

Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetininin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi

Mustafa Tüfekçi^{1*}, Doç. Dr. Fatih Karpat²

¹Maysan Mando, Türkiye

²Makine Mh., Bursa Uludağ Üniversitesi, Türkiye

*(mtufekci@maysanmando.com)

Özet – İnsan ve bilgisayar etkileşimi, interaktif teknolojilerin tasarımı, değerlendirilmesi ve uygulanması ile ilgilenen disiplinler arası bir çalışma alanıdır. Bankalar, hastaneler, okullar, internet siteleri gibi hayatın her alanında insan ve bilgisayar etkileşimi alanından bir uygulama görmek mümkündür. 2000li yıllarda ivme kazanan insan ve bilgisayar etkileşimi çalışmaları günümüzde de öncelikli alanlar arasında yer almaktadır. Derin öğrenme de insan ve bilgisayar etkileşimi alanının uygulamalarından biridir. Derin öğrenme, her ardışık katmanda, önceki katmanın çıktısının kendisine girdi olarak alınması prensibine dayanır. Derin öğrenmenin başlıca mimarileri Konvolüsyonel Sinir Ağları(CNN), Tekrarlayan Sinir Ağları(RNN), Uzun-Kısa vadeli Hafıza Ağları(LSTM), Sınırlı Boltzman Makineleri(RBM), Derin Oto-Kodlayıcıları(AE)'dir. Konvolüsyonel sinir ağları (CNN) çok katmanlı algılayıcıdır. Görüntü, ses, dil işleme ve biyomedikal alanlarında uygulama örnekleri bulunmakta olup bunlardan en iyi sonuçlar görüntü işleme alanında uygulanmıştır. Ayrıca Konvolüsyonel Sinir Ağları (CNN) anlamsal ayrıştırma, arama sorgusu, cümle modelleme, sınıflandırma, tahmin problemleri gibi alanlarda da başarılı sonuçlar vermiştir.

Bu çalışmada Konvolüsyonel Sinir Ağları (CNN) tabanlı görüntü işleme-sınıflandırma uygulamalarının iyileştirilmesine yönelik literatürde yapılan bazı çalışmalar incelenerek derlenmiştir. CNN tabanlı geliştirilen uygulamaların incelenen çalışmalarda yapılan deney sonuçlarına göre yüksek doğruluk oranları yakaladıkları gözlemlenmiştir.

Anahtar Kelimeler – Derin Öğrenme, Konvolüsyonel Sinir Ağları (CNN), Görüntü Sınıflandırma

A Review for Investigation Studies That are Done for Improving Image Processing-Classification Based on Convolutional Neural Network (CNN) That is Architectural of Deep Learning

Abstract – Human-Computer interaction (HCI) is a multidisciplinary study area that interested in interactive technology design, evaluation and application. Human-Computer interaction (HCI) is on all area of life such as banks, hospitals, schools and websites. Human-Computer interaction (HCI) that has acceleration after 2000's, is priority working topic nowadays. Deep learning is one of the applications of Human-Computer interaction (HCI). Output of the previous layer is input for the next layer in deep learning. The main architectures of deep learning are Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), Long-Short Term Memory (LSTM), Restricted Boltzmann Machine (RBM), Autoencoders (AE). Convolutional Neural Network (CNN) are detector that have many layers. Convolutional Neural Network (CNN) has so many applications related with image, sound, language processing and biomedical; however the best practice is on image processing for Convolutional Neural Network (CNN). In addition, Convolutional Neural Network (CNN) has successful applications on semantic decomposition, search results, sentence modelling, classification and prediction.

This study is a review study for investigation of some studies that are done for improving image classification based on Convolutional Neural Network (CNN). It seems that applications based on Convolutional Neural Network (CNN) has high successful ratio according to test results that are acquired from the investigated studies.

Keywords – Deep Learning, Convolution Neural Network (CNN), Image Classification

I. GİRİŞ

İnsan ve bilgisayar etkileşimi, insan ve bilgisayar arasındaki etkileşimi içeren teknolojilerin tasarlanması ve değerlendirilmesi konularını ele alan bir uygulama alanıdır. Günümüzde bankalardan hastanelere, toplu ulaşımdan alışveriş sitelerine kadar hayatın her alanında karşımıza

çıkılmaktadır. İnsan ve bilgisayar etkileşimi 1945 yılında Vannevar Bush'un "As We May Think" adlı makalesiyle ilk kez ortaya atılmıştır. Bu makalede Vannevar Bush "Memex" isimli hayali bir makineden bahsetmiştir. 1945 yılında yazılan bu makalede kullanıcı anahtar kelimeler yazarak bir sanal kütüphanede bilgi arayabilmekte ve bu bilgileri sanal disklere

kaydedebilmektedir. Bu fikirler günümüzde kullanılan internet ve bilgisayarların öncüsü olarak kabul edilmektedir. Makalede kullanıcı Memex'te Türk yayı ve okunun ne kadar iyi olduğunu araştırmakta, araştırma sonuçlarını kaydetmekte ve arkadaşına göndermektedir. Bu yönüyle makale tarihte Türklere yapılan ilk atıf olarak görülmektedir [1].

İnsan ve bilgisayar etkileşimi üzerinde birçok bilim insanının çalışması olmuştur. Bu bilim insanlarından önde gelen isimlere bakarsak Norman ve Schneideman, kullanıcı dostu olarak da isimlendirilebilecek bilgiyi işleme davranışı ve daha iyi arayüzlerin tasarımlarına yoğunlaşmışlardır. Suchman ve Licklider ise daha çok insan ve bilgisayar arasındaki iletişim üzerine çalışmışlardır. İnsan ve bilgisayar arasındaki etkileşimin insan ve insan arasındaki etkileşim gibi olması gerektiğini ve duygularında bu iletişime dahil olması gerektiğini savunmuşlardır. Bu gelecekteki insan ve bilgisayar etkileşimi alanının konusu olabilecek bir çalışma konusudur. Günümüzde arayüzleri iyileştirerek insan ve bilgisayar etkileşimini daha verimli hale getirmek ana amaçlardan biri olabilir.

Derin öğrenme, insan ve bilgisayar etkileşiminin çalışma alanlarından biri olan makine öğrenmesinin bir metodudur. Derin öğrenmede her ardışık katman, kendinden önceki katmanın çıktısını kendine girdi olarak alır. Derin öğrenme mimarileri aşağıdaki şekilde sınıflandırılabilir;

- Evrişimli Sinir Ağları (Convolutional Neural Network - CNN)
- Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN)
- Uzun-Kısa Vadeli Hafıza Ağları (Long-Short Term Memory - LSTM)
- Sınırlı Boltzmann Makineleri (Restricted Boltzmann Machine - RBM)
- Derin İnanç Ağları (Deep Belief Network - DBN)
- Derin Oto-Kodlayıcılar (Autoencoders - AE)

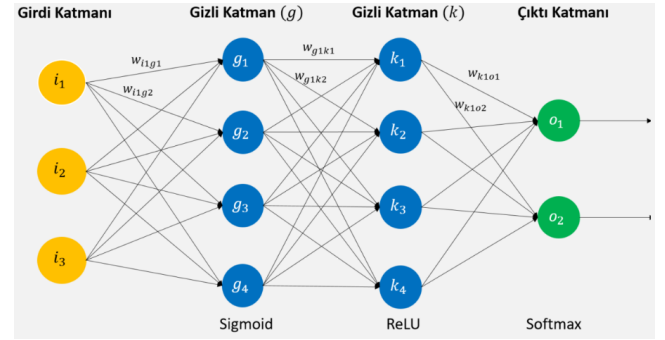
II. MATERYAL VE YÖNTEM

Yapay sinir ağları, her birinde özel hesaplamaların yapıldığı nöronlar ve bunların gruplaştığı katmanlardan oluşur. Katmanları; girdi katmanı, gizli katman ve çıktı katmanı olmak üzere 3 gruba ayırabiliriz. Girdi katmanı görüntü, ses veya metin olabilir. Sinir ağının gerçekleştireceği işlemler veri türüne göre değişebilir. Girdi verisi bir görüntü olduğu durumda, yapılan işlem renklerin ayırt edilmesi veya nesnelerin kenarlarının ayırt edilmesi olabilir. Bir sinir ağında katmanlar arasında her bir nöronu diğer katmandaki nörona bağlayan bağlantılar ve bu bağlantıların sayısal değerleri vardır. Bu değerlere ağırlık denir. Bu ağırlık değerleri eğitim sonucunda her bir nöronun çıktı değeri için ne kadar önemli olduğunu gösterir. Her bir nöronun hesaplanan çıkış değeri ağırlığı ile çarpılarak diğer katmandaki nöronun girdi değerini oluşturur. Girdi katmanından çıktı katmanına doğru ilerleyen bu hesaplama akışına ileri yayılım algoritması denir.

İleri yayılım algoritması sonucunda sinir ağının tahmin değerleri elde edilir. Bu tahmin değerlerinin bir hata oranı vardır. Bu hata oranını azaltmak için çeşitli algoritmalar vardır.

Bu çalışmada derin öğrenme mimarilerinden evrişimli sinir ağları (CNN) üzerinde görüntü sınıflandırma konusu

incelenmiştir. İleri yayılım algoritması sonucu elde edilen hata oranının minimize edilmesi için yapılan uygulamalardan bazıları incelenmiş ve derlenmiştir.



Şekil 1. Yapay Sinir Ağı Şematik Gösterimi [13]

A. Evrişimli Sinir Ağları (Convolutional Neural Network - CNN)

Evrişimli sinir ağları (Konvolüsyonel sinir ağları da denmektedir.) çok katmanlı algılayıcıların bir türüdür. Hayvanların görme merkezinden esinlenilmiştir. Görüntü ve ses işleme, doğal dil işleme ve biyomedikal gibi alanlarda kullanılmakla beraber en iyi sonuçları görüntü işleme alanında vermiştir. İleri yayılım algoritmalarındaki hata oranlarını minimize etmek için farklı algoritmalar vardır. Bu algoritmalarından bir tanesi geri yayılım algoritmasıdır. Geri yayılım algoritmasına göre, ileri yayılım algoritmasından elde edilen sonucun hata değeri çıktı katmanından girdi katmanına doğru çeşitli türev işlemlerine tabii tutularak geriye yayılma gösterir.

Yüksek doğruluk oranına sahip görüntü işleme uygulamalarından biri olarak Cireşan ve arkadaşlarının evrişimli sinir ağı (CNN) yaklaşımıyla yaptığı GPU uygulaması gösterilebilir. Olasılıksal gradyan iniş metodu ile eğitilen bu sinir ağı sonucunda elde edilen sonuçlara göre el yazısı tanıma için %0.35, nesne tanıma için %2.53 ve çözünürlüğü düşük doğal resimler için %19.51'lik bir doğruluk oranı yakalanmıştır. 2012'de yapılan bu çalışma için bu sonuçlar literatürdeki en iyi sonuçlar olarak belirtilmiştir. Görüntü tanıma için yeterli bir veritabanı ile eğitildiğinde CNN mimarilerinin en doğru sonuçları sağlayacağı çalışmada belirtilmiştir. GPU tabanlı yapılan bu uygulamada sonuçların doğruluk oranlarının yanında ayrıca yüksek öğrenme hızı büyük bir avantajdır. CPU tabanlı yapılan uygulamalara göre GPU tabanlı uygulamalar yaklaşık 10 ile 60 kat arasında daha hızlı bir öğrenme hızına sahiptir [2].

Başka bir uygulamada Sarıgül ve arkadaşları yine hata oranının minimize edilmesi için geri yayılım algoritması önermişlerdir. Geri yayılma algoritması aktivasyon hatalarını da dikkate alarak filtre sayısını değiştirmeden sınıflandırma performansını arttırmaktadır. Bu algoritmayı gözlemlemek için yapılan çalışmada 4 deney seti kurulmuştur. İlk deneyde doğruluk %55.29 oranında artmıştır. İkinci deney setinde, diferansiyel evrişimli ağ adaptasyonu, ImageNet veri setinde AlexNet'in ilk 1 ve ilk 5 test doğruluğunu %5.3 ve %4.75 arttırmıştır. Üçüncü deney seti tüm modelleri geride bırakmıştır. Diferansiyel CNN modeli, CIFAR-10 ve CIFAR-100 veri setleri için en yakın performans gösteren modelden %4.33 ve %7.72 daha yüksek sınıflandırma doğruluğu göstermiştir. Dördüncü deney setinde ise VGGney modeli CIFAR10 ve CIFAR100 için sırasıyla %93.58 ve %75.06'lık doğruluk oranlarına ulaşmıştır [3].

Meijera ve arkadaşları da yaptıkları uygulamada geri yayılım algoritmasını kullanmış ve sınıflandırıcılardan çıkan sonuçların yorumlanması konusunda çalışmışlardır. Önerilen sınıflandırıcı, tek başına sınıflandırma yapamasa da sonradan kontrol edilerek seçilecek olan görüntülerin sayısını azaltmış olacaktır. Tüm incelemelerin %90'ının tespit edilmesi yeterli olduğu göz önüne alındığında insan incelemesi gerektiren görüntülerin sayısının %60.5 oranında azaltılabileceği bu çalışmada görülmüştür. Evrişimli sinir ağının (CNN) eğitim metodu doğru tahminler alma açısından çok önemlidir. Bu çalışmada kullanılan evrişimli sinir ağının eğitilmesinde olasılıksal gradyan iniş metodu kullanılmıştır.

Gradyan iniş metodu veritabanının yapay sinir ağına öğretilmesini sağlayan bir algoritmadır. Makine öğrenmesi alanında popüler olan bu algoritma eğitim verisi üzerinde bir maliyet hesabı yapar ve bu maliyetin minimize edilmesini sağlar. Olasılıksal gradyan iniş metodunun literatürde birçok örneği vardır. Bunlardan bazıları bu çalışma kapsamında incelenmiş ve aşağıda derlenmiştir.

Traore ve arkadaşları 2018 yılında yaptıkları çalışmada mikroskobik görüntülerin tanımlanması için bir evrişimli sinir ağı (CNN) sunmuştur. Bu sayede kolera ve sıtma patojenlerinin tespit edilmesi için karar verme sürecine destek sağlanması ve bu sinir ağının mikroskoplara entegre edilerek akıllı mikroskoplara yardımcı olunması amaçlanmıştır. Evrişimli sinir ağı verisi eğitim veri setleri için olasılıksal gradyan iniş metodu kullanılmış ve 200 kolera patojeni, 200 sıtma patojeni olmak üzere toplamda 400 görüntü üzerinden eğitim yapılmıştır. 80 test görüntüsü ile yapılan çalışma sonunda %94 sınıflandırma doğruluğu sağlanmıştır. Evrişimli sinir ağı modeli veri setinin büyüklüğüne göre değişkenlik gösterebilmektedir. 14 milyon hiyerarşik görüntüden oluşan eğitilmiş bir CNN ile çalışmanın tekrarlanması amaçlanmaktadır. [4]

Elde çok fazla veri olduğunda görüntülerin hiyerarşik yapı çerçevesinde sınıflandırılması gerektiği durumlar olabilir. Veritabanında hiyerarşik görüntü sınıflandırma yaklaşımı temel sınıflandırma ile karşılaştırıldığında daha iyi sonuçlar verdiği gözlemlenmiştir. Seo ve Shin yaptıkları çalışmada hiyerarşik evrişimli sinir ağını görüntü sınıflandırma için önermişlerdir. Yaptıkları çalışmada ayrıca maksimum ortaklama (Max-pooling) yöntemini de kullanmışlardır. Maksimum ortaklama yöntemi elde edilen verinin belirli bir kısmını seçip, o kısımdaki en yüksek değeri alarak veriyi yeni bir şekilde göstermeye yarayan bir yöntemdir. Elde fazla bilgi olduğunda bilginin anlamını çok kaybetmeden boyutunu küçültmek için kullanılır. Moda resimlerinin (ayakkabı, elbise, çanta vs.) sınıflandırmasının yapıldığı bu uygulamada veritabanındaki görüntüleri önce 10 temel gruba, daha sonra 10 gruba da hiyerarşik yapı gereği 2 gruba ayırmışlardır. Sinir ağının eğitilmesi için olasılıksal gradyan iniş metodu kullanılmıştır. Hiyerarşik evrişimli sinir ağı (H-CNN) olarak adlandırılan bu sinir ağı tam bağlantılı katmanlardan oluşan VG-Gneti temel alır. 28x28 boyutlarında 50.000 eğitim görüntüsü ve 10.000 test görüntüsü bu sinir ağının eğitilmesi için kullanılmıştır. Hiyerarşik evrişimli sinir ağı modeli temel model ile karşılaştırılmış ve daha az kayıp, daha yüksek doğruluk oranlarında daha iyi performans göstermiştir. Eğitimin 52. döngüsünden sonra 0.9 momentum katsayısında öğrenme hızı 0.00005 olarak gerçekleşmiştir [5].

Olasılıksal gradyan iniş metodu ile kullanılan daha farklı yöntemler de bulunmaktadır. Bu yöntemlerden bir tanesi de

ince ayar (Fine tuning) yöntemidir. İnce ayar yöntemi önceden eğitilmiş bir modelin benzer ikincil bir görev için yeniden eğitilmesi işlemidir. Özellikle daha az görüntü içeren veritabanları ile eğitilen sinir ağlarında performansı etkilediği çalışmalarda gözlemlenmiştir.

İnce-ayar (fine-tuning) ağlarının duyarlılık tahmini için önceden eğitilmesi, nesne tanıma için önceden eğitilen ağlara göre daha iyi sonuçlar vermiştir. Cetinic ve arkadaşları yaptıkları çalışmada görsel görevlerde başarılı sonuçlar gösteren evrişimli sinir ağının sanatla ilgili görüntülerin sınıflandırılması için görüntü benzerliğinin farklı yönleri analiz edilerek uygulanabilirliğini incelemişlerdir. Sinir ağındaki bağlantıların ağırlığının ilk değer atamasının anlamsal sonuçları hakkında kesin sonuçlar çıkarmak için daha fazla araştırma yapılması gerektiği çalışma sonucunda ortaya konmuştur. Yapılan çalışmada evrişimli sinir ağı olasılıksal gradyan iniş metodu ile öğrenme hızı (Learning rate) 0.0005 değerinde eğitilmiştir. İnce ayar ağlardan türetilen özelliklerin stil veya içerikte benzer görüntüleri elde etmek için kullanılabilmesi ve farklı çevrimiçi sanat koleksiyonlarındaki arama sistemlerinin özelliklerinin geliştirmek için kullanılabilmesi çalışma sonunda belirtilmiştir [6].

Diğer bir optimizasyon metodu Adam optimizasyon algoritmasıdır. Özellikle sinir ağının eğitilmesi için tasarlanan ve adaptif öğrenme hızı, momentum katsayısına sahip bir algoritmadır. Adam optimizasyon (Adaptif momentum) algoritması öğrenme hızında çok yüksek bir performans göstermektedir. Bu yöntem ağı ağırlıklarını güncelleyerek daha iyi bir öğrenme sağlamaktadır.

Han ve arkadaşları yaptıkları çalışmada data sınıflandırma için görüntülerin sınıflandırması yerine grafikleri ortaya koyarak sınıflandırma yapılmasının mümkün olduğunu göstermiş ve önermişlerdir. Çalışmanın amacı, her örneği doğrudan öğrenme ve sınıflandırma için derin öğrenme yöntemine uygun formata dönüştürmektir. Çalışmada sinir ağı Adam optimizasyon ile 0.001 öğrenme hızında eğitilmiştir. Deneyler ve karşılaştırmalar, orijinal özellik alanından öğrenilen sınıflandırıcılarla karşılaştırıldığında net bir performans kazancı olduğunu doğrulamaktadır. Genel olarak sınıflandırma için genel veri setlerine uygulanacaktır. [7]

Park ve arkadaşları oluşturdukları yapay sinir ağının eğitilmesi için aşırı öğrenme makineleri kullanmışlardır (Extreme learning machine – ELM). Aşırı öğrenme makineleri evrişimli sinir ağları için farklı bir algoritmadır. Bu algoritma minimum insan müdahalesi ile bir rastgele öğrenme algoritmasına ve temel bir formülasyona dayanmaktadır. Park ve arkadaşları yaptıkları bu çalışmada önerdikleri yöntem ile ilgili diğer yöntemlerden daha yüksek doğruluk elde etmiş ve daha az eğitim süresi harcamışlardır. Eğitimlerde el yazısı tanıma veritabanı için 60.000 eğitim görüntüsü, 10.000 test görüntüsü, düşük çözünürlüklü nesne tanıma veri tabanı için 50.000 eğitim, 10.000 test görüntüsü kullanılmıştır. Önerilen metodun eğitim süresi temel eğitimlere göre 1.5-9 kat daha hızlı olduğu görülmüştür [8].

Bir diğer aşırı öğrenme makine örneği Santos ve arkadaşlarının yaptıkları çalışmada görülmektedir. Bu çalışmada aşırı öğrenme makinesine ve sabit bir filtre bankasına dayanan derin ve hızlı bir evrişimli sinir ağı (CNN) önerilmiştir. Modelin düşük maliyetli bilgisayarlarda kullanılabilmesi ve GPU tabanlı modellere göre daha hızlı gerçekleştiği çalışmada gösterilmiştir. Seçilen filtre bankaları,

önerilen iki aşamalı CELM (Convolutional Exterem learning Machine) mimarisini belirlemek için kullanılmıştır. Önerilen CELM sinir ağı için eğitim seti büyüklüğünü ve gizli nöron sayısını değiştirerek ampirik genelleme hatası elde edilmiştir [9].

Coletta ve arkadaşları da aktif öğrenme algoritmasını incelemiş ve bu konuda bir çalışma yapmışlardır. Yapılan çalışmada esnek bir görüntü sınıflandırıcı kullanılmıştır. Bu sınıflandırıcı yeni sınıfların tespitine yardımcı olmak için kümeleme algoritmaları tarafından sağlanan ek bilgileri kullanarak denetimli ve denetimsiz algoritmaları birleştirmektedir. Özellikle, iteratif Sınıflandırıcı (IC), sınıflandırma ve kümeleme algoritmalarını birleştirmek için bir optimizasyon algoritması, kullanılmaktadır. Her iterasyonda, bir entropi ve yoğunluğa dayalı seçim (EDS), belirsiz etiketleri olan ve yoğun bölgelerde bulunan etiketlenmemiş örnekleri araştırmakta ve seçmektedir. Bu örneklerin yeni kavramları/sınıfları temsil etmesi muhtemeldir ve bu nedenle, bir sonraki iterasyonda sınıflandırma modelini güncellemek için etiketlenmekte ve kullanılmaktadır. Deneysel sonuçlar, bu yöntemin etiketlenmemiş örnekleri kullanarak zaman içinde yeni sınıfları başarıyla keşfedebildiğini, hatta birçok farklı sınıf içeren hedef kümelerinde bile ortaya çıkardığını göstermektedir. Ek olarak, algoritma, etiketleme maliyetlerini azaltan temel örneklerin seçilmesine izin vermektedir. Bu çalışma zamanla ortaya çıkabilecek yeni örneklerin de farkına varabilecek bir çalışmadır. Bu iteratif seçimin önceden eğitilmiş evrişimli sinir ağındaki (CNN) ileri geçişlerden elde edilen özellikler üzerinde kullanılırken daha iyi performans verdiği gözlemlenmiştir [10].

Yuan ve arkadaşları da aktif öğrenme algoritması ile çalışmış ve manuel etiketleme prosesinin maliyetini bu çalışma kapsamında azaltmışlardır. Çalışmada kullanılan algoritma çoklu kriterler arasında adaptif ayar ile tahminin doğruluğunu artırma yeteneğine sahiptir. Doğrulama için MNIST ve CFAR10 veri setleri üzerinde deneyler yapılmıştır. Önerilen yaklaşım deneysel sonuçlara göre aktif öğrenme yaklaşımları arasında literatürde diğer yaklaşımlardan daha iyi sonuçlar vermiştir. Dengesizlik verileri üzerindeki etkinliğine rağmen, önerilen yaklaşım denge verileri üzerinde sınırlı etki yaratmaktadır. Yeterli performans için bazı hiper parametreyi manuel olarak ayarlamak gerekmektedir [11].

Matiz ve Barner yaptıkları çalışmada endüktif uygun tahminli evrişimli sinir ağı (CNN) uygulamasını önermişlerdir. Bu çalışmada aktif öğrenme konusundaki önceki çalışmalardan farklı olarak, önerilen sorgu işlevi, kullanılan veritabanının istatistiklerine uyum sağlayan benzerlik önlemleri almak için veri işleme dilini kullanılmaktadır. Veri işleme dili, temel bileşen analizi ile elde edilen azaltılmış bir alanda gerçekleştirilmekte ve böylece hesaplama yükünü azaltılmaktadır. ICP-CNN metodu CNN metoduna göre sınıflandırma performansı daha yüksektir. Garantili hata oranlarıyla sınıf etiketlerini tahmin etmek için ICP-CNN güvenilir veriler üretmektedir [11].

III. SONUÇLAR

Çalışmanın sonucunda derin öğrenme mimarilerinden evrişimli sinir ağlarındaki (CNN) öğrenme metodları incelenmiştir. İncelenen yöntemler olasılıksal gradyan inişi, adaptif momentum metodu, geri yayılım algoritması, aktif öğrenme, aşırı öğrenme makineleridir. Çalışmalardaki yüksek

doğruluk oranları evrişimli sinir ağlarının görüntü işlemedeki performansı bakımından en iyi sinir ağlarından biri olduğunu göstermektedir. Ayrıca evrişimli sinir ağlarının (CNN) öğrenimi için geri yayılım algoritmasını en yaygın kullanılan yöntemlerden biri olduğu çalışma sonucunda görülmüştür.

IV. GELECEK ÇALIŞMA

Gelecek çalışma için Maysan Mando ve Uludağ üniversitesinin işbirlik içinde olacağı bir proje yapılması hedeflenmektedir. Bu çalışmada grafik tanıma ve uygun bir veri seçme işlemi yapay sinir ağına yaptırılacaktır. Veritabanı çok geniş olduğundan maksimum ortaklama ve sinir ağının eğitimi için adaptif momentum algoritması bu projede uygulanabilir. Bu çalışma ileride yapılacak olan projeye bir ön çalışma niteliği taşımaktadır.

TEŞEKKÜR

Kongreye katılım konusunda desteklerini esirgemeyen Maysan Mando firmasına teşekkürü borç biliriz.

KAYNAKLAR

- [1] V. Bush, As We May Think, 1945.
- [2] D. C. Cirean, U. Meier, J. Masci, and L. M. Gambardella, Flexible, High Performance Convolutional Neural Networks for Image Classification, in Proceedings of the Twenty-Second international joint conference on Artificial Intelligence, pp. 1237–1242, 2012.
- [3] M. Sarıgül, B.M. Ozyildirim, M. Avci, Differential convolutional neural network., Neural Networks 116, 279–287, 2019.
- [4] B.B.Traorea, B. Kamsu-Foguea, F. Tangarab, Deep convolution neural network for image recognition, Ecological Informatics 48, 257–268, 2018.
- [5] Y. Seo, K. Shin, Hierarchical convolutional neural networks for fashion image classification, Expert Systems With Applications 116, 328–339, 2019.
- [6] E. Cetinic, T. Lipic, S. Grgic, Fine-tuning Convolutional Neural Networks for fine art classification, Expert Systems With Applications 114, 107–118, 2018.
- [7] H. Han, Y. Li, X. Zhu, Convolutional neural network learning for generic data classification, Information Sciences 477 (2019) 448–465.
- [8] Y. Park, H. S. Yang, Convolutional neural network based on an extreme learning machine for image classification, Neurocomputing 339, 66–76, 2019.
- [9] M. Santos, A. Filho, W. Santos, Deep convolutional extreme learning machines: Filters combination and error model validation, Neurocomputing 329, 359–369, 2019.
- [10] L. Coletta, M. Ponti, E. Hruschkab, A. Acharya, J. Ghosh, Combining clustering and active learning for the detection and learning of new image classes, Neurocomputing 358, 150–165, 2019.
- [11] J. Yuan, X. Hou, Y. Xiao, D. Cao, W. Guan, L. Nie, Multi-criteria active deep learning for image classification, Knowledge-Based Systems 172, 86–94, 2019.
- [12] S. Matiz, K. E. Barner, Inductive conformal predictor for convolutional neural networks: Applications to active learning for image classification, Pattern Recognition 90, 172–182, 2019.
- [13] D. Sönmez, Geri Yayılım Algoritması'na Matematiksel Yaklaşım, <http://www.derinogrenme.com/2018/06/28/geri-yayilim-algoritmasina-matematiksel-yaklasim/>, 2018.