

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME MODELLERİNİN BELİRSİZLİK ÖLÇÜMÜ

DOKTORA TEZİ

Samet GÜMÜŞ

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

OCAK, 2024

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DERİN ÖĞRENME MODELLERİNİN BELİRSİZLİK ÖLÇÜMÜ

DOKTORA TEZİ

Samet GÜMÜŞ
(Y1713.610006)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ali GÜNEŞ

OCAK, 2024

ONAY FORMU

ONUR SÖZÜ

Doktora tezi olarak sunduğum" Derin öğrenme modellerinin belirsizlik ölçümü" adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça 'da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (10/12/2023)

Samet GÜMÜŞ

ÖNSÖZ

Bu tez çalışmasındaki rehberliği ve destekleri ile eğitimime olan katkılarından ötürü danışman hocam Prof. Dr. Ali GÜNEŞ'e teşekkür etmek istiyorum. Bu tezin hazırlanması boyunca yaptıkları çok değerli yorum ve geri bildirimler için Dr. Öğr. Üyesi Peri GÜNEŞ'e ve Dr. Öğr. Ali Hamitoğlu'na teşekkür etmek istiyorum. Tez çalışmamda yapmış olduğu değerli önerilerinden dolayı Dr. Öğr. Üyesi Sina Apak'a teşekkür etmek istiyorum. Ayrıca yaşamım boyunca ve özellikle doktora çalışmam süresince desteklerini hiçbir zaman esirgemeyen arkadaşlarıma, aileme çok teşekkür etmek istiyorum.

Ocak, 2024

Samet GÜMÜŞ

DERİN ÖĞRENME MODELLERİNİN BELİRSİZLİK ÖLÇÜMÜ

ÖZET

Derin öğrenme modelleri, görüntü sınıflandırma, belirsizlikle başa çıkma yeteneklerini artırmaya, doğal dil işleme ve makine çevirisi gibi birçok alanda uzman insanları aşan performanslar sergilemektedir. Ancak, bu modeller belirsizlik durumlarını ele alırken zorluk yaşamaktadır, bu da yanlış kararlar ve güvenilirlik kaybına neden olabilir. Derin öğrenme modellerinin belirsizliğini ölçmek için kullanılan çeşitli yöntemler incelenmektedir. Bu yöntemler, model çıktılarının analizi, eğitim süreçlerinin incelenmesi ve yeni verilerle test edilmesi gibi farklı yaklaşımları içermektedir. Bu yöntemlerin avantajları ve dezavantajları tartışılarak, derin öğrenme modellerinin güvenilirliğini artırmak için nasıl kullanılabileceği araştırılmaktadır.

Ayrıca, bu çalışmada bir örnek sunulmuş ve Yönlü Merkezi Simetrik İkili Desen (DCSBP) temelli bir derin öğrenme çerçevesinin kullanıldığı bir uygulama özetlenmiştir. Bu çerçeve, X-ışını görüntülerinde COVID-19, zatürre ve verem gibi anormallikleri tespit etmek için kullanılmıştır. Önerilen DL yaklaşımı, zatürre ve CH veri tabanında sırasıyla %98'den fazla ve %87'den fazla doğruluk elde etti. Bu sonuçlar, mevcut en iyi yöntemlerle karşılaştırıldığında önemli ölçüde daha iyidir. Ayrıca, önerilen sistem, gürültülü ve bilinmeyen veri kümeleri de dahil olmak üzere belirsiz senaryolarda test edilmiş ve uyumlu sonuçlar elde edilmiştir. Önerilen yöntem, yüksek doğruluk oranları elde etmiş ve mevcut yöntemlere göre daha iyi sonuçlar vermiştir. Ayrıca, çerçeve belirsiz senaryolarda da test edilmiş ve uyumlu sonuçlar elde edilmiştir.

Anahtar Kelimeler: Derin Öğrenme Modelleri, Belirsizlik Ölçümü, Anormal Tespiti, Makine Öğrenimi, Derin Asamble

MEASURING UNCERTAINTY IN DEEP LEARNING MODELS

ABSTRACT

Deep learning models have demonstrated superior performance in various fields such as image classification, addressing uncertainty, natural language processing, and machine translation, often surpassing human experts. However, these models often struggle when dealing with uncertainty, leading to incorrect decisions and a decrease in reliability. Various methods for measuring the uncertainty of deep learning models are examined in this study. These methods encompass different approaches, including the analysis of model outputs, the examination of training processes, and testing with new data. The advantages and disadvantages of these methods are discussed, aiming to explore how they can be utilized to enhance the reliability of deep learning models.

Furthermore, this study presents an example where a Deep Learning framework based on Directional Central Symmetric Binary Pattern (DCSBP) is used. This framework is applied to detect anomalies such as COVID-19, pneumonia, and tuberculosis in X-ray images. The proposed DL approach achieved an accuracy of over 98% for pneumonia and more than 87% for the CH database. These results are significantly better than the current state-of-the-art methods. Moreover, the proposed system was tested in uncertain scenarios, including noisy and unknown datasets, and yielded consistent results. In summary, this thesis focuses on improving the ability of deep learning models to handle uncertainty in various applications. It explores different methods for measuring uncertainty and discusses their advantages and disadvantages. Additionally, it presents a practical example of using a DCSBP-based deep learning framework for detecting anomalies in X-ray images, achieving high accuracy and reliability even in uncertain scenarios.

Keywords: Deep Learning Models, Uncertainty Measurement, Anomaly Detection, Machine Learning, Deep Assemble

İÇİNDEKİLER

	<u>Sayfa</u>
ONUR SÖZÜ	i
ÖNSÖZ.....	ii
ÖZET.....	iii
ABSTRACT	iv
İÇİNDEKİLER	v
KISALTMALAR LİSTESİ.....	viii
ÇİZELGELER LİSTESİ.....	x
ŞEKİLLER LİSTESİ.....	xi
I. GİRİŞ	1
A. Temel Kavramlar	1
B. Tezin Önemi ve Amacı.....	4
II. LİTERATÜR TARAMASI.....	6
A. Yapılan Çalışmalar	6
III. DERİN ÖĞRENME (DL) TEKNİKLERİ.....	15
A. Derin sinir ağları (DNN).....	15
B. Bayes Teoremi	16
C. Dropout	17
1. Düzenleştirme ve Aşırı Öğrenme Kontrolü.....	18
2. Monte Carlo Dropout.....	18
D. Markov Chain Monte Carlo (MCMC).....	20
1. Markov Zincirleri ve MCMC Algoritmaları.....	20

2. Gibbs özellikler.....	22
3. Hamiltonian Monte Carlo (HMC)	23
IV. KAYIP FONKSİYONLAR	25
A. 3.2 Loss Fonksiyonu (Kayıp Fonksiyonlar)	25
B. Ortalama Karesel Hata (Mean Squared Error- MSE).....	26
C. Ortalama Mutlak Hata (Mean Absolute Error- MAE)	26
D. Çapraz Entropi (Cross-Entropy)	27
E. Focal Loss	29
F. Dice Loss	29
G. Triplet Loss	30
H. Hata Fonksiyonu	31
V. YEREL ÖZELLİK TANIMLAYICILARI	33
A. Yerel Bit Desen.....	33
B. Yönlü Merkezi Simetrik İkili Model (DCSBP).....	33
C. Merkezi Simetrik yerel ikili model (CS-LBP).....	34
D. Merkez Simetrik Bit Düzlemi Yönleri	35
E. Yığılmış Otomatik Kodlayıcı	37
VI. DERİN ÖĞRENME (DL) İLE ANORMALLİK TESPİTİ	41
A. Derin Öğrenmede Yanlılık- Varyans İkilemi	47
B. Belirsizlik Modelleme	48
VII. DERİN ÖĞRENME MODELLERİNİN BELİRSİZLİĞİ.....	51
A. Deep Ensemble (DE)	51
B. Derin Öğrenme Modellerinin Belirsizliğinin Nedenleri.....	51
C. Derin Öğrenme Modellerinin Belirsizliğini Ölçümü.....	52
D. Belirsizlik analizi olmadan Algılama Sonuçları	52
E. Belirsizlik Farkındalığı Göz önünde Bulundurarak Anormallik Tespiti	56

VIII.	YÖNTEM, SINIFLANDIRMA VE UYGULAMA	57
A.	Derin Topluluk Teknikleri.....	57
B.	Önerilen Yöntem	57
C.	Deneyisel Sonuçlar	59
D.	Deneyisel Veri Seti	61
IX.	MATARYEL VE METOT DEĞİŞİMİ	62
A.	Gürültülü Senaryo.....	62
B.	Bilinmeyen Veri Senaryosu.....	63
C.	En İyi Durum Algoritmaları	64
X.	SONUÇLAR VE DEĞERLENDİRİLMESİ	66
XI.	SONUÇLAR VE TARTIŞMALAR.....	67
XII.	KAYNAKÇA	68
ÖZGEÇMİŞ.....		81

KISALTMALAR LİSTESİ

AU	: Aleatorik belirsizlik
CAD	: Bilgisayar Destekli Teşhis
CH	: Şenzhen Hastanesi Çin
CNN	: Convolutional Neural Networks
CS-LBP	: Merkezi Simetrik Yerel İkili Desenler
CTN	: kontrastif üçlü ağ
CVPR	: Computer Vision and Pattern Recognition
CXR	: X-ray
DBP	: Directions of Bit-Planes
DCNN	: Derin Evrişimli Sinir Ağı
DCSBP	: Yönlü Merkezi Simetrik Bit-Düzlemi
DNN	: Derin Sinir Ağı
DL	: Derin öğrenme
DWC	: Daubechies Dalgalet Katsayıları
EDBP	: Eigen Yönlendirilmiş Bit Düzlemi
ELBO	: evidence lower bound maximization
EMCD	: Ensemble Monte Carlo Kesilmesi
EP	: Epok sayısı
EU	: Epistemik belirsizlik
FN	: Yanlış Negatifler
FTL	: İnce Ayar Öğrenme Oranı
GRU	: Gated Recurrent Unit
HMC	: Hamiltonian Monte Carlo
HOG	: Gradyan Histogramı
HRCT	: Yüksek Çözünürlüklü Bilgisayarlı Tomografi
KL	: Kullback –Leibler
LBP	: Yerel İkili Model
Leaky ReLU	: Leaky Rectified Linear Unit
LSTM	: Long Short-Term Memory

MAE	: Ortalama Mutlak Hata, Mean Absolute Error
MAN	: Modified Alex Net
MCMC	: Markov Chain Monte Carlo
MH	: Metropolis-Hastings
ML	: Makine Öğrenimi
MSE	: Ortalama Karesel Hata, Mean Squared Error
MS-YİD	: Merkezi Simetrik Yerel İkili Desen
MV-KBC	: çoklu görünüm tabanlı iş birliği içeren derin bir model
PA	: Posterior Anterior
PLR	: Ön Eğitim Öğrenme Oranı
PHOG	: Pyramid histogram of oriented gradient
PU	: Predictive Belirsizlik
ReLU	: Rectified Linear Unit
RNN	: Rekürrent Sinir Ağları, Recurrent Neural Networks
SAE	: Yığın Otomatik Kodlayıcı
SGD	: Stochastic Gradient Descent
SSL	: Semi-Supervised Learning
STD	: Standart Sapma Değeri
SWA-Gaussian	: Stochastic Weight Averaging Gaussian
TB	: Çeşitli Verem
TP	: Gerçek Pozitifler
YAO	: Yığınlanmış otokodlayıcılar
YBD	: Yönlü Bit-Düzlem
YMSBD	: Yönlü Merkezi Simetrik Bit-Düzlemi
YSA	: Yapay sinir ağları

ÇİZELGELER LİSTESİ

Sayfa

Çizelge 1.	DNN Yapılandırması	52
Çizelge 2.	DNN Yapılandırması CH, Zatürre ve COVID-19 Veri Kümelerinde Sınıflandırma Modellerinin Performans Değerlendirmesi	53
Çizelge 3.	Yönlü Bit Düzlemelerinin Performans Değerlendirmesi.....	54
Çizelge 4.	Önerilen yaklaşımın sözdizimi (pseudocode).....	58
Çizelge 5.	Kodlayıcı bölümü için SAE modeli.....	60
Çizelge 6.	SAE Parametreleri	60
Çizelge 7.	Önerilen yaklaşımın doğruluk oranındaki gürültünün etkileri.	63
Çizelge 8.	Önerilen yaklaşım ile bilinmeyen görüntü sınıfı tespit.....	64
Çizelge 9.	Önerilen yöntemin zatürre veri tabanında en son teknik yöntemlerle karşılaştırılması	65

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1.	Ensemble öğrenme segmentasyonuna uygulanmasını gösteren genel bir görünüm	13
Şekil 2.	Overview of deep neural network (DNN) model.....	16
Şekil 3.	Dropout ile Aşırı Öğrenme/Varyans Kontrolü.....	17
Şekil 4.	Dropout ensemblleri, Monte-Carlo Dropout ve Derin Ensembller yaklaşımları	19
Şekil 5.	Çapraz Entropinin Matematiksel Halinde Bir Örneği.....	28
Şekil 6.	Tripet Loss Fonksiyonunun Benzer ve Farklı Örnekleri.....	31
Şekil 7.	hata fonksiyonu üzerinde gradyan azaltma güncellemelerinin gösterimi	32
Şekil 8.	CS-LBP özellik tanımlayıcısı.....	35
Şekil 9.	CXR görüntüsünün Bit-Düzlemi ayrışımı.....	36
Şekil 10.	CXR görüntüsünde, çeşitli normal ve anormal anatomik yapılar	43
Şekil 11.	Önerilen yaklaşımın farklı veri kümelerinde ROC eğrisi	54
Şekil 12.	Farklı veri kümelerinde önerilen yaklaşımın karışıklık matrisi analizi...	55
Şekil 13.	DCSBP-SAE Yaklaşımı ile X-Işını Anomalisi Tespiti.....	57
Şekil 14.	Beyin inme görüntüsü	63

I. GİRİŞ

A. Temel Kavramlar

Derin öğrenme modelleri, görüntü sınıflandırma, doğal dil işleme ve makine çevirisi gibi çeşitli görevlerde insan uzmanlarını aşan performanslar sergilemiştir. Ancak, derin öğrenme modelleri, belirsizlik durumlarını iyi ele almakta genellikle zorluk çekerler. Bu durum, modellerin yanlış kararlar vermesine ve güvenilirliğinin azalmasına neden olabilir.

Derin öğrenme modellerinin belirsizliğini ölçmek, bu modellerin güvenilirliğini artırmanın önemli bir yoludur. Belirsizlik ölçümü, modellerin karar verme süreçlerini daha iyi anlamamıza yardımcı olur. Ayrıca, modellerin hatalarını daha iyi tespit etmemize ve modellerin farklı senaryolarda nasıl performans göstereceğini tahmin etmemize yardımcı olur.

Derin öğrenme modellerinin belirsizliğini ölçmek için çeşitli yöntemler kullanılmaktadır. Bu yöntemler, modellerin çıktılarını analiz etmek, modellerin eğitim süreçlerini incelemek veya modelleri yeni verilerle test etmek gibi yaklaşımları içerebilir.

Derin öğrenme modellerinin belirsizliğini ölçmenin birçok avantajı vardır. Bu avantajlar şunlardır (Choudhary et al., 2023)

- Modellerin karar verme süreçlerini daha iyi anlamamıza yardımcı olur. Örneğin, bir derin öğrenme modeli bir görüntüdeki nesneyi doğru bir şekilde sınıflandırmış olsa bile, belirsizliği yüksekse, modelin neden bu sınıflandırmayı yaptığından emin olmayabiliriz. Belirsizliği ölçerek, modelin karar verme sürecini daha iyi anlayabilir ve modelin doğruluğunu artırabiliriz.
- Modellerin güvenilirliğini artırmamıza yardımcı olur. Belirsizliği ölçerek, modelin güvenilirliğini artırmak için önlemler alabiliriz. Örneğin, bir

modelin belirsizliđi yüksekse, modelin tahminini dikkate almayarak hata riskini azaltabiliriz.

- Modellerin hatalarını daha iyi tespit etmemize yardımcı olur. Belirsizliđi ölçerek, modelin hatalarını daha iyi tespit edebiliriz. Örneđin, bir modelin belirsizliđi yüksekse, modelin tahmininin dođru olmadıđının daha yüksek bir ihtimali vardır. Belirsizliđi ölçerek, modelin hatalarını daha hızlı ve daha kolay tespit edebilir ve modelin performansını iyileştirebiliriz.
- Modellerin farklı senaryolarda nasıl performans göstereceđini tahmin etmemize yardımcı olur. Belirsizliđi ölçerek, modellerin farklı senaryolarda nasıl performans göstereceđini tahmin edebiliriz. Örneđin, bir modelin belirsizliđi yüksekse, modelin farklı ortamlarda veya koşullarda daha az güvenilir olabileceđini tahmin edebiliriz. Belirsizliđi ölçerek, modellerin farklı senaryolarda nasıl performans göstereceđini daha iyi anlayabilir ve modelin performansını iyileştirebiliriz.

Ancak, derin öğrenme modellerinin belirsizliđini ölçmenin de bazı dezavantajları vardır. Bu dezavantajlar şunlardır:

- Belirsizlik ölçümü, modellerin performansını düşürebilir. Belirsizliđi ölçmek, modelin karmaşıklılıđını ve öğrenme süresini artırabilir. Bu da modellerin performansını düşürebilir.
- Belirsizlik ölçümü, modellerin karmaşıklılıđını artırabilir. Belirsizliđi ölçmek için genellikle karmaşık modeller ve algoritmalar kullanılır. Bu da modellerin karmaşıklılıđını ve öğrenme süresini artırabilir.
- Belirsizlik ölçümü, modellerin eğitilmesini zorlaştırabilir. Belirsizliđi ölçmek için genellikle büyük miktarda veri gerekir. Bu da modellerin eğitilmesini zorlaştırabilir.

Derin öğrenme, yapay sinir ađları gibi karmaşık ve çok katmanlı yapılara dayanan bir makine öğrenimi alt dalıdır. Derin öğrenme algoritması, büyük veri setleri üzerinde otomatik öğrenme gerçekleştirir ve veri içindeki desenleri tanımak, anlamak ve çıkarım yapmak için kullanılır. Bu yaklaşım, insan beyninin sinir ađlarını modellemeye çalışır ve özellikle büyük veri setlerinden yüksek düzeyde özellikleri çıkarma yeteneđi ile dikkat çeker.

Derin öğrenme, yapay zekâ alanının uzun bir tarihçesi ve evrimi ile şekillenmiştir. Derin öğrenmenin tarihçesi hakkında ana hatlarıyla bilgiler:

1940'lar- 1950'ler: İlk Yapay Sinir Ağları

- İnsan beyninin temel bileşenlerini taklit etmeye yönelik ilk çalışmalar gerçekleşti.
- McCulloch-Pitts modeli gibi basit yapay sinir ağları ortaya çıktı.
- Frank Rosenblatt'ın "Perceptron" adını verdiği yapay sinir ağı modeli, öğrenme yetenekleri nedeniyle dikkat çekti.

1960'lar- 1970'ler: Perceptron'un Sınırlamaları

- Minsky ve Papert, "Perceptrons" adlı kitaplarında, tek katmanlı perceptronların bazı problemleri çözemeyeceğini gösterdi.
- Bu çalışmada, yapay sinir ağlarının gelişimini sınırladı ve ilgiyi diğer makine öğrenimi tekniklerine kaydırıldı.

1980'ler- 1990'lar: Sınırlı İlerleme

- Geri yayılım algoritması, yapay sinir ağlarının eğitimini geliştiren bir adım oldu ancak derin yapay sinir ağlarının aşılması zor olan eğitim sorunları yaşadığı görüldü.
- Yapay sinir ağları yerine sembolik yapay zeka yaklaşımları daha popülerdi.

2000'ler: Yeniden Canlanma

- Büyük veri setleri ve gelişmiş işlem gücü ile derin öğrenme yeniden popülerlik kazandı.
- Derin öğrenmenin eğitimi için daha iyi algoritmalar ve hesaplama kaynakları geliştirildi.
- Erişimli sinir ağları (CNN) görüntü tanıma alanında büyük başarı elde etti.

2010'lar: Derin Öğrenmenin Yükselişi

- Derin öğrenme, pek çok alanda büyük başarılar elde etti. Özellikle görüntü işleme, doğal dil işleme ve oyun oynama gibi alanlarda çığır açan sonuçlar elde edildi.

- Büyük teknoloji şirketleri derin öğrenmeye yatırım yaparak bu alanın hızla gelişmesini sağladı.
- Yapay zeka alanındaki çeşitli yarışmalar ve etkinlikler derin öğrenmenin başarısını gösterdi.

Bu tarihçe, derin öğrenmenin nasıl evrildiğini ve geçmişteki önemli dönüm noktalarını açıklamaktadır. Derin öğrenme, teknolojinin ve araştırmanın ilerlemesiyle günümüzde birçok farklı alanda etkili uygulamalara sahip bir alan haline gelmiştir.

Bu tezde, derin öğrenme modellerinin belirsizliğini ölçmek için kullanılan çeşitli yöntemler incelenecektir. Bu yöntemlerin avantajları ve dezavantajları tartışılacak ve bu yöntemler kullanılarak derin öğrenme modellerinin güvenilirliği nasıl artırılabilir araştırılacaktır (Gal and Ghahramani, 2016). Derin öğrenme modellerinin belirsizliğinin çeşitli nedenleri vardır. Bu nedenlerden bazıları şunlardır (Gawlikowski et al., 2023)

- Verilerin belirsizliği: Derin öğrenme modelleri, büyük miktarda veriden öğrenirler. Bu veriler, çeşitli kaynaklardan gelebilir ve farklı kalitede olabilir. Verilerin belirsizliği, modellerin belirsizliğini artırabilir.
- Modelin karmaşıklığı: Derin öğrenme modelleri, genellikle çok karmaşık yapıya sahiptir. Bu karmaşıklık, modellerin öğrenme sürecini zorlaştırabilir ve modelin belirsizliğini artırabilir.
- Girdi verilerinin doğası: Derin öğrenme modelleri, genellikle gerçek dünyadan gelen girdi verileri ile eğitilirler. Bu veriler, çeşitli gürültüler ve bozulmalarla içerebilir. Girdi verilerinin doğası, modellerin belirsizliğini artırabilir.

B. Tezin Önemi ve Amacı

Derin öğrenme modelleri, yapay zeka ve makine öğrenme alanlarında büyük bir ilgi ve başarı elde etmiştir. Bu modeller, büyük veri setlerinden karmaşık desenler çıkarmak ve pek çok uygulama alanında olağanüstü performans sergilemek konusunda büyük potansiyele sahiptirler. Ancak, bu modellerin tahminlerinin güvenilirliği ve belirsizlikleri, birçok uygulama alanında kritik bir

öneme sahiptir. İşte bu noktada, bu konunun önemi ve amacı ortaya çıkar. Bu tezin önemi, derin öğrenme modellerinin güvenilirliği ve tahminlerinin belirsizlik seviyelerinin değerlendirilmesinin, birçok kritik uygulama alanında gerekliliğini vurgular.

En önemli nokta model güvenilirliğini arttırmaktır. Derin öğrenme modelleri, karmaşık ve içinden çıkılması zor problemlerde yüksek doğruluk oranlarına erişebilirler ancak bu tahminlerin ne kadar güvenilir olduğu genellikle belirsizdir. Bu tezin bir numaralı amacı derin öğrenme modellerinin güvenilirliğini arttırmak ve belirsizlik ölçümünün kullanılmasının önemidir.

Belirsizlik ölçümü, aktif öğrenme ve veri toplama süreçlerini iyileştirebilir. Bu sayede modelin daha az veri ile daha iyi performans göstermesine ve veri toplama işlemlerinin daha verimli hale gelmesine yol açar. Bu bağlamda belirsizlik ölçümünün önemi büyüktür. Ayrıca belirsizlik ölçümü tahminlerin daha iyi anlamlandırılmasına ışık tutar. Özellikle regresyon problemlerinde, tahminlerin belirsizlik düzeyleri, tahminlerin yorumlanmasını kolaylaştırır.

II. LİTERATÜR TARAMASI

Günümüzde bilimsel arařtırmalar, hızla gelişen teknoloji ve artan bilgi birikimiyle birlikte önemli bir ivme kazanmıştır. Bu ivmelenme, farklı disiplinlerdeki arařtırmacıların belirli konularda yoğunlaşmalarına ve derinlemesine çalışmalarına yol açmıştır. Bu noktada, literatür taramasının rolü daha da kritik hale gelmiştir. Literatür taraması, belirli bir konu veya problem alanında daha önce yapılmış çalışmaların sistematik olarak toplanması, analiz edilmesi, sentezlenmesi ve değerlendirilmesi sürecini içerir. Bu süreç, mevcut bilgiye dayalı olarak yeni arařtırma sorularının belirlenmesi, eksikliklerin tanımlanması ve ileriye yönelik arařtırmaların temelini oluşturması bakımından büyük bir öneme sahiptir.

A. Yapılan Çalışmalar

Bu literatür taraması, Derin Öğrenme Modellerinin Belirsizlik Ölçümü konusundaki bilimsel literatürü derinlemesine incelemeyi amaçlamaktadır. Günümüzde bilimsel arařtırmalar, hızla gelişen teknoloji ve artan bilgi birikimiyle birlikte önemli bir ivme kazanmıştır. Bu ivmelenme, farklı disiplinlerdeki arařtırmacıların belirli konularda yoğunlaşmalarına ve derinlemesine çalışmalarına yol açmıştır. Derin öğrenme modelleri, çok katmanlı yapay sinir ağlarını kullanarak karmaşık görevleri çözmek ve büyük veri setlerinden özellikler ve desenler öğrenmek için tasarlanmış özel makine öğrenme modelleridir. Bu modeller, özellikle görsel tanıma, doğal dil işleme, ses tanıma, oyun oynama ve daha pek çok alanda büyük başarı elde etmiştir. İşte bazı popüler derin öğrenme modelleri: Evrişimli Sinir Ağı (Convolutional Neural Network- CNN), Rekurrent Sinir Ağı (Recurrent Neural Network- RNN), Uzun Kısa Vadeli Bellek (Long Short-Term Memory- LSTM) gibi birkaç örnek olup, derin öğrenme alanında birçok farklı model ve yapı bulunmaktadır.

Bu, derin öğrenme modellerinin güvenilirliğini artırmak ve belirsizlikleri daha iyi hesaba katmak isteyen araştırmacılar için önemli bir referans kaynağıdır (Gal, Y. and Ghahramani, Z. 2016).

Derin öğrenme modellerinin belirsizliklerini ve belirsizlikle başa çıkma stratejilerini tartışarak, dropout yöntemini bir Bayesian yaklaşımın bir parçası olarak sunmaktadır.

Derin öğrenme modellerinde belirsizliği ölçmek için basit ve ölçeklenebilir bir yöntem olan SWA-Gaussian'ı (Stochastic Weight Averaging Gaussian) sunmaktadır (Maddox et al. (2019)). Derin öğrenme modelleri, genellikle yüksek doğruluk oranları sergilerler. Ancak, bu modeller, belirsizlik durumlarını iyi ele almakta zorluk çekebilirler. Belirsizlik, bir modelin tahminlerinin ne kadar doğru olabileceğini ifade eder. Belirsizliği ölçmek, modellerin karar verme süreçlerini daha iyi anlamamıza, hatalarını daha iyi tespit etmemize ve farklı senaryolarda nasıl performans göstereceğini tahmin etmemize yardımcı olur (Maddox et al. 2019) SWA-Gaussian, basit ve ölçeklenebilir bir yöntemdir. Bu yöntem, derin öğrenme modellerini eğitmek için kullanılan SGD (Stochastic Gradient Descent) algoritmasını kullanır. SGD, modelin ağırlıklarını güncellemek için eğitim verilerinden rastgele örnekler kullanır. SWA-Gaussian yöntemi, SGD'yi her iterasyonda farklı ağırlıklar kullanarak modelleri eğitir. Bu yöntem, derin öğrenme modellerinin güvenilirliğini ve performansını iyileştirmek için kullanılabilir (Maddox et al. 2019).

SWA-Gaussian yönteminin avantajları şunlardır:

- Basit ve ölçeklenebilirdir.
- Diğer belirsizlik modelleme yöntemlerine göre daha verimlidir.
- Farklı görevlerde başarılı sonuçlar elde etmiştir.

SWA-Gaussian yönteminin dezavantajları şunlardır:

- Diğer belirsizlik modelleme yöntemlerine göre daha az karmaşıktır.
- Daha az esnektir.

Derin öğrenme modelleri, genellikle yüksek doğruluk oranları sergilerler (Russell and Reale 2021). Ancak, bu modeller, belirsizlik durumlarını iyi ele almakta zorluk çekebilirler. Belirsizlik, bir modelin tahminlerinin ne kadar doğru

olabileceğini ifade eder. Belirsizliği ölçmek, modellerin karar verme süreçlerini daha iyi anlamamıza, hatalarını daha iyi tespit etmemize ve farklı senaryolarda nasıl performans göstereceğini tahmin etmemize yardımcı olur. Bu çalışmada (Vollmer et al., 2018), makine öğrenmesi uygulamalarındaki belirsizliği sınıflandırmak için bir çerçeve sunmaktadır. Belirsizliğin önemi ve makine öğrenmesi modellerindeki belirsizliğin çeşitli kaynakları tartışılmaktadır.

- Epistemik belirsizlik: Modelin parametreleri hakkındaki belirsizlik. Bu belirsizlik, modelin eğitim verilerinden elde edilen bilginin sınırlı olmasından kaynaklanabilir.
- Aleatoryk belirsizlik: Verilerdeki belirsizlik. Bu belirsizlik, verilerin gürültülü olmasından veya eksik olmasından kaynaklanabilir.
- Ölçüm belirsizliği: Bir ölçüm probleminde, modelin bir ölçümün doğruluğu hakkındaki belirsizlik.
- Model belirsizliği: Modelin yapısal veya parametre belirsizliğinden kaynaklanan belirsizlik.
- Yanıltıcı belirsizlik: Modelin, gerçek dünyadaki sistemi yanlış temsil etmesinden kaynaklanan belirsizlik.

Çerçeve, çeşitli belirsizlik türlerini tanımlayarak ve bunların nasıl sınıflandırılabileceğini göstererek, makine öğrenmesi modellerinin güvenilirliğini ve performansını iyileştirmek için kullanılabilir.

(Russell and Reale 2021) çalışmada, tüm yöntemler genellikle epistemik ve istatistiksel belirsizliği ayrı ayrı ölçmek için kullanılır.

Epistemik belirsizliği ölçmek için kullanılan yöntemler şunlardır:

- Bayesiyen ağlar: Bayesian ağlar, modelin parametrelerinin olasılık dağılımını tahmin etmek için kullanılır. Bu dağılımdan, modelin tahminlerinin belirsizliği hesaplanabilir.
- Ensemble öğrenme: Ensemble öğrenme, birden fazla modelin çıktılarını birleştirerek daha güvenilir tahminler elde etmek için kullanılır. Ensemble öğrenmenin bir çeşidi olan dropout, modelin bazı parametrelerini rastgele olarak devre dışı bırakarak modelin belirsizliğini artırmaya yardımcı olur.

İstatistiksel belirsizliği ölçmek için kullanılan yöntemler şunlardır:

- Kanıt teorisi: Kanıt teorisi, modelin tahminlerinin güvenilirliğini ölçmek için kullanılır.
- Monte Carlo yöntemleri: Monte Carlo yöntemleri, modelin tahminlerinin belirsizliğini tahmin etmek için kullanılır.
- Bootstrapping: Bootstrapping, modelin tahminlerinin belirsizliğini tahmin etmek için kullanılır.

Bu yöntemler, derin öğrenme modellerinin güvenilirliğini ve performansını iyileştirmek için kullanılabilir.

Derin öğrenme modellerinin belirsizliği, modellerin karar verme süreçlerini daha iyi anlamamıza, hatalarını daha iyi tespit etmemize ve farklı senaryolarda nasıl performans göstereceğini tahmin etmemize yardımcı olur. Çok değişkenli belirsizlik, birden fazla tahminin belirsizliğini tahmin etmek için kullanılır. Çok değişkenli belirsizliği ölçmek için çeşitli yöntemler kullanılabilir. Bu yöntemler, derin öğrenme modellerinin güvenilirliğini ve performansını iyileştirmek için kullanılabilir (Russell and Reale 2021)

Belirsizlik, bir modelin tahminlerinin ne kadar doğru olabileceğini ifade eder. Belirsizliği ölçmek, modellerin karar verme süreçlerini daha iyi anlamamıza, hatalarını daha iyi tespit etmemize ve farklı senaryolarda nasıl performans göstereceğini tahmin etmemize yardımcı olur (Kendall 2018). Çalışmada, geometrinin derin öğrenme modellerinde belirsizliği ele almak için nasıl kullanılabileceği tartışılmaktadır. Geometri, nesnelerin ve ilişkilerinin yapısını ve özelliklerini tanımlamak için kullanılan bir matematik dalıdır. Bu bağlamda, geometri, derin öğrenme modellerinin belirsizliğini tahmin etmek için kullanılabilir.

Çalışmada, geometrinin derin öğrenme modellerinde belirsizliği ele almak için kullanılabilen iki ana yol tartışılmaktadır:

- Geometrik bilgi, modelin parametrelerini eğitmek için kullanılabilir. Örneğin, bir görüntüdeki nesnelerin geometrik özelliklerini hesaba katarak, modelin bu nesneleri daha doğru bir şekilde tanıması sağlanabilir.

- Geometrik bilgi, modelin çıktılarını yorumlamak için kullanılabilir. Örneğin, bir görüntüdeki nesnelerin konumunu tahmin eden bir modelin, geometrik bilgi kullanarak bu tahminlerin doğruluğunu artırması sağlanabilir.

Bir başka yöntem olan kanıtsal derin öğrenme, belirsizliği modellemek için Bayes Teoremi'ni kullanan bir yaklaşımdır. Bu yaklaşım, modelin parametrelerinin olasılık dağılımını tahmin eder. Bu dağılım, modelin belirsizliğini ölçmek için kullanılabilir [

(Ulmer et al. (2021). Bu çalışmada, kanıtsal derin öğrenme yöntemlerinin çeşitli türleri tartışılmaktadır:

- Bayesian ağlar: Bayesian ağlar, parametrelerinin olasılık dağılımını modellemek için Bayes Teoremi'ni kullanan derin öğrenme modelleridir.
- Ensemble öğrenme: Ensemble öğrenme, birden fazla modelin çıktılarını birleştirerek daha güvenilir tahminler elde etmek için kullanılan bir yöntemdir. Epistemik belirsizliği ölçmek için ensemble öğrenme kullanılabilir.
- Dropout: Dropout, modelin bazı parametrelerini rastgele olarak devre dışı bırakarak modelin belirsizliğini artırmaya yardımcı olan bir tekniktir.
- Monte Carlo yöntemleri: Monte Carlo yöntemleri, bir modelin tahminlerinin belirsizliğini tahmin etmek için kullanılan bir dizi tekniktir.

Kanıtsal derin öğrenme yöntemleri, çeşitli belirsizlik modelleme yöntemleriyle karşılaştırılmıştır. Bu karşılaştırmalar, kanıtsal derin öğrenme yöntemlerinin, diğer yöntemlere göre daha doğru ve etkili olduğunu göstermiştir.

Kanıtsal derin öğrenme yöntemlerinin avantajları şunlardır:

- Daha doğru ve etkilidir.
- Farklı belirsizlik türlerini ölçebilir.
- Daha esneklerdir.

Kanıtsal derin öğrenme yöntemlerinin dezavantajları şunlardır:

- Daha karmaşıktır.
- Daha fazla hesaplama kaynağı gerektirir.

Kanıtsal derin öğrenme yöntemleri, derin öğrenme modellerinin belirsizliğini ölçmek için oldukça etkili bir yöntemdir. Bu yöntem, derin öğrenme modellerinin güvenilirliğini ve performansını iyileştirmek için kullanılabilir (Ulmer et al. 2021) Bilgisayar görüşünü temel alarak yapılmış bir başka çalışmada derin öğrenmenin önemi ve Bayesiyen derin öğrenmenin avantajları tartışılmaktadır (Kendall and Gal, 2017) Bu belirsizlikler, şunlardır:

- Epistemik belirsizlik: Modelin parametreleri hakkındaki belirsizlik. Bu belirsizlik, modelin eğitim verilerinden elde edilen bilginin sınırlı olmasından kaynaklanabilir.
- Aleatorik belirsizlik: Verilerdeki belirsizlik. Bu belirsizlik, verilerin gürültülü olmasından veya eksik olmasından kaynaklanabilir.
- Sınıflandırma belirsizliği: Bir sınıflandırma probleminde, modelin bir sınıfa ait olma olasılığı hakkındaki belirsizlik.
- Ölçüm belirsizliği: Bir ölçüm probleminde, modelin bir ölçümün doğruluğu hakkındaki belirsizlik.
- İzleme belirsizliği: Bir izleme probleminde, modelin bir nesnenin konumu veya hızı hakkındaki belirsizlik.
- Bilgisayar görüşü için derin öğrenmenin önemi.
- Bayesiyen derin öğrenmenin avantajları.
- Bilgisayar görüşü için Bayesiyen derin öğrenmede gerekli olan belirsizlikler.
- Belirsizliklerin modellerin güvenilirliğini ve performansını iyileştirmek için nasıl kullanılabileceği (Kendall, A. and Gal, Y. 2017).

Belirsizliklerin kalibrasyonunun nasıl gerçekleştirilebileceği (Welling, Snoek and O'Hagan, 2019), aşağıdaki gibi çeşitli teknikler kullanılarak gerçekleştirilebilir:

- 1) Bağımlılık dağılımını tahmin etme: Model, parametrelerinin olasılık dağılımını tahmin eden bir Bayesiyen model olarak eğitilebilir.
- 2) Ensemble öğrenme: Birden fazla modelin çıktılarını birleştirerek, daha güvenilir tahminler elde edilebilir.

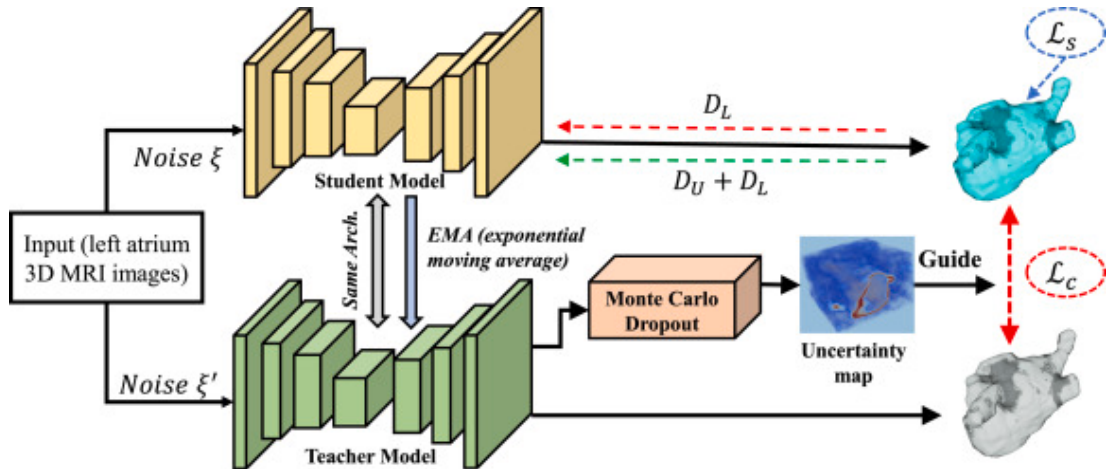
- 3) Dropout: Dropout, modelin bazı parametrelerini rastgele olarak devre dışı bırakarak aşırı uydurmayı azaltan bir yöntemdir. Aynı zamanda belirsizlikleri tahmin etmek için kullanılabilir. Dropout, test sırasında modeli birden çok kez çalıştırarak ve tahminlerin ortalamasını alarak belirsizlik tahminlerini hesaplayabilir.
- 4) Veri Denetimi ve Temizleme: Veri setindeki gürültü ve hataları temizlemek, modelin daha güvenilir tahminler yapmasına yardımcı olabilir. Veri denetimi, modelin belirsizliklerini azaltabilir.
- 5) Kaynak Verilerin İncelenmesi: Modelin tahminlerini incelemek ve yanlış tahminleri belirlemek, belirsizlikleri azaltmaya yardımcı olabilir. Bu sayede model, yanlış anlamış olabileceği verileri düzeltmeyi öğrenebilir.
- 6) Eğitim Verisi Artırma: Modelin eğitildiği veri kümesini artırarak veya veri artırma teknikleri kullanarak belirsizliklerin azaltılması mümkündür. Daha fazla çeşitlilik, modelin daha iyi tahminler yapmasına yardımcı olabilir.
- 7) Özel Belirsizlik Modelleri: Bazı durumlarda, belirsizliklerin doğrudan modellenmesi gerekebilir. Özel belirsizlik modelleri, belirsizlikleri tahmin etmek ve bu tahminleri kullanarak tahminlerin daha iyi kalibre edilmesini sağlar.
- 8) Post-Processing (Sonradan İşleme): Modelin tahminlerini sonradan işleyerek kalibrasyon sağlanabilir. Örneğin, tahminlerin sigmoid fonksiyonu gibi bir düzenleyiciye tabi tutulması, tahminlerin belirsizliklerini azaltabilir.
- 9) Doğruluk Puanı Ayarlama (Calibration Confidence Scores): Modelin tahminlerine eşlik eden bir doğruluk puanı veya güven düzeyi belirlemek, belirsizlikleri kontrol etmek için kullanışlı bir yaklaşımdır. Bu puanlar, tahminlerin ne kadar güvende olduğunu daha açıkça ifade edebilir (Welling et al., 2019)

(Liu et al., 2023) Çalışmada, derin öğrenme tabanlı tanımlama ve belirsizlik analizi yöntemi ayrıntılı olarak açıklanmaktadır. Yöntem, aşağıdaki gibi üç ana adımdan oluşur:

- Veri ön işleme: Veri ön işleme, veri setini temizlemek ve normalleştirmek için kullanılır.
- Model eğitimi: Bir derin öğrenme modeli, eğitim verilerine göre eğitilir.
- Belirsizlik analizi: Modelin belirsizliği, monte carlo emilimi kullanılarak analiz edilir.

Tek model yaklaşımlarının, derin öğrenme modellerinin belirsizliğini ölçmek için etkili olduğu gösterilmektedir (Hernández-Lobato et al. 2016). Yöntemler, çeşitli görevler için test edilmiştir ve iyi sonuçlar elde edilmiştir. Tek model yaklaşımı ayrıntılı olarak aşağıdaki gibidir:

- Simultane Quantile Regression (SQR): SQR, bir modelin tüm koşullu kümülatif dağılımlarını (CCDF) tahmin etmek için kullanılan bir tekniktir. CCDF, modelin belirsizliğini ölçmek için kullanılabilir.
- Monte Carlo Dropout: Monte Carlo Dropout, modelin bazı parametrelerini rastgele olarak devre dışı bırakarak modelin belirsizliğini artırmaya yardımcı olan bir tekniktir.
- Ensemble Learning (EL): Birden fazla modelin çıktılarını birleştirerek daha güvenilir tahminler elde etmek için kullanılan bir tekniktir. Bu teknik, epistemic belirsizliği ölçmek için kullanılabilir.



Şekil 1. Ensemble öğrenme segmentasyonuna uygulanmasını gösteren genel bir görünüm

Kaynak: (Aguilar, 2022)

Bu çalışmalar ışığında bu tezde derin öğrenme konusu ve bu konuya bağlantılı olarak fikirler derinlemesine ele alınacaktır. Hedef derin öğrenme

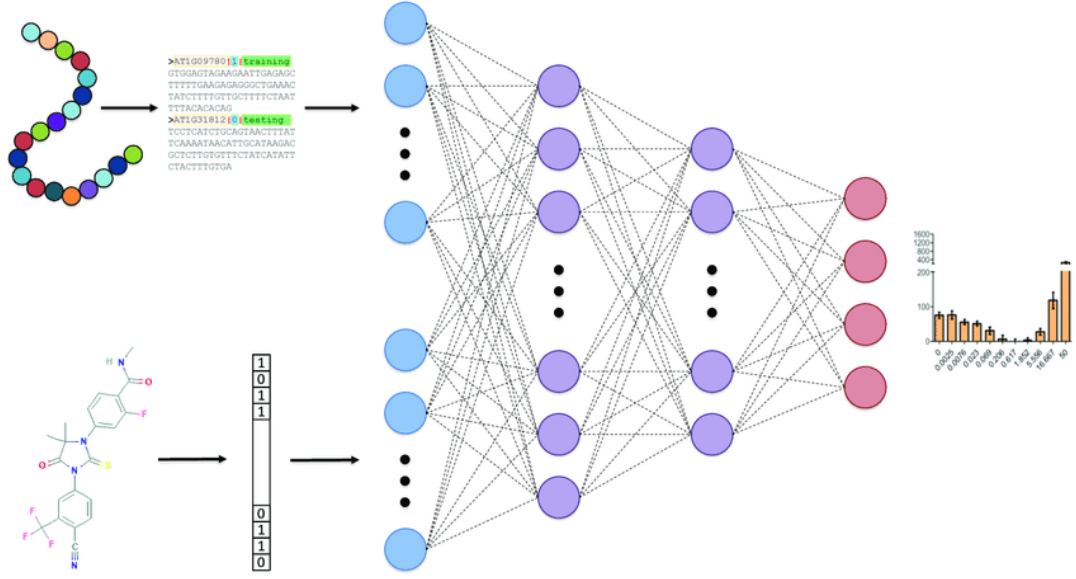
algoritmasıyla belirsizlik analizi konusuna katkıda bulunup bu konu hakkında iyileştirmeler yapmaktır. Tezde derin öğrenme ve belirsizlik ölçümü alanında yapılan çalışmalara, kullanılan metotları derinlemesine yer verilecektir. Bu konu hakkında ne yapılabilir, nasıl yapılabilir, neler yapılmış, sorulması gereken en önemli sorulardır. Yapılan çalışmalar ve tartışmalar bu konu hakkında önemli bir kaynaktır. Araştırma ile alakalı sorulması gereken sorularla beraber hipotez de çok önemli bir husustur. Tez'de toplanan verilerle beraber seçilen algoritmaların testi ve kullanımını sunar. Elde edilen bulgular mevcut literatür ile karşılaştırıldıktan sonra tezin önemi daha da gün yüzüne çıkar.

III. DERİN ÖĞRENME (DL) TEKNİKLERİ

A. Derin sinir ağıları (DNN)

Derin Sinir Ağları (DNN), yapay sinir ağlarının özel bir türüdür ve derin öğrenme alanında kullanılır. Bu ağlar, çok sayıda katman içeren, genellikle çok sayıda sinir hücresi veya nöron içeren bir yapay sinir ağı mimarisi kullanır. DNN'ler, büyük ve karmaşık veri setlerinden öğrenme yeteneği ile bilinir ve özellikle görsel tanıma, doğal dil işleme, konuşma tanıma ve diğer karmaşık görevler için kullanılırlar (A.Jain et al., 2022).

DNN'lerin en temel özelliklerinin başında gelen, adından da anlaşılabilirliği gibi Derinliğidir. Çok sayıda katmana sahiptir. Bu katmanlar girdileri işler ve zor desenleri öğrenmek için birbiriyle iletişim kurar. Her katman birbirleriyle iletişime girer ve bir önceki katmanın sonucundan gelen çıktıları alır. Yeni özellikleri öğrenmek ve geliştirmek için kendi katmanının ağırlıklarıyla çarpırlar. DNN'ler genellikle geri yayılım adı verilen, kendilerine bir eğitim süreci başlatır. Bu süreçte modelin tahminleri ve gerçek sonuçları arasındaki hata hesaplanır ve bu hata kendilerini güncellemek için kullanılırlar. DNN'ler büyük veri setlerinde eğitildiklerinde karmaşık desenleri yakalayabilirler (A.Jain et al., 2022). Bu, genelleme yeteneklerine sonuçlanır. Bu sayede DNN'ler çeşitli uygulama alanlarında başarı sağlayabilir. DNN'ler, görüntü sınıflandırma, nesne tanıma, dil çevirisi, konuşma tanıma, duygu analizi, otonom sürüş ve daha birçok alan için kullanılır. Özellikle büyük veri setleri ve yüksek hesaplama kapasitesi gerektiren uygulamalarda DNN'lerin başarısı önemlidir.



Şekil 2. Overview of deep neural network (DNN) model

Kaynak: (A.Jain et al., 2022)

B. Bayes Teoremi

Bayes teoremi, istatistik ve makine öğrenimi alanında yaygın olarak kullanılan bir teoremdir. Bu teorem, bir olayın olasılığını, o olayın sonuçlarına dair bazı bilgiler ışığında hesaplamamızı sağlar (J Padarian, B Minasny, AB McBratney 2022). Bayes teoreminin formülü (1) şu şekildedir.

$$P(A|B) = P(B|A) * P(A) / P(B) \quad (1)$$

- $P(A|B)$: A olayının B olayının gerçekleşmesi koşuluyla olasılığı
- $P(B|A)$: B olayının A olayının gerçekleşmesi koşuluyla olasılığı
- $P(A)$: A olayının olasılığı
- $P(B)$: B olayının olasılığı

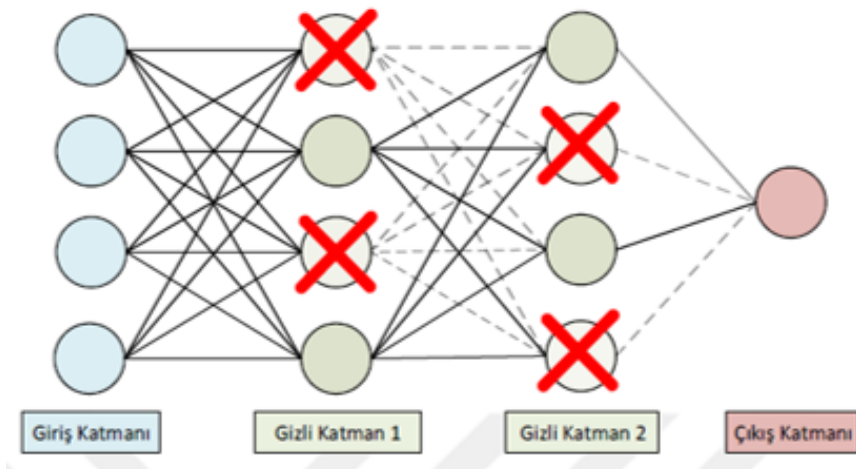
Bayes Teoremi, olay B'den elde edilen gözlemlere dayanarak olay A hakkındaki inançlarımızı nasıl güncelleyeceğimizi açıklar. Bu teorem özellikle nedenlerden sonuçlara çıkarım yapmak, tahminlerde bulunmak veya belirsiz veya eksik bilgi varken inançlarımızı güncellemek istediğimiz durumlarda güçlü bir şekilde kullanılır.

Makine öğrenimi ve yapay zeka bağlamında, Bayes Teoremi, Bayesian istatistik, Bayesian ağlar ve olasılıksal modeller gibi konularda yaygın olarak kullanılır. Bu teorem, önceden sahip olduğumuz bilgileri ve yeni kanıtları birleştirerek daha bilinçli kararlar ve tahminler yapmak için çeşitli algoritmalar ve yöntemlerin temelini oluşturur (L Wu, W Ji, 2019).

C. Dropout

Derin öğrenmede aşırı uymayı (overfitting) önlemek ve modelin genelleme yeteneğini artırmak için yaygın olarak kullanılan bir düzenleme tekniğidir. Aşırı uyma, bir modelin eğitim verileri üzerinde iyi performans göstermesine rağmen yeni, görülmemiş verilere genelleme yapamaması durumudur. Dropout, bu sorunu her eğitim iterasyonunda belirli bir orandaki nöronları rastgele devre dışı bırakarak çözer. Bu, bireysel nöronların belirli özelliklere aşırı bağımlı hale gelmesini engeller ve ağı daha sağlam hale getirerek aşırı uyma riskini azaltır (Nitish Srivastava, 2014).

Dropout değerinin 0,5 olarak ayarlandığı aşağıdaki şekildeki gibi basit bir derin sinir ağında, her bir gizli katmandaki nöronların yaklaşık yarısı bırakılacak yani ağ içinde kullanılmayacaktır. Burada, bir devirde (epoch 1) bir mini-batch için birinci gizli katmanda rastgele seçilen 1. ve 3. düğüm, ikinci gizli katmanda ise 2. ve 4. düğüm kapatılmıştır. Dolayısıyla şekil 4'te gösterdiği gibi tüm sinir ağının ağırlıkları da yaklaşık olarak yarıya inmiştir.



Şekil 3. Dropout ile Aşırı Öğrenme/Varyans Kontrolü

1. Düzenleştirme ve Aşırı Öğrenme Kontrolü

Derin sinir ağlarında aşırı öğrenmeyi kontrol etmek için diğer bir yol olan düzensizleştirme tekniği, model büyüdükçe modeldeki bazı ağırlıkları cezalandırma yaklaşımıdır. Sinir ağların düzenlemek için L1 ve L2 olmak üzere iki çeşit düzenleştirme yöntemi vardır. Fakat L düzenleştirme tekniği, hesaplama verimliliği açısından daha avantajlı olduğu için derin sinir ağlarında daha sık kullanılmaktadır.


Düzenleştirme yaklaşımı için hata fonksiyonunun düzenlenmesi gerekmektedir. Bunun için uygulanan düzenleştirme miktarının (2)'de değişimini arttırabilen ya da azaltabilen λ parametresi kullanılmakta olup ağırlık katsayılarının ne kadar cezalandırılacağını belirlemek için kullanılır. Aşağıdaki formülde L1 ve L2 düzenleştirme, sırayla verilmiştir:

$$E = -\frac{1}{m} \sum_{i=1}^m (y_i \times \ln(\hat{y}_i)) + ((1 - y_i) \times \ln(1 - \hat{y}_i)) + \lambda(|\mathbf{w}_1| + \dots + |\mathbf{w}_2|) \dots\dots\dots (2)$$

$$E = -\frac{1}{m} \sum_{i=1}^m (y_i \times \ln(\hat{y}_i)) + ((1 - y_i) \times \ln(1 - \hat{y}_i)) + \lambda(\mathbf{w}_1^2 + \dots + \mathbf{w}_2^2)$$

2. Monte Carlo Dropout

Özellikle belirsizlik tahmini ve Bayesian derin öğrenme bağlamında kullanılan geleneksel dropout tekniğinin bir uzantısıdır. Geleneksel dropout, şekil 5'te aşırı uyumunu önlemek için eğitim sırasında nöronları rastgele devre dışı bırakır, ancak çıkarım (test) sırasında genellikle kapatılır. Monte Carlo Dropout ise dropout'u çıkarım aşamasına da genişleterek model tahminleri ile ilişkilendirilen belirsizlikleri tahmin etmemizi sağlar (HK Lam, F Karray, 2021).



Şekil 4. Dropout ensemblleri, Monte-Carlo Dropout ve Derin Ensembller yaklaşımları

Kaynak: (URL1)

Bu yöntemde randomizasyon prosedürünü dropouttan bir adım daha ileriye götürerek her eğitim için ağ düğümlerini yalnızca rastgele kapatmakla kalmayıp aynı zamanda bu tür bir rastgeleliği tahmin prosedüründe denklem (3) de ki gibi dahil ediyor. Bu sayede YSA ya girdi değeri olarak her geçirildiğinde bazı karmaşık olasılık dağılımına sahip rastgele bir tahminle sonuçlanır.

$$\mathcal{L}_{\text{dropout}} := \frac{1}{N} \sum_{i=1}^N E(y_i, \hat{y}_i) + \lambda \sum_{l=1}^L (\|W_l\|_2^2 + \|b_l\|_2^2) \quad (3)$$

Monte Carlo Dropout, piksel düzeyinde ve yapı düzeyinde hem epistemik hem de aleatorik belirsizlikleri analiz etmek için CNN temelli derin tıbbi görüntü bölütleme problemlerinde kullanıldı. Epistemik belirsizlik, eksik veya yetersiz bilginin neden olduğu belirsizliği temsil ederken, aleatorik belirsizlik rastgele olaylardan veya ölçüm hatalarından kaynaklanan belirsizliği ifade eder.

Monte Carlo Dropout, tıbbi görüntü bölütleme problemlerinde modelin çıktılarını değerlendirirken belirsizliklerin nasıl tahmin edilebileceğini göstermede etkili bir araçtır. Bu yaklaşım, ağın birden çok ileri geçişi sırasında dropout'un uygulanmasını içerir. Bu sayede, her bir piksel veya yapı için elde edilen tahminlerdeki varyasyonlar belirsizliğin bir ölçüsünü sağlar.

Piksel düzeyinde, her pikselin sınıflandırılması veya etiketlenmesi sırasında Monte Carlo Dropout kullanılarak elde edilen farklı tahminler, her piksel için

belirsizlik haritaları oluşturmak için kullanılabilir. Bu belirsizlik haritaları, modelin her piksel için ne kadar emin olduğunu ve belirsiz olduğunu gösterir.

Yapı düzeyinde, örneğin organ veya lezyon gibi büyük yapıların bölütlenmesi sırasında Monte Carlo Dropout, yapının farklı bölgelerindeki belirsizliği değerlendirmek için kullanılabilir. Bu, özellikle tıbbi görüntüleme uygulamalarında doğru ve güvenilir sonuçlar elde etmek için önemlidir (M Abdar, S Salari, 2020).

D. Markov Chain Monte Carlo (MCMC)

Markov Chain Monte Carlo (MCMC), belirli bir olasılık dağılımından örneklem almak için kullanılan bir istatistiksel yöntemdir. Özellikle, bu dağılımın karmaşık ve doğrudan örnekleme yapmanın zor olduğu durumlarda MCMC oldukça yararlıdır. Bu teknik, özellikle Bayes istatistikçiliği ve kompleks sistemlerin simülasyonunda yaygın olarak kullanılır (L Wu, W Ji, SM AbouRizk 2020).

MCMC, bir Markov zinciri kullanarak araştırılacak dağılımdan rastgele örnekler üretir. Bu zincir, belirli bir durumdan başka bir duruma geçme olasılığını tanımlar. Uzun vadede, bu zincir tarafından üretilen örneklerin dağılımı, hedef olasılık dağılımına yaklaşır.

1. Markov Zincirleri ve MCMC Algoritmaları

Bir Markov zinciri, belirli bir olasılığa sahip olan sonraki durumuna sadece şu anki durumunu dikkate alarak geçen bir stokastik süreçtir. MCMC'nin temel fikri, önerilen bir ölçüm dağılımından örnekler çekmek için bu zincirleri kullanmaktır. MCMC'nin temel adımları şunlardır:

1. Rastgele bir başlangıç noktası seçilir.
2. Öneri dağılımından yeni bir nokta seçilir.
3. Yeni noktanın kabul edilip edilmeyeceğine karar verilir.
4. Adımlar, belirli bir durdurma kriteri karşılanana kadar tekrar edilir.

MCMC'nin Önemli Algoritmaları:

1. Metropolis-Hastings Algoritması: Bu, en eski ve en yaygın kullanılan MCMC yöntemlerinden biridir. Yeni bir örnek önerir ve bu öneriyi kabul edip etmeme kararı, hedef dağılıma olan yakınlığına dayanır.
 2. Gibbs Örnekleme: Bu, çok boyutlu dağılımlar için kullanılır. Her bir adımda, bir değişkenin diğer tüm değişkenler sabit tutularak koşullu dağılımından bir örnek alınır.
 3. Hamiltonian Monte Carlo (veya HMC): Bu, fizikten esinlenerek momentum terimleri kullanarak daha etkili örnekleme yapmaya çalışır. Özellikle yüksek boyutlu problemler için uygundur.
- Bayesyen İstatistik: MCMC, bir modelin parametrelerinin posterior dağılımını tahmin etmek için kullanılır.
 - Fizik: Denge dışı sistemlerin simülasyonlarında kullanılır.
 - Ekonomi, Sosyal Bilimler ve Diğer Alanlar: Çeşitli karmaşık sistemlerin simülasyonunda kullanılır.

Metropolis-Hastings algoritması, MCMC'nin en yaygın formudur. Önerilen bir yeni nokta, geçerli olan (mevcut) noktaya göre bir olasılıkla kabul edilir. Bu olasılık (4) formüldeki, hem önerilen yeni noktanın hem de şu anki noktanın olasılıklarına bağlıdır. Önerilen değişikliklerin kabul olasılığı şu formülle ifade edilir:

$$\alpha = \min \left(1, \frac{P(\text{yeni nokta}) \times Q(\text{eski nokta} \mid \text{yeni nokta})}{P(\text{eski nokta}) \times Q(\text{yeni nokta} \mid \text{eski nokta})} \right) \quad (4)$$

Burada:

- P hedef dağılımı temsil eder.
- Q öneri dağılımıdır.

Metropolis-Hastings (MH) algoritması, Markov Chain Monte Carlo (MCMC) yöntemlerinin en yaygın olarak kullanılanlarından biridir. Hedefi, belirli bir hedef dağılımdan örnekler çekmektir, özellikle de doğrudan örnekleme zor olan dağılımlardan. MH algoritmasının bazı önemli noktaları şunlardır:

- Öneri Dağılımı: Öneri dağılımı, yeni bir adım önermek için kullanılır. En sık kullanılan öneri dağılımlarından biri, normal dağılımıdır. Öneri dağılımının seçimi, algoritmanın verimliliğini büyük ölçüde etkileyebilir.
- Kabul Oranı: Kabul oranı, önerilen yeni adımın ne sıklıkla kabul edildiğini gösterir. Çok düşük veya çok yüksek kabul oranları, öneri dağılımının uygun olmadığını gösterebilir.
- Burn-in: Başlangıçtaki örneklerin (genellikle birkaç bin) atıldığı süreye "burn-in" denir, çünkü bu örnekler genellikle hedef dağılımı temsil etmez.
- Oto-korelasyon: Ardışık örnekler arasında yüksek korelasyon olabilir. Bu, örneklerin bağımsız olmadığı anlamına gelir. Oto-korelasyonun etkilerini azaltmanın bir yolu, her n adımda bir örnek alarak "inceleme" yapmaktır.

2. Gibbs özellikler

Gibbs Örnekleme, Markov Chain Monte Carlo (MCMC) yöntemlerinden biri olup çok boyutlu dağılımlardan örnekler çekmek için özellikle uygun bir tekniktir. Temel fikri, çok boyutlu bir dağılımdan doğrudan örnekleme yerine, her adımda sadece bir boyut boyunca örneklem yapmaktır. Bu, özellikle boyutların birbiriyle koşullu olarak örnekleme yapılması kolay olduğunda uygundur. Gibbs Örneklemesinin bazı önemli özellikleri:

- Kolaylık: Gibbs Örnekleme, koşullu dağılımların analitik olarak bilindiği ve bu dağılımlardan kolayca örnek alınabildiği durumlarda çok uygundur.
- Oto-korelasyon: Tıpkı diğer MCMC yöntemlerinde olduğu gibi, Gibbs Örneklemesinde de ardışık örnekler arasında yüksek oto-korelasyon olabilir. Bunu azaltmak için "inceleme" (örneğin, her 10 adımda bir örnek alma) gibi yöntemler kullanılabilir.
- Karışım ve Yakınsama: MCMC zincirlerinin hedef dağılıma iyi bir şekilde "karıştığından" ve "yakınsadığından" emin olmak için çeşitli diyagnostik yöntemler bulunmaktadır.
- Burn-in: Tıpkı diğer MCMC yöntemlerinde olduğu gibi, başlangıçtaki bazı örneklerin atılması gerekebilir. Bu süreye "burn-in" denir.

Sonuç olarak, Gibbs Örneklemesi, boyutların birbiriyle koşullu olarak örnekleme kolay olduğunda çok boyutlu dağılımlardan etkili bir şekilde örneklem yapmak için kullanılır. Ancak, her MCMC yönteminde olduğu gibi, örnekleme etkinliği ve doğruluğu konusunda dikkatli olunmalıdır.

3. Hamiltonian Monte Carlo (HMC)

Hamiltonian Monte Carlo (HMC) ya da bazen Hybrid Monte Carlo olarak da adlandırılır, Markov Chain Monte Carlo (MCMC) yöntemlerinden biridir. HMC, yüksek boyutlu örneklem yapma zorluklarını aşmak için klasik fizikten ilham alır. Özellikle Hamilton mekaniğine dayanarak, sistemdeki parçacıkların hareketine benzeyen bir yol ile örneklem yapılır.

HMC'nin temel fikri, hedef dağılımın yoğun bölgeleri arasında daha verimli hareket etmek için "momentum" kavramını kullanmaktır. Bu, HMC'nin birçok diğer MCMC yöntemine göre daha az oto-korelasyonlu örnekler üretmesine olanak tanır. HMC'nin Temel Adımları:

- Rastgele bir başlangıç noktası ve momentum seçimi: Her iterasyonda, mevcut pozisyon q ve rastgele bir başlangıç momentumu p seçilir.
- Hamiltonian Dinamiğini Simüle Etme: Hamiltonian denklemleri kullanılarak belirli bir süre boyunca parçacığın hareketi simüle edilir. Bu, enerjinin korunumunu garantileyen bir hareketle sonuçlanır.
- Momentumun Yansıtılması: Simülasyonun sonunda, momentumun yönü rastgele yansıtılır. Bu adım, HMC'nin detaylı denge koşulunu sağlamasına yardımcı olur.
- Kabul/Reddetme Adımı: Metropolis kriterine dayalı olarak, simülasyonun sonunda ulaşılan yeni pozisyon kabul edilir veya reddedilir.

Adımlar belirli bir durdurma kriteri karşılanana kadar tekrar edilir. HMC'nin Avantajları ve Dezavantajları:

- Yüksek Boyutlu Örneklem: HMC, yüksek boyutlu dağılımlarda diğer MCMC yöntemlerine göre daha verimlidir.

- Düşük Oto-korelasyon: HMC, momentumu kullanarak hedef dağılımın uzak bölgelerine "atlamalar" yapabilir, bu da ardışık örnekler arasında daha düşük oto-korelasyon anlamına gelir.
- Tüneme: Örnekleme verimliliği, adım boyutu ve simülasyon süresi gibi HMC'nin ayar parametrelerine duyarlıdır. Bu parametrelerin yanlış seçilmesi, örneklem verimliliğini önemli ölçüde azaltabilir.
- Karmaşıklık: HMC, diğer bazı MCMC yöntemlerine göre daha karmaşıktır ve hedef dağılımın gradyanını (türevini) gerektirir.

IV. KAYIP FONKSİYONLAR

A. 3.2 Loss Fonksiyonu (Kayıp Foksiyonlar)

Kayıp fonksiyonlar, makine öğrenimi modellerinin performansını değerlendirmek için kullanılan ölçümlerdir. Kayıp fonksiyonu, modelin tahminleri ile gerçek değerler arasındaki farkı ölçer. Kayıp fonksiyonunun değeri ne kadar düşükse, modelin performansı o kadar iyidir.

Kayıp fonksiyonları, farklı problemler için farklı şekillerde kullanılabilir. Örneğin, sınıflandırma problemlerinde, kayıp fonksiyonu, modelin tahminlerinin doğru veya yanlış olma olasılığını ölçer. Regresyon problemlerinde ise, kayıp fonksiyonu, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu ölçer.

Kayıp fonksiyonları, makine öğrenimi modellerinin eğitiminde de kullanılır. Kayıp fonksiyonunun değeri, modelin ağırlıklarının ve eğilimlerini güncellemek için kullanılır. Bu sayede, model, kayıp fonksiyonunun değerini en aza indirecek şekilde eğitilir (Das, Jiang and Rao, 2007).

Bir loss fonksiyon modeli oluştururken, aşağıdaki adımlar takip edilir:

1. Görev Belirleme: Hangi görevi çözmeye çalıştığınızı tanımlayın. Sınıflandırma mı yoksa regresyon mu gibi.
2. Veriye Göre Seçim: Veri yapısına ve problem türüne bağlı olarak en uygun loss fonksiyonunu seçin.
3. Özel Durumlar: Eğer verinizde sınıf dengesizliği varsa veya aykırı değerlerle başa çıkmak gerekiyorsa, özel loss fonksiyonları (örneğin Focal Loss) kullanmayı değerlendirin.
4. Modelin İşlevi: Loss fonksiyonu, modelin eğitim sırasında performansını ölçer ve bu nedenle modelin optimize edilmesinde kilit bir rol oynar.
5. Optimizasyon Algoritması: Loss fonksiyonunun minimize edilmesi, genellikle gradyan tabanlı optimizasyon algoritmalarıyla yapılır.

6. Eğitim: Loss fonksiyonunun optimize edilmesi, eğitim verisi üzerinde modelin ağırlıklarının ve parametrelerinin güncellenmesini içerir.
7. Değerlendirme: Eğitildikten sonra model, ayrı bir değerlendirme veri seti üzerinde test edilir. Loss fonksiyonu sonuçları değerlendirmenin bir parçasıdır.

B. Ortalama Karesel Hata (Mean Squared Error- MSE)

Ortalama Karesel Hata (Mean Squared Error- MSE), regresyon alanında kullanılan bir kayıp fonksiyonudur. Bu özel fonksiyon, bir modelin tahminlerini gerçek değerlerle ne kadar iyi hizaladığını ölçmede önemli bir rol oynar. MSE, tahminlerin gerçek değerlerden sapmalarını yakalar, bu sapmaların karelerini alarak ve ardından bu karelerin ortalamasını hesaplayarak değerlendirir.

MSE, denklem (5) deki gibi modelin kesin tahminler yapmasını özendirir. Yanı sıra, büyük sapmaların da öne çıkmasını sağlar. Özellikle hatalı tahminlerin ağırlığını artırmak için kullanılır. Ancak, bazen verilerde yer alan anormal değerler (outliers), MSE üzerinde büyük bir etki yaratabilir. Bu nedenle, veri analizi sırasında bu olasılığı göz önünde bulundurmak büyük önem taşır (Das, Jiang and Rao, 2007).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (5)$$

MSE = mean squared error
 n = number of data points
 Y_i = observed values
 \hat{Y}_i = predicted values

C. Ortalama Mutlak Hata (Mean Absolute Error- MAE)

Regresyon problemlerinde kullanılan bir kayıp fonksiyonudur ve model tahminlerinin gerçek değerlere ne kadar yakın veya uzak olduğunu

değerlendirmede yardımcı olur. MAE, tahminler ile gerçek değerler arasındaki mutlak farkların ortalama değerini ölçer.

MAE, hataları mutlak değerlerle ölçerek (6)'da ki gibi her tahminin gerçek değerden ne kadar uzak olduğunu açıkça yansıtır. Bu özelliği, büyük hataların (tahminlerin gerçek değerden ne kadar uzak olduğu) toplam hataya aşırı etki etmesini engeller. Bu sebeple, özellikle aykırı değerlerin olduğu senaryolarda, MSE'ye göre daha tutarlı sonuçlar üretebilir.

MAE, tahminlerin homojen bir şekilde değerlendirilmesine ve hataların etkisinin daha yumuşak bir şekilde dağıtılmasına olanak tanır. Büyük hataların etkisini azaltarak, belirli senaryolarda tercih edilir. Ancak, her kayıp fonksiyonunun avantaj ve dezavantajlarının bulunduğunu akılda tutmak önemlidir (Junqi Qian, 2020).

$$\text{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (6)$$

Hataların MAE yöntemi ile ölçümü

MAE	=	mean absolute error
y_i	=	prediction
x_i	=	true value
n	=	total number of data points

D. Çapraz Entropi (Cross-Entropy)

Çapraz Entropi (CE), derin öğrenme ve makine öğrenimi alanında oldukça sıkça karşımıza çıkan bir kavramdır ve özellikle sınıflandırma problemlerinde kullanılan bir kayıp fonksiyonudur. Bu kayıp fonksiyonu, modelin tahminleri ile gerçek sınıf etiketleri arasındaki farkları ve uyumsuzlukları değerlendirerek modelin performansını ölçmeye yarar.

Çapraz entropi, modelin tahmin ettiği sınıf olasılıklarını gerçek sınıf etiketleri ile kıyaslayarak tahminlerin ne kadar doğru ve uyumlu olduğunu ölçer. Temel olarak, iki farklı olasılık dağılımı arasındaki farkı değerlendirir: birincisi gerçek dağılımı temsil ederken diğeri modelin tahmin ettiği dağılımı belirtir.

Bu değerlendirme, ağırlıkları ve parametreleri optimize ederken modelin hangi yönde geliştirilmesi gerektiğini gösterir. Çapraz entropi değeri düşükse,

tahminlerin gerçek sınıflara yakın olduğu ve modelin iyi performans gösterdiği anlamına gelir (Yendapalli and Reddy, 2020).

Özellikle sınıflandırma problemlerinde, çapraz entropi oldukça yaygın bir şekilde kullanılır. Sınıf sayısına bağlı olarak, "Çok Sınıflı Çapraz Entropi" olarak adlandırılan daha geniş kapsamlı bir versiyonu da mevcuttur.

Çapraz entropinin bir avantajı, tahminlerin gerçek sınıf etiketlerine ne kadar yakın olduğunu hassas bir şekilde değerlendirebilmesidir. Aynı zamanda, gradyan tabanlı optimizasyon algoritmalarıyla model eğitimini daha etkili hale getirmek için kullanılır.


Ancak, çapraz entropi bazı zorluklar da sunabilir. Özellikle, modelin tahminleri ile sınıf etiketleri arasında tam bir uyumsuzluk durumunda çapraz entropi artabilir. Bu, modelin doğru sınıfları tahmin edememesi durumunda sorunlar yaratabilir. Ayrıca, sınıf dengesizliği gibi senaryolarda da dikkatli bir şekilde kullanılmalıdır.

Sonuç olarak, çapraz entropi, Şekil 6'da sınıflandırma problemlerinde model performansını değerlendirmek ve iyileştirmek için güçlü bir araç olarak kullanılır. Doğru sınıf tahminleri yapabilen modeller, düşük çapraz entropi

$$f(s)_i = \frac{e^{s_i}}{\sum_j^c e^{s_j}} CE = - \sum_i^c t_i \log(f(s)_i) \quad (7)$$

Çapraz entropinin matematiksel gösterimi

değerleri ile tanımlanır ve bu da modelin başarılı bir şekilde eğitildiğini gösterir.



Şekil 5. Çapraz Entropinin Matematiksel Halinde Bir Örneği

Kaynak: (URL 4)

E. Focal Loss

Sınıflandırma problemlerinde kullanılan bir kayıp fonksiyonudur. Focal Loss, modelin doğru sınıflandırma yaptığı örneklere daha az önem vererek, modelin daha zor sınıflandırma yaptığı örnekleri daha iyi öğrenmesini sağlar.

Focal Loss, MSE ve Cross Entropy Loss gibi geleneksel kayıp fonksiyonlarının dezavantajlarını gidermek için tasarlanmıştır. MSE ve Cross Entropy Loss, modelin doğru sınıflandırma yaptığı örneklere aynı önemi verir. Bu da, modelin daha zor sınıflandırma yaptığı örnekleri görmezden gelmesine neden olabilir. Focal Loss, modelin daha zor sınıflandırma yaptığı örneklere daha fazla önem vererek, modelin bu örnekleri daha iyi öğrenmesini sağlar. Bu sayede, denklem (8) deki modelin genel performansı iyileşir.

Focal Loss, sınıflandırma problemlerinde yaygın olarak kullanılır. Örneğin, görüntü tanıma, doğal dil işleme ve makine çevirisi gibi problemlerde kullanılabilir (Lin, Goyal, Girshick, He, 2017).

$$Focal\ Loss = - \sum_{i=1}^{i=n} (i - p_i)^{\gamma} \log_b(p_i) \quad (8)$$

Focal Loss matematiksel gösterimi

F. Dice Loss

Görüntü segmentasyonu problemlerinde kullanılan bir kayıp fonksiyonudur. Dice Loss, modelin tahminleri ile gerçek değerlerin kesişimini ölçer.

Dice Loss, MSE ve Cross Entropy Loss gibi geleneksel kayıp fonksiyonlarının dezavantajlarını gidermek için tasarlanmıştır. MSE ve Cross Entropy Loss, modelin tahminleri ile gerçek değerlerin toplam uzaklığını ölçer. Bu da, modelin tahminlerinin gerçek değerlere yakın olduğu durumlarda bile yüksek kayıp değerlerine yol açabilir.

Dice Loss, Denklem (9) modelin tahminleri ile gerçek değerlerin kesişimini ölçerek, bu sorunu çözmeyi amaçlar. Bu sayede, modelin tahminleri ile gerçek değerler arasında daha doğru bir karşılaştırma yapılır. Dice Loss, görüntü

segmentasyonu problemlerinde yaygın olarak kullanılır. Örneğin, tıbbi görüntüleme, nesne tanıma ve doğal dil işleme gibi problemlerde kullanılabilir (Huang, Sun, Ding, Gao and Ge, 2018) (Zhao, Qian, He, Peng, Pan and Yan, 2020).

$$DL = 1 - \frac{1}{2} \sum_{c=1}^2 \frac{2 \sum_{i=1}^N x_{c,i} y_{c,i}}{\sum_{i=1}^N x_{c,i}^2 + \sum_{i=1}^N y_{c,i}} \quad (9)$$

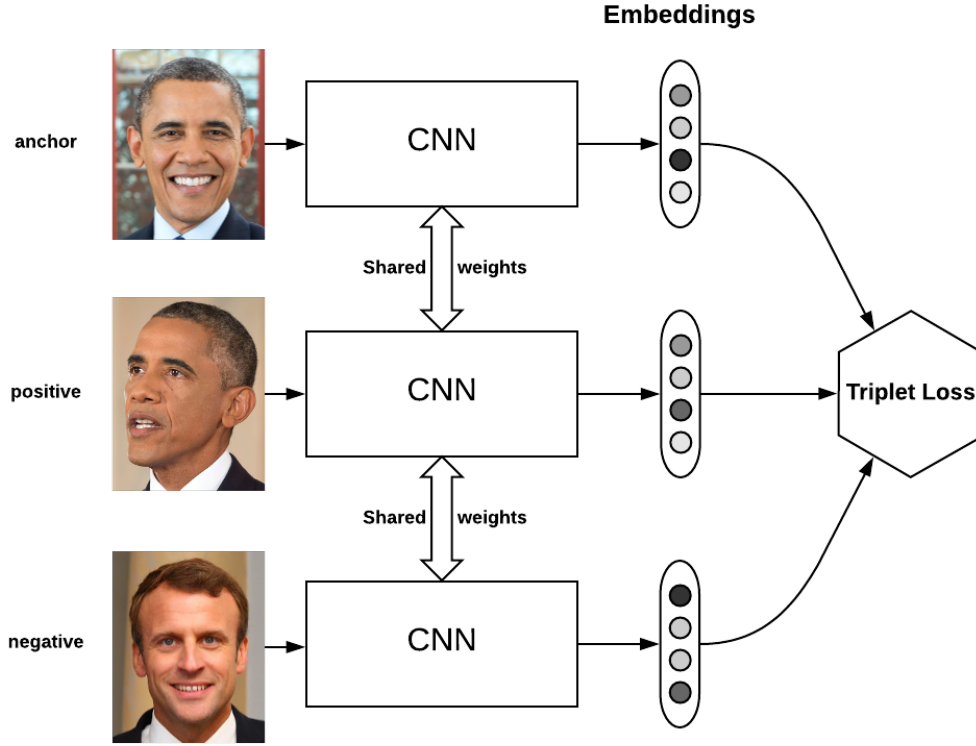
Dice Loss matematiksel gösterimi

G. Triplet Loss

Triplet Loss, benzerlik ve farklılık kavramlarını kullanarak, makine öğrenimi modellerinin benzer ve farklı örnekleri doğru bir şekilde ayırt etmesini sağlayan bir kayıp fonksiyonudur. Triplet Loss, MSE ve Cross Entropy Loss gibi geleneksel kayıp fonksiyonlarının dezavantajlarını gidermek için tasarlanmıştır. MSE ve Cross Entropy Loss, modelin tahminleri ile gerçek değerlerin toplam uzaklığını ölçer. Bu da, modelin benzer ve farklı örnekleri ayırt etmesini zorlaştırabilir (Schroff, Kalenichenko and Philbin, 2015).

Triplet Loss, modelin benzer örnekleri birbirine yakın ve farklı örnekleri birbirinden uzak olacak şekilde eğitilmesini sağlar. Bu sayede, modelin benzer ve farklı örnekleri doğru bir şekilde ayırt etmesi kolaylaşır.

Triplet Loss, Şekil7’de Benzerlik ve Farklılık problemlerinde yaygın olarak kullanılır. Örneğin, yüz tanıma, nesne tanıma ve doğal dil işleme gibi problemlerde kullanılabilir.



Şekil 6. Triplet Loss Fonksiyonunun Benzer ve Farklı Örnekleri

Kaynak: (URL2)

H. Hata Fonksiyonu

Hata fonksiyonu (LF), makine öğrenimi ve derin öğrenme modellerinin eğitilirken performanslarını ölçmek ve optimize etmek için kullanılan bir metrik veya fonksiyondur. Bu fonksiyon, modelin tahminlerinin gerçek değerlerden ne kadar uzak olduğunu nicel olarak değerlendirir. Modelin amacı, bu hata fonksiyonunu minimize ederek daha iyi tahminler yapmak ve daha iyi sonuçlar elde etmektir.

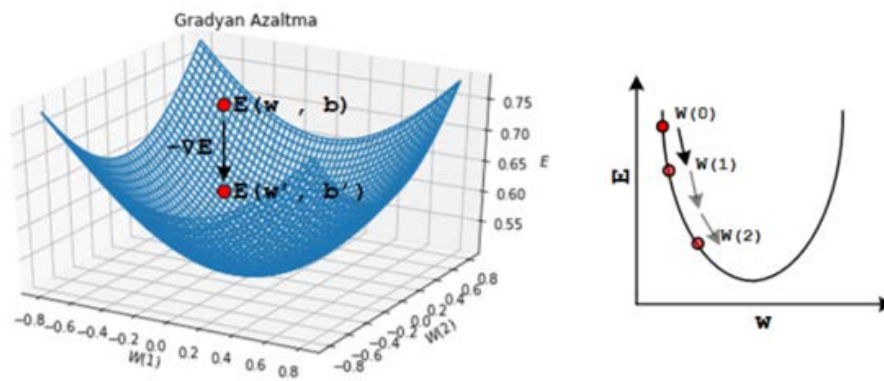
Hata fonksiyonları, problem türüne (sınıflandırma, regresyon, segmentasyon vb.) ve veri yapısına bağlı olarak farklı şekillerde tanımlanabilir. Farklı hata fonksiyonları, farklı performans metriklerini vurgular ve modelin optimizasyonunu farklı şekillerde etkiler. Örneğin, regresyon problemleri için "Ortalama Karesel Hata" (MSE) hata fonksiyonu yaygın olarak kullanılır. Bu fonksiyon, tahminlerin gerçek değerlere göre ne kadar iyi veya kötü performans gösterdiğini ölçer. Sınıflandırma problemleri için "Çapraz Entropi" (Cross-

Entropy) hata fonksiyonu tercih edilebilir. Bu fonksiyon, modelin tahmin ettiği sınıf olasılıklarının gerçek sınıf etiketleri ile uyumunu ölçer.

Hata fonksiyonları, modelin eğitim sürecinde kullanılarak modelin ağırlıklarını ve parametrelerini güncellemek için gradyan tabanlı optimizasyon algoritmalarıyla birleştirilir. Bu süreç, modelin tahminlerini gerçek değerlere daha yakın hale getirirken aynı zamanda overfitting (aşırı uyuma) riskini de azaltmaya çalışır.

Hata fonksiyonları seçilirken, veri yapısı, problem türü ve hedeflenen performans metrikleri göz önünde bulundurulmalıdır. Hangi hata fonksiyonunun kullanılacağı, modelin doğru bir şekilde eğitilmesi ve performansının en iyi şekilde optimize edilmesi için önemlidir. Ayrıca, bazı özel durumlarda (örneğin sınıf dengesizliği, aykırı değerler) özelleştirilmiş hata fonksiyonlarının kullanılması da gerekebilir. Hata fonksiyonları, makine öğrenimi ve derin öğrenme alanında model geliştirme süreçlerinin temel bir parçasıdır. Doğru hata fonksiyonunun seçilmesi, modelin performansını ve genel etkinliğini büyük ölçüde etkileyebilir.

$$E = -y \log(\hat{y}) - (1 - y) \log(1 - \hat{y}) \quad (10)$$



Şekil 7. hata fonksiyonu üzerinde gradyan azaltma güncellemelerinin gösterimi

Kaynak: (URL3)

V.YEREL ÖZELLİK TANIMLAYICILARI

A. Yerel Bit Desen

Yerel bit desen (LBP), temel olarak değişmez özellik tanımlayıcı tekniklerinden biridir. Bir LBP işlemcisi, her merkez piksel için $n \times n$ komşuluk değerlerini eşikleme yaparak ve sonuç olarak ikili bir sayıyı sunarak bir açıklama sağlar. Merkez pikselin değeri yüksek veya eşit komşu pikseller için bir olarak ayarlanır, aksi halde merkez piksel sıfır olarak ayarlanır, aşağıdaki gibidir.

$$LBP_{R,N}(X,Y) = \sum_{i=0}^{N-1} S(n_i - n_c)2^i,$$

$$S(x) = \begin{cases} 1, & x \geq 0, \\ 0, & \text{Otherwise,} \end{cases} \quad (11)$$

X ve Y değişkenleri için LBP gösterimi

Burada n_c merkez pikselin gri seviyesi ve n_i yerel komşuluk pikselleri ifade eder, bunlar bir yarıçap R'ye sahip bir daire içerisindedir. R (yarıçap) azaldıkça, merkez pikseller ile yerel komşu pikseller arasındaki ilişki uzaklaştıkça azalır. Bu durumda, daha fazla doku bilgisi toplanabilir. (11) denkleminde sunulduğu gibi, parametre sayısı diğer özellik tanımlayıcı algoritmalarına göre daha düşüktür, bu da LBP tabanlı özellik tanımlayıcı algoritmalarının avantajlarından biri olarak adlandırılabilir. Merkez piksellerin gri seviyesi ile çevreleyen pikseller arasındaki fark N-bit ikili sayılar olarak tanımlanır. Bu durumda, LBP'nin farklı aydınlatma koşullarında hızlı ve sağlam olduğu kanıtlanabilir (T. Ahonen, 2006) (Yoo, 2017).

B. Yönlü Merkezi Simetrik İkili Model (DCSBP)

Yönlü Merkezi Simetrik İkili Model (DCSBP), bilgisayar bilimleri ve yapay zeka alanlarında son derece önemli bir role sahip olan bir modeldir. Bu model, veri analizi, dil işleme, görüntü tanıma gibi birçok farklı uygulama alanında

kullanılabilen özgün bir yaklaşım sunmaktadır. DCSBP'nin temel avantajlarından biri, yönlü merkezi simetrisini kullanarak verileri daha iyi anlama kapasitesine sahip olmasıdır. Bu özellik, özellikle graf verileri ve ağlar üzerinde çalışırken büyük bir fayda sağlar.

Ayrıca, DCSBP'nin ikili model yaklaşımı, farklı modalitelerden gelen verileri birleştirme yeteneği sunar. Bu, metin ve görüntü verilerini veya ses ve metin verilerini bir araya getirerek daha kapsamlı ve çoklu boyutlu bir analiz yapmayı mümkün kılar. Derin öğrenme tekniklerini kullanarak öğrenme ve tahmin yeteneklerini geliştiren DCSBP, büyük veri kümeleri üzerinde karmaşık desenleri tanıma ve tahmin etme yeteneğini artırır.

DCSBP, kullanıcıların özel ihtiyaçlarına göre özelleştirilebilir ve bu sayede farklı uygulama alanlarına uygun çözümler üretebilir. Ayrıca, performans ve verimlilik açısından da avantajlıdır, bu da gerçek zamanlı uygulamalarda veya büyük veri kümeleri üzerinde çalışırken çok önemli bir faktördür. Yapay zeka ve bilgisayar bilimleri alanındaki hızlı gelişmeleri takip ederek sürekli olarak güncellenebilen bir model olması, geleceğe yönelik çözümler üretme yeteneği sunar.

C. Merkezi Simetrik yerel ikili model (CS-LBP)


Daha önce sunulduğu gibi, her pikseli merkez piksel ile karşılaştırmak, LBP'nin genellikle kullanılan metodolojisidir ve 256 (2^8) farklı ikili desen içeren uzun histogramlar üretir. Bu nedenle, merkezi simetrik yerel ikili desenler (CS-LBP), daha az hesaplama maliyetiyle bir önceki çalışmada (Heikkilä, 2009) önerilmiştir. Uzun histogramlar yerine, CS-LBP, merkezine dört komşu pikseli karşılaştırır ve yalnızca 16 ikili desen üretir. Ayrıca, denklem (12) gösterildiği gibi eşikleme ile bu özellik tanımlayıcısı T'yi düz bölgelerde sağlam ikili desenler toplar.

$$CS - LBP_{R,N,T}(X, y) = \sum_{i=0}^{\left(\frac{N}{2}\right)-1} S\left(n_i - n_{i+\left(\frac{N}{2}\right)}\right) 2^i, \quad (12)$$

$$S(x) = \begin{cases} 1, & x > t, \\ 0 & \text{otherwise,} \end{cases}$$

X ve Y değişkenleri için CS-LBP Gösterimi

Bu (12), denklemde n_i ve $n_{i+\left(\frac{N}{2}\right)}$, R yarıçapıyla simetrik çiftlere ait komşu piksellerin karşılık gelen n değerleridir, Şekil 9'de gösterildiği gibi.



Şekil 8. CS-LBP özellik tanımlayıcısı

Kaynak: (Heikkilä, 2009)

D. Merkez Simetrik Bit Düzlemi Yönleri

Önerilen Yönlendirilmiş Merkezi Simetrik Bit Düzlemi (DCSBP) yaklaşımı, CS-LBP'nin avantajını korur. Her bir girdi görüntüsü için, $CS - LBP_{R,N,T}(X, y)$ denklemiyle (13) işletilir ve görüntüleri piksel piksel işler. Bu durumda, $DCSBP_{R,N,T}(X, y)$ aşağıdaki gibi sunulabilir.

$$DCSBP_{R,N,T}(X, y) = \sum_{i=0}^{\left(\frac{N}{2}\right)-1} b_n(X, y) \times 2^i, \quad (13)$$

DCSBP matematiksel gösterimi

(13) de, $b_n(X, y)$, $i = 0, \dots, \left(\frac{N}{2}\right) - 1$ her bir girdi görüntüsünün yön bilgisini tanımlayan $n - th$ bit düzlemi olarak sunulur. Şekil 2'de gösterildiği

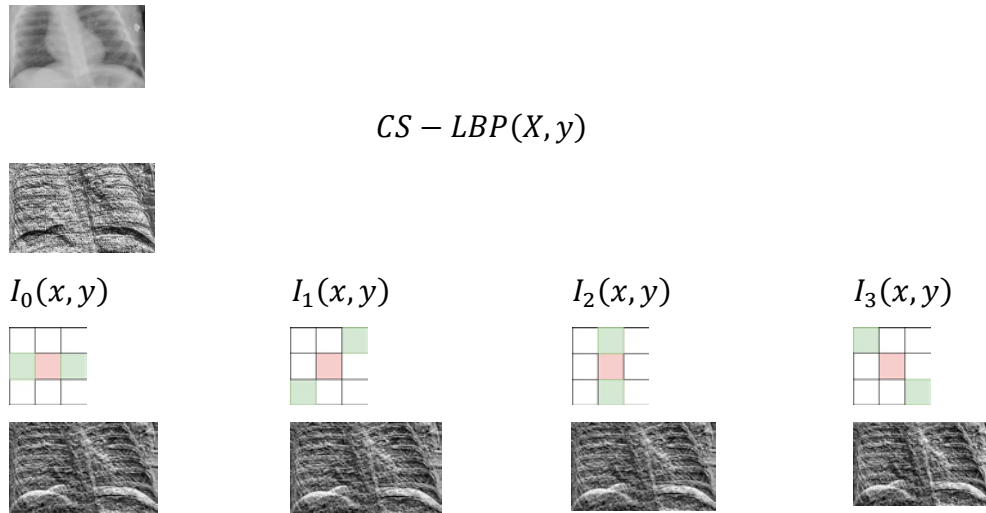
gibi, bir girdi görüntüsü I için, her pikselin merkezi simetrik çiftlerinin konumu (x, y) olarak tanımlanabilir.

$$I_{r,p}(x, y) = I \left(x_i + 2 \times r \times \cos \left(\frac{2\pi n}{n_i} + \pi \right), y_i + 2 \times r \times \sin \left(\frac{2\pi n}{n_i} + \pi \right) \right) \quad (14)$$

Burada $n = 0, \dots, n_i$ and $r = 1, \dots, R$ sırasıyla komşu sayısı ve yarıçapıdır. Piksellerin tam olarak merkezinde olmayan komşu piksel yoğunluk değerleri interpolasyonla tahmin edilir T. Ojala (1996). (x, y) için yaklaşık gradyan $\theta_n = \frac{2\pi n}{n_i} + \pi$ ile aşağıdaki gibi elde edilir.

$$\nabla_{\theta_n} f(x, y) = i_n - i_{\left(\frac{N}{2}\right)-1} \quad (15)$$

Bu durumda, $b_n(X, y)$ girdi görüntüsünün $n - th$ yön bilgisini içerir. Bu tezde DCSBP, dört komşu piksel için bir boyutlu bir vektöre yeniden düzenlenmiştir, Şekil 10'de gösterildiği gibi. Her bir DCSBP, her bir CXR görüntüsünün hem yerel yön hem de uzaysal bilgisini içerir.



Şekil 9. CXR görüntüsünün Bit-Düzlemi ayrışımı

E. Yığılmış Otomatik Kodlayıcı

Bir Otomatik Kodlayıcı (Autoencoder), üç ana bölümden oluşur: gizli katman (y birim), yeniden yapılandırma katmanı (d birim) ve bir aktivasyon işlevi. Eğitim adımlarında, model girişi " X " den " y " gizli katmana, yani "kodlayıcıya" eşler. Ardından, gizli katman "çıkış katmanı" ile eşlenir ve bu da "çözücü" olarak adlandırılır. Çıkış katmanı, giriş katmanı ile aynı boyutta ve "yeniden yapılandırma" olarak adlandırılır. Bu iki adımın denklemleri aşağıdaki gibidir.

$$\begin{aligned}y &= f(W_y x + b_y) \\z &= f(W_z y + b_z)\end{aligned}\tag{16}$$

Burada Z , W_y , W_z and $f(.)$ sırasıyla çıkış katmanı, gizli katmanın girişi, gizli katmandan çıkış katmanına ve aktivasyon işlevi olarak tanımlanır. AE'de tanımlanan üç tür parametre W , b_z ve b_y 'dir. Eğitim sırasında, bu parametreler giriş ve yeniden yapılandırma görüntüsü arasındaki hata oranı en aza indirilene kadar güncellenir, (17) denkleminde olduğu gibi.

$$\text{argmin}[c(x, z)] \dots\dots\dots (17)$$

Burada z , her X girişi için W , b_z ve b_y parametrelerine dayalı olarak tahmin edilir ve $c(x, z)$ hata oranını belirtir. Bu durumda, parametreler, hata oranını en aza indirmek için (18) denklemini temel alarak güncellenir.

$$\begin{aligned}
W &= W - \eta \left(\frac{\partial \cos(x, z)}{\delta W} \right) \\
b_y &= b_y - \eta \left(\frac{\partial \cos(x, z)}{\delta b_y} \right) \\
b_z &= b_z - \eta \left(\frac{\partial \cos(x, z)}{\delta b_z} \right)
\end{aligned} \tag{18}$$

Burada η , öğrenme hızı olarak tanımlanır. AE algoritması yeniden yapılandırma odaklı eğitime dayanır. Eğitim sırasında, gizli katmandaki (y) bilgi, giriş katmanından kodlanan rekonstrüksiyon için kullanılır. Eğer model girdi katmanındaki tüm bilgiyi geri kazanırsa, bu, y katmanının yeterli bilgi içerdiği anlamına gelir, çünkü ağırlıklar ve sapmalar gibi öğrenilmiş olmayan dönüşümlerle. Bu nedenle, eğitim için kodlayıcıları bir araya getirmek bilgi kaybını en aza indirir. Bu nedenle, bu algoritma daha önce önerilen bir yaklaşımda kullanılmıştır (Âdem, 2019).

AE'ler birbirine yığın halinde, yani yığın otomatik kodlayıcı (Stacking Autoencoder- SAE) olarak adlandırılan bir şekilde eklenir. Girdi, ilk AE katmanına eşlenir ve ilk AE eğitildikten sonra ilk AE'nin çıktısı ikinci AE'nin girdisi olarak kullanılır. Bu işlem, bu derin modelde uygulanan AE sayısına bağlı olarak devam eder. Bu derin modelin sonuna bir sınıflandırıcı eklenerek, tüm ağın eğitimi sırasında parametreler ayarlanabilir ve bu adım ince ayarlama olarak adlandırılır (Abraham, 2018).

Yığılanmış Otomatik Kodlayıcı (SAE), girdi görüntülerinden soyut özellikler çıkarır ve öğrenir ve bu özellikler daha sonra derin modelin üstüne lojistik regresyona beslenir. Lojistik regresyon temelli sınıflandırma kısmı, parametreleri bulmak için geri yayılım (backpropagation) kullanır (Ojala, 1996) (Heikkilä, 2009). İlk aşamada SAE modeli hiyerarşik bir şekilde eğitimle derin özelliği öğrenir. Aktivasyon işlevi $f(.)$ Eşitliği (19) temel alınarak uygulanır, aşağıdaki gibidir.

$$f(x) = \frac{1}{1 + e^{-x}} \tag{19}$$

Hata oranını tahmin etmek ve ağırlıkları güncellemek için yeniden yapılandırma amacıyla çapraz entropi maliyet fonksiyonu kullanılır. Bu çalışmada, maliyet fonksiyonu tahmini mini-batch boyutlu girdi görüntülerine dayanır, aşağıdaki (20) gibi ifade edilmiştir.

$$c = -\frac{1}{m} \sum_{i=1}^m \sum_{k=1}^d x_{ik} \log(z_{ik}) + (1 + x_{ik}) \log(1 - z_{ik}) \quad (20)$$

Burada D and M sırasıyla girdi vektörünün boyutu ve mini batch boyutunu ifade eder x_{ik} girdi özellikleri ve z_{ik} rekonstrüksiyon görüntüleri ile ilgilidir. Bu nedenle W , b_z , b_y parametrelerine göre maliyetin kısmi türevleri aşağıdaki gibi hesaplanabilir.

$$\begin{aligned} \partial \frac{c}{w_{r,s}} = & -\frac{1}{m} \sum_{i=1}^m \left\{ \sum_{k=1}^d \left[\frac{x_{i,k} - z_{i,k}}{z_{i,k}(1 - z_{i,k})} \hat{f}(net_{ik}^z) w_{ks} \hat{f}(net_{is}^y) x_{ir} \right] \right. \\ & \left. + \hat{f}(net_{ik}^z) \hat{f}(net_{is}^y) \right\} \end{aligned} \quad (21)$$

$$\begin{aligned} \partial \frac{c}{b_{y,r}} = & -\frac{1}{m} \sum_{i=1}^m \left\{ \sum_{k=1}^d \left[\frac{x_{i,k} - z_{i,k}}{z_{i,k}(1 - z_{i,k})} \hat{f}(net_{ik}^z) w_{kr} \hat{f}(net_{ir}^y) \right] \right\} \\ \partial \frac{c}{b_{z,r}} = & -\frac{1}{m} \sum_{i=1}^m \left\{ \sum_{k=1}^d \left[\frac{x_{i,k} - z_{i,k}}{z_{i,k}(1 - z_{i,k})} \hat{f}(net_{ik}^z) \right] \right\} \end{aligned}$$

Bu (21) 'da net_{ir}^y gizli katmandaki R. birimin i numarasının girdisini temsil eder ve (net_{ik}^z) rekonstrüksiyon katmanındaki k. öğeyi temsil eder (A. Karargyris et al., 2016) (K. C. Santosh, 2016). Ayrıca, \hat{f} sigmoid aktivasyon fonksiyonudur ve birinci ve ikinci dereceden türevleri aşağıdaki gibi yazılabilir.

$$\hat{f}(x) = f(x)(1 - f(x)) \quad (22)$$

$$\hat{f}(x) = f(x)(1 - f(x))(1 - 2f(x))$$

SAE ile sınıflandırma yapmak için, logistik regresyon sınıflandırıcısı derin modelin çıkış katmanına entegre edilir ve geri yayılım algoritması temelinde ince ayarlama yapılır. Sınıflandırıcı katmanının aktivasyon fonksiyonu SoftMax

fonksiyonuna dayanır. Girdi özelliklerinin I kategorisine ait olma olasılığının tahmini aşağıdaki denklem temelinde hesaplanır.

$$P(Y = i|R, W, b) = s(WR + b) = \frac{e^{w_i R + b_i}}{\sum_i e^{w_j R + b_j}} \quad (23)$$


(23) de, R son SAE katmanının (çıkış katmanı) çıktısı ve sınıflandırma katmanının girdi vektörüdür. Ayrıca, toplam sınıf sayısı çıkış katmanı boyutuyla aynıdır. Bu denklemde, W ve b sırasıyla lojistik regresyon katmanının ağırlıkları ve kaymalarıdır (Yushi Chen, 2014) (Y. Bengio, 2013) (S. Einy, 2021).

VI. DERİN ÖĞRENME (DL) İLE ANORMALLİK TESPİTİ

Anormalliklerinin X-ray görüntüleri aracılığıyla erken teşhisi, ilişkili riskleri azaltmak açısından son derece önemlidir. Ancak derin öğrenme algoritmaları kullanarak bu görüntülerin yorumlanması, görüntü gürültüsü ve yorumlardaki farklılıklar gibi faktörlerden kaynaklanan doğuştan belirsizlikleri içerir. Bu çalışma, güvenilirliği artırmak için belirsizliğe duyarlı bir yaklaşımı araştırarak anormallik tespitini iyileştirmeyi amaçlamaktadır, bu da zamanında müdahaleyi ve risk azaltımını kolaylaştırır. Önerilen derin öğrenme çerçevesi Yönlü Bit-Düzlem özellik çıkarma ve her Bit-Düzlem için bir yığılanmış Oto kodlayıcı kullanmaktadır. Yenilikçi özelliklerimizden biri, Yönlü Merkezi Simetrik Bit-Düzlem (YMSBD) olarak adlandırılan bir tanımlayıcıdır ve Merkezi Simetrik Yerel İkili Deseni (MS-YİD) dört Yönlü Bit-Düzleme (YBD) böler. Her bit düzlemi, X-ray görüntü desenlerinin yön bilgisini yakalar, bu da sağlam özelliklerin çıkarılmasına yardımcı olur. Yığılanmış oto kodlayıcılar (YAO) özellik sınıflandırması ve boyutsal azaltma için kullanılır. YAO derin öğrenme yöntemi, Bit-Düzlemlerden yüksek seviyeli, ayırt edici özelliklerin etkin bir şekilde öğrenilmesini ve çıkarılmasını sağlar. Derin öğrenme (DO) çerçevemizin performansını daha da artırmak ve özellik tekrarlığını azaltmak için Derin ensembl uyguluyoruz, çünkü bu, derin öğrenmedeki belirsizliği ele almak için son teknoloji bir yaklaşımı temsil eder. Önerilen yaklaşım, üç farklı kamuya açık erişim veri tabanı kullanılarak titizlikle test edilmiş ve değerlendirilmiştir, belirsizlikleri ele alma ve sınıflandırma oranlarının doğruluğu açısından mevcut en iyi algoritmalarla karşılaştırıldığında önemli gelişmeler göstermektedir.

Radyografi, kliniklerde zatürreyi tespit etme ve değerlendirme aşamasında genellikle ilk teşhis adımıdır. Bu, hastalar hakkında temel bilgiler sağlar, zatürrenin varlığı ve yeri ile birlikte in tedaviye tepkisinin bir tahminini sunar. Ayrıca, X-ray (CXR) görüntüleme, çeşitli anormallikleri teşhis etmekte doktorlara yardımcı olan invaziv olmayan bir tıbbi analizdir. Yumuşak dokuların anatomik yapısı, normal ve anormal X-ray görüntülerinin tespiti için yardımcı

olur (Nanehkaran ,2022). Bu anormallikler yoğunluğunun asimetrisini (yoğunluğun artması veya azalması), tek taraflı düşük yoğunluğu, tek taraflı siyah alt bölgeyi içerir (Einy, 2022). Şekil 11’de bakteri veya virüs etkilerine dayalı çeşitli anormallik türlerini X Ray görüntülerinde göstermektedir. Ayrıca, hastalıkları erken teşhis edilmez ve tedavi edilmezse yaşamı tehdit eder (Dey et al., 2021). Günümüzde, Makine Öğrenimi (ML) ve görüntü işleme kullanarak Bilgisayar Destekli Teşhis (CAD) prosedürleri, bu sorunları aşmaktadır (Arunmozhi, 2021). Bu bağlamda, CAD, zatürre vakalarının varlığını tespit etmeyi ve halk sağlığına olumsuz etkilerini önlemeyi amaçlar (Li et al., 2020) (Bhandary, 2020). Derin öğrenme yöntemlerinin temel avantajları, girdi görüntülerinin otomatik özellik çıkarması ve sınıflandırma, nesne tespiti ve segmentasyon alanında tespit hassasiyetinin artırılmasıdır Chandra 2020). Bu çalışma, CAD durumunda anormallik tespiti için derin öğrenme çerçevesi önermektedir (Y. A. Nanehkaran et al., 2022). Derin öğrenmenin ilerlemeleri son zamanlarda biyomedikal alana etki etmiş ve araştırmacılar bu alanın birçok zorlu problemine bu yöntemleri uygulamaya ilgi göstermiştir (Einy, Oz, and Navaei, 2021). X-ray görüntülerinden anormallik tespiti için, çıkarılan özellikler önemli bir rol oynamaktadır. Klinik araştırmalara göre, CXR görüntülerindeki yumuşak dokuların şekli ve dokusu anormalliği teşhis etmeye yardımcı olabilir (Einy, Oz, and Navaei, 2021). Ancak diğer yandan, bu özellikler renk kontrastının zayıf olması ve yoğun opasifikasyonlu görüntüler nedeniyle belirsiz olabilir. Bu tür durumlarda, son dönemde birçok çalışma, tıbbi görüntülerin otomatik analizi ve özellik çıkarımı için CAD sistemleri önermiştir.



Şekil 10. CXR görüntüsünde, çeşitli normal ve anormal anatomik yapılar

Anormalite tespiti için sınıflandırmanın doğruluğunu artırmak amacıyla farklı çalışmalarda genellikle şekil ve doku özellikleri geniş ölçüde kullanılmaktadır (Santosh, 2016) örneğin, (Van Ginneken, 2002) çalışmasında, önerilen yöntem, geometrik ve görüntüsel özellikleri CXR görüntülerinin Şekil 11’de geometrik ve görüntüsel özelliklerini açıklamak için yerel özellik tanımlayıcılarının Atlas tabanlı segmentasyon algoritması ve çeşitli kombinasyonlarını kullanarak çıkarmıştır. Başka bir benzer çalışmada (Jaeger, 2014), kenar haritalarını çıkarmak için piramit histogramı yönlü gradyan (PHOG) yöntemi önerilmiştir. Diğer bir benzer geometrik şekil analizi, bölgelerini alt bölgelere bölmeye dayalıdır. Bir önceki çalışma (Song, 2013) üst, orta ve alt bölgeler gibi sağ ve sol bölgelerinin yerel bölgeleri arasında karşılaştırmaya dayalı bir yöntem önermiştir. (Wang, 2018)’de, bölgesini çıkarmak için graf kesim segmentasyon yöntemi kullanılmıştır. Çıkarılan bölgelerinin dokusu normal veya anormal olarak bir ikili sınıflandırma algoritmasıyla sınıflandırılır. Hastalık tespitine odaklanarak, doku tabanlı özellik tanımlayıcı yöntemler öne çıkmaktadır. Örneğin, bir çalışma (Singh and Khare, 2014), yüksek çözünürlüklü bilgisayarlı tomografi (HRCT) görüntülerinin sınıflandırması için ikili bir özellik tanımlayıcı önermiştir. Doku tabanlı özellik çıkarma algoritmaları, genel olarak özelliklerin genel bilgilerini çıkarmak için tekstürleri açıklamaya odaklanır. Bu yakın zamanda rapor edilen çalışmalar, yerel ikili model (LBP) (Rajpurkar,

2017), gradyan histogramı (HOG) (Jaeger, 2014) ve Daubechies dalgalet katsayıları (DWC) (Saraiva, 2019) gibi doku tabanlı özellik tanımlayıcı yöntemleri içerir.

Yukarıda bahsedilen çalışmaların yanı sıra, bazı araştırmalar derin öğrenme yöntemlerinin CAD sistemlerinin doğruluğunu artırmak için analizini yapmaktadır. Örneğin, CheX-Net modeli (Rajpurkar, 2019) görüntülerinin normal ve anormal gruplara sınıflandırılması için önerilmiştir. Diğer ağlar iki ana bölümden oluşan hibrit modelleri uygular. İlk bölüm, bölgelerinin çıkarılmasını içerir, ardından çıkarılan bölgelerin derin evrişimli sinir ağı (DCNN) kullanılarak sınıflandırılması gelir (Saraiva, 2019). Başka bir çalışma (Xiei, 2019) CTX görüntülerinde iyi huylu nodüllerin segmentasyonu için çoklu görünüm tabanlı işbirliği içeren derin bir model (MV-KBC) önermiştir. Bu model, nodüllerin 3D özelliklerini öğrenmiş ve onları önceden eğitilmiş bir ResNet modeli yardımıyla sınıflandırmıştır. Ayrıca, azalmış sayıda epok ve faktör ile hafifletilmiş bir derin sinir ağı (DNN), COVID-19, zatürre ve tüberküloz gibi anormalliklerinin tespiti için önerilmiştir (Mahbub, 2022).

Derin evrişimli model eğitmek, tüm ağı düzgün bir şekilde ince ayarlamak için büyük sayıda etiketli veri gerektirir. Bu nedenle, daha önce de bahsedildiği gibi, bazı araştırmalarda transfer öğrenme kullanılmıştır. Transfer öğrenme, ImageNet veya başka yeterince büyük bir veritabanına dayalı olarak ön eğitilmiş ağları, yeni bir veri kümesiyle geriye yayılım yoluyla katmanları ince ayarlamak için kullanmayı içerir. Örneğin (Behzadi-khormouji, 2020), X-ray görüntülerinin sınıflandırılması için transfer öğrenme kullanarak bir DCNN önermiştir. Bu model, 121 katmanlı Dense Net modelinin ince ayarlanmasıyla geliştirilmiştir. (Toğaçar, 2019) çalışmasında, yazarlar, iltihabı tespiti için derin özellikler çıkarmak için AlexNet, VGG-16 ve VGG-19 temelli önceden eğitilmiş bir derin modeli rapor etmişlerdir. Bu özellik setleri daha sonra karar ağaçları, k-en yakın komşular, lineer ayırıcı analiz, lineer regresyon ve destek vektör makine öğrenme modelleri kullanarak sınıflandırma için verimli ve optimize edilmiş bir özellik seti sağlamak amacıyla birleştirilir. Başka bir benzer çalışmada (Einy, Oz, and Navaei, 2021) önceden eğitilmiş AlexNet modeliyle derin öğrenme çerçevesi önerilmiş ve destek vektör makineleri X-ray görüntülerindeki anormalliklerin tespiti için bir sınıflandırıcı olarak kullanılmıştır. Başka bir çalışmada (Lopes ve

Valiati, 2017), önceden eğitilmiş evrişimli sinir ağlarına dayalı derin özellik çıkarıcılar sunulmuştur. Başka bir araştırmada, Fine-tuned InceptionV3 ve Modifiye Edilmiş Etkin Net'e dayalı CoviXNet önerilmiştir (Srivastava, 2022). Bir diğer COVID tabanlı çalışmada COV-ResNet modeli önerilmiştir, bu model VGG16, VGG19, ResNet152 ve ResNet olmak üzere dört önceden eğitilmiş modeli içermektedir (Islam 2022) Ayrıca, (Apostolopoulos ve Mpesiana, 2020) çalışmasında, COVID-19 tespiti için CT görüntülerinden otomatik çıkarım ve sınıflandırma için hibrit önceden eğitilmiş CNN modeli önerilmiştir. Son zamanlarda, abnormalite tespiti için transfer öğrenme mimarisi ile kontrastif üçlü ağ (CTN) adlı otomatik derin öğrenme tabanlı X-ray raporlama sistemi önerilmiştir (Yang, 2022) Ancak, tıbbi görüntü işlemede ince ayarlı derin modellerin kullanılması, tıbbi ve normal görüntüler arasındaki farklılık nedeniyle verimsiz olabilir ve aşırı uyma sorunlarına yol açabilir. Bu sorunu çözmek için, bazı ensemble ve hibrit modeller önerilmiştir. Örneğin, önceki bir araştırmada (Livieris, 2019), X-ray'lerden anormalliklerinin sınıflandırılması için ensemble yarı denetimli öğrenme algoritmaları sunulmuştur. Otomatik X-ray tanısında, birçok araştırmacı etiket bağımlılıklarını görmezden gelmeye odaklanmış ve ön eğitim olmadan çalışan modeller tasarlamıştır. (Livieris, Kanavos ve Pintelas (2019)'da, etiketli görüntüler ve etiketsiz verilerin gizli katmanından gelen bilgi temel alınarak X-ray'lerin sınıflandırılması için yarı denetimli öğrenme algoritmaları önerilmiştir. (Wang, 2019)'da, çoklu CNN modelleri çoklu etiketli CT görüntü sınıflandırması için kullanılmış ve çalışmanın deneysel sonuçlarına göre, ResNet, sınıflandırma doğruluğu açısından diğer klasik CNN modellerine kıyasla önemli sonuçlar elde etmiştir. Örneğin, (Yao, 2017) çalışmasında, X-ray anormalliklerinin tespiti ve tahmini için Dense Net ve Long-Short Term Memory Network (LSTM) sıralı derin modelini birleştiren hibrit bir model önerilmiştir.

Sayısız çalışma, CNN modelinin CAD sistemlerinde büyük potansiyelini göstermiştir. Ancak, bu modellerle ilişkilendirilen sınırlamaları ele almak, özellikle de küçük boyutlu veri kümelerinde eğitilmeleri, son derece önemlidir. Daha önce tartışıldığı gibi, derin öğrenme modelleri birçok öğrenilebilir parametrenin eğitimi için geniş veri gerektirir ve sonuç olarak sınırlı eğitim verisi epistemik belirsizliğe yol açabilir. Ne yazık ki, çoğu mevcut yaklaşım tahminlerine bağlı belirsizlik hakkında bilgi eksikliği taşıırken, sadece birkaç

çalışma (Gour, 2022) ve (Jaskari, 2022) model belirsizliği hakkında ayrıntılar sunmuştur. Örneğin, M. Gour ve diğerleri (Gour, 2022), tahmin belirsizliğini hesaplamak için EfficientNet-B3 ve Monte Carlo kesilmesi kullanan UA-ConvNet adlı yeni bir belirsizlik farkındalığına sahip evrişimli sinir ağı modeli tanıtır. Önerilen yaklaşım, X-ray görüntülerinden COVID-19 vakalarını teşhis etmede mevcut yöntemleri geride bırakmaktadır. Başka bir çalışmada, (R. Gao et al., 2022), belirsizliği azaltma yöntemleriyle belirsizliği azaltmayı amaçlayan entegre bir derin öğrenme yaklaşımını sunar, bu yaklaşım belirsizliği azaltarak endeterminant nodülleri olan hastalar için kanser risk tahminini geliştirmeyi amaçlar (Calderon Ramirez, 2021)'da yazarlar, tıbbi uygulamalarda güvenli kullanım için kritik olan belirsizlik tahmini odaklı X-ray görüntülerine dayalı bir COVID-19 enfeksiyon tespit sistemi uygularlar. Belirsizlik tahminlerini geliştirmek için etiketlenmemiş veri, Mix Match yarı denetimli çerçevesi kullanılarak değerlendirilir. Başka bir araştırmada, diyabetik retinopatiyi retinal görüntülerden belirsizlik farkındalığına sahip derin öğrenme yöntemi ile otomatik olarak sınıflandıran bir yöntem sunulmuştur, bu yöntem ikili sınıflandırma şeması için Bayes evrişimli sinir ağını içerir (J. Jaskari *et al.*, 2022). CT tarama ve X-ray görüntülerinden COVID-19'ün doğru sınıflandırması için belirsizlik FuseNet adlı yeni bir derin öğrenme özellik birleştirme modeli sunar (Abdar, 2023). Model, Ensemble Monte Carlo Kesilmesi (EMCD) tekniğini kullanarak tahmin belirsizliğini nitelendirmek için kullanır, CT tarama ve X-ray veri kümeleri için sırasıyla %99,08 ve %96,35 tahmin doğruluğu elde ederek gürültüye ve görünmeyen verilere karşı sağlamlık sergiler.

Yukarıda bahsedilen çalışmalara dayanarak, model belirsizliğinin tahmin edilmesinin güvenilir ve güvenli bir CAD sistemi geliştirmek için önemli bir öneme sahip olduğu sonucuna varılabilir. Bu nedenle, bu eksiklikleri aşmak amacıyla, X-ray anormallik tespiti için belirsizlik farkındalığına sahip derin bir model geliştirdik. Bu yaklaşım, tıbbi teşhis için daha güvenilir ve güvenilir bir sistem sağlamayı amaçlamaktadır. Önerilen yaklaşım, bu zorlukları, Yönlendirilmiş Merkezi Simetrik Bit Düzlemi (DCSBP) adı verilen çok ölçekli bir şekil ve doku özellik açıklayıcısını tanıtarak ele almaktadır.

DCSBP yöntemi, Eigen Yönlendirilmiş Bit Düzlemi (EDBP) (Lei, 2014) kavramından esinlenilmiştir. Yüz tanıma sistemlerindeki yüksek doğruluk

oranları, özellikle gürültülü ve maskeli senaryolar gibi belirsiz durumlarda, EDBP yaklaşımına dayalı olarak DCSBP yöntemini önerdik. DCSBP'nin, mevcut EDBP yöntemiyle karşılaştırıldığında, mevcut yöntemde kullanılan altı bit düzlemi yerine dört bit düzleminden özellikler çıkardığı ana avantajı, aynı doğruluk seviyesini korurken. Sonuç olarak, yaklaşımımız mevcut yönteme göre daha düşük bir hesaplama maliyeti sunar, bu da DCSBP'nin gerçek dünya uygulamaları için daha verimli ve pratik bir seçenek olmasını sağlar.

(Saparkhojyev, 2021) çalışmada sunulan başarılı sonuçlara dayanarak, X-ray görüntülerinde belirsizlik tahmini kullanarak anormallik tespitinde benzer bir yaklaşımı bir yığın oto kodlayıcıyla benimsemeye karar verdim. Yığılmış oto kodlayıcının yeteneklerini kullanmanın, potansiyel anormallikleri X-ray görüntülerinde tespit etme yeteneğini daha da artıracığına inanıyoruz, bu da araştırmamda iyileştirilmiş doğruluk ve performansa katkı sağlayacaktır. Bu SAE'den çıkarılan özellikler daha sonra sınıflandırma için kullanılmaktadır. Tüm yönler için bilgileri etkili bir şekilde birleştirmek için, tüm DCSBP'lerden derin bir topluluk tekniği kullanıyoruz. Bu birleştirme tekniği, her yönlü bileşen tarafından yakalanan değerli bilgileri kullanmamıza olanak tanır, böylece anormallik tespit sisteminin genel performansını artırır. DCSBP'yi önererek ve SAE ve birleştirme tekniğini kullanarak, belirsizlikle ilgili zorlukları aşmayı amaçlıyoruz ve nihayetinde X-ray görüntülerinde anormallik tespitinin doğruluğunu ve güvenilirliğini artırmayı hedefler.

A. Derin Öğrenmede Yanlılık- Varyans İkilemi

Model ile ilişkili bir hatadır. Doğrusal olmayan bir fonksiyon doğrusal bir model ile modellenirse, model beklenenin altında kalır ve yanlılık hatası yüksek olur. Yanlılık hatası yüksek olduğunda, eğitim verisi eksik öğrenilir. Kısaca bu durum eksik öğrenme (underfitting) olarak adlandırılır. Yüksek yanlılık hatası olan bir ağ, eğitim seti üzerinde tahmin çıktılarını üretirken yüksek hata oranı çıkar ve model veriyi iyi bir şekilde öğrenemez. Yanlılık hatasını azaltmak için yeni katmanlar ve nöronlar ekleyerek ağ mimarisinin değiştirilmesi gereklidir. CNN ve RNN yöntemleri bu duruma iyi bir çözüm olabilmektedir (Mandal, Behera, Desai and Nair, 2019).

Varyans hatası, eğitim verisindeki rassallık sebebiyle ortaya çıkan hatadır. Eğitim dağılımı modelin artık genelleşemeyeceği kadar iyileştirildiğinde, yüksek varyans hatası ortaya çıkmış olur. Bu durum aşırı öğrenme (overfitting) olarak adlandırılır. Varyans hatası yüksek olan bir ağ, eğitim verisini çok iyi öğrenmiştir ve veriyi ezberleme problemi ile karşı karşıya kalmıştır. Doğrulama hatasının eğitim hatasından ayrılarak arttığı noktada, aşırı öğrenme problemi oluşmaya başlar. Varyans hatasını azaltmak için veri sayısının artırılması, dropout ve düzenlileştirme (regularization) tekniklerinin uygulanması çözüm olabilmektedir (Mandal, Behera, Desai and Nair, 2019).

B. Belirsizlik Modelleme

Eğitim verileri uygun olmadığı için modelin bilmediğini tanımlar. Epistemik belirsizlik, sınırlı veri ve bilgiden kaynaklanmaktadır. Yeterli eğitim örnekleri verildiğinde, epistemik belirsizlik azalacaktır. Eğitim için daha az örneklemin olduğu alanlarda epistemik belirsizlik ortaya çıkabilir. Gözlemlerin doğal stokastisitesinden kaynaklanan belirsizliktir. Aleatorik belirsizlik, daha fazla veri sağlandığında bile azaltılamaz. Ölçüm hataları söz konusu olduğunda, buna homoskedastik belirsizlik diyoruz çünkü tüm örnekler için sabittir. Girdi verilerine bağlı belirsizlik, heteroskedastik belirsizlik olarak bilinir. Predictive Belirsizlik (PU) Aleatorik ve Epistemik belirsizliklerin toplamıdır.

$$PU = EU + AU \quad (24)$$

Epistemik belirsizlikler, model parametreleri üzerindeki olasılık dağılımı olarak (24) ifade edilebilir. Aşağıdaki verilen formüllerde herbir x değeri girdiyi temsil edip belirsizlikte kullanılacaklardır.

$$p(y = c|x, w) = \frac{\exp(f_c^w(x))}{\sum_c \exp(f_c^w(x))} \quad (25)$$

Sınıflandırmada (25) nolu softmax likelihood kullanılabilir.

$$p(y|x, w) = \mathcal{N}(y: f^w(x), \tau^{-1}I) \quad (26)$$

Regresyonda (26) nolu Gaussian likelihood düşünülebilir.

$$p(w|X, Y) = \frac{P(Y|X, w)P(w)}{P(Y|X)} \quad (27)$$

Sonsal dağılımda (27) nolu Bayes teorimi kullanılır.

$$P(y^*|x^*, X, Y) = \int p(y^*|x^*, w)p(w|X, Y)dw \quad (28)$$

Verilen (28) nolu formül ile bir x test örneğinin sınıf etiketi $p(w|X, Y)$ tahmin edilebilir. Bu süreç çıkarım ve marjinalleştirme olarak adlandırılır analitik olarak hesaplanmayıp yaklaşık değerler değişken parametreler kullanılarak($q_\theta(w)$) elde edilir.

$$KL(q_\theta(w)||p(w|X, Y)) = \int q_\theta(w) \log \frac{q_\theta(w)}{p(w|X, Y)} dw \quad (29)$$

Amaç, sonsal dağılıma yakın bir dağılıma yaklaşımdır. (29) nolu formülde Kullback –Leibler (KL) divergence (uyuşmazlık) değerinin olabildiğince 0 a yaklaştırılmasıdır.

$$P(y^*|x^*, X, Y) \approx \int p(y^*|x^*, w)q_\theta^*(y^*, x^*) \quad (30)$$

(30) nolu formül ile tahmine dayalı dağılımın minimize edilmesi sözkonusu.

$$\mathcal{L}_{v1}(\theta) := \int q_\theta(w) \log p(Y|X, w)dw - KL(Yq_\theta(w)|p(w)) \quad (31)$$

KL uyuşmazlığının yeniden düzenlenmesi (31) nolu formülde gösterilen (ELBO) evidence lower bound maximization yöntemi ile sağlanabilir.

$$\mathcal{L}(\theta, p) = -\frac{1}{N} \sum_{i=1}^N \log p(y_i | x_i, w) + \frac{1-p}{2N} \|\theta\|^2 \quad (32)$$

(32) N numune sayısını temsil ederken P dropout olasılığını temsil eder

$$\begin{aligned} E^{W_1, W_2, b} &:= \\ &\frac{1}{2} (y - f^{W_1, W_2, b}(x)) g^{W_1, W_2, b}(x) (y - f^{W_1, W_2, b}(x))^T - \\ &\frac{1}{2} \log \det g^{W_1, W_2, b} + \frac{D}{2} \log 2\pi \\ &= -\log \mathcal{N}(f^\theta(x), g^\theta(x)^{-1}) \end{aligned} \quad (33)$$

(33) Veriye dayalı belirsizliği elde etmek için iki fonksiyonu karıştırıp ($f(x)$ ve $g(x)$) tahmini ortalama ve model keskinliği ve likelihood fonksiyonu elde edilebilir. Önsel dağılım modelin ağırlıklarının yerine konulup daha sonra değişim miktarı verilen örneklerden hesaplanıp Öklid mesafe kaybı fonksiyonuna (Euclidean Distance Loss Function) uyarlanabilir.

$$\begin{aligned} \widehat{\text{Var}}[x^*] &:= \frac{1}{T} \sum_{t=1}^T g^{\widehat{w}_t}(x) \mathbf{I} + f^{\widehat{w}_t}(x^*)^T f^{\widehat{w}_t}(x^*) \\ &\quad - \widetilde{\mathbb{E}}[y^*]^T \widetilde{\mathbb{E}}[y^*] \xrightarrow{T \rightarrow \infty} \text{Var}_{q_\theta^*(y^* | x^*)}[y^*] \end{aligned} \quad (34)$$

Yukarıda belirtildiği gibi (34) nolu formülde tahmine dayalı varyans elde ediliş yöntemi gösterilmiştir.

VII. DERİN ÖĞRENME MODELLERİNİN BELİRSİZLİĞİ

A. Deep Ensemble (DE)

Ensemble yöntemleri, bir dizi farklı öğrenme algoritması veya modelin sonuçlarını birleştirerek daha iyi sonuçlar elde etme amacı güder. Bu, model varyasyonları kullanarak aşırı uydurmayı azaltabilir ve daha genelleme yapabilen bir model elde etmeyi hedefler. Deep ensemble ise ensemble yöntemlerinin derin öğrenme modellerine uygulanmış bir türüdür. Bu yöntem, birden fazla derin sinir ağı modelini eğitir ve bu modellerin tahminlerini bir araya getirir. Genellikle bu modeller farklı özelliklere veya başlangıç noktalarına sahip olabilir.

B. Derin Öğrenme Modellerinin Belirsizliğinin Nedenleri

Derin öğrenme modellerinin belirsizliği, birçok nedenle ilişkilendirilebilir ve bu nedenler modelin tahminlerinin kesin olmadığı veya değişebildiği durumları açıklar.

Bu belirsizliklerin en önemli nedenlerinin başında işlenen veri gelir. Yapay zeka elde ki verilerden çıkarımlar yaparak öğrenmeye başlar. Eğitim için getirilen veri gürültülü veya hataları var ise bu doğru öğrenmeyi engelleyebilir. Bunun yanında öğrenilen bilgi, eğitimde ki verilere benzemiyor ise yapay zeka yabancılik çeker. Buda belirsizlik yaratır. Çok karmaşık modeller, eğitim verilerini aşırı uyum yaparak çok iyi bir şekilde öğrenebilir. Ancak bu durum genelleme yeteneğini azaltacağı gibi tahminlerin ve belirsizliklerin aksamasına da yol açabilir. Eğitim sürecinde terslik yaşanabilecek bir durum da eğitimde ki veri miktarıdır. Sınırlı veri kullanıldığında veya kalitesiz veriler seçildiğinde modelin belirsizlik yaşama durumu yüksektir. Veri miktarı ve kalitesi modelin doğruluğunu direkt etkiler. Yetersiz eğitim bir belirsizlik nedenidir. Birden fazla derin öğrenme modelinin bir araya getirildiği ensemble yöntemleri, tahminlerin belirsizliği ile mücadele etmek için kullanılabilir.

C. Derin Öğrenme Modellerinin Belirsizliğini Ölçümü

Modellerin belirsizlik ölçümü ile alakalı birden fazla yöntem vardır. Örneğin bootstrap yöntemi veriye dayalı bir yöntemdir. Farklı eğitim veri altkümeleri oluşturularak modelin varyasyonunu ölçer. Bu, veriye dayalı belirsizliği ölçmeye yardımcı olur. Ayrıca dropout katmanları kullanılarak birden fazla tahmin oluşturulur. Bununla beraber bayesçi yöntemler de modelin belirsizliğini ölçmek için matematiğin en zor ve en önemli konularından olan olasılık kuramını kullanır. Bir başka yöntem ise bağıntılı modellerdir. Farklı derin öğrenme modellerinin bir araya getirildiği deep ensemble yöntemleri tahminlerin belirsizliğini azaltabilir. Modelin tahminleri için entropi değerleri hesaplanarak belirsizliği ölçer. Daha yüksek entropi, daha fazla belirsizlik anlamına gelir.

D. Belirsizlik analizi olmadan Algılama Sonuçları

Bu bölümde, SAE (Yığılmış Otomatik Kodlayıcı) yardımıyla sınıflandırma tekniklerinin kullanımının, derin sinir ağı (DNN) kullanımının geleneksel yöntemi ile karşılaştırıldığında nasıl etkilerini değerlendirdik. Adil bir karşılaştırma yapmak için, DNN model yapısı, SAE'nin kodlayıcısı olarak aynı şekilde kullanılmıştır. Eğitim aşaması için DNN yapılandırması aşağıdaki gibi ayarlanmıştır:

Çizelge 1. DNN Yapılandırması

Parametreler	Değerler
Eğitim öğrenme oranı	0.1
Eğitim epokları	10000
Eğitim mini toplu boyutu	32
Kayıp işlevi	Çapraz Entropi
Optimizasyon	Adam

Çizelge 1’te sunulan deneysel sonuçlara dayanarak, CSLB- SAE'nin (Stacked Autoencoder) doğruluk açısından CSLB- DNN'yi (Deep Neural Network) üç veri kümesinde de (CH, Zatürre ve COVID-19) geride bıraktığı sonucuna varılabilir. Sırasıyla %87,01, %98,25 ve %98,12 oranında başarı elde edilmiştir. Bu, etiketlenmemiş veri kümeleri ile eğitim yapmanın ve ardından sınıflandırma için etiketli görüntülerle ince ayar yapmanın, CSLB- DNN kullanımına kıyasla sınıflandırma performansında gelişmiş doğruluk elde edilmesine yol açtığını gösterir. CSLB- SAE tarafından elde edilen daha yüksek

doğruluk, yarı denetimli öğrenim yaklaşımının, eğitim sırasında etiketlenmemiş verileri içerdiği ve ardından modeli etiketli verileri kullanarak uyarladığı için modelin daha sağlam özellikler öğrenmesine ve görünmeyen verilere daha iyi genellenmesine yardımcı olduğunu gösterir. Etiketlenmemiş verileri kullanarak, model verilerin temelindeki desenleri daha iyi anlama kapasitesi kazanır, bu da üç veri kümesinde daha iyi performansa yol açar. Önemli bir nokta olarak, F-Skoru, Hatırlama (Recall) ve Hassasiyet (Precision) metrikleri de CSLB- SAE ile tutarlı bir şekilde iyileşme gösterir, bu da yarı denetimli öğrenim yaklaşımının modelin sınıflandırma yeteneklerini geliştirdiğini destekler. Özetlemek gerekirse, sonuçlar, etiketlenmiş ve etiketlenmemiş verilerin avantajlarını bir araya getiren SAE gibi yarı denetimli bir öğrenim yaklaşımının kullanılmasının, CH, Zatürre ve COVID-19 için tıbbi veri kümelerini sınıflandırmada daha iyi doğruluk ve performansa yol açtığını vurgular.

Çizelge 2. DNN Yapılandırması CH, Zatürre ve COVID-19 Veri Kümelerinde Sınıflandırma Modellerinin Performans Değerlendirmesi

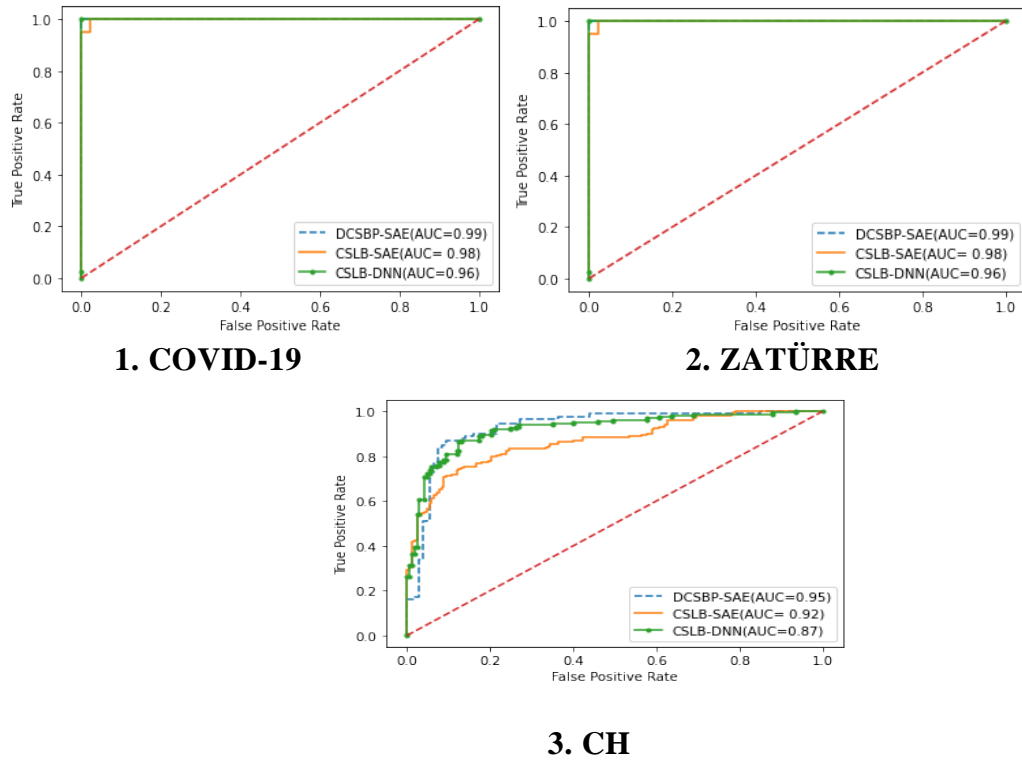
Veri Kümesi	Yöntem	Doğruluk	F-Skoru	Hatırlama	Hassasiyet
CH	CSLB- SAE	87.01	88.10	88.10	87.21
	CSLB- DNN	86.31	87.98	86.49	87.68
Zatürre	CSLB- SAE	98.25	97.15	97.18	98.10
	CSLB- DNN	92.14	93.17	93.26	92.02
COVID-19	CSLB- SAE	98.12	96.16	97.30	98.12
	CSLB- DNN	95.14	94.49	95.17	95.14

Bu çalışmanın devamı olarak, bit düzlemi ve topluluk yöntemlerinin modelin doğruluğu üzerindeki etkilerini daha fazla inceledik. Sunulan doğruluk oranları SAE sınıflandırma tekniklerine dayanmaktadır. Aşağıdaki çizelge her bit düzleminin ayrı ayrı doğruluk oranlarını sunmaktadır. Çizelge 3'da sunulan sonuçlara dayanarak, topluluk yönteminin COVID-19 veri kümesinde %98,53 ve Zatürre veri kümesinde %98,39 doğruluk oranlarını artırdığı sonucuna varılabilir. Ancak, muhtemelen b_1 özellik setinin düşük doğruluk oranı nedeniyle CH veri kümesinde karşılaştırılabilir sonuçlar elde edildi, bu durum yaklaşımın genel doğruluğunu etkiler. Özetlemek gerekirse, topluluk modelinin yalnızca yüksek doğruluk elde etmekle kalmadığı, aynı zamanda farklı boyutlara ve desenlere sahip üç farklı veri kümesinde anormallikleri tespit etme konusunda sağlam ve istikrarlı sonuçlar sunduğu sonucuna varılabilir.

Çizelge 3. Yönlü Bit Düzlemelerinin Performans Değerlendirmesi

	b_1 (ACC%)	b_2 (ACC%)	b_3 (ACC%)	b_4 (ACC%)	Ensemble (ACC%)
CH	87.11	87.13	87.91	87.17	87.41
Zatürre	98.12	98.01	98.34	98.13	98.39
COVID-19	98.03	98.50	98.41	98.37	98.53

Deneyisel sonuçların tartışmasına devam ederek, yaklaşımımızın genel performansı üzerinde derin topluluk tekniklerinin etkisini analiz etmeye devam ettik. Bu amacı gerçekleştirmek için, önerilen DCSBP-SAE yaklaşımımız ile diğer iki yöntemi: CSLB-SAE ve CSLB-DNN arasında karşılaştırmalı bir çalışma yaptık. Şekil 12'teki ROC eğrilerinin analizi temelinde, önerilen yaklaşımın geleneksel yöntemlere göre üstün performans sergilediği görülmüş, AUC değerleri sırasıyla COVID-19, Zatürre ve CH veri kümeleri için 0.99, 0.99 ve 0,95 olarak elde edilmiştir.

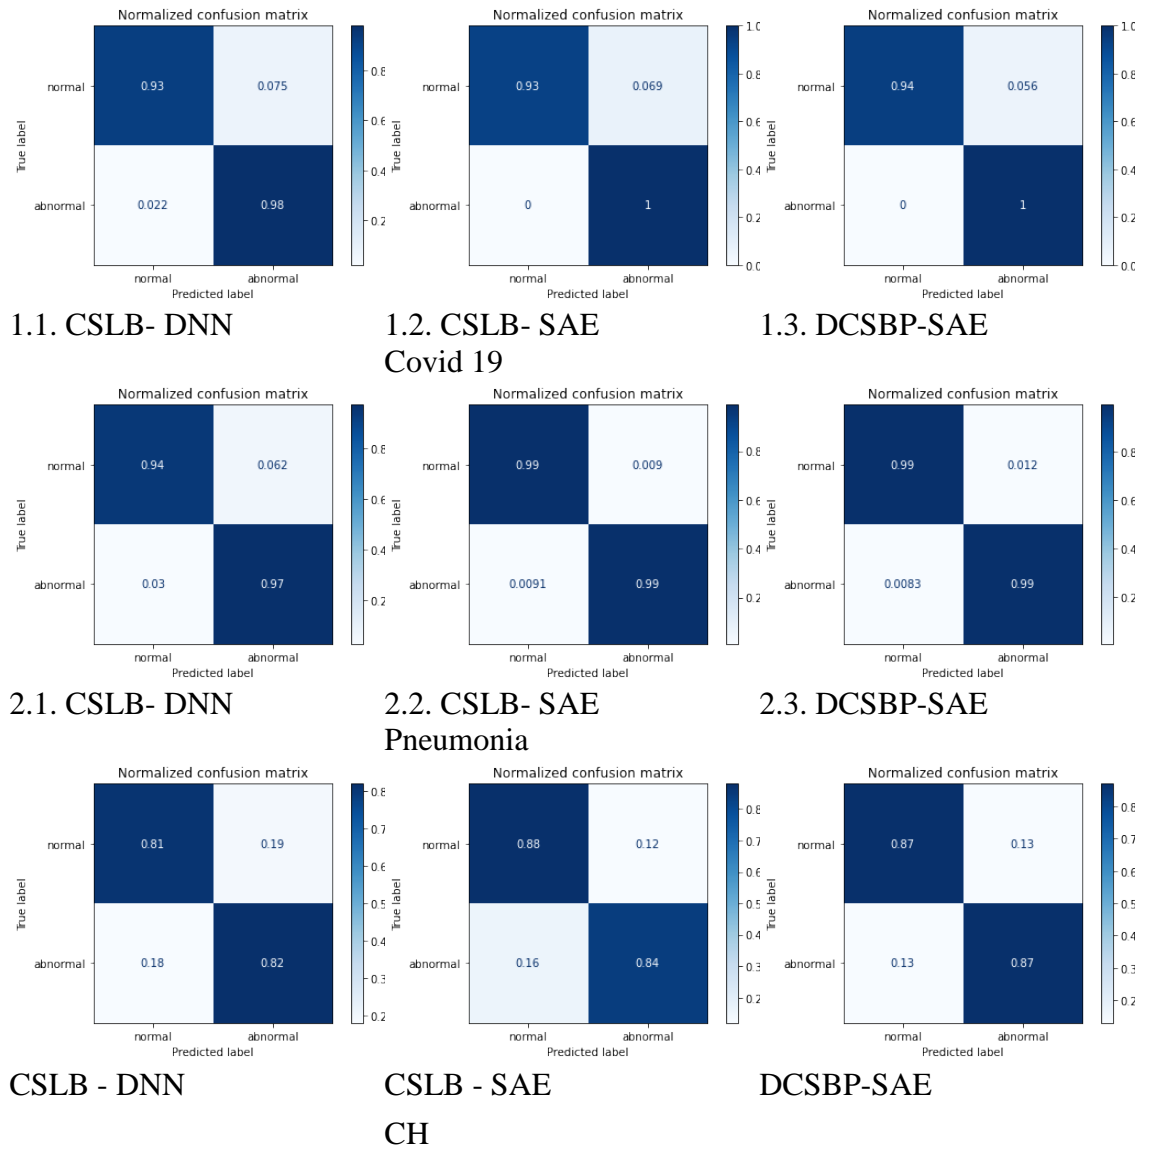


Şekil 11. Önerilen yaklaşımın farklı veri kümelerinde ROC eğrisi

Kaynak:(

<https://pdfs.semanticscholar.org/6091/b5c0d38fd1d2e4ee1f7b53e4f5736125514d.pdf>)

Önerilen sistemin performansını kapsamlı bir şekilde değerlendirmek için karışıklık matrisini kullandık ve deneysel yöntemlerle karşılaştırmalı bir analiz yaptık. Şekil 13'teki sonuçları değerlendirdiğimizde, DCSBP-SAE yönteminin tüm üç deneysel veri kümesinde de Hem Gerçek Pozitifler (TP) hem de Yanlış Negatifler (FN) açısından anlamlı sonuçlar gösterdiğini görebiliriz. Özellikle, DCSBP-SAE yöntemi Covid-19 veri kümesi için 0.94 TP ve 1 FN, Zatürre veri kümesi için 0.99 TP ve 0.009 FN, CH veri kümesi için ise 0.87 TP ve 0.13 FN değerlerine ulaşmayı başardı.



Şekil 12. Farklı veri kümelerinde önerilen yaklaşımın karışıklık matrisi analizi

E. Belirsizlik Farkındalığı Göz önünde Bulundurarak Anormallik Tespiti

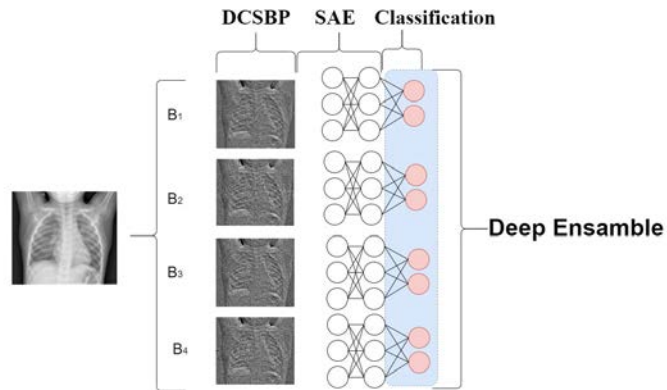
Önceki bölümde, veriyi etiketlenmemiş bir veri kümesine göre eğitmeyi ve ardından etiketli görüntüler kullanarak ince ayar yapmayı tartıştık. Bu bölümde, çok yönlü bit düzleminin derin topluluk öğrenimi ile birleşiminin etkilerini ve bu yaklaşımın belirsizlik üzerindeki etkisini anormallik tespitinde CT görüntüsünde araştırıyoruz. Sistemin belirsizlik farkındalığını incelemek için iki tür test gerçekleştirdik. İlk olarak, önerilen yaklaşımın gürültülü senaryolara karşı performansını değerlendirdik. İkincisi, bu sistemin bilinmeyen veri kümeleri ile uğraşırken tercihlerini değerlendirdik.

VIII. YÖNTEM, SINIFLANDIRMA VE UYGULAMA

A. Derin Topluluk Teknikleri

Derin ensembl (DA), derin öğrenme modellerinde belirsizliği tahmin etmek için kullanılan son teknoloji bir tekniktir. Ancak, hesaplama maliyeti yüksektir. Derin ensembl oluşturmak için ilk adım, M adet ensembl üyesini eğitmektir. Her üye, bağımsız bir derin sinir ağıdır ve benzersiz başlangıç değerleri ile eğitilir; ayrıca eğitim verisinin farklı alt kümeleri üzerinde eğitilir. Bu ensembl üyeleri arasındaki çeşitlilik, modelin tahminlerindeki belirsizliği etkili bir şekilde yakalama açısından önemlidir. Eğitim süreci, eğitim verisinin alt kümelerini rastgele örneklemeyi ve her ensembl üyesinin sinir ağının parametrelerini rastgele başlatmayı içerir. Bu üyeler daha sonra kendi veri alt kümelerini kullanarak eğitilir ve kayıp fonksiyonunu en aza indirmek için geri yayılım kullanılarak parametreleri ayarlanır. Farklı veri ve başlangıç değerleri ile çoklu ensembl üyelerini eğiterek, Derin ensembl daha sağlam ve güvenilir belirsizlik tahminleri sağlayabilir; bu, model tahminlerinin güveninin önemli olduğu karar alma senaryolarında değerli olabilir (Aguilar, Nagarajan ve Radeva, 2022).

B. Önerilen Yöntem



Şekil 13. DCSBP-SAE Yaklaşımı ile X-Işını Anomalisi Tespiti

Kaynak:

(<https://www.sciencedirect.com/science/article/pii/S0010482522000257>)

Şekil 12’de, DCSBP-SAE modeli tasvir edilmiştir ve metodolojinin iki temel bileşeni sergilenmiştir. İlk bileşen, X-ışını görüntülerini (224x224) boyutunda girdi olarak alan DCSBP (Yönlü Merkezi Simetrik Bit-Düzlem) özellik çıkarma yaklaşımıdır. DCSBP işlemi görüntüleri dört yönlü bit düzlemlere ayırarak, dört ayrı özellik kümesi oluşturur ve bu bit düzlemleri olarak adlandırılır. Bu adım, görüntü piksellerinden doğru yönlü ve desen bilgisini yakalar ve Standart Merkezi Simetrik Yerel İkilik Desenleri (CS-LBP) gibi standart tanımlayıcılarla karşılaştırıldığında sağlam ve ayırt edici özellikler üretir.

DCSBP'nin çıktısı daha sonra (4x224x224) formatına genişletilir, her biri temel desen bilgisi içeren dört yönlü bit düzlemi içerir. Bu genişletilmiş özellik kümesi daha sonra Yığılmış Oto kodlayıcılar (SAE) içine beslenir ve daha fazla işleme tabi tutulur.

Çizelge 4. Önerilen yaklaşımın sözdizimi (pseudocode)

1	Aşağıda belirtilen parametreleri başlatın: Mini-batch boyutu (BATCH_SIZE), Epok sayısı (EP), Ön eğitim öğrenme oranı (PLR), İnce ayar öğrenme oranı (FTL), Katman sayısı (NL), Boyut (D), Toplam sınıf sayısı (C), Her gizli katmandaki nöron sayısı (n[d]) ve X-ışını görüntülerinden sağlam özellikler çıkarmak için Merkezi Simetrik Bit Düzlemi Yönlendirmeli (DCSBP) yapısını oluşturun.
2	1'den 4'e kadar olan bit düzlemleri (BP) için:
3	1'den NL'ye kadar olan katmanlar (L) için:
4	X-ışını görüntülerinden sağlam özellikler çıkarmak için Merkezi Simetrik Bit Düzlemi Yönlendirmeli (DCSBP) yapısını oluşturun (Eşitlik 5).
5	Eğer L=1 ise:
6	n[1] = gizli katmanın boyutu.
7	D = giriş katmanının boyutu.
8	Aksi takdirde:
9	Görünür katman bileşeni n[L-1].
10	Gizli katman bileşeni n[L].
11	Son
12	AE parametrelerini W , b_z , b_y şeklinde başlatın.
13	Her epok için ön eğitimi gerçekleştirin (Eşitlik 8 - Eşitlik 12):
14	Her mini batch için:
15	Girişin yeniden oluşturulması işlemini gerçekleştirin..
16	$z = f(wf(wx + b_y) + b_z)$
17	İşlem Maliyeti $c = -\frac{1}{b} X \log(z) - (1 - x) \log(1 - z)$
18	Ağırlıkları güncelleyin ve öğrenmeye devam edin
19	Son
20	Yeniden oluşturma katmanını dondurun.
21	Son
22	Son
23	Farklı bit düzlemlerinden elde edilen dört SAE modelinin çıktılarını birleştirin (Eşitlik 13).
24	Lojistik regresyon katmanının parametrelerini başlatın.
25	Sınıflandırıcı katmanının girişi = $4 \times$ gizli katman boyutu n[D].
26	Sınıflandırıcı katmanının çıkışı = sınıf sayısı (C).
27	Dört SAE modelinin toplu ince ayarı için şunları gerçekleştirin:
28	Her mini batch için:
29	Her sınıfın olasılık fonksiyonunu lojistik regresyon kullanarak hesaplayın.
30	İnce ayar öğrenme oranına dayalı olarak ağırlıkları geri yayılım ile güncelleyin.
31	Son
32	Son

Önerilen yaklaşımın ikinci bileşeni, Çizelge 5'te Yığılmış Otomatik Kodlayıcıları (SAE) içerir. Burada, SAE, girdi verilerinden yüksek düzeyli ve ayırım yapıcı temsiller çıkaran bir özellik öğrenici olarak görev yapar. SAE'ler başlangıçta denetimsiz bir şekilde eğitilir, bu da onların etiketli verilere dayanmadan doğrudan X-ışını görüntülerinden temel özellikleri öğrenmelerine izin verir. Bu denetimsiz ön eğitim aşaması, verideki içsel desenleri ve temsilleri yakalar. Denetimsiz ön eğitimin ardından, SAE'ler etiketli verileri kullanarak ince ayar yaparlar. Bu aşamada, SAE'lerin yeniden oluşturma katmanları kaldırılır ve ağ doğrudan bir SoftMax sınıflandırma katmanına bağlanır. Bu yapılandırma, uçtan uca eğitimi mümkün kılar ve SAE'lerin öğrenilen özelliklerinin karşılıyan sınıf etiketleriyle doğru şekilde eşleştirilmesini sağlar, bu da anomali tespitinde SAE'nin öğrenilen özelliklerinin güvenilir bir şekilde haritalandığından emin olur.

Ayrıca, önerilen yaklaşım derin topluluk tekniğini belirsizlik farkındalığını artırmak için içerir. Dört SAE kullanarak paralel özellik öğrenimi, modellere çeşitlilik ekler. Her SAE farklı başlangıçlar ve karıştırılmış eğitim verileri ile bağımsız olarak eğitilir, böylece temel veri dağılımının farklı yönlerini yakalayabilirler. Derin topluluk, bireysel SAE'lerin tahminlerini birleştirir, bu da geliştirilmiş belirsizlik tahmini ve genel model güvenilirliği ile sonuçlanır. Bu önerilen metodoloji aracılığıyla DCSBP-SAE modeli karmaşık ve zorlu senaryolarda daha kesin ve doğru sonuçlar elde eder. DCSBP özellik çıkarma, SAE tabanlı özellik öğrenme ve derin topluluk tekniğinin birleşimi, X-ışını görüntülerinde belirsizliğe duyarlı anomali tespitinin ilerlemesine katkı sağlar.

C. Deneysel Sonuçlar

Bu çalışma boyunca, tüm görüntüler farklı veri kümeleri arasında tutarlı ve standart bir karşılaştırma sağlamak için (224×224) boyutlarına yeniden boyutlandırıldı. Sunulan çalışmada, SAE'nin mimarisi Çizelge 2'de sunulmuştur. SAE modelinin katman ve gizli düğme optimal yapılandırmasını bulmak için Keras tuner işlevini kullanarak bir ızgara arama yaklaşımı kullandık.

Çizelge 6, Yığın Otomatik Kodlayıcı (SAE) modelinin kodlayıcı bölümünü sunar. Girdi katmanı, 1024x1024 piksel boyutunda gri tonlamalı bir görüntüyü temsil eden (1024 × 1024 × 1) şeklinde tanımlanmıştır. Girdi katmanını takip eden dört Yoğun katman, tümü otomatik kodlayıcının kodlayıcı kısmı olarak

hizmet eder. İlk Yoğun katman, $(512 \times 512 \times 1)$ şeklinde olup 25,690,624 eğitilebilir parametreye sahiptir. Ardışık Yoğun katmanlar boyutları azalan şekilde: $(256 \times 256 \times 1)$ şeklinde 131,328 eğitilebilir parametre, $(128 \times 128 \times 1)$ şeklinde 32,896 eğitilebilir parametre ve $(64 \times 64 \times 1)$ şeklinde 8,256 eğitilebilir parametreye sahiptir. Toplamda, tüm model 25,863,104 eğitilebilir parametreye sahiptir ve herhangi bir eğitilemeyen parametre içermez.

Çizelge 5. Kodlayıcı bölümü için SAE modeli

Layer (type)	Layers	Param
input (Input Layer)	$(1024 \times 1024 \times 1)$	0
Dense layer (Encoder)	$(512 \times 512 \times 1)$	25690624
Dense layer (Encoder)	$(256 \times 256 \times 1)$	131328
Dense layer (Encoder)	$(128 \times 128 \times 1)$	32896
Dense layer (Encoder)	$(64 \times 64 \times 1)$	8256
Total params: 25,863,104		
Trainable params: 25,863,104		
Non-trainable params: 0		

Çizelge 7'te sunulduğu gibi hem ön eğitim hem de ince ayarlama aşamaları için belirli parametrelere sahip bir SAE kullanıyoruz. Ön eğitim aşaması için öğrenme hızını 0,1 olarak ayarlıyoruz ve eğitim sürecini 10,000 epok boyunca çalıştırıyoruz, 32'lik bir mini grup boyutu kullanıyoruz. Bu adım, modelin girdi verilerinden anlamlı temsiller öğrenmesine yardımcı olur. İnce ayarlama aşamasına geçerken öğrenme hızını daha düşük bir değer olan 0.001'e ayarlıyoruz ve yine 32'lik bir mini grup boyutu kullanarak 1000 epok boyunca ince ayarlama yapıyoruz. İnce ayarlama sırasında, öğrenilmiş temsilleri hedef problemimize uygun hale getirmek için modeli özel görevimiz üzerinde ince ayar yapıyoruz. Hem ön eğitim hem de ince ayarlama sırasında modeli optimize etmek için Adam optimizasyon algoritmasını kullanıyoruz. Ayrıca, görev için seçilen kayıp işlevi Çapraz Entropidir, bu da tahmin edilen ve gerçek dağılımlar arasındaki farklılığı ölçmeye yardımcı olur ve etkili bir eğitim sağlar.

Çizelge 6. SAE Parametreleri

parameters	Values
Ön eğitim öğrenme oranı	0.1
Ön eğitim epokları	10000
Ön eğitim mini toplu boyutu	32
İnce ayar öğrenme oranı	0.001
İnce ayar epokları	1000
İnce ayar mini toplu boyutu	32
Kayıp işlevi	Çapraz Entropi
Optimizasyon	Adam

D. Deneysel Veri Seti

Üç farklı kamuya açık erişim veritabanı toplandı ve test edildi. Bu veritabanları, anomali tespit sisteminin değerlendirilmesi için sağlıklı ve sağlıklı veri kümeleri olmak üzere iki ana gruba ayrıldı.

Zatürre veri kümesi (Kermany et al, 2018), 5,863 adet JPEG formatında X-ışını görüntüsünü içerir ve eğitim, test ve doğrulama için üç ayrı klasöre ayrılmıştır. Veri kümesi iki ana gruptan oluşur: Zatürre ve Normal. Zatürre görüntüleri iki farklı tipe ayrılır: Bakteriyel ve Viral zatürre.

1.Şenzhen Hastanesi Çin (CH) (Jaeger, 2014) veri kümesi, normal ve anormal veri tespiti için 662 X-ışını görüntüsü içerir. Bu veri kümesi Şenzhen Hastanesi tarafından toplandı ve PNG görüntü formatında sunuldu, çeşitli verem (TB) belirtileri içerir.

2.COVID-19 X-ışını görüntü veri kümesi (J. P. Cohen,2020), Montreal Üniversitesi'nden Dr. Joseph Cohen tarafından sağlandı. Önerilen çerçevemizin COVID-19 X-ışını görüntülerindeki analizi için, 25 adet Posterior Anterior (PA) görüntü seçtik. Bu görüntüler, COVID-19 pozitif vakalarını içermektedir.

IX. MATARYEL VE METOT DEĞİŞİMİ

A. Gürültülü Senaryo


Bu çalışma, bireysel görsel sistemlerin doğal gürültülere ve bozulmalara (kar, sis veya yağmur gibi) karşı önemli bir dayanıklılık gösterdiği göz önüne alınarak, uygulanan derin öğrenme yaklaşımının gürültüye karşı sağlamlığını araştırmaktadır. Bu testte, hem X-ışını görüntüleri hem de CT görüntüleri için standart sapma (STD) değeri 0.1 ile 0,6 arasında değişen tuz-biber gürültüsü uygulandı. Çizelge 8'de (CT tarama verisi sonuçları) sunulan sonuçlara göre, CSLB-DNN ve CSLB-DNN modellerinin önerilen yaklaşımımıza kıyasla gürültülü verilerde daha düşük performans gösterdiği açıktır. Özellikle, modellerin doğruluğu veri kümesindeki gürültüden etkilenir. Modeller arasında, DCSBP-SAE, üç veri kümesinde farklı gürültü seviyelerinde anormallik durumlarını yüksek doğrulukla tahmin etme konusunda tutarlı bir şekilde yüksek performans sergiler. Buna karşılık, CSLB-DNN ve DCSBP-SAE, gürültü seviyesine ve belirli hastalık tahminine bağlı olarak farklı derecelerde doğruluk gösterir. Özellikle, önerilen yaklaşım tüm gürültü seviyelerinde tutarlı bir şekilde yüksek doğruluk sergiler. Özellikle CH veri kümesinde model, %84,86 ile %87,23 arasında değişen doğruluk elde eder. Benzer şekilde, Zatürre veri kümesinde model, %96,89 ile %98,25 arasında değişen doğruluk oranlarını korur. Bu sonuçlar, modelin farklı veri kümelerinde ve değişen gürültü ortamlarında anormallik durumlarını doğru bir şekilde teşhis etme konusundaki sağlam performansını vurgular.

Çizelge 7. Önerilen yaklaşımın doğruluk oranındaki gürültünün etkileri.

	CH Gürültü (STD)	Doğruluk	Zatürre Doğruluk	COVID-19 Doğruluk
CSLB- SAE	0.1	86.67	98.12	98.03
	0.2	86.01	98.04	97.65
	0.3	85.29	97.63	97.01
	0.4	84.12	97.01	96.31
	0.5	81.30	96.15	96.12
	0.6	72.64	95.37	95.47
CSLB- DNN	0.1	85.21	90.15	93.65
	0.2	84.78	89.47	92.57
	0.3	81.36	88.12	90.12
	0.4	79.81	87.40	89.09
	0.5	71.37	85.23	88.47
	0.6	68.12	84.12	87.01
DCSBP-SAE	0.1	87.23	98.25	98.31
	0.2	86.62	98.17	98.16
	0.3	86.17	98.01	98.05
	0.4	85.69	97.85	97.78
	0.5	85.03	97.63	97.41
	0.6	84.86	96.89	97.09

B. Bilinmeyen Veri Senaryosu

Bu alt bölümde, derin modellere bilinmeyen veriler sunulduğunda önerilen sistemin performansını inceledik. Bu amacı gerçekleştirmek için, beyin görüntüsü inme (Şekil 15) verilerini derin modellere girdi olarak verdik. Sonuçlar, CSLB-SAE, CSLB- DNN ve kendi yeni yaklaşımımızın ortalama ve standart sapma (STD) değerlerini içermektedir.



Şekil 14. Beyin inme görüntüsü

Kaynak: (<https://jbsr.be/articles/10.5334/jbr-btr.921>)

Vurgulamak önemlidir ki, Ortalama değeri model tarafından yapılan tahmini temsil ederken, STD değeri ise bu tahminle ilişkilendirilen belirsizlik seviyesini gösterir. Çizelge 9’te belirtildiği gibi, önerilen yaklaşım özellikle CT tarama ve X-ışını görüntü veri kümelerinde bir görüntü sınıfı için Ortalama ve STD değerlerinin sıfıra yakın olma eğiliminde olduğu görülmektedir.

Çizelge 8. Önerilen yaklaşım ile bilinmeyen görüntü sınıfı tespit

		CH		Zatürre		COVID-19	
		Normal	Anormal	Normal	Anormal	Normal	Anormal
CSLB-	Ortalama	0.14	0.58	0.17	0.61	0.20	0.52
SAE	STD	0.29	0.38	0.26	0.41	0.23	0.32
CSLB-	Ortalama	0.23	0.69	0.20	0.72	0.30	0.73
DNN	STD	0.29	0.33	0.26	0.30	0.23	0.27
DCSBP-	Ortalama	0.1	0.44	0.00	0.58	0.06	0.59
SAE	STD	0.07	0.50	0.08	0.62	0.05	0.48

C. En İyi Durum Algoritmaları

Dört paralel Yığılmış Otomatik Kodlayıcı (SAE) ağı kullanarak renk-mekansal yerel ikili desen (CS-LBP) bit düzlemi ile bu ağların birleşimini kullanarak, sınıflandırma doğruluğunda dikkate değer bir artış elde edildi. Sonraki bölümde, önceki şekilde belirtilen Değerlendirme Metrikleri ve Protokollerini kullanarak önerilen yöntemimizin etkinliğini sistemli bir şekilde inceledik ve değerlendirdik. Bu değerlendirmeleri zatürre ve CH veri tabanlarını kullanarak birer örnek olay incelemesi olarak gerçekleştirdik. Ayrıca, önerdiğimiz yaklaşımın avantajını göstermek için önde gelen algoritmalarla karşılaştırmalı bir analiz yaptık.

Zatürre veri tabanındaki deneysel sonuçlara dayanarak (Çizelge 9), en iyi değerlendirme metriklerinin Alex Net ve VGG-16 ve VGG-19 ile LR (Lopes and Valiati, 2017) DenseNet-121 + SVM (Varshni, 2019) ve CNN’lerle Derin Özellik Çıkarma (Yang, 2020) olduğu görülmüştür. Sırasıyla %0,98, %0,97 ve %0,98 doğruluk oranlarına sahiptirler. Bu modeller, ünlü önceden eğitilmiş modellerin büyük yapılarını kullanmış ve yüksek hesaplama maliyetine sahiptirler, bu da önerdiğimiz yöntemle eşit bir doğruluk oranı (0,98 ACC) elde etmiştir. Ayrıca, önerilen yaklaşım, önceki bir çalışmada bildirilenlere kıyasla daha düşük bir hesaplama maliyeti ile 0.98 özgüllük ölçümünü sağlamıştır. Ek olarak, Transfer Öğrenme (InceptionV3) ve ADAM (Kermany, 2018) ile %0,92 doğruluk elde

edilen deneysel sonuçlar, transfer öğrenmenin CXR görüntülerinde tatmin edici sonuçlar elde edemediğini göstermektedir.

CH veri tabanındaki deneysel sonuçlara dayanarak (Çizelge 10) ACC ve AUC açısından en düşük sonuçlar, sırasıyla %0,84 ACC ve %0.90 AUC ile graf kesme segmentasyon yöntemi (Wang, 2018) ve %0.84 ACC ve %0.90 AUC ile graf kesme optimizasyon yöntemi (Song, 2013) ile elde edilmiştir. Önerilen yaklaşım, diğer yöntemlere kıyasla en iyi doğruluk oranına sahip olmuştur, örneğin özellik çıkarıcı yöntem veya Kenar haritası analizi (Jaeger, 2014) (%0,86 ACC) veya Önceden eğitilmiş konvolüsyonel sinir ağları gibi transfer öğrenme yöntemleri (%0,84 ACC) ile 0.87 doğruluk oranlarına sahiptir. En iyi AUC değeri, Atlas tabanlı segmentasyon özellikleri (Van Ginneken, 2002) ve Kenar haritası analizi (Van Ginneken, 2002) ile 0.93 (AUC) olarak elde edilmiştir ve bu durumda önerilen yaklaşım, bu modellere kıyasla doğruluğu 0.3 artırmıştır.

Çizelge 9. Önerilen yöntemin zatürre veri tabanında en son teknik yöntemlerle karşılaştırılması

Model	ACC	SE	SP	PR	F-score	AUC
Alex Net and VGG-16 and VGG-19 with LR	0.98	0.98	0.97	0.97	0.98	-
Transfer Learning (InceptionV3) and ADAM	0.92	-	-	-	-	-
Deep CNN	0.84	-	-	-	-	-
Semi-supervised learning (SSL)	0.83	-	-	-	88.17	-
Modified CNNs	0.95	-	-	-	-	-
Deep feature extraction with CNNs	0.98	-	-	-	-	-
DenseNet-121 + SVM	0.97	-	-	-	-	-
Modified Alex Net (MAN)	0.94	0.96	0.91	0.95	0.96	0.98
Proposed method	0.98	0.98	0.98	0.98	0.98	0.99

Kaynak: (Xiei, 2019)

Kaynak: (Varshni 2019)

Kaynak: (Yang, 2020)

Kaynak: (Livieris, 2019)

Kaynak: (Jakhar ve Hooda, 2018)

Kaynak: (Kermany diğerleri 2018)

Kaynak: (Toğacar, 2019)

X.SONUÇLAR VE DEĞERLENDİRİLMESİ

Bu çalışmada, Yönlü Merkezi Simetrik İkili Desen (DCSBP) temelli derin öğrenme bir çerçeve öneriyoruz ve bu çerçeve paralel yığılmış otomatik kodlayıcılarla destekleniyor. Bu derin öğrenme çerçevesi, X-ışını görüntülerinde üç farklı anormalliği test etmek üzere kullanıldı: COVID-19, zatürre ve verem. Bu yaklaşımda, X-ışını görüntülerinin anormal ve normal sınıflara sınıflandırılması için derin topluluk yöntemi kullanılmıştır. Önerilen DL yaklaşımı, zatürre ve CH veri tabanında sırasıyla %98'den fazla ve %87'den fazla doğruluk elde etti. Bu sonuçlar, mevcut en iyi yöntemlerle karşılaştırıldığında önemli ölçüde daha iyidir. Ayrıca, önerilen sistem, gürültülü ve bilinmeyen veri kümeleri de dahil olmak üzere belirsiz senaryolarda test edilmiş ve uyumlu sonuçlar elde edilmiştir. Gelecekteki çalışmalarda, belirsizlik farkındalığı tekniklerini kullanarak 3D tıbbi görüntüler üzerinde derin ve yerel özellik kümelerinin etkilerini analiz edeceğiz.

XI. SONUÇLAR VE TARTIŞMALAR

Derin öğrenme modelleri, büyük miktarda veriye dayalı karmaşık yapılar oluşturarak birçok görevde önemli başarılar elde etmiştir. Ancak, bu modellerin doğrulukları ve güvenilirlikleri hala birçok belirsizlikle çevrili bulunmaktadır. Bu çalışma, derin öğrenme modellerinin belirsizliklerini anlamak için farklı ölçüm yöntemlerini incelemiştir.

Bu çalışma, derin öğrenme modellerinin belirsizliklerini anlamak ve ölçmek için kullanılan yöntemleri ele almış ve bu yöntemlerin uygulama alanlarına katkı sağlayabileceğini göstermiştir. Derin öğrenme modellemesinde belirsizlik ölçümü, gelecekte daha fazla önem kazanacak ve daha güvenilir ve hesap verebilir yapay zeka sistemlerinin geliştirilmesine katkıda bulunacaktır.

Bu çalışmanın sonuçları, belirsizlik ölçümünün derin öğrenme topluluğunda daha fazla araştırılmasını teşvik etmektedir ve bu ölçüm yöntemlerinin daha fazla uygulama alanına entegre edilmesi beklenmektedir. Bu şekilde, daha güvenilir ve istikrarlı yapay zeka uygulamaları geliştirme yolunda önemli bir adım atılmış olacaktır.

Çalışma da sadece yenilikçi yaklaşıma değil, geçmişte yapılan araştırmalara ve makalelere yer verilmiştir. Kullanılan fonksiyonlar ve algoritmalar derinlemesine incelenmiş olup bunlardan çıkarımlar sonucu örneklerle desteklenmiştir.

Derin öğrenme modellerinin belirsizliklerinin daha iyi anlaşılması ve belirsizlik ölçüm yöntemlerinin geliştirilmesi için daha fazla araştırma yapılmalıdır. Belirsizlik ölçümü, derin öğrenme modellerinin güvenilirliğini artırmak ve endüstriyel uygulamalarda kullanımını teşvik etmek için daha fazla dikkate alınmalıdır. Bu alandaki gelecekteki çalışmalar, belirsizlik ölçüm yöntemlerinin daha geniş bir yelpazede ve farklı veri türleri için uyarlanmasına odaklanmalıdır.

XII. KAYNAKÇA

KİTAPLAR

MUELLER, A., and RASCHKA, S. (2017) **Neural networks from scratch**. O'Reilly Media. 2017.

NIELSEN, M. A. (2015) **Artificial neural networks: A comprehensive foundation**. Morgan Kaufmann. 2015.

DERGİLER

A. A. SARAİVA ET AL., (2019) “Classification of images of childhood pneumonia using convolutional neural networks,” **BIOIMAGING 2019 - 6th Int. Conf. Bioimaging, Proceedings; Part 12th Int. Jt. Conf. Biomed. Eng. Syst. Technol. BIOSTEC 2019**, no. Biostec, pp. 112–119, 2019, doi: 10.5220/0007404301120119.

A. BHANDARY ET AL., (2019) “Deep-learning framework to detect lung abnormality – A study with X-Ray and lung CT scan images,” **Pattern Recognit. Lett.**, vol. 129, pp. 271–278, 2020, doi: 10.1016/j.patrec.2019.11.013.

A. JAİN, A.C.S. RAO, P.K. JAİN, AND A, ABRAHAM. (2022) Deep Learning Modeling of Androgen Receptor Responses to Prostate Cancer Therapies, **IEEE Transactions on Biomedical Engineering**, vol. 69, no. 9, pp. 2756-2768, Sept. 2022.

A. KARARGYRİS ET AL., (2016) “Combination of texture and shape features to detect pulmonary abnormalities in digital X-rays,” **Int. J. Comput. Assist. Radiol. Surg.**, vol. 11, no. 1, pp. 99–106, 2016, doi: 10.1007/s11548-015-1242-x.

ABDAR, M., SALARİ, S., QAHREMANİ, S., LAM, H., KARRAY, F., HUSSAİN, S., KHOSRAVİ, A., ACHARYA, U. R.,

- MAKARENKOV, V., and NAHAVANDI, S. (2022) UncertaintyFuseNet: Robust uncertainty-aware hierarchical feature fusion model with ensemble Monte Carlo dropout for COVID-19 detection. **IEEE Transactions on Information Fusion**, 99(1), 364-381. 2022.
- AGUÍLAR, B. NAGARAJAN, AND P. RADEVA, (2022) “Uncertainty-aware selecting for an ensemble of deep food recognition models,” **Comput. Biol. Med.**, vol. 146, no. May, p. 105645, 2022, doi: 10.1016/j.combiomed.2022.105645.
- B. ABRAHAM AND M. S. NAIR, (2018) “Computer-aided classification of prostate cancer grade groups from MRI images using texture features and stacked sparse autoencoder,” **Comput. Med. Imaging Graph.**, vol. 69, pp. 60–68, 2018, doi: 10.1016/j.compmedimag.2018.08.006.
- B. VAN GINNEKEN, S. KATSURAGAWA, B. M. TER HAAR ROMENY, K. DOI, AND M. A. VIERGEVER, (2002) “Automatic detection of abnormalities in radiographs using local texture analysis,” **IEEE Trans. Med. Imaging**, vol. 21, no. 2, pp. 139–149, 2002, doi: 10.1109/42.993132.
- C. H. YOO, S. W. KIM, J. Y. JUNG, AND S. J. KO, (2017) “High-dimensional feature extraction using bit-plane decomposition of local binary patterns for robust face recognition,” **J. Vis. Commun. Image Represent.**, vol. 45, pp. 11–19, 2017, doi: 10.1016/j.jvcir.2017.02.009.
- CALDEIRA, J., GAL, Y., HERNÁNDEZ-LOBATO, J. M., and BICKEL, P. J. (2020) Deeply uncertain: Comparing methods of uncertainty quantification in deep learning algorithms. **Journal of Machine Learning Research**, 21(223), 1-54. 2020.
- CHOUDHARY, K., DECOST, B., CHEN, C., JAÏN, A., TAVAZZA, F., COHN, R., PARK, C. W., CHOUDHARY, A., AGRAWAL, A., BILLINGE, S. J. L., HOLM, E., ONG, S. P., and WOLVERTON, C. (2023) Recent advances and applications of deep learning methods in materials science. **IEEE Access**, 11, 1050-1058. 2023

- D. S. KERMANY ET AL., (2018) "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," **Cell**, vol. 172, no. 5, pp. 1122-1131.e9, Feb. 2018, doi: 10.1016/j.cell.2018.02.010.
- D. VARSHNI, K. THAKRAL, L. AGARWAL, R. NIJHAWAN, AND A. MITTAL, (2019) "Pneumonia Detection Using CNN based Feature Extraction," **Proc. 2019 3rd IEEE Int. Conf. Electr. Comput. Commun. Technol. ICECCT 2019**, 2019, doi: 10.1109/ICECCT.2019.8869364.
- DAHL, G. E., SAINATH, T. N., and HINTON, G. E. (2013) Rectified linear units improve neural network acoustic models. In **IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)** (pp. 8609-8613). 2013.
- DAS, K., JIANG, J., and RAO, J. N. K. (2007) Mean squared error of empirical predictor. **The Annals of Statistics**, 35(4), 1879-1900. 2007.
- G. SRIVASTAVA, A. CHAUHAN, M. JANGID, AND S. CHAURASIA, (2022) "CoviXNet: A novel and efficient deep learning model for detection of COVID-19 using X-Ray images," **Biomed. Signal Process. Control**, vol. 78, no. February, p. 103848, 2022, doi: 10.1016/j.bspc.2022.103848.
- GAL, Y., and GHAHRAMANI, Z. (2016) Dropout as a Bayesian approximation: Representing model uncertainty in deep learning. **In Advances in neural information processing systems**, pp. 1050-1058, 2016
- GAWLIKOWSKI, J., NJEUTCHEU TASSI, C. R., ALI, M., LEE, J., HUMT, M., FENG, J., KRUSPE, A., TRIEBEL, R., JUNG, P., ROSCHER, R., SHAHZAD, M., YANG, W., BAMLER, R., and ZHU, X. X. (2023). A survey of uncertainty in deep neural networks. **IEEE Access**, 11, 1050-1058.
- H. BEHZADI-KHORMOUJI ET AL., (2019) "Deep learning, reusable and problem-based architectures for detection of consolidation on X-ray images," **Comput. Methods Programs Biomed.**, vol. 185, p. 105162, 2020, doi: 10.1016/j.cmpb.2019.105162.

- HASTIE, T., TIBSHIRANI, R., and FRIEDMAN, J. (2009) The elements of statistical learning: Data mining, inference and prediction. **Springer**. 2009.
- HERNÁNDEZ-LOBATO, A., and HERNÁNDEZ-LOBATO, J. M. (2016) Single-model uncertainties for deep learning. **Neural Networks**, 82, 156-168. 2016.
- HUANG, Q., SUN, S., DING, H., GAO, T., and GE, W. (2018) Bayesian inference with Markov chain Monte Carlo–based numerical approach for input model updating. **Computer Methods in Applied Mechanics and Engineering**, 339, 1219-1237. (2018).
- HUANG, Q., SUN, S., DING, H., GAO, T., and GE, W. (2018) Robust liver vessel extraction using 3D U-Net with variant dice loss function. *Computerized Medical Imaging and Graphics*, 69, 125-135. 2018.
- I. D. APOSTOLOPOULOS AND T. A. MPESIANA, (2020) “Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks,” **Phys. Eng. Sci. Med.**, pp. 1–8, 2020, doi: 10.1007/s13246-020-00865-4.
- I. E. LIVIERIS, A. KANAVOS, V. TAMPAKAS, AND P. PINTELAS, (2019) “A weighted voting ensemble self-labeled algorithm for the detection of lung abnormalities from X-rays,” **Algorithms**, vol. 12, no. 3, pp. 1–15, 2019, doi: 10.3390/A12030064.
- I. LIVIERIS, A. KANAVOS, AND P. (2019) Pintelas, “Detecting Lung Abnormalities from X-rays Using an Improved SSL Algorithm,” **Electron. Notes Theor. Comput. Sci.**, vol. 343, pp. 19–33, 2019, doi: 10.1016/j.entcs.2019.04.008.
- J. JASKARI ET AL., (2022) “Uncertainty-Aware Deep Learning Methods for Robust Diabetic Retinopathy Classification,” **IEEE Access**, vol. 10, no. July, pp. 76669–76681, 2022, doi: 10.1109/ACCESS.2022.3192024.
- J. P. COHEN, P. MORRISON, L. DAO, K. ROTH, T. DUONG, AND M. GHASSEM, (2020) “COVID-19 Image Data Collection: Prospective

Predictions are the Future,” **Mach. Learn. Biomed. Imaging**, vol. 1, no. December 2020, pp. 1–38, Dec. 2020, doi: 10.59275/j.melba.2020-48g7.

K. ADEM, S. KİLİÇARSLAN, AND O. CÖMERT, (2018) “Classification and diagnosis of cervical cancer with softmax classification with stacked autoencoder,” **Expert Syst. Appl.**, vol. 115, pp. 557–564, 2019, doi: 10.1016/j.eswa.2018.08.050.

K. C. SANTOSH, S. VAJDA, S. ANTANI, AND G. R. THOMA, (2016) “Edge map analysis in X-rays for automatic pulmonary abnormality screening,” **Int. J. Comput. Assist. Radiol. Surg.**, vol. 11, no. 9, pp. 1637–1646, 2016, doi: 10.1007/s11548-016-1359-6.

K. JAKHAR AND N. HOODA, (2018) “Big data deep learning framework using keras: A case study of pneumonia prediction,” 2018 4th Int. **Conf. Comput. Commun. Autom. ICCCA** 2018, pp. 1–5, 2018, doi: 10.1109/CCAA.2018.8777571

KATTENBORN, T., and ERASMI, S. (2020) Review on convolutional neural networks (CNN) in vegetation remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, 94, 102280. 2020.

KENDALL, A., and GAL, Y. (2017) What uncertainties do we need in Bayesian deep learning for computer vision? In **Advances in neural information processing systems** (pp. 5574-5584). 2017.

KINGMA, D. P., and WELING, M. LEAKY RELU: (2015) A simple way to improve deep neural networks. In Proceedings of the 2nd International **Conference on Learning Representations (ICLR)** (pp. 152-160). 2015.

L. LEI, S. W. KIM, W. J. PARK, D. H. KIM, AND S. J. KO, (2014) “Eigen directional bit-planes for robust face recognition,” **IEEE Trans. Consum. Electron.**, vol. 60, no. 4, pp. 702–709, 2014, doi: 10.1109/TCE.2014.7027346.

- L. YAO, E. POBLENZ, D. DAGUNTS, B. COVINGTON, D. BERNARD, AND K. LYMAN, (2017) “**Learning to diagnose from scratch by exploiting dependencies among labels,**” pp. 1–12, 2017.
- LIN, T.-Y., GOYAL, P., GIRSHICK, R., HE, K., and DOLLÁR, P. (2017) Focal loss for dense object detection. **Transactions on Pattern Analysis and Machine Intelligence**, 40(11), 2980-2994. 2017.
- LIU, W., LI, C., MA, L., DU, L., ZHANG, H., and JIANG, B. (2023) Deep learning based identification and uncertainty analysis of metro train induced ground-borne vibration. **Mechanical Systems and Signal Processing**, 189, 106262. 2023.
- M. ABDAR ET AL., (2022) “UncertaintyFuseNet: Robust uncertainty-aware hierarchical feature fusion model with Ensemble Monte Carlo Dropout for COVID-19 detection,” **Inf. Fusion**, vol. 90, no. July 2022, pp. 364–381, 2023, doi: 10.1016/j.inffus.2022.09.023.
- M. GOUR AND S. JAÏN, (2022) “Uncertainty-aware convolutional neural network for COVID-19 X-ray images classification,” **Comput. Biol. Med.**, vol. 140, no. July 2021, p. 105047, 2022, doi: 10.1016/j.compbimed.2021.105047.
- M. HEIKKILÄ, M. PIETIKÄINEN, AND C. SCHMID, (2008) “Description of interest regions with local binary patterns,” **Pattern Recognit.**, vol. 42, no. 3, pp. 425–436, 2009, doi: 10.1016/j.patcog.2008.08.014.
- M. K. ISLAM, S. U. HABIBA, T. A. KHAN, AND F. TASNİM, (2022) “COV-RadNet: A Deep Convolutional Neural Network for Automatic Detection of COVID-19 from X-Rays and CT Scans,” **Comput. Methods Programs Biomed. Updat.**, vol. 2, no. August, p. 100064, 2022, doi: 10.1016/j.cmpbup.2022.100064.
- M. K. MAHBUB, M. BISWAS, L. GAUR, F. ALENEZI, AND K. C. SANTOSH, (2022) “Deep features to detect pulmonary abnormalities in X-rays due to infectious diseaseX: Covid-19, pneumonia, and tuberculosis,” **Inf. Sci. (Ny).**, vol. 592, pp. 389–401, 2022, doi: 10.1016/j.ins.2022.01.062.

- M. TOĞAÇAR, B. ERGEN, AND Z. CÖMERT, (2019) “A Deep Feature Learning Model for Pneumonia Detection Applying a Combination of mRMR Feature Selection and Machine Learning Models,” **Irbm**, vol. 1, pp. 1–11, 2019, doi: 10.1016/j.irbm.2019.10.006.
- MADDOX, W. J., GARİPOV, T., IZMAİLOV, P., VETROV, D., and WILSON, A. G. (2019) A simple baseline for Bayesian uncertainty in deep learning. In Proceedings of the 33rd **International Conference on Neural Information Processing Systems** PP. 13063-13074. NIPS 2019.
- MANDAL, S., BEHERA, T. K., DESAİ, P. G., and NAİR, V. (2019) Reconciling modern machine-learning practice and the classical bias–variance trade-off. **Proceedings of the National Academy of Sciences**, 116(15), 7534-7539. 2019.
- N. DEY, Y. D. ZHANG, V. RAJİNİKANTH, R. PUGALENTHİ, AND N. S. M. RAJA, (2020) “Customized VGG19 Architecture for Pneumonia Detection in X-Rays,” **Pattern Recognit. Lett.**, vol. 143, pp. 67–74, 2021, doi: 10.1016/j.patrec.2020.12.010.
- N. SAPARKHOJAYEV, L. ZHOLAYEVA, Y. TASHKENBAYEV, AND D. TOKSEİT, (2021) Abnormality Detection in X-ray Images Using Uncertainty Prediction Algorithms, no. June 2021. **Springer International Publishing**, 2021. doi: 10.1109/ICECCO53203.2021.9663852.
- P. RAJPURKAR ET AL., (2017) “**CheXNet: Radiologist-Level Pneumonia Detection on X-Rays with Deep Learning**,” pp. 3–9, 2017.
- Q. WANG, Y. ZHENG, G. YANG, W. JİN, X. CHEN, AND Y. YİN, (2018) “Multiscale Rotation-Invariant Convolutional Neural Networks for Lung Texture Classification,” **IEEE J. Biomed. Heal. Informatics**, vol. 22, no. 1, pp. 184–195, 2018, doi: 10.1109/JBHI.2017.2685586.
- R. ARTHUR, (2003) “Interpretation of the paediatric x-ray,” **Curr. Paediatr.**, vol. 13, no. 6, pp. 438–447, 2003, doi: 10.1016/S0957-5839(03)00089-7.

- R. GAO ET AL., (2022) “Reducing uncertainty in cancer risk estimation for patients with indeterminate pulmonary nodules using an integrated deep learning model,” **Comput. Biol. Med.**, vol. 150, no. September, p. 106113, 2022, doi: 10.1016/j.compbiomed.2022.106113.
- R. SINGH AND A. KHARE, (2012) “Fusion of multimodal medical images using Daubechies complex wavelet transform - A multiresolution approach,” **Inf. Fusion**, vol. 19, no. 1, pp. 49–60, 2014, doi: 10.1016/j.inffus.2012.09.005.
- RUSSELL, R. L., and REALE, C. (2021) Multivariate uncertainty in deep learning. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, 44(1), 1-16. 2021.
- S. CALDERON-RAMÍREZ ET AL., (2021) “Improving Uncertainty Estimation with Semi-Supervised Deep Learning for COVID-19 Detection Using X-Ray Images,” **IEEE Access**, vol. 9, pp. 85442–85454, 2021, doi: 10.1109/ACCESS.2021.3085418.
- S. ARUNMOZHÌ, V. RAJÌNIKANTH, AND M. P. RAJAKUMAR, (2021) “Deep-Learning based Automated Detection of Pneumonia in Radiographs,” 2021 Int. Conf. Syst. **Comput. Autom. Networking, ICSCAN** 2021, pp. 17–20, 2021, doi: 10.1109/ICSCAN53069.2021.9526482.
- S. EİNY, C. OZ, AND Y. D. NAVAEİ, (2020) “The Anomaly- And Signature-Based IDS for Network Security Using Hybrid Inference Systems,” **Math. Probl. Eng.**, vol. 2021, 2021, doi: 10.1155/2021/6639714.
- S. EİNY, C. OZ, AND Y. D. NAVAEİ, (2021) “IoT Cloud-Based Framework for Face Spoofing Detection with Deep Multicolor Feature Learning Model,” **J. Sensors**, vol. 2021, no. 5047808, p. 18, 2021, doi: <https://doi.org/10.1155/2021/5047808>.
- S. EİNY, C. OZ, AND Y. D. NAVAEİ, (2021) “Network Intrusion Detection System Based on the Combination of Multiobjective Particle Swarm Algorithm-Based Feature Selection and Fast-Learning Network,” **Wirel. Commun. Mob. Comput.**, vol. 2021, 2021, doi: 10.1155/2021/6648351.

- S. EİNY, H. SAYGİN, H. HİVEHCH, AND Y. DOROSTKAR NAVAEİ, (2022) “Local and Deep Features Based Convolutional Neural Network Frameworks for Brain MRI Anomaly Detection,” **Complexity**, vol. 2022, pp. 1–11, 2022, doi: 10.1155/2022/3081748.
- S. JAEGER ET AL. (2014), “Automatic Tuberculosis Screening Using Radiographs,” **IEEE Trans. Med. Imaging**, vol. 33, no. 2, pp. 233–245, 2014.
- S. JAEGER, S. CANDEMİR, S. ANTANI, Y.-X. J. WÁNG, P.-X. LU, AND G. THOMA, (2014) “Two public X-ray datasets for computer-aided screening of pulmonary diseases.,” **Quant. Imaging Med. Surg.**, vol. 4, no. 6, pp. 475–477, 2014, doi: 10.3978/j.issn.2223-4292.2014.11.20.
- SCHROFF, F., KALENİCHENKO, D., and PHİLBİN, J. (2015) Facenet for a unified embedding for face recognition and clustering. **In Proceedings of the conference on computer vision and pattern recognition** (pp. 853-863). 2015.
- SHEN, L., CHENG, W., LİN, Z., and WANG, G. (2020) On mean absolute error for deep neural network based vector-to-vector regression. **Transactions on Pattern Analysis and Machine Intelligence**, 43(1), 135-147. 2020.
- SRİVASTAVA, N., HİNTON, G. E., GRAVES, A., and SALAKHUTDİNOV, R. (2014) Dropout: A simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, 15(1), 1929-1958. 2014.
- ŞEKER, A., DİRİB, B., ve BALIK, H. H. (2023) Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. **Signal Processing Magazine**, 30(6), 23-38. 2023.
- T. AHONEN, A. HADİD, AND M. PİETİKÄİNEN, (2006) “Face description with local binary patterns: Application to face recognition,” **IEEE Trans. Pattern Anal. Mach. Intell.**, vol. 28, no. 12, pp. 2037–2041, 2006, doi: 10.1109/TPAMI.2006.244.

- T. B. CHANDRA, K. VERMA, B. K. SINGH, D. JAİN, AND S. S. NETAM, (2020) “Automatic detection of tuberculosis related abnormalities in X-ray images using hierarchical feature extraction scheme,” **Expert Syst. Appl.**, vol. 158, p. 113514, 2020, doi: 10.1016/j.eswa.2020.113514.
- T. OJALA, M. PIETIKÄINEN, AND D. HARWOOD, (1996) “A comparative study of texture measures with classification based on feature distributions,” **Pattern Recognit.**, vol. 29, no. 1, pp. 51–59, 1996, doi: 10.1016/0031-3203(95)00067-4.
- U. K. LOPES AND J. F. VALIATI, (2017) “Pre-trained convolutional neural networks as feature extractors for tuberculosis detection,” **Comput. Biol. Med.**, vol. 89, no. February, pp. 135–143, 2017, doi: 10.1016/j.combiomed.2017.08.001.
- ULMER, D., HARDMEIER, C., and FRELLSEN, J. (2021) Prior and posterior networks: A survey on evidential deep learning methods for uncertainty estimation. **Transactions on Pattern Analysis and Machine Intelligence**, 44(12), 1-14. 2021.
- VOLLMER, K., KRÜGER, B., BÜCHEL, M., LEMMERICH, F., and HOBFELD, T. (2018) Uncertainty in machine learning applications: A practice-driven classification of uncertainty. **24th International Conference on Pattern Recognition (ICPR)** (pp. 2491-2496). 2018.
- W. YANG, J. LI, W. PENG, AND A. DENG, (2020) “A Pneumonia Detection Method Based on Improved Convolutional Neural Network,” **Comput. Mater. Contin.**, vol. 62, no. 3, pp. 283–299, 2020, doi: 10.32604/cmc.2020.07511.
- WEICKENMEIER, S., VERHOOSSEL, K., and WRIGGERS, P. (2022) Recurrent neural networks (RNNs) with dimensionality reduction and break down in computational mechanics; application to multi-scale localization step. **Computer Methods in Applied Mechanics and Engineering**, 390, 114769. 2022.

- WELLING, M., SNOEK, J., and O'HAGAN, T. (2019) On calibrated model uncertainty in deep learning. **Journal of the Royal Statistical Society: Series B (Statistical Methodology)**, 81(1), 269-284, 2019.
- X. LI ET AL., (2019) "Multi-resolution convolutional networks for X-ray radiograph based lung nodule detection," **Artif. Intell. Med.**, vol. 103, no. October 2018, p. 101744, 2020, doi: 10.1016/j.artmed.2019.101744.
- X. WANG, Y. PENG, L. LU, Z. LU, M. BAGHERI, AND R. M. SUMMERS, (2019) "X-ray: Hospital-Scale X-ray Database and Benchmarks on Weakly Supervised Classification and Localization of Common Thorax Diseases," **Adv. Comput. Vis. Pattern Recognit.**, pp. 369–392, 2019, doi: 10.1007/978-3-030-13969-8_18.
- Y. A. NANEHKARAN ET AL., (2022) "Diagnosis of Chronic Diseases Based on Patients' Health Records in IoT Healthcare Using the Recommender System," **Wirel. Commun. Mob. Comput.**, vol. 2022, pp. 1–14, 2022, doi: 10.1155/2022/5663001.
- Y. BENGIO, A. COURVILLE, AND P. VINCENT, (2013) "Representation learning: A review and new perspectives," **IEEE Trans. Pattern Anal. Mach. Intell.**, vol. 35, no. 8, pp. 1798–1828, 2013, doi: 10.1109/TPAMI.2013.50.
- Y. SONG, W. CAI, Y. ZHOU, AND D. D. FENG, (2013) "Feature-based image patch approximation for lung tissue classification," **IEEE Trans. Med. Imaging**, vol. 32, no. 4, pp. 797–808, 2013, doi: 10.1109/TMI.2013.2241448.
- Y. XIE ET AL., (2019) "Knowledge-based Collaborative Deep Learning for Benign-Malignant Lung Nodule Classification on CT," **IEEE Trans. Med. Imaging**, vol. 38, no. 4, pp. 991–1004, 2019, doi: 10.1109/TMI.2018.2876510.
- Y. YANG, J. YU, H. JIANG, W. HAN, J. ZHANG, AND W. JIANG, (2022) "A contrastive triplet network for automatic X-ray reporting," **Neurocomputing**, vol. 502, pp. 71–83, 2022, doi: 10.1016/j.neucom.2022.06.063.

YENDAPALLI, V., and REDDY, P. V. G. D. P. (2020) Binary cross entropy with deep learning technique for image classification. *International Journal of Advanced Trends in Computer Science and Engineering*, 9(4), 3778-3784. 2020.

YUSHI CHEN, ZHOULAN LIN, AND Y. G. XING ZHAO, GANG WANG, (2015) "Deep Learning-Based Classification of Hyperspectral Data," *IEEE J. Sel. Top. Appl. EARTH Obs. Remote Sens.*, vol. 7, no. June 2014, pp. 1–14, 2015, doi: 10.1109/JSTARS.2014.2329330.

Z. WANG, J. XIN, P. SUN, Z. LIN, Y. YAO, AND X. (2018) Gao, "Improved lung nodule diagnosis accuracy using lung CT images with uncertain class," *Comput. Methods Programs Biomed.*, vol. 162, pp. 197–209, 2018, doi: 10.1016/j.cmpb.2018.05.028.

ZHAO, R., QIAN, B., HE, L., PENG, Y., PAN, Y., and YAN, J. (2020) Rethinking Dice loss for medical image segmentation *Transactions on Medical Imaging*, 40(11), 2770-2781. 2020.

ZHAO, Y., ZHOU, J., and ZHAO, Y. (2023) An Essay Toward Solving a Problem in the Doctrine of Chances by Thomas Bayes Assessing the uncertainty of deep learning soil spectral models using Bayesian neural networks. *Transactions on Geoscience and Remote Sensing*, 61(3), 1-12. 2023.

TEZLER

ALEX GUY KENDALL, (2018) "Geometry and Uncertainty in Deep Learning for Computer Vision," Ph.D. dissertation, Department of Engineering, University of Cambridge, 2018.

ELEKTRONİK KAYNAKLAR

URL1: <https://www.inovex.de/de/blog/uncertainty-quantification-deep-learning/>

URL2: <https://github.com/omindrot/tensorflow-triplet-loss>

URL3: <https://stackoverflow.com/questions/45650695/how-to-plot-the-typical-bowl-shape-when-illustrating-gradient-descent-with-matpl>

URL4:<https://medium.com/intro-to-artificial-intelligence/the-link-betweenmaximum-likelihood-estimation-mle-and-cross-entropy-599cc1414753>

ÖZGEÇMİŞ

Aşağıdaki gösterildiği üzere yüksek öğrenimi tamamladı. Bu süre zarfında Tübitak destekli ulusal ve uluslararası birçok projede görev aldı ve bu alanlarda çeşitli makale ve kitap bölümleri yayınladı.

ÖĞRENİM DURUMU:

- **Lisans:** Fırat Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
- **Yüksek Lisans :** Sakarya Üniversitesi, Bilgisayar ve Bilişim Mühendisliği
- **Lisans:** Dicle Üniversitesi, Eğitim Fakültesi, İlköğretim Matematik Öğretmenliği