüstrisinde genişlemiş olsa da bu teknolojilerin ampirik tasarımının çok zor olduğu vurgulanmaktadır. Bu sorunun temel nedeni, Evrişimli Sinir Ağlarının (CNN) performansının, girdi veri setinin istatistiksel dağılımına bağlı olarak büyük ölçüde farklılık göstermesidir. Farklı hiperparametreler de CNN modellerinin başarısını büyük ölçüde etkilemektedir. Ağ yapısına uygun parametrelerin seçilmesinin geniş bir araştırma alanı haline geldiği ilgili çalışmada belirtilmektedir. Genetik Algoritmanın (GA), yüksek performanslı bir ağ mimarisini otomatik olarak seçmek için çok popüler bir teknik olduğunun altı çizilen çalışmada, önerilen algoritmanın performansını doğrulamak için Alzheimer hastalığının teşhisi için kullanılan bir amiloid beyin görüntü veri setinden faydalanılmıştır. Sonuç olarak, önerilen algoritmanın GA optimizasyonu içermeyen CNN'den %11,73 oranında daha iyi performans verdiği belirtilmiştir.

En sağlam ve verimli makine öğrenmesi yöntemlerinden biri olan yapay sinir ağları (NN'ler), çeşitli problemlerin çözümünde yaygın olarak kullanılmaktadır. Bununla birlikte, uygun hiperparametrelerin seçilmesi (örneğin, her bir mimarideki katman ve nöron sayısı) bu yöntemlerin doğruluğu üzerinde önemli bir etkiye sahiptir. Bu nedenle, NN hiperparametrelerini optimize etmek için birçok çalışma yürütülmüştür. Bu alanda yapılan bir çalışmada (Nikbakht, Anitescu, & Rabczuk, 2021), optimal hiperparametreleri bulmak için genetik algoritma NN'ye uygulanmıştır. Daha sonra, her katmandaki nöronların sayısı, bu yapılar aracılığıyla stres dağılımını tahmin etmek için en yüksek doğruluğa erişmek adına optimize edilmiştir.

Thakare & V'nin (2022) çalışması, (Thakare & V, 2022) tarım alanlarındaki zararlıları tespit etmek için otomatik bir haşere tespit modülü önermektedir. Bu amaçla hibrit optimizasyon kontrollü derin öğrenme modeli kullanılmıştır. Çalışmada Kablosuz Sensör Ağı (WSN) aracılığıyla veri toplanmakta ve fraksiyonel karınca arı kolonisi optimizasyonu (FABC) algoritmasıyla düğümler seçilmektedir. Elde edilen görüntü verileri, çeşitli öznetelik

ıkarma yntemleri ile iřlenmekte ve MFGHO optimizasyon algoritması kullanılarak Deep-CNN'nin ağırlıkları ayarlanmaktadır. Performans ltlerine gre yapılan analizler, nerilen modelin yksek doęruluk, duyarlılık ve zgllk deęerleriyle zararlıları tespit etmede etkili olduęunu gstermektedir. Bu model, tarım alanlarında uygun maliyetli pestisitlerin daha iyi seimi iin kullanılabilir. Analiz, FABC optimizasyonu tabanlı veri toplama stratejisini kullanan bu sınıflandırıcının, mevcut yntemlere kıyasla daha yksek olan %94,3482 doęruluk ve %93,3247 duyarlılık elde ettięini kanıtlamaktadır.

DL'lerin eęitimi NP-hard bir optimizasyon problemi olduęundan, metasezgisel algoritmaların kullanımıyla parametre optimizasyonları nemli lde ilerleme kaydetmiştir. Bir optimizasyon problemi olarak, metasezgisel algoritmalar DL bileřenlerinin (hiperparametre, ağırlıklar, nron sayısı gibi) optimal tahminini gerekleřtirebilmektedir (F. Han et al., 2019). DL'leri optimize etmede hata minimizasyonu, aę genellemesi ve model basitleřtirme gibi birden fazla hedefin varlıęı, ok amalı metasezgisel algoritmalara olan ihtiyaı artırmıştır. DL mimarilerini optimize etmek iin metasezgisel algoritmaları kullanmak hala olduka zordur ve daha fazla arařtırmaya ihtiya vardır. DL'leri eęitmek iin metasezgisel algoritmaları kullanmak ęrenme srecini iyileřtirir. Bu, algoritmanın doęruluęunu artırmaya ve yrtme sresini de azaltmaya yaramaktadır (Kaveh & Mesgari, 2023).

Yukarıdaki alıřmalar incelendięinde, farklı uygulama alanlarına ynelik geliřtirilen derin ęrenme modellerinin hiperparametrelerinin ve mimarilerindeki bazı detaylarının optimizasyonunun ele alındıęı grlmektedir. Derin ęrenme modelinin tm bileřenlerinin aynı anda optimize edildięi bir alıřma literatrde bulunamamıştır. Bu alıřmada bu eksiklięin giderilmesi hedeflenmektedir.

Bilgisayarlı Gr ve Saęlık Alanındaki Uygulamaları

Gnmz toplumunda bilgisayarın bir ara olarak iřyerlerinde, akademik kurumlarda, eřitli tesislerde ve evlerde kullanımının olduka yaygın hale geldięi grlmektedir (Akinbinu & Mashalla, 2014). Bilgisayar sistemlerinin yayılmış olduęu bu geniř platformlar ierisinde saęlık uygulamaları da olduka nemli bir yere sahiptir. Saęlıkta dijitalleřme kavramıyla birlikte Endstri 4.0 ile hayatımıza giren Saęlık 4.0 ve uygulamalarına artık daha sık rastlanmaktadır. Saęlık uygulamalarının daha verimli hale getirilmesi amacıyla toplumun yararına sunmak zere teknolojik ve bilimsel geliřmelerin bu uygulamalara dahil edilmesiyle Dijital Saęlık kavramı ortaya ıkmaktadır.

Saęlık ve Dijital Saęlık uygulamalarında da kullanılmakta olan Yapay Zek (YZ), analiz yapabilme ve ęrenebilme gibi akıllı davranıř yeteneęine sahip bilgisayar ve bilgisayar

yazılımı olarak tanımlanabilir. YZ uygulaması, hastalıkların teşhisiyle ilgili avantajlar sağlamaktadır. Bu avantajları uygulamaya geçirmek isteyen Gunn tarafından YZ teknolojisi cerrahi alanda, ilk olarak 1976 yılında bilgisayar analiziyle akut karın ağrısının teşhis olasılığının araştırılması sırasında kullanılmıştır.

YZ, DEF tarafından gelişmekte olan en önemli teknolojilerden biri olarak adlandırılmakta ve YZ uygulamalarının tüketiciler için giderek daha faydalı hale geleceği ifade edilmektedir (Cilhoroz & Isik, 2021). Ek olarak, tıbbi bilgilerin klinik olarak yorumlanmasının bilişsel olarak zorlayıcı bir iş olduğu belirtilmektedir (Singh et al., 2021). Tıp uzmanlarının mevcut süresi genellikle sınırlıdır (Rosen et al., 2018; Wears & Berg, 2005) ve buna bağlı olarak geç tanı ve tedaviye başlama sonucu hastalıklar gelişmekte ve hasta dinamikleri zamanla değişebilmektedir (Eigner, Bodendorf, & Nilmini, 2019; Zwaan & Singh, 2015). Bu kısıtlar tanılamayı son derece zor ve karmaşık bir süreç haline getirmektedir (Baerheim, 2001; Samhan, Crampton, & Ruane, 2018). Bununla birlikte, doğru bir tanı süreci, zamanında tedaviyi sigortalamak ve böylece güvenli ve etkili hasta bakımı elde etmek için merkezi bir öneme sahiptir (Balogh, Miller, & Ball, 2015; N. R. J. Frick, Möllmann, Mirbabaie, & Stieglitz, 2021). Sağlık sistemi dinamik ve değişen bir ortamdır (Menschner, 2011) ve tıp uzmanları değişen sorumluluklar ve sık sık kesintilerle sürekli olarak yeni zorluklarla karşı karşıyadır (Rosen et al., 2018; Wears & Berg, 2005). Bu nedenle son yirmi yılda sağlık alanında YZ'ye olan ilgide bir artış olduğu görülmektedir (Ramesh, Kambhampati, Monson, & Drew, 2004).

Bu kapsamda YZ, kanser gibi hastalıkları daha doğru ve erken aşamalarında saptamak için son zamanlarda artan bir ilgiyle kullanılmaktadır (Akalın & Veranyurt, 2020; Büyükgöze & Dereli, 2019). Son çalışmalar, genel olarak sağlık hizmetlerinde (N. R. Frick, Brünker, Ross, & Stieglitz, 2021; Guoguang Rong, Mendez, Assi, Zhao, & Sawan, 2020; F. Jiang et al., 2017) veya belirli klinik alanlarda YZ uygulamasını öne sürmektedir (Rauschert, Raubenheimer, Melton, & Huang, 2020). YZ uygulamalarının öneminin anlaşılması açısından bu çalışmalara örnek olarak Amerikan Kanser Derneği'nin açıklaması gösterilebilir. Açıklamaya göre, mamogram alanındaki mevcut tanı yöntemleri yanlış sonuç vermekte, bu da sağlıklı 2 kişiden 1'inin kanser olduğunu söylemektedir. YZ kullanımı, mamogramların %90'ı aşan doğrulukla 30 kat daha hızlı gözden geçirilip tercüme edilmesini sağlayarak gereksiz biyopsilere olan ihtiyacı azaltmaktadır (C.U.A., 2016). Diğer taraftan sağlık harcamalarının artarak devam ettiği ve 2050 yılına kadar mevcut büyüme oranlarında gayri safi yurtiçi hasılanın %30'unu aşacağını tahmin edildiği (Orszag & Ellis, 2007) göz önüne alındığında YZ'nin gereksiz

biyopsi ihtiyacını azaltıcı, süreci hızlandırıcı ve maliyeti oldukça düşürücü niteliklerinin önemi daha iyi anlaşılmaktadır.

Oldukça öneme sahip bu alanda yürütülen çalışmalar incelendiğinde, sağlık hizmetleri ve hastalık tanılama da dahil olmak üzere mevcut pratik uygulamaların belirli bir görevi yürütmekle sınırlandırıldığı (Batin, Turchin, Sergey, Zhila, & Denkenberger, 2017) ve genellikle makine öğrenimi algoritmaları kullanılarak geliştirildiği görülmektedir (Knijnenburg & Willemsen, 2016; Luger & Sellen, 2016). Bu yöntemlerden en sık kullanılanları, yapay sinir ağları, destek vektör makinesi, en yakın komşu, rastgele orman, karar ağacı, lojistik regresyon, naive bayes, ayrık analiz, evrişimli sinir ağı, derin öğrenme modelleri, tekrarlayan sinir ağı algoritmaları olarak sıralanabilir. Literatürdeki uygulamalara bakıldığında görüntülere dayalı kardiyovasküler, dermatolojik, gastrointestinal, enfeksiyöz, metabolik, nörolojik/psikiyatrik, pediatrik, pulmoner ve ürogenital alanlarında makine öğrenmesi algoritmalarına dayanan yapay zekâ (bilgisayarlı görü) çalışmalarının yürütüldüğü görülmektedir (Mirbabaie et al., 2021).

Cilt Kanseri ve Teşhisi

Cildimiz vücudumuzdaki en büyük organlardan biridir ve önemli birçok görevi vardır. İç organları saran derinin görevlerinin başında şunlar sıralanabilir: fazla su ve sıvı kaybını önlemek, yaralanmalara karşı vücudumuzu korumak ve vücudun D vitamini elde etmesine yardımcı olmak (Koçak, 2021). Cildimiz aynı zamanda mikroorganizmalara ve ultraviyole (uv) ışınlarına karşı vücudumuzu korumaktadır. Ayrıca vücut sıcaklığını da kontrol etmektedir.

Tüm bu önemli görevleri yerine getirirken vücut derisi, birçok nedenden dolayı ciltte oluşan kötücül (malignant) büyümelere bağlı olarak kanser hastalığına yakalanabilir. Bu kanser türüne cilt veya deri kanseri adı verilmektedir. Cilt kanseri tüm kanserler içinde en yaygın görülen kanserler arasındadır (Koçak, 2021). Her kanser türünde olduğu gibi cilt kanserinde de erken tanı oldukça önemlidir. Tıp alanındaki yoğunluk göz önüne alındığında erken tanı için pratik bir ön tanı yöntemine ihtiyaç duyulduğu açıktır. Günümüzde yapay zekâ teknolojisinde varılan nokta göz önüne alındığında bu ihtiyacın yapay zekâ teknolojisine sahip akıllı bir sistem tarafından karşılanabileceği ön görülmektedir. Burada dikkat edilmesi gereken husus cilt kanseri teşhisinde kullanılacak olan yapay zekâ teknolojisinin oldukça yüksek başarı oranıyla karar verebilmesi gerekliliğidir.

Cilt kanserinde ayırt edilmesi gereken farklı türler mevcut olup yapay zekânın bu türleri ayırt etmesi oldukça güç bir durum olarak karşımıza çıkmaktadır. Literatürdeki çalışmalar incelendiğinde cilt hastalıkları içerisinde kanser türü olanların ayrımı ile kanser türleri

arasındaki ayrımların yapıldığı yapay zekâ tanı uygulamalarına rastlanmaktadır. Cilt Kanseri Vakfının raporu incelendiğinde bu alandaki tanı yöntemlerinde yapay zekâyâ olan ihtiyacın ne denli yüksek olduğu anlaşılmaktadır. İlgili raporda cilt kanserinin küresel görülme sıklığının artmaya devam ettiği ve 2019 yılında Amerika Birleşik Devletleri'nde 192.310 Melanom vakasının olacağının tahmin edildiği belirtilmektedir (In, 2019).

Mevcut tanı için kullanılmakta olan tıbbi uygulamada dermatologlar dermoskopi ile polarize ışık büyütme yardımıyla hastaları görsel muayene ile muayene etmektedirler. Tıbbi tanı genellikle hastanın geçmişine, etnik kökenine, sosyal alışkanlıklarına ve güneşe maruz kalmasına bağlıdır. Şüphe duyulan lezyonlar bir laboratuvar ortamında biyopsilenir, kalıcı parafin bölümleri olarak işlenir ve bir tanı koymak için bir patolog tarafından temsili cam slaytlar olarak incelenir. Şekil 3'de biyopsi için cilt örneği alma işlemi gösterilmektedir.



Şekil 3. Biyopsi için cilt örneği alma işlemi (Erdil, 2021)

Mevcut durumda, kısıtlar ve yetersizlikler nedeni ile son zamanlarda, cilt kanseri tanısı için YZ özellikli bilgisayar destekli tanı çözümleri geliştirilmesine büyük ilgi duyulmaktadır. Cilt kanserlerinin görülme sıklığının artması, artan nüfus arasında farkındalığın düşük olması ve yeterli klinik uzmanlık ve hizmetlerin eksikliği nedenleri ile bu alanda klinisyenlere yardımcı olmak için yapay zekâ sistemlerine olan ihtiyacın aciliyet taşıdığı belirtilmektedir (Goyal, Knackstedt, Yan, & Hassanpour, 2020).


Cilt Kanseri Türleri ve Teşhisinin Önemi

Cilt kanserinin farklı türleri bulunmaktadır. Cilt kanseri tüm kanserler içinde en yaygın görülen kanserler arasında sayılmaktadır. Ülkemizde cilt kanseri türlerinden biri olan Melanom vakalarının, son 30 yılda %237 oranında artış gösterdiği görülmüştür (Gazioğlu, 2021). Melanom, cilt kanserleri içerisinde en az sıklıkla rastlanana (%2'den azı) olmasına rağmen en riskli cilt kanseri türüdür. Diğer organlara yayılım gösteren Melanom, tüm cilt kanseri ölümlerinin çoğunluğunu oluşturmaktadır. Melanom dışındaki cilt kanserleri grubunda yer alan bazal ve yassı kanserler arasında daha çok BHK vakalarına denk

gelmektedir. Amerika’da her yıl 1 milyon yeni vaka görülürken bu oran ülkemizde her 100 bin erkekte 1,9, her 100 bin kadında ise 1,3 görülme sıklığındadır. Cilt kanserlerinde yaşam kaybı oranı ise her 100 hastada 1 şeklindedir (Goyal et al., 2020).

En son istatistiklere göre, 2018 yılında Amerika Birleşik Devletleri’nde 91.270, 2019 yılında da 192.310 yeni Melanom vakasının teşhis edileceği tahmin edilmektedir (Society, 2018). Melanom oluşum oranlarının ve bu hastalığın ölüm sonucunun önümüzdeki on yıllarda artması beklenmektedir (Nikolaou & Stratigos, 2014). Son rapor, 2008’den 2018’e kadar, her yıl yeni Melanom vakası tanısında %53’lük bir artış olduğunu göstermektedir (Society, 2008). Bu kanser türü, uygun tedavinin seçilmesiyle erken evrelerinde teşhis edilebilirse (Habib Safigholi, Meigooni, & Song, 2017; H. Safigholi, Song, & Meigooni, 2015), hayatta kalma oranlarının çok umut verici olduğu vurgulanmaktadır (Ouhib, 2015). Aksi takdirde, bir hastanın öngörülen 5 yıllık sağ kalım oranının %99’dan %14’e düşeceği belirtilmektedir (Brinker, 2018; Esteva et al., 2017). Ayrıca Melanom dışı kanser türünde, 1994 ile 2014 yılları arasında yeni vakaların tanısında %77’ye varan ciddi bir artış olmuştur. Bazal hücreli karsinom, ölümle sonuçlanan Melanom dışı cilt kanserinin en yaygın türüdür. 3000 kişi her yıl bu kanser türünden dolayı hayatını kaybetmektedir (Mohan & Chang, 2014). Bu nedenle, daha kötüye gitmesini önlemek ve daha iyi prognoz şansı vermek için farklı cilt kanseri türlerinin birincil muayenesi ve tespiti için giderek artan bir talep olduğu açıklanmaktadır (Nikolaou & Stratigos, 2014). Bir klinisyenin Melanomu saptamasının genellikle yolu, düşük kesinliğe sahip görsel ayrıntıları incelemektir (Lindelöf & Hedblad, 1994; Morton & Mackie, 1998). Öte yandan dermoskopi, dermatologların çıplak gözle görülemeyen özellikleri tespit etmelerini sağlayan derinin yüksek çözünürlüklü bir görüntüsünü yakalayabilen invazif olmayan bir tekniğin uygulanmasıdır (Argenziano, 2003). Ancak kesine yakın sonuç için biyopsi alınması ve incelenmesi gerekmektedir. Cilt kanseri türleri aşağıda açıklanmaktadır.

BHK en sık karşılaşılan cilt kanseri türüdür. Belirti ve nitelikleri genellikle düz, sert, bulunduğu bölge soluk renkli veya en küçük darbeye dahi kolay kanayabilen küçük, tümsekli, pembe veya kırmızı, şeffaf, parlak, inci büyüklüğünde şişlikler olarak açıklanabilir. Ortası çökük ve alanı mavi, siyah veya kahverengi renktedir. Büyük bazal hücreli karsinomların kabuklu veya yayılan bir alana sahip olduğu gözlenmektedir. Melanom ve BHK örnek görüntüleri Şekil 4’de gösterilmektedir.



Şekil 4. a. Melanom kanseri örnek görüntüleri, b. Bazal hücreli karsinom örnek görüntüleri


Tez kapsamında kullanılan veri seti içerisinde de bulunan yaygın deri hastalıklarından olan aktinik keratoz ve intraepitelyal karsinom hastalıkları cilt kanseri türlerine oldukça benzemektedirler ve bu aşamada tespit edildiklerinde kanser riski oluşmadan tedavi imkânı elde edilebilmektedir. Şekil 5’de bu hastalıklara dair örnek görüntüler verilmektedir.



Şekil 5. Aktinik keratoz ve intraepitelyal karsinom hastalık görüntüleri

Cilt kanseri tanılarına oldukça benzeyen cilt hastalıkları aşağıda listelenmiştir ve örnek görüntüler Şekil 6’da gösterilmiştir.

- İyi Huylu Keratoz
- Dermatofibrom
- Melanositik Nevi
- Vasküler lezyonlar



Şekil 6. Cilt kanseri tanılarına oldukça benzeyen cilt hastalıkları görüntüleri; a. İyi huylu keratoz, b. Dermatofibrom, c. Melanositik nevi, d. Vasküler lezyonlar


Yapay Zekâ ile Cilt Kanseri Teşhisi Literatür Çalışmaları

Dermoskopinin en önemli sınırlamalarından ikisi öznellik ve kapsamlı eğitim gereksinimidir. Dermatologlar tarafından yukarıda belirtilen sorunların üstesinden gelmek için kullanılabilecek bilgisayar destekli tanı (CAD) araçlarının geliştirilmesinde araştırma topluluğu tarafından büyük bir çaba sarf edilmiştir (Akalin & Veranyurt, 2020; Guoguang Rong et al., 2020; F. Jiang et al., 2017). CAD sistemlerinde makine öğrenmesi yöntemleri sıklıkla kullanılmaktadır (Acharya, 2018; G. Litjens, 2016; G. Wang, 2018). Bu sistemler bir dizi adımları izlemektedir:

- görüntü ön işleme,
- lezyon segmentasyonu,
- öznitelik çıkarma,
- öznitelik seçimi (isteğe bağlı) ve
- sınıflandırma.

Yapay zekâ ile cilt kanseri teşhisi çalışmaları incelendiğinde üç farklı görüntü türü üzerinde çalışmaların gerçekleştirildiği görülmektedir. Dermoskopik görüntülerle, klinik görüntülerle ve histopatoloji görüntüleriyle cilt kanseri teşhisine yönelik yapay zekâ

çalışmaları yürütülmüştür (Goyal et al., 2020). Şekil 7'de bu görüntülere ait örnekler verilmiştir.



Şekil 7. Cilt kanseri teşhisine yönelik yapay zekâ çalışmalarının yürütüldüğü görüntü türlerine dair örnekler; a. dermoskopik görüntüler, b. klinik görüntüler c. histopatoloji görüntüleri (Goyal et al., 2020).

Dermoskopik görüntülerde yapay zekâ çalışmaları

Dermoskopi, cilt lezyonlarının yüksek kaliteli büyüteç ve polarize edilebilir aydınlatma sisteminden oluşan bir dermatoskop cihazı ile incelenmesidir. Dermoskopik görüntüler, yüksek çözünürlüklü dijital tek lens refleksi veya akıllı telefon kamera ekleriyle yakalanır. YZ algoritmaları için dermoskopik görüntülerin kullanımı, Şekil 7'de gösterildiği gibi, farklı iyi huylu ve kanserli cilt lezyonlarından oluşan halka açık birçok büyük dermoskopik veri kümesinin piyasaya sürülmesinden bu yana çok popüler bir araştırma alanı haline gelmiştir. Aşağıda dermoskopik cilt lezyon veri kümeleri kullanılarak lezyon tanısı üzerine yürütülmüş birden fazla yapay zekâ çalışması detaylandırılmıştır.

Haenssle ve arkadaşlarının yapmış olduğu bir çalışmada (Haenssle, 2018) 100.000'den fazla iyi huylu lezyon ve Melanom görüntüsünden oluşan büyük bir dermoskopik veri kümesi üzerinde derin öğrenme yöntemi InceptionV4 eğitilmiş ve derin öğrenme yönteminin performansı 58 dermatologla karşılaştırılmıştır. Sonuçlar incelendiğinde 75 iyi huylu lezyon ve 25 Melanom görüntüsünün bulunduğu 100 adet dermoskopik görüntü içeren test setinde

dermatologların ortalama %86,6 *duyarlılık* ve %71,3 *özgüllük* değerine, derin öğrenme yönteminin ise %95 *duyarlılık* ve %63,8 *özgüllük* değerine sahip olduğu anlaşılmıştır.

Tschandl ve arkadaşlarının gerçekleştirdiği bir çalışmada (P. Tschandl, 2019b) pigmentsiz cilt kanserlerinin teşhisi için 7895 dermoskopik ve 5829 yakın çekim lezyon görüntülerinin birleşik veri kümesinde InceptionV3 ve ResNet50 olarak bilinen popüler derin öğrenme mimarileri kullanılmıştır. Performans, deneyime göre üç gruba ayrılan 95 dermatologla karşılaştırılmıştır. Derin öğrenme algoritmalarının, insan uzmanlarla eşit doğruluk elde ettiğinin gözlemlendiği çalışmada, kanser başlangıcı ve orta seviye kanser durumlarında ise dermatolog gruplarının doğruluk oranının aşıldığı belirtilmiştir.

Codella ve çalışma arkadaşları (N. C. Codella, 2017) ISIC-2016 veri kümesinde derin öğrenme algoritmalarından oluşan bir yöntem geliştirmiş ve bu yöntemin performansını 100 cilt lezyonunun iyi huylu veya kötü huylu olarak sınıflandırılması için 8 dermatologla karşılaştırmışlardır. İlgili yöntemin, dermatologların %70,5 *doğruluk* ve %59'luk *özgüllük* değerlerine karşılık ortalama olarak %76 *doğruluk* ve %62 *özgüllük* oranları ile dermatologların başarısını geride bıraktığı vurgulanmıştır.

Başka bir çalışmada (Brinker, 2019b) on iki Alman üniversite hastanesine gelen 157 kurul sertifikalı dermatoloğun performansı, 80 nevi ve 20 Melanom olgusunun yer aldığı 100 dermoskopik görüntü için derin öğrenme yöntemi (ResNet50) performansı ile karşılaştırılmıştır. Dermatologların kişisel tanılarıyla dermoskopik veri kümesinde genel *duyarlılık* %74,1 ve *özgüllük* %60,0 oranları elde edilirken, derin öğrenme yöntemi %69,2 *özgüllük* ve %84,2 *duyarlılık* elde etmiştir.

Bir diğer çalışmada (Maron, 2019) derin öğrenme yönteminin (ResNet50) *kesinliğini* ve *özgüllüğünü*, nevi, Melanom, iyi huylu keratoz, BCC ve SCC (ayrıca güneş keratozu ve intraepitelyal karsinom) içeren cilt lezyonlarının çok sınıflı sınıflandırılması için 112 Alman dermatologdan faydalanılmış ve derin öğrenme yönteminin önemli düzeyde dermatologları geride bıraktığı belirtilmiştir.

Tschandl ve arkadaşları (P. Tschandl, 2019a) ISIC 2018 yarışmasına katılan hem yapay zekâ algoritmalarının (toplamda 139) hem de 511 uzmanın ortalama performansını 1511 görüntüden oluşan bir test veri setinde karşılaştırmışlar ve sonuç olarak, yapay zekâ algoritmalarının uzmanlardan daha doğru cilt kanseri teşhisi elde ettiğini bildirmişlerdir.

Dermoskopik görüntüler üzerinde gerçekleştirilen başka bir çalışmada (Haenssle, 2020) InceptionV4'e dayanan derin öğrenme mimarisi ve dermatolog görüşleri 60 iyi huylu ve 40 kötü huylu lezyon görüntüsünden oluşan veri seti üzerinde karşılaştırılmıştır. Derin

öğrenme algoritmasıyla sırasıyla %95 ve %76,7 *duyarlılık* ve *özellik* oranı elde edilirken, dermatologlar tarafından sırasıyla %89 ve %80,7 *duyarlılık* ve *özellik* oranlarının elde edildiği belirtilmiştir.

Klinik görüntülerde yapay zekâ çalışmaları

Klinik görüntüler, Şekil 7'de gösterildiği gibi, uzaktan muayene ve hasta tıbbi kayıtlarına kaydedilmek üzere mobil kameralarla farklı cilt lezyonlarından rutin olarak elde edilmektedir. Klinik görüntüler değişken arka planlara, parlaklık ve renge sahip farklı kameralarla yakalandığından, bu görüntüler dermoskopik görüntülere kıyasla farklı özellikler taşımaktadır. Aşağıda klinik görüntülere dayalı ve öne çıkan bazı yapay zekâ çalışmaları açıklanmıştır.

Brinker ve arkadaşları gerçekleştirdikleri çalışmalarında (Brinker, 2019a) 80 adet nevi olgu ve 20 adet biyopsisi doğrulanmış Melanom olgusunun 100 klinik cilt lezyon görüntüsü test çalışması için 145 dermatolog ve bir derin öğrenme yönteminin (ResNet50) performansını karşılaştırmışlar ve dermatologlar genel olarak %89,4 *duyarlılık*, %64,4 *özellik* ve 0,769 AUC değerlerine ulaşırken, derin öğrenme yönteminin aynı *duyarlılık* oranını ve %69,2 oranıyla daha iyi *özellik* skorunu elde ettiği belirtilmiştir.

Başka bir çalışmada (Yang, 2018) SD-198 veri kümesindeki ABCD kuralından esinlenerek klinik cilt lezyonu tanısı gerçekleştirilmiştir. Önerilen yöntemlerin performansını derin öğrenme yöntemleri ve dermatologlarla karşılaştırmışlardır. Elde edilen bulgularda %53,35'lik en iyi performans gösteren derin öğrenme yöntemine (ResNet) kıyasla %57,62 *doğruluk* oranı aldığı belirtilmiştir. Klinisyenlerle karşılaştırıldığında, sadece cilt hastalığında önemli deneyime sahip kıdemli klinisyenler ortalama %83,29 *doğruluk* oranına ulaşmıştır. Bu çalışmada uygulanan yapay zekâ yöntemi dermatologların gerisinde kalarak başarısız sonuç üretmiştir.

Fujisawa ve arkadaşları (Fujisawa et al., 2019) hem kötü huylu hem de iyi huylu durumlar dahil olmak üzere 14 tanının 6009 klinik görüntüsü üzerinde derin bir öğrenme yöntemini test etmiştir. Derin öğrenme algoritması, 140 görüntülü bir veri kümesinde 13 kurul sertifikalı dermatolog (%59,7) ve dokuz dermatoloji stajyerinin (%41,7) performansından daha üstün olan %76,5 tanısal *doğruluk* elde etmiştir.

Klinik görüntüler üzerinde gerçekleştirilen diğer bir çalışmada (S. S. Han et al., 2018) bir Asan eğitim veri kümesinde, bir MED-NODE veri kümesinde ve atlas sitesi görüntülerinde 12 cilt hastalığının klinik görüntülerini sınıflandırmak için derin öğrenme mimarisi (ResNet-152) eğitilmiş ve bir Asan test setinde ve bir Edinburgh veri kümesinde (Dermofit) test

edilmiştir. Algoritmanın performansı, Asan test veri kümesinden (260 görüntü) ve Edinburgh veri kümesinden (220 görüntü) rastgele seçilen 480 görüntüde 16 dermatolog ekibiyle eşitken, yapay zekâ sistemi BHK tanısında dermatologları geride bırakmıştır.

Histopatoloji görüntülerinde yapay zekâ çalışmaları

Cilt kanseri tanısı, doku biyopsisinin mikroskopik değerlendirmesine dayanarak dermatopatologlar tarafından doğrulanır. Derin öğrenme çözümleri, tüm slayt görüntüleme ile dijital patoloji alanında başarılı olmuştur. Deri lezyonlarının histopatoloji görüntülerinin örnekleri Şekil 7'de gösterilmiştir. Bu teknikler, deri, akciğer ve meme gibi kanserlerin sayısını teşhis etmek için biyopsi doku örneklerinin sınıflandırılması için kullanılır. Bu bölümde cilt kanserine özgü dijital histopatolojide kullanılan yapay zekâ yöntemlerine yönelik çalışmalara değinilmiştir.

Cruz-Roa ve arkadaşları yaptıkları çalışmalarında (Cruz-Roa, Arevalo Ovalle, Madabhushi, & González Osorio, 2013) 1417 cilt histopatolojisi görüntüsü üzerinde BHK ve normal doku desenleri arasında ayırım yapmak için derin öğrenme mimarisi kullanmışlardır. Derin öğrenme yöntemini geleneksel makine öğrenimi ile öznetelik torbası, kurallı ve Haar tabanlı dalgacık dönüşümü de dahil olmak üzere öznetelik tanımlayıcılarıyla karşılaştırmışlardır. Derin öğrenme mimarisi, F1-skor'da %89,4 ve dengeli doğrulukta %91,4'e ulaşarak uygulanan yöntem açısından geleneksel yaklaşımlara göre üstünlüğünü ortaya koymuştur.

Başka bir çalışmada (Hekler et al., 2019) Melanom ve nevi sınıflandırmasında patologların performansını karşılaştırmak için derin öğrenme yöntemi (ResNet50) kullanılmıştır. Derin öğrenme modeli 595 histopatoloji görüntüsü (300 Melanom ve 295 nevi) içeren veri kümesi üzerinde eğitilmiş ve 100 görüntü üzerinde test edilmiştir. Histopatolog ile toplam uyumsuzluğun Melanom için %18, nevi için %20 ve tam görüntü kümesi için %19 olduğu belirtilmiştir.

Xie ve arkadaşları (Xie, 2019) 2008'den 2018'e kadar 1321 hastanın 2241 histopatolojik görüntüsünden oluşan büyük bir veri kümesini tanıtmıştır. Melanom ve nevi'nin farklı büyütme ölçeklerinde sınıflandırılmasını test etmek için 2241 histopatolojik görüntüden oluşturulan 9,95 milyon yama üzerinde VGG19 ve ResNet50 adlı iki derin öğrenme mimarisi kullanmışlardır. Yaptıkları deneylerde Melanom'un ortalama olarak *F1-skor* %89, *kesinlik* %92 ve *özgüllük* %94 ile Nevi'den ayırt edilmesinde yüksek doğruluk oranlarına erişildiğini açıklamışlardır.

Bir diğerk çalışmada (Y. Q. Jiang et al., 2020) BHK'nin tespiti için akıllı telefon tarafından yakalanan dijital histopatoloji görüntülerinde (MOI) derin öğrenme algoritmasının kullanılması önerilmiştir. Algoritmanın MOI ve Tüm Slayt Görüntüleme üzerindeki performansının 0,95 AUC puanıyla karşılaştırılabilir olduğunu bulmuşlar ve 0,987 AUC, 0,97 duyarlılık, 0,94 özgüllük puanı ile performansı daha da artırmak için zor vakaların derinlemesine analizi için derin bir segmentasyon ağı sunmuşlardır.

Yukarıda bahsedilen çalışmalardan da görüldüğü üzere cilt kanseri teşhisinde yapay zekâ çalışmaları büyük bir öneme sahiptir. Dermatologlara oranla daha yüksek *doğruluk* ve *duyarlılık* oranlarının elde edilmesine öncülük etmektedirler. Yapay zekânın tanı koymadaki hızı da düşünüldüğünde bu alandaki ihtiyaçların karşılanmasında tercih sebebi olmasının bir başka yönü böylece ortaya çıkmaktadır.

Cilt Kanseri Teşhisinde Kullanılan Görüntü Temelli Diğerk Yapay Zekâ Teknikleri

Özniteliklerin çıkarılması sınıflandırma problemi hakkında belirli bir bilgi düzeyi gerektirir. Cilt kanseri verilerinde bu bilgi dermatologlar tarafından tasarlanan metodolojilerden gelir. Farklı tıbbi prosedürler arasında, ilk Bilgisayar Destekli Tanı (CAD) sistemlerinin gelişimine ilham veren ve hala popülerliğini koruyan, dermoskopinin ABCD kuralı bulunmaktadır. Bu yöntemeye göre, cilt lezyonları dört özelliğe göre karakterize edilebilir: asimetri, sınır düzensizliği, renk dağılımı ve dermoskopik yapıların sayısı. Bu nedenle, CAD sistemleri daha sonra uygun özellikleri kullanarak bu bilgileri karakterize etmeye çalışır (Abbas, Emre Celebi, & Fondón, 2012). Melanosit lezyonları için ABCD yöntemi önerilmiş olmasına rağmen, vurgulanan renk ve doku özniteliklerinden bazıları melanosit olmayan lezyonları teşhis eden CAD sistemlerinin geliştirilmesinde de kullanılmıştır (Shimizu, Iyatomi, Celebi, Norton, & Tanaka, 2015).

Bazı çalışmalar, iyi huylu lezyonların genellikle küçük boyutlara sahip olduğu ve yaklaşık dairesel olduğu varsayımını dikkate alarak lezyonun genel şeklini karakterize etmektedir. Bu nedenle, bu öznitelikleri karakterize eden basit ölçümler (alan, çevre, kompaktlık indeksi, dikdörtgenlik, hacimlilik, ana ve küçük eksen uzunluğu, dışbükey gövde, daire ile karşılaştırma ve eksantriklik) çalışmalarda kullanılmıştır (Katapadi, Celebi, Trotter, & Gurcan, 2018; Mikołajczyk, Kwasigroch, & Grochowski, 2017; Ruela, Barata, Marques, & Rozeira, 2017) (örneğin, (Acharya, 2018; Argenziano, 2003; Haenssle, 2018; G. Litjens, 2016; Morton & Mackie, 1998; P. Tschandl, 2019b; G. Wang, 2018)). Diğerk kullanılan öznitelikler ise şunlardır: Hu'nun moment değişmezleri, dalgacık değişmez anları, Žunić kompaktlığı, simetri haritaları, simetri mesafesi ve uyarlanabilir bulanık simetri mesafesi (Acharya, 2018; Argenziano, 2003).

Son zamanlarda, Satheesha ve ark. çalışmalarında (Satheesha, Satyanarayana, Prasad, & Dhruve, 2017) lezyonun 3 boyutlu rekonstrüksiyonunu elde etmek için dermoskopi görüntülerinden derinlik bilgilerini çıkarmak için bir metodoloji önermiştir. Yazarlar daha sonra 3-B şeklini karakterize etmek için birkaç öznitelik kullanmışlar ve umut verici sınıflandırma sonuçları elde etmişlerdir.

Renk ve desen simetrisini değerlendirmek için çeşitli stratejiler kullanılmıştır. En basiti simetrik piksellerinin renk bileşenlerini veya yoğunluk değerlerini karşılaştırmaktan oluşmaktadır (Marques, 2015; Zortea et al., 2014). Daha karmaşık yöntemler, lezyonun üzerine düzenli bir ızgaranın (kayan pencere yöntemi) yerleştirilmesini gerektirir. Bu ızgara eksenlerden biri boyunca yönlendirilir ve simetrik lezyon bloklarının ekstraksiyonunu sağlar. Buradaki amaç, simetriklerinin istatistiksel tabanlı bir karakterizasyonunu (örneğin, maksimum mesafe, minimum mesafe ve standart sapma) elde etmek için blokların renk ve doku özniteliklerini karşılaştırmaktır (örneğin, simetrik blokların özellik vektörleri arasındaki Öklid veya Kullback-Leibler mesafesini hesaplayarak). HSV renk uzaylarındaki ortalama renk vektörü gibi blokları karakterize etmek için basit renk ve doku tanımlayıcıları kullanılmıştır (Seidenari, Pellacani, & Grana, 2005).

Diğer çalışmalar, lezyonun yüzeyindeki pigment dağılımını ve düzensizliğini değerlendirmek için fraktal boyut (Manousaki et al., 2006) veya radyal analiz (Clawson, Morrow, Scotney, McKenna, & Dolan, 2007) kullanılmasını önermektedir. Liu ve ark. (Liu, Sun, Smith, Smith, & Warr, 2012) görüntüyü melanin ve hemoglobin renk bileşenlerine bölmek için bir metodoloji önermiştir ve ardından bu iki bileşenin dağılımına dayanarak asimetri analizi yapmışlardır.

Bir çalışmada renk özneliği kapsamlı bir şekilde incelenmiştir (Madooei & Drew, 2016). Yalnızca ayırt edici renk özniteliklerini bulmaya adanmış birkaç çalışma bu konuda öne çıkmaktadır (örneğin, (Celebi & Zornberg, 2014; Stanley, Stoecker, & Moss, 2007)). Bu çalışmaların amacı, dermatologlar tarafından gerçekleştirilen renk özelliğini taklit etmek için lezyonun içindeki renk dağılımını karakterize etmektir. Basit istatistiksel ölçülerden daha karmaşık renk niceleme tabanlı yöntemlere kadar çeşitli yaklaşımlar önerilmiştir.

Cilt kanseri teşhisinde görüntüler üzerine uygulanan popüler istatistiksel ölçüler ortalama, standart sapma, varyans, eğrilik, maksimum, minimum ve entropi, çift boyutlu veya 3-B renkli histogramlar ve otokorrelogram hesaplamalarıyla gerçekleştirilmektedir (C. Barata, Ruela, Francisco, Mendonça, & Marques, 2014; Sadri, Azarianpour, Zekri, Emre Celebi, & Sadri, 2017).

Diğer taraftan dokusal öznelik kapsamında gri düzeydeki birlikte oluşum matrisi (GCLM), lezyonların dokusunu karakterize etmek için yaygın olarak kullanılmıştır (örneğin, (Jaworek-Korjakowska & Kłeczek, 2016; Schaefer, Krawczyk, Celebi, & Iyatomi, 2014)). Bu matris gri tonlamalı görüntü üzerinden hesaplanır ve sabit bir mesafe ile ayrılmış iki pikselin eklem olasılığının tahmin edilmesine izin verir. Varyans, korelasyon, homojenlik, kontrast ve entropi gibi birçok istatistiksel ölçü bu tanımlayıcının kullanılmasıyla tahmin edilebilir. Bu tanımlayıcıların bazıları doğrudan gri ölçek görüntüsünden de hesaplanabilir. Daha yüksek sıra istatistikleri gri düzey çalışma uzunluğu matrisi (GLRLM) kullanılarak hesaplanabilir. Degrade bilgileri (genlik ve oryantasyon histogramları ve yönelimli degrade histogramı) ayrıca lezyonların dokusunu (Rastgoo, Garcia, Morel, & Marzani, 2015) ve bir hücre içindeki komşu piksellerin yoğunluklarını karşılaştıran yerel ikili örüntülerin (LBP) varyantlarını karakterize etmek için de kullanılmıştır (Abedini, 2015). Kullanılan diğer doku tanımlayıcıları arasında dalgacık ve Fourier dönüşümleri, fraktal boyut, çok boyutlu alıcı alanlar histogramları, Markov rastgele alanları ve Gabor filtreleri bulunmaktadır.

Renk özelliklerine benzer şekilde, doku temelli olanlar da lezyonun iç ve kenarlık kısımları için ayrı ayrı hesaplanabilir (örneğin, (Capdehourat, Corez, Bazzano, Alonso, & Musé, 2011)).

Bir başka öznelik çıkarma türü olan yerel özneliklerin temel fikri, bir görüntünün (cilt lezyonu) görsel kelimeler sözlüğünün öğelerinin (atomlarının) bir koleksiyonu olarak temsil edilebilmesidir. Bir görüntü çiftinde karşılık gelen tüm özellik noktalarını bulmanın en basit yolu, yerel tanımlayıcılardan birini kullanarak bir görüntüdeki tüm özellikleri diğerindeki tüm özelliklerle karşılaştırmaktır (Adel, Elmogy, & El-Bakry, 2014).

Öznelik tabanlı tekniklere dayalı görüntü birleştirme için, öznelik çıkarma, kayıt ve karıştırma, görüntü birleştirme süreçleri gerektiren farklı adımlardır. Öznelik tabanlı yöntemler, noktalar, çizgiler, kenarlar, köşeler veya diğer geometrik varlıklar arasında benzerlikler kurarak başlamaktadır. Sağlam dedektörlerin özellikleri arasında görüntü gürültüsüne değişmezlik, ölçek değişmezliği, öteleme değişmezliği ve döndürme dönüşümleri bulunur. Harris köşe dedektörü (Harris & Stephens, 1988), SIFT (Yanfeng, Yaming, Wenqing, & Zuoli, 2008), SURF (Bay, Ess, Tuytelaars, & Van Gool, 2008), FAST (Rosten & Drummond, 2006), PCA-SIFT (Yan & Sukthankar, 2004) ve ORB (Kulkarni, Jagtap, & Harpale, 2013) teknikleri gibi birçok öznelik algılama tekniği vardır. İyi bilinen SIFT (Ölçeklenebilir Değişmeyen Öznelik Dönüşümü) (Yanfeng et al., 2008) tekniği çok başarılıdır, ancak hesaplama süresi gerçek zamanlı uygulamalar için uygun değildir. Öznelikleri tespit etmek için Harris köşe dedektörü (Harris & Stephens, 1988) kullanılmıştır. Bunları eşleştirmek için

yoğunluk değerlerinin normalleştirilmiş bir çapraz korelasyonunu kullanmaktadır. Harris köşe dedektörü, ölçek değişiklikleri ve çapraz korelasyon için değişmez değildir. Oysa SURF (Speeded Up Robust Features) (Bay et al., 2008), bir görüntü üzerinde hızlı yerel gradyan hesaplamaları için entegre bir görüntü kullanarak SIFT'in hesaplama süresini iyileştirmektedir.

Dermoskopi çalışmalarında yama ekstraksiyonu ve temsili de detaylı bir şekilde araştırılmıştır. En basit strateji, lezyonu düzenli bir ızgara kullanarak karelere bölmektir, buna yoğun örnekleme denir. Alternatif olarak, lezyonda belirli renk ve doku desenleriyle ilişkili belirgin noktaların varlığı incelenebilir ve bunlara ortalanmış kare bölgeler çıkarılabilir (seyrek örnekleme). Bazı popüler tuş noktası dedektörleri Gauss ve Harris-Laplace farkını içerir (Catarina Barata, Marques, & Rozeira, 2013). Ayıklanan düzeltme eklerinin her biri, bir süper piksel oluşturan bir dizi komşu pikselden oluşacaktır.

Cilt kanseri tanı problemlerinde yaygın olarak kullanılmakta olan derin öğrenme algoritmaları problemin çözümünde derin öğrenme yöntemlerinin kendi özneliklerini kendilerinin çıkarmasından dolayı yaygın olarak kullanılmaktadır. Krizhevsky ve ark. (Krizhevsky, Sutskever, & Hinton, 2012) 2012 ImageNet yarışmasını kazandığından beri, derin öğrenmenin ve özellikle evrişimli sinir ağlarının (CNN) birçok bilgisayarlı görme probleminde tercih edilen teknik haline geldiği yadsınamaz bir gerçektir (Guo et al., 2016). Tıbbi görüntüleme topluluğu da bu tekniği benimsemiştir. Tıbbi görüntülerdeki organları ve yapıları teşhis etmek veya segmentlere ayırmak için bu metodolojiyi kullanan uygulamaların sayısı giderek artmaktadır (Geert Litjens et al., 2017). Bilindiği kadarıyla, dermoskopi görüntülerine derin öğrenme uygulayan ilk çalışma Codella ve ark. (N. Codella et al., 2015) tarafından 2015 yılında yayınlanmış ve o zamandan beri birkaç araştırmacı uygun görüntü gösterimlerini öğrenmek ve insan uzmanlarının tanı performansına ulaşmak için derin öğrenmeyi araştırmıştır. Dermoskopi alanında derin öğrenmenin popüleritesinin bir göstergesi olarak, 23 eserden 22'sinde en az bir çeşit CNN mimarisinin kullanıldığı 2017 ISIC raporlarında belirtilmektedir (N. C. F. Codella et al., 2018).

İki tür derin öğrenme yöntemi vardır: denetimsiz (örneğin, yığılmış otomatik kodlayıcılar ve derin inanç ağları) ve denetimli (örneğin, CNN'ler ve tekrarlayan NN'ler). Dermoskopideki çalışmaların hemen hemen hepsi cilt lezyonlarını teşhis etmek için CNN'leri kullanmaktadır. Bu tür yöntemler, hiyerarşik bir çerçevede düzenlenmiş üç ana katmandan (evrişimli, havuzlama ve tam bağlı katmanlar) oluşan belirli bir mimari sergilemektedir (C. Barata, Celebi, & Marques, 2019).

Yukarıda belirtilen yöntemlerle ilgili sorunların yanı sıra dermatologların kendilerine karar destek ve öğrenme araçları olarak hizmet edebilecek CAD sistemleriyle çalışma arzusu,

bu alanda önemli bir eğilim oluşmasını teşvik etmektedir. Bu sistemlerin temeli, dermoskopik kriterleri tespit etmek için stratejilerin tasarlanması ve ardından cilt lezyonlarını teşhis etmek için bu kriterlerin (klinik verilerin) kullanılmasıdır. Bunun bir uzman tarafından yapılan analizi taklit ettiğine ve aynı zamanda tanıyı anlamak için zemin sağladığına inanılmaktadır. Bu konuyla ilgili çalışmaların sayısının son on yılda hızlı bir şekilde arttığı gözlemlenmektedir (Dreiseitl & Binder, 2005).

Makine Öğrenmesi Tekniklerinin Cilt Kanseri Teşhisinde Uygulanması: MLML Modeli

Bu tezde ön çalışma olarak literatürde kullanılan algoritmalar farklı bir kurguyla birleştirilmiş ve cilt kanseri tanısında yapay zekâ performansının artırılması hedeflenmiştir. Bunun için Çok Katmanlı Makine Öğrenmesi Algoritması (MLML) geliştirilmiştir. Algoritmaların ve yöntemlerin geliştirilmesinde ve uygulanmasında Python programlama dili kullanılmıştır. Aşağıda bu mimari hakkındaki açıklamalara ve deneysel çalışmalarda kullanılan HAM10000 cilt kanseri veri seti detaylarına yer verilmiştir.

HAM10000 cilt kanseri veri seti

Bu çalışmada, yaygın cilt lezyonlarının dermatoskopik görüntülerinden oluşan ve literatürde sıklıkla kullanılan bir veri seti olan HAM10000'den faydalanılmıştır. HAM10000 veri seti, dermatoloji ve cilt kanseri araştırmaları alanında önemli bir yere sahiptir. Yüksek kaliteli cilt lezyonu görüntülerinin bir derlemesini içeren bu veri seti, 10.015 dermatoskopik görüntüden oluşan geniş bir koleksiyondur. Büyüklüğü, onu cilt lezyonu analizi için özel olarak tasarlanmış, halka açık en büyük veri kümelerinden biri yapmaktadır. Bu görüntüler, farklı cilt kanseri formları ve iyi huylu lezyonlar dahil olmak üzere birçok cilt koşullarını kapsayan çeşitli ve temsili bir dizi vaka örneği sunmaktadır. Özellikle, HAM10000 veri kümesindeki her görüntüye, klinik bilgileri ve uzman tarafından teşhis edilen etiketleri içeren kapsamlı meta veriler eşlik etmektedir. Bu veri setinin bu alandaki en geniş ve önemli veri seti olduğu bir çok çalışmada belirtilmiştir (N. C. F. Codella et al., 2018). Stanford Üniversitesi tarafından kendi Araştırma Hastanesi bünyesindeki çeşitli hastalardan elde edilen verilerden oluşturulmuştur (Philipp Tschandl, Rosendahl, & Kittler, 2018).

HAM10000 veri seti hem dermatoloji hem de bilgisayarlı görme alanlarında standart bir ölçüt olarak kendini kanıtlamıştır. (Philipp Tschandl et al., 2018). 450 × 600 çözünürlüğünde görüntülerden oluşmaktadır ve ayrıca hastaların yaşı, cinsiyeti ve lezyonun tanı bölgesi hakkında bilgiler de dahil olmak üzere 8 farklı hastalık verisi içermektedir.


Sekiz farklı cilt hastalığı türü ve veri setindeki her türle ilişkili örnek sayısı aşağıda listelenmiştir. Bu hastalıkların kanser olup olmadıklarına göre sınıflandırılması Şekil 8'de verilmiştir.

1. Melanom (Mel, 1113 adet örnek görüntü),
2. Bazal hücreli karsinom (BCC, 514 adet örnek görüntü),
3. Aktinik keratoz ve İntraepitelyal karsinom (AKIEC, 327 adet örnek görüntü),
4. Melanositik nevi (NV, 6705 adet örnek görüntü),
5. İyi huylu keratoz (BKL, 1099 adet örnek görüntü),
6. Dermatofibrom (DF, 115 adet örnek görüntü),
7. Vasküler lezyonlar (VASC, 142 adet örnek görüntü).



Şekil 8. HAM10000 veri setindeki hastalık türleri ve sınıflandırması

Şekil 9'da HAM10000 veri seti içerisinde yer alan hastalıklar ve örnek görüntüleri verilmiştir. Bu çalışmada şekilsel ve dokusal olarak birbirine çok benzeyen Şekil 9'daki görüntülerden yararlanılmıştır. Sınıflandırma işlemi kanser ve kanser olmayı ayırt ediyormuş gibi olsa da aslında 8 farklı hastalığa ait görüntüler üzerinde bu süreç yürütülmektedir ve bu da sınıflandırma sürecini daha karmaşık hale getirmektedir.



Şekil 9. Hastalık türleri görüntüleri a. Melanom, b. Bazal hücreli karsinom, c. Aktinik keratoz, d. İntraepitelyal karsinom, e. İyi huylu keratoz, f. Dermatofibrom, g. Melanositik nevi, h. Vasküler lezyonlar

MLML mimarisinde veri önışleme ve öznitelik çıkarma yöntemleri

Makine öğrenmesi algoritmalarının uygulanmasından önce, literatürde yaygın olarak kullanılan 14 öznitelik çıkarma yöntemiyle görüntülerdeki patolojik vücut bölgesinin parlaklık ve RGB (kırmızı, yeşil ve mavi renk yelpazesi kodu) değerlerinden öznitelikler çıkarılmıştır. Bu bağlamda, sırasıyla 8x8 ve 28x28 pencere boyutları kullanılmıştır. Daha sonra, sınıflandırma süreci, görüntü öznelerinin yaş, cinsiyet ve tanısal bölgesine ilişkin bilgilerin eklenmesiyle başlatılmıştır.

Bu çalışmada kullanılan öznitelik çıkarma yöntemleri aşağıdaki paragraflarda detaylı olarak açıklanmıştır.

1. Kurtosis: Bir dağılımın normal olup olmadığını belirlemek için kullanılır. Dağılım simetrik olabilir ancak normal olmayabilir. Bu durum, dağılımın ortasında çok az veya çok fazla örneğin birikmesi durumunda olabilir. Normal bir dağılımın kurtosis değeri sıfırdır. Dağılımın ortasında çok fazla örnek varsa, kurtosis değeri pozitiftir.
2. Çarpıklık (Skewness): Bir dağılımın asimetrik olma derecesini ölçer. Bir dağılımdaki çarpıklık değeri pozitifse, değerlerin çoğu ortalamanın solunda ve dolayısıyla ortalama değerden daha küçüktür. Öte yandan, bir dağılımdaki çarpıklık değeri negatifse, değerlerin çoğu ortalamanın sağında birikmiştir.
3. Ortalama: Bir dağılımdaki tüm verilerin değerlerinin toplamının toplam veri sayısına bölünmesini ifade etmektedir.
4. Medyan: En küçükten en büyüğe sıralanmış bir dağılımda ortanca değeri ifade etmektedir.
5. Varyans: Bir veri kümesindeki değerlerin dağılımını ortalama ile ilişkilendirme yöntemidir. Dağılım ölçüsü olarak da bilinir. Varyans aynı zamanda standart sapmanın karesidir.
6. Toplam: Bir dağılımdaki verilerin toplamıdır.
7. Yerel Min: Bir dağılımdaki verilerin azalmadan artışa doğru değiştiği değeri ifade etmektedir.
8. Yerel Maks: Bir dağılımdaki verilerin artıştan azalmaya doğru değiştiği değeri ifade etmektedir.
9. Standart Sapma: Bir dağılımdaki verilerin yakınlığını ve uyumunu ölçer. Veri kümesindeki sayıların aritmetik ortalamaya göre nasıl dağıldığını belirler.

10. Sıfır Noktalarının Kesişim Sayısı: Bir dağılımdaki iki veya daha fazla verinin sıfır noktasında kesişim sayısıdır.
11. Global Min: Bir dağılımdaki verilerin en küçük değeridir.
12. Global Maks: Bir dağılımdaki verilerin en büyük değeridir.
13. Polinom Uydurma: Bir dağılımdaki verilerle en uyumlu fonksiyonu bulma sürecidir.
14. Karekök Ortalaması: Bir dağılımdaki verilerin karelerinin aritmetik ortalamasının kareköküne eşit olan değerdir.

Tablo 1'de görüldüğü gibi, hasta/lezyon bilgileri (yaş, cinsiyet ve lezyonun bölgesi) dahil edilerek toplamda 59 adet öznitelik belirlenmiştir ve görüntülerden her bir pencere boyutu ve piksel değeri (parlaklık veya RGB) için ayrı ayrı 14 öznitelik çıkarılmıştır.

Önerilen MLML yönteminin veri ön işleme aşaması, Veri Ön İşleme I ve Veri Ön İşleme II olarak iki aşamada gerçekleştirilmektedir. Veri Ön İşleme I aşamasında, yaş, cinsiyet ve görüntünün alındığı tanısal bölge gibi hasta/lezyon bilgilerindeki eksik veriler, deneysel denemelerde en iyi başarı oranını sağladığı için medyan değerleriyle doldurulmaktadır. Diğer yandan, Veri Ön İşleme II aşamasında, deneysel denemelerde diğer yöntemlere göre daha iyi sonuçlar elde etmeye yardımcı olduğu için tüm 59 özniteliğe standart sapma normalizasyonu uygulanmaktadır.

Tablo 1. Çok Katmanlı Makine Öğrenimi (MLML) Yönteminde Kullanılan Öznitelik Çıkarma ve Veri Ön İşleme Adımlarının Ayrıntıları

	Görüntü Pikselleri I	Görüntü Pikselleri II	Görüntü Pikselleri III	Görüntü Pikselleri IV	Hastalık/Lezyon Bilgileri			Top.
Öznitelik Türü	Parlaklık Değeri	RGB Değeri	Parlaklık Değeri	RGB Değeri	Yaş	Cinsiyet	Bölge	
Değer Sayısı	8x8=64	3x8x8=192	28x28=784	3x28x28=2352	1	1	1	3395
Öznitelik Sayısı	14	14	14	14	1	1	1	59
Veri Ön İşleme I	Eksik Verilerin Tamamlanması							
Veri Ön İşleme II	Tüm Verilere Standart Sapma Normalizasyonu Uygulanmaktadır.							

Çok katmanlı makine öğrenmesi (MLML) mimarisi

Toplam başarı oranlarının artırılmasına topluluk öğrenmesi yöntemlerinin uygulanması önemli katkılar sağlamaktadır. Çok Katmanlı Makine Öğrenimi (MLML) mimarisi, birçok farklı öğrenme modelinin birleştirilmesi olarak tanımlanan topluluk öğrenmesi tasarımına benzemektedir. Bu tasarımda, alt modeller farklı veya aynı türde olabilir. Bu modellerden her

biri tarafından öğrenilen bilgi, daha iyi performansa sahip yeni bir model oluşturmak için birleştirilmektedir. MLML de alt modeller kullanır, ancak bu modellerden gelen sonuçlar birleştirilmez. Her modelden elde edilen veri, bir sonraki adımda başka bir modele öznitelik olarak aktarılmaktadır. Bu, MLML ve geleneksel topluluk öğrenmesi arasındaki temel farktır. MLML mimarisinin matematiksel modeli aşağıda açıklanmıştır. İlgili formülasyonlarda; w , öznitelik çıkarma yöntemlerini temsil etmektedir (örneğin, polinom uydurma, global maksimum vb.). d kullanılan veri setini temsil etmektedir. L ve RGB sırasıyla görüntünün parlaklık değerini ve kırmızı, yeşil ve mavi renk değerlerini temsil etmektedir. RGB'de 3 değer bulunduğu ve L'de 1 değer bulunduğu için eşitliklerde $8 \times 8 \times 3$ ve $8 \times 8 \times 1$ değerleri kullanılmıştır. Burada, 8×8 , kullanılan pencerenin piksel boyutunu ifade etmektedir.

$$w \in \{Set\ of\ Feature\ Ext.\ Alg.\ (14\ Alg.)\} \quad (5)$$

$$X_{8L}(d) = FE_{dw}(8 \times 8 \times 1) \quad (6)$$

$$X_{8RGB}(d) = FE_{dw}(8 \times 8 \times 3) \quad (7)$$

$$X_{28L}(d) = FE_{dw}(28 \times 28 \times 1) \quad (8)$$

$$X_{28RGB}(d) = FE_{dw}(28 \times 28 \times 3) \quad (9)$$

$$X_C(d) = FE_d(3) \quad (10)$$

"w" tarafından belirtilen 14 algoritmanın veri kümesinden öznitelik çıkarmak için kullanılan ayrıntıları, Tablo 1'de verilmiştir. (6), cilt lezyonu değerlerinden elde edilen parlaklık değeriyle 8×8 piksel boyutunda çıkarılan öznitelikleri ifade etmektedir. FE, bir öznitelik çıkarma işlevini temsil eder ve veri kümesi "d"ye atıfta bulunmaktadır. (7)'de, görüntünün RGB değeri, parlaklık değeri yerine kullanılmaktadır. (8) ve (9)'da, cilt lezyonundan alınan pencere piksel boyutu 28×28 olarak değiştirilmiştir. (10)'da, cilt lezyonunun alanı, cinsiyet ve yaş gibi klinik özellikler dahil edilmektedir.

$$f = \sum_{i=1}^{Count(w)} X_{8Li}(d) + X_{8RGBi}(d) + X_{28Li}(d) + X_{28RGBi}(d) + X_{Ci}(d) \quad (11)$$

(11)'de, çalışmada kullanılan 14 öznitelik çıkarma algoritmasıyla beş yeni öznitelik oluşturulmuştur.

$$\beta \in \{Classification\ Algorithms\ (5\ Alg.)\} \quad (12)$$

$$k, l, m = 0$$

$$C(f) = \sum_{n=1}^{Count(data)} \begin{cases} k_n += 1, & C_\beta(f_n) = 0 \\ l_n += 1, & C_\beta(f_n) = 1 \\ m_n += 1, & C_\beta(f_n) = 2 \end{cases} \quad (13)$$

β tarafından belirtilen ve veriyi sınıflandırmak için kullanılan 5 algoritmanın ayrıntıları Şekil 10'da gösterilmektedir. (13)'de her bir verinin özelliklerine dayanarak sınıflandırma

sonuçları hesaplanmaktadır. 0, 1 ve 2 değerleri sırasıyla kanser, kanser değil ve erken evre kanser sınıflandırmasına karşılık gelmektedir.

$$R_{layer1} = C(f) \quad (14)$$

$$R_{layer2} = KNN(R_{layer1}) \quad (15)$$


$$R_{layer3} = LR(R_{layer2}) \Rightarrow Result_{MLML} \quad (16)$$

(14)'de beş makine öğrenmesi algoritmasının sınıflandırma sonuçları hesaplanmaktadır ve Katman 1'in sonuçlarını temsil etmektedir. Bu sonuçlar, (15)'de KNN algoritmasının sonuçlarını elde etmek için öznitelik olarak kullanılmaktadır. Bu sonuçlar, (16)'da Lineer Regresyon algoritması için öznitelik olarak kullanılmıştır. Bu son katmanın sonucu aynı zamanda MLML mimarisinin sonucunu da ifade etmektedir.

Önerilen yöntemin tasarım akışı Şekil 10'da gösterilmiştir. Şekil 10'da daire içine alınmış sayılar, akışın adımlarını temsil etmektedir. Örneğin, adım ①'de, veri seti tanımlanır ve bu özel adımda üç farklı veri türü incelenir. Benzer şekilde, adım ②'de, öznitelik türleri tanımlanır ve beş farklı öznitelik türü incelenir. MLML mimarisi, veri ön işleme adımı hariç olmak üzere toplam 3 katmandan oluşmaktadır.

Önceden vurgulandığı gibi, tasarım akışının ④. adımında (ön işleme), ilk olarak 14 farklı öznitelik çıkarma yöntemi kullanılarak öznitelikler elde edilir. Bu bağlamda, iki farklı pencere boyutu ile birlikte parlaklık ve renk uzayı bilgileri kullanılır. Bu işlem, 56 öznitelikten ($2 \times (14 + 14) = 56$) oluşan bir öznitelik seti ile sonuçlanır. Ayrıca, fazladan üç öznitelik klinik verilerden gelmektedir (yaş, cinsiyet ve lezyon bölgesi). Bu nedenle nihai öznitelik seti 59 öznitelik içerir. Tüm bu öznitelikler, tasarım akışının ③. adımı tarafından temsil edilen iki aşamalı veri ön işleme aşamasından geçer. Eksik klinik verilerin eklenmesi ve normalleştirme adımları da verinin sınıflandırma algoritmalarının kullanımı için hazırlanması adına gerçekleştirilir. Ön işleme adımlarının ayrıntıları, tasarım akışının ③. adımında gösterilmiştir.

Sınıflandırma süreci, MLML mimarisinin tasarım akışının ⑤. adımında gösterildiği gibi ilk katmanda gerçekleşir. Bu katmanda, Karar Ağacı, Rastgele Orman, Yapay Sinir Ağı, Naif Bayes ve Destek Vektör Makinesi olmak üzere 5 farklı makine öğrenmesi algoritması kullanılır. İlgili problem için literatürde en yaygın olarak kullanılan makine öğrenmesi algoritmalarından olan her bir algoritma, eğitim verisindeki görüntüleri üç grupta (kanser, kanser değil ve kanser başlangıcı) sınıflandırır. İlk katman çalıştırıldıktan sonra, 5 farklı sınıflandırma sonucu ikinci katmana aktarılır.



Şekil 10. MLML mimarisi ve iş akış şeması

İlk katmanda, her bir algoritma karar alma sürecini ayrı ayrı ve bağımsız gerçekleştirir. İlk katmandaki sınıflandırma sonuçları, ikinci katman için öznitelik olarak kullanılır ve bu sürecin ayrıntıları tasarım akışının 6. adımında görülebilir. İlgili veri daha sonra KNN algoritması için eğitim verisi olarak kullanılmak üzere tasarım akışının 7. adımına aktarılır. Başka bir deyişle, KNN algoritması, ilk katmandaki beş farklı algoritmanın kararlarına göre veriyi yeniden etiketler. MLML, birden fazla makine öğrenmesi algoritmasının birleşik kullanımından faydalanırken, ilk katmanın çoklu sınıflandırma kararlarını bir araya getirecek bir mekanizmaya ihtiyaç duyar. Bu bağlamda, MLML, bir çoğunluk oyu tekniğine dayanan bir

yakınlık öğrenimi tekniği kullanır ve bu nedenle KNN algoritması, yalnızca çoğunluk oyuyla sınırlı kalmaksızın çoklu kararların benzerliklerini de dikkate alır. Benzerlik, k-değerini ayarlayarak belirlenebilir ve bu sayede kullanılan makine öğrenmesi algoritmalarının eksik veya zayıf noktaları ortadan kaldırılarak daha doğru kararlar elde edilebilir. Son olarak, ikinci katmanın uzlaşma temelli sınıflandırma sonuçları tasarım akışının 8. adımındaki üçüncü katmana gönderilmektedir.

Önerilen yöntemin son adımı üçüncü katmanda gerçekleştirilir ve bu sürecin ayrıntıları tasarım akışının 9. adımında gösterilmektedir. Bu adımda, ikinci katmandan gelen KNN sınıflandırma sonucuna dayanarak cilt kanserini tahmin etmek için lineer regresyon formunda bir sınıflandırıcı kullanılır. Tahminde, lineer regresyon algoritması yalnızca KNN'den elde edilen etiketlerle eğitilir. Bu katmanın kullanılmasının amacı, önceki katmanın sınıflandırma performansını artırmaktır. Son katmanın çıktısı olarak tasarım akışının 10. adımında cilt kanseri teşhis sonuçları elde edildikten sonra, MLML yönteminin başarısı bir sonraki bölümde açıklandığı şekilde doğrulama verilerine karşı test edilir.

Bulgularla ispat

Bu bölümde, cilt kanseri teşhisi noktasında MLML yönteminin sonuçları ile ilgili diğer çalışmaların sonuçları bir arada sunulmuştur. Deneysel sonuçlarla desteklenen detaylı tablolar ve şekillerle gösterildiği gibi, MLML yöntemi, literatürdeki tek makine öğrenmesi tabanlı çalışmalardan ve derin öğrenme yöntemlerinden daha iyi performans göstermektedir.

Tablo 2, makine öğrenmesi algoritmalarının 3 katmanlı mimariye entegre edilmeden önceki bireysel başarı oranlarını sunmaktadır. Bu oranlar, 3 katmanlı mimarinin ilk katmanındaki sonuçlarla karşılaştırıldığında nispeten daha düşüktür, ki bu da Tablo 3'te gösterilmiştir. Bu farklılık, veri setinde gözlenen yüksek entropiye bağlanabilir; bu durum, bireysel algoritmaların performansını engellemektedir. Kullanılan veri seti, heterojenlik gösteren sekiz farklı hastalık görüntüsünden oluşmaktadır.


Algoritmaların ilk aşamada ayrı ayrı kullanıldığı başlangıç aşamasında sonuçlar, toplamda 10.015 verinin %80'inin eğitim için ve %20'sinin test için kullanıldığı şekilde elde edilmiştir. Bu kadar büyük bir oranın (%80) eğitim için kullanılması, aşırı öğrenmeye neden olmuş ve test verilerinin sınıflandırılması için nispeten daha düşük başarı oranlarına yol açmıştır. Bununla birlikte, 3 katmanlı mimaride, ilk katmanın yaklaşık %50'si eğitim ve %20'si test amaçları için özel bir dağılımla kullanılmaktadır (Şekil 11'de detayları verilmiştir).

Deneysel testlerde, veri seti dört gruba ayrılmıştır: bunlar sırasıyla katman 1 eğitim verileri (%50), katman 1 test verileri (%20), katman 2 test verileri (%15) ve katman 3 test

verileri (%15) şeklinde gösterilmiştir (Şekil 11'de gösterildiği gibi). Beş makine öğrenmesi algoritması (Karar Ağacı, Rastgele Orman, Yapay Sinir Ağı, Naive Bayes ve Destek Vektör Makinesi) ayrı ayrı ilk katmanda %50 veri ile eğitilir. Daha sonra, her bir algoritma %20 veri ile test edilir. Böylece, beş makine öğrenmesi algoritmasının sınıflandırma sonuçları elde edilir. Bu sonuçlar, ikinci katmandaki KNN algoritmasını eğitmek için kullanılır. Başka bir deyişle, katman 2, başlangıçta çıkarılan veri setinin 59 özniteliği ile eğitilmez; bunun yerine, ilk katmandaki beş algoritmanın sonuçları öznitelik olarak kullanılır. Daha sonra, katman 1'deki 5 makine öğrenmesi algoritmasından kullanılmayan %15 veri sınıflandırılır ve ilgili sonuçlar, gerçek etiket değerleri ile birlikte katman 2 için test verisi olarak kullanılır.

Tablo 2. Bireysel Makine Öğrenimi Algoritmaları Kullanıldığında Ölçülen Performans Değerleri

Algoritma	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)
Decision Tree	74,13	85,05	81,25	83,11
Random Forest	82,52	87,83	82,79	85,24
Neural Network	79,72	83,74	91,96	87,66
Naive Bayes	62,94	86,42	62,50	72,54
Support Vector Machine	80,42	80,88	98,21	88,71
K-Nearest Neighbor	82,52	84,25	95,54	89,54



Şekil 11. MLML yönteminin veri kümesi kullanım akış şeması

Katman II'de test verisinden elde edilen sonuçlar, 3. katmandaki doğrusal regresyon algoritmasını eğitmek için kullanılır. Başka bir deyişle, 3. katman, orijinal veri kümesinin öznitelikleriyle eğitilmez; bunun yerine, 2. katmandaki KNN algoritmasının sonuçları öznitelik

olarak kullanılarak eğitilir. 3. katmanın ürettiği çıktılar, MLML tekniğinin sonuçlarını yansıtmaktadır.

Burada, 1. katman, 2. katman için öznitelik oluşturmaktan sorumludur. Benzer şekilde, 2. katman, 3. katman için öznitelik oluşturmakla görevlidir. Genel olarak, verinin %85'i MLML yönteminin eğitimi için kullanılırken, %15'i ile test süreci yürütülmektedir.

Deney testinin ilk aşamasında, bu çalışmada kullanılan makine öğrenmesi algoritmaları, yani Karar Ağacı (KA), Rastgele Orman (RO), Yapay Sinir Ağı (YSA), Naive Bayes (NB), Destek Vektör Makinesi (SVM) ve K-En Yakın Komşu (KNN) algoritmaları ayrı ayrı eğitilmiştir. Ardından, eğitim ve test verileri kullanılarak başarı oranları hesaplanmıştır. Böylece, her bir bireysel algoritmanın MLML mimarisine entegre edilmeden önceki performansı belirlenmiştir. Tablo 2'ye dikkatlice bakıldığında, bu aşamada RO ve KNN algoritmalarının en yüksek *doğruluk* değerini (%82,52) sağladığı görülmektedir. RF algoritması ayrıca en iyi *kesinlik* değerini (%87,83) vermiştir. Diğer yandan, SVM algoritması en yüksek *duyarlılık* değerini (%98,21) sağlarken, en iyi F1-skoru (%89,54) KNN algoritması ile elde edilmiştir.

Tablo 2'nin detaylı bir şekilde incelenmesi, en kötü performans gösteren algoritmaları şu şekilde ortaya koymaktadır: (1) NB algoritması, %62,94'lük bir *doğruluk* oranı ile en kötü değeri üretmiştir. (2) SVM algoritması, %80,88'lik bir *kesinlik* değeri ile en düşük değeri üretmiştir. (3) En kötü *duyarlılık* değeri, %62,50'lik bir oran ile NB algoritması tarafından elde edilmiştir. (4) NB algoritması, %72,54'lük bir F1-skoru ile en düşük F1-skorumu sağlamıştır.


Her bir bireysel makine öğrenmesi algoritmasının performansını belirledikten sonra, her bir algoritmanın güçlerini katmanlı bir yapıda birleştirmeyi amaçlayan önerilen MLML yönteminin etkinliğini doğrulamak için deneyler yapılmıştır. Bu bağlamda, makine öğrenmesi algoritmaları 3 katmana ayrılmıştır. İlk katmanda, KA, RO, YSA, NB ve SVM algoritmaları kullanılmıştır. Veri setinin %50'si eğitim ve %20'si test için kullanılmıştır. Daha sonra, ikinci katmandaki KNN algoritması, ilk katmandaki test verilerinin sonuçları kullanılarak eğitilmiştir. Daha sonra, başarı oranı tüm veri setinin %15'i kullanılarak test edilmiştir. Üçüncü katmanda, ikinci katmanın test sonuçları kullanılarak Lineer Regresyon algoritması eğitilmiştir. Daha sonra, başarı oranı tüm veri setinin %15'i kullanılarak test edilmiştir.

Tablo 3, tüm katmanlar için *doğruluk*, *kesinlik*, *duyarlılık* ve *F1-skoru* değerlerini listelemektedir. Üçüncü katmanın sonuçları aynı zamanda MLML tekniğinin performansını yansıtmaktadır. Şekil 12'nin detaylı incelenmesi, MLML yönteminin dört başarı kriterinde en iyi performansı sergilediğini göstermektedir: %88,81 *doğruluk*, %88,89 *kesinlik*, %99,17 *duyarlılık* ve %93,75 *F1-skoru* elde edilmiştir.

Tablo 3. MLML Mimarisinin Tüm Katmanları İçin Ölçülen Performans Değerleri

	Algoritma	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)
Katman I	KA (Decision Tree)	77,70	86,84	85,19	86,00
	RO (Random Forest)	82,36	88,35	89,93	89,13
	YSA (Neural Network)	83,31	87,60	89,16	88,37
	NB (Naive Bayes)	66,89	91,10	65,22	76,02
	SVM (Support Vector Machine)	82,36	83,11	97,98	89,93
Katman II	KNN (K-Nearest Neighbor)	82,47	84,34	95,91	89,75
Katman III	Linear Regression	88,81	88,89	99,17	93,75

Tablo 4, literatürde konuyla ilgili yürütülen çalışmaları, ilgili Çalışma Numarası (ÇN) ile birlikte listelemektedir. Bu çalışmalarda kullanılan veri setleri dermatoskopik görüntüler içermektedir ve aynı niteliksel özelliklere sahiptir. Bu çalışmalar arasında, birbirine eşdeğer veri setlerinde farklılık gösteren farklı sayılarda veriler bulunmaktadır. Bu nedenle, benzer özelliklere sahip veri setleri kullanılarak başarıdaki değişiklik incelenebilir.

**Şekil 12.** MLML katmanlarının başarı performanslarının karşılaştırılması

Tablo 4. MLML Yönteminin Literatürdeki Diğer Sınıflandırma Algoritmalarıyla Performans Karşılaştırması

Çalışma No	Veri Seti İsmi	Veri Sayısı	Sınıflandırıcı	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)
ÇN1 (Rezvantab, Safigholi, & Karimijeshni, 2018)	HAM10000	10015	DenseNet 201 ResNet 152 Inception v3 InceptionResNet v2	- - - -	85,24 81,29 80,22 83,37	- - - -	85,13 82,09 79,60 81,18
ÇN2 (Lau & Al-Jumaily, 2009)	Royal Prince Alfred Hospital	448	Auto-Associative NN	63,3	-	-	-
ÇN3 (Sigurdsson et al., 2004)	Clinical Dataset	222	Feedforward NN	80,5	-	93,0	-
ÇN4 (Yildiz, 2019)	Dermoscopic Dataset	3920	AlexNet GoogLeNet ResNet VGGNet	- - - -	93,4 94,6 92,5 94,2	94,9 95,6 93,9 95,9	- - - -
ÇN5 (Esteve et al., 2017)	ISIC Dermoscopic Archive	129450	Dermatologist 1 Dermatologist 2 CNN CNNPA	65,6 66,0 69,4 72,1	- - - -	- - - -	- - - -
ÇN6 (Brinker, 2018)	ISBI 2016 Challenge	1379	CNNTL CNNScratch	81,33 81,0	- -	- 81,0	- -
ÇN7	HAM10000	10015	MLML	88,81	88,89	99,17	93,75

ÇN1'de, cilt kanseri HAM10000 veri kümesi kullanılarak teşhis edilmiştir. Bu çalışmada, DenseNet 201, ResNet 152, Inception v3 ve InceptionResNet v2 olmak üzere dört farklı sınıflandırıcı kullanılmıştır. Tablo 4'de görülebileceği gibi, DenseNet 201 sınıflandırıcısı %85,24 *kesinlik* ve %85,13 F1-skoru değerleriyle en başarılı sonucu sağlamıştır.

ÇN2'de, cilt kanseri sınıflandırması 448 görüntü içeren Royal Prince Alfred Hastanesi veri kümesi kullanılarak gerçekleştirilmiştir. Bu çalışmada, Otomatik Asosiyatif NN algoritması kullanılarak %63,3 *doğruluk* elde edilmiştir.

ÇN3'te, cilt kanseri teşhisi Clinical Dataset adı verilen ve 222 görüntü içeren bir veri seti kullanılarak yapılmıştır. Bu çalışmada, Feedforward NN algoritması %80,5 *doğruluk* ve %93,0 *duyarlılık* elde etmiştir.

ÇN4'te, cilt kanseri Dermoscopic Dataset adı verilen 3920 dermatoskopik görüntü içeren bir veri seti kullanılarak teşhis edilmiştir. Bu çalışmada, AlexNet, GoogleNet, ResNet ve VGGNet olmak üzere dört farklı sınıflandırıcı kullanılmıştır. Tablo 4'de görülebileceği gibi, GoogleNet algoritması %94,6 *kesinlik* ile en başarılı sonucu sağlarken, VGGNet algoritması %95,9 *duyarlılık* ile en iyi performansı sergilemiştir.

ÇN5'te, cilt kanseri ISIC Dermoscopic Archive adı verilen ve 129450 dermatoskopik görüntü içeren bir veri seti kullanılarak teşhis edilmiştir. Bu çalışmada, Dermatolog 1,

Dermatolog 2, CNN ve CNNPA olmak üzere dört farklı sınıflandırıcı kullanılmıştır. Tablo 4'de görülebileceği gibi, CNNPA algoritması %72,1 *doğruluk* ile en başarılı sonucu sağlamıştır.

ÇN6'da, cilt kanseri ISBI 2016 Challenge veri seti kullanılarak sınıflandırılmıştır ve bu veri seti 1379 dermatoskopik görüntü içermektedir. İki farklı sınıflandırıcı olan CNNTL ve CNNScratch kullanılmıştır. Tablo 4'de görülebileceği gibi, CNNTL algoritması %81,33 *doğruluk* ile en başarılı sonucu sağlamıştır. Bu çalışmada, *duyarlılık* değeri yalnızca CNNScratch algoritması için verilmiş ve %81,0 değeri elde edilmiştir.

ÇN7'de, cilt kanseri sınıflandırması bu çalışmada önerilen MLML (Çok Katmanlı Makine Öğrenmesi) yöntemi kullanılarak gerçekleştirilmiştir. MLML ayrıca HAM10000 veri kümesini kullanmış ve %88,81 *doğruluk*, %88,89 *kesinlik*, %99,17 *duyarlılık* ve %93,75 *F1-skoru* elde etmiştir. Tablo 4'den anlaşılabileceği gibi, MLML yöntemi, literatürdeki derin öğrenme tabanlı çalışmalar ve diğer bireysel makine öğrenmesi algoritmalarına kıyasla dört performans ölçütü açısından en iyi sonuçları sağlamıştır. MLML tekniğinin başarısını artıran önemli faktörlerden biri, görüntü verilerine ek olarak klinik verilerin (yaş, cinsiyet ve lezyonun teşhis edildiği bölge) kullanılmasıdır. Yapılan deneyler, bu özneliliklerin sınıflandırma sürecine dahil edilmesinin başarıyı %2-3 artırdığını göstermiştir.

ÇN1, ÇN2, ÇN3, ÇN4 ve ÇN6'da, sınıflandırma iki farklı etikete (kanser, kanser oluşumu olmayan) dayanmaktadır. Buna karşılık, ÇN5'te ve çalışmamızda (ÇN7), sınıflandırıcılar üç farklı etiket değeri (kanser, kanser oluşumu, kanser olmayan) kullanmıştır. Bu çalışmada daha fazla etiket değerinin kullanılması başarıyı azaltan bir faktör olmasına rağmen, yine de diğer çalışmalara kıyasla daha iyi sonuçlar elde edilmiştir. Bu durum aynı zamanda MLML tekniğinin üstünlüğünü de göstermektedir. Çalışmamızda sunulan metodoloji, sonuç etkililiği açısından mevcut yaklaşımları aşmıştır. Bu başarıya katkı sağlayan faktörler şöyle özetlenebilir:

- Önceki çalışmalar, vakalarla ilgili diğer ilgili klinik verileri dikkate almayarak yalnızca görüntü analizine odaklanmıştır. Buna karşılık, önerdiğimiz yöntem cinsiyet, yaş ve görüntünün alındığı belirli vücut bölgesi gibi ek öznelilikleri sınıflandırma sürecine dahil etmektedir. Bu dahil etme daha kapsamlı bir değerlendirme sağlar. Örneğin, bacak bölgesinde gözlemlenen bir vaka kanser riski taşıırken, araştırma bulguları benzer bir vakada boyun bölgesinde bu riskin bulunmadığını göstermektedir (Spanos et al., 2023). Bu ek özneliliklerin dahil edilmesi, başarı açısından yaklaşık %2-3 artış sağlamıştır.

- Çalışmamız, görüntülerden öznitelik çıkarmak için 14 yeni yöntem kullanmıştır ve renk, şekil ve doku temelli özniteliklerden kaynaklanan zorlukları nispeten gidermiştir.
- Genel başarıyı artırmak için topluluk öğrenmesi yöntemleri kullanılmıştır. Özellikle, başarı seviyelerini yükseltmek için yeni geliştirilen üç katmanlı bir topluluk öğrenmesi yaklaşımı kullanılmıştır. Tek bir sınıflandırma algoritmasının karmaşık sorunlar için yetersiz kalabileceği gerçeğinden hareketle çeşitli yöntemlerin birleşimini kullanmak, bireysel eksiklikleri azaltarak daha iyi sonuçlara yol açmıştır.
- Topluluk öğrenmesi algoritmalarında, karar alma genellikle çoğunluk sonuçlarına dayanır. Önerilen yöntemimizde, karar KNN (K-En Yakın Komşu) algoritması tarafından belirlenir. Bu yaklaşım, sadece mutlak çoğunluk kararına dayanmak yerine, verilen vakaya komşu vakaların yakınlığını da dikkate almaktadır. Bu gelişmiş karar verme süreci daha kesin sınıflandırmalar yapılmasını sağlar. Bazı YZ tabanlı çalışmalar, veri kümesi artırmanın ve genişletmenin performansı artırdığını göstermiştir (Shorten & Khoshgoftaar, 2019). Ancak, çalışmamız bu tür bir ön işleme tekniğini kullanmamıştır. Bununla birlikte, elde edilen yüksek başarı oranları, önerilen mimarının sağlamlığının bir kanıtıdır.

Tez çalışması kapsamında geliştirilen MLML tekniği ile literatürdeki derin öğrenme modellerinin başarılarının üzerine çıkıldığı yukarıdaki deneysel bulgularla ispatlanmaktadır. Modern derin öğrenme modellerinin istenilen performansı gösterememesi ve başarılarının geleneksel makine öğrenmesi algoritmalarının gerisinde kalması bu modellerin tam verimlilikle kullanılamadığını ortaya koymaktadır. Tecrübeye ve uzmanlığa dayalı olarak geliştirilen derin öğrenme modellerinin optimize edilmesi gerekliliği böylelikle ortaya konulmaktadır. Bu nedenledir ki bu tez çalışmasında bu problemin giderilmesi için sonraki bölümlerde derin öğrenme modelleri tüm bileşenleri ile optimize edilmeye çalışılmıştır.

MATERYAL VE METOT

Bu tez kapsamında CNN tabanlı derin öğrenme mimarileri üzerinde araştırmalar yürütülmüştür. CNN'ler manuel olarak öznitelik çıkarma ihtiyacını ortadan kaldırmaktadır. Böylece görüntüleri sınıflandırmak için kullanılan özniteliklerin çıkarılması gerekmemektedir. Bu otomatik öznitelik çıkarma, derin öğrenme modellerini nesne sınıflandırma gibi bilgisayarlı görme görevleri için son derece kullanışlı hale getirmektedir (Xia et al., 2022).

Bu tez çalışmasında derin öğrenme mimarisinin optimizasyonu ve tasarımı için metasezgisel yöntemlerden faydalanılmıştır. Gerçekleştirilen literatür taraması sonucunda, henüz bu alanda çok az kullanılışından ve genel olarak sergilediği başarılı optimizasyon sonuçlarından dolayı Benzetilmiş Tavlama (Simulated Annealing, SA) metasezgiselinin kullanılmasına karar verilmiştir.

Mimari optimizasyonu için faydalanılan Benzetilmiş Tavlama yönteminde *maliyet (cost) fonksiyonu* olarak kullanılan derin öğrenme mimarisine ait *doğruluk* değerinin hesaplanmasının hızlandırılması için geleneksel makine öğrenmesi algoritmaları (rastgele orman, destek vektör makinesi ve lojistik regresyon algoritmaları) regresyon sürecinde kullanılmak üzere seçilmiştir.

Bu bölümde öncelikle benzetilmiş tavlama yöntemi ile derin öğrenme modeli optimizasyonu anlatılarak, çözüm temsili, pertürbasyon yöntemi ve derin öğrenme ağı oluşturma süreci konuları açıklanmaktadır. Sonra SA ile tam otomatik derin öğrenme modeli üreticinin geliştirilmesi üç bölüm halinde anlatılmaktadır. Birinci bölümde, geleneksel makine öğrenmesi algoritmalarını eğitmek üzere kullanılacak olan mimari veri seti oluşturma sürecinden bahsedilmektedir. İkinci bölümde, derin öğrenme modeli üretme süreci anlatılmaktadır. Son olarak üçüncü bölümde ise, sistem tarafından üretilen optimize edilmiş ağların etkinliği cilt kanseri teşhisi için test edilmektedir.

Veri Önışleme

Benzetilmiş tavlama yönteminde *maliyet fonksiyonu* hesaplamasında derin öğrenme modelinin *doğruluk* değeri kullanılmaktadır. Fakat derin öğrenme modelinin eğitim süresi fazla zaman aldığından süreci hızlandırmak için veri setinde seyreltme yoluna gidilmiştir. Tablo 5’de yaklaşık %3 oranında seyreltilmiş olan veri setinin dağılımı verilmektedir. Seyreltme işlemi yapılırken hastalık türlerine göre mevcut oranın korunması hedeflenmiştir. Yani her hastalık

türünün tüm veri seti içerisindeki oranı korunarak seyreltilme işlemi yapılmıştır. Böylece HAM10000 veri setinin küçük bir örneği elde edilmiştir.

Tablo 5. Derin Öğrenme Modellerinin Optimizasyonu Süreçlerinde Kullanılan ve %3 Oranına Seyreltilmiş Veri Sayıları

Hastalık Türleri	Eğitim Verisi	
	Kanser	Diğer
Melanom	33	-
Bazal hücreli karsinom	16	-
Aktinik keratoz ve İntraepitelyal karsinom	10	-
Melanositik nevi	-	201
İyi huylu keratoz	-	33
Dermatofibrom	-	3
Vasküler lezyonlar	-	4
Toplam	59	241
	300	

Tablo 6’da dağılımı verilen HAM10000 veri setinin eğitim ve test verisi olarak ayrıştırılması yapılırken hem eğitim hem de test verisi içerisinde her hastalık türünün oranının korunması amaçlanmıştır.

Tablo 6. Keşfedilen Derin Öğrenme Modellerinin Eğitim ve Test Süreçlerinde Kullanılan Veri Sayıları

Hastalık Türleri	Eğitim Verisi (%80)		Test Verisi (%20)		Toplam
	Kanser	Diğer	Kanser	Diğer	
Melanom	890	-	223	-	1113
Bazal hücreli karsinom	411	-	103	-	514
Aktinik keratoz ve İntraepitelyal karsinom	262	-	65	-	327
Melanositik nevi	-	5364	-	1341	6705
İyi huylu keratoz	-	879	-	220	1099
Dermatofibrom	-	92	-	23	115
Vasküler lezyonlar	-	114	-	28	142
Toplam	1563	6449	391	1612	10015
	8012		2003		

Benzetilmiş Tavlama ile Derin Öğrenme Modeli Optimizasyonu

Benzetilmiş Tavlama yöntemi ile CNN tabanlı derin öğrenme algoritmasının hiperparametre optimizasyonu için hedef boyutu, parti boyutu, aktivasyon fonksiyonu, optimizasyon fonksiyonu ve eğitim tur sayısı hiperparametreleri seçilmiştir. Ayrıca mimari üzerinde de katman sayısı, katman türleri ve sıralanışları için optimizasyon yapılarak derin öğrenme modeli tüm bileşenleri ile aynı anda optimize edilmiştir.

Derin öğrenme modelinin benzetilmiş tavlama yöntemi ile optimizasyonunu gösteren sözde kod Tablo 7’de verilmiştir.

Tablo 7. Cilt Kanseri Teşhisi İçin Derin Öğrenme Algoritması Optimizasyonunda Kullanılan SA Sözde Kodu

Algoritma 1: SA ile Derin Öğrenme Optimizasyonu Sözde Kodu	
Input: $Init_{Temp}$, $innerLoopCriteria$	
Output: $bestClassification$, $bestClassificationCost$	
Begin	
1:	$T \leftarrow Init_{Temp}$;
2:	$classification \leftarrow Init_{classification}$;
3:	$bestClassification \leftarrow Init_{classification}$;
4:	$Random(classification)$;
5:	$classificationCost \leftarrow Cost(classification)$;
6:	$bestClassificationCost \leftarrow classificationCost$;
7:	while $T > \epsilon$ do
8:	while $innerLoopCriteria \leftarrow false$ do
9:	$newClassification \leftarrow Perturb(classification)$;
10:	$newClassificationCost \leftarrow Cost(newClassification)$;
11:	$\Delta C \leftarrow newClassificationCost - classificationCost$;
12:	if $\Delta C < 0$ then
13:	$classification \leftarrow newClassification$;
14:	$classificationCost \leftarrow newClassificationCost$;
15:	if $newClassificationCost < bestClassificationCost$ then
16:	$bestClassificationCost \leftarrow newClassificationCost$;
17:	$bestClassification \leftarrow newClassification$;
18:	End if
19:	end if
20:	else if $Random(0,1) < e^{-(\Delta C / T)}$ then
21:	$classification \leftarrow newClassification$;
22:	$classificationCost \leftarrow newClassificationCost$;
23:	end if
24:	$T \leftarrow Classify(T)$;
25:	end while
26:	end while
27:	return $bestClassification$, $bestClassificationCost$;
End	

Bu tez çalışmasında benzetilmiş tavlama yöntemi doğrudan, yani hazır bir kütüphane kullanılmadan Python dili ile kodlanmıştır.

Benzetilmiş Tavlama yöntemi ile CNN tabanlı derin öğrenme algoritmasının hiperparametre optimizasyonu için *hedef boyutu*, *parti boyutu*, *aktivasyon fonksiyonu*, *optimizasyon fonksiyonu* ve *eğitim tur sayısı* hiperparametreleri seçilmiştir. Ayrıca mimari üzerinde de katman sayısı, katman türleri ve sıralanışları için optimizasyon yapılarak derin öğrenme modeli tüm bileşenleri ile optimize edilmiştir.

Çözüm temsilinein gerçekleştirilmesi

Benzetilmiş tavlama yönteminde her bir çözüm Python dilinde oluşturulan liste veri yapısı içerisinde tutulmaktadır. Bu listenin yapısı Şekil 13’de gösterilmektedir. Boyutu 42 olan bu listede ilk 5 değer beş farklı hiperparametre seçeneğini saklamaktadır. 6. indeksteki değer derin öğrenme mimarisindeki katmanların toplam sayısını tutmaktadır. 7-42 arasındaki indekslerde ise katmanların türlerine göre sıralanışları saklanmaktadır. Tablo 8’de çözüm temsilinein değerlerin gerçek karşılıkları gösterilmektedir.

Tablo 8. Çözüm Temsilindeki Değerlerin Gerçek Karşılıkları

Temsil Değeri	Hedef Boyutu	Parti Boyutu	Aktivasyon Fonksiyonu	Optimizasyon Fonksiyonu	Katman Türü	Katman Sayısı	Eğitim Tur Sayısı
1	32x32	2	softmax	rmsprop	Evrişimli K.		
2	64x64	4	exponential	adam	Ort. Havuzlama K.		
3	128x128	8	ReLU	fttl	Bırakma K.	Giriş K. + Gizli K. (36’ya kadar) + Çıktı K.	Temsil Değeri x 2
4	192x192	12	sigmoid	SDG	Maks. Havuzlama K.		Temsil Aralığı: 1-18
5	256x256	16	tanh	adagrad	Tam Bağlı K.		
6	-	32	-	-	Düzleştirme K.		
0	-	-	-	-	Katman Yok		

Örneğin temsil değeri 3 olduğunda hedef boyutu için 128x128 değerinin, parti boyutu için 8 değerinin, aktivasyon fonksiyonu için ReLU’nun, optimizasyon fonksiyonu için fttl’nin ve katman türünde ise bırakma katmanının kullanıldığı anlaşılmaktadır. Katman sayısında ise giriş ve çıkış katmanları sabit olduğundan çözüm temsilinein belirtilmemektedir. Bu iki katman arasındaki diğer katmanlar en fazla 36 olacak şekilde temsil edilmektedir. İlk katman evrişimli katman, son iki katman da düleştirme katmanı ve tam bağlı katman olarak sabit bir şekilde belirlenmiştir. Son olarak eğitim tur sayısı ise 1-18 temsil aralığında tanımlanmaktadır ve

“temsil değeri x 2” ile hesaplanmaktadır. Örneğin temsil değeri 7 olarak seçildiğinde gerçekte eğitim tur sayısı 14 olmaktadır.

Hiperparametreler					Kat. Sayısı	Katman Türleri ve Sıralanışları																															
5	3	5	2	13	17	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
1-5	1-6	1-5	1-5	1-18	1-36	0-6																															
Temsil Aralıkları																																					

Şekil 13. Çözüm temsili

Pertürbasyon

Benzetilmiş tavlama, metalurjideki tavlama işleminden ilham alan olasılıksal bir optimizasyon yöntemidir. Geniş bir arama uzayında belirli bir fonksiyonun global optimumuna iyi bir yaklaşımını bulmak için kullanılır. Algoritma bir başlangıç çözümüyle başlar ve rastgele hareketler yaparak çözüm uzayını yinelemeli olarak araştırır. Bu hamleler, tavlama sürecini simüle ederek zamanla kademeli olarak azalan bir olasılık dağılımına göre kabul edilir veya reddedilir. Benzetilmiş tavlama algoritması özellikle arama uzayının karmaşık olduğu ve birçok yerel optimum içerebildiği optimizasyon problemleri için kullanışlıdır (Kirkpatrick, Gelatt, & Vecchi, 1983).

Pertürbasyon, bir sistemin davranışını keşfetmek veya performansını optimize etmek amacıyla bir sistemde veya çözümde küçük değişiklikler veya yenilikler yapma eylemini ifade eder. Optimizasyon algoritmalarında pertürbasyon genellikle yerel optimumlardan kaçmak ve daha iyi çözümler aramak için kullanılır. Mevcut çözüme küçük rastgele değişiklikler getiren pertürbasyon teknikleri, arama uzayının yeni bölgelerini keşfetmeyi ve potansiyel olarak daha iyi bir çözüm bulmayı amaçlar. Pertürbasyon stratejileri, optimizasyon problemine özgüdür ve kullanılan algoritmaya bağlı olarak değişebilir (Kuo, Chen, & Keng, 2021).

Metasezgisel yöntemler, genellikle bir başlangıç çözümünden yola çıkarak ve ardından çeşitli değişiklikler yaparak daha iyi bir çözüm ararlar. *Yeni Düğüm Ekleme (Yenileme) ise*, mevcut bir çözüme yeni bir bileşen eklenmesi veya mevcut bir bileşenin değiştirilmesi gerektiğinde, bu eklemenin veya değişikliğin nasıl yapılacağını ifade eder (Prasad, Mishra, & Laskar, 2021). Bu sayede, algoritmanın çözüm alanını daha iyi araştırması ve daha iyi sonuçlar elde etmesi amaçlanır.

Swap yöntemi, metasezgiseller içinde sıklıkla kullanılan bir pertürbasyon tekniğidir. Bu teknik, bir aday çözümdeki iki elemanın yerlerini değiştirerek yeni bir çözüm elde etmeyi amaçlar (Xu, Cao, Shi, & Gorbachev, 2023). Bu yer değiştirme işlemi genellikle rastgele seçilen iki eleman arasında gerçekleştirilir.

Bu çalışmada *Yeni Düğüm Ekleme* ve *Swap yöntemleri* pertürbasyon fonksiyonu olarak kullanılmaktadır. Tam otomatik derin öğrenme modeli üreticinin merkezinde benzetilmiş tavlama algoritması çalışmaktadır ve pertürbasyon süreci de toplam 3 aşamadan oluşmaktadır. Bu sürece ait sözde kod Tablo 9’da paylaşılmıştır.

Benzetilmiş tavlama algoritmasında kullanılan pertürbasyon yönteminde Tablo 9’daki sözde kodda görüldüğü gibi *modelList* isimli liste değişkeni giriş ve çıkış değişkeni olarak kullanılmıştır. Bu değişken bir çözümü içerisinde saklamaktadır. Mevcut çözümü içeren ve örnek görünümü Şekil 14’de verilen *modelList* değişkeni sözde kod sonunda pertürbe edilerek geri döndürülmektedir.

Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																											
5 3 5 2 13	17	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																											

Şekil 14. Pertürbasyon işlemlerinin gerçekleştirildiği örnek çözüm temsili

I. Bölgenin pertürbasyon süreci Tablo 9’da 2 ile 13. satırlar arasında gerçekleştirilmektedir. Öncelikle 1. Satırda 0 ile 1 arası rastgele bir sayı üretilmektedir. Üretilen bu değer, 0,6’dan büyük ise (%40 olasılıkla) Şekil 15’de yer alan I. Bölge pertürbe edilmektedir. Bu süreçte *Yeni Düğüm Ekleme* pertürbasyon yöntemi kullanılmaktadır. *modelList* değişkeninin ilk 5 indisini kapsayan I. Bölge için rastgele olarak temsil aralığında bir tamsayı üretilmekte ve yine rastgele olarak seçilen bir indisin değeri üretilen bu sayı ile doldurulmaktadır. Örnek uygulama Şekil 15’de gösterilmektedir.


Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																											
5 3 5 2 13	17	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																											
[1-6]																													
Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																											
5 1 5 2 13	17	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																											

Şekil 15. I. Bölge pertürbasyon örneği


Tablo 9. Pertürbasyon Yöntemine Ait Sözde Kod

Algoritma 2: Pertürbasyon Yönteminin Sözde Kodu	
Input:	<i>modelList</i>
Output:	<i>modelList</i>
Begin	
1:	<i>randomValue</i> $\leftarrow$ <i>GenerateRandomFloat</i> (0,1)
2:	if <i>randomValue</i> > 0.6 then
3:	<i>index</i> $\leftarrow$ <i>GenerateRandomInteger</i> (0,4)
4:	if <i>index</i> is equal to 1 then
5:	<i>modelList</i> [1] $\leftarrow$ <i>GenerateRandomInteger</i> (1,6)
6:	End if
7:	else if <i>index</i> is equal to 4 then
8:	<i>modelList</i> [4] $\leftarrow$ <i>GenerateRandomInteger</i> (1,18)
9:	End if
10:	else
11:	<i>modelList</i> [<i>index</i>] $\leftarrow$ <i>GenerateRandomInteger</i> (1,5)
12:	End if
13:	End if
14:	else if <i>randomValue</i> > 0.2 then
15:	<i>finalIndex</i> $\leftarrow$ 5 + <i>modelList</i> [5]
16:	<i>randomValueII</i> $\leftarrow$ <i>GenerateRandomFloat</i> (0,1)
17:	if <i>randomValueII</i> > 0.25 then
18:	<i>index1</i> $\leftarrow$ <i>GenerateRandomInteger</i> (7, <i>finalIndex</i> - 2)
19:	<i>index2</i> $\leftarrow$ <i>GenerateRandomInteger</i> (7, <i>finalIndex</i> - 2)
20:	<i>swap</i> $\leftarrow$ <i>modelList</i> [<i>index1</i>]
21:	<i>modelList</i> [<i>index1</i>] $\leftarrow$ <i>modelList</i> [<i>index2</i>]
22:	<i>modelList</i> [<i>index2</i>] $\leftarrow$ <i>swap</i>
23:	End if
24:	else
25:	<i>index</i> $\leftarrow$ <i>GenerateRandomInteger</i> (7, <i>finalIndex</i> - 2)
26:	<i>modelList</i> [<i>index</i>] $\leftarrow$ <i>GenerateRandomInteger</i> (1,6)
27:	End if
28:	End if
29:	else
30:	<i>numberOfLayers</i> $\leftarrow$ <i>modelList</i> [5]
31:	<i>modelList</i> [5] $\leftarrow$ <i>GenerateRandomInteger</i> (1,36)
32:	if <i>numberOfLayers</i> - <i>modelList</i> [5] > 0 then
33:	<i>i</i> $\leftarrow$ 5 + <i>numberOfLayers</i>
34:	while <i>i</i> not equal to (5 + <i>modelList</i> [5]) do
35:	<i>modelList</i> [<i>i</i>] $\leftarrow$ 0
36:	<i>i</i> --
37:	end while
38:	<i>modelList</i> [<i>i</i> - 1] $\leftarrow$ 6
39:	<i>modelList</i> [<i>i</i>] $\leftarrow$ 5
40:	End if
41:	else if <i>numberOfLayers</i> - <i>modelList</i> [5] < 0 then
42:	<i>i</i> $\leftarrow$ 5 + <i>numberOfLayers</i>
43:	while <i>i</i> not equal to (5 + <i>modelList</i> [5]) do
44:	<i>modelList</i> [<i>i</i> - 1] $\leftarrow$ <i>GenerateRandomInteger</i> (1,6)
45:	<i>i</i> ++
46:	end while
47:	<i>modelList</i> [<i>i</i> - 1] $\leftarrow$ 6
48:	<i>modelList</i> [<i>i</i>] $\leftarrow$ 5
49:	End if
50:	End if
51:	return <i>modelList</i> ;
End	

III. Bölgenin pertürbasyon süreci Tablo 9'daki sözde kodun 14 ile 28. satırları arasında gerçekleştirilmektedir. Sözde kodun 1. satırında üretilen rastgele değer 0,6'dan küçük eşit ve 0,2'den büyükse (%40 olasılıkla) Şekil 16'da yer alan III. Bölge pertürbe edilmektedir. Bu kısımda iki farklı pertürbasyon yöntemi kullanılmaktadır. Bunun için 16. satırda yeniden bir ondalıklı sayı üretilmektedir. Bu sayının değeri 0.25'den büyükse (%75 olasılıkla) III. bölgede Swap işlemi uygulanarak pertürbasyon süreci tamamlanmaktadır. Eğer üretilen sayının değeri 0.25'den küçük ve eşitse (%25 olasılıkla) Yeni Düğüm Ekleme işlemi uygulanarak bölge pertürbe edilmektedir. Swap işleminde, modelList değişkeninin 7-40 arası (ilk katman ve son iki katman sabit olduğundan 6, 41 ve 42. katmanlar dikkate alınmamaktadır) indislerini kapsayan III. Bölge için rastgele olarak 2 adet indis değeri üretilmektedir. Üretilen bu iki indis içerisindeki değerler yer değiştirilmektedir. Örnek uygulama Şekil 16'da gösterilmektedir. Yeni Düğüm Ekleme işleminde de aynı aralıktaki indis değerlerinden birisi rastgele sayı üretilmek suretiyle seçilerek indis değerinin yerine 1 ile 6 değerleri arasında rastgele farklı bir katman türü değeri atanmaktadır. Bu yöntemle mimari içerisindeki katman türü değişimi sağlanarak komşu çözümlerde dolaşım sağlanmaktadır. Örnek uygulama Şekil 17'de gösterilmektedir. Tablo 9'daki 15. satırda yer alan modelList[5] içerisinde katman sayısı tutulmaktadır. 0-4 indisleri arasında hiperparametre değerleri tutulduğu için bu indislerden sonraki indisler ile ağın katmanlarının bittiği indisler arasında Swap işlemi yapılmaktadır. Fakat sözde kodda 18. ve 19. satırlar incelendiğinde 6. indisteki katman ile son 2 katmanın Swap işlemine dahil edilmediği görülmektedir. Bunun nedeni ağın ilk katmanının evrişimli katman ile başlamasını sağlamaktır. Son iki katman da çıkış işlemlerinin sağlandığı düğümlerin ikili sınıflandırma seviyesine indirgenmesinden dolayı sabit tutularak Swap işlemlerine dahil edilmemiştir. Kısaca ağın ilk katmanı ve son iki katmanı her zaman sabit tutulmaktadır. Bu katmanlar değiştirildiğinde derin öğrenme modellerinin doğası gereği çalışma zamanı hatası oluşabilmektedir.



Şekil 16. III. Bölge Swap pertürbasyon örneği



Şekil 17. III. Bölge Yeni Düğüm Ekleme pertürbasyon örneği

II. Bölgenin pertürbasyon süreci Tablo 9’da 29 ile 50. satırlar arasında gerçekleştirilmektedir. Öncelikle 1. satırda üretilen rastgele sayı 0,2’den küçük ve eşitse (%20 olasılıkla) II. Bölge pertürbe edilmektedir. Bu kısımda katman sayısı *Yeni Düğüm Ekleme* pertürbasyon yöntemi kullanılarak değiştirildiği için ağ içerisindeki katmanlar artırılarak veya azaltılarak işlemler gerçekleştirilmektedir. Katman sayısı azaltmada son iki katmandan önceki son katmanlar çıkarılarak ağ küçültülmektedir. Katman sayısı artırmada ise sondaki iki katman öncesine rastgele oluşturulan katmanlar eklenerek ağ büyütülmektedir. Örnek katman sayısı azaltma uygulaması Şekil 18’de ve katman sayısı artırma uygulaması da Şekil 19’da gösterilmektedir.

Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																			
5 3 5 2 13	17	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	1	4	3	0	0
I. Bölge	II. Böl.	III. Bölge																			
Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																			
5 3 5 2 13	14	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																			

Şekil 18. II. Bölge katman sayısı azaltma pertürbasyon örneği

Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																			
5 3 5 2 13	17	1	4	3	1	4	3	1	4	3	1	4	3	6	5	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																			
Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																			
5 3 5 2 13	19	1	4	3	1	4	3	1	4	3	1	4	3	2	1	6	5	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																			

Şekil 19. II. Bölge katman sayısı artırma pertürbasyon örneği

Çözüm temsilinden derin öğrenme modelinin elde edilmesi

Benzetilmiş tavlama yönteminde her bir çözüm temsili bir liste yapısında tutulmaktadır. 42 boyutlu bu listenin ilk 5 indisi hiperparametre değerlerini, 6. indis katman sayısını ve geriye kalan diğer indisler ise katmanların türlerine göre sıralanışını saklamaktadır. Makine öğrenmesi algoritması ile maliyet hesaplamasına dayalı olarak üretilen bu çözümlerin gerçek derin öğrenme modeli olarak tasarlanıp test edilmesi ve nihai olarak tüm veri seti ile başarısının ölçülmesi gerekmektedir. Bu durumda liste halinde tutulan mevcut çözümün derin öğrenme modeline dönüştürülmesi sürecinde Tablo 10’daki sözde kod kullanılmaktadır.

Tablo 10’da *modelList* olarak adlandırılan değişken çözüm temsili saklamaktadır. 1. ve 7. satırlar arasında bu liste alt değişkenlere ayrılmaktadır. Örneğin ilk 5 indisteki değerler sırasıyla ait oldukları hiperparametre değişkenlerine atanmaktadır. Bu hiperparametre değerleri görüntü verilerinin giriş katmanına (8-10. satırlar) girdi olarak verilmesinden modelin derlenmesine (33. satır) kadar olan süreçlerin ilgili kısımlarında kullanılmaktadır. Tablo 10’da 11 – 30. satırlar arasında temsil değerlerine göre katmanlar sırasıyla modele eklenmektedir. 31.

ve 32. satırlarda modelin son katmanları eklenmektedir. Bu katmanlar sabittir. Derin öğrenme mimarisi *Python* dilinde *Tensorflow Keras* kütüphanesi kullanılarak oluşturulmaktadır.

Tablo 10. Derin Öğrenme Modeli Oluşturma Sürecine Ait Sözde Kod

Algoritma 3: Derin Öğrenme Modeli Oluşturma Süreci Sözde Kodu
Input: <i>modelList, images</i> Output: <i>dLModel</i> Begin <pre> 1: <i>targetSize</i> ← <i>modelList</i>[0]; 2: <i>batchSize</i> ← <i>modelList</i>[1]; 3: <i>activation</i> ← <i>modelList</i>[2]; 4: <i>optimizer</i> ← <i>modelList</i>[3]; 5: <i>epoch</i> ← <i>modelList</i>[4]; 6: <i>numberOfLayers</i> ← <i>modelList</i>[5]; 7: <i>architecture</i> ← <i>modelList</i>[6:41]; 8: <i>data</i> ← <i>ReadImages</i>(<i>images, batchSize, targetSize</i>); 9: <i>dLModel</i> ← <i>tensorflow.keras.DefineModel</i>(); 10: <i>dLModel.AddLayer</i>(<i>Conv, activation, targetSize</i>); 11: for <i>i</i> ← 1 to <i>numberOfLayers</i> by 1 do 12: if <i>architecture</i>[<i>i</i>] is equal to 1 then 13: <i>dLModel.AddLayer</i>(<i>Conv</i>); 14: End if 15: else if <i>architecture</i>[<i>i</i>] is equal to 2 then 16: <i>dLModel.AddLayer</i>(<i>AvgPooling</i>); 17: End if 18: else if <i>architecture</i>[<i>i</i>] is equal to 3 then 19: <i>dLModel.AddLayer</i>(<i>Dropout</i>); 20: End if 21: else if <i>architecture</i>[<i>i</i>] is equal to 4 then 22: <i>dLModel.AddLayer</i>(<i>MaxPooling</i>); 23: End if 24: else if <i>architecture</i>[<i>i</i>] is equal to 5 then 25: <i>dLModel.AddLayer</i>(<i>Dense</i>); 26: End if 27: else if <i>architecture</i>[<i>i</i>] is equal to 6 then 28: <i>dLModel.AddLayer</i>(<i>Flatten</i>); 29: End if 30: end for 31: <i>dLModel.AddLayer</i>(<i>Flatten</i>); 32: <i>dLModel.AddLayer</i>(<i>Dense, activation</i>); 33: <i>dLModel.Compile</i>(<i>data, optimizer, epoch</i>); 34: return <i>dLModel</i>; End</pre>

SA ile Tam Otomatik, Metasezgisel ve Makine Öğrenmesi Tabanlı Derin Öğrenme Modeli Üreticinin Geliştirilmesi

Bu çalışma kapsamında, hiperparametrelerin belirlenmesi, derin öğrenme mimarisinin katman sayısı ve türlerinin yanı sıra katmanların sıralanışının da dikkate alınarak tüm bileşenlerin birlikte optimize edilmesiyle, tam otomatik bir prensiple çalışan, metasezgisel ve makine öğrenmesi tabanlı KES-DAL-GEN isimli yenilikçi bir üreteç geliştirilmiş ve yeni derin öğrenme mimarileri üretilmiştir. Bu sistemin genel tasarımı Şekil 20’de gösterilmektedir. Derin öğrenme modeli üreticinin merkezinde benzetilmiş tavlama algoritması bulunmaktadır.




Şekil 20. Yenilikçi, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı derin öğrenme modeli üretici KES-DAL-GEN sisteminin genel tasarımı

Tablo 11. Tam Otomatik Derin Öğrenme Modeli Üreticinin (KES-DAL-GEN) Sözde Kodu

Algoritma 4: KES-DAL-GEN Sözde Kodu	
Input:	<i>parametersSA, limitedParametersSA, images, imagesAll, numberDL</i>
Output:	<i>architectureDL, hyperParameterContainer, metricContainer</i>
Begin	
1:	<i>df</i> ← <i>Read(images)</i> ;
2:	while <i>NumberData(dataSet) < NumberData(df) * 10/100</i> do
3:	<i>dataSet</i> ← <i>CreateDSforMLusingLimitedSA(limitedParametersSA, df, cost = DLacc)</i> ;
4:	<i>modelRF</i> ← <i>TrainRandomForest(dataSet)</i> ;
5:	<i>modelLR</i> ← <i>TrainLinearRegression(dataSet)</i> ;
6:	<i>modelSVM</i> ← <i>TrainSupportVectorMACHINE(dataSet)</i> ;
7:	<i>modelML</i> ← <i>ModelSelector(modelRF, modelLR, modelSVM)</i> ;
8:	if <i>0.9 < R2(modelML)</i> then
9:	break ;
10:	end if
11:	end while
12:	<i>initDLModel</i> ← <i>VGG16Model</i> ;
13:	for <i>i</i> ← 1 to <i>numberDL</i> by 1 do
14:	<i>foundDL</i> ← <i>DiscoverDLwithSA(parametersSA, dataSet, initDLModel, cost = modelMLRegression)</i> ;
15:	<i>modelDL</i> ← <i>CreateRealDLModel(foundDL.architecture, foundDL.hyperParameters)</i> ;
16:	<i>Train.modelDL(df)</i>
17:	Print (<i>foundDL.score, modelDL.score</i>);
18:	<i>dfAll</i> ← <i>Read(imagesAll)</i> ;
19:	<i>Train.modelDL(dfAll)</i> ;
20:	<i>metricContainer</i> ← <i>modelDL.score(acc, prc, rcl, f1sc, auc)</i> ;
21:	<i>hyperParameterContainer</i> ← <i>modelDL.parameters</i> ;
22:	<i>architectureDL</i> ← <i>modelDL.architecture</i> ;
23:	return <i>architectureDL, hyperParameterContainer, metricContainer</i> ;
24:	end for
End	

Tablo 8’de her bir parametre değeri için temsil edilen tam sayı aralığı verilmiştir. Örneğin, hedef boyutu parametresi için 1 ile 5 arasında 5 değer temsil aralığı olarak belirlenmiştir. 5. değer 256x256 parametresine karşılık gelmektedir. SA yönteminde her parametre temsil edildiği aralığa göre pertürbasyon fonksiyonuna gönderilerek pertürbe edilmektedir. Her yeni sıcaklık değerinde bu işlem tekrarlanmaktadır. Bu parametreler ve değerleri bir liste yapısında tutulmaktadır.

Yenilikçi, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı derin öğrenme modeli üretici KES-DAL-GEN sisteminin sözde kodu Tablo 11’de verilmiştir. Şekil 21’de sistemin tüm süreçlerine ait akış şeması gösterilmektedir. Sözde kod ve akış şemasının açıklamaları alt başlıklar altında detaylandırılmaktadır.




Şekil 21. Tam otomatik derin öğrenme modeli üreticinin (KES-DAL-GEN) akış şeması

Makine Öğrenmesi Yöntemleri İçin Mimari Veri Setinin Oluşturulması

Makine öğrenmesi yöntemleri için mimari veri setinin oluşturulması işlemleri Şekil 21’deki A alanında gerçekleştirilmektedir. Şekil 22’de yer alan iş akış şemasında ①. adımda görüntülerden oluşan veri seti (Görüntü Veri Seti) ilgili dizinden okunmaktadır. Adım ②’de tüm veri setinden (HAM10000 için 10015 adet) %3 oranında seyreltilmiş veri seti (300 adet) oluşturulmaktadır. Seyreltilmiş veri seti tüm veri setinin küçük bir örneklemdir. Yani HAM10000 veri seti içerisinde bulunan 8 hastalığın bulunma oranıyla uyumlu bir şekilde seyreltme işlemi gerçekleştirilmiştir. Bu seyreltmenin amacı çalışmada metasezgisel yöntem olarak kullanılan benzetilmiş tavlama algoritmasının *maliyet fonksiyonu* hesaplamasının

hızlandırılmasıdır. Daha az veri ile derin öğrenme modelinin eğitilmesi ve başarısının hesaplanması çok daha kısa sürmektedir. Böylece belirli oranda başarı sağlayan modeller keşfedilmekte ve nihai başarı hesaplamalarında tüm veri seti kullanılmaktadır. Tablo 11’de verilen sözde kodda *input* olarak kullanılan *images* (sayıca seyreltilmiş görüntüler, 300 adet) ve *imagesAll* (veri setindeki tüm görüntüler, 10015 adet) kullanılan veri setindeki görüntüleri temsil etmektedir. Akış şemasının ①. adımı sözde kodda 1. satırda tamamlanmaktadır.

Tablo 11’de yer alan *parametersSA* giriş değeri optimizasyonda kullanılan SA algoritmasının parametre değerlerini (başlangıç sıcaklığı, soğuma oranı, iterasyon sayısı vb.) temsil etmektedir. Bu parametre değerleri Şekil 21’deki akış şemasında ⑥. adımda yer alan SA algoritmasının çalıştırılması sırasında kullanılmaktadır. Sözde kodda yer alan *limitedParametersSA* değeri ise regresyon sürecinde kullanılacak olan veri setinin üretimi sürecinde kısıtlı olarak çalıştırılan Şekil 21’deki ③. adımda bulunan SA algoritması parametre değerlerinin belirlenmesi içindir. Sözde kodda giriş değerleri arasında olan *numberDL* değişkeni ise sistemin üreteceği toplam derin öğrenme modeli sayısını saklamaktadır.



Şekil 22. Makine öğrenmesi yöntemleri için mimari veri setinin oluşturulması süreci iş akış şeması


Benzetilmiş tavlama modelinin *maliyet fonksiyonu* hesaplamasının hızlandırılması için yeni bir yöntem geliştirilmiştir. Bu yöntemde, geleneksel makine öğrenmesi algoritmaları derin öğrenme ağını taklit ederek *doğruluk* değerini daha hızlı tespit etmektedir. Şekil 22’deki

adım ③'de çeşitli hiperparametre değerlerini, ağ katmanları sayısını, türlerini ve sıralanışlarını içeren belirli sayıda veri oluşturulmaktadır. Bu verilerin her bir satırı bir derin öğrenme modelini/mimarisini temsil etmektedir. Bu derin öğrenme modellerinin gerçekteki *doğruluk* değerleri hesaplanmaktadır. Sonra bu veriler kullanılarak makine öğrenmesi algoritmaları eğitilmektedir. Daha sonra bu makine öğrenmesi algoritmaları ağın doğruluk değerini (*maliyet fonksiyonunu*) tahmin etmektedir. Burada görüntü veri setinin yaklaşık %10'u kadar sayıda veri içeren bir mimari veri seti oluşturulmaktadır. Şekil 21'de A bölümünde çıktı olarak Mimari Veri Seti elde edilmektedir. Bu çalışmada HAM10000 veri seti kullanıldığı için %10 oranı yaklaşık 1000 satır mimari çözüm oluşturulduğu anlamına gelmektedir. Oluşturulan veri setine ait örnek görüntü Şekil 23'de sunulmuştur. Bu oran (%10), deneysel çalışmalar sonucu tespit edilmiştir. Daha az sayıda veri seti oluşturulduğunda makine öğrenmesi algoritmaları yeterli düzeyde eğitilememiştir ve daha fazla sayıda oluşturulduğunda ise aşırı öğrenmeden dolayı tahmin başarılarının düştüğü gözlemlenmiştir. Veriler benzetilmiş tavlama algoritması aracılığıyla oluşturulmuştur. Bahsi geçen algoritma kısmen düşük iterasyonlarla çalıştırılarak hem iyi hem de kötü sonuç veren modeller kaydedilmiştir. Bu aşamada ağın *maliyet fonksiyonu* her bir iterasyonda pertürbe edilen derin öğrenme modelinin eğitilmesi ve doğruluk değerinin hesaplanması sonucu elde edilmekte ve oldukça yüksek zaman almaktadır. Seyreltilmiş veri seti kullanımıyla bu süre olabildiğince bu aşamada düşürülmeye çalışılmıştır.

Makine öğrenmesi algoritmalarının regresyon süreçleri için eğitilmesinde kullanılacak olan Mimari Veri Setinin oluşturulmasında benzetilmiş tavlama algoritmasının kullanılması zorunluluğu yoktur. Ancak çalışmalar sırasında hazırlanan kodun bu amaç için de kullanılması iş yükünü azaltmıştır ve aynı zamanda benzetilmiş tavlama yönteminin çözüm uzayındaki geniş tarama özelliğinden de yararlanılmıştır. Benzetilmiş tavlama yöntemi gerçek anlamda Şekil 21'deki iş akış diyagramındaki adım ⑥'da kullanılarak optimizasyon süreci gerçekleştirilmiştir. SA bu durumda adım ③'de sadece veri seti oluşturmak için kısmen çalıştırılmıştır. Tablo 11'de yer alan sözde kodun 2. ve 3. satırları iş akış şemasının ③. adımını yerine getirmektedir.

Çalışmada, SA yöntemi Python dilinde başka bir kütüphaneden yararlanmadan yazılmıştır. İş akış diyagramının ③. adımındaki SA parametre değerlerinden olan sıcaklık değeri 100,0 °C, alfa değeri 0,91, epsilon değeri 0,012, her sıcaklıktaki iterasyon sayısı 40 olarak belirlenmiştir.

benzetilmiş tavlama yönteminde *maliyet fonksiyonunun* hesaplamasında kullanılarak hesaplama süresi mili saniyelere kadar düşürülmüştür. Böylece her bir iterasyonda saatler süren hesaplama süresi oldukça kısaltılmıştır. Literatürde derin öğrenme ağlarının hem hiperparametre hem de mimari açıdan (katman sayısı, türleri ve sıralanışları) tüm bileşenleriyle optimize edilmesinin oldukça zor bir süreç olduğu belirtilmekte ve bu nedenle sadece hiperparametre seviyesinde optimizasyon süreçlerinin yapıldığı anlatılmaktadır (Kaveh & Mesgari, 2023). Bu çalışmada kullanılan bu hızlandırıcı yöntemler ile belirtilen zorlukların bir kısmının giderilmesi neticesinde kapsamlı optimizasyonlar gerçekleştirilebilmiştir. Tablo 11’de yer alan sözde kodun 4., 5. ve 6. satırlarında makine öğrenmesi algoritmaları eğitilmiştir. Bu algoritmalarından en başarılı olanı 7. satırda seçilmiştir. 8. ve 10. satırlar arasında ise en başarılı makine öğrenmesi algoritmasının R^2 skor değerinin 0,90 değerinin üzerine çıkıp çıkmadığı kontrol edilmiştir. Eğer çıkarsa veri seti oluşturma sürecine son verilmektedir ve döngü kırılmaktadır. Aksi takdirde veri seti üretimi devam etmektedir. Burada seçilen 0,90 tahmin başarı oranı, kabul edilebilir doğrulukta regresyon işlemi yürütülmesi içindir.



Şekil 24. Derin öğrenme modellerinin üretilmesi süreci iş akış şeması

Şekil 24’de yer alan iş akış diyagramındaki adım ⑥’da derin öğrenme modeli tüm bileşenleri ile optimize edilerek orijinal yeni modeller oluşturulmaktadır. Bu adımda benzetilmiş tavlama algoritmasının başlangıç çözüm noktası için literatürde cilt kanseri problemi ve diğer problemlerde yaygın olarak kullanılan CNN tabanlı VGG16 ağı seçilmiştir. Böylece iyi bir başlangıç ile arama uzayında gezinmeye başlayan benzetilmiş tavlama

algoritması daha kısa sürede optimizasyon sürecini tamamlamaktadır. Rastgele bir noktadan başlamak yerine seçilen bu yöntem ile zamandan kazanılmış ve bu kazanılan zaman genişliğinde benzetilmiş tavlama algoritması daha fazla iterasyonla çalıştırılarak çözüm uzayındaki gezintisi artırılmıştır. Böylece daha optimum derin öğrenme modelleri keşfedilebilmiştir. Bu adımda benzetilmiş tavlama algoritmasının *maliyet fonksiyonu* geleneksel makine öğrenmesi algoritmasının tahmin ettiği *doğruluk* metriği kullanılarak hesaplanmıştır. Bu nedenle bulunan ağ aslında gerçek derin öğrenme modeline ait doğruluk değerini yansıtmamaktadır. Fakat yüksek başarı oranıyla tahmin gerçekleştiren makine öğrenmesi algoritmasının regresyon sonucu gerçek değere yakın oranları hesaplayabilmektedir. Tablo 11'deki sözde kod içerisinde 12. ve 14. satırlar arasında iş akış diyagramının ⑥. adımına ait işlemler gerçekleştirilmektedir.

İş akış diyagramının ⑥. adımındaki SA parametre değerlerinden olan sıcaklık değeri 10000,0 °C, alfa değeri 0,985, epsilon değeri 0,012, her sıcaklıktaki iterasyon sayısı 100 olarak belirlenmiştir.

Maliyet fonksiyonu

Şekil 21'deki adım ⑥'da Tablo 13'de verilen yöntem ile maliyet hesaplanmaktadır. Tablo 13'de 1. satırda adım ③'de üretilen Mimari Veri Seti kullanılarak regresyon işlemi için geleneksel makine öğrenmesi algoritması eğitilmektedir. 2. ve 3. satırlarda eğitilen model (*modelList*) ile üretilen çözümün *doğruluk* değeri tahmin edilmektedir. 4. satırda ise hesaplanan bu değer maliyet değeri olarak geri döndürülmektedir. Tablo 12'deki yönteme göre oldukça hızlı olan Tablo 13'deki maliyet hesabı çok uzun süren hesaplama süresinden tasarruf sağlamaktadır. Böylece benzetilmiş tavlama yöntemi iyi sonuç verecek şekilde kullanılabilir.


Tablo 13. Maliyet Fonksiyonu II Sözde Kodu

Algoritma 6: Maliyet Fonksiyonu II Sözde Kodu
Input: <i>modelList, dataSet</i>
Output: <i>cost</i>
Begin
1: <i>modelML</i> $\leftarrow$ <i>TrainMachineLearning(dataSet)</i> ;
2: <i>results</i> $\leftarrow$ <i>modelML.predict(modelList)</i> ;
3: <i>cost</i> $\leftarrow$ <i>results</i> ;
4: return <i>cost</i> ;
End

VGG16 modelinin SA içerisinde başlangıç çözümü olarak kullanılması

VGG16, Oxford Üniversitesi'ndeki Görsel Geometri Grubu (VGG) tarafından geliştirilen bir evrişimli sinir ağı (CNN) mimarisidir. Adı VGG16 olarak geçer çünkü 13

evrişimli katman ve 3 tam bağımlı katman dahil olmak üzere toplam 16 katmandan oluşur. Şekil 25’de VGG16 derin öğrenme modelinin mimari yapısı verilmiştir.



Şekil 25. VGG16 Derin Öğrenme Mimarisi (Choi, Bell, Kim, & Kim, 2021)

Mimarinin ayrıntıları şöyledir:

Giriş Katmanı: Sabit boyutta giriş görüntülerini kabul eder (genellikle 224x224 piksel).

Evrişim Katmanları (13 katman): Bu katmanlar giriş görüntüsünde evrişim işlemleri gerçekleştirir. Her evrişim katmanı, modele doğrusallığı azaltan bir düzleştirilmiş doğrusal birim (ReLU) *aktivasyon fonksiyonuyla* takip edilir. VGG16’deki evrişim katmanları, girişin uzamsal boyutlarının korunduğu küçük 3x3 evrişim filtreleri kullanılarak göreceli olarak işlem yoğunluğunu basitleştirmektedir (Navale, 2023).

Havuzlama Katmanları: Birkaç evrişim katmanından sonra, havuzlama katmanları, öznitelik haritalarının uzamsal boyutlarını küçültmek için kullanılır. Havuzlama süreci, modelin hesaplama karmaşıklığını azaltır ve en önemli öznitelikleri çıkarmaya yardımcı olur.

Tam Bağımlı Katmanlar (3 katman): Bunlar, bir katmandaki her nöronun bir sonraki katmandaki her nörona bağlı olduğu geleneksel sinir ağı katmanlarıdır. VGG16’deki tam bağlantılı katmanlar, evrişim katmanları tarafından çıkarılan özniteliklere dayanarak tahminler yapmak için kullanılır.

Çıkış Katmanı: Ağın son katmanı çıkış tahminlerini üretir. Sınıflandırma görevlerinde, bu katman genellikle her sınıf için olasılıkları çıkarmak için bir softmax *aktivasyon fonksiyonuna* sahiptir.

VGG16, özellikle görüntü sınıflandırma görevlerinde basitliği ve etkinliği nedeniyle popülerlik kazanmıştır. Ancak, 138 milyondan fazla parametreye sahiptir, bu da onu eğitmek ve dağıtmak noktasında hesaplama açısından maliyetli hale getirir, modern mimariler olan

ResNet veya EfficientNet gibi. Bununla birlikte, VGG16, derin öğrenme alanında yaygın olarak kullanılan bir referans modelidir.

VGG16 modeli görüldüğü üzere kapsamlı olarak geliştirilmiş ve literatürde kabul görmüş bir derin öğrenme modelidir. Bu nedenle Şekil 24'deki iş akış diyagramındaki adım ⑥'da SA içerisinde başlangıç çözümü olarak kullanılmasına karar verilmiştir. Başlangıç çözümünün rastgele başlaması yerine alınan bu karar sayesinde SA algoritması çözüm uzayında iyi bir noktadan aramaya başlamaktadır. Böylece derin öğrenme optimizasyon süreci daha erken bitmektedir. Kazanılan bu zaman dilimi SA iterasyon sayısı artırılarak kullanılmaktadır. Böylece aynı zaman içerisinde daha fazla çözüm taranarak optimizasyon süreci iyileştirilmektedir. Şekil 26'da VGG16 modelinin bu tez kapsamında geliştirilen çözüm temsili gösterimine yer verilmiştir.

Hiperparametreler	Kat. Sayısı	Katman Türleri ve Sıralanışları																											
5 2 3 2 5	20	1	1	3	1	1	3	1	1	1	3	1	1	1	3	1	1	1	3	6	5	0	0	0	0	0	0	0	0
I. Bölge	II. Böl.	III. Bölge																											

Şekil 26. VGG16 modelinin çözüm temsilindeki gösterimi

Makine öğrenmesi algoritmaları ile regresyon yapılarak maliyet hesaplanması

Regresyon, bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkileri modellemek ve analiz etmek için kullanılan istatistiksel bir yöntemdir. Makine öğrenimi bağlamında, regresyon algoritmaları sürekli bir sonucu tahmin etmeyi amaçlar, bu da onları konut fiyatlarını, hisse senedi fiyatlarını veya herhangi bir sayısal değeri tahmin etme gibi görevlere uygun hale getirir. Regresyon süreci, geçmiş verileri kullanarak bir modeli eğitmeyi, değişkenler arasındaki kalıpları ve ilişkileri çıkarmayı ve ardından eğitilmiş modeli yeni, görünmeyen veriler hakkında tahminlerde bulunmak için kullanmayı içerir. Doğrusal regresyon, polinom regresyonu ve destek vektör regresyonu veya rastgele orman regresyonu gibi daha gelişmiş yöntemler dahil olmak üzere çeşitli regresyon algoritmaları mevcuttur. Regresyon modellerinin başarısı, verilen problem için uygun bir algoritmanın seçilmesine ve optimum tahmin performansı elde etmek için parametrelerinde ince ayar yapılmasına bağlıdır.

Bu tez çalışmasında makine öğrenmesi algoritmalarından Rastgele Orman, Lojistik Regresyon ve Destek Vektör Makinesi kullanılarak bir derin öğrenme modelinin *doğruluk* değeri tahmin edilmeye çalışılmıştır. Benzetilmiş Tavlama yönteminde *maliyet (cost) fonksiyonu* hesaplamasında derin ağıın eğitim *doğruluk* değeri kullanılmaktadır. Ağıın eğitimi süresi çok uzun sürdüğü için bu *doğruluk* değeri, bahsedilen 3 makine öğrenmesi algoritmasıyla regresyon işlemi yapılarak tahmin edilmeye çalışılmıştır. Böylece *maliyet fonksiyonu* hesaplama süresi oldukça kısalarak SA yöntemi ile derin öğrenme mimarisi ve

hiperparametreleri optimize edilmeye çalışılmıştır. Bu algoritmalarından hangisi daha iyi tahminde bulunuyorsa o algoritma regresyon işlemi için sistem tarafından otomatik seçilerek kullanılmıştır. Aşağıda kullanılan algoritmalara dair açıklamalara yer verilmiştir.

Rastgele Orman (RO)

Rastgele Orman hem sınıflandırma hem de regresyon görevleri için yaygın olarak kullanılan bir topluluk öğrenme tekniğidir. Eğitim aşamasında çok sayıda karar ağacı oluşturarak çalışır ve regresyon problemleri için ortalama tahmini veya sınıflandırma problemleri modunu çıkarır. Her karar ağacı, eğitim verilerinin bir alt kümesi ve rastgele bir öznitelik alt kümesi kullanılarak oluşturulur ve ağaçlar arasında çeşitlilik sağlar. Anahtar kavram, birden fazla ağacın tahminlerini birleştirerek, Rastgele Ormanın aşırı uyumu azaltma eğiliminde olması ve modelin genel doğruluğunu artırmasıdır. Ek olarak, gürültülü verilere ve aykırı değerlere karşı dayanıklıdır, bu da onu çok yönlü ve güçlü bir algoritma haline getirir. Random Forest'ın popüleritesi, yüksek boyutlu veri kümelerinin işlenmesindeki basitliği, ölçeklenebilirliği ve etkinliğinden kaynaklanmaktadır (Keith, 2020). Bu algoritmanın kodlanmasında Python programlama dilinin *RandomForestRegressor* kütüphanesi kullanılmıştır. *n_estimators* parametresinin değeri 100 olarak seçilmiştir.

Lojistik Regresyon (LR)

Lojistik regresyon, özellikle ikili sınıflandırma problemleri için uygun olan ve yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. Adına rağmen, lojistik regresyon, regresyon görevlerinden ziyade sınıflandırma için kullanılır. Algoritma, bir örneğin belirli bir sınıfa ait olma olasılığını modelleyerek, giriş özniteliklerini lojistik işlevini kullanarak 0 ile 1 arasındaki bir aralığa eşleştirir. Eğitim, verilen girdi verilerine karşılık gelen gözlemlenen sınıf etiketlerinin olasılığını en üst düzeye çıkarmak amacıyla model parametrelerinin optimize edilmesini içerir. Lojistik regresyon doğası gereği doğrusaldır, bu da onu her özelliğe ağırlık atadığı için hesaplama açısından verimli ve yorumlanabilir hale getirir. Sadeliği ve uygulama kolaylığı, onu girdi öznitelikleri ile hedef değişken arasındaki ilişkiyi anlamamanın çok önemli olduğu uygulamalar için popüler bir seçim haline getirir. Ek olarak, lojistik regresyon, bire bir gibi bazı tekniklerle çok sınıflı sınıflandırmayı işlemek için genişletilebilir. Sadeliğine rağmen, lojistik regresyon, makine öğrenimi alanında güçlü ve çok yönlü bir araç olmaya devam etmektedir (Hosmer, Lemeshow, & Sturdivant, 2005). Bu algoritmanın kodlanmasında Python programlama dilinin *LogisticRegression* kütüphanesinden faydalanılmıştır.

Destek Vektör Makinesi (SVM)

Destek Vektör Makinesi (SVM), hem sınıflandırma hem de regresyon görevleri için kullanılan güçlü ve çok yönlü bir makine öğrenimi algoritmasıdır. Veri noktalarını yüksek boyutlu bir alanda farklı sınıflara en iyi ayıran en uygun hiper düzlemi bulmada üstündür. SVM, hiper düzlem ile her sınıftan en yakın veri noktaları arasındaki mesafe olan marjı en üst düzeye çıkarmayı amaçlar. Bu yaklaşım sadece gürültüye ve aykırı değerlere karşı sağlamlığı teşvik etmekle kalmaz, aynı zamanda görünmeyen verilere de genelleme yapar. SVM özellikle karmaşık karar sınırlarına sahip senaryolarda etkilidir ve görüntü sınıflandırması, metin sınıflandırması ve biyolojik veri analizinde yaygın olarak kullanılır. Ayrıca SVM, çekirdek işlevlerini kullanarak değişkenler arasındaki hem doğrusal hem de doğrusal olmayan ilişkileri işleyebilir ve verilerdeki karmaşık kalıpları yakalamasına olanak tanır. Çok yönlülüğü, yüksek boyutlu verileri işleme yeteneği ve güçlü genelleme performansı, SVM'nin makine öğreniminin çeşitli alanlarındaki popülaritesine katkıda bulunur (Noble, 2013). Bu algoritmanın kodlanmasında Python programlama dilinin SVR kütüphanesinden faydalanılmıştır. C parametresinin değeri 2, *kernel* parametresinin değeri ise *linear* olarak seçilmiştir.

Üretilen Derin Öğrenme Modellerinin Etkinliğinin Test Edilmesi

KES-DAL-GEN üretici tarafından üretilen derin öğrenme modellerinin etkinliğinin test edilmesi işlemleri Şekil 21'deki C bölgesinde gerçekleştirilmektedir. Şekil 27'deki adım ⑦'de, adım ⑥'da üretilen ağıın gerçekte tasarlanması ve gerçek *doğruluk* metriğinin hesaplanması yapılmaktadır. Böylece makine öğrenmesi tahminine dayalı olarak keşfedilmiş modelin gerçekte ne kadarlık başarı gösterdiği raporlanmaktadır. Tablo 11'deki sözde kod içerisinde 15. ve 17. satırlar arasında iş akış diyagramının ⑦. adımına ait işlemler gerçekleştirilmektedir.

Adım ⑨'a kadar başarı hesaplamalarında sadece *doğruluk* değeri kullanılmıştır. Ağıın performansının belirlenmesinde bu adıma kadar önemli bir işlev yürüten *doğruluk* değeri hesaplamasına bu adımda *kesinlik*, *duyarlılık*, *AUC* ve *F1-skor* metrikleri de eklenmiştir. Bunun nedeni entropisi yüksek veri setlerinde (eşit oranlarda etiket türü içermeyen) doğruluk değerinin tek başına başarı hesaplamasında her zaman doğru sonucu gösterememesidir. Yani verilerin %80'i kanser içermeyen görüntü ise ve önerilen yöntem tüm görüntüler için kanser değil teşhisinde bulunursa %80 oranında doğruluğa sahip olacaktır. Aslında hiçbir teşhiste bulunamayan algoritma kısmen başarılı görülecektir. Bu nedenle diğer metriklerle birlikte nihai başarının değerlendirilmesi önem arz etmektedir. Ayrıca adım ⑧'e kadar Seyreltilmiş Veri Setine dayalı olarak adımlar yürütülmüştür. Bu adımda ise nihai sonuçlar hesaplanacağından tüm Görüntü Veri Seti kullanılarak keşfedilen derin öğrenme modeli baştan

eğitilmiş ve daha sonra başarısı belirtilen 5 metrikle test edilmiştir. Bu aşamada %80 eğitim ve %20 test verisi kullanılarak hesaplamalar gerçekleştirilmiştir. Tablo 1'deki sözde kod içerisinde 18. ve 24. satırlar arasında iş akış diyagramının ⑧ - ⑨. adımlarına ait işlemler gerçekleştirilmektedir.



Şekil 27. Üretilen derin öğrenme modellerinin etkinliğinin test edilmesi süreci iş akış şeması

Adım ⑨'da keşfedilmiş ve başarısı test edilmiş derin öğrenme modelinin Python programlama dilinde *plot_model* kütüphanesi kullanılarak çizimi gerçekleştirilmiştir. Ayrıca *doğruluk* ve *loss* değerlerine ait grafikler otomatik olarak çizdirilerek raporlanmıştır. Böylece başlangıçta görüntülere ait veri setlerinin bulunduğu dizinin kullanıcı tarafından sisteme girdi olarak verilmesinden sonra tüm süreçler otomatik olarak işletilerek optimum bir ağ keşfedilmekte ve bu modele ait sonuçlar raporlanmaktadır.

Performans ölçüm metrikleri

Çalışma kapsamında doğruluk, kesinlik, duyarlılık, AUC, F1-skor ve R^2 performans ölçüm metriklerinden faydalanılmıştır. Bu metrikler üretilen modellerin performansını birçok yönüyle ölçebilmektedir. Böylece modellerin başarısı sağlıklı bir şekilde saptanabilmektedir. Metrik hesaplamalarında kullanılan terimler şunlardır (Hossin, Sulaiman, Mustapha, & Rahmat, 2011):

Doğru Pozitifler (TP): Model tarafından doğru bir şekilde pozitif olarak tahmin edilen örneklerin sayısı.

Yanlış Pozitifler (FP): Model tarafından pozitif olarak tahmin edilen ancak gerçekte negatif olan örneklerin sayısı.

Doğru Negatifler (TN): Model tarafından doğru bir şekilde negatif olarak tahmin edilen örneklerin sayısı.

Yanlış Negatifler (FN): Aslında pozitif olan ancak model tarafından negatif olarak tahmin edilen örneklerin sayısı.

Doğruluk, bir modelin tahminlerinin genel doğruluğunu değerlendirmek için makine öğreniminde kullanılan yaygın bir performans ölçüsüdür. Doğru tahmin edilen örneklerin veri kümesindeki toplam örnek sayısına oranını sağlayan basit ve sezgisel bir ölçüdür. *Doğruluk* değerinin hesaplanması (17)'de verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (17)$$

Başka bir deyişle *Doğruluk*, gerçek pozitif (doğru tahmin edilen pozitif örnekler) ve gerçek negatif (doğru tahmin edilen negatif örnekler) sayısının toplam örnek sayısına oranıdır. 0 ile 1 arasında değişir.

Doğruluk yaygın olarak kullanılan bir metrik olsa da özellikle sınıfların dengesiz olduğu durumlarda her tür veri kümesi için uygun olmayabilir. Örneğin, örneklerin %95'inin A Sınıfına ve %5'inin B Sınıfına ait olduğu ikili bir sınıflandırma probleminde, tüm örnekleri A Sınıfı olarak tahmin eden bir model yine de %95'lik yüksek bir doğruluğa ulaşacaktır. Bu gibi durumlarda, *kesinlik*, *duyarlılık*, *F1-skor* veya *AUC* değeri gibi diğer ölçümler, modelin performansının daha kapsamlı bir değerlendirmesini sağlayabilir.

Kesinlik, bir model tarafından yapılan olumlu tahminlerin doğruluğunu değerlendiren bir makine öğrenimi metriğidir. Yanlış pozitiflerin maliyetinin yüksek olduğu veya bir veri kümesindeki sınıflar arasında bir dengesizlik olduğu durumlarda özellikle yararlıdır. *Kesinlik* değerinin hesaplanması (18)'de verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (18)$$

Başka bir deyişle, *Kesinlik*, doğru tahmin edilen pozitif örneklerin (Gerçek Pozitifler) pozitif olarak tahmin edilen toplam örnek sayısına (Gerçek Pozitiflerin ve Yanlış Pozitiflerin toplamı) oranıdır. *Kesinlik*, modelin doğru olumlu tahminler yapma yeteneği hakkında fikir verir ve özellikle odak noktası yanlış pozitifleri en aza indirmeye odaklandığında önemlidir. Hassasiyet 0 ile 1 arasında değişir, burada 1 mükemmel hassasiyeti göstermektedir.

Sensitivity veya gerçek pozitif oranı olarak da bilinen *Duyarlılık*, bir modelin belirli bir sınıfa ait tüm ilgili örnekleri doğru şekilde tanımlama yeteneğini ölçen bir makine öğrenimi ölçümüdür. Yanlış negatiflerin (ilgili örneklerin kaçırılması) maliyeti yüksek olduğunda bu özellikle önemlidir. *Duyarlılık* değerinin hesaplanması (19)'da verilmiştir.

$$Duyarluluk = \frac{TP}{TP + FN} \quad (19)$$

Başka bir deyişle *Duyarluluk*, doğru tahmin edilen pozitif örneklerin (Gerçek Pozitifler), gerçek pozitif örneklerin toplam sayısına (Doğru Pozitiflerin ve Yanlış Negatiflerin toplamı) oranıdır. *Duyarluluk*, modelin belirli bir sınıfın tüm örneklerini yakalama yeteneğine odaklanır ve özellikle pozitif örneklerin eksik olmasının, yanlış pozitiflere sahip olmaktan daha kritik olduğu durumlarda çok önemlidir. Geri çağırma değerleri 0 ile 1 arasında değişmektedir.

F1-skor, hem *kesinlik* değerini hem de *duyarluluk* değerini tek bir değerde birleştiren bir makine öğrenimi ölçümüdür. Sınıflar arasında dengesizliğin olduğu veya yanlış pozitifler ile yanlış negatiflerin farklı sonuçlara yol açtığı durumlarda özellikle faydalıdır.

F1-skor değerinin hesaplanması (20)'de verilmiştir.

$$F1 - skor = \frac{2 \times Kesinlik \times Duyarluluk}{Kesinlik + Duyarluluk} \quad (20)$$

Başka bir deyişle F1-skor, *kesinlik* ve *duyarluluk* değerlerinin harmonik ortalamasıdır. *F1-skor* 0 ile 1 arasında değişmektedir.

AUC (Alıcı Çalışma Karakteristik Eğrisi Altındaki Alan), ikili sınıflandırma modelinin performansını değerlendirmek için kullanılan bir makine öğrenmesi ölçümüdür ve aşağıdaki şekilde hesaplanır.

Farklı eşik değerlerinde gerçek pozitif oranı (TPR) y eksenine ve yanlış pozitif oranı (FPR) x eksenine çizerek ROC eğrisi oluşturulur. *AUC*, ROC eğrisinin altındaki alan hesaplanarak bulunur. *AUC* değeri 0 ile 1 arasında değişir. Daha yüksek bir *AUC* değeri genellikle modelin pozitif ve negatif sınıfları daha iyi ayırt etme yeteneği olduğunu gösterir.

AUC özellikle dengesiz veri kümeleriyle uğraşırken veya yanlış pozitiflerle yanlış negatiflerin maliyeti eşit olmadığında kullanışlıdır. Modelin çeşitli karar eşiklerindeki performansını özetlemek için tek bir skaler değer sağlar.

R-kare (R^2), bir bağımlı değişkenin varyansının, bağımsız değişkenler veya bir regresyon modeli tarafından açıklanan oranını ölçen bir istatistiksel göstergedir. Korelasyon, bağımsız ve bağımlı değişken arasındaki ilişkinin gücünü ölçerken, *R-kare*, bir değişkenin varyansının ikinci bir değişkenin varyansını ne kadar açıkladığını ifade eder. Bir modelin R^2 değeri 0,50 ise, gözlemlenen varyasyonun yaklaşık yarısı modelin girdileri tarafından anlatılabilmektedir. R^2 değerinin hesaplanması (21)'de verilmiştir.

$$R^2 = \frac{1}{n} \times \sum_{i=1}^n (y_i - y'_i) \quad (21)$$

Burada:

- n , örnek sayısıdır.
- y_i , i 'inci örnek için hedef değişkenin gerçek değeridir.
- $\hat{y}_i$, i 'inci örnek için tahmin edilen değerdir.

Loss değeri, Keras'ta bir modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçen bir metriktir. Loss fonksiyonu, modelin eğitimi sırasında geriye doğru yayılım (backpropagation) algoritmasının optimize edilmesi için kullanılır. Loss fonksiyonunun düşük olması, modelin daha iyi performans gösterdiği anlamına gelir.

Keras'ta kullanılan loss fonksiyonları, farklı problemler için farklı türde olabilir. Örneğin, sınıflandırma problemleri için ikili çapraz entropi (binary crossentropy) veya ortalama kareler hatası (mean squared error) gibi fonksiyonlar kullanılabilir.

Loss fonksiyonunun nasıl hesaplandığı, kullanılan fonksiyon türüne bağlıdır. Ancak genel olarak, loss fonksiyonu, modelin tahmin ettiği çıktılarla gerçek etiketler arasındaki farkı hesaplar. Bu farkın bir ölçüsü olarak belirlenen değer, modelin parametrelerini güncellemek için kullanılır.

Örneğin, bu tez çalışmasında da kullanılan ikili çapraz entropi loss fonksiyonu, modelin sınıflandırma tahminlerini ve gerçek etiketler arasındaki hata oranını ölçer. Bu fonksiyon, doğru sınıfın olasılığını maksimize etmeye ve yanlış sınıflandırmaları minimize etmeye çalışır.

Loss fonksiyonu, genellikle modelin çıktıları ve gerçek etiketler kullanılarak gerçekleştirilir. Bu değerler arasındaki fark, belirlenen loss fonksiyonu ile hesaplanır ve sonuç olarak bir loss değeri elde edilir. Bu loss değeri, modelin eğitimi sırasında geriye doğru yayılım algoritması sayesinde parametrelerin güncellenmesinde kullanılır. Bu şekilde, modelin loss fonksiyonunu minimize etmek ve daha iyi performans göstermek için parametreler ayarlanır.

ARAŞTIRMA BULGULARI VE TARTIŞMA

Deneysel çalışmalar sırasında oldukça zaman alıcı denemeler gerçekleştirilmiş ve bu denemelerin sonucunda çalışma zamanı hataları giderilmiştir. Sistem sorunsuz bir şekilde çalışır hale getirildikten sonra, bulguları elde etmek amacıyla deneyler yapılmaya başlanmış ve elde edilen sonuçlar çeşitli tablo ve şemalarla paylaşılmıştır.

Cilt kanseri teşhisi için gerçekleştirilen optimum derin öğrenme ağı keşfi sürecinde harcanan zaman hesaplamaları Tablo 14’de gösterilmiştir. Bu hesaplamalar ve deneysel sonuçlar Tablo 15’de özellikleri verilen çalışma ortamında yürütülerek ölçülmüştür.

Tablo 14. Metasezgisel Algoritma ile Optimum Derin Öğrenme Mimarisi Keşfi İçin Çalışma Zamanı Hesaplamaları

Makine öğrenmesi algoritmaları ile maliyet fonksiyonu tahmininin eğitiminde kullanılmak üzere üretilen yaklaşık 1000 satırlık mimari veri setinin oluşturulması için gereken süre yaklaşık olarak 15 saattir.
Makine öğrenmesi algoritmasının tahmini maliyet fonksiyonu olarak kullanımı sonucu benzetilmiş tavlama ile optimizasyon süresi ortalama olarak 2,5 dakikadır (toplam süre).
Makine öğrenmesi regresyonu ile bulunan ağın 300 görüntü ile gerçek derin ağ performans testi yaklaşık olarak 1 dakika sürmektedir.
10015 görüntü için bir eğitim süresi ortalama 37 dakika, test süresi de yaklaşık olarak 1 dakika sürmektedir.
Eğer mimari eğitim verisi hazırsa optimize edilmiş yeni bir derin ağın keşfi ve tüm görüntü veri seti üzerindeki performans değerlendirmeleri yaklaşık olarak 41,5 dakika sürmektedir.

Tablo 14’de yer alan bilgiler göz önüne alındığında optimum başarıya sahip bir ağın bulunması için hızlandırıcı yöntemlerde kullanılsa (veri seti sayısının seyreltilmesi gibi) bile tüm durumların kaba kuvvet yöntemine dayalı olarak hesaplanması mümkün değildir. Bu nedenle optimum derin öğrenme modelinin bulunması için metasezgisel yöntemlerin uygulanması gerektiği açıktır. Fakat metasezgisel yöntemde dahi maliyet hesaplamasında kullanılan derin öğrenme algoritmasının uzun süren eğitim ve *doğruluk* hesaplama sürecinden dolayı pratik olmayan bir durum söz konusudur. Bu nedenle geleneksel makine öğrenmesi algoritmalarından yararlanılarak *doğruluk* hesaplaması süreci hızlandırılmıştır. Belirtilen

makine öğrenmesi algoritmalarının derin öğrenme modeli gibi davranarak tahmin edebilmesi için eğitim sürecinde kullanılacak mimari veri setinin oluşturulması yaklaşık olarak 15 saati bulmaktadır. Bu mimari veri seti oluşturulduktan sonra sistem istenildiği kadar çalıştırılarak yeni bir optimize edilmiş derin öğrenme modeli elde edilebilmektedir.

Bu çalışmada cilt kanseri görüntüleri için en iyi regresyon yapan algoritmanın RO algoritması olduğu sistem tarafından otomatik olarak tespit edilmiştir. RO algoritmasıyla SA yöntemi çalıştırılarak yaklaşık olarak 2,5 dakikada bir yeni bir optimum ağ keşfedilebilmektedir. Seyreltilmiş Görüntü Veri Setine (300 görüntü) dayalı olarak geliştirilen bu ağın gerçekte tasarlanıp başarısının test edilmesi ise yaklaşık 1 dakikalık süreyi bulmaktadır. Tüm görüntü veri seti (10015 görüntü) kullanılarak gerçekleştirilen eğitim ve test süreci de bulunan ağlar için ortalama olarak 37 dakikalık zaman maliyeti oluşturmaktadır. Bu süre, keşfedilen ağın katman sayısı, türleri ve hiperparametre değerlerinden doğrudan etkilenmektedir. Kısaca makine öğrenmesi algoritmalarının eğitimi için oluşturulan Mimari Veri Seti tamamlandıktan sonra ortalama olarak 41,5 dakikada bir yeni optimum derin öğrenme modeli keşfedilebilmektedir.

Tablo 15. Çalışma Ortamının Özellikleri

Birim	Özellik
İşlemci	AMD Ryzen 5 5600H 6 Çekirdek – 12 Threads
Bellek	24 GB 3200 MHz DDR4
Ekran Kartı	Nvidia GeForce GTX1650 GDDR6
Ön Bellek	16 MB
Hafıza	512 GB SSD

SA içerisinde *maliyet fonksiyonu* olarak kullanılan makine öğrenmesi algoritmasının eğitilmesi ve *doğruluk* değerinin hesaplanması çok fazla çalışma süresi gerektirmektedir. Bazen bir ağın eğitimi için 5 saati aşan eğitim süresine ihtiyaç duyulmaktadır. SA yöntemi binlerce farklı kombinasyonda çalışmaya ihtiyaç duyduğundan dolayı bu izlenilen yol kullanılamaz hale gelmektedir. Bu nedenle daha hızlı sonuç verecek yöntemlerin uygulanmasına karar verilmiştir. Bunun için 10015 adet olan görüntü sayısı, içerdiği etiket değerlerine göre rastgele seçim yapacak bir Python kodu yazılarak 300 adete seyreltilmiştir. Böylece derin öğrenme ağı çok daha hızlı bir şekilde sonuç verecek eğitim süresine ulaşmıştır. Burada hızlandırıcı yöntemler uygulanırken derin öğrenme mimarisinin *doğruluk* değerinin %80-85 dolaylarında sonuçlanması hedeflenmiştir. Böylece kısmen kabul edilebilir doğruluklara ulaşan hiperparametre ve katman optimizasyonu tamamlanmış bir mimarinin, daha yüksek sayıda

görüntü ile eğitilmesiyle daha iyi doğruluklara ulaşılması, literatür çalışmalarına dayandırılarak amaçlanmıştır (Kaveh & Mesgari, 2023). Böylece ortalama 1 dakika süren sınıflandırma süresine derin öğrenme mimarisi eğitim süreci için ulaşılmıştır. Şekil 28’de derin öğrenme ağının eğitim sürecine yönelik konsol çıktısı verilmiştir. Daha sonra elde edilen bu mimari çalıştırılarak 941 adet sonuç içeren bir Mimari Veri Seti oluşturulmuştur. Bu veri seti, regresyon problemleri için oldukça iyi sonuçlar ürettiği literatürce tasdik edilen Rastgele Orman, Destek Vektör Makinesi (SVM) ve Lojistik Regresyon algoritmalarında test edilmiş ve aralarında en iyi sonucu üreten Rastgele Orman algoritmasının eğitilmesinde kullanılmıştır. SA’da başlangıç mimarisi olarak VGG16 ağı kullanılmıştır. Böylece çözüm uzayında tarama nispeten iyi bir noktadan başlatılarak hem tarama süresi kısaltılmış hem de keşfedilen ağların göreceli daha yüksek bir başarıya sahip olması sağlanmıştır.

```
Found 300 images belonging to 2 classes.
Epoch 1/10
75/75 [=====] - 10s 119ms/step - loss: 0.7944 - accuracy: 0.6200 - precision_8: 0.6376
Epoch 2/10
75/75 [=====] - 9s 118ms/step - loss: 0.6530 - accuracy: 0.6533 - precision_8: 0.6567
Epoch 3/10
75/75 [=====] - 9s 118ms/step - loss: 0.5894 - accuracy: 0.7267 - precision_8: 0.7282
Epoch 4/10
75/75 [=====] - 9s 119ms/step - loss: 0.5815 - accuracy: 0.6867 - precision_8: 0.6865
Epoch 5/10
75/75 [=====] - 9s 118ms/step - loss: 0.5423 - accuracy: 0.7300 - precision_8: 0.7349
Epoch 6/10
75/75 [=====] - 9s 118ms/step - loss: 0.4706 - accuracy: 0.7833 - precision_8: 0.7807
Epoch 7/10
75/75 [=====] - 9s 118ms/step - loss: 0.3936 - accuracy: 0.8200 - precision_8: 0.8233
Epoch 8/10
75/75 [=====] - 9s 118ms/step - loss: 0.3885 - accuracy: 0.8433 - precision_8: 0.8405
Epoch 9/10
75/75 [=====] - 9s 124ms/step - loss: 0.3786 - accuracy: 0.8333 - precision_8: 0.8361
Epoch 10/10
75/75 [=====] - 9s 119ms/step - loss: 0.3350 - accuracy: 0.8711 - precision_8: 0.8667
```

Şekil 28. SA ile bulunan optimum çözüme ait derin öğrenme eğitim sürecini gösteren Spyder konsol ekran görüntüsü

Tablo 16. SA Yönteminde *Maliyet Fonksiyonunu* Hızlandırmak İçin Kullanılan Makine Öğrenmesi Yöntemlerinin Başarı Oranları

	Rastgele Orman	SVM	Lojistik Regresyon
R² Skor Değerleri	0,9391	0,2213	0,8476

Tablo 16’da regresyon için kullanılan 3 makine öğrenmesi algoritmasının R² sonuçları verilmiştir. Rastgele orman %93,91, SVM %22,13, Lojistik regresyon %84,76 doğrulukla modeli tahmin edebilmiştir. Bu durumda en yüksek başarı oranına sahip olan Rastgele orman algoritması derin ağın *doğruluk* değerini tahmin etmede kullanılarak SA yöntemi için *maliyet tahmin fonksiyonu* hesaplamasına dahil edilmiştir.

İlk aşamada SA algoritması çalıştırılarak mevcut daha iyi sonuçların hiperparametre değerleri kaydedilmiştir. Makine öğrenmesi algoritması (Rastgele Orman) bu değere göre ilk başta eğitilmiştir. Bu sonuçlara göre Rastgele Orman algoritmasının başarı sonucu (R² değeri)

ortalama olarak 0,0613 deęerinde ölçölmüştür. Bu yöntem kötü sonuçları içermeyen veri setine göre yapılan eğitimde makine öğrenmesi algoritmasının düşük düzeyde başarı oranıyla tahmin etmesine neden olmuştur. Çünkü sadece iyi hiperparametre sonuçlarına göre eğitilmesi kötü durumları bilememesine yol açmıştır. Bu durum ikinci aşamada düzeltilerek metasezgisel algoritmanın (SA) sadece iyi sonuçlar yerine uzayda gezinmesi sırasında elde etmiş olduęu kötü sonuçları da içeren farklı hiperparametre deęerlerindeki derin öğrenme algoritmalarının sonuçları da kaydedilerek RO algoritmasının eğitilmesi gerçekleştirilmiştir. Bu işlemlerin sonucunda RO makine öğrenmesi algoritmasının tahminindeki başarı (R^2 deęeri) 0,9391 deęerine yükselmiştir. Böylece RO algoritmasının Derin Öğrenme algoritmasının yerine *maliyet tahmin fonksiyonu* olarak kullanılacak seviyede başarılı sonuç verdięi gözlemlenmiştir. Bu deęer +1 deęerine ne kadar yaklaşırsa o kadar başarılı olarak deęerlendirilmektedir.

Böylece SA yönteminde *maliyet tahmin fonksiyonu* olarak derin öğrenme mimarisi yerine onun gibi karar verebilen makine öğrenmesi algoritması kullanılmıştır. Bu sayede bir *maliyet fonksiyonun* hesaplanma süresi mili saniyeler seviyesine düşürölmüştür. Artık metasezgisel yöntem, binlerce kombinasyonunu hızlı bir şekilde derin aę optimizasyonu için uygulayarak optimum deęerlere sahip hiperparametre ve aę mimari yapısı kombinasyonuna ulaşabilecek kabiliyete kavuşturulmuştur.

Optimizasyon ile Elde Edilen DeneySEL Sonuçlar

Tablo 17’de bu çalışmada elde edilen derin öğrenme modellerine ait sonuçlar paylaşılmıştır. Eğitim ve test süreçlerine ait bu sonuçlar modeller hakkında detaylı bilgileri de içermektedir.

Bu çalışmada bir makine öğrenmesi algoritmasıyla hızlandırılmış SA yöntemi ile keşfedilen optimum hiperparametre ve mimari yapılar sahip CNN tabanlı derin öğrenme modellerine ait sonuçlar ve literatürde yer alan dięer sonuçlar Tablo 18’de verilmiştir. Tablodaki her çalışmanın (literatürde yer alan) başarısının 5 metrik ile ölçölmedięi görölmektedir. Oysa HAM10000 gibi entropisi yüksek veri setlerinde *doęruluk* deęerinin dışındaki dięer metrikler daha fazla önem kazanmaktadır. Çünkü bu veri setinde yaklaşık 8000 adet kanser hastalığı içermeyen görüntü bulunmaktadır. Yani önerilen yöntem tüm görüntülere kanser deęil derse doğrudan %80 *doęruluk* deęeri elde edecektir. Aslında hiçbir sınıflandırma yapamayan algoritma neredeyse başarılı sonuç üretmektedir. Bu nedenle *kesinlik*, *duyarlılık*, *F1-skor* ve *AUC* metrikleri ile başarının test edilmesi büyük önem arz etmektedir. Bu çalışmada da hedef tüm metriklerde yüksek başarının elde edilmesidir. Tablo 18’de paylaşılan literatürdeki dięer çalışmalara ait sonuçlar da aynı veri seti (HAM10000) kullanılarak elde edilmiştir. ÇN17 bu çalışmada bulunan 10 derin öğrenme modelini temsil etmektedir. Bu

modeller, Keskenler & Dal Convolutional Neural Network (Keskenler & Dal Evrişimli Sinir Ağı) kelimelerinin kısaltmasından KES-DAL-CNN olarak isimlendirilmiştir.

Tablo 17. Keşfedilen KES-DAL-CNN Modellerinin Eğitim ve Test Sonuçları

Model	300 Adet Veri Kullanıldığında			10015 Adet Veri Kullanıldığında					
	ML Doğruluk (%)	Gerçek Model Acc (%)	Bulunan SA Sıcaklığı (°C)	Eğitim Sür. (dk)	Toplam Param.	Eğitim Acc (%)	Eğitim Loss	Test Loss	Nöron Sayısı
KES-DAL-CNN1	83,09	81,67	0,02	81,60	11778	92,55	0,1800	0,1785	1024
KES-DAL-CNN2	83,08	84,00	0,24	26,70	123458	94,55	0,0342	0,0754	61504
KES-DAL-CNN3	84,16	85,67	479,38	34,55	35538	91,12	0,1114	0,1736	16384
KES-DAL-CNN4	85,68	83,00	118,17	54,95	11778	93,09	0,1780	0,1390	1024
KES-DAL-CNN5	83,42	86,00	23,58	53,72	138482	98,60	0,0400	0,0480	65536
KES-DAL-CNN6	84,12	86,33	61,38	18,06	132098	98,54	0,0519	0,0951	63504
KES-DAL-CNN7	83,96	87,67	0,03	14,93	33522	99,48	0,0220	0,0974	15376
KES-DAL-CNN8	82,45	86,33	382,14	17,48	2064962	97,45	0,0910	0,0260	1032256
KES-DAL-CNN9	84,06	84,33	0,02	26,58	293890	99,83	0,0181	0,0468	144400
KES-DAL-CNN10	85,32	88,67	218,46	32,02	291570	99,60	0,0200	0,0212	144400
Ortalama	83,93	85,37	128,34	36,06	313708	96,48	0,0746	0,0901	154540

Tablo 18’de yer alan ÇN8 çalışması, DenseNet-AA isimli modeli kullanmıştır. Bu çalışma içerisinde %90,0 *doğruluk*, %88,0 *kesinlik*, %76,0 *duyarlılık* ve %82,0 *F1-skor* değerlerinin elde edildiği belirtilmiştir.

ÇN9 çalışması, ImageNet isimli modeli kullanmıştır. Bu çalışma içerisinde %90,48 *doğruluk*, %88,76 *kesinlik* ve %89,57 *duyarlılık* değerlerinin elde edildiği belirtilmiştir.

ÇN10 çalışması, DenseNet121, VGGNet, ResNet50, MobileNet ve Xception isimli modelleri kullanmıştır. Bu çalışma içerisinde elde edilen metriklerle ait en yüksek başarı oranları şöyledir: %93,28 *doğruluk*, %83,64 *kesinlik*, %88,22 *F1-skor* ve %97,91 *AUC*. Modellerin başarısı oldukça dengesiz dağılım göstermektedir. Örneğin, VGGNet modeli %93,28 *doğruluk* değerine ulaşırken aynı zamanda %79,13 *kesinlik* değeri sunmaktadır. Yani her ne kadar *doğruluk* değeri yüksek çıksa da aslında istenilen başarıya ulaşamadığı görülmektedir. Zira, önemli olan tüm metriklerde olabildiğince yüksek başarının elde edilmesidir.

ÇN11 çalışması, InceptionV3, ResNetXt101, InceptionResNetV2, Xception ve NASNetLarge isimli modelleri kullanmıştır. Bu çalışma içerisinde elde edilen metriklerle ait en

yüksek başarı oranları şöyledir: %93,20 *doğruluk*, %89,0 *kesinlik*, %89,0 *F1-skor* ve %89,0 *duyarlılık*. Modellerin başarısı ÇN10 çalışmasındaki gibi dengesiz dağılım göstermektedir. Örneğin, InceptionResNetV2 modeli %93,20 *doğruluk* değerine ulaşırken aynı zamanda %87,0 *kesinlik* değeri sunmaktadır. Yani her ne kadar *doğruluk* değeri yüksek çıksa da aslında istenilen başarıya ulaşamadığı görülmektedir.

ÇN12 çalışması, Standalone ResNet-50, Standalone Inception V3 ve Ensemble isimli modelleri kullanmıştır. Bu çalışma içerisinde elde edilen metriklere ait en yüksek başarı oranları şöyledir: %89,9 *doğruluk*, %86,2 *kesinlik*, %80,0 *duyarlılık* ve %82,9 *F1-skor*. Modellerin beklenen başarıya ulaşamadığı gözlemlenmiştir.

ÇN13 çalışması, DenseNet121 isimli modeli kullanmıştır. Bu çalışma içerisinde %82,68 *doğruluk*, %89,0 *kesinlik*, %83,0 *duyarlılık*, %84,0 *F1-skor* ve %97,34 *AUC* değerlerinin elde edildiği belirtilmiştir.

ÇN14 çalışması, PMDL isimli modeli kullanmıştır. Bu çalışma içerisinde %87,84 *doğruluk*, %78,71 *kesinlik*, %77,38 *duyarlılık*, %77,81 *F1-skor* ve %95,71 *AUC* değerlerinin elde edildiği belirtilmiştir. Çalışmada ulaşılan başarı oranlarına bakıldığında beklenen seviyede başarı gösteremediği sonucu çıkarılmaktadır.

ÇN15 çalışması, VGG19, InceptionV3, InceptionResnetV2, ResNet50, Xception ve MobileNet isimli modelleri kullanmıştır. Bu çalışma içerisinde elde edilen metriklere ait en yüksek başarı oranları şöyledir: %89,66 *doğruluk*, %88,76 *kesinlik*, %89,57 *duyarlılık* ve %89,02 *F1-skor*.

ÇN16 çalışması, XceptionSb isimli modeli kullanmıştır. Bu çalışma içerisinde %93,89 *doğruluk*, %89,46 *kesinlik*, %89,15 *duyarlılık*, %88,99 *F1-skor* ve %87,40 *AUC* değerlerinin elde edildiği belirtilmiştir.

ÇN17 isimli çalışma bu tez kapsamında otomatik olarak üretilen derin öğrenme modellerini temsil etmektedir. KES-DAL-CNN1'den KES-DAL-CNN10'a kadar isimlendirilen modellerin performansı 5 farklı metriğe göre değerlendirilmiştir. Metasezgisel ve makine öğrenmesi tabanlı geliştirilen yenilikçi bir yöntem ile elde edilen bu 10 adet ağın ortalama başarı oranları şu şekildedir: %95,26 *doğruluk*, %95,19 *kesinlik*, %94,82 *duyarlılık*, %95,01 *F1-skor* ve %98,74 *AUC*. Ayrıca VGG16 modeli SA yönteminde başlangıç çözümü olarak belirlenmiştir. Bu modelin başarı oranları ise şöyledir: %78,58 *doğruluk*, %78,61 *kesinlik*, %78,53 *duyarlılık*, %78,57 *F1-skor* ve %87,41 *AUC*. Sonuç olarak başlangıçta bu performansla başlayan çözüm temsili yukarıda paylaşılan ortalama değerlerdeki performansa sahip DL modellerine ulaşmıştır.

Tablo 18. Keşfedilen KES-DAL-CNN Modellerinin Literatürdeki Diğer Modellerle Başarı Karşılaştırmaları (Tüm Çalışmalarda HAM10000 Veri Seti Kullanılmıştır.)

Çalışma No	Model	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)	AUC (%)
ÇN8 (Carcagni et al., 2019)	DenseNet-AA	90,0	88,0	76,0	82,0	-
ÇN9 (Jain, Singhanian, Tripathy, et al., 2021)	ImageNet	90,48	88,76	89,57	-	-
ÇN10 (Tasar, 2023)	DenseNet121	92,29	83,64	-	88,22	96,96
	VGGNet	93,28	79,13	-	81,80	96,43
	ResNet50	87,10	74,92	-	75,57	97,91
	MobileNet	83,10	67,34	-	70,64	97,05
	Xception	80,05	61,09	-	63,94	96,55
ÇN11 (Chaturvedi, Tembhurne, & Diwan, 2020)	InceptionV3	91,56	89,0	89,0	89,0	-
	ResNetXt101	93,20	88,0	88,0	88,0	-
	InceptionResNetV2	93,20	87,0	88,0	88,0	-
	Xception	91,47	89,0	88,0	88,0	-
	NASNetLarge	91,11	86,0	86,0	86,0	-
ÇN12 (Shahin, Kamal, & Elattar, 2018)	Standalone ResNet-50	87,1	78,6	77,0	-	-
	Standalone Inception V3	89,7	84,9	80,0	-	-
	Esnsemble	89,9	86,2	79,6	82,9	-
ÇN13 (Raghavendra, Charitha, Begum, & Prasath, 2023)	DenseNet121	82,68	89,0	83,0	84,0	97,34
ÇN14 (Diwan, Shukla, Ghuse, & Tembhurne, 2023)	PMDL	87,84	78,71	77,38	77,81	95,71
ÇN15 (Jain, Singhanian, & Tripathy, 2021)	VGG19	67,54	85,48	67,34	74,79	-
	InceptionV3	86,40	87,69	86,19	87,13	-
	InceptionResnetV2	88,40	87,93	87,62	88,45	-
	ResNet50	82,32	86,80	82,22	84,16	-
	Xception	89,66	88,76	89,57	89,02	-
	MobileNet	87,21	88,38	87,11	87,40	-
ÇN16 (Mehmood et al., 2023)	XceptionSb	93,89	89,46	89,15	88,99	87,40
ÇN17 (Önerilen Yöntem ile Bulunan DL Modelleri)	VGG16 (Başlangıç)	78,58	78,61	78,53	78,57	87,41
	KES-DAL-CNN1	91,67	91,76	90,67	91,21	97,67
	KES-DAL-CNN2	91,97	92,02	91,62	91,82	97,50
	KES-DAL-CNN3	92,18	92,63	92,04	92,33	97,11
	KES-DAL-CNN4	95,33	95,39	94,96	95,20	98,27
	KES-DAL-CNN5	95,91	95,50	96,85	96,17	99,74
	KES-DAL-CNN6	96,06	96,09	95,81	95,95	98,83
	KES-DAL-CNN7	96,06	96,15	96,05	96,10	99,89
	KES-DAL-CNN8	97,24	97,16	96,22	96,69	99,10
	KES-DAL-CNN9	97,90	98,22	96,86	97,54	99,91
	KES-DAL-CNN10	98,26	97,06	97,16	97,11	99,46
ÇN17	Ortalama (KES-DAL-CNN1-10)	95,26	95,19	94,82	95,01	98,74

Sonuçlardan anlaşıldığı üzere keşfedilen ağların başarı oranları tüm metriklerde oldukça yüksek seviyededir ve literatürdeki diğer çalışmaların oldukça üzerindedir. Bu bulgu çalışma kapsamında geliştirilen derin öğrenme modeli üreteç sisteminin tutarlı sonuçlar ürettiği anlamına gelmektedir.

Deneysel bulgulara göre KES-DAL-CNN10 modeli %98,26 *doğruluk* değeri ile, KES-DAL-CNN9 modeli %98,22 *kesinlik* değeri ile, KES-DAL-CNN10 modeli %97,16 *duyarlılık* değeri ile, KES-DAL-CNN9 modeli %97,54 *F1-skor* değeri ile ve KES-DAL-CNN9 modeli %99,91 *AUC* değeri ile en yüksek metrik değerlerine ulaşmıştır. Görüldüğü üzere elde edilen sonuçlar kabul edilebilir tanı sistemlerinde kullanılabilir seviyededir. Literatürdeki diğer çalışmalar incelendiğinde bu değerleri geçen başka bir derin öğrenme modelinin olmadığı gözlemlenmektedir. Böylece çalışmanın amacına ve hedeflerine ulaşıldığı saptanabilmektedir.

Tablo 19. Literatürde Kullanılan Diğer Derin Öğrenme Modelleri ile Bu Çalışmada Elde Edilen Derin Öğrenme Modellerinin Eğitim Sürelerinin Kıyaslanması (Tablodaki Çalışmalarda Aynı Veri Seti Kullanılmıştır.)

Model	Eğitim Süresi (dakika)
VGG19 (Bozkurt, 2023)	370
VGG16 (Bozkurt, 2023)	389
SqueezeNet (Bozkurt, 2023)	534
LeNet-5 (Bozkurt, 2023)	173
AlexNet (Bozkurt, 2023)	118
Deep CNN (Bozkurt, 2023)	469
InceptionResNetV2 (Bozkurt, 2023)	110
Bu Çalışmadaki Modellerin Ortalaması	37
Bu Çalışmadaki Modellerin Minimumu	14,93
Bu Çalışmadaki Modellerin Maksimumu	81,6


Literatürde derin öğrenme modellerinin çalışma sürelerinin genellikle paylaşılmadığı veya bu açıdan bir kıyasın yaygın olarak yapılmadığı görülmektedir. Bunun en büyük nedeni modellerin farklı çalışma ortamlarında yürütülmeleridir. Tablo 19’da bu tez çalışmasında kullanılan sistem özelliklerine yakın bir sistemde yürütülen derin öğrenme modellerine ait eğitim süreleri verilmiştir. Bozkurt vd., 7 farklı derin öğrenme modeli ile HAM10000 veri setini kullanarak yapmış oldukları çalışmada cilt kanseri teşhisindeki eğitim sürelerini paylaşmıştır. Çalışmada yapılan tüm deneyler, i7 (8700U) @ 3.20 GHz işlemciye sahip CPU, 4 GB grafik kartı ve 16 GB birincil bellek donanımına sahip bir bilgisayarda Python 3.10.0 Jupyter Notebook geliştirme ortamı kullanılarak gerçekleştirilmiştir. Ayrıca Keras ve Tensorflow kütüphaneleri kullanılmıştır. En düşük eğitim süresi 110 dakika ve en yüksek eğitim süresi ise 534 dakika olarak belirtilmiştir. Bu tez kapsamında keşfedilen KES-DAL-CNN optimum

ağlarının eğitim süreleri ise en düşük 14,93 dakika, en yüksek 81,6 dakika ve ortalamada yaklaşık 37 dakika olarak gözlemlenmiştir. Bu bulgulara göre metasezgisel ve makine öğrenmesi tabanlı optimum derin öğrenme modeli üreticinin (KES-DAL-GEN) bulduğu bu modellerin eğitim zamanı açısından da başarılı olduğu ve daha verimli çalıştığı anlaşılmaktadır.


Deneysel Çalışmalarda Üretilen Derin Öğrenme Modelleri

Bu başlık altında, bu tez kapsamında gerçekleştirilen deneysel çalışmalar sonucu elde edilen Keskenler & Dal Evrişimli Sinir Ağları (Keskenler & Dal Convolutional Neural Network, KES-DAL-CNN) adındaki 10 adet derin öğrenme modeli incelenmektedir. Bu modeller geliştirilen sistem tarafından otomatik olarak oluşturulmuştur ve bazılarının örnek modelleri aşağıda paylaşılmıştır. Paylaşılan modeller az katmanlı, çok katmanlı, düşük ve yüksek performanslı olanlar arasından seçilmiştir.


Şekil 29’da KES-DAL-GEN ile üretilen bir derin öğrenme mimarisi (KES-DAL-CNN1) yer almaktadır. Bu mimari Rastgele Orman algoritmasının *maliyet fonksiyonunda* derin ağın *doğruluk* değerini tahmin etmesine göre belirlenmiş ve %83,09 *doğruluk* başarı oranının elde edileceği ölçülmüştür. Bu varsayımdaki mimari gerçekte de tasarlanarak yeniden ölçüm yapılmış ve %81,67 *doğruluk* oranı elde edilmiştir. Böylece tahmin edilen *doğruluk* ile gerçek *doğruluk* arasında yaklaşık %1,7’lik bir fark olduğu ortaya çıkmıştır. Bu değerler 300 görüntüye dayanmaktadır. Ayrıca elde edilen bu ağ HAM10000 veri setinin tamamıyla eğitilip test edilerek Şekil 31’deki *eğitim tur sayısı* değerine göre *loss* ve *doğruluk* değerleri elde edilmiştir. Şekil 30’da ise elde edilen ağın mimari yapısı gösterilmektedir.



Şekil 29. KES-DAL-CNN1 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 15 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).




Şekil 30. KES-DAL-CNN1 mimari çizimi




Şekil 31. KES-DAL-CNN1 derin öğrenme modelinin eğitim sürecindeki *doğruluk* ve *loss* değerlerinin değişimi


Şekil 32’de KES-DAL-GEN ile üretilen KES-DAL-CNN6 isimli bir başka mimari verilmiştir. Bu mimari Rastgele Orman algoritmasının *maliyet fonksiyonunda* derin ağın *doğruluk* değerini tahmin etmesine göre belirlenmiş ve %84,12 *doğruluk* oranının elde edileceği ölçülmüştür. Bu varsayımdaki mimari gerçekte de tasarlanarak yeniden ölçüm yapılmış ve %86,33 *doğruluk* oranı elde edilmiştir. Bu değerler 300 görüntüye dayanmaktadır. Ayrıca elde edilen bu ağ HAM10000 veri setinin tamamıyla eğitilip test edilerek Şekil 34’deki *eğitim tur sayısı* değerine göre *loss* ve *doğruluk* değerleri elde edilmiştir. Şekil 33’de ise elde edilen ağın mimari yapısı gösterilmektedir.



Şekil 32. KES-DAL-CNN6 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 9 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).



Şekil 33. KES-DAL-CNN6 mimari çizimi (Spyder konsol çizimi örneği)




Şekil 34. KES-DAL-CNN6 derin öğrenme modelinin eğitim sürecindeki *doğruluk* ve *loss* değerlerinin değişimi


Şekil 35’de, önerilen yöntemle bulunan bir başka mimari (KES-DAL-CNN9) görülmektedir. Bu mimari Rastgele Orman algoritmasının *maliyet fonksiyonunda* derin ağın *doğruluk* değerini tahmin etmesine göre belirlenmiş ve %84,06 *doğruluk* başarı oranının elde edileceği ölçülmüştür. Bu varsayımdaki mimari gerçekte de tasarlanarak yeniden ölçüm yapılmış ve %84,33 *doğruluk* oranı elde edilmiştir. Bu değerler 300 görüntüye dayanmaktadır. Ayrıca elde edilen bu ağ HAM10000 veri setinin tamamıyla eğitilip test edilerek Şekil 37’deki *eğitim tur sayısı* değerine göre *loss* ve *doğruluk* değerleri elde edilmiştir. Şekil 36’da ise elde edilen ağın mimari yapısı gösterilmektedir.



Şekil 35. KES-DAL-CNN9 mimari yapısı ve hiperparametreleri (6. Sütunda yer alan Cv, Fl ve Dn katmanları sabit katman olduğu için mavi ile renklendirilmiştir. Sabit ve giriş-çıkış katmanları dahil toplam 8 katmanlıdır. Cv: Convolution, Ap: AveragePooling, Dr: Dropout, Mp: MaxPooling).



Şekil 36. KES-DAL-CNN9 mimari çizimi



Şekil 37. KES-DAL-CNN9 derin öğrenme modelinin eğitim sürecindeki *doğruluk* ve *loss* değerlerinin değişimi

SONUÇLAR VE ÖNERİLER

Bu çalışmada, yenilikçi, tam otomatik, metasezgisel ve makine öğrenmesi tabanlı ve KES-DAL-GEN isimli bir üreteç geliştirilerek optimize edilmiş derin öğrenme modelleri üretilmiştir. Literatürde hala hiperparametre seviyesinde metasezgisel tabanlı optimizasyon çalışmalarının yürütüldüğü görülmektedir. Ancak, bir derin öğrenme modelinden beklenen verim ve başarıyı elde etmek için derin ağın tüm bileşenleriyle optimize edilmesi gerektiği birçok çalışmada vurgulanmaktadır. Bu konu literatürde zorlukları ile ele alınmış ve gelecekte bu tür çalışmaların yapılabilceği öngörülmüştür. Bu çalışmanın temel motivasyonu da bu problemin giderilmesine ve bu zorlu ve geniş kapsamlı optimizasyonun gerçekleştirilmesine dayanmaktadır.

Bu çalışmada öncelikle evrişimli sinir ağları (CNNs) formundaki derin öğrenme mimarilerinin tüm bileşenleriyle birlikte bütünsel bir optimizasyonu için metasezgisel ve makine öğrenmesi tabanlı, yeni ve tamamen otomatik bir mimari üreteç geliştirilmiştir. Bu yenilikçi üreteç sayesinde, bir derin öğrenme mimarisinin hiperparametreleri, katman sayısı, türleri ve dizilimleri bütüncül bir yaklaşımla optimize edilebilmiştir. Bu tez kapsamında ayrıca, söz konusu üreticinin dermatoskopik görüntülerden oluşan bir veri seti aracılığıyla cilt kanserinin non-invaziv teşhisi noktasındaki etkinliği gösterilmiştir.

Derin öğrenme ağı optimizasyon sürecinde birçok zorlukla karşılaşmıştır. Bunlardan en önemlisi, metasezgisel olarak kullanılan benzetilmiş tavlama yönteminin maliyet fonksiyonunun hesaplanma süresidir. Maliyet, her bir iterasyonda değişime uğrayan derin öğrenme modelinin doğruluk değeri olarak belirlenmiştir. Benzetilmiş tavlama yönteminde binlerce iterasyonla çözüm uzayı taranarak optimizasyon çalışması gerçekleştirilmektedir. Bir ağın eğitilmesi ve doğruluk değerinin hesaplanması oldukça zaman alıcı bir süreçtir ve metasezgisel yöntemin uygulanamaz hale gelmesine sebep olmaktadır.

Bu çalışmada yukarıda bahsedilen problemin çözümü için süreci hızlandırıcı yöntemler geliştirilmiştir. Öncelikle, cilt kanseri veri setinin boyutu %3 oranında seyreltilmiştir. Böyle bir veri seti kullanılarak üretilen ve %80-85 aralığında doğruluk oranına sahip bir ağ, tüm veri seti kullanılarak gerçekleştirilen bir eğitim sonucunda daha yüksek başarılarla ulaşmıştır. Bir başka deyişle seyreltilmiş veri seti sayesinde önemli ölçüde hızlanma sağlanmıştır. Ancak bu da yeterli olmamıştır. Bu nedenle metasezgisel algoritma, seyreltilmiş görüntü veri seti ile kısmen çalıştırılarak iyi ve kötü mimariler kaydedilmiştir. Görüntü veri setindeki örnek sayısının yaklaşık %10'u kadar model ve bu modellerin başarılarına ait sonuçlar listelenmiştir.

Sonrasında, bu mimari veri seti kullanılarak makine öğrenmesi algoritmalarından rastgele orman, lojistik regresyon ve destek vektör makinesi algoritmaları eğitilmiş ve bu modeller ile mimari veri setindeki modellerin başarı oranları tahmin edilmeye çalışılmıştır. Böylece, maliyet fonksiyonunda en başarılı olan algoritma doğruluk (cost) tahmininde kullanılmıştır. Bu yöntemle her bir iterasyonda maliyet hesabı mili saniyeler seviyesine düşürülmüştür. Sonuç olarak, benzetilmiş tavlama çalıştırılarak hiperparametreleri ve mimari yapıları optimum olan yeni derin öğrenme modelleri keşfedilmiştir. Her seferinde yeni bir ağ elde edilmiştir. Keşfedilen ağların başarısı literatürdeki diğer derin öğrenme modelleriyle karşılaştırılarak ortaya konulmuştur. Sonuç olarak, otomatik olarak optimum derin öğrenme modeli oluşturan bir üreteç geliştirilmiştir. Çalışma kapsamında seçilen cilt kanseri teşhisi uygulama alanında, güvenilir sonuçlar üretebilen bir yapay zekâ yöntemi elde edilmiştir.

Elde edilen yüksek başarıya sahip yapay zekâ modellerinin (KES-DAL-CNN'lerin) rolü oldukça önemlidir. Çünkü günümüzde artan hastalık türleri ve vaka sayıları, sağlık sektörünü ve çalışanlarını giderek daha fazla yük altına sokmaktadır. Cilt kanseri de bu hastalıklardan biridir. Tıbbi profesyoneller, zaman kısıtlamaları nedeniyle zorlu ve karmaşık bir teşhis süreciyle karşı karşıya kalmaktadır, bu da gecikmiş teşhise ve zamanında gerçekleşemeyen tedaviye neden olabilir. Bu nedenle, cilt kanserinin teşhisinde yapay zekâ teknolojilerinden yararlanmak neredeyse zorunluluk haline dönüşmektedir. Yapay zekâ, kanser gibi hastalıkları daha doğru ve erken aşamalarda tespit etmek için artan bir ilgiyle kullanılmaktadır. Son çalışmalar, gereksiz biyopsileri azaltmak ve tedavi maliyetlerini düşürmek için yapay zekâ uygulamalarının sağlık alanına entegrasyonunun önemini vurgulamaktadır. Sağlık harcamaları artmaya devam ettikçe, yapay zekânın, maliyetleri önemli ölçüde azalttığı ve hastalıkları teşhis ve tedavi noktasında iyileştirme potansiyeline sahip olduğu ortaya çıkmaktadır.

Cilt kanseri teşhisinde, klinik, dermatoskopik ve histopatolojik olmak üzere 3 farklı görüntü türüyle muayene yapılmaktadır. Bu çalışmada, dermatoskopik görüntüler incelenmiştir. Bu alanda kendisini ispat etmiş bir veri seti olan HAM10000 veri kümesi kullanılmıştır. Bu veri kümesi, 8 farklı hastalığın 10.015 görüntüsünü içermektedir. Bu görüntüler, kanser olmayan ve kanser olmak üzere 2 etiketle sınıflandırılmıştır. Kanser oluşumunun tespiti, erken tedavi açısından çok önemlidir. Bu nedenle, bu tür hastalıkların erken aşamalarında tespit edilmesi veya ayırt edilmesi önemlidir.

Sonuç olarak, bu çalışmada daha doğru cilt kanseri tespiti için optimum derin öğrenme modelleri üreten bir sistem geliştirilmiştir. Hedeflenen başarı sonuçlarına, beş farklı metrik ile ölçümler yapılarak ulaşıldığı gösterilmiştir.

Gelecek alıřmalarda, optimize edilen hiperparametre deęerlerinin sayısı daha da artırılabilir. Bylece, bařarıya etkisi nispeten daha dřk olan hiperparametreler de optimize edilerek kısmen daha bařarılı modeller geliřtirilebilir. Ayrıca, bu alıřmada CNN tabanlı derin ęrenme modelleri kullanılmıřtır. Gelecekte dięer derin ęrenme modelleri de kullanılarak optimizasyon alıřmaları yrtlebilir. Bu alıřmada SA yntemi ile optimizasyon yapılırken maliyet fonksiyonunda sadece *doęruluk* deęeri hesaba katılmıřtır. *Kesinlik* deęeri de dahil edilerek alıřma kapsamında bir forml geliřtirilmiřtir. Gelecek alıřmalarda birden fazla metrięin deęeri dikkate alınarak maliyet fonksiyonları hesaplanabilir. Bunlara ek olarak, bu alıřma kapsamında cilt kanseri teřhisi uygulama alanı olarak seilmiřtir. Ancak uygulama alanı, farklı grntlerin sınıflandırılması iin de geniřletilebilir.



KAYNAKLAR

- Abbas, Q., Emre Celebi, M., & Fondón, I. (2012). Computer-aided pattern classification system for dermoscopy images. *Skin Research and Technology*, 18(3), 278-289. doi:<https://doi.org/10.1111/j.1600-0846.2011.00562.x>
- Abedini, M. (2015). Accurate and scalable system for automatic detection of malignant melanoma *Dermoscopy image analysis* (pp. 293343).
- Acharya, U. R. (2018). Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals. *Computers in Biology and Medicine*, 100, 270-278.
- Adel, E., Elmogy, M. M., & El-Bakry, H. M. (2014). Image Stitching based on Feature Extraction Techniques: A Survey. *International Journal of Computer Applications*, 99, 1-8.
- Akalın, B., & Veranyurt, Ü. (2020). Sağlıkta Dijitalleşme Ve Yapay Zeka. *SDÜ Sağlık Yönetimi Dergisi*, 2(2), 128-137.
- Akinbinu, T. R., & Mashalla, Y. J. (2014). Impact of computer technology on health: Computer Vision Syndrome (CVS). *Medical Practice and Reviews*, 5(3), 2030.
- Al-Shahri, O. A., Ismail, F. B., Hannan, M. A., Lipu, M. S. H., Al-Shetwi, A. Q., Begum, R. A., . . . Soujeri, E. (2021). Solar photovoltaic energy optimization methods, challenges and issues: A comprehensive review. *Journal of Cleaner Production*, 284, 125465. doi:<https://doi.org/10.1016/j.jclepro.2020.125465>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-dujaili, A., Duan, Y., Al-Shamma, O., . . . Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data*, 8.
- Anand, V., Gupta, S., Altameem, A., Nayak, S., Poonia, R. C., & Saudagar, A. K. J. (2022). An Enhanced Transfer Learning Based Classification for Diagnosis of Skin Cancer. *Diagnostics*, 12.
- Anita Singhrova, A. (2022). Optimal Healthcare Resource Allocation in Covid Scenario Using Firefly Algorithm. *International Journal of Engineering Trends and Technology*.
- Archana, R., & Eliahim, P. S. J. (2024). Deep learning models for digital image processing: a review. *Artificial Intelligence Review*, 57(1), 11.
- Argenziano, G. (2003). Dermoscopy of pigmented skin lesions: results of a consensus meeting via the Internet. *J Am Acad Dermatol*, 48(5), 679-693.
- Baerheim, A. (2001). The diagnostic process in general practice: has it a two-phase structure? . *Family Practice*, 18(3), 243-245.
- Bagherian, M. A., Mehrazamir, K., Pour, A. B., Rezaia, S., Taghavi, E., Nabipour-Afrouzi, H., . . . Alizadeh, S. M. (2021). Classification and Analysis of Optimization Techniques for Integrated Energy Systems Utilizing Renewable Energy Sources: A Review for CHP and CCHP Systems. *Processes*.
- Balogh, E. P., Miller, B. T., & Ball, J. R. (2015). Improving Diagnosis in Health Care. *National Academies of Sciences, Engineering, and Medicine*.

- Barata, C., Celebi, M. E., & Marques, J. S. (2019). A Survey of Feature Extraction in Dermoscopy Image Analysis of Skin Cancer. *IEEE Journal of Biomedical and Health Informatics*, 23(3), 1096-1109. doi:10.1109/JBHI.2018.2845939
- Barata, C., Marques, J. S., & Rozeira, J. (2013, 2013//). *Evaluation of Color Based Keypoints and Features for the Classification of Melanomas Using the Bag-of-Features Model*. Paper presented at the Advances in Visual Computing, Berlin, Heidelberg.
- Barata, C., Ruela, M., Francisco, M., Mendonça, T., & Marques, J. S. (2014). Two Systems for the Detection of Melanomas in Dermoscopy Images Using Texture and Color Features. *IEEE Systems Journal*, 8(3), 965-979. doi:10.1109/JSYST.2013.2271540
- Batin, M., Turchin, A., Sergey, M., Zhila, A., & Denkenberger, D. (2017). Artificial Intelligence in Life Extension: from Deep Learning to Superintelligence. *Informatica (Slovenia)*, 41(4), 1.
- Bay, H., Ess, A., Tuytelaars, T., & Van Gool, L. (2008). Speeded-Up Robust Features (SURF). *Computer Vision and Image Understanding*, 110(3), 346-359. doi:https://doi.org/10.1016/j.cviu.2007.09.014
- Bozkurt, F. (2023). Skin lesion classification on dermatoscopic images using effective data augmentation and pre-trained deep learning approach. *Multimedia Tools and Applications*, 82(12), 18985-19003. doi:10.1007/s11042-022-14095-1
- Brinker, T. J. (2018). Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review. *J Med Internet Res*, 20(10), 11936.
- Brinker, T. J. (2019a). A convolutional neural network trained with dermoscopic images performed on par with 145 dermatologists in a clinical melanoma image classification task. *European Journal of Cancer*, 111, 148-154.
- Brinker, T. J. (2019b). Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task. *European Journal of Cancer*, 113, 47-54.
- Büyükgöze, S., & Dereli, E. (2019). *Artificial Intelligence in Digital Health Applications*. Paper presented at the VI. International Scientific and Vocational Studies Congress – Science and Health.
- C.U.A. (2016). Artificial Intelligence Will Change Healthcare as We Know It Wired. Retrieved from <http://www.wired.co.uk/article/cancer-risk%02ai-mammograms>
- Cai, Y., Wu, J., & Zhang, C. (2019). Classification of Trash Types in Cotton Based on Deep Learning. *2019 Chinese Control Conference (CCC)*, 8783-8788.
- Capdehourat, G., Corez, A., Bazzano, A., Alonso, R., & Musé, P. (2011). Toward a combined tool to assist dermatologists in melanoma detection from dermoscopic images of pigmented skin lesions. *Pattern Recognition Letters*, 32(16), 2187-2196. doi:https://doi.org/10.1016/j.patrec.2011.06.015
- Carcagnì, P., Leo, M., Cuna, A., Mazzeo, P. L., Spagnolo, P., Celeste, G., & Distanto, C. (2019). *Classification of Skin Lesions by Combining Multilevel Learnings in a DenseNet Architecture*, Cham.
- Celebi, M. E., & Zornberg, A. (2014). Automated Quantification of Clinically Significant Colors in Dermoscopy Images and Its Application to Skin Lesion Classification. *IEEE Systems Journal*, 8(3), 980-984. doi:10.1109/JSYST.2014.2313671
- Celik, E., & Dal, D. (2021). A novel simulated annealing-based optimization approach for cluster-based task scheduling. *Cluster Computing*, 24(4), 2927-2956.

- Chaturvedi, S. S., Tembhurne, J. V., & Diwan, T. (2020). A multi-class skin Cancer classification using deep convolutional neural networks. *Multimedia Tools and Applications*, 79(39), 28477-28498. doi:10.1007/s11042-020-09388-2
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K. P., & Yuille, A. L. (2016). DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40, 834-848.
- Cho, J., Kwon, J., & Hong, B. W. (2019). Adaptive Regularization via Residual Smoothing in Deep Learning Optimization. *IEEE Access*, 7, 122889-122899. doi:10.1109/access.2019.2938200
- Choe, J., & Shim, H. (2019). Attention-Based Dropout Layer for Weakly Supervised Object Localization. *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2214-2223.
- Choi, D., Bell, W., Kim, D., & Kim, J. (2021). UAV-Driven Structural Crack Detection and Location Determination Using Convolutional Neural Networks. *Sensors (Basel)*, 21(8). doi:10.3390/s21082650
- Cilhoroz, Y., & Isik, O. (2021). Artificial Intelligence: Implementations from Healthcare Services. *Ankara Hacı Bayram Veli University Journal of the Faculty of Economics and Administrative Sciences*, 23(2), 573-588.
- Clawson, K. M., Morrow, P. J., Scotney, B. W., McKenna, D. J., & Dolan, O. M. (2007, 5-7 Sept. 2007). *Computerised Skin Lesion Surface Analysis for Pigment Asymmetry Quantification*. Paper presented at the International Machine Vision and Image Processing Conference (IMVIP 2007).
- Codella, N., Cai, J., Abedini, M., Garnavi, R., Halpern, A., & Smith, J. R. (2015). *Deep Learning, Sparse Coding, and SVM for Melanoma Recognition in Dermoscopy Images*, Cham.
- Codella, N. C. (2017). Deep learning ensembles for melanoma recognition in dermoscopy images. *IBM Journal of Research and Development*, 61(4), 5-15.
- Codella, N. C. F., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., . . . Halpern, A. (2018, 4-7 April 2018). *Skin lesion analysis toward melanoma detection: A challenge at the 2017 International symposium on biomedical imaging (ISBI), hosted by the international skin imaging collaboration (ISIC)*. Paper presented at the 2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018).
- Cruz-Roa, A. A., Arevalo Ovalle, J. E., Madabhushi, A., & González Osorio, F. A. (2013). A deep learning architecture for image representation, visual interpretability and automated basal-cell carcinoma cancer detection. *Med Image Comput Comput Assist Interv*, 16(Pt 2), 403-410. doi:10.1007/978-3-642-40763-5_50
- Dal, D., & Celik, E. (2023). Investigation of the impact of different versions of GCC on various metaheuristic-based solvers for traveling salesman problem. *The Journal of Supercomputing*, 79(11), 12394-12440.
- Dalli, A. (2022). Impact of Hyperparameters on Deep Learning Model for Customer Churn Prediction in Telecommunication Sector. *Mathematical Problems in Engineering*.
- Darwish, A., Hassanien, A. E., & Das, S. (2020). A survey of swarm and evolutionary computing approaches for deep learning. *Artificial Intelligence Review*, 53(3), 1767-1812. doi:10.1007/s10462-019-09719-2

- Diwan, T., Shukla, R., Ghuse, E., & Tembhurne, J. V. (2023). Model hybridization & learning rate annealing for skin cancer detection. *Multimedia Tools and Applications*, 82(2), 2369-2392. doi:10.1007/s11042-022-12633-5
- Dreiseitl, S., & Binder, M. (2005). Do physicians value decision support? A look at the effect of decision support systems on physician opinion. *Artif Intell Med*, 33(1), 25-30. doi:10.1016/j.artmed.2004.07.007
- Eigner, I., Bodendorf, F., & Nilmini, W. (2019). *Predicting High-Cost Patients by Machine Learning: a Case Study in an Australian Private Hospital Group*. Paper presented at the Proceedings of 11th International Conference.
- Erdil, D. (2021). Deri biyopsisi nedir? Nasıl alınır?
- Esteva, A., Kuprel, B., Novoa, R., Ko, J., Swetter, S., Blau, H., & Thrun, S. (2017). Dermatologist-Level Classification of Skin Cancer with Deep Neural Networks. *Nature*, 542(7639), 115-118.
- Feng, J., Shen, L., Chen, Z., Wang, Y., & Li, H. (2020). A Two-Layer Deep Learning Method for Android Malware Detection Using Network Traffic. *IEEE Access*, 8, 125786-125796.
- Frick, N. R., Brünker, F., Ross, B., & Stieglitz, S. (2021). Comparison of Disclosure/Concealment of Medical Information Given to Conversational Agents or to Physicians. *Health Informatics Journal*, 27(1), 146045822199486.
- Frick, N. R. J., Möllmann, H. L., Mirbabaie, M., & Stieglitz, S. (2021). Driving Digital Transformation During a Pandemic: Case Study of Virtual Collaboration in a German Hospital. *JMIR Medical Informatics*, 9(2), 25183.
- Fujisawa, Y., Otomo, Y., Ogata, Y., Nakamura, Y., Fujita, R., Ishitsuka, Y., . . . Fujimoto, M. (2019). Deep-learning-based, computer-aided classifier developed with a small dataset of clinical images surpasses board-certified dermatologists in skin tumour diagnosis. *Br J Dermatol*, 180(2), 373-381. doi:10.1111/bjd.16924
- Gazioğlu, B. S. (2021). *Dermatolojide melanoma malignansının sınıflandırılması*. İstanbul Teknik Üniversitesi Retrieved from <https://doi.org/10.35232/estudamhsd.499257>
- Gong, Q., Kang, W., & Fahroo, F. (2023). Approximation of compositional functions with ReLU neural networks. *Systems & Control Letters*, 175. doi:10.1016/j.sysconle.2023.105508
- Goyal, M., Knackstedt, T., Yan, S., & Hassanpour, S. (2020). Artificial Intelligence-Based Image Classification Methods for Diagnosis of Skin Cancer: Challenges and Opportunities. *Computers in Biology and Medicine*, 127, 104065.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27-48. doi:<https://doi.org/10.1016/j.neucom.2015.09.116>
- Guoguang Rong, Mendez, A., Assi, E. B., Zhao, B., & Sawan, M. (2020). Artificial Intelligence in Healthcare: Review and Prediction Case Studies. *Engineering*, 6(3), 291-301.
- Haenssle, H. A. (2018). Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of oncology*, 29(8), 1836-1842.
- Haenssle, H. A. (2020). Man against machine reloaded: performance of a marketapproved convolutional neural network in classifying a broad spectrum of skin lesions in comparison with 96 dermatologists working under less artificial conditions. *Annals of oncology*, 31(1), 137-143.

- Han, F., Jiang, J., Ling, Q.-H., & Su, B.-Y. (2019). A survey on metaheuristic optimization for random single-hidden layer feedforward neural network. *Neurocomputing*, 335, 261-273. doi:<https://doi.org/10.1016/j.neucom.2018.07.080>
- Han, J. H., Choi, D. J., Park, S. U., & Hong, S. K. (2020, 16-21 April 2020). *Hyperparameter Optimization for Multi-Layer Data Input Using Genetic Algorithm*. Paper presented at the 2020 IEEE 7th International Conference on Industrial Engineering and Applications (ICIEA).
- Han, S. S., Kim, M. S., Lim, W., Park, G. H., Park, I., & Chang, S. E. (2018). Classification of the Clinical Images for Benign and Malignant Cutaneous Tumors Using a Deep Learning Algorithm. *J Invest Dermatol*, 138(7), 1529-1538. doi:10.1016/j.jid.2018.01.028
- Harris, C. G., & Stephens, M. J. (1988). *A Combined Corner and Edge Detector*. Paper presented at the Alvey Vision Conference.
- Hekler, A., Utikal, J. S., Enk, A. H., Berking, C., Klode, J., Schadendorf, D., . . . Brinker, T. J. (2019). Pathologist-level classification of histopathological melanoma images with deep neural networks. *Eur J Cancer*, 115, 79-83. doi:10.1016/j.ejca.2019.04.021
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2005). *Applied Logistic Regression: Hosmer/Applied Logistic Regression*.
- Hossin, M., Sulaiman, M. N., Mustapha, N., & Rahmat, R. W. (2011). *Improving Accuracy Metric with Precision and Recall Metrics for Optimizing Stochastic Classifier*.
- In, T. (2019). Facts & figures 2019: US cancer death rate has dropped 27% in 25 years.
- Jain, S., Singhanian, U., & Tripathy, B. (2021). Deep learning-based transfer learning for classification of skin cancer. *Sensors (Basel)*, 21(23), 1.
- Jain, S., Singhanian, U., Tripathy, B., Nasr, E. A., Aboudaif, M. K., & Kamrani, A. K. (2021). Deep Learning-Based Transfer Learning for Classification of Skin Cancer. *Sensors (Basel)*, 21(23). doi:10.3390/s21238142
- Jaworek-Korjakowska, J., & Kłeczek, P. (2016). Automatic Classification of Specific Melanocytic Lesions Using Artificial Intelligence. *Biomed Res Int*, 2016, 8934242. doi:10.1155/2016/8934242
- Jiang, F., Jiang, Y., Zhi, H., Dong, Y., Li, H., Ma, S., . . . Wang, Y. (2017). Artificial Intelligence in Healthcare: Past, Present and Future. *Stroke and Vascular Neurology*, 2(4), 230-243.
- Jiang, Y. Q., Xiong, J. H., Li, H. Y., Yang, X. H., Yu, W. T., Gao, M., . . . Sun, J. F. (2020). Recognizing basal cell carcinoma on smartphone-captured digital histopathology images with a deep neural network. *Br J Dermatol*, 182(3), 754-762. doi:10.1111/bjd.18026
- Katapadi, A. B., Celebi, M. E., Trotter, S. C., & Gurcan, M. N. (2018). Evolving strategies for the development and evaluation of a computerised melanoma image analysis system. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 6(4), 465-472. doi:10.1080/21681163.2016.1277785
- Kaveh, M., & Mesgari, M. S. (2023). Application of Meta-Heuristic Algorithms for Training Neural Networks and Deep Learning Architectures: A Comprehensive Review. *Neural Processing Letters*, 55(4), 4519-4622. doi:10.1007/s11063-022-11055-6
- Keith, M. (2020). Random Forest. *Machine Learning with Regression in Python*.
- Kirkpatrick, S., Gelatt, C. D., & Vecchi, M. P. (1983). Optimization by Simulated Annealing. *Science*, 220, 671 - 680.

- Knijnenburg, B., & Willemsen, M. (2016). Inferring Capabilities of Intelligent Agents from Their External Traits. *ACM Transactions on Interactive Intelligent Systems*, 6(4), 1-25.
- Koçak, Y. (2021). Cilt (Deri) Kanseri Belirtileri, Tedavisi Ve Korunma Yöntemleri. Retrieved from <https://www.memorial.com.tr/hastaliklar/cilt-derikanseri-belirtileri-tedavisi-ve-korunma-yontemleri>
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60, 84 - 90.
- Kulkarni, A. V., Jagtap, J., & Harpale, D. V. K. (2013). *Object recognition with ORB and its Implementation on FPGA*.
- Kuo, R. J., Chen, C.-K., & Keng, S.-H. (2021). Application of hybrid metaheuristic with perturbation-based K-nearest neighbors algorithm and densest imputation to collaborative filtering in recommender systems. *Inf. Sci.*, 575, 90-115.
- Lau, H. T., & Al-Jumaily, A. (2009, 4-7 Dec. 2009). *Automatically Early Detection of Skin Cancer: Study Based on Neural Network Classification*. Paper presented at the 2009 International Conference of Soft Computing and Pattern Recognition.
- Lee, S., Kim, J., Kang, H., Kang, D.-Y., & Park, J. (2021). Genetic Algorithm Based Deep Learning Neural Network Structure and Hyperparameter Optimization. *Applied Sciences*.
- Lindelöf, B., & Hedblad, M. A. (1994). Accuracy in the clinical diagnosis and pattern of malignant melanoma at a dermatological clinic. *J Dermatol*, 21(7), 461-464.
- Link. (2022). How does deep learning attain such impressive results?, How It Works, Techniques & Applications. Retrieved from mathworks.com
- Litjens, G. (2016). Deep learning as a tool for increased accuracy and efficiency of histopathological diagnosis. *Scientific Reports*, 6(1), 26286.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., . . . Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88. doi:<https://doi.org/10.1016/j.media.2017.07.005>
- Liu, Z., Sun, J., Smith, L., Smith, M., & Warr, R. (2012). Distribution quantification on dermoscopy images for computer-assisted diagnosis of cutaneous melanomas. *Med Biol Eng Comput*, 50(5), 503-513. doi:10.1007/s11517-012-0895-7
- Luger, E., & Sellen, A. (2016). *Like Having a Really Bad PA The Gulf between User Expectation and Experience of Conversational Agents*. Paper presented at the Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems.
- Madooei, A., & Drew, M. S. (2016). Incorporating colour information for computer-aided diagnosis of melanoma from dermoscopy images: A retrospective survey and critical analysis. *International journal of biomedical imaging*, 2016, 18.
- Mai, H. T., Lieu, Q. X., Kang, J., & Lee, J. (2023). A novel deep unsupervised learning-based framework for optimization of truss structures. *Engineering with Computers*, 39(4), 2585-2608. doi:10.1007/s00366-022-01636-3
- Manousaki, A. G., Manios, A. G., Tsompanaki, E. I., Panayiotides, J. G., Tsiftsis, D. D., Kostaki, A. K., & Tosca, A. D. (2006). A simple digital image processing system to aid in melanoma diagnosis in an everyday melanocytic skin lesion unit: a preliminary report. *Int J Dermatol*, 45(4), 402-410. doi:10.1111/j.1365-4632.2006.02726.x

- Maron, R. C. (2019). Systematic outperformance of 112 dermatologists in multiclass skin cancer image classification by convolutional neural networks. *European Journal of Cancer*, 119, 57-65.
- Marques, J. S. (2015). *Improved skin lesion diagnostics for general practice by computeraided diagnostics*: CRC Press.
- Mehmood, A., Gulzar, Y., Ilyas, Q. M., Jabbari, A., Ahmad, M., & Iqbal, S. (2023). SBXception: A Shallower and Broader Xception Architecture for Efficient Classification of Skin Lesions. *Cancers (Basel)*, 15(14). doi:10.3390/cancers15143604
- Menschner, P. (2011). Reaching into patients' homes – participatory designed AAL services. *Electronic Markets*, 21(1), 63-76.
- Mikołajczyk, A., Kwasigroch, A., & Grochowski, M. (2017, 2017//). *Intelligent system supporting diagnosis of malignant melanoma*. Paper presented at the Trends in Advanced Intelligent Control, Optimization and Automation, Cham.
- Mirbabaie, M., Stieglitz, S., & Frick, N. (2021). Artificial Intelligence in Disease Diagnostics: A Critical Review and Classification on the Current State of Research Guiding Future Direction. *Health and Technology*, 11(4), 1.
- Mohan, S., & Chang, A. L. (2014). Advanced Basal Cell Carcinoma: Epidemiology and Therapeutic Innovations. *Current Dermatology Reports*, 3, 40-45.
- Morton, C. A., & Mackie, R. M. (1998). Clinical accuracy of the diagnosis of cutaneous malignant melanoma. *Br J Dermatol*, 138(2), 283-287.
- Nagaoka, T. (2020). Hyperparameter Optimization for Deep Learning-based Automatic Melanoma Diagnosis System. *Advanced Biomedical Engineering*.
- Navale, V. S. (2023). Bone Abnormalities Detection and Classification Using Deep Learning-Vgg16 Algorithm. *International Journal for Research in Applied Science and Engineering Technology*.
- Netsanet, S., Zheng, D., Zhang, W., & Teshager, G. (2022). Short-term PV power forecasting using variational mode decomposition integrated with Ant colony optimization and neural network. *Energy Reports*, 8, 2022-2035. doi:https://doi.org/10.1016/j.egyr.2022.01.120
- Nikbakht, S., Anitescu, C., & Rabczuk, T. (2021). Optimizing the neural network hyperparameters utilizing genetic algorithm. *Journal of Zhejiang University-SCIENCE A*, 22(6), 407-426. doi:10.1631/jzus.A2000384
- Nikolaou, & Stratigos, A. J. (2014). Emerging Trends in the Epidemiology of Melanoma. *The British Journal of Dermatology*, 170(1), 11-19.
- Noble, W. S. (2013). *Support vector machine*.
- Nwankpa, C., Ijomah, W. L., Gachagan, A., & Marshall, S. (2018). Activation Functions: Comparison of trends in Practice and Research for Deep Learning. *ArXiv*, abs/1811.03378.
- Ojha, V. K., Abraham, A., & Snášel, V. (2017). Metaheuristic design of feedforward neural networks: A review of two decades of research. *Engineering Applications of Artificial Intelligence*, 60, 97-116. doi:https://doi.org/10.1016/j.engappai.2017.01.013
- Orszag, P., & Ellis, P. (2007). The Challenge of Rising Health Care Costs—a View from the Congressional Budget Office. *The New England Journal of Medicine*, 357(18), 1793-1795.

- Ouhib, Z. (2015). Aspects of dosimetry and clinical practice of skin brachytherapy: The American Brachytherapy Society working group report. *Brachytherapy*, 14(6), 840-858.
- Park, G.-H., Park, J. H., & Kim, H.-N. (2022). Convolutional Neural Network-Based Target Detector Using Maxpooling and Hadamard Division Layers in FM-Band Passive Coherent Location. *Journal of Electromagnetic Engineering and Science*.
- Prasad, G., Mishra, D., & Laskar, R. H. (2021). Optimal New Node Insertion for Strong Minimum Energy Topology in IoT Networks. *2021 IEEE 18th Annual Consumer Communications & Networking Conference (CCNC)*, 1-4.
- Prihatno, A. T., Nurcahyanto, H., Ahmed, M. F., Rahman, M. H., Alam, M. M., & Jang, Y. M. (2021). Forecasting PM2.5 Concentration Using a Single-Dense Layer BiLSTM Method. *Electronics*.
- Raghavendra, P. V. S. P., Charitha, C., Begum, K. G., & Prasath, V. B. S. (2023). Deep Learning-Based Skin Lesion Multi-class Classification with Global Average Pooling Improvement. *Journal of Digital Imaging*, 36(5), 2227-2248. doi:10.1007/s10278-023-00862-5
- Ramesh, A., Kambhampati, C., Monson, J., & Drew, P. (2004). Artificial Intelligence in Medicine. *Annals of the Royal College of Surgeons of England*, 86(5), 334-338.
- Ramli, A. N., & Ab Rashid, M. F. F. (2022). A review of assembly line balancing optimisation with energy consideration using meta-heuristic algorithms. *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture*, 236(5), 475-485. doi:10.1177/09544054211040612
- Rastgoo, M., Garcia, R., Morel, O., & Marzani, F. (2015). Automatic differentiation of melanoma from dysplastic nevi. *Comput Med Imaging Graph*, 43, 44-52. doi:10.1016/j.compmedimag.2015.02.011
- Rauschert, S., Raubenheimer, K., Melton, P., & Huang, R. (2020). Machine Learning and Clinical Epigenetics: A Review of Challenges for Diagnosis and Classification. *Clinical Epigenetics*, 12(1), 1-11.
- Rezvantab, A., Safigholi, H., & Karimijeshni, S. (2018). Dermatologist Level Dermoscopy Skin Cancer Classification Using Different Deep Learning Convolutional Neural Networks Algorithms. *arXiv E-Prints*, 1810.
- Ri, J. H., Kang, T. G., & Choe, C. R. (2024). Target adaptive extreme learning machine for transfer learning. *International Journal of Machine Learning and Cybernetics*, 15(3), 917-927.
- Rosen, M. A., Granados, D. D., SDietz, A., Benishek, L. E., Thompson, D., Pronovost, P. J., & Weaver, S. J. (2018). Teamwork in Healthcare: Key Discoveries Enabling Safer, High-Quality Care. *American Psychologist*, 73(4), 433.
- Rosten, E., & Drummond, T. (2006, 2006/). *Machine Learning for High-Speed Corner Detection*. Paper presented at the Computer Vision – ECCV 2006, Berlin, Heidelberg.
- Ruela, M., Barata, C., Marques, J. S., & Rozeira, J. (2017). A system for the detection of melanomas in dermoscopy images using shape and symmetry features. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 5(2), 127-137. doi:10.1080/21681163.2015.1029080
- Sadri, A. R., Azarianpour, S., Zekri, M., Emre Celebi, M., & Sadri, S. (2017). WN-based approach to melanoma diagnosis from dermoscopy images. *IET Image Processing*, 11(7), 475-482. doi:https://doi.org/10.1049/iet-ipr.2016.0681

- Safigholi, H., Meigooni, A., & Song, W. (2017). Comparison of ^{192}Ir , ^{169}Yb , and ^{60}Co High-Dose Rate Brachytherapy Sources for Skin Cancer Treatment. *Medical Physics*, 44(9), 4426–4436.
- Safigholi, H., Song, W. Y., & Meigooni, A. S. (2015). Optimum radiation source for radiation therapy of skin cancer. *J Appl Clin Med Phys*, 16(5), 219–227.
- Samhan, B., Crampton, T., & Ruane, R. (2018). The Trajectory of It in Healthcare at Hicss: A Literature Review, Analysis, and Future Directions. *Communications of the Association for Information Systems*, 43(1), 41.
- Satheesha, T. Y., Satyanarayana, D., Prasad, M. N. G., & Dhruve, K. D. (2017). Melanoma Is Skin Deep: A 3D Reconstruction Technique for Computerized Dermoscopic Skin Lesion Classification. *IEEE J Transl Eng Health Med*, 5, 4300117. doi:10.1109/jtehm.2017.2648797
- Schaefer, G., Krawczyk, B., Celebi, M. E., & Iyatomi, H. (2014). An ensemble classification approach for melanoma diagnosis. *Memetic Computing*, 6(4), 233–240. doi:10.1007/s12293-014-0144-8
- Seidenari, S., Pellacani, G., & Grana, C. (2005). Colors in atypical nevi: a computer description reproducing clinical assessment. *Skin Res Technol*, 11(1), 36–41. doi:10.1111/j.1600-0846.2005.00097.x
- Shahin, A. H., Kamal, A., & Elattar, M. A. (2018, 20–22 Dec. 2018). *Deep Ensemble Learning for Skin Lesion Classification from Dermoscopic Images*. Paper presented at the 2018 9th Cairo International Biomedical Engineering Conference (CIBEC).
- Shimizu, K., Iyatomi, H., Celebi, M. E., Norton, K. A., & Tanaka, M. (2015). Four-class classification of skin lesions with task decomposition strategy. *IEEE Trans Biomed Eng*, 62(1), 274–283. doi:10.1109/tbme.2014.2348323
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 60. doi:10.1186/s40537-019-0197-0
- Sigurdsson, S., Philipsen, P. A., Hansen, L. K., Larsen, J., Gniadecka, M., & Wulf, H. C. (2004). Detection of skin cancer by classification of Raman spectra. *IEEE Trans Biomed Eng*, 51(10), 1784–1793. doi:10.1109/tbme.2004.831538
- Singh, A., Mehta, J. C., Anand, D., Nath, P., Pandey, B., & Khamparia, A. (2021). An Intelligent Hybrid Approach for Hepatitis Disease Diagnosis: Combining Enhanced K-means Clustering and Improved Ensemble Learning. *Expert Systems*, 38(1), 12526.
- Society, A. C. (2008). Cancer Facts & Figures 2008. Retrieved from <https://www.cancer.org/research/cancer-facts-statistics/all-cancer-facts-figures/cancer-facts-figures-2008.html>
- Society, A. C. (2018). Cancer Facts & Figures 2018. Retrieved from <https://www.cancer.org/research/cancer-facts-statistics/all-cancer-facts-figures/cancer-facts-figures-2018.html>
- Spanos, S., Singh, N., Laginha, B. I., Arnolda, G., Wilkinson, D., Smith, A. L., . . . Rapport, F. (2023). Measuring the quality of skin cancer management in primary care: A scoping review. *Australas J Dermatol*, 64(2), 177–193. doi:10.1111/ajd.14023
- Stanley, R. J., Stoecker, W. V., & Moss, R. H. (2007). A relative color approach to color discrimination for malignant melanoma detection in dermoscopy images. *Skin Res Technol*, 13(1), 62–72. doi:10.1111/j.1600-0846.2007.00192.x

- Sun, B., Wu, D., Shang, M., & He, Y. (2022). *Toward Auto-Learning Hyperparameters for Deep Learning-Based Recommender Systems*. Paper presented at the International Conference on Database Systems for Advanced Applications.
- Tasar, B. (2023). SkinCancerNet: Automated classification of skin lesion using deep transfer learning method. *Traitement du Signal*, 40(1), 285-295.
- Thakare, P., & V, R. S. (2022). Advanced pest detection strategy using hybrid optimization tuned deep convolutional neural network. *Journal of Engineering, Design and Technology, ahead-of-print*(ahead-of-print). doi:10.1108/JEDT-09-2021-0488
- Tschandl, P. (2019a). Comparison of the accuracy of human readers versus machine learning algorithms for pigmented skin lesion classification: an open, web-based, international, diagnostic study. *The Lancet Oncology*, 20(7), 938-947.
- Tschandl, P. (2019b). Expert-level diagnosis of nonpigmented skin cancer by combined convolutional neural networks. *JAMA dermatology*, 155(1), 58-65.
- Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, 5(1), 180161. doi:10.1038/sdata.2018.161
- Wang, G. (2018). Interactive Medical Image Segmentation Using Deep Learning With Image-Specific Fine Tuning. *IEEE Trans Med Imaging*, 37(7), 1562-1573.
- Wang, Q., Zhang, S.-l., Ji, X., & Ran, F. (2020). High rejection performance ultrafiltration membrane with ultrathin dense layer fabricated by the movement and dissolution of metal–organic frameworks. *New Journal of Chemistry*, 44, 13745-13754.
- Wang, Z., Luo, G., Li, Y., & Cao, P. (2024). Using a deep learning prior for accelerating hyperpolarized ¹³ C MRSI on synthetic cancer datasets. *Magnetic Resonance in Medicine*, 1(1), 1.
- Wears, R. L., & Berg, M. (2005). Computer Technology and Clinical Work Still Waiting for Godot. *JAMA*, 293(10), 1261-1263.
- Xia, H. S., Zhou, Y. J., & Zhang, Z. P. (2022). Auto insurance fraud identification based on a CNN-LSTM fusion deep learning model. *International Journal of Ad Hoc and Ubiquitous Computing*, 39(1-2), 37-45. doi:10.1504/ijahuc.2022.120943
- Xie, P. (2019). Interpretable classification from skin cancer histology slides using deep learning: A retrospective multicenter study. *arXiv preprint arXiv:1904.06156*.
- Xu, X., Cao, J., Shi, X., & Gorbachev, S. (2023). Cumulative Capacitated Colored Traveling Salesman Problem. *IEEE transactions on cybernetics*, PP.
- Yan, K., & Sukthankar, R. (2004, 27 June-2 July 2004). *PCA-SIFT: a more distinctive representation for local image descriptors*. Paper presented at the Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. CVPR 2004.
- Yanfang, L., Yaming, W., Wenqing, H., & Zuoli, Z. (2008, 7-9 July 2008). *Automatic image stitching using SIFT*. Paper presented at the 2008 International Conference on Audio, Language and Image Processing.
- Yang, J. (2018). *Clinical skin lesion diagnosis using representations inspired by dermatologist criteria*. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.

- Yildiz, O. (2019). Melanoma Detection from Dermoscopy Images with Deep Learning Methods: A Comprehensive Study. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(4), 2241–2260.
- Zhang, K., Zuo, W., Chen, Y., Meng, D., & Zhang, L. (2016). Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising. *IEEE Transactions on Image Processing*, 26, 3142-3155.
- Zortea, M., Schopf, T. R., Thon, K., Geilhufe, M., Hindberg, K., Kirchesch, H., . . . Godtliessen, F. (2014). Performance of a dermoscopy-based computer vision system for the diagnosis of pigmented skin lesions compared with visual evaluation by experienced dermatologists. *Artif Intell Med*, 60(1), 13-26. doi:10.1016/j.artmed.2013.11.006
- Zwaan, L., & Singh, H. (2015). The challenges in defining and measuring diagnostic error. *Diagnosis*, 2(2), 97-103.



ÖZGEÇMİŞ

Kişisel Bilgiler	
Adı Soyadı:	Mustafa Furkan KESKENLER
Doğum tarihi:	
Doğum Yeri:	
Uyruğu:	
Adres:	
Tel:	
E-mail:	
Eğitim	
Lise:	Ilıca Yavuz Selim Anadolu Öğretmen Lisesi (2012)
Lisans:	Atatürk Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü (2016)
Lisans:	İstanbul Üniversitesi, Açık ve Uzaktan Eğitim Fakültesi, Tarih Bölümü (2023)
Yüksek lisans:	Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (2019)
Doktora:	Atatürk Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı (2024)
Yabancı Dil Bilgisi	
İngilizce:	İyi
Tezden Üretilmiş Yayınlar	
1. Keskenler, M.F. , Çelik, E. & Dal, D. A New Multi-Layer Machine Learning (MLML) Architecture for Non-invasive Skin Cancer Diagnosis on Dermoscopic Images. J. Electr. Eng. Technol. (2024).	