

Turkish World Implementation and Research Center

Journal of Informatics



- **Okul Öncesi Öğrencilerine Çevre Bilinci Kazandırmaya Yönelik UNITY Tabanlı Eğitici Oyun Tasarımı**
- **Adveksiyon Difüzyon Denkleminin Kuartik B-Spline En Küçük Kareler Metodu ile Sayısal Çözümü**
- **Derin Öğrenme ile Aspergillus Mantar Türlerinin Sınıflandırılması**
- **Retinal Hastalıkların Teşhisi için Optik Koherans Tomografi Görüntülerinin Derin Öğrenme Metotları ile Sınıflandırılması**
- **Doğada Yetişen Mantar Türlerinin Derin Öğrenme ile Tespiti**
- **Evolution and State of the Art in Password Storage**
- **İşaret Yayıncı ve Akıllı Telefon Destekli Öğrenci Yoklama Otomasyonu**

ISSN-eISSN: 2687-606X

Year 2023

Volume 4 Issue 3

İÇİNDEKİLER

Sayfa

Araştırma Makaleleri

- Okul Öncesi Öğrencilerine Çevre Bilinci Kazandırmaya Yönelik UNITY Tabanlı Eğitici Oyun Tasarımı 1
- Adveksiyon Difüzyon Denkleminin Kuartik B-Spline En Küçük Kareler Metodu ile Sayısal Çözümü 9
- Derin Öğrenme ile Aspergillus Mantar Türlerinin Sınıflandırılması..... 15
- Retinal Hastalıkların Teşhisi için Optik Koherans Tomografi Görüntülerinin Derin Öğrenme Metotları ile Sınıflandırılması 22
- Doğada Yetişen Mantar Türlerinin Derin Öğrenme ile Tespiti 29
- İşaret Yayıcı ve Akıllı Telefon Destekli Öğrenci Yoklama Otomasyonu..... 45

Derleme Makaleleri

- Evolution and State of the Art in Password Storage..... 37

(Araştırma Makalesi)

Okul Öncesi Öğrencilerine Çevre Bilinci Kazandırmaya Yönelik UNITY Tabanlı Eğitici Oyun Tasarımı

Onur ÖZER*¹, Durmuş ÖZDEMİR²

¹Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No: <https://orcid.org/0009-0003-9664-108X>

²Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43030, Kütahya, ORCID No: <https://orcid.org/0000-0002-9543-4076>

Anahtar Kelimeler:

Okul Öncesi Eğitim,
STEM,
Çevre Bilinci,
Eğlenerek Öğrenme,
UNITY 2D,
Mayer Çoklu Ortam İlkeleri

Özet: Bu çalışmada, okul öncesi öğrencilere çevre bilinci kazandırmaya yönelik UNITY tabanlı eğitici oyun tasarımı ele alınmaktadır. Makalede, okul öncesi öğrencilerin fiziksel ve mental durumları ile çevre bilinci ve önemi hakkında genel bir bilgilendirme edinmeleri amaçlanmıştır. STEM (Science, Technology, Engineering, Mathematics) eğitim modeli çerçevesinde hazırlanan öğretim modeli, UNITY oyun motoru, C# programlama dili kullanılarak tasarlanmıştır. Tasarımda Mayer çoklu ortam ilkeleri de dikkate alınarak öğrencilerin yaşlarına uygun görseller oluşturulmuştur. Çalışmada, mobil tabanlı tasarlanan oyunların okul öncesi çağıdaki çocukların eğlenerek öğrenmelerini sağlayabileceği, hedeflenen bilgi ve becerilerin kazandırabileceği öngörülmektedir.

(Research Article)

UNITY-Based Educational Game Design to Raise Environmental Awareness for Preschool Students

Keywords:

Pre-school education,
STEM,
Environmental awareness,
Fun Learning,
UNITY 2D,
Mayer Multimedia Principles

Abstract: This study discusses a UNITY-based educational game designed to raise environmental awareness in preschool students. The article aims to gain general information about preschool students' physical and mental states, environmental awareness, and importance. The teaching model, prepared within the STEM (Science, Technology, Engineering, Mathematics) education model, was designed using the UNITY game engine and C# programming language. Considering the Mayer multimedia principles in the design, visuals suitable for the ages of the students were created. The study predicted that mobile-based games could enable preschool children to learn while having fun and gaining targeted knowledge and skills.

1. GİRİŞ

Okul öncesi dönem, çocukların temel becerileri edindiği ve kişisel gelişimlerini şekillendirdikleri önemli bir dönemdir. Bu dönemde çocuklara çevre bilinci kazandırma, doğa sevgisi ve sürdürülebilirlik anlayışını aşılama önemli bir hedef haline gelmiştir. Eğitici oyunlar, okul öncesi öğrencilere bu değerleri kazandırmada etkili bir araç olarak kullanılmaktadır [1].

Okul öncesi eğitim kurumlarında öğrenim gören öğrencilere doğru, etkin ve verimli bir şekilde güncel teknolojileri içeren uygulamalar oldukça sınırlıdır[2]. Ayrıca, ülkemizde okul öncesi müfredat programlarında ele alınan çevre konularının çevre bilincini geliştirme açısından yeterli olmadığı belirtilmektedir [3]. Bu proje, okul öncesi öğrencilerine çevre bilinci kazandırmak

amacıyla .Net platformunda C# programlama dilinde ve UNITY oyun motoru kullanılarak hazırlanan mobil tabanlı oyun tasarımı geliştirerek bu soruna alternatif çözüm sunmayı hedeflemektedir.

2. MATERYAL VE METOT

Bu çalışma, STEM eğitim modeli kapsamında mobil tabanlı çevre bilinci oluşturmayı hedefleyen bir oyun yazılımı geliştirmeyi planlamaktadır. Oyun tasarımında Unity platformu ve C# programlama dili kullanılmıştır. Çalışmamız, okul öncesi eğitim kurumlarındaki öğrencilerine ve bu yaş grubundaki çocuklara yönelik çevre bilinci kazanmalarına yardımcı olmayı hedeflemekte ve öğretim teknolojilerinin kullanımını okul öncesi seviyesindeki öğrencilere tanıtmayı amaçlamaktadır.

Okul öncesi öğrencilerine yönelik tasarlanmış çalışmamızda, görsel tasarım ilkeleri, oyunun daha çekici, anlaşılır ve eğlenceli olması için büyük bir öneme sahiptir. Bu amaç doğrultusunda Mayer (2002)'in Çoklu Ortam ilkelerinde yer alan gereksizlik, formal denge, zamansal ve uzamsal yakınlık ve duyu biçimi ilkelerine göre etkinlik hazırlanmıştır. Font seçimi, arka plan resimleri ve diğer tasarım öğeleri, çocukların ilgisini çekmek ve oyunu daha eğlenceli hale getirmek için özenle seçilmiştir. Örneğin, büyük, basit ve okunması kolay fontlar tercih edilerek, okuma ve yazma becerileri henüz gelişmekte olan çocukların oyunu daha kolay anlamaları sağlanmıştır. Ayrıca, arka plan resimleri de çocukların ilgisini çekecek, renkli ve eğlenceli seçimler yapılmıştır. Oynanış da görsel tasarım ilkelerinin uygulanmasıyla kolaylaştırılmıştır. Oyunun arayüzü, çocuklar için anlaşılır simgelerle ve basit bir tasarımla oluşturulmuştur. Ayrıca, oyunun amacı da net bir şekilde belirtilerek, çocukların oyunu nasıl oynayacaklarını anlamaları kolaylaştırılmıştır.

2.1. Okul Öncesi Öğrencilerin Fiziksel ve Mental Durumu

Okul öncesi dönem, çocukların hızlı bir gelişim dönemi olduğu için fiziksel ve mental durumları dikkat etmek önemlidir. Bu dönemde çocuklar, motor becerilerini, dil ve iletişim becerilerini, bilişsel ve zihinsel yeteneklerini hızla geliştirmektedirler. Okul öncesi eğitimde mobil oyunlar, çocukların bu becerileri güçlendirmesine ve zenginleşmesine yardımcı olabilir [4].

Ancak, mobil oyunların kullanımı konusunda dikkatli olunması gerekmektedir. Çocukların oyunlara fazla zaman ayırmaları, uygun olmayan oyunlar oynamaları veya oyunların sürekli izlenmesi, olumsuz etkiler yaratabilir [5]. Bu nedenle, ebeveynlerin ve öğretmenlerin, çocukların oyun seçimlerini ve oyun sürelerini kontrol etmeleri, çocukların oyunları eğitici ve öğretici amaçlarla kullanmalarına özen göstermeleri önemlidir.

2.1.1. Fiziksel Gelişim

Okul öncesi dönemde çocukların fiziksel gelişimi oldukça hızlı bir şekilde gerçekleşir. Bu dönemde çocuklar, motor becerilerini geliştirirler. Yürüme, koşma, zıplama, tırmanma ve denge gibi becerileri öğrenirler. Bu beceriler, çocukların kas gelişimlerini artırarak, güçlenmelerine ve koordinasyonlarının gelişmesine yardımcı olur. Mobil oyunlar da çocukların fiziksel becerilerini güçlendirmelerine ve zenginleşmelerine yardımcı olabilir [6]. Örneğin, hareket etmeye teşvik eden oyunlar, el-göz koordinasyonunu geliştiren oyunlar, denge oyunları gibi mobil oyunlar, çocukların fiziksel gelişimlerine katkı sağlamaktadır [7].

2.1.2. Mental Gelişim

Okul öncesi dönemde çocukların zihinsel ve bilişsel gelişimi de hızla ilerler. Bu dönemde çocuklar, problem çözme, eleştirel düşünme, algılama ve hatırlama gibi bilişsel becerilerini geliştirirler. Ayrıca, hayal güçleri de oldukça gelişir. Mobil oyunlar, çocukların zihinsel ve bilişsel gelişimlerine katkıda bulunarak, hayal güçlerini kullanmalarını, problem çözme ve eleştirel düşünme becerilerini geliştirmelerine yardımcı olmaktadır [8]. Örneğin, bulmaca çözme, matematik oyunları, hafıza oyunları, kelime oyunları ve yaratıcılığı teşvik eden oyunlar gibi mobil oyunlar, çocukların zihinsel gelişimlerine katkı sağlayabilmektedir [9].

2.1.3. Dil ve İletişim Gelişimi

Okul öncesi dönemde dil ve iletişim becerileri de hızla ilerler. Bu dönemde çocuklar, yeni kelimeler öğrenir, cümle kurma becerilerini geliştirir ve anlama yetenekleri artar. Ayrıca, duygusal ifade ve empati kurma becerileri de gelişir [10]. Mobil oyunlar, çocukların dil ve iletişim becerilerini geliştirmelerine yardımcı olmaktadır [11]. Örneğin, kelime oyunları, hikâye anlatma oyunları, konuşma ve telaffuz egzersizleri gibi mobil oyunlar, çocukların dil ve iletişim becerilerini zenginleştirir.

2.1.4. Sosyal Gelişim

Okul öncesi dönemde çocukların sosyal gelişimi de oldukça önemlidir. Bu dönemde çocuklar, arkadaşlarıyla etkileşim kurmayı öğrenirler, grup içinde davranışlarını düzenlemeyi öğrenirler ve empati kurma becerileri gelişir. Mobil oyunlar, çocukların sosyal gelişimlerine katkı sağlayarak, arkadaşlık kurma, paylaşma, iş birliği yapma, kurallara uyma gibi sosyal becerilerini geliştirmelerine yardımcı olur. Örneğin, takım oyunları, arkadaşlarla etkileşim kurmaya teşvik eden oyunlar, grup etkinlikleri ve sanal toplantılar gibi mobil oyunlar, çocukların sosyal gelişimlerine katkı sağlamaktadır [12].

2.2. Çevre Bilinci ve Önemi

Çevre bilinci, bireylerin doğal çevreye karşı farkındalık ve sorumluluk duygusu geliştirmelerini ifade eder. Doğanın korunması, sürdürülebilirlik, atık yönetimi, enerji tasarrufu ve su kaynaklarının korunması gibi

konuları içerir. Dünya genelinde artan çevre sorunları ve doğal kaynakların azalması nedeniyle son yıllarda giderek daha önemli hale gelmiştir [13].

Okul öncesi dönem, çocukların bu bilinci kazanmaya başladıkları bir dönemdir. Bu dönemde çocuklar, çevrenin önemini anlamaya başlarlar ve çevreyi koruma sorumluluğunu öğrenirler. Okul öncesi dönemde, çocukların çevre bilinci kazanmalarına yardımcı olmak için, öğretmenler ve ebeveynler çeşitli etkinlikler ve oyunlar düzenleyebilirler. Bu etkinlikler aracılığıyla çocuklar, doğanın korunması, atık yönetimi, enerji tasarrufu ve su kaynaklarının korunması gibi temel çevre kavramlarını öğrenirler [14].

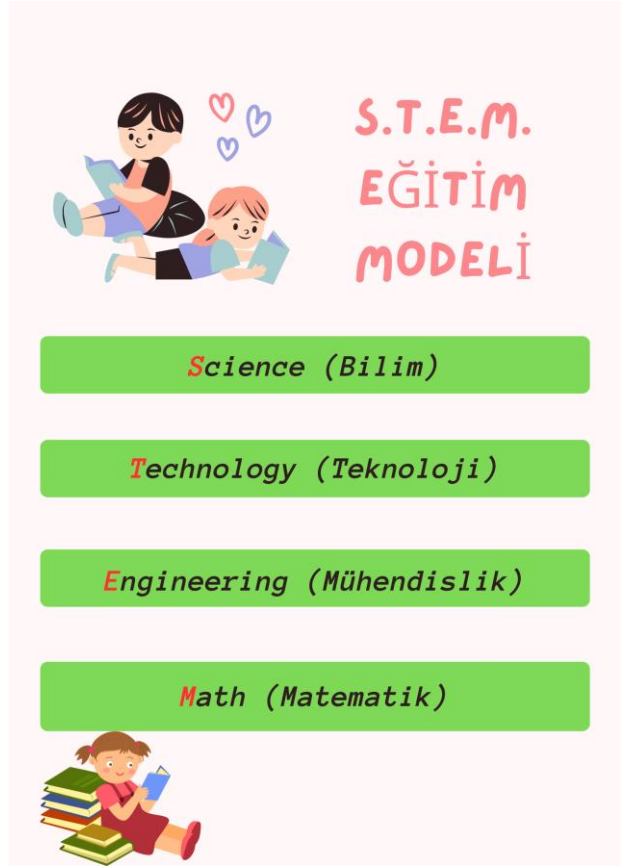
Çevre bilincinin önemi, sadece doğal kaynakların korunması açısından değil, aynı zamanda insan sağlığı ve refahı açısından da büyük bir öneme sahiptir. Çevre kirliliği, hava, su ve toprak gibi doğal kaynakların kirlenmesine neden olur ve insan sağlığına zararlı etkileri vardır. Ayrıca, çevrenin korunması ve sürdürülebilirliği, gelecek nesillerin de yaşanabilir bir dünya bulmalarını sağlar [15]. Şekil-1 'de geri dönüşümü anlatan simge sunulmuştur.



Şekil 1. Geri Dönüşüm

2.3. S.T.E.M. Eğitim Modeli

S.T.E.M. (Science, Technology, Engineering, Mathematics), fen bilimleri, teknoloji, mühendislik ve matematik alanlarını birleştiren bir eğitim modelidir. Bu model, öğrencilerin bilimsel düşünme, problem çözme, yaratıcılık ve iş birliği gibi becerilerini geliştirmeyi hedefler. S.T.E.M. eğitimi, özellikle son yıllarda giderek daha önemli hale gelmiştir, çünkü teknolojinin hızlı bir şekilde gelişmesiyle birlikte, bu alanda çalışacak nitelikli iş gücüne olan ihtiyaç artmıştır [16]. Şekil-2 'de S.T.E.M eğitim modelini özetleyen şema verilmiştir.



Şekil 2. S.T.E.M Eğitim Modeli

Bu eğitim modeli, öğrencilerin merak duygusunu uyandırır, keşfetmelerine ve deneyimlemelerine olanak sağlar. Bu eğitim modeli, öğrencilerin doğal olarak sahip oldukları merak ve keşfetme isteğini kullanarak, onları bilimsel düşünme ve problem çözme becerilerini geliştirmeye yönlendirir. Bu sayede, öğrenciler bilimsel yöntemleri kullanarak sorunlara çözüm üretmeyi öğrenirler ve bu becerilerini hayatları boyunca kullanabilecekleri bir şekilde kazanırlar.


S.T.E.M. eğitim modeli, öğrencilerin teknolojiye karşı olumlu bir tutum geliştirmelerini sağlar ve dijital becerilerinin gelişmesini ve teknoloji çağına uyum sağlamalarını kolaylaştırır. [17].

2.4. UNITY Oyun Motoru ve C# Programlama Dili

UNITY oyun motoru, oyun geliştiricilerin oyunlarını oluşturup yayınlamalarına kolaylık sağlar. Bu motor, C# programlama dilini destekleyerek oyun geliştiricilerin programlama işlemlerini basitleştirir. UNITY, farklı platformlarda oyun yayınlama özelliği sayesinde oyunların daha geniş bir kitleye erişmesine olanak tanır [18]. Bu nedenle UNITY, popüler bir oyun motoru olarak birçok büyük oyun şirketi ve bağımsız geliştirici tarafından kullanılmaktadır. Ayrıca, UNITY, eğitim kurumları ve öğrenciler tarafından da kullanılan bir oyun motorudur ve genç oyun geliştiricilerin kariyerlerine başlamadan önce önemli bir deneyim kazanmalarına yardımcı olur.

2.5. Mayer Çoklu Ortam İlkeleri

Mayer'in Çoklu Ortam İlkeleri, öğrenme materyallerinin etkili bir şekilde tasarlanması için kullanılan önemli bir çerçeve olarak kabul edilir. Bu ilkeler, öğrenme materyallerinde yer alan çoklu ortam bileşenlerinin etkin bir şekilde kullanımını vurgular ve öğrencilerin öğrenme deneyimlerini zenginleştirmeye yardımcı olur. Bu ilkelerin uygulanması, öğrencilerin dikkatini çekerek bilginin daha iyi anlaşılmasını ve hatırlanmasını sağlar [19]. Çoklu ortam ilkelerini özetleyen şema Şekil-3 'de sunulmuştur.



Şekil 3. Mayer İlkeleri

2.5.1. Gereksizlik İlkesi

Bu ilke, öğrenme materyallerinde gereksiz bileşenlerin kullanılmaması gerektiğini vurgular. Öğrenme materyallerinde yer alan gereksiz görseller, animasyonlar veya diğer sesli ve görsel bileşenler, öğrencilerin dikkatini dağıtabilir ve ana mesajın anlaşılmasını zorlaştırabilir. Bu nedenle, öğrenme materyallerinin tasarımında gereksiz bileşenlerden kaçınılmalıdır.

Bu çalışmada kullanılan görseller, animasyonlar ve sesli öğeler, Mayer Çoklu Ortam ilkelerinden Gereksizlik ilkesine uygun olarak gerekli yerlerde ve doğru bir şekilde kullanılmıştır. Gereksiz hiçbir öğe bulunmamaktadır. Kullanılan her öğenin bir amacı bulunmaktadır.

2.5.2. Formal Denge İlkesi

Bu ilke, öğrenme materyallerinde yer alan görsel ve metin bileşenlerinin dengeli bir şekilde kullanılması gerektiğini vurgular. Örneğin, bir slayt gösterisi veya sunumda, görsel ve metin bileşenleri arasındaki denge önemlidir. Çok fazla metin veya görsel yoğunluğu, öğrencilerin dikkatini dağıtabilir ve öğrenme sürecini olumsuz etkileyebilir.

Bu çalışmada kullanılan görseller ve metinler birbirlerine uygun olmak üzere özenle seçilmiştir. Görsellerin ve Metinlerin renk uyumları, büyüklüklerine dikkat edilmiştir.

2.5.3. Zamansal ve Uzamsal Yakınlık İlkesi

Bu ilke, öğrenme materyallerinde yer alan görsel ve işitsel bileşenlerin zaman ve mekânsal olarak yakın olması gerektiğini vurgular. Örneğin, bir slayt gösterisinde, sesli açıklama ve görsel gösterimlerin zamanlaması önemlidir. Ayrıca, görsel ve işitsel bileşenlerin birbirine yakın olması, öğrencilerin dikkatini çekerek bilginin daha iyi anlaşılmasını ve hatırlanmasını sağlar.

Bu uygulamada kullanılan görsel ve sesli animasyonlar doğru zamanda ve doğru yerde kullanılmıştır. Bu sayede çocuklar oyunları oynarken görsel ve sesli öğeler sayesinde öğrenme becerileri artırılmıştır. Uygulama başlığının altında da detaylı bir şekilde anlatılmıştır.

2.5.4. Duyu Biçimi İlkesi

Bu ilke, öğrenme materyallerinin öğrencilerin duyu biçimlerine uygun olarak tasarlanması gerektiğini vurgular. Öğrencilerin bazıları görsel öğrenme stiline sahipken, diğerleri işitsel veya dokunsal öğrenme stilini tercih edebilirler. Bu nedenle, öğrenme materyallerinin tasarımında, öğrencilerin duyu biçimleri göz önünde bulundurularak uygun görsel, işitsel veya dokunsal bileşenlerin kullanılması önemlidir.

Uygulamamız farklı öğrenme kabiliyetine sahip olan çocuklar için farklı oyunlar sunmaktadır. Örneğin, işitsel öğrenme yeteneği yüksek olanlar, onlar için hazırlanmış özel oyunları, görsel yeteneği yüksek olanlar ise kendileri için özel hazırlanmış özel oyunları seçebileceklerdir.

2.5.5. Bireysel Farklılıklara Uygunluk İlkesi

Bu ilke, öğrenme materyallerinin öğrencilerin bireysel farklılıklarına uygun olarak tasarlanması gerektiğini vurgular. Öğrencilerin öğrenme hızları, öğrenme stilleri ve öğrenme düzeyleri farklı olabilir. Bu nedenle, öğrenme materyallerinin tasarımı, öğrencilerin bireysel farklılıklarına uygun bir şekilde yapılmalıdır. Örneğin, bir materyal, görsel öğrenme stilini tercih eden öğrenciler için uygun bileşenler içermelidir.

Bu çalışmanın amacı hiçbir çocuğu ayırmadan eğlenerek öğrenmelerini sağlamaktır. Bu amaç doğrultusunda Mayer ilkelerine uyulmuştur.

3. UYGULAMA

3.1. Ana Sahne


Ana sahnemiz, çocukların eğlenirken öğrenebilecekleri interaktif bir ortamdır. Renkli ve canlı tasarımı ile çocukların dikkatini çekmekte ve eğlenceli bir öğrenme deneyimi sunmaktadır. Ana sahnemizde yer alan 4 mini oyun, çocukların motor becerilerini, dil ve iletişim becerilerini, bilişsel ve zihinsel yeteneklerini geliştirme fırsatı sunmaktadır. Şekil-4 'de çalışmamızın ana sahnesi gösterilmiştir.



Şekil 4. Ana Sahne

3.2. Oyun Sahnesi 1

Geliştirilen oyun, solda ekranda sırasıyla 1, 2, 3, 4, 5, 6, 7, 8, 9 şeklinde görüntülenen rakamlardan oluşur. Sağ tarafta ise bu rakamlar mevcuttur. Oyuncu, solda belirtilen rakamın sağ taraftaki rakamlar arasından doğru olanı seçerek ilerlemeye çalışır. Yanlış rakam seçimi durumunda, oyuncu hatalı cevap yazısı ile karşılaşır ve sonraki buton aktif hale gelmez. Doğru rakam seçimi durumunda ise sonraki buton aktif hale gelir ve doğru cevap yazısı görüntülenir. Oyuncu, sırasıyla 2, 3, 4, 5 ... rakamlarını tahmin ettikten sonra, 9. rakamı doğru tahmin ettiğinde, sonraki buton tekrar 1 rakamına döner. Oyun, bu şekilde devam eder. Rakamları öğreniyorum etkinliği için oluşturulan oyunun arayüz tasarımı Şekil-5'de gösterilmiştir. Şekil-5'te gösterildiği üzere metin yazıları sesli bir şekilde ifade edilmiştir. Bu sayede oyuncunun ne yapması gerektiği daha çok anlaşılır olmuştur.




Şekil 5. Oyun Sahnesi

Oyun, oyunculara sayıları tanıma, sayıları doğru sıralama ve sayıları hızlı bir şekilde algılama becerileri kazandırmayı amaçlamaktadır. Ayrıca, oyuncuların dikkat ve odaklanma becerilerini geliştirmelerine yardımcı olabilir. Oyun, oyuncuların yanlış seçimlerine karşı sabırlı ve kararlı bir şekilde devam etmelerini teşvik ederek, problem çözme ve karar verme becerilerini de geliştirebilir. Sonuç olarak, bu oyun, özellikle küçük yaşlardaki çocuklara sayıları tanıma becerilerini geliştirme ve gelişimlerine katkıda bulunma açısından faydalı olmaktadır.

3.3. Oyun Sahnesi 2

Oyuncunun, solda alfabetik sırayla belirlenen harfleri, orta kısımdaki rastgele harf yığını içerisinde bulup işaretlemesi gerekmektedir. Her doğru harf bulunduğu, sıradaki harfe geçiş yapılır ve oyuncunun hızlı bir şekilde harfleri bulması gerekmektedir. Oyuncunun amacı, mümkün olduğunca çok harf bulup doğru sıralamayı tamamlamak için belirlenen adet sayısına ulaşmaktır. Harfleri öğreniyorum etkinliği için tasarlanan oyun sahnesi Şekil-6 'de sunulmuştur. Şekil-6'da gösterildiği üzere metin yazıları sesli bir şekilde ifade edilmiştir. Bu sayede oyuncunun ne yapması gerektiği daha çok anlaşılır olmuştur.



Şekil 6. Oyun Sahnesi

3.4. Oyun Sahnesi 3

Bu oyun, çevre bilincini geliştirmek ve geri dönüşüm konusunda farkındalık yaratmak için harika bir fırsat sunmaktadır. Oyun da oyuncuların yapması gereken şey, çöpleri doğru geri dönüşüm kutularına atmaktır. Eğer yanlış bir tercih yaparlarsa, çöp ilk konumuna geri dönecek ve büyük bir çarpı işareti ekranda belirecek ve yanlış olduğunu belirten bir ses duyulacaktır. Ancak doğru geri dönüşüm kutusunu seçerlerse, çöp kaybolacak ve ekranda büyük bir tik işareti belirecek ve doğru olduğunu belirten bir ses duyulacaktır. Oyun, çöpler bitene kadar bu şekilde devam edecektir. Şekil-7'de gösterilen metin yazıları sesli bir şekilde ifade edilmektedir. Bu sayede oyuncuyu yönlendirmek istenmektedir.



Şekil 7. Oyun Sahnesi

Şekil-7 olarak gösterilen bu oyunda, oyunculara çevre bilincini geliştirme fırsatı sunarak birçok farklı beceriyi kazandırabilir. İşte bu oyunun kazandırdığı bazı beceriler:

- Geri dönüşüm ve sürdürülebilirlik bilinci: Oyuncuların geri dönüşüm kutularını doğru bir şekilde kullanarak çöpleri geri dönüştürmeleri gerekiyor. Bu da oyuncuların sürdürülebilirlik ve atık yönetimi hakkında daha bilinçli olmalarını sağlayabilir.
- Gözlem ve analiz becerileri: Oyuncuların çöpleri doğru geri dönüşüm kutusuna atmak için önce çöp türlerini tanımaları gerekiyor. Bu, oyuncuların gözlem ve analitik becerilerini geliştirebilir.
- Dikkat ve el-göz koordinasyonu becerileri: Oyuncuların çöpleri doğru kutuya atmak için hedefe odaklanmaları ve el-göz koordinasyonlarını kullanmaları gerekiyor. Bu da oyuncuların dikkat ve el-göz koordinasyonu becerilerini geliştirebilir.
- Sabır ve öz disiplin: Oyuncuların doğru geri dönüşüm kutusunu seçmek için sabırlı ve öz disiplinli olmaları gerekiyor. Bu da oyuncuların sabır ve öz disiplin becerilerini geliştirebilir.

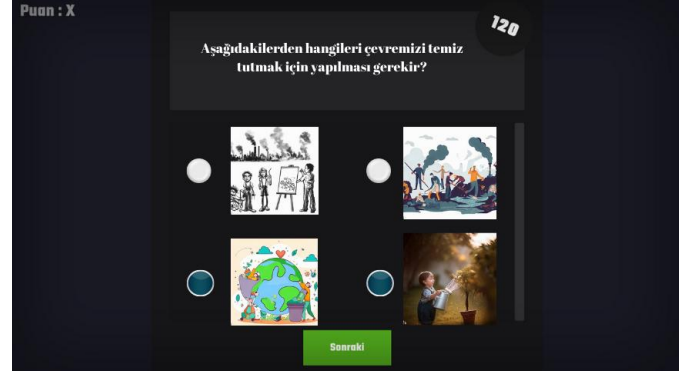
Bu beceriler, oyunun sadece eğlenceli olmakla kalmayıp aynı zamanda oyuncuların sürdürülebilirlik ve çevre bilincini geliştirmelerine de yardımcı olduğunu gösterir.

3.5. Oyun Sahnesi 4

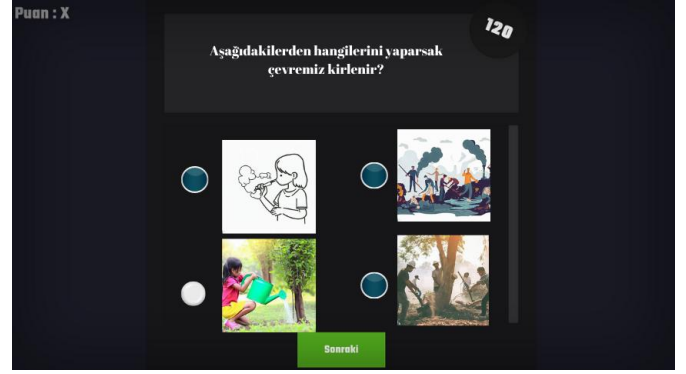
Oyunumuz bir çevre bilinci ve genel kültür kazandırmayı amaçlayan soru cevap tabanlı bir oyundur. Oyunumuzun sol üst köşesinde oyuncunun puanını (skorunu) gösteren bir skor tablosu sağ üst köşesinde ise oyuncunun cevaplamak için belirli bir süresi olan bir zamanlayıcı bulunmaktadır. Oyunumuzun orta kısmında ise oyuncuya yöneltilen çevre bilinci ile ilgili çoktan seçmeli sorular ve onların şıkları yer almaktadır.

Oyuncu doğru bir cevap verdiğinde ekranın ortasında çıkan animasyonlarla oyuncuya doğru cevapladığı belirtilir. Yanlış cevaplandığında ise farklı bir animasyon çıkararak oyuncunun yanlış cevapladığı gösterilir. Oyun bitiminde oyuncunun toplam puanı gösterilir ve tekrar oynama butonu çıkar.

Sorular oyun içinde rastgele seçilen ve çevre bilincini arttırmayı amaçlayan çoktan seçmeli sorulardan oluşmaktadır. Örneğin Şekil-8 'de çevremizi temiz tutmak için yapılması gerekir?' sorusu. Şekil-9'da ise çevremizi kirletecek faaliyetlerin seçilmesi istenmektedir. Bu şekillerde bulunan soruların sesli bir biçimde ifade edilmesi oyuncuyu doğru cevabı bulması için harekete geçirmektedir.



Şekil 8. Oyun Sahnesi



Şekil 9. Oyun Sahnesi

- İlk olarak, oyuncuların soruları doğru cevaplaması, çocukların öğrenme yeteneklerini geliştirmelerine yardımcı olabilir. Doğru cevaplar, çocukların bilgi birikimlerini artırarak genel kültürlerini ve çevre bilincini geliştirmelerine katkı sağlayabilir.
- Oyunda yer alan zamanlayıcı, çocukların zaman yönetimi becerilerini geliştirmelerine yardımcı olabilir. Çocuklar, süre içinde soruları cevaplandırmak için hızlı ve verimli bir şekilde düşünebilmeleri gerekmektedir. Bu sayede, zaman yönetimi becerileri geliştirilebilir.
- Oyunda yer alan skor board, çocukların motivasyonlarını artırarak yüksek puanlar almak için çaba sarf etmelerine yardımcı olabilir. Bu da çocukların hedef belirleme ve motivasyon yönetimi becerilerinin gelişmesine katkı sağlayabilir.
- Doğru cevapların belirtilmesi için kullanılan animasyonlar, çocukların dikkat ve algılama becerilerini arttırabilir. Çocuklar, doğru cevapların belirtilmesiyle olumlu bir geri bildirim aldıklarında, kendilerine olan güvenlerini arttırabilirler.

- e) Yanlış cevapların belirtilmesi için kullanılan animasyonlar da çocukların öğrenme sürecine katkı sağlayabilir. Yanlış cevapların gösterilmesi, çocukların hatalarından ders çıkarmalarına ve daha sonra benzer hataları yapmamasına yardımcı olabilir.
- f) Son olarak, oyunda yer alan çoktan seçmeli sorular, çocukların eleştirel düşünme, analitik düşünme ve karar verme becerilerini geliştirmelerine yardımcı olabilir. Çocuklar, sorulara doğru cevaplar vermek için verilen seçenekleri analiz etmek ve en doğru cevabı seçmek için düşünme becerilerini kullanabilirler.
- g) Tüm bu becerilerin yanı sıra, oyunda yer alan çevre bilinci ile ilgili sorular, çocukların çevre konusunda farkındalıklarını artırarak onların çevre dostu davranışlar sergilemelerine katkı sağlayabilir. Oyunda yer alan sorular sayesinde çocuklar, çevrenin önemini anlayarak çevre koruma ve sürdürülebilirlik konularında bilinçlenerek yetişkinliklerinde de çevre dostu bir yaşam sürdürmelerine yardımcı olabilirler.

Tüm bu nedenlerle, çocuklar için tasarlanmış bu soru-cevap tabanlı oyun, çocukların genel kültürlerini, çevre bilincini, zaman yönetimi, hedef belirleme, motivasyon yönetimi, dikkat, algılama, eleştirel düşünme, analitik düşünme, karar verme ve çevre dostu davranışlar sergileme gibi birçok farklı beceriyi geliştirmelerine yardımcı olabilir.

4. SONUÇLAR VE ÖNERİLER

Bu çalışmada okul öncesi eğitim öğrencilerine, Çevre bilincini eğlenerek öğretmek için araştırmalar ve uygulamalar yapılmış bulunmaktadır. Bu amaç doğrultusunda Yurtiçinde ve Yurtdışında yapılmış literatür incelenmiş ve uygulama örnekleri çeşitlendirilerek sunulmuştur. UNITY tabanlı eğitici oyun tasarımı, okul öncesi öğrencilere çevre bilinci kazandırmada etkili bir yöntem olmaktadır. Oyunlar çocukların çevreye yönelik farkındalık geliştirmelerini sağlayarak, mobil oyunlar okul öncesi öğrencilerin fiziksel, zihinsel, dil ve sosyal becerilerini geliştirmelerine yardımcı olmaktadır.

Hareket etmeye teşvik eden oyunlar, el-göz koordinasyonunu geliştiren oyunlar, problem çözme becerilerini destekleyen oyunlar ve sosyal etkileşimi teşvik eden oyunlar gibi çeşitli oyunlar, çocukların genel gelişimine katkı sağlamaktadır. Oyun tasarımında görsel tasarım ilkelerine uygun olarak hazırlanan oyunlar, çocukların ilgisini çekmekte ve oyun deneyimini daha eğlenceli hale getirmektedir. Büyük, basit ve okunması kolay fontlar, çocukların oyunu anlamalarını kolaylaştırırken, renkli ve eğlenceli arka plan resimleri çocukların dikkatini çekmektedir. Ebeveynler ve öğretmenler, çocukların mobil oyunları eğitici ve öğretici amaçlarla kullanmalarını sağlamak için oyun seçimlerini ve oyun sürelerini kontrol etmelidir. Mobil oyunların doğru bir şekilde kullanılması, çocukların gelişimine olumlu katkı sağlamaktadır.

Okul öncesi eğitim kurumları, çevre bilinci eğitimine daha fazla odaklanmalı ve öğrencilere çevre dostu değerleri kazandırmak için STEM tabanlı oyunlar gibi yeni öğretim teknolojilerini kullanmalıdır. Ebeveynler, çocukların mobil oyunları seçerken, eğitici ve çevre bilinci odaklı oyunlara yönlendirmelidir. Oyun seçimi, çocukların gelişimine uygun olmalı ve oyun süreleri sınırlandırılmalıdır.

Oyun tasarımcıları, çocukların yaş ve gelişim düzeylerini dikkate alarak UNITY tabanlı eğitici oyunlar geliştirmelidir. Oyunlar, çocukların dikkatini çekmek ve ilgisini sürdürmek için renkli ve etkileyici grafiklere sahip olmalıdır. Ayrıca, oyunlar basit kullanıcı arayüzüne ve anlaşılır talimatlara sahip olmalıdır, böylece çocuklar oyunu kolayca kullanabilir ve anlayabilir. Oyunlar, çevre bilincini destekleyen görevler, bulmacalar ve aktiviteler içermelidir. Örneğin, çocuklar geri dönüşümün önemini öğrenebilir, enerji tasarrufu hakkında bilgi edinebilir veya doğal yaşamın korunmasına yönelik görevler gerçekleştirebilirler.

Bu şekilde, çocuklar hem eğlenirken hem de çevreyle ilgili önemli kavramları öğrenirler. Oyunlar, çocukların sosyal etkileşimini teşvik etmek için çok oyunculu özelliklere sahip olabilir. Çocuklar, arkadaşlarıyla birlikte oynayarak iş birliği yapmayı, iletişim becerilerini geliştirmeyi ve takım çalışmasını öğrenebilirler. Oyunlar, çocukların başarılarını takip eden ve ödüllendiren bir ilerleme sistemi içermelidir. Örneğin, çocuklar belirli görevleri tamamladıkça veya belirli puanları elde ettikçe ödüller kazanabilirler. Bu, çocukların motivasyonunu artırır ve oyunu daha ilgi çekici hale getirir. Ebeveynler ve öğretmenler, çocukların oyun deneyimlerini takip etmeli ve çevre bilinci eğitimine katkıda bulunmak için oyunlarla ilgili konuşmalar yapmalıdır. Oyunların sağladığı öğrenme fırsatlarını vurgulayarak çocukları teşvik etmek ve desteklemek önemlidir.

Etik Hususlar

Etik kurallara uyum

Bu çalışmanın, özgün bir çalışma olduğunu; çalışmanın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallarına uygun davrandığımızı; çalışmamızın Committee on Publication Ethics (COPE) in tüm şartlarını ve koşullarını kabul ederek etik görev ve sorumluluklara riayet ettiğimizi beyan ederiz.

Finansman

Bu çalışma, Onur ÖZER tarafından Doç. Dr. Durmuş ÖZDEMİR danışmanlığında hazırlanan TÜBİTAK 2209-A - Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı Bilimsel Araştırma Projeleri ID:[1919B012213284] tarafından finanse edilmiştir ve gerçekleştirilmiştir.

Çıkar çatışması

Makalemiz ile ilgili herhangi bir kurum, kuruluş, kişi ile mali çıkar çatışması yoktur ve yazarlar arasında çıkar çatışması bulunmamaktadır.

Teşekkür

2209-A - Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı Bilimsel Araştırma Projeleri kapsamında çalışmamızı destekleyen Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na teşekkür ederiz.

KAYNAKÇA

- [1] Üstündağ, A. 2019. 4-6 yaş arası çocuklar tarafından tercih edilen dijital oyunlar. Çankırı Karatekin Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 10(2), 1-19.
- [2] Saylık, M. 2019. İlkokul 1. kademe 4. sınıf öğrencileri için oyun ve fiziksel etkinlikler dersinde çevre bilinci oluşturmaya yönelik oyun tasarımı. Kütahya Dumlupınar Üniversitesi, Sosyal Bilimler Enstitüsü, Kütahya.
- [3] MEB Temel Eğitim Genel Müdürlüğü, 2013. <https://tegm.meb.gov.tr/dosya/okuloncesi/ooproram.pdf> (Erişim Tarihi: 17 Mayıs 2023)
- [4] Yazıcı, E., Çelik, M., Yıldırım, F. N., Altıntaş, E. & Güneş, A. 2018. Okul Öncesi Dönemdeki Çocukların Okul Kavramına İlişkin Metaforik Algıları. Sakarya Üniversitesi Eğitim Fakültesi Dergisi, 35, 64-86. <https://dergipark.org.tr/tr/pub/sakaefd/issue/38142/338285>
- [5] Sağır, A. & Okutan, S. (2022). Dijital Oyunların Ortaokul Öğrencileri Üzerindeki Etkisi: Karabük Örneği. Milli Eğitim Dergisi, 51(233), 715-744. DOI: 10.37669/milliegitim.769932
- [6] Akbulut, Y. 2013. Çocuk ve Ergenlerde Bilgisayar ve İnternet Kullanımının Gelişimsel Sonuçları. Trakya Üniversitesi Eğitim Fakültesi Dergisi 3(2), 53-68.
- [7] Akçay M. ve Oktar, Ç. 2023. Android Cihazlarda Kullanılabilecek Örnek Bir Okul Destek Programının Oluşturulması. Eskişehir Türk Dünyası Uygulama ve Araştırma Merkezi Bilişim Dergisi, 4(1), 33-42. doi:10.53608/estudambilisim.1242070
- [8] Özdemir, D., & Karaman, S. 2017. Investigating interactions between students with mild mental retardation and humanoid robot in terms of feedback types. Education and Science, 42(191), 109-138.
- [9] Ülker, Ü. & Bülbül, H. İ. 2018. Dijital Oyunların Eğitim Seviyelerine Göre Kullanılma Durumları. TÜBAV Bilim Dergisi, 11 (2), 10-19. <https://dergipark.org.tr/tr/pub/tubav/issue/38182/430197>
- [10] Seven Uzun, A. 2022. Türkiye’de Okul Öncesi Dönemdeki Çocukların Dil Gelişimine Yönelik Yapılan Lisansüstü Tezlerin İncelenmesi. Journal of Sustainable Education Studies, Özel Sayı 1 (Ö1), 11-20. <https://dergipark.org.tr/tr/pub/seader/issue/69007/1056317>
- [11] Özkılıç Kabul, N. D. 2019. Üç yaş çocuklarda teknolojik alet kullanımının sosyal beceri, oyun becerisi ve dil gelişimi üzerindeki etkilerinin incelenmesi. Maltepe Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, İstanbul.
- [12] TanrıverdiH. ve Erarslan, N. (2016) Okul Öncesi Çocukların Sosyal Uyum ve Beceri Düzeyleri ile Değer Kazanımları Arasındaki İlişki", Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Dergisi, 5(9), 9-23.
- [13] Kızıroğlu, İ. 2023. Çevre Eğitimi ve Çevre Bilinci. Tabiat ve İnsan, 2(193), 5-17. <https://dergipark.org.tr/tr/pub/tabin/issue/75873/1251424>
- [14] Yoleri, S. 2012. Çocuk ve Çevre: Okul Öncesi Çocuklar Arasında Çevre Bilinci Oluşturma. Dokuz Eylül Üniversitesi Buca Eğitim Fakültesi Dergisi, 34, 100-111. <https://dergipark.org.tr/tr/pub/deubefd/issue/25115/265162>
- [15] Esen, A. ve Esen, M. 2018. Çevre Eğitimi ve Bilinci Araştırması. Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi, 65, 164-178. <https://dergipark.org.tr/en/pub/abuhsbd/issue/36059/404866>
- [16] Çavaş, P., Ayar, A. & Gürcan, G. 2020. Türkiye’de STEM Eğitimi Üzerine Yapılan Araştırmaların Durumu Üzerine Bir Çalışma. Van Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi, 17(1), 823-854. DOI: 10.33711/yyuefd.751853
- [17] Akarsu, M., Okur Akçay, N. & Elmas, R. 2020. STEM Eğitimi Yaklaşımının Özellikleri ve Değerlendirilmesi. Boğaziçi Üniversitesi Eğitim Dergisi, STEM Eğitimi, 155-175. <https://dergipark.org.tr/tr/pub/buje/issue/58376/842413>
- [18] Unity Technologies 2005. Unity- Manual: About Unity. <http://docs.unity3d.com/Manual/UnityOverview.html>. (Erişim Tarihi: 17 Mayıs 2023)
- [19] Mayer, R. E. 2002. Multimedia learning. Psychology of Learning and Motivation, 41, 85-139.

(Research Article)**Numerical Solution of Advection-Diffusion Equation via Quartic B-Spline Least Squares Method****Buket Ay¹, Bulent Saka², Ozlem Ersoy Hepson³, Idiris Dag^{*4}**¹Haliç University, Faculty of Engineering, Department of Computer Engineering, 34060, İstanbul, ORCID No:<http://orcid.org/0000-0002-4188-6667>²Eskisehir Osmangazi University, Faculty of Science, Department of Mathematics and Computer, 26040, Eskisehir,ORCID No: <http://orcid.org/0000-0002-4714-4189>³Eskisehir Osmangazi University, Faculty of Science, Department of Mathematics and Computer, 26040, Eskisehir,ORCID No: <http://orcid.org/0000-0002-5369-8233>⁴Eskisehir Osmangazi University, Faculty of Engineering and Architecture, Department of Computer Engineering,26040, Eskisehir, ORCID No: <http://orcid.org/0000-0002-2056-4968>**Keywords:**Advection-diffusion equation,
Least squares method,
Quartic B-spline**Abstract:** Numerical solutions are obtained for the time dependent one dimensional Advection-Diffusion equation (ADE) using the least squares method (LSM). After the time-integration of the ADE by use of the Crank-Nicolson technique, the combination of the quartic B-splines as a trial function is substituted in the time discretized ADE and for the LSM procedure, a weight function is obtained by taking derivative of the integrand of integral of squared ADE with respect to time parameters of the trial functions. Thus solution of obtained recursive system of the unknown parameters provides solutions of the ADE at discrete times. Achievement is displayed by studying three test problems.**(Araştırma Makalesi)****Adveksiyon Difüzyon Denkleminin Kuartik B-Spline En Küçük Kareler Metodu ile Sayısal Çözümü****Anahtar Kelimeler:**Advection-diffusion denklemi,
En küçük kareler metodu,
Kuartik B-spline**Özet:** En küçük Kareler metodu (LSM) kullanılarak zamana bağlı bir boyutlu Advection-Diffusion denklemi (ADE) için yaklaşık çözümler elde edilmiştir. Crank-Nicolson yöntemi ile ADE'in zaman ayrıştırması yapıldıktan sonra, Kuadratik B-spline fonksiyonların kombinasyonundan oluşan deneme fonksiyonu zaman ayrılmış ADE'nin bilinmeyen fonksiyonuna yerleştirilmiştir. Böylece elde edilen cebirsel ifadenin karesi alınmış integralinin integrantının deneme fonksiyonun da tanımlı zaman parametresine göre türevi alınarak ağırlık fonksiyonu belirlenmiştir. Bulunan iterative sistemin çözümlerinden ADE'nin ayrık zamanlardaki çözümlerini elde edilir. Metodun başarısı üç test problem çalışılarak gösterilmiştir.**1. INTRODUCTION**

The ADE is the time dependent one-dimensional partial differential equation which models many problems of physics, chemistry and biology. It describes advection-diffusion processes depending on the given parameters such as heat, energy, mass, etc. It indicates combination of both non-dissipative (hyperbolic) advective and a dissipative (parabolic) diffusive behaviors. The ADE, as an mathematical model, is used to designate water transfer

in soils, heat transfer in draining film, spread of pollutants in rivers, dispersion of tracers in porous media, the Timoshenko beam problem, the Reissner-Mindlin plate, the arch problem and the axisymmetric shell problem. It is known that the numerical solution is obtained well when the diffusion is dominant whereas for the larger advection coefficient taken, numerical methods produce higher error solutions. The effort has been made on producing the efficient numerical methods. Various numerical techniques including B-splines have been set up for solving the one-dimensional ADE of constant

coefficients with appropriate initial and boundary conditions [1].

The numerical solution of the advection-diffusion problem is provided by use of both quadratic and cubic B-spline finite element methods in which Taylor series expansion is used for the time discretization [2]. Cubic B-spline collocation methods are build up for solving convection diffusion equations in the studies [3,4]. The differential quadrature methods based on the cubic B-splines is constructed for the advection-diffusion equation [5]. ADE is solved by using the extended cubic B-spline collocation method [6]. Differential quadrature together with B-spline functions of degree four and five have been designed to compute advection-diffusion equation numerically [7]. ADE is integrated using the extended cubic B-spline Galerkin method to find its numerical solutions [8]. The fourth order single step methods for time integration and cubic B-spline Galerkin method for space integration is used to solve ADE in the work [9]. The cubic trigonometric B-spline for space discretization and finite difference scheme for time discretization is established to discretize the ADE fully [10]. ADE is also handled by means of the least squares method. A space time least-squares finite elements scheme is constructed for advection-diffusion equation [11], space-time Galerkin least squares method for the one-dimensional ADE is proposed in the works [12,13]. The space time least squares method was set up by way of both linear and quadratic B-spline shape functions for computing numerical solutions of the ADE [14]. A p-version based space-time least-squares finite-element method is applied to solve the unsteady convection-diffusion equation [15]. The linear and quadratic B-spline basis functions have been used in the space time least squares formulation for solving the ADE in the study [16]. The cubic B-spline least square finite element method is established for solving the ADE [17]. The Nonic B-splines are adapted to form the collocation method for solving ADE numerically [18]

Linear joining of $\frac{\partial u}{\partial t}$, advection $\frac{\partial u}{\partial x}$ and diffusion $\frac{\partial^2 u}{\partial x^2}$ terms constitute the ADE,

$$u_t + \varepsilon u_x - \lambda u_{xx} = 0, x \in [a, b], t > \quad (1)$$

where ε and λ are parameters, x and t are time and space coordinates respectively. The initial condition (IC) is given as,

$$u(x, 0) = f(x). \quad (2)$$

Dirichlet boundary conditions (BCs) are,

$$u(a, t) = 0, \quad u(b, t) = 0. \quad (3)$$

The equation includes behaviors of both advection and diffusion processes depending upon value of ε (advection coefficient) and γ (diffusion coefficient). Numerical difficulties arise like exhibiting both spurious oscillations

and excessive numerical diffusion when the advection becomes dominant. Thus, numerical methods have been constructed to overcome the adversity of advection domination for getting right solutions of the ADE.

In this paper, fully-integration of ADE is managed by help of the Crank-Nicolson method in time and quartic B-spline least squares method in space. Solution steps are illustrated in section 2. Three standard test problems are presented to show the performance of the suggested algorithm.

2. THE QUARTIC B-SPLINE LEAST SQUARE METHOD

Let the interval $[a, b]$ be partitioned into subintervals $[x_i, x_{i-1}], i = 1, \dots, N$ at a uniformly distributed mesh points $x_i = a + ih, i = 0, \dots, N$ with $x_0 = a$ and $x_N = b$. The quartic B-splines $P_i^4(x), i = -2, \dots, N + 1$ are defined at the defined mesh points and fictitious points $x_{-4}, x_{-3}, x_{-2}, x_{-1}, x_{N+1}, x_{N+2}, x_{N+3}, x_{N+4}$ outside problem interval $[a, b]$ in the following form:

$$P_i^4(x) = \frac{1}{h^4} \begin{cases} (x - x_{i-2})^4 & , [x_{i-2}, x_{i-1}] \\ (x - x_{i-2})^4 - 5(x - x_{i-1})^4 & , [x_{i-1}, x_i] \\ (x - x_{i-2})^4 - 5(x - x_{i-1})^4 + 10(x - x_i)^4 & , [x_i, x_{i+1}] \\ (x_{i+3} - x)^4 - 5(x_{i+2} - x)^4 & , [x_{i+1}, x_{i+2}] \\ (x_{i+3} - x)^4 & , [x_{i+2}, x_{i+3}] \\ 0 & , \text{otherwise} \end{cases} \quad (4)$$

$P_i^4(x)$ are basis functions for the functions defined in the problem interval $[a, b]$ so that any function can be arranged as a linear combination of the quartic B-spline basis functions:

$$u(x, t) \approx U(x, t) = \sum_{i=-2}^{N+1} \psi_i(t) P_i^4(x). \quad (5)$$

Where $\psi_i(t)$ are time dependent parameters determined by application of the least squares method to the ADE. The B-spline approximation at the mesh points to the nodal value $u(x, t)$ can be expressed in terms of element parameters.

$$\begin{aligned} U(x_i, t) &= U_i = \psi_{i-2} + \psi_{i-1} + \psi_i + \psi_{i+1} \\ U_i' &= \frac{4}{h} (-\psi_{i-2} - 3\psi_{i-1} + 3\psi_i + \psi_{i+1}) \\ U_i'' &= \frac{12}{h^2} (\psi_{i-2} - \psi_{i-1} - \psi_i + \psi_{i+1}) \\ U_i''' &= \frac{24}{h^3} (-\psi_{i-2} + 3\psi_{i-1} - 3\psi_i + \psi_{i+1}) \end{aligned} \quad (6)$$

To start the integration of the ADE (1), first, time integration is managed via the Crank-Nicolson technique to obtain time-integrated ADE

$$\frac{U^{n+1} - U^n}{\Delta t} + \varepsilon \left(\frac{U_x^{n+1} + U_x^n}{2} \right) - \lambda \left(\frac{U_{xx}^{n+1} + U_{xx}^n}{2} \right) = 0 \quad (7)$$

and organize (7) to have the form:

$$2U^{n+1} - 2U^n + (\varepsilon\Delta t)(U_x^{n+1} + U_x^n) - (\lambda\Delta t)(U_{xx}^{n+1} + U_{xx}^n) = 0 \quad (8)$$

At the second step, the least squares scheme is going to be performed to the Eq. (8) to reach the integral equation:

$$\int_a^b (2U^{n+1} - 2U^n + (\varepsilon\Delta t)(U_x^{n+1} + U_x^n) - (\lambda\Delta t)(U_{xx}^{n+1} + U_{xx}^n))^2 dx = 0 \quad (9)$$

For the purpose of suitability, the B-splines (4) and integral Equations (9) are transformed by using local coordinate system

$$\zeta\Delta x = x - x_i, 0 \leq \zeta \leq 1 \quad (10)$$

mapping the sample interval $[x_i, x_{i+1}]$ to interval $[0,1]$. Thus the quartic B-splines within interval $[x_i, x_{i+1}]$ have expression with respect to ζ on the interval $[0,1]$

$$\begin{aligned} P_{i-2}^4 &= 1 - 4\zeta + 6\zeta^2 - 4\zeta^3 + \zeta^4 \\ P_{i-1}^4 &= 11 - 12\zeta - 6\zeta^2 + 12\zeta^3 - \zeta^4 \\ P_i^4 &= 11 + 12\zeta - 6\zeta^2 - 12\zeta^3 + \zeta^4 \\ P_{i+1}^4 &= 1 + 4\zeta + 6\zeta^2 + 4\zeta^3 - \zeta^4 \\ P_{i+2}^4 &= \zeta^4 \end{aligned} \quad (11)$$

and using transformation (10) for derivative in ζ coordinates, the first and second derivatives becomes

$$\begin{aligned} U_x &= \frac{\partial U}{\partial \zeta} \frac{\partial \zeta}{\partial x} = U_\zeta \frac{1}{\Delta x}, \\ U_{xx} &= \frac{\partial}{\partial x} (U_x) = \frac{1}{\Delta x} \frac{\partial}{\partial x} (U_\zeta) \\ &= \frac{1}{\Delta x} \frac{\partial U_\zeta}{\partial \zeta} \frac{\partial \zeta}{\partial x} = \frac{1}{\Delta x^2} U_{\zeta\zeta}, \end{aligned}$$

an approximation

$$u^e(x, t) \approx U^e(x, t) = \sum_{i=m-2}^{m+1} \psi_i(t) P_i^4(\zeta) \quad (12)$$

in the interval $[0,1]$, integral equation (9) yields

$$\int_0^1 (2(U^e)^{n+1} - 2(U^e)^n + \beta(U^e)_\zeta^{n+1} + \beta(U^e)_\zeta^n - \theta(U^e)_{\zeta\zeta}^{n+1} - \theta(U^e)_{\zeta\zeta}^n) d\zeta = 0 \quad (13)$$

Taking the derivative of the integral Equation (13) with respect to time parameter ψ^{n+1} yield

$$\frac{d}{d\psi^{n+1}} \int_0^1 (2U^{n+1} - 2U^n + \beta U_\zeta^{n+1} + \beta U_\zeta^n - \theta U_{\zeta\zeta}^{n+1} - \theta U_{\zeta\zeta}^n)^2 d\zeta = 0 \quad (14)$$

so that the least squares weak formulation is obtained in the form of Galerkin with weight function

$$\frac{d}{d\psi^{n+1}} (2U^{n+1} - 2U^n + \beta U_\zeta^{n+1} + \beta U_\zeta^n - \theta U_{\zeta\zeta}^{n+1} - \theta U_{\zeta\zeta}^n). \quad (15)$$

Replacing approximation (12) in Eq. (14) leads to a system of equations:

$$\begin{aligned} &(4P_i P_i \psi_i^{n+1} - 4P_i P_i \psi_i^n + 2\beta P_i P_i' \psi_i^{n+1} \\ &+ 2\beta P_i P_i' \psi_i^n - 2\theta P_i P_i'' \psi_i^{n+1} - 2\theta P_i P_i'' \psi_i^n \\ &+ 2\beta P_i' P_i \psi_i^{n+1} - 2\beta P_i' P_i \psi_i^n + \beta^2 P_i' P_i' \psi_i^{n+1} \\ &+ \beta^2 P_i' P_i' \psi_i^n - \beta\theta P_i' P_i'' \psi_i^{n+1} \\ &- \beta\theta P_i' P_i'' \psi_i^n - 2\theta P_i'' P_i \psi_i^{n+1} \\ &+ 2\theta P_i'' P_i \psi_i^n - \theta\beta P_i'' P_i' \psi_i^{n+1} \\ &- \theta\beta P_i'' P_i' \psi_i^n + \theta^2 P_i'' P_i'' \psi_i^{n+1} \\ &+ \theta^2 P_i'' P_i'' \psi_i^n) d\zeta = 0 \end{aligned} \quad (16)$$

In this system, we use the integral for brevity

$A_{ij}^e = \int_0^1 P_i P_j d\zeta,$	$B_{ij}^e = \int_0^1 P_i P_j' d\zeta,$
$(B_{ij}^e)^T = \int_0^1 P_i' P_j d\zeta$	$C_{ij}^e = \int_0^1 P_i P_j'' d\zeta,$
$(C_{ij}^e)^T = \int_0^1 P_i'' P_j d\zeta,$	$D_{ij}^e = \int_0^1 P_i' P_j' d\zeta,$
$E_{ij}^e = \int_0^1 P_i' P_j'' d\zeta$	$(E_{ij}^e)^T = \int_0^1 P_i'' P_j' d\zeta$
$F_{ij} = \int_0^1 P_i'' P_j'' d\zeta$	

(17)

to have the iterative matrix equation having the unknown ψ_i^{n+1} on each sample intervals $[x_i, x_{i+1}]$

$$\begin{aligned} &[4A^e + 2\beta((B^e)^T + B^e) - 2\theta((C^e)^T + C^e) + \beta^2 D^e - \\ &\beta\theta((E^e)^T + E^e) + \theta^2 F^e](\psi^e)^{n+1} = [4A^e + \\ &2\beta((B^e)^T + B^e) - 2\theta((C^e)^T + C^e) + \beta^2 D^e - \\ &\beta\theta((E^e)^T + E^e) - \theta^2 F^e](\psi^e)^n. \end{aligned} \quad (18)$$

Putting together all the system of equations (18) to have the global matrix equation:

$$[4A + 2\beta(B^T + B) - 2\theta(C^T + C) + \beta^2 D - \beta\theta(E^T + E) + \theta^2 F](\psi)^{n+1} = [4A + 2\beta(B^T + B) - 2\theta(C^T + C) + \beta^2 D - \beta\theta(E^T + E) - \theta^2 F](\psi)^n. \quad (19)$$

$A, B, B^T, C, C^T D, E, E^T, F$ are obtained by combining the element matrices $A^e, B^e, (B^e)^T, C^e, (C^e)^T, D^e, E^e, (E^e)^T$. The time-space discrete solutions can be found by implementing the system of equations(19) once the initial solution parameters are determined by way of the following equations

$$\begin{aligned}
 U(x_m, 0) &= \psi_{m-2}^0 + 11\psi_{m-1}^0 + 11\psi_m^0 + \psi_{m+1}^0 \\
 U'(x_0, 0) &= 4/h(-\psi_{-2}^0 - 3\psi_{-1}^0 + 3\psi_0^0 + \psi_1^0) \\
 U''(x_0, 0) &= 12/h^2(\psi_{-2}^0 - \psi_{-1}^0 - \psi_0^0 + \psi_1^0) \\
 U'(x_N, 0) &= 4/h(-\psi_{N-2}^0 - 3\psi_{N-1}^0 + 3\psi_N^0 + \psi_{N+1}^0)
 \end{aligned}$$

3. NUMERICAL RESULTS

3.1. Pure advection in long channel

The effect of pure advection is going to be studied in an infinitely long channel of long constant cross-section when $\gamma = 0$. Peak of the initial wave is going to be positioned at $x = x_0$ in the channel whose length is taken L and then movement of the initial wave to the right side of the channel is going to be observed. Analytical solution of the ADE is

$$\begin{aligned}
 u(x, t) &= 10 \exp\left(-\frac{1}{2\rho}(x - x_0 - \varepsilon t)^2\right), \\
 0 < x < L
 \end{aligned} \quad (20)$$

from which the initial condition is taken with $t = 0$:

$$u(x, 0) = 10 \exp\left(-\frac{1}{2\rho}(x - x_0)^2\right). \quad (21)$$

Boundary condition

$$u(0, t) = u(L, t) = \alpha, t > 0$$

are chosen.

The velocity of $\varepsilon = 0.5m/s$, position of peak wave of $x_0 = 2000m$ and standard deviation $\rho = 264$ are used for purpose of comparison with earlier results. The program is run over the problem domain $[0,9000]$ until time $t = 9600s$ at which time error norms are given at time $t = 9600$ in Table 1 for equal time/space increments.

When $h = \Delta t = 50$ are used, wave behavior is given at times $t = 1000, 2000, \dots, 9000$ in Fig. 1a and absolute difference between exact and numerical solutions is displayed at time $t = 9600$ in Fig. 1b from which errors happen at most near peak position of wave. From Fig. 1a, wave magnitude remain almost same and move $4800m$ during the running of the algorithm as expected.

Table 1. Error norms at $t=9600$

$h = \Delta t$	$L_2(t = 9600)$	$L_\infty(t = 9600)$
200	54.39436	2.305734
100	15.65584	0.733745
50	4.00316	0.189633
25	1.00492	0.047043
10	0.16095	0.007502

3.2. Combined effect of advection-diffusion

Disappearance of the initial bell-shaped Gauss concentration can be illustrated by way of the analytical solution of ADE:

$$u(x, t) = \frac{1}{\sqrt{4t+1}} \exp\left(-\frac{(x-x_0-\varepsilon t)^2}{\lambda\sqrt{4t+1}}\right) \quad (22)$$

Initial concentration is derived from the analytical solution (22) for $t = 0$:

$$u(x, t) = \exp\left(-\frac{(x-x_0)^2}{\lambda}\right) \quad (23)$$




Figure 1a. Solutions at some times.




Figure 1b. |Exact – numerical| solution at $t=9600$.

The velocity $\varepsilon = 0.8m/s$, diffusion coefficient $\lambda = 0.005 m^2/s$ and peak position of initial concentration $x_0 = 1m$ and time-space increments $h = \Delta t$ combinations are selected to run the algorithm over the interval $[0,9]$ with boundary conditions $u(0, t) = u(9000, t) = 0$. Results of L_2 and L_∞ norms are documented at time $t = 5$ in Table 2.

Table 2. Error norms at $t=5$

$h = \Delta t$	$L_2(t = 5)$	$L_\infty(t = 5)$
0.1	0.033049	0.053645
0.05	0.008523	0.014100
0.02	0.001359	0.002173
0.01	0.000340	0.000538
0.005	0.000085	0.000134

Smaller increments cause smaller errors seen in Table 2. Initial concentration can be observed to vanish drawn in Fig. 2a as time increase and error distribution at time $t = 5$ is depicted in Fig. 2b.




Figure 2.a. Solution behavior




Figure 2. b. |Exact – numerical| solution

3.3. Convection-diffusion of continuous flow of pollutants

This test problem examines the effect of both advection and diffusion while flowing. During the simulation process, the velocity $\varepsilon = 0.01$, the diffusion constant $\lambda = 0.002$, the length of the channel $L = 200m$, boundary conditions $u(0, t) = 1$ and $u(200, t) = 0$, initial condition $u(x, 0) = 0, x \geq 0$ are chosen. Analytical solution is

$$u(x, t) = \frac{1}{2} \operatorname{erfc}\left(\frac{x - \varepsilon t}{\sqrt{4\lambda t}}\right) + \frac{1}{2} \exp\left(\frac{\varepsilon x}{\lambda}\right) \frac{1}{2} \operatorname{erfc}\left(\frac{x + \varepsilon t}{\sqrt{4\lambda t}}\right) \quad (24)$$

The program is run and error norm L_∞ at times 3000 and 6000 is documented for time/space combinations in Table 3.

Numerical solutions at times $t = 3000$ and $t = 6000$ and their absolute errors are given in Figs. 3a-b-c, from which the maximum errors at times $t = 3000$ and 6000 happens at about positions $30m$ and $60m$ respectively.

Δt	h	$L_\infty(= 3000)$	$L_\infty(= 6000)$
60	1	0.035207	0.024590
30		0.010528	0.00718
10		0.005212	0.003489
5		0.008159	0.00568
60	0.5	0.0336759	0.023552
30		0.0094947	0.006512
10		0.005397	0.003696
5		0.008398	0.005906




Figure 3.a. Solutions




Figure 3. b. errors at time t = 3000




Figure 3. c. errors at time 6000

An effective algorithm has been suggested for getting numerical solution of the ADE. Error for the diffusion dominant form of the ADE is obtained to be smaller than the pure advection form of it numerically as expected, seen the results of the example test problems 2 and 3. The quartic B-spline based least square method can be used as alternative numerical method for solving advection-diffusion systems fairly.

Ethical Considerations Compliance with ethical guidelines

The study does not require ethical permission.

Funding No public or private support.

Conflict of interest There is no conflict of interest.

REFERENCES

- [1] Kirli, E. 2023. Quintic Trigonometric B-spline Algorithm for Numerical Solution of the Modified Regularized Long Wave Equation. ESTUDAM Bilişim Derg, 4(2), 10-15.
- [2] Dag,I., Canıvar, A., Şahin, A. 2011. Taylor-Galerkin method for advection-diffusion equation. Kybernetes, 40, 762-777.

- [3] Mittal, R. C., Jain, R. K., 2012. Redefined cubic B-spline collocation method for solving convection diffusion equations. *Appl. Math. Model.* 36, 5555–5573.
- [4] Mittal, R.C., Rohila, R. 2020. The numerical study of advection–diffusion equations by the fourth-order cubic B-spline collocation method. *Mathematical Sciences* 14, 409–423.
- [5] Korkmaz, I., Dag, A. 2012. Cubic B-spline differential quadrature methods for the advection-diffusion equation. *International Journal of Numerical Methods for Heat and Fluid Flow.* 22(8), 1021-1036.
- [6] Irk, D., Dag, I., Tombul, M. 2015. Extended Cubic B-Spline Solution of the Advection-Diffusion Equation. *KSCE J. Civ. Eng.*, 19, 929-934.
- [7] Korkmaz, A., Dag, I. 2016. Quartic and quintic B-spline methods for advection diffusion equation. *Appl. Math. Comput.*, 274, 208-219.
- [8] Görgülü, M. Z., Dağ, İ., Doğan, S., Irk, D. 2018. A numerical solution of the Advection-Diffusion Equation by using extended cubic B-spline functions. *Anadolu Univ. J. of Sci. and Technology A -Appl. Sci. and Eng.* 2 (19), 347-355.
- [9] Görgülü, M. Z., Irk, D. 2019. The Galerkin Finite Element Method for advection diffusion equation. *Sigma Journal of Engineering and Natural Science* 37(1), 119-128.
- [10] Yousaf, A., Abdeljawad, T., Yaseen, M., Abbas, M. 2020. Novel Cubic Trigonometric B-Spline Approach Based on the Hermite Formula for Solving the Convection-Diffusion Equation. *Mathematical Problems in Engineering*, Article ID 8908964, 17 pages.
- [11] Nguyen, H., Reynen, J. 1984. A spacetime least-squares finite elements scheme for advection-diffusion equation. *Comput. Methods Appl. Mech. Eng.* 42, 331-442.
- [12] Kadalbajoo M. K., Arora, P. 2010. Space–time Galerkin least-squares method for the one–dimensional Advection–Diffusion Equation. *International Journal of Computer Mathematics* 87(1), 103-118. Shin-Jye, L. 1997. p-Version space-time least-squares finite-element method for unsteady Convection-Diffusion and Burgers’ Equations. *IEEE*, 1, 277-282.
- [13] Dhawan, S., Bhowmik, S., Kumar, K. S. 2015. Galerkin-least square B-spline approach toward advection diffusion equation. *Applied Mathematics and Computation*, 261, 128-140.
- [14] Dag, I., Irk, D., Tombul, M. 2006. Least-squares finite element method for the Advection Diffusion Equation. *Appl. Math. Comput.*, 173, 554-565, 2006.
- [15] Shin-Jye, L. 1997. p-Version space-time least-squares finite-element method for unsteady Convection-Diffusion and Burgers’ Equations. *IEEE*, 1, 277-282.
- [16] Dhawan, S., Kapoor, S., Kumar, S. 2012. Numerical method for Advection Diffusion Equation using FEM and B-splines. *Journal of Computational Science* 3, 429-437.
- [17] Dag, I., Ay B., Saka B. 2022. Cubic B-spline least squares method for the numerical solution of advection-diffusion. *J. Appl. Comp. Sci. equation*, 1(1), 53-58.
- [18] Kirli, E. 2023. Nonic B-spline Approach for Advection-Diffusion Equation. *Eskişehir Technical Univ. J. of Sci. and Tech. A-Appl. Sci. and Eng.* 24(2), 155-163.

(Araştırma Makalesi)

Derin Öğrenme ile *Aspergillus* Mantar Türlerinin SınıflandırılmasıSimara SAFARLI¹, Uğur GÜREL², Yasemin ÖZ³¹Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0003-3447-9593>²Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0001-9088-1515>³Eskişehir Osmangazi Üniversitesi, Tıp Fakültesi, Temel Tıp Bilimleri Bölümü, 26040, Eskişehir, ORCID No : <http://orcid.org/0000-0003-2243-7644>**Anahtar Kelimeler:**Aspergillus,
Sınıflandırma,
Derin Öğrenme,
Evrişimsel Sinir Ağı

Özet: Küf mantarları doğada yaygın olarak bulunan ve genellikle saprofit, mantarlardır. Küf mantarları, özellikle bağışıklığı yetersiz olan hastalarda fırsatçı invaziv enfeksiyonlara neden olarak ölüm oranlarının artmasına neden olabilirler. Küf mantarlarının neden olduğu fırsatçı enfeksiyonların en yaygın etkenleri *Aspergillus* türleri, sıklıkla da *A. fumigatus* ve takiben *A. flavus*'tur. Çalışmamızda, Derin Öğrenme algoritmalarından biri olan Evrişimsel Sinir Ağı (ESA) modeli oluşturulmuş ve küf mantarlarından *A. flavus* ve *A. fumigatus* türlerinin mikroskopik görüntüleri kullanılarak tür tayini yapılmıştır. Çalışmada, her bir tür için 525 adet olmakla, toplamda 1050 görüntüden oluşan veri seti kullanılmıştır. Bu görüntüler gri tona dönüştürülerek üzerinde çalışma yapılmıştır. Çalışmamızda, deneyler 73 kez tekrar edilerek sınıflandırma sonucu %97.62 oranında eğitim doğruluğu ve %91.90 test doğruluğu olarak elde edilmiştir.

(Research Article)

Classification of *Aspergillus* Fungi Species with Deep Learning**Keywords:**Aspergillus,
Classification,
Deep Learning,
Convolutional Neural Network

Abstract: The mold fungi are commonly found in nature and are usually saprophyte fungi. Mold fungi can lead to an increase in mortality rates by causing opportunistic invasive infections, especially in immunocompromised patients. The most common causes of opportunistic infections caused by mold fungi are species of *Aspergillus*, frequently *A. fumigatus*, and subsequently *A. flavus*. In our study, the Convolutional Neural Network (CNN) model, which is one of the Deep Learning algorithms, was created and species determination was made using microscopic images of the mold fungi *A. flavus* and *A. fumigatus* species. In the study, a dataset consisting of a total of 1050 images, with 525 images for each species, was used. These images were converted to grayscale and worked on. In our study, experiments were repeated 73 times, resulting in a training accuracy of 97.62% and a test accuracy of 91.90% in classification.

1. GİRİŞ

Aspergillus türleri doğada yaygın olarak bulunan küf mantarlarıdır. Doğal habitatları gübre yığınları veya çürüyen gıdaların bulunduğu organik materyalden zengin ortamlardır. Bununla birlikte, insanlarda basit yüzeysel enfeksiyonların yanı sıra, özellikle bağışıklık defekti olan hastalarda ciddi fırsatçı enfeksiyonlara neden olabilirler [1]. Küf mantarlarının neden olduğu fırsatçı enfeksiyonların en sık etkenleri *Aspergillus* türleridir.

Enfeksiyon çevresel kaynaklardan, sıklıkla solunum yoluyla bulaşır ve tüm *Aspergillus* enfeksiyonlarının en sık etkeni *A. fumigatus*'tur. *A. flavus*, genellikle ikinci sırada yer almakla birlikte, *Aspergillus* nedenli yumuşak doku enfeksiyonlarından daha sıklıkla izole edilen türdür [2]. Ayrıca *A. flavus*'un kontamine ettiği gıdalarda sekonder metabolit olarak aflatoksin ürettiği ve aflatoksinin potent bir karsinojenik madde (karaciğer kanserine neden olur) olduğu bilinmektedir [3]. Farklı *Aspergillus* türlerinin antifungal duyarlılık özellikleri ve dolayısıyla tedavileri farklılık gösterdiğinden, etkenin tür

düzeyinde tanımlanması büyük önem taşımaktadır. Ancak küf mantarlarında tanımlama büyük oranda mantarın mikroskopik ve makroskopik morfolojik özelliklerinin değerlendirilmesine dayandığından, değerlendiricinin bilgi ve tecrübesi son derece önemlidir ve genellikle tanımlama, birçok merkezde genus düzeyinde sınırlı kalmaktadır. Bu nedenle, küf mantarlarının doğru ve güvenilir tanımlamasını yapabilecek sistemlerin geliştirilmesine yönelik çalışmalar ilgi çekmektedir.

Bu çalışmada, insan sağlığı için oldukça tehlikeli olan *Aspergillus* türlerinden *A.flavus* ve *A.fumigatus* mantarlarının tanımlanabilmesi için derin öğrenme algoritmalarından biri olan Evrişimsel Sinir Ağı (ESA) modeli oluşturularak tür tayini yapılmıştır.

Literatüre baktığımızda birçok farklı çalışmanın olduğunu görmekteyiz. Billones ve arkadaşları, 9 çeşit *Aspergillus* mantar türünün mikroskopik görüntüleri üzerinden ESA ile tanımlanmasını ve sınıflandırmasını yapmışlardır. Çalışmada iki aşamalı bir yöntem izlenmiştir. İkinci aşama sınıflandırma iyileştirme amaçlı yapılmıştır. Çalışmada 4545 görüntüden, 3600 eğitim, 900 doğrulama ve 45'i test için kullanılmak üzere ayrılmıştır. Çalışmada ilk aşamada sınıflandırma sonucu: Accuracy %87.50, Loss 0.4107, Val Accuracy %95.65, Val Loss 0.1211 olarak elde edilmiştir. İkinci aşamada ise iyileştirme yapılarak elde edilen sonuçlar: Accuracy %94.20, Loss 0.1459, Val Accuracy %94.31, Val Loss 0.1459 olmuştur [4].

Diğer bir çalışmada, Fan ve arkadaşları, mikroskopik mantar görüntüleri ve göğüs kanseri histolojisi veri setleri kullanarak ince taneli nesne tanımlanmasını ve sınıflandırılmasını yapmışlardır. Makalede kullanılan görüntüler Peking Union Hospital ile işbirliği ile elde edilmiştir. Beş *Aspergillus* türünün (*A.flavus*, *A.fumigatus*, *A.niger*, *A.nidulans* ve *A.terreus*) her birine ait 400 görüntüden oluşan 2000 klinik görüntü toplanmıştır. Mantar görüntülerinin sınıflandırılması sonucu diğer ince taneli nesne sınıflandırma algoritmaları ile karşılaştırılarda 0.943 doğruluk oranı göstererek en iyi sonuç elde edilmiştir. Göğüs kanseri histolojisi görüntülerinin sınıflandırılması, aynı veri seti ile yapılan 5 yöntemden 0.960 doğruluk oranı göstererek daha iyi sonucu göstermiştir [5].

Polap ve arkadaşları, mikroskopik görüntü tanımlanması üzerine çalışma yapmışlardır. Bu çalışmada, karışık bakteri görüntüleri içeren orjinal bir veri seti kullanılmıştır. Her bir görselde ise 4213 bakteri bulunmaktadır. Çalışmada, diğer mimariler ile karşılaştırılarda encoder-decoder mimarisinin çok iyi sonuçlar verdiği ve girdi görüntülerinde en az %2 ila %20 daha fazla tanınan bakteri sayısını elde ettiği sonucuna varılmıştır. Önerilen mimari ile %92 oranında doğruluk elde edilmiştir [6].

Mital ve arkadaşları çalışmalarında, 9 çeşit *Aspergillus* mantar türünün önceden eğitilmiş ESA ile sınıflandırılmasını yapmışlardır. Kullanılan veri seti toplamda 1152 görselden oluşmaktadır, bu görsellerden 785'i eğitim, 337'si ise doğrulama için kullanılmıştır.

Görüntülerin Image Batch Processor uygulaması ile yeniden boyutlandırılması yapılmıştır. %93.3333 oranında bir test doğruluk oranı elde edilmiştir. Önceden eğitilmiş modellerden MobileNetV2, DenseNet201 ve ResNet101 modelleri güvenilir bir değer elde etmiştir. Bu 3 model arasından MobileNetV2 en küçük boyuta ve eğitim süresine sahip olmuştur. MobileNetV2, 3 demeye aşamasından birinci denemede %100, ikinci denemede %94.96 ve üçüncü denemede %96.44 doğruluk oranı göstermiştir [7].

Gaikwad ve arkadaşları çalışmalarında, ESA kullanarak elma yapraklarında hastalığa neden olan mantarların tanımlanması ve sınıflandırmasını yapmışlardır. Çalışma için kullanılan veri seti (plant pathology dataset) elma kabuğu, elma pası, elma kara çürüğü ve sağlıklı yaprak olmak üzere 4 sınıftan ve toplamda 9164 görüntüden oluşmaktadır. Görüntülerin %60'ı eğitim, %40'ı ise test seti için kullanılmıştır. Sınıf bazında tanıma doğruluğu olarak elma kabuğu-%86.6, elma çürüğü-%86.8, elma pası-%47.6 ve sağlıklı yaprak-%95.7 doğruluk oranları vermiştir. Sınıflandırma sonucunda %88.9 oranında doğruluk elde edilmiştir [8].

Bir diğer çalışmada Gaikwad ve arkadaşları, mango ve şeker elması meyvelerinin yapraklarında bulunan *Colletotrichum gloeosporioides* ve *Cylindrocladium colhounii* mantarının görüntülerinin ESA ile tanımlanmasını yapmışlardır. Çalışmada derin öğrenme modellerinden AlexNet ve SqueezeNet kullanılmıştır. Görüntülerden %80'i eğitim, %20'i ise doğrulama için kullanılmıştır. Sonuç olarak AlexNet modeli daha yüksek doğruluk oranı göstermiştir. AlexNet modeli %93.8, SqueezeNet modeli %87.5 doğruluk oranı göstermiştir [9].

Çalık çalışmasında, gömülü sistemler üzerinde ESA modeli ile nesne sınıflandırması yapmıştır. Çalışmada, Cifar-10 isimli veri seti kullanılmıştır. Veri setindeki toplam 60000 görselden 50000'i eğitim ve doğrulama, 10000 tanesi ise test aşaması için kullanılmıştır. Çalışmanın amacı, daha az zaman ve daha az miktarda hafıza kullanılarak yapılması olmuştur. Ve ESA mimarisi ile problem hızlı ve daha az hafıza kullanarak başarılı şekilde çözülmüştür. Nesne görüntüleri birbirlerine benzemediği için ESA mimarisi nesnelere rahatlıkla ayırmıştır. Sonuç olarak çalışmada, 3GB hafıza kullanılarak %85.9 doğruluk oranı elde edilmiştir [10].

Hao ve arkadaşlarının çalışmasında, ESA ve morfolojik yöntemle mikroskopik *Leucorrhea* görüntülerinde mantarların sınıflandırılması yapılmıştır. Görüntüler, bir pozitif yani mantar içeren ve bir negatif yani mantar içermeyen olarak iki sınıfa ayrılmıştır. Veri setinin %90'ı eğitim ve %10'u test seti olarak kullanılmıştır. Sınıflandırma için ESA yapısı olan LeNet5 uygulanmıştır. Daha sonra ise bir morfolojik yöntem uygulanmıştır. Sınıflandırma sonucu olarak %93.26 doğruluk oranı elde edilmiştir [11].

Wang ve arkadaşları yaptıkları araştırmada, göğüs kanseri mikroskopik görüntülerinin ESA ile sınıflandırılmasını yapmışlardır. Çalışmada, ICIAR2018 veri seti

kullanılmıştır. Veri setinde, her biri 4 sınıfa ayrılmış, toplamda 400 görüntü kullanılmıştır. Sınıflar, normal doku, iyi huylu lezyon, in situ karsinom ve invaziv karsinom olarak ayrılmıştır. Bu görüntülerin 320'si eğitim, 80'i ise doğrulama için ayrılmıştır. Sınıflandırma için VGG modeli kullanılmıştır. Sınıflandırma sonucu doğrulama setinde %92.5, test setinde %91.7 doğruluk oranları elde etmiştir. ESA+DVM sonucu doğrulama setinde %81.25, test setinde %80.6 doğruluk oranları elde edilmiştir [12].

Karakurt ve İşeri, insan hayatı için büyük ölçüde önemli olan meme kanseri olan ve olmayan görüntülerin ESA model kullanarak sınıflandırılmasını yapmışlardır. Çalışmada, 60000 görüntüden 40000'i eğitim, 20000'i test verisi için kullanılmıştır. En iyi sonuç 0.8775 doğruluk oranı, 0.8238 F1 skoru olarak elde edilmiştir [13].

Tahir ve arkadaşları, 5 çeşit mantar sporları görüntülerinin tanımlanmasını yapmışlardır. Kullanılan veri seti 40800 görüntüden oluşmuştur. Bu görüntülerde, eğitim seti için 30000, test seti için 10800 görüntü olarak ayrılmıştır. ESA mimarisi ile sınıflandırma sonucu %94.8 oranında doğruluk elde edilmiştir [14].

Wahid ve arkadaşları, 7 çeşit bakteri türü görüntülerinin derin ESA ile sınıflandırmasını yapmışlardır. Veri seti, her bakteriye ait 160 görüntü olmakla toplamda 1150 görüntüden oluşmuştur. ESA mimarisinin Xception modeli ile sınıflandırma sonucu %95.5 oranında doğruluk elde edilmiştir [15].

Oktaria ve arkadaşları çalışmalarında, mikroskopik ahşap görüntülerinin türlerine göre ESA ile sınıflandırmasını yapmışlardır. ESA mimarisi olarak AlexNet, ResNet ve GoogLeNet kullanılmıştır. Sınıflandırma sonucu AlexNet mimarisi %96.4 doğruluk oranı ile en iyi sonucu vermiştir [16].

2. MATERYAL VE METOT


Bu çalışmada *A.flavus* ve *A.fumigatus* küf mantarlarının mikroskopik görüntülerinin sınıflandırılması yapılmıştır. Bu inceleme için derin öğrenme mimarilerinden biri olan ESA model oluşturuldu ve bu model kullanılarak mikroskopik mantar türleri sınıflandırılmıştır.

Literatüre bakıldığında genellikle ESA model ile yapılmış çalışmalar renkli görüntüler üzerinde olduğu görülmüştür. Bu çalışmada deneyler ilk önce renkli görüntüler ile yapılmıştır. Ancak bu renkli görüntülerin deneyimlenmiş bilgi ekleyerek sonuçları olumlu yönde etkilediği görülmüştür. Dolayısı ile bu etkinin ortadan kaldırılması için görüntüler gri tonlara dönüştürülerek deneyler tekrar edilmiştir.


2.1. Veri seti

Çalışmada kullanılan veri seti Eskişehir Osmangazi Üniversitesi Tıp Fakültesi Öğretim Üyesi Prof.Dr.

YASEMİN ÖZ tarafından hazırlanmıştır. Veri setinde ayrı ayrı *A.flavus* türüne ait 525 adet görüntü ve *A.fumigatus* türüne ait 525 adet görüntü olmakla toplamda 1050 görüntü vardır. Girdi verilerinin boyutu bellek hacmini, eğitim süresini ve başarı yüzdesini etkilemektedir. Veri boyutları yüksek verildiği zaman eğitim süresi uzun ve kullanılan bellek yüksek olduğu görülmüştür ama bu durum başarı yüzdesinin yükselmesine de sebep olur. Veri boyutu düşük verildiği zaman ise tam tersine eğitim süresi kısa ve kullanılan bellek az olur. Ancak bu durum başarı yüzdesini de etkilediği için ağırlık derinliği azalır ve performans düşük olabilmektedir [17]. Buna esasen bu çalışmada görüntü boyutları uygun bir giriş boyutları olarak 500x500 piksel ayarlanmıştır. Görüntülerin %80'i eğitim, %20'si test için kullanılmıştır. Şekil 1, *A.flavus* ve Şekil 2, *A.fumigatus* küflerinin her birine dair bir görsel gösterilmiştir.




Şekil 1. *Aspergillus flavus*



Şekil 2. *Aspergillus fumigatus*

2.2. Derin öğrenme


Derin öğrenme, yapay sinir ağları kullanarak insan beyninin çalışma prensiplerine benzer şekilde öğrenme yapabilen bir algoritmadır. Bu algoritma, bir yapıdaki verileri insanlar gibi analiz etme yeteneği sağlayarak, makinelerle karmaşık problemleri çözme ve verileri anlama becerisi kazandırır [18]. Derin öğrenme, çok katmanlı yapay sinir ağlarından oluşmaktadır [19]. Bu katmanlar arasında gizli katmanlar bulunur ve verilerin öğrenilmesi için bu katmanlar kullanılır. Derin öğrenme algoritmaları, farklı veri türleri üzerinde tahminleme, sınıflandırma ve analiz gibi birçok görevde kullanılmaktadır. Örneğin, görüntülerin nesne tespiti, metinlerin duygu analizi, seslerin konuşma tanıma gibi alanlarda derin öğrenme algoritmaları kullanılmaktadır. Bu algoritmalar, veri içerisindeki karmaşıklığı anlamak ve desenleri keşfetmek için çok sayıda parametreyi optimize eder. Şekil 3'te genel bir derin öğrenme mimarisi gösterilmektedir.



Şekil 3. Genel Derin Öğrenme mimarisi [20]


2.3. Evrişimsel sinir ağı

Evrişimsel Sinir Ağı, görsel tanımlama üzerine bir derin öğrenme algoritmasıdır. ESA modeli, modern makine öğrenmesi uygulamalarında çok yaygın kullanılıyor. Geleneksel ESA modeli, giriş katmanı, evrişim (konvolüsyon) katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıktı katmanlarından oluşmaktadır [21]. Şekil 4'te genel ESA mimarisi gösterilmektedir.



Şekil 4. Genel ESA mimarisi [22]

Girdi katmanı, video, ses ve görüntü verileri olabilir. Verilerin türüne göre sinir ağlarının işlemleri de değişir. Girdi katmanına yüklenen veri görüntü olduğu zaman, renk analizi veya obje kenarlarının bulunması işlemleri gibi işlemler gerçekleştirilir. Bir sinir ağında katmanlar arasında bulunan nöron bağlantılarının sayısal değerleri yani ağırlıkları vardır [23]. Bu ağırlıklar eğitim zamanı çıktı değeri için nöronların önemini göstermektedir. Katmanlar arasında elde edilen çıkış değeri, ağırlıkları ile çarpılarak sonraki katmanın girdi değerini oluşturmaktadır. Girdi katmanından başlayarak çıktı katmanına kadar giden ileri yönlü akış, ileri yayılım algoritması adlanır. İleri yayılım algoritması ile elde edilen sonuçlar sinir ağlarının tahmin değerleridir [24]. Şekil 5'te, bu çalışmada kullanılan ESA mimarisini gösterilmiştir.



Şekil 5. Kullanılan ESA mimarisi

2.4. Evrişim katmanı

Evrişim katmanı ESA'nın temel yapı bileşenlerinden biridir. Görüntü verileri, piksellerden oluşan matrislerdir. Bu katman, görüntüler üzerindeki belirli özellikleri öğrenmektedir [25]. Evrişim katmanı görüntüden özellik

çıkarmak için filtreler uygular. Ve bu filtreler çok boyutludur. Uygulanan filtreler 2x2, 3x3, 5x5 boyutlarda olabilir [17]. Aynı zamanda evrişim katmanı, dönüşüm katmanı olarak da adlandırılmaktadır. Yani, filtrelerin görseller üzerinde dolaştırılarak yeni matris oluşturmasıdır [22].

2.5. Havuzlama katmanı

Havuzlama katmanı, evrişimli katmanlar arasında yerleşir. Bu katman, sonraki katmanlardaki iş yükünü azaltıyor. Yani, görsel verisi çok fazla büyük olduğunda parametre sayısını azaltarak görseli küçültmektedir. Sonuçta bir bilgi kaybı oluşuyor ve bununla da hesaplama maliyeti azalmaktadır [25]. Lakin bu işlem derinlik boyutuna etki etmez [17].

2.6. Değerlendirme metrikleri

Değerlendirme metrikleri, bir modelin performansını ölçmek için kullanılmaktadır. Sınıflandırma problemleri için kullanılan değerlendirme metriklerine doğruluk (accuracy), kesinlik (precision), geri çağırma (recall) ve F1 skoru dahildir [26].

Doğruluk değeri, sınıflandırma modelinin doğru tahminlerinin toplam örnek sayısına oranını göstermektedir. Doğruluk değerinin formülü denklem 1'de verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Burada, TP (True Positive) doğru tahmin edilen pozitiflerin, TN (True Negative) doğru tahmin edilen negatiflerin, FP (False Positive) yanlış tahmin edilen pozitiflerin, FN (False Negative) ise yanlış tahmin edilen negatiflerin sayılarını göstermektedir.

Kesinlik değeri, modelin doğru pozitif sonuçlarının toplam pozitif tahminlere oranını ölçmektedir. Yani tüm örnekler içerisindeki doğru tahmin edilen örneklerin yüzdesini göstermektedir. Denklem 2'de kesinlik değerinin formülü verilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (2)$$

Geri çağırma değeri, modelin pozitif örneklerinin doğru sınıflandırma sonucunu ölçmektedir. Geri çağırma değerinin formülü denklem 3'te verilmiştir.


$$\text{Geri çağırma} = \frac{TP}{TP + FN} \quad (3)$$

F1 skor değeri, kesinlik ve geri çağırma değerlerinin harmonik ortalamasını ölçmektedir. F1 skor değerinin formülü denklem 4'te verilmiştir [27].


$$\text{F1 skor} = \frac{2 * \text{Kesinlik} * \text{Geri çağırma}}{\text{Kesinlik} + \text{Geri çağırma}} \quad (4)$$

3. BULGULAR

Bu çalışmadaki ESA model giriş katmanı, üç adet Evrişim2D, üç adet MaxHavuzlama, iki adet Yoğun ve dört adet Bırakma katmanlarından oluşmaktadır. Optimizasyon algoritması olarak RMSprop algoritması kullanılmıştır. Optimizasyon algoritması görüntü sınıflandırma modellerinin performansını yükseltmek için kullanılmaktadır. Bu algoritmanın öğrenme oranı hiperparametresi 0.001 olarak belirlenmiştir. Öğrenme oranı, ağırlık güncellemelerindeki adımların büyüklüğünü kontrol etmektedir. Yığın boyutu (batch_size) olarak 12 rakamı belirlenmiştir. Yığın boyutu, eğitim veri setinde modelin bir seferde işleyeceği örnek sayısını belirlemektedir. Görüntü boyutları, 500x500 piksel olarak girilmiştir. Modelin eğitiminin doğru ve tam olması açısından erken durdurma kullanılmıştır. Erken durdurma, model tam olarak eğitildiğinde girilen dönem sayısını tamamlamadan otomatik olarak modeli durdurur. Dönem sayısı, veri setinin işlenerek ağırlıklarının güncellenmesidir [24]. Çalışmada bu özellik sayesinde, toplamda 1000 dönem içerisinde, bine kadar gitmeden modelin eğitimi 71'ci dönemde, %97.62 eğitim doğruluğu olarak tamamlanmıştır. Eğitilmemiş verilerin F1 skor değeri %86.23 olarak elde edilmiştir.

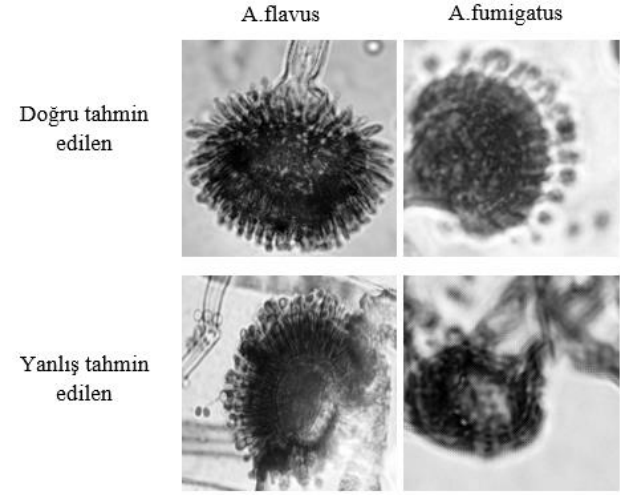


Şekil 6. Eğitim ve Doğrulama verilerinin kayıp oranları



Şekil 7. Eğitim ve Doğrulama verilerinin doğruluk oranları

Şekil 6, eğitilen modelde eğitim verilerinin kayıp oranının 0.0822 olduğunu göstermektedir. Şekil 7 ise en yüksek doğruluk oranının %97.62 olduğunu göstermektedir. Sonuçlara esasen eğitilmemiş verilerin F1 skor değeri, %86.23 olarak elde edilmiştir. Şekil 8'de doğru ve yanlış tahmin edilen görüntülere ait birer örnek verilmiştir.



Şekil 8. Doğru ve yanlış tahmin edilen görüntü örnekleri

Tablo 1'de önceden eğitilmemiş ESA modeller ile yapılan çalışmaların bu çalışma ile karşılaştırılması verilmiştir.

Tablo 1. Önceden eğitilmemiş ESA modeller ile yapılan çalışmaların karşılaştırılması

Yazar	Veri Seti	Yöntem	Tanıma Oranı
Simara Safarlı, Uğur Gürel, Yasemin Öz	A.flavus, A.fumigatus	ESA model	%97.62
Robert Kerwin Billones vd.	9 çeşit Aspergillus	ESA model	%94.20
Muhammad Waseem Tahir vd.	5 çeşit mantar sporu	ESA model	%94.8
Mengran Fan vd.	Mikroskopik Mantar ve Göğüs kanseri Histoloji görüntüleri	ESA model	%94.3
Sukanya S Gikwad vd.	Pant Pathology	ESA model	%88.9
Meral Karakurt ve İsmail İşeri	Meme Pataloji Görüntüleri	ESA model	%87.75
Caner Çalık	Cifar-10	ESA model	%85.9

4. TARTIŞMA VE SONUÇ

Literatüre bakıldığında evrişimsel sinir ağları oldukça yaygın olarak kullanılmaktadır. Bu algoritma, tanımlama ve sınıflandırma problemleri üzerine gelişmiş bir algoritmadır. Evrişimsel sinir ağları ile yapılan çalışmalar içerisinde özellikle tıp alanında olan çalışmalar önde gelmektedir.

Çalışmamızda, evrişimsel sinir ağları model ile *A.flavus* ve *A.fumigatus* mikroskopik mantar türlerinin sınıflandırılması başarılı bir şekilde yapılmıştır. Çalışmada, en iyi sonuca varmak için denemeler zamanı eğitim ve test veri seti karıştırılarak tekrar bölünmüştür. Eğitimler sonucunda, doğruluk oranının düşük olmasına esasen ve kayıp değerleri azaltmak için optimize edici değiştirilerek RMSprop optimizasyon algoritması kullanılmıştır. Sonuç olarak yapılan denemeler içerisinde en yüksek sonuç %97.62 oranında eğitim doğruluğu ve %91.90 oranında test doğruluğu olarak elde edilmiştir. Tablo 1'deki karşılaştırmaya esasen, önceden eğitilmemiş evrişimsel sinir ağı model ile yapılan çalışmalar arasındaki en iyi sonucu bu çalışma göstermiştir.

Etik Hususlar

Etik kurallara uyum

Bu çalışma, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun olarak yürütülmüştür.

Finansman

Bu çalışma, kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe alınmamıştır.

Çıkar çatışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- [1] Ayberkin, E., Çiftçi, E. 2009. Çocuklarda Aspergillus Enfeksiyonları. J Pediatr Inf, 3, 118-25.
- [2] Kilich, M. A. 2007. Aspergillus flavus: the major producer of aflatoxin. Molecular plant pathology, 8(6), 713-722. DOI:10.1111/j.1364-3703.2007.00436.x
- [3] Gourama, H., Bullerman, L. B. 1995. Aspergillus flavus and Aspergillus parasiticus: Aflatoxigenic fungi of concern in foods and feeds: A review. Journal of Food protection, 58(12),1395-1404. DOI:10.4315/0362-028X-58.12.1395
- [4] Billones, R. K. C., Calilung, E. J., Dadios, E. P., Santiago, N. 2020. Aspergillus Species Fungi Identification Using Microscopic Scale Images. In 2020 IEEE 12th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment, and Management (HNICEM), 3-7 December, Manila, Philippines, 1-5.
- [5] Fan, M., Chakraborti, T., Eric, I., Chang, C., Xu, Y., Rittscher, J. 2020. Fine-Grained Multi-Instance Classification in Microscopy through Deep Attention. In 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI), 3-7 April, Iowa City, IA, USA, 169-173.
- [6] Polap, D., Wozniak, M., Korytkowski, M., Scherer, R. 2020. Encoder-Decoder Based CNN Structure for Microscopic Image Identification. In International Conference on Neural Information Processing, 23-27 November, 301-312.
- [7] Mital, M. E., Tobias, R. R., Villaruel, H., Maningo, J. M., Billones, R. K., Vicerra, R. R., Dadios, E. 2020. Transfer Learning Approach for the Classification of Conidial Fungi (genus aspergillus) Thru Pre-Trained Deep Learning Models. In 2020 IEEE Region 10 Conference (TENCON), 16-19 November, Osaka, Japan, 1069-1074.
- [8] Gaikwad, S. S., Rumma, S. S., Hangarge, M. 2021. Fungi classification using convolution neural network. Turkish Journal of Computer and Mathematics Education (TURCOMAT), 12(10), 4563-4569. DOI:10.17762/turcomat.v12i10.5200
- [9] Gaikwad, S. S., Bhalerao, S., Rumma, S. S., Hangarge, M. 2021. Classification of Microscopic Images of Fungi Using Deep Learning Models. SAMRIDDHI: A Journal of Physical Sciences, Engineering and Technology, 13(SUP 2), 105-110.
- [10] Çalık, R. C. 2018. Gömülü Sistem Üzerinde Evrişimsel Sinir Ağları ile Nesne Sınıflandırması. TOBB ETÜ, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 78s, Ankara.
- [11] Hao, R., Wang, X., Zhang, J., Liu, J., Du, X., Liu, L. 2019. Automatic detection of fungi in microscopic leucorrhea images based on convolutional neural network and morphological method. In 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 15-17 March, Chengdu, China, 2491-2494.
- [12] Wang, Y., Sun, L., Ma, K., Fang, J. 2018. Breast cancer microscope image classification based on CNN with image deformation. In Image Analysis and Recognition: 15th International Conference, 27-29 June, Povo de Varzim, Portugal, 845-852.
- [13] Karakurt, M., & İşeri, İ. 2022. Patoloji Görüntülerinin Derin Öğrenme Yöntemleri İle Sınıflandırılması. Avrupa Bilim ve Teknoloji Dergisi, (33), 192-206. DOI:10.31590/ejosat.1011091
- [14] Tahir, M. W., Zaidi, N. A., Rao, A. A., Blank, R., Vellekoop, M. J., & Lang, W. 2018. A fungus spores dataset and a convolutional neural network based approach for fungus detection. IEEE transactions on nanobioscience, 17(3), 281-290.
- [15] Wahid, M. F., Hasan, M. J., & Alom, M. S. (2019, September). Deep Convolutional Neural Network for Microscopic Bacteria Image Classification. In 2019 5th International Conference on Advances in Electrical Engineering (ICAEE), 26-28 September, Dhaka, Bangladesh, 866-869.

- [16] Oktaria, A. S., Prakasa, E., & Suhartono, E. 2019. Wood Species Identification Using Convolutional Neural Network (CNN) Architectures on Macroscopic Images. *Journal of Information Technology and Computer Science*, 4(3), 274-283.
- [17] İnik, Ö., Ülker, E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3), 85-104.
- [18] Günal, A. 2020. Derin Öğrenme Nedir? Nerelerde Kullanılır? <https://www.bilimya.com/derin-ogrenme-nedir-nerelerde-kullanilir.html> (Erişim Tarihi: 08.06.2023).
- [19] Şeker, A., Diri, B., Balık, H. H. 2017. Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- [20] Doğan, Ö. 2020. Derin Öğrenme Nedir? Yapay Sinir Ağları Ne İşe Yarar? <https://teknoloji.org/derin-ogrenme-nedir-yapay-sinir-aglari-ne-ise-yarar/> (Erişim Tarihi: 08.06.2023).
- [21] Hussain, M., Bird, J. J., Faria, D. R. 2019. A study on cnn transfer learning for image classification. In *Advances in Computational Intelligence Systems: Contributions Presented at the 18th UK Workshop on Computational Intelligence*, 5-7 September, Nottingham, UK 191-202.
- [22] Aydın, A. G. A. 2021. Derin Öğrenme. *Bilgisayar Bilimlerinde Teorik Ve Uygulamalı Araştırmalar*, 105s.
- [23] Tüfekçi, M., Karpaz, F. 2019. Derin Öğrenme Mimarilerinden Konvolüsyonel Sinir Ağları (CNN) Üzerinde Görüntü İşleme-Sınıflandırma Kabiliyetinin Arttırılmasına Yönelik Yapılan Çalışmaların İncelenmesi. In *International Conference on Human-Computer Interaction, Optimization and Robotic Applications*, 5-7 July, Ürgüp, Nevşehir, 28-31.
- [24] Kayalı, N. S, Omurca, S. İ. Konvolüsyonel Sinir Ağları (CNN) ile Çin Sayı Örüntülerinin Sınıflandırması. *Computer Science*, (Special), 184-191. DOI:10.53070/bbd.989668
- [25] Li, Q., Cai, W., Wang, X., Zhou, Y., Feng, D. D., Chen, M. 2014. Medical image classification with convolutional neural network. In *2014 13th international conference on control automation robotics & vision (ICARCV)*, 10-12 December, Singapore, 844-848. 989668
- [26] Ay, Ş. 2020. Model Performansını Değerlendirmek – Metrikler. <https://medium.com/deep-learning-turkiye/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-metrikler-cb6568705b1> (Erişim Tarihi: 10.06.2023).
- [27] Abacı, B. 2019. Makine Öğrenmesi Performans Ölçütleri. [https://imlab.io/2019/07/14/machine-](https://imlab.io/2019/07/14/machine-learning-performance-metrics/)

learning-performance-metrics/ (Erişim Tarihi: 10.06.2023).

(Araştırma Makalesi)**Retinal Hastalıkların Teşhisi için Optik Koherans Tomografi Görüntülerinin Derin Öğrenme Metotları ile Sınıflandırılması****Hafiza Esra URMAMEN^{*1}, Sabri KOÇER²**¹Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID No: 0000-0002-4933-1586²Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, ORCID No: 0000-0002-4849-747X**Anahtar Kelimeler:**Optik Koherans Tomografi,
Derin Öğrenme,
Evrişimli Sinir Ağı,
Transfer Öğrenme,
Retina OCT

Özet Retina, görmeyi sağlayan ışığa ve renklere duyarlı ağ tabakasıdır. Retinadaki bozulmalar insanların yaşam kalitesini düşürmektedir. Retinada meydana gelen hasarlar körlüğe varan ciddi sorunlara sebep olabilmekte ve retinada kalıcı hasarlar meydana gelebilmektedir. Retinal hastalıkların tedavisinde gelişen teknoloji ile birlikte bilgisayarlı tanı sistemlerinin kullanımı oldukça yaygınlaşmıştır. Erken teşhis ve tedavi edilmesi retina da oluşabilecek kalıcı hasarları ve hastaların görme yetisini kaybetmesini önlemektedir. Teknolojinin ilerlemesiyle birlikte fotoğraf makineleri ve bilgisayarlı tanı sistemleri oldukça yaygın kullanılmaya başlanmıştır. OCT cihazları kullanılarak elde edilen retinal görüntüler uzmanların daha doğru ve erken teşhis koymalarını sağlamaktadır. Bu çalışmada, retinal hastalıkların sınıflandırılması için transfer öğrenme yöntemlerinden InceptionV3, Xception ve önerilen Evrişimsel Sinir Ağı (ESA) modeli karşılaştırılmıştır. Xception ağında %95.36 oranında doğruluk değerine, Inception ağında ise %98.2 oranında doğruluk oranı elde edilmiştir. Önerilen ESA mimarisinde %97.51 oranında doğruluk oranı elde edilmiştir. Önerilen mimari hastalık bazında diyabet ve normal hastalıkların sınıflandırılmasında diğer yöntemlerden daha başarılı sonuçlar elde etmiştir.

(Research Article)**Classification of Optical Coherence Tomography Images for the Diagnosis of Retinal Diseases using Deep Learning Methods****Keywords:**Optical Coherence Tomography,
Deep Learning,
Convolutional Neural Network,
Transfer Learning,
Retinal OCT

Abstract: The retina is light-sensitive neural layer that enables vision and perception of colors. Distortions in the retina can negatively impact people's quality of life. Such distortions can lead to serious problems, including blindness and permanent damage to the retina. With the advancement of technology in the treatment of retinal diseases, the use of computer-aided diagnosis systems has become increasing common. Early diagnosis and treatment can prevent permanent damage to the retina and help patients retain their vision. As technology has progressed, cameras and computer-aided diagnosis systems have been widely adopted. Retinal images obtained using OCT devices enable experts to make more accurate and early diagnoses. In this study, transfer learning methods, specifically InceptionV3, Xception, and the proposed Convolutional Neural Network(CNN) model, were compared for classifying retinal diseases. The Xception network achieved an accuracy of 95.36%, while the Inception network achieved an accuracy of 98.2%. The proposed CNN architecture achieved an accuracy of 97.51%. The proposed architecture has obtained more successful results in the classification of diabetes and normal diseases based on diseases architecture compared to other methods.

*Sorumlu Yazar/Corresponding Author: heurmamen@ktun.edu.tr

1. GİRİŞ

Retina, göz küresinin arka tabakasında bulunan yaklaşık 0.5 mm genişliğe sahip ışığı algılayan hassas yapıdaki ağ dokudur[1]. Yapısında bulunan foto reseptör hücreleri sayesinde algıladığı bilgileri beyne iletir ve görme eyleminin gerçekleşmesine yardımcı olmaktadır.

Retina hücreleri kendini yenileyemeyen yapıya sahip olması sebebiyle yapısında meydana gelen bozulmalar, değişiklikler kalıcı olabilmektedir. Retinanın yapısında meydana gelen bu değişiklikler ciddi görme kayıplarına neden olabilmektedir. Retina, görme eyleminde önemli rol alması sebebiyle yapısında meydana gelebilecek rahatsızlıklar görme yetisinin kaybedilmesi gibi geri dönüş olmayan, oldukça ciddi sorunlara sebep olabilmektedir. Retinada aniden oluşan perdeli görüntü, görme kayıpları, gözün önünde ışık çakması, eğik veya kırık görüntü gibi ciddi sorunlarla karşılaştığında uzman kişilere başvurusu gerekmektedir.

Uzmanlar tarafından teşhis için kullanılan retinal tomografi görüntüleri elde edildikten sonra alanında uzman ve deneyim sahibi hekimler tarafından teşhis edilmelidir. Ancak zaman ve uzman hekim sayısının yetersiz kalması gibi sorunlar sebebiyle hastalıkların teşhisi zorlaşabilmektedir. Bu sorunun üstesinden gelebilmek için son teknoloji ile birlikte oldukça sık kullanılan bilgisayarlı tanı sistemleri geliştirilerek hekimlerin zamandan ve işgücünden tasarruf etmeleri amaçlanmıştır.

Diyabetik Retinopati(DR), Miyop, Hipertansiyon, Glokom, Yaşa Bağlı Maküler Ödem (YBMÖ), Katarakt ve Drusen gibi retinada oluşabilen birçok göz rahatsızlığı mevcuttur. Retinal hastalıklar birçok sebepten dolayı meydana gelebilmektedir. Kalıtsal ve çevresel birçok neden retinanın zarar görmesine sebep olabilmektedir. Son zamanlarda oldukça sık kullanılan evrişimli sinir ağları (ESA), retinal patolojilerin erken tespit ve tedavisinde kayda değer sonuçlar elde edilmesini sağlamaktadır.

2014 yılında Srinivasan ve ark. yönlendirilmiş gradyan (HOG) ve destek vektör makinesine (SVM) dayalı bir sistem önermişlerdir. Yönlendirilmiş gradyan, Yaşa Bağlı Maküler Dejenerasyon (AMD) ve Diyabetik Maküler Ödem (DME) gibi retinal hastalıkların tespit edilmesi için kullanılmıştır. Açık kaynak olarak sunulan Optik Koherans Tomografi (OCT) veri setinde bulunan görüntüler yetişkin hastaların retinalarından seçilmiş görüntülerden oluşmaktadır. OCT setinde veriler Normal, CNV, Drusen ve DME olmak üzere dört sınıfa ayrılmıştır. DME için %100, AMD için %100 ve normal olarak sınıflandırılmış sağlıklı retina da %86.76 gibi yüksek bir doğruluk oranı elde etmiştir [2].

2016 yılında Gulshan ve ark. tarafından Diyabetik Retinopati ve Diyabetik Maküler Ödem belirlenebilmesi için Inception mimarisi kullanarak önerdikleri modeli EyePACS-1 veri seti ve Messidor-2 veri setleri üzerinde eğitmişlerdir. EyePACS-1 için duyarlılık %90.3 ve özgüllük %98.1 değerleri elde edilmiştir. Messidor-2 veri seti için duyarlılık %87.0 ve özgüllük %98.5 olarak bulunmuştur[3].

2018 yılında Najeeb ve ark. tarafından retinal anormalliklerin otomatik olarak tespit edilebilmesi için Optik Koherans Tomografi (OCT) tarama görüntülerinden oluşturulan içerisinde çeşitli hastalıklardan oluşan 83.484 veri içeren OCT veri setini kullanarak retinal rahatsızlıkların sınıflandırması için tek katmanlı nötr ağ yapısı kullandıkları modeli önermişlerdir. Önerilen model %95.66 oranında doğruluk oranına sahip ve açık kaynak olarak kullanıma sunulmuştur [4].

Sunja ve ark. tarafından Optik Koherans Tomografi görüntülerinin sınıflandırılması için 6 evrişim bloğundan oluşan derin evrişimli sinir ağı önerilmiştir. Modelin eğitim ve doğrulanması için halka açık bulunan OCT veri seti kullanılmıştır. Kullanılan veri seti Diyabetik Maküler Ödem (DME), Drusen, Koroidal NeoVaskülarizasyon (CNV) ciddi retinal patolojileri içermektedir. Önerilen yöntem ile %99.69 doğruluk, %99.69 özgüllük ve %99.69 duyarlılık değerleri elde edilmiştir. Elde edilen sonuçlar ResNet-50 modeline kıyaslandığında öğrenebilir parametrelerin sadece %6.9 unu kullandığını ve sınıflandırma performansında ResNet-50 modelini geride bıraktığı görülmektedir [5].


2023 yılında Lu ve ark. Oftalmologların hastaların tedavilerini geliştirmek için DR ve DME hastalıklarını otomatik olarak derecelendirmek için transfer öğrenmeye dayalı beş katmanlı evrişimli sinir ağı modeli geliştirmişlerdir. Geliştirdikleri beş katmanlı çapraz doğrulama modeli Messidor veri setinin kullanarak DR ve DME hastalıklarında sırasıyla 0.96, 0.97, 0.96 ve 0.96'lük ortalama doğruluk, kesinlik, özgüllük ve F1 skorunu MobileNetV2'den daha iyi sonuçlar elde etmiştir. Bu sonuçlar geliştirdikleri modelin klinik deneylerde retina hastalıklarının teşhisinde umut verici sonuçlar elde ettiği görülmektedir [6].

2. MATERYAL VE METOT

Bu bölümde retinal hastalıkların erken teşhisi ve sınıflandırılması için kullanılan yöntemlerde, retinanın yapısından ve kullanılan ODIR-5K veri setinden bahsedilmiştir. Veri seti üzerinde çeşitli ön işleme teknikleri, ölçeklendirme ve veri çoğaltma işlemleri uygulanmıştır. Elde edilen veriler öncelikle gri filtre sonrasında CLAHE ön işlem aşamasından geçirilmiştir. Veri ön işlemleri ardından önerilen ESA modelinde eğitilmiştir. Elde edilen sonuçlar önceden eğitilmiş transfer öğrenme metotlarından InceptionV3 ve XceptionV3 ağlarının eğitiminden elde edilen sonuçlar ile karşılaştırılmıştır.

2.1. Retinanın Yapısı

Retina, gözün en temel ve hassas yapıya sahip alanıdır. Işık kaynağından gelen ışığı alarak ve bunu beyne iletir ve görme eyleminin gerçekleşmesini sağlayan sinir hücrelerinden oluşan ağ tabakasıdır. Yapısında bulunan konik ve basil hücreler sayesinde keskin ve net görüş sağlamaktadır.



Şekil 2.1. Retinanın Anatomik Yapısı[7].

Retina Şekil 2.1 incelendiğinde temelde fovea, makula, optik disk, retinal damarlar ve retinal atardamarları içeren birçok hassas bölümden oluşmaktadır. Makula, retina tabakasında bulunan yaklaşık 4-5 mm çapındaki yapıdır. Göz yapısında dıştan içe doğru destekleyici (sert) tabaka, vasküler (damar) tabaka ve ağ tabaka olmak üzere birbirini saran üç temel segmentten oluşmaktadır [8]. Renkli ve keskin görmenin merkez bölgesidir. Makula bölgesinin ortasında “fovea” adı verilen “sarı nokta” olarak da bilinen merkezi ve ayrıntılı, keskin görmeden sorumlu bölge bulunmaktadır.

2.2. Veri Seti


Bu çalışmada, retinal hastalıkların tespit edilmesi için ODIR-5K veri seti kullanılmıştır. ODIR-5K halka açık şekilde bulunan veri seti Kaggle web sayfası üzerinden alınmıştır.

Çin ‘de bulunan Shangong Medikal Teknoloji tarafından çeşitli sağlık kuruluşlarından alınan verilerle oluşturulan retinal hastalara ve sağlıklı bireylere ait tomografi görüntülerini içermektedir. Kullanılan veri setinde toplamda 5000 hastadan alınan 6.392 retinal fundus görüntüsü bulunmaktadır[9].

ODIR-5K veri setinde sekiz farklı sınıfa ait patolojik veri içeren tomografi görüntüsü bulunmaktadır. Veri setinde bulunan patolojiler sırasıyla Yaşa Bağlı Maküler Ödem (AMD), Glukom, Miyop, Hipertansiyon, Diyabet, Katarakt, normal ve diğer hastalıklar ve anormallikleri içeren verilerden oluşmaktadır.

ODIR-5K veri setinde bulunan hastalıkların veri dağılımları arasında farklılıklar ve dengesizlikler bulunmaktadır. Veri setinde bulunan sınıfların dağılımları arasındaki dengelenmenin sağlanması için çeşitli veri çoğaltma işlemleri görüntü yaklaştırma, döndürme, parlaklık ayarı, yeniden ölçeklendirme işlemleri uygulanarak veri dengelenme işlemi yapılmıştır. Veri seti dengeleme işleminin ardından gri filtre ve CLAHE (Contrast Limited Adaptive Histogram Equalization) ön işleme uygulaması yapılarak veri ön işleme tamamlanmış ve eğitim için hazır hale getirilmiştir.

Veri setine ait sınıflandırılmış hastalıkların dağılımına ait histogram grafiği Şekil 2.2’de verilmiştir.



Şekil 2.2. ODIR-5K Veri Seti Hastalıkların Dağılımı


Tablo 1. Veri Setinde Bulunan Hastalıkların Sayısal Dağılımı

Hastalıklar	Sayısal dağılımı
AMD	266
Katarakt	293
Diyabet	1608
Glukom	284
Hipertansiyon	128
Normal	2873
Patolojik Miyop	232
Diğer Hastalıklar ve Anormallikler	708

Tablo 1’de ODIR-5K veri setine ait hastalıkların sayısal değerlerinin dağılımına yer verilmektedir. Tablo 2’de veri dengeleme işlemleri sonrasında elde edilen hastalıklara ait sayısal değerlere yer verilmektedir.

Tablo 2. Veri Seti Dengeleme İşlemi Sonrası Sayısal Dağılımı

Hastalıklar	Sayısal dağılımı
AMD	2888
Katarakt	2769
Diyabet	3048
Glukom	2901
Hipertansiyon	2856
Normal	2816
Patolojik Miyop	2928
Diğer Hastalıklar ve Anormallikler	2592

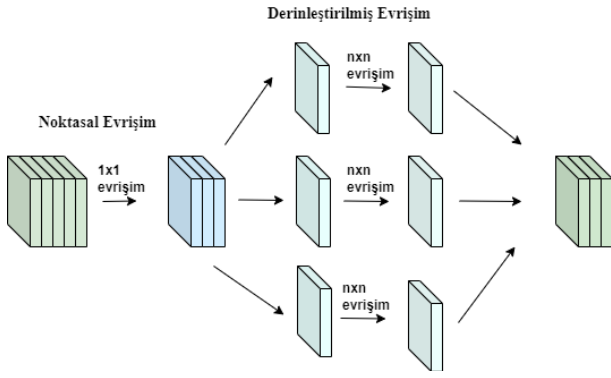


Şekil 2.3. ODIR-5K Veri seti[9].

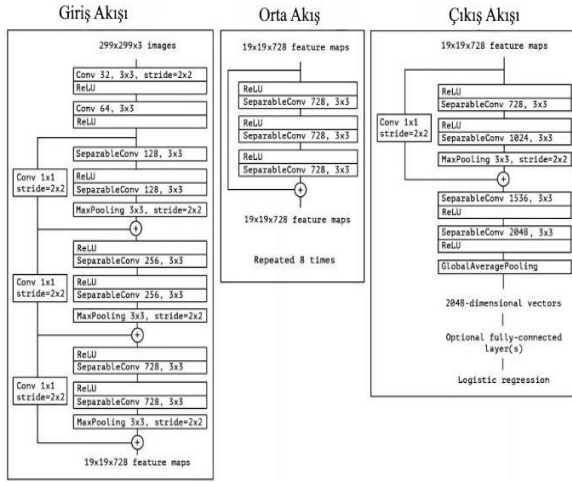
2.3. Xception Mimarisi

Xception, Chollet tarafından geliştirilen temel yapı olarak InceptionV3 ağ mimarisinden ilham alınarak inşa edilmiştir. “Aşırı Başlangıç (Extreme Inception)” olarak da bilinen Derin Sinir Ağı (DNN) mimarisidir[10]. Inception mimarisi yeniden yapılandırılmış, derinlemesine ayrılabilir evrişim katmanları ile değiştirilerek formüle edilmiştir [10].

Inception mimarisine göre daha verimli sonuçlar elde etmiştir. Şekil 2.4’de Xception mimarisinde uygulanan derinlemesine evrişim yapısı gösterilmiştir. Xception mimarisi, toplamda 14 tane modülden oluşan evrişim katmanlarının her biri artık bağlar ile birbirine bağlantılıdır. Özellik çıkarımı işlemi için 36 evrişim katmanı, tam bağlı ve çıkışında bulunan sınıflandırma katmanlarından oluşmaktadır.



Şekil 2.4. Xception Mimarisi Derinleştirilmiş Evrişim Modeli [10].

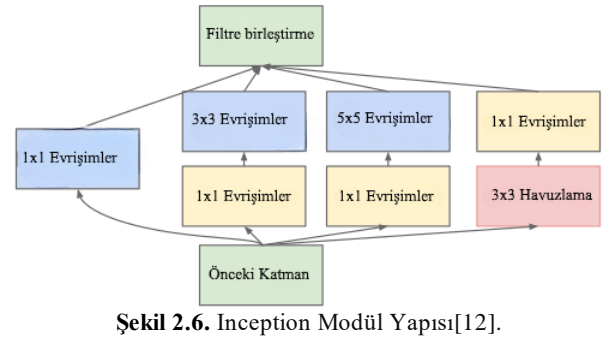


Şekil 2.5. Xception Ağ Mimarisi [10].

Veriler öncelikle giriş akışından, sonrasında 8 kez yinelenen orta akıştan son olarak çıkış akışından geçirilmektedir ve ağı eğitimi tamamlanmaktadır.

2.3. Inception Mimarisi


2015 yılında Christian Szegedy ve arkadaşları tarafından "Bilgisayarlı Görü için Inception Mimarisini Yeniden Düşünmek (Rethinking the Inception Architecture for Computer Vision)" makalesinde geliştirilen InceptionNet, GoogleNet için geliştirilmiş evrişimli sinir ağıdır [11]. Evrişim katmanlarının sayısının fazla olması işlem karmaşıklığına, eğitim maliyetini artırmaya, hafıza ihtiyacının, çıkış veri miktarının artması gibi dezavantajlara neden olmuştur. Ayrıca kaybolan gradyan problemi gibi bazı sorunları da beraberinde getirmektedir. Bu sorunlara çözüm olarak geliştirilen mimariyi katman olarak derinleşmektense, ağı genişletmek mantığıyla modelleme yapılmıştır. Inception mimarisinde toplam 22 katmandan oluşmakta olan ağ ImageNet veri yarışmasında %6,67'lik top-5 hata oranına ulaşarak birincilik almıştır. [12].



Şekil 2.6. Inception Modül Yapısı [12].

2.4. Önerilen ESA Mimarisi

Önerilen ESA mimarisinde önceden eğitilmiş transfer öğrenme mimarilerinin aksine katman sayısı minimal seviyede tutulmaya çalışılmıştır. Veri seti ön işlemlerden geçirilerek eğitim için hazır hale getirilmiştir. Veriler evrişim katmanlarından ardından 2x2 boyutlarında maksimum havuzlama uygulanarak sonrasında batch-normalization katmanı ile veri normalizasyonu ve veri dağılımının dengesi sağlanmıştır. Ardından dropout katmanı uygulanarak tekrar evrişim katmanları eklenmiştir. Önerilen ESA mimarisi detaylı şekilde 2.7' de gösterilmektedir.




Şekil 2.7. Önerilen ESA Mimarisi

3. BULGULAR

Veri setinde artırma işlemleri bulunan 6.392 retina tomografi fotoğrafına veri uygulanarak veri dağılımında bulunan dengesizliklerin giderilmesi amaçlanmıştır ve veri sayısı 22.798 olarak artırılıp dengelenmiştir. Veri seti %64 eğitim, %16 doğrulama ve %20 test olmak üzere ayrılmıştır.

ODIR-5K veri seti önceden eğitilmiş transfer öğrenme metotlarından XceptionV3, InceptionV3 ağlarında ve önerilen ESA modeli üzerinde eğitilmiştir. Optimizasyon fonksiyonu olarak 'Adam' tercih edilmiştir. Öğrenme oranı 0.0001, batch size değeri 32 olarak belirlenmiştir ve 50 adım sayısında eğitim işlemi tamamlanmıştır. Eğitim ve test verileri üzerinde elde edilen doğruluk, kesinlik, duyarlılık ve F1-puanı değerleri Tablo 3'de verilmiştir.

Eğitilen ağlara ait doğruluk ve kayıp grafikleri 2.8, 2.10, 2.12’de gösterilmiştir. Eğitilen mimarilere ait karmaşıklık matrisleri Şekil 2.9, Şekil 2.11 ve Şekil 2.13’de verilmiştir. Karmaşıklık matrisi veri setinde sınıflandırılmak istenen yedi farklı hastalığa ait ve normal retinaya sahip bireyler olmak üzere sekiz farklı sınıf için doğru sınıflandırmaları ve yanlış sınıflandırma sonuçlarını göstermektedir.




Şekil 2.8. Xception Ağ Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	534	0	7	1	1	1	11	9
Katarakt	0	529	0	1	0	1	5	1
Diyabet	0	4	360	15	33	3	132	58
Glokom	2	1	3	552	2	0	20	1
Hipertansiyon	0	0	6	1	595	0	1	2
Miyop	1	1	0	1	0	577	0	2
Normal	16	9	106	37	20	3	300	64
Diğer	28	14	43	11	5	15	88	313

Şekil 2.9. Xception Ağ Karmaşıklık Matrisi

Şekil 2.9’da verilen XceptionV3 mimarisine ait karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 534 tanesini doğru olarak sınıflandırmıştır ve %94.68 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden 529 tanesini doğru, 8 veriyi yanlış sınıflandırarak %98.51’lik başarı oranına elde edilmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 360 tanesini doğru sınıflandırmıştır ve %59.21 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 552 veriyi doğru sınıflandırmıştır, 29 adet veriyi yanlış tahminde bulunarak %95 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 595 tanesini doğru olarak sınıflandırarak %98.34 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden 577 tanesini doğru, 5 veriyi yanlış sınıflandırarak %99.14 oranında doğruluk elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 313 tanesini doğru sınıflandırmıştır ve %60.54 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 300 tanesini doğru sınıflandırarak %54.05 oranında doğruluk değeri elde edilmiştir.




Şekil 2.10. Inception Mimarisi Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	555	0	0	1	0	0	7	1
Katarakt	0	537	0	0	0	0	0	0
Diyabet	8	0	393	12	26	2	122	50
Glokom	0	1	3	566	0	0	10	1
Hipertansiyon	1	0	1	0	601	0	1	1
Miyop	0	0	0	0	0	582	0	0
Normal	14	10	119	32	13	4	323	40
Diğer	15	4	23	5	5	8	60	401

Şekil 2.11. Inception Ağ Karmaşıklık Matrisi

Şekil 2.11’de verilen karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 555 tanesini doğru olarak sınıflandırmıştır ve %98.40 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden tamamını doğru sınıflandırarak %100 başarı oranı elde edilmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 393 tanesini doğru sınıflandırmıştır ve %64.63 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 566 veriyi doğru sınıflandırmıştır, 15 adet veriyi yanlış tahminde bulunarak %97.41 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 601 tanesini doğru olarak sınıflandırarak %99.33 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden tamamını doğru sınıflandırarak %100 oranında doğruluk elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 401 tanesini doğru sınıflandırmıştır ve %77.56 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 323 tanesini doğru sınıflandırarak %58.19 oranında doğruluk değeri elde edilmiştir.



Şekil 2.12. ESA Mimarisi Doğruluk ve Kayıp Grafikleri

Gerçek değer	Tahmin edilen değer							
	YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
YBMÖ	559	0	0	0	0	0	3	2
Katarakt	0	537	0	0	0	0	0	0
Diyabet	2	3	429	5	9	0	138	27
Glokom	0	0	0	566	0	0	15	0
Hipertansiyon	0	1	1	0	602	0	1	0
Miyop	0	0	0	0	0	581	0	1
Normal	8	5	107	23	4	3	358	47
Diğer	7	4	23	3	2	7	40	435

Şekil 2.13. Önerilen ESA Mimarisi Karmaşıklık Matrisi

Şekil 2.13’de verilen karmaşıklık matrisi incelendiğinde Yaşa Bağlı Maküler Ödem (YBMÖ) için 564 görüntü içerisinde 559 tanesini doğru olarak sınıflandırmıştır ve 5 veriyi yanlış sınıflandırarak %99.11 oranında doğruluk değerine ulaşmıştır. Katarakt hastalığı için 537 adet veriden tamamını doğru sınıflandırarak %100 başarı oranı elde etmiştir. Diyabet hastalığı için bulunan 608 veri içerisinde sadece 429 tanesini doğru sınıflandırmıştır ve %70.55 oranında doğruluk değerine ulaşmıştır. Glokom hastalığı için 581 veri içerisinde 566 veriyi doğru sınıflandırmıştır, 15 adet veriyi normal sınıfta tahmin etmiştir ve %97.41 oranında doğruluk değeri elde etmiştir. Hipertansiyon hastalığı için bulunan 605 veriden 602 tanesini doğru olarak sınıflandırarak %99.50 oranında doğruluk değeri elde etmiştir. Miyop hastalığı için 582 veriden 581 tanesini doğru 1 tanesini diğer hastalık sınıfına dahil ederek %99.82 oranında doğruluk değeri elde etmiştir. Diğer hastalık sınıfında bulunan 517 veriden 435 tanesini doğru sınıflandırmıştır ve %84.13 oranında doğruluk değeri elde edilmiştir. Son olarak normal retinaya sahip verilerin bulunduğu sınıf incelendiğinde 555 verinin 358 tanesini doğru sınıflandırarak %64.5 oranında doğruluk değeri elde edilmiştir.

Tablo 3. Modellerin Performans Metrikleri

Model	Eğitim doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
InceptionV3	%98.2	%86.83	%86.29
Xception	%95.36	%82.49	%88.60
Önerilen ESA	%97.51	%89.22	%89.26

4. TARTIŞMA VE SONUÇ

Retinal hastalıkların teşhis edilebilmesi için kullanılan Optik Koherans Tomografi (OCT) retinanın enine kesit görüntülerinin detaylı şekilde analizi için kullanılan bir tekniktir. OCT, diğer tomografi cihazlarının aksine radyasyona maruz bırakmadan retinal görüntünün elde edilmesini sağlamaktadır. Elde edilen fundus fotoğrafları alanında uzman oftalmologlar tarafından teşhis edilmekte ve erken tedavi uygulanması sağlanmaktadır. Ancak OCT cihazlarının sayısının az olması ve uzman sayısının yetersiz kalması gibi sorunlar ortaya çıkmaktadır. Teknolojinin gelişmesiyle birlikte bilgisayarlı tanı sistemleri oldukça sık kullanılmaya başlanmıştır. Derin

öğrenmede Evrişimli Sınır Ağları (ESA) sınıflandırma problemlerinde oldukça iyi sonuçlar vermektedir. Bu makalede, OCT cihazından elde edilen tomografi görüntülerinden Yaşa Bağlı Maküler Ödem (YBMÖ), Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, Normal ve Diğer anormallikleri içeren sekiz farklı sınıf için ESA modeli önerilmiştir. Önerilen model önceden eğitilmiş InceptionV3 ve XceptionV3 ağları ile karşılaştırılmıştır. InceptionV3 mimarisinde %98.2, XceptionV3 mimarisinde %95.36 ve önerilen ESA mimarisinde ortalama %97.51 doğruluk oranı elde edilmiştir. Önerilen ESA mimarisi diyabet hastalığı için %70.55, normal sınıf için %64.5 ve diğer hastalıklarda %84.13 doğruluk oranına ulaşmış olup InceptionV3 ve XceptionV3 mimarileri ile kıyaslandığında sınıf bazında kıyaslandığında normal, diğer hastalıklar, katarakt ve diyabet hastalığında önceden eğitilmiş transfer öğrenme metotlarından daha yüksek doğruluk değerlerine ulaşmıştır. Modellerin test doğruluk değerleri karşılaştırıldığında Inception mimarisinin %86.29, Xception mimarisinin %88.60 ve önerilen ESA mimarisinin %89.26 oranında test başarısına ulaşarak önceden eğitilmiş transfer öğrenme metotlarına kıyasla yüksek test başarısına ulaştığı görülmektedir.

Sonuç olarak önerilen ESA modeli transfer öğrenme metotlarından en sık kullanılan iki tanesi ile karşılaştırılarak doğruluk ve test değerleri elde edilmiştir. 8 sınıfın olduğu veri seti genişletilerek farklı hastalıklar içinde çeşitlendirilebilir ve önerilen ESA mimarisi sayesinde retinal hastalıkların erken teşhis edilmesi ve tedavi yöntemlerinin uygulanmasında uzmanlar tarafından kullanılabilir. Böylelikle uzman sayısının yetersiz kaldığı durumlarda önerilen ESA mimarisi sayesinde retinada meydana gelebilecek kalıcı hasarlar erken tespit yapıldığı takdirde önlenmiş olacaktır.

Etik Hususlar

Etik kurallara uyum

Bu çalışmada, insan gönüllüleri ve deneysel hayvan içeren çalışmalarda gerçekleştirilen tüm prosedürleri, kurumsal ve / veya ulusal araştırma komitesinin etik standartlarına ve 1964 Helsinki deklarasyonuna ve daha sonraki değişikliklerine veya karşılaştırılabilir etik standartlara uygun olarak çalışıldığını beyan ederiz.

Finansman

Bu çalışmada, araştırmalarının kamu, ticari veya kar amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe kullanılmadığını beyan ederiz.

Çıkar çatışması

Bu çalışmada herhangi bir çıkar çatışması olmadığını beyan ederiz.

KAYNAKÇA

- [1] Kolb, H. Simple anatomy of the retina. 2012.
- [2] Srinivasan, P. P., Kim, L. A., Mettu, P. S., Cousins, S. W., Comer, G. M., Izatt, J. A., Farsiu, S. 2014. Fully automated detection of diabetic macular edema and dry age-related macular degeneration

from optical coherence tomography images. *Biomed Opt Express*, 2014. 5(10): p. 3568-77. <https://doi.org/10.1364/BOE.5.003568>

Computer Vision and Pattern Recognition (CVPR). <https://doi.org/doi:10.1109/CVPR.2015.7298594>.

- [3] Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., Webster, D. R. 2016. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA*, 2016. 316(22): p. 2402-2410. <https://doi.org/10.1001/jama.2016.17216>
- [4] S. Najeeb, N. Sharmile, M. S. Khan, I. Sahin, M. T. Islam, M. I. Hassan Bhuiyan, 2018. Classification of Retinal Diseases from OCT scans using Convolutional Neural Networks. 10th International Conference on Electrical and Computer Engineering (ICECE). 2018.
- [5] A P, S., Kar, S., S, G., Gopi, V. P., Palanisamy, P. 2021. OctNET: A Lightweight CNN for Retinal Disease Classification from Optical Coherence Tomography Images. *Computer Methods and Programs in Biomedicine*, 2021. 200: p. 105877. <https://doi.org/10.1016/j.cmpb.2020.105877>
- [6] Lu, Z., Miao, J., Dong, J., Zhu, S., Wang, X., Feng, J. 2023. Automatic classification of retinal diseases with transfer learning-based lightweight convolutional neural network. *Biomedical Signal Processing and Control*, 2023. 81: p. 104365. <https://doi.org/10.1016/j.bspc.2022.104365>
- [7] S.C., E.P.A. 2023. Retina. [cited 2023 16.4.2023]; Available from: <https://www.epawi.com/comprehensive-eye-care-milwaukee/retina/>.
- [8] Karalezli, A., Kaderli, A. 2021. Tıp Fakültesi Öğrencileri için Göz Hastalıkları. 2021: p. 1-3.
- [9] Kaggle, 2019.
- [10] Chollet, F. 2017. Xception: Deep Learning with Depthwise Separable Convolutions, 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, 2017, pp. 1800-1807, <https://doi.org/10.1109/CVPR.2017.195>.
- [11] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., Wojna, Z. 2016. Rethinking the Inception Architecture for Computer Vision, 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 2818-2826, <https://doi.org/10.1109/CVPR.2016.308>.
- [12] Szegedy, C., et al. 2015. *Going deeper with convolutions*. in *2015 IEEE Conference on*

(Araştırma Makalesi)

Doğada Yetişen Mantar Türlerinin Derin Öğrenme ile Tespiti**Merve AKIN*¹, Aycan DAĞDELEN², Rabia Nur EĞİNME³, Durmuş ÖZDEMİR⁴**¹Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0007-0542-0396>²Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0004-4603-4764>³Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0009-0007-6504-2323>⁴Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43100, Kütahya, ORCID No : <https://orcid.org/0000-0002-9543-4076>**Anahtar Kelimeler:***Derin Öğrenme,
Veri Seti,
Tensorflow,
Keras,
Mantar,
Zehirli Mantarlar,
Yenilebilen Mantarlar*

Özet: Mantarların Türk ve Dünya mutfaklarında kullanımı hızla artmakta, özellikle son yıllarda yabani mantar toplayıcılığı ve tüketiminde önemli artışlar yaşanmaktadır. Çevremizde sıkça gözlemediğimiz gıda zehirlenmelerinin birçoğunu mantar zehirlenmeleri oluşturmaktadır. Öyle ki bu oran erişkinlerde mantar zehirlenmeleri tüm akut zehirlenme vakalarının yaklaşık %7'sini oluşturmaktadır. Ülkemizin kırsal kesimleri başta olmak üzere pek çok yerinde halk mantarları toplayarak gıda olarak tüketmektedir. Ülkemizde yeterli bilgiye sahip olmayan kişiler tarafından toplanan mantarların besin olarak tüketilmesi ile zehirlenmeler ve ne yazık ki ölümler görülebilmektedir. Bu çalışmada doğada kolaylıkla yetişebilen mantarların insanlar üzerindeki olumsuz etkilerini azaltmak amacıyla, insanların mantar kullanımında bilgi sahibi olmalarını sağlayarak bilinç düzeylerini artırmak için derin öğrenme tabanlı mobil uygulama tasarlanmıştır. Çalışmada ayrıca açık kaynak kod olarak sunulan, Google ve bağımsız geliştiriciler tarafından geliştirilen Tensorflow ve Keras kütüphaneleri kullanılmıştır. Android Studio ve Java programlama dili kullanılarak tasarlanan mobil uygulamaya derin öğrenme metodlarından VGG16 entegre edilerek kameradan görüntüsü alınan mantar tespit edilerek kullanıcıya özellikleri sunulmaktadır. Araştırma bulgularına uygulanan istatistiksel analizler sonucunda doğruluk oranı %81.75 olarak hesaplanmıştır.

(Research Article)

Detection of Mushroom Species Growing in Nature with Deep Learning**Keywords:***Deep Learning,
Dataset,
Tensorflow,
Keras,
Mushroom,
Poisonous Mushrooms,
Edible Mushrooms*

Abstract: The use of mushrooms in Turkish and World cuisines is increasing rapidly, especially in recent years, there has been a significant increase in wild mushroom picking and consumption. Most food poisonings we frequently observe in our environment are caused by mushroom poisoning. This rate is such that mushroom poisoning in adults constitutes approximately 7% of all acute poisoning cases. In many parts of our country, especially in rural areas, people collect mushrooms and consume them as food. In our country, poisoning and, unfortunately, deaths can be seen due to the consumption of mushrooms collected by people who do not have sufficient knowledge of food. In this study, to reduce the harmful effects of mushrooms that can quickly grow in nature on humans, a deep learning-based mobile application was designed to increase people's awareness by providing information on mushroom use. Tensorflow and Keras libraries, which are offered as open-source code and developed by Google and independent developers, were also used in the study. VGG16, one of the deep learning methods, is integrated into the mobile application designed using Android Studio and Java programming language, and the mushroom image taken from the camera is detected, and

its features are presented to the user. As a result of the statistical analyses applied to the research findings, the accuracy rate was calculated as 81.75%.

1. GİRİŞ

Dünyada gelişen teknoloji ile birlikte yapay zekâ ve alt kümesi olan derin öğrenme teknolojileri birçok farklı alanda hayatımızı kolaylaştıran bir unsur haline gelmiştir. Derin öğrenme, beyindeki nöron ağını taklit eden bir bilgisayar yazılımıdır. Derin öğrenme ifadesi 2012 yılında Hinton tarafından çok katmanlı yapay sinir ağlarının verimli bir şekilde eğitilebileceği ortaya koyulduktan sonra literatürde kullanılmaya başlanmıştır [9].

Derin öğrenme (aynı zamanda derin yapılandırılmış öğrenme, hiyerarşik öğrenme ya da derin makine öğrenmesi) bir veya daha fazla gizli katman içeren yapay sinir ağları ve benzeri makine öğrenme algoritmalarını kapsayan çalışma alanıdır. Klasik Makine öğrenme teknikleri ile bir model tanımlama veya makine öğrenimi sistemi kurmak için öncelikle özellik vektörünün çıkarılması gerekmektedir. Özellik vektörünün çıkarılması için alanında uzman kişilere ihtiyaç duyulmaktadır. Bu işlemler hem çok zaman almakta hem de uzmanı çok meşgul etmektedir. Bu sebeple bu teknikler, ham bir veriyi ön işlem yapmadan ve uzman yardımı olmadan işleyemezler. Derin Öğrenme makine öğrenimi alanında çalışanların uzun yıllar boyunca uğraştığı bu sorunu ortadan kaldırarak büyük ilerleme sağlamıştır. Çünkü derin ağlar geleneksel makine öğrenmesi ve görüntü işleme tekniklerinin aksine öğrenme işlemini ham veri üzerinde yapmaktadır. Ham veriyi işlerken gerekli bilgiyi farklı katmanlarda oluşturmuş olduğu temsillerle elde etmektedir. Derin Öğrenme ilk defa 2012 yılında nesne sınıflandırma için yapılan, büyük ölçekli görsel tanıma (ImageNet) yarışmasında elde ettiği başarı ile dikkatleri üzerine çekmiştir. Derin Öğrenmenin temelleri geçmişe dayansa da özellikle son yıllarda popüler olmasının en önemli sebeplerinden ilki eğitim için yeteri kadar verinin olması ve ikinci olarak bu veriyi işleyecek donanımsal alt yapının olmasıdır [5].

Derin öğrenme (Deep Learning-DL), birçok alanda önemli başarılar elde etmiş güçlü bir makine öğrenmesi yöntemidir. Özellikle son on yılda, bilgisayarlı görü, nesne tanıma, konuşma tanıma, doğal dil işleme gibi birçok araştırma alanında başarılı sonuçlar elde ederek, yapay zekanın derin uykudan uyanmasına yol açmıştır. Günümüzde, çeşitli alanlardaki birçok araştırmacı, DL yöntemlerini kullanarak alanlarında en iyi sonucu almaya çalışmaktadır [8].

Sayısal veriler incelendiğinde yeryüzünde yaklaşık 1,5 milyon mantar türü vardır. Günümüzde ise sadece 69.000 kadar mantar türü tanımlanmıştır. Mantarların kullanım alanları ve insan hayatına çok fazla yararları olsa da

neden oldukları hastalıklar ve zehirlenmeler de oldukça fazladır. Mantar zehirlenmeleri, ülkemizde zehirlenmelerin çok büyük bir kısmını oluşturmaya da insan hayatını tehlikeye atma konusunda önemli bir riske sahiptir. Ülkemizde mantar zehirlenmesinden kaynaklanan ağır karaciğer yetmezliği gibi bazı hastalıklara sebebiyet vermektedir. İnsanların bilinçsizce mantar tüketiminden kaynaklanan sağlık sorunları ortaya çıkmaktadır [23]. Doğal alanlarda yetişen ve yapısında zehirli madde bulunan şapkalı mantarların taze, kurutulmuş veya konserve olarak yenmesi sonucunda gelişen ve ölümlerle de sonuçlanabilen ciddi tehlikeleri vardır. Bir haber kaynağına göre Karaman’da yaşayan bir aileden üç kişi bahçedeki mantarlardan zehirlenerek hastaneye kaldırıldı. Aileden iki kişi hastanede tedavi altına alınırken zehirlenmeye bağlı organ yetmezliği gelişen diğer aile üyesine kardeşinden karaciğer nakledildi. Bu olay bilinçsizce mantar tüketimine bağlı olumsuz sonuçlara sadece bir örnektir [11].

Bu çalışma ile amacımız toplumun mantarlar hakkında bilgi sahibi olmalarını sağlamak ve toplumu bilinçlendirerek bu gibi durumların ortaya çıkmasını en aza indirmektir. Bu amaç doğrultusunda mantarların türlerini belirterek zehirli olup olmadıkları bilgisini insanlara gösteren derin öğrenme tabanlı bir mobil uygulama tasarlandı. Bu uygulamayla birlikte; mantar toplayıcılığının hala yaygın olduğu yörelerde insan sağlığına zararlı olan mantarların eksik bilgi sebebi ile tüketilmesinin önüne geçilmesi hedeflenmiştir. Çalışmanın tasarımında Android Studio ve Java programlama dili ile derin öğrenme kütüphaneleri kullanılmaya karar verilmiştir.

Farklı sektörlerde de bu çalışmada kullanılan teknikler kullanılarak farklı problemlere çözüm getiren çalışmalar yapılmıştır. Yapılan literatür taramalarında karşılaşılan çalışmalarda, bu çalışmada da kullanılan tekniklerle benzerlik gösteren çalışmalar vardır. Eryılmaz, Şahin ve Kılıç; yaptıkları çalışmada derin öğrenme, yapay zeka ve makine öğrenmesi tekniklerini kullanarak istenmeyen e-postaların tespitini gerçekleştiren bir çalışma gerçekleştirmiştir. Çalışmada aynı veri kümesinde yapılan diğer çalışmalara göre, daha fazla öznelik seçim yöntemi ve daha fazla makine öğrenmesi algoritması test edilmiştir. Bu sayede veri kümesinin boyutunu artırarak geniş kapsamlı denemelerin yapılması hedeflenmiştir [7].

Alimovski ve Erdemir; çalışmalarında derin öğrenme, evrimsel sinir ağları ve makine öğrenmesi kullanmıştır. Orijinal veri seti ve çoğaltılmış veri setlerini kullanarak derin öğrenmeye dayalı yüz tanıma sistemindeki etkisi araştırılmıştır. Elde edilen sonuçlar, uygulanan veri artırma tekniğinin, yüz doğrulama işlemi için %1.8 oranında, yüz sınıflandırma işlemi için %2.2 ve %2.5 oranında artış sergilediği gözlemlenmiştir [1].

Muradlı; çalışmalarında VGG16, Resnet50 ile “MPI İnsan Duruşu” veri seti ve Evrişimsel Sinir Ağı kullanılarak insan duruş tespiti gerçekleştirmişlerdir. Çalışmanın amacı, Keras modeli adı verilen bir derin öğrenme modelinde son teknoloji bir ağ uygulayarak insan vücudunun duruşunu tahmin etmek için derin bir CNN yapısının nasıl kullanılabilirliğini keşfetmektir [15].

Bu çalışmada Android platformunda uygulamayı çıkarmak için Android Studio ve Java programlama dili kullanılmak üzere seçilmiştir. Toplanan veriler ile eğitilen modelimiz TensorFlow Lite biçiminde Android Studio ortamında kullanıldı. Ayrıca kullanıcı kayıt/giriş bilgilerinin kaydı tutmak adına veri tabanı bağlantısı kuruldu. Bu bağlamda veri tabanı olarak Firebase seçildi.

2. MATERYAL VE METOT


2.1. Kullanılan Yöntemler

Bu çalışmada mantar türlerinin tespiti için derin öğrenme sınıflandırıcı model olarak önceden eğitilmiş bir CNN modeli olan VGG16 kullanılmıştır.

2.1.1. CNN Model

Bilgisayar görmesi alanında, öznelik çıkarımı ve sınıflandırma her zaman önemli bir çalışma alanı olmuştur. ESA, görüntülerin analiz edilmesine başarıyla uygulanmış derin ileri beslemeli yapay sinir ağıdır. Genellikle görüntü işleme problemlerinde kullanılmaktadır. Giriş katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantı katmanı ve çıkış katmanı adı verilen katmanlardan oluşur. ESA, görüntü tanıma uygulamalarında kullanılmaktadır. Her bir evrişim katmanında özellik haritaları bulunabilir. Bu özellik haritaları sayesinde ağ, farklı özellikleri öğrenebilmektedir [3].

ESA, sayılan bu avantajlarının dışında önemli bir dezavantaja sahiptir. Bu dezavantaj ise, modelin eğitim ve test aşamasında başarı ile çalışabilmesi için ihtiyaç duyulan yüksek bellekli güçlü GPU (Graphics Processing Unit) kartlarıdır. Son günlerde üreticilerin geliştirmiş oldukları yüksek bellekli kartları sayesinde bu sorunun önüne geçilmesine çalışılmaktadır [23].



Şekil 1. CNN Mimarisi [4].

2.1.2. Keras

Keras, Python için derin bir öğrenme kütüphanesidir ve derin öğrenme modellerinin oluşturulması ve eğitimi için çok uygun bir ortam sağlar [5]. Keras başlangıçta araştırmacıların daha hızlı denemeler yapabilmeleri için geliştirilmiştir. Keras'ın öne çıkan özellikleri aşağıdaki gibidir;

- Kodu değiştirmeden hem CPU'da (Central Processing Unit) hem de GPU'da çalışmasını sağlar.
- Derin öğrenme modellerinin prototiplemesinin hızlıca yapılmasına imkân sağlayan kullanıcı dostu API'ye (Application Programming Interface) sahiptir.
- Evrişimsel ağlar (bilgisayarlı görü için), yinelenmeli ağlar (zaman serisi işlemek için) ve her ikisinin beraber kullanımını için önceden tanımlı desteğe sahiptir. Keras'da pek çok değişik ağ yapısının, çoklu girdi ya da çoklu çıktının, katman paylaşımının, model paylaşımının vb. uygulanabilmesi mümkündür. Bu da Keras'ı, çeşitli üretici ağlardan sinirsel Turing makinesine kadar her türlü derin öğrenme modelinin oluşturulması için uygun hale getirmektedir. Keras, MIT lisansı (Massachusetts Institute of Technology) ile dağıtılmaktadır. Yani ticari projeler dahil her yerde serbest olarak kullanılabilir.

Önerilen modeli kurulumak için gerekli çalışmalar, Python 3.8 programlama dilinde yazılmış derin öğrenme kütüphanesi Keras kullanılarak yapılmıştır [14, 18, 10]. Modeli kurulumak ve derin öğrenme mimarisini inşa etmek için ihtiyaç duyulan kütüphaneler Anaconda yazılımı aracılığıyla yüklenmiştir [2]. Keras, Python ile yazılmış ve TensorFlow, CNTK (The Microsoft Cognitive Toolkit), Theano'nun üzerinde çalışabilen üst düzey bir sinir ağları uygulama derin öğrenme kütüphanesidir. Keras, Python için 250.000'den fazla kullanıcısı ve 700'den fazla açık kaynaklı katılımcısı ile (2018'in ortalarına itibaren) önde gelen bir derin öğrenme kütüphanesidir. Çabuk sonuç sağlamaya odaklanarak geliştirilmiştir. Kullanıcı dostu, modülerlik ve genişletilebilir olması özellikleriyle kolay ve hızlı prototipleme sağlar. Konvolüsyon ağları, yinelenen ağlar ve her ikisinin kombinasyonlarını destekler. CPU ve GPU'da sorunsuz çalışır. Keras, önemli sayıda girişimde, araştırma laboratuvarlarında (CERN, Microsoft Research ve NASA dahil) ve Netflix, Yelp, Square, Uber, Google gibi büyük şirketlerde kullanılmaktadır. Keras varsayılan olarak, TensorFlow'u tensör manipülasyon kütüphanesi olarak kullanır [14, 12].

Keras, Google mühendisi François Chollet tarafından, dört temel ilkeyi dikkate alınarak geliştirilmiştir [13]:


- Modülerlik: Bir model sadece bir sekans veya grafik olarak okunup, anlaşılabilir. Derin bir öğrenme modelinin tüm özellikleri, keyfi bir şekilde birleştirilip ayrılabilir.
- Minimalizm: Kütüphane, bir sonuç elde etmek için yeterli seviyedir, gereksiz süsten uzak ve okunabilirliği en üst seviyeye çıkaracak biçimde tasarlanmıştır.
- Genişletilebilirlik: Araştırmacıların yeni fikirleri denemelerini ve keşfetmelerini sağlamaya yönelik olarak, kütüphane içine yeni bileşenler kolaylıkla eklenebilir, eklenen yeni bileşenler kolaylıkla kullanılabilir.

- Python: Özel dosya formatlarına sahip ayrı bir model dosyası yoktur. Her şey doğal Python'dır.

Derin öğrenme modeli Python programlama dili Keras kütüphanesi kullanılarak Spyder geliştirme ortamı ile geliştirilmiştir. Google Colaboratory ile de Tensorflow tabanlı Keras kütüphanesi kullanılmaktadır.

2.1.3. TensorFlow

TensorFlow makine öğrenmesi ve derin öğrenme projelerini baştan sona tasarlayıp sonuçları görebileğimiz bir ortam sunmaktadır [16]. Google Brain ekibi tarafından 2015 yılında açık kaynaklı bir proje olarak yayınlanan bu kütüphane birbirinden farklı ortamlarda çalışabileceği gibi farklı programlama dilleri ve farklı donanımlarda da çalışabilir. Bu kütüphanedeki yapı temel olarak bir dizi hesaplamalardan meydana gelen veri akış grafiklerinden oluşmaktadır. Bu akış grafikleri düğümlerin durumunu kaydetmek, güncellemek için dallanma ve döngü kontrolüne izin veren bir veri akışı hesaplaması sunar [19]. Her bir düğüm 0 veya daha fazla girişe ve 0 veya daha fazla çıkışa sahip olan işlem örneği gösterir. Şekil 2'de görülmektedir.



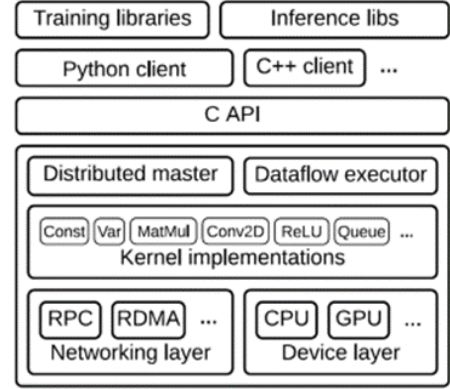
Şekil 2. Veri Akış Grafığı

TensorFlow, otomatik farklılaştırma ve parametre paylaşma yetenekleri nedeniyle farklı mimari türlerini destekler. TensorFlow, paylaşılan parametreleri güncellemek için iş birliği yapan çoklu hesaplama kaynaklarını kullanarak veri akış grafiği modelinin paralel yürütülmesi yoluyla paralellliği destekler. Paralel çalışma yeteneği ciddi performans artışlarına izin verir [25]. TensorFlow ayrıca mobil ve Nesnelerin İnterneti (IoT) cihazlar için optimize edilmiş çıkarım yapma sürümünü de sunmaktadır. Düşük donanım özelliklerinde etkin sonuçlar vermesi hedeflenmiştir [22]. TensorFlow ile Google ve Amazon gibi bulut ortamlarında model oluşturmak, eğitmek ve test etmek mümkündür. Şekil 3'de TensorFlow mimari katmanlarına yer verilmiştir.

2.1.3. VGG16 model


VGG-16 mimarisi; evrişimsel, havuz ve tamamen bağlı katmanlardan oluşur. Toplam 21 ana katmandan oluşur. Bu mimari artan bir ağ yapısına sahiptir. Görüntü giriş çözünürlüğü 224×224 pikseldir. Evrişimsel katmanındaki filtre boyutu 3×3 pikseldir. Bu mimaride

son katmanlar özellik çıkarımı için kullanılan tam bağlantılı katmanlardan oluşur [20].




Şekil 3. TensorFlow Mimari Katmanları [19]

VGG16 modeli Görsel Geometri Grubu (Visual Geometry Group) tarafından ILSVRC-2014 yarışmasında daha iyi sonuçlar elde etmek için geliştirilen bir ağ modelidir [6]. Giriş katmanında yer alacak görüntü $224 \times 224 \times 3$ boyutundadır. ImageNet veri seti ile %89 doğruluk yakalamış bir derin öğrenme ağ modelidir [21]. Şekil. 3'te sunulan VGG16 ağ mimarisinde, 13 evrişim katmanı ve 5 havuzlama katmanı ile toplamda 18 katman bulunmaktadır [6].



Şekil 4. VGG16 Mimarisi [24].



Şekil 5. VGG16 Mimarisi [4].

2.2. Kullanılan Veri Seti

Bu çalışmada kullanılan veri seti, internet üzerinden alınan fotoğraflarla 23 ayrı sınıf oluşturulacak şekilde hazırlandı. Yapay zekâ tarafından daha anlaşılabilir olabilmesi için her bir fotoğraf arka planından ayrıldı. Her bir hedef mantarı, yeterli çeşitlilik seviyesine sahip yeterli kaynak görüntü toplamak için mantarlardan çeşitli açılardan ve mesafelerden görüntüleri veri setine

eklemeye özen gösterildi. Veri setini hazırlarken tüm mantar fotoğrafları, arka planlarının sadeliği baz alınarak tek tek seçilip eğitim modeli için ayarlandı. Tek tek sınıflara ayrılan tüm fotoğraflar “eğitim”, “geçerleme” ve “test” olmak üzere 3 sınıfa ayrıldı. Eğitim sınıfında 130 fotoğraf, geçerleme sınıfında 40 fotoğraf, test sınıfında ise 50 fotoğraf bulunmaktadır. Bu üç sınıf altında da her biri kendi sınıfının mantar türüyle aynı kategoriye konuldu.

2.3. Veri Seti İçin Kullanılan Mantarlar

Bu çalışmada 23 farklı mantar türüne ait 5060 adet mantar fotoğrafı kullanıldı. Bu mantarlar; Ağulu Mantarı, Bal Mantarı, Biftek Mantarı, Borazan Mantarı, Çam Kabara Mantarı, Çörek Mantarı, İmparator Mantarı, İstiridye Mantarı, Kanlıca Mantarı, Kantarel Mantarı, Kamabakar Mantarı, Kış Mantarı, Köygöçüren Mantarı, Kuzugöbeği Mantarı, Kültür Mantarı, Maitake Mantarı, Panter Mantarı, Sığır Dili Mantarı, Sinek Mantarı, Şeytan Mantarı, Şimeji Mantarı, Şitake Mantarı ve Trüf Mantarıdır.

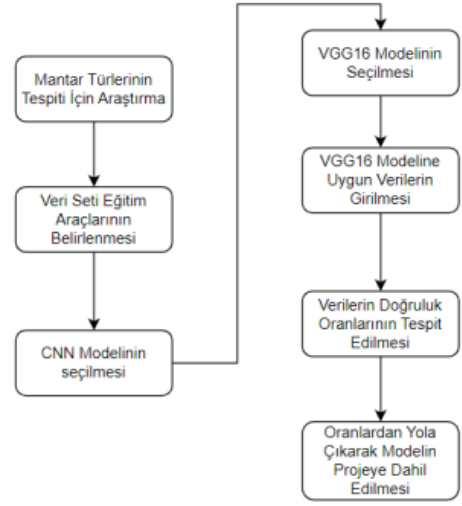


Şekil 6. a) İmparator Mantarı b) Ağulu Mantarı c) Panter Mantarı

2.4. Model'in Eğitilmesi

Modelin eğitilmesi için TensorFlow'un Keras API'si kullanılarak bir VGG16 modelinin evrişim tabanı oluşturuldu ve ön eğitilmiş ağırlıkları yüklendi. Bu taban, özellik çıkarımı için kullanılacak bir derin öğrenme modelidir. VGG16 modeli kullanılarak yeni bir sinir ağı modelinin oluşturulması sağlandı. Model, eğitim veri seti üzerinde belirtilen sayıda epoch boyunca eğitildi ve

doğrulama veri seti üzerinde performansı izlendi. Bu işlemlerin ardından h5 uzantılı bir dosya elde edildi. Bu dosya, Android Studio ortamına uyarlanabilmesi için TensorFlow Lite uzantılı bir dosya haline getirildi.



Şekil 7. Akış Şeması

3. BULGULAR

Proje bir mobil uygulamaya entegre edilerek daha verimli ve kullanışlı hale getirildi. Mobil uygulama için Android Studio ortamı seçilmiştir.

3.1 Uygulamanın Kayıt Ol Sayfası

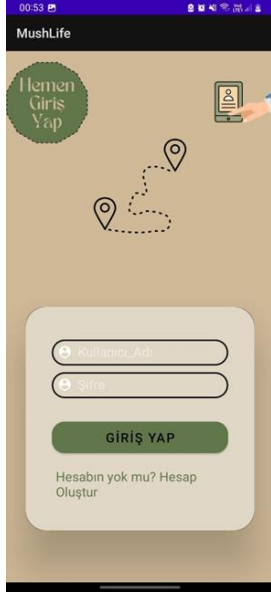
Uygulamayı kullanırken öncelikle kullanıcıların kaydolması gerekmektedir. Bu kayıt işlemi gerçekleştiğinde kullanıcının bilgileri veri tabanına kaydedilmektedir. Veri tabanı olarak Firebase kullanıldı. Uygulamanın kayıt ol sayfası Şekil 8’de gösterilmektedir.



Şekil 8. Kayıt Ol Sayfası.

3.2 Uygulamanın Giriş Yap Sayfası

Kaydılduktan sonra uygulamaya girmek için giriş yapılması gerekmektedir. Giriş yap butonuna tıklandıktan sonra kayıt bilgileri doğru bir şekilde girilip uygulamaya giriş yapılmaktadır. Uygulamadaki giriş yap sayfası Şekil 9'da bulunmaktadır.



Şekil 9. Giriş Yap Sayfası.

3.3 Uygulamanın Ana Sayfası

Uygulama açıldığında ana ekranda mantarlar ile ilgili bilgilendirici bir yazı bulunmaktadır. Ardından sol taraftaki menü butonundan seçenekler görüntülenmektedir.



Şekil 10. Uygulamanın Ana Sayfası.

3.4 Mantarları Tarama Sayfası

Ana ekrandaki menüden hemen tarayın kısmına tıklanılması durumunda kullanıcı, mantarları tarama sayfasına yönlendirilmektedir. Bu sayfada taratılmak istenen mantarın fotoğrafını yükleyerek mantar hakkında

bilgi sahibi olunmaktadır. Mantarın fotoğrafı, telefon kamerasından veya telefonun galerisinden seçilip veri setindeki en iyi eşleşme yapılarak hangi mantar olduğu kullanıcıya gösterilmektedir. Mantarın isminin olduğu kısma tıklanıldığında mantarın yenilebilir ya da zehirli olduğu bilgisi ile birlikte mantar hakkındaki bilgiler de kullanıcıya sunulmaktadır. Bu sayede kullanıcılar mantarı yemeden önce kolaylıkla mantarlar hakkında bilgi sahibi olmaktadır.



Şekil 11. Taratılan Mantar.



Şekil 12. Taratılan Mantarın Bilgileri.

3.5 Veri Setindeki Bulgular

Çalışmada TensorFlow, Python kullanarak bazı bulgular elde edilmiştir. Bu çalışmanın asıl amacı kullanıcıları

mantar zehirlenmelerine karşı en etkili biçimde bilinçlendirmektir.


Bu çalışmada mantar veri seti oluşturuldu. Veri seti bir görüntü veri kümesini eğitim, doğrulama ve test veri kümelerine böldü. Bu işlem daha sonra modelin eğitimi, doğrulaması ve performansını değerlendirmesi için kullanıldı. Bir evrişimsel sinir ağı modeli oluşturuldu. Modelin eğitimi gerçekleştirilirken bu veriler TensorBoard'a kaydedildi. Tablo 1.'de 4 eğitim boyunca kaydedilen veriler gösterilmektedir.

Tablo 1. 4 Eğitim Boyunca TensorBoard Kaydedilen Veriler

Eğitim Sayısı	Kayıp	Kesinlik	Değer Kaybı	Değer Doğruluğu
1	0.0630	0.9162	0.2000	0.7375
2	0.0704	0.9262	0.1367	0.8250
3	0.0660	0.9036	0.1121	0.8750
4	0.0576	0.9174	0.1398	0.8500


Tablo 1.'de görüldüğü üzere eğitim sayısı arttıkça kayıp değerlerinde bir azalma meydana gelmektedir. Ayrıca değer kaybı da azalmaktadır.

Modelin eğitimi sırasında kaydedilen kayıp ve değer kaybı değerlerini çizgi grafiği olarak Şekil 13'de görselleştirilmiştir.



Şekil 13. Kayıp ve Değer Kaybı Çizgi Grafiği.

Modelin eğitimi boyunca TensorBoard'a kaydedilen kesinlik ve değer doğruluğu metrikleri çizgi grafiği olarak Şekil 14' de gösterilmiştir.



Şekil 14. Kesinlik ve Değer Doğruluğu Çizgi Grafiği.

Grafikten de anlaşılacağı üzere kesinlik değerlerinde bir artma meydana gelmiştir.

4. TARTIŞMA VE SONUÇ

Çalışmada, bilinçsizce tüketilen mantarların insan yaşamını büyük risklerle karşı karşıya bırakabileceği bilindiği için riskleri en aza indirebilmek adına kullanıcıların bilinçlendirilmesi gerektiği vurgulanmaktadır. Kullanıcılar tükettiği mantarın özelliklerini bilirse hem zararlarını hem de faydalı özelliklerini öğrenmiş olacaklardır. Bu sayede insan hayatının tehlikeye girebilecek durumları en aza indirgenmiş olacaktır.

Derin öğrenme ve yapay zekâ günümüz teknolojisinin vazgeçilmez bir parçası olmuştur. Birçok alanda kullanıldığı gibi sosyal inovasyon alanındaki uygulamalarında da başarılı sonuçlar üretmektedir. Yapay zekâ ve derin öğrenme doğru bir şekilde uygulandığında birçok alandaki uygulamalarda çok başarılı sonuçlar verebilir.

Bu çalışma, elde edilen bulgular doğrultusunda eğitilen veri setleriyle gerçekleştirilmektedir. Bulgularda meydana gelen kayıp değerlerindeki ve değer kaybındaki azalma açıkça görülmektedir. Tüm verilerin doğruluk değeri %81.75 olarak hesaplanmıştır. Ayrıca modelin eğitimi sırasındaki kesinlik ve doğruluk değerleri artmaktadır. Bu dört bulgu bu veri setinin eğitilmesindeki başarıyı açıkça göstermiştir.

Elde edilen sonuçlardan yola çıkarak, çoğaltılmış veri setinin mevcut görüntü sayısı artırıldığı takdirde mantar tespiti uygulamamızın performansında iyileşme olacağına kanaatlenmiştir.

Etik Hususlar

Etik kurallara uyum

Bu araştırmanın planlanmasından uygulanmasına, verilerin toplanmasından verinin analizine kadar olan tüm süreçte "Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi" kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan "Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler" başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir. Çalışmanın yazım sürecinde bilimsel etik ve alıntı kurallarına uyulmuş, toplanan veriler üzerinde herhangi bir tahrifat yapılmamış ve bu çalışma herhangi başka bir akademik yayın ortamına değerlendirme için gönderilmemiştir.

Finansman

Yazarlar kamu, ticari veya kâr amacı gütmeyen sektörlerdeki fon kuruluşlarından özel bir hibe alınmadığını beyan ederler.

Çıkar çatışması

Çalışma ile ilgili herhangi bir kişi veya kurumla çıkar çatışmasının bulunmadığını yazarlar olarak onaylıyoruz.

KAYNAKÇA

- [1] Alimovski, E., Erdemir, G. 2021. Veri Artırma Tekniklerinin Derin Öğrenmeye Dayalı Yüz Tanıma Sisteminde Etkisi . İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi , UAKK2020 , 76-80.
- [2] Anaconda3 (1.9.6) [Computer software].
- [3] Ari A., Hanbay D., 2018. Deep learning based brain tumor classification and detection system, Turkish J. Elect. Eng. Comput. Sci., 26: 2275–2286.
- [4] CNN mimarisi, Erişim Adresi: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>, Erişim: 19.10.2022.
- [5] Dandil, E., 2015. Mr görüntüleri ve mr spektroskopi verileri ile yapay öğrenme tabanlı beyin tümörü tespit yöntemi ve uygulaması, pp. 4-7
- [6] Doğan, F., Türkoğlu İ. 2018. Comparison of Leaf Classification Performance of Deep Learning Algorithms. Sakarya University Journal of Computer and Information Sciences, 1: 10-21.
- [7] Eryılmaz, E., Şahin, D. Ö., Kılıç, E. 2020. Türkçe İstenmeyen E-postaların Farklı Öznitelik Seçim Yöntemleri Kullanılarak Makine Öğrenmesi Algoritmaları ile Tespit Edilmesi". Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, c. 13, sayı. 2, ss. 57-77.
- [8] He, X. Zhang, S. Ren., J. Sun. 2016. Deep residual learning for image recognition. In CVPR.
- [9] Hinton, G. Deng, L. Yu, D. Dahl, G.E. Mohamed, A.-r. Jaitly, N. Senior, A. Vanhoucke, V. Nguyen, P., Sainath, T.N. 2012. Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. IEEE Signal Processing Magazine, 29: 82-97.
- [10] JetBrains PyCharm (2018.3.2) [Computer software]
- [11] Karaaslan, Y.S. (2023,14 Haziran). Mantardan zehirlenen genç kız karaciğer nakliyle hayata döndü. aa.com.tr
- [12] Keras, <https://machinelearningmastery.com/introduction-python-deep-learning-library-keras/>, erişim tarihi sürekli.
- [13] Keras , <http://linkedin.com/in/fchollet>, erişim tarihi sürekli.
- [14] Keras , <http://keras.io> , erişim tarihi sürekli.
- [15] Muradli, F. 2021. Derin öğrenme kullanılarak görüntülerden insan duruş tespiti. acikerisim.sakarya.edu.tr
- [16] Neden TensorFlow. (accessed May 19, 2021). <https://www.tensorflow.org/about?hl=tr>
- [17] Pekşen, A. Mantar Zehirlenmeleri ve Başlıca Zehirli Mantarlar. ordu.tarimorman.gov.tr
- [18] Python (3.6) [Computer software]
- [19] Serbest, K., Aktürk, S. 2022. Nesne Tespiti İçin Derin Öğrenme Kütüphanelerinin İncelenmesi. Journal of Smart Systems Research 3(2), 97-119.
- [20] Simonyan, K., Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv Prepr arXiv14091556.
- [21] Simonyan, K. ve Zisserman, A.(2015). Very Deep Convolutional Networks For Large-scale Image Recognition. ICLR.
- [22] TensorFlow Lite | Mobil ve Uç Cihazlar için Makine Öğrenimi. (accessed May 19, 2021). <https://www.tensorflow.org/lite/?hl=tr>
- [23] Türkoğlu, M., Hanbay, K., Saraç Sivrikaya, I., Hanbay, D. 2020. Derin Evrimsel Sinir Ağı Kullanılarak Kayısı Hastalıklarının Sınıflandırılması. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 9: 334-345.
- [24] VGG16 mimarisi, Erişim Adresi: <http://www.cs.toronto.edu/~frossard/post/vgg16/>, Erişim: 19.10.2022.
- [25] Wahab, A., Elshawi, R., Barnawi, A., Sakr, S. 2021. DLBench: a comprehensive experimental evaluation of deep learning frameworks, Clust. Comput. J. Networks, Softw. Tools Appl., p. 1, doi: 10.1007/s10586-021-03240-4.

(Derleme Makalesi)**Parola Saklama Tekniklerinin Evrimi ve Güncel En İyi Uygulamaları****Tuğberk KOCATEKİN*¹**

¹İstanbul Arel Üniversitesi, Mühendislik-Mimarlık Fakültesi, Yazılım Mühendisliği Bölümü, Büyükçekmece, İstanbul,
ORCID No : <http://orcid.org/0000-0001-6171-0135>

Anahtar Kelimeler:

Özetleme,
Tuzlama,
Anahtar Türetme Fonksiyonları,
Şifreler

Özet: Parolalar tarihsel olarak erişim kontrolü ve kimlik doğrulama için kilit bir öneme sahip olmuşlarsa da, güvenlikleri bugünün dijital dünyasında tekrar eden bir endişe olarak kalmaktadır. Yüksek profilli veri ihlalleri ve güvenlik açıklarıyla kanıtlandığı gibi, güvenli parola saklama her zaman en üst düzeyde önemli olmasına rağmen, genellikle başarılı olunamamıştır. Kullanıcılar güçlü ve akılda kalıcı parolalar oluşturma konusunda uğraşırken, parolaların güvenli bir şekilde saklama sorumluluğu da hizmet sağlayıcılara düşmektedir. Alternatif kimlik doğrulama mekanizmaları ortaya çıkmış olmasına rağmen, parola tabanlı kimlik doğrulama yaygın olarak kullanılmaya devam etmektedir. Araştırmalar, yazılım geliştiricilerin parola saklama güvenliği konusunda yanılırlara ya da ihmalkarlığa düştüğünü göstermektedir. Bu makale, Crypt ile başlayıp Parola Özetleme Yarışması'nın kazananı Argon2d'de son bulan parola saklama yöntemlerinin ilerleyişini izlemektedir. Dört adet modern parola saklama sistemleri hakkında bilgi vererek bu bilgi boşluğunu kapatmayı, daha iyi uygulamalar için savunma yapmayı ve güvenliği işlevsellikle birlikte önceliklendirme önemini aydınlatmaya çalışmaktadır.

(Review Article)**Evolution and State of the Art in Password Storage****Keywords:**

Hashing,
Salting,
Key Derivation Functions,
Passwords

Abstract: Passwords have historically been pivotal for access control and authentication, yet their security remains a recurring concern in today's digital world. As evidenced by high-profile data breaches, secure password storage has always been paramount, but often not achieved. While users grapple with the creation of strong, memorable passwords, the burden also falls on service providers to store these passwords securely. Even though alternative authentication mechanisms have emerged, password-based authentication remains pervasive. Surprisingly, studies highlight that developers frequently exhibit misconceptions or negligence towards password storage security. This paper traces the progression of password storage methods by explaining four password hashing methods. By informing of four modern password storage systems, this work seeks to bridge the knowledge gap, advocating for better practices and illuminating the significance of prioritizing security alongside functionality.

1. INTRODUCTION

Passwords are widely used for authenticating ourselves to reach sensitive information. It is known that poor password practices end up with being exploited and expose private information about users. Although password security is just a component of a system's security, it is essential [1]. In the recent years, both Sony and LinkedIn were hacked and user information was published [2], [3]. In addition, there are local breaches that

are known such as Yemeksepeti [4]. It should be noted that it is also possible there are some attacks which are not even known to public. These data breaches have both monetary and non-monetary effects on companies. For example, it was calculated that data breach on Sony had a direct cost exceeding 150M US dollars and combined with the brand damage, it exceeded 1B US dollars [5], [6]. Choosing a right password is very important for users. If the user lacks a strong password, attackers can easily guess the user password regardless of the security of services. They may have to use and memorize multiple

passwords. Password managers are such software which aims to solve this problem. However, it doesn't end there. Service providers and applications also needs to keep their security in check. It is also known that several vulnerabilities are found in the service providers [7].

There are difference schemes to use for authentication other than using passwords, but it is still one of the most common ways for authentication. There are several studies showing that developers are still asking a lot of questions about passwords and password storage online and password storage is one of the most popular areas in security [8]. Apart from these, there are a lot of studies showing that developers are having a hard time to store passwords in a secure way [9]. Although many developers are working in a group setting and it would be expected that it would be more secure, number of developers working alone cannot be dismissed [10]. It is also safe to say that developers are not prioritize security [10] and put functionality above security [11].

Hallett et al. [9] conducted an experiment with 138 developers and asked them to write code to store password in whatever language they want. Half of them were asked to write a specification before writing the code and the other half were asked to write code immediately. It turned out that although they were confident in themselves, they failed to store passwords in a secure manner. Only 38% used hashing algorithms and only 14% used salting while storing passwords. Naiakshina et al. have several studies on how developers approach security [11], [12]. First, he did a study on 20 computer science students and gave the task of password storage. The outcome of the study was that students consider functionality before security. Unless the students are primed to consider security, they didn't. Even those who were primed, they could not meet the standards of the time [11]. Examples above show that there is a lack of knowledge on password storage. This study aims to inform users by giving knowledge about modern password storage systems and their comparisons.

2. MATERIALS AND METHODS

2.1. Types of attacks

Password guessing attacks can be classified into three categories: brute-force attacks, dictionary attacks and rainbow tables [13]. Although all of them are explained, throughout the paper; password cracking refers specifically to brute force and dictionary attacks.

2.1.1. Brute-force attacks

Brute-force attacks are generally applied to the hashed values of the passwords to get the original plaintext. These attacks are CPU-intensive and therefore time-consuming [14]. In brute-force attacks, the attacker is trying every possible combination of the available characters. For example, if a password of eight digits is being attacked, the attack will start by typing "aaaaaaa", "aaaaaaab" and

increment to "zzzzzzz" [15]. There are also several configurations to adjust the character set based on the data set. Attacker can choose the character set as numeric-only, alphanumeric and alike.

2.1.2. Dictionary attacks

Studies show that users tend to select easy to remember and predictable passwords [16]. Password leaks show us that they use common names and surnames, pet names, band names, sports team names, etc. [17]. These phrases are combined together alongside with the password obtained from recent-leaks to create a list of passwords, also called a dictionary. Instead of trying all possible combinations of characters, words from these dictionaries are used to crack passwords. There are four types of dictionary attacks [13]: i) pure, ii) Probabilistic Context Free Grammar (PCFG) based [18], iii) Markov model based [19] and iv) mangling rules [20]. In pure type, attacker is just using a simple dictionary. In second, dictionary is constructed by using PCFG theories and it contains modified passwords with assigned probabilities. In the third type, Markov based models are applied based on the probability distribution over sequences of characters to create new passwords [19]. Finally in the last type, rules are applied to words in the dictionary and generate new highly likely passwords such as combination of multiple words, mixed letter cases and leet speak [21].

2.1.3. Rainbow tables

Cryptographic hash functions are not reversable. Therefore, attackers cannot reverse the hash to get the original password. However, attackers may use precalculated tables for hash lookup. These tables are called rainbow tables. When the attacker has access to the database where the passwords are hashed instead of plaintext, attacker can use rainbow tables to search for hash values to find the original password. However, it should be noted that rainbow tables are not usable for salted passwords, multiple hashes, or combination of several hash functions [22].

2.2. Cryptographic hash functions

Generally, a hash function is used to compress (index) arbitrary-length strings into shorter strings, in order to achieve $O(1)$ insertion and lookup times for a set of elements. However, as the amount of data increases, possibility of having a collision also increases. That is why regular hash functions are not good candidates to use in cryptography.

A good hash function has to supply a unique output for every possible input to minimize the possibility of collision. Those kind of hash functions are called collision-resistant hash functions. Designing those are not as easy as creating a regular hash function, where the only purpose is to index files as a data structure. However, in order to use hash functions in cryptography, collision-


resistance is one of the key goals and therefore they have a more advanced design [23]. It should be noted that although every cryptographic hash function is a hash function, not every hash function can be called as cryptographic hash function.

According to Katz and Lindell [23], there are three levels of security when considering a cryptographic hash function: collision resistance, second pre-image resistance and preimage resistance. • Collision resistance: It should be computationally infeasible to find a pair of different input values (m, m') to have the same digest. • Second pre-image resistance: It should be computationally infeasible to find a message m' , to hash to the same output as message m . • Pre-image resistance: It should be computationally infeasible to find a message m' , which hashes to a specific output, $y = H(m)$. Here, if a hash function is collision resistant, it is also preimage resistant; because if there is a second preimage, then that means there is a colliding pair. A pre-image resistant function is called a one-way function, since it is difficult to inverse it.

One-way function means that there is no inverse on that function, meaning that one cannot find message m by looking at the digest y , where $H(m) = y$. That is why cryptographic hash functions are used in several information security areas such as digital signatures, message authentication codes, fingerprinting, checksums, and many more [24], [25], [26].

2.2.1. Salting

It is possible that multiple users can have the same password. If this is the case, the hashed values are going to be the same. This can easily be a security problem. It is also possible that these passwords can be used in other services. In order to solve this problem, a random value (salt) is concatenated with the password in the registration process and the instead of just giving the password to the hash function, the system now gives salt+password to it [27]. Therefore, even if multiple users are using the same password, the hash value would be different because the password has a unique salt concatenated to it (see Figure 1). In addition to this, since one or more systems are going to be using different salts, salting makes it impossible for an attacker to find out whether a person is using the same password on two or more systems [1]. Salting also provides security against the usage of rainbow tables [28] and dictionary attacks [29], [30].



2.2.2. Key derivation functions

Key derivation functions (KDF) aim to produce one or more secret keys from a secret value such as passwords.

They derive cryptographic keys of desired length from passwords. They are usually implemented by secure cryptographic hash functions or HMACs [27]. PBKDF2 [31], scrypt [32] and argon2 [33] are examples to KDFs.

Password-based key derivation functions are mainly used for these two purposes: hashing passwords and creating cryptographic keys [34]. Key derivation functions use secure hashes to provide password hashing and therefore is strong against key derivation attacks. However, it is possible for attackers to apply a brute-force attack to get the output.

2.2.3. Key stretching

Ordinarily, passwords are chosen to be 8 characters (8 bytes). Since it is low-entropy, it is susceptible to exhaustive search attacks where the attacker is trying every possible combination until they find the password [27]. Key stretching is the typical method for protection of such attacks. The term *key stretching* was first used by Kelsey et al. in 1997 [29]. The aim is to increase the entropy of a low-entropy key by adding bits to it and thus increase the time required for a brute-force attack. With key stretching, low-entropy s -bit keys are converted into a longer $s + t$ bit keys and the difficulty of a brute-force attack is increased to 2^{s+t} operations instead of 2^s . It also makes exhaustive searching more expensive for the attacker [28]. However, this process also slows down the user login process, therefore key stretching should be limited to the user's tolerance [27].

2.3. Password hashing schemes

The easiest way to store passwords in a database is by storing them as plaintext. Wilkes [35] observed that storing passwords as plaintext is insecure. If the database is compromised, the attacker can see the passwords easily. In addition, even there is no attacker, people who has access to database can also see passwords. However, one was able to find systems storing passwords as plaintext until the recent years.

2.3.1. Password hashing

The passwords were stored as plaintext in the filesystem in the early versions of Unix operating systems. This made it very hard for system administrators to adjust read and write permissions in order to provide security for password files. After an incident where the password file became visible to everyone due to a software design error, Morris and Thompson decided to solve the password storage problem. They are credited as the first ones with the idea of storing passwords by using a one-way function and storing the output instead of the original password [1]. This algorithm was called Crypt and it was based on Data Encryption Standard (DES) algorithm.

Crypt was a very important breakthrough for password storage. Before that, the standard was storing the passwords as plaintext and it was known to be insecure [35]. With Crypt, a minimum-security standard for

password storage emerged. After that, storing hash values instead of plaintext became a standard [28]. Other important contributions of Crypt are adopting key stretching and usage of salts. It is based on DES and works on encrypting the password instead of hashing it. However, it is used as a hash function [28].

Password hashing is applying a moderately-hard function to a password or a password concatenated with salt. Resulting output is the password hash and is stored in the database instead of storing the password as plaintext. This way, even if the database or file containing the password is compromised, a brute-force attack will be costly for the attacker [36]. Additional approach can be applying the hash function multiple times. This does not present any problem for the user, but it creates a time-consuming task for the attacker. However, evolution of Moore's law led to production of faster gates and units. Nowadays, GPUs can compute billions of instructions in a second, it has become easier for attackers to run cryptographic hash functions such as SHA1, MD5, etc. Mishra and Janarthanan [37] showed that GPUs accelerate the cracking process compared to CPU implementation by launching comprehensive search attacks on password hashing schemes. Therefore, using cryptographic hash functions by themselves are not considered as secure anymore [11].

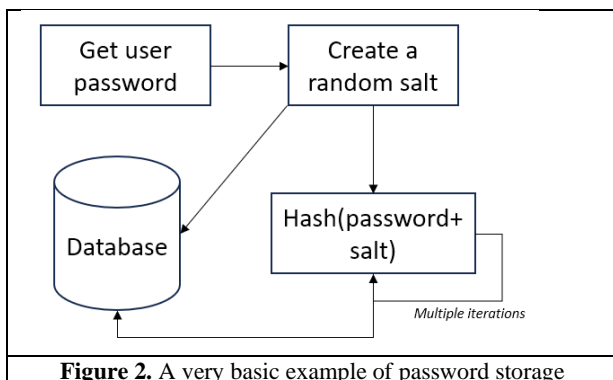


Figure 2. A very basic example of password storage

2.4. Standards

Since GPU's are improved a lot and can run billions of instructions per second [38], one-way hash functions can be calculated very quickly. For these reasons, new and more computationally intensive password hashing schemes are proposed such as PBKDF2 [39], bcrypt [40] and scrypt [32].

In 2013, because of limited set of solutions, cryptographic community announced Password Hashing Competition (PHC) with the purpose of providing a better solution to password hashing problem [27]. Out of the initial 22 candidates, Argon2 ended up being the winner. NIST (National Institute of Standards and Technology) published Digital Identity Guidelines in 2017, with a recent update in 2020 [41]. In addition to many recommendations about password creation and authentication, it also provides guidelines on secure password hashing. They recommended storing passwords

in such form that they are resilient to offline attacks. For this reason, they stated that passwords must be salted and hashed by using a suitable one-way key derivation function such as PBKDF2 and Balloon [42] using an approved one-way function such as HMAC [25], and approved hash function such as SHA3 [43].

2.4.1 bcrypt

Bcrypt was designed by Provos and Mazieres in 1999 as an improvement to the present password schemes [40]. In their study, they presented two algorithms, eksblowfish and bcrypt. Eksblowfish is a block cipher with a purposefully expensive key schedule, and bcrypt is the password hash function related to it.

Bcrypt algorithm gets three parameters as input: cost, salt and key. Cost parameter is used to change the cost of computation. Salt is a random 128-bit value. It is chosen randomly in order to create a different output even if the key is the same. Key is the user-chosen password which is used to encrypt a specific 192-bit plaintext (OrpheanBeholderScryDoubt) and it can be up to 72 bytes. It produces a 192-bit hash as output.

Eksblowfish is a variable cost and salted block cipher based on Blowfish algorithm [40]. Blowfish is a 64-bit block cipher [44]. It is free and resides in public domain, where everyone can use freely. Authors replaced the key setup to be able to control the speed of the function. Therefore, by adjusting the cost, it can render one of the most common offline attacks (dictionary attack) unfeasible. The user can increase the cost as much as they want as long as it is tolerable by the users.

In short, *Bcrypt* is a password-hashing function based on Blowfish cipher. It is not a key derivation function because the output is fixed. It is the output of encrypting OrpheanBeholderScryDoubt 64 times using Blowfish cipher and presents the end result as the hash. It is also used as the default password hashing scheme for the BSD operating system.

2.4.2. PBKDF2: Password based key derivation function 2

First and foremost, PBKDF2 is a key derivation function. The aim is to provide cryptographic keys for encryption algorithms by using the user-chosen passwords. PBKDF2 was chosen as a good key derivation function and was mentioned in NIST documents [45]. It was also used in Blackberry and IOS systems [46]. It is also used in TrueCrypt, WPA2, WinRAR [47] and many more.

PBKDF2 introduces CPU-intensive operations which are intentionally designed to take more time to compute by applying key stretching [31]. This helps by providing better resistance for brute-force attacks by increasing the computation time by iterating the hash of the salted passwords multiple times [48], [29]. Random salts are used to provide different keys from the same password and the iteration count is used to call the pseudorandom

function. PBKDF2 requires four inputs: a user password pwd , a salt S , desired output length k_{len} and an iteration counter c .

NIST recommends the iteration count should be as high as possible unless there are performance problems, and stated that 10.000 iterations are the minimum number of iterations [41]. However, Blocki et al. [49] stated that PBKDF2-SHA256 with 100.000 iterations is not enough to provide secure user password storage. They also stated that memory hard functions like scrypt [32] and argon2 [33] would provide better protection compared to PBKDF2. In addition, since PBKDF2 does not take memory into account, it is vulnerable to parallel attacks [27]. This vulnerability is important to note as processors are getting faster and cheaper, the number of parallel attacks is expected to rise.

2.5. Memory hard functions

With constant improvement in technology, we expect that processors are going to be faster and smaller. Although using iteration count in key derivation functions helps us to cope with the increasing speed of processors, attackers would be able to store more processing power in a given space. This would allow attackers to have more parallelism with the same cost. It means that in time, the iteration count must be increased to keep the information secure from the attackers because their computation power will increase. However, not only that, attackers are going to be able to store more processors in a given space with the same cost and will have highly parallel circuits. That means that in time, CPU intensive security will be disadvantageous to brute-force attacks [34].

Although Kelsey et al. [29] stated that using moderately large amounts of RAM would make hardware attacks more expensive, before Percival's work [34] introducing a sequential memory-hard algorithm **scrypt**, such functions used only constant memory.

2.5.1. scrypt

Scrypt is a password-based key derivation function created by Colin Percival in 2009 for the Tarsnap online backup service [32]. He introduced the concept of memory-hard algorithm and a sequential memory-hard function.

It was specifically designed to require large amounts of memory so that it would be costly to perform custom hardware attacks to it. It is widely used in proof-of-work schemes for well-known cryptocurrencies such as Litecoin and Dogecoin [36]. Since it is memory-intensive, it reduces the risk of brute-force attacks by making them more expensive computationally. Therefore, it is a good option for password hashing and therefore used in password storage.

As input, scrypt takes a passphrase P , a salt S , and parameters N , p , and $dkLen$. These are CPU/Memory cost parameters, parallelization parameter and the output length in octet respectively. It then generates a derived

key DK with output of length $dkLen$ octets to be used as a cryptographic key.

First, it uses PBKDF2 with SHA256 and generates p blocks of octets from the provided password and salt. Generated blocks are mixed by a mixing function in order to make the computation expensive. Lastly, the result is used as salt for another PBKDF2 computation to get the final result. However, it is vulnerable to attacks such as cache-timing and garbage-collector attacks [50], [51].

2.5.2. Argon2

Argon2 is the next generation of memory hard hash function Argon [33]. It became the winner of the Password Hashing Competition (PHC) out of 24 submitted projects and became the standard for password storage. It is the state of the art in memory-hard functions for password storage. It is optimized for x86 architecture and exploits the cache and memory organization of the recent Intel and AMD processors [52].

It has two flavors: Argon2d and Argon2i. Argon2i is more suitable to use for password storage because it uses data-independent memory access and therefore preferred for password hashing and password-based key derivation [53]. Being slower compared to Argon2d helps provide better security from tradeoff attacks. It is slower because it uses the memory at a speed of two processor cycles per byte [54]. Argon2d on the other hand uses data-dependent memory access and is better suited for applications such as backend servers and cryptocurrencies, where side-channel attacks are not a threat [55].

Argon2 has two types of inputs: primary and secondary inputs. Primary inputs are the message P as password with length between 0 and $2^{32} - 1$ bytes; and a nonce S as a salt for password hashing with length between 8 and $2^{32} - 1$ bytes. Secondary inputs are not mandatory, but they are as follows: a degree of parallelism p , tag length ρ , memory size m , number of iterations t , version number v , a key K , associated data X and type(mode) as y [52].

3. DISCUSSION AND CONCLUSION

Although there are a lot of downsides to it, passwords are still the primary way to authenticate users with various systems. They are usually stored in the database in hashed form. When attackers compromise the database, they apply dictionary and brute-force attacks to crack these hashes. They are often successful because passwords have low-entropy. With the emergence of Crypt, developers started to add salt values and use one-way hash functions to passwords to make them secure against these types of attacks.

Computers are rapidly advancing, leading to quicker computation of hash algorithms. To combat this, hash functions are iterated numerous times. But this isn't without its issues. As GPU technology advances, CPU-intensive calculations aren't as secure. Attackers migrated to new architectures such as FPGAs, GPUs, dedicated

ASIC modules [33]. A solution to this problem was memory-hard functions [34], like scrypt which require a large amount of memory and therefore making it costlier for attackers [49].

Table 1. Comparison of password storage algorithms

Algorithm	Iterations	Key Length	Speed	Security	Highlights
Bcrypt	Configurable ($\geq 4,000$)	192	Moderate	Strong	Resistant to rainbow tables (salt)
Scrypt	Configurable	Varied Length	Slow	Very strong	Memory hard
Argon2	Configurable	Varied Length	Slow	Very strong	Memory hard
PBKDF2	Configurable ($> 10,000$)	Varied Length	Moderate	Strong	Very popular and widely used

This research delves into the criticality of safe password storage and various methods, ranging from less secure to highly secure techniques. Given NIST's recommendation of key derivation functions, we shed light on their purpose and application in password storage.

Recent studies advocate for the use of memory-hard functions [11]. However, it's essential to note that not all systems are updated regularly. This paper serves as a guide for those still using older security measures to protect user credentials. It's very important for system admins to regularly upgrade their security, considering the evolving threats.

To conclude, considering past studies that indicate developers' limited understanding of secure password storage [9, 10, 11], our research aims to educate readers on the current best practices for password storage.

Ethical Considerations

Compliance with ethical guidelines

Funding

No funding.

Conflict of interest

There is no conflict of interest.

REFERENCES

- [1] Morris, R., Thompson, K. 1979. Password Security: A Case History, *Communications of the ACM*, 22(11), 594-597.
- [2] Goode, S., Hoehle, H., Venkatesh, V., Brown, SA. 2017. User Compensation as a Data Breach Recovery Action, *MIS Quarterly*, 41, 703–A16.
- [3] Gibbon, B., Townes, S., Lewis, D., Bhunia, S. 2021. Vulnerability in Massive Api Scraping: 2021 linkedin data breach, 2021 International Conference on Computational Science and Computational Intelligence (CSCI).
- [4] webteknohaber. 2021. Yemeksepeti Hacklendi: Kullanıcıların Hesap Bilgileri Ele Geçirildi, 27 Mart 2021. Available: <https://www.webtekno.com/yemeksepeti-kullanici-veri-tabani-siber-saldiri-h108027.html>.
- [5] Hachman, M. 2011. PlayStation Hack to Cost Sony \$171M; Quake Costs Far Higher, 23 May 2011. [Çevrimiçi]. Available: <https://news.yahoo.com/playstation-hack-cost-sony-171m-quake-costs-far-163824525.html?guccounter=1>.
- [6] Sherr, I., Wingfield, N. 2011. Play by Play: Sony's Struggles on Breach, 7 May 2011. [Çevrimiçi]. Available: <https://www.wsj.com/articles/SB10001424052748704810504576307322759299038>.
- [7] Hatzivasilis, G. 2020. Password Management: How Secure Is Your Login Process?, *International Workshop on Model-Driven Simulation and Training Environments for Cybersecurity*.
- [8] Yang, X.-L., Lo, D., Xia, X., Wan, Z.-Y., Sun, J.-L. 2016. What Security Questions Do Developers Ask? A Large-Scale Study of Stack Overflow Posts, *Journal of Computer Science and Technology*, 31, 910–924.
- [9] Hallett, J., Patnaik, N., Shreeve, B., Rashid, A. 2021. "Do this! Do that!, And Nothing Will Happen" Do Specifications Lead to Securely Stored Passwords?, 2021 IEEE/ACM 43rd International Conference on Software Engineering (ICSE).
- [10] Van Der Linden, D., Anthonysamy, P., Nuseibeh, B., Tun, T. T., Petre, M., Levine, M., Towse, J., Rashid, A. 2020. Schrödinger's Security: Opening the Box on App Developers' Security Rationale, *Proceedings of the ACM/IEEE 42nd International Conference on Software Engineering*, 2020.
- [11] Naiakshina, A., Danilova, A., Tiefenau, C., Herzog, M., Dechand, M., Smith, M. 2017. Why do Developers Get Password Storage Wrong? A Qualitative Usability Study, *Proceedings of the 2017 ACM SIGSAC Conference on Computer and Communications Security*, 2017.
- [12] Naiakshina, A., Danilova, A., Gerlitz, E., Von Zezschwitz, E., Smith, M. 2019. If You Want, I Can Store The Encrypted Password a Password-Storage Field Study with Freelance Developers, *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems*, 2019.
- [13] Christoforos Ntantogian, S. M. C. X. 2019. Evaluation of Password Hashing Schemes in Open Source Web Platforms, *Computers & Security*, 206-24.

- [14] Raza, M., Iqbal, M., Sharif, M., Haider, W. 2012. A survey Of Password Attacks and Comparative Analysis on Methods for Secure Authentication, *World Applied Sciences Journal*, 19(4), 439-444.
- [15] Kyaw, A. K., Sioquim, F., Joseph, J. 2015. Dictionary attack on Wordpress: Security and Forensic Analysis, 2015 Second International Conference on Information Security and Cyber Forensics (InfoSec), Cape Town, 2015.
- [16] Bošnjak, L., Sreš, J., Brumen, B. 2018. Brute-force and Dictionary Attack On Hashed Real-World Passwords, 2018 41st International Convention on Information and Communication Technology, Electronics And Microelectronics (Mipro), Opatija, 2018.
- [17] Zviran, M., Haga, W. J. 1999. Password Security: an Empirical Study, *Journal of Management Information Systems*, 15(4), 161-185.
- [18] Matt Weir, S. A. B. d. M. B. G. 2009. Password Cracking Using Probabilistic Context-Free Grammars, 30th IEEE Symposium on Security and Privacy, 2009.
- [19] Arvin Narayanan, V. S. 2005. Fast Dictionary Attacks on Passwords Using TimeSpace Tradeoff, Proceedings of the 12th ACM Conference on Computer and Communications Security, Virginia, 2005.
- [20] Marechal, S. 2012. Automatic Mangling Rules Generation, December 2012. [Çevrimiçi]. Available: <https://www.openwall.com/presentations/Passwords12-Mangling-Rules-Generation/Passwords12-Mangling-Rules-Generation.pdf>. [Erişildi: 25 09 2023].
- [21] Briland, H., Paolo, G., Giuseppe, A., Fernando, P.-C. 2017. PassGAN: A Deep Learning Approach for Password Guessing, *CoRR*, 2017.
- [22] Josef Horálek, F. H. O. H. L. P. V. S. 2017. Analysis of the Use of Rainbow Tables to Break Hash, *Journal of Intelligent & Fuzzy Systems*, 1523-1534.
- [23] Katz, J., Lindell, Y. 2020. Introduction to Modern Cryptography, CRC press, 2020.
- [24] Merkle, R. C. 1987. A Digital Signature Based on a Conventional Encryption Function, Conference on the theory and application of cryptographic techniques.
- [25] Krawczyk, H., Bellare, M., Canetti, R. 1997. HMAC: Keyed-hashing for Message Authentication.
- [26] Oostveen, J., Kalker, T., Haitsma, J. 2002. Feature Extraction and A Database Strategy for Video Fingerprinting, Recent Advances in Visual Information Systems: 5th International Conference, VISUAL 2002 Hsin Chu, Taiwan, March 11–13, 2002 Proceedings 5, 2002.
- [27] Hatzivasilis, G., Papaefstathiou, I., Manifavas, C. 2015. Password Hashing Competition-Survey and Benchmark, *Cryptology ePrint Archive*.
- [28] Forler, C., Lucks, S., Wenzel, J. 2013. Catena: A Memory-Consuming Password-Scrambling Framework, *Cryptology ePrint Archive*.
- [29] Kelsey, J., Schneier, B., Hall, C., Wagner, D. 1997. Secure Applications of Low-Entropy Keys, International Workshop on Information Security.
- [30] Abadi, M., Lomas, T. M., Needham, R. 1997. Strengthening passwords, Digital Equipment Corporation Systems Research Center [SRC].
- [31] Ertaul, L., Kaur, M., Gudise, V. A. K. R. 2016. Implementation and Performance Analysis of Pbkdf2, Bcrypt, Scrypt Algorithms, Proceedings of the international conference on wireless networks (ICWN).
- [32] Percival, C., Josefsson, S. 2016. The Scrypt Password-Based Key Derivation Function.
- [33] Biryukov, A., Dinu, D., Khovratovich, D. 2015. Argon 2 : The Memory-Hard Function For Password Hashing and Other Applications.
- [34] Percival, C. 2009. Stronger Key Derivation Via Sequential Memory-Hard Functions, BSDCan.
- [35] Wilkes, M.V. 1968. Time-Sharing Computer Systems. MacDonald Computer Monographs, American Elsevier Publishing Company.
- [36] Alwen, J., Chen, B., Pietrzak, K., Reyzin, L., Tessaro, S. 2017. Scrypt is Maximally Memory-Hard, Annual International Conference on the Theory and Applications of Cryptographic Techniques.
- [37] Mishra, J. K., Janarthanan, M. 2022. GPU-based Security Of Password Hashing In Cloud Computing, *Materials Today: Proceedings*, 60, 939–944.
- [38] Orman, H. 2013. Twelve Random Characters: Passwords In The Era Of Massive Parallelism, *IEEE Internet Computing*, 17, 91–94.
- [39] Kaliski, B. 2000. PKCS# 5: Password-based cryptography Specification version 2.0.
- [40] Provos, N., Mazieres, D. 1999. A future-Adaptable Password Scheme., USENIX Annual Technical Conference, FREENIX Track.
- [41] Grassi, P., Garcia, M., Fenton, J. 2020. Digital Identity Guidelines.
- [42] Boneh, D., Corrigan-Gibbs, H., Schechter, S. 2016. Balloon Hashing: A Memory-Hard Function Providing Provable Protection Against Sequential Attacks, Advances in Cryptology–ASIACRYPT 2016: 22nd International Conference on the Theory and Application of Cryptology and Information Security, Hanoi, Vietnam, December 4-8, 2016, Proceedings, Part I 22.
- [43] Kelsey, J., Chang, S.-j., Perlner, R. 2016. SHA-3 Derived Functions: cSHAKE, KMAC, TupleHash, and ParallelHash, NIST special publication, 800, 185.
- [44] Schneier, B. 1993. Description of a New Variable-Length Key, 64-Bit Block Cipher (Blowfish), International Workshop on Fast Software Encryption.
- [45] Turan, M. S., Barker, E., Burr, W., Chen, L. 2010. Recommendation for Password-Based Key Derivation, NIST special publication, 800, 132.
- [46] Smartphone forensics: cracking blackberry.
- [47] Chen, J., Zhou, J., Pan, K., Lin, S., Zhao, C., Li, X. 2013. The Security of Key Derivation Functions in WINRAR., *J. Comput.*, 8, 2262–2268.
- [48] Visconti, A., Mosnáček, O., Brož, M., Matyáš, V. 2019. Examining PBKDF2 security margin—Case study of

- LUKS, Journal of Information Security and Applications, 46, 296–306.
- [49] Blocki, J., Harsha, B., Zhou, S. 2018. On the economics Of Offline Password Cracking, 2018 IEEE Symposium on Security and Privacy (SP).
- [50] Forler, C., Lucks, S., Wenzel, J. 2014. Memory-Demanding Password Scrambling, Advances in Cryptology – ASIACRYPT 2014, Berlin.
- [51] Forler, C., List, E., Lucks, S., Wenzel, J. 2015. Overview of the Candidates for the Password Hashing Competition, Technology and Practice of Passwords, Cham.
- [52] Polasek, V. 2019. Argon2 Security Margin for Disk Encryption Passwords.
- [53] Biryukov, A., Dinu, D., Khovratovich, D. 2016. Argon2: New Generation Of Memory-Hard Functions For Password Hashing and Other Applications, 2016 IEEE European Symposium on Security and Privacy (EuroS&P).
- [54] Duka, M. 2020. Elliptic-curve Cryptography (ECC) And Argon2 Algorithm in Php Using Openssl and Sodium Libraries, Informatyka, Automatyka, Pomiary w Gospodarce i Ochronie Środowiska, 10, 91-94.
- [55] Wetzels, J. 2016. Open Sesame: The Password Hashing Competition And Argon2.

(Araştırma Makalesi)**İşaret Yayıcı ve Akıllı Telefon Destekli Öğrenci Yoklama Otomasyonu****Muammer AKÇAY*¹, Aykut ALTAY²**¹Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No: 0000-0003-0244-1275.²Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID No: 0009-0009-1425-8380.**Anahtar Kelimeler:**BLE işaretçi,
Mobil Programlama,
Web Programlama,
Öğrenci yoklama,
Dağıtık sistemler

Özet: Bluetooth düşük enerji teknolojisine sahip işaretçi (BLE beacon) cihazlarının düşük enerji tüketimi ve işletim sistemi desteği nedeniyle kullanımı hızla artmaktadır. Akıllı cihazlar işaretçi cihazların konumlandırıldıkları alana geldiklerinde, mobil uygulama tarafından algılanabilmektedir. Bu özelliği nedeniyle uzaklık ve yakınlığa duyarlı birçok uygulama geliştirilebilir. Bizim amacımız, işaretçilerin özellikleri ile etkileşime geçen mobil uygulama ile gerçekleştirilen öğrenci yoklama sistemi sunmaktır. Bu amaçla Android temelli bir mobil uygulama geliştirilmiştir. Geliştirilen sistem kullanıcıların işaretçiler ile etkileşimde bulunduğu konum ve süreye göre katılımlarını takip etmeyi sağlamaktadır. Sonuç olarak öğrenci yoklama takip işlemi daha kolay ve daha pratik hale gelerek öğrencinin hangi saatte sınıfta olduğu ve hangi saatte ayrıldığı izlenebilecektir.

(Research Article)**Signal Supported and Intelligent Telephone Supported Student Application Automation****Keywords:**BLE pointer,
Mobile Programming,
Web Programming,
Student polling,
Distributed systems

Abstract: Use of Bluetooth low energy beacon (BLE beacon) devices are rapidly increasing due to the low energy consumption and support of the operating system. Smart devices can be detected by mobile application when they arrive at the area where the pointer devices are located. Because of this feature, many distance and proximity sensitive applications can be developed. Our goal is to provide a student polling system with the mobile application that interacts with the markers' features. For this purpose, an Android based mobile application has been developed. The developed system allows tracking the attendance of the users according to the location and duration of the interaction with the beacons. As a result, the student attendance tracking process will become easier and more practical, and it will be possible to monitor at what time the student is in the classroom and at what time he/she leaves.

1. GİRİŞ

Öğrencilerin ders devamlılığının izlenmesi, öğretim üyesinin zaman kazanması ayrıca ders başarısının artırılması için de etkin bir çalışmadır. Ders devamlılığının kontrolü öğretim üyesi tarafından hızlıca yapılsa bile toplamda bu kontrol önemli bir zaman kaybına yol açar. Bilgisayar ve otomasyon teknolojisindeki gelişmeler sayesinde günümüzde bilgisayarlı kontrol sistemleri yaygın olarak kullanılmaktadır.

Bu çalışmalarda ders devam kontrollerinin kolaylaştırılması için güncel bir teknoloji olan BLE işaretçi ve akıllı telefonlardan yararlanarak geliştirilen bir öğrenci yoklama sistemi sunulmaktadır. Geliştirilen sistem katılım süresinin saat bazında tam olarak belirlenmesi, yoklama işlemi için harcanan sürenin kısaltılması gibi birçok avantaj sunmaktadır. Bununla birlikte kullanıcıların BLE teknolojisini destekleyen mobil cihazlara sahip olma zorunluluğu, sistemin bir dezavantajı olarak göze çarpmaktadır.

RFID ile kapı kontrolü [1], parka yeri uygulaması [2], nesnelerin takibi [3] ve radyo frekansı ile kimlik tanıma sistemleri [4] tasarlanmıştır. Beacon ile ise nesnelerin interneti çalışması [5], ilgili internet kaynakları [6-9] ve yoklama takip gibi yapılan çalışmalar [10-17] verilmiştir.

2. MATERYAL VE METOT

İşaretçi (Beacon) cihazlar, Bluetooth 4.0 ya da Bluetooth smart olarak da bilinen BLE teknolojisi ile donatılmış, düşük güçlü ve düşük maliyetli elektronik vericilerdir (Şekil 1).



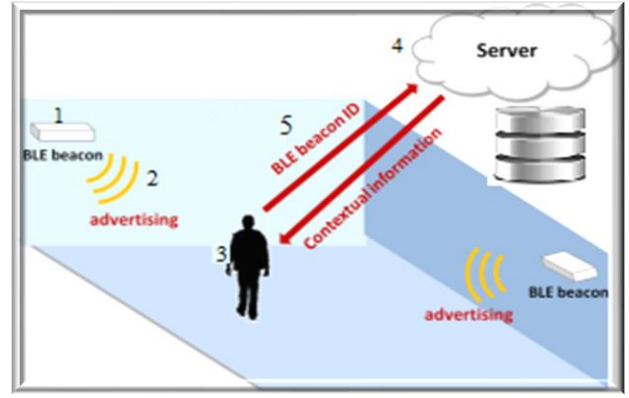
Şekil 1. İşaretçi Cihaz

İşaretçi Özelliklerinin sahip olması gereken özellikler aşağıdaki gibi sıralanabilmektedir. Buna göre:

- İç mekânlardaki kapsama alanı 5 metre ile 20 metre aralığında olmalıdır.
- Uzaktan ayarların ve güncellemelerin yapılması gerekir.
- Düşük güçte öngörülen pil ömrü en az 2 yıl olmalıdır.
- Sinyal gönderim gücü 4 dBm ile -20dBm aralığında olmalıdır.
- Bluetooth radyo versiyonu 4.0 desteklemelidir.
- Değiştirilebilir paket yapısı ve UUID bilgilerini desteklemektedir.
- IOS (iBeacon) ve Android (Eddystone) işletim sistemlerini desteklemektedir.
- -10 ile +50 derece sıcaklık aralığında çalışabilmelidir.
- Bluetooth® Smart / Bluetooth Low Energy desteklemelidir.
- EN300328, EN301489 standartlarına uygun olmalıdır.
- iBeacon güvenlik kriterlerine sahip olmalıdır.

3. İŞARET YAYICI VE AKILLI TELEFON DESTEKLİ ÖĞRENCİ YOKLAMA OTOMASYONU

Öğrenci yoklama otomasyonunda kullanılan sistem mimarisi ve bileşenleri Şekil 2’de görüldüğü gibi konumlandırılmış işaretçi (1), konumlandırılmış işaretçinin yayınları (2), yayınları yakalayan mobil uygulama (3), server ve database (4) ve haberleşmeyi sağlayan web servisler (5) olmak üzere 5 aşamadan oluşmaktadır.



Şekil 2. Sistem mimarisi ve bileşenleri

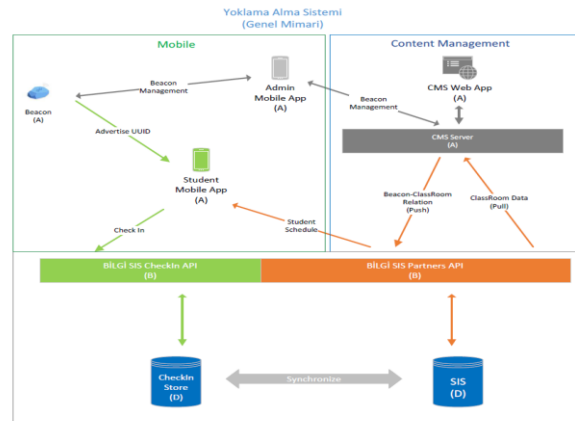
3.1. Sistem Mimarisi

Öğrenci yoklama otomasyonunun işlemesi için ilk olarak dersin öğretmeninin yoklamayı, web sitesi üzerinden başlatması gerekmektedir. Daha sonra kullanıcıların mobil uygulama üzerinden işaretçiyi araması gerekmektedir. Arama sonucunda bulunan işaretçilerden yakın olanı seçilir. Seçme işleminden sonra kullanıcıların, öğrenci numaraları ve şifrelerini girdikten sonra “imza at” butonuna tıklaması gerekmektedir. Bu işlemlerin başarılı şekilde gerçekleşmesi için gereken şartlar aşağıda belirtilmiştir. Buna göre:

- Dersin hocasının yoklamayı açması gerekir.
- İşaretçiyle mesafesi en fazla 20 metre uzaklıkta bulunmalıdır.
- İşaretçi aranmalı ve doğru işaretçi seçilmelidir.
- Öğrenci numarası ve şifresi girilmelidir.
- Öğrenci numarası ve şifre doğru girilmeli ve ders alınıyor olmalıdır.
- Mobil uygulama üzerinden sadece kendi adına e-imza atılmış olmalıdır.
- Akıllı cihazın internet bağlantısı olmalıdır.
- Öğrenci sınıfın içerisinde olmalıdır (Duvar engeli işaretçi yayını keser).

Yukarıda belirtilen şartlara uygun olanlar imza atabilir. Aksi halde imza atması mümkün değildir.

Şekil 3’te yoklama sisteminin genel mimarisi özetlenmiştir.




Şekil 3. Genel mimari modeli

3.2. Uygulamanın Büyüklükleri

Uygulama büyüklükleri şartlara göre farklılıklar gösterebilmektedir. Buna göre:

- Hafta içi günlerde okul genelinde ortalama (öğrenci) x (ders sayısı)
- Günlük ortalama (hoca) x (ders sayısı)
- En çok öğrenci hafta boyunca 09.00'da başlayan derslerde min 3.000 ile max 8.000 arasında öğrenci sayısına erişilmektedir.
- Günlük ortalama kullanılan derslik sayısı ve ders sayısı çok fazla olmaktadır.

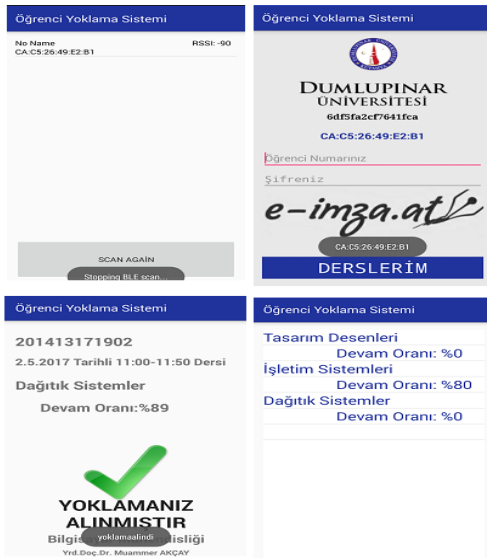
Şekil 4'te öğrenci yoklama otomasyonunun MYSQL veri tabanı modeli sunulmaktadır. MYSQL veri tabanında veri bütünlüğü sağlanması için ilişkisel veri tabanı modeli kullanılmış ve burada toplam 10 adet tablo bulunmaktadır.



Şekil 4. Veri tabanı modeli

3.3. Android Tabanlı Mobil Yoklama Uygulaması

Mobil uygulama, android studio editöründe gerçekleştirilmiştir. Geliştirilen mobil uygulama sayesinde kullanıcılar, dersliklere konumlandırılan işaretçilerin yaydığı sinyalleri yakalayarak yoklaması açılan derse imza atabilme imkânı sağlamaktadır (Şekil 5).

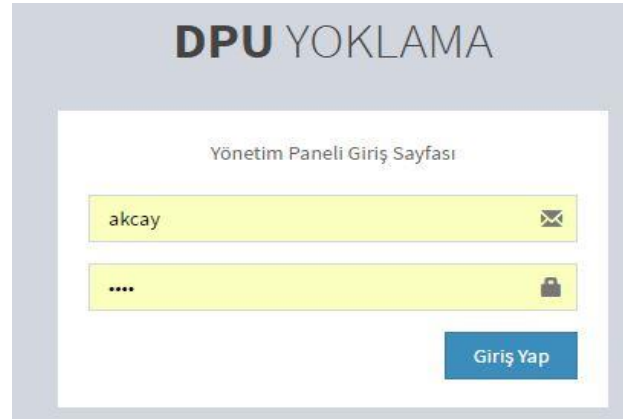


Şekil 5. Android uygulama ara yüzleri

Android uygulamasının ana sayfasında bulunan beacon arama butonu sonrasında çevrede bulunan işaretçilerin yayıncıları yakalanır. Yakalanan işaretçi sonrasında imza atmak için gereken öğrenci numarası ve şifre girilmelidir. Öğrenci numarası ve şifre girildikten sonra imza atmak için e-imza (elektronik imza) butonuna tıklanmalıdır. E-imza (elektronik imza) butonuna tıklandıktan sonra sistem mimarisinde sıralanan şartlar sağlanıyorsa imza başarılı şekilde atılmış olur (Şekil 5).

3.4. Web Temelli Yoklama Yazılımı (Web-Based Polling Software)

Web temelli yoklama yazılımı, öğrencilerin derse katılım durumlarının takibini sağlamayı ve izlenmesini amaçlamaktadır. Bu yazılım tasarımının geliştirilmesinde php, html, bootstrap teknolojileri kullanılmıştır. Öğretmen web temelli yoklama sistemine Şekil 6'da görülen ara yüz üzerinden kullanıcı adı ve şifre bilgileri ile giriş yapmaktadır.



Şekil 6. Web temelli yoklama yazılımı öğretmen giriş ekranı

Öğretmen, web temelli yoklama yazılımına giriş yaptığında vermekte olduğu derslerin bilgilerini görmektedir (Şekil 7).



Şekil 7. Web temelli yoklama yazılımı öğretmenin verdiği dersler ekranı

Bu ara yüz aracılığıyla olan herhangi bir ders seçildiğinde Şekil 8'deki ara yüz gelmekte ve bu ara yüzde seçilen derse alan öğrencilerin devamsızlık oranları görülmektedir.

Öğrenci No	Adı Soyadı	Sınıf	Devamsız Durumu	Devamsızlık
201913171014	BULUN ÖZNER	4		0%
201913171017	ANDI HOSE	4		0%
201913171018	GANDE ULUYOL	4		0%
201913171019	CHAKI ÇETİN	4		0%
201913171017	RAFİ ÇİHAĞ	4		0%
201913171002	İRİŞAD AKILANAKA	4		0%
201913171003	FIRIĞ AKTEŞ	4		0%
201913171004	EMEL BAĞRANA	4		0%
201913171007	SELMA BUDAK	4		0%
201913171011	HAYRİYE ÇALKIRANNOĞLU	4		0%

Şekil 8. Web temelli yoklama yazılımı dersi alan öğrencilerin devamsızlık oranı

Web temelli yoklama yazılımına giriş yapıldıktan sonra geçiş sekmelerinde ana sayfa, ders programım ve bölüm ders programı bulunmaktadır. Bulunan sekmeler arasında ders programı Şekil 9'da gösterilmekte ve giriş yapan öğretmenin verdiği derslerin ders programı burada gösterilmektedir.

Yıl	Ay	Gün	Saat	Ders
2017	Mayıs	1	10:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	11:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	12:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	13:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	14:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	15:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	16:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	17:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	18:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	19:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	20:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	21:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	22:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	23:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	24:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	25:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	26:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	27:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	28:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	29:00	Yrd. Doç. Dr. Muammer AKÇAY
2017	Mayıs	1	30:00	Yrd. Doç. Dr. Muammer AKÇAY

Şekil 9. Öğretmenin verdiği derslerin ders programı

Şekil 9 üzerinde öğretmenin verdiği derslerin programı görülmektedir. Bu sayfada dersler yıl, ay, gün, saat olarak ayrılmıştır. Girilen dersin yoklamasının açılması için açılacak dersin saati seçilir ve Şekil 10'da olduğu gibi görünür. Dersin yoklaması kaç dakika açık kalacaksa süre seçilir ve dersin yoklaması açılır. Öğrenci ders devamlılığı ise Şekil 11'deki gibi görünür.

Öğrenci No	Adı Soyadı	Devamsızlık
201913171004	SEYRAN AKIŞ	100% Devamsız
201913171012	BÜYÜK AKÇA	100% Devamsız
201913171020	ÖZÜR AKIŞ	100% Devamsız
201913171047	SERVAĞI	100% Devamsız
201913171002	ARUÇU AKIŞ	100% Devamsız
201913171004	MURATTA AKIŞ	100% Devamsız
201913171008	ŞERHATİN AKIŞ	100% Devamsız
201913171002	İRİŞAD AKILANAKA	100% Devamsız
201913171016	ÖZGÜR AKIŞ	100% Devamsız
201913171003	FIRIĞ AKTEŞ	100% Devamsız
201913171002	FERİT AKIŞ	100% Devamsız
201913171008	ÖZGÜR AKIŞ	100% Devamsız
201913171004	EMEL BAĞRANA	100% Devamsız
201913171007	SELMA BUDAK	100% Devamsız
201913171017	RAFİ ÇİHAĞ	100% Devamsız
201913171005	CHAKI ÇETİN	100% Devamsız
201913171009	SİMGE ÇOBAN	100% Devamsız
201913171002	MURATTA AKIŞ	100% Devamsız
201913171011	HAYRİYE ÇALKIRANNOĞLU	100% Devamsız
201913171019	SERVAĞI	100% Devamsız

Şekil 10. Web temelli dersin yoklamasını açma sayfası

Öğrenci Yoklama Sistemi	
Tasarım Desenleri	Devamsızlık Oranı: %0
İşletim Sistemleri	Devamsızlık Oranı: %80
Dağıtık Sistemler	Devamsızlık Oranı: %0

Şekil 11. Öğrenci ders devamlılığı

4. BULGULAR

iOS ve Android işletim sistemli mobil kullanıcılar, BLE kablosuz haberleşme teknolojisini kullanan işaretçilerin kapsama (etkileşim) alanına girdiğinde uygulama çalıştırma, içerik sunma gibi hizmetler almaktadır. İşaretçiler reklam, lojistik, ürün, tarihi eser ve yerlerin tanıtımı, yön bulma (navigasyon) gibi çok geniş uygulama alanı sunmaktadır.

Bu çalışmada, kullanımı hızla yaygınlaşan ve güncel bir teknoloji olan işaretçilere dayalı olarak geliştirilen yoklama ve katılım sistemi sunulmuştur. Geliştirilen sistem kullanıcıların işaretçiler ile etkileşimde bulunduğu konum ve süreye göre katılımını takip etmeyi sağlamaktadır. Böylelikle öğrencinin hangi saat sınıfta olduğu hangi saat ayrıldığı izlenebilmektedir.

Geliştirilen öğrenci yoklama sistemi yapılacak küçük değişiklikler ile kurumsal firmaların toplantı takip ve değerlendirme süreçlerinde de kullanılabilir. Firma sahibi ya da proje yöneticileri, toplantılara katılanları, katılma sürelerini raporlama imkânına sahip olacaktır.

Geliştirilen sistemin en büyük dezavantajı ise kullanıcıların BLE teknolojisine sahip mobil cihaz kullanımınıdır. Günümüzde yeni cihazların çoğunda BLE teknolojisinin standart olarak sunulması bu dezavantajın hızla giderileceğini göstermektedir.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, kullanımı hızla yaygınlaşan ve güncel bir teknoloji olan işaretçilere dayalı olarak geliştirilen yoklama ve katılım sistemi sunulmuştur. Sonuç olarak geliştirilen sistem, kullanıcıların işaretçiler ile etkileşimde bulunduğu konum ve süreye göre katılımını takip etmeyi sağlamaktadır. Böylelikle öğrencinin hangi saat sınıfta olduğu, hangi saat ayrıldığı rahatlıkla izlenebilmektedir.

Etik Hususlar

Etik kurallara uyum

Yazarlar, çalışmalarının etik kurallara uygun olduğunu beyan ederler.

Finansman

Yazarlar, fon kuruluşlarından özel bir hibe almamıştır.

Çıkar çatışması

Yazar herhangi bir çıkar çatışması yoktur.

Teşekkür

Yazarlar Kütahya Dumlupınar Üniversitesi ne verdikleri desteklerden dolayı teşekkür eder.

KAYNAKÇA

[1] Bektaş, F., Sondaş, A. 2015. RFID Modülü ile Kapı Giriş Çıkış Takip Sistemi. UMAS 2015 Ulusal

- Mühendislik Araştırmaları Sempozyumu, 10-12 Eylül, Düzce, Türkiye.
- [2] Pala, Z., İnanç, N. 2007. Smart Parking Applications Using RFID Technology, 2007 1st Annual RFID Eurasia, 5-6 September, Istanbul, Turkey, 1-3.
- [3] Yüksel, M.A. Durukan, Ş. 2009. Nesnelere izlenebilir ve yönetilebilir mi? Çözüm: RFID. 11. Akademik Bilişim Konferansı, 11-13 Şubat, Şanlıurfa-Türkiye, 127-136.
- [4] Kavas, A. 2006. Endüktif bağlaşımlı radyo frekans kimlik tanıma sistem optimizasyonu. ELECO'2006, 6-10 Aralık, Bursa-Türkiye.
- [5] Burzacca, P., Mircoli, M., Mitolo, S., Polzonetti, A. 2014. iBeacon technology that will make possible Internet of Things. International Conference on Software Intelligence Technologies and Applications & International Conference on Frontiers of Internet of Things, 4-6 December, Hsinchu, Taiwan, 159-165.
- [6] Apple: iBeacon for developers, <https://developer.apple.com/ibeacon/> (Erişim Tarihi: 28.08.2023).
- [7] Android Beacon Library, https://altbeacon.github.io/android-beacon-library/requesting_permission.html (Erişim Tarihi: 28.08.2023).
- [8] Class BeaconManager, <https://altbeacon.github.io/android-beacon-library/javadoc/org/altbeacon/beacon/BeaconManager.html> (Erişim Tarihi: 28.08.2023).
- [9] Explore our product portfolio, <https://www.nordicsemi.com/eng/Products/Nordic-mobile-Apps/nRF-Beacon-App> (Erişim Tarihi: 28.08.2023).
- [10] Köhne, M., Sieck, J. 2014. Location-based Services with iBeacon Technology. Second International Conference on Artificial Intelligence, Modelling and Simulation, 18-20 November, Madrid, Spain, 315-321.
- [11] Malayeri, D. N. 2011. Review of UWB Technology Specifications and Benefits As a Powerful Technology to Develop Power Distribution Grid Automation Techniques. 16th Conference on Electrical Power Distribution Networks, 19-20 April, İran, 1-7.
- [12] Gajjar, S., Choksi, N., Sarkar, M., Dasgupta, K. 2014. Comparative analysis of Wireless Sensor Network Motes. International Conference on Signal Processing and Integrated Networks (SPIN), 20-21 February, Delhi, India, 426-431.
- [13] Google beacon eddystone, <https://developers.google.com/beacons/> (Erişim Tarihi: 28.08.2023).
- [14] Bluegiga BLE113, <https://www.bluegiga.com/en-US/products/ble113bluetooth-smart-module/> (Erişim Tarihi: 28.08.2023).
- [15] Radhakrishnan, M., Misra, A., Balan, R. K., Lee, Y. 2015. Smartphones & BLE Services: Empirical Insights, 12th International Conference on Mobile Ad Hoc and Sensor Systems, 19-22 October, Dallas, USA, 226-234.
- [16] Ali, A., Nadir. B., Beacondriod: Beacondriod: An Automated Student Attendance System. Journal of Duhok University, 23(2), 396-401. (Special Issue).
- [17] Pataki, V., Karthik, B., Shabareesh, K., Gaga Deep, S. N., Khan, F. 2022. Attendance System with Bluetooth and Android App., International Journal of Innovative Science and Research Technology, 7(6) 1314-1318. <https://doi.org/10.5281/zenodo.6850030>.