

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MATEMATİK MÜHENDİSLİĞİ ANABİLİM DALI

SİNİR AĞLARINDA ÖZELLEŞTİRİLMİŞ DEĞERLER İLE AĞIRLIKLARIN
BAŞLATILMASI VE SINIFLANDIRMA SONUÇLARINA ETKİLERİNİN
İNCELENMESİ

YÜKSEK LİSANS

Hüseyin Kamer KARA

MAYIS-2024
GÜMÜŞHANE



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

MATEMATİK MÜHENDİSLİĞİ ANABİLİM DALI

**SİNİR AĞLARINDA ÖZELLEŞTİRİLMİŞ DEĞERLER İLE AĞIRLIKLARIN
BAŞLATILMASI VE SINIFLANDIRMA SONUÇLARINA ETKİLERİNİN
İNCELENMESİ**

**INITIALIZATION OF WEIGHTS WITH CUSTOMIZED VALUES IN NEURAL
NETWORKS AND INVESTIGATION OF THEIR EFFECTS ON
CLASSIFICATION RESULTS**

YÜKSEK LİSANS

Hüseyin Kamer KARA

**MAYIS-2024
GÜMÜŞHANE**



T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

MATEMATİK MÜHENDİSLİĞİ ANABİLİM DALI

**SİNİR AĞLARINDA ÖZELLEŞTİRİLMİŞ DEĞERLER İLE AĞIRLIKLARIN
BAŞLATILMASI VE SINIFLANDIRMA SONUÇLARINA ETKİLERİNİN
İNCELENMESİ**

**INITIALIZATION OF WEIGHTS WITH CUSTOMIZED VALUES IN NEURAL
NETWORKS AND INVESTIGATION OF THEIR EFFECTS ON
CLASSIFICATION RESULTS**

YÜKSEK LİSANS

Hüseyin Kamer KARA

Danışman: Dr. Öğr. Üyesi Özkan BİNGÖL

MAYIS-2024
GÜMÜŞHANE

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Yüksek Lisans Tezi olarak hazırlamış olduğum “**Sinir Ağlarında Özelleştirilmiş Değerler İle Ağırlıkların Başlatılması Ve Sınıflandırma Sonuçlarına Etkilerinin İncelenmesi**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmaları kaynakçada belirttiğimi ve Gümüşhane Üniversitesi’nin lisanslı kullanıcısı olduğu intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü’nün belirlediği kıstaslara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

20/05/2024

.....
Hüseyin Kamer KARA

TEŞEKKÜR

Bu tez çalışmamın her aşamasında yanımda olan, bilgi ve deneyimlerini benimle paylaşarak akademik ve kişisel gelişimime katkıda bulunan danışman hocam Dr. Öğr. Üyesi Özkan BİNGÖL'e şükranlarımı sunarım. Bana gösterdiği sabır, verdiği destek ve değerli yönlendirmeleri için minnettarım.

Tez çalışması TÜBİTAK 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı tarafından desteklenen 122E402 nolu "Kısıtlamasız Ortamda Alınan El Görüntülerinden Biyometrik Doğrulama İçin Güvenilir Avuç İzi Bölgesinin Tespiti" isimli proje kapsamında gerçekleştirilmiştir. Bu desteklerinden dolayı TÜBİTAK'a teşekkürlerimi sunarım.

Ayrıca, bu yolculukta her zaman beni motive eden, başarılarımı kutlayan ve zor zamanlarımda yanımda olan annem Nurten KARA ve babam Ayhan KARA'ya, kardeşlerim Yusuf Eymen KARA ve Muhammed Emin KARA'ya, her zorluğumda yanımda olan Beyza ARAL'a teşekkürlerimi sunarım..

Hüseyin Kamer KARA
GÜMÜŞHANE – 2024

ÖZET

Evrişimli sinir ağı modellerinin evrişim katmanlarının başlangıç değerlerinin belirlenmesi, ağı öğrenme sürecini ve nihai performansını doğrudan etkileyen kritik bir konudur. Yanlış belirlenmiş başlangıç değerleri, gradyan patlaması veya yok olması gibi sorunlara yol açabilir. Bu nedenle, doğru ağırlık başlatma stratejilerinin geliştirilmesi, derin öğrenme modellerinin etkinliğini ve verimliliğini artırmak için önemlidir.

Bu tezde, ESA'lardaki evrişim katmanlarının başlangıç değerlerinin belirlenmesinde kullanılan yöntemlerin avantaj ve dezavantajları karşılaştırılmıştır. Xavier, He, sabit değer ve sıfır değer başlatma gibi yaygın yöntemlerin yanı sıra, Gabor filtreleri gibi yenilikçi yaklaşımlar da ele alınmıştır. Gabor filtrelerinin biyolojik görme sistemini taklit eden özellikleri sayesinde, ağırlık başlatma olarak kullanıldığında ağı öğrenme sürecini hızlandırma ve genelleme performansını artırma potansiyeli bulunmaktadır. Bu yöntemlerin performans üzerindeki etkileri, literatürde yaygın olarak kullanılan FashionMNIST veri seti ve IITD Temassız Avuçizi veritabanı ile test edilmiştir.

Deneysel çalışmalarda, ağırlık başlatma yöntemlerinin doğrudan performans üzerindeki etkilerini gözlemlemek için basit ağ modelleri kullanılmıştır. Bu yaklaşım, farklı başlatma stratejilerinin teorik avantajlarını pratikte gözlemlemeyi ve karşılaştırmayı mümkün kılmaktadır. Ortak parametrelerin kullanılması, ağırlık başlatma yöntemlerinin karşılaştırılabilirliğini artırmakta ve hangi yöntemin hangi koşullar altında daha üstün performans sergilediğini anlamayı kolaylaştırmaktadır. Bu metodoloji, çalışmanın sonuçlarının güvenilirliğini ve geçerliliğini artırarak literatüre sağlam ve tekrarlanabilir bulgular sunmayı amaçlamaktadır.

Anahtar Kelimeler: Evrişim katmanı, Evrişimli sinir ağları, Gabor filtreleri.

SUMMARY

Determining the initial values of convolutional layers in convolutional neural network (CNN) models is a critical issue that directly impacts the learning process and ultimate performance of the network. Incorrectly set initial values can lead to problems such as gradient explosion or vanishing, hindering the training process. Therefore, developing correct weight initialization strategies is essential for enhancing the effectiveness and efficiency of deep learning models.

In this thesis, the advantages and disadvantages of the methods used to determine the initial values of convolutional layers in CNNs are compared. In addition to commonly used methods such as Xavier, He, fixed value, and zero initialization, innovative approaches like Gabor filters are also considered. Due to their ability to mimic the biological visual system, Gabor filters have the potential to accelerate the learning process and improve the generalization performance of the network when used as weight initialization. The effects of these methods on performance have been tested using the widely recognized FashionMNIST dataset and the IITD Touchless Palmprint database.

In the experimental studies, simple network models were used to observe the direct effects of weight initialization methods on performance. This approach allows for practical observation and comparison of the theoretical advantages of different initialization strategies. The use of common parameters increases the comparability of weight initialization methods and facilitates understanding which method performs better under specific conditions. This methodology aims to enhance the reliability and validity of the study's results, providing robust and replicable findings to the literature.

Keywords: Convolutional layer, Convolutional neural networks, Gabor filters.

İÇİNDEKİLER

KABUL VE ONAY	III
BİLİMSEL ETİĞE UYGUNLUK BEYANI.....	IV
TEŞEKKÜR.....	V
ÖZET.....	VI
SUMMARY	VII
İÇİNDEKİLER	VIII
TABLolar DİZİNİ	X
ŞEKİLLER DİZİNİ.....	XI
SİMGELER VE KISALTMALAR DİZİNİ	XIII
1. GİRİŞ	1
1.1. Yapay Sinir Ağları	1
1.2. Derin Sinir Ağları.....	3
1.3. Evrişimsel Sinir Ağları.....	5
1.4. YSA Ağırlıklarının Başlangıç Değerlerinin Belirlenmesi	7
1.5. Evrişim Katmanlarının Başlangıç Değerlerinin Belirlenmesi.....	8
1.6. Tezin Amacı ve Kapsamı	8
2. LİTERATÜR ÖZETİ	11
3. MATERYAL VE YÖNTEMLER.....	17
2.1. FashionMNIST Veri Kümesi	17
2.1. Basit Ağ Model Yapısı.....	18
2.2. Evrişimli Basit Ağ Model Yapısı	20
2.3. Evrişim Katmanlarının Başlangıç Değerlerinin Belirlenmesi.....	20
2.4. Gabor Filtreleri.....	22
2.5. Avuç İzi Tanıma.....	24
2.6. IITD Palmprint Avuç İzi Veritabanı	27
3. YAPILAN ÇALIŞMALAR VE BULGULAR	28
3.1. Basit Ağ Modelinin Uygulanması.....	28
3.2. Tek Evrişim Katmanının Sınıflandırmaya Etkisi.....	31
3.3. Sabit Değerlerle Başlatma	31
3.3.1. Sabit Sıfır (0) Değerleriyle Başlatma	32
3.3.2. Sabit Bir (1) Değerleriyle Başlatma	35
3.3.3. Çok Küçük Değerlerle Başlatma.....	38

3.3.4. Çok Büyük Değerlerle Başlatma.....	40
3.4. Rastgele Değerlerle Başlatma	44
3.4.1. He-Kaiming Katsayılarıyla İlk Değerlerin Belirlenmesi	44
3.4.2. Normal Dağılımla Başlatma.....	47
3.4.3.Uniform Dağılımla Başlatma	49
3.4.4. Xavier Katsayılarıyla İlk Değerlerin Belirlenmesi.....	53
3.5. Gabor Filtreleri İle Başlatma.....	56
3.6. Çoklu Evrişim Katmanı ve İlkendirme Stratejileri	72
3.7. Avuç İzi Tanımda Gabor Filtreleriyle İlkendirme	75
4. SONUÇLAR VE TARTIŞMA	80
KAYNAKÇA.....	82
ÖZGEÇMİŞ	88

TABLÖLAR DİZİNİ

Tablo 1. Basit ağ modelinden elde edilen ortalama başarımlar değerleri	30
Tablo 2. Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	34
Tablo 3. Sabit bir (1) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	37
Tablo 4. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	40
Tablo 5. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	43
Tablo 6. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	46
Tablo 7. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	49
Tablo 8. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	52
Tablo 9. Xavier başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.	55
Tablo 10. 3x3 Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	59
Tablo 11. 5x5'lik Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	62
Tablo 12. 7x7'lik Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	65
Tablo 13. 9x9'luk Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	68
Tablo 14. 9x9'luk Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	71
Tablo 15. 9x9'luk Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.....	74
Tablo 16. Gabro filtreleri başlangıç değerleri ile başlatılan avuç izi doğrulama ağ modelinden elde edilen başarımlar değerleri.	79

ŞEKİLLER DİZİNİ

Şekil 1. Basit bir yapay sinir ağı modeli	2
Şekil 2. Örnek bir ESA modeli (URL - 1)	5
Şekil 3. Örnek bir evrişim işlemi	6
Şekil 4. FashionMNIST verisetinden örnek görüntüler (Sasao, 2024).	18
Şekil 5. Basit ağ model yapısı	19
Şekil 6. Evrişim katmanını eklenmiş basit ağ model yapısı.....	20
Şekil 7. Örnek bir Gabor filtre bankası (URL - 1).	23
Şekil 8. Bir görüntüye uygulana farklı Gabor filtreleri (URL - 2). Örnek bir Gabor filtre bankası (Kamarainen, 2012).	24
Şekil 9. IITD Temassız Avuçizi Veritabanından örnek görüntüler. Bir görüntüye uygulana farklı Gabor filtreleri (URL - 3).	27
Şekil 10. İki katmanlı YSA modelinden elde edilen başarımlar	29
Şekil 11. Basit ağ modelinden elde edilen ortalama başarımlar	30
Şekil 12.Sabit Sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.....	32
Şekil 13.Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen doğruluk değerleri.....	33
Şekil 14.Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar	34
Şekil 15. .Sabit bir (1) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar	36
Şekil 16. .Sabit bir (1) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar	36
Şekil 17.Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar	38
Şekil 18.Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar	39
Şekil 19.Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.	41
Şekil 20.Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen doğruluk değerleri.	42
Şekil 21.Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama değerler.	42

Şekil 22. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.	45
Şekil 18. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.	45
Şekil 24. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	47
Şekil 25. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.	48
Şekil 26. Uniform dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	51
Şekil 27. Uniform dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	54
Şekil 28. 3x3'lük 64 adet Gabor filtreleri bankası.	57
Şekil 29. 3x3'lük Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	58
Şekil 30. 5x5'lik 64 adet Gabor filtreleri bankası.	60
Şekil 31. 5x5'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	61
Şekil 32. 7x7'lik 64 adet Gabor filtreleri bankası.	63
Şekil 33. 7x7'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	64
Şekil 34. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	66
Şekil 35. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	67
Şekil 36. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	69
Şekil 37. 11x11'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	70
Şekil 38. 11x11'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımların değerleri.	73
Şekil 39. Avuçizi doğrulama sistemi.	76
Şekil 39. Örnek avuçizi ROI'leri.	76
Şekil 41. Gabor filtreleri başlangıç değerleri ile başlatılan avuç izi doğrulama ağı modelinden elde edilen başarımların değerleri.	78

SİMGELER VE KISALTMALAR DİZİNİ

BBA	: Bağımsız Bileşenler Analizi
DİA	: Derin İnanç Ağları
DVM	: Destek Vektör Makineleri
EOK	: Evrişimli Otomatik Kodlayıcı
ESA	: Evrişimli Sinir Ağları
KA	: Karar Ağaçları
k-NN	: k-En Yakın Komşu
LSTM	: Uzun Kısa Süreli Bellek
ReLU	: Rectified Linear Unit
RNN	: Recurrent Neural Networks
tanh	: hiperbolik
TBA	: Temel Bileşen Analizi
TESA	: Tensörlü Evrişimli Sinir Ağları
YSA	: Yapay Sinir Ağları

1. GİRİŞ


1.1. Yapay Sinir Ağları

Son yıllarda, bilim insanları, büyük miktarda bilgi depolamaya dayanan geleneksel yapay zekâ yaklaşımlarını terk ederek, insan düşünme süreçlerini taklit eden daha basit veri işleme yöntemlerine odaklanmışlardır. Bu dönüşüm, Yapay Sinir Ağları (YSA) ve derin öğrenme yöntemlerinin geliştirilmesine yol açmıştır.

YSA'nın kökeni, 1943 yılında McCulloch ve Pitts tarafından sinir hücrelerinin matematiksel bir modeli olarak geliştirilmiştir (McCulloch ve Pitts, 1943). Bu model, basit bir şekilde biyolojik nöronların nasıl çalıştığını açıklamaya çalışıyordu. Daha sonra, 1958 yılında Frank Rosenblatt tarafından geliştirilen Perceptron, YSA'nın ilk uygulamalı modeli olarak kabul edilmektedir (Rosenblatt, 1958). Bu model, temel olarak ikili sınıflandırma problemlerini çözmek için kullanılmıştır.

1980'lerde ve 1990'larda, YSA araştırmaları, bilgi işlem gücünün yetersizliği ve veri setlerinin sınırlı olması nedeniyle yavaşlamıştı. Ancak, 2000'li yılların başında, veri depolama ve işlem gücündeki büyük ilerlemeler, derin öğrenme yöntemlerinin yeniden popülerlik kazanmasına yol açtı (LeCun vd., 2015). Bu dönemde, Hinton vd. (2006) tarafından geliştirilen Derin İnanç Ağları (DİA) ve Evrimsel Sinir Ağları (ESA), özellikle görüntü ve konuşma tanıma alanlarında büyük başarılarla imza atmıştır (Hinton vd., 2006).

YSA'nın temel yapı taşları, yapay nöronlar veya düğümler olarak adlandırılan birimlerden oluşmaktadır. Her yapay nöron, belirli bir girdiyi alır, bu girdiyi işlemekte ve ardından bir çıktı üretmektedir. Yapay sinir hücreleri, Şekil 1.'de gösterildiği gibi ağırlıklandırılmış bağlantılar aracılığıyla birbirlerine bağlanmakta ve bu bağlantılar gerçek sinir hücrelerindeki sinapsların işlevini taklit etmektedirler. Bu ağırlıklar, sinir ağının öğrenme sürecinde sürekli olarak güncellenmektedirler ve modelin veri üzerindeki performansını doğrudan etkilemektedirler.



Şekil 1. Basit bir yapay sinir ağı modeli

Bir yapay sinir hücresinin çıktısı, aktivasyon fonksiyonu adı verilen bir matematiksel fonksiyon aracılığıyla belirlenir (Goodfellow vd., 2016). En yaygın kullanılan aktivasyon fonksiyonları arasında sigmoid, tanjant hiperbolik (tanh) ve Rectified Linear Unit (ReLU) bulunur. Sigmoid fonksiyonu, çıktıyı 0 ile 1 arasında sınırlarken, tanh fonksiyonu -1 ile 1 arasında bir çıktı üretmektedir. ReLU fonksiyonu ise, girdinin pozitif olması durumunda girdiyi olduğu gibi geçirmektedir, negatif olması durumunda ise çıktıyı sıfır yapmaktadır. Bu fonksiyonlar, ağıın doğrusal olmayan ilişkileri öğrenmesine yardımcı olmaktadır (Nair ve Hinton, 2010).

Yapay sinir ağları, öğrenme sürecinde ileri besleme ve geri yayılım algoritmalarını kullanmaktadır. İleri besleme sürecinde, veri, giriş düğümlerinden geçerek ağıın çıkış düğümlerine ulaşmaktadır. Bu aşamada, her bir yapay nöron, aldığı girdiyi işlemekte ve bir sonraki katmana aktarmaktadır. Girdiler, ağırlıklandırılmış bağlantılar aracılığıyla bir yapay nörondan diğerine iletilmektedir ve her bir bağlantının ağırlığı, ağıın öğrenme sürecinde güncellenmektedir (LeCun vd. 2015).

Sinir ağı eğitimi, ağı parametreleri üzerinde bir maliyet fonksiyonunu optimize etmeyi içermektedir. Bu parametreler, maliyet fonksiyonu en aza inecek şekilde ayarlanmaktadır (Duch vd.,1998). Rumelhart vd. (1985) tarafından popüler hale getirilen geri yayılım algoritması, sinir ağlarını eğitmek için temel bir yöntem olmuştur. Bu algoritma, tahmin edilen ve gerçek çıktılar arasındaki hatayı minimize etmek için ağırlıkları iteratif olarak ayarlamaktadır. Sinir ağlarının yakınsaması, yalnızca maliyet fonksiyonunun küresel minimumuna ulaşmakla ilgili değildir, aynı zamanda alt-optimal çözümlerle sonuçlanan yerel minimumlardan kaçınmayı da içermektedir.

1.2. Derin Sinir Ağları

Derin öğrenme, insan beyninin verileri işleme şeklini taklit eden yapay sinir ağları üzerine kurulu bir makine öğrenme yöntemidir. Derin öğrenme, özellikle çok sayıda katmana sahip sinir ağları kullanılarak gerçekleştirilen, daha karmaşık veri yapılarını modelleme yeteneğine sahiptir (LeCun vd., 2015).

Geleneksel makine öğrenimi teknikleri, ham verileri doğrudan işleme yetenekleri bakımından sınırlıdır. Bu tekniklerde, ham verilerin (örneğin bir görüntünün piksel değerleri gibi) uygun bir iç temsile veya özellik vektörüne dönüştürülmesi, genellikle insan mühendisler tarafından dikkatlice tasarlanmış özellik çıkarıcıları gerektirir (Bengio vd., 2013). Temsil öğrenimi, bu süreci otomatikleştirerek, makinenin ham verilerden algılama veya sınıflandırma için gerekli temsilleri keşfetmesine olanak tanımaktadır. Derin öğrenme yöntemleri, bu temsilleri çok katmanlı bir yapıda öğrenmekte, her katman bir öncekine göre daha yüksek bir soyutlama seviyesinde temsil sağlamaktadır (Goodfellow vd., 2016).

Derin öğrenme modelleri, insan gözlemcisinin kolayca başaramayacağı düzeyde, verilerden karmaşık ve soyut özellikler çıkarma kapasitesine sahiptir. Bu modeller, her katmanda ham verilerden giderek daha anlamlı özellikler çıkarmayı öğrenirler (Goodfellow vd., 2016). İlk katmanlar genellikle basit özellikleri, örneğin kenarları veya renkleri tespit ederken, daha derin katmanlar bu basit özellikleri kullanarak nesnelerin bölümlerini veya tamamını tespit edebilirler.

Derin öğrenmenin sunduğu avantajlar, onun pek çok alanda uygulanabilirliğini ve etkinliğini açıkça ortaya koymaktadır. Bu avantajların başında, veriler içerisindeki karmaşık yapıları modelleyebilme kapasitesi gelmektedir. Derin öğrenme, birden fazla işlem katmanı kullanarak girdi olarak aldığı ham veriden başlayıp, bu verileri aşamalı bir şekilde daha yüksek düzeyde soyutlamalarla işleyebilmektedir. Bu süreçte, her katman önceki katmandan gelen bilgiyi dönüştürür ve böylece model, veri setindeki önemli özellikleri ve ilişkileri otomatik olarak belirleyebilir (LeCun vd., 2015).

Bir diğer önemli avantajı, özellik çıkarımının otomatikleştirilmesidir. Geleneksel makine öğrenimi modellerinde, özellik çıkarımı için genellikle uzman müdahalesi gereklidir. Ancak derin öğrenme, veri setlerinden otomatik olarak etkili özellikler çıkarabilmektedir, bu da modelin daha genel ve esnek olmasını sağlamaktadır. Örneğin, derin sinir ağları görüntü işlemede pikseller üzerinden doğrudan çalışabilir ve gerekli tüm özellikleri veriden öğrenebilir, bu da zaman alıcı ve maliyetli özellik mühendisliği gereksinimini ortadan kaldırmaktadır (Goodfellow vd., 2016).

Ayrıca, derin öğrenme modelleri, farklı veri türlerine geniş adaptasyon yeteneğine sahiptir. Görüntü, ses, metin gibi çok çeşitli veri türlerini işleyebilir ve bu sayede çok yönlü kullanım alanlarına imkan tanır. Özellikle, birden fazla veri türünün entegre edildiği görevlerde, derin öğrenme modelleri etkileyici sonuçlar sunmaktadır. Örneğin, bir robotun çevresini algılama yeteneği, hem görsel hem de işitsel bilgileri işleyebilen derin öğrenme modelleri ile büyük ölçüde geliştirilebilir (Hinton vd., 2012).

Derin öğrenme, son yıllarda görsel ve işitsel tanıma sistemlerinde önemli başarılar elde etmiştir. Örneğin, konuşma tanıma, görsel nesne tanıma ve doğal dil işleme gibi alanlarda çok önemli başarılar elde edilmiştir (Hinton vd., 2012). Bu başarılar, derin öğrenme modellerinin, geleneksel makine öğrenme tekniklerine göre daha etkili ve verimli olduğunu göstermektedir. Derin öğrenme aynı zamanda tıp, otomotiv ve finans gibi çeşitli endüstriyel uygulamalarda da kullanılmaktadır. Örneğin, tıbbi görüntüleme analizinde, derin öğrenme tabanlı sistemler, kanser tespiti gibi karmaşık görevlerde yüksek doğruluk oranları sunmaktadır (Esteva vd., 2017).

Derin öğrenmenin pek çok avantajı bulunmasına rağmen, bu yöntem bazı dezavantajlar ve sınırlamalar da içermektedir. İlk olarak, derin öğrenme modellerinin büyük miktarlarda etiketli veriye ihtiyaç duyması önemli bir dezavantajdır. Yüksek performanslı derin öğrenme sistemlerinin eğitimi genellikle büyük ve çeşitlendirilmiş veri setlerini gerektirir. Etiketli verilerin hazırlanması ise zaman alıcı ve maliyetli bir süreçtir. Özellikle, nadir olaylar veya özel durumlar için yeterli miktarda etiketli veri toplamak zor olabilir (Zhu ve Goldberg, 2009).

İkinci olarak, derin öğrenme modelleri "kara kutu" olarak algılanabilir, yani bu modellerin nasıl ve neden belirli tahminlerde bulundukları çoğu zaman şeffaf değildir. Bu durum, özellikle tıp ve hukuk gibi yüksek derecede doğruluk ve açıklama gerektiren alanlarda ciddi sorunlara yol açabilir. Modelin karar verme sürecini anlamak ve yorumlamak zordur, bu da modelin güvenilirliği üzerinde şüphelere neden olabilir (Castelvecchi, 2016).

Derin öğrenme modelleri, eğitildikleri veri setlerindeki önyargıları öğrenme eğilimindedir. Eğitim verileri çeşitli sosyo-demografik grupları adil bir şekilde temsil etmiyorsa, model de bu önyargıları yansıtacak ve hatta pekiştirebilir. Bu, algoritmik önyargı ve adaletsizlik sorunlarına yol açabilir, dolayısıyla bu modellerin etik kullanımı büyük bir dikkat gerektirir (Barocas ve Selbst, 2016). Bununla beraber, derin öğrenme modellerinin genelleştirme kabiliyeti, eğitim verilerinin kalitesi ve çeşitliliği ile doğrudan ilişkilidir. Model, eğitim setinde görmemiş olduğu yeni durumlarla karşılaştığında, beklenmeyen şekilde davranabilir veya hatalı tahminler yapabilir. Bu, modelin gerçek


dünya senaryolarında nasıl performans göstereceği konusunda belirsizliklere yol açar (Szegedy vd., 2013).

Derin öğrenme modellerinin en önemli sorunlarından biri özellikle büyük ve karmaşık modeller söz konusu olduğunda, hesaplama kaynakları açısından oldukça talepkardır. Bu modellerin eğitimi ve uygulanması için güçlü donanım ve yüksek miktarda enerji gerekebilir, bu da maliyetleri ve çevresel etkiyi artırır (Strubell vd., 2019).

1.3. Evrişimsel Sinir Ağları

Evrişimli Sinir Ağları (ESA), derin öğrenme modellerinin bir alt sınıfı olup, özellikle görüntü ve video işleme gibi iki boyutlu veriyle ilgili görevlerde önemli başarılar elde etmiştir. Bu ağlar, görüntü verilerindeki özellikleri otomatik olarak öğrenme ve çıkarma yetenekleri sayesinde, birçok uygulama alanında devrim gerçekleştirmiştir.

ESA'nın temel yapısı, Şekil 2'de gösterildiği gibi evrişim katmanları, havuzlama katmanları ve tam bağlantılı katmanlardan oluşmaktadır. Evrişim katmanları, girdideki yerel özellikleri tespit etmek için kullanılan filtreler veya çekirdekler içermektedir. Bu katmanlar, girdi verisi üzerinde kaydırılarak (evrişim) yerel özellik haritaları oluşturur. Havuzlama katmanları, bu özellik haritalarını alt örnekleyerek (subsampling) boyutlarını küçültür ve bilgi yoğunluğunu artırmaktadır (LeCun vd., 2015).




Şekil 2. Örnek bir ESA modeli (URL - 1)

Evrişim katmanı, ESA'nın temel yapı taşlarından biridir ve özellikle görüntü işleme uygulamalarında kullanılan bu ağların, görsel verilerden karmaşık özellikleri öğrenmesinde kritik bir rol oynamaktadır. Evrişim katmanı, çeşitli alanlarda uygulanan matematiksel bir işlem olan evrişimi (konvolüsyon) kullanarak girdi olarak aldığı veriler üzerinde yerel özellik çıkarma işlemi gerçekleştirmektedir (LeCun vd., 2015).

Evrişim işlemi, bir filtre veya çekirdek matrisinin, girdi matrisi üzerinde kaydırılarak uygulanmasıyla gerçekleştirilir. Bu işlem sırasında, filtre ile girdi matrisinin

ilgili elemanları arasında eleman bazında çarpım yapılır ve çarpımlar toplanır (Şekil 3). Bu toplam, çıktı özellik haritasının ilgili birimine yazılmaktadır.



Şekil 3. Örnek bir evrişim işlemi

Evrişim süreci, filtrenin girdi üzerinde tüm geçerli pozisyonlara uygulanarak devam eder, böylece filtre girdi verisindeki yerel özellikleri, örneğin kenarları, doku desenlerini veya renk geçişlerini çıkarabilir (Goodfellow vd., 2016). Bu işleme ilişkin formül Eşitlik 1’de verilmiştir.

$$(f * w)(x, y) = \sum_{i=-k}^k \sum_{j=-l}^l [f(x-i, y-j)w(i, j)] \quad (\text{Eşitlik 1})$$

Eşitlikteki, f bir görüntüyü, w ise filtreyi temsil etmektedir. Yeni oluşacak görüntüdeki x ve y koordinatındaki değer, $k \times l$ boyutundaki filtrenin f görüntüsündeki (x, y) koordinatındaki pikseli merkeze alan bir pencere boyunca tüm filtre katsayılarının ve görüntü piksellerinin çarpımı ile hesaplanır. Bu denklem, filtrenin girdinin her bölgesine uygulanarak bir özellik haritası (feature map) oluşturulmasını sağlar (Goodfellow vd., 2016).

Evrişim katmanları, her bir filtre için ayrı bir özellik haritası oluşturur. Bu özellik haritaları, girdinin belirli bölgelerindeki belirli özelliklerin varlığını temsil eder. Genellikle, evrişim katmanlarının çıktısı, doğrusal olmayan bir aktivasyon fonksiyonu ile işlenir. Bu, modelin doğrusal olmayan ilişkileri öğrenme yeteneğini artırır (Krizhevsky vd., 2012).

Evrişim katmanlarının başarısı, yerel bağlantı ve parametre paylaşımı özelliklerinden kaynaklanır. Yerel bağlantı, her nöronun yalnızca küçük bir girdi

bölgesiyle bağlantılı olması ve bu şekilde yerel özellikleri algılamasını sağlar. Parametre paylaşımı ise, aynı filtrenin farklı girdi bölgelerine uygulanarak, modelin daha az parametre ile daha geniş bir girdi alanını öğrenebilmesine olanak tanır. Bu özellikler, evrişim katmanlarını, özellikle büyük görüntü veri setleri üzerinde çalışırken, hem hesaplama açısından verimli hem de aşırı uyuma (overfitting) karşı dayanıklı kılar (Krizhevsky vd., 2012).

1.4. YSA Ağırlıklarının Başlangıç Değerlerinin Belirlenmesi

YSA'daki ağırlıkların başlangıç değerlerinin belirlenmesi, ağların performansı üzerinde önemli bir etkiye sahiptir. Başlangıç değerlerinin uygun şekilde belirlenmesi, sinir ağının daha hızlı ve verimli bir şekilde öğrenmesine yardımcı olabilmektedir. Ağırlıklar, nöronlar arasındaki bağlantıların gücünü temsil eder ve nöronların girdilerini nasıl işlediği ve çıktıları nasıl ürettiği üzerinde etkilidir. Yanlış belirlenmiş başlangıç değerleri, ağın yavaş öğrenmesine, yerel minimumlara takılmasına veya aşırı uyuma yol açabilir. Doğru belirlenmiş başlangıç değerleri ise, öğrenme sürecini hızlandırabilir ve daha genelleştirilmiş sonuçlar elde edilmesini sağlayabilir.

Sinir ağlarındaki ağırlıkların başlangıç değerlerini belirlemek için kullanılan çeşitli yöntemler aşağıdaki kategorilere ayrılabilir (Narkhede vd., 2021):

1. Rastgele yöntemlerle başlatma, en yaygın kullanılan başlangıç değeri belirleme yöntemlerinden biridir. Bu yöntemler, ağırlıkları rastgele değerlere atar. Rastgele değerler, farklı ağırlık değerlerini denemek ve öğrenme sürecini iyileştirmek için kullanılır. Bu yaklaşımda alt yöntemleri vardır:

a. Aralık Tabanlı Başlatma: Ağırlıkların belirli bir aralık içinde seçildiği yöntemlerdir. Bu aralık, gizli düğümlerin aktif bölgede kalmasını sağlamak veya ağın yanlış yerel minimumlarda takılmasını önlemek için belirlenir. Nguyen ve Widrow (1990) tarafından önerilen yöntem, eğitim süresini azaltarak hızlı yakınsama sağlar.

b. Varyans Ölçeklendirme Tabanlı Başlatma: Ağırlıkların, giriş ve çıkış aktivasyonlarının varyansını koruyacak şekilde ölçeklendiği yöntemlerdir. Glorot ve Bengio (2010), ağın katman derinliği arttıkça gradyanların kaybolmasını önlemek için varyansın korunmasını önermiştir. He vd. (2015), ReLU aktivasyon fonksiyonları için bu ölçekleme faktörünü değiştirmiştir.

c. Diğer Rastgele Başlatma Teknikleri: Aralık ve varyans ölçeklendirme tabanlı olmayan, özel rastgele başlatma teknikleridir. Chen ve Nutter (1991), ilk katman ağırlıklarını rastgele başlatmış ve gizli katman ağırlıklarını analitik olarak belirlemiştir.

2. Veri Odaklı Başlatma: Eğitim verilerinden türetilen ağ ağırlıklarının başlatılmasıdır. Bu yöntem, ağı başlangıçta anlamlı özellikler öğrenmesini sağlar.

a. Bağımsız Bileşenler Analizi (BBA): Yam vd. (2002), girdi verilerinin önemli özelliklerini yakalayan başlangıç gizli katman ağırlıklarını belirlemek için BBA kullanmıştır.

b. Temel Bileşen Analizi (TBA): Gan vd. (2015), eğitim veri setindeki örneklerden filtre ağırlıklarını öğrenmek için TBA kullanmıştır.

3. Hibrit Başlatma Teknikleri: Hem rastgele hem de veri odaklı başlatma yaklaşımlarını birleştiren tekniklerdir. Mishkin ve Matas (2015), rastgele ağırlıkları seçmiş ve ardından her katmanın varyansını korumak için bu ağırlıkları ölçeklemiştir.

1.5. Evrişim Katmanlarının Başlangıç Değerlerinin Belirlenmesi

Evrişim katmanlarının ağırlıklarının başlangıç değerleri, ağı öğrenme kapasitesini ve eğitim sürecinin etkinliğini belirleyen kritik bir faktördür. Yanlış belirlenmiş başlangıç değerleri, gradyanların katmanlar arasında düzgün bir şekilde yayılmasını engelleyebilir, bu da klsaik sinir ağlarında olduğu gibi gradyanın kaybolması veya patlaması problemlerine yol açar. İyi başlatılmış ağırlıklar, gradyanların düzgün bir şekilde yayılmasını ve tüm katmanlarda öğrenmenin etkili bir şekilde gerçekleşmesini temin eder. Bu durum, ağı eğitim sürecinde daha hızlı yakınsama sağlamasına ve daha yüksek doğruluk oranlarına ulaşmasına katkıda bulunur.

Ek olarak, evrişim katmanlarının başlangıç değerlerinin belirlenmesi, modelin genelleme yeteneğini de etkiler. İyi başlatılmış bir ağ, sadece eğitim verisi üzerinde iyi performans göstermekle kalmaz, aynı zamanda yeni, görülmemiş veri üzerinde de güçlü genelleme yetenekleri sergiler. Bu, modelin aşırı uyum göstermeden, eğitim verisindeki gürültüden etkilenmeden genel kalıpları öğrenmesine olanak tanır.

1.6. Tezin Amacı ve Kapsamı

ESA modellerinin evrişim katmanlarının başlangıç değerlerinin belirlenmesi, literatürde geniş yer bulmaya başlamıştır. Bu ilgi, başlangıç ağırlık değerlerinin ağı öğrenme sürecini ve nihai performansını doğrudan etkilemesinden kaynaklanmaktadır. Yanlış belirlenmiş başlangıç değerleri, gradyan patlaması veya yok olması problemleri gibi zorluklara yol açarak ağı eğitim sürecini sekteye uğratabilir. Bu nedenle, doğru ağırlık başlatma stratejilerinin geliştirilmesi, derin öğrenme modellerinin etkinliğini ve verimliliğini artırmak için kritik bir araştırma alanı haline gelmiştir.

Bu tezin amacı, ESA'lardaki evrişim katmanlarının başlangıç değerlerinin belirlenmesi konusunu derinlemesine inceleyerek, bu değerlerin belirlenmesinde kullanılan farklı yöntemlerin avantaj ve dezavantajlarını karşılaştırmaktır. Literatürde yaygın olarak kullanılan Xavier, He, sabit değer ve sıfır değer başlatma gibi yöntemlerin yanı sıra, yeni ve yenilikçi yaklaşımlar da ele alınmıştır. Bu kapsamda, her bir yöntemin teorik temelleri, uygulama pratikleri ve performans üzerindeki etkileri detaylandırılarak karşılaştırılmıştır. Böylelikle, hangi başlatma stratejilerinin belirli senaryolarda daha etkili olduğu hakkında kapsamlı bir anlayış geliştirilmeye çalışılmıştır.

Bu çalışma kapsamında özellikle makine öğrenmesinde iyi bir öznitelik çıkarıcı olarak bilinen Gabor filtreleri incelenmiş ve bu yöntemin sinir ağı performansına olan etkisi değerlendirilmiştir. Gabor filtreleri, biyolojik görme sistemini taklit eden ve belirli frekans ve yönelim bileşenlerini yakalamada üstün yeteneklere sahip filtrelerdir. Bu özellikleri nedeniyle, Gabor filtrelerinin ESA modellerinde ağırlık başlatma olarak kullanılması, ağırlık öğrenme sürecini hızlandırma ve genelleme performansını artırma potansiyeline sahiptir. Bu tez, Gabor filtrelerinin başlatma yöntemi olarak kullanıldığında sinir ağı performansına nasıl etki ettiğini deneysel olarak değerlendirerek literatüre önemli katkılar sunmayı hedeflemektedir. Dolayısıyla çalışma kapsamında evrişim katmanlarının başlangıç değerlerinin belirlenmesine konusuna odaklanılmış olup, başlangıçta genel olarak kullanılan yöntemler irdelenmiştir. Devamında ise özellikle Gabor filtrelerinin başlangıç değerler olarak kullanılmasının ağırlık üzerindeki etkileri incelenmiştir. Bununla beraber, özelleştirilmiş başlangıç değerlerinin kullanımının sinir ağlarının eğitim sürecindeki başarı oranına ve genel performansına olan etkisi de değerlendirilmiştir.

Çalışma kapsamında, başlangıçta literatürde iyi bilinen ve yaygın olarak kullanılan bir veri seti olan FashionMNIST üzerinde farklı ağ modelleri test edilmiştir. FashionMNIST veri seti özellikle derin öğrenme ve makine öğrenmesi alanlarında model performanslarını karşılaştırmak için sıklıkla kullanılmaktadır. Literatürde geniş yer bulan bu veri seti, model değerlendirmeleri ve ağırlık başlatma stratejilerinin etkinliğinin ölçülmesi için ideal bir platform sağlar.

Deneysel çalışmalarda, farklı ağırlık başlatma yöntemlerinin etkilerini izole edebilmek için basit ağ modellerinin kullanılması tercih edilmiştir. Bu basit modeller, ağırlık başlatma yöntemlerinin doğrudan performans üzerindeki etkilerini gözlemlemeyi kolaylaştırmaktadır. Karmaşık modellerin aksine, basit yapılar, başlangıç ağırlıklarının model performansına olan etkilerini daha net bir şekilde ortaya koymaktadır. Bu

yaklaşım, ağırlık başlatma stratejilerinin teorik avantajlarını pratikte gözlemlemek ve karşılaştırmak için uygun bir zemin hazırlamaktadır.

Çalışmanın devamında ise genel erişime açık bir avuç içi veritabanından alınan tanıma için kullanılacak örüntüler üzerinde çalışacak bir ağ modelinin evrişim katmanının ilk değerlerinin belirlenmesi üzerine çalışılmıştır.

Her bir model denemesinde, ilk değer belirlemenin etkisini gösterebilmek amacıyla birçok parametre ortak olarak ele alınmıştır. Bu parametreler arasında öğrenme hızı, epoch sayısı, batch boyutu ve optimizasyon algoritması gibi faktörler yer alır. Bu şekilde, başarıyı etkileyebilecek diğer faktörler tüm modeller için ortak belirlenmiş ve sadece başlangıç değerinin belirlenmesine odaklanılmıştır. Ortak parametrelerin kullanılması, ağırlık başlatma yöntemlerinin karşılaştırılabilirliğini artırır ve hangi yöntemin hangi koşullar altında daha üstün performans sergilediğini anlamayı kolaylaştırır. Bu metodolojik yaklaşım, çalışmanın sonuçlarının güvenilirliğini ve geçerliliğini artırır, böylece literatüre katkı sağlayacak sağlam ve tekrarlanabilir bulgular elde edilmesini sağlar.

2. LİTERATÜR ÖZETİ

Sinir ağlarının eğitimi ve performansı, ağırlıkların nasıl başlatıldığına büyük ölçüde bağlıdır. Rastgele başlatma stratejileri, ağırlıkların belirli bir dağılımdan rastgele seçilmesini içeren yöntemlerdir. Bu stratejiler, ağın simetriyi kırmasını ve etkili bir şekilde öğrenmesini sağlamak amacıyla kullanılır. Literatürde, rastgele başlatma tekniklerinin sinir ağlarının eğitime olan etkileri geniş bir şekilde araştırılmıştır.

Rastgele başlatma tekniklerinin temelinde, ağırlıkların rastgele dağılımlardan seçilmesi yer alır. Bu dağılımlar genellikle üniform veya normal dağılımlar olabilir. Üniform dağılımda, ağırlıklar belirli bir aralık içinde eşit olasılıkla seçilirken, normal dağılımda ağırlıklar belirli bir ortalama ve standart sapmaya sahip olacak şekilde seçilir. Rumelhart vd. (1986) tarafından geliştirilen geri yayılım algoritması, ağırlıkların rastgele dağılımlardan seçilmesini ve bu şekilde sinir ağının eğitilmesini sağlar. Yazarlar, rastgele başlatmanın ağın simetriyi kırmasına ve daha iyi öğrenmesine yardımcı olduğunu belirtmişlerdir.

Simetri kırma, sinir ağlarının etkili bir şekilde öğrenmesi için kritik bir öneme sahiptir. Eğer ağırlıklar sıfır olarak başlatılırsa, her bir düğüm aynı çıktıyı üretir ve ağ hiçbir şey öğrenemez. Rastgele başlatma, bu sorunu çözer ve ağın simetriyi kırarak farklı özellikler öğrenmesini sağlar. LeCun vd. (1998), sinir ağlarının eğitiminde simetri kırmanın önemini vurgulamış ve ağırlıkların rastgele dağılımlardan seçilmesini önermişlerdir. Bu yaklaşım, ağın daha hızlı yakınsamasını ve genel performansının artmasını sağlar.

Nguyen ve Widrow (1990), iki katmanlı sinir ağlarının herhangi bir doğrusal olmayan fonksiyonu yaklaşık olarak modelleyebileceğini ve adaptif ağırlıkların başlangıç değerlerinin seçilmesiyle eğitim süresinin azaltılabileceğini açıklar. Yazarlar, çeşitli problemler üzerinde adaptif ağırlıkları başlatmak için kullanılan bir yöntem sunmuşlardır ve her durumda öğrenme hızında önemli iyileştirmeler elde edildiğini belirtmişlerdir.

Yam, ve Chow (2000), beslemeli ileri sinir ağlarının optimal başlangıç ağırlıklarını belirlemek için Cauchy'nin eşitsizliği ve bir lineer cebirsel yöntemle dayanan bir algoritma geliştirmişlerdir. Sunulan yöntem, nöron çıktılarının aktif bölgede olmasını sağlamakta ve yakınsama hızını artırmaktadır. Belirlenen ağırlıklarla, hata önemli ölçüde azalmakta ve belirli bir kriteri elde etmek için gereken yineleme sayısı önemli ölçüde azaltılmaktadır.

Hinton ve Salakhutdinov (2006), yüksek boyutlu verilerin, küçük merkezi katmana sahip çok katmanlı bir sinir ağı eğitilerek düşük boyutlu kodlara dönüştürülebileceğini

tartışır. Ağırlıkların ince ayarlamak için gradyan inişi kullanılır, ancak bu, başlangıç ağırlıkları iyi bir çözüme yakın olduğunda iyi çalışır.

Son yıllarda, rastgele başlatma tekniklerinde önemli gelişmeler kaydedilmiştir. Mishkin ve Matas (2015), rastgele ağırlıkları seçmiş ve ardından her katmanın varyansını korumak için bu ağırlıkları ölçeklemişlerdir. Bu yöntem, ağırlıkların hızlı bir şekilde yakınsamasını sağlar ve performansı artırır. Chen ve Nutter (1991) ise, ilk katman ağırlıklarını rastgele başlatmış ve gizli katman ağırlıklarını analitik olarak belirlemiştir. Bu yaklaşım, iteratif olmayan eğitim süreçlerinde bile etkili sonuçlar vermektedir.

Aralık tabanlı başlatma stratejileri, ağırlıkların belirli bir aralık içinde seçilmesini sağlayarak, ağırlıkların simetriyi kırmasını ve verimli bir şekilde öğrenmesini amaçlar. Bu stratejiler, ağırlık eğitim süresini kısaltmak ve performansını artırmak için önemlidir. Aralık tabanlı başlatma tekniklerinin temelinde, ağırlıkların belirli bir aralık içinde rastgele seçilmesi yatmaktadır. Bu yaklaşım, ağırlıkların başlangıçta küçük ve rastgele değerler almasını sağlayarak simetri kırma hedeflemektedir.

Aralık tabanlı başlatma teknikleri, ağırlıkların belirli bir aralık içinde seçilmesini sağlar. Bu aralık, genellikle $[-r, r]$ gibi simetrik bir aralıktır ve bu aralığın genişliği, ağırlıkların büyüklüğünü kontrol eder. LeCun vd. (1998), sinir ağlarının eğitiminde simetri kırmanın önemini vurgulamış ve ağırlıkların küçük rastgele değerlerle başlatılmasını önermişlerdir. Aralık tabanlı başlatma tekniklerinde, aralığın genişliği ve ağırlıkların dağılımı önemli faktörlerdir. Glorot ve Bengio (2010), ağırlıkların başlangıçta rastgele dağılımlardan seçilmesini ve ardından bu ağırlıkların ölçeklenerek giriş ve çıkış aktivasyonlarının varyansının korunmasını önermiştir. Bu yaklaşım, özellikle derin ağlarda gradyanların stabil kalmasını sağlar ve eğitim sürecini hızlandırır. Glorot ve Bengio (2010)'un geliştirdiği bu yöntem "Xavier initialization" olarak bilinmektedir. Bu yöntem, ağırlıkların başlangıç değerlerini, giriş ve çıkış nöronlarının sayısına bağlı olarak ayarlayarak, ağırlıkların daha hızlı ve etkili bir şekilde eğitilmesini sağlar.

Benzer şekilde, He vd. (2015), ReLU aktivasyon fonksiyonları için bu ölçekleme faktörünü değiştirmişlerdir. Bu çalışmada önerilen "He initialization" yöntemi, derin sinir ağlarının eğitiminde önemli bir gelişme olarak sunulmuştur. Bu yöntem, ağırlıkların varyansını, önceki katmanın nöron sayısına bağlı olarak ayarlar, böylece aktivasyonların dağılımını daha etkili bir şekilde kontrol eder.

Veri odaklı başlatma stratejileri, sinir ağlarının eğitiminde kullanılan ve ağırlıkların başlangıç değerlerini eğitim verilerinden türetmeyi amaçlayan tekniklerdir. Bu stratejiler, ağırlıkların başlangıçta verilerle uyumlu olmasını sağlayarak, ağırlıkların daha hızlı yakınsamasını ve daha yüksek performans göstermesini sağlar. Veri odaklı başlatma

stratejileri, özellikle görüntü tanıma ve sınıflandırma gibi uygulamalarda yaygın olarak kullanılmaktadır. Bu bölümde, literatürde yer alan çeşitli veri odaklı başlatma teknikleri ve bunların performansa olan etkileri detaylı bir şekilde incelenecektir.

Ana Bileşen Analizi (TBA), verilerdeki önemli özellikleri yakalamak için kullanılan bir yöntemdir ve bu özellikler, sinir ağlarının başlangıç ağırlıklarını belirlemek için kullanılabilir. Gan vd. (2015), eğitim veri setindeki örneklerden filtre ağırlıklarını öğrenmek için TBA kullanmışlardır. Bu yöntem, ağırlıkların verilerle uyumlu olmasını sağlar ve ağırlıkların hızlı bir şekilde yakınsamaya başlamasına olanak tanır. PCA tabanlı başlatma, özellikle yüksek boyutlu veri kümeleri için uygundur ve ağırlıkların başlangıçta verilerin temel bileşenlerini yakalamasını sağlar.

Bağımsız Bileşen Analizi (BBA), verilerin bağımsız bileşenlerini çıkarma yöntemidir. Yam vd. (2002), girdi verilerinin önemli özelliklerini yakalayan başlangıç gizli katman ağırlıklarını belirlemek için BBA kullanmıştır. BBA tabanlı başlatma, verilerin bağımsız bileşenlerine dayalı olarak ağırlıkların belirlenmesini sağlamaktadır, bu da sinir ağının daha verimli bir şekilde öğrenmesini desteklemektedir. BBA, özellikle karmaşık veri yapılarını çözümlemek için etkili bir yöntemdir ve ağırlıkların başlangıçta bu bağımsız bileşenlere göre ayarlanmasını sağlamaktadır.

K-ortalamlar algoritması, veri kümelerini k sayıda kümeye ayırmak için kullanılan bir kümeleme yöntemidir. Krähenbühl vd. (2015), ağırlıkların normalizasyonunu ve aktivasyonların eşit dağılımını sağlamak için TBA ve k-means tabanlı iki veri odaklı teknik önermişlerdir. Bu teknikler, ağırlıkların başlangıçta verilerle uyumlu olmasını sağlar ve ağırlıkların hızlı ve stabil bir şekilde öğrenmesini destekler. K-ortalamlar tabanlı başlatma, ağırlıkların başlangıçta verilerin kümelerine göre seçilmesini sağlayarak, ağırlıkların daha anlamlı özellikler öğrenmesine olanak tanımaktadır.

Sutskever vd. (2013), başlangıç değerlerinin yanı sıra, derin öğrenmede momentumun da önemli bir faktör olduğunu belirtmişlerdir. Bu çalışma, başlangıç değerlerinin ve momentumun, özellikle derin ağların eğitiminde, performansı önemli ölçüde etkileyebileceğini göstermektedir. Paine vd. (2014), sıfır önyargılı Evrişimli Otomatik Kodlayıcı (EOK) kullanarak girdi verilerinden parametrelerin denetimsiz bir şekilde öğrenilmesi için bir yöntem önermişlerdir. Rastgele başlatılan bir ESA ile karşılaştırıldığında, bu teknik STL-10 veri kümesinde %3,87 daha yüksek doğruluk göstermiştir. Masci vd. (2011), denetimsiz özellik öğrenmeyi önermişlerdir. Bu yöntem, CIFAR-10 veri seti üzerinde diğer denetimsiz eğitim yöntemlerinden daha iyi performans göstermiştir. Ayrıca, rastgele başlatılan ağlara kıyasla çok daha yüksek tanıma oranları elde edilmiştir.

Dai vd. (2015), tekrarlayan ağırlık için ağırlık başlatılmasına yönelik bir yaklaşım geliştirmişlerdir. Bu yaklaşım, daha sonra tekrarlayan ağırlık için başlatma olarak kullanılabilecek ağırlıkların elde edilmesi için bir dizi otomatik kodlayıcının önceden eğitilmesine dayanmaktadır. Sonuçlar, bu yöntemin belge sınıflandırma görevlerinde iyi performans gösterdiğini ortaya koymuştur. Wiehman vd. (2016), görüntü bölümlenme mimarisi olan U-Net üzerinde denetimsiz ön eğitim kullanmışlardır. Yazarlar, önerilen yöntemi, ortalamaların ve varyansın eşitliği için istatistiksel testler kullanarak değerlendirmişlerdir. Bu yöntem, tamamen denetimli bir öğrenme yöntemiyle karşılaştırıldığında, model varyansını azaltmada daha sağlam olduğunu göstermiştir.

Ruiz-Garcia vd. (2017), yüz tanımadan duygu tanıma görevine kadar ESA ağırlıklarını önceden eğitmek için yığılmış evrişimli otomatik kodlayıcı kullanmışlardır. Yazarlar, rastgele ağırlık başlatma ile sunulan teknik arasındaki performansı karşılaştırmışlar ve kodlayıcıyı kullanarak yapılan ön eğitimin daha iyi doğruluk sağladığını ve eğitim süresini kısalttığını gözlemlemişlerdir.

Tu vd. (2017), yüz sınıflandırma görevi için evrişim seyrek filtre öğrenme tekniğini tanıtmışlardır. ESA'nın ilk katmanının filtreleri giriş verilerinin ayırt edici özellikleri kullanılarak başlatılmış ve daha sonra ESA denetimli bir şekilde eğitilmiştir. Bu yöntem, bazı rastgele başlatma teknikleriyle karşılaştırıldığında daha iyi sonuçlar vermiştir.

Sudowe ve Leibe (2016), görüntü tanıma için başlangıç ağırlıklarını elde etmek amacıyla kendi kendini denetleyen bir ön eğitim yöntemi sunmuşlardır. İlk olarak, görüntüden rastgele yamalar çıkarılmış ve her yama, He vd. (2015) tarafından verilen rastgele ağırlıklarla başlatılan bir ağırlık kullanılarak sınıflandırılmıştır. Bu ön eğitim aşaması, eğitim görüntülerinden yama yapısını kodlamaktadır. Son parametreler, görüntü tanıma görevini gerçekleştiren ağırlık için başlangıç ağırlıkları olarak kullanılmıştır.

Ijjina vd. (2016), sınıflandırma hatasını en aza indirmek amacıyla genetik algoritma kullanarak ESA ağırlık başlatma sınıflandırıcısını insan eylemlerini tanıma sürecinde genetik algoritmalar ve derin ESA kullanarak göstermiştir. Qiao vd. (2016), sigmoid beslemeli ileri sinir ağının (SFNN) eğitimi sırasında yerel minimumlardan kaçınmak ve stabiliteyi artırmak için karşılıklı Bilgiye dayalı ağırlık başlatma yöntemini tanıtmıştır.

Tang vd. (2017), geleneksel evrişim sinir ağının parametrelerinin rastgele başlatma ağırlıklarını, k-ortalamalar denetimsiz özellik öğrenmesi ile bir ön eğitim süreci olarak değiştirmiş ve sonuçta optimizasyon sürecinden önce daha iyi yabancı ot tanımlama doğruluğu elde edilmiştir.

Kumar (2017), 0'da türevlenebilir aktivasyon fonksiyonları kullanarak genel bir ağırlık başlatma stratejisi türetilerek doğrusal olmayan aktivasyonlarla ağırlık

başlatmalarını önermiştir. Daha sonra, ReLU için ağırlık başlatma stratejisini üretmişlerdir. Du vd. (2018), ağırlıkların rastgele başlatılmasını kullanarak, Gauss girişini kullanırken yanlış bir yerel minimum oluşabileceğini göstermişlerdir. Bu yanıltıcı yerel minimum durumlarında bile, ağırlık normalizasyonu kullanan bir gradyan inişiyle başlandığında doğru parametreleri belirleme olasılığının sürekli olduğu gösterilmiştir.

Weiler vd. (2018), yönelim bağımlı tepkileri verimli bir şekilde hesaplamak amacıyla rotasyonel artefaklardan kurtarmak için birçok yönelim için ortak öteleme ve rotasyon dengesi sağlamak amacıyla He vd. (2015) 'in ağırlık başlatma şemasını kullanmıştır.

Her ESA katmanında, eğitim veri setinde öğrenilen belirli parametreler veya ağırlıklar bulunur. Bu ideal ağırlıkları belirlemek amacıyla çeşitli optimizasyon teknikleri kullanılır. Bu tekniklere sağlanan girdiler arasında başlangıç ağırlık seti, bir kayıp fonksiyonu ve etiketlenmiş eğitim verileri yer alır. Algoritma, eğitim verilerindeki etiketlere dayanarak kayıp değerini hesaplamak için başlangıç ağırlıklarını kullanır ve kaybı minimize etmek amacıyla ağırlıkları düzenler. Bu düzenlenmiş ağırlık, sonraki iterasyon için kullanılır ve yakınsama sağlanana kadar bu süreç devam eder. Bu işlemde anlaşılacağı üzere, ağırlık başlatılmasında kullanılan başlangıç ağırlıklarının seçimi, ağırlık eğitim sürecinin yakınsama kalitesi ve hızı üzerinde kritik bir etkiye sahiptir (Bhardwaj ve Wei, 2018).

Trinh vd. (2019), Resnet-50 ESA mimarisinin başlatılması için kendi kendini denetleyen bir ön eğitim yaklaşımı sunmuşlardır. Eğitim öncesi aşamada kodlayıcı-kod çözücü modülü kullanılmıştır. Bu modül, görüntünün genel içeriğini anlamakta ve daha sonra görüntülerin sınıflandırılmasına yardımcı olmaktadır. Görüntü, ilk olarak yamalar halinde örneklenmiş ve dikkat dağıtıcı yamalar kod çözücüye girdi olarak verilmiştir. Kodlayıcı, görüntünün parçalarını alır ve çıktı olarak görüntüyü temsil eden bir vektör üretir. Kod çözücü ise, dikkat dağıtıcı parçaları alır ve maskelenmiş konum için doğru parçayı bulmak üzere eğitilir. Resnet-50 mimarisinin ilk üç bloğu, önceden eğitilmiş bu yama işleme ünitesinden başlatılmıştır. Yazarlar, bu başlatma tekniğini CIFAR-10 veri kümesindeki rastgele başlatma ile karşılaştırmış ve bu tekniğin modelin genelleme yeteneğini geliştirdiğini göstermişlerdir.

Sun vd. (2019), sınıflandırma problemleri için yeni bir derin ESA ağırlık başlatma değeri ve genetik algoritmalar kullanarak mimarileri geliştirmek için yeni bir yöntem tanıtmışlardır. Yu vd. (2019), Görsel özelliklerden tıklama özelliklerini tahmin etmeyi amaçlayan iki ağırlık başlatma yöntemi uygulamıştır. Bu tıklama özelliği tahmincisi, tıklama verilerini içeren ek bir görüntü veri kümesi kullanılarak eğitilmiştir.

Mehdipour vd. (2019), eğitim kararsızlığını ele almak için Uzun Kısa Süreli Bellek (LSTM) ağlarına uygulanan sağlam bir başlatma yöntemi geliştirmiştir. Sonuçlar, önerilen tekniğin, elde edilen çözümün eğitim yakınsaması ve genel performansında başlatma tekniklerini geride bıraktığını göstermektedir.

Aguirre ve Fuentes (2019), ReLU aktivasyon fonksiyonu için geleneksel sinir ağı yapılarında veriye dayalı yeni bir ağırlık başlatma yöntemi önermiştir. Sonuçlar, en gelişmiş ağırlık başlatma teknikleriyle karşılaştırıldığında, bu yeni yöntemin ImageNet veri kümesinde daha hızlı yakınsama sağladığını göstermiştir. Cao vd. (2018), derin öğrenme ile görüntü tanıma sorunlarında öğrenme algoritmalarının eğitimini iyileştirmek için RGB etkisi yüzdesine dayalı bir ağırlık başlatma yaklaşımı sunmuştur. RGB oranını türetmiş ve bunu ağırlıkların başlatılmasına uygulamışlardır. Çeşitli veri kümeleri üzerinde birçok test yapmışlar ve küçük veri kümeleri için iyi çalıştığını göstermişlerdir.

Palanisamy vd. (2020), araştırma, önceden eğitilmiş ağırlıkların kullanılmasıyla, sesin önceden eğitilmiş standart ESA modelleri aracılığıyla sınıflandırılmasında rastgele başlatılan ağırlıklardan daha iyi performans gösterdiğini ortaya koymuştur. Bu gözlem, ses spektrogramları ile standart ImageNet görüntü örnekleri arasındaki büyük farkı dikkate alarak bile transfer öğrenme varsayımlarının geçerliliğini yeniden teyit etmektedir.

Hermosilla vd. (2021), sürekli konvolüsyonların çeşitliliğini birleştiren bir çerçeve önermişlerdir ve bu başlangıç yönteminin, bazı durumlarda benzer veya daha iyi performans elde ederken toplu normalleştirmeyi önleyebileceğini göstermişlerdir. Zhao vd. (2022), sadece sıfırlardan ve birlerden oluşan ZerO başlatmayı önermiştir. CIFAR-10 veri kümesi üzerinde ResNet-18 modeli ve ImageNet veri kümesi üzerinde ResNet-50 kullanılarak test edilmiştir. ZerO başlatma, test hata oranını 0.03 ila 0.08 std. arasında başarılı bir şekilde azaltmıştır.

Pan vd. (2022), Tensörlü Evrişimli Sinir Ağları (TSA) için ağırlık başlatmaya yönelik yeni bir yaklaşım sunmuşlardır. Bu, yaklaşım geleneksel Xavier ve He başlatma yöntemlerinin etkisizliğine yanıt olarak geliştirilmiştir.

3. MATERYAL VE YÖNTEMLER

Sinir ağlarının performansını etkileyen en önemli faktörlerden biri, ağırlıkların başlangıç değerleridir. Literatürde, ağların eğitim sürecini optimize etmek ve daha hızlı yakınsama sağlamak amacıyla çeşitli ağırlık başlatma yöntemleri geliştirilmiştir. Bu yöntemler, ağırlıkların uygun bir şekilde başlatılmasıyla gradyanların düzgün bir şekilde yayılmasını ve vanishing/exploding gradyan problemlerinin önlenmesini hedefler.


En yaygın kullanılan başlatma yöntemlerinden biri sabit değer başlatmadır. Bu yöntemde, tüm ağırlıklar sabit bir değerle başlatılır. Ancak, bu yaklaşımın öğrenme sürecini yavaşlattığı ve ağırlık simetri kırma yeteneğini azalttığı bilinmektedir. Sabit değerle başlamanın türevlerinden biri sıfır değer ile başlatma yaklaşımıdır. Bu yaklaşımda ağırlık tüm ağırlıkları sıfır olarak ayarlar, ancak bu da benzer şekilde ağırlık simetri kırma yeteneğini ortadan kaldırır ve eğitim sürecinde etkisiz kalır. Bu tür sınırlamaları aşmak için daha gelişmiş başlatma yöntemleri geliştirilmiştir.

Bu bölümde bilinen tüm başlangıç değeri belirleme yaklaşımlarının etkileri ilk önce basit ağlar üzerinde test edilerek gösterilmiştir. Bu deneysel çalışmalar FashionMNIST verisetinde ilk önce uygulanmış olup, devam eden çalışmalarda ise farklı verisetleri kullanılmıştır. Bununla beraber modellerde de katman sayıları artırılarak daha karmaşık modeller üzerinde çalışmalar gerçekleştirilmiştir.

3.1. FashionMNIST Veri Kümesi

FashionMNIST, bilgisayarla görü ve derin öğrenme alanında yaygın olarak kullanılan bir veri setidir (Xiao vd., 2017). Bu veri seti, klasik MNIST (LeCun vd., 1998) veri setine alternatif olarak geliştirilmiştir. MNIST veri seti, el yazısı rakamları içeren bir veri seti olup, derin öğrenme modellerinin eğitiminde sıklıkla kullanılmıştır. Ancak, MNIST veri seti üzerinde yapılan çalışmaların doygunluğa ulaşması ve daha gerçek dünya problemlerine yakın veri setlerine olan ihtiyaç, FashionMNIST'in geliştirilmesine yol açmıştır.

FashionMNIST veri seti, moda ürünlerini içeren siyah-beyaz görüntülerden oluşur. Veri setinde toplam 70.000 görüntü bulunmaktadır; bunların 60.000'i eğitim, 10.000'i ise test için ayrılmıştır. Her bir görüntü, 28x28 piksel boyutunda olup, gri tonlamalıdır. Görüntüler, 10 farklı sınıfa ayrılmıştır: Tişört/Üst, Pantolon, Kazak, Elbise, Ceket, Sandalet, Gömlek, Spor Ayakkabı, Çanta ve Bilek Botu. Her sınıf, 7,000 görüntü ile temsil edilmektedir. Bu verisetinden alınan örnek görüntüler Şekil 4'te gösterilmiştir.



Şekil 4. FashionMNIST verisetinden örnek görüntüler (Sasao, 2024).

Veri setinin temel amacı, araştırmacıların ve uygulayıcıların, daha karmaşık ve gerçekçi veri setleri üzerinde model geliştirme ve değerlendirme yapmalarını sağlamaktır. FashionMNIST, özellikle görüntü sınıflandırma problemleri üzerinde çalışanlar için önemli bir kaynak olup, derin öğrenme modellerinin yeteneklerini değerlendirmek ve karşılaştırmak için standart bir benchmark olarak kabul edilmektedir. Bu veri seti, hem başlangıç seviyesindeki araştırmacılar hem de ileri düzeydeki kullanıcılar için uygundur ve çeşitli derin öğrenme kütüphaneleri ile kolaylıkla entegre edilebilir.

FashionMNIST'in avantajlarından biri, çeşitli gürültü ve sapmalar içeren gerçek dünya görüntülerini temsil etmesidir. Bu, model genel performansını ve genelleme yeteneğini test etmek için ideal bir ortam sunar. Ayrıca, veri seti ile yapılan çalışmalar, derin öğrenme algoritmalarının moda endüstrisi gibi belirli sektörlerde nasıl kullanılabileceğine dair değerli içgörüler sağlamaktadır.


Sonuç olarak, FashionMNIST veri seti, bilgisayarla görü ve derin öğrenme alanında önemli bir yer tutmakta ve araştırma topluluğu için vazgeçilmez bir araç olarak kabul edilmektedir. Bu veri seti, modellerin performansını test etmek ve geliştirmek için ideal bir benchmark sunmakta olup, aynı zamanda moda endüstrisi ve diğer ilgili alanlarda uygulamalı araştırmalar için önemli bir referans noktası oluşturmaktadır.

3.1. Basit Ağ Model Yapısı

Bir ağın başarısını etkileyen birçok faktör mevcuttur. Bu çalışma kapsamında özellikle evrimsel katmanların başlangıç değerlerinin ağın başarısına olan etkileri incelenmesi amaçlandığından, çalışmada başarıyı etkileyecek diğer parametrelerin tümü sabitlenmeye çalışılmıştır. Bu nedenle özellikle ağı oluştururken belirlenen parametrelere tüm çalıştırmalarda aynı olacak şekilde ayarlanmaya çalışılmıştır.

Standart olarak oluşturulan tüm ağ modellerinde ağırlıkların belirlenmesi dışında, birçok faktör rastgeleliğe dayalı oluşturulmaktadır. Bu nedenle modeller oluşturulmadan önce rastgelelik tohumu (seed) tüm kütüphaneler için sabitlenmiştir. Bunun sonucunda da hem verilerin çekilmesi sırasında, hem de modellerin çalıştırılması sırasında oluşturulacak olan rastgele değerle sabitlenmiştir.

Çalışma için ilk oluşturulan model basit bir sınıflandırıcı özelliği taşımaktadır ve herhangi bir evrişim katmanı içermemektedir. Bu sınıflandırıcı için iki katmandan oluşan bir YSA modeli oluşturulmuştur. Bu modelin ilk katmanı 1024 ikinci ve aynı zamanda çıkış katmanı için 10 adet nöron bulunmaktadır. Çalışma için ilk oluşturulan model Şekil 5'te verilmiştir.




Şekil 5. Basit ağ model yapısı

Modellerin tümünde giriş verisi olarak FashionMNIST verisetinden görüntüler kullanılacağı için giriş sayısı 786'dır (28x28). Verileri üzerinde piksel normalizasyonu dışında herhangi bir ön işlem uygulanmamıştır. Modellerin tümünde eğitim verileri ve test verileri aynı görüntüler olacak şekilde kullanılmıştır. Çalışmada eğitim ve validasyon süreçlerinin paralel takip edilmesi amaçlandığından test verileri validasyon verisi olarak kullanılmıştır. Ayrıca test verisi oluşturulmamıştır.

3.2. Evrişimli Basit Ağ Model Yapısı

İlk geliştirilen basit ağ model yapısı klasik bir YSA modeli olarak tasarlanmıştır. Modelden daha fazla öznetelik elde edilebilmesi amacıyla evrişim katmanı eklenmiştir. Evrişim katmanı eklenmiş model Şekil 6’da verilmiştir. Eklenen evrişim katmanı 64 farklı filtreyi içerecek şekilde düşünülmüştür.



Şekil 6. Evrişim katmanı eklenmiş basit ağ model yapısı

Oluşturulan modeldeki evrişim katmanı padding (doldurma) parametresi verilmemiştir. Bundan dolayı 28x28 giriş görüntüleri bu katmanda 26x26’lık görüntülere dönüşmektedir. Bu katman sonrasında doğrudan düzleştirme katmanına iletilmektedir.

3.3. Evrişim Katmanlarının Başlangıç Değerlerinin Belirlenmesi

ESA, temel bileşenlerin farklı kombinasyonlarını içermektedir ve bu bileşenler, özellikle görüntü sınıflandırma gibi görevlere uyarlanmış derin öğrenme modellerinin temelini oluşturmaktadır. Evrişim katmanlarının ilk değerlerinin belirlenmesi, ağın başlangıç performansını ve eğitim sürecinin seyrini önemli ölçüde etkileyebilmektedir. İlk değerlerin doğru seçilmesi, ağın daha hızlı ve daha verimli bir şekilde eğitilmesine yardımcı olabilmektedir. Evrişimli sinir ağlarında (CNN) evrişim katmanlarının ilk değerlerinin belirlenmesi için rastgele değerlerle başlatma, sıfır değerler ile başlatma, çok küçük değerlerle başlatma, Xavier katsayıları ile başlatma, He - Kamimin katsayıları ile başlatma gibi birçok yaklaşım mevcuttur.

Sabit deęer aęırlık bařlatma, sinir aęlarının eęitimine bařlamadan nce tm aęırlıkların belirli bir sabit deęerle (genellikle sıfır veya kk bir pozitif deęer) bařlatılmasıdır. Bu yaklařım, simetri kırma ilkesine uygun olmadığı iin modern derin ęrenme uygulamalarında yaygın olarak kullanılmaz. Ancak, bu yntemin etkileri, avantajları ve dezavantajları akademik baęlamda incelenmeye deęerdir.

Sabit deęer bařlatmanın teorik bir avantajı, bařlatmanın basit ve hesaplama aısından ok dřk maliyetli olmasıdır. Sabit bir deęerle bařlatma, rastgele daęılımlardan aęırlık seme veya karmařık bařlatma algoritmaları kullanma ihtiyaını ortadan kaldırır. Ayrıca, belirli durumlarda ve belirli aę yapılarına zg olarak, sabit deęer bařlatmanın bazı sınırlı faydaları olabilir. rneęin, belirli derin ęrenme arařtırmalarında veya deneysel ayarlarda, sabit deęer bařlatmanın etkilerini incelemek, dięer bařlatma yntemlerinin performansını deęerlendirmede bir referans noktası saęlayabilir.

Sabit deęer aęırlık bařlatmanın bařlıca dezavantajı, simetri kırmanın gerekleřememesidir. Eęitim srecinde nronların aynı gncellemeleri alması, modelin ęrenme kapasitesini byk lde kısıtlar. Bu durum, modelin karmařık veri setlerini ęrenememesine ve dřk genelleme performansı sergilemesine neden olur. Ayrıca, sabit deęer bařlatma, vanishing gradyan ve exploding gradyan gibi problemleri zmede yetersiz kalır. Bu problemler, zellikle derin aęlarda, aęın gradyanlarının ařırı kk veya byk deęerlere ulařmasına ve modelin eęitim srecinin durmasına yol aabilir.

Btn aęırlıklara bařlangıta rastgele bir deęer verilir. Eęer aęırlıklar ok yksek deęerlerde bařlatılırsa, gradyanların patlaması (exploding gradients) sorununa neden olabilmektedir. ęrenmenin ok zaman almasına, yanlış hesaplamalara, NaN veya Inf deęerini alan kayıplara ve modelin asla ęrenememesine neden olabilmektedir.

PyTorch, evriřim katmanlarının aęırlıklarını varsayılan olarak He (Kaiming) normal bařlatma yntemiyle belirler. Bu yntem, He vd. (2015) tarafından nerilmiř olup, zellikle ReLU ve trevleri gibi doymayan aktivasyon fonksiyonları iin optimize edilmiřtir. He normal bařlatma yntemi, aęırlıkların ortalaması sıfır ve varyansı $2/x_{in}$ olan bir normal daęılımdan rastgele seilmesini saęlar; burada x_{in} , ilgili katmandaki giriř birimlerinin (nronlarının) sayısını ifade eder. Bu bařlatma stratejisi, aęırlıkların bařlangıta kk ama anlamlı deęerlerle ayarlanmasını, bylece aęın derin katmanlarında bile aktivasyonların ve gradyanların etkin bir řekilde yayılmasını amalar.

Bu forml, aęırlıkların normal daęılım (Gaussian distribution) ile seildięini ve bu daęılımın standart sapmasının, x_{in} deęeri ile leklendięini gsterir. Bu sayede, her bir

nöronun çıkışlarının varyansı dengelenir ve derin ağlarda karşılaşılan gradyan kaybolması veya patlaması gibi sorunlar minimize edilir.

PyTorch'daki evrişim katmanlarının varsayılan başlatma sürecinde, ağırlıklar He normal başlatma yöntemiyle belirlenirken, bias (sapma) terimleri ise sıfır olarak başlatılır. Bu, modelin başlangıçta nötr bir durumda olmasını sağlar ve öğrenme sürecine etkili bir başlangıç yapmasına olanak tanır.

He normal başlatma yöntemi, özellikle derin sinir ağlarında önemli avantajlar sağlar. ReLU ve türevleri gibi doymayan aktivasyon fonksiyonları, negatif değerler için sıfır döndürdüğünden, ağın derin katmanlarında aktivasyon değerlerinin sıfıra yaklaşması riski vardır. He normal başlatma, bu riski azaltmak için ağırlıkları optimize eder ve ağın daha derin katmanlarında bile etkin bir sinyal yayılımı sağlar.

3.4. Gabor Filtreleri

Gabor filtreleri, Dennis Gabor tarafından tanımlanan ve görüntü işleme, bilgisayarla görme, ve sinir ağlarında yaygın olarak kullanılan araçlardır (Gabor, 1946). Bu filtreler, bir görüntünün belirli frekans ve yönelim özelliklerini yakalamak için tasarlanmış doğrusal filtrelerdir. Gabor filtreleri, hem uzay hem de frekans alanında lokalize olmaları nedeniyle, özellikle kenar tespiti, doku analizi, ve nesne tanıma gibi görevlerde etkili olurlar. Bir Gabor filtresi, bir sinüzoidal düzlem dalgasının Gauss fonksiyonu ile modüle edilmesiyle oluşturulur, bu da filtreyi belirli bir frekans ve yönelime duyarlı hale getirir.

Gabor filtreleri, biyolojik görme sisteminin özellikle erken aşamalarındaki görsel kortekste bulunan reseptörlere benzer özellikler gösterir. Bu benzerlik, Gabor filtrelerinin biyolojik sistemlerdeki sinirsel mekanizmaların matematiksel bir modeli olarak kabul edilmesine neden olmuştur. Görsel kortekste, farklı frekans ve yönelimlere duyarlı hücreler bulunmaktadır. Gabor filtreleri, bu hücrelerin özelliklerini taklit ederek, görüntülerdeki kenarları, çizgileri ve diğer önemli yapısal bilgileri etkili bir şekilde yakalayabilir. Bu nedenle, Gabor filtreleri, birçok bilgisayarla görme algoritmasında, görüntü özelliklerini çıkarmak ve analiz etmek için temel bileşenler olarak kullanılır. Bir Gabor filtresini hesaplamak için kullanılan denklem Eşitlik 2'de verilmiştir.


$$F(u_1, u_2) = \exp\left(-\frac{(\hat{u}_1^2 + \gamma^2 \hat{u}_2^2)}{2\sigma^2}\right) \cdot \cos\left(\frac{2\pi}{\lambda} \hat{u}_1\right) \quad (\text{Eşitlik 2})$$

Bu denklemdeki $\hat{u}_1$ ve $\hat{u}_2$, θ açısı yönelimine bilgisi kullanılarak Eşitlik 3 ve 4'deki gibi hesaplanmaktadır.

$$\hat{u}_1 = u_1 \cos(\theta) + u_2 \sin(\theta) \quad (\text{Eşitlik 3})$$


$$\hat{u}_2 = -u_1 \sin(\theta) + u_2 \cos(\theta) \quad (\text{Eşitlik 4})$$

Her bir θ açısı ve λ dalga boyur farklı bir filtre üretmektedir. Bu parametreler değiştirilerek birçok filtre oluşturulabilmektedir ve bunlar bir araya getirilerek Gabor filtre bankası adı verilen yapılar kurulabilmektedir. Örnek olarak oluşturulmuş bir Gabor filtre bankası Şekil 7’de gösterilmiştir.



Şekil 7. Örnek bir Gabor filtre bankası (URL - 1).

Üretilen Gabor filtreleri bir görüntüye uygulandığı zaman her bir filtre görüntüdeki farklı özelliklerin açığa çıkarılmasına yardımcı olmaktadır. Bu da bir sınıflandırıcının en çok ihtiyaç duyduğu girdilerin oluşturulmasına önemli katkı sunmaktadır. Dolayısıyla Gabor filtre bankası ne kadar geniş olursa o kadar farklı özneliliğin açığa çıkarılması ihtimali artmaktadır. Örneğin bir görüntü üzerine uygulanmış farklı Gabor filtrelerinden üretilen yeni görüntüler Şekil 8’de gösterilmiştir. Şekilde de görüleceği üzere her filtrenin etkisi farklıdır.



Şekil 8. Bir görüntüye uygulana farklı Gabor filtreleri (URL - 2). Örnek bir Gabor filtre bankası (Kamarainen, 2012).

3.5. Avuç İzi Tanıma

Avuç izi tanıma, biyometrik tanıma teknolojilerinden biridir ve kişisel kimlik doğrulama süreçlerinde kullanılmaktadır. Avuç izleri, her birey için benzersiz olan ve yaşam boyunca değişmeyen desenler içerir. Bu özellik, avuç izi tanımayı güvenilir ve doğruluk oranı yüksek bir kimlik doğrulama yöntemi haline getirir. Avuç izi tanıma sistemleri, genellikle optik veya kapasitif sensörler kullanarak avuç içinin detaylı bir görüntüsünü alır. Bu görüntüler, daha sonra çeşitli algoritmalar kullanılarak analiz edilir. Önemli özellikler arasında avuç içi çizgileri, damar yapıları ve cilt dokusu gibi unsurlar yer alır. Bu özelliklerin dijital olarak kodlanması ve karşılaştırılması yoluyla kimlik doğrulama gerçekleştirilir (Kumar ve Zhang, 2006).

Avuç izi tanımanın birçok avantajı bulunmaktadır. İlk olarak, avuç içi izleri, parmak izlerine kıyasla daha geniş bir alan kapladığından, daha fazla bilgi içerir ve bu da tanıma sürecinin doğruluğunu artırır. İkinci olarak, avuç içi izleri dış etkenlerden (örn. kesikler veya yaralanmalar) daha az etkilenir. Son olarak, avuç izi tanıma, temassız tarama seçenekleri sunarak hijyen açısından da avantaj sağlar.

Makine öğrenmesi, avuç izi tanıma özelliği çıkarımı ve sınıflandırma süreçlerinde merkezi bir rol oynamaktadır. Özellik çıkarımı, avuç içi görüntülerindeki belirgin çizgiler, kırıksıklıklar ve damar yapıları gibi önemli bilgilerin tespit edilmesini içerir. Bu

süreçte, çeşitli görüntü işleme teknikleri ve algoritmalar kullanılarak, avuç izinin karakteristik özellikleri sayısal verilere dönüştürülür. Özellik çıkarımı için yaygın olarak kullanılan yöntemler arasında Gabor filtreleri, dalgacık dönüşümleri ve histogram tabanlı teknikler yer almaktadır.

Sınıflandırma aşamasında, çıkarılan özelliklerin analiz edilmesi ve uygun bir modelle sınıflandırılması gerekmektedir. Klasik makine öğrenmesi yöntemleri arasında, Destek Vektör Makineleri (DVM), K-En Yakın Komşu (k-NN), YSA ve Karar Ağaçları (KA) gibi algoritmalar yaygın olarak kullanılmaktadır. Örneğin, Kumar ve Zhang (2006), kişisel kimlik doğrulama için avuç izi görüntülerinde çoklu temsil yöntemlerini kullanarak DVM tabanlı bir yaklaşım geliştirmiştir. Bu çalışmada, avuç izi görüntüleri çeşitli alt bantlara ayrılmış ve her bir alt banttandırılan özellikler, DVM kullanılarak sınıflandırılmıştır.

DVM, avuç izi tanıma çalışmalarında yüksek doğruluk oranlarıyla öne çıkan bir başka makine öğrenmesi tekniğidir. Bu yöntem, avuç içi desenlerinin yüksek boyutlu özellik uzayında ayrıştırılması ve doğru sınıflandırılması için kullanılır. DVM, küçük veri kümelerinde dahi etkili sonuçlar verebilir ve bu nedenle biyometrik tanıma sistemlerinde yaygın olarak tercih edilir.

Son yıllarda, derin öğrenme teknikleri, biyometrik tanıma sistemlerinde önemli ilerlemelere yol açmıştır. Avuç izi tanıma da bu gelişmelerden yararlanan alanlardan biridir. Derin öğrenme algoritmaları, özellikle karmaşık veri yapılarının otomatik olarak öğrenilmesi ve yüksek doğruluk oranlarıyla tanınması için güçlü araçlar sunmaktadır. Bu bağlamda, avuç izi tanıma sistemlerinde derin öğrenme tabanlı yaklaşımlar, geleneksel makine öğrenmesi yöntemlerine kıyasla belirgin avantajlar sağlamaktadır.

Derin öğrenme, avuç izi tanımada yaygın olarak kullanılan ESA ve derin ESA gibi mimarilerle öne çıkmaktadır. ESA, avuç içi görüntülerindeki karmaşık desenleri ve ince detayları öğrenme kapasitesine sahiptir. Bu ağlar, çeşitli katmanlardan oluşur ve her katman, görüntüdeki belirli özellikleri çıkararak daha yüksek seviyeli bir temsile dönüştürür. Örneğin, avuç izi tanımada ESA kullanarak yapılan bir çalışma, avuç içi çizgilerinin ve damar yapılarının otomatik olarak çıkarılmasını ve sınıflandırılmasını sağlamıştır (Yang vd., 2017).

Derin öğrenme tabanlı avuç izi tanıma sistemlerinde kullanılan bir diğer önemli yöntem, evrimsel özelliklerin yanı sıra Tekrarlayan Sinir Ağları (Recurrent Neural Networks - RNN) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory - LSTM) gibi zaman serisi verilerini işleyebilen ağlardır. Bu tür ağlar, avuç içi desenlerinin zaman içindeki değişimlerini ve varyasyonlarını daha iyi modelleyebilir. Örneğin, LSTM tabanlı

bir yaklaşım, avuç içi damar yapılarının doğrusal olmayan özelliklerini başarılı bir şekilde öğrenmiş ve yüksek doğruluk oranları elde etmiştir (Luo vd. 2024).

Transfer öğrenme, derin öğrenme tabanlı avuç izi tanıma çalışmalarında sıklıkla kullanılan bir başka tekniktir. Transfer öğrenme, önceden eğitilmiş bir modelin, farklı ancak ilgili bir görevde yeniden kullanılması prensibine dayanır. Bu yaklaşım, büyük veri kümeleri gerektiren derin öğrenme modellerinin, daha küçük veri kümeleriyle etkin bir şekilde eğitilmesini sağlar. Örneğin, ImageNet veri kümesi üzerinde eğitilmiş bir ESA modeli, avuç izi tanıma görevinde yeniden eğitilerek yüksek performans göstermiştir (Izadpanahkakhk vd., 2018).

Derin öğrenme tabanlı avuç izi tanıma sistemlerinin avantajları arasında, otomatik özellik çıkarımı, yüksek doğruluk oranları ve büyük ölçekli veri kümeleriyle başa çıkabilme yeteneği bulunmaktadır. Bununla birlikte, bu sistemlerin eğitimi ve uygulanması, yüksek hesaplama gücü ve büyük miktarda etiketli veri gerektirmektedir. Gelecekte, derin öğrenme tekniklerinin daha verimli ve ölçeklenebilir hale getirilmesi, avuç izi tanıma sistemlerinin performansını ve yaygınlığını artıracaktır.

Gabor filtreleri, belirli frekans ve yönelimlere sahip sinüzoidal dalgaların, Gauss fonksiyonu ile modüle edilmesiyle oluşturulan filtrelerdir. Bu filtreler, yerel uzaysal frekans bileşenlerini ve yönelimlerini yakalayarak, görüntüdeki önemli detayların ve desenlerin belirlenmesini sağlar. Avuç izi biyometrisi açısından, avuç içi çizgileri ve damar yapıları gibi ince detaylar, Gabor filtreleri kullanılarak etkili bir şekilde çıkarılabilir. Bu nedenle, Gabor filtreleri, avuç izi tanıma sistemlerinde özellik çıkarımı için ideal bir araçtır (Ekinci ve Aykut, 2007; Bingöl ve Ekinci, 2017).

Derin öğrenme mimarilerinde, Gabor filtreleri ile ilklendirilmiş evrişim katmanlarının kullanılması, modelin başlangıç aşamasında daha iyi bir özellik çıkarımı yapmasına olanak tanır. Bu ilklendirme, modelin öğrenme sürecini hızlandırır ve doğruluğunu artırır. Özellikle derin ESA, Gabor filtreleri ile ilklendirildiğinde, avuç içi görüntülerindeki karmaşık desenleri ve detayları daha etkin bir şekilde öğrenir. Bu yaklaşım, derin ağların daha iyi genelleme yapmasını ve farklı avuç izi desenlerini daha yüksek doğruluk oranlarıyla tanımasını sağlar (Genovese vd. 2019).


Gabor filtreleri ile ilklendirilmiş evrişim katmanlarının avuç izi biyometrisine uyumu, bu filtrelerin görüntülerdeki yönelim ve frekans bileşenlerini yakalama kabiliyetiyle doğrudan ilişkilidir. Avuç içi desenleri, belirli yönelimlere ve frekanslara sahip karmaşık yapılar içerir. Gabor filtreleri, bu yapıları etkili bir şekilde analiz ederek, avuç izi tanıma sistemlerinin performansını artırır. Ayrıca, bu filtrelerin kullanımı,

sistemin gürültüye karşı dayanıklılığını da artırır, çünkü Gabor filtreleri, yerel görüntü özelliklerini hassas bir şekilde çıkarabilir.

3.6. IITD Palmprint Avuç İzi Veritabanı

Avuç izi biyometrik bilgilerde çizgi formasyonunun fazla olması ve Gabor filtrelerinin bu çizgileri ön plana çıkarma yetisi göz önünde bulundurularak bu çalışmada avuç izi tanımda Gabor ile ilklendirilmiş bir Evrişimli Sinir Ağı kullanılması düşünülmüştür. Bu amaçla literatürde çok bilinen bir avuç izi veritabanı olan IITD Temassız Avuçizi Veritabanı (URL – 3) tercih edilmiştir.

IITD avuç izi veritabanı, çeşitli bireylere ait avuç içi görüntülerini içerir. Veritabanında yer alan görüntüler, farklı yaş gruplarından, cinsiyetlerden ve etnik kökenlerden gelen bireylerin avuç izlerini kapsar. Bu çeşitlilik, avuç izi tanıma sistemlerinin geniş bir kullanıcı kitlesi üzerinde test edilmesini ve doğrulanmasını sağlar. IITD avuç izi veritabanı, toplamda 235 kişi tarafından sağlanan 5,200 avuç içi görüntüsünü içerir. Veritabanında yer alan görüntüler, farklı yaş gruplarından, cinsiyetlerden ve etnik kökenlerden gelen bireylerin avuç izlerini kapsar. Bu çeşitlilik, avuç izi tanıma sistemlerinin geniş bir kullanıcı kitlesi üzerinde test edilmesini ve doğrulanmasını sağlar. Veritabanı, her bir bireyin avuç izinin birden fazla pozunu içerir ve bu pozlar farklı yönelim ve pozlamalarda çekilmiştir. Görüntüler, yüksek çözünürlüklü tarayıcılar kullanılarak elde edilmiştir ve genellikle 150 dpi çözünürlüğe sahiptir. Her bir görüntü, bireyin avuç içi çizgilerini, kırışıklıklarını ve diğer belirgin özelliklerini net bir şekilde göstermektedir. Görüntüler genellikle gri tonlamalıdır ve çeşitli ön işleme teknikleri uygulanmıştır. Bu teknikler, görüntü kalitesini artırmak ve avuç içi desenlerinin daha belirgin hale getirilmesini sağlamak amacıyla kullanılmaktadır (Kumar ve Zhang, 2006). Bu veritabanından alınmış örnek görüntüler Şekil 9.'da gösterilmiştir.



Şekil 9. IITD Temassız Avuçizi Veritabanından örnek görüntüler. Bir görüntüye uygulana farklı Gabor filtreleri (URL - 3).


4. YAPILAN ÇALIŞMALAR VE BULGULAR

Bu bölümde tez kapsamında yapılan deneysel çalışmalar ve elde edilen bulgular beraber değerlendirilmiştir. Bir önceki bölümde verilen yöntem ve bu yöntemler için tercih edilen verisetleri üzerinde ulaşılan bulgular detaylı bir şekilde anlatılmaya çalışılmıştır. Dolayısıyla yöntem bölümünde verilen sistematik yaklaşıma uygun olarak bulgular sunulmuştur. Çalışmanın ilk aşaması basit ağ modeli ile başlatılmış olup, tez kapsamında ele alınan konuların eklenerek ilerlendiği bir yol izlenmiştir.

4.1. Basit Ağ Modelinin Uygulanması

İlk oluşturulan model sadece sınıflandırıcı yapacak iki adet YSA katmanı içermektedir. Bu model tüm çalışma için temel model olarak seçilmiş olup, bu model üzerine eklemeler yapılarak özellik çıkarma katmanlarının ve başlangıç ağırlık belirleme tekniklerinin etkileri tez süresince incelenmiştir. Bu model için her ne kadar rastlantısallık içeren süreçlerde tohumlama kullanılmış olsa da özellikle sinir hücrelerini barındıran doğrusal katmanlarda ve hatayı minimize eden optimizasyon algoritmasındaki rastlantısallık süreçlerine müdahale edilmemiştir. Aksi takdirde modelin tüm nöronlarının aynı karakteristik davranışları sergileyecek ve model eğitimi gerçekleştiremeyecektir. Rastlantısallığın etkisinin kayıp ve skor değerlerine olan etkisinin azaltılması ve doğru analizin yapılabilmesi için de her kurulan model 10 defa tekrarlanarak eğitilmiştir. Her bir çalıştırmada epochalara göre elde edilen değerlerin ortalaması alınarak genel bir kanı elde edilmeye çalışılmıştır. İlk model için gerçekleştirilen eğitim ve validasyon süreçlerine ait kayıp değeri ve doğruluk skorları Şekil 10'da verilmiştir.

Şekillerde hem eğitim hem de validasyon verisinden elde edilen değerler gösterilmiştir. Çalışma kapsamında ele alınan değerler kayıp değerleri ve doğrulaam skorlarıdır. Tüm değerlerin epochlara göre iteratif olarak nasıl ilerlediği açık bir şekilde gösterilmeye çalışılmıştır. Tez çalışması kapsamında ele alınan tüm modeller rastlantısallığın etkisinin azaltılması için 10 defa tekrarlı çalıştırılmıştır. Bunlar grafiklerde Çalıştırma No ile farklı renklerde gösterilmiştir. Ayrıca tüm çalışmalardan elde edilen ortalama değerler de kırmızı kesikli çizgi ile gösterilmiştir. Bununla beraber ortalama değerlerin karşılaştırmasının yapılabilmesi için tablolar şeklinde de sunulmuştur.




Şekil 10. İki katmanlı YSA modelinden elde edilen başarımlar değerleri

Şekil 10.'da görüldüğü üzere iki katmanlı sınıflandırıcı içeren ağ modelinde eğitim kayıp değeri 0.6'nın biraz üzerinde başlamakta olup, 20. epoch sonucunda 0.36 seviyesinde sonlanmaktadır. Buna paralel olarak doğruluk skorları 0.8 seviyelerinde başlayıp 0.87 seviyesine kadar çıkmaktadır. Validasyon verilerinde ise kayıp değeri ve doğruluk değerleri ile ilgili çok fazla iyileşme gerçekleşmemektedir. Model için gerçekleştirilen tüm çalışmaları için benzeri sonuçlar elde edilmiş olup, validasyon verilerindeki doğruluk oranları 0.83 seviyesinin biraz üstüne çıkabilmiştir. Basit ağ modelindeki tüm çalışmalardan elde edilen ortalama başarımlar değerleri Tablo 1'de verilmiştir. Ayrıca bu değerler Şekil 11'de grafik şeklinde de sunulmuştur.


Tablodaki verilen ilerleyişini gösteren Şekil 11'deki grafikler eğitim verisinin epochlara göre sürekli daha iyi değerlere ulaştığını gösterse de validasyon verilerinde bu iyileşmenin gerçekleşmediğine de göstermektedir. Özellikle ilerleyen epochlarda kayıp ve doğruluk değerleri arasındaki fark açılmaktadır.

Tablo 1. Basit ağ modelinden elde edilen ortalama başarımların değerleri

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	0.6086	0.8016	0.5244	0.8205
2	0.4693	0.8373	0.5359	0.8222
3	0.4415	0.8458	0.5482	0.8241
4	0.4317	0.8500	0.5326	0.8270
5	0.4206	0.8527	0.5339	0.8305
6	0.4121	0.8563	0.5383	0.8297
7	0.4081	0.8578	0.5423	0.8290
8	0.4082	0.8591	0.5363	0.8335
9	0.4023	0.8609	0.5561	0.8321
10	0.3975	0.8619	0.5606	0.8301
11	0.3874	0.8631	0.5304	0.8352
12	0.3797	0.8648	0.5339	0.8348
13	0.3793	0.8652	0.5371	0.8335
14	0.3776	0.8660	0.5471	0.8341
15	0.3732	0.8677	0.5414	0.8349
16	0.3721	0.8678	0.5391	0.8365
17	0.3695	0.8688	0.5542	0.8345
18	0.3688	0.8690	0.5530	0.8349
19	0.3662	0.8697	0.5514	0.8379
20	0.3626	0.8706	0.5620	0.8375
Genel Ort.	0.4068	0.8578	0.5429	0.8316



(a)



(b)

Şekil 11. Basit ağ modelinden elde edilen ortalama başarımların değerleri.

Ortalamalara ait tablo ve grafiklerde görüldüğü üzere özellikle validasyon değerleri epochlar süresince çok iyileşme göstermemektedir. Doğruluk değeri en yüksek 19. epochda 0.8379 seviyesinde kalmaktadır. Bu değer ilk epochdaki 0.8205'a çok yakın bir değerdir. Ayrıca kayıp değerleri eğitim aşamasında 0.36 civarına kadar düşmüş olmasına rağmen validasyon aşamasında neredeyse tüm epochlarda 0.54 seviyelerindedir. Dolayısıyla ilk kurulan basit modelin iyi bir sınıflandırıcı olduğu söylenemez. Daha

başarılı bir sınıflandırma yapabilmek için bu modele evrişim katmanları eklenmeye başlanmış ve bu katmanların başlangıç değeri belirlemelerinin etkileri incelenmiştir.

4.2. Tek Evrişim Katmanının Sınıflandırmaya Etkisi

Bu aşamada mevcut modele bir adet evrişim katmanı eklenerek daha fazla öznetelik üretilmesi ve başarımın artırılması amaçlanmıştır. Eklenen evrişim katmanı bu aşamadan sonraki başlangıç değeri belirleme çalışmalarının tümünde ortak bir özellik olarak kullanılmıştır. Böylece her bir durumun ayrıca irdelenmesi imkanı sağlanmıştır. Bu amaçla basit ağ modeline 64 filtreden oluşan bir evrişim katmanı eklenmiştir. Bu katmanın farklı filtre boyutlarındaki versiyonları için deneyler yapılmıştır. Genellikle literatürdeki çalışmalarda sıklıkla 3x3'lük filtre boyutları tercih edilse de 5x5, 7x7, 9x9 ve 11x11 boyutlarının da tercih edildiği durumlar mevcuttur. Bu çalışmada da tüm boyutlar ayrı ayrı test edilmiştir. Eklenen evrişim katmanının dahil olduğu model yapısı aşağıdaki şekilde verilmiştir. Evrişim katmanındaki filtre boyutları arttıkça padding boyutu da artacaktır. Bu çalışmada ek bir veri eklemesinin yapılmaması adına padding işlemi uygulanmamıştır. Dolayısıyla modelin filtre boyutu arttıkça düzleştirme katmanına giren özellik sayısı azalmaktadır. Oluşturulan model yapısı daha önce verilen Şekil &'da gösterildiği gibidir.


Tek evrişim katmanının eklendiği bu modelde parametre sayısı basit ağ modeline göre ciddi oranda artmıştır. Basit ağ modelindeki toplam parametre sayısı 814.090 iken bu modelde 44.314.250 olmuştur. Bu sayının ciddi oranda artmasının sebebi eklenen evrişim katmanının 64 filtreye sahip olmasıdır. Oluşturulan model üzerinde yapılan deneysel çalışmalarda evrişim katmanının ilk değerlerinin belirlenmesi amacıyla başlangıçta literatürde bilinen teknikler üzerinden gidilmiştir ve ilk olarak sabit değerlerle başlatma teknikleri uygulanmıştır.

4.3. Sabit Değerlerle Başlatma

Modelin sabit değerlerle başlatılması yaklaşımı beraberinde kullanılacak sabit değerin ne olacağı sorunu getirmektedir. Bu konuda genel olarak küçük değerlerle başlatma yaklaşımı ele alınmış olmasına rağmen, tüm yaklaşımların sonuçları irdelenmeye çalışılmıştır. Bu amaçla 0 (Sıfır), 1 (Bir), çok küçük ve çok büyük değerlerle başlatma yaklaşımları üzerinde deneysel çalışmalar yapılmıştır.

4.3.1. Sabit Sıfır (0) Değerleriyle Başlatma

Sıfır değer başlangıç yöntemi, sinir ağlarının ağırlıklarının tümünü sıfır olarak başlatmayı ifade eder. Bu yöntem, ağırlıkların başlangıç değerlerini belirlerken en basit ve en anlaşılır yaklaşımı temsil eder. Evrişim katmanının sıfır (0) değerler ile başlatılması sonucunda eğitim ve validasyon aşamalarında elde edilen kayıp değerlerine ait grafikler Şekil 12’de verilmiştir. Bu şekilde hem eğitim hem validasyon için verilen kayıp değerleri iki farklı grafikte gösterilmesi tercih edilmiştir. Örneğin Şekil 12’(a)’da verilen eğitim verisi kayıp değeri Şekil 12 (b)’de logaritması alınarak gösterilmiştir. Burada amaç ilk epochda çok büyük değerlerle başlayan ve sonraki epochlarda birbirine çok yakın olan bu değerlerin açık bir şekilde gösterilmesidir.




Şekil 12. Sabit Sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.

Şekil 12’den de anlaşılacağı üzere eğitim aşamasında kayıp değerleri çok büyük değerlerle başlamış olup, sonraki epochlarda 1’in altına düşmeyi başarmıştır. Validasyon

aşamasında ise daha tutarlı bir grafik elde edilmiştir ve kayıp değerleri 1 civarında kalmıştır. Tüm çalıştırmalardan elde edilen doğrulama değerlerine ait grafikler Şekil 13’de verilmiştir. Eğitim aşamasında 0.9 seviyelerine ulaşan çalışma denemeleri olmuştur. Buna rağmen validasyon aşamasında yine 0.8’in biraz üzerinde kalmıştır. Bu durumu özellikle ortalama değerlerin gösterildiği Şekil 14’de ve Tablo 2’de daha açık bir şekilde görülmektedir.


Şekil 13’de daha ilginç bir durum dikkat çekmektedir. 10 farklı çalışmada elde edilen sonuçlara bakıldığında bunlardan ikisine ait grafiklerde modelin eğitilemediği bir çalışmada 5., başka bir çalışmada ise 7. epochda 0.1 değerinde sabitlenmiş doğruluk değerlerine ulaşılmıştır. Bu denemeler aslında sıfır ile başlatma durumunun stabil olmadığını bazı çalıştırmalarda modelin hiç öğrenemeyeceğini açık bir şekilde göstermektedir.




Şekil 13. Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen doğruluk değerleri.

Şekil 14’de ve Tablo 2’de sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama doğruluk değerleri verilmiştir. Ortalama değerlere bakıldığında kayıp değerinin eğitim aşamasında 0.6409’a validasyon aşamasında en düşük 0.9110 seviyesine ulaştığı, doğruluk değerlerinin ise eğitim aşamasında 0.7583 validasyon aşamasında ise 0.7081 seviyesinde ulaştığı görülmektedir. Ortalama değerlerinin düşük olmasının sebebi yukarıda bahsedildiği gibi 2 çalıştırmada eğitimi yapılamamış olan denemelerdir. Ortalama değerler açısından değerlendirildiğinde sabit sıfır (0) değerleri ile başlatılan evrişim katmanı eklenmiş ağ modelinin, eklenmemiş basit ağ modelinden daha başarısız olduğu söylenebilir. Diğer taraftan eğitimi yapılamayan iki

çalıştırma deneyi ihmal edildiğinde validasyon doğruluk değerlerinde 0.84 seviyelerine çıkılarak basit modele göre kısmi bir iyileşme durumu söz konusudur.



(a)



(b)

Şekil 14. Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar.

Tablo 2. Sabit sıfır (0) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	15.9925	0.4658	2.4556	0.4742
2	2.0244	0.4076	2.4373	0.3833
3	2.0449	0.3370	2.2066	0.3279
4	1.9381	0.3023	1.9569	0.2849
5	1.8774	0.3016	1.8561	0.3126
6	1.7803	0.3220	1.6898	0.3688
7	1.5999	0.3852	1.5340	0.4285
8	1.4138	0.4536	1.3859	0.4763
9	1.2735	0.5027	1.2751	0.5260
10	1.1231	0.5714	1.0193	0.6160
11	0.9325	0.6415	0.9790	0.6347
12	0.8718	0.6653	0.9407	0.6583
13	0.8143	0.6868	0.9241	0.6709
14	0.7761	0.7014	0.9110	0.6776
15	0.7399	0.7157	0.9154	0.6865
16	0.7001	0.7325	0.9210	0.6957
17	0.6794	0.7406	0.9446	0.6987
18	0.6656	0.7466	0.9615	0.7004
19	0.6531	0.7523	0.9800	0.7035
20	0.6409	0.7583	0.9886	0.7081
Genel Ort.	1.9271	0.5595	1.3641	0.5516


Sabit sıfır (0) değerleri ile evrişim katmanını başlatma yaklaşımı önemli dezavantajlar içermektedir ve modern derin öğrenme uygulamalarında genellikle tercih edilmez. Ağırlıkların sıfır olarak başlatılması, her katmandaki aktivasyonların ve gradyanların aynı olmasına yol açar. Bu durum, modelin derin katmanlarında bilgi akışını engeller ve öğrenme sürecini yavaşlatır. Tüm ağırlığı 0 olarak ayarladığında, kayıp fonksiyonuna göre türev ağıdaki her ağırlık için aynıdır. Bu nedenle tüm ağırlıklar sonraki yinelemede aynı değerlere sahiptir. Modeli doğrusal bir modele eşdeğer yapmaktadır. Dolayısıyla her nöron aynı kayıp değerini hesaplayacak ve her yinelemede, aynı gradyan güncellemesini yapacaktır. Bu, her nöronun benzer özellikleri öğreneceği ve ağırlıkların verilerden ilginç kalıpları öğrenecek kadar çeşitli olmayacağı anlamına gelmektedir. Ayrıca ağırlıklar sıfır olduğunda, ilgili katmandan geçen sinyaller de sıfırlanır. Bu durum, derin ağlarda sinyal ve gradyanların geriye doğru yayılmasını engeller. Özellikle derin öğrenme modellerinde, sinyalin ileri ve geriye doğru etkin bir şekilde yayılması kritik öneme sahiptir. Sıfır ağırlıklar, bu sürecin tamamen durmasına neden olabilmektedir.

4.3.2. Sabit Bir (1) Değerleriyle Başlatma


Evrişim katmanının sıfır (0) ile başlatılması ağırlık parametrelerindeki çarpım işleminden kaynaklanan yakınsama sorunlarına neden olduğundan dolayı sabit bir (1) değeri ile başlatılmasının daha uygun sonuçlar üretebileceği fikrini ortaya çıkarmıştır. Çalışmanın bu aşamasında başlangıç değerleri bir (1) olarak belirlenerek denemeler yapılmıştır. Yapılan denemelerde elde edilen kayıp değerleri ve doğruluk değerleri Şekil 15'te verilmiştir.

Şekil 15'den de anlaşılacağı üzere bu denemelerde eğitim aşamasında doğruluk değeri 0.9'ların üzerine çıkmayı başarmıştır. Validasyon aşamasında da 0.9 seviyelerine yaklaşmıştır. Kayıp değerlerinde de yine sıfır (0) değeri ile başlatma denemelerine göre daha düşük değerler elde edilmiştir. Burada dikkat çeken yine bir çalıştırmada 12. epochdan sonra modelin öğrenmesinin durmasıdır. Sıfır (0) başlatma ile karşılaşılan benzeri durum burada da gerçekleşmiştir. Şekil 16'da ortalama doğruluk ve kayıp değerleri verilmiştir.

Eğitim ve validasyon değerlerinin biribiri ile uyumlu olması sıfır (0) ile başlatmaya göre daha avantajlı olduğunu göstermektedir. Bazı denemelerde doğruluk değeri 0.9'ların üzerine çıkmış olmasına rağmen ortalama doğruluk değeri 0.78'ler seviyesinde kalmaktadır. Bu değerler Tablo 3'ten de takip edilebilir.



Şekil 15. Sabit bir (1) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.



Şekil 16. Sabit bir (1) değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Ağırlıkların bir sabit değerle (örneğin 1) başlatılması, ağıdaki aktivasyonların ve gradyanların boyutunu büyük ölçüde artırabilmektedir. Bu, eğitim sırasında gradyanların patlamasına neden olabilir. Gradyanların patlaması, ağırlık güncellemelerinin aşırı büyük olmasına ve modelin kararsız hale gelmesine yol açmaktadır. Aynı şekilde, her katmanda ağırlıklar sabit olduğu için, gradyanlar hızla düşebilmekte ve kaybolabilmektedir, bu da ağırlıkların derin katmanlarında etkili öğrenmeyi engellemektedir.

Tüm ağırlıklar 1 ile başlatıldığında, nöronlar arası ayırım da kaybolmakta ve tüm nöronlar aynı ağırlıklara sahip olduğu için girdiye aynı tepkiyi vermektedir. Bu durum, ağırlıkların farklı özellikler öğrenmesini engeller ve etkili bir şekilde öğrenme sürecini durdurmaktadır. Ağırlıkların eşit olması, nöronların eğitim sürecinde farklılaşmasını önlemekte, böylece ağırlıkların öğrenme kapasitesi ciddi şekilde sınırlanmaktadır.


Her ne kadar ağırlıkların 1 ile başlatılması genellikle ağırlıkların öğrenme yeteneğini sınırlasa da, eğer bazı özel durumlarda ağırlıklar yine de eğitilebilirse, modelin aşırı uyuma eğiliminde olması mümkündür. Çünkü model, eğitim verisindeki varyasyonları yeterince genelleştiremeyebilir ve yalnızca eğitim setine özgü özellikleri öğrenebilir.

Tablo 3. Sabit bir (1) değeri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	16.0008	0.4557	2.4495	0.4163
2	2.1087	0.3846	2.6984	0.3588
3	2.0713	0.3382	2.0796	0.3235
4	1.8951	0.3222	1.9318	0.3291
5	1.8035	0.3287	1.8179	0.3335
6	1.6554	0.3664	1.6275	0.3928
7	1.3920	0.4662	1.2606	0.5097
8	1.1225	0.5677	1.1169	0.6031
9	0.9377	0.6406	0.8868	0.6643
10	0.7827	0.7015	0.8513	0.7019
11	0.7148	0.7284	0.7908	0.7102
12	0.6648	0.7458	0.7342	0.7415
13	0.5706	0.7849	0.6956	0.7637
14	0.5203	0.8052	0.7036	0.7728
15	0.4937	0.8166	0.7173	0.7764
16	0.4740	0.8242	0.7491	0.7755
17	0.4625	0.8287	0.7702	0.7791
18	0.4466	0.8366	0.7757	0.7831
19	0.4344	0.8413	0.8089	0.7822
20	0.4229	0.8452	0.8354	0.7818
Genel Ort.	1.7487	0.6314	1.2151	0.6150

4.3.3. Çok Küçük Değerlerle Başlatma

Çok küçük değerler ile başlatma stratejisi, sinir ağlarının ağırlıklarını eğitime başlamadan önce oldukça düşük değerlere (yakın veya eşit sıfıra) ayarlamak anlamına gelir. Çalışmanın bu aşamasında bu stratejiye uygun şekilde evrişim katmanının katsayıları 0.001 olarak belirlenmiştir. Buradaki amaç, ağırlıklar tam sıfır alındığında karşılaşılan hesaplamalardaki aritmetik sorunlardan uzaklaşmak ve değerlerin değişmesi sağlayacak bir yapı oluşturmaktır. Çok küçük değer katsayıları ile çalıştırılan modelden elde edilen başarımlar değerlerine ait grafikler Şekil 17’de verilmiştir.




Şekil 17. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Şekillerde görüldüğü üzere her bir çalıştırmaya ait değerler birbirleriyle uyumlu bir şekilde ilerlemektedir. Eğitim değerlerinde beklenildiği üzere kayıp değerleri azalmakta 0.12 seviyelerine kadar inmektedir. Ayrıca doğruluk değerleri 0.8 seviyelerinden başlayıp 0.97 seviyelerine kadar çıkmaktadır. Diğer taraftan validasyon sürecinde ise kayıp

değerleri başlangıçtaki epochlarda düşmesine rağmen, özellikle 4. epochtan sonra artmaya başlamaktadır. Ayrıca doğruluk değeri 0.85 seviyelerinde salınım yapmaktadır. Bu da modelin eğitim verilerinde başarılı olarak ilerlemesine rağmen, validasyon verilerinde beklenen performansı göstermemesine sebep olmaktadır.

Ortalama çalıştırma verilerine ait grafik Şekil 18’de verilmiştir. Bu şekilde de açık bir şekilde görüldüğü üzere kayıp verileri için eğitim ve validasyon süreçlerinde uyumsuzluk söz konusudur. Doğruluk verilerinde ise ağırlık aslında istenilen öğrenme performansını vermediği gözlemlenmektedir. Bu değerlerin epochlara göre nasıl ilerlediği Tablo 4’de daha açık bir şekilde gösterilmiştir.



Şekil 18. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Tablo 4’de verilen ortalama eğitim doğruluk değeri en iyi 0.9610 değerine ve en düşük kayıp değeri 0.1222’ye son epochta ulaşmış olması modelin halen daha eğitilebileceği göstermesine rağmen, validasyon denemelerinde bu durum tam aksini belirtmektedir. Dolayısıyla eğitim süreci yine 20 epochta sonlandırılmıştır.

Küçük değerler ile başlatma stratejisinin etkileri ve kullanım durumları çeşitlidir ve belirli avantajlar sunarken bazı dezavantajlara da sahip olabilir. Avantajları açısından incelendiğinde, yüksek ağırlık değerleri, özellikle derin ağlarda gradyan patlaması problemine yol açabilmektedir. Çok küçük ağırlıklar kullanarak bu risk azaltılabilir, çünkü ağırlıkların küçük olması, ağ içindeki aktivasyonların ve dolayısıyla gradyanların büyümesini sınırlayabilmektedir. Ayrıca küçük ağırlıklar, modelin eğitim sırasında daha kararlı olmasını sağlayabilmektedir. Büyük ağırlıklar nedeniyle oluşabilecek yüksek varyanslı çıktılar ve aşırı uyum riski bu şekilde azaltılabilir.

Tablo 4. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	0.5635	0.8092	0.4717	0.8341
2	0.3787	0.8636	0.4476	0.8486
3	0.3401	0.8782	0.4406	0.8521
4	0.2926	0.8941	0.4703	0.8572
5	0.2644	0.9050	0.5052	0.8579
6	0.2435	0.9133	0.5425	0.8598
7	0.2248	0.9202	0.5724	0.8577
8	0.2042	0.9276	0.6162	0.8593
9	0.2003	0.9307	0.6908	0.8565
10	0.1848	0.9363	0.6981	0.8616
11	0.1745	0.9408	0.7621	0.8580
12	0.1668	0.9436	0.8172	0.8577
13	0.1726	0.9440	0.8482	0.8563
14	0.1557	0.9488	0.8938	0.8579
15	0.1446	0.9523	0.9901	0.8553
16	0.1373	0.9543	1.0276	0.8613
17	0.1475	0.9535	1.0362	0.8605
18	0.1406	0.9565	1.1090	0.8596
19	0.1360	0.9576	1.2036	0.8597
20	0.1222	0.9610	1.2354	0.8573
Genel Ort.	0.2197	0.9245	0.7689	0.8564

Çok küçük değerlerle başlatmanın dezavantajları ise özellikle derin ağlarda, aktivasyon değerlerinin ve gradyanların hızla düşmesine sebep olabilmektedir. Bu durum, gradyan kaybolması problemine yol açmakta ve ağın alt katmanlarında etkili öğrenmenin gerçekleşmesini engellemektedir. Bununla beraber ağırlıkların çok düşük olması, ağın girdi üzerindeki etkisinin minimal olması demektir. Bu, ağın öğrenme sürecini yavaşlatabilmekte ve eğitim süresini uzatabilmektedir. Tüm ağırlıklar çok küçük ve eşit bir değerle başlatıldığında, nöronlar arasında gerekli ayırım sağlanamaz ve tüm nöronlar benzer şekilde güncellenmeye devam eder. Bu durum, ağın farklı özellikleri öğrenebilmesini engellemektedir.


4.3.4. Çok Büyük Değerlerle Başlatma

Çalışma kapsamında ağırlıkların çok küçük değerlerle başlatılması stratejisine alternatif olarak çok büyük değerlerle başlatma stratejisi de uygulanmıştır. Çok büyük değerlerle başlatma stratejisi, sinir ağlarının ağırlıklarını eğitime başlamadan önce oldukça yüksek değerlere ayarlamak anlamına gelir. Bu yaklaşım, çeşitli riskler taşır ve genellikle önerilmez. Bu durum özellikle gradyan patlaması denen olayın

gerçekleşmesine neden olabilir. Gradyan patlaması, ağıdaki gradyanların kontrolsüz bir şekilde büyümesi durumudur.

Çok büyük değerlerle başlatma yaklaşımı için çalışma için geliştirilen tek evrişim katmanlı ağ modelinde evrişim katsayıları 1000 olarak belirlenmiştir. Bu değer tüm ağ parametreleri göz önüne alındığında çok daha büyük değerlerin üretilmesi için yeterli olacaktır.


Bu stratejiye göre çalıştırılmış olan ağ modelinden elde edilen kayıp değerleri Şekil 19'da verilmiştir. Farklı çalıştırmalarda elde edilen kayıp değerleri arasındaki farklılıkların gösterilmesi için yine logaritmaları alınmış hali grafik listesine eklenmiştir.



Şekil 19. Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.


Kayıp değerleri açısından incelendiğinde eğitim ve validasyon aşamasında ilk epochlarda elde edilen değerlerin çok büyük olduğu ve hızlı bir şekilde aşağı düştüğü görülmektedir. Farklı çalıştırma zamanlarındaki elde edilen değerler birbirleriyle uyumlu

hareket etmekte olmasına rağmen, kayıp değerlerin ulaştığı değerler (özellikle validasyon aşamasında) diğer başlatma stratejilerine göre çok büyüktür. Bu durum Tablo 5’de daha açık bir şekilde incelenebilir. Kayıp değerlerindeki düşük ilk bakışta model için başarılı gibi bir algı oluşmaktadır. Fakat doğruluk değerlerine bakıldığında ise ideal değerlerden çok uzak olduğu farkedilmektedir. Modelden elde edilen doğruluk değerleri aşağıdaki şekilde gösterilmiştir.



Şekil 20. Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen doğruluk değerleri.

Modelin her bir epochda üretmiş olduğu tüm çalıştırmalara ait ortalama değerler Şekil 21’de ve Tablo 5’te verilmiştir. Bu değerler de yukarıda bahsedilen durumu açık bir şekilde göstermektedir. Tüm durumlar değerlendirildiğinde modelin çok büyük değerlerle öğrenemediği görülmüştür.



Şekil 21. Çok büyük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama değerler.

Tablo 5. Çok küçük başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	18654.4282	0.1753	710.3988	0.1311
2	321.3719	0.1215	769.5141	0.1181
3	314.0736	0.1156	447.6949	0.1136
4	224.5098	0.1134	249.8617	0.1105
5	145.2655	0.1114	199.4149	0.1092
6	139.2988	0.1097	99.7107	0.1083
7	79.8341	0.1090	185.4651	0.1074
8	56.8525	0.1084	93.3929	0.1066
9	32.7766	0.1083	70.8536	0.1064
10	27.8199	0.1079	68.0847	0.1059
11	44.9399	0.1079	139.0820	0.1062
12	50.0382	0.1079	74.2046	0.1059
13	51.9371	0.1076	128.9179	0.1062
14	53.0099	0.1077	62.3989	0.1057
15	36.0207	0.1076	89.2810	0.1052
16	21.1887	0.1070	79.6944	0.1053
17	30.4665	0.1070	57.0052	0.1052
18	14.6787	0.1069	57.6049	0.1054
19	8.5322	0.1071	63.9254	0.1052
20	29.5811	0.1070	58.5056	0.1052
Genel Ort.	1016.8312	0.1127	185.2506	0.1086

Çok büyük ağırlıklar, modelin eğitim verilerindeki küçük dalgalanmaları ve gürültüyü dahi modellemesine neden olabilmektedir. Bu, modelin genelleme yeteneğini azaltmakta ve yeni, görülmemiş veriler üzerinde kötü performans göstermesine yol açabilmektedir. Çok büyük ağırlıklar, ağırlık girdi üzerindeki küçük değişikliklere aşırı tepki vermesine neden olabilmektedir, bu da modelin genel olarak daha az dayanıklı olmasına sebep olur. Bu durum, modelin pratik kullanımını zorlaştırmakta ve bazı durumlarda modelin faydalı bilgileri işlemesini engelleyebilmektedir.

Çok büyük ağırlıklarla başlatılan bir model, ağırlık güncellemelerinin yüksek volatilitesi nedeniyle daha yavaş ve daha az etkili bir şekilde eğitilebilir. Ayrıca, büyük ağırlıklar, aktivasyon fonksiyonlarının doymuş bölgelerine girmesine neden olabilir (örneğin, sigmoid ve tanh fonksiyonlarında), bu da geri yayılım sırasında etkili gradyanların yok olmasına yol açabilir.

4.4. Rastgele Değerlerle Başlatma


Sabit değerlerle yapılan deneysel çalışmalarda çok düşük değerler verilmesi durumu dışında diğer değerlerde beklenen sonuçlara ulaşılamamıştır. Literatürde yapılan çalışmalara bakıldığında küçük değerler içeren fakat her ağırlığın aynı olmadığı başlangıç değerlerinin verildiği modellerde daha başarılı sonuçlar elde edildiği görülmektedir. Parametre sayısı modellerde çok fazla olduğundan bu değerlerin başlangıç durumlarının rastgele belirlenmesi modellerin hem uygulanabilirliğini hem de genellebilirliğini artırmaktadır. Çalışma bu aşamadan sonra rastgele değerlerle başlatılan yaklaşımlar üzerine ilerletilmiştir. Bu yaklaşımlar içerisinde genel kabul görmüş ESA kütüphanelerinde doğrudan kullanılması mümkün olan bazı yaklaşımlar vardır. Dolayısıyla bunların performansları bu bölümde irdelenmiştir.

4.4.1. He-Kaiming Katsayılarıyla İlk Değerlerin Belirlenmesi


He-Kaiming başlatma yöntemi, derin öğrenme modellerinin özellikle doymayan aktivasyon fonksiyonları ile çalıştığında karşılaştığı bazı temel zorlukları ele almak amacıyla geliştirilmiştir. He vd. (2015) tarafından sunulan bu yöntem, özellikle ReLU ve benzeri aktivasyon fonksiyonları için tasarlanmıştır. Bu başlatma stratejisi, sinir ağlarının daha derin katmanlarında etkin bir şekilde öğrenmesini sağlamak ve gradyan kaybolması sorununu minimize etmek için bir nörona gelen bağlantı sayısına bağlı olarak ağırlıkları başlatır.

He-Kaiming başlatma, ağırlıkları ortalaması sıfır olan ve varyansı $2/n$ olan bir normal dağılımdan rastgele seçer; burada n ilgili nörona gelen bir önceki katmandaki nöron sayısıdır. Bu, ReLU aktivasyon fonksiyonunun doğasını göz önünde bulunduran bir düzenlemedir. ReLU, negatif değerler için sıfır dönerken, pozitif değerler için girdi değerini olduğu gibi geçirir. Bu durum, aktivasyonların ve dolayısıyla gradyanların katmanlar arası geçişinde dengesizliklere yol açabilmektedir. He başlatma, bu dengesizliği azaltmayı hedefler ve ağırlıkların derin katmanlarında bile etkin öğrenmeyi destekler.


Çalışma kapsamında He – Kaiming başlangıç değerleri ile başlatılan modelden elde edilen kayıp ve doğruluk değerleri Şekil 22’de verilmiştir. Bu grafiklere bakıldığında eğitimde çok yüksek değerlerde başlayan kayıp değerinin hızlı bir şekilde düştüğü görülmektedir. Fakat validasyon aşamasında kayıp değeri her epochda yükselmeye başlamaktadır. Doğruluk değerlerine bakıldığında ise eğitimde 0.95’in üzerine çıkılmış olmasına rağmen, validasyon aşamasında tüm epochlarda 0.87 civarında gezinmektedir.




(a)



(b)




(c)




(d)

Şekil 22. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen kayıp değerleri.



(a)



(b)

Şekil 23. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Şekil 23’te verilen ortalama değerler üstteki şekili daha iyi açıklamaktadır. Şöyle ki eğitim ve validasyona ait değerler arasındaki fark ilerleyen epochlarda daha da açılmaktadır. Bu değerler Tablo 6’da daha açık bir şekilde takip edilebilir. Tabloya ve şekle bakıldığında validasyon verilerindeki epochlara göre yükseliş te dikkat çekicidir. Bu durum model parametrelerini eğitim için çok yeterli olmadığını göstermektedir.

Tablo 6. He – Kaiming başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	5.1127	0.8295	0.4593	0.8408
2	0.3536	0.8764	0.4512	0.8534
3	0.3156	0.8903	0.4870	0.8521
4	0.2890	0.9002	0.4796	0.8612
5	0.2613	0.9091	0.4841	0.8643
6	0.2368	0.9180	0.5162	0.8620
7	0.2234	0.9240	0.5470	0.8671
8	0.2170	0.9280	0.5856	0.8683
9	0.2035	0.9339	0.6242	0.8651
10	0.1916	0.9387	0.6661	0.8624
11	0.1765	0.9446	0.7356	0.8662
12	0.1803	0.9457	0.7949	0.8690
13	0.1702	0.9494	0.8508	0.8689
14	0.1609	0.9527	0.9206	0.8673
15	0.1608	0.9539	0.9937	0.8684
16	0.1513	0.9570	1.0689	0.8687
17	0.1415	0.9600	1.1152	0.8680
18	0.1389	0.9616	1.1755	0.8645
19	0.1429	0.9617	1.1868	0.8696
20	0.1381	0.9629	1.2889	0.8691
Genel Ort.	0.4483	0.9299	0.7716	0.8638


He başlatma yöntemi, ağırlık eğitim sürecinde daha hızlı konverjansa ulaşmasını sağlar. Bu durum ağırlıkların uygun bir şekilde ölçeklenmesi sayesinde aktivasyon ve gradyanların ağı boyunca etkin bir şekilde yayılmasından kaynaklanır. He başlatma, özellikle derin sinir ağlarında gradyan kaybolması veya patlamasını önlemede etkilidir. Ağırlıkların başlangıçtaki uygun dağılımı, öğrenme sürecinin başlarında gradyanların kaybolmasını veya aşırı büyümesini engeller. Ayrıca bu yöntem, modelin eğitim sürecinde daha stabil olmasını da sağlamaktadır. Ağırlıkların dengeli başlatılması, özellikle farklı veri kümeleri ve çeşitli eğitim senaryolarında modelin performansının tutarlı olmasına katkıda bulunmaktadır.

4.4.2. Normal Dağılımla Başlatma

Normal dağılım ile başlatma, ağırlıkların belirli bir ortalama (μ) ve standart sapma (σ) ile tanımlanan normal (Gaussian) dağılımdan rastgele seçilmesi anlamına gelir. Bu yöntemde, ağırlıklar şu şekilde formüle edilir:

$$w \sim \mathcal{N}(\mu, \sigma^2) \quad (\text{Eşitlik 5})$$

Bu formül, ağırlıkların ortalaması μ ve varyansı σ^2 olan normal bir dağılımdan seçildiğini ifade eder. Normal dağılım ile başlatma, özellikle ağırlık katmanlarında aktivasyonların belirli bir düzeyde tutulmasını ve gradyanların dengeli bir şekilde yayılmasını amaçlar. Bu başlatma yöntemi, ağırlıkların aşırı büyük veya küçük olmadan dengeli bir aralıkta seçilmesine olanak tanır, bu da eğitim sürecinde kararlılık sağlar.




Şekil 24. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar.

Çalışma kapsamında normal dağılıma göre başlatma çalışmalarında eğitim verilerindeki kayıp değeri 0.1 seviyelerine kadar inmiş olmasına rağmen, validasyon verilerinde ilerleyen epochlarda kayıp değerleri artmaktadır. Şekil 24’de gösterilen bu durum doğruluk değerlerine de yansımaktadır.

Eğitim verilerindeki doğruluk değerleri 0.98 seviyesine kadar çıkmaktadır, fakat validasyon verilerinde ise bu değer 0.86 seviyesinde kalmaktadır. Bu strateji He – Kaiming başlatma stratejisi ile benzeri bir seyir izlemektedir.

Ortalama kayıp ve doğrulama değerlerinin gösterildiği Şekil 25’te özellikle validasyon kayıp değerinin epochlar ilerledikçe artması dikkati çekmektedir. Validasyon doğruluk değerlerinin 0.87 seviyesinde kalması ise modelin öğrenemediğini göstermektedir. Bu ortalama değerlerinin değişimi Tablo 7’den de takip edilebilir.



Şekil 25. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Normal dağılım ile başlatma, ağırlık öğrenme süreci üzerinde çeşitli olumlu etkilere sahiptir. İlk olarak, ağırlıkların dengeli bir aralıkta seçilmesi, ağırlık eğitim sürecinin başlangıcında aktivasyonların ve gradyanların aşırı büyük veya küçük olmasını önler. Bu, özellikle derin ağlarda gradyan kaybolması ve patlaması gibi sorunların önlenmesine yardımcı olur. Ayrıca, normal dağılım ile başlatma, modelin daha hızlı konverjans göstermesini ve eğitim sürecinin daha kararlı olmasını sağlar.

Ancak, bu yöntemin bazı sınırlamaları da bulunmaktadır. Normal dağılım ile başlatma, genellikle aktivasyon fonksiyonlarının doğasına ve ağırlık derinliğine bağlı olarak optimize edilmelidir. Örneğin, ReLU gibi doymayan aktivasyon fonksiyonları, negatif değerler için sıfır döndürdüğü için, bu tür fonksiyonlarla çalışan katmanlar için normal dağılım ile başlatma her zaman ideal olmayabilir.

Tablo 7. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	0.5602	0.8285	0.4030	0.8585
2	0.3224	0.8863	0.4409	0.8614
3	0.2589	0.9088	0.4918	0.8637
4	0.2303	0.9227	0.5478	0.8652
5	0.1897	0.9362	0.6405	0.8656
6	0.1694	0.9452	0.7416	0.8610
7	0.1791	0.9489	0.8172	0.8658
8	0.1490	0.9561	0.9317	0.8634
9	0.1514	0.9583	1.0376	0.8637
10	0.1260	0.9650	1.1609	0.8651
11	0.1446	0.9640	1.2862	0.8636
12	0.1253	0.9684	1.3357	0.8675
13	0.1426	0.9679	1.4741	0.8637
14	0.1194	0.9716	1.5398	0.8677
15	0.1143	0.9741	1.6642	0.8631
16	0.1106	0.9758	1.7784	0.8669
17	0.1274	0.9750	1.9548	0.8646
18	0.1121	0.9775	1.9285	0.8677
19	0.1047	0.9795	2.1189	0.8671
20	0.1040	0.9800	2.3161	0.8627
Genel Ort.	0.1771	0.9495	1.2305	0.8644

He-Kaiming başlatma ile normal dağılım ile başlatma arasındaki temel fark, ağırlıkların varyansının belirlenme şeklidir. Kaiming başlatma, ReLU gibi aktivasyon fonksiyonlarının doğasına uygun olarak varyansı optimize ederken, normal dağılım ile başlatma, sabit bir ortalama ve standart sapma kullanarak daha genel bir yaklaşım benimser. Bu nedenle, Kaiming başlatma, özellikle derin ve karmaşık ağlar için daha uygun olabilirken, normal dağılım ile başlatma daha basit ve genel amaçlı uygulamalar için yeterli olabilir.

4.4.3. Uniform Dağılımla Başlatma

Uniform (düzgün) dağılım ile başlatma, sinir ağlarında ağırlıkların belirli bir aralıkta rastgele olarak başlatılması anlamına gelir. Bu yaklaşım, genellikle ağırlıkları küçük ve kontrol edilebilir değerlerle başlatmak ve ağırlık başlatmanın simetrisini kırmak için kullanılır. Ağırlıklar, belirli bir minimum ve maksimum değer arasında düzgün bir şekilde dağıtılarak başlatılır. Bu, -limit ile +limit arasında rastgele değerler alınarak

gerçekleştirilir, burada limit değerleri genellikle ağırlık matrisinin boyutuna bağlı olarak hesaplanır.

Uniform dağılım ile başlatma yöntemi, ağırlıkların belirli bir minimum ve maksimum değer arasında eşit olasılıkla rastgele seçilmesi esasına dayanır. Bu yöntemde, ağırlıklar aşağıdaki gibi formüle edilir:


$$w \sim U(a, b) \quad (\text{Eşitlik 6})$$

Burada $U(a, b)$, a ve b arasında uniform dağılımdan seçilen rastgele bir değeri ifade eder. Bu aralık genellikle, ağırlıkların belirli bir ölçekle sınırlı tutulmasını sağlayarak, aşırı büyük veya küçük değerlerin ortaya çıkmasını önler. Genellikle, aralık $\left[-\frac{1}{\sqrt{n}}, \frac{1}{\sqrt{n}}\right]$ veya $\left[-\frac{\sqrt{6}}{\sqrt{x_{in}+x_{out}}}, \frac{\sqrt{6}}{\sqrt{x_{in}+x_{out}}}\right]$ şeklinde belirlenir. Burada x_{in} ve x_{out} katmandaki giriş ve çıkış nöronlarının sayısını temsil eder.


Bu başlatma yöntemi, modelin daha hızlı konverjans göstermesini sağlayabilir. Dengeli başlatılan ağırlıklar, ağırların erken aşamalarda daha verimli öğrenmesine olanak tanır. Ancak, uniform dağılım ile başlatma, her zaman en optimal çözüm olmayabilir. Bu yöntem, özellikle derin ve karmaşık ağlarda, belirli aktivasyon fonksiyonlarıyla tam uyum göstermeyebilir. Örneğin, ReLU gibi aktivasyon fonksiyonları kullanıldığında, ağırlıkların başlangıç değerlerinin daha dikkatli bir şekilde belirlenmesi gerekebilir.

Çalışmanın bu aşamasında tek evrişim katmanlı ağ yapısının evrişim katmanı uniform dağılım ile ilk değer başlangıcı yapılmıştır. Alt ve üst limit değerleri -1 ve 1 tutulmuştur. Dolayısıyla çok küçük değerlerle başlatma yaklaşımına benzer veya daha iyi sonuçların gözlemlenmesi beklenmiştir. Bu model çalıştırıldığında eğitim ve validasyon verilerinden elde edilen başarımların değerleri Şekil 26'da verilmiştir.


Şekildeki grafikler incelendiğinde karakteristik olarak normal dağılıma benzer bir ilerlemenin söz konusu olduğu anlaşılmaktadır. Bu çalıştırmada da eğitim kayıp değerleri ideallere yakın (yaklaşık 0.13) seviyelere gelmiş olmasına rağmen, validasyon kayıp değerlerinde ilerleyen epochlarda kötüleşme görülmektedir. Bu fark özellikle 13. epochdan sonra ciddi bir şekilde artış göstermektedir. Doğruluk değerleri açısından normal dağılımda olduğu gibi validasyon verilerinde bir iyileşme söz konusu değildir. Epochlar arasındaki çok küçük salınımlar söz konusu olup, modelin eğitimine bir katkısı olmadığı anlaşılmaktadır.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 26. Uniform dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar.

Tablo 8. Normal dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	0.8687	0.8417	0.3853	0.8648
2	0.2827	0.8986	0.4677	0.8557
3	0.2622	0.9119	0.5294	0.8614
4	0.2669	0.9217	0.6368	0.8545
5	0.2208	0.9334	0.6535	0.8647
6	0.2206	0.9412	0.8031	0.8589
7	0.1935	0.9487	0.8815	0.8621
8	0.1641	0.9567	0.9895	0.8665
9	0.1640	0.9597	1.1889	0.8583
10	0.1786	0.9610	1.2983	0.8600
11	0.1617	0.9647	1.3773	0.8636
12	0.1515	0.9684	1.6626	0.8594
13	0.1540	0.9699	1.6231	0.8649
14	0.1547	0.9708	1.9074	0.8642
15	0.1418	0.9743	2.0670	0.8638
16	0.1464	0.9749	2.3914	0.8644
17	0.1656	0.9740	2.5489	0.8638
18	0.1457	0.9768	2.6013	0.8627
19	0.1390	0.9790	2.9331	0.8650
20	0.1334	0.9804	3.1314	0.8646
Genel Ort.	0.2158	0.9504	1.5039	0.8622

Uniform dağılım ile başlatma, ağırlıkların belirli bir aralıkta dengeli bir şekilde dağıtılmasını sağlar. Bu, ağırlıkların eğitim sürecinde kararlı olmasına ve gradyanların ağırlıkların derin katmanlarında bile etkin bir şekilde yayılmasına yardımcı olur. Ağırlıkların dengeli bir aralıkta seçilmesi, her bir nöronun çıktıların varyansını kontrol altında tutarak, gradyan kaybolması ve patlaması gibi problemlerin önlenmesine katkıda bulunur.

Uniform dağılım ile başlatma yöntemi, sinir ağlarındaki ağırlıkların simetri problemini çözmeye ve eğitim sürecinde nöronların daha etkin öğrenmesini sağlamaya yönelik bir tekniktir. Bu başlatma stratejisi, ağırlıkları belirlenmiş bir aralıkta rastgele olarak ayarlayarak her bir nöronun girdilere farklı tepkiler vermesini ve dolayısıyla ağırlıkların genelinde farklı özelliklerin öğrenilmesini mümkün kılar. Ağırlıkların bu şekilde başlatılması, özellikle derin sinir ağlarında, gradyanların daha dengeli bir şekilde yayılmasını sağlar, bu da gradyan kaybolması veya patlaması problemlerini önemli ölçüde azaltabilir. Ayrıca, bu yöntem modelin genelleştirme kabiliyetini artırarak, eğitim veri setine aşırı uyum sağlama (overfitting) riskini düşürür. Bununla birlikte, uniform dağılım ile başlatmanın bazı dezavantajları da bulunmaktadır. Bu yöntem, ağırlıkların başlangıç değerlerinin belirlenmesinde dikkatli bir ayar gerektirir; çünkü yanlış limit

değerleri, öğrenme sürecini olumsuz yönde etkileyebilir ve ağırlık eğitim performansını düşürebilir. Ayrıca, uniform dağılım bazı özel durumlarda yetersiz kalabilir. Bu, özellikle ReLU gibi aktivasyon fonksiyonları kullanıldığında ağırlıkların büyük veya küçük başlatılmasının ağırlık aktivasyon çıktıları sınırlayabileceği anlamına gelir. Dolayısıyla, uniform dağılımın etkinliği, kullanılan aktivasyon fonksiyonunun doğası ve ağırlık mimari yapısına bağlı olarak değişiklik gösterebilir.

4.4.4. Xavier Katsayılarıyla İlk Değerlerin Belirlenmesi


Xavier (Glorot) başlatma yöntemi, özellikle derin öğrenme alanında, sinir ağlarının başlangıç ağırlıklarını belirlemek için yaygın olarak kullanılan bir tekniktir. Bu başlatma stratejisi, Glorot ve Bengio (2010) tarafından tanıtıldı ve özellikle sigmoid ve hiperbolik tanjant gibi s-sigmoid aktivasyon fonksiyonlarının kullanıldığı durumlar için tasarlanmıştır. Xavier başlatma, ağırlıkları başlatırken, giriş ve çıkış düğümlerinin (x_{in} ve x_{out}) sayısına bağlı olarak bir normalizasyon faktörü kullanır. Bu normalizasyon, ağırlıkların varyansını kontrol altında tutarak ağırlık daha derin katmanlarına kadar etkin bir şekilde sinyal ve gradyanların iletilmesini sağlar. Xavier başlatma, ağırlıkları normal veya uniform dağılımdan seçer ve bu dağılımların varyansını, giriş ve çıkış nöronlarının sayısına göre ayarlar. Xavier normal başlatma Eşitlik 7’de verilen formülle edilir:

$$w \sim N(0, \frac{2}{x_{in} + x_{out}}) \quad (\text{Eşitlik 7})$$


Xavier uniform başlatma ise Eşitlik 8’deki şekilde ifade edilir:

$$w \sim U\left[-\frac{\sqrt{6}}{\sqrt{x_{in}+x_{out}}}, \frac{\sqrt{6}}{\sqrt{x_{in}+x_{out}}}\right] \quad (\text{Eşitlik 8})$$


Burada, x_{in} ilgili katmandaki giriş nöronlarının sayısını, x_{out} ise çıkış nöronlarının sayısını ifade eder. Bu formüller, ağırlıkların başlangıçta dengeli bir şekilde dağıtılmasını sağlar, böylece ağırlık öğrenme sürecinde aktivasyonların ve gradyanların uygun şekilde yayılmasına yardımcı olur. Çalışmada kullanılan ağ modelindeki evrişim katmanının Xavier katsayıları ile başlatılması sonucunda elde edilen başarımların değerleri Şekil 27’de verilmiştir. Bu strateji de diğer rastgele başlangıç değeri stratejileri ile benzer çıktılar üretmiş olup, özellikle validasyon verilerinde istenilen düzeyde değildir.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 27. Uniform dağılım başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar.

Şekil 27'deki özellikle e ve f grafikleri modelin eğitiminin gerçekleştirilemediğini açıkça göstermektedir. Model bu değerlerle yerel minimum noktalarına takılmaktadır. Bu durum ortalama değerlerin gösterildiği Tablo 9'da da gözlemlenebilir.

Tablo 9. Xavier başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	0.7575	0.8396	0.4132	0.8584
2	0.3020	0.8934	0.4683	0.8554
3	0.2769	0.9108	0.6438	0.8468
4	0.2459	0.9222	0.6178	0.8569
5	0.2294	0.9333	0.7119	0.8574
6	0.2255	0.9391	0.8889	0.8537
7	0.1943	0.9483	0.8875	0.8581
8	0.1689	0.9558	1.0713	0.8553
9	0.1873	0.9563	1.2316	0.8609
10	0.1661	0.9613	1.3293	0.8584
11	0.1730	0.9646	1.5507	0.8592
12	0.1494	0.9683	1.7410	0.8604
13	0.1463	0.9708	1.8075	0.8621
14	0.1514	0.9719	2.0123	0.8617
15	0.1507	0.9730	2.1859	0.8628
16	0.1428	0.9750	2.4311	0.8632
17	0.1426	0.9768	2.7165	0.8618
18	0.1423	0.9776	2.8689	0.8624
19	0.1531	0.9779	3.3609	0.8620
20	0.1416	0.9798	3.1614	0.8650
Genel Ort.	0.2124	0.9498	1.6050	0.8591

Xavier başlatma, ağırlıkların başlangıçta dengeli ve uygun bir aralıkta dağıtılmasını sağlayarak, ağırlık eğitimi sürecini olumlu yönde etkiler. Bu yöntem, sinir ağlarının eğitim sürecinde karşılaşılabileceği gradyan kaybolması ve gradyan patlaması gibi sorunları azaltır. Ağırlıkların uygun şekilde başlatılması, her bir katmandaki aktivasyonların ve gradyanların dağılımını dengeler ve bu da daha hızlı ve kararlı bir konverjans sağlar.

Xavier başlatma, özellikle sigmoid ve tanh gibi aktivasyon fonksiyonları kullanan ağlarda etkilidir. Bu aktivasyon fonksiyonları, çıktıların belirli bir aralıkta sınırlar ve bu da ağırlıkların dikkatli bir şekilde başlatılmasını gerektirir. Xavier başlatma, bu tür ağlarda gradyanların kaybolma riskini azaltarak, daha derin katmanlarda bile etkin bir öğrenme süreci sağlar.

Xavier başlatmanın en belirgin avantajı, ağırlık eğitimi sürecinde karşılaşılabileceği gradyan kaybolması ya da patlaması problemlerinin önüne geçmesidir. Ağırlıkların uygun bir şekilde ölçeklenmesi, her katmandaki aktivasyonların ve gradyanların, eğitim sürecinin başlangıcından sonuna kadar dengeli bir şekilde dağılmasını sağlar. Bu da genellikle daha hızlı konverjansa ve daha kararlı bir öğrenme sürecine yol açar. Ayrıca,

Xavier başlatma yöntemi, ağın derinleştiği durumlarda bile, öğrenme sürecinin başarısını artırmak için aktivasyonların yayılımını optimize eder.


Bununla birlikte, Xavier başlatma yönteminin bazı sınırlamaları da bulunmaktadır. Bu yöntem özellikle ReLU ve benzeri aktivasyon fonksiyonları için optimal sonuçlar üretmeyebilir. ReLU, aktivasyon değerlerinin negatif bölgesinde sıfırı döndürdüğü için, Xavier başlatmanın temel varsayımları bu durumda geçerli olmayabilir. ReLU ve varyantları için He veya Kaiming başlatma gibi alternatif yöntemler, bu tür aktivasyon fonksiyonlarının doğasına daha uygun düşecek şekilde tasarlanmıştır. Bunlar, Xavier'den farklı olarak, ağırlıkların varyansını giriş düğüm sayısı göre ayarlayarak daha uygun bir başlangıç değeri sağlar.

4.5. Gabor Filtreleri İle Başlatma

Sinir ağırları için literatürde önerilen başlangıç değerlerinin belirlenmesine ilişkin yaklaşımlar genellikle nöronlar arası bağlantıların değerlerini belirlemek üzerine kurgulanmıştır. Yani yapay sinir hücrelerinin arasında kurulacak bağlantıları ne olacağına ilişkin yaklaşımlar sunulmuştur. Son yıllardaki ağ yapılarının genişlemesi ve bu ağ yapılarında çok sayıda sinir hücresinin kullanılması bu yaklaşımları haklı hale getirmektedir. Fakat bu yaklaşımlar evrişim katmanlarında beklenen etkiyi göstermemektedir. Çünkü evrişim katmanları filtreler üzerine kurgulanmış olup, çok fazla dağılıma ihtiyaç duyan yapılar değildir. Örneğin 3x3'lük bir evrişim katmanında 16 filtre olduğu farz edilirse toplamda $3 \times 3 \times 16 = 144$ adet parametre belirlenmesi gerekmektedir. Bu yoğun bağlantıların olduğu YSA katmanlarına göre çok daha az sayıda parametre demektir. Ayrıca evrişim katmanlarının kullanım amacı özellik çıkarımıdır. Bu nedenle başarılı özellik çıkaracak filtreler ihtiyacı duyulmaktadır. Tez çalışması kapsamında da özellik çıkarımı konusunda başarısı bir çok çalışma ile gösterilmiş olan Gabor filtrelerin evrişim katmanlarında kullanılmasının nasıl bir etkiye sahip olacağı irdelenmiştir. Bu amaçla teknik detayları önceki bölümlerde verilen gabor filtrelerinden oluşan bir filtre bankası oluşturulmuş ve bunların sınıflandırmaya olan etkileri incelenmiştir.


Gabor filtreleri oluşturmak için birçok parametre verilmesi gerekmektedir. Bunların başında filtrenin açısı, dalga boyunun genliği ve filtrelerin açısı bulunmaktadır. Çalışma içerisinde bir katmanda çok sayıda filtre oluşturulması amaçlandığından filtre açısı ve genliğin bu sayı ile tölore edilebileceği düşünülmüştür. Burada özellikle filtre boyutunun değiştirilmesine odaklanılmış ve farklı boyutlarda Gabor filtreleri oluşturulmuştur.

Gabor filtresi ile evriřim katmanının ilkendirilmesi alışmasında ilk nce 3x3 boyutunda filtreler oluřturulmuřtur. Bu filtrelerin uygulanacađı katman ve mimari nceki alışmalarda kullanılan yapı ile aynıdır. Dolayısıyla 64 farklı filtreden oluřan 3x3'lk Gabor filtreleri řekil 28'de gsterildiđi gibi oluřturulmuřtur.



řekil 28. 3x3'lk 64 adet Gabor filtreleri bankası.

Oluřturulan bu filtreler evriřim katmanının ilk deđerleri olarak belirlenmiřtir. Daha nceki deneysel alışmalarda olduđu gibi kayıp ve dođruluk deđerleri model zerinden deđerlendirilmesi iin gerekli grafikler ve tablolar ıkarılmıřtır. 3x3'lk Gabor filtrelerin uygulandıđı ađ modelinden elde edilen bařarım deđerleri řekil 29'da sunulmuřtur.



Şekil 29. 3x3'lük Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.


3x3'lük Gabor filtrelerinin sınıflandırma için kullanıldığı durumda eğitim verilerinde kayıp değerleri 0.15 seviyesine düşmektedir. Bununla beraber validasyon verilerinde kayıp değeri normal ve uniform dağılımda olduğu gibi artarak ilerlemektedir. Diğer taraftan doğruluk değerleri validasyon verilerinde her epochda kısmi olarak

yükselerek ilerlemektedir. Bu durum Gabor katsayılarının uygulanması sonucunda modelin öğrenme sürecini gerçekleştirebildiğini göstermektedir. Kayıp değerleri açısından normal ve uniform dağılımına benzer yapıda ilerlemesi aslında elde edilen filtre katsayılarının karakteristik olarak bu dağılımlara benzerlik göstermesinden kaynaklanmaktadır. Şöyle ki 3x3'lük Gabor filtreleri tam olarak Gabor katsayılarını yansıtamamaktadır. Gabor'daki yönelim ve dalga boyu bilgileri için daha büyük boyutlu filtrelere ihtiyaç duyulmaktadır. 3x3'lü Gabor filtreleriyle elde edilen ortalama kayıp ve doğruluk değerleri Tablo 10'da verilmiştir.

Tablo 10. 3x3 Gabro filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.


Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	3.2056	0.7644	0.6103	0.8004
2	0.4781	0.8429	0.5356	0.8296
3	0.4115	0.8637	0.5340	0.8365
4	0.3597	0.8784	0.5046	0.8461
5	0.3299	0.8887	0.5073	0.8510
6	0.3038	0.8981	0.5282	0.8527
7	0.2748	0.9081	0.5410	0.8561
8	0.2573	0.9149	0.5897	0.8621
9	0.2348	0.9228	0.6197	0.8634
10	0.2164	0.9290	0.6467	0.8662
11	0.2050	0.9341	0.6921	0.8674
12	0.1967	0.9377	0.7463	0.8663
13	0.1906	0.9408	0.7790	0.8679
14	0.1813	0.9445	0.8184	0.8642
15	0.1787	0.9465	0.8535	0.8700
16	0.1708	0.9493	0.8992	0.8706
17	0.1669	0.9514	0.9408	0.8705
18	0.1645	0.9526	1.0043	0.8690
19	0.1603	0.9547	1.0675	0.8662
20	0.1541	0.9563	1.0557	0.8716
Genel Ort.	0.3920	0.9139	0.7237	0.8574

Gabor filtrelerindeki ilk olarak tercih edilen 3x3 boyutları folması gereken yönelim ve dalga boyu bilgilerini tam yansıtmadığı için çalışmanın bir sonraki aşamasında filtre boyutları artırılmıştır. Bu aşamada ilk önce 5x5 boyutlarında filtreler oluşturulmuştur. Bu filtrelere ait görüntüler Şekil 30'da verilmiştir. Şekilden de anlaşılacağı üzere açık ve koyu pikseller filtrelerin yönelimlerini ortaya çıkarmıştır. Bu bilgilerin özellikle giriş görüntülerindeki kenar bilgilerini ortaya çıkarması beklenmiştir.




Şekil 30. 5x5'lik 64 adet Gabor filtreleri bankası.


5x5 boyutlarındaki Gabor filtrelerin uygulanması sonucun ağ modelinde 0.14 seviyelerin eğitim verisinde kayıp değeri ve 0.87 validasyon verisinde doğruluk değerlerine ulaşılabilmiştir. Bu değerlere ulaşma, diğer modellere göre daha çabuk gerçekleşmiştir. Bu durum Şekil 31'de ve Tablo 11'de daha açık bir şekilde gözlemlenebilir.




(a)




(b)




(c)



(d)



(e)




(f)

Şekil 31. 5x5'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.

Tablo 11. 5x5'lik Gabor filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.


Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	3.2033	0.7654	0.5978	0.8103
2	0.4730	0.8438	0.5319	0.8307
3	0.4061	0.8646	0.5230	0.8444
4	0.3621	0.8780	0.5022	0.8486
5	0.3245	0.8898	0.5119	0.8557
6	0.2941	0.8999	0.5097	0.8603
7	0.2735	0.9085	0.5525	0.8595
8	0.2497	0.9170	0.5570	0.8636
9	0.2320	0.9243	0.6233	0.8637
10	0.2141	0.9304	0.6476	0.8669
11	0.2018	0.9354	0.6656	0.8723
12	0.1965	0.9388	0.7480	0.8714
13	0.1877	0.9425	0.7543	0.8701
14	0.1782	0.9459	0.8459	0.8696
15	0.1700	0.9492	0.8526	0.8723
16	0.1659	0.9510	0.9222	0.8704
17	0.1630	0.9526	0.9500	0.8703
18	0.1593	0.9538	0.9684	0.8710
19	0.1484	0.9573	0.9756	0.8665
20	0.1586	0.9564	1.1233	0.8699
Genel Ort.	0.3881	0.9152	0.7181	0.8604

Gabor filtrelerindeki 5x5'lik filtre boyutlarının, filtreler için düşünülen yönelimleri açığa çıkarması özelliği filtre boyutları artırılarak genişletilmeye çalışılmıştır. Bu aşamada filtre boyutları 7x7 olarak benimsenmiştir. Buna göre yeni oluşturulan filtreler Şekil 32'de gösterilmiştir. Şekildeki filtrelerden de anlaşılacağı üzere yeni oluşturulan filtrelerin kenar öznitelikleri tespiti etme yeteneği artırılmaya çalışılmıştır. Ayrıca filtrelerin ortasında daha net bir şekilde oluşmaya başlayan blob yapılarının da görüntüler içerisindeki elipsoid yapıların tespitini kolaylaştırması beklenmiştir.




Şekil 32. 7x7'lik 49 adet Gabor filtreleri bankası.


Oluşturulan 7x7 boyutlarındaki yeni Gabor filtreleri yine evrişim katmanının ilk başlangıç değerleri olarak belirlenmiş ve buna göre ağ modeli eğitime başlanmıştır. Eğitilen ağ modelinden elde edilen başarımlar Şekil 33'de grafikler halinde sunulmuştur. Grafiklerden de anlaşılacağı üzere model özellikle 2. Epochtan itibaren kararlı duruma geçmeye başlamıştır. Eğitim kayıp değeri 0.14'e kadar düşmüştür. Ayrıca doğruluk değeri 0.95 seviyesinin üstünde kalmıştır. Bu değerlerin detaylı gösterimi Tablo 12'de de verilmiştir. Validasyon verisinde elde edilen değerler eğitim verisinde yakalanan başarılı değerler kadar değildir. Fakat değerlerin epochlara göre ilerleme süreçleri paralel olduğundan kabuledilebilir aralıkta olduğu düşünülebilir.




(a)




(b)




(c)



(d)



(e)




(f)

Şekil 33. 7x7'lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.

Tablo 12. 7x7'lik Gabor filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.


Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	3.2062	0.7639	0.5883	0.8090
2	0.4781	0.8434	0.5414	0.8282
3	0.4092	0.8639	0.5147	0.8415
4	0.3590	0.8782	0.5061	0.8490
5	0.3286	0.8882	0.5249	0.8497
6	0.3037	0.8976	0.5361	0.8580
7	0.2779	0.9067	0.5478	0.8604
8	0.2538	0.9156	0.5748	0.8619
9	0.2348	0.9228	0.6182	0.8657
10	0.2216	0.9279	0.6448	0.8677
11	0.2122	0.9325	0.6779	0.8698
12	0.1995	0.9373	0.7281	0.8673
13	0.1915	0.9405	0.7537	0.8666
14	0.1814	0.9440	0.7824	0.8705
15	0.1775	0.9467	0.8714	0.8705
16	0.1753	0.9481	0.9258	0.8684
17	0.1709	0.9502	0.9473	0.8687
18	0.1636	0.9525	0.9968	0.8676
19	0.1588	0.9545	1.0275	0.8697
20	0.1495	0.9571	1.0748	0.8691
Genel Ort.	0.3927	0.9136	0.7191	0.8590

Gabor filtrelerinin farklı boyutlarda oluşturulmuş maske görüntülerinin etkileri bir sonraki aşamada 9x9 ve 11x11'lik boyutlarda da test edilmiştir. Örneğin 9x9 boyutlarındaki filtrelerin görüntüleri Şekil 34'de verilmiştir. Bu filtrelerle elde edilen başarımlar değerleri ise Şekil 35'te verilmiştir. Filtre boyutları büyüdükçe öznetelik çıkarma özelliğinin artması beklenmektedir. Fakat ağırlık giriş görüntüleri 28x28 olduğunda filtre boyutları büyüdükçe bu durum ortadan kalmaktadır. Ayrıca filtrelenenmiş görüntülerin boyutları da padding işlemi uygulanamadığından dramatik bir şekilde düşmektedir. Bu da özellikle kenar bölgelere kalan özneteliklerin kaybolmasına neden olmaktadır. Dolayısıyla 9x9 boyutlarındaki filtreler ile başlatılmış olan ağ modelindeki başarımlar değerleri önceki deneylerden elde edilenlerden daha iyi değildir.




Şekil 34. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.


Şekil 35'den görüleceği üzere elde edilen değerler 7x7'lik gabor filtresi ve öncekilere benzerdir. Eğitim doğruluk değerleri 0.95 seviyelerinde olmasına karşın validasyon doğruluk değerleri 0.87 seviyelerine kadar çıkabilmiştir. Benzeri şekilde eğitim verisindeki kayıp değeri 0.14 seviyesine kadar düşürülebilmektedir. Bu verilerin detaylı olarak sıralanmış hali Tablo 13'de verilmiştir.




(a)




(b)




(c)



(d)



(e)




(f)

Şekil 35. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.

Tablo 13. 9x9'luk Gabor filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımların değerleri.


Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	3.2044	0.7643	0.6113	0.7977
2	0.4782	0.8426	0.5200	0.8371
3	0.4053	0.8644	0.5214	0.8404
4	0.3591	0.8788	0.4944	0.8499
5	0.3315	0.8881	0.4895	0.8578
6	0.2992	0.8984	0.5282	0.8572
7	0.2738	0.9082	0.5431	0.8590
8	0.2488	0.9169	0.5558	0.8677
9	0.2299	0.9245	0.6002	0.8661
10	0.2197	0.9291	0.6463	0.8674
11	0.2027	0.9348	0.6757	0.8672
12	0.1875	0.9403	0.7498	0.8648
13	0.1894	0.9415	0.7619	0.8677
14	0.1801	0.9451	0.8233	0.8664
15	0.1729	0.9487	0.8745	0.8668
16	0.1677	0.9499	0.9263	0.8669
17	0.1635	0.9527	0.9592	0.8666
18	0.1599	0.9539	1.0374	0.8631
19	0.1526	0.9561	1.0717	0.8697
20	0.1475	0.9584	1.1012	0.8699
Genel Ort.	0.3887	0.9148	0.7246	0.8585

9x9'luk Gabor filtrelerinde karşılaşılan filtre boyutu artmasına rağmen değerlerin iyileştirilememesi durumunun filtre boyutlarından kaynaklanıp kaynaklanmadığını tespit etmek amacıyla 11x11'lik Gabor filtreleri de uygulanmıştır. Oluşturulan 11x11 boyutlarındaki filtrelerin görüntüleri Şekil 36'da verilmiştir.




Şekil 36. 9x9'luk Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar.


11x11'lik Gabor filtrelerinin uygulanması sonucunda elde edilen başarımlar Şekil 37'de gösterilmiştir. Eğitim ve validasyon verilerinde elde edilen kayıp ve doğruluk değerleri 9x9'luk filtreler ile elde edilen sonuçlara yakındır. Hatta tahmin edildiği gibi bir miktar 9x9'luk filtrelerden alınan sonuçlarda daha kötü değerler elde edilmiştir. Örneğin eğitim verilerindeki doğruluk değerleri 0.15'ler seviyesinde kalmıştır. Bu değer 9x9'luk filtrelerde 0.14 seviyesinde idi. Bununla beraber validasyon verilerindeki doğruluk değerlerinde 9x9'luk değerlerden bir miktar daha iyi sonuca ulaşılmıştır. 9x9'luk filtrelerdeki ortalama 0.8585 iken 11x11'lik filtrelerde bu değer 0.8595 seviyesine ulaşmış, en iyi ulatığı değer ise 0.8731'dir.




(a)




(b)




(c)



(d)



(e)



(f)

Şekil 37. 11x11’lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evrişim katmanlı modelden elde edilen başarımlar değerleri.

11x11’lik Gabor filtrelerinin uygulanması sonucunda her bir epoch için elde edilen ortalama değerler Tablo 13’de verilmiştir. Bu değerler grafiklerde gösterilen çizimlere ait ortalama değerler olup, hem eğitim hem de validasyon verilerinin nasıl ilerlediğini açık

bir şekilde göstermektedir. Bu denemelerde de eğitim ve validasyon verileri arasında farklılıkların bulunduğu ve ağın iyileştirmeye ihtiyaç duyduğu tespiti yapılabilir.

Tablo 14. 9x9'luk Gabor filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	3.2059	0.7641	0.5864	0.8072
2	0.4733	0.8437	0.5501	0.8314
3	0.4083	0.8642	0.5062	0.8449
4	0.3582	0.8782	0.5007	0.8484
5	0.3264	0.8894	0.5203	0.8493
6	0.2963	0.8992	0.5311	0.8591
7	0.2731	0.9078	0.5456	0.8612
8	0.2494	0.9160	0.5713	0.8594
9	0.2316	0.9233	0.6207	0.8651
10	0.2150	0.9297	0.6406	0.8650
11	0.2030	0.9350	0.7139	0.8648
12	0.1963	0.9383	0.7296	0.8671
13	0.1845	0.9427	0.7776	0.8687
14	0.1744	0.9461	0.8213	0.8697
15	0.1756	0.9473	0.8582	0.8691
16	0.1707	0.9494	0.8822	0.8718
17	0.1591	0.9532	0.9103	0.8706
18	0.1568	0.9539	0.9601	0.8728
19	0.1520	0.9562	1.0062	0.8731
20	0.1504	0.9576	1.0734	0.8724
Genel Ort.	0.3880	0.9148	0.7153	0.8595

Gabor filtreleri ile başlatılan evrişim katmanları, eğitim sürecinin başlarında daha etkin özellik algılama yeteneğine sahip olur. Bu, özellikle görüntü sınıflandırma, yüz tanıma ve nesne tespiti gibi görsel görevlerde, modelin hızlı bir şekilde yüksek düzeyde öznetelikleri öğrenmesine olanak tanır.

Gabor iklenilmesi kullanılarak başlatılan modeller, özellikle evrişimli sinir ağlarında, eğitim sürecinin başlarında hızlı bir konverjansa ulaşabilir. Gabor filtrelerinin sağladığı önceden tanımlı öznetelik çıkarım kabiliyeti, rastgele başlatılan ağırlıklara kıyasla eğitim sürecini önemli ölçüde hızlandırabilir. Bu, ağın erken aşamada daha karmaşık öznetelikleri öğrenmeye başlamasına olanak tanır. Gabor filtreleriyle başlatılmış ağlar, genellikle öğrenilmesi gereken parametre sayısını azaltarak eğitim sürecini hızlandırabilir. Çünkü bu filtreler belirli görsel özelliklere zaten duyarlıdır ve bu özelliklerin eğitim süreci boyunca sıfırdan öğrenilmesine gerek kalmaz.

Gabor filtreleri, doğal görüntülerde sıkça rastlanan özellikleri modelleme konusunda etkilidir. Bu, ağın sadece eğitim verisine özgü detayları değil, daha genel görsel özellikleri öğrenmesini sağlar, bu da modelin farklı veri kümeleri üzerinde daha iyi genelleştirme yapabilmesine olanak tanır. Gabor filtreleri, belirli frekans ve yönelimlerdeki özellikleri yakalama konusunda ustadır. Bu, modelin görsel veriler üzerinde daha duyarlı ve ayırt edici öznitelikler öğrenmesine yardımcı olur. Özellikle görsel tanıma görevlerinde, Gabor ilklendirmesi sayesinde ağ, daha etkin ve doğru bir şekilde sınıflandırma yapabilir.


Her ne kadar Gabor filtreleri ile başlatma pek çok avantaj sunsa da, bu yöntemin uygulamaları sınırlıdır. Gabor filtreleri ile başlatma genellikle yalnızca görsel işleme görevleri için uygun olup, metin işleme veya ses işleme gibi diğer alanlarda kullanımı için ek çalışmalar ve adaptasyonlar gerektirir. Ayrıca, bu filtrelerin parametrelerinin uygun şekilde ayarlanması, başarılı bir model eğitimi için kritik öneme sahiptir ve bu parametrelerin her bir uygulama için özel olarak incelenmesi ve optimize edilmesi gerekir. Gabor filtreleri ile başlatılan katmanlar, belirli özniteliklere aşırı duyarlı hale gelebilir ve bu, modelin eğitim verisine aşırı uyum sağlamasına yol açabilir. Eğer model yeterince düzenlenmez veya veri çeşitliliği yetersiz ise, bu durum genelleştirme kabiliyetinin azalmasına sebep olabilir. Gabor ilklendirmesi, modelin belirli türdeki özniteliklere duyarlı olmasını sağlarken, bu özelleşme diğer potansiyel önemli özniteliklerin göz ardı edilmesine neden olabilir. Modelin, Gabor filtrelerinin yakalayamadığı öznitelikleri öğrenme yeteneği sınırlanabilir, bu da modelin çeşitli görevlerde ve koşullarda uyarlanabilirliğini azaltabilir.

4.6. Çoklu Evrişim Katmanı ve İlklendirme Stratejileri

İlk evrişim katmanı, genellikle düşük seviyeli öznitelikleri (kenarlar, dokular, yönelimler) yakalamak için kullanılır. Bu katmanı Gabor filtreleri ile başlatmak, ağın başlangıçta bu temel öznitelikleri etkili bir şekilde öğrenmesini sağlar. Gabor filtreleri, belirli frekans ve yönelimlerdeki bilgiyi yakalama yetenekleri sayesinde, ilk katmanda kullanılmaları durumunda, ağın görsel bilgiyi daha zengin bir şekilde temsil etmesini sağlayabilir fikri oluşmuştur.

Çoklu evrişim katmanlarının Gabor filtreleri ile ilklendirilmesi, sinir ağlarının görsel öznitelikleri daha etkili bir şekilde yakalamasını sağlamak için kullanılan güçlü bir yaklaşım sunabilir. Bu filtrelerin sinir ağlarında kullanılması, özellikle ilk katmanlar için yaygın olsa da, ardışık katmanlar için de uygun stratejiler geliştirilerek daha kapsamlı bir özellik çıkarımı yapılması beklenmiştir. Çalışma kapsamında Gabor filtreleri ile

iklendirilmiş evriřim katmanı sayısı artırılması düşünölmüřtür. Bu amaçla ardışıl iki Gabor evriřim katmanı kullanılmıştır.



Şekil 38. 11x11’lik Gabor filtreleri başlangıç değerleri ile başlatılan tek evriřim katmanlı modelden elde edilen başarıım değerleri.

Mevcut ağ yapısındaki ilk katman üzerinde herhangi bir değişikliğe gidilmemiş, 64 filtreli ikinci bir evrişim katmanı ilk katmanın arkasına yerleştirilmiştir. İlk katmanda ve eklenen yeni evrişim katmanında kullanılan filtre boyutları 7x7 olarak seçilmiştir. Bu boyutların seçilmesinin sebebi 9x9 ve 11x11 gibi filtre boyutlarının başarımlarına önemli bir katkı sunmamış olmasıdır.

İki evrişim katmanına sahip ağ modelinin çalıştırılması sonucunda elde edilen başarımlar Şekil 38’de verilmiştir. Elde edilen grafikler incelendiğinde önceki deneylerde elde edilen değerlerle benzeri bir epochlar arasında ilerlemenin söz konusu olduğu anlaşılmaktadır. Eğitim verilerindeki kayıp değerleri 2. epochtan itibaren düşmektedir. Fakat bu değerler 0.30’ları biraz altına kadar ancak inebilmektedir. Doğruluk değerleri ise 0.9 seviyesinde kalmaktadır. Validasyon verilerinde ise doğruluk değeri 0.85’in altında kalmaktadır.

Tablo 15. 9x9’luk Gabor filtreleri ile başlatılan tek evrişim katmanlı modelden elde edilen ortalama başarımlar.

	Eğitim Verileri		Validasyon Verileri	
Epoch No	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	1.3374	0.7729	0.5018	0.8176
2	0.4374	0.8411	0.4829	0.8296
3	0.4028	0.8545	0.4838	0.8322
4	0.3888	0.8599	0.5201	0.8334
5	0.3811	0.8628	0.5044	0.8347
6	0.3587	0.8710	0.5191	0.8344
7	0.3576	0.8716	0.5006	0.8418
8	0.3425	0.8764	0.5177	0.8451
9	0.3310	0.8818	0.5504	0.8428
10	0.3298	0.8823	0.5428	0.8423
11	0.3282	0.8836	0.5622	0.8408
12	0.3148	0.8872	0.5630	0.8451
13	0.3120	0.8891	0.6051	0.8408
14	0.3121	0.8904	0.5830	0.8497
15	0.3029	0.8928	0.5961	0.8426
16	0.3089	0.8919	0.5820	0.8432
17	0.2869	0.8988	0.6211	0.8452
18	0.2889	0.8978	0.6299	0.8436
19	0.2914	0.8997	0.7039	0.8477
20	0.2861	0.9012	0.6441	0.8482
Genel Ort.	0.3850	0.8753	0.5607	0.8400

Şekil 38’deki her bir çalıştırmaya ait ortalama verilerine bakıldığında validasyon verilerindeki kayıp verilerinin 0.5 seviyesinin altına inmediği hatta bir miktar arttığı görülmektedir. Ayrıca hem eğitim hem de validasyon verilerinden elde edilen doğruluk


değerleri diğer deneysel çalışmaların altında kalmaktadır. Bu durum Tablo 13’de daha açık bir şekilde gözlemlenebilir.

Ardışıl Gabor filtreleri ile evrişim katmanlarını başlatma çalışmalarında beklenen performans elde edilememiştir. Burada seçilen filtrelerin boyutları ve sayıları üzerinde detaylı bir incelemeye ihtiyaç duyulduğu anlaşılmaktadır.

4.7. Avuç İzi Tanımda Gabor Filtreleriyle İklendirme


FashionMNIST veriseti üzerinde yapılan deneysel çalışmalarda evrişim katmanının Gabor filtreleri ile iklenmesinin bir miktar başarımlarında iyileştirmelere ve yenilikçi düşüncelere yol açtığı gözlemlenmiştir. Fakat bu verisetindeki görüntülerin 28x28 boyutlarında olması ve farklı türde görüntüler içermiş olmasından dolayı istenen değerlere ulaşamadığı görülmüştür. Çalışmanın son aşamasında ise özellikle çizgiler özniteliklerin daha fazla önem arz ettiği bir veriseti üzerinde denemeler yapılmasına karar verilmiştir.

Gabor filtrelerinin içerdiği yön ve genlik bilgileri sayesinde daha başarılı özniteliklerin çıkarılabileceği bir veriseti IITD Temassız Avuçiçi Veritabanı tercih edilmiştir. Avuçiçi tanıma ile ilgili yapılan çalışmalarda Gabor filtrelerin başarısı klasik makine öğrenme yaklaşımlarında gösterilmiştir (Kong vd. 2003; Bingöl ve Ekinci, 2017; Aykut ve Ekinci, 2007). Bununla beraber doğrudan Gabor filtresinden geçirilmiş görüntülerin ağ giriş olarak kullanıldığı çalışmalar da mevcuttur (Genovese vd. 2019). Bu durum gözetilerek bu çalışmada da bir tanıma ağ modeli oluşturulmuş ve ilk evrişim katmanının ağırlıkları Gabor filtreleriyle iklendirilecek şekilde ayarlanmıştır. Çalışma bu özelliği ile 122E402 kodlu TÜBİTAK Projesi kapsamında dahil edilmiştir. Geliştirilen ağ modeli Şekil 39’da sunulmuştur. Bu modelde 3 adet evrişim katmanı kullanılmış olup, sadece ilk katmanı Gabor filtreleri ile iklendirilmiştir. Ağ modelinde sınıflandırıcı bölümünde iki adet doğrudal katman kullanılmıştır. Toplamda ağın parametre sayısı 10.761.195’dir. son katman hariç diğer tüm katmanlarda aktivasyon fonksiyonu olarak ReLU tercih edilmiştir. Ağın son katmanı 235 kişiyi temsil eden çıkış katmanıdır ve ağ bir sınıflandırıcı olarak ele alınmıştır.



Şekil 39. Avuçizi doğrulama sistemi.

Modelin eğitimi ve testi için tercih edilen açık erişimli IIDT Temassız Avuçiçi Veritabanı 235 kişiye ait 6'şar adet el görüntüsü içermektedir. Bu el görüntülerinden elde edilen ve tanıma için kullanılacak örüntüler veritabanında sunulmuştur. Dolayısıyla bu tez çalışması kapsamında örüntü çıkarma süreçleri ile ilgilenilmemiştir. Veritabanına ait bazı örnek el görüntüleri ve bunlardan üretilen avuçizi örüntüleri Şekil 40'da gösterilmiştir. Örüntüler eli orta kısmına denk gelecek şekilde ve avuç izi çizgilerini içerecek şekilde otomatik olarak tespit edildiği veritabanı açıklamalarında mevcuttur.



Şekil 40. Örnek avuçizi ROI'leri.

Bu çalışmada, avuç izi biyometrik verilerinin artırılması amacıyla çeşitli veri artırma teknikleri kullanılmıştır. Veri artırma, sınırlı sayıda mevcut görüntüden daha fazla sayıda yeni görüntü üretmek için kullanılan bir yöntemdir. Bu işlem, özellikle derin öğrenme modellerinin eğitimi için yeterli veri sağlamak amacıyla kritik bir rol


oynamaktadır. Çalışmada kullanılan Python kodu, Pillow kütüphanesi aracılığıyla görüntü işleme ve artırma işlemlerini gerçekleştirmektedir.

Çalışmada, altı farklı veri artırma fonksiyonu kullanılmıştır. Yatay çevirme (horizontal_flip) fonksiyonu, görüntüyü yatay olarak aynalar ve böylece simetrik bir görüntü oluşturur. Rastgele döndürme (random_rotation) fonksiyonu, görüntüyü -10 ile 10 derece arasında rastgele bir açıyla döndürür. Parlaklık ayarı (adjust_brightness) fonksiyonu, görüntünün parlaklığını artırır veya azaltır. Kontrast ayarı (adjust_contrast) fonksiyonu, görüntünün kontrastını değiştirir. Rastgele kırpma (random_crop) fonksiyonu, görüntünün rastgele bir bölümünü keser ve böylece farklı perspektifler sağlar. Ölçeklendirme (scale) fonksiyonu, görüntüyü belirli bir faktörle yeniden boyutlandırır. Bu fonksiyonlar, avuç içi desenlerinin farklı varyasyonlarını oluşturmak için kullanılır ve her biri farklı bir açıdan görüntü üzerinde değişiklik yapar.


Veri artırma süreci, belirli bir hedef görüntü sayısına ulaşmak amacıyla gerçekleştirilir. Öncelikle, kaynak dizindeki mevcut görüntüler kişi ID'sine göre sınıflandırılır. Bu sınıflandırma, her bireyin görüntülerinin ayrı ayrı işlenmesini sağlar. Mevcut görüntüler, hedef dizine kopyalanır ve burada kişi başına hedeflenen görüntü sayısına ulaşana kadar artırma işlemi yapılır. Örneğin, her kişi için hedeflenen görüntü sayısı 100 olarak belirlenmiştir. Eğer mevcut görüntü sayısı bu hedefin altında ise, eksik görüntü sayısını tamamlamak için rastgele veri artırma fonksiyonları uygulanarak yeni görüntüler oluşturulur.

Kod, her bir kişi için mevcut görüntü sayısını belirler ve hedeflenen 100 görüntüye ulaşmak için gerekli olan eksik görüntü sayısını hesaplar. Mevcut görüntüler, hedef dizine kopyalandıktan sonra, eksik görüntü sayısını tamamlamak için rastgele bir veri artırma fonksiyonu seçilir ve uygulanır. Bu süreç, her bir kişi için toplamda 100 görüntü elde edilene kadar devam eder. Veri artırma işlemleri, avuç izi tanıma sistemlerinin doğruluğunu artırmak ve modelin daha geniş bir veri kümesi üzerinde eğitilmesini sağlamak için kritik öneme sahiptir.

Artırılmış görüntüler üzerinde yapılan çalışmalarda elde edilen başarımların sonuçları Şekil 41'de gösterilmiştir. Şekilden de anlaşılacağı üzere hem eğitim verilerinde hem de validasyon verilerindeki kayıp değerleri ideal değerler seviyesindedir. Şöyle ki, eğitimde 0.0103, validasyon verilerinde ise 0.1283 değerlerine kadar inilebilmiştir. Ayrıca doğruluk değerlerinde eğitimde 0.9979, validasyon verilerinde 0.9777 değerlerine ulaşılmıştır.



(e)



(f)

Şekil 41. Gabor filtreleri başlangıç değerleri ile başlatılan avuç izi doğrulama ağ modelinden elde edilen başarımlar.

Deneyisel çalışmalarda edilen başarımların epochlara göre nasıl ilerlediğini gösteren veriler Tablo 13’de sunulmuştur. İlk epochda yüksek bir kayıp değeriyle başlanmasına rağmen sonraki epochlarda hızlı ve çok düşük değerlere ulaşılması dikkat çekicidir. Bununla beraber özellikle 17. epochda elde edilen değerler anlamlı ve çok başarılıdır. Bu epochda sırasıyla eğitim ve validasyon verilerinde 0.0008 ve 0.0665 kayıp değerlerine ulaşılmıştır. Ayrıca doğruluk değerleri sırasıyla 0.9998 ve 0.9891 değerlerindedir. Bu durum bir tanıma sistemi yeterli görülebilecek değerlerdir.

Avuç izi doğrulamada ulaşılan değerler FashionMNIST’de ulaşılan değerlerden daha başarılıdır. Çünkü FashionMNIST verisetinde 10 farklı sınıfa ait obje bulunmakta ve bu objelerin özellikleri farklılıklar içermektedir. Gabor filtreleri kenar özelliklerinin ortaya çıkarılmasında çok etkilidir. Dolayısıyla FashionMNIST verisetinde başarımlar oranları düşük kalmaktadır. Avuç izi doğrulamada ise ayırtıcı özellikler el içerisindeki çizgiler tarafından belirlenmektedir. Bu nedenle Gabor filtrelerinin bu özellikleri ortaya çıkarma başarısı daha yüksektir. Çalışmada elde edilen kayıp değerleri ve doğruluk skorları da bu durumu desteklemektedir.

Tablo 16. Gabor filtreleri başlangıç değerleri ile başlatılan avuç izi doğrulama ağ modelinden elde edilen başarımların değerleri.

Epoch No	Eğitim Verileri		Validasyon Verileri	
	Kayıp Değeri	Doğruluk Skoru	Kayıp Değeri	Doğruluk Skoru
1	1.6639	0.6734	0.2186	0.9481
2	0.0762	0.9818	0.1231	0.9747
3	0.0338	0.9911	0.1148	0.9753
4	0.0293	0.9919	0.1383	0.9742
5	0.0406	0.9896	0.1165	0.9718
6	0.0235	0.9944	0.1085	0.9753
7	0.0279	0.9929	0.0658	0.9870
8	0.0106	0.9965	0.0872	0.9851
9	0.0095	0.9974	0.1082	0.9809
10	0.0235	0.9942	0.0813	0.9832
11	0.0089	0.9978	0.1088	0.9795
12	0.0188	0.9944	0.1061	0.9835
13	0.0234	0.9942	0.1037	0.9795
14	0.0258	0.9942	0.1222	0.9798
15	0.0180	0.9964	0.0832	0.9851
16	0.0035	0.9992	0.0665	0.9880
17	0.0008	0.9998	0.0665	0.9891
18	0.0232	0.9946	0.1078	0.9766
19	0.0127	0.9969	0.0778	0.9859
20	0.0103	0.9979	0.1283	0.9777
Ortalama	0.1042	0.9784	0.1067	0.9790

5. SONUÇLAR VE TARTIŞMA

ESA son yıllarda çok hızlı bir şekilde ilerlemektedir ve farklı disiplinlerle zor olarak bilinen birçok probleme çözümler sunabilmektedir. Bir problemi çözecek ağı oluşturulması problem uzayına bağlı olmakla beraber kurulan ağ modellerinin başarısı mimarilerin içerdiği katmanların ve bağlantılarının uygun bir şekilde kurgulanması ile doğru orantılıdır. Bu durum modeller için birçok belirsizlikler içermekle beraber bu belirsizliklerin etkisinin azaltılması için genellikle çok daha derin ağ yapıları kurulması yolu tercih edilmektedir. Böylece ayırtedici daha fazla öznitelik tespit edilebileceği düşünülmektedir. Diğer taraftan ağların derinliğinin artması hem donanım maliyeti hem de hesaplama karmaşıklığını artırmaktadır.

Bu çalışmada daha etkin öznitelik çıkarabilecek basit ağ yapılarının oluşturulup oluşturulamacağı irdelenmiştir. Bu amaçla tez çalışması kapsamında ESA ağ mimarilerinde kullanılan evrişim katmanlarının ilk başlangıç değerlerinin probleme özgün olarak belirlenmesinin eğitim süresini kısaltabileceği ve daha başarılı sonuçlar üretilebileceği gösterilmeye çalışılmıştır.

Çalışmada öncelikli evrişim katmanlarının bilinen yöntemlerle ilk değerlerinin belirlenmesi ile ilgili deneysel çalışmalar yapılmış, sonrasında ise Gabor filtreleri ile ilk değerler belirlenmiştir. Bu deneylerde literatürde çok bilinen bir veriseti olan FashionMNIST kullanılmıştır. Çalışmanın son aşamasında ise IITD Temassız Avuçizi Veritabanı üzerinde Gabor filtrelerle başlatılmış evrişim katmanına sahip ağ modelleri kullanılmıştır. Yapılan çalışmalar sonucunda Gabor filtreleri ile modelin başlatılmasının diğer yöntemlerle başlatılan ağlara göre daha erken epochlarda kararlı duruma geçtiği gösterilmiştir. Özellikle avuç izi tanımda olduğu gibi çizgi özniteliklere dayalı modellerde bu durum daha açık bir şekilde gösterilmiştir.

Çalışma sırasında yukarıda belirtilen ana sonuların yanında elde edilen önemli ara sonuçlarda da bulunmaktadır: Bunların başında, başlangıç değeri belirleme yöntemlerinden sıfır ilklendirmesi modelde istenmeyen öğrenme değerlerine ulaşmıştır. Bunun durum çarpım şeklinde alınan filtre değerleri verinin niteliğini ortadan kaldırmasından kaynaklanmaktadır ve sonuç olarak tüm filtreler aynı öğrenememe durumuna sebep olmaktadır. Rastgele değerlerle başlama sıklıkla literatürde tercih edilen bir yöntemdir. Fakat bizim denemelerimizde özellikle küçük değerlerle başlama ve bunun uniform dağılımda olması ağı daha hızlı ve başarılı öğrendiğini göstermiştir.

Bir ağ modelinde birden fazla evrişim katmanı içerilebilmektedir ve bu durum tek evrişim katmanlı ağ modellerinden daha yaygındır. Çalışmada çoklu evrişim katmanı

içeren ağ modellerinin her bir katmanı Gabor filtreleri ile başlatılmış ve daha başarılı sonuçlar üretilmesi beklenmiştir. Fakat yapılan deneylerde durumun bu şekilde gerçekleşmediği, Gabor evrişim katmanları sayısının artırılmasının modelin yakınsamasını geciktirdiği tespit edilmiştir. Bu durum özellikle ağın öğrenme karakteristiğini bozmaktadır. Özellikle sadece ilk evrişim katmanında kullanılan Gabor filtrelerinin daha etkili olduğu görülmüştür. Bu noktada diğer evrişim katmanları için farklı yönelim ve genliklere sahip Gabor filtrelerinin kullanılmasının performansının ölçülmesine ihtiyaç bulunmaktadır.

Çalışmada Gabor filtresinin daha önce literatürde başarısından yola çıkılarak hareket edilmiş ve bir kez daha bu çalışma ile etkili sonuçlar alınabileceği gösterilmiştir. Bununla beraber Gabor filtresi dışında öznetelik çıkarabilecek Dalgacık Dönüşümü, Ayrık Kosinüs Dönüşümü gibi yaklaşımlar ağ modellerinde kullanılara sonuçlar irdelenebilir.

İki farklı veriseti üzerinden gidilerek deneysel çalışmalar yapılmıştır. Bu verisetlerinden ilki olan FashionMNIST küçük görüntüler içermektedir olup, çok farklı gruplara ait görünüler barındırmaktadır. Bu durum veriseti için geliştirilecek olan modelin boyutlarını kısıtlı olmasına neden olmaktadır. Diğer taraftan avuçizi görüntülerinin olduğu veritabanı daha büyük boyutlu görüntüler içerdiğinden model kurulumu daha rahat gerçekleştirilmiştir. Ayrıca ayırtedici öznetelikler açısından avuçiçi örüntüleri Gabor filtreleri için daha uygun veriler sunmaktadır. Bu çalışmada elde edilen deneyimler benzeri özellikler içeren verisetleri üzerinde de uygulanabilir.

Gabor filtreleri oluşturulurken yönelim bilgisi, dalga boyu gibi özellikler parametre olarak girilerek farklı filtreler ortaya çıkarılabilmektedir. Bu filtrelerin oluşturulmasında parametre optimizasyonuna gidilmesi daha başarılı sonuçlar üretilmesine olanak sağlayabilir. Ele alınan probleme uygun olarak filtre parametrelerinin belirlenmesi, hatta dinamik filtre oluşturma yaklaşımlarının uygulanması modellerin başarısını artırabilir.

KAYNAKÇA

- Aguirre, D. ve Fuentes, O. (2019). Improving weight initialization of relu and output layers. ICANN 2019: 28th International Conference on Artificial Neural Networks, Munich, Germany, September 17–19, 2019, Proceedings, Part II 28 (pp. 170-184). Springer International Publishing.
- Barocas, S. ve Selbst, A. D. (2016). Big data's disparate impact. *California Law Review*, 104, 671.
- Bhardwaj, A., Di, W. ve Wei, J. (2018). Deep Learning Essentials: Your hands-on guide to the fundamentals of deep learning and neural network modeling. Packt Publishing Ltd.
- Bingöl, Ö. ve Ekinçi, M. (2017). Stereo-based palmprint recognition in various 3D postures. *Expert Systems with Applications*, 78, 74-88.
- Castelvecchi, D. (2016). Can we open the black box of AI?. *Nature News*, 538(7623), 20.
- Chen, C. L. ve Nutter, R. S. (1991). Improving the training speed of three-layer feedforward neural nets by optimal estimation of the initial weights. IEEE International Joint Conference on Neural Networks (pp. 2063-2068).
- Dai, X., Chalkidis, I., Darkner, S. ve Elliott, D. (2022). Revisiting transformer-based models for long document classification. arXiv preprint arXiv:2204.06683.
- Deng, Z., Cao, Y., Zhou, X., Yi, Y., Jiang, Y. ve You, I. (2020). Toward efficient image recognition in sensor-based IoT: a weight initialization optimizing method for CNN Based on RGB influence proportion. *Sensors*, 20(10), 2866.
- Du, S., Lee, J., Tian, Y., Singh, A. ve Póczos, B. (2018). Gradient descent learns one-hidden-layer cnn: Don't be afraid of spurious local minima. In International Conference on Machine Learning (pp. 1339-1348).
- Duch, W., Korczak, J. ve Rutkowski, L. (1998). Optimization and global minimization methods suitable for neural networks. *Neural Networks*, 11(4), 687-693.
- Ekinçi, M. ve Aykut, M. U. R. A. T. (2007). Gabor-based kernel PCA for palmprint recognition. *Electronics Letters*, 43(20), 1.

- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118.
- Gabor, D. (1946). Theory of communication. Part 1: The analysis of information. *Journal of the Institution of Electrical Engineers-part III: radio and communication engineering*, 93(26), 429-441.
- Gan, Y., Liu, J., Dong, J. ve Zhong, G. (2015). A PCA-based convolutional network. arXiv preprint arXiv:1505.03703.
- Genovese, A., Piuri, V., Plataniotis, K. N. ve Scotti, F. (2019). PalmNet: Gabor-PCA convolutional networks for touchless palmprint recognition. *IEEE Transactions on Information Forensics and Security*, 14(12), 3160-3174.
- Glorot, X. ve Bengio, Y. (2010). Understanding the difficulty of training deep feedforward neural networks. In *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics* (pp. 249-256).
- Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep Learning*. MIT Press.
- He, K., Zhang, X., Ren, S. ve Sun, J. (2015). Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification. In *Proceedings of the IEEE International Conference on Computer Vision* (pp. 1026-1034).
- Hermosilla, D. M., Codorníu, R. T., Baracaldo, R. L., Zamora, R. S., Rodriguez, D. D., Albuérne, Y. L. ve Álvarez, J. R. N. (2021). Shallow convolutional network excel for classifying motor imagery EEG in BCI applications. *IEEE Access*, 9, 98275-98286.
- Hinton, G. E. ve Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *science*, 313(5786), 504-507.
- Hinton, G. E., Osindero, S. ve Teh, Y. W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*, 18(7), 1527-1554.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A., Jaitly, N., ... & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97.

- Ijjina, E. P. ve Chalavadi, K. M. (2016). Human action recognition using genetic algorithms and convolutional neural networks. *Pattern Recognition*, 59, 199-212.
- Izadpanahkakhk, M., Razavi, S. M., Taghipour-Gorjikotaie, M., Zahiri, S. H. ve Uncini, A. (2018). Deep region of interest and feature extraction models for palmprint verification using convolutional neural networks transfer learning. *Applied Sciences*, 8(7), 1210.
- Kamarainen, J. K. (2012). Gabor features in image analysis. In 2012 3rd international conference on image processing theory, tools and applications (IPTA) (pp. 13-14).
- Kong, W. K., Zhang, D. ve Li, W. (2003). Palmprint feature extraction using 2-D Gabor filters. *Pattern Recognition*, 36(10), 2339-2347.
- Krähenbühl, P., Doersch, C., Donahue, J. ve Darrell, T. (2015). Data-dependent initializations of convolutional neural networks. arXiv preprint arXiv:1511.06856.
- Krizhevsky, A., Sutskever, I. ve Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In Advances in neural information processing systems (pp. 1097-1105).
- Kumar, A. ve Zhang, D. (2006). Personal recognition using hand shape and texture. *IEEE Transactions on Image Processing*, 15(8), 2454-2461.
- Kumar, S. K. (2017). On weight initialization in deep neural networks. arXiv preprint arXiv:1704.08863.
- LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- Luo, D., Qiao, Y., Xie, D., Zhang, S. ve Kang, W. (2024). Palm Vein Recognition under Unconstrained and Weak-cooperative Conditions. *IEEE Transactions on Information Forensics and Security*.
- Masci, J., Meier, U., Cireşan, D. ve Schmidhuber, J. (2011). Stacked convolutional auto-encoders for hierarchical feature extraction. ICANN 2011: 21st International Conference on Artificial Neural Networks, Espoo, Finland, June 14-17, 2011. Proceedings, Part I 21 (pp. 52-59). Springer Berlin Heidelberg.

- McCulloch, W. S. ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mehdipour Ghazi, M., Nielsen, M., Pai, A., Modat, M., Cardoso, M. J., Ourselin, S. ve Sørensen, L. (2019). On the initialization of long short-term memory networks. In *Neural Information Processing: 26th International Conference, ICONIP 2019, Sydney, NSW, Australia, December 12–15, 2019, Proceedings, Part I* 26 (pp. 275-286). Springer International Publishing.
- Mishkin, D. ve Matas, J. (2015). All you need is a good init. arXiv preprint arXiv:1511.06422.
- Nair, V. ve Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)* (pp. 807-814).
- Narkhede, M. V., Bartakke, P. P. ve Sutaone, M. S. (2021). A review on weight initialization strategies for neural networks. *Artificial Intelligence Review*, 55, 291-322. <https://doi.org/10.1007/s10462-021-10033-z>
- Nguyen ve Widrow (1990). Improving the learning speed of 2-layer neural networks by choosing initial values of the adaptive weights. In *1990 IJCNN international joint conference on neural networks* (pp. 21-26). IEEE.
- Paine, T. L., Khorrami, P., Han, W. ve Huang, T. S. (2014). An analysis of unsupervised pre-training in light of recent advances. arXiv preprint arXiv:1412.6597.
- Palanisamy, K., Singhanian, D. ve Yao, A. (2020). Rethinking CNN models for audio classification. arXiv preprint arXiv:2007.11154.
- Pan, Y., Su, Z., Liu, A., Jingquan, W., Li, N. ve Xu, Z. (2022. June). A unified weight initialization paradigm for tensorial convolutional neural networks. In *International Conference on Machine Learning* (pp. 17238-17257). PMLR.
- Qiao, J., Li, S. ve Li, W. (2016). Mutual information based weight initialization method for sigmoidal feedforward neural networks. *Neurocomputing*, 207, 676-683.
- Rosenblatt, F. (1958). The Perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408.
- Ruiz-Garcia, A., Elshaw, M., Altahhan, A. ve Palade, V. (2017, May). Stacked deep convolutional auto-encoders for emotion recognition from facial expressions. In

- 2017 International Joint Conference on Neural Networks (IJCNN) (pp. 1586-1593). IEEE.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.
- Sasao, T. (2024). Linear Decomposition. In: Classification Functions for Machine Learning and Data Mining. *Synthesis Lectures on Digital Circuits & Systems*. Springer, Cham.
- Strubell, E., Ganesh, A. ve McCallum, A. (2019). Energy and policy considerations for deep learning in NLP. arXiv preprint arXiv:1906.02243.
- Sudowe, P. ve Leibe, B. (2016). Patchit: Self-supervised network weight initialization for fine-grained recognition. In BMVC (Vol. 1. pp. 24-25).
- Sun, Y., Xue, B., Zhang, M. ve Yen, G. G. (2019). Evolving deep convolutional neural networks for image classification. *IEEE Transactions on Evolutionary Computation*, 24(2), 394-407.
- Sutskever, I., Martens, J., Dahl, G. ve Hinton, G. (2013). On the importance of initialization and momentum in deep learning. In International Conference On Machine Learning (pp. 1139-1147).
- Szegedy, C., Zaremba, W., Sutskever, I., Bruna, J., Erhan, D., Goodfellow, I. ve Fergus, R. (2013). Intriguing properties of neural networks. arXiv preprint arXiv:1312.6199.
- Tang, J., Wang, D., Zhang, Z., He, L., Xin, J. ve Xu, Y. (2017). Weed identification based on K-means feature learning combined with convolutional neural network. *Computers and Electronics in Agriculture*, 135, 63-70.
- Trinh, T. H., Luong, M. T. ve Le, Q. V. (2019). Selfie: Self-supervised pretraining for image embedding. arXiv preprint arXiv:1906.02940.
- Tu, S., Huang, Y. ve Liu, G. (2017). CSFL: A novel unsupervised convolution neural network approach for visual pattern classification. *AI Communications*, 30(5), 311-324.
- URL-1, <https://baylor.ai/?p=191>. Erişim: 10.02.2024
- URL-2, https://tr.d2l.ai/chapter_convolutional-neural-networks/lenet.html, Erişim: 13.04.2024

URL–3, https://www4.comp.polyu.edu.hk/~csajaykr/IITD/Database_Palm.htm, Eriřim: 15.10.2023

Weiler, M., Hamprecht, F. A. ve Storath, M. (2018). Learning steerable filters for rotation equivariant cnns. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (pp. 849-858).

Wiehman, S., Kroon, S. ve De Villiers, H. (2016, November). Unsupervised pre-training for fully convolutional neural networks. In 2016 Pattern Recognition Association of South Africa and Robotics and Mechatronics International Conference (PRASA-RobMech) (pp. 1-6). IEEE.

Xiao, H., Rasul, K. ve Vollgraf, R. (2017). Fashion-mnist: a novel image dataset for benchmarking machine learning algorithms. arXiv preprint arXiv:1708.07747.

Yam, J. Y. ve Chow, T. W. (2000). A weight initialization method for improving training speed in feedforward neural network. *Neurocomputing*, 30(1-4), 219-232.

Yam, Y. F., Leung, C. T., Tam, P. K. ve Siu, W. C. (2002). An independent component analysis based weight initialization method for multilayer perceptrons. *Neurocomputing*, 48(1-4), 807-818.

Yang, A., Zhang, J., Sun, Q. ve Zhang, Q. (2017, October). Palmprint recognition based on CNN and local coding features. In 2017 6th International Conference on Computer Science and Network Technology (ICCSNT) (pp. 482-487). IEEE.

Yang, W., Liu, Q., Wang, S., Cui, Z., Chen, X., Chen, L. ve Zhang, N. (2018). Down image recognition based on deep convolutional neural network. *Information processing in agriculture*, 5(2), 246-252.

Yu, J., Tan, M., Zhang, H., Rui, Y. ve Tao, D. (2019). Hierarchical deep click feature prediction for fine-grained image recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(2), 563-578.

Zhao J., Schaefer F.T., Anandkumar A. Zero initialization: Initializing neural networks with only zeros and ones, *Transactions on Machine Learning Research* (2022)

Zhu, X. ve Goldberg, A. B. (2009). Introduction to semi-supervised learning. *Synthesis lectures on artificial intelligence and machine learning*, 3(1), 1-130.

ÖZGEÇMİŞ

Lise eğitimini 2014 yılında Ömer Çam Anadolu İmam Hatip Lisesinde tamamlamıştır. 2020 yılında Gümüşhane Üniversitesi Matematik Mühendisliği Lisans programından mezun oldu. 2021 yılında Gümüşhane Üniversitesi Matematik Mühendisliği Yüksek Lisans programına başladı. 2021-2022 yılların arasında Özel bir şirkette İş Analisti olarak görev yaptı. Eylül 2022 – Ocak 2023 tarihleri arasında Fenerbahçe Üniversitesi'nde Yazılım Geliştirme eğitimi aldı. Eğitim sonrasında Özel bir şirkette Yazılım Geliştirici olarak çalıştı. Aralık 2023 de Novatech Danışmanlık Yazılım şirketini kurdu.

Bu tez çalışması TÜBİTAK 1001 - Bilimsel ve Teknolojik Araştırma Projelerini Destekleme Programı tarafından desteklenen 122E402 nolu “Kısıtlamasız Ortamda Alınan El Görüntülerinden Biyometrik Doğrulama İçin Güvenilir Avuç İzi Bölgesinin Tespiti” isimli proje kapsamında gerçekleştirilmiştir.