



**TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**



NVIDIA DIGITS KULLANILARAK YÜZ DUYGU İFADELERİNİN SINIFLANDIRILMASI VE ADLİ YAKLAŞIM

Sevim Çağla DEMİR

**DİSİPLİNLERARASI ADLİ BİLİMLER ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**DANIŞMAN
Doç. Dr. Gazi Erkan BOSTANCI**

**ANKARA
2020**

**TÜRKİYE CUMHURİYETİ
ANKARA ÜNİVERSİTESİ
SAĞLIK BİLİMLERİ ENSTİTÜSÜ**

**NVIDIA DIGITS KULLANILARAK YÜZ DUYGU
İFADELERİNİN SINIFLANDIRILMASI VE ADLİ
YAKLAŞIM**

Sevim Çağla DEMİR

**DİSİPLİNLERARASI ADLİ BİLİMLER ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**DANIŞMAN
Doç. Dr. Gazi Erkan BOSTANCI**

**ANKARA
2020**

Etik Beyan

Ankara Üniversitesi

Sağlık Bilimleri Enstitüsü Müdürlüğü'ne,

Yüksek Lisans/Doktora tezi olarak hazırlayıp sunduğum “NVIDIA DIGITS Kullanılarak Yüz Duygu İfadelerinin Sınıflandırılması ve Adli Yaklaşım” başlıklı tez; bilimsel ahlak ve değerlere uygun olarak tarafımdan yazılmıştır. Tezimin fikir/hipotezi tümüyle tez danışmanım ve bana aittir. Tezde yer alan deneysel çalışma/araştırma tarafımdan yapılmış olup, tüm cümleler, yorumlar bana aittir.

Yukarıda belirtilen hususların doğruluğunu beyan ederim.

Öğrencinin Adı Soyadı: Sevim Çağla DEMİR

Tarih:

İmza:

KABUL VE ONAY

Ankara Üniversitesi Sağlık Bilimleri Enstitüsü
Disiplinlerarası Adli Bilimler Anabilim Dalı
Kriminalistik Tezli Yüksek Lisans Programında

Sevim Çağla DEMİR tarafından hazırlanan

“NVIDIA DIGITS Kullanarak Yüz Duygu İfadelerinin Sınıflandırılması ve Adli Yaklaşım”
adlı tez çalışması

aşağıdaki jüri tarafından **YÜKSEK LİSANS TEZİ** olarak

OY BİRLİĞİ ile kabul edilmiştir.

10.02.2020



Prof.Dr. Nergis CANTÜRK
Ankara Ü. Adli Bilimler Enstitüsü
Jüri Başkanı



Doç.Dr. Gazi Erkan BOSTANCI
Ankara Ü. Mühendislik Fakültesi
Üye



Dr.Öğr.Üyesi Hilal KAYA
Ankara Yıldırım Beyazıt Ü. Müh.ve Doğa Bil.Fakültesi
Üye

Tez hakkında alınan jüri kararı, Ankara Üniversitesi Sağlık Bilimleri Enstitüsü Yönetim Kurulu tarafından onaylanmıştır.

Prof.Dr. Mehmet AKAN
Sağlık Bilimleri Enstitüsü Müdürü

İÇİNDEKİLER

Etik Beyan	ii
Kabul ve Onay	iii
İçindekiler	iv
İthaf	v
Önsöz	vi
Simgeler ve Kısaltmalar	vii
Şekiller	viii
Çizelgeler	x
1. GİRİŞ	1
1.1. Sınır Ağları Ve Derin Öğrenme	4
1.2. Nvidia Digits Kullanım Alanları Ve İçeriği	6
1.3. Nvidia Digits Yüz Tanımda Kullanımı Ve Adli Yaklaşım	7
2. GEREÇ ve YÖNTEM	11
2.1. Çalışmada Kullanılan Donanımsal Ekipmanlar	11
2.2. Çalışmada Kullanılan Yazılımsal Ekipmanlar	11
2.3. Deneysel Verilerin Elde Edilmesi ve Hazırlanması	12
3. BULGULAR	19
3.1. Nvidia Digits İle Gerçekleştirilen Giriş Seviyesi Deneysel Çalışma	19
3.2. Deneysel Kapsamında Gerçekleştirilen McNemar Testi	32
3.3. Nvidia Digits İle Gerçekleştirilen Deneysel Çalışma	43
3.4. Nvidia Digits İle Adli Açıdan Yürütülen Deneysel Çalışma-1	45
3.5. Nvidia Digits İle Adli Açıdan Yürütülen Deneysel Çalışma-2	46
4. TARTIŞMA	49
5. SONUÇ ve ÖNERİLER	55
ÖZET	59
SUMMARY	60
KAYNAKLAR	61
ÖZGEÇMİŞ	66

Bu tezi sonsuz ve koşulsuz sevgisini benden hiç bir zaman esirgemeyen anneannem
Sevim Caner'e ithaf ediyorum.

ÖNSÖZ

“NVIDIA DIGITS Kullanılarak Yüz Duygu İfadelerinin Sınıflandırılması ve Adli Yaklaşım” adlı tez çalışmasında; derin öğrenme ile insan yüz ifadelerinin duygular açısından sınıflandırılması incelenmiştir. Çalışmaların adli alanda kullanımı ile vereceği sonuçların başarı oranı ve bu alana yeni bir pencere açarak sağlayacağı katkılar yorumlanmıştır.

Öncelikle tez konusu seçimimde taleplerimi dikkate alarak bana yol gösteren tez danışmanım Doç.Dr.Gazi Erkan BOSTANCI’ya teşekkürlerimi sunarım.

Bu çalışmanın tüm safhalarında destek ve katkılarını benden esirgemeyen değerli Prof.Dr.Nergis CANTÜRK’e teşekkür ederim.

Tez sürecim bir yana hayatım boyunca benden desteklerini bir an için bile esirgemeyen ve bu konuda bana sabır gösteren başta Selin, Emel, Ece ve Mine olmak üzere değerli dostlarıma ve iş arkadaşlarıma teşekkürü bir borç bilirim.

Bana olan sevgisini ve inancını göstererek, çalışmalarımda beni destekleyen ve cesaretlendiren sevgili yol arkadaşım Mert’e teşekkür ederim.

En önemlisi, hedeflediğim hiç bir başarı, sevgili ailem olmadan gerçekleşmezdi. Bu yüzden tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen, her zaman yanımda olan ve bana inanan başta Çağatay, annem, babam, anneannem ve teyzelerim olmak üzere tüm aileme sevgi ve derin şükranlarımı sunarım.

SİMGELER VE KISALTMALAR

α	Alfa (Yanılma Yüzdesi)
BVLC	Berkeley Vision ve Learning Center
Caffe	(Convolution Architecture For Feature Extraction)
CK +	Extended Cohn-Kanada
CNN	Convolutional Neural Networks (Evrişimsel Sinir Ağları)
Conv	Convolution (Evrişim)
CUDA	Compute Unified Device Architecture
DNN	Deep Neural Networks (Derin Sinir Ağları)
GPU	Graphics Processing Unit (Grafik İşlemci Ünitesi)
ILSVRC2012	ImageNet Large Scale Visual Recognition Challenge 2012
INTERPOL	International Criminal Police Organization (Uluslararası Kriminal Polis Teşkilatı)
JAFFE	Japanese Female Facial Expression
χ^2	Ki Kare Testi
NVIDIA DIGITS	NVIDIA Deep Learning GPU Training System (Deep Learning GPU Eğitim Sistemi)
Pxl	Piksel
RaFD	The Radboud Faces Database
ReLU Layer	Rectified Linear Units Layer (Düzleştirilmiş Doğrusal Birim Katmanı)
Sd	Serbestlik Derecesi

ŞEKİLLER

Şekil 1.1. Turing Testi	1
Şekil 1.2. Verinin Artışı ile İşlemin Dönüşümü	3
Şekil 1.3. Verinin Büyüklüğü, Sinir Ağı Büyüklüğü ve Performans Arasındaki İlişki	5
Şekil 3.1. Klasör İsimlendirmesi	19
Şekil 3.2. DIGITS Home - Veri kümesi	20
Şekil 3.3. DIGITS Home – Models	20
Şekil 3.4. NVIDIA DIGITS - Veri Seti Oluşturma Arayüzü	21
Şekil 3.5. NVIDIA DIGITS – Model Oluşturma Arayüzü	22
Şekil 3.6. AlexNet Ağ Mimarisi (Doğan ve Türkoğlu, 2018)	23
Şekil 3.7. Katmanların dizilişleri	25
Şekil 3.8. Görüntü İşlenme Süreci 1	26
Şekil 3.9. Görüntü İşlenme Süreci 2	26
Şekil 3.10. Sınıflandırma Veri Seti Sonucu	27
Şekil 3.10. Devam. Sınıflandırma Veri Seti Sonucu	28
Şekil 3.11. Model Sonucu	28
Şekil 3.11. Devam. Model Sonucu	29
Şekil 3.12. Yapılan Çoklu Sınıflandırma Çalışmasından Örnek Sonuçlar	30
Şekil 3.13. Yapılan Caffe-AlexNet Çalışması	33
Şekil 3.14. Yapılan Caffe-GoogLeNet Çalışması	33


Şekil 3.15. Yapılan Torch-AlexNet Çalışması	34
Şekil 3.16. Yapılan Torch-GooLeNet Çalışması	34
Şekil 3.17. Yapılan Çalışmadan Örnek Sonuçlar	36
Şekil 3.18. Güven Aralığı Grafiği	38
Şekil 3.19. LeNet ile Yapılan Çalışmadan Örnek Görüntü	44
Şekil 3.20. Adli Görüntü ile Yapılan Çalışma	45
Şekil 3.21. Adli Görüntü ile Yapılan Çalışma	47
Şekil 4.1. Ezberleme	53
Şekil 4.2. Öğrenmeme	53

ÇİZELGELER

Çizelge 2.1. Veri Seti Kategorileri	13
Çizelge 2.2. Kullanılan Veri Seti Kategorileri	13
Çizelge 2.3. Kullanılan Veri Seti Kategorileri ve Sayıları	13
Çizelge 2.4. Kullanılan Veri Kategorileri Örnekleri	14
Çizelge 2.5. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri	16
Çizelge 2.5.Devam-1. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri	17
Çizelge 2.5.Devam-2. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri	18
Çizelge 3.1. Yapılan Tekli Sınıflandırma Çalışmasından Örnek Sonuçlar	31
Çizelge 3.2. McNemar Test Tablosu	37
Çizelge 3.3. Ki Kare Test Tablosu	38
Çizelge 3.4. McNemar Test z score Tablosu	39
Çizelge 3.5. Caffé Sabit Tutulup AlexNet ve GoogLeNet Değişkenlerinin Değerlendirildiği McNemar Test Tablosu	40
Çizelge 3.6. Torch Sabit Tutulup AlexNet ve GoogLeNet Değişkenlerinin Değerlendirildiği McNemar Test Tablosu	41
Çizelge 3.7. AlexNet Sabit Tutulup Caffé ve Torch Değişkenlerinin Değerlendirildiği McNemar Test Tablosu	42
Çizelge 3.8. GoogLeNet Sabit Tutulup Caffé ve Torch Değişkenlerinin Değerlendirildiği McNemar Test Tablosu	42
Çizelge 3.9. Adli Görüntü ile Yapılan Çalışma Sonucu 1	46
Çizelge 3.10. Adli Görüntü ile Yapılan Çalışma Sonucu 2	48

1. GİRİŞ

1950’li yıllarda Alan Turing, meşhur Turing Testini ortaya atmıştır. Turing Testi ile aslında makinaların düşünüp düşünemediklerini yani zeki olup olmadıklarını sorgulamayı hedeflemiştir. Kısaca testten bahsetmek gerekirse, değerlendirici kişi (C) hangi tarafta hangisi olduğunu bilmeden makina (A) ve insana (B) sorular yönelterek etkileşime girmektedir. Aldığı cevaplar üzerine ise insan mı yoksa makina mı ayrımını yapmaya çalışmaktadır. Eğer değerlendirici etkileşimde bulunduktan sonra aldığı geri dönüşler karşısında karşısındakinin makina mı insan mı olduğunun ayrımını yapamıyorsa karşısındaki makinanın düşünen zeki bir makina olduğu kabul edilmektedir (Turing, 1950, s:433-460) (Ahn ve ark., 2004, s:56-60).



Şekil 1.1. Turing Testi (Adam, 2019)


Bundan 6 yıl sonra, 1956 yılında ise John McCarthy akademik bir konferans düzenlemiştir. Bu konferans esnasında ‘yapay zekâ’ tanımı ilk kez kendisi tarafından dile getirilmiştir (Peart, 2017). Katılımcılar tarafından da yapay zekâ kavramı değerli bulunmuştur ve bu alandaki çalışmaların ivme kazanması gerektiğine inanılmıştır. Günümüzde de yapay zekâ çalışmaları gerek teknoloji gerek ticari gerekse devletler tarafından önemli bir araç olarak görülmektedir.

Yapay zekâyı kendi içinde zayıf ve kuvvetli yapay zekâ olarak ikiye ayırabilmekteyiz. Zayıf yapay zekâ programlananın dışına çıkmadan isteklere belirlenen çerçeveler eşiğinde riayet etmektedir. Girdiler gösterilen yolları takip ederek beklenen şekilde çıktılara dönüşmektedir. Diğer taraftan kuvvetli yapay zekâlar girdiler üzerinde algoritmik işlemler gerçekleştirebilmektedir. Beklenen çıktıları gösterilen yollara gerek duymadan, hesapladıkları farklı yollar üzerinden varabilmektedir. Bu demek oluyor ki, istenilen çıktıyı belki de bizim düşündüğümüz yoldan daha basite indirgenmiş bir yol üzerinden biz sunabilmektedir.

Eğer programlamadığımız bir sonuç açığa çıkarsa ne olur? Arthur Samuel, kendi hatalarından sonuç çıkarımı yapabilen ve bu şekilde kendini geliştiren bir dama oyunu programlamıştır. 1959 yılında da Samuel makine öğrenimini, makinelerin programlanmadığı sonuçları öğrenebilme yeteneği olarak belirtmiştir (Samuel, 1959, s:210-229).

Makine öğreniminin popülaritesinin artmasının nedeni resim tanıma yeteneği olmuştur. Makinenin ilgili resmi tanınması için önce yüzlerce hatta binlerce kez resim makineye tanıtılmaktadır. Daha sonra tanıtılan resimler üzerinden öğrendiği desenler, diziler veya piksellerden yola çıkarak tanıtılan resimleri ve benzerlerini de tanımlayabilmektedir. Örneğin, Facebook, Pinterest ve Google+ gibi çevrimiçi uygulamalar zaman tüneli, beğenebileceğiniz içerik veya ilginizi çekebilecek yayınlar gibi önerileri size bu şekilde sunmaktadır (editor_goodworks, 2017). Yani makine öğrenimi hali hazırda hayatlarımızın bir parçası halini almıştır.

Bu alanda çalışırken, elimizde ne kadar çok veri olursa o kadar iyi bir çalışma gerçekleştireceğimizi bilmekteyiz. Diğer bir deyişle, makine öğrenimi üzerine çalışma gerçekleştirirken elimizde ne kadar çok veri olursa o kadar iyi olacağını bilmekteyiz. Diğer taraftan çok fazla veri, yapay zekâ için karmaşıklığa yol açacaktır. Bu denli karmaşıklık yapay zekâdan makine öğrenimine kaymalara neden olacaktır. Eğer veriler daha da arttırılır ise bu sefer makine öğrenimine de fazla gelecek karmaşık yapı bizi derin öğrenmeye yönlendirecektir (Brownlee, 2019).



Şekil 1.2. Verinin Artışı ile İşlemin Dönüşümü (Shorten, 2018)

Eski çalışmalarda makineye cisimleri kendimizin tanıtması gerekmekteydi. Örneğin, bir çalışmamızda iki çeşit arabayı çalışma öznelerimiz olarak belirlemiş olalım. Bu iki çeşit arabayı makine öğreniminde kendimizin tanıtması gerekmekteydi. Arabaların fiziksel yapıları ile ilgili belli farklılıkları tek tek biz öğretmeliydik. İzlemesinin doğru olacağı yolu biz göstermeliydik. Oysaki derin öğrenmede bu farkları sistemimiz kendi başına ayırt edebilmekte ve yolunu kendisi seçebilmektedir. Bizim tek yapmamız gereken sistemimize bu iki çeşit arabanın görsellerini vermektir. Bizim verdiğimiz görsellerden yola çıkarak derin öğrenme sistemimiz kendi yollarını oluşturacak ve far şekli, araba yüksekliği veya kapılarının şekli gibi ana fark yaratıcı fiziksel özelliklerin ayırt edici olduğunu kendisi saptayacaktır. Hatta belki de insanların sisteme tanımlayacağı ayırt edici özelliklerden daha etkili bir fark bulacak ve onu kullanarak işlemleri insan önerisinden daha yüksek bir doğruluk ile gerçekleştirecektir. Bu noktada bizim yapabileceğimiz çıkarım ise artık derin öğrenme ile birlikte makinelerin temel insani yetilerin yardımına ihtiyaç duymadıkları olmalıdır.

Diğer taraftan ise daha fazla veri her zaman için tahmin doğruluğunu arttıracaktır. Bu temel nokta asla unutulmamalıdır. Oluşturulan derin öğrenme sisteminin farkları ne kadar yüksek başarı oranı ile kendisinin öğrenmesi isteniyorsa, o kadar çok örnek sunulması gerekmektedir. Kısaca, verilen örnek sayısı ne kadar çok olursa, karşılaştırma sonuçlarının başarısı da arttırılan örnek sayısı ile doğru

orantılı olarak artacaktır. Daha önce de bahsettiğimiz üzere, kurduğumuz sisteme ne kadar çok veri sunulursa, karmaşıklık o derece artacaktır. Bu karmaşıklık eğer doğru yollar izlenerek ve köprüler kurularak oluşturulan bir derin öğrenme sistemi ile birleşirse, bizi başarıya götürecektir.

1.1. SİNİR AĞLARI ve DERİN ÖĞRENME

Bir tarafta derin öğrenme sistemi, diğer tarafta ise karmaşık ve/veya büyük veri setleri bulunurken arada kurulan köprüler ve izlenilen yollar, kılavuzluk görevini edinecek olan sinir ağları olacaktır. Derin öğrenme denildiğinde Derin Sinir Ağları (DNN) ön plana çıkmaktadır. DNN'lerin makine öğrenme algoritmalarından daha güçlü olmaları, DNN'ler için bir artıdır. Diğer taraftan uygulamalarının daha zor olması bir eksi oluşturmaktadır. Derin sinir ağları, derin öğrenmede, görüntü tanıma işleminde temel rollerden birini oynayan katmanlardan oluşan bir algoritma olarak tanımlanabilmektedir.


Eğer elimizdeki derin sinir ağı ne kadar çok katmana sahip ise o kadar işlevsel, doğruluğu yüksek veya başka bir deyişle derin bir ağ olarak tanımlanacaktır. Eğer biz modelimize bir nesneyi tanıtmak istiyorsak, modelimize o nesnenin görüntülerinin yanı sıra o nesneden olmayan görüntülerimizi de sunmak zorundayız. Bir nevi modelimize o nesnenin olduğu ve olmadığı iki farklı gruptan oluşan eğitim seti vermemiz gerekmektedir. Elimizdeki veri setimizin boyutu yani bu iki grup için de veri miktarı ne kadar çok olursa derin öğrenmeden elde edeceğimiz doğruluk o kadar yüksek olacaktır.

Yürütülen çalışmalar evrimsel sinir ağları (CNN) ile görüntü sınıflandırmada son derece zorlu verilerde rekor sayılabilecek başarılı sonuçlar elde edilebileceğini gözler önüne sermiştir. Diğer taraftan bu gizli katmanlardan herhangi birinin çekilmesi de performans kaybına neden olmaktadır. Bu nedenle başarıya ulaşmada her bir katmanın değeri oldukça yüksektir (Krizhevsky, 2012).

Normal şartlarda bu kadar çok veri işlemek için bize oldukça fazla zaman gerekecektir. İşte tam bu noktada Grafik İşlemci Üniteleri (Graphics Processing Unit)(GPU) devreye girmektedir. GPU'lar sayesinde sistemimizi eğitmemiz daha kısa sürede tamamlamamız mümkün hale gelmektedir. Bu yüzden derin öğrenmede grafik teknolojisi temel rollerden birine sahiptir (Shaikh, 2017).

DNN'lerin en bilineni evrişimsel sinir ağları (CNN)'dır. CNN'ler iki boyutlu evrişimsel katmanlar kullanmaktadır ve bu şekilde daha önce öğrendiklerini girdilere uygulamaktadır. CNN'ler için bir görüntünün özelliklerinin insan tarafından belirtilmesine gerek yoktur. Bu özellikleri kendi başına algılamakta ve sistemin öğrenmesini sağlamaktadır. Kullanılan her bir CNN katmanı görüntüyü sistemin daha detaylı tanınmasına yardımcı olmaktadır.

DNN'de ilk katmanlarda görüntünün kenarları öğrenilirken sonraki katmanlara gelindiğinde tam anlamı ile şekli oluşturulmaya başlanmaktadır. Diğer taraftan kullandığımız sinir ağı büyüklüğü arttıkça derin öğrenme sistemimizdeki başarı da o derece artacaktır.



Şekil 1.3. Verinin Büyüklüğü, Sinir Ağı Büyüklüğü ve Performans Arasındaki İlişki (Tang A ve ark., 2018)

1.2. NVIDIA DIGITS KULLANIM ALANLARI ve İÇERİĞİ

Derin öğrenmenin kullanım alan yelpazesi son derece geniştir. Teknolojinin de ilerlediğini göz önünde bulunduracak olursak kullanım alanlarının sayısı artmaya devam edecektir. Kullanım alanlarına örnek vermek gerekirse; yüz tanıma, ses tanıma, ortam tanımlama, nesne analizi, doku ve obje analizi kullanım alanlarına girmektedir (LeCun ve ark., 2015, s:436).

2015 yılında, NVIDIA derin sinir ağlarını geliştirmek, eğitmek ve görselleştirmek için bir araç olan Deep Learning GPU Eğitim Sistemini (DIGITS) piyasa sürmüştür. GPU'lar sayesinde işlemleri paralel hale getiren DIGITS, işlemleri Merkezi İşlem Birimine (Central Processing Unit)(CPU)' göre daha hızlı sonlandırmaktadır. Cargenie Mellon Üniversitesi'nden Prof. Dr. Ian Lane yaptığı çalışmalar neticesinde GPU'ların, CPU'lara göre 33 kata kadar daha hızlı tanım yaptığını ortaya konulmuştur (Bitbix, 2018). Bu özellik görüntü işlemede GPU tabanlı faaliyetlerin gerçekleştirilmesi için en belirleyici özelliklerden biri sayılmaktadır. Ayrıca açık kaynaklı bir yazılımdır ve veri bilimciler ile araştırmacıların gerçek zamanlı olarak DNN'lerini kendi verileri için eğitmelerine imkân sunmaktadır. Şu ana kadar NVIDIA DIGITS'in 6 sürümü bulunmaktadır. NVIDIA DIGITS'te modelleri eğitebilmekteyiz ve bu özellik sayesinde eğittiğimiz modelleri kullanarak sistemimizin başarı oranını arttırabilmekteyiz. Ayrıca kullandığımız mimarimizi görselleştirebilme imkânı bize sunulan önemli artılardan biri olmaktadır. Kendi sinir ağıımızı tasarlayabileceğimiz gibi AlexNet, LeNet ve GoogleNet gibi popüler sinir ağlarını da kullanmak mümkün olmaktadır (Das, 2017). DIGITS kütüphane olarak, Tensorflow, Caffe ve Torch'tan yararlanmaktadır. Tensorflow, Google Brain takımının, Caffe (Convolution Architecture For Feature Extraction) Berkeley Vision ve Learning Center'ın (BVLC) ve Torch ise Facebook AI Research, Twitter ve Google DeepMind'ın geliştirmekte oldukları kütüphanelerdir (Opala, 2019).

NVIDIA DIGITS'in ana konsolunda veri kümesi ve modeller için bölümler bulunmaktadır. Veri kümesi kısmından kendimiz veri kümesi yaratabilmekteyiz.

Model kısmından ise veri setimizi eğitebiliyoruz. Veri setimizi eğitirken hazır sinir ağları kullanabileceğimiz gibi kendimiz de bir tane oluşturup veya hazırları kendi isteğimize göre değiştirip kullanabilmekteyiz. Son olarak, parametrelerdeki değişikliklere imkân vermesi sayesinde sistemimizin doğruluğunu en üst düzeye çıkarabilmekteyiz.

1.3. NVIDIA DIGITS KULLANIM ALANLARI ve İÇERİĞİNE ADLI YAKLAŞIM

Derin öğrenme alanında yapılan yüz ifade tanıma çalışmaları genel olarak başarılı sonuçlar vermektedir. Mavani ve ark. (2017), tarafından yürütülen deneysel çalışmada, insanlarda yüz ifadelerini tanımak için bir CNN geliştirilmiştir. ILSVRC2012'de kullanılan veri setinde eğitilmiş CNN modeli, yaygın olarak kullanılan iki adet, yüz ifadesi veri seti (CFEE ve RaFD) üzerinde test edilmiştir. Sonuç ise en genelleştirilmiş deney aşamasında, test setinde doğruluğun %65,39 olarak gözlemlendiği yönünde olmuştur.

Uçar'ın yaptığı çalışmada ise CNN temel alınarak geliştirilen yüz ifade tanıma sistemi söz konusudur. Uçar testlerini Japon kadınların yüz ifadelerinden oluşan Japanese Female Facial Expression (JAFFE) ve Extended Cohn-Kanada (CK+) veri setleri üzerinde yürütmüştür. Bu çalışmada, yüz tanıma, özellik çıkarımı ve sınıflandırma için bir algoritma kombinasyonu kullanılmıştır. Önerilen yöntem, iki-kanallı bir CNN kullanması yönündedir. Her iki kanaldan gelen bilgiler, görüntü özellikleri ile ilgili genel bilgileri öğrenmek için kullanılan ve daha sonra sınıflandırma için kullanılmış olup, tamamen bağlı bir katman içinde birleşmektedir. Önerilen bu yöntemin yürütülen deneysel çalışmalar neticesinde, iki veri kümesi için sırasıyla %97,71 ve %95,72 ortalama ifade tanıma doğruluğunu sağlayabildiği gösterilmiştir (Uçar, 2017, s:371-375).

Adli olgu içerisinde suç unsuru bulunan olgulardır ve bir yargılama sürecinde yer alması öngörülen durumlardır (Dilaver, 2019).

Adli olguların kapsamına aşağıdaki sıralanan;

- Ateşli silah ve patlayıcı madde yaralanmaları,
- Kesici, delici, ezici alet yaralanmaları,
- Trafik kazaları,
- Darp olguları,
- Cinsel – yaşlı – çocuk istismarı,
- İş kazaları,
- İntoksikasyonlar,
- Yanıklar (yakıcı-aşındırıcı madde, kızgın cisim, alev),
- Elektrik ve yıldırım çarpmaları,
- Mekanik asfiksi olguları (ası, iple boğulma, suda boğulma),
- İntihar girişimleri,
- Düşmeler,
- Zehirlenmeler,
- Yasa dışı madde kullanımı (ekstazi, bonzai vb.),
- İntoksikasyon şüphesi olan vakalar (kullanılan ilaçların doz aşımaları dâhil),
- İşkence iddiaları,
- Öz yıkım,
- İnsan hakları ihlali,
- Gözaltı ve cezaevinde meydana gelen yaralanmalar,
- Hayvan ısırıkları tırmalamaları, sokmaları (kedi, köpek, arı, ayı, yılan, vb.),
- Alt ve üst soyun ihmal ve suiistimali,
- Şüpheli yaralanma ve ölümler,
- Bir başkasının kasıtlı, tedbirsiz, dikkatsiz davranışı sonucu meydana gelen tüm yaralanmalar,
- Sindirim kanalına oral veya anal yoldan yabancı madde girmesi

gibi durumlar dâhil edilmektedir (Kavalcı, 2016, s:1-2) (Terzi, 2014).

Derin öğrenme sistemlerinde adli açıdan yaklaşım sergileyerek yürütülen çalışmalardan biri Bedeli ve ark. (2018), tarafından yürütülmüş öznitelik tabanlı tanımlama sistemidir. Bu tarz çalışmalar adli araştırmalar için gerekli olmakla birlikte, bireyleri görüntülerden belirlemeye oldukça yardımcı olan unsurlar olarak görülmektedir. Kıyafet gibi bir öge görsel bir niteliktir çünkü genellikle insanları tanımlamak için kullanılabilir. Bedeli ve ark.'ın çalışması bu yöndedir. İnsanları kıyafetlerinden, elde edilen görsel bilgilere dayanarak tanımlamayı amaçlamaktadır. Derin öğrenme sistemi, giyim içeriğine göre görüntüleri sınıflandırmak için eğitilmiştir. İlk önce, büyük ölçekli bir veri kümesi kullanarak yapılan çalışmada, giysi sınıflandırmasını yapılırken önerilen modelin nispeten düşük performans gösterdiği belirtilmiştir. Daha sonra, popüler logoları ve ünlü marka tarzlarını içeren bir veri seti kullanılmış ve giysi sınıflandırması gerçekleştirilmiştir. Sonuçlar, modelin test görüntülerinin çoğunu % 70'ten yüksek bir başarı oranıyla doğru bir şekilde sınıflandırdığını gösterdiği belirtilmiştir. Çalışmanın son adımı olarak gerçek güvenlik kameralarındaki görüntüler kullanılarak giysi sınıflandırılması gerçekleştirilme yoluna gidilmiş ve sonuç olarak % 70 doğru şekilde giysilerin sınıflandırıldığı görülmüştür. Çalışmalar ve kullanılan derin öğrenme sistemi bu veri setinde iyi bir performans sergilemiştir (Bedeli ve ark., 2018, s:219-229).

Yüz tanıma ise adli açıdan ele alınması gereken ve üzerine çok daha ciddi çalışılması bir konudur. Adli bilimlerde yüz tespitinin yapılp tanıma işleminin kullanılması, aslında zorlu ve hassas bir süreçtir. Öncelikle adli bilimler, yasal bir sisteme ilgi duyulan soruları cevaplamak için bilimsel ilke ve yöntemlerin kullanılması olarak tanımlanabilmektedir. Adli bilimlerde, güvenlik uygulamalarının amacı, olayların ortaya çıkmasını önlemektir. Adli vakalarda ise genellikle bir olay meydana gelmiştir. Yüz tanımlama gerçekleştirilirken, aydınlatma koşulları, yüz orantıları, bakış açısı ve diğer faktörlerin tümündeki değişkenler yürütülen çalışmaları zor bir iş haline getirmektedir. Ayrıca görüntü alınan kamera açısındaki değişimler de yüz görüntülerinin kaydedilememesine veya sistem doğruluk

oranlarının kötüleşmesine neden olmaktadır. Düşük sistem doğruluğu yasal konularda yanlış yönlendirmeler ile ciddi sorunlara neden olabilmektedir. Bu nedenle, birçok adli kurum henüz güvenlik alanında yüz tanımlama sistemlerini benimsememiştir. Diğer bir deyişle adli kurumlar yüz tanımlama sistemlerini ana belirleyici unsur olarak kabul etmekten kaçınmaktadır (Electronic Frontier Foundation, 2017).

Diğer taraftan INTERPOL Yüz Tanıma Sistemi, yüz özelliklerine ve kontürlerine göre karşılaştırma yapıp analiz ederek bir kişiyi benzersiz şekilde tanımlayabilen veya doğrulayabilen otomatik bir biyometrik yazılım uygulamasını başarılı bir şekilde kullanmaktadır (INTERPOL, 2019).

Derin öğrenme sistemleri sayesinde ise adli açıdan yürütülen yüz tanıma sistemlerini bir adım öteye götürerek adli vakalardan elde edilen görüntülerin oluşturduğu büyük veri havuzlarında yürütülecek, nötr, mutluluk, üzüntü, şaşkınlık, kızgınlık, korku ve tiksiniş olmak üzere temeldeki 7 adet yüz duygu ifadesinin saptanması insan gücünden tasarrufa gidilmesine, çalışan kişilerin verimliliğini arttırmaya, zaman kaybının önüne geçilmesine ve objektif bir bakış açısı sağlamaya yardımcı olacaktır. Diğer bir taraftan da olası şüpheliler ve kurbanların saptanmasında yol gösterici nitelikte bir bilgi sağlayıcı görevi görecektir.

2. GEREÇ ve YÖNTEM

Tezde deneysel bir yaklaşım üzerinde durulmaktadır. Yürütülen deneysel çalışmalarda kullanılan materyalden iki alt kategoride bahsetmek uygun olacaktır. Bu kategoriler donanımsal ve yazılımsal olarak adlandırılmıştır.

2.1. Donanımsal Ekipmanlar

Deneyde donanımsal gereklilik olarak görülebilecek ana ihtiyaç yeterli güçteki bir ekran kartı yani CPU'dur. Bizim oluşturduğumuz düzeneğimizde de GPU üzerinden görüntü işleme çalışmaları yürütüleceği için GeForce GTX 1080 kullanılmıştır.

2.2. Yazılımsal Ekipmanlar

NVIDIA Digits kullanımı için önerilen işletim sistemi Linux olduğu için Linux tercih edilmiş ve Ubuntu 16.04 kullanımı ile kurulumu yapılmıştır.

NVIDIA Digits yüklemek için Caffe kurulumu gerekmektedir. Caffe'nin sağlıklı çalışması için ise NVIDIA driver, CUDA toolkit ve cuDNN gerekmektedir. CUDA, GPU için NVIDIA'nın sunduğu C programlama dili üzerinde eklenti olarak kullanıma sunulan bir mimari ve teknolojidir. cuDNN ise kısaca CUDA'nın derin öğrenmeye göre optimize edilmiş bir sürümüdür (Durukan, 2016). DIGITS 6 sürümünü yüklemek için Python2 2.7.11, CUDA 8, CuDNN 5.1, CUDA Toolkit 10.2, Caffe ve Graphviz kurulumları gerekmektedir. Bu bağlamdaki paketler indirildikten sonra Caffe indirilmiştir. Son olarak ise NVIDIA Digits kurulumu gerçekleştirilmiştir.

NVIDIA Digits’te ise Caffé ve Torch kütüphaneleri kullanılmıştır. Derin sinir ağı olarak ise GoogLeNet, AlexNet ve LeNet kullanımı tercih edilmiştir.

2.3. Deneysel Verilerin Elde Edilmesi ve Hazırlanması

Çalışmalara ilk başlandığında Kaggle’ın büyük çaplı veri setlerini kullanarak yürüttükleri yarışmalardan biri olan ve Pierre-Luc Carrier ile Aaron Courville’in düzenlediği veri setinin bizim çalışmamız için uygun olduğuna karar verilmiştir. Veri seti, Kaggle üzerinden, “yüz ifadelerini tanıma zorluğu” başlığı altında yayınlanmıştır. Bu veri seti üzerinden belirlenen çok sayıda görsel ile çalışmalar gerçekleştirilmiştir (Kaggle, 2012).

Önce .cvs formatında yayınlanan, içeriğinde duygu durumlarının sınıflandırılmış olarak bulunduğu ve pikselleri içeren iki sütuna sahip dosya, python kullanılarak .png formatına çevrilmiştir. Png formatının seçilmesinin nedeni eğitim esnasında veri kaybını en düşük düzeye çekmektir. Bahsi geçen ve .cvs formatından .png formatına çekilen Pierre-Luc Carrier ile Aaron Courville’in eğitim setinde toplamda 28.709 örnek görüntü bulunmaktadır. Veri setinde bulunan görüntüler, 48x48 piksel boyutundadır. Gri tonlamalı görüntüler çalışmamız için uygun görülmüştür. Zira LeNet için gerekli görüntülerin özellikleri 36x36 piksel boyutunda ve gri tonlamayı sağlanması beklendiğinden dolayı, elimizdeki Pierre-Luc Carrier ile Aaron Courville’in eğitim setindeki görüntülerin 48x48 pikselden 36x36 piksel çekilmesi daha uygun olmaktadır. Bu nedenle görüntü boyutunun küçültülmesi ile daha anlamlı sonuçlar elde edileceği düşünülmüştür. Ayrıca hali hazırda Pierre-Luc Carrier ile Aaron Courville’in eğitim setindeki görüntülerin gri tonlamada olması, LeNet’in gri tonlama talebini karşılamasından dolayı ekstra görüntüleri dönüştürmeden kullanılması açısından kolaylık sağlamıştır.

Pierre-Luc Carrier ile Aaron Courville’in eğitim setindeki görüntüler, duygu ifadelerine göre 7 farklı kod ile aşağıdaki şekilde sınıflandırılmıştır.

Çizelge 2.1. Veri Seti Kategorileri

0	1	2	3	4	5	6
Kızgın	İğrenmiş	Korkmuş	Mutlu	Üzgün	Şaşırmış	Nötr

Bu duygu görüntülerinden 6 tanesi adli yaklaşım için çalışmalarda kullanıma uygun görülmüştür. 1= İğrenmiş olan sınıf çalışmalara dahil edilmemiştir. Sonuç olarak, çalışmalarımızda kullanılan yüz duygu ifadeleri aşağıdaki tablodaki halini almıştır.

Çizelge 2.2. Kullanılan Veri Seti Kategorileri

0	2	3	4	5	6
Kızgın	Korkmuş	Mutlu	Üzgün	Şaşırmış	Nötr

Veri seti içinden bu duygu türleri için elemeler yapılmış ve sağlıklı görünen görüntüler seçilmiştir. Seçilen görüntü sayıları aşağıdaki tabloda görüldüğü gibi son halini almıştır. Bu esnada her bir kategori için aynı sayıda görüntü sayısı gerçek veya sanal görüntü artırımı ile eşitlenmemiştir. Esas yapılan çalışmanın ön hazırlığı olması açısından gereklilikleri değerlendirmek adına deneysel olarak gerçekleştirildiği için çalışma prensibine öncelik verilmiştir.

Çizelge 2.3. Kullanılan Veri Seti Kategorileri ve Sayıları

0	2	3	4	5	6
Kızgın	Korkmuş	Mutlu	Üzgün	Şaşırmış	Nötr
1031	307	500	447	529	637

Kullanılan görüntülerden Kızgın, Korkmuş, Mutlu, Üzgün, Şaşırmış ve Nötr için 48x48 piksel gri tonlamalı birer örnek aşağıdaki gibi seçilmiş ve şekilde verilmiştir.

Çizelge 2.4. Pierre-Luc Carrier ile Aaron Courville Veri Setinden Örnekler (Kaggle, 2012)

Şaşırmış	Üzgün
	
Korkmuş	Mutlu
	
Üzgün	Nötr
	

Yapılan birçok araştırma üzerine teze uygun olarak yüz duygu durum ifadelerini yansıtacak iki adet veri seti tespit edilmiştir. Tespit edilen veri setleri, AffectNet Database ve MUG Facial Expression Database olmak üzere, çalışmalarımızda bu iki adet veri seti kullanılmıştır. Veri setlerinin veri tabanlarına ulaşmak için gerekli izinlerin alınması gerekmiştir. Söz konusu iki veri seti içinde benzer de olsa farklı tarzda yazışmalar yürütülmüş ve gerekli izinler alınmıştır (Mollahosseini ve ark., 2017, s:18-31) (Aifanti ve ark., 2010, s:1-4).

İlk aşama olarak bu elde edilen iki kaynak, model için kullanılacak sınıflandırma veri seti oluşturmada kullanılmış olup, daha sonra ise kalan veriler yardımı ile model için oluşturulan veri seti, modeli eğitme sürecinde gerekli geri beslemeleri yapmak amacı ile kullanılmıştır.




Sınıflandırma veri setini oluşturmak için 7 farklı yüz duygu durum ifadesi olarak mutlu, mutsuz, kızgın, şaşırmış, nötr, korkmuş ve tiksiniş yüz duygu durum ifadeleri belirlenmiş olup, bu ifadeleri yansıtan görsellerin her birinden 2.000'er adet olmak üzere toplamda 14.000 tane görsel üzerine çalışılmasına karar verilmiştir. Kategorilerden kızgın, şaşırmış ve korkmuş ve tiksinişte yeterli kalitelide ve/veya sayıda görüntü olmadığından ötürü sanal artırma gidilmiştir. Sanal artırım yöntemi olarak döndürme kullanılmıştır. Son olarak ise seçilen görseller daha önceden kullanacağımızı saptadığımız sinir ağıları AlexNet ve GoogLeNet'in kullandığı görsel formatının gereklilikleri incelenerek, 256x256 piksel olarak tekrar boyutlandırılmıştır.

Veri derleme kısmının ikinci aşaması olarak çalışmamızda kullanılacak en uygun ve en başarılı sonuç alacağımız sinir ağı ve kütüphane seçimi için yapılacak McNemar test kısmında kullanılmak üzere bu iki veri tabanından toplamda daha önce bahsi geçen 7 farklı yüz duygu durum ifadesi kategorisi için 1000'er adet görsel seçilmiş ve eğittiğimiz modeli test etmek amacı ile kullanılmıştır. Bahse konu olan test görselleri de aynı sinir ağlarının kullanımı esnasındaki gereklilikten ötürü tekrar boyutlandırılarak 256x256 piksel boyutuna çekilmiştir. Çalışmalarda kullanılan AffectNet Database ve MUG Facial Expression Database veri setlerinden birer örnek aşağıdaki şekildedir.

Çizelge 2.5. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri

	AffectNet Veri kümesi	MUG Facial Expression Veri kümesi
Kızgın		
Korkmuş		
Mutlu		

Çizelge 2.5.Devam-1. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri

	AffectNet Veri kümesi	MUG Facial Expression Veri kümesi
Mutsuz		
Nötr		
Şaşırmış		

Çizelge 2.5.Devam-2. AffectNet Database ve MUG Facial Expression Database Veri Setlerinden Örnekleri

	AffectNet Veri kümesi	MUG Facial Expression Veri kümesi
Tiksinmiş		

Tez çalışmasının son basamağı olan adli yaklaşım kısmının gerektirdiği adli vakalara konu görseller ise açık kaynaklardan gerekli araştırmalar yapılarak etik açıdan sorun teşkil etmeyeceğine kanaat getirilen adli vaka görüntüleri ile derlenmiştir. Bu görüntüler daha önce hazırlanmış olan veri setleri kullanılarak oluşturulan modeller üzerinde çalışılarak incelenmiştir ve konuya adli açıdan yaklaşım sağlanmıştır.

3. BULGULAR


3.1. NVIDIA DIGITS ile GERÇEKLEŞTİRİLEN GİRİŞ SEVİYESİ DENEYSEL ÇALIŞMA

Öncelikle NVIDIA DIGITS ile localhost üzerinden veri setimiz ile model oluşturmamız gerekmektedir. Elimizde bulunan veriler ile yeni bir sınıflandırma veri seti yaratmak amacıyla açılan sayfada bir sınıflandırma veri seti oluştururken öncelikle bizim kullanacağımız veri setini belirlememiz gerekmektedir. Bu esnada dikkat etmemiz gereken en önemli nokta veri setimizin sınıflandırma veri seti oluştururken öğrenmesini istediğimiz sınıflandırmaya uygun şekilde kendi içlerinde gruplandırılmış olmasıdır. Bunun için de aşağıda bulunan şekilde görüldüğü üzere kullanılan yöntem, daha önce hazırlanmış veri setini istenilen sınıflandırma olan mutlu, mutsuz, kızgın, şaşırılmış, nötr, korkmuş ve tiksiniş yüz duygu durum ifadelerinin her biri için ayırmak ve her biri için ayrı klasörler oluşturmaktır. Oluşturulan klasörler, sonuçlarda karşımıza çıkacak sınıflandırmaların isimleri olacak şekilde adlandırılmalı ve Türkçe karakter kullanmamak gerekmektedir. Diğer bir deyişle bizim sınıflandırma klasörlerine vereceğimiz isimler bize çalışmamızın sonuç kısmında, sistemin vereceği çıktı isimler olacağının bilincinde olarak isim verilmelidir.




Şekil 3.1. Klasör İsimlendirmesi

Localhost5000'e giriş yaptıktan sonra "Home" sayfası bizi karşılamaktadır. Bu sayfada "Veri kümesi" kısmından yeni veri seti oluşturabiliriz veya "Models" kısmından daha önce oluşturulmuş sınıflandırma veri setleri ile sınıflandırma modelleri oluşturabilmekteyiz. Ayrıca daha önce gerçekleştirilen tüm çalışmalar silmediğimiz sürece bu sekmelerde saklı tutulmaktadır.



Şekil 3.2. DIGITS Home - Veri kümesi



Şekil 3.3. DIGITS Home - Models

Daha sonra hazırlanan veri setine uygun olan seçenekleri aşağıdaki gibi olacak şekilde belirleyerek sınıflandırma veri seti oluşturma sürecine devam ediyoruz. En önemli seçim unsurları sol üstte yer alan seçeneklerden “image type” ve “image size” kısımlarıdır. “training imageset” kısmına ise kullanacağımız veri setinin dosya yolunu belirtmekteyiz. Son olarak da sınıflandırma veri setimize isim vererek verilerimizi işleme sürecini başlatıyoruz.

Şekil 3.4. NVIDIA DIGITS - Veri Seti Oluşturma Arayüzü

İşlenerek eğitilmiş veri setimizden elde ettiğimiz sınıflandırma veri setimizi oluşturduktan sonra bir sonraki basamağa geçmiş olmaktadır. Bir sonraki basamak olan model oluşturma işlemi aşağıda da görülebileceği üzere önceden eğitilmiş ve hazırlanmış veri setimizden oluşturulmuş sınıflandırma veri setimizin belirlenmesi ile başlamaktadır. Burada seçtiğimiz sınıflandırma veri setimizin özelliklerini de görerek sol üstten seçebilmekteyiz. Bu durum birden fazla sınıflandırma veri seti oluşturulduğu durumlarda seçilecek işlenmiş veri setinin kolayca ayırt edilebilmesi açısından fayda sağlamaktadır. Sınıflandırma veri setinin belirlenmesinin ardından modelimiz için gerekli görülen uygun isterler girilip, kullanmak istediğimiz sinir ağını ve kütüphaneyi seçiyoruz. Yürüttüğümüz çalışmamızda Torch kütüphanesi ve AlexNet sinir ağını seçmiş bulunmaktayız. Eğer istenirse AlexNet sinir ağı modelinin üzerinde oynamalar yaparak çalışmamız için daha uygun hale getirebilmekteyiz fakat biz varsayılan AlexNet sinir ağını kullanmış bulunmaktayız. Son olarak, isim verdiğimiz modelimizi oluşturma aşamasına geçmekteyiz.

DIGITS
New Model
cagla (Logout)
Info
About

New Image Classification Model

Select Dataset

c1

Done 08:51:11 PM
Image Size
256x256
Image Type
GRAYSCALE
DB backend
lmdb
Create DB (train)
2523 images
Create DB (val)
842 images

Solver Options

Training epochs 30

Snapshot interval (in epochs) 1

Validation interval (in epochs) 1

Random seed [none]

Batch size [network defaults] multiples allowed

Batch Accumulation

Solver type SGD (Stochastic Gradient Descent)

Base Learning Rate 0.01 multiples allowed

☐ Show advanced learning rate options

Data Transformations

Subtract Mean Image

Crop Size none

Python Layers

Server-side file

☐ Use client-side file

Standard Networks
Previous Networks
Pretrained Networks
Custom Network

Caffe
Torch
Tensorflow

Network	Details	Intended image size
☐ LeNet	Original paper [1998]	28x28 (gray)
☒ AlexNet	Original paper [2012]	256x256 Customize
☐ GoogLeNet	Original paper [2014]	256x256

Group Name

Model Name


Create

Şekil 3.5. NVIDIA DIGITS – Model Oluşturma Arayüzü

Ayrıca, LSVRC-2010 eğitim setindeki 1.3 milyon yüksek çözünürlüklü görüntüyü 1000 farklı sınıfa ayırmak için büyük, derin bir evrimsel sinir ağı kurup modelleyen ve bu sayede ImageNet'in 2012 yılında gerçekleştirdiği yarışmayı kazanarak adını bu alanda ilk sıralara yazdıran AlexNet'in sahip olduğu derin öğrenme mimarisi ile tasarlanan model aşağıdaki şekildedir. Çalışmamızda da bu sinir ağından yararlanılmıştır (Krizhevsky ve ark. 2012, s:1097-1105). 25 katmandan

oluşan AlexNet sinir ağının içeriği aşağıdaki şekilde listelenmiştir (Doğan ve Türkoğlu, 2018, s:10-21).

- 5 adet evrişimsel katman
- 3 adet maxpool katmanı
- 2 adet dropout katmanı
- 3 adet tam bağlı katman
- 7 adet Relu katmanı
- 2 adet normalizasyon katmanı
- Softmax katmanı
- Giriş katmanı
- Çıkış yani sınıflandırma katmanı




Şekil 3.6. AlexNet Ağ Mimarisi (Doğan ve Türkoğlu, 2018)

Oluşturulmuş bu mimariye göre ilk aşamalar Evrişimsel (Convolution(conv)) ve Havuzlama (Pooling (pool)) katmanlarından oluştuğu görülmektedir. Son aşama ise Tam Bağlı katmanlar devreye girer ve Sınıflandırma katmanı ile son bulmaktadır (İnik ve Ülker, 2017, s:85-104).

Yürütülen çalışmada veri ham olarak giriş katmanından sinir ağına verilmektedir. Evrişimsel katmana geçiş yapıldığında bu katmanda veri filtrelenerek özellik haritası oluşturulur. Diğer bir deyişle bu katmanda istenilen sınıflandırmaya ait belirleyici özellikler burada sistem tarafından saptanmaktadır. Ayrıca kullanılan verinin önemli bölümleri yine bu katmanda belirlenmektedir. Evrişimsel katmanın


ardından gelen ReLu katmanı (Rectified Linear Units Layer–Düzleştirilmiş Doğrusal Birim Katmanı) aktifleştirme katmanı olarak da bilinmektedir. Evrişim katmanı da doğrusal olan ağı doğrusal olmayan yapıya sokmak için kullanılmaktadır. En önemli özelliklerinden bir diğeri ise sistemin daha hızlı öğrenmesini sağlamasıdır. ReLu katmanından çıkan verdiğimiz veriler genellikle havuzlama katmanına geçmektedir. Bu katmanda arkasından gelecek evrişimsel katmana hazırlık sağladığı bilinmektedir. Bu katman, verilerin giriş boyutunu azaltmayı amaçlamaktadır. Bu bilgi kaybına neden olsa dahi veri yükünü hafiflettiği için sinir ağıma olumlu yansımaktadır. Bu sayede hem sinir ağından geçen verilerin geçiş hızı artacaktır hem de öğrenme süresi kısılacaktır. Ayrıca bu katman sayesinde verdiğimiz verileri sistemin ezberlemesinin önüne geçilerek, bu konuda görev yapması sağlanmaktadır. Tam bağıntılı katman ise kendinden önceki katmanın tüm alanlarına bağlı bulunan katmandır. Genellikle mimarinin sonlarına doğru bulunur. Sınıflandırma sonuçlarını optimize etmek için kullanılabilmektedir. DropOut katmanı ezberlemenin önünde geçmeyi hedefleyen bir diğerkatmandır. Sinir ağıının bazı noktalarının kaldırılması ile gerçekleştirilmektedir. Normalizasyon katmanında ağıın performansı açısından önemli görölmektedir. Bu katmanda, süreçte ilerleyen veriler düzenlenmektedir (Ioffe ve Szegedy, 2015, s:448-456). Softmax katmanı, önceki katmandan gelen değerleri alarak sınıflandırma sürecinde verdiğimiz görüntünün hangi sınıfa daha yakın olduğuna dair olasılık üretir. Kısacası verdiğimiz görüntünün her bir sınıfa göre ihtimalini ortaya çıkartır (Tang, 2013). Sınıflandırma katmanı ise sinir ağıımızda son basamaktır. Katmanın çıkış değeri sınıflandırması yapılacak nesne sayısına eşit olmaktadır. 1'e en yakın sonucu üreten çıkış, sistem tarafından tahmin edilen nesneyi işaret etmektedir (İnik ve Ülker, 2017).




Şekil 3.7. Katmanların dizilişleri

Genel olarak özetlemek istersek yürüttüğümüz çalışmanın ilerleme sürecini, sırasıyla veri seti düzenleme, sınıflandırma veri seti oluşturma, model oluşturma ve testi gerçekleştirip çıktıları alma basamakları şeklinde ilerlemekteyiz.

Oluşturulan bu mimaride, sınıflandırma veri seti ile oluşturulan modelimizi test ederken, sınıflandırma işlemi aşamasında öncelikle pikseller incelenmekte ve daha sonra kenarlara odaklanılmaktadır. Bu aşamalardan sonra ise nesnelerin parçalarına ilerleyip son olarak da nesneler ön plana çıkmaktadır. Kısacası bir sınıflandırma işlemi testi yapılırken parçadan bütüne doğru bir ilerleme söz konusu olmaktadır.




Şekil 3.8. Görüntü İşlenme Süreci 1 (Abdelkareem, 2018)




Şekil 3.9. Görüntü İşlenme Süreci 2 (Lee, 2009)

Oluşturulan modelin işlem esnasında gerçek zamanlı olarak takibi yapılabilir. Model oluşturma işlemi sonlandığında ise oluşturulan model ile ilgili çıktılar görülmektedir. Bunda kullanılan görüntü büyüklükleri, tonlama özellikleri, veri seti, bu veri setine bağlı eğitim verisi ve doğrulama verilerine ilişkin bilgiler gözükmemektedir. Kendi oluşturduğumuz modelde Torch kütüphanesi ve AlexNet sinir ağı kullanıldığı için aşağıda da eğitilen Torch kütüphanesine ve AlexNet sinir ağına bağlı model ile ilgili bilgiler yer almaktadır. Ayrıca NVIDIA DIGITS bize görsel öğeler sunmaktadır. Bize sunulan görsel öğeler yürüttüğümüz işlemimizi görselleştiren niteliktedir. Sunulan görsel öğelerden işlem yürütüldüğü süre boyunca birincisinde eğitim verilerimizin kaybı ve doğruluğu anlık olarak


gösterilmekteyken ikincisinde sistemimizin model oluştururken öğrenme oranını anlık olarak görebilmekteyiz. Daha sonra işlem bitirildiği zaman bize son olarak bu iki görselin tamamlanmış halini vermektedir.




Şekil 3.10. Sınıflandırma Veri Seti Sonucu



Şekil 3.10. Devam. Sınıflandırma Veri Seti Sonucu



Şekil 3.11. Model Sonucu



Şekil 3.11. Devam. Model Sonucu

Veri setimizi sınıflandırma alanında eğittik ve modelimizi oluşturduk. Artık sistemimizin yüzlerdeki belirlediğimiz ifadeleri öğrenmesini beklemekteyiz. Verilerin isimlerini .txt formatında liste oluşturup sisteme vererek toplu sınıflandırma işlemi gerçekleştirebileceğimiz gibi tek tek sistemimize sunarak da işlem sonuçlarını görebilmekteyiz.

All classifications

Path	Top predictions					
1 /home/cagla/Resimler/list2/0001.jpg	notr 52.35%	mutlu 26.05%	mutlu 12.33%	korkmus 4.29%	kizgin 3.71%	
2 /home/cagla/Resimler/list2/0002.jpg	mutlu 61.26%	notr 17.6%	kizgin 0.55%	korkmus 0.2%	sasirmis 0.16%	
3 /home/cagla/Resimler/list2/0003.jpg	mutlu 93.76%	notr 4.97%	mutlu 0.56%	sasirmis 0.37%	korkmus 0.2%	
4 /home/cagla/Resimler/list2/0004.png	notr 25.82%	mutlu 24.45%	kizgin 22.49%	sasirmis 19.72%	mutlu 4.15%	
5 /home/cagla/Resimler/list2/0005.jpg	mutlu 63.83%	notr 13.35%	kizgin 1.06%	korkmus 0.7%	mutlu 0.44%	
6 /home/cagla/Resimler/list2/0006.jpg	mutlu 58.09%	notr 37.95%	mutlu 1.52%	kizgin 0.94%	korkmus 0.71%	
7 /home/cagla/Resimler/list2/0007.jpg	mutlu 51.11%	notr 19.99%	kizgin 8.65%	korkmus 6.71%	mutlu 5.77%	
8 /home/cagla/Resimler/list2/0008.jpeg	mutlu 61.2%	notr 25.88%	kizgin 3.87%	mutlu 3.3%	korkmus 2.75%	
9 /home/cagla/Resimler/list2/0009.jpg	notr 69.45%	mutlu 22.85%	kizgin 3.15%	korkmus 1.62%	mutlu 1.49%	
10 /home/cagla/Resimler/list2/0010.jpg	mutlu 74.9%	notr 21.82%	kizgin 1.05%	mutlu 0.92%	korkmus 0.73%	
670 /home/cagla/Resimler/list2/0671.jpg	notr 94.57%	mutlu 4.58%	korkmus 0.54%	sasirmis 0.3%	mutlu 0.01%	
671 /home/cagla/Resimler/list2/0672.jpg	notr 97.13%	mutlu 2.11%	sasirmis 0.47%	korkmus 0.28%	mutlu 0.02%	
672 /home/cagla/Resimler/list2/0673.jpg	notr 92.61%	sasirmis 3.12%	mutlu 2.44%	korkmus 1.81%	mutlu 0.02%	
673 /home/cagla/Resimler/list2/0674.jpg	notr 89.71%	mutlu 0.19%	mutlu 0.05%	kizgin 0.03%	tiksinmis 0.01%	
674 /home/cagla/Resimler/list2/0675.jpg	notr 91.58%	mutlu 7.32%	korkmus 0.82%	sasirmis 0.22%	mutlu 0.06%	
675 /home/cagla/Resimler/list2/0676.jpg	notr 90.83%	mutlu 8.21%	mutlu 0.4%	korkmus 0.35%	sasirmis 0.21%	
676 /home/cagla/Resimler/list2/0677.jpg	notr 99.57%	mutlu 0.41%	kizgin 0.01%	korkmus 0.01%	mutlu 0.01%	
677 /home/cagla/Resimler/list2/0678.jpg	notr 92.46%	mutlu 6.21%	korkmus 0.98%	sasirmis 0.28%	mutlu 0.05%	
678 /home/cagla/Resimler/list2/0679.jpg	notr 69.63%	mutlu 29.56%	korkmus 0.47%	sasirmis 0.31%	mutlu 0.01%	
846 /home/cagla/Resimler/list2/0847.jpg	mutlu 48.11%	notr 30.04%	korkmus 6.34%	kizgin 5.69%	mutlu 4.23%	
847 /home/cagla/Resimler/list2/0848.jpg	mutlu 90.58%	notr 6.42%	kizgin 0.86%	sasirmis 0.75%	korkmus 0.6%	
848 /home/cagla/Resimler/list2/0849.jpg	sasirmis 32.58%	mutlu 23.47%	notr 22.41%	korkmus 19.23%	kizgin 0.82%	
849 /home/cagla/Resimler/list2/0850.jpg	kizgin 95.64%	notr 3.76%	mutlu 0.4%	mutlu 0.11%	tiksinmis 0.08%	
850 /home/cagla/Resimler/list2/0851.jpg	mutlu 49.74%	notr 42.26%	kizgin 2.87%	korkmus 1.87%	mutlu 1.45%	
851 /home/cagla/Resimler/list2/0852.JPG	notr 35.29%	mutlu 19.86%	sasirmis 17.48%	kizgin 10.93%	korkmus 8.08%	
852 /home/cagla/Resimler/list2/0853.jpg	sasirmis 44.14%	korkmus 42.04%	mutlu 6.96%	notr 6.22%	mutlu 0.39%	
853 /home/cagla/Resimler/list2/0854.jpg	mutlu 89.54%	notr 9.6%	kizgin 0.51%	korkmus 0.13%	sasirmis 0.1%	
854 /home/cagla/Resimler/list2/0855.jpg	mutlu 82.67%	notr 11.49%	kizgin 2.43%	mutlu 1.38%	korkmus 0.99%	

Şekil 3.12. Yapılan Çoklu Sınıflandırma Çalışmasından Örnek Sonuçlar

Bu aşamada sonuçları almadan önce belirtmemiz halinde eğer istersek sonuçları görselleştirebilmekteyiz. Büyük verilerde çoklu tarama tercih edilmektedir fakat sınıflandırma açısından eğittiğimiz veri seti ve oluşturduğumuz modeli test etmek için tekli işlem her zaman daha ön plana çıkmaktadır. Diğer bir deyişle test aşamasında başarı sonucunu tekli sınıflandırma işlemlerinde daha net görebilmekteyiz. Gerçekleştirdiğimiz çalışmadan birer örnek aşağıdaki şekilde derlenmiştir.


Çizelge 3.1. Yapılan Tekli Sınıflandırma Çalışmasından Örnek Sonuçlar

Görüntü	Tahmin	Yüzdelik
	Kızgın	69.1%
	Nötr	10.77%
	Şaşırmış	8.99%
	Korkmuş	5.75%
	Mutsuz	5.15%
	Mutlu	77.29%
	Kızgın	16.94%
	Mutsuz	2.66%
	Korkmuş	2.3%
	Nötr	0.44%
	Şaşırmış	77.29%
	Korkmuş	16.94%
	Nötr	2.66%
	Kızgın	2.3%
	Mutsuz	0.8%
	Korkmuş	48.65%
	Mutsuz	15.7%
	Şaşırmış	15.4%
	Mutlu	11.25%
	Nötr	4.87%
	Mutsuz	70.57%
	Kızgın	16.46%
	Nötr	6.03%
	Korkmuş	5.24%
	Şaşırmış	1.26%
	Nötr	73.67%
	Şaşırmış	10.48%
	Korkmuş	9.25%
	Kızgın	3.14%
	Mutsuz	2.69%


3.2. DENEYSEL KAPSAMINDA GERÇEKLEŐTİRİLEN MCNEMAR TESTİ

Bir sonraki adli yaklařım basamađına geilmeden nce yrtlecek alıřmanın bařarı oranının ekilebilecek en st seviyede olması beklendiđi iin AffectNet Database ve MUG Facial Expression Database Veri Setlerinden oluřturulan tek bir sınıflandırma veri seti kullanılarak, 2 farklı ktphanenin ve 2 farklı sinir ađının kombinasyonlarından elde edilen drt farklı sınıflandırma model sonucunun deđerlendirilmeye tabi tutulması gerekmektedir. Bu karřılařtırma iin McNemar testinin kullanılması uygun grlmřtr. McNemar testinde, bu drt farklı kombinasyonun hepsinde aynı 1000 farklı grsel test etmek iin kullanılmıř olup bu 1000 grselden 999 adeti bařarılı řekilde test edilmiřtir. Bu iřlem esnasında her kombinasyonun testinde aynı olan 1 grsel hata vermiřtir. Bunun nedenin ise bahsi geen o grselden kaynaklı hata olduđu, diđer bir deyiřle ne sinir ađları ne de ktphanelerin iřleyiři veya iřlem srecinde karřılařtıđı bir sorundan kaynaklı olmadıđı deđerlendirilmiřtir.


Bu bahsi geen 1000 grsel ile drt farklı eđitilmiř model olan Caffe-AlexNet, Caffe-GoogLeNet, Torch-AlexNet, Torch-GoogLeNet kullanılarak yrtlen testlerden elde edilen drt farklı sonu elde edilmiřtir. Bu sonulara ait grseller ařađıdaki řekildedir.




Şekil 3.13. Yapılan Caffe-AlexNet Çalışması



Şekil 3.14. Yapılan Caffe-GoogLeNet Çalışması



Şekil 3.15. Yapılan Torch-AlexNet Çalışması



Şekil 3.16. Yapılan Torch-GooLeNet Çalışması

Daha sonra Caffe-AlexNet, Caffe-GoogLeNet, Torch-AlexNet, Torch-GoogLeNet için gerçekleştirilen 4 farklı testten başarılı çıkan 999 görselin sonucu ile elimizdeki bu 1000 görselden testten başarılı çıkan 999 adeti bire bir insan gücüyle karşılaştırılmıştır. Sistemin verdiği doğru sonuçlar için “1” yanlış sonuçlar için ise “0” değerlendirmesi yapılmıştır. Bu şekilde, Caffe-AlexNet, Caffe-GoogLeNet, Torch-AlexNet, Torch-GoogLeNet olmak üzere dört farklı modelden elde ettiğimiz sonuçlar için doğru yanlış yani “1” ve “0” listesi hazırlanmıştır. Bu listeler için Excel çalışma ortamı tercih edilmiştir. Aşağıda örnek olarak kesitleri gösterilmiştir. Daha sonra listeler oranlar açısından bir birleri ile karşılaştırıldığı ve bir birlerinden ne kadar farklılaştığının tespiti için kullanılmıştır. Kısacası bu doğru olan kütüphane ve sinir ağını seçmek için gerçekleştirilmiş bir karşılaştırma testidir.

Görsel Numarası	Caffe		Torch		Framework Network
	AlexNet	GoogLeNet	AlexNet	GoogLeNet	
1	1	0	1	0	
2	1	1	1	1	
3	1	1	1	1	
4	1	1	1	1	
5	1	1	1	1	
6	1	1	1	1	
7	1	1	1	1	
8	1	1	1	1	
9	1	0	1	0	
10	1	1	1	1	



500	1	1	1	1
501	1	1	1	1
502	1	1	1	1
503	1	1	1	1
504	1	1	1	1
505	1	1	1	1
506	1	1	1	0
507	1	1	1	1
508	0	1	1	1
509	1	0	1	1
510	1	0	1	1



989	1	1	1	1
990	0	1	0	1
991	1	1	1	1
992	1	1	1	1
993	1	1	1	1
994	0	0	0	1
995	1	1	0	1
996	0	1	0	0
997	0	1	1	0
998	0	0	0	0
999	1	0	0	0

Şekil 3.17. Yapılan Çalışmadan Örnek Sonuçlar

Kategorik özellikteki iki değişken bağımlılık gösteriyorsa ve değişkenlerin aldıkları değerler iki kategoride toplanıyorsa (2x2) bu değişkenlerin karşılaştırmasında McNemar testi kullanılır. Bu testi uygulayabilmek için bir gruptan alınan bilgiler bir işlemde önce-sonra ya da değişik iki işleme göre belirli bir özelliği gösteren ve göstermeyenler olarak iki ayrı grup oluşturmak üzere düzenlenebilir. Bizim için uygun olan ise belirli bir özelliği gösterip

göstermemesidir. Daha açık belirtmek gerekirse sistemlerin doğru sonuç verip vermemesidir.

Çizelge 3.2. McNemar Test Tablosu

		2.işlem	
		Başarılı (Successful (S))	Başarısız (Fail (F))
1.işlem	Başarılı (Successful (S))	a	b
	Başarısız (Fail (F))	c	d

“a, b, c, d” frekans değerleridir. Böyle bir tabloda iki grup arasındaki farkı belirleyen ve etki gösteren değerler c ve b değerleridir.

Eğer iki grup arasında bir fark yoksa, her iki yönde grup değiştiren (başarılıdan, başarısız ve başarısızdan, başarılıya) birimlerin sayısı eşit oranda olup bunlara ait beklenen değer de $(b+c)/2$ olacaktır.

Normalde McNemar formülünde b ve c’ye ait değerler yerlerine koyulursa aşağıdaki şekilde formül elde edilmektedir.

$$\chi^2 = \frac{(b - c)^2}{b + c}$$

Formül bu şekilde elde edilmektedir fakat biz çalışmamızda McNemar’ı Edward süreklilik düzeltmesi eklenmiş versiyonu kullanacağız (Madrigal, 2012). Bir çok uzman teorik ve hesaplanan değerlerin arasındaki farkın minimum değerlere çekilebilmesi için dört gözlü olarak düzenlenen test tablolarında bu düzeltmenin yapılmasını uygun bulmaktadır.

$$x^2 = \frac{(|b - c| - 1)^2}{b + c}$$

Yukarıdaki formül bizim McNemar testini gerçekleştirirken kullanacağımız formüldür (Bostancı B ve Bostancı E. 2013, s:15-26).


McNemar testinde kullanılan serbestlik derecesi formülü bu şekildedir:

$$\text{Serbestlik derecesi} = (\text{sıra sayısı} - 1) \times (\text{sütun sayısı} - 1)$$

Yanılma yüzdesini de belirleyerek tabloda 1-100 serbestlik derecelerine karşı alfanın 0.995, 0.99, 0.975, 0.9, 0.10, 0.05, 0.025, 0.01, 0.005 değerleri için kritik McNemar Ki Kare değerleri üzerinden giderek uygun değeri belirlemekteyiz.

Çizelge 3.3. Ki Kare Test Tablosu

Alfa S.D.	0.05
1	3.84



Şekil 3.18. Güven Aralığı Grafiği

Biz çalışmamızda tek kuyruk değerlerini kullanacağız. Araştırmanın yönü ile ilgili emin bir duruş sergileyemeseydik çift kuyruğa yönelebilirdik fakat bizim

istediğimiz hipotez sonucunda emin olduğumuz için tek kuyruk yaklaşım değerini kullanabilmekteyiz.

Çizelge 3.4. McNemar Test z score Tablosu

z score	One-tailed Prediction	Two-tailed Prediction
1.645	95%	90%
1.960	97.5%	95%
2.326	99%	98%
2.576	99.5%	99%

Test iki tane hipotez üzerinden kurulmaktadır. Bunlardan birincisi fark yoktur ikincisi ise fark vardır şeklinde oluşturulmuştur. Bu hipotezler sırasıyla H_0 ve H_1 şeklinde adlandırılmaktadır. Testi yaparken ilk basamak olarak hipotezleri daha sonra ise testin gereklilikleri olan değişkenleri belirliyoruz. Değişkenleri belirlemeye öncelikle serbestlik derecesini (sd) belirlemek ile başlıyoruz. Daha sonra ise alfa (α) yani yanılma yüzdesini belirlemekteyiz. Bahsi geçen serbestlik derecesini ve yanılma yüzdesini kullanarak da McNemar tablo değerini belirlemiş oluyoruz. Değişkenler belirlendikten ve McNemar testi tablo değeri bulunduktan sonra karşılaştırma yapmamız gereken, bizim deneyimizden elde ettiğimiz sonuçlar ile yapılan McNemar testi sonuçlarını karşılaştırmamız gerekmektedir. Bunun için deneysel McNemar testi sonuçlarımızı McNemar testi formüllerini ve Excel’de oluşturduğumuz doğru-yanlış değerlerini kullanarak kendi hesaplarımızı yapıyoruz. Testin deneysel olarak hesaplanan McNemar testi değerini belirleyip karşılaştırıyoruz. Eğer tablo değeri hesaplanan değerden büyük ise H_0 hipotezini kabul ediyoruz. Yani fark yoktur sonucu çıkarılmaktadır. Diğer taraftan hesaplanan McNemar testi değeri tabloda bulunan McNemar testi değerinden büyük ise farkın var olduğunu söyleyen H_1 hipotezini kabul ediyoruz.

Tezde bu test 4 farklı kombinasyon için de ayrı ayrı uygulanmıştır. Sırasıyla

uygulama şekli aşağıdaki şekilde gerçekleştirilmiştir. Tabloda, a ve d değerleri McNemar testini etkileyen değerler olmadığı için a ve d değerleri tablolara alınmamıştır. Oluşturulan karşılaştırma McNemar testi tabloları sırasıyla aşağıda gösterilmiştir. Ayrıca, McNemar testi yapılırken ve tablolar oluşturulurken kullanılan belirleyici unsurlar her test için aynı tutulmuş olup tablolar gösterilmeden önce belirtilmiştir.

- Hipotezler;
 - H_0 : Fark yoktur.
 - H_1 : Fark vardır.
- $\alpha = 0.05$
- $sd = 1$
- χ^2 Tablo Değeri = 3.84
- Z Score Tablo Değeri = 2.576 (99.5%)

1. Caffe sabit tutularak AlexNet ve GoogLeNet değişken olarak kullanılmıştır. Gerçekleştirilen teste ait tablo aşağıdaki şekildedir.

Çizelge 3.5. Caffe Sabit Tutulup AlexNet ve GoogLeNet değişkenlerinin Değerlendirildiği McNemar Test Tablosu

		Caffe - AlexNet	
		S	F
Caffe - GoogLeNet	S	a	110
	F	140	d

$$\chi^2 = \frac{(|140 - 110| - 1)^2}{140 + 110}$$

- McNemar χ^2 Test Değeri = 1.83412

- χ^2 tablo değeri $> \chi^2$ test değeri, bu yüzden H_0 hipotezi kabul edilmektedir ve farklılık yoktur demektir.
- Z score tablo değeri karşılaştırıldığında 95%'ten yüksektir diyebiliriz.

2. Torch sabit tutularak AlexNet ve GoogLeNet değişken olarak kullanılmıştır. Gerçekleştirilen teste ait tablo aşağıdaki şekildedir.

Çizelge 3.6. Torch Sabit Tutulup AlexNet ve GoogLeNet değişkenlerinin Değerlendirildiği McNemar Test Tablosu

		Torch - AlexNet	
		S	F
Torch- GoogLeNet	S	a	92
	F	141	d

$$\chi^2 = \frac{(|141 - 92| - 1)^2}{141 + 92}$$

- McNemar χ^2 Test Değeri= 3.14458
- χ^2 tablo değeri $> \chi^2$ test değeri, bu yüzden H_0 hipotezi kabul edilmektedir ve farklılık yoktur demektir.
- Z score tablo değeri karşılaştırıldığında 99.5%'ten yüksektir diyebiliriz.

3. AlexNet sabit tutularak Caffe ve Torch deęişken olarak kullanılmıştır. Gerçekleştirilen teste ait tablo aşağıdaki şekildedir.

Çizelge 3.7. AlexNet Sabit Tutulup Caffe ve Torch Deęişkenlerinin Deęerlendirildięi McNemar Test Tablosu

		Caffe - AlexNet	
		S	F
Torch-AlexNet	S	a	197
	F	78	d

$$\chi^2 = \frac{(|197 - 78| - 1)^2}{197 + 78}$$

- McNemar χ^2 Test Deęeri= 7.115668
- χ^2 tablo deęeri < χ^2 test deęeri, bu yüzden H_1 hipotezi kabul edilmektedir ve farklılık vardır demekteyiz.
- Z score tablo deęeri karşılaştırıldığında 99.5%'ten yüksektir diyebiliriz.

4. GoogLeNet sabit tutularak Caffe ve Torch deęişken olarak kullanılmıştır. Gerçekleştirilen teste ait tablo aşağıdaki şekildedir.

Çizelge 3.8. GoogLeNet Sabit Tutulup Caffe ve Torch Deęişkenlerinin Deęerlendirildięi McNemar Test Tablosu

		Caffe - GoogLeNet	
		S	F
Torch-GoogLeNet	S	a	191
	F	91	d

$$\chi^2 = \frac{(|191 - 91| - 1)^2}{191 + 91}$$

- McNemar χ^2 Test Değeri= 5.895364
- χ^2 tablo değeri < χ^2 test değeri, bu yüzden H_1 hipotezi kabul edilmektedir ve farklılık vardır demektir.
- Z score tablo değeri karşılaştırıldığında 99.5%'ten yüksektir diyebiliriz.

Yürütülen testlere göre elde edilen sonuçlar değerlendirildiğinde yapılacak deneysel çalışmamızda kullanılacak en uygun sinir ağının AlexNet, en uygun kütüphanenin ise Torch olduğu gözükmemektedir.

3.3. NVIDIA DIGITS ile GERÇEKLEŞTİRİLEN DENEYSEL ÇALIŞMA

NVIDIA DIGITS ile yürütülen deneysel çalışmalarda üç farklı sinir ağı ile iki farklı kütüphane kullanılmıştır. Kullanılan üç farklı sinir ağı LeNet, AlexNet ve GoogLeNet iken kullanılan kütüphaneler Caffe ve Torch'tur. Öncelikle testlere başlanırken bu üç sinir ağı ile iki kütüphanenin kombinasyonları düşünülmüş ve deneme testleri yapılmıştır. Denemeler üzerine testlerde LeNet elenmiştir. Bunun nedeni ise LeNet'in gereksinimi olan 36x36 piksel (pxl) boyutun, kullanılan veri setine uygun olmaması durumudur.

Daha önce elde ettiğimiz veri setimiz olan Pierre-Luc Carrier ile Aaron Courville'in eğitim setinde toplamda, 48x48 piksel gri tonlamalı 28.709 örnek görüntü bulunmaktayken bunları 36x36 pxle çekerek elde ettiğimiz sonuçlar tatmin edici olmuştur. Diğer taraftan esas kullandığımız veri setlerimiz olan AffecNet Database ve MUG Facial Expression Database için durum daha farklı olacaktır. Çünkü bahsi geçen iki veri setindeki görsellerin piksel boyutları Pierre-Luc Carrier ile Aaron Courville'in eğitim setinden çok daha yüksek değerlere sahiptir. AffecNet Database ve MUG Facial Expression Database veri setlerindeki görsellerin boyutları 36x36 piksel yapıldığı zaman elde edeceğimiz sonuçların Pierre-Luc Carrier ile

Aaron Courville'in eğitim setinden elde edilen sonuçlara nazaran başarısız çıkacağı aşikâr olarak değerlendirilmiştir. Zira denemek amacı ile yürütülen çalışmada Caffe- LeNet kombinasyonu denenmiş olup sonuçların tez çalışmamızda istediğimiz ve beklediğimiz sürece katkısının olmayacağı değerlendirilmiştir. Sonuç olarak LeNet'in çalışmalarımızda yeterli performansı gösteremeyeceği kanaatine varıldığından ötürü tezin ilerisindeki deneysel çalışmalarda test ortamına dahil edilmemiştir.

Literatürde LeNet ile yapılan çalışmalar incelenmiş olup bir tanesinden yola çıkılarak örnek verme gereksinimi duyulmuştur. Bunun için LeCun ve ark. (1998) tarafından yürütülmüş "Gradient-based learning applied to document recognition" çalışmasını inceleyebiliriz. Söz konusu çalışmaya bakıldığında zaman küçük boyutlu görseller kullanıldığı görülmektedir. Örneğin sadece rakamlar ve çizgilerden oluşan görseller seçilmiştir. Aşağıda bulunan görsel buna örnek olarak gösterilebilir. Bunun nedeninin ise LeNet'in küçük boyutlu görsellerde başarılı olurken bizim kullanacağımız veri setlerindeki görseller gibi büyük çaplı görsellerde yetersiz kalacağıdır. Kullandığımız veri setindeki görselleri LeNet'in gereksinimi olan boyutlara göre küçülttüğümüzde başarısız olacağını bu çalışmanın çıktıları öngörmemizi sağlamıştır.



Şekil 3.22. LeNet ile Yapılan Çalışmadan Örnek Görüntü (LeCun ve ark., 1998)

3.4. NVIDIA DIGITS ile ADLİ AÇIDAN YÜRÜTÜLEN DENEYSEL ÇALIŞMA-1

Deneyisel olarak Pierre-Luc Carrier ile Aaron Courville'in eğitim setini kullanarak elde ettiğimiz sınıflandırma veri seti ile model oluşturulmuştur. Sonrasında deneyisel çalışmamızı gerçekleştirmek amacı ile söz konusu model ile adli vakaya yaklaşım çalışması gerçekleştirilmiştir.

19 Aralık 2016 tarihinde, Ankara Çağdaş Sanatlar Merkezi'nde, Rusya'nın Ankara Büyükelçiliği ve Çankaya Belediyesi işbirliğiyle gerçekleştirilen "Gezgin Gözüyle Kaliningrad'dan Kamçatka'ya Rusya" adlı fotoğraf sergisi gerçekleşmiştir. Açılış konuşması için kürsüye çıkan Rusya'nın Ankara Büyükelçisi Andrey Karlov, bu sırada silahlı saldırıya uğramıştır.

Rusya'nın Ankara Büyükelçisi Andrey KARLOV'un katil zanlısı M. M. ALTINTAŞ'ın cinayeti işledikten sonraki bağırması kameralara yansımıştır (Aljazeera, 2016). Gerçekleştirilen çalışmada ise ALTINTAŞ'ın görüntülerden bir örnek görüntü seçilmiş ve bu görüntü kullanılmıştır.



Şekil 3.23. Adli Görüntü ile Yapılan Çalışma

ALTINTAŞ'ın görüntüsünden yola çıkarak, Torch – AlexNet kütüphane ve sinir ağı çifti kullanılarak gerçekleştirilen adli yaklaşımlı deneysel çalışmadan elde edilen sonuç aşağıdaki şekilde olmuştur.

Çizelge 3.9. Adli Görüntü ile Yapılan Çalışma Sonucu 1

Görüntü	Tahmin	Yüzdelik
	Kızgın	96.35%
	Mutsuz	2.23%
	Şaşırmış	1.17%
	Mutlu	0.08%
	Korkmuş	0.06%

Katil zanlısı ALTINTAŞ'ın yüz duygu durum ifadesinde %96.35 kızgın, %2.23 mutsuz, %1.17 şaşırmış, %0.08 mutlu, %0.06 korkmuş şeklinde sonuç elde edilmiştir.

3.5. NVIDIA DIGITS İLE ADLİ AÇIDAN YÜRÜTÜLEN DENEYSEL ÇALIŞMA-2

İntihar, bir kimsenin toplumsal ve ruhsal nedenlerin etkisi ile kendi hayatına son vermesi olarak TDK'de tanımlanmaktadır. Yasalarımıza göre ise her intihar olayı adli bir olay olup adli tıbbi ve hukuki olarak iyi incelenmesi gereken bir durumdur (Bulut, 2012, s:128-137). Bu nedenle bir intihar olgusuna ait görüntüler kullanılarak yürütülen deneysel çalışma, adli yaklaşımda bulunmak istediğimiz deneysel çalışmamıza katkı sağlayacaktır.

Osmaniye'nin Düziçi İlçesi'nde 22 yaşındaki Erdoğan CEREN, sosyal paylaşım sitesi Facebook hesabından canlı yayın yaptığı esnada av tüfeği ile karnına ateş ederek yaşamına son verdiği ile ilgili haberler çıkmıştır (EMÜL, 2016). Bu haberlerde Erdoğan CEREN'in yayınlanan fotoğraflarından yola çıkılarak deneysel bir çalışma gerçekleştirilmiştir. Görüntüler intihar eden CEREN'in yayınladığı videodan elde edilen görüntüler olup, yürütülen çalışmada söz konusu kişinin yüzünden duygu durum ifadesi değerlendirilmesi yapılmıştır.



Şekil 3.24. Adli Görüntü ile Yapılan Çalışma

Yukarıdaki intihar vakasına ait görüntüler kullanılarak yürütülen çalışmada AffectNet Database ve MUG Facial Expression Database veri setleri kullanılarak öncelikle sınıflandırma veri seti kullanılmış olup, daha sonra bu sınıflandırma veri setinden model oluşturulmuş ve kullanılmıştır. Kullanılan model ile gerçekleştirilen deney sonrasında da elde edilen sonuç aşağıdaki şekildedir.

Çizelge 3.10. Adli Görüntü ile Yapılan Çalışma Sonucu 2

Görüntü	Tahmin	Yüzdelik
	Mutsuz	57.3%
	Kızgın	24.73%
	Korkmuş	7.59%
	Mutlu	5.58%
	Şaşırmış	2.06%

Erdoğan CEREN'in yüz duygu durum ifadesine bağlı sistemden alınan çıktılar doğrultusunda, %57.3 mutsuz, %24.73 kızgın, %7.59 korkmuş, %5.58 mutlu ve %2.06 şaşırmış şeklinde sonuç elde edilmiştir.

4. TARTIŞMA

Tez kapsamında NVIDIA Digits ile gerçekleştirilen kategorize çalışmaları genel anlamda yüz duygu durumları ve bu alandaki adli açıdan yaklaşımının belirlenmesi değerlendirilmiştir. Bu alanda adli açıdan değerlendirmeler yapılırken deneysel çalışmada başarı oranlarının adli açıdan yaklaşımlara uygun olup olmayacağı değerlendirilmiştir. Adli yaklaşımlı duygu durum ifadesi kategorize çalışmasının adli vakalarda sadece bizim örneklemelerimizde kullandığımız adli olgu konularında değil aynı zamanda birçok adli vaka alanında da kullanılabileceği düşünülmektedir. Bu çalışma, özellikle söz konusu adli vakalarda, insanların olay anındaki görüntülerinden yola çıkarak o anki ifadelerini değerlendirip şüphelilerin ve/veya mağdurların belirlenmesinde kullanılabileceği, bu esnada ise hem objektif bir yaklaşım sunacağı, hem de zaman kazanımı sağlayacağı düşünülmektedir.

Ek olarak zanlıların suç işledikleri esnada, duygu durumlarının belirlenmesinde ve alacakları cezaların belirlenmesinde faydalı olacağı düşünülmektedir. Aynı şekilde olayın gerçekleşme anından sonraki tavır ve tutumlarındaki duyguların da belirlenebileceği öngörülmektedir. Bu şekilde iyi hal indirimi gibi cezaya yansiyarak etkileyebilecek kararlar üzerinde de yön verebileceği düşünülmektedir.

Örneğin, eşini öldüren bir adam olay esnasında kameralara yansıyan görüntüsünde öfkeli görünmek yerine soğukkanlı donuk bir ifade ile cinayeti işliyor ise bu kişinin ağır tahrik indirimi alması söz konusu olmamalı tam tersine bu kişinin soğukkanlılıkla planlayarak bu suçu işlediğine kanıt olarak sayılabileceği düşünülmektedir. Benzer farklı bir örnek üzerinden de bunu açıklayabiliriz. Bir adli vaka fotoğraf karesi düşünün ki, fotoğrafta silahlı iki kişi ve bir kurban bulunuyor. Bir cinayet işlendiği görülüyor ve kurban yerde yatıyor. İki kişi ise kurbanın karşısında duruyor. Bu cinayeti kimin işlediğini silahlı iki kişinin yüz duygu

durumuna bakarak çıkarım yapılabileceği düşünülmektedir. Vuran kişinin yüzünde ana ifade olarak öfke veya mutsuzluk ifadelerinden birini bulmayı beklerken, yanındaki kişinin yüz duygu durumunda şaşkınlık veya korku ifadelerinden birini bulmayı beklemekteyiz. Bu şekilde kesin kanaate varılamayacağı düşünülse bile şüpheleri üstüne çekecek ve odaklanılması gereken kişiyi gösterir nitelikte olacaktır. Dahası bu unsur henüz ana kaynak olması muhtemel olmasa bile yardımcı kaynak olarak başvurulabilecek bir unsur olarak değerlendirilebileceği düşünülmektedir.

Aynı örnek üzerinden yola çıkarak yüz duygu durumunun belirlenmesi yoluna başvurmadan ilerlendiği zaman, adli olayı her açıdan değerlendirerek, sonuçlandırma ve adaleti sağlama sürecinde geçen sürenin de uzayacağı düşünülmektedir. En basitinden sorgu ve savunma kısmında harcanacak zaman artacaktır. Yapılan duygu durum ifadesi belirleme çalışmasının işaret edeceği oklardan yola çıkarak, odağın ve şüphenin tek bir kişi üzerinde yoğunlaşması gerekirken, bölünerek söz konusu kişiler üzerinde ikiye bölüneceği için adaletin sağlanacağı bu sürecin de uzaması öngörülmektedir. Dahası bu durumdan dolayı adalet için harcanan süreçte zaman kaybı yaşanmasının yanı sıra, çalışan güvenlik güçleri personelinin üzerindeki iş yükü artacağı aşîkardır.

Daha önce derin öğrenme sistemi ile adli yaklaşımda bulunan çalışmaların yapıldığı literatürde görölmektedir. Bu çalışmalardan en çok dikkat çeken, “Derin öğrenme yoluyla kıyafet tanımı: adli uygulamalar (Clothing identification via deep learning: forensic applications)” adlı çalışma olmuştur. Kullanılan veri seti ile yapılan bu çalışmada, sınıflandırmada %70’ten yüksek bir başarı oranı elde edildiği belirtilmektedir. Aynı yayında bu tarz yüzlerin ve kıyafetlerin özelliklerini karşılaştırmak üzerine kurulu sınıflandırma çalışmalarının, adli tıp uzmanları için son derece avantajlı olacağından bahsedilmektedir. Ayrıca çalışmada, özellikle gerçek zamanlı durumlarda, derin öğrenme tabanlı oluşturulan bir araç, adli tıp uzmanlarının şüpheli suçluları veya kayıp kişileri tespit etmelerini sağlamak için otomatik arama sistemlerinde kullanılabileceğinden bahsedilmektedir. Bu yapılan çalışma derin öğrenme sistemlerinin adli yaklaşım açısından benim çalışmamda da

göstermek istediğim faydalara denk nitelikte çıkarımlar sunduğu görülmektedir (Bedeli, 2018, s:219-229).

“Görsel Belirginlik ve Derin Öğrenme Kullanarak Yüz İfade Tanıma (Facial Expression Recognition using Visual Saliency and Deep Learning)” konulu makalede yürütülen çalışmalarda derin öğrenmenin temelindeki evrimsel sinir ağlarının insan ifadesi ve yüz ifadesi tanınmasında heyecan verici sonuçlar elde edildiğinden bahsedilmiştir. Bu tezde de yürütülen çalışmalara paralel olarak aynı bulgularla karşılaşmıştır. İnsan ifadesi veya yüz ifadesi tanınmasında elde edilen bulguların bu alanda umut verici olduğu üzerinde durulmuştur. Bu çıkarımın, yürüttüğümüz çalışmanın umut verici sonuçlarını destekler nitelikte olduğu aşikârdır (Mavani, 2017, s:2783-2788).


Yürütülen yüz ifadesinden duygu durum tespit çalışmalarında çok küçük görüntülerin başarı oranının oldukça düştük olduğu tespit edilmiştir. LeNet ile yürütülen deneysel çalışmamızda da bunu gözlemleme imkânı bulduğumuz ve bu yüzden LeNet ile çalışmama kararı aldığımız belirtilmiştir. Görüntü boyutu büyüdükçe elde edilen başarıda artmaktadır. Bunun nedeninin de yapay zekânın sınıflandırma yapmak için talep ettiği, öğreneceği ve kullanacağı ayırt edici özelliklerin görüntünün büyümesi ile daha belirgin hale gelmesidir. İstenirse daha ileriki çalışmalar için daha gelişmiş bir yapay sinir ağı ve algoritma oluşturularak başarı oranının arttırılabileceği düşünülmektedir. Diğer bir deyişle, daha gelişmiş bir sinir ağının şu anda kullandığımız standart yapay sinir ağına göre küçük boyutlu görüntülerde daha başarılı sınıflandırmalar yapabileceği düşünülmektedir.

Çalışmada uygun sinir ağı ve kütüphaneyi seçmek için gerçekleştirdiğimiz McNemar testinde elde edilen sonuçlar da ise Torch ve Caffé arasında fark olduğunu H_1 hipotezini elde etmemizle net görebilirken, AlexNet ve GoogLeNet arasında farkın olmadığı H_0 hipotezi görülmektedir. Çalışmada AlexNet’i bu farklılık yoktur sonucuna rağmen seçmemizin nedeni rakamsal olarak değerlendirmeden sonra AlexNet’in GoogLeNet’e göre 999 görsel arasından daha fazla doğru sonuca ulaştığını tespit etmemizdir. Diğer taraftan GoogLeNet ile de çalışma


yürütülebilineceği ve başarı oranında çok belirgin bir fark gözlemlenemeyeceği unutulmamalıdır.

Yürütülen deneysel çalışmada ne kadar fazla veri setini geri besleme yaparak sınıflandırma veri seti oluşturursak, o kadar çalışmamızın doğruluk ve başarı oranının arttığını gözlemlemiş bulunmaktayız. Çalışmadaki deneysel testlerin başlamasından sonlanmasına kadar geçen süreçte birçok geri besleme yapılmıştır. Geri besleme ve başarı oranındaki pozitif yöne sahip doğru orantılı değişimin gözlemlenmiştir. Çalışmada yapılan testler ile son başarı oranı tatmin edici olmasına karşın, testlerden elde edilen sonuçlar eğer daha fazla geri besleme ile desteklenmiş olsaydı, derin öğrenme sisteminin hatalı tespit ettiği görsellerin sayısında azalma olacağı ve bu şekilde başarı oranında da belirtildiği üzere artış olacağı öngörülmektedir.

Ek olarak çalışmalarımızda grafiksel incelemelerde de bulunulmuştur. Bunun nedeni ise eğittiğimiz sınıflandırma veri setimiz ile oluşturduğumuz modelde sistemimizin ezberleme ve öğrenememe durumlarına düşmesini engellemektir. Eğer bir sistem ezberleme ve öğrenememe durumlarına düşüyorsa aşağıdaki grafikleri bize çıktı olarak vermektedir. Buna özellikle dikkat etmek gerekmektedir. Doğrulama verisi ezberlemenin ne zaman gerçekleştiğini tespit etmemize yardımcı olmaktadır. Loss eğitim verisi azalmasına karşın doğrulama artmaktadır. Bu da bize sistemimizin ezberlemeye kaçtığını göstermektedir. Öğrenememe durumunda ise Loss artmamakta fakat doğruluk iyileşmektedir (Kurt, 2016). Bu iki grafiksel durumla karşılaşıldığında başarısız bir sistem olduğunu görmekteyiz. Oluşturduğumuz sınıflandırma veri setine ve/veya sınıflandırma modeline müdahale etmemiz gerekmektedir.



Şekil 4.1. Ezberleme



Şekil 4.2. Öğrenmeme

Yürüttüğümüz çalışmalar üzerine konuşmak gerekirse adli açıdan yaklaşımlardan bahsetmek doğru olacaktır. İki örnek üzerine de konuşmak

gerekmektedir. Çünkü iki örnekte de farklı olgular işlenmiş olup, farklı getirileri bulunmaktadır. Örneklerden ilkinin göz önünde bulunduralım. Katil zanlısının görüntülerinin işlenmesi sonucu elde edilen çıktılarının analizinde en yüksek yüzdeliğe sahip olan kızgın ifadenin gerçekten cinayet işleyen birinden beklenenecek bir ifade ile örtüştüğü görülmektedir. Buna ek olarak da ikinci en yüksek yüzdeliğin mutsuzluk ifadesi olması bize katilin duygu durumu hakkında fikir verebilmektedir. Gerçekleştirilen suç eylemi sonrası mutsuzluk da beklenen bir duygu durum ifade biçimi olarak kabul edilebilmektedir.

Adli açıdan yaklaşım için yapılan ikinci deneyde ise bir intihar olgusu ele alındığı bilinmektedir. İntihar eden kişinin videosundan elde edilen görüntülerle yapılan çalışmadan başarılı sonuçlar elde edildiği anlaşılmaktadır. Bunun nedeni ise intihar eden şahsın mutsuz görünmesi, içinde bulunduğu ruhsal durumdan dolayı beklenen bir yansıma olmasıdır. Bu çalışmanın bize verdiği sonuçtan yola çıkılarak yapılan değerlendirmeler ile bir intihar olgusunda nasıl faydası olacağı üzerinde durulmalıdır. Öncelikle intihar eden kişinin ruh hali unutulmamalıdır. İntihar eden kişinin duygu durumu genelde mutsuz olma eğilimindedir ve mutsuzluk da yüz ifadesine yansımaktadır. Bu gerçekler ışığında, adli açıdan incelemek istersek, olgunun intihar değil de, cinayete intihar süsü verilebileceğini göz ardı etmemek gereklidir. Bir cinayetin üstünü kapatmanın en kolay yollarından biri katil zanlılarının ölümüne intihar süsü vermeleri olduğu bilinmektedir. Bunu katillerin öldürdükten sonra da yapabildikleri gibi tehdit, şantaj ve baskılar ile de gerçekleştirdikleri bilinmektedir. Eğer bir cinayete intihar süsü veriliyorsa sözde intihar eden kişinin yüzünde ana ifadenin mutsuzluk yerine korku olması beklenmektedir.

5. SONUÇ ve ÖNERİLER

Yapay zekâ, makine öğrenmesi ve derin öğrenme günümüze kadar birçok alanda insan hayatını kolaylaştırmış olup dahası git gide hayatımızın vazgeçilmez parçası haline gelmeye başlamıştır. Her gün kullandığımız akıllı telefonlardan seri üretim hatlarındaki makinelere kadar birçok alanda kullanılmaktadır. Kısacası, onlarla kurulan hayat düzeninin artık onlarsız olamayacağı aşîkârdır.

NVIDIA DIGITS, derin öğrenme tabanlı çalışmalarını yürütülmesi için kullanıcılarına oldukça kolaylık sağlayan bir yapı kurmuştur. Açık kaynaklı bir yazılım olması, kullanıcılarının sürdürdükleri çalışmalarını beklentilerine ve amaçlarına yönelik olarak gerekli düzenlemeler yapıp ilerletmelerine imkân sağlamaktadır. Başka bir deyişle NVIDIA DIGITS'in, bu alanda çalışmak isteyen kişiler için kolay ve ücretsiz erişimi ile hem teşvik edici hem de kullanıcıların kendilerini geliştirmeleri için fırsat sağladığı görülmektedir.

Yapılan deneysel çalışmalar yoluyla alınan sonuçlar değerlendirildiğinde, elde ettiğimiz modeli kullanırken ne kadar çok sınıflandırma veri setini beslersek, o kadar veri setindeki kaybı azaltabilmekteyiz. Modelimize ait sonuçlardan elde ettiğimiz grafikteki kayıplarda logaritmik azalma gözlemlenirken, modelin doğruluk oranında da logaritmik artış gözlemlemekteyiz. Diğer taraftan, model grafiğindeki dalgalanmalar model oluşturulurken derin öğrenme sistemimizin verilerdeki benzerliklerden ve uygunsuz işlenemeyen verilerden kaynaklı olarak ara ara ezbere kaydığını ve/veya öğrenememe yaşadığını göstermektedir. Bahsi geçen bu nedenlerden ötürü, kullanılacak veri setine geri besleme yapılması ve veri setinde hata yaratabilme ihtimali görülen verilerin temizlenmesi gerektiği düşünülmüş ve gereken çalışma bu yönde gerçekleştirilerek pozitif açıdan sonuç elde edilmiştir. Dahası veri setinin büyüklüğünü arttırmanın, derin öğrenmenin bir parçası olan ne kadar çok veri o kadar başarı artışı mantığı göz önünde bulundurulmuştur. Bu hamlenin doğruluk oranına olumlu olarak yansıtacağı bilinmektedir. Böyle bir gerçeği göz ardı etmeden, veri setimizin boyutunu arttırırken doğal beslemeler

yapılabileceği gibi sistemimizin öğrenme durumuna ve/veya ezbere kaymayacak şekilde yapay beslemeler ile de artırma yoluna gidilebileceği göz önünde bulundurulmuştur. Bu nedenle, veri setimizde hem gerçek hem de sanal beslemelerde bulunulmuş ve kullandığımız veri setimizin boyutunda artışa gidilmiştir.

Görsel verinin kriminal çalışmalar açısından oldukça yüksek değeri olduğundan daha önce bahsedilmiştir. Görsel veriler adli vakalarda 1. derece delil sayılmasından dolayı, bu verilerin de büyük veri havuzlarından ayıklanarak tespit edilmesinin önemi gün geçtikçe artmaktadır. Derin öğrenme ile birlikte büyük veri havuzlarında gerçekleştirilen ayıklama işlemi, çalışanların faaliyetlerini kolaylaştırmanın yanı sıra aynı zamanda da adli süreçleri sonuçlandırmada geçen zamanı oldukça aza indirmektedir. Zaman, bir adli vakanın tespiti ve o adli olaya alınan karşı aksiyon için oldukça değerlidir. Zaman kaybını hatırı sayılır boyutta azaltacak bir çalışma yöntemi olan derin öğrenme, hem adli mercilerin üzerindeki iş yükünü azaltmaktadır hem zaman kaybının önüne geçmekte hem de adalet sağlanması için objektif bir bakış açısı kazandırarak pozitif yönde katkılar sağladığı yapılan çalışmalar ışığında da görülmüştür.

Genel olarak gerçekleştirilen çalışmalar incelendiğinde, NVIDIA Digits derin öğrenme sistemimizin bu deneysel çalışmada başarılı bir şekilde standart ve adli yaklaşımlı yüz duygu durum ifadelerine ait görüntüler ile sınıflandırma veri setini oluşturabildiğini görmekteyiz. Hem bu veri seti ile sınıflandırma modeli oluşturulabildiğini hem de bu modeli kullanarak sağlıklı bir şekilde görüntüleri işlenilebildiğini görülmektedir. Adli yaklaşımlı çalışmalardan bahsetmek gerekirse, NVIDIA DIGITS ile gerçekleştirdiğimiz adli yaklaşımlı deneysel çalışmalarımızda hem bir cinayet vakasına ait görüntü hem de bir intihar vakasına ait görüntü kullanılmıştır. Yürütülen çalışmaların sonuçları göz önünde bulundurulduğunda, adli olayların gerçekleşme sürecinden elde edilen görüntülerdeki şahısların yüz duygu durum ifadeleri tespit edilebilmekte olup görüntülerdeki gerçekleştirilen faaliyetle bağdaştırılabilmektedir.

Çalışmamız ışığında, daha açık belirtmek gerekirse, 7 farklı çeşit yüz duygu ifadesinin tespiti için sınıflandırma açısından eğittiğimiz veri setimiz bu çalışmada bizim ilk basamağımızı oluşturmaktadır. Bahse konu veri setimizi kullanarak oluşturduğumuz modelimiz ise bizim ikinci basamağımızdır. Ardından, oluşturduğumuz modelimiz üzerinden görüntüleri işleme amacı ile verdiğimiz olay yerlerinden elde edilen katil zanlısının ve intihar eden şahsın görüntülerinin işlenmesi ise çalışmadaki üçüncü basamağı oluşturmaktadır. Son basamak ise sisteme verilen bu adli görüntülerin işlenmesinin ardından sınıflandırmada çıktıların sistemden alınmasıdır. Elde edilen çıktıların analizlerinin yüzelikler olarak sergilenmesi bize ihtimaller üzerinde durmamız gerektiğini göstermiştir. Yüzeliklerden ana duygu durum ifadelerini saptayabileceğimiz gibi yan duygu durum ifadelerine de vakıf olabilmekteyiz.

Adli vakalar üzerinde çalışan güvenlik güçleri her vaka için tam olarak objektif olamayabilmektedir. Bu tarz olgularda objektif bakış açısını bozabilecek birçok alt değişken bulunabilmektedir. Güvenlik güçleri adına çalışan kişilerin ruh hali, kişiyi tanıyıp tanınamaması ve adli vakaya yaklaşımdaki dikkatsizlik gibi daha birçok adli olguya yaklaşımdaki objektifliği zedeleyici değişken bu duruma örnek olarak sunulabilmektedir. Diğer taraftan objektifliği zedeleyecek insani duyguların ve düşüncelerin neden olacağı sübjektif görüşleri barındırmayan bir bakış açısı adli bilimler için her zaman bir artı sağlayacağı düşünülmektedir. Bu noktada ise kullanılan derin öğrenme sisteminin faydası tartışılmaz olacaktır.

Çalışmalara ve geri beslemelere devam edilirse çok karmaşık görüntüler üzerinde de çok başarılı sonuçlar alınabileceği çıkarımı yürütülen çalışmalar sayesinde yapılabilmektedir. Geri beslemelere ek olarak, hazır sinir ağıları bir yana, çalışmaya odaklı geliştirilen sinir ağıları ve buna bağlı algoritmalar geliştirildiğinde adli alana ve çalışmalara daha doğru etkiler sunabileceği ve çalışmanın başarı oranında da buna bağlı olarak artmalar gözlemlenebileceği değerlendirilmektedir. Ayrıca şu anda kullandığımız sinir ağı ile bir görselde tek bir kişinin yüz duygu durum ifadesi üzerinde çalışabiliyorken, adli açıdan bu alanda kullanım amacıyla geliştirilen yeni sinir ağıları ile birçok kişinin yüz duygu durum ifadelerinin ayrı ayrı

başarılı bir şekilde algılanabileceği değerlendirilmektedir. Bu da adli vakalardaki olay yeri görüntüleri incelenirken tez kapsamında yürütülen çalışmaların sağlayacağı fayda veya faydaları bir adım öteye taşıyarak daha ileri seviye çalışmalara yol göstereceği ve bu alanda ilerlemede bir ışık olduğunu bize göstermektedir.

Derin öğrenme sistemlerinden hem işleyiş hem de sunduğu görsel unsur imkanları ve takviyeleri açısından çalışmada kullanılması uygun bulunularak tercih edilen NVIDIA Digits ile yürütülen çalışmanın adli yaklaşım olarak tatmin edici sonuçlar verdiği değerlendirilmiştir. NVIDIA Digits bir yana genel olarak derin öğrenme sistemleri kullanarak yüz duygu durum ifadelerinin tespit edilmesi üzerine çalışmaların geliştirilerek devam ettirilmesi önem arz etmektedir. Gerçekleştirilmesi oldukça değerli ve önemli olduğu kabul edilen bu alandaki çalışmalara ise adli yaklaşımın eklenmesi gelişen teknoloji ve dünya düzeninde adli alana, hem deneysel uygulama süreçlerinde hem de teorik yürütülecek çalışmalarda ışık tutacağı ön görülmektedir.

ÖZET

NVIDIA DIGITS Kullanılarak Yüz Duygu İfadelerinin Sınıflandırılması ve Adli Yaklaşım

NVIDIA derin sinir ağlarını (deep neural network (DNN)) geliştirmek, eğitmek ve görselleştirmek için bir araç olan Deep Learning GPU Eğitim Sistemini (DIGITS) piyasaya sürmüştür. GPU'lar (grafik işlemci ünitesi) sayesinde işlemleri paralel hale getiren DIGITS, işlemleri CPU'lara (merkezi işlem birimi) göre yapılan çalışmalar doğrultusunda 33 kat daha hızlı sonuca kavuşturmaktadır. Aynı zamanda bu sistemde kütüphane olarak kullanılan Torch ve web arayüzü desteği ile yürütülen çalışmaları görselleştirebilmekteyiz.

Deneyisel çalışmamızda sinir ağı ve kütüphanelerden en uygun olanına karar vermek amacıyla bir test gerçekleştirmeye karar verilmiştir. McNamer testinin de çalışmamız için en uygun sinir ağı ve kütüphane eşini bulmak için uygun test yaklaşımı olacağı düşünülmüştür. Doğruluk oranını en yüksek verecek kombinasyonu seçmek için tüm varyasyonlar, GoogLeNet ve AlexNet sinir ağları ile Torch ve Caffe kütüphaneleri kullanılarak McNamer testi üzerinden karşılaştırılarak değerlendirilmiştir. Bunun üzerine en iyi sonucu veren AlexNet sinir ağı ve Torch kütüphanesi kullanılmıştır.

NVIDIA Digits üzerinden yürüttüğümüz çalışmamız için elde ettiğimiz Pierre-Luc Carrier ile Aaron Courville, AffectNet Database ve MUG Facial Expression Database veri setlerinden yararlanılmıştır. Bu üç veri setinden öncelikle deneme çalışmasında kullanılmak üzere, daha sonra ise uygun sinir ağı-kütüphane eşini bulmak ve adli yaklaşımlı çalışma yürütmek üzere iki adet model oluşturmak amacıyla iki farklı veri seti oluşturulmuştur. Daha sonra oluşturulan modeller üzerinden deneme ve adli yaklaşımlı deneyleri gerçekleştirmek adına iki farklı sınıflandırma veri seti oluşturulmuştur.

Deneme amaçlı ve adli yaklaşım için gerçekleştirilen çalışmalardan elde edilen sonuçlar analiz edilmiştir. Adli yaklaşım için gerçek adli vakalardan alınan örnek görüntüler teste tabii tutularak adli yaklaşım deneyleri gerçekleştirilmiştir. Bu testlerden elde edilen sonuçlar analiz edildikten sonra yürütülen deneylerin genel olarak ve adli yaklaşım açısından başarı oranları değerlendirilmiştir.

Analiz ve değerlendirmeler sonucunda yapılan çalışmanın adli açıdan yarar sağlayacağı değerlendirilmiş olup, bu sayede adli vakalardan elde edilen görüntülerin oluşturduğu büyük veri havuzlarında gerçekleştirilen veri tarama işlemi süreci daha az zaman alacağından dolayı adli vaka karşısında aksiyon almak adına zamandan kazanım sağlanacağı kanısına varılmıştır. Buna ek olarak diğer bir sorun olan adli olaylarda olay yerinden intikal eden görüntülerden oluşan olası şüphelilerin ve kurbanlarının ayrımlarının yapılmasında kolaylık sağlanacağı ve çalışan güvenlik güçleri personelinin üzerindeki yükün azalacağı öngörülmektedir. Son olarak ise güvenlik güçlerine bağlı adli vakalar üzerinde çalışmalar yürüten personelin objektif tutum sağlayamayacağı noktada bir derin öğrenme unsurunun faydasının dokunacağı düşünülmektedir.

Anahtar Sözcükler: Adli Bilimler, Derin Öğrenme, Duygu İfadelerinin Sınıflandırılması, Görüntü Sınıflandırma, NVIDIA Digits.

SUMMARY

Classification of Facial Emotion Expressions and Forensic Approach Using NVIDIA DIGITS

NVIDIA releases a tool Deep Learning GPU Training System (DIGITS) to improve, train and visualize Deep Neural Network(DNN). According to scientific research, DIGITS, which makes parallel operations thanks to GPUs (Graphics Processing Unit), are 33 times quicker than CPUs (Central Processing Unit). Also, Torch which is used as a framework and web interface support can visualize study.

We decide to perform a test to determine the most suitable network and framework for experimental study. Then we choose Mc Namer as a most appropriate test to find the most suitable network and framework match for study. All variations to choose the combination that will give the highest accuracy rate from GoogLeNet and AlexNet networks and Torch and Caffe frameworks are compared with Mc Namer test. As a result of test, AlexNet network and Torch framework which give the best outcome are used.

We use Pierre-Luc Carrier, Aaron Courville, AffectNet Database and MUG Facial Expression Database that we obtain for study on NVIDIA DIGITS. We make two different training datasets to create two models. First model is used for testwork and the second one is operated for suitable network-framework matching and conducting a forensic investigation. Then, two different classification data sets have been created in order to carry out trial and forensic experiments through the models.

The results obtained from studies prepared for trial and forensic approach are analyzed. For forensic approach, sample images taken from real forensic cases are tested and experiment is performed. After analyzing the results of these test, the success rate of experimental studies in general and forensic approach is evaluated.

As a result of the analysis and assessments, it is decided that the study can be useful in forensic science because the process of data scanning in the large data repositories formed by the images obtained from forensic cases would take less time. Thus, authorities can save time in order to take action against the forensic case. Moreover, it can be facilitated to discriminate possible suspects and victims with images come from the scene which can assist the security forces. Lastly, it is clear that using deep learning has some advantages in the cases that people working on forensic cases cannot be objective.

Keywords: Classification of Emotion Expressions, Classification of Images, Deep Learning, Forensic Sciences, NVIDIA Digits

KAYNAKLAR

- ABDELKAREEM A (2018). Machine Learning for Everyone. Erişim Adresi: [https://www.slideshare.net/AlyOsama2/machine-learning-for-everyone-86450754]. Erişim Tarihi: 20. Ocak. 2018.
- ADAM (2019). Improve the User Experience of Chatbots with Tone Analysis.10.13140/RG.2.2.20569.57444.
- AIFANTI N, PAPACHRISTOU C, DELOPOULOS A (2010). The MUG facial expression database. *11th International Workshop on Image Analysis for Multimedia Interactive Services WIAMIS 10*. p: 1-4.
- AL JAZEERAMEDIA NETWORK (2016). Rusya Büyükelçisi Karlov öldürüldü. Erişim Adresi: [http://www.aljazeera.com.tr/haber/rusya-buyukelcisi-karlov-olduruldu]. Erişim Tarihi: 19. Aralık. 2016.
- BANFİ V (2018). What is The Turing Test? A Guide to Running One With Slack. Erişim Adresi: [botsociety.io/blog/2018/03/the-turing-test]. Erişim Tarihi: 2. Mart. 2018.
- BEDELI M, GERADTS Z, VAN EIJK E (2018). Clothing identification via deep learning: forensic applications. *Forensic sciences research*, **3.3**: 219-229.
- BITBIX (2018). How neural networks learn for you and where they are applied?. Erişim: [https://medium.com/@bixbit.official/how-neural-networks-learn-for-you-and-where-they-are-applied-c8867fc64d15]. Erişim Tarihi: 29. Ekim. 2018.
- BROWNL EE J (2019). What is Deep Learning?. Erişim Adresi: [https://machinelearningmastery.com/what-is-deep-learning/]. Erişim Tarihi: 20. Aralık. 2019
- BOSTANCI B, BOSTANCI E (2013). An evaluation of classification algorithms using Mc Nemar's test. *Proceedings of Seventh International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA 2012)*. p: 15-26.
- BULUT E, KÜÇÜKER H, BULUT N (2012). İntiharın kısa tarihçesinden sebep ve yöntemlerine genel bir bakış. *Cumhuriyet Medical Journal*, **34.1**: 128-137.
- COLLOBERT R, BENGIO S, MARIÉTHOZ J (2002). Torch: a modular machine learning software library. *Idiap*.
- COLLOBERT R, BENGIO S, MARIÉTHOZ J (2002). Torch, 7.0, *Idiap*.

- DAS S (2017). CNN Architectures: LeNet, AlexNet, VGG, GoogLeNet, ResNet and more.... Erişim Adresi: [<https://medium.com/@sidereal/cnns-architectures-lenet-alexnet-vgg-googlenet-resnet-and-more-666091488df5>]. Erişim Tarihi: 16. Kasım. 2017
- DİLAVER MN (2016). Adli Rapor. Erişim Adresi: [<http://ailehekimimedicine.ankara.edu.tr/wp-content/uploads/sites/581/2019/04/Adli-Rapor.pdf>]. Erişim Tarihi: Nisan. 2019
- DOĞAN F, TÜRKOĞLU İ (2018). Derin Öğrenme Algoritmalarının Yaprak Sınıflandırma Başarımlarının Karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, **1.1**: 10-21.
- DURUKAN E (2016). TensorFlow ile Derin Öğrenmeye Giriş. Erişim Adresi: [<https://emredurukn.github.io/2016/11/02/tensorflow-ile-derin-ogrenmeye-giris.html>]. Erişim Tarihi: 2. Kasım. 2016.
- EDITOR_GOODWORKS (2017). Effects of Machine Learning on Social Media. Erişim Adresi: [<https://www.goodworklabs.com/how-is-machine-learning-changing-social-media/>]. Erişim Tarihi: 13. Mayıs. 2017
- ELECTRONIC FRONTIER FOUNDATION (2017). Face Recognition. Erişim Adresi: [<https://www.eff.org/pages/face-recognition>]. Erişim Tarihi: 24. Ekim. 2017.
- EMÜL İ (2016). Canlı yayında intihar etti. Erişim Adresi: [<http://www.milliyet.com.tr/gundem/canli-yayinda-intihar-etti-2324752>]. Erişim Tarihi: 10. Ekim. 2016
- Face Recognition in Forensic Science (Face Recognition Applications) Part 1. Erişim Adresi: [<http://what-when-how.com/face-recognition/face-recognition-in-forensic-science-face-recognition-applications-part-1/>].
- HEATH N (2018). What is deep learning? Everything you need to know. Erişim Adresi: [www.zdnet.com/article/what-is-deep-learning-everything-you-need-to-know]. Erişim Tarihi: 7. Ağustos. 2018
- INTERPOL. Facial Recognition. Erişim: [<https://www.interpol.int/INTERPOL-expertise/Forensics/Facial-recognition>].
- İNİK Ö, ÜLKER E (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, **6.3**: 85-104.
- IOFFE S, SZEGEDY C (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift. *In International conference on machine learning*. P: 448-456.

JIA Y, 2014, Caffe, Berkeley AL Research

JIA Y (2014). Caffe: Convolutional Architecture for Fast Feature Embedding. ArXiv preprint arXiv:1408.5093 Berkeley AI Research.

JIA Y, SHELHAMER E, DONAHUE J, KARAYEV S, LONG J, GIRSHICK R, GUADARRAMA S, DARRELL T (2014), Caffe: Convolutional Architecture for Fast Feature Embedding. *Proceedings of the 22nd ACM international conference on Multimedia*. p.: 675-678.

KAGGLE Inc (2013). Challenges in Representation Learning: Facial Expression Recognition Challenge. Erişim Adresi: [<https://www.kaggle.com/c/challenges-in-representation-learning-facial-expression-recognition-challenge#description>]. Erişim Tarihi: 2013.

KAVALCI C (2015). Acil Serviste Adli Vaka Yönetimi. *Journal of Clinical And Analytical Medicine*, p.: 1-2.

KRIZHEVSKY A, SUTSKEVER I, HINTON GE (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*. p.: 1097-1105.

KURT F (2016). NVIDIA Digits Başlangıç Rehberi Sunumu. Erişim Adresi: [<http://www.derinogrenme.com/2016/01/20/Digits-baslangic-rehberi-sunumu>]. Erişim Tarihi: 20. Ocak. 2016.

LECUN Y, BOTTOU L, BENGIO Y, HAFFNER P (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86.11**: 2278-2324.

LECUN Y, BENGIO Y, HINTON G (2015). Deep learning. *nature* **521.7553**: 436.

LEE H, GROSSE R, RANGANATH R, NG AY (2009). Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations. *Proceedings of the 26th annual international conference on machine learning ACM*, p.: 609-616.

MADRIGAL L (2012). *Statistics for anthropology*. Cambridge University Press, p.: 183-184

MAVANI V, RAMAN S, MIYAPURAM KP (2017). Facial expression recognition using visual saliency and deep learning. *Proceedings of the IEEE International Conference on Computer Vision*, p.: 2783-2788.

MOLLAHOSSEINI A, HASANI B, MAHOOR MH (2017). Affectnet: A database for facial expression, valence, and arousal computing in the wild. *IEEE Transactions on Affective Computing*. **10.1**: 18-31.

NVIDIA CORPORATION, 2007, CUDA, 7.5, Santa Clara, Kaliforniya, ABD

NVIDIA CORPORATION, 2007, CuDNN, 7.6, Santa Clara, Kaliforniya, ABD

NVIDIA CORPORATION, 2015, Nvidia DIGITS, Santa Clara, Kaliforniya, ABD

NVIDIA CORPORATION, 2007, CUDA Toolkit, 10.2, Santa Clara, Kaliforniya, ABD

NVIDIA Deep Learning GPU Training System

OPALA M (2019). Deep Learning Frameworks Comparison – Tensorflow, PyTorch, Keras, MXNet, The Microsoft Cognitive Toolkit, Caffe, Deeplearning4j, Chainer. Erişim Adresi: [<https://www.netguru.com/blog/deep-learning-frameworks-comparison>]. Erişim Tarihi: 10. Eylül. 2019.

PEART A (2017). Homage to John McCarthy, the Father of Artificial Intelligence (AI). Erişim Adresi: [<https://www.artificial-solutions.com/blog/homage-to-john-mccarthy-the-father-of-artificial-intelligence>]. Erişim Tarihi: 2. Haziran. 2017.

SAMUEL AL (1959). Some studies in machine learning using the game of checkers. IBM Journal of research and development, 3.3: 210-229.

SHAIKH F (2017). Why are GPUs necessary for training Deep Learning models?. Erişim Adresi: [<https://www.analyticsvidhya.com/blog/2017/05/gpus-necessary-for-deep-learning/>]. Erişim Tarihi: 18. Mayıs. 2017

SHORTEN C (2018). Machine Learning vs. Deep Learning. Erişim Adresi: [<https://towardsdatascience.com/machine-learning-vs-deep-learning-62137a1c9842>]. Erişim Tarihi: 7. Eylül. 2018

TANG A, TAM R, CADRIN-CHÊNEVERT A, GUEST W, CHONG J, BARFETT J, CHEPELEV L, CAIRNS R, MITCHELL J, CICERO M, GAUDREAU POUDRETTE M, JAREMKO J, MD C, GALLIX B, GRAY B, GEIS R, O'CONNELL T, BABYN P, KOFF D, SHABANA W (2018). Canadian Association of Radiologists white paper on artificial intelligence in radiology. Canadian Association of Radiologists Journal, 69.2: 120-135.

TANG Y (2013). Deep learning using linear support vector machines. *arXiv preprint arXiv. 1306.0239*.

TERZİ B (2015). Acil Serviste Adli Olgular. Erişim Adresi: [<https://slideplayer.biz.tr/slide/1959474/>]. Erişim Tarihi: 2015.

TURING AM (1950). Computing Machinery and Intelligence. *Mind*, **49**: 433-460.

UÇAR A (2017). Deep Convolutional Neural Networks for facial expression recognition. 2017 IEEE International Conference on INnovations in Intelligent SysTems and Applications (INISTA), p.: 371-375.

VON AHN L, BLUM M, LANGFORD J (2004). Telling humans and computers apart automatically. Communications of the ACM, 47.2: 56-60.



ÖZGEÇMİŞ

I. Bireysel Bilgiler

Sevim Çağla

DEMİR

Ankara/ 09.05.1990

T.C.

Bekar

İletişim Adresi: 7.cadde 70.sokak 36/4 06650 Bahçelievler Ankara

Tel: 0554 984 94 51

II. Eğitim

Yüksek Lisans: Ankara Üniversitesi/ Kriminalistik (Devam Ediyor)

Lisans: Orta Doğu Teknik Üniversitesi/ Fizik (2009-2016)

Lise: Kırkkonaklar Anadolu Lisesi /Matematik- Fen (2005-2009)

Yabancı Dil: İngilizce (İleri Seviye) / Almanca (Başlangıç)

III. Bilimsel Etkinlikler

Kütle Çekimsel Dalgaların İspatlanması ve Astrofizik Üzerindeki Etkileri (METU, 2016)

Görünmez: Karanlık Madde (Gökyüzü, 2015)

Güneş Enerjisi Verimlilik Hesaplayıcısı (ODTÜ, 2014)

Biyofizik – Balistik – Atış Mesafesi Hesaplayıcısı (AU, 2017)

IV. Diğer Bilgiler

Haber ve Yayın Çevirisi (ODTÜ - AAT- Gokyuzu.org , 2012-2016)

19.UAK

ODTÜ Amatör Astronomi Topluluğu