



Journal of Investigation on Engineering & Technology

<http://dergipark.gov.tr/jiet>



PUBLISHER:

Yayıncı

Karadeniz Technical University, Faculty of Technology
Karadeniz Teknik Üniversitesi, Of Teknoloji Fakültesi

PRIVILEGE OWNER (Dean):

İmtiyaz Sahibi (Dekan)

Dr. İrfan ACAR

EDITOR IN CHIEF:

Baş Editör

Dr. Canan AKSOY

JOURNAL EDITORS:

Dergi Editörleri

Dr. Canan AKSOY
Dr. Emin TUĞCU
Dr. Erol İSKENDER
Dr. Hamdi Tolga KAHRAMAN
Dr. Hasan Tahsin ÖZTÜRK

PRODUCTION EDITOR:

Yayın Editörü

Dr. Hasan Tahsin ÖZTÜRK

ISSUE EDITORS

Sayı Editörleri

Dr. Hamdi Tolga KAHRAMAN
Dr. Canan AKSOY

FIELD EDITORS

Alan Editörleri

Dr. Zeynep ŞAHİN TİMAR (Karadeniz Technical
University) Software Engineering

Dr. Hasan ÖLMEZ (Karadeniz Technical University)
Marine Machinery Management Engineering

LANGUAGE EDITOR: Dr. Nilgün MÜFTÜOĞLU (Karadeniz Technical University)
Dil Editörü

STATISTICS EDITOR: Dr. Hanefi CALP (Ankara Hacı Bayram Veli University)
İstatistik Editörü

LAYOUT EDITOR: Sefa ARAS
Mizanpaj Editörü

SECRETARY: Bora ÇAVDAR
Sekreter

PROOF READER: Hakan Aydın
Son okuyucu

EDITORIAL BOARD:
Yayın Kurulu

Dr. Adem DOĞANGÜN (Bursa Uludağ University)
Dr. Zeki KARACA (Ondokuz Mayıs University)
Dr. Tayfun DEDE (Karadeniz Technical University)
Dr. Egemen ARAS (Bursa Technical University)
Dr. Erdem TÜRKELİ (Ordu University)
Dr. Erdoğan DOĞDU (Çankaya University)
Dr. Şeref SAĞIROĞLU (Gazi University)
Dr. Güngör BAL (Gazi University)
Dr. M. Ali AKCAYOL (Gazi University)
Dr. Recep DEMİRCİ (Gazi University)
Dr. Tuncay YİĞİT (Süleyman Demirel University)
Dr. Ercan Nurcan YILMAZ (Gazi University)
Dr. Cemal YILMAZ (Gazi University)
Dr. Uğur GÜVENÇ (Düzce University)
Dr. Yusuf SÖNMEZ (Gazi University)
Dr. Mehmet ŞİMŞEK (Düzce University)
Dr. İbrahim Alper DOĞRU (Gazi University)
Dr. Atakan AKSOY (Karadeniz Technical University)
Dr. Cemaleddin ŞİMŞEK (Karadeniz Technical University)
Dr. Tuncay BAYRAM (Karadeniz Technical University)
Dr. Bakiye ÇAKIR (Artvin Çoruh University)
Dr. Ezgi Taylan KOPARAN (Bülent Ecevit University)
Dr. Numan DOĞAN (North Carolina State University)
Dr. Tayebah MOUSAVİ (University of Oxford)
Dr. Germán F. de la FUENTE (University of Zaragoza)
Dr. Luis A ANGUREL (University of Zaragoza)
Dr. Bilge Han TOZLU (Hitit University)

INDEXING:

İndeksler



ASOS
indeks

Product Information

Ürün Bilgisi

Volume **6** **Issue** **2** **December/2023**
Cilt *Sayı* *Aralık/2023*

Publisher Karadeniz Technical University, Faculty of Technology
Yayıncı *Karadeniz Teknik Üniversitesi Of Teknoloji Fakültesi*

Web Page <http://dergipark.gov.tr/jiet>
Web Sayfası

Date of Publication December /2023
Basım Tarihi *Aralık/2023*

Language English/Turkish
Yayın Dili *İngilizce/Türkçe*

Frequency Published twice in a year
Yayın Aralığı *Yılda iki kez yayınlanır*

Type of Publication Periodical
Yayın Türü *Sürekli yayın*

ISSN Number 2687-3052
ISSN Numarası

Yazışma Adresi

Karadeniz Teknik Üniversitesi
Teknoloji Fakültesi
Çamlı M. Hacı Mehmet Baheddin Ulusoy
Cad. No:144 61830 Of/ TRABZON
Telefon: +90 462 377 83 01
E-posta: jiet@ktu.edu.tr

Makale gönderimi dergipark üzerinden yapılmaktadır. Tüm yayınlanan makalelere <http://dergipark.gov.tr/jiet> adresinden ulaşılabilir.

Correspondence Address

Karadeniz Technical University
Faculty of Technology
Çamlı M. Hacı Mehmet Baheddin Ulusoy
St. No:144 61830 Of/ TRABZON
Phone: +90 462 377 83 01
E-mail: jiet@ktu.edu.tr

Paper submission is done via dergipark. All published papers are available at <http://dergipark.gov.tr/jiet>.



CONTENTS

İçindekiler



Research Articles

(Araştırma Makaleleri)

Pages

Sayfalar

Face Detection and Recognition Application Using Convolutional Neural Networks <i>Evrışimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulaması</i> Özge Gürbüz, Tolga Yılmaz	45-60
Using Steady State Visually Evoked Potential-Based Brain Computer Interface in Multiple Choice Questions <i>Çoktan Seçmeli Sorularda Kararlı Durum Görsel Olarak Uyarılmış Potansiyel Tabanlı Beyin Bilgisayar Arayüzü Kullanılması</i> Elif Yıldırım, Fatih Aydın, Oğuzhan Başer, Önder Aydemir	61-69
Design and Development of Screw-type Pellet Machine for Aquatic Feeds with Dual Operations Jamilu Ya'u Muhammad, Yusuf Alhaji, Abubakar Muhammad Shitu, Abdulkareem Mika'il Alhaji, Umar Muhammad Ahmad, Audu Taofeek Olaniyi	70-79



Evrişimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulaması

Özge Gürbüz¹, Tolga Yılmaz

(Alınış / Received: 07.09.2023, Kabul / Accepted: 21.12.2023, Online Yayınlanma / Published Online: 24.01.2024)

Anahtar Kelimeler
Derin Öğrenme,
Evrişimli Sinir Ağı,
Yüz Tanıma

Öz: Son yıllarda gelişen teknolojilerin başarı oranının artması ve günlük hayatı kolaylaştırması nedeniyle yüz tanıma tabanlı uygulamaların kullanımı giderek artmaktadır. Yüz tanıma uygulamaları telefonların kilit ekranlarında, öğrenci ve personel devam takibinde, güvenlik kontrolü vb. alanlarda kullanılmakta ve gün geçtikçe kullanım alanı genişlemektedir. Yüz tanıma işlemi için farklı yöntemler bulunmaktadır. Bu yöntemlerden bir tanesi derin sinir ağı çeşidi olan Evrişimli Sinir Ağı kullanılmaktadır. Bir görüntü içerisindeki nesnelere belirleme ve tanıma alanında yüksek başarı gösterdiği için Evrişimli Sinir Ağları yüz tanıma işleminde ön plana çıkmaktadır. Bu sebeple çalışma kapsamında yüz belirleme ve tanıma için Evrişimli Sinir Ağları kullanılmıştır. Bu çalışmada, en üstün performansı sergileyen ESA modelinin belirlenmesi, ESA modellerinin eğitiminde kullanılan verilerin çeşitli yöntemlerle artırılması ve yüz tanıma sistemine dönüştürülmesi gerçekleştirilmiştir.

Face Detection and Recognition Application Using Convolutional Neural Networks

Keywords
Deep Learning,
Convolutional Neural
Networks,
Face Recognition

Abstract: In recent years, the use of face recognition-based applications has been increasing due to the increasing success rate of developing technologies and facilitating daily life. Face recognition applications can be used on the lock screens of phones for student and staff attendance tracking, security control, etc. It is used in certain areas, and its usage area is expanding day by day. There are different methods for face recognition. One of these methods is to use a convolutional neural network, which is a type of deep neural network. Convolutional neural networks come to the fore in face recognition because they show high success in identifying and recognizing objects in an image. Therefore Convolutional neural networks (CNNs) were used for face detection and recognition within the scope of this study. In this study, the determination of the ESA model with the highest performance, the data used in the training of the ESA models were increased by various methods and converted into a face recognition system.

1. Giriş

Son yıllarda kişisel bilgilerin işlenmesi ile ortaya çıkan güvenlik açıkları artan yüz tanıma tabanlı uygulamaların yaygın olarak kullanılmaya başlanmasına vesile olmuştur. Bu uygulamalar birçok alanda uygulanmaya başlanmış ve başarılı sonuçlar ortaya çıkmıştır. Bu alanların başında sağlık, endüstriyel uygulamalar, eğitim ve askeri alanlar yer almaktadır. Yüz tanıma (FR), kimlik tespiti için yüzün biyolojik karakteristiğini işleyerek bunu kullanan teknolojik bir süreçtir. Literatürde yaygın olarak kullanılan bu yöntemin diğer biyometrik yöntemlerle karşılaştırıldığında; parmak izleri, iris ve DNA gibi özelliklerin yerine yüz, üstün uygulama potansiyeli sunan güvenilirlik, güvenlik ve toplumsal kabul açısından ön plana çıkmaktadır. [1]. Yüz tanıma uygulamalarının kullanım durumu farklı alanlarda da kabul görmektedir. Özellikle Covid-19 salgını sebebiyle temas gerektirmeyen kontroller giderek önem kazanmıştır. Bunlardan bazıları, suçluların tespiti, çalışanların şirket içi uygulamalardaki fotoğraf gönderilerinden duygu tespiti, öğrencilerin online yoklama ile varlık yokluk kontrolü ve insan duygu analizleri gibi çalışmalar yaygınlaşmaktadır [1].

Bu çalışmada yaygınlaşan uygulamalardan biri olan okullarda yoklama sistemi için veri çoğaltma ve derin sinir ağı modelinin seçimi yapılmıştır. Bir görüntü içerisindeki nesnelere belirleme ve tanıma alanında yüksek başarı gösterdiği için derin sinir ağı çeşidi olan Evrişimli Sinir Ağları yüz tanıma işleminde ön plana çıkmaktadır [2]. Evrişimli Sinir Ağları (CNN'ler), bilgisayarlı görme görevlerinde son derece başarılı bir performans sergileyen ve geniş çapta kullanılan bir sinir ağı tipidir [3]. Yüksek başarısından dolayı bu çalışmada Evrişimli Sinir Ağı modelleri kullanılmıştır.

Şu anki yüz tanıma sistemleri, kontrol edilen ortamlarda yüksek bir başarı düzeyine ulaşmış olsa da çeşitli zorluklarla karşılaşmaya devam etmektedir. Bu zorluklar, poz değişiklikleri, aydınlatma koşulları, ifade farklılıkları ve kısmi yüz kapanmaları gibi durumları içerir. Özellikle kısmi yüz kapanmaları, gerçek dünya uygulamalarında en zorlu sorunlardan birini oluşturur. Bu tür kapanmalar, gözlük, güneş gözlüğü, şapka, eşarp gibi yaygın nesnelere veya yüzün bir kısmının örtülmesiyle ortaya çıkabilir. Bu nedenle, gerçek dünya koşullarında güvenilir bir şekilde çalışabilen bir yüz tanıma sisteminin, bu tür kapanmalara karşı dirençli olması gerekmektedir. Geleneksel olarak, bu tür kapanmalarla başa çıkmak için kullanılan temel yaklaşımlardan biri, kapanmış yüz görüntülerini yerel olarak analiz ederek veya test görüntülerini eğitim verilerinde bulunan kapanmamış yüzlerle karşılaştırarak çalışır [4].

Derin sinir ağı eğitimlerinde çok sayıda veri gerekmektedir. Evrişimli Sinir Ağı eğitimlerinde görsel veri kullanıldığı için bu durum veri bulma problemi doğurmaktadır. Yoklama sisteminde küçük okullar için öğrencilerin az sayıda fotoğrafı yeterli olsa da büyük okullar, fakülteler vb. yerlerde fotoğraf sayısı kişiler arasındaki farkı ağı daha iyi öğrenebilmesi için daha fazla olmalıdır. Ayrıca öğrenciler yıl boyunca hep aynı görünmedikleri durumlar oluşabilmektedir. Öğrencinin sakal veya bıyık bırakması, saçını uzatması ya da kesmesi, yüzüne dövme yaptırması, kamera önüdeyken şapka-gözlük takması vb. birçok olay bu durumlara örnektir. Bu durumlardan biri olan makyaj, genellikle yüzün çekiciliğini artırmak amacıyla yaygın bir şekilde kullanılan ve genel olarak toplum tarafından kabul gören bir uygulamadır. Ancak, farklı makyaj stilleri, yüzün görünümünde belirgin değişikliklere yol açabilir. Makyajlı ve makyajsız yüz görüntülerini başarılı bir şekilde eşleştirmek hala büyük bir zorluk oluşturmaktadır [5].

Bu çalışmada, yüz tanıma ve belirleme sistemi için öğrenci fotoğraflarına şapka, gözlük, farklı saç modelleri vb. durumlar eklenerek veriler çoğaltılmış ve elde edilen sonuçlar ile derin sinir ağı eğitilmiştir. İşlenecek verilerin ortaya çıkması ile analiz çalışmaları yapılarak çalışmanın önemi vurgulanmıştır. Makale içeriği olarak kullanılmış araçlar, yöntemler ve veri setleri detaylandırılarak aktarılmıştır.

2. Materyal ve Metot

Yöntem bölümünde çalışmanın geliştirilme aşamasında takip edilmiş adımlar verilmiştir. Bu adımlarda sırasıyla veri kümesi oluşturma, Evrişimli Sinir Ağları, veri çoğaltma ve Evrişimli Sinir Ağları Modellerinin Eğitilmesi anlatılmıştır.


Bu çalışmada iki bilgisayar kullanılmıştır. Bilgisayarlardan birisi i7-13700H 2.40 GHz işlemci, 16GB DDR4 bellek, Windows 11 Home Single Language işletim sistemi ve 6GB Nvidia RTX4050 ekran kartına sahiptir. Diğeri ise Ryzen 7 5700X 4.60 Ghz işlemci, 32GB DDR4 bellek, Windows 10 Pro 64-bit işletim sistemi ve 12GB Nvidia RTX3060 ekran kartına sahiptir.

2.1. Veri kümesi

Çalışmanın veri çoğaltma ve Evrişimli Sinir Ağı eğitimlerinde “FEI Face Database” [6] ve “Labeled Faces in the Wild” [7] yüz veri setleri kullanılmıştır. FEI Face Database, 2005 ve 2006 yılları arasında Brezilya’daki FEI Yapay Zekâ Laboratuvarında çekilmiş yüzlerin veri tabanıdır. 200 farklı kişinin 14 farklı pozisyonda (yüzün sağından, solundan, 2 önünden, gülümserken ve gülümsemezken, düşük ışık altında) fotoğraflarını içermektedir. Yüzler 19 ila 40 yaşları arasındaki FEI’deki öğrenci ve personellerden oluşmaktadır [6]. LFW, web’den toplanan 13.000’den fazla yüz görüntüsü içermektedir. Bu görüntülerdeki yüzler Viola Jones algoritması tarafından tespit edilebilmiştir [7]. Bu veri setinde birçok kişinin az miktarda fotoğrafı bulunmaktadır. Bu sebeple veri setinde fotoğraf sayısı sekiz ve üstü olan kişilerin yüz verileri çalışmada kullanılmıştır. FEI yüz veri setindeki 14 farklı yüz pozisyonundaki fotoğrafların 8 tanesi bu çalışmada kullanılmıştır. Eğitim aşamasında kişilerin veri sayısı eksik kalmaması için LFW veri setinde fotoğraf sayısı minimum 8 olan kişiler seçilmiş ve bunların 8 adet fotoğrafı kullanılmıştır.

2.2. Evrişimli sinir ağları

Evrişimli Sinir Ağları (Convolutional Neural Networks – CNN), bir Derin Sinir Ağlar (DSA) türüdür. Ve çok katmanlı algılayıcıların mimarisini kullanır. Evrişimli Sinir Ağları çoğunlukla görüntü analizi, görüntülerdeki nesnelere tanımak ve Bilgisayar görüşündeki (CV) sorunları çözmek için kullanılır. Evrişimli Sinir Ağları, insanların ve hayvanların görsel korteksinin işleyişini taklit eder. Son zamanlarda görüntü analizi, görüntülerdeki nesnelere tanımak ve Bilgisayar görüşündeki (CV) sorunları çözmek konusunda yüksek başarı elde etmişlerdir [8]. Bundan dolayı bu çalışmada Evrişimli Sinir Ağı kullanılmıştır. Bu ağlar, bir görüntüdeki nesneyi tanımak için birlikte çalışan birçok farklı katmana sahiptirler, Şekil 1’te ESA’nın yapısı gösterilmektedir.



Şekil 1. ESA'nın yapısı [9]

Konvolüsyon (convolutional) ve havuzlama (pooling), Evrişimli Sinir Ağları mimarisinin ilk aşamalarındandır. Tam bağlı katman ve hemen ardındaki sınıflandırma katmanı ise Evrişimli Sinir Ağları mimarisinin son aşamalarındandır. Evrişimli sinir ağları birden fazla eğitilebilir bölümlerden oluşur ve devamında eğitici bir sınıflandırıcı ile devam eder. Giriş verileri alınır, katman katman işlemler yapılarak eğitim süreci gerçekleştirilir. Son olarak da doğru sonuç ile karşılaştırma yapabilmek için bir final çıktısı verir. Üretilen sonuç ile istenen sonuç arasındaki fark kadar hata oluşur. Geriye yayılım algoritması sayesinde bu hata bütün ağırlıklara dağıtılır. Her bir iterasyonla birlikte de ağırlıklar güncellenerek hatanın azaltılması sağlanır [10]. Evrişim katmanı ve havuz katmanı, sonraki bölümlerde açıklanan hiper parametrelere göre ince (fine-tuned) ayarlanabilir [10]. ESA girdi görüntüsünü alarak çalışmaya başlar, ilk gizli katmanda nöronlar kenarlar, kulakların şekli veya burun gibi basit kalıpları öğrenirler. Sonra, görüntü bir sonraki katmana iletilir ki bu katman bir önceki katman ile kıyaslandığında daha belirgin özellikleri öğrenebilmektedir. Katmanlar arttıkça nöronlar, yüz veya araba gibi üst düzey özellikleri öğrenmeye başlar [8]. Görüntülerin boyutu, tam bağlı katmana varıncaya kadar düşmektedir. Çünkü girdi verisi tam bağlı katmana kadar konvolüsyon ve havuzlama katmanlarından geçer. Konvolüsyon (evrişim) katmanında görüntü üzerinde filtreleme benzer operasyonlar uygulanır ve farklı özellikleri vurgulanır. Bu katmanlar görüntü boyutunu azaltmazlar, ancak çıkış olarak elde edilen özellik haritaları giriş boyutuna kıyasla daha küçük olabilmektedir. Havuzlama katmanları konvolüsyon katmanının çıktısını 3x3, 5x5 gibi filtreler kullanarak özetler ve bu özetleme sırasında girdinin boyutu küçülür. Bu işlem daha yüksek seviye özetleme ve hesaplama maliyetinin düşürülmesi için kullanılır.


2.3. Veri çoğaltma

ESA modellerinin eğitimlerinde ne kadar çok iyi veri kullanılırsa eğitimin başarısı o kadar artar. Burada çok iyi veriden kastedilen veri setinin homojen olmasıdır. Örneğin veri setindeki bir kişinin kırmızı gözlük ile olan bir fotoğrafı eğitimde kullanılmadığı, veri setindeki diğer kişilerin ise kırmızı gözlük taktığı fotoğraflar eğitimde kullanıldığı varsayalım. Kişinin kırmızı gözlük taktığı bir fotoğraf ESA modeline verildiğinde eğitimde kırmızı gözlük takan kişilere benzerlik oranı daha fazla çıkar ve hatalı sonuç döndürür. Aynı zamanda yoklama sisteminde kullanıcıların zamanla yüz görüntüleri değişebilmektedir. Kişilerin fiziksel olarak değişimlerinin yanında aksesuar kullanımı da veri işleme sürecinde olumsuz durumlar ortaya çıkarabilmektedir. Bunlar, şapka takması, saçın durumu, gözlük kullanma, sakal-bıyık uzatma vb. durumlarda eğitilmiş olan ağ daha önce çoğaltılmış veriler ile eğitildiği için bu değişiklik karşısında da başarılı olması bu tip sistemler için son derece önemlidir. Yapılan çalışmada bu tip durumlar için başarılı sonuçlar ortaya çıktığı analizler sonucunda gösterilmiştir. Bu nedenle verilerin çoğaltılması ve uygun sonuçlar alınması son derece önemli bir konudur.

Veri çoğaltmak için iki yöntem kullanılmıştır. Biri Python ortamında Mediapipe Frameworkü yardımıyla resimler üzerine PNG formatındaki başka bir resmin birleştirilmesi. Diğer yöntem ise yapay zekâ yöntemi olan "Stable Diffusion" yöntemidir.

2.3.1. Mediapipe kullanarak veri çoğaltma

Mediapipe, Google tarafından geliştirilen makine öğrenimi çözümleri oluşturmak için kullanılan bir framework'tür. Mediapipe, video analizi, nesne algılama, yüz izleme, beden izleme, el izleme gibi birçok çoklu ortam işleme görevini gerçekleştirebilen açık kaynak kodlu bir projedir. Video içerisinde insan yüzünün, gözünün, burnunun, alınının nerede olduğunu; elin parmak uçlarından avuç içine kadar nerelerde olduğunu kullanıcıya geri döndürür. Bu çalışmada Mediapipe insan yüzünün fotoğraf üzerinde nerede olduğunu ve koordinatlarının neler olduğunu bulmakta kullanılmıştır. Platformdan bağımsız olarak farklı işletim sistemlerinde kullanılabilir [11]. Bu çalışmada Mediapipe ile veri çoğaltma temelinde iki resmin birleştirilmesi mantığına dayanmaktadır. Yüz fotoğrafı ile eklenecek olan fotoğrafın doğru koordinatlar ile birleştirilmesi sonucu veriler çoğaltılır. Doğru koordinatlar yüz landmark noktaları ile tespit edilmektedir. Yüz landmark noktaları, insan yüzünün uzuvları olan göz, burun, kaş, dudak, çene, yanak vb. bölgelerin noktalar ile işaretlendiği halidir. Farklı yöntemler ile bu noktalar tespit edilebilse de bu çalışmada bu noktaların tespitinde Mediapipe kullanılmıştır. Mediapipe ile bir fotoğraftaki insan yüzünün numaralandırılmış bölgelerinin koordinatlarını elde edilebilmektedir. Şekil 2'de 468 yüz landmark noktasının görseli verilmiştir.



Şekil 2. 468 Yüz landmark noktası [12]


Şekil 2'de görülen her çizgi çakışması insan yüzü üzerindeki 1 landmark noktasını temsil etmektedir. Bu çalışmada sadece 468 yüz landmark noktası değil 74 yüz landmark noktası da kullanılmıştır. Mediapipe yardımıyla 2 farklı birleştirme işlemi yapılabilmektedir. Bunlardan bir tanesi iki resmi doğrudan birleştirmektir. Bu yöntemle 468

yüz landmark noktasından doğru olanları seçilip PNG formatındaki fotoğrafın bu noktalara göre konumlandırılarak resimlerin birleştirilmesi. Şekil 3'te bu konumlandırma işleminin gözlük ile yapıldığında elde edilen sonuçlardan üç adet örnek verilmiştir.



Şekil 3. Gözlük ekleme örnekleri

Bir diğeri ise 74 yüz landmark noktasını kullanarak yüze yapışık şekilde eklemeler yapmak. Mediapipe sayesinde bir PNG resmi insan yüzü üzerinde yapışık şekilde eklenebilmektedir. Bu "PNG" formatındaki resmin etrafında bulunan landmark noktalarının etiketlenmesi ile ".csv" uzantılı dosya elde edilmektedir. Bunun için MakeSense isimli web tabanlı uygulama ücretsiz olarak kullanılabilir [13]. MakeSense bir veri etiketleme uygulamasıdır. MakeSense yardımıyla fotoğraf üzerindeki bir noktayı ya da bir alanı işaretleyerek o koordinatlara sınıf etiketi verebiliriz. Şekil 4'te MakeSense web sitesinin arayüzü ve bir PNG sakal resminin etiketlenmesi gösterilmektedir.



Şekil 4. MakeSense arayüzü [13]

Etiketlenmiş PNG resmi ile Python geliştirme ortamında 74 yüz landmark noktası kullanılarak birleştirme işlemi gerçekleştirilir. Bu birleştirme sonrası PNG resim insan yüzünde belirtilen noktalar arasında yapıştırılmış gibi görünmektedir. Şekil 5'te örnek birleştirilmiş resimler verilmektedir.



Şekil 5. Örnek eklemeli resimler

Python geliştirme ortamında tek bir fotoğraf girdisi ile yukarıda bahsedilen iki yöntem kullanılarak, bir fonksiyonun çıktısı diğer ekleme fonksiyonunun girdisi haline getirilir, sadece cinsiyet bilgisi verilerek verileri çoğaltan kod yazılmıştır. Bu kod yoklama sistemine de entegre edilebilir hale getirilmiştir. Bu aşamada 30 farklı yüz yapısına sahip kişi FEI yüz veri setinden seçilmiştir. Her bir PNG dosyası bu yüzler üzerinde denenerek X eksenindeki kayma, Y eksenindeki kayma ve PNG resminin kaç kat büyütülüp ya da küçültüleceği hesaplanmıştır.

Tek bir fotoğraftan otomatik çoğaltma ile yaklaşık 50.000 ayrı fotoğraf elde edilebilmektedir fakat bu sayı eğitim için hem aşırı fazla hem de eğitimin süresini aşırı büyütüp gereksiz zaman kaybetmeye sebep olabilmektedir. Ayrıca tek bir fotoğraftan çok fazla veri çıkarılmasından dolayı depolama alanı sorunu yaşanabilmektedir. Bu sebeple fotoğraflara resim ekleme kısıtı getirilerek tek bir fotoğraftan yaklaşık 500 ayrı çoğaltılmış veri elde edilen şekle çevrilmiştir. Eklenecek gözlük, şapka, sakal vb. resimlerin tamamı bir fotoğrafa uygulanmayıp, rastgele seçilerek belli bir kısım ekleme yapılarak aşırı fazla veri üretiminin önüne geçilmiştir. Şekil 6'da Mediapipe ile başarılı şekilde çoğaltılmış fotoğraf örnekleri verilmiştir.



Şekil 6. Mediapipe başarılı çoğaltılmış fotoğraf örnekleri

Genel olarak kişinin sağ ve sola dönük fotoğraflarında başarısızlık oranı daha fazla olmaktadır. Fakat kişinin düz baktığı fotoğraflarda da başarısızlık durumuyla karşılaşılabilir. Kişinin sağa ve sola dönük olduğu fotoğrafları çoğaltılmaz, sadece düz şekilde durduğu fotoğrafları çoğaltılırsa hatalı veri oranı büyük oranda düşmektedir. Yoklama sisteminde öğrenciler sınıfa girerken kameraya doğrudan baktığı varsayılırsa bu yöntem başarılı olmaktadır. Fakat öğrencilerin sınıfa kameraya doğrudan bakmadan hafif sağa ya da sola dönüş şeklinde girmeleri durumunda bu açılardan olan fotoğrafları da çoğaltma ihtiyacı doğmaktadır. Ya da veriler çoğaltıldıktan sonra başarısız olan çoğaltma işlemleri veri setinden çıkarılmalıdır.

2.3.2. Stable diffusion ile veri çoğaltma

Stable Diffusion, özgün bir veri setini kullanarak yeni örnekler oluşturmak için kullanılan bir veri çoğaltma yöntemidir. Bu yöntem, veriye gürültü ekleyerek veya varyasyonlar oluşturarak mevcut örnekleri çeşitlendirmek için kullanılır. Stable Diffusion, genellikle derin öğrenme ve yapay zekâ alanlarında kullanılan ve özellikle sınırlı veri durumlarında performansı arttırmaya yardımcı olan bir tekniktir.

Stable Diffusion Inpainting, eksik veya hasarlı bir resmin boş veya zarar görmüş bölgelerini doldurmak için ısı yayılma özelliklerini kullanan bir iç boyama tekniğidir. Bu yöntem, eksik veya hasarlı bölgenin etrafındaki resim piksellerine ısı yayılma işlemi uygulayarak, doğal bir şekilde bütünleşen pürüzsüz bir yama oluşturur [14].

Negative Prompt (Olumsuz Bilgi İstemi), Stable Diffusion'ı kullanıcının herhangi bir ekstra giriş yapmadan görmek istemediğini belirtmesine izin verecek şekilde kullanmanın bir yoludur. Stable Diffusion modeline, oluşturulan görüntüye nelerin dahil edilmeyeceğini söyleyen bir parametredir.

Prompt (Bilgi İstemi), yazılı metni girdi olarak kullanarak görüntü üretici ile iletişim kurma yöntemidir. Birincil işlevi, yapay zekâ (AI) modeline verilen istemi temel alarak görüntüler oluşturma talimatı vermektir [16]. Şekil 7'te Stable Diffusion modelinin Inpaint yöntemi kullanılarak üretilmiş fotoğraflardan örnekler yer verilmiştir.



Şekil 7. Stable Diffusion modeli Inpaint yöntemi kullanılarak üretilmiş örnekler

2.4. ESA modellerinin eğitilmesi


Bu kısımda veri çoğaltma aşamasında üretilen veri setleri ile ESA modelleri eğitilmiştir. Mediapipe ve Stable Diffusion yöntemleri ile çoğaltılan verilerden 50 kişilik ayrı bir veri seti oluşturulmuştur. Bu veri setinde başarısız çoğaltma işlemi yapılan veriler ayıklanmıştır. ESA modellerinin eğitimleri uzun sürdüğü ve Google Colab 12 saat çalışma sınırı verdiği için veri setindeki başarısız veriler çıkarılarak eğitim süresi düşürülmeye çalışılmıştır. Google Colab'ta AlexNet, VGG-16, Darknet ve GoogLeNet modelleri oluşturulan veri seti ile eğitilmiştir. Ek olarak her fotoğraf için bir ekleme yapılmış, daha sade bir veri seti ile de eğitim yapılmıştır.

2.4.1. AlexNet

2012 yılında Alex Krizhevsky, Ilya Sutskever ve Geoffrey E. Hinton tarafından geliştirilen Evrişimli Sinir Ağı mimarisidir. Girdi olarak 224x224x3 (bazı kaynaklarda 227x227x3 olarak geçer fakat 224x224x3 doğru olanıdır) boyutunda görüntü alır. Beş adet evrişim katmanı ve üç adet tam bağlı katmandan oluşur. Havuzlama katmanlarında maxpooling kullanır [17]. ILSRVC (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) 2012 kazananıdır [18].


Eğitilen ilk derin sinir ağı modeli AlexNet. Bu modelin eğitimlerinde düşük doğruluk oranı problemi ile karşılaşmıştır. Öğrenme katsayısı, aktivasyon fonksiyonu vb. hiper parametrelerde değişiklikler yapılarak bu

problem çözülmüştür. Bu modelin eğitimi 70 epok, öğrenme katsayısı "0.001" ve batch boyutu "32" olarak ayarlanmıştır. Batch Boyutu, ağa verilen alt örneklerin sayısını belirtmektedir [19].



Şekil 8. AlexNet doğruluk oranı grafiği

Şekil 8'da AlexNet modelinin bir fotoğrafta birden fazla eklemenin yapıldığı veri seti ile eğitiminin doğruluk oranı grafiği verilmiştir. Bu grafikte mavi renk ile belirtilen test, sarı renk ile belirtilen ise doğruluk oranının grafiğidir. Eğitim veri setinin tamamının modele verilip bir kere işlenmesine bir epok denir. Her epok sonunda model test verileri ile test edilir ve doğruluk oranına bağlı olarak eğitim yön kazanır. Her epok sonunda doğrulama veri seti de modele verilir. Eğitimin performansını izlemek ve hiperparametreleri ayarlamak için doğrulama verisi ile doğruluk oranı kullanılır. Aynı zamanda modelin ezber yapıp yapmadığı da kontrol edilir. Modelin eğitim ve test verilerini ezberleyip doğruluk oranını yüksek verir ancak modele verilmeyen verilerde düşük başarı elde edilir. Grafikte 20 ve 24. epoklarda bu durum gözlemlenmiştir. Doğrulama doğruluk oranı yüksek değerlerden birden çok fazla düşmüştür. Grafikte görüldüğü gibi doğrulama verisi doğruluk oranı test verisinin altında kalmıştır. Epok sayısı arttıkça test ve doğrulama doğruluk oranları birbirlerine benzer hareket etmiştir. Bu modelin başarı oranı eğitimlerde %85 seviyelerine çıkmıştır.




Şekil 9. Sadeleşmiş veri seti ile eğitilmiş AlexNet doğruluk ve loss oranı grafiği

Şekil 9 'da ise daha sade veri seti ile yapılmış eğitimin doğruluk oranları ve loss değeri grafiği verilmiştir. Loss değeri modelin gerçek verilere ne kadar yakın veya ne kadar uzak olduğunu belirtir. Sağdaki grafikte "Loss" olarak belirtilen test verisi loss değeri ve "Val_Loss" olarak belirtilen ise doğrulama verisi loss değeridir. Bu veri seti 50 epok uzunluğunda eğitilmiştir. İki veri setinde de benzer özellikler görülmektedir.

2.4.2. VGG-16


Bir diğer derin sinir ağı modeli VGG-16 popüler bir ESA modelidir. 2014 yılında Karen Simonyan ve Andrew Zisserman tarafından Oxford üniversitesinde tasarlanmıştır. Altı farklı model olarak ortaya çıkmıştır. Bu modeller 11 (Vgg-11), 13 (Vgg-13), 16 (Vgg-16) ve 19 (Vgg-19) katmandan oluşmaktadır. 11 ve 16 katmandan oluşan modellerin iki farklı çeşidi vardır. Her bir modelde evrişim katmanlarından sonra üç adet tam bağlı katman bulunmaktadır. Bu modeller evrişim katmanlarında 3x3 boyutunda filtre uygular. Girdi olarak 224x224x3 boyutunda görüntü alır. Havuzlama katmanlarında 2x2 boyutunda filtreyle max-pooling uygulanır. Bu model doğrudan Tensorflow kütüphanesinin içerisinde bulunmaktadır. Modelin her bir katmanını tek tek oluşturmak yerine doğrudan fonksiyon olarak çağrılarak kullanılabilir.

Çalışmada test edilmiş model Vgg-16 modelidir. Bu model 13 adet evrişim katmanı ve üç adet tam bağlı katmandan oluşmaktadır [20]. Modelin eğitimi 70 epok, batch boyutu 32 ve öğrenme katsayısı "0.001" olarak ayarlanmıştır.



Şekil 10. Vgg-16 doğruluk oranı grafiği

Şekil 10'de da görüldüğü gibi test ve doğrulama verisi doğruluk oranları birbirlerine çok benzer ilerlemiştir. Doğrulama verisi doğruluk oranı eğitim boyunca test verisinin üstünde kalmıştır. Farklı veri setleri ile yapılan eğitim denemelerinde de doğrulama verisi doğruluk oranı test verisinden yüksek kalmıştır.



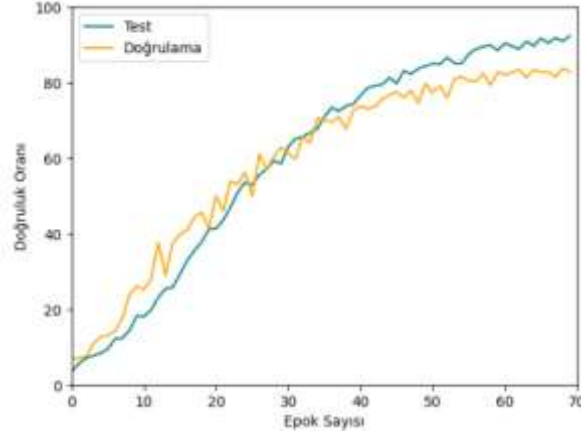
Şekil 11. Sadeleşmiş veri seti ile eğitilmiş Vgg-16 doğruluk ve loss oranı grafiği

Şekil 11'de sade veri seti ile eğitilmiş Vgg-16'nın doğruluk oranları ve loss değeri grafiği verilmiştir. Sade veri seti 50 epok uzunluğunda eğitilmiştir. Bu veri setinin eğitiminin doğruluk değeri daha erken epoklarda yüksek başarı oranlarına çıkmıştır.

2.4.3. GoogLeNet


2014 yılında yapılan ILSRVC (ImageNet Büyük Ölçekli Görsel Tanıma Yarışması) kazananıdır. Girdi olarak gelen görüntüyle aynı anda birden fazla evrişim ve havuzlama işlemi gerçekleştirilir. Elde edilen sonuçlar birleştirilir ve sonraki katmana gönderilir [21]. GoogLeNet mimarisi 22 katman derinliğindedir. Giriş olarak 224x224x3 boyutunda görüntü alır. Havuzlama katmanlarında max-pooling kullanır [22].

Katman yapısı diğer modellere göre daha karmaşık ve uzun olan bir model olmasına rağmen eğitim süreleri genel olarak VGG-16'dan daha kısa sürmüştür. Modelin eğitimi 70 epok, batch boyutu 32 ve öğrenme kat sayısı "0.0001" olarak ayarlanmıştır.



Şekil 12. GoogLeNet doğruluk oranı grafiği

GoogLeNet modelinin diğer modeller gibi tek çıkışlı değildir. Bu modelin üç adet çıktısı bulunmaktadır. Şekil 12'de verilen grafik son katmandaki çıkışa aittir. Grafikte görüldüğü gibi test ve doğrulama verisi doğruluk oranı birbirlerine benzer ilerlemiştir. Eğitimin başlangıcında doğrulama verisi doğruluk oranı test verisinin üstünde kalmış fakat eğitim ilerledikçe test verisi doğruluk oranı doğrulama verisinininkini geride bırakmıştır.



Şekil 13. Sadeleşmiş veri seti ile eğitilmiş GoogLeNet doğruluk ve loss oranı grafiği

Sade veri seti ile GoogLeNet modeli 50 epok uzunluğunda eğitilmiştir. Test doğruluk oranı başlangıçta çok yüksek seviyeden başlamıştır. Veri seti daha sade olduğu için dalgalanma az olmuş ve çok hızlı bir şekilde %100 doğruluk oranını yakalamıştır. Doğrulama doğruluk oranı ise bazı epoklarda hızlı düşüşler yapıp tekrar yükselmiştir.

2.4.4. Model-A

Tensorflow ile derin sinir ağı modeli oluşturulabilmektedir. Bu sebeple yapılan çalışma için basit bir Evrişimli Sinir Ağı modeli oluşturulmuştur. İsmine sembolik olarak Model-A verilmiştir. Bu model 5 adet evrişim katmanından oluşmakta ve her evrişim katmanından sonra bir adet maksimum havuzla bulunmaktadır. Giriş verisi olarak


(256,256,3) boyutunda fotoğraflar almakta, aktivasyon fonksiyonu olarak "ReLU", filtre boyutu (3x3) ve çıkış katmanında "softmax" fonksiyonu kullanmaktadır. Tablo 1'de bu modelin katmanlarının özeti verilmiştir.

Tablo 1. Model-A modelinin katman bilgileri

Katman	Çıkış Boyutu	Parametre Sayısı
1.Evrişim Katmanı	(None, 254,254,16)	448
Maksimum Havuzlama	(None, 127,127,16)	0
2.Evrişim Katmanı	(None, 125,125,32)	4640
Maksimum Havuzlama	(None, 62,62,32)	0
3.Evrişim Katmanı	(None, 60,60,64)	18496
Maksimum Havuzlama	(None, 30,30,64)	0
4.Evrişim Katmanı	(None,28,28,32)	18464
Maksimum Havuzlama	(None, 14,14,32)	0
5.Evrişim Katmanı	(None,12,12,16)	4624
Maksimum Havuzlama	(None, 6,6,12)	0
Flatten	(None, 576)	0
Tam Bağlantı Katmanı	(None, 256)	147712
Tam Bağlantı Katmanı	(None, 50)	7710
Toplam Parametre = 202,094		

Tablo 1'de parametre sayısı olarak belirtilen değerler o katmanda bulunan öğrenilebilir parametreleri ifade eder. Öğrenilebilir parametreler Evrişimli Sinir Ağının nöronları arasında bulunan ağırlıklar ve önyargıdır (bias değerleri). ESA modelinin eğitilmesi sırasında bu parametrelerin değerleri değiştirilir. ESA modelleri eğitilerek bu ağırlıklar ve önyargı değerlerinin en iyi kombinasyonunu bulmaya çalışır. ESA modeline eğitim sonrası verilen girdi verisi bu ağırlık ve önyargı değerleri ile çarpılarak doğru sınıflandırma yapmaya çalışılır.

Bu model de diğer modellerin eğitildiği veri seti ile eğitilmiştir. Eğitim uzunluğu 70 epok, öğrenme katsayısı "0.0001" ve batch boyutu 32 olarak ayarlanmış ve eğitime sokulmuştur. Diğer modellere oranla çok daha az katman ve parametre sayısına sahip olduğu için eğitimi yaklaşık 7 ila 8 kat hızlı gerçekleşmiştir. Bu modelin doğruluk oranı diğer modeller ile benzer çıkmıştır. Şekil 14'te Model-A doğruluk oranı grafiği verilmiştir.

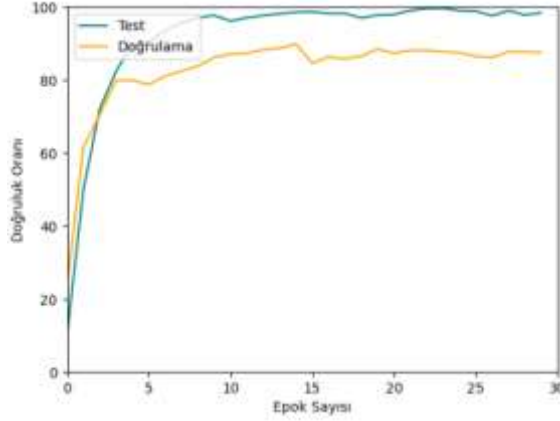


Şekil 14. Model-A doğruluk oranı grafiği


Model-A ESA modeli diğer eğitilen modellerden daha hızlı eğitim gerçekleştirdiği için veri azaltma işlemi uygulamadan, başarısız verilerle birlikte tekrar eğitilmiştir. Elde edilen eğitim sonucu, azaltılmış veri ile yapılan eğitim kadar olmasa da diğer modellerden daha yüksek doğruluk oranı yakalanmıştır.

Şekil 14'te de görüldüğü gibi başlangıçta düşük doğruluk oranı ile başlayıp hızlı bir artış göstermiştir. Doğrulama verisi genel olarak test verisinden düşük seviyede kalmıştır.

Şekil 15'te Model-A'nın azaltılmamış ve başarısız verilerin silinmediği veri seti ile olan eğitiminin doğruluk oranı grafiği verilmiştir.



Şekil 15. Model-A azaltılmamış veri ile eğitimin doğruluk oranı grafiği



Şekil 16. Sadeleşmiş veri seti ile eğitilmiş Model-A doğruluk ve loss oranı grafiği

Bu oluşturulan model sade veri seti ile 50 epok uzunluğunda tekrar eğitilmiştir. Yukarıdaki grafikte görüldüğü gibi başlangıç epoklarında %95 in üzerinde doğruluk oranı göstermiş ve devamında %100 doğruluk oranına ulaşmıştır. Genel olarak sade veri seti ile yapılan eğitimler, oluşturulan veri setinden çok daha yüksek doğruluk oranına sahip olmuştur.

Düşük sayıda sınıf olduğu için bu basit model yüksek doğruluk oranlarını yakaladığını, daha fazla sınıf olduğunda GoogLeNet, VGG-16 ve AlexNet gibi karmaşık modellerin daha başarılı olacağı tahmin edilmektedir. Test aşamasında, eğitilen ModelA test edilmemiştir. Doğru bir test olması için diğer modellere verilen veri seti ile eğitilen ilk model test edilmiştir.

2.4.5. Darknet

Darknet modeli, C ve CUDA dilleri kullanılarak geliştirilmiş bir açık kaynaklı nesne algılama framework'üdür, açık kaynak kodlu bir projedir ve GitHub üzerinden erişilebilir [23].

YOLO (You Only Look Once) algoritması da dahil olmak üzere derin öğrenme teknikleri kullanır [24]. Darknet, nesne algılama ve sınıflandırma, yüz tanıma, video analizi gibi görsel analiz problemlerini çözmek için özellikle etkilidir. Önceden eğitilmiş ağ modellerini kullanma ve yeni veri setlerine özelleştirme yeteneklerine sahiptir. Derin öğrenme modelinin eğitimini gerçekleştirmek için gerekli olan birtakım dosyaları da içerir. YOLO algoritması için Darknet, önceden eğitilmiş bir modeli kullanarak nesne tespiti işlemini gerçekleştirebilir [25].

Bu derin sinir ağını eğitmek için diğerlerinden farklı bir yöntem kullanılmıştır. Veri seti olarak Stable Diffusion ile çoğaltılan yüz verileri, model olarak da Yolov4 kullanılmıştır. Bu yöntemin eğitiminin diğerlerinden farkı yüz verileri fotoğraf üzerinde seçilerek kime ait olduğunun etiketlenmesidir. Etiket kullanılmadan eğitim yapılabilir fakat bu çalışmada etiketli veriler ile eğitim yapılmıştır. Elde edilen veri setindeki her bir fotoğrafta yüzler işaretlenip kime ait oldukları etiketlenmiştir. Yolov4 modeline bu etiketlenmiş yüz verileri verilerek derin sinir ağı eğitilmiştir.

Şekil 17'de Yolov4 modeli ile eğitim sonrası sonuçları verilmiştir. Bu eğitim sonucundaki genel başarı oranı %92,52 olarak elde edilmiştir. Daha detaylı veriler incelenecek olursa ise kişi bazlı olarak (name karşılığında) ortalama performans başarıları görülebilmektedir.

```
Calculation over (mean average precision)...
Detection layer: 130 type = Z8
Detection layer: 130 type = Z8
Detection layer: 141 type = Z8

200
-detections_count = 1829; unique_truth_count = 200
class_id = 0, name = Akshay Kumar, ap = 100.00% [TP = 10, FP = 3]
class_id = 1, name = Alexandra Daddario, ap = 96.69% [TP = 8, FP = 1]
class_id = 2, name = Alia Bhatt, ap = 68.81% [TP = 2, FP = 3]
class_id = 3, name = Amitabh Bachchan, ap = 100.00% [TP = 10, FP = 0]
class_id = 4, name = Andy Samberg, ap = 100.00% [TP = 10, FP = 3]
class_id = 5, name = Anushka Sharma, ap = 84.67% [TP = 10, FP = 6]
class_id = 6, name = Billie Eilish, ap = 100.00% [TP = 10, FP = 5]
class_id = 7, name = Brad Pitt, ap = 99.89% [TP = 9, FP = 0]
class_id = 8, name = Camila Cabello, ap = 94.87% [TP = 8, FP = 1]
class_id = 9, name = Courtney Cox, ap = 84.18% [TP = 8, FP = 5]
class_id = 10, name = Ellen DeGeneres, ap = 100.00% [TP = 10, FP = 2]
class_id = 11, name = Henry Cavill, ap = 87.73% [TP = 8, FP = 2]
class_id = 12, name = Hrithik Roshan, ap = 91.72% [TP = 9, FP = 1]
class_id = 13, name = Hugh Jackman, ap = 88.43% [TP = 9, FP = 0]
class_id = 14, name = Jessica Alba, ap = 85.36% [TP = 8, FP = 5]
class_id = 15, name = Katalie Portman, ap = 81.94% [TP = 8, FP = 4]
class_id = 16, name = Priyanka Chopra, ap = 96.81% [TP = 10, FP = 3]
class_id = 17, name = Robert Downey Jr, ap = 88.71% [TP = 10, FP = 5]
class_id = 18, name = Roger Federer, ap = 85.45% [TP = 8, FP = 4]
class_id = 19, name = Virat Kohli, ap = 100.00% [TP = 10, FP = 4]

for conf_thresh = 0.25, precision = 0.72, recall = 0.90, F1-score = 0.80
for conf_thresh = 0.25, TP = 100, FP = 09, FN = 30, average IAU = 92.52 %

IOU threshold = 50 %, used Area-under-Curve for each unique Recall
mean average precision (mAP@0.50) = 0.925182, or 92.52 %
total Detection Time: 10 seconds
```

Şekil 17. Yolov4 modeli ile eğitim sonrası sonuçları

Test için ayrılan veri setleri eğitilmiş ağa verildiğinde yüksek doğruluk oranı elde edilmiştir. Şekil 19'de test aşamasında alınan çıktılar verilmektedir.



Şekil 18. Yolov4 modeli örnek çıktı sonuçları

3. Bulgular

Bu aşamada eğitilen ESA modelleri test edilmiştir. Toplamda 1000 adet fotoğraf her bir modele verilerek fotoğrafların kime ait oldukları sorulmuştur. Bu 1000 fotoğrafın 750 adeti eğitime sokulan kişilerin eğitimde kullanılmamış fotoğrafları, 250 adeti ise eğitime hiç sokulmamış kişilerden oluşan fotoğraflardır.

GoogLeNet'in testi sırasında bir hata farkedilmiştir. GoogleNet eğitim sırasında yüksek doğruluk oranı vermesine rağmen test sırasında neredeyse hiçbir fotoğrafı doğru sınıflandırmamıştır. Bir kişinin eğitim yapılmış ve ekleme yapılmamış 5 adet fotoğrafı modele verilmiştir. Model bu 5 fotoğrafı 4 farklı kişi ile eşleştirmiş ve bu 4 kişinin 4'ü de yanlış kişilerdir. Bu hata sebebiyle GoogLeNet ilk veri setinin test aşamasında kontrol edilmemiştir.

AlexNet, VGG-16 ve Model-A ESA modellerine hazırlanan 1000 fotoğraflık test verisi verilmiştir. Benzerlik oranı %85'in altında olan cevaplarda kişi tahmini doğru olsa dahi yanlış kabul edilmiştir.

Tablo 2. ESA Modellerinin Test Veri Seti Başarı Oranları

	AlexNet	VGG-16	Model-A
Test Veri Setindeki Yüzde (%) Başarı Oranı	72,3	66,2	68,7

Tablo 2'de AlexNet, VGG-16 ve Model-A modellerinin eğitimde kullanılmayan ve bir fotoğraf üzerinde birden fazla eklemenin yapıldığı test verisinde doğruluk oranları yüzde olarak verilmiştir. Bu modellerin eğitimde de bir fotoğrafa birden fazla eklemenin yapıldığı sade olmayan veri seti kullanılmıştır. AlexNet diğer modellerden yaklaşık yüzde beş oranında daha fazla doğruluk oranı vermiştir.

Bu değerler beklenen başarı oranlarına göre çok düşüktür. Eğitime sokulmayan fotoğraflara yapılan eklemeler ile eğitime sokulmuş fotoğraflardaki eklemeler birbirleri ile aynı olduğu için %85-90 benzerlik oranı ile eşleştirme yapmaktadır. Az sayıda ekleme yapılmış fotoğraflar ise %60-65 oranında benzerlik yakalamışlardır. Bunun dışında hata oranının yüksek olmasına sebep olan iki şey daha vardır. Bunlardan ilki modelin döndürdüğü sınıfın doğru olduğu ama benzerlik sınırının altında kaldığı için yanlış sayılan fotoğraflar. Bu durumu düzeltmek için benzerlik sınırı düşürülebilir fakat bazı test verilerinde sınıf doğru olmasına rağmen %40-45 gibi düşük benzerlik oranı vermektedir.

Diğer bir hata ise veri setindeki dengesizlik. Veriler çoğaltılırken depolama alanı sorunu sebebiyle eklenen filtreler belli sayıda ve rastgele olarak seçilmiştir. Bir gözlük üzerinden örnek verilecek olursa, bir kişi veri çoğaltma aşamasında gözlüğü sadece 1 yerde ve başka bir kişi aynı gözlüğü 3 farklı yerde çoğaltmış varsayalım. Eğitime ilk kişinin bu gözlük ile 10 adet fotoğrafı ikinci kişinin ise 30 fotoğrafı verilmiştir. Test aşamasında ilk kişinin bu gözlük ile olan farklı bir fotoğrafı modele verildiğinde model bu kişiyi ikinci olarak işaretlemektedir. Veri setinin homojen ve doğru olmasının önemi bu kısımda tekrardan anlaşılmıştır.

Bu sebeple sade bir veri seti oluşturulmuştur. Bu veri setinde fotoğraflara tüm eklemeler uygulanmış fakat aynı anda sadece bir adet ekleme kullanılmıştır. Böylece eğitim aşamasında homojen bir veri seti kullanılmıştır.

Yeni eğitilen modellerin test verileri önceki eğitimin testinde kullanılan 1000 fotoğraf ile aynı fotoğraflardır. Önceki veri setinde olduğu gibi doğru cevap için %85'in üstünde bir benzerlik oranı beklenmektedir. Aşağıdaki Tablo 3'te ModelA, AlexNet, VGG-116 ve GoogleNet'in test sonucu doğruluk oranları verilmektedir.

Tablo 3.ESA Modellerinin sadeleşmiş veri seti ile eğitilmiş Test Veri Seti Başarı Oranları

	AlexNet	VGG-16	Model-A	GoogLeNet
Test Veri Setindeki Yüzde (%) Başarı Oranı	65,0	69,0	72,2	84,2

Tablo 3'te verilen doğruluk oranları eğitim veri setinde bir fotoğrafa maksimum bir adet eklemenin yapıldığı sade veri seti ile eğitilmiş modellerin test sonucu verilmiştir. Bu testte eğitim veri setinin aksine bir fotoğrafta birden fazla eklemenin yapıldığı fotoğraflar kullanılmıştır. Tablo 3'te görüldüğü gibi VGG-16 ve Model-A'nın doğruluk oranında artış gözlemlenirken AlexNet'te düşüş görülmüştür. AlexNet yeni veri setinde bazı kişilerin tüm fotoğraflarını doğru bilirken bazı kişilerin fotoğraflarını eğitime katılmış başka biriyim gibi tek bir kişi olarak

hatalı bilmektedir. Bu sebeple doğruluk oranı düşmüştür. GoogleNet, bu veri setinde hatasız çalışmış ve diğer modellerden daha yüksek doğruluk oranına ulaşmıştır; ayrıca, eğitime sokulmamış kişilerin sınıflandırılmasında da diğerlerine göre önemli ölçüde daha başarılı olmuştur. Test sonuçları ele alındığında sadeleştirilmiş veri seti ile yapılan eğitimin, eklemeleri sınırlandırarak homojen olmayan veri setinin eğitiminden çok daha başarılı olduğu görülmüştür. GoogleNet hem eğitime katılmış kişilerin hem de eğitime katılmamış kişilerin sınıflandırılmasında diğerlerinden başarılı olmuştur. Ayrıca sadeleştirilmiş veri seti ile eğitilen modeller birden fazla ekleme olan fotoğrafları da doğru bilmiştir. Bu sebeple bir fotoğrafa birden fazla ekleme yapmaya gerek görülmemektedir.

4. Tartışma ve Sonuç

Mediapipe yöntemi kullanılarak kodlar ile otomatize edilebilen veri çoğaltma işlemi, yapılan çalışmanın tamamlanmış ve sonuçlanmış bir aşamasını oluşturmaktadır. Test aşamasında meydana gelen homojenlik probleminden dolayı her fotoğrafa bir ekleme yapılmıştır. Veri seti oluşturulurken hatalı veriler çıkarılmamış, modeli güçlendirmek için veri seti içerisinde bırakılmıştır.

Stable Diffusion ile fotoğraflara eklenen gözlük, şapka, sakal vb. eklentilerin görüntüsü Mediapipe ile yapılan eklemelere göre çok daha başarılı olmuştur. Fakat bu işlemde çıktı almak çok uzun sürmektedir. Ayrıca tek seferde çok fazla çıktı alınamamakta, alınan çıktılar bazılarının da bozuk olabilmektedir. Stable Diffusion, kurumun kendi ağlarını daha güçlü hale getirmek için veri setine takviye yapmak isterlerse kullanılabilir bir yöntem olabilir.

Yapılan ESA modelleri eğitimlerinde doğruluk oranı dört modelde de yüksek sayılara ulaşmıştır. Eğitimlerde doğruluk oranları tüm modellerde birbirine çok yakındır.

Veri seti daha homojen yapıldığında test başarıları daha düzgün seviyelere gelmektedir. Bu modeller arasında yoklama sisteminde kullanmaya en uygunu, test aşamasında diğerlerinden daha yüksek başarı oranına sahip olan GoogleNet olmuştur.

Bu ağ modellerinden farklı olarak eğitilen Yolov4 modeli yoklama sistemi için ana Evrişimli Sinir Ağı olamaz. Çünkü her bir fotoğraf tek tek el ile işaretlenip kime ait olduğu etiketlenmesi gerekmektedir. Fakat bu yöntem dönem ortasında kuruma yeni katılan kişilerin sonraki büyük ESA eğitimine kadar geçici süre yoklama için ufak eğitimler ile kullanılabilir.

Yüz görüntülerine filtre eklemek, literatürde daha önce denenmiş bir yaklaşımdır. Evrişimli Sinir Ağları Kullanarak Yüz Belirleme ve Tanıma Uygulaması, önceki uygulamalardan birkaç önemli noktada farklılık göstermektedir. Önceki uygulamalar genellikle tek bir filtreye odaklanırken, yeni uygulama birden fazla filtre kullanarak insan yüzüne çeşitli kılık değiştirmelerle karşı kimlik tespitinin doğruluğunu artırmayı amaçlamaktadır [26].

İki uygulama arasındaki temel fark, yeni uygulamanın daha kapsamlı olmasıdır. Yeni uygulama, yüz tanımanın çeşitli yönlerini içermektedir ve kişiyi çeşitli durumlarda tanıma potansiyeline sahiptir [26]. Genel olarak, yeni uygulama önceki uygulamalara göre daha iyi sonuçlar sunmaktadır. Bu uygulama, homojen veri seti kullanılarak kişinin filtrelenmiş halinin tespitinde başarılı olmuştur [26].

Bu çalışmada, AlexNet, VGG-16, GoogleNet, DarkNet ve daha basit bir yapıya sahip olan Model-A modellerinin, birden fazla kişinin kullanıldığı bir yüz tanıma uygulamasındaki doğruluk yetenekleri incelenmiştir. Modellerin insan yüzündeki fiziksel değişikliklere karşı daha etkili tahminler yapabilmesi için eğitim verilerine bir veya daha fazla fotoğraf eklenmiştir. Eklenen fotoğrafların modellerin bu değişikliklere tepkilerini değerlendirmek amacıyla başarı oranları analiz edilmiş ve elde edilen sonuçlar, literatüre önemli bir katkı sağlamıştır.

TEŞEKKÜR

Bu araştırma 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı Kapsamında 1919B012220788 numarası ile desteklenmiştir.

ETİK STANDARTLARIN BEYANI

Bu makalenin yazar(lar)ı çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal özel bir izin gerektirmediğini beyan ederler.

YAZARLARIN KATKILARI

Özge Gürbüz-Problemi tanımlamış, konu ile ilgili literatürü taramış, problemi modellemiş, uygulama sonuçlarını analiz etmiş ve çalışmanın yazım işlemini gerçekleştirmiştir.

Tolga Yılmaz-Problemi tanımlamış, konu ile ilgili literatürü taramış, problemi modellemiş, uygulama sonuçlarını analiz etmiş ve çalışmanın yazım işlemini gerçekleştirmiştir.

ÇIKAR ÇATIŞMASI

Yazarlardan Özge Gürbüz Çalık Holding firmasında çalışmaktadır.

KAYNAKLAR

- [1] Li, M., Huang, B., & Tian, G. (2022). A comprehensive survey on 3D face recognition methods. *Engineering Applications of Artificial Intelligence*, 110, 104669.
- [2] Türkoğlu M., Hanbay K., Saraç Sivrikaya I. & Hanbay D., (2020). Derin Evrişimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. *BEÜ Fen Bilimleri Dergisi*, 9(1), 334-345.
- [3] Wu, C., Hu, H., Lin, K., Wang, Q., Liu, T., & Chen, G. (2023). Attention-guided and fine-grained feature extraction from face images for gaze estimation. *Engineering Applications of Artificial Intelligence*, 126, 106994.
- [4] Ou, W., You, X., Tao, D., Zhang, P., Tang, Y., & Zhu, Z. (2014). Robust face recognition via occlusion dictionary learning. *Pattern Recognition*, 47(4), 1559-1572.
- [5] Li, Y., Song, L., Wu, X., He, R., & Tan, T. (2019). Learning a bi-level adversarial network with global and local perception for makeup-invariant face verification. *Pattern Recognition*, 90, 99-108.
- [6] <https://fei.edu.br/~cet/facedatabase.html> FEI face database (Erişim tarihi: 25.02.2023)
- [7] <http://vis-www.cs.umass.edu/lfw/> Labeled Faces in the Wild (Erişim tarihi: 25.02.2023)
- [8] Alimovski, E. (2019). Derin öğrenmeye dayalı güçlü yüz tanıma sistemi için gan ile veri çoğaltma (Master's thesis, İstanbul Sabahattin Zaim Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı).
- [9] <https://medium.com/deep-learning-from-deepest/derin-ogrenme-ve-evrisimsel-sinir-aglari-446dc8a8d2f> Derin Öğrenme ve Evrişimsel Sinir Ağları (Erişim Tarihi: 16.09.2023)
- [10] Sert Z., ESA (Evrişimsel Sinir Ağları) <https://zeysert.medium.com/esa-evrisimsel-siniraglari-87d9bd986579> (Erişim tarihi: 07.07.2023)
- [11] <https://developers.google.com/mediapipe> Mediapipe (Erişim tarihi: 14.03.2023)
- [12] <https://github.com/google/mediapipe/tree/a908d668c730da128dfa8d9f6bd25d519d006> Mediapipe (Erişim Tarihi: 7 Temmuz 2023)
- [13] <https://www.makesense.ai> MakeSense (Erişim Tarihi: 16.09.2023)
- [14] <https://neuroflash.com/blog/understanding-stable-diffusion-inpainting-aguide/#:~:text=Stable%20Diffusion%20Inpainting%20is%20a,damaged%20parts%20of%20an%20image> Understanding Stable Diffusion Inpainting: A Guide (Erişim tarihi: : 07.07.2023)
- [15] <https://stablediffusionweb.com/WebUI> Stable Diffusion (Erişim Tarihi: 16.09.2023)
- [16] <https://www.hosting.com.tr/blog/midjourney/> Midjourney Nedir? Yaratıcılığınızı Görsellere Çevirin – Yapay Zekâ ile Mükemmel Görseller Oluşturma (Erişim tarihi: 07.07.2023)
- [17] Krizhevsky A., Sutskever I., & Hinton G. E., (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems*, 25(2),1097-1105.
- [18] Ghazi M. M., Yanikoglu B. & Aptoula E., (2017). Plant identification using deep neural networks via optimization of transfer learning parameters. *Neurocomputing*, 235, 228-235.
- [19] <https://towardsdatascience.com/what-are-hyperparameters-andhow-to-tune-the-hyperparameters-in-a-deep-neural-network-d0604917584a> (Erişim tarihi: 07.07.2023)
- [20] Simonyan K. & Zisserman A. (2014). Very Deep Convolutional Networks for LargeScale Image Recognition. *arXiv preprint arXiv:1409.1556*.
- [21] Kurt F., (2018). Evrişimli Sinir Ağlarında Hiper Parametrelerin Etkisinin İncelenmesi, Yüksel Lisans tezi, Hacettepe Üniversitesi.
- [22] Szegedy C., Liu W., Jia Y., Sermanent P., Reed S., Anguelov D., Erhan D., Vanhoucke V. & Rabinovich A., (2015). Going deeper with convolutions, 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (ss 1-9).
- [23] <https://github.com/pjreddie/darknet> Darknet (Erişim tarihi: 07.07.2023)
- [24] <https://pjreddie.com/darknet/> Darknet: Open Source Neural Networks in C (Erişim tarihi: 07.07.2023)
- [25] Ozel, M. & Baysal, S. & Sahin, M. (2021). Derin Öğrenme Algoritması ile Dinamik Test Süresince Süspansiyon Parçalarında Çatlak Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (26), 1-5.
- [26] Yılmaz, A. G., Gedikli, E., & Alhori, O. (2023). Yüz Görüntülerine Morflemeye Dayalı Maske Giydirmeye ve Maskeli Yüz Tanıma. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 27(1), 12-21.



Çoktan Seçmeli Sorularda Kararlı Durum Görsel Olarak Uyarılmış Potansiyel Tabanlı Beyin Bilgisayar Arayüzü Kullanılması

Elif Yıldırım¹, Fatih Aydın², Oğuzhan Başer³, Önder Aydemir⁴

(Alınış / Received: 17.12.2023, Kabul / Accepted: 10.01.2024, Online Yayınlanma / Published Online: 30.01.2024)

Anahtar Kelimeler

Beyin Bilgisayar Arayüzü
Elektroensefalografi
Kararlı Durum Görsel Olarak
Uyarılmış Potansiyel

Öz: Önerildiği ilk yıllarda daha çok felçli hastalara yönelik olan beyin bilgisayar arayüzü (BBA) teknolojisi zaman içinde akıllı ev ve araba uygulamalarından oyun sektörüne uzanan geniş bir yelpazede kullanılmaya başlanmıştır. Bu çalışmada kişilerin sadece düşüncelerini kullanarak, çoktan seçmeli sorulara yanıt vermelerine olanak sağlayan yeni bir BBA modeli geliştirilmiştir. Literatürde BBA modelleri için kullanılan elektroensefalogram (EEG) cihazları yerine, geliştirilen bu modelde Texas Ins. ADS1299 çipi ile bir EEG ölçüm sistemi tasarlanmıştır. Hem önerilen uygulama hem de geliştirilen ölçüm sistemi açısından yenilikçi olan bu çalışma; engelli statüsünde sınavlara katılan bireylerin sadece düşünceleri ile sorulara cevap vermelerine olanak sağlayacaktır.

Using Steady State Visually Evoked Potential-Based Brain Computer Interface in Multiple Choice Questions

Keywords

Brain Computer Interface
Electroencephalography
Steady State Visually Evoked
Potential

Abstract: In the early years, brain-computer interface (BCI) technology was primarily aimed at patients with paralysis. Over time, it has begun to be used in a wide range of applications, from smart home and car applications to the gaming industry. In this study, a new BCI model has been developed that allows individuals to answer multiple-choice questions using only their thoughts. Instead of electroencephalogram (EEG) devices commonly used in BCI models in the literature, this model involves a designed EEG measurement system using the Texas Ins. ADS1299 chip. This innovative study, both in terms of the proposed application and the developed measurement system, will enable individuals with disabilities to answer questions using only their thoughts in exams.

¹ Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Trabzon, Türkiye

² Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Trabzon, Türkiye

³ Karadeniz Teknik Üniversitesi, Medikal Cihaz Tasarım ve Üretim Uygulama ve Araştırma Merkezi, Trabzon, Türkiye

⁴ Karadeniz Teknik Üniversitesi, Elektrik-Elektronik Mühendisliği Bölümü, Trabzon, Türkiye

Sorumlu yazar ve e-posta adresi: Fatih Aydın aydinf@ktu.edu.tr

1. Giriş

Beynin elektriksel aktivitesini gerçek zamanlı olarak işleyip bilgisayar komutlarına dönüştüren ve bu yolla beyin ile bilgisayar arasında bir haberleşme katmanı oluşturan sistemlere beyin bilgisayar arayüzü (BBA) denir [1]. Literatürde; BBA ile ilgili tıp, haberleşme, kontrol/kumanda, eğlence gibi alanlarda birçok çalışma yapılmıştır ve bu çalışmaların çoğu beyin sapı felci, ileri seviye omurga hasarı, amyotrofik lateral skleroz (ALS) gibi kronik kas-sinir hastalıkları sonucunda felçli olan bireylerin yaşadığı kontrol ve iletişim problemlerini gidermeye odaklanmıştır [2, 3]. Örnek olarak ALS hastalarında zamanla konuşma hızının düşmesiyle anlaşılabilirliğin azalmaya başladığı durumlarda hastanın iletişim kurabilmesi için BBA sistemlerinin oldukça yararlı uygulamalar olduğu görülmektedir [4]. Cortez vd. (2021) yaptıkları çalışmada, felç geçirmiş bireylerin evlerindeki konforunu koruyabilmek adına kontrol alanından bir örnek olarak BBA entegre edilmiş akıllı ev sistemlerini kullanabileceklerini göstermiştir [5].

P300 ve kararlı durum görsel olarak uyarılmış potansiyel (KDGOU, ing. Stable State Visually-Evoked Potential-SSVEP) BBA çalışmalarında en sık kullanılan yöntemlerdendir [6]. P300, beynin beklenmedik bir uyarana karşılaştıktan 300 ms. sonra tepki olarak ürettiği elektriksel aktiviteye verilen isimdir [7]. KDGOU ise belirli bir frekans ile yanıp sönen görsel bir uyarana karşısında beyinde oluşan tepkidir. İncelenen EEG kayıtlarında görülmüştür ki görsel uyarının frekansı, beyin görsel bölgesi olarak anılan oksipital bölgedeki elektriksel aktivitenin baskın frekansı ile ilişkilidir [8].

Literatürde bulunan BBA çalışmaları sayesinde, kullanıcıların BBA heceleyicileri adı verilen yazım arayüzleri ile kendilerini ifade edebilmesini [9, 10], bir tekerlekli sandalyeyi veya bir el protezini kontrol edebilmesini [11, 12], bir bilgisayar oyunu oynayabilmesini [13, 14] veya günlük yaşantıda yardımcı olabilecek bazı elektronik cihazları [15, 16] kontrol edebilmesi mümkün kılınmıştır. Son zamanlarda ise BBA, giderek popülerlik kazanan sanal gerçeklik ve nesnelerin interneti teknolojileri ile entegre edilmektedir ve BBA aracılığıyla ortamın gerçek zamanlı olarak kontrol edildiği çalışmalar gerçekleştirilmektedir [17]. Ayrıca askeri alanda BBA kullanımı öngörülmektedir [18]. Wang vd. (2018) Tetris oyunu kontrolleri için geliştirdikleri hibrit yöntemde motor hayali ve KDGOU yöntemlerini kullanmışlardır. Motor hayali yöntemi hız ve doğruluğun yüksek olması gereken komutlar için kullanılırken; KDGOU yöntemi oyunda karşılaşılabilecek hatalı rotasyon komutlarını olabilecek en az seviyeye indirebilmek için kullanılmıştır [19]. Allison vd. (2014) tarafından yapılan 4 seçeneğe sahip hibrit P300/KDGOU çalışmasında P300 ve KDGOU tekniği yakın sonuçlar vermiş olsa da katılımcılar P300 içeren paradigmayı daha yorucu bulmuşlardır. Bunun yanında sürekli kontrol gerektiren sistemlerde KDGOU kullanılmasının daha uygun olacağı sonucuna varılmıştır [20]. KDGOU tabanlı BBA ile bir elektrikli el protezin hareket ettirilmesini amaçlayan Muller-Putz ve Pfurtsceller (2008), yaptıkları çalışmada gerçekleştikleri protezi, parmakları açıp kapayarak kavrama işlevini, buna ek olarak da bileği sağa ve sola döndürmeyi sağlayacak şekilde programlamıştır. Bileğin sola döndürülmesini sağlayacak 6 Hz frekanslı led serçe parmağa, sağa döndürülmesini sağlayacak 7 Hz frekanslı led ise işaret parmağına bağlamıştır. Eğitim sırasında gönüllüler aracılığıyla toplamda 160 deneme yapılmış ve bu denemeler sonucunda %44 ile %88 sınıflandırma doğruluğu elde edilmiştir [12]. KDGOU tabanlı bilgisayar oyunu tasarlayan E. Lalor vd. (2004) yaptıkları çalışmada, KDGOU tabanlı BBA kullanarak, 3D oyunların beyinden alınan EEG sinyalleri ile kontrol edilmesini hedeflemişlerdir. Oyunun arayüzünde, karakterin sağ ve solunda bulunan 2 farklı frekansa sahip (6 ve 8 Hz) matrisler kullanılmıştır. Böylece dengenin hangi tarafa kurulması gerektiğini oyuncu seçmektedir. Bu sinyallerin anlaşılabilir hale getirilmesi için 3 öznelik ve çeşitli sınıflandırma metotları kullanılmıştır. Test aşamasında oyun, çalışmaya katılan oyuncular tarafından 48 tur oynanmıştır ve bu oyunlardan 41 tanesinde animasyonlu karakter dengede kalarak oyunu başarılı bir şekilde tamamlamıştır. Bu çalışmanın sağladığı performansın, dikkat eksikliği/hiperaktivite bozukluğu teşhisi konmuş hastaların rehabilitasyon sürecine olan etkisini pozitif yönde artıracak ön sürülmüştür [13]. Hongtao Wang vd. (2011) ise yaptıkları çalışmada, KDGOU tabanlı BBA kullanarak uzaktan kumandalı elektrikli arabanın, beyinden alınan EEG sinyallerini kullanarak kontrolünü sağlamayı amaçlamışlardır. Görsel uyarım olarak 9 Hz, 11 Hz, 13 Hz, 15 Hz ve 17 Hz frekans değerlerine sahip 5 farklı led kullanılmıştır. Bu ledler ileri, geri, sağ, sol ve durdurma komutlarına ait bileşenlerdir. Gerekli öznelik çıkarma ve sınıflandırma metotları uygulandıktan sonra, farklı dönem uzunluklarına sahip kişilerden alınan verilerin sınıflandırılmasında çapraz doğrulama metodu kullanılmış ve dönem uzunlukları arttıkça sınıflandırma doğruluğu %100'e yakın doğruluk vermiştir [14].


Literatür incelemeleri göstermektedir ki; KDGOU tabanlı BBA ile oluşturulan çalışmaların birçoğu heceleyiciler, tekerlekli sandalyeler ve bilgisayar oyunları üzerine olan çalışmalara odaklanmıştır. Ancak mevcut çalışmalar, bireylerin sadece nöral aktivitelerini kullanarak çoktan seçmeli bir soruya yanıt vermesine olanak tanıyan bir KDGOU tabanlı BBA çalışmanın henüz gerçekleştirilmediğine işaret etmektedir. Bu tür bir çalışma, özellikle genel kültür alanında doğru ve yanlış seçenekler içeren sınav sorularının yalnızca nöral aktivite ile yanıtlanabilmesi açısından büyük potansiyele sahiptir. Bu çalışmanın temel amacı, bireylerin çoktan seçmeli sorulara sadece nöral aktivitesiyle KDGOU tabanlı BBA kullanarak yanıt verebilmeleri ve verdikleri yanıtların yüksek bir doğrulukla belirlenmesidir. Verilen yanıtın yüksek doğrulukla belirlenebilmesi için Ag/AgCl kendinden jelli elektrot

kullanılarak oksipital bölgeden alınan EEG sinyallerine Hızlı Fourier Dönüşümü (HFD) ve bant gücü özneliği uygulanmıştır. Uygulanan yöntemler sonucunda 8 sorudan 7 tanesinde katılımcıların seçtiği seçenek tespit edilmiştir ve %87.5 sınıflandırma doğruluğu elde edilmiştir.

2. Materyal ve Metot

2.1. Verilerin Alınması

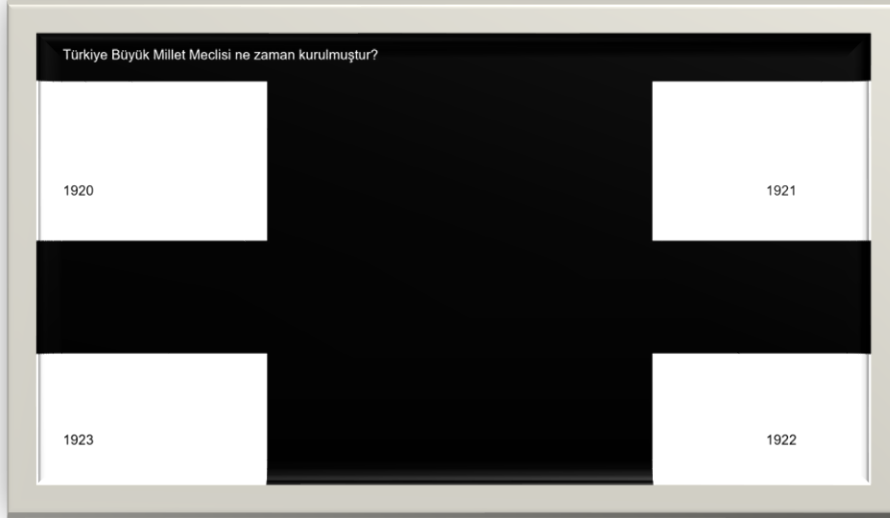
Verilerin alınması amacıyla 2 gönüllü katılımcı test ortamına davet edilmiştir. Gönüllü katılımcılar 'Katılımcı 1' ve 'Katılımcı 2' olarak adlandırılmıştır. Katılımcı 1, bilinen herhangi bir nöro-kas veya zihinsel bozukluğu olmayan sağlıklı ve kısa saçlı olan 24 yaşındaki bireydir. Katılımcı 2 de bilinen herhangi bir nöro-kas veya zihinsel bozukluğu olmayan sağlıklı ve Katılımcı 1'e göre daha uzun saçlı olan 25 yaşındaki bireydir. Gönüllü katılımcılar 60 Hz yenileme hızına sahip LCD monitörden 0.7 metre uzaklıkta rahat bir sandalyeye oturtulmuştur. Yerini alan katılımcıdan ilgili EEG sinyallerinin alınması amacıyla, 10-20 elektrot sistemine göre A1 referans alınarak Pz ve Oz konumlarına 2 adet Ag/AgCl kendinden jelli elektrot yerleştirilmiştir. Kaydedilen EEG sinyallerinin sinyal-gürültü oranını yükseltmek amacıyla elektrot empedansları 10 k Ω 'un altında tutulmuştur.



Şekil 1. Elektrot konumları

Gönüllü katılımcılardan ADS1299 ön uç arayüzü kartının 3 kanalı kullanılarak ilgili EEG sinyal verileri kaydedilmiştir. Bu kanalların iki tanesi fark alma üçüncüsü ise topraklama amacıyla kullanılmıştır. Örneklem frekansı 500 Hz olup her bir soru için 6000 örnek içeren, 12 saniye uzunluğunda kayıt alınmıştır.

Deney esnasında katılımcının ona yöneltilen soru ve seçenekleri okuması, yanıt vermek istediği ilgili hücrede siyah/beyaz olarak yanıp sönen ışığa odaklanması ve bunun sonun olarak görsel uyartım frekansı ile ilgili bantta nöral aktivite oluşturması için bir uyartım paradigması oluşturulmuştur. Oluşturulan uyartım paradigma arayüzünde siyah arka plan üzerine seçenekler için dört ayrı hücre konumlandırılmıştır. Her hücre sadece kendine ait bir frekansta siyah ve beyaz renklerde yanıp sönmektedir. Hücrelerin içerisine seçenek metni yanıp sönmeyecek şekilde siyah renkte yazılmıştır. Sorular, bu bölünmüş hücrelerin yukarısında kalan boş alana yazılmıştır. Sorunun bulunduğu alanda herhangi bir yanıp sönmeye işlemi uygulanmayıp; siyah zemin üzerine beyaz renkte yazılmıştır. Uyartım paradigma arayüzü MATLAB R2022b üzerinden Psychtoolbox kullanılarak oluşturulmuştur. Hücreler üzerinde bulunan görsel uyartım frekansları A, B, C, D seçenekleri için sırasıyla 8.5 Hz, 6.6 Hz, 10 Hz ve 7.5 Hz olarak belirlenmiştir.



Şekil 2. Tasarlanan uyartım paradigması arayüzü

Uyartım paradigma arayüzü çalıştırıldığında ekranda tek bir soru görülmektedir. Soruya ait seçenekler, kendi frekanslarında yanıp sönmeye başlamadan önce 5 saniye boyunca ekranda kalmaktadır. Bu süre zarfında gönüllü katılımcının soru ve seçenekleri okuması beklenmiştir. 5 saniye ardından 7 saniye süren, seçeneklerin yanıp sönmeye işlemi başlatılmıştır. 7 saniye süren yanıp sönmeye işlemi bittikten sonra yeni soru ekrana gelmiştir ve süreç aynı şekilde devam etmiştir. Her katılımcıya art arda olacak şekilde 4 adet soru yöneltilmiştir. Deney sonrasında katılımcıların sorulara verdikleri yanıtlar beyanları üzerine kaydedilmiştir.

2.2. Yöntem

Önerilen yöntem 4 aşamadan oluşmaktadır. Bunlar HFD alınması, filtreleme, bant gücü özniteliği çıkarılması ve sınıflandırma aşamalarıdır.

Bir kişi, belli bir frekansta yanıp sönen bir uyarıyı izlediğinde, beyindeki KDGÖUP yanıtı, ilgili yanıp sönmeye frekansında ortaya çıkmaktadır [21]. Bu nedenle uygulanacak yöntemlerle elde edilen sinyal verilerinin filtrelenmesi, frekans bölgesi analizi ve bu bölgedeki güç analizinin yapılması gerekmektedir. Bu gereklilikler doğrultusunda kaydedilen sinyal verilerine HFD ve bant gücü özniteliği uygulanmıştır. Elde edilen bant gücü değerlerine göre sınıflandırma yapılmıştır. Uygulama ortamı olarak MATLAB R2022b kullanılmıştır.

2.2.1. Hızlı Fourier Dönüşümü

Frekans alan analiz yöntemi olan HFD, literatürde bulunan BBA çalışmalarında beyin sinyallerinden öznitelik çıkarılması aşamasında sıkça tercih edilmektedir [22]. HFD, çalışmada farklı frekansta yanıp sönen hücreler sonucu oluşan nöral banttaki aktivitenin ayırt edici davranışlarını gözlemlemek, hücrelerin sahip olduğu frekans aralıklarındaki (6.6 Hz ile 10 Hz) göreceli gücü keşfetmek ve baskın frekans bileşenlerini belirlemek için kaydedilen verilere uygulanmıştır. HFD, ayrık Fourier dönüşüm işleminin hızlandırılmış bir versiyonu olduğundan örneklenmiş bir sinyalin ayrık Fourier dönüşümü Denklem 1'de verilmiştir.

$$X(k) = \sum_{n=1}^{N-1} x(n) e^{-j2\pi kn/N} \quad (1)$$

Denklem 1'de $X(k)$ Fourier katsayılarını, $x(n)$ dönüşümü alınmak istenen işaret, N işaretteki örnek sayısını temsil etmektedir.

2.2.2. Bant Gücü Özniteliği Çıkarılması ve Sınıflandırma

Sinyal işleme bağlamında, bant gücü bir sinyalin belirli bir frekans bandında bulunan güç miktarını ifade etmektedir. Gönüllü katılımcıların vermiş olduğu yanıt seçeneğinin belirlenebilmesi için HFD alınmış verilerden bant gücü özniteliği elde edilmiştir. Bunun için ilgili frekansları içerisinde bulunduran 5–11 Hz arası bant, adım büyüklüğü 0.9 Hz seçilerek 6.6 Hz, 7.5 Hz, 8.5 Hz ve 10 Hz olacak şekilde 4 farklı banda bölünmüştür. Her veri için, bölünen her bir bantın ayrı ayrı bant gücü, o banttaki sinyal örneklerinin büyüklüğünün kareleri toplanarak hesaplanmıştır. İlgilenilen frekansın bulunduğu bantta hesaplanan toplam güç değerinin, diğer seçeneklerin sahip

olduğu frekansların bulunduğu bantlardaki güç değerinden daha büyük olması beklenmiştir. Böylece büyük güç değerine sahip banda düşen frekans ile yanıp sönen seçenek, seçilen yanıt seçeneği olarak sınıflandırılmıştır. Örneğin 8.5 Hz frekansına sahip A seçeneğini seçen katılımcıdan alınan sinyal verilerinin bu belirlenen 4 bant için güç değerleri ayrı ayrı hesaplandığında, 7.6–9.4 Hz aralığında bulunan bantta oluşan güç değerinin diğer bantlarda (5.7–7.5 Hz, 9.1–10.9 Hz ve 6.6–8.4 Hz) hesaplanan güç değerlerinden daha yüksek bir değerin elde edilmesi beklenmiştir. Böylece elde edilen bu sonuç A seçenek grubuna sınıflandırılmıştır.

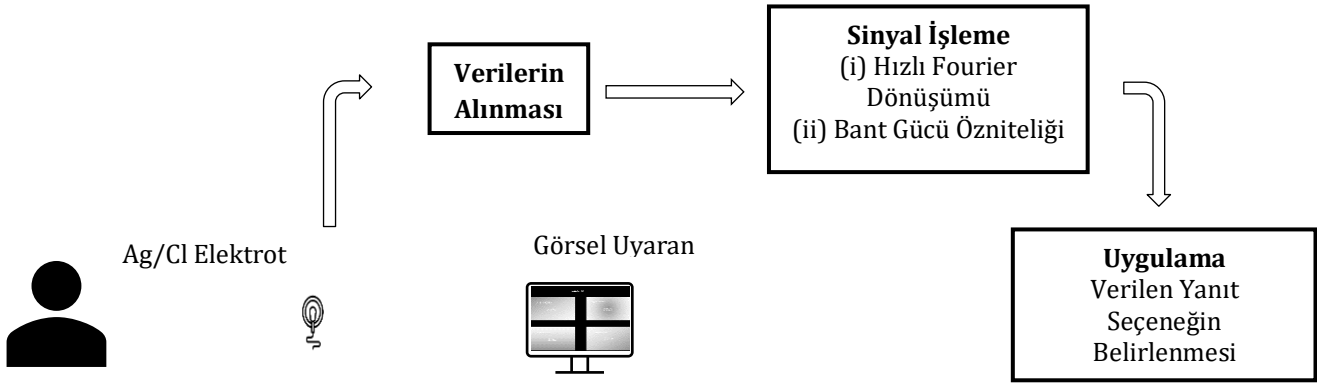
Tablo 1. Belirlenen frekans bant sınırları

Seçenekler	Seçeneklerin Sahip Olduğu Merkez Frekanslar (Hz)	Bant Gücü Özniteliği İçin Belirlenen Frekans Bant Sınırları (Hz)
A Seçeneği	8.5	7.6–9.4
B Seçeneği	6.6	5.7–7.5
C Seçeneği	10	9.1–10.9
D Seçeneği	7.5	6.6–8.4

$X(f)$, f karmaşık sayı olarak frekansı temsil etmek üzere bant gücü Denklem 2 kullanılarak hesaplanmıştır.

$$\sum |X(f)|^2 \quad (2)$$

Çalışmanın akış diyagramı Şekil 3'teki gibidir.



Şekil 3. Çalışma akış diyagramı

3. Bulgular

Bu çalışmada, KDGOU tabanlı BBA kullanılarak çoktan seçmeli bir soruya verilen yanıt seçeneğinin doğru tespit edilmesi amaçlanmıştır. Bu amaç doğrultusunda, kaydedilen verilere HFD uygulanmış ve bu verilerin bant gücü öznitelikleri elde edilmiştir. Elde edilen bant gücü değerlerine göre sınıflandırma yapılmıştır. Bant gücünü hesaplamak için 5–11 Hz aralığı, yanıt frekansları ile örtüşen 4 ayrı frekans bandına ayrılmıştır. Seçeneklerin sahip olduğu frekans değerleri merkez kabul edilerek bu değerlerden 0.9 Hz düşük ve 0.9 Hz yüksek olan değerler bant sınırları olarak kabul edilmiştir. Her veri için, bölünen her bir bantın ayrı ayrı bant gücü, o banttaki Fourier dönüşümü alınan sinyal örneklerinin büyüklüğünün kareleri toplanarak MATLAB R2022b üzerinden hesaplanmıştır. Elde edilen bant gücü değerleri katılımcının hangi seçeneği seçtiği konusunda bilgi vermektedir. Elde edilen sonuçlara göre en yüksek bant gücüne sahip frekans bandında bulunan seçenek, katılımcının seçtiği yanıt seçeneği olarak sınıflandırılmıştır. Bu yöntemle 4 sınıflı bir sınıflandırma yapılmıştır. Katılımcılardan alınan 8 sinyal verisinin hesaplanan bant gücü değerleri Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te verilmiştir.

Tablo 2. A seçeneği (8.5 Hz) seçildiğinde kaydedilen verilerin bant gücü değerleri

	5.7-7.5 Hz Sınırlarına Sahip Bant	6.6-8.4 Hz Sınırlarına Sahip Bant	7.4-9.4 Hz Sınırlarına Sahip Bant	9.1-10.9 Hz Sınırlarına Sahip Bant
Katılımcı 1 İçin Hesaplanan Bant Gücü (μV)	140	115	182	136
Katılımcı 2 İçin Hesaplanan Bant Gücü (μV)	126	114	205	164

Tablo 2'de katılımcıların A seçeneğine odaklandıkları anlarda kaydedilen verilerin bant gücü değerleri gösterilmiştir. İki katılımcı için de bant gücünün en yüksek olduğu frekans bandı 7.4-9.4 Hz olmuştur. Bu, A seçeneğinin yanıp sönme frekansını içeren frekans bandı olduğu için sınıflandırma doğru sonucu vermiştir.

Tablo 3. B seçeneği (6.6 Hz) seçildiğinde kaydedilen verilerin bant gücü değerleri

	5.7-7.5 Hz Sınırlarına Sahip Bant	6.6-8.4 Hz Sınırlarına Sahip Bant	7.4-9.4 Hz Sınırlarına Sahip Bant	9.1-10.9 Hz Sınırlarına Sahip Bant
Katılımcı 1 İçin Hesaplanan Bant Gücü (μV)	236	170	166	229
Katılımcı 2 İçin Hesaplanan Bant Gücü (μV)	252	197	159	153

Tablo 4. C seçeneği (10 Hz) seçildiğinde kaydedilen verilerin bant gücü değerleri

	5.7-7.5 Hz Sınırlarına Sahip Bant	6.6-8.4 Hz Sınırlarına Sahip Bant	7.4-9.4 Hz Sınırlarına Sahip Bant	9.1-10.9 Hz Sınırlarına Sahip Bant
Katılımcı 1 İçin Hesaplanan Bant Gücü (μV)	318	276	287	429
Katılımcı 2 İçin Hesaplanan Bant Gücü (μV)	285	219	252	376

Tablo 3'te ise iki katılımcı için de B seçeneğinin yanıp sönme frekansı olan 6.6 Hz merkezli 5.7-7.5 Hz frekans bandı en yüksek güç değerlerini içermektedir. Bu yüzden önerilen yöntem ile bu seçenek için de doğru sınıflandırma yapılmıştır. Benzer şekilde Tablo 4'te C seçeneği için iki katılımcının verisi de doğru sınıflandırılmıştır.

Tablo 5. D seçeneği (7.5 Hz) seçildiğinde kaydedilen verilerin bant gücü değerleri

	5.7-7.5 Hz Sınırlarına Sahip Bant	6.6-8.4 Hz Sınırlarına Sahip Bant	7.4-9.4 Hz Sınırlarına Sahip Bant	9.1-10.9 Hz Sınırlarına Sahip Bant
Katılımcı 1 İçin Hesaplanan Bant Gücü (μV)	318	276	287	429
Katılımcı 2 İçin Hesaplanan Bant Gücü (μV)	285	219	252	376

Son tablo olan Tablo 4 incelendiğinde sonuç beklenenden farklı elde edilmiştir. D seçeneğinin (7.5Hz) seçildiği bilinen verinin, 4 frekans bandındaki bant gücü her bir bant için ayrı ayrı hesaplanmıştır. Katılımcı 1 için en yüksek bant gücü beklediği şekilde 6.6–8.4 Hz sınırlarına sahip bant üzerinde elde edilirken; Katılımcı 2 için en büyük güç değerine sahip bandın 7.4–9.4 Hz sınırlarına sahip bant olduğu gözlemlenmiştir. Katılımcı 1 için doğru sınıflandırma yapılmıştır. Katılımcı 2 için elde edilen sonuç incelendiğinde, önerilen yöntemle göre seçilen seçenek C olarak hesaplanmıştır.

Elde edilen sonuçların karşılaştırılabilmesi için Tablo 6 oluşturulmuştur.

Tablo 6. Verilen yanıt seçenekleri ve bant gücü özneliği sonucunda tespit edilen seçenekler

	Veri Seti 1				Veri Seti 2			
Katılımcının Verdiği Yanıt Seçeneği	A	B	C	D	A	B	C	D
Tespit Edilen Yanıt Seçeneği	A	B	C	D	A	B	C	C

Çıkarılan bant gücü özneliği sonucunda Katılımcı 1 için 4 sorunun hepsi doğru sınıflandırılırken, Katılımcı 2 için 4 sorunun 3 tanesi doğru sınıflandırılmıştır. Tüm sorular göz önüne alındığında %87.5 sınıflandırma doğruluğu elde edilmiştir.

4. Tartışma ve Sonuç

Bu çalışmada, KDGoup tabanlı BBA sayesinde bir bireyin, arayüz ekranında bulunan çoktan seçmeli bir soruya sadece nöral aktivitesiyle istediği yanıtı verebileceği gösterilmiştir. Katılımcılardan alınan veriler üzerindeki baskın frekans bileşenlerini bulmak için HFD uygulanmış ve bant gücü öznelikleri çıkartılarak veriler sınıflandırılmıştır. Sınıflandırma sonucunda 8 sorunun 7 tanesine verilen yanıtlar doğru tespit edilerek çalışma sonucunda %87.5 sınıflandırma doğruluğu elde edilmiştir.

Çalışmanın sınıflandırma doğruluğunu etkileyen durumlardan ilki, uyarım paradigma arayüzü tasarımı olabilir. Katılımcıdan veri alınması sırasında, katılımcının istediği yanıt seçeneğinin bulunduğu hücreye odaklanırken dikkatinin dağılması, ya da diğer hücrelerin yanıp sönmelerinin katılımcıların görüş açıları içinde gerçekleşmeleri sonuçları etkileyebilir. Katılımcının dikkatinin dağılmaması ve yanıt seçeneklerine odaklanabilmesi için uyarım paradigma arayüzünün iyileştirilmesi gerekebilir.

Çalışma gerçekleştirilirken katılımcının sahip olduğu saç uzunluğunun, verilerin alınması aşamasında bir etken olabileceği gözlemlenmiştir. Örneğin Katılımcı 1 kısa saç tipine sahipken, Katılımcı 2 uzun saç tipine sahiptir. Bu saç tipi Katılımcı 2 ile elektrot arasındaki elektrot ile cilt empedansını arttırmış olabilir. Katılımcı 1'den alınan veri içerisinde bulunan tüm seçenekler doğru tespit edilirken; Katılımcı 2'den alınan veri içerisinde bulunan bir seçeneğin tespit edilememesinin nedeni oluşan elektrot ile cilt arasındaki empedans olabilir. Bu nedenle, gelecekte benzer çalışmalar yapılırken, katılımcının saç uzunluğu gibi faktörlerin dikkate alınması gerekebilir.

Dikkate alınması gereken diğer önemli nokta, çalışmada kullanılan veri sayısının sınırlı olmasıdır. İki gönüllü katılımcıdan kaydedilen veri miktarı elde edilen sonuçların güvenilirliğini etkilemiştir. Gönüllü katılımcıların sayıları artırılarak yapılacak deneylerden alınacak verilerin, sonuçları nasıl etkileyebileceği konusunda daha fazla araştırmaya ihtiyaç vardır.

Bu çalışmada, çoktan seçmeli sorulara yanıt verilmesi gereken senaryolarda KDGoup tabanlı BBA kullanılabilirliğine yönünde başarılı sonuçlar elde edilmiştir. Bu senaryolar bir sınav, oyun veya yarışma olabilir. Çalışmada motor fonksiyonları ve beyin düşünme yetisi sağlıklı olan katılımcılardan kaydedilen veriler kullanılarak bazı sonuçlar elde edilmiştir ancak benzer sonuçların motor fonksiyonlarında hasar bulunan fakat beyin düşünme yetisi sağlıklı bireylerde de elde edilebileceği öngörülmektedir. Bu durum motor fonksiyonlarında hasar bulunan fakat beyin düşünme yetisi sağlıklı olan bireylerin eğitim ve öğretim hayatına önemli bir katkı sağlama potansiyeli oluşturmaktadır. Örneğin bu çalışma, ALS hastası olan bireylerin lise veya üniversiteye giriş sınavlarına katılmalarını kolaylaştırabilir. Böylece bu çalışma ilgili kitleye daha fazla fırsat eşitliği sunabilir. Bu çalışma konsepti, çoktan seçmeli soruları içeren bir oyuna veya yarışmaya uyarlanabilir. Böylece çalışma daha geniş bir topluluğa erişilebilir. Dolayısıyla, bu çalışma sadece ilgili bireylerin eğitim hayatına katkı sağlama, yaşam

kalitesini artırma ve toplumda daha fazla eşitlik potansiyeli oluşturmakla kalmayıp; oyun sektörü ve eğlence alanında BBA'ların kullanımına teşvik sağlayabilir.

5. Teşekkür

Bu çalışma TÜBİTAK 2209-B Üniversite Öğrencileri Sanayiye Yönelik Araştırma Projeleri Desteği programı kapsamında 1139B412202088 numaralı proje ile desteklenmiştir.

Çıkar Çatışması

Yazar(lar), bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

Kaynakça

- [1] Kawala-Sterniuk, A., ve diğerleri. (2021). *Summary of over Fifty Years with Brain-Computer Interfaces—A Review. Brain Sciences*, 11(1), 43.
- [2] McFarland, D. J., & Wolpaw, J. R. (2017). EEG-based brain-computer interfaces. *Current Opinion in Biomedical Engineering*, 4, 194-200.
- [3] Zabcikova, M., Koudelkova, Z., Jasek, R., & Lorenzo Navarro, J. J. (2022). Recent advances and current trends in brain-computer interface research and their applications. *International Journal of Developmental Neuroscience*, 82(2), 107-123.
- [4] Vaughan, T. M. (2020). Brain-computer interfaces for people with amyotrophic lateral sclerosis. In *Handbook of Clinical Neurology*, Vol. 168, 33-38.
- [5] Cortez, S. A., Flores, C., & Andreu-Perez, J. (2021). A Smart Home Control Prototype Using a P300-Based Brain-Computer Interface for Post-stroke Patients. In Y. Iano, R. Arthur, O. Saotome, G. Kemper, & A. C. Borges Monteiro (Eds.), *Proceedings of the 5th Brazilian Technology Symposium* (s. 202). Springer, Cham.
- [6] Amiri, S., Fazel-Rezai, R., & Asadpour, V. (2013). A review of hybrid brain-computer interface systems. *Advances in Human-Computer Interaction*, 2013, 1-1.
- [7] S. Kundu and S. Ari, "MsCNN: A Deep Learning Framework for P300-Based Brain-Computer Interface Speller," in *IEEE Transactions on Medical Robotics and Bionics*, vol. 2, no. 1, pp. 86-93, Feb. 2020, doi: 10.1109/TMRB.2019.2959559.
- [8] Zhu, D., Bieger, J., Garcia Molina, G., & Aarts, R. M. (2010). A survey of stimulation methods used in SSVEP-based BCIs. *Computational intelligence and neuroscience*, 2010.
- [9] Yin, E., Zhou, Z., Jiang, J., Yu, Y., & Hu, D. (2015). A Dynamically Optimized SSVEP Brain-Computer Interface (BCI) Speller. *IEEE Transactions on Biomedical Engineering*, 62(6), 1447-1456.
- [10] Chen, X., Chen, Z., Gao, S., & Gao, X. (2014). A high-ITR SSVEP-based BCI speller. *Brain-Computer Interfaces*, 1(3-4), 181-191.
- [11] Albawardi, H., Almoaibed, A., Al Abbas, N., Alsayed, S., Almaghlouth, T., & Alzahrani, S. (2021, December). Design of Low-Cost Steady State Visually Evoked Potential-Based Brain Computer Interface Using OpenBCI and Neuromore. In *2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART)* (pp. 1-4). IEEE.
- [12] Müller-Putz, G. R., & Pfurtscheller, G. (2008). Control of an electrical prosthesis with an SSVEP-based BCI. *IEEE Transactions on Biomedical Engineering*, 55(1), 361-364.
- [13] Lalor, E., Kelly, S., Finucane, C., Burke, R., Reilly, R., & Mcdarby, G. (2004). Brain computer interface based on the steady-state VEP for immersive gaming control. *Biomed. Tech.*, 49, 63.

- [14] Jiang, L., Guan, C., Zhang, H., Wang, C., & Jiang, B. (2011). Brain computer interface based 3D game for attention training and rehabilitation. In 2011 *6th IEEE Conference on Industrial Electronics and Applications* (s. 124-127).
- [15] Shao, L., Zhang, L., Belkacem, A. N., Zhang, Y., Chen, X., Li, J., & Liu, H. (2020). EEG-Controlled Wall-Crawling Cleaning Robot Using SSVEP-Based Brain-Computer Interface. *Journal of Healthcare Engineering*, vol. 2020, Article ID 6968713, 11 pages.
- [16] Marin, I., Al-Battbooti, M. J. H., & Goga, N. (2020). Drone Control based on Mental Commands and Facial Expressions. In 2020 *12th International Conference on Electronics, Computers and Artificial Intelligence (ECAI)* (s. 1-4).
- [17] Coogan, C. G., & He, B. (2018). Brain-Computer Interface Control in a Virtual Reality Environment and Applications for the Internet of Things. *IEEE Access*, 6, 10840-10849.
- [18] Cutter, P. A. (2015). The Shape of Things to Come: The Military Benefits of the Brain-Computer Interface in 2040 Air Command and Staff College.
- [19] Wang, Z., Yu, Y., Xu, M., Liu, Y., Yin, E., & Zhou, Z. (2018). Towards a Hybrid BCI Gaming Paradigm Based on Motor Imagery and SSVEP. *International Journal of Human-Computer Interaction*, 35(3), 197-205.
- [20] Allison, B. Z., Jin, J., Zhang, Y., & Wang, X. (2014). A four-choice hybrid P300/SSVEP BCI for improved accuracy. *Brain-Computer Interfaces*, 1(1), 17-26.
- [21] Zhou, C. (2023). SSVEP-Based BCI Wheelchair Control System. arXiv preprint arXiv:2307.08703.
- [22] Albahri, A. S., Al-Qaysi, Z. T., Alzubaidi, L., Alnoor, A., Albahri, O. S., Alamoodi, A. H., & Bakar, A. A. (2023). A systematic review of using deep learning technology in the steady-state visually evoked potential-based brain-computer interface applications: current trends and future trust methodology. *International Journal of Telemedicine and Applications*, 2023.



Design and Development of Screw-type Pellet Machine for Aquatic Feeds with Dual Operations

Jamilu Ya'u Muhammad^{1*}, Yusuf Alhaji², Abubakar Muhammad Shitu²,
Abdulkareem Mika'il Alhaji³, Umar Muhammad Ahmad⁴, Audu Taofeek Olaniyi⁵

(Received: 20.02.2023, Accepted: 04.07.2023, Published Online: 30.01.2024)

Keywords

Aquatic
Design
Efficiency
Pellet
Screw-type Pellet Machine

Abstract: Fishes and many animals have always been fed in a primitive way; this involves grinding of cereals on stones into meals. In this research work, a screw-type pellet machine was developed for aquatic feeds with dual-operations system whereby the electric motor was used to run the machine electrically and a handle was used to replace the motor in the absent of National Grid to operate the machine manually. Three dies with different holes diameters (2 mm, 3 mm and 4 mm holes diameters) were used to test the performance of the machine. The result revealed that the dryness of the feed materials is proportional to the temperature of the materials and time taken for the removal of the moisture content in the materials and 76.67% was the machine's efficiency whereas the efficiency of the pelletizing was 93.33%.

1. Introduction

Aquatic farming in developing countries is one of the developing business and it promotes food security and poverty eradication. Nigeria is blessed with rivers and lakes, but the feeds for aquatics are always increases due to inflation and devaluation of the currency.

To overcome these challenges, aquatic farmers are to produce the feeds locally for their fishes and yet this feed is not nutrient enough and there is a waste of raw materials in the process [1, 2]. Use of pelletizing machine is the modern method of production of the feeds for fishes and animals. This machine is used to extrude the raw material in a different pellet dies shape and the feed is nutrient and healthy for the fishes and animals [3]. Pelletizing machines could be operated manually or electrically. For the pelleting machine that is operated manually, the screw auger is rotated using handle whereas in an electrically operated machine, an electric motor is used to moves the auger.

Pelletizing machines can either be screw-type or roll-type machine. In 2017, Olusegun and his co-workers [4] developed a pelletizing machine with high capacity of 113 kg/h and two pellet dies of 4 mm and 6 mm diameter holes. Another pelletizing machine of screw-type was design and developed by Cian et al. [5], this machine is aimed to optimize the temperature on the die and moisture content of the pellet feed. Another pellet machine was designed by Okolie et al., [6] with a highly efficiency of capacity of 17 kg/h with pelletizing efficiency of 91 %. One

¹ Department of Mechanical Engineering, Nigerian Army University, Biu, Borno State, Nigeria

² School of Technology, Binyaminu Usman Polytechnic, Hadejia, Nigeria

³ Department of Chemical Engineering, Federal University, Wukari, Nigeria

⁴ Department of Mechanical Engineering, Modibbo Adama University of Technology, Yola, Nigeria

⁵ Department of Mechanical Engineering, Bayero University, Kano, Nigeria

Corresponding Author and e-mail address: Jamilu Ya'u Muhammad jamilu.muhammad@naub.edu.ng

of the problems of the pelletizing machine is the rise of die temperature due to rotation of a screw auger, Liu et al., [7] developed an advanced machine with cooling die and low moisture content. Susastriawan et al., [8] design and construct a machine of 75 kg/h capacity with roller as the extruder, the machine has cylindrical pelletizing chamber and die that produces pellet feeds of 4 mm diameter and 4 mm in length.

Sunil et al., [9] developed a pelletizing machine for animal feeds with different dies using a multilevel inverter that has a problem related to variation in the capacitor voltage. The ratio of length to the diameter of the pelletizing machine is among the factors affecting the performance of the machine. In 2018, Ambalkar [10] designed a pelletizing machine, the result shows that the ratio of length to the diameter is inversely proportional to the energy consumption by the machine. The amount of moisture and operating speed are other factors that affect the efficiency of the pelletizing machine, Burmanu et al., [11] developed a pelletizing machine for fish feed with a hand operation and the machine was 88% efficient. A pelletizing machine incorporated with drying system was developed by Ojediran et al., [12] whereby the machine produces the drying feeds for fishes. The results revealed that when the moisture contents of the raw materials were 10 and 18%, the machine efficiencies of were $18 \pm 2\%$ and $72 \pm 5\%$, respectively.

Following the frequent break down of the national grid and insufficient power supply in most of developing countries especially rural areas, this study tends to develop a dual operation pelletizing machine for aquatic feed.

2. Materials and Method

2.1 Description of the Machine

The machine includes the feed container (hopper) which is welded to a cylindrical barrel (pelletizing chamber) and inside the chamber there is screw auger mounted over the shaft that carried the raw materials to the die extruder of the machine. One end of the shaft is connected with the pulley (driven) and another pulley on the electric motor were connected using V-belt. The driving pulley rotates the driven pulley when the machine is on, the raw material is poured into the hopper whereby the auger conveys it towards the die after the auger break the raw material in small piece. The feed is the flow out through the die and it then collected for drying process after cut it into smaller size for ease swallowing by the aquatics.

2.2 Design Considerations and Requirements

In design of the machine’s components, the following points were considered:

- a. Physical and chemical properties of the materials used for construction of the machine. should be checked to ensured that it has no harmful to the aquatics.
- b. The maintainability of the machine should be ease.
- c. The cost of production should be considered when selection of materials.
- d. The electric motor operates under steady state condition.

2.3 Materials Selections

The cost, reliability, functionality and processability factors are considered while selection of materials used for construction of the machine [13].

Table 1 shows the components of the system, materials used and reason(s) for selections:

Table 1. Materials Selected for Construction of the System

Components	Materials Selected	Reason(s)
Hopper	Mild steel	Weldability, High tensile and impact strength [14]
Pelletizing chamber	Mild steel	Weldability, High tensile and impact strength [14]
Screw auger	Cast iron sheet	Deformability and fatigue resistant [15]
Shaft	Stainless Steel	Corrosion resistant, durability [15]
Supporting Stand	Mild steel	Weldability, High tensile and impact strength [14]

2.4 Design Calculations for the Machine's Components

2.4.1 Design of Hopper

The hopper is made up of mild steel in the form of truncated frustum of the pyramid. Therefore, the volume of the hopper is equal to the volume of truncated frustum of pyramid and it can be calculated using the equation given as:

$$V_h = \frac{h_h(A_1 + A_2 + \sqrt{A_1A_2})}{3} \quad (1)$$

Where: V_h is Volume of the feed container (hopper) (mm^3), h_h is Height of the feed container (hopper) (350mm) (See Figure 1), A_1 is Area of the trapezium (mm^2) and A_2 is Area of rectangle (mm^2).

The area of the trapezium and that of rectangle were determined using equations (2) and (3) respectively as:

$$A_1 = \frac{(a + b)h}{2} \quad (2)$$

and,

$$A_2 = LB \quad (3)$$

Where: a and b are two opposite sides of the trapezium (150mm and 48.8mm respectively), h = height of the trapezium (100mm), L = Length of the rectangle (250mm) and B = Breadth of the rectangle (150mm) (See Figure 1).

Johnson equation is used to calculate the mass flow rate of the raw material through the hopper to the pelletizing chamber and the equation is given as:

$$\dot{m} = \rho_b A \sqrt{\frac{Bg}{2\tan\phi}} \quad (4)$$

Where: \dot{m} = mass flow rate (kg/s), ρ_b = Bulk density of the raw materials (1.3 g/m^3), A = surface area of the hopper (m^2), g = acceleration due to gravity (9.81 m/s^2) and ϕ = angle of inclination of the hopper (45°) (Selected).




Figure 1: Front and Isomeric Views of Hopper

2.4.2 Design of the Barrel

The barrel consists of hollow cylinder and screw auger is inside the chamber. The volume of the barrel is obtained using equation (5):

$$V_b = V_e - V_i - V_a \quad (5)$$

Where: V_b = Volume of the pelletizing chamber (mm^3), V_e = Exterior volume of the cylinder (mm^3), V_i = Interior volume of the cylinder (mm^3) and V_a = Volume of the Screw auger (mm^3).

The exterior volume of the cylinder is:

$$V_e = \frac{\pi D^2 h_b}{4} \quad (6)$$

The interior volume of the cylinder is:

$$V_i = \frac{\pi d^2 h_b}{4} \quad (7)$$

And the exterior volume of the cylinder is:

$$V_a = \frac{\pi x^2 h_b}{4} \quad (8)$$

Where: D = External diameter of cylinder (40mm), d = Internal diameter of cylinder (10mm), x = Diameter of the Screw auger (10mm) and h_b = Height of the Screw auger (260mm) (See Figure 2).

2.4.3 Design of the Screw auger and Shaft

For the shaft to adopt torsional and bending strength, the following equation was used to determine the diameter of the shaft as given by [14]:

$$d_s^3 = \frac{16T_s}{0.27\pi\sigma_y} \quad (9)$$

Where: d_s = Shaft diameter (m), T_s = Torque transmitted by the shaft (10Nmm) (Electric motor Specification) and σ_y = Yield stress of the material of the shaft ($200\text{N}/\text{m}^2$) [14].

The power required to drive the screw auger can be found using the equation given as:

$$P_a = \frac{Qh_b\omega_o}{367} \quad (10)$$

Where: P_a = Power of the screw auger (W), Q = Capacity of the screw auger (N/s) and $\omega_o = 4.0$ for the slow-flowing abrasive materials [16].

Figures 2 and 3 show the front and end views of the screw auger and isometric drawing of the screw auger.




Figure 2: Front and End Views of the Screw Auger




Figure 3: Isometric Drawing of the Screw Auger

2.4.4 Design of the Pulley and Belt Drive

For design of the drive system (Pulley and Belt), the following parameters are to be determine:

- a. Diameter of the pulley;
- b. Length of the belt;
- c. Tensions acting on the belt and;
- d. Power transmitted by the belt.

The above parameters were determined as follows:

- a. Pulley's Diameter

The diameter of the pulley can be calculated using the equation given by Khurmi and Gupta [14] as:

$$D_2 = \frac{D_1 N_1}{N_2} \quad (11)$$

Where: D_2 is Diameter of the driven pulley (mm), N_2 is Speed of the driven pulley (1200rpm) (Selected), D_1 is Diameter of the driving pulley (30mm) (Available Pulley Specification) and N_1 = Speed of the driving pulley (200rpm) (Selected).

- b. Length of the belt

Equation (12) is used to obtain the length of the belt to join the two pulleys (Driven and driving pulleys as:

$$L_b = \frac{D_2 - D_1}{4C} + \frac{\pi(D_1 + D_2)}{2} + 2C \quad (12)$$

Where: L_b = V-belt Length (mm) and C = Two pulleys distance apart (200mm) (Selected).

- c. Tensions acting on the belt

Two opposite tensions are acting on the belt in the same direction. We let T_1 and T_2 as the tensions acting on the tight side and slack side of the belt respectively.

The tension acting on the slack side of the belt is found using the equation (13):

$$T_2 = \frac{T_1}{e^{\mu\theta \sin(\theta/2)}} \quad (13)$$

Where: μ = Coefficient of friction between the belt and the pulley (0.4) [14] and θ = Groove angle (15°) [14].

And The tension acting on the tight side of the belt can be calculated using the expression given as:

$$T_1 = T - T_c \quad (14)$$

Where: T = Maximum tension acting on the belt (N) and T_c = Centrifugal tension acting on the belt (N).

These maximum tension and centrifugal tension are given as:

$$T = \sigma A_b \quad (15)$$

$$T_c = MV^2 \quad (16)$$

Where: σ = Allowable stress in the belt material (80N/mm²) [14], A_b = Cross sectional area of the belt material (mm²), M = Mass per unit length of the belt material (kg/mm) and V = Belt velocity (m/s) and its given as:

$$V = 2\pi N_b R_b \quad (17)$$

d. Power transmitted by the belt

The power transmitted by the belt can be found using the equation given as:

$$P = (T_1 - T_2)V \quad (18)$$

2.4.5 Capacity/Selection of the electric motor

For the design of pelletizing machine will not be appropriate until a suitable electric motor with the required power that can run the pulley attached to the shaft of the screw auger was selected. The power required to run the shaft of the screw auger by an electric motor is given as:

$$P_m = m\omega^3 r^2 \quad (19)$$

Where: P_m = Power required to run the shaft (W), m = Mass of the shaft (10kg), ω = Angular velocity of the electric motor (rad/s) and r = Radius of the shaft (10mm) (See figure 2).

3. Construction Process of the Machine


The feeding unit (hopper) is in the form of truncated frustum of pyramid was constructed using mild steel of thickness 1.5 mm by marking out using scribe, meter rule and try square. The portable grinding machine was used to cut out the marks on the mild steel and welding the cut part of the steel after folding to give the required shape of the hopper.

The barrel (pelletizing chamber) is made up of a cylinder using mild steel of thickness 1.5 mm and length of 900 mm using rolling machine and welding the ends of the steel. At 200 mm from one of its ends an opening was made of 170 by 170 mm where the frustum shaped hopper is attached. 1 mm thickness cast iron sheet was folded and welded on the stainless-steel shaft to form a screw auger.

The supporting base and frame were constructed using angle iron of thickness 3 mm. A hacksaw was used to cut seven pieces of 800 mm long and two pieces of 700 mm long section from two and half angle iron of 6000 mm length each. These nine sections were arranged and welded to form the frame and supporting base.

The motor bracket was constructed on another two 500 mm long, two 450 mm and two 260 mm long sections of the same angle iron. These six components were then arranged and welded to form the motor support and the bracket.

Figure 4 shows the side view of the complete designed and constructed machine for pelleting the aquatic feeds.



SIDE VIEW OF FISH FEED PELLETIZING MACHINE

Figure 4. Side View of the Fish Feed Pelletizing Machine

4. Performance Analysis of the Machine

4.1 Cost Analysis

The cost of all the materials used in construction of the screw type pellet machine was given in the table 2.

Table 2. Cost of the Materials Used

S/No	Materials/Particulars	Quantity	Unit Price (₹)	Total Cost (₹)
1	1.5mm mild steel	2	8,000	16,000
2	1 mm cast iron sheet	1	9,000	9,000
3	3 mm angle iron	3	6,500	19,500
4	6-inch pulley	1	3,000	3,000
5	2-inch pulley	1	2,500	2,500
6	Electric motor	1	25,000	25,000
7	'A' type belt	1	1,000	1,000
8	Bearing	4	500	2,000
9	Bolt and nut	10	80	800
10	Labor	1	30,000	30,000
11	Electrodes	2	1,000	2,000
12	Cutting disc	5	800	4,000
13	Grinding disc	1	1,000	1,000
Total				115,800

4.2 Drying Rate, Pelletizing Percentage and Machine Percentage

Table 3 presents the rate of dryness (%) and temperature (°C) of the pellet feeds for different die holes.

Table 3. Dryness and temperature of the feeds

Dryness (%)	Temperature (°C)		
	1 mm die hole	2 mm die hole	3 mm die hole
50	103	101	97
60	148	141	138
70	192	187	184
80	238	233	229
90	275	272	267
100	302	298	293

Table 4 presents the rate of dryness (%) and time taken (minutes) for the pellet feeds to dry for different die holes.

Table 4. Dryness and time taken of the feeds

Dryness (%)	Time (min)		
	1 mm die hole	2 mm die hole	3 mm die hole
50	3	5	7
60	11	13	16
70	19	21	25
80	27	30	34
90	39	42	46
100	48	45	51

4.3 Discussion of the Results

The cost of production of the machine was ₦115,800 which is equivalent to \$258 and this is far less than the cost of purchasing the machine in the market [17].

From table 3 presents the relationship between the rate of drying the moisture and temperature, it shows that when the temperature increases the dryness will also increases so also the time taken for the drying the pellet feeds as shown in the table 4. It was also observed that the temperatures were decreases when the die hole diameter was increase but the time taken for the feed materials to dry was increases as the diameter of the die hole increases for both electrical and manual operations.

The machine efficiency was calculated using equation (20) given as:

$$\eta = \frac{m_r}{m_f} \times 100\% \tag{20}$$

Where, m_f is the mass of feed sample fed into the hopper (2kg) and m_r is the mass of feed materials recovered after the pelletizing process (1.5kg).

And the pelletizing efficiency was found using equation (21) as:

$$\varepsilon = \frac{m_p}{m_r} \times 100\% \tag{21}$$

Where, m_p is the mass of pelletizing sample (1.4kg). This was obtained by weighing the pellets, which was manually separated from the recovered feed.

The machine and pelletizing efficiencies were obtained as 75% and 93.33% respectively.

The average values of the weight of the feed materials, discharge time, weight of the pelletized feed, weight of the residue materials and the loss due to non-pelletized materials were 8 kg, 2 min, 7.6 kg, 0.5 kg and 7.75%, respectively, this is in agreement with the research work done by [4, 18-20].

The moisture content of the pellets was found using equation (22) as:

$$\text{Moisture content} = \frac{m_1 - m_2}{m_1} \times 100\% \quad (22)$$

Where m_1 is the mass of pellets before drying for 7days (1.4kg) and m_2 is the average mass of pellets after drying period of 7days (0.95kg).

The pellet was dried on direct solar drying system (Open air) for 7days and the average moisture content of the pellets was 32.1%. The efficiency of both machine and pelletizing and the moisture content obtained in this design shows an improvement over those pelletizing machines developed by [21-24].

5. Conclusions

A screw-type pellet machine was successfully developed with different die holes diameters using electric and manual operations. The following are remarkable conclusions made:

- i. The temperature of the feed materials is inversely proportional to the die holes diameters but the time taken for the pellet feeds to dry is directly proportional to the die holes diameters;
- ii. The machine efficiency was found to be 75% whereas, 93.33% was the efficiency of the pelletizing and;
- iii. 8 kg, 2 minutes, 7.6 kg, 0.5 kg and 7.75% were respectively found as weight of the feed materials, discharge time, weight of the pelletized feed, weight of the residue materials and the loss due to non-pelletized materials.

References

- [1] Aremu, A. K., Kadiri, A. O. and Ogunlade, C. A. T. (2014). Development and testing of screw type kenaf (*Hibiscus cannabinus*) pelletizing machine. *International J. of Agricultural Tech.*, 10(4), 803-815.
- [2] Bhosale, S. V., Bhilave, M. P., Nadaf, S. B. (2010). Formulation of fish feed using ingredients from plant sources. *Res. J. Agric. Sci.*, 1(3), 284-287.
- [3] Mc-Donald P. (1995): *Animal Nutrition*. Longman, London, p. 69 – 96.
- [4] Olusegun, H. D., Adekunle, A. S., Ohijeagbon, I. O., Akande, K. A. and Mohammad, B. G. (2017). Design, Fabrication and Evaluation of Fish Feed Pelletizing Machine. *J. of Sci. and Tech.*, 37(1), 51 – 65.
- [5] Cian, R. E., Bachetta, C., Cazenave, J. and Drago, S. R. Optimization of single screw extrusion process for producing fish feeds based on vegetable meals and evaluation of nutritional effects using a juvenile *Piaractus mesopotamicus* model. *Animal Feed Sci. and Tech.*
- [6] Okolie, P. C., Chukwujike, I. C., Chukwuneke, J. L. and Dara, J. E. (2019). Design and production of a fish feed pelletizing machine. *Heliyon*, 5.
- [7] Liu, K., Frost, J., Welker, T. L. and Barrows, F. T. (2021). Comparison of new and conventional processing methods for their effects on physical properties of fish feed. *Animal Feed Sci. and Tech.*, 273: 114818.
- [8] Susastriawan, A. A. P., Edhy, S., Yusuf, M., Sudarsono and Suparni R. S. (2021). Design and Fabrication of Roller Type Pelletizing Machine Equipped with a Steam Injector for Production of Buoyant Fish Feed. *SSRG International J. of Mech. Eng.*, 8(10), 13-16.
- [9] Sunil, S., Akant, G. S., Borade, V. and Nandurkar, Y. Y. (2017). Design and fabrication of animal food pellet making machine. *J. of Research in Eng. and Appl. Sci.*, 2(3), 127-131.
- [10] Ambalkar, P. P. (2018). Modification and testing of pelletizing machine for aqua feed pellets with enhanced floatability and water stability. *Sam Higgin bottom University of Agric., Tech. and Sci. (SHUATS)*.

- [11] Burmamu, B. R., Aliyu, B. and Tya, T. S. K. (2015). Development of a Manually Operated Fish Feed Pelleting Machine. *International J. of Research in Eng. and Adv. Tech.*, 2(6), 23–32.
- [12] Ojediran, J. O., Fasinmirin, J. T. and Owa, O. P. (2017). Development and Performance Evaluation of an Indigenous Fish Feed Palletizing Machine. *J. of Eng. and Eng. Tech.*, 11(2), 139–148.
- [13] Jamilu, Y. M., Adamu, Y. A., Ibrahim, B. A., Auwal, B. A., Ibrahim, U. I., Mahmoud, M. M. and Mustapha, A. A. (2020). Design, Construction and Performance Assessment of a Hybrid Solar Dryer Using Forced Convection Principle. *International J. of Energy and Smart Grid*, 5(1-2), 11-26.
- [14] Khurmi, R. S. and Gupta, J. K. (2006). *A Textbook of Machine Design*, 14th edition Eurasia Publishing house (PVT) Ltd, Ram Nagar, New Delhi.
- [15] Shigley, J. E. and Mischike, C. R. (2001). *Mechanical Engineering Design*, 6th edition McGraw-Hill Publication, New York.
- [16] Spivakovsky, A. and Dyachkov, V. (1967). *Conveyors and Related Equipment*. Translated from the Russian by Don danemanis. peace publishers.
- [17] Cost of Pelletizing Machine (2022). Retrieved from www.m.alibaba.com>product>Nigeria-Widely-Used-Feed-Machine-Factory.html
- [18] Modibbo, U. U., Osemeahon, S. A., Shagal, M. H. and Halilu, M. (2014). Effect of Moisture Content on the Drying Rate using Traditional Open Sun and Shade Drying of Fish from Njuwa Lake in North-Eastern Nigeria. *IOSR J. of Appl. Chem.*, 7(1), 41– 45.
- [19] Ojomo, A. O., Agbetoye, L. A. S. and Ologunagba, F. O. (2010). Performance Evaluation of a Fish Feed Pelletizing Machine. *ARPJ. of Eng. and Appl. Sci.*, 5(9), 88 – 97.
- [20] Siddique, A. B. and Wright, D. (2003). Effect of Different Drying Time and Temperature on Moisture Percentage and Seed Quality (Viability and Vigour) of Pea Seeds (*Pisum sativum* L.). *Asian J. of Plant Sci.*, 2, 978–982.
- [21] Olusegun, H. D., Adekunle, A. S., Ohijeagbon, I. O., Akande, K. A. and Mohammad, B. G. (2017). Design, Fabrication and Evaluation of Fish Meal Pelletizing Machine. *Journal of Science and Technology*, 37(1), 51-63.
- [22] Kaankuka, T. K. and Osu, D. T. (2013). Development of a revolving die and roller fish feed pelletizer. *International Journal of Engineering Innovations and Research*. 2(1): 105-110.
- [23] Nwaokocha, C. N. and Akinyemi, O. O. (2010). Development of a dual-mode laboratory sized pelletizing machine. Mechanical Engineering Department, Olabisi Onabanjo University, Ago Iwoye, Nigeria.
- [24] Olusegun, H. D. and Adekunle, A. S. (2009). Design, construction and testing of a wormlike pellet fish meal processing machine. *International Journal of Engineering*, 3(1): 31-44.