

T.C.
AKDENİZ ÜNİVERSİTESİ



EVRIŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA

İLHAN KOÇASLAN

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ŞUBAT 2023

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ



EVRIŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA

İLHAN KOÇASLAN

FEN BİLİMLERİ ENSTİTÜSÜ

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

ŞUBAT 2023

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

EVRIŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA

**İLHAN KOÇASLAN
ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

ŞUBAT 2023

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EVRIŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA

İLHAN KOÇASLAN

ELEKTRİK ELEKTRONİK MÜHENDİSLİĞİ

ANABİLİM DALI

YÜKSEK LİSANS TEZİ

Bu tez 01/02/2023 tarihinde jüri tarafından Oybirliği ile kabul edilmiştir.

Prof. Dr. Hüseyin GÖKSU (Danışman)

Doç. Dr. Süleyman BİLGİN

Doç. Dr. Utku KÖSE

ÖZET

EVRIŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA

İLHAN KOÇASLAN

Yüksek Lisans Tezi, ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
Anabilim Dalı

Danışman: Prof. Dr. Hüseyin GÖKSU

Mayıs 2023; 45 sayfa

Bir resim tanıma işlemi nesnelerin sahip olduğu özniteliklerin öğrenilmesi ve öğrenilen bu özniteliklerin daha önceden görülmemiş resimler üzerinde tanınabilmesidir. Evrişimsel sinir ağları da resim tanıma işlemlerinde kullanılan oldukça popüler bir yapıdır. Evrişimsel sinir ağları yapay sinir ağlarının özel bir sınıfıdır ve resimlerdeki hiyerarşik özniteliklerin çıkarılıp yapay sinir ağı aracılığıyla anlamlandırılması işlemidir. Bu işlem çeşitli katmanlar aracılığıyla yapılır. Bu katmanlardan evrişim katmanında çeşitli filtreler ile önemli özellikler çıkarılır, bu katmanın amacı en doğru özelliklerin çıkarılmasıdır. Evrişim katmanından sonra havuzlama katmanı vardır ve bu katman evrişimsel sinir ağlarında anahtar konuma sahiptir. Havuzlama katmanının temel görevi, evrişim katmanı aracılığıyla oluşturulan özellik haritalarının anlamlı şekilde boyutunun düşürülmesidir. Bilinen temel yöntemleri basit olması ve işlem kolaylığı sağlamasına rağmen düşük doğrulukta olabilmektedir. Bizim yapacağımız bu çalışmada da başarısı bilgi teorisine dayanan ve sinyal ve görüntülerden anlamlı bilgi çıkarmada başarılı sonuçlar veren entropi kavramına dayanılarak bir entropi havuzlama yöntemi geliştirilmiş ve performansı geleneksel yöntemlerle kıyaslanmıştır. Test sonuçları ayrıntılı olarak paylaşılmıştır.

ANAHTAR KELİMELER: Derin öğrenme, Evrişimsel Sinir Ağları, Entropi, Havuzlama, Evrişim

JÜRİ: Prof. Dr. Hüseyin GÖKSU

Doç. Dr. Süleyman BİLGİN

Doç. Dr. Utku KÖSE

ABSTRACT

ENTROPY POOLING IN CONVOLUTIONAL NEURAL NETWORKS

İLHAN KOÇASLAN

MSc Thesis in ELECTRICAL AND ELECTRONICS ENGINEERING

Supervisor: Prof. Dr. Hüseyin Göksu

March 2023; 45 pages

An image recognition process is to learn the features of the objects and to recognize these learned features on previously unseen images. Convolutional neural networks are also a very popular structure used in image recognition processes. Convolutional neural networks are a special class of artificial neural networks and are the process of extracting hierarchical features from the images and making them meaningful through the artificial neural network. This process is done through various layers. From these layers, important features are extracted with various filters in the convolution layer, the purpose of this layer is to extract the most meaningful features. Pooling layer is after the convolution layer and this layer has a key position in convolutional neural networks. The main task of the pooling layer is to significantly reduce the size of the feature maps created through the convolution layer. Although the known basic pooling methods are simple and easy to process, they can be of low accuracy. In this study, which we will do, an entropy pooling method has been developed based on the concept of entropy, whose success is based on information theory and which gives successful results in extracting meaningful information from signals and images, and its performance will be compared with traditional methods. Test results are shared in detail.

KEYWORDS: Deep Learning, Convolutional Neural Network, Entropy, Pooling, Convolution

COMMITTEE: Prof. Dr. Hüseyin GÖKSU

Assoc. Prof. Dr. Süleyman BİLGİN

Assoc. Prof. Dr. Utku KÖSE

ÖNSÖZ

Çalışma boyunca bilgi ve tecrübelerini benden esirgemeyen, tez konumun belirlenmesinde yardımcı olan, öneri ve yardımları ile tezime katkıda bulunan, tez danışman hocam Sayın Prof. Dr. Hüseyin GÖKSU' ya teşekkür ve saygılarımı sunarım.

Eğitim-öğretim ve çalışma hayatım boyunca bana desteklerini esirgemeyen, her konuda bana sonsuz güvenen aileme teşekkürlerimi ve minnettarlığımı sunarım.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ.....	iii
AKADEMİK BEYAN	vii
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ.....	viii
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. KAYNAK TARAMASI	5
3. MATERYAL VE METOT	8
3.1. Aktivasyon Fonksiyonları	8
3.1.1. Basamak fonksiyonu.....	8
3.1.2. Sigmoid fonksiyonu.....	8
3.1.3. Hiperbolik tanjant fonksiyonu	9
3.1.4. ReLU(Rectified Linear Unit) fonksiyonu.....	10
3.1.5. Sızıntı(Leaky) ReLU(Rectified Linear Unit) fonksiyonu.....	11
3.1.6. Softmax fonksiyonu.....	11
3.1.7. Swish(A Self-Gated) fonksiyonu.....	12
3.2. Tek Katmanlı Algılayıcı Yapısı	13
3.3. Çok Katmanlı Yapay Sinir Ağı Yapısı.....	13
3.4. Evrişimsel Sinir Ağları Genel Tanımı.....	14
3.5. Veri Seti.....	14
3.6. Piksel Ekleme	15
3.7. Kaydırma Adımı.....	16
3.8. Evrişim Katmanı.....	17
3.9. Maksimum Havuzlama.....	18
3.10. Ortalama Havuzlama.....	18
3.11. Log Enerji Entropi.....	19
3.12. Shannon Entropi	20
3.13. Enerji	20
4. BULGULAR.....	21

5. TARTIŞMA	38
5.1. Havuzlama Seçimi.....	38
5.2. Model Seçimi	38
6. SONUÇLAR	42
7. KAYNAKLAR	43

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum EVRİŞİMSEL SİNİR AĞLARINDA ENTROPİ HAVUZLAMA adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

01./02/2023

Öğrencinin Adı Soyadı

İlhan KOGASLAN

İmzası



SİMGELER VE KISALTMALAR

Bu tezde kullanılan ondalık ayırıcı virgül (“,”)’dür.

Kisaltmalar

ÇKYSA	: Çok Katmanlı Yapay Sinir Ağları
CNN	: Convolutional Neural Network
MNIST	: Modified National Institute of Standards and Technology
SPP	: Spatial Pyramid Pooling
RoI	: Region of Interest Pooling
MOP	: Multi-scale order-less pooling
CIFAR-10	: Canadian Institute For Advanced Research 10 Clases
CIFAR-100	: Canadian Institute For Advanced Research 100 Clases
RELU	: Rectified Lineer Unit
M. H.	: Maksimum Havuzlama
O. H.	: Ortalama Havuzlama
E. H.	: Entropi Havuzlama
T. DE.	: Test Değeri
SDK.	: Son Devir Kaybı
SDD.	: Son Devir Doğruluğu
T. DO.	: Test Doğruluğu

ŞEKİLLER DİZİNİ

Şekil 1.1. Çok katmanlı yapay sinir ağı	1
Şekil 1.2. Evrimsel sinir ağlarının evrişim ve havuzlama kısımları	2
Şekil 1.3. Örnek bir giriş matrisi ve filtre matrisi	3
Şekil 1.4. CNN yapısına ait bir maksimum havuzlama işlemi	4
Şekil 3.1. Basamak fonksiyonu.....	5
Şekil 3.2. Sigmoid fonksiyonu.....	6
Şekil 3.3. Tanh fonksiyonu	7
Şekil 3.4. Doğrultulmuş doğrusal birimler fonksiyonu	8
Şekil 3.5. Sızıntı doğrultulmuş doğrusal birimler fonksiyonu.....	9
Şekil 3.6. Softmax aktivasyon fonksiyonu	10
Şekil 3.7. Swish fonksiyonu	11
Şekil 3.8. Çok katmanlı yapay sinir ağı.....	12
Şekil 3.9. a) MNIST b) CIFAR10 c) CIFAR100.....	13
Şekil 3.10. Piksel ekleme	14
Şekil 3.11. Kaydırma adımı	15
Şekil 3.12. Giriş matrisi ve bir filtre matrisi	16
Şekil 3.13. Giriş matrisi ve filtre matrisinin çarpılması.....	17
Şekil 3.14. Maksimum havuzlama yöntemi.....	18
Şekil 3.15. Ortalama havuzlama yöntemi	19
Şekil 3.16. Log enerji entropi yöntemi	20
Şekil 4.1. a) M. H. doğruluk eğrisi b) M. H. kayıp eğrisi.....	21
Şekil 4.2. a) O. H. doğruluk eğrisi b) O. H. kayıp eğrisi	22
Şekil 4.3. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi	23
Şekil 4.4. a) Enerji doğruluk eğrisi b) Enerji kayıp eğrisi	24
Şekil 4.5. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H. kayıp eğrisi	25

Şekil 4.6. a) M. H. doğruluk eğrisi b) M. H. kayıp eğrisi.....	26
Şekil 4.7. a) O. H. (Ortalama Havuzlama) doğruluk eğrisi b) O. H. kayıp eğrisi	27
Şekil 4.8. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi	28
Şekil 4.9. a) Enerji doğruluk eğrisi b) Enerji kayıp eğrisi	29
Şekil 4.10. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H.kayıp eğrisi	30
Şekil 4.11. a) M. H. doğruluk eğrisi b) M. H. kayıp eğrisi.....	31
Şekil 4.12. a) O. H. (Ortalama Havuzlama) doğruluk eğrisi b) O. H. kayıp eğrisi	32
Şekil 4.13. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi	33
Şekil 4.14. a) Enerji doğruluk eğrisi b) Enerji kayıp eğrisi	34
Şekil 4.15. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H.kayıp eğrisi	35
Şekil 4.16. a) M. H. doğruluk eğrisi b) M. H. kayıp eğrisi.....	36
Şekil 4.17. a) O. H. (Ortalama Havuzlama) doğruluk eğrisi b) O. H. kayıp eğrisi	37
Şekil 4.18. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi	38
Şekil 4.19. a) Enerji doğruluk eğrisi b) Enerji kayıp eğrisi	39
Şekil 4.20. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H.kayıp eğrisi	40
Şekil 5.1. Çalışmada kullanılan CNN modeli.....	41
Şekil 5.2. Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 1	42
Şekil 5.3. Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 2	43
Şekil 5.4. Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 3	44
Şekil 5.5. Çalışmanın ikinci kısmında kullanılan CNN modeli.....	45

ÇİZELGELER DİZİNİ

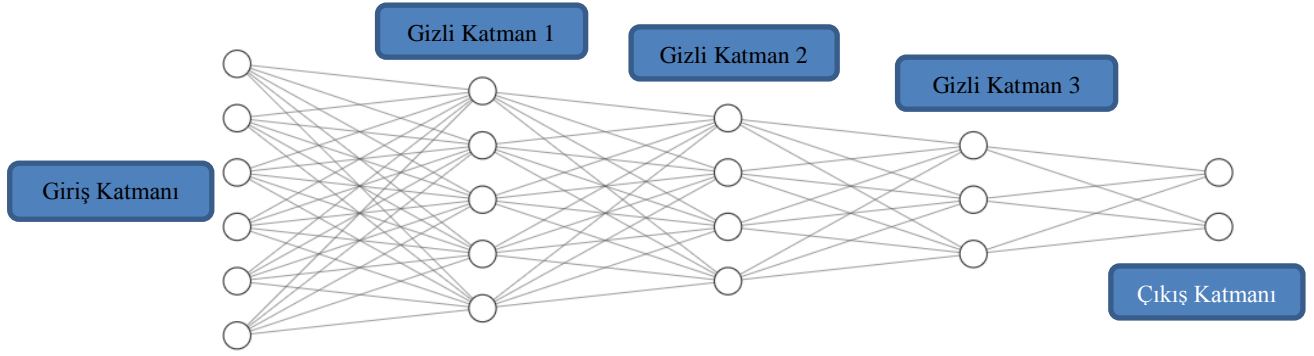
Çizelge 4.1. MNIST veri seti 50 devirde test sonuçları	1
Çizelge 4.2. CIFAR-10 veri seti 70 devirde test sonuçları	2
Çizelge 4.3. CIFAR-100 veri seti 200 devirde test sonuçları	3
Çizelge 4.4. CIFAR-100 veri seti (4,4) adımlama ile 150 devirde test sonuçları.....	4

1. GİRİŞ

Teknolojinin gelişimine paralel olarak bazı alanlarda özellikle'de yapay zeka alanında hızlı ilerlemeler meydana gelmiştir. Yapay zeka alanında bu kadar hızlı bir gelişmenin meydana gelmesinde özellikle yapay sinir ağlarının ihtiyacı olan veriye erişimin daha kolay olması bu gelişmeyi meydana getirmiştir. Son zamanlarda makine öğrenmesi alanında ve çip teknolojisinde meydana gelen gelişmeler'de bu alanı desteklemiştir (Deng 2014). Yapay zeka bazen kış bazen de yaz olmak üzere bazı süreçlerden geçmiştir ve son zamanlarda ise yeniden ivme kazanmıştır. Yapay zeka alanı birçok alt alana sahiptir.


Yapay zeka alanı içinde derin öğrenme, makine öğrenmesi konularını içeren bir bütündür. Derin öğrenme kısmında özellikle beyinde bulunan nöronların çalışmasından ilham alınmıştır. Derin öğrenme birçok alanda çeşitli amaçlar için kullanılabilir. Örneğin ham veriden anlamlı kısımların çıkarılması, transfer learning ve skip gram model gibi örnekleri vardır (Ren ve Xu 2015). Derin öğrenme yapay sinir ağlarının kullanımıyla meydana gelir. Günümüzde yapay sinir ağları birçok alanda yaygın olarak kullanılmakla birlikte farklı yapay sinir ağı çeşitleri'de mevcuttur. Bu alanlar arasında otonom sürüş, tahmin sistemleri, finans, sağlık, sesli asistanlar, robotik vs. alanlar dan oluşmaktadır. Yapay sinir ağları giriş katmanı, gizli katman veya gizli katmanlar ve çıktı katmanı olmak üzere üç katman türüne sahiptir. Yapay sinir ağı yapısı ve katman sayısı probleme göre değişiklik gösterebilir. Katman sayısı arttıkça işlem yükünün artacağı da unutulmamalıdır.

Yapay sinir ağlarında her bir yapay sinir hücresi kendisinden önceki katmandaki nöronlar'dan beslenirken kendisinden sonraki nöronları da beslemektedir. Yapay sinir hücresinin çıkışını üretebilmek için bir aktivasyon fonksiyonuna ihtiyaç duyulmaktadır. Aktivasyon fonksiyonlarının birçok modeli mevcut olmakla birlikte bazı aktivasyon fonksiyonları çıkış katmanında daha iyi sonuç verirken bazıları ara katmanlarda bazıları ise giriş katmanında daha iyi sonuçlar verebilmektedir.



Şekil 1.1. Çok katmanlı yapay sinir ağı

Şekil 1.1.'de üç adet gizli katmana sahip çok katmanlı yapay sinir ağı görülmektedir. Çok katmanlı yapay sinir ağları ile çeşitli sınıflandırma problemleri üzerinde çalışılmış ve bazı başarılı sonuçlar alınmıştır. Çok katmanlı yapay sinir ağlarının daha başarılı sonuçlar verebilmesi için evrimsel sinir ağları yapısı önerilmiştir (Lecun vd. 1998). Evrimsel sinir ağlarının çok katmanlı yapay sinir ağlarından farkı, çok katmanlı yapay sinir ağlarının girişine gelen verilerin önce evrişim daha sonra da havuzlama katmanından geçiyor olmasıdır. Evrimsel sinir ağlarının bu denli yaygınlaşmasında ise çiplerin işlem gücünün artması ve yeni havuzlama yöntemlerinin bulunmasıdır (Husain ve Bober 2019). Evrimsel sinir ağlarının başarısının altında yatan temel ise insan doğasında da bulunan bir görüntünün belirgin noktalarından kesitler almak ve bu kesitlerin çeşitli nesnelere ait özniteliklerle eşleşip eşleşmediğine bakmaktır (Lecun vd. 2010).



Şekil 1.2. Evrimsel sinir ağlarının evrişim ve havuzlama kısımları

Şekil 1.2.'de Evrimsel sinir ağının havuzlama ve evrişim işlemleri sonucunda oluşan özellik haritaları ve bunların havuzlama işlemi ile boyutlarının nasıl düşürüldüğü görülmektedir. Evrişim katmanında resimlere ait öznitelikler çeşitli filtreler aracılığıyla

çıkarılmaktadır. Özellik çıkarma işlemi CNN (Convolutional Neural Network) yapısının en fazla zaman alan kısmıdır. Özellik çıkarmada kullanılan bazı filtreler box blur, Gaussian blur, Unsharp masking vb dir.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

5x5 – Giriş Matrisi


1	0	1
0	1	0
1	0	1

3x3 Filtre Matrisi

Şekil 1.3. Örnek bir giriş matrisi ve filtre matrisi

Şekil 1.3.'de Örnek bir giriş matrisi ve bu matrisin önemli özelliklerinin çıkarılmasına yardımcı olacak bir filtre matrisi görülmektedir.

Evrişim katmanında çıkış matrisi hesaplanırken giriş matrisi üzerinde filtre matrisi gezdirilerek sonuç hesaplanır ve aktivasyon fonksiyonundan geçirilir sonuç yeni oluşturulacak sonuç matrisine yazılır. Evrişim katmanının sonucunda oluşan matris boyutları giriş matrisi ve filtre matrisinin boyutlarıyla ilgilidir. Evrişim katmanından sonra havuzlama katmanı gelir ve bu katman çıkartılan özellik haritalarından daha anlamlı verileri çıkartarak yapay sinir ağının girişine ulaşmasını sağlar. Bu noktada daha anlamlı veri gönderebilmek için çeşitli piksel ekleme yöntemleri'de geliştirilmiştir. Dolgusuz, sıfır dolgu ve aynı dolgu olmak üzere üç tanedir. Aynı dolgu yönteminin amacı özellikle köşeler vb. yerlerde bulunan anlamlı verilerin kaybının önlenmesidir.



Şekil 1.4. CNN yapısına ait bir maksimum havuzlama işlemi

Şekil 1.4.'de Maksimum havuzlama işlemine ait örnekler görülmektedir. Burada farklı renk bölgelerindeki en yüksek değere sahip değer alınmaktadır.

Evrişimsel sinir ağlarının son kısmında ise çok katmanlı yapay sinir ağı yapısı bulunmaktadır ve bu yapının 5 farklı çeşidi vardır (Guo vd. 2016). Evrişimsel sinir ağları ilk defa el yazısı rakamların tanınması çalışmasında kullanıldı (Lecun vd. 1998). Evrişimsel sinir ağları büyük ölçekli veri setleriyle'de test edilmişlerdir (Krizhevsky vd. 2017). Evrişimsel sinir ağlarında evrişim katmanı gibi havuzlama katmanı da büyük bir öneme sahiptir (Gholamalinezhad ve Khosravi 2020). Geleneksel havuzlama metotları maksimum, toplam, ortalama gibi havuzlama yöntemleridir bu yöntemlerin avantajı hızlı çalışmasıdır lakin aynı zamanda anlamlı piksel kaybına da neden olabilmektedir. Maksimum havuzlama yöntemi bazı veri setlerinde diğer yöntemlere üstünlük sağlamıştır (Bera ve Shrivastava 2020). Bazı çalışmalarda da çeşitli havuzlama yöntemleri denenmiş ve bu yöntemlerde geleneksel yöntemlere göre daha başarılı sonuçlar elde edilmiştir (Russakovsky vd. 2012; Saeedan vd. 2018). Bu yöntemlerin yanı sıra melez denemeler'de yapılmış ve çeşitli başarılar elde edilmiştir (Lee vd. 2017). Yapılan çalışmalarda çeşitli başarılı sonuçlar elde edilmiş lakin yüksek düzeyde başarılı sonuçlar elde edilememiştir. Bunun için başarısını bilgi teorisine dayanan ve sinyal ve görüntülerden anlamlı bilgi çıkarmada başarılı sonuçlar veren entropi kavramına dayanan bir entropi havuzlama yöntemi geliştirilmiştir (Göksu 2018a, b). Geliştirilen yöntem geleneksel yöntemlerle kıyaslanmıştır. Havuzlama katmanında geleneksel havuzlama yöntemleri yerine entropi havuzlama denemeyi düşünmemizin temel nedeni ise entropi havuzlama'nın görüntü işlemede başarılı kullanımlarıdır (Lecun vd. 1990; Song vd. 2009). Keras kütüphanesi yardımıyla deneme yapılmıştır. Çalışmada veri seti olarak kolay orta ve zor olmak üzere 3 tip veri seti kullanılmıştır. Geleneksel havuzlama yöntemlerinde ise maksimum havuzlama ve ortalama havuzlama yöntemi baz alınacaktır. Entropi havuzlama yönteminde ise Log enerji entropi, Energy, Shannon entropi olmak üzere üç adet havuzlama yöntemi denenmiştir.

2. KAYNAK TARAMASI

Evrişimsel sinir ağlarında bulunan havuzlama katmanının değiştirilerek yerine yeni mantıksal çıkarımlarla elde edilen yöntemlerin uygulanması konusunda çeşitli makaleler yayınlanmıştır. Bu yöntemlerden ortalama havuzlama yöntemi ilk kez el yazısı rakam tanıma işleminde kullanılmıştır. (Lecun vd. 1989).

Ortalama havuzlama yöntemi ile diğer havuzlama yöntemleri kıyaslanmıştır. (Lecun vd. 1998). Bazı veri setlerinde maksimum havuzlama bazı veri setlerinde ortalama havuzlama yöntemi daha iyi sonuç verebilmektedir. Yapılan bir çalışmada bu iki yöntemi birleştiren heterojen havuzlama yöntemi denenmiş ve diğer yöntemlere göre daha iyi sonuç ürettiği gözlenmiştir (Dingjun vd. 2014). Mixed havuzlama yöntemine ait formül aşağıdadır.

$$y_{kij} = \lambda \cdot \max_{(p,q) \in R_{ij}} x_{kpq} + (1 - \lambda) \cdot \frac{1}{|R_{ij}|} \sum_{(p,q) \in R_{ij}} x_{kpq} \quad (2.1)$$

Burada:

y_{kij} : Havuzlama işleminin çıkışını ifade etmektedir.

R_{ij} : Yerel komşuyu ifade etmektedir.

x : Giriş resmini ifade etmektedir.

λ : 0 ile 1 arasında rasgele bir değeri ifade etmektedir.

Sermanet vd. (2013), çalışmalarında lp pooling yönteminin genelleme yeteneğinin maksimum havuzlama yöntemine göre daha iyi olduğunu göstermişlerdir. Önerilen yöntem SVHN (Street View House Numbers) veri set üzerinde %95 başarı sağlamıştır. Çalışmada p değeri $p = 1, 2, 4, 8, 12, 16, 32, 1$ değerleri arasında tutulmuştur.

$$s_j = \left(\frac{1}{|S_j|} \sum_{i \in R_j} a_i \right)^{1/p} \quad (2.2)$$

Burada:

S_j : j konumunda bulunan havuzlama operatörünün çıkışını ifade etmektedir.

a_i : R_j pooling bölgesinde bulunan i konumundaki özellik değeridir.

Bir diğer havuzlama çalışması olan stochastic havuzlama yönteminde aşırı uydurmayı engellendiği görülmektedir (Zeiler ve Fergus 2013). Stochastic havuzlama yönteminde ilk olarak her j bölgesindeki p olasılığı bulunur.

$$p_i = \frac{a_i}{\sum_{k \in R_j} a_k} \quad (2.3)$$

Burada:

p_i : j bölgesinin olasılığını ifade etmektedir.

a_i : R_j pooling bölgesinde bulunan i konumundaki özellik değeridir.

p değeri bulunduktan sonra bu değere bağlı olarak l konumundaki değerler bulunur.

$$S_j = a_l \sim P(p_1, \dots, p_{|R_j|}) \quad (2.4)$$

Burada:

S_j : Havuzlama işleminin çıkışını ifade etmektedir.

a_l : Havuzlama aktivasyonunu ifade etmektedir.

l : l konumunu ifade etmektedir.

Lazebnik vd. (2006), çalışmalarında spatial pyramid havuzlama yöntemini önermişlerdir. Bu yöntem özellikle nesne tanıma problemleri için iyidir. Bunun için yolo adlı modülde' de bu yöntem kullanılmaktadır.

He vd. (2015), çalışmalarında SPP (Spatial Pyramid Pooling)'nin farklı boyutlarda olan resimlerin işlenmesinde esneklik sağladığından bahsetmişlerdir. RoI (Region of Interest Pooling) havuzlama yöntemi çoğunlukla nesne tanıma ve sınıflandırma problemlerinde kullanılır (Girshick 2015; Li vd. 2018).

Gong vd. (2014), çalışmalarında MOP (Multi-scale order-less pooling) yöntemini önermişlerdir. Bu havuzlama yöntemi CNN in doğal özellikler çıkarma gücünü etkilemeden nesnelere ait değişmeyen özellikleri bulur.

Gao vd. (2016), çalışmalarında özellikle yüz tanıma, anlamsal sınıflandırmada iyi sonuçlar veren bir yöntem önermişlerdir. Köşe bilgilerini korumada daha iyi olan bir yöntem ise edge-aware pyramid pooling yöntemidir (Xu vd. 2019). Frekans alanında girişin boyutunu azaltan bir yöntem ise spectral pooling yöntemidir (Rippel vd. 2015).

Giriş matrisinin her satırındaki en büyük değeri alan havuzlama yöntemi ise Row-Wise Max-Pooling yöntemidir (Shi vd. 2015).

Lee vd. (2016), çalışmalarında intermap Pooling yöntemini önermişlerdir. Bu yöntem filtreleri gruplayan ve özellik haritalarını bir grupta birleştiren bir yöntemdir.

Park ve Lee (2017), çalışmalarında per-pixel pyramid pooling yöntemini önermişlerdir ve aşağıdaki formül ile hesaplanmaktadır.

$$P^{4P} = [P(F, S_1), \dots, P(F, S_m)] \quad (2.5)$$

Burada:

s : M tane elemana sahip bir vektör.

$P(F, S_i)$: S_i büyüklüğünde bir havuzlama işlemidir

Shi vd. (2016), sıra tabanlı ortalama havuzlama yönteminden bahsetmişler ve çalışmanın öneminin geleneksel yöntemlerden önemli bilgileri kaybetmemesi olduğunu ifade etmişlerdir.

$$S_j = \frac{1}{t} \sum_{i \in R_j, r_i < t} a_i \quad (2.6)$$

Burada:

S_j : Havuzlama işleminin çıkışını ifade etmektedir.

t : Sıra eşliğini ifade etmektedir.

a_i : Aktivasyon eşliğini temsil etmektedir.

R_j : Özellik haritasındaki j bölgesine ait havuzlama bölgesidir.


Dong vd. (2018), çalışmalarında weighted pooling yöntemini önermiştir. Bu yöntemde bir sınır hücresinin cevabının yanı sıra cevabın faydalılığını da göz önüne alır.

3. MATERYAL VE METOT

3.1. Aktivasyon Fonksiyonları:

3.1.1. Basamak fonksiyonu

Genellikle çıkış katmanında tercih edilen bir fonksiyondur. x değeri X_0 değerinden büyük veya eşitse 1, küçük ise 0 değerini alır. Basamak fonksiyonu ara katmanlarda kullanılması genellikle tavsiye edilmez.



Şekil 3.1. Basamak fonksiyonu

Şekil 3.1.'de basamak fonksiyonu -100 ile +100 arasında oluşan sonuçları görülmektedir.

$$Q(x) = 1, x \geq X_0 \quad (3.1)$$

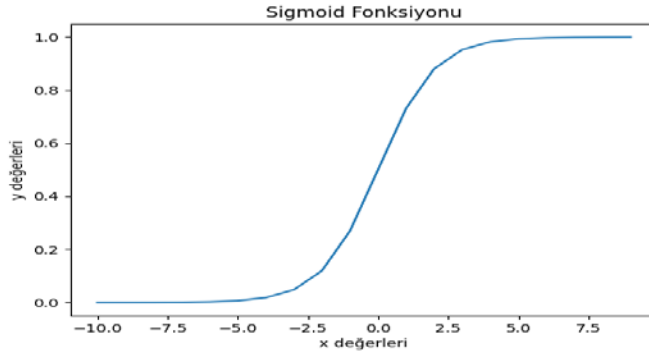
$$Q(x) = 0, x < X_0 \quad (3.2)$$

Burada:

x : x bir reel sayıdır.

3.1.2. Sigmoid Fonksiyonu

Sigmoid aktivasyon fonksiyonu doğrusal olmayan yapısıyla oldukça önemli bir aktivasyon fonksiyonudur. Sigmoid aktivasyon fonksiyonunun önemli dezavantajı x değerlerinin uç noktalardaki değişimlere gittikçe daha az tepki vermesi gösterilebilir. Aynı zamanda çok katmanlı yapılarda türev alma işleminde bazı sorunlara neden olabilmektedir.



Şekil 3.2. Sigmoid fonksiyonu

Şekil 3.2.'de sigmoid fonksiyonunun -10 ile +10 arasında oluşan sonuçları görülmektedir.

$$S(x) = \frac{1}{1+e^{-x}} \quad (3.3)$$

Burada:

x: x bir reel sayıdır.

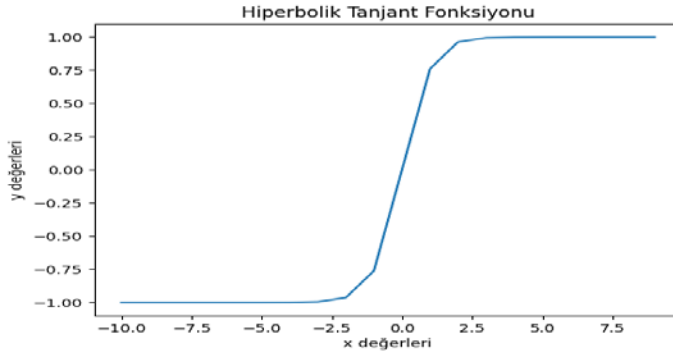
3.1.3. Hiperbolik Tanjant Fonksiyonu

Hiperbolik tanjant fonksiyonu sigmoid fonksiyonuna benzemekle birlikte sigmoid fonksiyonu 0,1 aralığında değer alırken hiperbolik tanjant fonksiyonu -1,+1 aralığında değer almaktadır. Hiperbolik tanjant fonksiyonu geniş bir aralıkta değer almasından dolayı özellikle sınıflandırma problemlerinde daha iyi sonuç vermektedir.

$$H(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (3.4)$$

Burada:

x: x bir reel sayıdır.



Şekil 3.3. Tanh fonksiyonu

Şekil 3.3.'de Hiperbolik tanjant fonksiyonunun -10 ile +10 arasında oluşan sonuçları görülmektedir.

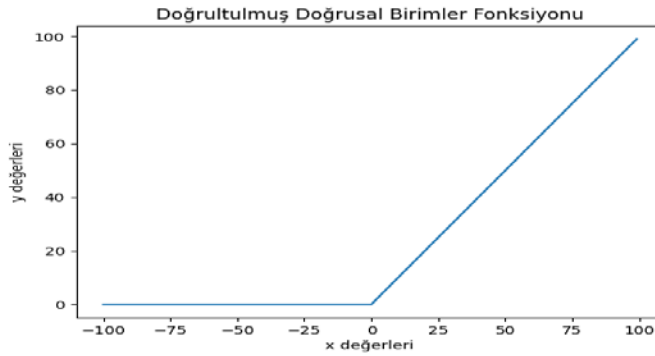
3.1.4. ReLU(Rectified Linear Unit) Fonksiyonu

Genellikle evrimsel sinir ağlarında kullanılan RELU fonksiyonu doğrusal olmayan bir fonksiyondur. 0'dan küçük değerler için 0 değerini alırken 0'dan büyük x değerlerinde yine x değerini alır. RELU aktivasyon fonksiyonunun 0'dan küçük bölgelerde hızlı çalışmasına rağmen aynı zamanda bu bölgede öğrenmenin olmaması dezavantaj olarak söylenebilir. RELU fonksiyonu 0 ile ∞ arasında değer almaktadır.

$$Q(x) = 0, x < 0 \parallel x, x \geq 0 \quad (3.5)$$

Burada:

x: x bir reel sayıdır.



Şekil 3.4. Doğrultulmuş doğrusal birimler fonksiyonu

Şekil 3.4.'de doğrultulmuş doğrusal birimler fonksiyonunun -100 ile +100 arasında oluşan sonuçları görülmektedir.

3.1.5 Sızıntı(Leaky) ReLU(Rectified Linear Unit) Fonksiyonu

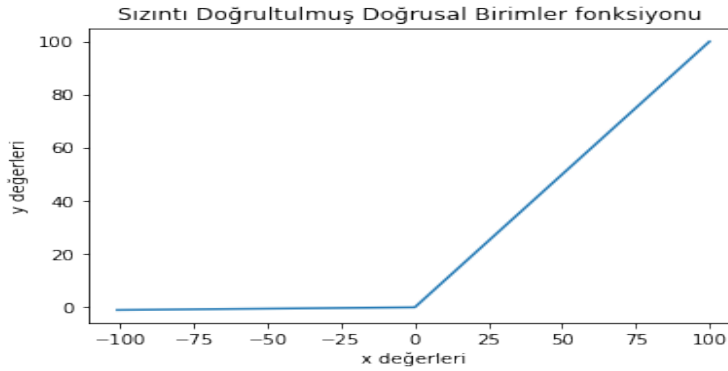
RELU fonksiyonunun negatif bölgelerde öğrenememesinin önüne geçmek amacıyla bulunan bu fonksiyon negatif değerlerde'de değer alarak öğrenmenin o bölgede de devam etmesini sağlamaktadır. Negatif değerlerde eğimi pozitif değerlere göre daha azdır. Genellikle gan yapılarında kullanılmaktadır.

$$Q(x) = x, x \geq X_0 \quad (3.6)$$

$$Q(x) = 0.01.x, x < X_0 \quad (3.7)$$

Burada:

x : x bir reel sayıdır.

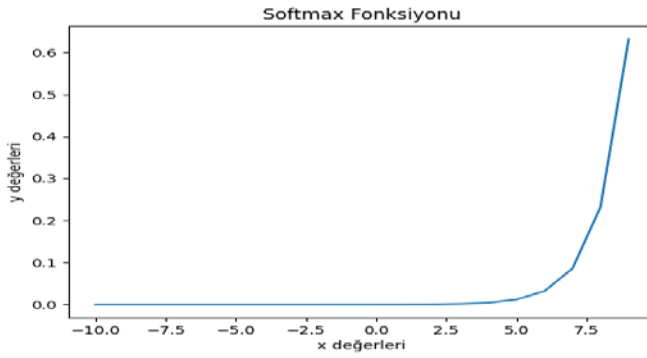


Şekil 3.5. Sızıntı Doğrultulmuş Doğrusal Birimler fonksiyonu

Şekil 3.5.'de sızıntı doğrultulmuş doğrusal birimler fonksiyonunun -100 ile +100 arasında oluşan sonuçları görülmektedir.

3.1.6. Softmax Fonksiyonu

Genellikle çıkış katmanında kullanılan softmax fonksiyonu sınıflandırma problemlerinde iyi sonuçlar vermektedir.



Şekil 3.6. Softmax aktivasyon fonksiyonu

Şekil 3.6.'da Softmax fonksiyonunun -10 ile +10 arasında oluşan sonuçları görülmektedir.

3.1.7. Swish(A Self-Gated) Fonksiyonu


Bu fonksiyonunun en büyük avantajı negatif bölgede doğrusal olmayan değerler alır. Swish fonksiyonunun bir diğer önemli özelliği ise beta adında değiştirilebilen bir öğrenme parametresine sahip olmasıdır.

$$f(x) = x \cdot \text{sigmoid}(\beta \cdot x) \quad (3.8)$$

Burada:

x : x bir reel sayıdır.

β : öğrenme parametresi



Şekil 3.7. Swish fonksiyonu

Şekil 3.7.'de Swish fonksiyonunun -10 ile +10 arasında oluşan sonuçları görülmektedir.

3.2. Tek Katmanlı Algılayıcı Yapısı

Tek katmanlı algılayıcı en basit nöron yapısıdır ve yalnızca bir çıkışa sahiptir. Çıkış değerinin oluşturulabilmesi için giriş ve girişe ait olan ağırlıklar çarpılır ve çarpılan ağırlıklar toplanır ve toplanmış olan değer aktivasyon fonksiyonundan geçirilmesi ile çıkış değeri oluşur. Bazı yapılarda eşik değeri de kullanılmaktadır. Eşik değeri yardımıyla aktivasyon fonksiyonu eğrisi yer değiştirilebilmektedir. Aşağıda perceptron ağının yapısı görülmektedir.

$$Toplam = \sum_{i=1}^n x_i \cdot w_i \quad (3.9)$$

$$Y = f(Toplam) \quad (3.10)$$

Burada:

n : Hücrenin giriş sayısını ifade etmektedir.

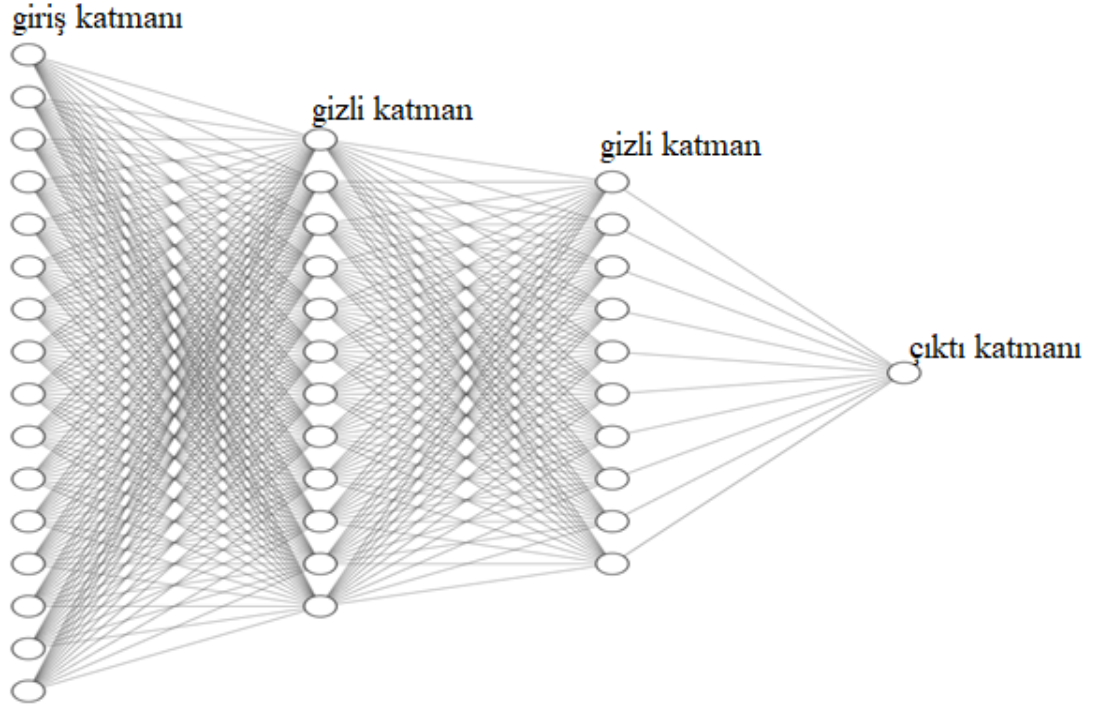
x_i : Girişleri ifade etmektedir.

w_i : Ağırlıkları ifade etmektedir.

y : Çıkış değerini ifade etmektedir.

3.3. Çok Katmanlı Yapay Sinir Ağı Yapısı

Çok katmanlı yapay sinir ağı yapay sinir ağlarının katmanlar halinde düzenlenmiş halidir. Giriş katmanı ara katman ve çıkış katmanı olmak üzere katmanlara sahiptir. Ara katman sayısı istenilen probleme göre değişiklik gösterebilir. ÇKYSA yapısında nöronlar arasında ağırlıklar mevcuttur ve öğrenme olayı bu ağırlıklar aracılığıyla olur. Giriş ve ağırlığın çarpılması daha sonra aktivasyon fonksiyonundan geçirilmesiyle ilgili nöronun çıktısı oluşur oluşan bu çıkış ise diğer nöronun girişini oluşturur. ÇKYSA yapısının başarılı olmasındaki temel faktör ise geri beslemenin olmasıdır. Geri besleme çeşitli optimizasyon teknikleri ile yapılabilmektedir. Bunlar arasından en popüler olanı Adaptif Moment Tahmini optimizasyon tekniğidir. Geri besleme ile çıkış hatasının azaltılması ve böylece istenilen girişe göre istenilen çıkışın elde edilmesi amaçlanmaktadır. ÇKYSA yapısı teknoloji, finans, sağlık vb. alanlar da kullanımı gün geçtikçe artmaktadır. ÇKYSA yapısı özelleştirilmiş olarak yazılabileceği gibi çeşitli modüller aracılığıyla da eklenebilmektedir bunlar arasında bizim kullanacağımız François Chollet tarafından yazılmış olan keras kütüphanesidir. Keras modülünde katmanlar modele layers.dense komutu aracılığı ile eklenmektedir. Geri besleme için' de istenilen optimizasyon tekniği kolaylıkla kullanılabilir.



Şekil 3.8. Çok Katmanlı Yapay Sinir Ağı

Şekil 3.8.'de iki tane gizli katma sahip bir ÇKYSA görülmektedir.

3.4. Evrişimsel Sinir Ağları Genel Tanımı

CNN yapay sinir ağlarının özelleştirilmiş bir sınıfıdır. CNN 3 bölümden oluşur bunlar evrişim, havuzlama ve çok katmanlı yapay sinir ağı bölümleridir. Evrişim katmanında filtre matrisleri her bir örnek matris üzerinde evrişim işlemi yapılır ve özellik haritaları elde edilir. Matris çarpımı sonucu elde edilen özellik haritaları, havuzlama katmanında havuzlama yöntemleri aracılığıyla anlamlı veriler filtre edilerek boyut azaltma işlemi yapılmaktadır.

3.5. Veri Seti

Çalışma kapsamında genel olarak bilinen MNIST (Modified National Institute of Standards and Technology), CIFAR-10 (Canadian Institute For Advanced Research 10 Clases), CIFAR-100 (Canadian Institute For Advanced Research 100 Clases) veri setleri kullanılmış ve bu veri setleri keras aracılığıyla indirilmiştir. MNIST veri seti (28,28) boyutlarındadır. 60.000'i öğrenme 10.000'i doğrulama ve 10.000'i test için kullanılacaktır. CIFAR-10 veri seti (32,32) boyutlarındadır. 50.000' i eğitim 10.000' i doğrulama ve 10.000'i test için kullanılmıştır. CIFAR-100 veri seti (32,32) boyutlarındadır. 50.000' i eğitim 10.000' i doğrulama ve 10.000' i test için kullanılmıştır. Çalışma genel havuzlama yöntemleri ile karşılaştırılacağı için seçilen veri setleri'de genel olarak kullanılan veri setleridir. MNIST veri seti kullanılırken önce

çerçeve i (28,28) şekline getirilir daha sonra 60.000 örnek maksimum havuzlama ve ortalama havuzlama yöntemi ile eğitilir ve daha sonra 10.000 örnek ile test edilir ve elde edilen sonuçlar kaydedilir. Geleneksel yöntemlerden sonra sırasıyla Log enerji entropi, Shannon entropi, Enerji yöntemleri uygulanıp sonuçlar kaydedilmiştir. CIFAR-10 veri seti için'de öncelikle maksimum havuzlama ve ortalama havuzlama yöntemi ile eğitilmiş ve daha sonra sırasıyla Log enerji entropi, Norm entropi, Shannon entropi, Enerji yöntemleri denenmiş sonuçları karşılaştırılmıştır. CIFAR-100 veri seti için'de öncelikle maksimum havuzlama ve ortalama havuzlama yöntemi ile eğitilmiş ve daha sonra sırasıyla Log enerji entropi, Shannon entropi ve Enerji yöntemleri denenmiş ve sonuçları karşılaştırılmıştır.



Şekil 3.9. a) MNIST

b) CIFAR-10

c) CIFAR-100

Şekil 3.9.'da MNIST, CIFAR-10 ve CIFAR-100 veri setlerine ait örnek çıktılar görülmektedir.

3.6. Piksel Ekleme

CNN işlemi sırasında kullanılan iki çeşit piksel ekleme türü vardır. CNN işleminde giriş matrisi bazen bizim belirlediğimiz matrisin boyutundan az veya fazla veya tam uyabilir. CNN yapısında bu gibi durumlarda giriş matrisinin tamamında işlem yapmak istiyorsak aynı dolgulama, sadece eşleştiği kısmı kadar işlem yapmak istiyorsak dolgusuz yapmalıyız.

17	80	14	63	0
13	11	43	79	0
27	33	7	4	
255	89	77	63	

x_0 x_1
 x_1 x_0

Şekil 3.10. Piksel ekleme

Şekil 3.10.'da piksel ekleme yöntemine ait bir örnek görülmektedir. Şekil 3.6.1'de görülen aynı dolgulama işleminde seçilen filtre tam olarak eşleşmezse diğer kısımlara 0 yazarak işlem yapılmaktadır. Geçerli dolgulama işleminde ise bu kısım görmezden gelinir.

3.7. Kaydırma Adımı

CNN yapısında seçilen filtrelerin kaç adım ilerleyeceği adım terimi ile belirlenir. Adımı 1 seçersek 1 piksel ilerlerken 2 seçersek 2 adım ilerler. Örneğin adımlama (2,2) şeklinde seçersek 2 adım sağa aynı şekilde 2 adım aşağı şeklinde ilerler.

17	80	14	63	
13	11	43	79	
27	33	7	4	
255	69	77	63	

kaydırma
adımı →

17	80	14	63
13	11	43	79
27	33	7	4
255	69	77	63

x_0 x_1
 x_1 x_0

Şekil 3.11. Kaydırma adımı

Şekil 3.11.'de Kaydırma Adımına bir örnek görülmektedir.

3.8. Evrişim Katmanı

Evrişim katmanı bir CNN yapısının çekirdeğini oluşturur ve örnekten önemli özelliklerin çıkarılmasını sağlar. Evrişim katmanındaki amaç bir nesneyi tanımlayan karakterize özellikleri çıkarmaktır. Bu özellikleri çıkarmak için çeşitli filtre matrisleri mevcuttur. Bunlar bir resimdeki belirgin kısımları açığa çıkartmak için örnek matris üzerine uygulanırlar. Filtre matrisine aynı zamanda çekirdek matris’de denilmektedir. Evrişim işlemi için bir örnek matrisi ve bir filtre matrisine ihtiyaç vardır. Filtre matrisi örnek matris üzerinde birebir eleman çarpımı yapıp çıkan sonucu toplar ve bir değer elde eder daha sonra adımlama ve piksel ekleme yöntemine göre filtre matrisi kaydırılır ve elde edilen sonuçlar yeniden boyutlandırılır. Böylece evrişim işleminden geçirilmiş bir matris elde etmiş oluruz. Daha sonra diğer bütün filtreler’de örnek resme uygulanır ve sonuçlar elde edilir.

0	13	13
7	7	7
9	11	11

0	1
1	0

Şekil 3.12. Giriş matrisi ve bir filtre matrisi

0	13	13
7	7	7
9	11	11


20	

Şekil 3.13. Giriş matrisi ve filtre matrisinin çarpılması

Şekil 3.13.'de Giriş matrisi ve giriş matrisine ait olan filtre matrisi ile işleminden elde edilen sonuç görülmektedir. Bu işlem bütün örnekler boyunca başta belirlenen kurallara göre yapılır.

3.9. Maksimum Havuzlama

Maksimum havuzlama yöntemi evrişim işlemi sonucu çıkarılan çok yüksek boyutlu matrislerin boyutlarını anlamlı şekilde düşürmek için kullanılır ve böylece yapay sinir ağının girişine anlamlı ve az bilgi gider. Böylece yapay sinir ağı hem daha hızlı hem de daha doğru çalışır. Maksimum havuzlama yönteminde belirlenen çerçevedeki en yüksek değer alınır. Böylece yüksek boyut görece azaltılmış olur.




Şekil 3.14. Maksimum havuzlama yöntemi

Şekil 3.14.'de Maksimum havuzlama yöntemine ait bir örnek görülmektedir. Bu yöntemlerin yanında geleneksel hale gelmiş toplam havuzlama ve ortalama havuzlama yöntemleri bulunmaktadır. Bu yöntemlerden toplam havuzlama yöntemi seçilen penceredeki değerlerin toplamını alırken ortalama havuzlama yönteminde ise seçilen pencerenin ortalaması alınmaktadır.

3.10. Ortalama Havuzlama

Ortalama havuzlama yöntemi ilk defa el yazısı rakam tanımada kullanılmıştır (Lecun vd. 1989). Bu yöntemde giriş matrisi olarak verilen değerler toplanır ve toplanan bu değerler eleman sayısına bölünür.



Şekil 3.15. Ortalama havuzlama yöntemi

Şekil 3.15.'de Ortalama havuzlama yöntemine ait bir örnek görülmektedir.

3.11. Log Enerji Entropi

Log enerji entropi yönteminde seçilen pencere üzerinde ilk önce belirlenen özelliklerde bir pencere alınır daha sonra her bir elemanın karesi alınır. Karesi alınan değerlere logaritma işlemi yapılır. Logaritma işlemi yapılırken ilk olarak 0 değerlerinin 0 olarak kalacağı ve $(\log(0)=0)$ kabullenmesi yapılacaktır. Bu işlemi yapabilmek için \log_{1p} fonksiyonu kullanılacaktır. \log_{1p} fonksiyonunun kullanılmasındaki temel neden 0 değerlerine log alma işlemi yaptığımızda hata alacağımız için bunun yerine 1 fazlasının log değerini alırsak başlangıçtaki kabulümüze'de uyumuş olacak ve $\log(0) = 0$ olacaktır.

$$Q = \sum_{1}^n \log_{1p_e} s^2 \quad (3.11)$$

Burada:

s : Seçilen çerçevedeki elemanları ifade etmektedir.

n : Çerçeve sayısını ifade etmektedir.

pencere	örnek	kare	logaritma	toplam
0 3	0 3	0 9	0. 2,30E+07	9.171.599
5 6	5 6	25 36	3,26E+07 3,61E+06	
10 11 13 15				
20 21 22 23				
89 25 53 72				

Şekil 3.16. Log enerji entropi yöntemi

Şekil 3.16.'da belirlenen pencerenin karesi alınır daha sonra logaritması ve son olarak da logaritması alınan değerler toplanır.

3.12. Shannon Entropi

Shannon entropi yönteminde öncelikle her bir elemanın karesi alınır daha sonra karesi alınan elemanların logaritması alınır ve logaritması alınan değerler ile karesi alınan değerler çarpılır ve daha sonra bu değerler toplanır.

$$Q = \sum_1^n ((s^2) \cdot (\log_{10} s^2)) \quad (3.12)$$

Burada;

s : Seçilen çerçevedeki elemanları ifade etmektedir.

n: Çerçeve sayısını ifade etmektedir.

3.13. Enerji

Enerji yönteminde her bir elemanın karesi alınır. Daha sonra bu elemanlar toplanır. Her bir elemanın s ile ifade edildiğini varsayarsak formül aşağıdaki gibi olacaktır.

$$Q = \sum_1^n s^2 \quad (3.13)$$

Burada;

s: Seçilen çerçevedeki elemanları ifade etmektedir.

n: Çerçeve sayısını ifade etmektedir


4. BULGULAR

Önerilen havuzlama metotları öğrenme gerçekleşene kadar veri setleri üzerinde 5, 30, 50, 200 devir olmak üzere test edilmiştir. Test işlemi MNIST, CIFAR-10, CIFAR-100 veri setlerinde test denemeleri yapılmıştır.

Çizelge 4.1. MNIST veri seti 50 devirde test sonuçları

Veri Seti	Devir	Havuzlama Tipi	Geçen süre	T. DE.	T. DO.	SDK.	SDD.
Mnist	50	enerji	1910,24	0,02128	0,9963	0,0212	0,9963
Mnist	50	log enerji entropi	2559,53	0,02164	0,9962	0,0216	0,9962
Mnist	50	Shannon entropi	2559,53	0,02164	0,9962	0,0216	0,9962
Mnist	50	Ortalama	443,69	0,02068	0,9959	0,0195	0,9959
Mnist	50	Maksimum	429,81	0,02122	0,9951	0,0212	0,9951


Çizelge 4.1'den görüldüğü gibi enerji yöntemi en yüksek test doğruluğuna sahiptir ondan sonra log enerji entropi yöntemi gelmektedir. Entropi havuzlama yöntemleri bu veri seti üzerinde en yüksek doğruluğa sahiptir. MNIST veri seti için 50 devir'de en iyi doğruluğa enerji yöntemi ulaşmıştır. Aşağıdaki şekillerde eğitim ve doğrulama eğrileri görülmektedir.



Şekil 4.1. a) M. H. doğruluk eğrisi

b) M. H. kayıp eğrisi


Şekil 4.1’de MNIST veri setinde kullanılan maksimum havuzlama yöntemine ait doğruluk eğrisi ve kayıp eğrisi görülmektedir. MNIST veri setinde öğrenme hızı yüksek olmuştur.



Şekil 4.2. a) O. H. doğruluk eğrisi


b) O. H. kayıp eğrisi

Şekil 4.2’de MNIST veri setinde kullanılan ortalama havuzlama yöntemine ait doğruluk eğrisi ve kayıp eğrisi görülmektedir. Maksimum havuzlama yönteminden farklı olarak ara ara görülen pikler öğrenmenin kararlılığını etkilemiştir.



Şekil 4.3. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi


Şekil 4.3’de MNIST veri setinde kullanılan log enerji entropi havuzlama yöntemine ait doğruluk eğrisi ve kayıp eğrisi görülmektedir. Geleneksel yöntemlerden farklı olarak ilk devirlerde daha az kararlılık gösterirken ilerleyen devirlerde daha kararlı hale gelmiştir.



Şekil 4.4. a) Enerji doğruluk eğrisi

b) Enerji kayıp eğrisi

Şekil 4.4'de MNIST veri setinde kullanılan enerji yöntemine ait doğruluk eğrisi ve kayıp eğrisi görülmektedir. Geleneksel yöntemlerden farklı olarak ilk devirlerde daha az kararlılık gösterirken ilerleyen devirlerde daha kararlı hale gelmiştir. Log enerji entropi havuzlama yöntemiyle benzer hareketler sergilemiştir.



Şekil 4.5. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H. kayıp eğrisi


Şekil 4.5’de MNIST veri setinde kullanılan Shannon entropi havuzlama yöntemine ait doğruluk eğrisi ve kayıp eğrisi görülmektedir. Geleneksel yöntemlerden farklı olarak ilk devirlerde daha az kararlılık gösterirken ilerleyen devirlerde daha kararlı hale gelmiştir. Log enerji entropi havuzlama yöntemiyle benzer hareketler sergilemiştir.

CIFAR-10 veri seti 70 devir’de havuzlama kısmında (2,2)’lik adımlama kullanılmış ve elde edilen sonuçlarda log enerji entropi havuzlama yöntemi en iyi sonucu vermiştir.

Çizelge 4.2 CIFAR-10 veri seti 70 devirde test sonuçları

Veri Seti	Devir	Havuzlama Tipi	Geçen süre	T. DE.	T. DO.	SDK.	SDD.
cifar10	70	Log enerji entropi	1226,64	0,8662	0,6949	0,8663	0,6950
cifar10	70	Enerji	2216,92	1,1957	0,6899	0,0881	0,9716
cifar10	70	Maksimum	503,97	1,1663	0,5935	1,2877	0,5523
cifar10	70	Ortalama	441,93	1,1720	0,5792	1,2738	0,5520
cifar10	70	Shannon entropi	1240,08	2,8200	0,2860	1,0513	0,6350

Çizelge 4.2’de CIFAR-10 veri setinin 70 devir sonucunda elde ettiği sonuçlar görülmektedir. CIFAR-10 veri setinde 70 devir sonucunda en yüksek test doğruluğuna log enerji entropi havuzlama yöntemi ulaşmıştır.

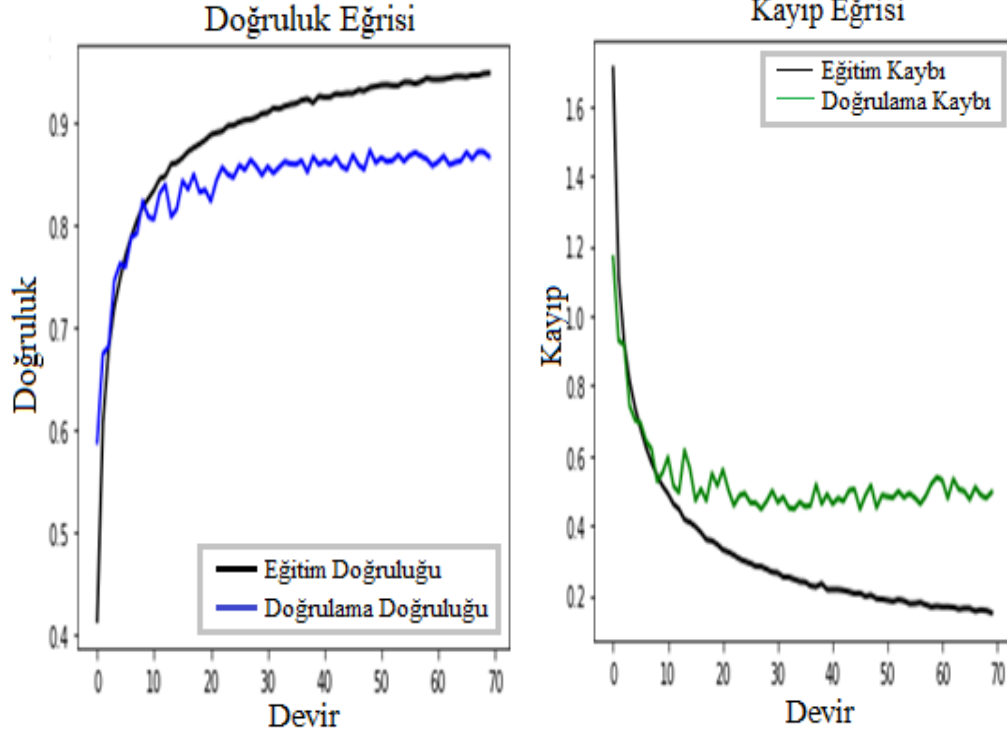


Şekil 4.6. a) M. H. doğruluk eğrisi

b) M. H. kayıp eğrisi

Şekil 4.6’da CIFAR-10 veri setinde 70 devir sonunda maksimum havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-10 veri


setinde MNIST veri setine göre kısmen daha yavaş bir öğrenme gerçekleşmiştir.



Şekil 4.7. a) O. H. doğruluk eğrisi

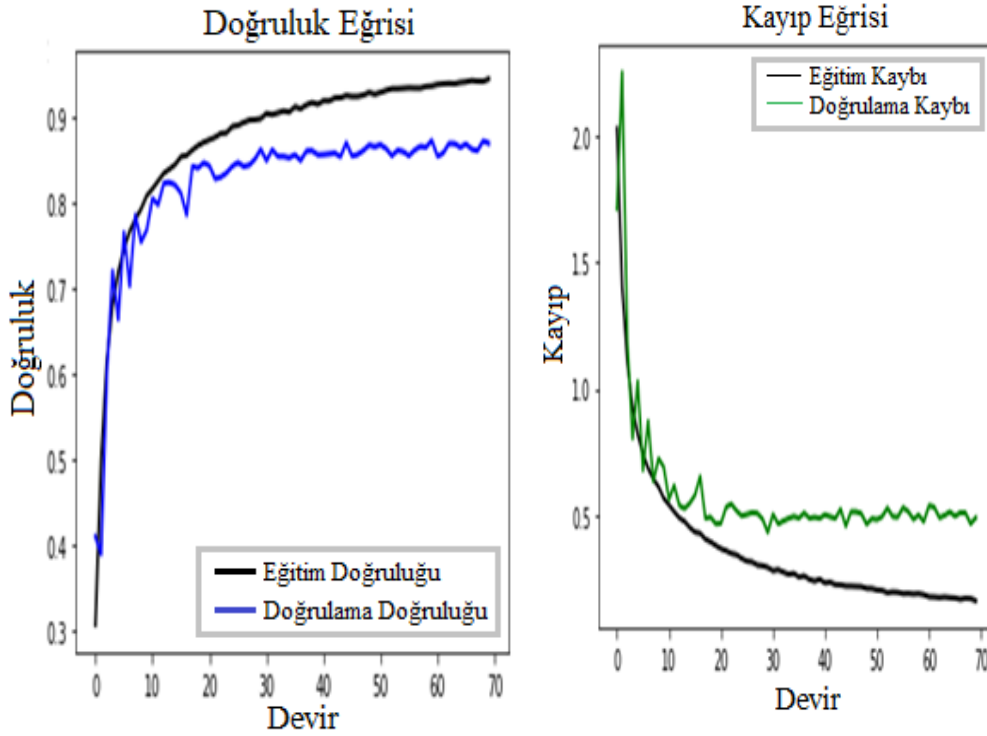
b) O. H. kayıp eğrisi

Şekil 4.7’de CIFAR-10 veri setinde 70 devir sonunda ortalama havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-10 veri setinde ortalama havuzlama yöntemi ile maksimum havuzlama yöntemi benzer özellik göstermiştir.



Şekil 4.8. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi


Şekil 4.8’de CIFAR-10 veri setinde 70 devir sonunda log enerji entropi havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir.



Şekil 4.9. a) Enerji doğruluk eğrisi

b) Enerji kayıp eğrisi

Şekil 4.9’da CIFAR-10 veri setinde 70 devir sonunda enerji yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir.




Şekil 4.10. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H. kayıp eğrisi

Şekil 4.10’da CIFAR-10 veri setinde 70 devir sonunda shannon entropi yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-100 veri seti 200 devir’de eğitilmiş ve bu kısımda da log enerji entropi yöntemi başarısını ortaya koymuştur.

Çizelge 4.3. CIFAR-100 veri seti 200 devirde test sonuçları

Veri Seti	Devir	Havuzlama Tipi	Geçen süre	T. DE.	T. DO.	SDK.	SDD.
cifar100	200	Log enerji entropi	10457,22	1,5284	0,6302	1,5285	0,6303
cifar100	200	Maksimum	2500,48	1,5480	0,6268	1,5480	0,6268
cifar100	200	Ortalama	2484,30	1,5189	0,6220	1,5189	0,6221
cifar100	200	Shannon entropi	12059,46	1,5535	0,6194	1,5535	0,6194
cifar100	200	Enerji	9560,71	1,5704	0,6183	1,5704	0,6184

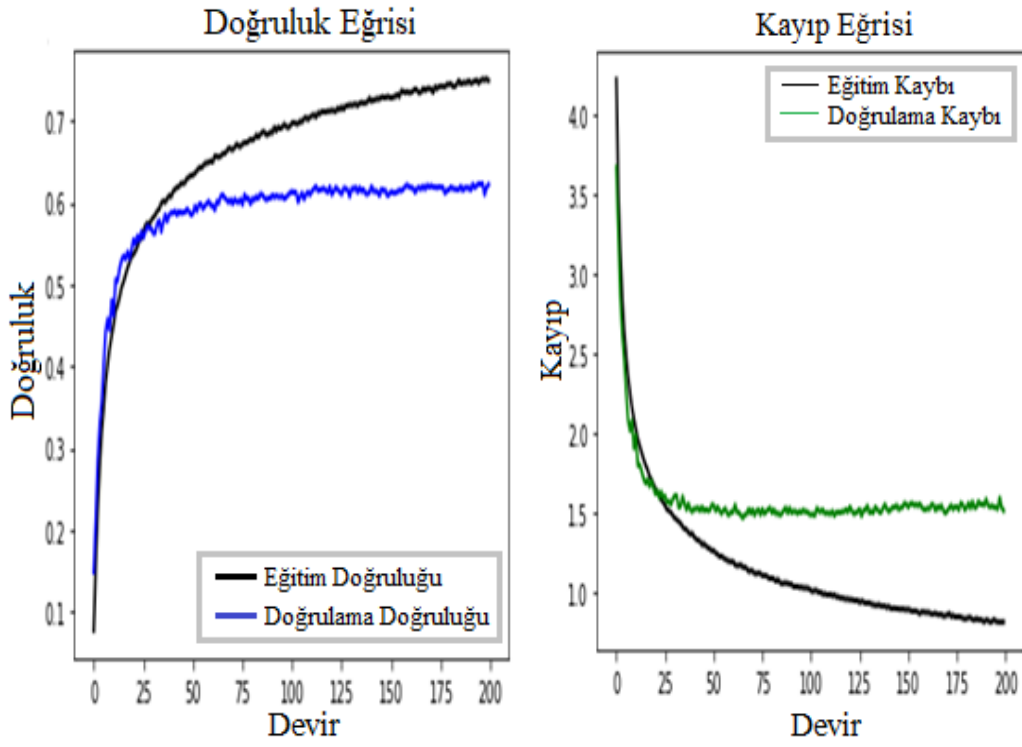
Çizelge 4.3’de CIFAR-100 veri setinin 200 devir sonucunda oluşan değerlendirme tablosu görülmektedir. CIFAR-100 veri setinde log enerji entropi havuzlama yöntemi geleneksel yöntemleri geçmeyi başarmıştır.



Şekil 4.11. a) M. H. doğruluk eğrisi

b) M. H. kayıp eğrisi

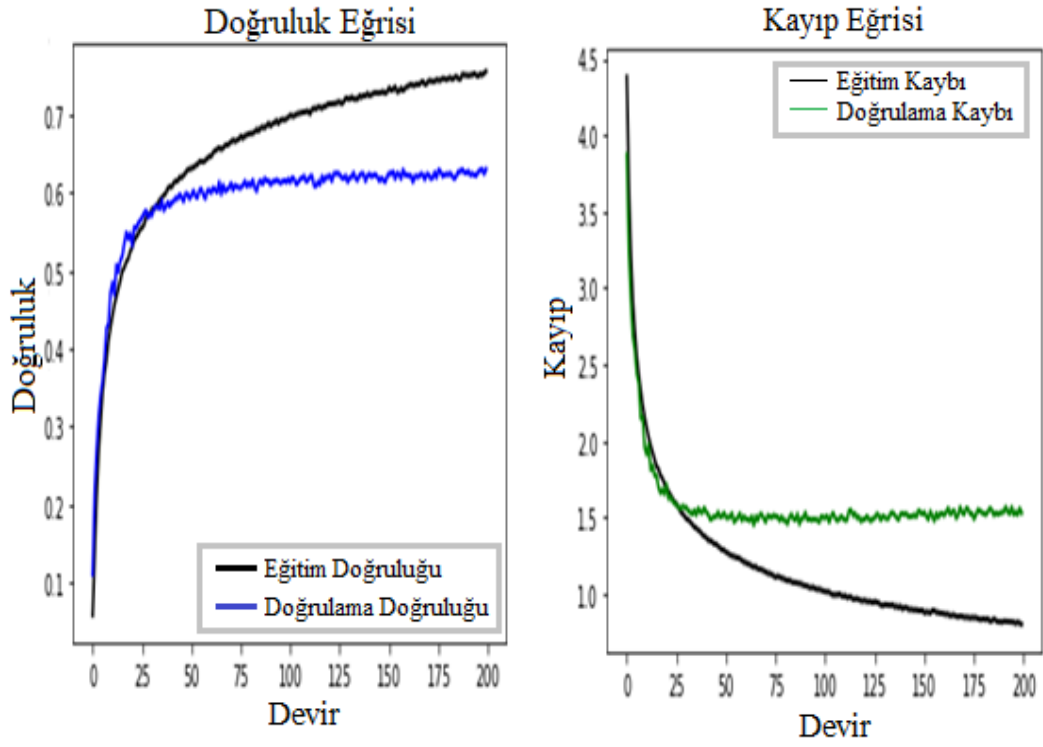
Şekil 4.11’de CIFAR-100 veri setinde 200 devir sonunda maksimum havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-100 veri setinde öğrenmenin başlangıçta üstel olduğu daha sonra yavaşladığı ve 50 devir’den sonra yataya ulaştığı görülmektedir.



Şekil 4.12. a) O. H. doğruluk eğrisi

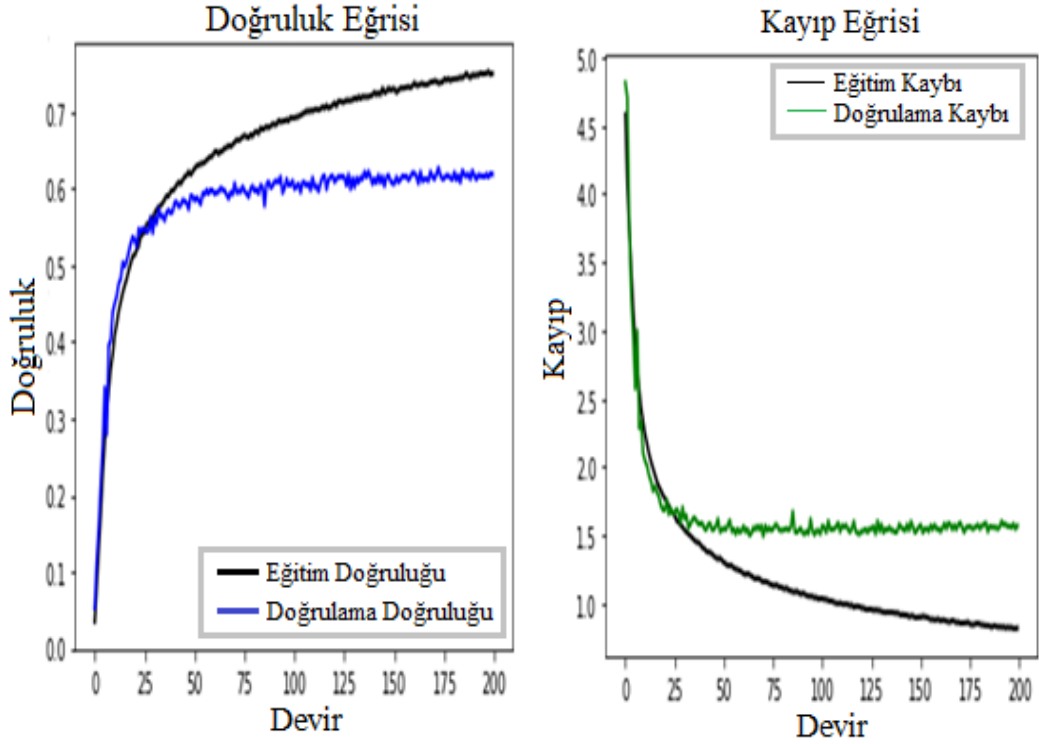
b) O. H. kayıp eğrisi

Şekil 4.12’de CIFAR-100 veri setinde 200 devir sonunda ortalama havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-100 veri setinde maksimum havuzlama ve ortalama havuzlama yöntemlerinin benzer özellik gösterdiği görülmektedir.




Şekil 4.13. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi

Şekil 4.13’de CIFAR-100 veri setinde 200 devir sonunda log enerji entropi havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir.



Şekil 4.14. a) Enerji doğruluk eğrisi b) Enerji kayıp eğrisi

Şekil 4.14’de CIFAR-100 veri setinde 200 devir sonunda enerji yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir.




Şekil 4.15. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H. kayıp eğrisi

Şekil 4.15’de CIFAR-100 veri setinde 200 devir sonunda shannon entropi yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. CIFAR-100 veri seti için’de aynı model kullanılmış ve devir değeri 150’ye çıkarılmıştır. Bu veri setinde de log enerji entropi yöntemi geleneksel yöntemleri geçmeyi başarmıştır.

Çizelge 4.4. CIFAR-100 veri seti (4,4) adımlama ile 150 devirde test sonuçları

Veri Seti	Devir	Havuzlama Tipi	Geçen süre	T. DE.	T. DO.	SDK.	SDD.
cifar100	150	Log enerji entropi	2668,95	1,9110	0,4867	1,9111	0,4867
cifar100	150	Ortalama	1402,67	1,9608	0,4681	1,9608	0,4682
cifar100	150	Shannon entropi	2862,43	2,0495	0,4530	2,0495	0,4531
cifar100	150	Enerji	2798,47	2,0525	0,4521	2,0525	0,4521
cifar100	150	Maksimum	1289,54	2,0400	0,4512	2,0403	0,4512


Çizelge 4.4’de CIFAR-100 veri seti 150 devirlik bir denemeye tabi tutulmuş ve bu testin sonucuda log enerji entropi havuzlama yöntemi daha yüksek başarı oranına sahip olmuştur.



Şekil 4.16. a) M. H. doğruluk eğrisi

b) M. H. kayıp eğrisi


Şekil 4.16’da CIFAR-100 veri setinde 150 devir sonunda maksimum havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. Maksimum havuzlama yönteminde adımlama değeri değişince grafik daha az kararlı hale gelmiştir.



Şekil 4.17. a) O. H. doğruluk eğrisi

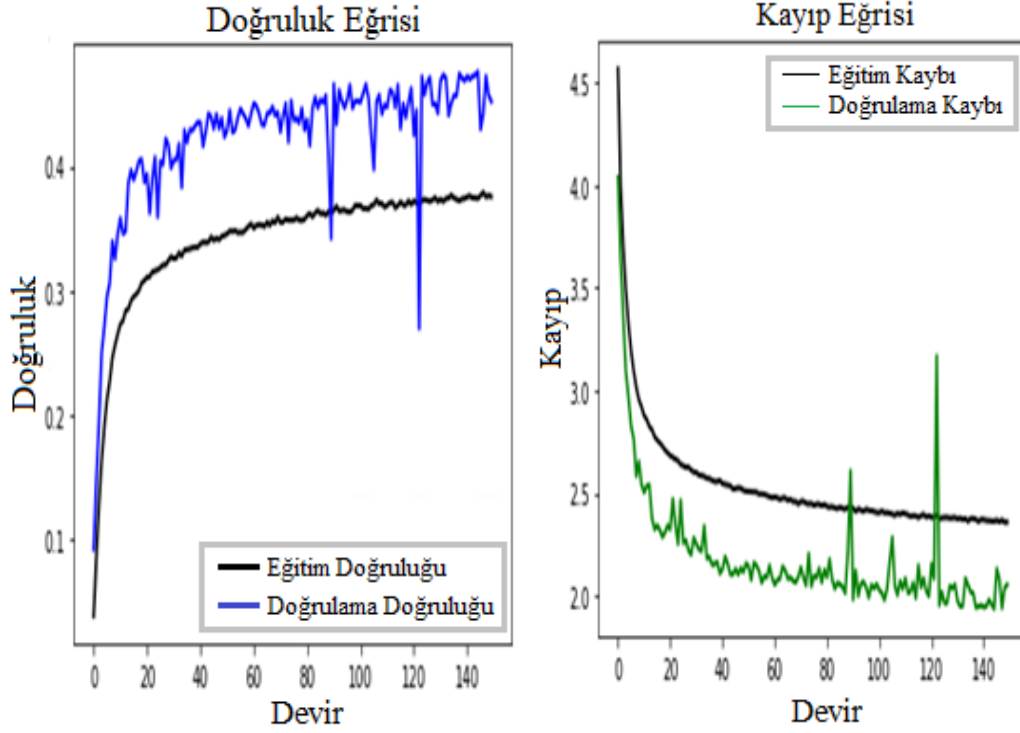
b) O. H. kayıp eğrisi

Şekil 4.17’de CIFAR-100 veri setinde 150 devir sonunda ortalama havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. Ortalama havuzlama yönteminde adımlama değişince grafiğin kararlılığı azalmıştır.



Şekil 4.18. a) Log enerji E. H. Doğruluk eğrisi b) Log enerji E. H. Kayıp eğrisi


Şekil 4.18’de CIFAR-100 veri setinde 150 devir sonunda log enerji entropi havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. Log enerji entropi havuzlama yönteminde geleneksel yöntemlere göre daha kararlı bir grafik oluşmuştur.



Şekil 4.19. a) Enerji doğruluk eğrisi

b) Enerji kayıp eğrisi

Şekil 4.19’da CIFAR-100 veri setinde 150 devir sonunda enerji yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. Enerji yönteminde bazı noktalarda derin doğrulama doğruluğu kayıpları oluşmuştur.



Şekil 4.20. a) Shannon E. H. doğruluk eğrisi b) Shannon E. H. kayıp eğrisi

Şekil 4.20’de CIFAR-100 veri setinde 150 devir sonunda Shannon entropi havuzlama yöntemi ile elde edilen doğruluk eğrisi ve kayıp eğrisi görülmektedir. Shannon entropi yöntemi görece daha az bir kararlılık sergilemiştir.

5. TARTIŞMA

5.1. Havuzlama Seçimi

Çalışmada ilk olarak belirlenen havuzlama yöntemlerinin denenebilmesi için mevcut keras kütüphanesi üzerinde alt sınıf kullanılarak üst sınıf kısmındaki havuzlama katmanı değiştirilmiştir. Bu da hem lambda katmanı hem de sınıf kullanılarak yapılabilir. Her havuzlama yönteminin farklı veri setleri üzerinde başarıları farklı olabilmektedir.


Denenmiş olan havuzlama yöntemleri aşağıdadır.

- Log enerji entropi
- Norm entropi
- Shannon entropi
- Enerji

Bizim yapacağımız bu çalışmada bilgi teorisine dayanan ve sinyal ve görüntülerden anlamlı bilgi çıkarmada başarılı sonuçlar veren entropi kavramına dayanan yöntemler denenmiştir.

5.2. Model Seçimi

Tasarlanan modeli eğitmek için öncelikle python dili ile gerekli modüller eklenir ve kod bloğu yazılır. Seçilen mimaride batch normalization ve dropout'lar kullanılmıştır. Son kısımda istenilen özellikler çıkarıldıktan sonra yapay sinir ağının girişine düzleştirilerek gönderilir.



Şekil 5.1. Çalışmada kullanılan CNN modeli

Şekil 5.1.'de çalışma'da kullanılan CNN modelinin görselleştirilmiş hali görülmektedir.

Layer (type)	Output Shape
conv2d (Conv2D)	(None, 32, 32, 32)
batch_normalization (Batch Normalization)	(None, 32, 32, 32)
conv2d_1 (Conv2D)	(None, 32, 32, 32)
batch_normalization_1 (Batch Normalization)	(None, 32, 32, 32)
max_pooling2d (MaxPooling2D)	(None, 16, 16, 32)
batch_normalization_2 (Batch Normalization)	(None, 16, 16, 32)
dropout (Dropout)	(None, 16, 16, 32)
conv2d_2 (Conv2D)	(None, 16, 16, 64)
batch_normalization_3 (Batch Normalization)	(None, 16, 16, 64)

Şekil 5.2. Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 1

Şekil 5.2.'de Çalışmanın ilk kısmında kullanılmış modelin keras özeti görülmektedir.

Param #	conv2d_3 (Conv2D)	(None, 16, 16, 64)
2432	batch_normalization_4 (Batch Normalization)	(None, 16, 16, 64)
128	max_pooling2d_1 (MaxPooling2D)	(None, 8, 8, 64)
25632	batch_normalization_5 (Batch Normalization)	(None, 8, 8, 64)
128	dropout_1 (Dropout)	(None, 8, 8, 64)
0	conv2d_4 (Conv2D)	(None, 8, 8, 128)
128	batch_normalization_6 (Batch Normalization)	(None, 8, 8, 128)
0	conv2d_5 (Conv2D)	(None, 8, 8, 128)
51264	batch_normalization_7 (Batch Normalization)	(None, 8, 8, 128)
256		

Şekil 5.3. Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 2

Şekil 5.3.'de Çalışmanın ilk kısmında kullanılmış modelin keras özetinin devamı görülmektedir.

```


102464 batch_normalization_7 (Batch Normalization) (None, 8, 8, 128) 512
256 max_pooling2d_2 (MaxPooling2D) (None, 4, 4, 128) 0
0 batch_normalization_8 (Batch Normalization) (None, 4, 4, 128) 512
256 dropout_2 (Dropout) (None, 4, 4, 128) 0
0 flatten (Flatten) (None, 2048) 0
204928 dense (Dense) (None, 128) 262272
512 batch_normalization_9 (Batch Normalization) (None, 128) 512
409728 dropout_3 (Dropout) (None, 128) 0
512 dense_1 (Dense) (None, 100) 129000

```

Şekil 5.4 Çalışmanın ilk kısmında kullanılan CNN modeli keras çıktısı 3

Şekil 5.4.'de Çalışmanın ilk kısmında kullanılmış modelin keras özetinin devamı görülmektedir.

İkinci test aşamasında CIFAR-10 için farklı bir model CIFAR-100 için ayrı bir model kullanılmıştır. İlk model ile ikinci model arasında ki fark adımlama değerinin ilk modele göre artırılması olmuştur.



Şekil 5.5. Çalışmanın ikinci kısmında kullanılan CNN modeli

řekil 5.5.'de alıřmanın ikinci kısmında kullanılmıř modelin grselleřtirilmiř hali grlmektedir.

6. SONUÇLAR

Çalışma kapsamında yapılan karşılaştırma işlemlerinde entropi havuzlama yöntemleri MNIST, CIFAR-10, CIFAR-100 veri setleri üzerinde geleneksel yöntemlere göre daha iyi sonuç verdiği bulgular yardımıyla gösterilmiştir. Karşılaştırma işlemine başlamadan önce her veri seti için öğrenmenin kaç devir’de tamamlandığını anlamak için devir sayıları kademeli olarak arttırılmış ve en optimum devir sayısı bulunmaya çalışılmıştır. Karşılaştırmanın birinci kısmında keras modülü kullanılmış ve MNIST veri seti ile yapılan çalışmalarda 50 devir’de önerilen yöntemler daha iyi sonuç vermiştir. CIFAR-10 veri seti ile yapılan çalışmalarda 70 devir’de önerilen yöntem daha iyi sonuç vermiştir. CIFAR-100 veri seti ile yapılan çalışmada’da 200 devir’de önerilen yöntem daha iyi sonuç vermiştir. Yapılan testlerde kullanılan havuzlama adımı (2,2) tipindedir. Karşılaştırmanın ikinci kısmında önerilen havuzlama yönteminin gerçekten anlamlı verileri ayrıştırıp ayrıştıramadığını anlamak için havuzlama kısmında adımlama büyüklüğü 4,4 ve havuz büyüklüğü 2,2 olarak değiştirilip yeni model üzerinde denemeler yapılmıştır. Denemeler sırasında adımlama değerinin düşük olduğu durumlarda grafik daha kararlı olurken adımlama değerinin yüksek olduğu durumlarda daha az kararlı hale gelmiştir. Entropi kavramına dayanılarak önerilen yöntemler çok daha iyi sonuç vermiştir. Kaynak taramasında özellikle entropi kavramına dayanan bir havuzlama yönteminin olmaması yapılan çalışmanın önemini göstermektedir ayrıca çalışmanın geleneksel yöntemlere göre, geleneksel veri setleri üzerinde daha iyi sonuç vermesi’de çalışmanın başarısını göstermektedir.

7. KAYNAKLAR

- Bera, S., & Shrivastava, V. K. 2020. Effect of pooling strategy on convolutional neural network for classification of hyperspectral remote sensing images. *IET Image Processing*, 407-584.
- Bhattacharjee, K., Pant, M., Zhang, Y., & Satapathy, S. 2020. Multiple Instance Learning with Genetic Pooling for medical data analysis. *Pattern Recognition Letters*, 247-255.
- Deng, L. 2014. A tutorial survey of architectures, algorithms, and applications for deep learning. *APSIPA Transactions on Signal and Information Processing*.
- Dong, L., He, L., Kong, g., Zhang, Q., Cao, X., & Izquierdo, E. 2018. A Compact Unsupervised Network For Image Classification. *JOURNAL OF IEEE TRANSACTIONS ON MULTIMEDIA*, 2012 - 2021.
- Gao, Y., Beijbom, O., Zhang, N., & Darrell, T. 2016. Compact Bilinear Pooling. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, ss. 317-326.
- Gholamalinezhad, H., & Khosravi, H. 2020. Pooling Methods in Deep Neural Networks, a Review.
- Girshick, R. 2015. Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, ss. 1440-1448.
- Gong, Y., Wang, L., Guo, R., & Lazebnik, S. 2014. Multi-Scale Orderless Pooling of Deep Convolutional Activation Features. *European Conference on Computer Vision*, ss. 392-407.
- Göksu, H. 2018. BCI oriented EEG analysis using log energy entropy of wavelet packets. *Biomedical Signal Processing and Control*, 101-109.
- Göksu, H. 2018. Ground moving target recognition using log energy entropy of wavelet packets. *Electronics Letters*, 233-235.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. 2016. Deep learning for visual understanding: A review. *Neurocomputing*, 27-48.
- He, K., Zhang, X., Ren, S., & Sun, J. 2015. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition. *European Conference on Computer Vision*.
- Holland, J. H. 1992. Genetic Algorithms. *SCIENTIFIC AMERICAN*.

- Husain, S. S., & Bober, M. 2019. REMAP: Multi-layer entropy-guided pooling of dense CNN features for image retrieval. *IEEE Transactions on Image Processing*.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 84-90.
- Lazebnik, S., Schmid, C., & Ponce, J. 2006. Beyond Bags of Features: Spatial Pyramid Matching for Recognizing Natural Scene Categories. *Conference on Computer Vision and Pattern Recognition (CVPR)*. New York, NY, USA.
- Lecun, Y., Boser, B. E., Denker, J. S., Henderson, D., Howard, R., Hubbard, W., & Jackel, L. 1990. Handwritten Digit Recognition with a Back-Propagation Network. d. s. Touretzky içinde, *Advances in neural information processing systems 2* ss. 396-404. San FranciscoCA United States.
- Lecun, Y., Bottou, L., Bengio, Y., & Haffner, P. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 2278 - 2324.
- Lecun, Y., Kavukcuoglu, K., & Farabet, C. 2010. Convolutional networks and applications in vision. *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*. 30 May -02 June, Paris, France.
- Lee, C.-Y., Gallagher, P. W., & Tu, Z. 2017. Generalizing Pooling Functions in Convolutional Neural Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.
- Lee, H., Kim, G., Kim, H.-G., Oh, S.-H., & Lee, S.-Y. 2016. Deep CNNs along the Time Axis with Intermap Pooling for Robustness to Spectral Variations. *IEEE Signal Processing Letters*, 1310-1314.
- Liu, W., Zhang, M., Zhang, Y., Liao, Y., Huang, Q., Chang, S., . . . He, J. 2018. Real-Time Multilead Convolutional Neural. *IEEE Journal of Biomedical and Health Informatics*.
- Park, H., & Lee, K. M. 2017. Look Wider to Match Image Patches with Convolutional Neural Networks. *Signal Processing Letters, IEEE*.
- Ren, J. S., & Xu, L. 2015. On Vectorization of Deep Convolutional Neural Networks for Vision Tasks. *Proceedings of the AAAI Conference on Artificial Intelligence*. Austin, Texas, USA.
- Rippel, O., Snoek, J., & Adams, R. P. 2015. Spectral Representations for Convolutional Neural Networks. *Advances in Neural Information Processing Systems*. Curran Associates, Inc.

- Russakovsky, O., Lin, Y., Yu, K., & Fei-Fei, L. 2012. Object-Centric Spatial Pooling for Image Classification. European Conference on Computer Vision, ss. 1-15.
- Saeedan, F., Weber, N., Goesele, M., & Roth, S. 2018. Detail-Preserving Pooling in Deep Networks. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, ss. 9108-9116.
- Sermanet, P., Chintala, S., & LeCun, Y. 2013. Convolutional neural networks applied to house numbers digit classification. International Conference on Pattern Recognition. Tsukuba, Japan: Proceedings of the 21st International Conference on Pattern Recognition.
- Shi, B., Bai, S., Zhou, Z., & Bai, X. 2015. DeepPano: Deep Panoramic Representation for 3-D Shape Recognition. IEEE Signal Processing Letters, 2339 - 2343.
- Shi, Z., Ye, Y., & Wu, Y. 2016. Rank-based pooling for deep convolutional neural networks. Neural Networks, 21-31.
- Song, Y., Li, Q., & Sun, F. 2009. Shannon Entropy-Based Adaptive Fusion Particle Filter for Visual Tracking. Chinese Conference on Pattern Recognition. Nanjing, China.
- Xu, L., Yan, S., Chen, X., & Wang, P. 2019. Motion Recognition Algorithm Based on Deep Edge-aware Pyramid Pooling Network in Human-Computer Interaction. IEEE Access, 163806 - 163813.
- Yu, D., Wang, H., Chen, P., & Wei, Z. 2014. Mixed Pooling for Convolutional Neural. International Conference on Rough Sets and Knowledge Technology, ss. 364–375.
- Zeiler, M. D., & Fergus, R. 2013. Stochastic Pooling for Regularization of Deep Convolutional Neural Networks.

ÖZGEÇMİŞ

İlhan KOÇASLAN
kocaslanilhan1@gmail.com



ÖĞRENİM BİLGİLERİ

Yüksek Lisans 2020-Devam ediyor	Akdeniz Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği A.B.D, Antalya
Lisans 2013-2018	Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü, Elektrik-Elektronik Mühendisliği Bölümü, Isparta