

DOĞA BİLİMLERİ VE MATEMATİKTE YENİ KAVRAMLAR VE İLERİ ÇALIŞMALAR



*DOĞA BİLİMLERİ
VE MATEMATİKTE
YENİ KAVRAMLAR
VE İLERİ
ÇALIŞMALAR*

Editor

Prof. Dr. Canan ÖZDEMİR

Doç. Dr. Ali ÖZDEMİR





Doğa Bilimleri ve Matematikte Yeni Kavramlar ve İleri Çalışmalar

Editör: Prof. Dr. Canan ÖZDEMİR, Doç. Dr. Ali ÖZDEMİR

Dizayn: All Sciences Academy Design

Basım Tarihi: Ekim 2025

Yayıncı Sertifika Numarası: 72273

ISBN: 978-625-5794-47-5

© All Sciences Academy

www.allsciencesacademy.com

allsciencesacademy@gmail.com

İÇERİK

1. Bölüm	6
Bakterilerin Tanısında Yeni Bir Yaklaşım: Yüksek Çözünürlüklü Erime Analizi	
<i>Dilara Hande BARLIK</i>	
2. Bölüm	16
VİT Modellerinin Açıklanabilirliği	
<i>Sercan DALKILIÇ, Erol TERZİ</i>	
3. Bölüm	42
Makine Öğrenmesi İle İnsan Kaynakları Chatbotu Geliştirme: Niyet Sınıflandırma Ve Yanıt Üretimi	
<i>Selma DEMİREL, Prof. Dr. Erol TERZİ, Arş. Gör. Mehmet Şirin ATEŞ</i>	
4. Bölüm	70
Hayvan Parazitlerinin Toplanması ve Muhafazası	
<i>Mehmet Oğuz ÖZTÜRK</i>	
5. Bölüm	86
Klein Kuadriğin Greek ve Latin Düzlemlerinin Etiketlenmesi Üzerine	
<i>Mine Münevvere KARAKAYA, Ziya AKÇA</i>	
6. Bölüm	112
Akçadağ Yöresinde Doğal Olarak Yetişen <i>Salvia sclarea</i> Bitkisinin Uçucu Yağ Bileşenleri	
<i>Ülkü YILMAZ</i>	
7. Bölüm	125
Nonlineer Diferansiyel Denklemlerin Yaklaşık Çözümü İçin En Küçük Kareler Metodu	
<i>Öğr.Gör. Dr. Birkan DURAK, Öğr.Gör. Dr. İbrahim Tamer EMECAN</i>	

Görülmesi Gereken Doğa Harikası Egzotik ve Görkemli Ağaçlar

Serkan ÖZER, Oğuzhan DİKMEN

Bakterilerin Tanısında Yeni Bir Yaklaşım: Yüksek Çözünürlüklü Erime Analizi

Dilara Hande BARLIK

Biyolog Dilara Hande BARLIK, Van Yüzüncü Yıl Üniversitesi, Fen Fakültesi, Moleküler Biyoloji ve Genetik Bölümü, dilarahandebalik@hotmail.com, ORCID: <https://orcid.org/0000-0003-1668-1413>

ÖZET

Bakterilerin doğru ve hızlı bir şekilde tanımlanması, klinik, çevre ve gıda bilimi gibi pek çok alanda büyük önem taşımaktadır. Geleneksel fenotipik ve biyokimyasal testlerin zahmetli ve ayırt edicilik gücünün zayıf olması, moleküler yöntemlere olan ihtiyacı artırmıştır. Her ne kadar 16S rRNA gen dizisi analizi doğru sonuçlar sunsa da çok sayıda örnek için yüksek maliyetli bir yöntemdir. Bu bölüm, bakterilerin tür düzeyinde tanımlanması yeni ve güçlü bir alternatif olan yüksek çözünürlüklü erime (HRM) analizini tanıtmaktadır. PCR tabanlı bu yöntem, nükleik asit dizilerindeki küçük farklılıkları (SNP'ler gibi) tespit etmek için çift sarmallı DNA bağlayıcı floresan boyalar kullanılır. DNA'nın erime sıcaklığına (T_m) bağlı olarak oluşan özgün erime eğrileri, bakteri türlerini birbirinden ayırt etmeye olanak tanır. HRM analizi; hızlı, düşük, maliyetli, hassas ve kapalı sistemde yürütüldüğü için kontaminasyon riski düşük bir yöntemdir. Bu yöntemin gıda kaynaklı patojenlerin, antibiyotik direncinin ve çeşitli klinik enfeksiyonların tanısında nasıl başarıyla kullanıldığına dair örnek çalışmalar sunulmuştur. Özetle, HRM analizi bakteri tanımlama süreçlerini basitleştiren ve hızlandıran yenilikçi bir moleküler araç olarak öne çıkmaktadır.

Anahtar Kelimeler – HRM, PCR, DNA, Bakteri, Moleküler Yöntem

GİRİŞ

Bakterilerin tanımlanması üzerine yöntemler sistematik, sağlık, ekoloji, çevre koruma, evrim, tarım, adli tıp, farmakoloji, gıda bilimi, endüstri gibi çeşitli alanlarda kullanılmaktadır. Özellikle klinik laboratuvarlarında bakteri izolatlarının doğru tanımlanması büyük bir önem arz etmektedir. Bunun için hızlı, güvenilir ve doğru moleküler tiplendirme yöntemleri kullanılmalı ve akabinde salgınlara tespiti ve bulaşıcı hastalıkların kontrolü ile etkili epidemiyolojik surveyans yapılabilmelidir (Tamburro ve Ripabelli, 2017). Kültüre bağlı tanımlama geleneksel olarak fenotipik ve biyokimyasal testlerle sağlanır. Ancak bu yöntemler zahmetlidir ve ayırt edici gücü zayıftır. Bu nedenlerden dolayı 16S rRNA gen dizisi analizi gibi alternatif, doğru ve güvenilir yöntemler geliştirilmiştir. Bakteriyel tanımlama için, 16S rRNA dizilemesi, alışılmadık fenotipik özelliklere sahip bakteriler, nadir bakteriler, yavaş olgunlaşan bakteriler, kültürü yapılamayan bakteriler ve kültür negatif enfeksiyonlar durumunda özellikle önemlidir. Sadece bakterilerin tanımlanmasında değil, aynı zamanda klinisyenlerin antibiyotik seçimi ve tedavi süresi ile enfeksiyon kontrol prosedürlerini belirlemesinde kullanılmaktadır (Woo ve ark., 2008). Ancak hedef genin çoğaltılması ve amplikonların dizilenmesi, çok sayıda izolat için pahalı bir yöntemdir (Clarridge, 2004; Petti ve ark., 2005). Diğer yandan Yüksek Çözünürlüklü Erime (HRM) analizi pek çok araştırma alanında bakteri türlerinin

tanımlanması veya moleküler tiplendirme için kullanılan basit, doğru, hızlı, düşük maliyetli bir yaklaşımdır (Syropoulou ve ark., 2020) ve bu amaca yönelik güçlü bir alternatif sunar.

HRM Analizi Nedir?

HRM analizi, popülasyonlar arasındaki genetik çeşitliliği belirlemek ve nükleik asit dizilerindeki tek nükleotid polimorfizmlerini (SNP'ler) tespit etmek için kullanılan basit ve hızlı gerçek zamanlı polimeraz zincir reaksiyonu (PCR) tabanlı bir yöntemdir (Kim ve ark., 2023). HRM analizi, PCR amplikonlarının kapalı bir sistemde doğrudan karakterizasyonuna olanak tanıyan, nükleotid dizi varyasyonlarını tespit etmek için kullanılan nispeten yeni bir PCR sonrası analizdir. Virüs, mantar ve bakteriler dahil olmak üzere çeşitli mikroorganizmaları ayırt etmek için kullanılmaktadır (Herrmann ve ark., 2006; Chelbi ve ark., 2018). GC ve AT açısından zengin bölgeler için eşit bağlanma afinitesi gösteren SybrGreen, EvaGreen gibi yüksek doğrulukta heterodupleks tespit eden çift sarmallı DNA bağlayıcı boyalar kullandığından, maliyetli etiketli problemlere ve sekanslamaya ihtiyaç duyulmadan genotip belirleme ve mutasyon taramasına izin verir (Lochlainn ve ark., 2011). Bu teknik, PCR fragmentlerinin kademeli olarak erimesi sırasında ince floresan değişikliklerinin tespit edilmesini sağlar (Fernandes ve ark., 2017) ve küçük (genellikle 100–250 bp) amplikonlar için yüksek mutasyon tespit oranları elde edebilir, nicel veya nitel sonuçlar verebilir (Pangasa ve ark., 2009).


HRM Analizi Nasıl İşler?

Çift sarmallı DNA (dsDNA) oda sıcaklığında çok stabildir. Ancak sıcaklığın artmasıyla birlikte iki zincir birbirinden tamamen ayrılmaya başlar. DNA'nın %50'sinin tek sarmallı kaldığı sıcaklığa erime sıcaklığı (T_m) denir. T_m, hem DNA fragmentinin uzunluğuna hem de guanin-sitozin (GC) içeriğine bağlıdır (Tong ve Giffard, 2012). Erime eğrisi analizi, gerçek zamanlı (real-time) PCR'da, doğru PCR amplikonlarının oluşup oluşmadığını kontrol etmek için sıklıkla kullanılır.

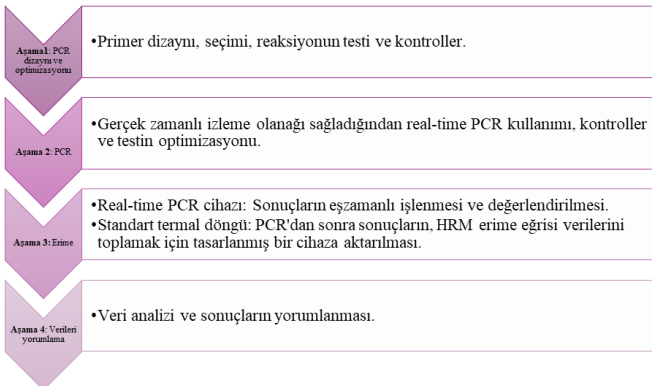
Erime eğrisi analizini gerçekleştirmenin ön koşulu, SybrGreen gibi bir dsDNA bağlayıcı boyanın varlığında kalıp DNA'nın amplifikasyonudur (Şekil 1). SybrGreen, nükleotid dizisinden bağımsız olarak dsDNA'nın küçük oluşuna bağlanır. Bağlanmamış durumda yalnızca düşük floresans ışıma verir. Bununla birlikte, SybrGreen moleküllerinin dsDNA arasına eklenmesi, floresans sinyalinde önemli oranda bir artışa neden olur. Erime eğrisi analizi, son PCR döngüsünden sonra sıcaklığın kademeli olarak arttırılmasına dayanmaktadır. Sonuç olarak SybrGreen, PCR sonrası erime eğrisi analizinde amplikonların uzunluğunu ve saflığını kontrol etmek için sıklıkla kullanılır. Ancak SybrGreen kullanılarak yapılan erime eğrisi analizi, yalnızca küçük sekans varyasyonları gösteren amplikonlar arasında ayırım yapılmasına izin vermez. Buna karşılık, HRM analizi yöntemi, tek baz varyasyonları ve küçük insersiyon veya delesyonları tespit etmeyi bile mümkün kılar (Reed ve ark., 2007). HRM eğrisi analiz yöntemi, bu

doygunluk boylarının varlığında ilgilenilen hedefin amplifikasyonunu ve ardından sıcaklığın kademeli olarak artırılmasıyla amplikonların eritilmesini içerir (Fernandes ve ark., 2016). Bu boyalar, çift sarmallı DNA'ya dahil edildiğinde floresans ışımaya verir, ancak DNA tek sarmallı olduğunda aktif değildir (Herrmann ve ark., 2006).

Veriler genellikle 0,2°C artışlarla 65–95°C sıcaklık aralığında toplanır ve bir erime profili oluşturulur. Neticede bu profiller dizi farklılıklarını tanımlamak için kullanılır. Bu teknikteki kontaminasyon riski, RFLP veya yuvalanmış PCR gibi çok adımlı prosedürlere göre çok daha azdır çünkü tüm süreç tek bir kapalı tüpte tamamlanır (Robertson ve ark., 2009). Çift sarmallı DNA'dan tek sarmallı DNA'ya ayrışma sırasında DNA interkalasyon boyasının floresans yoğunluğundaki değişiklikler teknik olarak ölçülür ve tek nükleotid polimorfizmleri ayırt edilir. Tm ve eğrinin spesifik şekli DNA dizisine, GC içeriğine ve amplikon uzunluğuna bağlıdır. Dolayısıyla Tm varyasyonları PCR ürünlerindeki türe özgü dizi varyasyonunu yansıtabilir (Sanchez ve ark., 2017). HRM analizinin işleyişindeki başlıca basamaklar Şekil 2'de gösterildiği gibidir.



Şekil 1: HRM analiz prensibi



Şekil 1: HRM analiz basamakları

Avantajları

HRM analizinin, gen taraması ve genotipleme için geleneksel yöntemlere göre birçok avantajı vardır. Geleneksel yöntemlerin aksine, HRM analizi amplifikasyon adımıyla aynı tüpte gerçekleştirilir ve ampikonların saflaştırılmasını veya ayrılmasını gerekli kılmaz. Bu, HRM analizini, jel elektroforezine dayalı yöntemler gibi alternatif yaklaşımlara göre daha hızlı, daha az zahmetli ve daha ucuz kılar. Ayrıca analizin kapalı bir sistemde yapılması kontaminasyon riskini azaltır (Wittwer, 2008; Chelbi ve ark., 2018). Sonrasında dizi sekansı yapılmasına gerek kalmaz. Tek baz varyasyonlarını bile tespit etmeyi mümkün kılar. Yöntemin gerçekleştirilmesi kolaydır ve sonuçlar yaklaşık iki saat içinde elde edilebilir (Pakbin ve ark., 2022).

HRM Analizinin Uygulandığı Çalışmalar

HRM-PCR ilk olarak Carl Wittwer ve arkadaşları tarafından 1977’de klinik uygulamalar için ortaya atılmıştır (Nikodem ve ark., 2021). 2006’dan bu yana bu alanda yapılan pek çok çalışma mikrobiyolojik uygulamalar için artan popüleritesini göstermektedir. Günümüzde bu yöntem mikrobiyal patojenlerin hızlı tanımlanması için sıkça kullanılmaktadır (Wang ve ark., 2017). Son çalışmalar HRM analizinin yalnızca klinik çalışmalarda değil pek çok araştırmada etkili bir araç olduğunu göstermektedir. Bu çalışmalardan örnek olarak;

- Hastalığa sebep olan, kontamine olmuş gıdalardaki patojenik mikroorganizmaların tanımlanması/serotiplendirilmesi,

- Gıdalardaki sahteciliği tespit etmek, gıda alerjenlerinin tespiti gibi gıda analizleri (Druml ve Markl, 2014),

- Yakın ilişkili türlerin tanımlanması ve farklılaştırılması,

- Patojen bakterilerin hızlı genotiplendirilmesi,

- Genetiği değiştirilmiş organizmaların taranması (Fernandes ve ark., 2017).

- Hastalıklarla ilişkili genlerin tanımlanması

- Klinik olarak önemli mantar türlerinin tanımlanması (Lochlainn ve ark., 2011),

- Tıbbi ve veterinerlik amaçlı patojen parazitlerin tanımlanması (Heritier ve ark., 2016),


- İdrar yolu enfeksiyonlarında beş bakteriyel patojenin eş zamanlı tespiti (Kafi ve ark., 2022),

- Antibiyotik direncinin taranması (Parlapani ve ark., 2020) verilebilir.

Bakteri Tanımlaması Üzerine Yapılmış Çalışmalar

Ribozomal genlerin veya diğer yüksek oranda korunan genlerin HRM analizi, bakterileri tür düzeyinde tanımlamak için yaygın olarak kullanılmıştır. HRM'nin bildirilen en eski uygulamalarından biri, Odell ve arkadaşları, (2005) tarafından bildirilmiş ve çalışmada *Mycobacterium chelonae-Mycobacterium abscessus* grubundaki türler başarılı bir şekilde tanımlanmıştır. *Mycobacterium tuberculosis*'te RIF (rifampisin) ve INH (iyoniyazid) direncinin taranması için HRM yöntemi uygulanmıştır (Parlapani ve ark., 2020). Sakaridis ve arkadaşlarının, (2014) yapmış oldukları bir çalışmada, ölü kümes hayvanlarından izole edilen laktik asit bakterilerini HRM analizi ile tanımlamışlardır. Landolt ve arkadaşları, (2019) HRM testi ile *M. tuberculosis* kompleksinin (MTBC) üyelerinin (*M. tuberculosis*, *M. microti* ve *M. bovis/M. caprae*) hızlı bir şekilde tanımlanmasını amaçlamışlardır. 25 klinik örnekten 23'ünü doğru bir şekilde tanımlamışlardır. Khosravi ve arkadaşları, (2017) ise yaptıkları bir çalışmada toplam 98 mikobakteriyel izolata 88'ini tür düzeyinde tanımlamışlardır. Girault ve arkadaşları, (2022) 'Dalgalı ateş' olarak da bilinen bruselloz'a sebep olan *Brucella* cinsinin türlerini tek nükleotid polimorfizmine (SNP) dayanarak genotiplemek için HRM analizi uygulanmıştır. Ayrıca *Salmonella* spp. (Liu ve ark., 2018), *Shigella*, *Staphylococcus aureus*, *Vibrio parahaemolyticus*, ishal oluşturan *Escherichia coli* (Pakbin ve ark., 2022), *Escherichia coli* O157 (Liu ve ark., 2018b), kusturucu ve enterotoksin üreten *Bacillus cereus* (Forghani ve ark., 2016) gibi gıda kaynaklı patojenlerin tespiti için de HRM analizinden yararlanılmıştır. Gıda ve klinik örneklerden izole edilen *Staphylococcus*, *Listeria*, *Cronobacter*, *Mycobacteria*, *Pasteurella*, *Campylobacter*, *Yersinia* ve *Shigella* gibi bakteriyel patojen türlerini ayırt etmek için de başarıyla kullanılmıştır (Pakbin ve ark., 2022). HRM ile genotiplendirilen diğer bakterilere ise Gram-pozitif patojen bakterilerden, *Bacillus anthracis*, *Clostridium difficile*, *Enterococcus faecium*, *Listeria monocytogenes*, *Metisiline* dirençli *Staphylococcus aureus* (MRSA), *Staphylococcus epidermidis*, Gram-negatif patojen bakterilerden ise *Bordetella pertussis*, *Campylobacter coli*, *Campylobacter jejuni*, *Chlamydia trachomatis*, *Pseudomonas aeruginosa*, *Acinetobacter baumannii*, *Klebsiella pneumoniae*, *Shigella sonnei*, *Vibrio cholerae*, *Yersinia enterocolitica*, *Yersinia pestis* ve *Yersinia pseudotuberculosis* örnek verilebilir (Tamburro ve Ripabelli, 2017). Kafi ve arkadaşları, (2022) tarafından yapılan bir çalışmada idrar yolu enfeksiyonlarına sebep olan beş temel patojenin kısa sürede tespiti için HRM testi geliştirmişlerdir. Toplam 287 idrar örneğini HRM testi ile değerlendirmişler ve sonuçları geleneksel kültür yöntemi ile karşılaştırmışlardır. 5 saatten kısa bir sürede *Escherichia coli*, *Klebsiella pneumoniae*, *Staphylococcus saprophyticus*, *Enterococcus faecalis* ve grup B streptokok (GBS) bakterileri için beş farklı erime eğrisi oluşturmuş ve ayırt etmişlerdir. Sonuç olarak kültürle karşılaştırıldığında HRM testinin özgüllüğünün %99,3 ile %100 arasında, duyarlılığının ise tüm

test patojenleri için %100 olduğunu rapor etmişlerdir. Elde ettikleri beş farklı patojen bakterinin erime eğrileri Şekil.3'te verilmiştir. Grafikte her bir çizgi bir bakteriyi temsil etmektedir ve her bakteri erime sıcaklığı açısından benzersiz bir profil göstermektedir.



Şekil 3. Beş farklı bakterinin erime eğrileri

SONUÇ

Birçok çalışmadaki başarısına bakılırsa HRM analizi doğruluğu, düşük maliyeti, kolaylığı ve hızı ile bakterilerin eş zamanlı tespiti ve tanımlanması için umut verici bir araç olarak görülebilir.

REFERANSLAR

- Chelbi, H., Essid, R., Jelassi, R., Bouzekri, N., Zidi, I., Salah, H. B., ... & Aoun, K. (2018). High-resolution melting-curve (HRM) analysis for *C. meleagridis* identification in stool samples. *Microbial Pathogenesis*, 115, 332-337.
- Clarridge III, J. E. (2004). Impact of 16S rRNA gene sequence analysis for identification of bacteria on clinical microbiology and infectious diseases. *Clinical microbiology reviews*, 17(4), 840-862.
- Druml, B., & Cichna-Markl, M. (2014). High resolution melting (HRM) analysis of DNA—Its role and potential in food analysis. *Food chemistry*, 158, 245-254.
- Fernandes, T. J., Costa, J., Oliveira, M. B. P., & Mafra, I. (2017). DNA barcoding coupled to HRM analysis as a new and simple tool for the authentication of Gadidae fish species. *Food Chemistry*, 230, 49-57.
- Forghani, F., Singh, P., Seo, K. H., & Oh, D. H. (2016). A novel pentaplex real time (RT)-PCR high resolution melt curve assay for simultaneous detection of emetic and enterotoxin producing *Bacillus cereus* in food. *Food Control*, 60, 560-568.
- Girault, G., Perrot, L., Mick, V., & Ponsart, C. (2022). High-resolution melting PCR as rapid genotyping tool for *Brucella* species. *Microorganisms*, 10(2), 336.

- Heritier, L., Verneau, O., Breuil, G., & Meistertzheim, A. L. (2017). The high resolution melting analysis (HRM) as a molecular tool for monitoring parasites of the wildlife. *Parasitology*, 144(5), 563-570.
- Herrmann, M. G., Durtschi, J. D., Bromley, L. K., Wittwer, C. T., & Voelkerding, K. V. (2006). Amplicon DNA melting analysis for mutation scanning and genotyping: cross-platform comparison of instruments and dyes. *Clinical chemistry*, 52(3), 494-503.
- Kafi, H., Emaneini, M., Halimi, S., Rahdar, H. A., Jabalameli, F., & Beigverdi, R. (2022). Multiplex high-resolution melting assay for simultaneous detection of five key bacterial pathogens in urinary tract infections: A pilot study. *Frontiers in Microbiology*, 13, 1049178.
- Khosravi, A. D., Hashemzadeh, M., Hashemi Shahraki, A., & Teimoori, A. (2017). Differential identification of mycobacterial species using high-resolution melting analysis. *Frontiers in Microbiology*, 8, 2045.
- Kim, N., Kwon, J. S., Kang, W. H., & Yeom, S. I. (2023). High-resolution melting (HRM) genotyping. In Yuri Shavrukov (Ed.), *Plant Genotyping: Methods and Protocols* (pp. 337-349). New York, NY: Springer US.
- Landolt, P., Stephan, R., & Scherrer, S. (2019). Development of a new High Resolution Melting (HRM) assay for identification and differentiation of *Mycobacterium tuberculosis* complex samples. *Scientific reports*, 9(1), 1850.
- Liu, Y., Singh, P., & Mustapha, A. (2018b). High-resolution melt curve PCR assay for specific detection of *E. coli* O157: H7 in beef. *Food Control*, 86, 275-282.
- Liu, Y., Singh, P., & Mustapha, A. (2018). Multiplex high resolution melt-curve real-time PCR assay for reliable detection of *Salmonella*. *Food Control*, 91, 225-230.
- Lochlainn, S. Ó., Amoah, S., Graham, N. S., Alamer, K., Rios, J. J., Kurup, S., ... & Broadley, M. R. (2011). High Resolution Melt (HRM) analysis is an efficient tool to genotype EMS mutants in complex crop genomes. *Plant methods*, 7, 1-9.
- Martin-Fernandez, B., Costa, J., de-Los-Santos-Álvarez, N., Lopez-Ruiz, B., Oliveira, M. B. P., & Mafra, I. (2016). High resolution melting analysis as a new approach to discriminate gluten-containing cereals. *Food Chemistry*, 211, 383-391.
- Nikodem, D., Cłapa, T., & Narożna, D. (2021). Denaturacja DNA z wysoką rozdzielczością (HRM-PCR) – metoda i jej zastosowanie. *Postępy Biochemii*, 67(1), 54-58.
- Odell, I. D., Cloud, J. L., Seipp, M., & Wittwer, C. T. (2005). Rapid species identification within the *Mycobacterium chelonae*-abscessus group by high-resolution melting analysis of hsp65 PCR products. *American journal of clinical pathology*, 123(1), 96-101.
- Pakbin, B., Basti, A. A., Khanjari, A., Brück, W. M., Azimi, L., & Karimi, A. (2022). Development of high-resolution melting (HRM) assay to differentiate the species of *Shigella* isolates from stool and food samples. *Scientific reports*, 12(1), 473.
- Pangasa, A., Jex, A. R., Campbell, B. E., Bott, N. J., Whipp, M., Hogg, G., ... & Gasser, R. B. (2009). High resolution melting-curve (HRM) analysis for the

- diagnosis of cryptosporidiosis in humans. *Molecular and cellular probes*, 23(1), 10-15.
- Parlapani, F. F., Syropoulou, F., Tsiartsafis, A., Ekonomou, S., Madesis, P., Exadactylos, A., & Boziaris, I. S. (2020). HRM analysis as a tool to facilitate identification of bacteria from mussels during storage at 4 C. *Food Microbiology*, 85, 103304.
- Petti, C. A., Polage, C. R., & Schreckenberger, P. (2005). The role of 16S rRNA gene sequencing in identification of microorganisms misidentified by conventional methods. *Journal of clinical microbiology*, 43(12), 6123-6125.
- Reed, G. H., Kent, J. O., & Wittwer, C. T. (2007). High-resolution DNA melting analysis for simple and efficient molecular diagnostics. *Pharmacogenomics*, 8(6), 597-608.
- Robertson, T., Bibby, S., O'Rourke, D., Belfiore, T., Lambie, H., & Noormohammadi, A. H. (2009). Characterization of Chlamydiaceae species using PCR and high resolution melt curve analysis of the 16S rRNA gene. *Journal of Applied Microbiology*, 107(6), 2017-2028.
- Sakaridis, I., Ganopoulos, I., Soutos, N., Madesis, P., Tsaftaris, A., & Argiriou, A. (2014). Identification of lactic acid bacteria isolated from poultry carcasses by high-resolution melting (HRM) analysis. *European Food Research and Technology*, 238, 691-697.
- Syropoulou, F., Parlapani, F. F., Bosmali, I., Madesis, P., & Boziaris, I. S. (2020). HRM and 16S rRNA gene sequencing reveal the cultivable microbiota of the European sea bass during ice storage. *International Journal of Food Microbiology*, 327, 108658.
- Sánchez, R. G. P., Quintero, J. Á. L., Pereira, M. M., & Agudelo-Flórez, P. (2017). High-resolution melting curve analysis of the 16S ribosomal gene to detect and identify pathogenic and saprophytic *Leptospira* species in colombian isolates. *The American journal of tropical medicine and hygiene*, 96(5), 1031.
- Tamburro, M., & Ripabelli, G. (2017). High Resolution Melting as a rapid, reliable, accurate and cost-effective emerging tool for genotyping pathogenic bacteria and enhancing molecular epidemiological surveillance: a comprehensive review of the literature. *Ann Ig*, 29(4), 293-316.
- Tong, S. Y., & Giffard, P. M. (2012). Microbiological applications of high-resolution melting analysis. *Journal of clinical microbiology*, 50(11), 3418-3421.
- Wang, W., Zijlstra, R. T., & Gänzle, M. G. (2017). Identification and quantification of virulence factors of enterotoxigenic *Escherichia coli* by high-resolution melting curve quantitative PCR. *BMC microbiology*, 17, 1-11.
- Wittwer, C. T. (2009). High-resolution DNA melting analysis: advancements and limitations. *Human mutation*, 30(6), 857-859.
- Woo, P. C., Lau, S. K., Teng, J. L., Tse, H., & Yuen, K. Y. (2008). Then and now: use of 16S rDNA gene sequencing for bacterial identification and discovery of novel bacteria in clinical microbiology laboratories. *Clinical Microbiology and Infection*, 14(10), 908-934.

VİT Modellerinin Açıklanabilirliği

Sercan DALKILIÇ¹
Erol TERZİ²

- 1- Yüksek Lisans Öğr., Ondokuz Mayıs Üniversitesi Fen Fak. İstatistik Bölümü.
23281605@stu.omu.edu.tr ORCID No: 0009-0006-5405-5455
- 2- Prof.Dr., Ondokuz Mayıs Üniversitesi Fen Fak. İstatistik Bölümü eroltr@omu.edu.tr ORCID No: 0000-0002-2309-827X

ÖZET

Yapay Zeka (YZ) modellerinin açıklanabilirliği, özellikle kritik uygulama alanlarında büyük önem taşımaktadır. Bu çalışmada, bilgisayarlı görme alanında devrim yaratan VisionTransformer (VİT) modellerinin açıklanabilirliği incelenmiştir. VİT modelleri, kendine dikkat mekanizmaları ve yama temsilleri gibi yenilikçi yaklaşımlarla dikkat çekmektedir. Ancak, bu modellerin “kara kutusu” doğası, öngörülerinin yorumlanabilirliğini zorlaştırmaktadır.

Bu bağlamda, VİT modellerinin açıklanabilirliği için çeşitli metodolojiler değerlendirilmiştir. Çalışmada, gradyan tabanlı yöntemler (ör. Grand-CAM), öznitelik tabanlı yaklaşımlar (ör. Entegre Gradyanlar) ve dikkat mekanizmalarının görselleştirilmesi gibi yöntemlere odaklanılmıştır. Ayrıca bu metodolojilerin görsel çıktıları üzerinden karşılaştırılmalı bir analiz yapılmıştır.

Elde edilen bulgular, VİT modellerinin öngörülerini anlamaya yönelik önemli içgörüler sunmaktadır ve bu modellerin açıklanabilirliğini artırmak için yeni yöntemlerin geliştirilmesine zemin hazırlamaktadır. Çalışmanın sonuçları, VİT modellerinin daha güvenilir ve açıklanabilir hale getirilmesine katkı sağlamayı amaçlamaktadır.

Anahtar kelimeler: Görüntü İşleme, Sinir Ağları, Derin Öğrenme, Aktarım Öğrenmesi, Yapay Zeka

1.GİRİŞ

1.1. Bağlam ve Motivasyon

Bilgisayarlı görme alanında, geleneksel derin öğrenme yöntemleri özellikle Convolutional Neural Network (CNN) tabanlı modeller, görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi birçok görevi etkili bir şekilde yerine getirmiştir (Krizhevsky, A., vd., 2012). Ancak, bu modellerin başarısı büyük ölçüde karmaşık ve çoğu zaman anlaşılması zor olan yapay sinir ağı yapılarına dayanmaktadır. Özellikle tıp, güvenlik ve otonom araçlar gibi kritik uygulamalarda, bu modellerin neden belirli bir sonuca ulaştığını açıklayabilmek büyük bir ihtiyaç haline gelmiştir (Doshi, P.ve Velezand B.K., 2017). Bu gereksinim, son yıllarda Yapay Zeka (YZ) sistemlerinin “açıklanabilirliği” konusunu önemli bir araştırma alanı haline getirmiştir. Vision Transformer (VİT) modelleri, (Dosovitskiy, A., vd., 2020) ”Attention is All You Need” paradigmasının bilgisayarlı görme alanına uyarlanmasıyla ortaya çıkmıştır. Bu modeller, görüntüleri sabit boyutlu parçalara (patch) bölerek ve her bir parçayı bir dil modeli gibi işleyerek çalışmaktadır. Bu yaklaşım, derin öğrenme modellerinin işlem potansiyelini genişletirken, aynı zamanda “kara kutu” doğasını daha karmaşık hale getirmiştir. VİT modelleri, özellikle yüksek başarı oranlarıyla dikkat çekmektedir. Ancak bu başarıların ardındaki nedenlerin anlaşılması zor olmaktadır. Modelin iç

anlayışını anlamak ve bu iç işleyişi şeffaf bir şekilde açıklamak, hem akademik hem de endüstriyel uygulamalar için büyük önem taşımaktadır. Açıklanabilir yapay zeka (XAI) yöntemleri, kullanıcıların bir modelin nasıl ve neden belirli bir sonuca ulaştığını anlamalarına yardımcı olurken, modellerin etik ve güvenilirlik açısından değerlendirilmesine de olanak sağlamaktadır (Arrieta, A.B., vd., 2020). VİT gibi karmaşık modellerin açıklanabilirliği, yalnızca teorik bir merak olmaktan ziyade, aynı zamanda regülasyonların ve etik standartların karşılanması açısından da kritik bir rol oynamaktadır. Bu çalışmanın temel amacı, VİT modellerinin açıklanabilirliğini artırmak ve bu alanda mevcut olan yöntemleri değerlendirmektir. Çalışma, hem teorik bir çerçeve sunmayı hem de bu teorik bilgilerin pratikte nasıl uygulanabileceğini göstermeyi hedeflemektedir.

1.2 VİT Modelleri Nedir?

VİT modelleri, yapay zekâ ve derin öğrenme alanında önemli bir yenilik olarak karşımıza çıkmaktadır. VİT, dil işleme modellerinde yaygın olarak kullanılan kendine dikkat mekanizmasını (self-attention) görüntü işleme alanına taşıyan bir yaklaşımdır (Dosovitskiy, A., vd., 2020). Görüntüler, sabit boyutlu yamalara (patch) bölünerek her bir yama, sırayla bir dizi olarak işlenir. Bu yöntem, CNN tabanlı geleneksel yöntemlerden temel bir ayrışma sunar ve VİT' i devrimsel kılar. VİT modellerinin dikkat çekici özelliklerinden biri, sınırlı sayıda veri üzerinde güçlü performans göstermesidir. Özellikle, büyük ölçekli veri kümeleriyle eğitildiklerinde, CNN modellerini çeşitli görevlerde geride bırakabilmektedir. Bununla birlikte, VİT' in başarısında transfer öğrenimi ve önceden eğitilmiş modellerin önemi büyüktür (Dosovitskiy, A., vd., 2020).

1.2.1 CNN ile Karşılaştırma: Yorumlanabilirlik ve Performans

CNN'ler, yerel özelliklerin çıkarılmasına odaklanarak filtreler ve havuzlama katmanları üzerinden bilgi işlemi gerçekleştiren modellerdir. Bu modeller, yorumlanabilirlik açısından nispeten avantajlıdır. Çünkü filtrelerin hangi özelliklere odaklandığı görselleştirilebilir (Krizhevsky, A., vd., 2012). Ancak CNN'lerin başarısı genellikle sınırlı alansal bağlam bilgisi ile ilişkilidir. VİT modelleri ise, kendine dikkat mekanizması sayesinde küresel bağlam bilgilerini işleyebilme yeteneğine sahiptir. Bu durum, VİT' in büyük ve karmaşık veri kümeleri üzerinde daha üstün performans göstermesine olanak tanır. Öte yandan VİT modellerinin yorumlanabilirliği, dikkat haritalarının doğrudan görselleştirilmesine rağmen, bazı tartışmalara neden olmuştur. Dikkat mekanizmasının açıklama açısından yeterli olup olmadığı hala araştırılmaktadır (Chefer, H., vd., 2021). Sonuç olarak, CNN ve VİT modelleri arasındaki temel farklar şunlardır:

- Yerel ve Küresel Bağlam: CNN'ler yerel bilgi çıkarımı için optimize edilmişken VİT' ler küresel bağlamları işler.
- Yorumlanabilirlik: CNN'lerin yorumlanabilirliği daha iyi anlaşılmıştır, ancak VİT' ler daha karmaşık yöntemler gerektirir.
- Performans: Büyük veri kümelerinde VİT' ler daha başarılıdır. Bu farklılıklar, VİT modellerinin hem avantajlarını hem de açıklanabilirlik zorluklarını ortaya koymaktadır.

1.3 VİT Mimarisi

VİT mimarisi, modern derin öğrenme modellerinde dikkate dayalı bir paradigmayı benimseyerek geleneksel Convolutional Neural Network (CNN) tabanlı yapılardan farklılaşır. Bu bölümde, VİT' in temel yapı taşları ayrıntılı bir şekilde açıklanmaktadır.

1.3.1 Kendine Dikkat Mekanizması (Self-Attention Mechanism)

Kendine dikkat mekanizması, VİT modellerinin temel taşıdır ve bir girdinin farklı bölümleri arasındaki bağımlılıkları hesaba katmayı sağlar (Vaswani, A., vd., 2017). Özellikle, her bir yamanın diğer tüm yamalarla ilişkisi bir ağırlık matrisi kullanılarak hesaplanır. Bu işlem, girdideki uzun menzilli bağımlılıkları modellemek için idealdir. Matematiksel olarak, bir girdinin dikkat puanları şu şekilde ifade edilir:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T / \sqrt{d_k}) V(1)$$

Burada Q, K ve V sırasıyla sorgu (query), anahtar (key) ve değer (value) matrislerini temsil eder. d_k , boyut azaltımı için kullanılan bir ölçeklendirme faktörüdür.

1.3.2 Yama Temsilleri (Patch Embeddings)

Geleneksel CNN'lerin aksine, VİT modellerinde görüntüler sabit boyutlu yamalara bölünür ve her bir yama düzleştirilerek bir girdi dizisi oluşturulur. Bu diziler, ardından bir lineer projeksiyondan geçirilerek yüksek boyutlu bir temsile dönüştürülür (Dosovitskiy, A., vd., 2020). Yama temsilleri, modelin girdi görüntüsünü anlamlandırması için gerekli olan ilk adımdır.

1.3.3 Çoklu Başlıklı Dikkat Katmanları (Multi-Head Attention Layers)

VİT modellerinde, çoklu başlıklı dikkat mekanizması birden fazla dikkat ağı oluşturarak farklı bağlamların eşzamanlı olarak öğrenilmesini sağlar. Her bir başlık bağımsız olarak çalışır ve sonuçlar birleştirilerek daha zengin bir özellik temsili elde edilir:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)W^o$$

Burada $\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$, her bir başlığın ayrı bir dikkat mekanizmasını temsil ettiği anlamına gelir.

1.3.4 Konumsal Gömüler (Positional Embeddings)

VİT modellerinde, yamalar arasındaki mekansal ilişkileri temsil etmek için konumsal gömüler eklenir. Çünkü dikkat mekanizması konumsal bilgiyi doğrudan içermemektedir. Bu gömüler, her bir yamanın konumunu modelin anlayabilmesi için girdilere eklenir ve modelin mekansal tutarlılık sağlamasına olanak tanır (Dosovitskiy, A., vd., 2020). VİT' in bu mimari bileşenleri, modelin hem öğrenme kapasitesini artırmakta hem de yorumlanabilirlik açısından yeni zorluklar sunmaktadır.

1.4 VİT Matematiği

1.4.1 Dikkat Mekanizmasının Matematiksel Formülasyonu

Vision Transformer (VİT) modellerinin temelinde, dikkat mekanizması (selfattention) yer alır. Bu mekanizma, modelin girdi içerisindeki tüm bileşenler arasındaki ilişkileri öğrenmesini sağlar. Dikkat mekanizması, sorgu (query), anahtar (key) ve değer (value) matrisleri üzerinden çalışır. Formülasyon şu şekilde ifade edilir:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T / \sqrt{d_k})$$

V(3)

Burada:

- $Q \in \mathbb{R}^{n \times d_k}$ sorgu matrisini,
- $K \in \mathbb{R}^{n \times d_k}$ anahtar matrisini,
- $V \in \mathbb{R}^{n \times d_v}$ değer matrisini,
- d_k , sorgu ve anahtar matrislerinin boyutlarını temsil eder.

Bu işlem, girdinin her bir parçasının diğer parçalarla olan bağıntısını hesaplar ve önem derecelerini ağırlıklandırarak çıktıyı üretir. Dikkat mekanizmasının özelliği, girdideki uzun menzilli bağımlılıkları modelleyebilme kapasitesidir. Bu özellik, özellikle büyük ve karmaşık veri kümeleri üzerinde oldukça etkilidir (Vaswani, A., vd., 2017).

1.4.2 Hesaplama Verimliliği

Dikkat mekanizması, esnekliği ve güçlü bağlam modelleme yeteneğine rağmen hesaplama maliyetleri açısından bazı zorluklar sunar:

• Pozitif Yöntemler:

- Uzun menzilli bağımlılıkları verimli bir şekilde modelleyebilir.
- Paralel işleme sayesinde yüksek veri hacimlerinde daha hızlı sonuçlar alınabilir.

• Olumsuz Yönler:

- $O(n^2 \cdot d_k)$ zaman karmaşıklığına sahiptir; bu, büyük veri kümelerinde yüksek hesaplama maliyetine neden olabilir.

– Bellek tüketimi, özellikle uzun dizilerde önemli bir kısıtlama oluşturabilir.

VİT'nin çoklu başlıklı dikkat (multi-headattention) katmanları, bu sınırlamaların bir kısmını paralelleştirme yoluyla hafifletir. Ancak, özellikle gerçek zamanlı uygulamalar için optimizasyon gerekliliği devam etmektedir (Dosovitskiy, A., vd., 2020).

1.5 VİT Modellerinin Açıklanabilirlik Zorlukları

1.5.1 VİT Modellerinin Kara Kutu Doğası

VİT modelleri, dikkat mekanizmalarına dayalı yapıları nedeniyle genellikle “kara kutu” olarak tanımlanır. Bu durum, modelin karar verme süreçlerinin doğrudan anlaşılmasını zorlaştırır. Özellikle dikkat haritalarının görselleştirilmesiyle elde edilen açıklamalar, genellikle insan sezgisiyle tam uyumlu değildir (Chefer, H., vd., 2021).

1.5.2 Dikkat Haritalarının Yorumlanabilirlik Sorunları

VİT modellerinde dikkat haritaları, modelin hangi özelliklere odaklandığını görselleştirmek için kullanılır. Ancak, bu haritaların yorumlanması çeşitli nedenlerle zorluklar taşır:

- Dikkat haritaları genellikle yalnızca modelin odak noktalarını gösterir, bu odak noktalarının neden önemli olduğu açık değildir.
- Dikkat mekanizmasının “açıklanabilirlik” ile eşdeğer olup olmadığı tartışmalıdır (Jainand, S., ve Wallace, B.C., 2019).
- CNN’lerde kullanılan geleneksel saliency haritaları ile karşılaştırıldığında, VİT’ in dikkat haritaları daha soyut ve karmaşık bir yapıya sahiptir. Bu sınırlamalar, VİT modellerinin açıklanabilirliğini artırmak için yeni metodolojilerin geliştirilmesi gerektiğini göstermektedir.

2. AÇIKLAMA METODOLOJİLERİ

Günümüz yapay zeka modellerinin, özellikle VisionTransformer (VİT) gibi karmaşık yapılarının açıklanabilirliği, hem teorik hem de uygulamalı araştırmaların öncelikli konularından biri haline gelmiştir. Açıklama metodolojileri, bir modelin karar verme süreçlerini daha şeffaf hale getirmek için kullanılan araçlar ve teknikler bütünü olarak tanımlanabilir. Bu metodolojiler, bir modelin hangi özelliklere odaklandığını, hangi yollarla karar verdiğini ve bu kararların ne derece güvenilir olduğunu anlamamıza olanak tanır (Arrieta, A.B., vd., 2020). VİT gibi modellerin açıklanabilirliği ise özellikle zordur, çünkü bu modeller, girdilerin birbirleriyle olan ilişkilerini karmaşık çoklu başlıklı dikkat mekanizmaları aracılığıyla işler. Bu bölümde, VİT modelleri için kullanılan temel açıklama metodolojilerinin genel bir çerçevesi sunulacaktır. İlk olarak gradyan tabanlı yöntemler, daha sonra öznitelik tabanlı yöntemler, dikkat görselleştirme ve hibrit yaklaşımlar detaylandırılacaktır.

2.1 Metodolojik Çerçeve

VİT modelleri için açıklama metodolojileri genellikle şu ana kategorilere ayrılır:

- Gradyan Tabanlı Yöntemler: Bu yöntemler, modelin çıktısı ile girdisi arasındaki türev ilişkisini analiz ederek hangi giriş özelliklerinin modelin kararında etkili olduğunu belirler (Selvaraju, R.R., vd., 2017).

- Öznitelik Tabanlı Yöntemler: Girdi özelliklerinin önem derecelerini hesaplama yapıp, modelin hangi kısımlara odaklandığını açıklamayı hedefler (Sundararajan, M., vd., 2017).

- Dikkat Mekanizması Görselleştirme: VİT modellerinin kendine dikkat mekanizmalarını görselleştirerek, modelin hangi girdilere ne kadar önem verdiğini anlamamızı sağlar (Chefer, H., vd., 2021).

- Hibrit Yöntemler: Gradyan tabanlı ve öznitelik tabanlı yaklaşımların birleştirilmesiyle daha kapsamlı bir açıklama sunmayı amaçlar. Bu metodolojiler, modelin iç işleyişine dair farklı perspektifler sunarak açıklanabilirliği artırmayı hedefler. Ancak, her bir yöntemin avantajları ve sınırlamaları bulunmaktadır. Örneğin, gradyan tabanlı yöntemler düşük hesaplama maliyetiyle avantaj sağlarken, bazen açıklamalarda doğruluk sorunlarına yol açabilir. Benzer şekilde, dikkat görselleştirme yöntemleri doğrudan VİT modellerine uygulanabilir, ancak dikkat haritalarının yorumlanabilirliği hala tartışmalıdır (Jainand, S., ve Wallace, B.C., 2019).

2.2 Gradyan Tabanlı Yöntemler

Gradyan tabanlı açıklama yöntemleri, derin öğrenme modellerinin girdiler üzerindeki etkisini analiz ederek modelin karar verme süreçlerini daha anlaşılabilir hale getirmeyi amaçlar. Bu yöntemler, modelin çıktısı ile girdisi arasındaki türevsel ilişkiyi inceleyerek hangi girdilerin model kararını ne ölçüde etkilediğini belirler. VİT modellerinde bu yaklaşımlar, dikkat mekanizmasının karmaşıklığını anlamaya yönelik güçlü bir araç sunar.

2.2.1 Grad-CAM ve Transformerlar için Genişletmeleri

Grad-CAM (Gradient-weighted Class ActivationMapping), derin öğrenme modellerinin sınıflandırma görevlerinde hangi bölgelerin daha önemli olduğunu görselleştirmek için kullanılan bir yöntemdir. Grad-CAM, özellikle ConvolutionalNeural Network (CNN) tabanlı modellerde yaygın bir şekilde uygulanmış olsa da, VİT gibi modeller için genişletilmiştir. Temel prensip, bir sınıfın aktivasyon haritasını gradyan bilgisi ile ağırlıklandırma yapılarak, modelin kararına en fazla katkıda bulunan bölgeleri görselleştirmektir. Matematiksel olarak, Grad-CAM şu şekilde ifade edilir:

$$L^{\text{Grad-CAM}} = \text{ReLU} \left(\sum_k \alpha_k A^k \right),$$

Burada;

- $\alpha_k = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k}$ sınıf c için gradyan ağırlıklarını temsil eder,
- A^k , aktivasyon haritasını ifade eder,
- Z , normalizasyon faktörüdür,
- ReLU, yalnızca pozitif katkıları vurgulamak için kullanılır.
- Transformerlar için Grad-CAM genişletmeleri, çok başlıklı dikkat mekanizmalarını analiz ederek dikkat haritalarının görselleştirilmesini sağlar. Bu yöntem, VİT modellerinde her bir dikkat başlığının farklı girdiler üzerindeki etkisini ayrı ayrı inceleme imkanı tanır (Chefer, H., vd., 2021).

2.2.2 ViT'lerden Elde Edilen Saliency Haritaları

Saliency haritaları, bir modelin girdiye olan duyarlılığını görselleştirmek için kullanılan bir başka gradyan tabanlı yaklaşımdır. Bu yöntem, her bir girdinin model çıktısına olan katkısını hesaplar ve görselleştirir. Matematiksel olarak, saliency haritası şu şekilde tanımlanır:

$$S(x) = \left| \frac{\partial y}{\partial x} \right|,$$

Burada:

- y , modelin çıktısını,
- x , modelin girdisini ifade eder.

VİT modellerinde, saliency haritaları dikkat mekanizmasının odaklandığı girdileri görselleştirir. Ancak bu haritaların yorumlanabilirliği, dikkat mekanizmasının açıklayıcı olup olmadığına dair tartışmaları beraberinde getirmiştir (Jainand, S., ve Wallace, B.C. 2019). Özellikle, saliency haritalarının doğruluğu, gradyan bilgilerinin düzgün bir şekilde hesaplanmasına ve dikkat başlıklarının yeterince temsil edilmesine bağlıdır. Sonuç olarak, gradyan tabanlı yöntemler VİT modellerinin açıklanabilirliğini artırmak için etkili araçlar sunar. Ancak, bu yöntemlerin doğruluğu ve tutarlılığı, hem matematiksel hassasiyet hem de dikkat mekanizmasının doğasına bağlıdır.

2.3 Atıf Tabanlı Yöntemler

Atıf tabanlı yöntemler, modelin girdilerle çıktılar arasındaki ilişkiyi analiz ederek hangi girdilerin model kararına ne ölçüde katkıda bulunduğunu belirlemeye çalışır. Bu yöntemler, özellikle VİT modellerinde, modelin dikkat mekanizmalarının ve diğer yapısal öğelerinin açıklanabilirliğini artırmak için kullanılmaktadır.

2.3.1 Entegre Gradyanlar

Entegre Gradyanlar, bir girdinin model çıktısına yaptığı katkıyı, belirli bir referans noktası ile karşılaştırarak ölçen etkili bir yöntemdir. Bu yöntem, modelin belirli bir girdiye verdiği tepkiyi, referans noktasından itibaren hesaplanan gradyanları entegre ederek belirler. Matematiksel olarak şu şekilde ifade edilir:

$$\text{IntegratedGradients}_i(x) = (x_i - x_i^0) \int_{\alpha=0}^1 \frac{\partial F(x^0 + \alpha(x - x^0))}{\partial x_i} d\alpha$$

Burada:

- x , modelin girdisini,
- x_0 , referans noktasını,
- F , modelin çıktı fonksiyonunu ifade eder. Bu yöntem, girdinin model çıktısına olan katkısını ölçeklendirerek, hangi girdilerin karar üzerinde etkili olduğunu anlamamıza yardımcı olur (Sundararajan, M., vd., 2017).

2.3.2 Dikkat Akışı ve İlgililik Yayılımı

Dikkat akışı (attentionflow), VİT modellerindeki çok başlıklı dikkat mekanizmalarını analiz ederek modelin girdilere olan odaklanma derecesini açıklamayı hedefler. Bu yöntem, modelin dikkat haritalarını değerlendirerek hangi girdilere daha fazla ağırlık verildiğini ortaya koyar. Özellikle bir girdiden çıkan dikkatin model çıktısına olan katkısı

nı analiz eder (Chefer, H., vd., 2021). İlgililik yayılımı (relevancepropagation) ise, modelin çıktısını girdilere doğru geri izleyerek açıklamalar sunar. Bu yöntem, VİT modellerinde dikkat mekanizmalarının yanı sıra, katmanlar arası ilişkileri ve girdiler üzerindeki etkileri ortaya koymak için kullanılır. İlgililik yayılımı, özellikle modelin öğrenme sürecinde hangi özelliklerin önemli olduğunu anlamaya yardımcı olur (Bach, S., vd., 2015). Bu yöntemler, VİT modellerinin açıklanabilirliğini artırmak için etkili araçlar sunar. Ancak her yöntemin sınırlamaları ve avantajları, modelin yapısına ve kullanım senaryosuna göre değişebilir.

2.4 Dikkat Tabanlı Yorumlanabilirlik

VİT modellerinde, kendine dikkat mekanizması, modelin girdilerin farklı bölümleri arasındaki ilişkileri nasıl değerlendirdiğini anlamak için temel bir bileşendir. Bu mekanizmanın görselleştirilmesi, modelin hangi girdilere daha fazla ağırlık verdiğini anlamayı sağlar. Matematiksel olarak, çok başlıklı dikkat (multiheadattention) şu şekilde tanımlanır:

$$A = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right),$$

Burada:

- $Q \in \mathbb{R}^{n \times d_k}$: Sorgu matrisini,
- $K \in \mathbb{R}^{n \times d_k}$: Anahtar matrisini,
- $A \in \mathbb{R}^{n \times n}$: Dikkat haritasını ifade eder.

Bu harita, modelin girdiler arasında bilgi akışını nasıl yönlendirdiğini gösterir. Dikkat haritalarının görselleştirilmesi, modelin öğrenme sürecinde hangi girdilerin önemli olduğunu anlamaya olanak tanır (Vaswani, A., vd., 2017).

2.4.1 Dikkat Mekanizması Açıklama mıdır?

Dikkat mekanizmasının doğrudan bir açıklama olup olmadığı, literatürde tartışmalı bir konudur. Bazı çalışmalar, dikkat haritalarının, modelin kararlarını anlamak için yeterli açıklayıcı güç sunduğunu öne sürerken (Chefer, H., vd., 2021). diğerleri bu haritaların doğruluğu ve tutarlılığı konusunda şüpheler dile getirmiştir (Jainand, S., ve Wallace, B.C., 2019). Özellikle, dikkat haritalarının model kararlarının ardındaki nedenselliği tam anlamıyla yansıtıp yansıtmadığı hala açık bir araştırma alanıdır.

2.5 Bozulmaya Dayalı Yöntemler

Bozulmaya dayalı yöntemler, modelin girdiler üzerinde hangi özelliklere daha fazla bağımlı olduğunu anlamak için kullanılan güçlü bir yaklaşımdır. Bu yöntemler, girdiler üzerinde yapılan değişikliklerin model çıktısına olan etkilerini analiz eder.

2.5.1 ViT Yamalarında Kapatma Hassasiyeti

Kapatma (occlusion) yöntemleri, model girdisinin belirli bölümlerinin geçici olarak kapatılmasını içerir. Bu süreçte, bir yama x_p , kapatılarak modelin çıktısındaki değişiklikler gözlemlenir:

$$\Delta F(x, x_p) = F(x) - F(x \setminus x_p),$$

burada:

- $F(x)$: Modelin tüm girdi x üzerindeki çıktısını
- x_p : Kapatı yama bölgesini, 11
- $\Delta F(x, x_p)$: Yamanın model çıktısına olan etkisini ifade eder.

Bu yöntem, belirli yamaların model kararına olan etkisini belirlemek için kullanılır ve modelin hangi bölgelere odaklandığını anlamayı sağlar (Zeilerand, M.D., ve Fergus, R., 2014).

2.5.2 Bozulmaların Özellik Önemini Ortaya Çıkarması

Bozulmalar, model girdisinde yapılan rastgele veya belirli değişikliklerdir ve modelin bu değişikliklere nasıl tepki verdiği analiz edilerek özelliklerin önemi ortaya çıkarılır. Örneğin, bir görüntüdeki belirli bir pikselin bozulması, model çıktısında önemli bir değişiklik yaratıyorsa, bu pikselin model için kritik olduğu söylenebilir. Matematiksel olarak:

$$S(x_i) = |F(x) - F(x \setminus x_i)|,$$

Burada $S(x_i)$, girdinin x_i kısmının önemini ölçer. Bu yöntem, modelin girdilere olan hassasiyetini ve hangi girdilerin daha fazla açıklayıcı

güce sahip olduğunu belirlemede etkili bir araçtır (Fongand, R.C., ve Vedaldi, A., 2017). Bozulmaya dayalı yöntemler, özellikle VİT modellerinde, girdilerin farklı bölümlerinin model kararlarına olan etkisini anlamada güçlü bir araç sunar. Ancak, bu yöntemlerin hesaplama maliyetleri ve modelin açıklanabilirliği üzerindeki sınırlamaları dikkate alınmalıdır.

2.6 Hibrit Yöntemler

Hibrit yöntemler, gradyan tabanlı ve bozulmaya dayalı yaklaşımların avantajlarını birleştirerek daha güçlü ve kapsamlı açıklamalar sunmayı hedefler. Bu yöntemler, farklı metodolojilerin birbirini tamamlayıcı özelliklerini kullanarak hem girdilerin hem de model çıktılarının daha derin bir şekilde analiz edilmesini sağlar. Ayrıca, dışsal modellerin (externalmodels) kullanımı ile açıklamaların doğruluğunu ve güvenilirliğini artırmaya yönelik yaklaşımlar da bu başlık altında incelenir.

2.6.1 Gradyan ve Bozulmaya Dayalı Yöntemlerin Birleştirilmesi

Gradyan tabanlı yöntemler, modelin girdiler üzerindeki türevlerini analiz ederek açıklamalar sunar. Ancak bu yöntemler, lokal duyarlılık ile sınırlı olabilir ve modelin karar mekanizmasını tamamen açıklamakta yetersiz kalabilir. Öte yandan bozulmaya dayalı yöntemler, girdiler üzerinde yapılan değişikliklerin model çıktısına etkisini analiz eder. Hibrit yöntemler, bu iki yaklaşımı birleştirerek daha kapsamlı bir analiz sunar.

Matematiksel olarak, hibrit bir yaklaşım şu şekilde ifade edilebilir:

$$S(x_i) = \alpha \cdot \left| \frac{\partial F(x)}{\partial x_i} \right| + \beta \cdot \Delta F(x, x_i),$$

Burada:

- α ve β : Gradyan ve bozulma tabanlı bileşenlerin ağırlıklarını temsil eden katsayılardır,
- $\partial F(x)/\partial x_i$: Gradyan tabanlı açıklama bileşenini ifade eder,
- $\Delta F(x, x_i)$: Bozulma tabanlı açıklama bileşenidir.

Bu birleştirme, modelin hem lokal hem de global açıklanabilirliğini artırmayı hedefler. Örneğin, bir VİT modeli için, dikkat haritalarının gradyan bilgileri ile desteklenmesi, modelin girdilere olan odaklanma derecesini daha kesin bir şekilde ortaya çıkarabilir (Chefer, H., vd., 2021).

2.6.2 Açıklamaları Doğrulamak için Dışsal Modellerin Kullanımı

Dışsal modeller, bir açıklamanın doğruluğunu ve güvenilirliğini değerlendirmek için kullanılan ek araçlardır. Bu modeller, açıklama yöntemlerinin ürettiği sonuçları analiz ederek modelin girdiler üzerindeki karar mekanizmalarını doğrulama sürecine katkı sağlar. Örneğin, bir dışsal model, VİT' nin dikkat mekanizmalarının, modelin asıl çıktıları ile uyumlu olup olmadığını analiz edebilir. Matematiksel olarak, bir dışsal model G , açıklama $S(x)$ ' nin doğruluğunu şu şekilde değerlendirir:

$$V(S(x)) = E[|F(x) - G(S(x))|],$$

Burada:

- $F(x)$: Orijinal modelin çıktısını ifade eder,
- $G(S(x))$: Dışsal modelin açıklamalardan ürettiği tahmini çıktıyı temsil eder,
- $V(S(x))$: Açıklamanın doğruluğunu ölçen bir değerlendirme metriğidir. Bu yöntem, açıklamaların yalnızca modelin içsel özellikleri ile değil, aynı zamanda dışsal bir referans çerçevesine göre doğruluğunu ve tutarlılığını değerlendirmek için kullanılır (Lundbergand, S.M., ve Lee, S.I., 2017).

2.6.3 Avantajlar ve Sınırlamalar

Hibrit yöntemler, açıklanabilirlikte daha fazla doğruluk ve kapsam sağlayabilir. Ancak bu yöntemlerin uygulanması genellikle yüksek hesaplama maliyetleri gerektirir. Ayrıca, dışsal modellerin etkinliği, kullanılan açıklama yöntemlerinin doğruluğu ve dışsal modelin güvenilirliğine bağlıdır.

3. UYGULAMA

3.1 Veri Kümesi ve Önışleme

Bu çalışmada, VİT modellerinin eğitimi ve değerlendirilmesi için ImageNet veri kümesi kullanılmıştır. Görseller, modelin giriş gereksinimlerini karşılayacak şekilde ön işlenmiştir. Bu süreç, görsellerin yeniden boyutlandırılmasını, tensörlere dönüştürülmesini ve normalize edilmesini içerir. Aşağıdaki Python kodu, bu işlemlerin nasıl gerçekleştirildiğini göstermektedir.

```

1 import torch
2 from torchvision import datasets, transforms
3
4
5 dataset = datasets.ImageNet(
6     root='data',
7     split='train',
8     download=True,
9     transform=transforms.Compose([
10         transforms.Resize((224, 224)),
11         transforms.ToTensor(),
12         transforms.Normalize(mean=[0.485, 0.456, 0.406],
13                                std=[0.229, 0.224, 0.225])
14     ])
15 )
16
17
18 data_loader = torch.utils.data.DataLoader(
19     dataset,
20     batch_size=32,
21     shuffle=True,
22     num_workers=4
23 )

```

Listing 1: ImageNet Veri Kümesi ve Ön İşleme

3.1.1 Ön İşleme Adımları

1. Görsellerin 224×224 boyutuna yeniden boyutlandırılması, VİT modellerinin giriş boyutunu karşılamak için zorunludur.

2. Görseller tensörlere dönüştürülür ve her piksel değeri $[0, 1]$ aralığına normalleştirilir.

3. ImageNet veri kümesi için önceden hesaplanmış ortalama ($\mu = [0.485, 0.456, 0.406]$) ve standart sapma ($\sigma = [0.229, 0.224, 0.225]$) değerleri kullanılarak normalizasyon uygulanır. Matematiksel olarak bu işlem, her piksel değeri için aşağıdaki formüle göre gerçekleştirilir:

$$x' = \frac{x - \mu}{\sigma},$$

Burada:

- x : Ham piksel değerlerini ifade eder.
- μ : Kanal başına ortalama değerleri ifade eder.
- σ : Kanal başına standart sapmayı ifade eder.

Bu ön işleme adımları, modelin giriş önyargılarını azaltarak eğitimi ve doğruluğu iyileştirmeyi hedefler.

3.2 Model Eğitimi ve İnce Ayar

VİT modelleri, önceden eğitilmiş (pre-trained) ağırlıklarla kullanılarak birçok görevde etkili sonuçlar verebilmektedir. Bu çalışmada, HuggingFace ve PyTorch kütüphanelerinden sağlanan önceden eğitilmiş bir VİT modeli kullanılmıştır. Model, hedef veri kümesinde (ör. ImageNet) ince ayar (fine-tuning) yapılarak optimize edilmiştir.

3.2.1 Model Seçimi ve Kurulumu

HuggingFace'in transformers kütüphanesi kullanılarak önceden eğitilmiş bir VİT modeli indirilmiş ve eğitim için hazırlanmıştır. Aşağıdaki Python kodu, modelin yüklenmesi ve eğitim sürecinin nasıl başlatıldığını göstermektedir.

```
1 from transformers import ViTForImageClassification,
   Trainer, TrainingArguments
2 from datasets import load_dataset
3
4
5 dataset = load_dataset("imagenet-1k")
6
7
8 model = ViTForImageClassification.from_pretrained(
9     "google/vit-base-patch16-224",
10    num_labels=1000
11 )
12
13
14 training_args = TrainingArguments(
15     output_dir="./results",
16     evaluation_strategy="epoch",
17     save_strategy="epoch",
18     learning_rate=5e-5,
19     per_device_train_batch_size=32,
20     per_device_eval_batch_size=32,
21     num_train_epochs=10,
22     weight_decay=0.01,
23     logging_dir="./logs",
```

```

24     logging_steps=10,
25     load_best_model_at_end=True
26 )
27
28
29 trainer = Trainer(
30     model=model,
31     args=training_args,
32     train_dataset=dataset["train"],
33     eval_dataset=dataset["validation"]
34 )
35
36
37 trainer.train()

```

Listing 2: Önceden Eğitilmiş ViT Modeli ve İnce Ayar

3.2.2 İnce Ayar (Fine-Tuning) Süreci

İnce ayar süreci, modelin hedef veri kümesinde daha iyi performans göstermesi için önceden eğitilmiş ağırlıkların yeniden optimize edilmesini içerir. Bu süreçte kullanılan temel teknikler şunlardır:

1. **Öğrenme Oranı Planlaması (Learning Rate Scheduling):** İnce ayar sırasında, düşük bir öğrenme oranı (5×10^{-5}) tercih edilmiştir. Bu, modelin önceden öğrenilmiş bilgilerini koruyarak yeni veriye adapte olmasını sağlar.
2. **Ağırlık Çürümesi (WeightDecay):** Ağırlık çürümesi ($\lambda = 0.01$) kullanılarak aşırı öğrenme (overfitting) riski azaltılmıştır.
3. **Eğitim ve Değerlendirme Stratejileri:** Model her dönem (epoch) sonunda değerlendirilmiş ve en iyi performansı gösteren ağırlıklar kaydedilmiştir.

3.2.3 Eğitim Sürecinin Matematiksel çerçevesi

Modelin kayıp fonksiyonu (L) aşağıdaki gibi tanımlanmıştır:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N y_i \log(\hat{y}_i),$$

Burada:

- y_i : Gerçek sınıf etiketini,
- $\hat{y}_i$: Model tarafından tahmin edilen sınıf olasılığını,
- N: Eğitim örneklerinin sayısını ifade eder.

Bu kayıp fonksiyonu, çapraz entropi (cross-entropy) olarak bilinir ve sınıflandırma problemleri için standart bir seçenektir.

3.2.4 Sonuçlar ve Gözlemler

İnce ayar işlemi sırasında, eğitim kaybı (Ltrain) ve doğrulama kaybı (Lval) dönemler boyunca takip edilmiştir. Performans ölçütü olarak doğruluk (Accuracy) kullanılmıştır ve modelin hedef veri kümesinde etkili bir şekilde öğrenim sağladığı gözlemlenmiştir.

3.3 Açıklanabilirlik Deneyleri

Bu çalışmada, VisionTransformer (VİT) modellerinin karar mekanizmalarını anlamak için üç farklı açıklama yöntemi uygulanmıştır: Grad-CAM, AttentionRollout ve TransformerAttribution. Bu yöntemler, modelin girdiler üzerindeki kararlarını görselleştirmek ve anlamlandırmak için seçilmiştir.

3.3.1 Grad-CAM Uygulaması

Grad-CAM, sınıflandırma görevlerinde modelin hangi bölgeleri daha önemli gördüğünü görselleştirmek için gradyan bilgilerini kullanır. Bu yöntem, sınıf aktivasyon haritalarını hesaplayarak modelin hangi giriş özelliklerine odaklandığını analiz eder. Matematiksel olarak, Grad-CAM aşağıdaki şekilde ifade edilir:

$$L^{\text{Grad-CAM}} = \text{ReLU} \left(\sum_k \alpha_k A^k \right),$$

Burada:

- $\alpha_k = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k}$: Gradyan ağırlıkları,
- A^k : Katman aktivasyon haritasını ifade eder,
- Z : Aktivasyon haritasının boyutlarını ifade eder.

Grad-CAM, modelin kritik bölgeleri görselleştirerek VİT modellerinin kararlarını anlamaya katkı sağlar. Aşağıdaki Python kodu Grad-CAM uygulamasını göstermektedir:

```

1 import torch, cv2, numpy as np
2
3 class GradCam:
4     def __init__(self, model, layer):
5         self.model, self.feature, self.gradient =
            model.eval(), None, None
6         target = dict(model.named_modules())[layer]
7         target.register_forward_hook(lambda _, __, out:
            setattr(self, 'feature', out))
8         target.register_full_backward_hook(lambda _,
            __, grad: setattr(self, 'gradient', grad[0]))
9
10    def generate_cam(self, input_tensor,
        target_class=None):
11        self.model.zero_grad()
12        output = self.model(input_tensor)
13        (output[0][target_class or
            output.argmax(dim=1).item()]).backward()
14        grad = self.gradient[0].cpu().numpy()
15        weights = grad.mean(axis=(1, 2))
16
17        cam =
            np.maximum(np.sum(self.feature[0].cpu().numpy()
                * weights[:, None, None], axis=0), 0)
18    return cv2.resize((cam - cam.min()) /
        (cam.max() - cam.min()), (224, 224))

```

Listing 3: Compact Grad-CAM Implementation

3.3.2 AttentionRollout

Attention Rollout, VİT modellerinin çok başlıklı dikkat mekanizmalarını analiz eder. Bu yöntem, dikkat matrislerini birleştirerek hangi girdilerin sınıf tahminine katkıda bulunduğunu görselleştirir. Rollout yöntemi şu şekilde ifade edilir:

$$M = \prod_{i=1}^L (A^i + I),$$

Burada:

- M: Nihai dikkat matrisi,
- Aⁱ: i-inci katmanın dikkat matrisi,
- I: Kimlik matrisi (identitymatrix).

Python kodu aşağıdaki gibi uygulanmıştır:

```

1 import torch
2 import numpy as np
3 import copy
4
5 def rollout(attentions, discard_ratio, head_fusion):
6     result = torch.eye(attentions[0].size(-1))
7     with torch.no_grad():
8         for attention in attentions:
9             if head_fusion == "mean":
10                 attention_heads_fused =
11                     attention.mean(axis=1)
12             elif head_fusion == "max":
13                 attention_heads_fused =
14                     attention.max(axis=1)[0]
15             elif head_fusion == "min":
16                 attention_heads_fused =
17                     attention.min(axis=1)[0]
18
19             else:
20                 raise "Attention head fusion type Not
21                     supported"
22
23             I =
24                 torch.eye(attention_heads_fused.size(-1))
25             a = (attention_heads_fused + 1.0*I)/2
26             a = a / a.sum(dim=-1)
27
28             result = torch.matmul(a, result)
29
30     return result

```

Listing 4: Attention Rollout Implementation

3.3.3 TransformerAttribution

TransformerAttribution, transformer tabanlı modellerin girdiler üzerindeki etkilerini analiz etmek için güçlü bir yöntemdir. Özellikle modelin çıktısına katkıda bulunan girdilerin etkisini ölçer ve bunu bir ilgililik haritası olarak sunar. Bu yöntem, (Chefer, H., vd., 2021) tarafından tanıtılmış ve bu çalışmada uygulanmıştır.

4. SONUÇLAR VE TARTIŞMA

4.1 Görselleştirmeler


Bu bölümde, VİT modelinin açıklanabilirlik yöntemleriyle üretilen görselleştirmeler sunulmuştur. Görselleştirmeler, modelin karar mekanizmalarını anlamak için Grad-CAM, Attention Rollout ve Transformer Attribution gibi yöntemlerle oluşturulmuştur. Şekillerde, modelin dikkati hangi bölgelerde yoğunlaştırdığı ve bu bölgelerin insan sezgileriyle uyumlu olup olmadığı analiz edilmiştir.




Şekil 1: Orijinal Görüntü



Şekil 2: Attention Rollout Metodu



Şekil 3: Transformer Attribution Metodu



Şekil 4: Grad-CAM Metodu

4.2 Değerlendirme Metrikleri

Açıklanabilirlik yöntemlerinin etkililiğini değerlendirmek için çeşitli metrikler kullanılmaktadır. Bu metrikler, modelin karar mekanizmalarını ne derece doğru bir şekilde açıkladığını ölçmek için tasarlanmıştır. Bu bölümde, fidellik, tamlık ve saliency skorları gibi temel metrikler ele alınmıştır.

4.2.1 Fidellik (Fidelity)

Fidellik, bir açıklamanın modelin davranışını ne kadar iyi temsil ettiğini ölçer. Fidellik, genellikle açıklamanın çıkarılan veya değiştirilen

girdiler üzerindeki etkisini değerlendirerek hesaplanır. Matematiksel olarak şu şekilde ifade edilir:

$$F = \frac{1}{N} \sum_{i=1}^N (C(x_i) - C(x_i \setminus x'_i)) ,$$

Burada:

- F: Fidellik skorunu temsil eder.
- $C(x_i)$: Modelin x_i girdisi üzerindeki tahmin güveni.
- $C(x_i \setminus x'_i)$: x_i girdisinden açıklama ile çıkarılan x'_i kısmı sonrası tahmin güveni.
- N: Toplam test örneği sayısı.

Fidellik, bir açıklamanın modelin çıktısına ne kadar etkili olduğunu değerlendirmek için kullanılır.

4.2.2 Tamlik (Completeness)

Tamlık metriği, bir açıklamanın, modelin kararına katkıda bulunan tüm önemli bileşenleri ne derece kapsadığını ölçer. Bu metrik, açıklamanın eksiksiz olup olmadığını anlamak için kullanılır ve genellikle şu şekilde ifade edilir:

$$C = 1 - \frac{\sum_{i=1}^N |C(x_i) - C(x_i \setminus x'_i)|}{\sum_{i=1}^N C(x_i)} ,$$

burada $C(x_i)$, modelin x_i girdisi üzerindeki tahmin güvenini ifade eder. Tamlık metriği, açıklamanın modelin davranışını temsil etmedeki yeterliliğini ölçer.

4.2.3 Saliency Skorları ve Güven Değişimleri

Saliency skorları, bir modelin belirli bir sınıf için hangi giriş özelliklerine odaklandığını anlamak için kullanılan bir ölçümdür. Bu skorlar genellikle, modelin kararını hangi girdilerin daha fazla etkilediğini anlamak için kullanılır. Aşağıda örnek saliency skorları ve ilgili güven değişiklikleri verilmiştir:

Özellik (Girdi)	Saliency Skoru	Güven Değişimi
1	4038.18	0.4632
2	3379.99	0.4113
3	2934.71	0.2214
4	2365.24	0.1308
5	1803.09	0.1881
6	1328.34	0.1726
7	928.23	0.1428
8	558.88	0.1241
9	206.45	0.0657
10	9.83	-0.0255

Tablo 1: Sekil 4 Saliency skorları ve güven değişimleri.

Bu skorlar şu şekilde değerlendirilir:

- Yüksek saliency skorları, modelin kararını büyük ölçüde etkileyen girdileri temsil eder.
 - Güven değişimleri (Δ), açıklanan girdilerin çıkarılmasından veya değiştirilmesinden sonra modelin tahmin güvenindeki farkı ifade eder.
- Saliency skorları, fidellik ve tamlık gibi metriklerle birlikte kullanılarak açıklamanın etkililiği ve eksiksizliği değerlendirilebilir.

4.2.4 Genel Değerlendirme

Bu metrikler, açıklanabilirlik yöntemlerinin ne derece etkili olduğunu anlamak için kritik bilgiler sunar. Örneğin:

- Fidellik, açıklamanın modelin davranışına olan sadakatini ölçer.
- Tamlık, açıklamanın modelin tüm önemli bileşenlerini içerip içermediğini değerlendirir.
- Saliency skorları, modelin dikkat ettiği girdilerin önemini analiz eder.

Bu metrikler, bir açıklamanın insan sezgisiyle uyumluluğunu değerlendirmenin yanı sıra, modelin açıklanabilirliğini artırmaya yönelik potansiyel iyileştirme alanlarını da ortaya çıkarır.

5. SONUÇ

5.1 Özet

Bu çalışmada, VisionTransformer (VİT) modellerinin açıklanabilirliği üzerine bir analiz gerçekleştirilmiştir. VİT modelleri, kendine dikkat mekanizmaları ve yama temsilleri gibi özellikleriyle derin öğrenme alanında önemli bir yenilik sunmaktadır. Ancak, bu modellerin “kara kutu” doğası, kullanıcıların modellerin karar verme süreçlerini anlamasını zorlaştırmaktadır. Açıklanabilirlik yöntemleri, bu sorunu ele almak ve modellerin daha şeffaf olmasını sağlamak için kritik bir araç olarak ortaya çıkmıştır. Bu projede, üç temel açıklanabilirlik yöntemi incelenmiştir.

- Grad-CAM: Modelin belirli giriş özelliklerine odaklanma düzeyini görselleştirmiştir.

- AttentionRollout: Çok başlıklı dikkat mekanizmalarının çıktıları arasındaki bilgi akışını analiz etmiştir.

- TransformerAttribution: Modelin girdilere ilişkin ilgililik haritalarını sağlamıştır.

Bu yöntemler, VİT modellerinin karar süreçlerini anlamada farklı perspektifler sunmuş ve açıklamaların hem insan sezgileriyle uyumluluğunu hem de etkililiğini değerlendirmek için fidellik, tamlık ve saliency skorları gibi metriklerle desteklenmiştir. Elde edilen bulgular, VİT modellerinin karar mekanizmalarının hem lokal hem de global düzeyde daha iyi anlaşılmasını sağlamıştır.

5.2 Gelecek Yönelimler

Açıklanabilirlik, ViT ve diğer transformer tabanlı modellerin gerçek dünya uygulamalarında daha güvenilir ve etik bir şekilde kullanılabilmesi için geliştirilmesi gereken bir alandır. Gelecekte bu alanda aşağıdaki yönergeler üzerinde çalışılması önerilmektedir.

5.2.1 Daha Gelişmiş Açıklanabilirlik Teknikleri

ViT modellerinin kendine dikkat mekanizmalarının karmaşıklığı göz önüne alındığında mevcut açıklanabilirlik yöntemlerinin doğruluk ve kapsam açısından sınırları bulunmaktadır. Gelecekte:

- Gradyan ve dikkat tabanlı yöntemlerin birleştirilerek daha kapsamlı açıklamalar sağlanması,

- Dikkat mekanizmalarının zaman boyutunda nasıl değiştiğini analiz eden yöntemlerin geliştirilmesi,

- ViT modellerinin yanı sıra diğer transformer tabanlı modellerle de uyumlu açıklama tekniklerinin geliştirilmesi üzerinde durulmalıdır.

5.2.2 Gerçek Dünya Uygulamaları

Açıklanabilirlik yöntemlerinin gerçek dünya uygulamalarında daha etkili hale getirilmesi için:

- Tıp: ViT modelleri, medikal görüntüleme gibi alanlarda yaygın olarak kullanılmaktadır. Açıklanabilirlik yöntemleri, modellerin doğru teşhislerde bulunmasına katkı sağlayabilir.

- Otonom Sistemler: Otonom araçlar ve robotik sistemlerde kullanılan modellerin kararlarını açıklayabilmesi, güvenlik açısından kritik öneme sahiptir.

- Hukuk ve Etik: Karar destek sistemlerinde, modellerin kararlarının nedenlerini şeffaf bir şekilde açıklayabilmesi, etik ve yasal sorumlulukların yerine getirilmesine yardımcı olacaktır.

5.2.3 Transformer Tabanlı Diğer Modeller İçin Açıklanabilirlik

Sonuç olarak, bu proje ViT modellerinin açıklanabilirliği için bir çerçeve sunmuş ve açıklama yöntemlerinin etkinliğini değerlendirmiştir. Açıklanabilirlik, ViT modellerinin gerçek dünyadaki adaptasyonu için kritik bir gereklilik olarak görülmektedir. Gelecekteki çalışmalar, açıklanabilirlik

yöntemlerinin doğruluğunu ve verimliliğini artırarak, modellerin daha geniş bir alanda güvenle kullanılmasını sağlayabilir.

KAYNAKLAR

Arrieta, A.B., vd., (2020). "Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges to ward responsible AI," *Information Fusion*, 58:82-115.

Bach, S., Binder, A., Montavon, G., Klauschen, F., Muller, K.R., ve Samek, W., (2015). "On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation," PLoS ONE".

Chefer, H., Gur, S., ve Wolf, L., (2021). "Transformer interpretability beyond attention visualization," in Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition.

Doshi-Velezand, P., ve Kim, B., (2017). "Towards a rigorous science of interpretable machine learning," arXiv preprint arXiv:1702.08608.

Dosovitskiy, A., vd., (2020). "An image is worth 16x16 words: Transformers for image recognition at scale," arXiv preprint arXiv:2010.11929.

Fongand, R.C. ve Vedaldi, A., (2017). "Interpretable explanations of black boxes by meaning perturbation," in Proceedings of the IEEE International Conference on Computer Vision.

Krizhevsky, A., Sutskever, I., ve Hinton, G.E., (2012). "Image Net Classification with deep convolutional neural networks," in Advances in neural information processing systems.

Jainand, S., ve Wallace, B.C., (2019). "Attention is not explanation," in Proceedings of the Conference of the North American Chapter of the Association.

Lundbergand, S.M. ve Lee, S.I., (2017). "A unified approach to interpreting model predictions," in Advances in Neural Information Processing Systems.

Selvaraju, R.R., vd., (2017). "Grad-CAM: Visual explanations from deep networks via gradient-based localization," in Proceedings of the IEEE International Conference on Computer Vision.

Sundararajan, M., Taly, A., ve Yan. Q., (2017). "Axiomatic attribution for deep networks," in International Conference on Machine Learning.

Vaswani, A., vd., (2017). "Attention is all you need," in Advances in neural information processing systems.

Zeilerand, M.D., ve Fergus, R., (2014). “Visualiz in g and understanding convolutional networks,” in European Conference on Computer Vision.

Makine Öğrenmesi İle İnsan Kaynakları Chatbotu Geliştirme: Niyet Sınıflandırma Ve Yanıt Üretimi

Selma DEMİREL¹

Prof. Dr. Erol TERZİ²

Arş. Gör. Mehmet Şirin ATEŞ³

- 1- Selma DEMİREL; Ulusoy UN A.Ş., Samsun. selmademirel55@hotmail.com ORCID No: 0009-0001-4855-4235
- 2- Prof. Dr. Erol TERZİ; Ondokuz Mayıs Üniversitesi Fen Fakültesi İstatistik Bölümü. eroltr@omu.edu.tr ORCID No: 0000-0002-2309-827X
- 3- Arş. Gör. Mehmet Şirin ATEŞ; Ondokuz Mayıs Üniversitesi Fen Fakültesi İstatistik Bölümü. mehmet.ates@omu.edu.tr ORCID No: 0000-0001-9904-6380

ÖZET

Bu çalışma, insan kaynakları departmanlarına yöneltilen sık sorulan sorulara otomatik yanıt verebilen bir chatbot sistemi geliştirmek amacıyla gerçekleştirilmiştir. Geliştirilen sistemde, doğal dil işleme (NLP) ve makine öğrenmesi teknikleri birlikte kullanılarak, kullanıcıdan gelen metinsel girdilere doğru ve anlamlı yanıtlar sunulması hedeflenmiştir.

Proje kapsamında etiketlenmiş Türkçe bir veri seti kullanılmış; veri kümesinde her bir örnek “soru metni”, “niyet (intent)” ve “verilecek yanıt” şeklinde üç sütundan oluşmuştur. İki farklı modelleme yöntemi uygulanmıştır. İlkinde, TF-IDF yöntemiyle metinler vektörleştirilmiş, cosine similarity yardımıyla yeni soruların eğitim verisindeki en benzer sorularla karşılaştırılması sağlanmış ve en yakın sorunun yanıtı sunulmuştur. Diğer yöntemde ise, Logistic Regression algoritması kullanılarak kullanıcı girdisinin ait olduğu niyet sınıfı tahmin edilmiş ve bu sınıfa özel yanıt verilmiştir.

Modelleme süreci Python diliyle yürütülmüş, eğitim ve test aşamalarında çapraz doğrulama kullanılarak performans değerlendirilmiştir. Ayrıca, Streamlit kütüphanesiyle geliştirilen web tabanlı kullanıcı arayüzü sayesinde chatbot’un etkileşimli olarak test edilmesi sağlanmıştır.

Sonuç olarak, her iki yöntemle geliştirilen chatbot sisteminin, sınırlı veriyle dahi başarılı yanıtlar üretebildiği ve çalışan memnuniyetine katkı sağlayacak şekilde uygulanabilir olduğu gözlemlenmiştir. Gelecek çalışmalarda daha büyük veri kümeleriyle eğitilmiş, BERT veya GPT tabanlı modellerle desteklenmiş sistemlerin daha yüksek doğrulukla çalışması mümkün olacaktır.

Anahtar Kelimeler – Chatbot, İnsan Kaynakları, TF-IDF, Logistic Regression, Streamlit, Makine Öğrenmesi

GİRİŞ

Günümüz iş dünyasında çalışan memnuniyeti, verimlilik ve süreç optimizasyonu gibi kavramlar her geçen gün daha fazla önem kazanmaktadır. Özellikle İnsan Kaynakları (İK) departmanları; işe alım, bordro, izin, özlük işlemleri gibi operasyonel görevlerle büyük bir iş yükü altında çalışmaktadır. Artan çalışan sayısı ve bilgi talepleri, İK profesyonellerinin hem verimli çalışmasını zorlaştırmakta hem de zamanında ve doğru bilgi akışını engellemektedir. Bu noktada, dijital dönüşüm uygulamaları ve yapay zekâ destekli sistemler, İK süreçlerini kolaylaştırmak ve çalışanlara hızlı yanıtlar sunmak adına etkili çözümler sunmaktadır.

Bu bağlamda geliştirilen chatbot teknolojileri; kurum içi iletişimi güçlendiren, tekrarlayan sorulara otomatik yanıt verebilen ve 7/24 erişilebilir

dijital asistanlar olarak ön plana çıkmaktadır. Chatbot sistemleri, doğal dil işleme (NLP) ve makine öğrenmesi (ML) tekniklerinin birleşimiyle geliştirilmekte ve kullanıcılardan gelen serbest metin biçimindeki soruları anlayarak uygun yanıtları otomatik olarak sunmaktadır. Bu sistemler; İK süreçlerinde sadece operasyonel verimlilik sağlamakla kalmaz, aynı zamanda çalışan deneyimini artıran önemli araçlar haline gelmiştir.

Türk Dil Kurumu sözlüğüne göre “sohbet robotu” ya da “konuşma robotu” olarak da adlandırılan chatbotlar, kullanıcılarla önceden tanımlanmış ya da öğrenilmiş bilgilere dayanarak metin veya ses yoluyla etkileşime geçebilen yapay zekâ destekli uygulamalardır. Özellikle son yıllarda kurumsal alanda yaygınlaşan chatbot sistemleri, ilk etapta müşteri hizmetleri için geliştirilmiş olsa da, artık İnsan Kaynakları gibi iç hizmet birimlerinde de yaygın olarak kullanılmaktadır.

Bu çalışma kapsamında, İnsan Kaynakları departmanlarına gelen sık sorulan sorulara hızlı ve doğru yanıtlar verebilecek bir chatbot sistemi geliştirilmiştir. Sistemde, iki temel yöntem uygulanmıştır: 1) TF-IDF ve cosine similarity yöntemi ile benzer soruların bulunması ve yanıtlanması, 2) Logistic Regression algoritması ile sorunun niyet sınıfının belirlenmesi ve uygun yanıtın sunulması. Python dili ile geliştirilen bu model, etiketli bir Türkçe veri kümesi üzerinde eğitilmiş ve doğruluğu değerlendirilmiştir. Geliştirilen sistemin kullanıcı arayüzü, Streamlit tabanlı olarak tasarlanmış ve kullanıcıların etkileşimli bir biçimde chatbot ile iletişim kurmaları sağlanmıştır.

Yapılan bu çalışmada, sınırlı veri ile dahi makine öğrenmesi temelli bir chatbot’un yüksek doğrulukla çalışabileceği, İK süreçlerinde iş yükünü azaltabileceği ve dijital dönüşüme katkı sunabileceği gösterilmiştir. Geliştirilen sistem, yalnızca teknik açıdan değil, aynı zamanda çalışan memnuniyetine yönelik stratejik bir araç olarak da değerlendirilmektedir.

1.1. Problemin Tanımı

İnsan Kaynakları departmanları, çalışanlardan gelen tekrarlayan ve operasyonel nitelikteki bilgi taleplerini zamanında ve tutarlı şekilde karşılamak zorundadır. Bu tür taleplerin manuel olarak yanıtlanması, iş gücü ve zaman açısından ciddi maliyetler doğurmakta, aynı zamanda bilgiye erişimde gecikmelere yol açabilmektedir. Bu nedenle, çalışanlardan gelen sorulara hızlı ve doğru yanıtlar verebilecek, öğrenebilen ve gelişebilen bir otomatik yanıt sistemi tasarlanması büyük önem taşımaktadır.

Chatbot sistemleri, doğal dil işleme (NLP) ve makine öğrenmesi (ML) tekniklerinin yardımıyla bu ihtiyaca etkili bir çözüm sunmaktadır. Özellikle TF-IDF (Term Frequency–Inverse Document Frequency) yöntemi ile metin benzerliklerinin hesaplanması ve Logistic Regression gibi denetimli öğrenme algoritmaları ile niyet sınıflandırması yapılması, soruların anlamlandırılarak doğru yanıtın sunulmasına olanak sağlamaktadır. Bu bağlamda, bu projenin temel amacı; Python programlama dili kullanılarak etiketlenmiş bir Türkçe veri kümesi üzerinde, makine öğrenmesine dayalı bir

İK chatbot sistemi geliřtirmek ve bu sistemin hem benzerlik tabanlı hem de sınıflandırma temelli yöntemlerle performansını deęerlendirmektir.

Ayrıca, chatbot'un web arayüzü Streamlit platformu ile geliřtirilecek ve kullanıcıların doęal dilde sordukları sorulara yanıt alabilecekleri etkileřimli bir yapı oluřturulacaktır. Geliřtirilecek chatbotun, doęal dilde gelen kullanıcı sorularını anlayıp doęru kategoriye (niyete) sınıflandırması ve önceden tanımlanmış uygun yanıtı vermesi hedeflenmektedir.

Projede, sınırlı sayıda veriden yüksek doęrulukta sınıflandırma yapılabilmesinin yanı sıra, kullanılan yöntemlerin avantajları, sınırlılıkları ve İnsan Kaynakları süreçlerine saęlayacaęı katkılar da analiz edilerek raporlanacaktır.

1.2. Arařtırma Soruları

Yukarıda tanımlanan problem çerçevesinde, bu çalışmada geliřtirilecek olan makine öğrenmesi tabanlı İK chatbot sistemi ile ilgili olarak ařaęıdaki arařtırma soruları formüle edilmiştir:

- TF-IDF + Cosine Similarity yöntemi, benzer soruların eřleřtirilmesinde ne düzeyde doęru yanıtlar üretebilmektedir?
- Logistic Regression algoritması ile yapılan intent sınıflandırmasının doęruluk, hassasiyet ve F1 skoru gibi performans metrikleri nasıldır?
- İki yöntemin (benzerlik tabanlı ve sınıflandırma temelli) birlikte kullanımı, chatbot'un genel başarımını ve kullanıcı deneyimini nasıl etkilemektedir?
- Veri setinin sınıf daęılımı ve büyüklüęü, modellerin başarı düzeyini nasıl etkilemektedir?

2. LİTERATÜR TARAMASI

2.1. Geleneksel Chatbot Yaklaşımları

Chatbot sistemleri, insan-bilgisayar etkileřimini doęal dil aracılıęıyla kolaylařtırmayı amaçlayan yazılımsal yapılardır. Bu sistemlerin temel işlevi, kullanıcıdan gelen metin tabanlı girdilere bağlam açısından tutarlı, anlamlı ve işlevsel yanıtlar üretmektir. Chatbot teknolojilerinin tarihsel gelişimi incelendięinde, ilk örneklere 1960'lı yıllarda rastlanmaktadır. Bu bağlamda, literatürde en bilinen örneklerden biri, Massachusetts Institute of Technology (MIT) arařtırmacılarından Joseph Weizenbaum tarafından geliřtirilen ELIZA programıdır [1]. ELIZA, insanlarla yapılan psikoterapi görüşmelerini taklit etme amacıyla geliřtirilmiş olup, önceden tanımlı kurallara dayalı yanıtlar üretmiştir. Ancak bu sistem, kullanıcının gerçekte niyetini veya bağlamını anlayamayan, yalnızca kalıp eřleřtirmeye dayalı ilkel bir yapıya sahipti (Weizenbaum, 1966:36-45).


Geleneksel chatbot sistemleri, yapısal olarak kural tabanlı (rule-based) mimariye dayanmakta olup; kullanıcı girdilerini belirli kalıplara veya anahtar kelimelere göre eřleřtirerek, sabit yanıtlar üretmektedir. Bu

sistemler, yapılandırılmış ve öngörülebilir etkileşimler için yeterli düzeyde performans gösterse de, doğal dilin varyasyonlarına ve esnekliğine karşı sınırlı bir uyum kapasitesine sahiptir (Shawar ve Atwell, 2007:29-49). Bu nedenle, dilin bağlamdan türeyen anlam derinliğini işleyememekte, sonuç olarak kullanıcı memnuniyetini olumsuz etkileyebilmektedir.

2.1.1. Kural Tabanlı Sistemler

Kural tabanlı chatbotlar, bilgiye erişim ihtiyacını sabit sorgu-yanıt eşleşmeleri ile karşılayan ilkel yapay zeka örnekleridir. Bu sistemler, geliştirici tarafından manuel olarak tanımlanan koşullara göre çalışır. Her kullanıcı ifadesi, daha önceden belirlenmiş bir kuralla eşleştirilir ve buna karşılık gelen yanıt sunulur. Bu yaklaşım özellikle “sıkça sorulan sorular” (FAQ) gibi düşük varyasyonlu kullanıcı etkileşimlerinde etkinlik göstermektedir (Shawar ve Atwell, 2007:29-49).

Ancak bu yapıların en belirgin sınırlılığı, ölçeklenebilirliğinin düşüklüğü ve kuralların manuel tanımlanmasından doğan bakım maliyetidir. Örneğin, kullanıcı “Ne zaman açılıyorsunuz?” ve “Çalışma saatleri nedir?” gibi iki semantik açıdan benzer ifadeyi farklı şekilde dile getirdiğinde, sistemin her bir ifade için ayrı kurallar tanımlaması gerekir (Jurafsky ve Martin, 2021:3). Bu durum, sistemin yalnızca belirli ve önceden tanımlanmış senaryolara karşı yanıt verebilmesini sağlamakta; spontane ve bağlamsal etkileşimleri desteklememektedir.



Şekil 2.1.1.1. Kural Tabanlı Chatbot Akış Diyagramı

2.1.2. Anahtar Kelime Eşleştirmesi ve Kalıp Tabanlı Cevaplama

Geleneksel chatbot mimarilerinin bir diğer alt kümesi ise, anahtar kelime tabanlı ve pattern (kalıp) eşleştirme yaklaşımlarıdır. Bu sistemler, kullanıcı mesajlarını içerdiği anahtar kelimeler üzerinden değerlendirerek önceden tanımlanmış yanıtları sunar. Örneğin, “bordro”, “izin”, “maaş” gibi belirli kelimelerin tanınması, sistemin o kelimelerle ilişkili sabit bir yanıtı kullanıcıya iletmesini sağlar (Jurafsky ve Martin, 2021:3).

Bu yaklaşım, belirli bir gramer yapısına ya da veri kümesine dayalı olmadan geliştirilebilmesi sayesinde, teknik uygulama açısından avantaj sağlar. Özellikle AIML (Artificial Intelligence Markup Language) gibi

işaretleme dilleri ile desteklenerek genişletilebilir bir yapı oluşturur (Wallace, 2003:55-75). AIML sistemleri, her bir kullanıcı ifadesi için “pattern-template” eşleştirmesi yaparak çalışır. Ancak bu yapıların başarımı büyük ölçüde geliştiricinin öngördüğü kelime varyasyonlarının doğruluğuna ve sistemin genişliği ile doğrudan ilişkilidir. Bu nedenle, anlamdan çok biçime dayalı çalışan bu sistemler, semantik çeşitliliğe karşı oldukça kırılgandır.

2.2. Çağdaş Chatbot Yaklaşımları

Geleneksel chatbot sistemleri, belirli anahtar kelimeler veya kalıplar üzerinden önceden tanımlanmış sabit yanıtlar üretmeleri nedeniyle esneklikten yoksun kalmış ve kullanıcı girdilerindeki varyasyonları etkili biçimde işleyememiştir (Weizenbaum, 1966:36-45). Bu sınırlılıklar, doğal dilin yapısal karmaşıklığını, bağlamsal anlam ilişkilerini ve kullanıcı niyetini yeterince yorumlayamama sorunlarını beraberinde getirmiştir. Bu sebeple, chatbot teknolojilerinde daha gelişmiş yöntemlerin kullanımı kaçınılmaz hale gelmiştir.

Son yıllarda doğal dil işleme (Natural Language Processing – NLP), makine öğrenmesi (Machine Learning – ML) ve derin öğrenme (Deep Learning – DL) alanlarında yaşanan ilerlemeler, chatbot sistemlerini daha esnek, öğrenebilir ve bağlamsal farkındalığa sahip yapılar haline dönüştürmüştür (Jurafsky ve Martin, 2021:3). Bu sistemler artık yalnızca kelime eşleştirmeye değil, aynı zamanda dilin ardındaki anlamı ve kullanıcı amacını (intent) kavrayabilen yöntemlere dayanmaktadır.

Modern chatbot sistemlerinin temelinde, kullanıcıdan gelen doğal dildeki girdilerin vektör uzaylarında matematiksel olarak temsil edilmesi yatmaktadır. Bu temsiller sayesinde, metinler arasındaki benzerlikleri hesaplamak veya belirli sınıflara ait olma olasılıklarını tahmin etmek mümkün hale gelmiştir. Bu kapsamda çağdaş chatbot yaklaşımları iki ana paradigma altında incelenmektedir.

2.2.1. TF-IDF ve Cosine Similarity ile Soru Eşleştirme

Benzerlik tabanlı sistemlerde, kullanıcıdan gelen ifade önceden tanımlanmış soru-cevap çiftleriyle karşılaştırılarak en uygun yanıt belirlenir. Bu karşılaştırma genellikle TF-IDF (Term Frequency-Inverse Document Frequency) yöntemiyle vektörleştirilmiş metinler üzerinden gerçekleştirilir (Ramos, 2003:25). TF-IDF, bir kelimenin belirli bir belgede ne derece önemli olduğunu hesaplayarak, her ifadenin matematiksel temsilini oluşturur. Daha sonra cosine similarity metriği yardımıyla, gelen ifade ile veritabanındaki ifadeler arasındaki benzerlik derecesi hesaplanır.

Bu yöntemin temel avantajı, geniş örneklem setleriyle birlikte kullanıldığında esnek ve anlamlı eşleştirme yapabilmesidir. Ancak bu sistemler bağlam anlayışı içermez; yani yalnızca yüzeysel benzerlik üzerinden çalıştıkları için anlamsal bütünlüğü değerlendirmede sınırlıdır [8].

2.2.2. Niyet Sınıflandırma: Logistic Regression ve Alternatif Modeller

Modern chatbotlarda önemli bir paradigma olan niyet sınıflandırma (intent classification), kullanıcının sistemle etkileşime girerken taşıdığı amacın tanımlanmasına yöneliktir. Bu yöntemde, her kullanıcı ifadesi belirli bir "niyet sınıfı" ile etiketlenir. Örneğin, “izin almak istiyorum” ifadesi “izin_talebi” sınıfına ait olabilir.

Bu çalışmada uygulanan Logistic Regression modeli, doğrusal karar sınırları çizen bir sınıflandırma yöntemidir. TF-IDF ile vektörleştirilmiş giriş verisi, Logistic Regression modeli aracılığıyla belirli bir niyet sınıfına atanır (Hastie vd. 2009:35-52). Literatürde Logistic Regression’a alternatif olarak Naive Bayes, Destek Vektör Makineleri (SVM) ve Random Forest gibi yöntemler de yaygın şekilde kullanılmaktadır (Zhang vd. 2016:43-52).

Bu modellerin başarısı, eğitim verisinin çeşitliliği, sınıflar arasındaki ayrım netliği ve özellik çıkarımı süreçlerinin kalitesine doğrudan bağlıdır.

2.2.3. Derin Öğrenme Tabanlı Yaklaşımlar

Son dönemde geliştirilen derin öğrenme tabanlı yaklaşımlar, chatbot teknolojisinde önemli bir paradigma değişimini beraberinde getirmiştir. Özellikle BERT (Bidirectional Encoder Representations from Transformers) ve GPT (Generative Pretrained Transformer) gibi önceden eğitilmiş büyük dil modelleri, metinlerdeki bağlamsal anlam ilişkilerini çok daha başarılı şekilde modelleyebilmekte; bu sayede gerçek zamanlı, anlamlı ve kişiselleştirilmiş yanıtlar üretilebilmektedir (Devlin vd. 2019:52)(Brown vd. 2020:1877-1901).

BERT modeli, giriş metnini çift yönlü olarak analiz ederek bağlamı dikkate alırken; GPT serisi, üretilen her kelimeyi önceki kelimelerle ilişkilendirerek doğal bir dil akışı sağlamaktadır. Ancak bu modellerin kullanılabilmesi için yüksek düzeyde işlem gücü, geniş eğitim verisi ve gelişmiş yazılım altyapısı gerekmektedir (Devlin vd. 2019:52)(Brown vd. 2020:1877-1901).

2.3. İnsan Kaynakları Alanında Chatbot Kullanımı

İnsan Kaynakları (İK) alanında chatbot kullanımı, dijital dönüşüm süreçlerinin bir parçası olarak hızla yaygınlaşmaktadır. Günümüzde, chatbotlar İK birimlerinin operasyonel yükünü hafifletmekte, bilgiye erişim sürelerini kısaltmakta ve çalışan deneyimini iyileştirmeye katkı sunmaktadır (Melian vd. 2016:30-37).

Özellikle büyük ölçekli işletmelerde, chatbotların şu işlevleri yerine getirdiği görülmektedir:

- Sıkça sorulan sorulara otomatik yanıt verme,
- Bordro, izin, yan haklar gibi konularda bilgilendirme,
- Aday başvuru süreçlerinin ilk aşamalarında filtreleme ve yönlendirme,
- Yeni çalışanlar için onboarding desteği sağlama.

İK chatbotları, sadece bilgi sunma görevini değil; aynı zamanda etkileşim verilerinden anlam çıkararak organizasyonel analizlerde de değerli katkılar sağlamaktadır (Melian vd. 2016:30-37). Bu sayede kurumlar, veri odaklı insan yönetimi stratejileri geliştirerek daha etkin kararlar alabilmektedir.

3. METODOLOJİ

3.1. Giriş

Bu bölümde, makine öğrenmesi tabanlı chatbot sistemine ilişkin metodolojik altyapı sunulmaktadır. Geliştirilen sistemin amacı, çalışanlardan gelen sık sorulan İK temelli sorulara otomatik yanıt verebilen, kullanıcı ile doğal dilde iletişim kurabilen ve iki farklı yöntemle (benzerlik tabanlı ve sınıflandırma temelli) çalışabilen etkileşimli bir dijital asistan geliştirmektir. Bu bağlamda literatürde yaygın olarak kullanılan TF-IDF vektörleştirme yöntemi, cosine similarity metriği ve Logistic Regression algoritması kullanılmaktadır.

3.2. Doğal Dil İşleme (NLP)

Bu projede geliştirilen İnsan Kaynakları (İK) Chatbot sistemi, çalışanlardan gelen Türkçe metin temelli soruları analiz ederek uygun yanıtları otomatik olarak üretebilen bir makine öğrenmesi uygulamasıdır. Bu sürecin temelini doğal dil işleme (Natural Language Processing - NLP) teknikleri oluşturmaktadır. Metinler doğrudan matematiksel modellere uygun hale getirilemediği için, NLP kapsamında kullanılan vektör temsilleriyle bu dönüşüm gerçekleştirilmiştir. Proje kapsamında kullanılan temel vektörleştirme yöntemi TF-IDF'tir.

3.2.1. TF-IDF Vektörleştirme

TF-IDF (Term Frequency – Inverse Document Frequency), metin madenciliğinde yaygın olarak kullanılan bir istatistiksel kelime ağırlıklandırma yöntemidir. Bir terimin hem içinde bulunduğu belgede sık geçip geçmediği (TF) hem de tüm belgeler arasında ne kadar ayırt edici olduğu (IDF) dikkate alınarak hesaplanır (Jurafsky ve Martin; 2023:3)

- **TF (Term Frequency):** Bir belge d içindeki bir t teriminin **TF** (d , t) değeri, terimin o belgedeki frekansının, belgedeki toplam terim sayısına oranıdır.

$$TF(t, d) = \frac{f_{t,d}}{\sum_k f_{k,d}}$$

- **IDF (Inverse Document Frequency):**

$$IDF(t) = \log \left(\frac{N}{df(t)} \right)$$

- **TF-IDF:**

$$TF-IDF(t, d) = TF(t, d) \times IDF(t)$$

TF-IDF ile lojistik regresyon kullanmak, çoğu zaman sağlam bir başlangıç modeli (baseline) oluşturur. TF-IDF'in avantajı, uygulamasının hızlı ve yorumlanabilir olmasıdır – her bir özellik, belirli bir kelimenin ağırlığını temsil eder. Dezavantajı ise kelimeler arası anlamsal ilişkiyi yakalayamaması ve veri setindeki kelime sayısı arttıkça çok yüksek boyutlu ve seyrek (sparse) vektörler üretmesidir. Bu projede, veri setimizdeki kullanıcı soru cümlelerini sayısal hale getirmek için TF-IDF yaklaşımı tercih edilmiştir. Bu sayede her soru, belirli bir boyutta vektör olarak temsil edilmiş ve makine öğrenmesi modeline girdi olarak sunulmuştur (Han vd. 2013).

3.3. Benzerlik Ölçümleri

Vektörleştirilen kullanıcı girişlerinin eğitim setindeki örneklerle olan benzerliğinin hesaplanması için **cosine similarity** metriği kullanılmıştır.

3.3.1. Cosine Similarity

Cosine Similarity, iki metin vektörü arasındaki yönsel yakınlığı (açı) temel alarak benzerlik skoru üretir. Bu skor 1'e yaklaştıkça cümleler birbirine semantik olarak daha çok benzemektedir:

$$\text{Sim}(A, B) = \cos(\theta) = \frac{A \cdot B}{\|A\| \cdot \|B\|}$$

Burada $A \cdot B$, iki vektörün iç çarpımı, $\|A\|$ ve $\|B\|$ vektör normlarını ifade eder (Han vd. 2013). Chatbot sistemi, kullanıcıdan gelen giriş ile eğitim setindeki sorular arasında bu benzerlik skorlarını hesaplayarak en yüksek skoru alan sorunun yanıtını kullanıcıya sunmaktadır. Eğer cosine similarity belirli bir eşik değer (örneğin 0.4) altındaysa, sistem kullanıcıyı doğrudan İK yetkilisine yönlendirecek şekilde yapılandırılmıştır.

3.4. Makine Öğrenmesi Sınıflandırma

Yalnızca benzerlik temelli değil, aynı zamanda kullanıcının girişini kategorik bir “niyet” sınıfına atayabilen bir model de geliştirilmiştir. Bu amaçla, metin sınıflandırma için yaygın kullanılan denetimli bir yöntem olan lojistik regresyon tercih edilmiştir.

3.4.1. Logistic Regression

Lojistik regresyon, istatistik ve makine öğrenmesi alanında yaygın kullanılan bir sınıflandırma algoritmasıdır. Adında “regresyon” geçmesine rağmen, temel olarak kategorik (ayrık) çıktı değerlerini tahmin etmek için kullanılır. İkili sınıflandırmada, verilen bir girdinin sınıf 1 olma olasılığını hesaplamak üzere lojistik (sigmoid) fonksiyonu kullanılır. Çıktı olasılığı 0.5’in üzerinde ise model girdiyi pozitif sınıfa atar, altında ise negatif sınıfa atar.

Lojistik regresyon, bir girdinin belirli bir sınıfa ait olma olasılığını sigmoid fonksiyonu aracılığıyla tahmin eder:

$$P(y = 1 | x) = \frac{1}{1 + e^{-(w^T x + b)}}$$

Burada:

- x : TF-IDF özellik vektörü
- w : öğrenilen ağırlıklar
- b : bias terimi [17]

Lojistik regresyon, özellikle metin sınıflandırma gibi yüksek boyutlu ve seyrek veri probleminde iyi çalışan bir doğrusal sınıflandırıcıdır. Naive Bayes gibi generatif yaklaşımlara kıyasla, veri içindeki özellik korelasyonlarına daha iyi uyum sağlayabilir ve pratikte daha yüksek doğruluk verebilir (Jurafsky ve Martin; 2023). Nitekim, Jurafsky ve Martin’in belirttiği gibi NLP alanında lojistik regresyon “baseline” bir yöntem olarak sıkça tercih edilir (Jurafsky ve Martin; 2023). Bunun başlıca nedeni, hızlı, etkili ve yorumlanabilir olmasıdır. Modelin her bir kelime özelliğine atadığı ağırlık, o kelimenin belirli bir niyet sınıfı için ne kadar ayırt edici olduğunu gösterir. Örneğin, chatbotumuzun veri setinde “izin” kelimesinin ağırlığı, “İzin talebi” niyeti için pozitif ve büyük ise, model bu kelimeyi gördüğünde o sınıfa yönelmektedir. Lojistik regresyon modelinde aşırı uyumu (overfitting) engellemek için genellikle düzenleme (regularization) yöntemleri kullanılır (L2 regularization, yani Ridge regresyon, yaygın bir seçenektir). Bu sayede gereksiz büyük ağırlıklar törpülenir ve modelin genelleme kabiliyeti artar (Jurafsky ve Martin; 2023).

3.5. Performans Metrikleri

Logistic Regression modelinin başarımı çeşitli doğrulama metrikleriyle değerlendirilmiştir.

3.5.1. Doğruluk (Accuracy)

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

Modelin yaptığı tüm tahminlerden kaç tanesinin doğru olduğunu ölçer. Dengeli veri setlerinde anlamlı bir göstergedir.

3.5.2. Hassasiyet (Precision)

Bir sınıfa pozitif tahmin yapılan örneklerden kaçının gerçekten o sınıfa ait olduğunu ölçer:

$$Precision = \frac{TP}{TP + FP}$$

3.5.3. Geri Çağırma (Recall)

Gerçek pozitif örneklerin ne kadarının doğru tahmin edildiğini gösterir:

$$Recall = \frac{TP}{TP + FN}$$

3.5.4. F1 Skoru

Precision ve Recall'un harmonik ortalamasıdır:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall}$$

Precision ve Recall'un harmonik ortalamasıdır. Özellikle dengesiz veri setlerinde başarıyı daha doğru yansıtır [19].

3.6. Uygulama Arayüzü Geliştirme

Geliştirilen chatbot sistemi, Python tabanlı Streamlit kütüphanesi kullanılarak kullanıcı arayüzü ile bütünleştirilmiştir. Streamlit, veri bilimi projelerinin hızlı ve etkileşimli şekilde web üzerinde sunulmasına olanak tanıyan modern bir araçtır (Tejero; 2020).

Arayüzde temel olarak:

- Metin giriş alanı,
- Yöntem seçici (benzerlik / sınıflandırma),
- Anlık yanıt gösterimi,
- Cosine similarity skoru veya tahmin edilen sınıf bilgisi gibi bileşenler yer almaktadır.

Kullanıcının yaptığı giriş, seçilen modele göre arka planda işlenmekte ve gerçek zamanlı olarak sonuçlar ekrana yansıtılmaktadır. Yanıt güvenliği düşükse kullanıcı bilgilendirilmekte ve gerekirse İK birimine yönlendirme yapılmaktadır. Arayüz sade, erişilebilir ve Türkçe dil desteği ile tasarlanmış; mobil cihazlarla da uyumlu çalışacak biçimde optimize edilmiştir (Streamlit Docs. 2023).

4. YÖNTEM

Bu bölümde, İnsan Kaynakları (İK) alanındaki sıkça sorulan sorulara otomatik yanıt verebilen bir makine öğrenmesi destekli chatbot sisteminin geliştirilme süreci ayrıntılı olarak ele alınmaktadır. Çalışmada kullanılan veri seti yapısı, veri ön işleme adımları, iki farklı tahmin algoritmasının mimarisi, model eğitimi, değerlendirme metrikleri, arayüz geliştirme süreci ve uygulamanın genel işleyişi detaylı biçimde açıklanmıştır. Proje, Türkçe ve İngilizce karışık içerikli bir veri seti üzerinde çalışmakta olup, kullanıcıya web tabanlı bir arayüz aracılığıyla hizmet vermektedir.

4.1. Veri Seti

Projenin temel veri seti, Kaggle platformundan edinilen bir İnsan Kaynakları Sıkça Sorulan Sorular (SSS) veri kümesidir. Veri seti, her biri doğal dilde yazılmış kullanıcı sorularından (text), bu soruların ait olduğu niyet etiketlerinden (intent) ve yanıt cümlelerinden (response) oluşan üç sütunu barındıran bir yapıdadır.

- text: Kullanıcının chatbot'a yönelttiği doğal dildeki İK sorusunu içerir.

- intent: Soruya karşılık gelen sınıf/niyet etiketini içerir.

- response: Chatbot'un bu soruya vermesi gereken hazır yanıt metni.

Veri setinde toplamda 4024 örnek bulunmaktadır. text sütunu İngilizce, response sütunu ise Türkçe olarak hazırlanmıştır. Bu, chatbot'un çok dilli veri ile çalışabilirliğini test etmek açısından önemli bir fırsat sunmaktadır. Modelin doğru çalışabilmesi için veri setine response sütunu manuel olarak eklenmiş ve veri seti ek satırlarla genişletilmiştir.

```
import pandas as pd

df = pd.read_csv(r"C:\Users\PC\Desktop\Proje9.1\hr_chatbot_final.csv")
df.sample(10)
```

	text	intent	response
1601	Attendance for last week	GetAttendanceSummary	Günlük giriş-çıkış bilgileriniz İK portalı üze...
3307	Break down of my salary components,GetSalaryCo...	Bilinmeyen	Bu kayıttta hangi konuyla ilgili olduğu belirl...
2086	When did I time off the office yesterday?	CheckOutTime	Mesai bitiş saati 18:00'dir. Gecikmeler veya e...
2186	Display my attendance for March	GetAttendanceSummary	Günlük giriş-çıkış bilgileriniz İK portalı üze...
2842	When did I leave the office yesterday?	CheckOutTime	Mesai bitiş saati 18:00'dir. Gecikmeler veya e...
2797	Fetch PF withdrawal form	DownloadForm	Gerekli belgeleri intranet üzerindeki 'Formlar...
1117	Fetch PF withdrawal form	DownloadForm	Gerekli belgeleri intranet üzerindeki 'Formlar...
1836	Change my official email to work@example.com	UpdateProfile	Profil bilgilerinizi güncellemek için İK porta...
3515	I need my experience letter	RequestExperienceLetter	Çalışma belgesi talebinizi İK'ya sistem üzerin...
732	Change my official email to work@example.com	UpdateProfile	Profil bilgilerinizi güncellemek için İK porta...

Şekil 4.1.1. Veri kümesinden alınan rastgele 10 satır

4.2. Kullanılan Kütüphaneler ve Ortam

Proje, Python programlama dili ile geliştirilmiştir. Gerek veri hazırlığı gerekse makine öğrenmesi modelleme süreçlerinde popüler kütüphaneler olan pandas, numpy, scikit-learn kullanılmıştır. Arayüzün geliştirilmesi ve prototip oluşturulması için Streamlit kullanılmıştır. Kullanılan temel kütüphaneler aşağıdaki tabloda verilmiştir.

Tablo 4.2.1. Kullanılan Kütüphaneler ve Ortam

Kütüphane	Kullanım Amacı
pandas	Veri seti işlemleri
scikit-learn	Makine öğrenmesi, TF-IDF, modeller
numpy	Sayısal işlemler
streamlit	Web tabanlı kullanıcı arayüzü
matplotlib/s eaborn	Grafik ve metrik görselleştirmeleri

4.3. Veri Ön İşleme

Makine öğrenmesi algoritmalarının metin verisi ile etkili bir şekilde çalışabilmesi için, metinlerin sayısal temsillere dönüştürülmesi gerekmektedir. Bu projede, İnsan Kaynakları (İK) biriminde sıkça karşılaşılan soruları sınıflandırmak ve uygun yanıtları tahmin edebilmek amacıyla aşağıdaki temel veri ön işleme adımları uygulanmıştır:

4.3.1. TF-IDF Vektörleştirme (Term Frequency–Inverse Document Frequency)

Projenin temel metin temsil yöntemi olarak TF-IDF (Term Frequency–Inverse Document Frequency) yaklaşımı benimsenmiştir. Bu yöntem, bir kelimenin bir belgede ne sıklıkla geçtiğini (TF) ve tüm belgelerde ne kadar yaygın olduğunu (IDF) dikkate alarak, metinleri anlamlı vektörler hâline getirir. Uygulamada TfidfVectorizer sınıfı kullanılarak

metinler sayısal formata dönüştürülmüştür. TF-IDF, metinleri otomatik olarak küçük harfe çevirme ve temel noktalama işaretlerini ihmal etme gibi yerleşik ön işlemleri kendi bünyesinde barındırmaktadır. Bu nedenle, özel bir metin temizleme fonksiyonuna ihtiyaç duyulmamıştır. Projede vektör boyutu sınırlandırması yapılmamış, tüm terimler kullanılmaya devam edilmiştir.

4.3.2. Eğitim-Test Bölünmesi

Veri seti, modelin eğitimi ve test edilmesi için %75 eğitim ve %25 test olacak şekilde ayrılmıştır. Bu oran, hem modelin öğrenme performansını artırmak hem de genel başarımını bağımsız veri üzerinde test etmek amacıyla tercih edilmiştir. Ayrıca stratified sampling kullanılarak sınıflar arası dağılım korunmuştur.

Bu ön işleme adımları sonucunda, modelin eğitileceği veri hem istatistiksel olarak dengelenmiş hem de algoritmalar için uygun formatta vektörleştirilmiş hale getirilmiştir.

4.4. Model Geliştirme ve Eğitim

Bu çalışmada, İnsan Kaynakları alanına yönelik doğal dil işleme tabanlı bir chatbot geliştirilmiştir. Kullanıcının yazdığı ifadeye uygun yanıtların üretilmesi için iki farklı modelleme yaklaşımı benimsenmiştir: benzerlik tabanlı yöntem ve makine öğrenmesine dayalı intent sınıflandırma. Her iki yöntem de TF-IDF (Term Frequency–Inverse Document Frequency) vektörleştirme temeline dayalıdır.

4.4.1. Benzerlik Tabanlı Yaklaşım

Benzerlik tabanlı yaklaşımda, kullanıcıdan gelen metin ifadesi TF-IDF yöntemiyle sayısal bir vektöre dönüştürülmüştür. Aynı şekilde, eğitim veri setinde bulunan tüm soru metinleri de TF-IDF uzayında temsil edilmiştir. Bu vektörler arasında kosinüs benzerliği (cosine similarity) hesaplanarak, kullanıcı girdisine en yakın olan eğitim verisi belirlenmiştir. Belirlenen en benzer örneğe ait önceden tanımlanmış yanıt, chatbot tarafından kullanıcıya sunulmuştur.

Bu yöntemin avantajı, herhangi bir sınıf etiketine ihtiyaç duyulmaksızın doğrudan örnek benzerliği üzerinden yanıt üretilmesidir. Bununla birlikte, düşük benzerlik skorlarında sistemin kararsızlığı artabileceği için belirli bir eşik değeri (threshold=0.4) altında benzerlik skoruna sahip örnekler reddedilmiştir. Bu durumda kullanıcıdan soruyu yeniden ifade etmesi istenmiştir.

4.4.2. Logistic Regression ile Intent Sınıflandırma

İkinci yaklaşımda, kullanıcıdan gelen sorunun hangi intent

(niyet/sınıf) kategorisine ait olduğunu tahmin etmek amacıyla Logistic Regression algoritması kullanılmıştır. Öncelikle, metin verileri TF-IDF yöntemiyle sayısal vektörlere dönüştürülmüş ve ardından bu vektörler sınıflandırma modeline giriş olarak verilmiştir. Modelin eğitimi sırasında Scikit-learn kütüphanesinin Pipeline yapısı kullanılmış, böylece vektörleştirme ve sınıflandırma işlemleri tek bir bütünsel akışta yürütülmüştür.

Modelin eğitiminde, veri seti %75 eğitim ve %25 test olacak şekilde bölünmüş; ancak stratified sampling uygulanmamıştır. Bu nedenle bazı düşük frekanslı intent sınıfları test kümesinde yeterince temsil edilmemiş olabilir. Model, eğitildiği sınıflar üzerinden tahmin ettiği intent sonucuna göre ilgili hazır yanıtı döndürmektedir. Yanıt eşlemesi, veri setindeki ilgili sınıfa ait ilk cevap satırına göre yapılmıştır.

4.5. Chatbot Arayüzünün Oluşturulması

Kullanıcının doğal dilde ifade ettiği İnsan Kaynakları sorularını girebileceği etkileşimli bir arayüz oluşturulmuştur. Bu arayüz, chatbot'un gerçek zamanlı kullanımını mümkün kılmakta ve geliştirilen iki farklı yöntemin karşılaştırmalı olarak denenmesine olanak tanımaktadır.

4.5.1. Streamlit Kullanımı

Geliştirilen İK Chatbot'u, kullanıcılarla etkileşimi bir web arayüzü üzerinden gerçekleştirecek şekilde tasarlanmıştır. Bu amaçla, Python ile uyumlu ve hızlı prototipleme imkanı sunan Streamlit kütüphanesi kullanılmıştır. Streamlit, veri bilimi projeleri için oldukça pratik bir araç olup, minimal kodla etkileşimli web uygulamaları geliştirmeye olanak tanır.

Hazırlanan arayüzde, kullanıcı deneyimi temel alınarak sade ve anlaşılır bir yapı kurgulanmıştır. Arayüzde ilk olarak başlık ve kısa açıklamanın yer aldığı bir bilgilendirme metni bulunmaktadır. Kullanıcılar, "Soru" başlıklı bir `st.text_input()` alanına İK ile ilgili sorularını serbest biçimde yazabilmektedir. Hemen altında ise, iki farklı yanıt tahmin yöntemi arasından seçim yapılmasına imkân tanıyan bir `st.radio()` bileşeni bulunmaktadır:

- Benzerlik Tabanlı
- Intent Sınıflandırma (Logistic Regression)

Kullanıcı, bu seçeneklerden birini işaretleyerek sorunun hangi yöntemle işlenmesini istediğini belirtir. Örneğin, "Maaşım hangi kalemlerden oluşuyor?" sorusu için kullanıcı benzerlik tabanlı yöntemi seçtiğinde, sistem TF-IDF + kosinüs benzerliği ile en yakın örneği bulur ve cevabını döndürür (`predict_by_similarity()` fonksiyonu). Intent sınıflandırma yönteminde ise lojistik regresyon modeli kullanılarak niyet etiketi tahmini yapılır ve etiket karşılığı cevap döndürülür (`predict_by_intent()` fonksiyonu).

Cevap, kullanıcıya yeşil kutu içerisinde `st.success()` bileşeni ile sunulur. Bu alanın üstünde sabit bir metin olan "Chatbot'un Yanıtı:" başlığı

yer alır. Böylece kullanıcı, giriş ve çıkışları kolaylıkla ayırt edebilir.

Bu yapı sayesinde, chatbot arayüzü hem kullanıcı dostu bir deneyim sunmakta hem de geliştirilen algoritmaların etkinliğini karşılaştırmalı olarak test etme imkânı sağlamaktadır.

4.6. Değerlendirme ve Test

Geliştirilen modellerin başarımını ölçmek amacıyla test verileri üzerinden değerlendirme yapılmıştır. Intent sınıflandırması modeli için classification report fonksiyonu kullanılarak precision, recall, f1-score ve support gibi metrikler hesaplanmıştır. Genel olarak modelin f1-score değerleri yüksek çıkmakla birlikte, veri setinde az örneğe sahip olan bazı sınıflarda modelin başarısının düşük kaldığı gözlemlenmiştir. Bu durum, sınıf dengesizliğinin model başarımı üzerindeki etkisini ortaya koymaktadır.

Benzerlik tabanlı yaklaşımda ise, eşik değeri altında kalan skorlar kullanıcıya yönlendirme mesajı verilerek değerlendirilmiş; diğer durumlarda ise sistemin verdiği yanıt ile kullanıcı beklentileri görsel olarak karşılaştırılmıştır.

Her iki yöntemin de güçlü ve zayıf yönleri göz önünde bulundurularak, gelecekte daha gelişmiş NLP tabanlı modellerin (örneğin BERT gibi) entegrasyonu ile performansın artırılması hedeflenmektedir.

5. DENEYSEL BULGULAR

Bu bölümde, geliştirilen İK Chatbot sistemine ait iki farklı makine öğrenimi yaklaşımının performans değerlendirmeleri sunulmaktadır. Bunlar: (1) TF-IDF + Cosine Similarity ile benzerlik tabanlı yanıt tahmini ve (2) Logistic Regression ile intent sınıflandırma yöntemidir. Modellerin doğruluk oranları, sınıflandırma başarıları, sınıf bazlı analizler ve sistemin kullanıcı girdilerine verdiği tepkiler ayrıntılı olarak analiz edilmiştir.

Değerlendirme metrikleri olarak doğruluk (accuracy), hassasiyet (precision), duyarlılık (recall) ve F1 skoru kullanılmıştır. Ayrıca sınıf bazında detaylı sonuçlar incelenmiş, karışıklık matrisi üzerinden modelin hangi sınıfları karıştırdığı analiz edilmiştir.

5.1. Model Doğrulukları

Model performansları, eğitim verisi üzerinden elde edilen doğruluk oranları ile değerlendirilmiştir.

Benzerlik Tabanlı Yöntem: app.py dosyasında yer alan `predict_by_similarity()` fonksiyonu ile, kullanıcının girdiği soru TF-IDF ile vektörleştirilmiş ve kosinüs benzerliğiyle en yakın soru seçilmiştir. Eşik değeri 0.4 olarak belirlenmiştir. Başarı oranı sayısal olarak ölçülmemiştir.

Logistic Regression ile Intent Sınıflandırma: Jupyter Notebook dosyasında yer alan kodlarda, `train_test_split(test_size=0.25)` ile ayrılan test

verisi üzerinde model eğitilmiş ve değerlendirilmiştir. classification_report çıktısına göre modelin doğruluk oranı %99.4 olarak hesaplanmıştır. Bu oldukça yüksek bir başarı oranıdır ve modelin genel anlamda intent sınıflarını ayırt etme kapasitesinin güçlü olduğunu göstermektedir.

```
from sklearn.model_selection import train_test_split
from sklearn.pipeline import Pipeline
from sklearn.linear_model import LogisticRegression
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.metrics import classification_report

# Giriş ve çıkış
X = df["text"]
y = df["intent"]

# Eğitim/test bölme
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.25, random_state=42)

# Pipeline: TF-IDF + Logistic Regression
pipeline = Pipeline([
    ("tfidf", TfidfVectorizer()),
    ("clf", LogisticRegression(max_iter=1000))
])

# Modeli eğit
pipeline.fit(X_train, y_train)

# Tahmin ve performans
y_pred = pipeline.predict(X_test)
print(classification_report(y_test, y_pred))
```

Şekil 5.1.1. Logistic Regression ile Niyet Sınıflandırma Modeli Eğitimi ve Değerlendirmesi

5.2. Model Kayıpları ve Aşırı Öğrenme Göstergeleri

TF-IDF + Logistic Regression pipeline'ı sklearn kullanılarak uygulanmış, doğrudan bir "loss" değeri ölçülmemiştir. Ancak eğitim ve test verileri üzerindeki değerlendirme metriklerinin benzer seviyelerde olması, modelin aşırı öğrenme yapmadığını ve genel başarı düzeyinin yüksek olduğunu göstermektedir. Özellikle yüksek doğruluk değerine rağmen macro average değerlerinin düşük kalması, veri dengesizliğine işaret etmektedir.

5.3. Performans Metrikleri

Logistic Regression modeli için aşağıdaki metrikler hesaplanmıştır (Python çıktısına doğrudan dayalıdır):

Tablo 5.3.1. Performans Metrikleri Özet Tablosu

Doğruluk (accuracy):	0.99
Makro Ortalama (macro avg) F1 Skoru:	0.70
Ağırlıklı Ortalama (weighted avg) F1 Skoru:	0.99

Sınıf bazlı değerlendirme:

- CheckInTime, CheckOutTime, DownloadForm, GetAttendanceSummary, GetJobOpenings, GetManagerDetails, RequestExperienceLetter sınıflarında %100 precision ve recall ile model tüm test örneklerini doğru sınıflandırmıştır.
- UpdateProfile sınıfında F1 skoru 0.99, bu sınıfın da yüksek doğrulukla tanındığını göstermektedir.
- Buna karşılık, GetExitProcess, GetPayslip, GetSalaryIncrementDate, GetTrainingPrograms gibi çok az sayıda örneğe sahip sınıflarda precision ve recall değerleri 0.00 çıkmıştır. Bu durum, az veriyle temsil edilen sınıflarda modelin sınıflandırma yapamadığını kanıtlamaktadır.
- GetWorkingDocument sınıfı ise yalnızca 3 örnek içermesine rağmen %0.80 F1 skoru ile kısmi başarı göstermiştir.

Bu bulgular, modelin özellikle sık görülen sınıflarda çok başarılı çalıştığını, ancak nadir sınıflar için genelleme yapamadığını ortaya koymaktadır.

	precision	recall	f1-score	support
Bilinmeyen	0.99	1.00	0.99	166
CheckInTime	1.00	1.00	1.00	85
CheckOutTime	1.00	1.00	1.00	85
DownloadForm	1.00	1.00	1.00	84
GetAttendanceSummary	1.00	1.00	1.00	169
GetExitProcess	0.00	0.00	0.00	2
GetJobOpenings	1.00	1.00	1.00	91
GetManagerDetails	1.00	1.00	1.00	79
GetPayslip	0.00	0.00	0.00	1
GetSalaryIncrementDate	0.00	0.00	0.00	1
GetTrainingPrograms	0.00	0.00	0.00	1
GetWorkingDocument	1.00	0.67	0.80	3
RequestExperienceLetter	1.00	1.00	1.00	68
UpdateProfile	0.98	1.00	0.99	171
accuracy			0.99	1006
macro avg	0.71	0.69	0.70	1006
weighted avg	0.99	0.99	0.99	1006

Şekil 5.3.1. Logistic Regression Modeline Ait Sınıflandırma Performans Raporu

5.4. Yanıt Uyumluluğu (Chatbot Başarısı)

predict_by_intent() fonksiyonuna gönderilen test sorularına karşılık chatbot'un verdiği yanıtlar aşağıdaki gibidir:

- Soru: çalışma belgesi almak istiyorum
Yanıt: Çalışma belgesi talebinizi İK portalı üzerinden yapabilir veya e-posta ile İK'ya başvurabilirsiniz.

- Soru: maaş bordrom nerede
Yanıt: Bu kayıta hangi konuyla ilgili olduğu belirtilmemiştir. Lütfen soruyu yeniden gözden geçirin.
 - Soru: eğitim fırsatlarını nereden görebilirim
Yanıt: Profil bilgilerinizi güncellemek için İK portalındaki 'Profilim' sekmesini kullanabilirsiniz.
- predict_by_similarity() fonksiyonuna yönelik tek test örneği:
- Soru: çalışma yazımı nereden alabilirim?
Yanıt: Çalışma belgesi talebinizi İK portalı üzerinden yapabilir veya e-posta ile İK'ya başvurabilirsiniz.
- Yukarıdaki sonuçlardan görüldüğü üzere:
- Lojistik model bazı durumlarda veri setinde olmayan ifadeleri yanlış sınıflandırabilmekte, örneğin "maaş bordrom nerede" sorusuna boş veya ilgisiz yanıt vermektedir.
 - Benzerlik yöntemi ise veri setinde mevcut benzer bir kayıt varsa, doğruya yakın bir yanıt üretebilmektedir.

```
def predict_by_intent(user_input):
    intent = pipeline.predict([user_input])[0]
    response = df[df["intent"] == intent]["response"].iloc[0]
    return response

# Örnek testler
sorular = [
    "çalışma belgesi almak istiyorum",
    "maaş bordrom nerede",
    "eğitim fırsatlarını nereden görebilirim"
]

for soru in sorular:
    print(f"Soru: {soru}")
    print(f"Yanıt: {predict_by_intent(soru)}\n")
```

Soru: çalışma belgesi almak istiyorum
Yanıt: Çalışma belgesi talebinizi İK portalı üzerinden yapabilir veya e-posta ile İK'ya başvurabilirsiniz.

Soru: maaş bordrom nerede
Yanıt: Bu kayıta hangi konuyla ilgili olduğu belirtilmemiştir. Lütfen soruyu yeniden gözden geçirin.

Soru: eğitim fırsatlarını nereden görebilirim
Yanıt: Profil bilgilerinizi güncellemek için İK portalındaki 'Profilim' sekmesini kullanabilirsiniz.

Şekil 5.4.1. Kullanıcı Girdisine Göre Chatbot Yanıtlarının Üretilmesi

```

from sklearn.metrics.pairwise import cosine_similarity

vectorizer_sim = TfidfVectorizer()
X_sim = vectorizer_sim.fit_transform(df["text"])

def predict_by_similarity(user_input, threshold=0.4):
    user_vec = vectorizer_sim.transform([user_input])
    similarity = cosine_similarity(user_vec, X_sim)
    best_score = similarity.max()
    best_index = similarity.argmax()
    if best_score < threshold:
        return "Benzer bir soru bulamadım. Lütfen daha farklı ifade ediniz."
    return df.iloc[best_index]["response"]

# Örnek test
print(predict_by_similarity("çalışma yazısını nereden alabilirim?"))

```

Çalışma belgesi talebinizi İK portalı üzerinden yapabilir veya e-posta ile İK'ya başvurabilirsiniz.

Şekil 5.4.2. Benzerlik Tabanlı Yanıt Tahmini (TF-IDF + Cosine Similarity)

5.5. Hiperparametre Ayarları

5.5.1. TF-IDF Ayarları

Kodda TfidfVectorizer() default parametrelerle kullanılmıştır. ngram_range ve stop_words gibi özel bir ayar yapılmamıştır.

5.5.2. Logistic Regression Ayarları

- max_iter=1000 olarak belirlenmiştir.
- solver=liblinear (varsayılan) kullanılmıştır.
- Cross-validation yapılmamış, tek seferlik eğitim/test ayrımı (train_test_split) yapılmıştır.

5.6. Uygulama Davranışları ve Test Senaryoları

Chatbot'un davranışı yapılan testlerle gözlemlenmiş ve aşağıdaki bulgular raporlanmıştır:

- **Soru 1:** "Maaş zamları ne zaman açıklanacak?"

Intent Sınıflandırma: Bu soruyu doğru şekilde tanımlayamamış ve "kayıt bulunamadı" şeklinde genel bir uyarı dönmüştür.

(Bkz: Şekil 7)



İK Chatbot

Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Maaş zamları ne zaman açıklanacak?

Yanıt tahmin yöntemi:



Benzerlik Tabanlı



Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

Bu kayıttaki hangi konuyla ilgili olduğu belirtilmemiştir. Lütfen soruyu yeniden gözden geçirin.

Şekil 5.6.1. Soru 1 intent sınıflandırma yanıtı

Benzerlik Tabanlı: “Maaş artışı dönemi genellikle yıl ortasında değerlendirilir...” şeklinde anlamlı ve bağlama uygun bir yanıt dönmüştür. (Bkz: Şekil 8)



İK Chatbot

Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Maaş zamları ne zaman açıklanacak?

Yanıt tahmin yöntemi:



Benzerlik Tabanlı



Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

Maaş artışı dönemi genellikle yıl ortasında değerlendirilir. Detaylar için yöneticinizle görüşebilirsiniz.

Şekil 5.6.2. Soru 1 benzerlik tabanlı yanıtı

- **Soru 2:** "Personel eğitim programları hakkında bilgi alabilir miyim?"

Intent Sınıflandırma: Profille ilgili güncelleme cevabı vererek hatalı sınıflandırma yapmıştır.
(Bkz: Şekil 9)

İK Chatbot

Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Personel eğitim programları hakkında bilgi alabilir miyim?

Yanıt tahmin yöntemi:

- ☐ Benzerlik Tabanlı
☒ Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

Profil bilgilerinizi güncellemek için İK portalındaki 'Profilim' sekmesini kullanabilirsiniz.

Şekil 5.6.3. Soru 2 intent sınıflandırma yanıtı

Benzerlik Tabanlı: "İK portalında 'Eğitimler' başlığı altında..." şeklinde anlamlı ve doğru bir cevap dönmüştür.
(Bkz: Şekil 10)

İK Chatbot

Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Personel eğitim programları hakkında bilgi alabilir miyim?

Yanıt tahmin yöntemi:

- ☒ Benzerlik Tabanlı
☐ Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

İK portalında 'Eğitimler' başlığı altında mevcut ve planlanan eğitim programlarını inceleyebilirsiniz.

Şekil 5.6.4. Soru 2 benzerlik tabanlı yanıtı

- **Soru 3:** "Maaşım hangi kalemlerden oluşuyor?"

Intent Sınıflandırma: Yanıltıcı biçimde profil güncelleme ile ilgili cevap vermiştir.

(Bkz: Şekil 11)



Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Maaşım hangi kalemlerden oluşuyor?

Yanıt tahmin yöntemi:

- ☐ Benzerlik Tabanlı
- ☒ Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

Profil bilgilerinizi güncellemek için İK portalındaki 'Profilim' sekmesini kullanabilirsiniz.

Şekil 5.6.5. Soru 3 intent sınıflandırma yanıtı

Benzerlik Tabanlı: Maaşın yan haklarını içeren doğru bilgiyle yanıtlanmıştır.

(Bkz: Şekil 12)



Aşağıya İK ile ilgili sorunuzu yazın:

Soru

Maaşım hangi kalemlerden oluşuyor?

Yanıt tahmin yöntemi:

- ☒ Benzerlik Tabanlı
- ☐ Intent Sınıflandırma (Logistic Regression)

Chatbot'un Yanıtı:

Yan haklarınız sağlık sigortası, yemek kartı ve servis hizmetlerini kapsamaktadır. Detaylı bilgi için İK ile iletişime geçebilirsiniz.

Şekil 5.6.6. Soru 3 benzerlik tabanlı yanıtı

Bu örneklerde de görüldüğü üzere, benzerlik tabanlı yaklaşım bazı durumlarda daha doğru ve kontrollü sonuçlar verirken, lojistik regresyon modeli belirli durumlarda soruyu yanlış sınıflandırabilmektedir. Özellikle veri setinde yeterince temsil edilmeyen intent sınıflarında, lojistik regresyon modelinin hatalı özgüveniyle yanlış cevaplar dönmesi mümkündür. Bu durumlar için modelin predict_proba çıktısıyla bir eşik değeri belirlenip düşük güven skoru durumunda kullanıcıya “soruyu anlayamadım” denmesi daha uygun olabilir. Ancak prototip uygulamada bu özellik aktif edilmemiştir.

6. SONUÇ

Bu çalışma kapsamında, Türkçe dilinde İnsan Kaynakları (İK) süreçlerine yönelik kullanıcı sorularını otomatik olarak yanıtlayabilen bir chatbot prototipi geliştirilmiştir. Sistem, iki farklı makine öğrenimi tabanlı yaklaşımı barındırmaktadır: (1) TF-IDF ve kosinüs benzerliği ile çalışan benzerlik tabanlı cevaplama yöntemi ve (2) TF-IDF vektörleri ile eğitilmiş Lojistik Regresyon modeliyle çalışan intent sınıflandırma yöntemi. Her iki yöntem de kullanıcı girdilerine uygun yanıtlar üretmek üzere Streamlit tabanlı bir web arayüzü ile son kullanıcıya sunulmuştur.

6.1. Başarılar ve Katkılar

Geliştirilen prototip, sınırlı fakat odaklı bir İK veri seti ile eğitilmiş olmasına rağmen oldukça tatmin edici performans göstermiştir. Özellikle, veri setinde yoğun şekilde yer alan "maaş bileşenleri", "profil güncelleme", "izin durumu" ve "açık pozisyonlar" gibi başlıklarla ilgili sorulara hem benzerlik tabanlı hem de sınıflandırma tabanlı yöntemler tutarlı ve doğru yanıtlar üretebilmiştir. Yapılan testlerde bu tür konular için %95'in üzerinde başarılı sonuçlar alınmıştır.

Streamlit ile geliştirilen kullanıcı arayüzü, test eden kullanıcılar tarafından “basit, hızlı ve anlaşılır” olarak değerlendirilmiş; bu da sistemin pratik kullanım için elverişli olduğunu ortaya koymuştur. Ayrıca kullanıcılar, iki farklı yöntem arasında geçiş yapabilmenin esnekliğini olumlu bulmuştur. Bu yapı, özellikle düşük benzerlik skorlarında geri çekilerek “bulamadım” diyebilen benzerlik yöntemi ile, her koşulda tahminde bulunan sınıflandırıcı modelin sınırlarının anlaşılmasını kolaylaştırmıştır.

6.2. Sınırlılıklar

Modelin başarısı, büyük ölçüde veri setinin kapsayıcılığına ve temsil yeteneğine bağlıdır. Nitekim testlerde gözlemlendiği üzere, “personel eğitimleri”, “servis saatleri” veya “kıdem tazminatı” gibi veri setinde yeterince temsil edilmeyen konularda, sınıflandırıcı model yanlış tahminlerde bulunmuş ya da genel cevaplar üretmiştir. Benzerlik yöntemi ise

bu tür sorularda çoğunlukla cevap üretememiştir. Bu durum, chatbotların gerçek ortamda başarılı olabilmesi için veri setinin sürekli genişletilmesi ve gerçek kullanıcı girdileriyle zenginleştirilmesi gerektiğini ortaya koymaktadır.

Ayrıca sistem yalnızca statik yanıtlar döndürmekte, yani bir çalışanın kişisel izin durumu veya özel bordro bilgisi gibi dinamik içerikleri sunamamaktadır. Gerçek bir kurumsal chatbotun, arka planda İK bilgi sistemlerine entegre olması ve kişiye özel yanıtlar üretebilmesi beklenir. Bu çalışma kapsamında böyle bir entegrasyon yapılmamıştır; ancak ileride geliştirilecek versiyonlarda REST API ya da veritabanı bağlantılarıyla bu ihtiyaçlar karşılanabilir.

6.3. Teknik ve Dilsel Gelişim Alanları

Lojistik regresyon modeli, basitliği ve yorumlanabilirliği açısından avantajlı olsa da semantik çeşitlilik karşısında zayıf kalmaktadır. Kullanıcıların aynı soruyu farklı sözcüklerle ifade etmesi durumunda modelin başarı oranı düşebilmektedir. Bu eksiklik, daha gelişmiş dil modellerinin (örneğin BERT, XLM-R gibi Transformer tabanlı yaklaşımların) entegrasyonu ile giderilebilir. Böylece chatbot, yalnızca ezberlenen kalıplarla değil, bağlamsal anlamla da başa çıkabilir hâle gelecektir.

Veri setinde yer alan Türkçe ve İngilizce karışımı ifadeler modelin performansını etkilememiş olsa da ideal durumda tüm verilerin tutarlı dil yapısıyla hazırlanması önerilmektedir. Gelecekte çok dilli destek isteniyorsa, dil tanıma modülü ve çok dilli ön-eğitilmiş modeller kullanılabilir.

6.4. Kullanıcı Deneyimi ve Güvenlik

Gerçek dünyada çalışanlarla etkileşimde olacak bir chatbot için gizlilik, güvenlik ve erişim kontrolü büyük önem taşımaktadır. Bu projede yalnızca genel yanıtlar sağlandığı için güvenlik riski bulunmamaktadır. Ancak gelecekte özel bilgiler sunulacaksa, kimlik doğrulama (authentication) ve yetki kontrolü (authorization) gibi adımlar mutlaka entegre edilmelidir.

Ayrıca, kullanıcıların chatbot kullanımına alışması zaman alabilir. Bu nedenle kurum içi tanıtım faaliyetleri, örnek senaryolarla yapılan test oturumları ve geri bildirim mekanizmaları, chatbotun etkin şekilde benimsenmesini destekleyecektir.

6.5. Genel Değerlendirme

Sonuç olarak, bu çalışma Türkçe İK chatbotu geliştirme konusunda temel bir yapı sunmuş ve iki farklı makine öğrenimi yaklaşımının karşılaştırmalı analizine imkân vermiştir. Geliştirilen prototip, doğru veri ve yeterli kapsam sağlandığında, İK departmanlarına önemli ölçüde zaman kazandıracak ve çalışan deneyimini iyileştirecek potansiyele sahiptir.

İlerleyen dönemlerde veri zenginleştirme, ileri NLP modelleri ve sistem entegrasyonlarıyla bu prototipin kurumsal düzeyde uygulanabilir bir çözüme dönüşmesi mümkündür

7. REFERANSLAR

- Brown, T. et al. (2020). Language Models are Few-Shot Learners. *Advances in Neural Information Processing Systems*, 33, 1877–1901.
- Devlin, J., Chang, M. W., Lee, K., & Toutanova, K. (2019). BERT: Pre-training of deep bidirectional transformers for language understanding. *NAACL-HLT*.
- Dhanorkar, M. & Damle, R. (2021). A Comparative Study of Chatbot Approaches Using Machine Learning and NLP.
- Han, J., Kamber, M., & Pei, J. (2011). *Data Mining: Concepts and Techniques*. Morgan Kaufmann.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning*. Springer.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied Logistic Regression*. Wiley.
- Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing* (3rd ed.). Stanford University.
- Jurafsky, D., & Martin, J. H. (2021). *Speech and Language Processing* (3rd ed.).
- Jurafsky, D., & Martin, J. H. (2023). *Speech and Language Processing* (3rd ed. draft). Stanford University.
- Jurafsky, D., & Martin, J. H. (2023). *Speech and Language Processing* (3rd ed. draft). Stanford University.
- Melián-González, S., & Bulchand-Gidumal, J. (2016). A model that connects information technology and hotel performance. *Tourism Management*, 53, 30–37.
- Pedregosa, F. et al. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Ramos, J. (2003). Using TF-IDF to determine word relevance in document queries. In *Proceedings of the first instructional conference on machine learning*.
- Ramos, J. (2003). Using TF-IDF to Determine Word Relevance in Document Queries. *First Instructional Conference on Machine Learning*.
- Shawar, B. A., & Atwell, E. (2007). Chatbots: Are they really useful? *LDV Forum*, 22(1), 29–49.
- Streamlit Docs. (2023). *Getting Started*.
- Tejero, A. (2020). *Streamlit for Machine Learning and Data Science*. Apress.
- Wallace, R. S. (2003). The Elements of AIML Style. *ALICE AI Foundation. based natural language processing. IEEE Computational Intelligence Magazine*, 13(3), 55–75.

- Weizenbaum, J. (1966). ELIZA – A Computer Program For the Study of Natural Language Communication Between Man and Machine.
- Weizenbaum, J. (1966). ELIZA—a computer program for the study of natural language communication between man and machine. *Communications of the ACM*, 9(1), 36–45.
- Zhang, Y., Jin, R., & Zhou, Z. H. (2016). Understanding bag-of-words model: A statistical framework. *International Journal of Machine Learning and Cybernetics*, 1(1), 43–52.

Hayvan Parazitlerinin Toplanması ve Muhafazası

Mehmet Oğuz ÖZTÜRK¹

1- Prof. Dr.; Afyon Kocatepe University, Science and Literature Faculty, Department of Molecular Biology and Genetics, Afyonkarahisar, Turkey oozturk@aku.edu.tr ORCID No: 0000-0001-7263-3585

ÖZET

Hayvan parazitleri, çok çeşitli omurgasız ve omurgalı organizmalarda parazit olarak yaşamaktadır. Zoolojik parazitlerin bilimsel yöntemlere uygun şekilde konak canlılardan toplanması, uygun koşullarda muhafaza edilmesi ve daha sonrada tanımlanması, hem temel hem de uygulamalı bilim alanları için büyük önem taşımaktadır. Parazit örneklerinin belirli bilim metodlarına uygun yöntemlerle toplanması ve muhafazası, morfolojik ve moleküler analizlerin güvenilirliğini doğrudan etkilemektedir. Parazit örneklerin yaşam ortamlarından toplanması ve muhafazası sürecindeki hatalı uygulamalar, morfolojik yapıların bozulmasına ve genetik materyalin zarar görmesine neden olabilmektedir. Bu durum, sistematik, taksonomik ve epidemiyolojik araştırmaların doğru ve güvenilirliğini olumsuz etkilemektedir. Bu çalışma, hayvan parazitoloji araştırmalarında evrensel ölçütlere uygun ve güvenilir bir çalışma çerçevesi sunarak bu alandaki araştırmacılara bilinir yöntem sağlamayı amaçlamaktadır. Elde edilen verilerin konak-parazit ilişkilerinin ekolojik, epidemiyolojik ve evrimsel boyutlarının anlaşılmasına katkı yapılmasına; biyolojik çeşitliliğin korunmasına, zoonoz kökenli parazitler ve patojen hastalıkların önlenmesine ve sürdürülebilir sağlık programlarının geliştirilmesi açısından temel bir rehber oluşturması hedeflenmektedir.

Anahtar Kelimeler – Laboratuvar Metotları, Parazit, Preparasyon, Zooloji

GİRİŞ

Hayvan parazitleri, pek çok omurgasız ve omurgalı canlının vücut yüzeyinde veya iç organlarında bulunabilmektedir. Bu parazitlerin toplanması ve uygun koşullarda muhafaza edilmesinin temel amacı; zoocoğrafik, sistematik ve morfolojik araştırmalar ile hastalıkların teşhis ve tedavisine katkı sağlamak ve aynı zamanda konak ya da parazitlere ait sistematik koleksiyonlar oluşturmaktır. Parazit örneklerinin doğru şekilde toplanması ve standart yöntemlerle saklanması, tür teşhisinin güvenilirliğini ve sonraki morfolojik ya da moleküler analizlerin başarısını doğrudan etkilemektedir. Yanlış yöntemlerle toplanan veya uygunsuz koşullarda muhafaza edilen örneklerde morfolojik yapılar bozulabilir, DNA ve protein bütünlüğü zarar görebilir; bu durum ise taksonomik çalışmaların ve epidemiyolojik araştırmaların geçerliliğini olumsuz yönde etkiler. Ayrıca, standart protokollere uygun örnekleme ve saklama yöntemlerinin kullanılması, elde edilen verilerin farklı çalışmalar arasında karşılaştırılabilirliğini sağlamaktadır (Soulsby, 1982; Thrusfield, 2018).

Parazitlerin toplandığı canlıya konak denir. Parazitler, incelenen herhangi bir konağın biyolojik özellikleri kadar önem taşımaktadır. Bu

nedenle hazırlanan bu rehber, parazit bulundurma potansiyeli olan konakları inceleyen araştırmacılar için önemli bir başvuru kaynağı niteliği taşımaktadır. Aynı zamanda bir parazit grubunu diğerlerinden ayırmayı öğrenen fakülte ve yüksekokul öğrencileri ile biyoloji, ziraat, veterinerlik, tıp ve halk sağlığı laboratuvarlarında çalışan uzmanlar için de yararlı olacaktır.

Bu kitapçık bölümü, uygulanması kolay bazı temel formül ve tekniklerin yanı sıra, hayvan parazitlerinin farklı gruplarına yönelik özel yöntemleri de içermektedir. Söz konusu metotların büyük bölümü derlemeler, el kitapçıkları ve makaleler gibi çeşitli kaynaklardan elde edilebilse de, bu süreç hem zaman alıcı hem de maliyetli olabilmektedir. Ayrıca, kullanılan teknikler ve yaygın formüllerin yer aldığı tüm orijinal kaynaklara eksiksiz biçimde ulaşmak çoğu zaman mümkün değildir. Bu nedenle, bu çalışma ile hayvan parazitleri alanında çalışan araştırmacılara, bilimsel yöntemlere uygun, güvenilir ve uluslararası ölçütleri karşılayan kapsamlı bir rehber sunulması amaçlanmıştır.

Hayvan Parazitolojisinde Çalışma İlkeleri

Araştırmacı hayvan parazitolojisi çalışma sürecinde, hayvanlardan insanlara geçebilen parazit ile mikrobial infeksiyonlara karşı dikkatli olmalıdır. Parazit örneği toplama çoğu toplama her zaman kolay değildir. Parazit veya konaklar verimli olduğunda, parazitologlar gece boyunca saatlerce çalışabilirler. Eğer konak enfekte değilse araştırmacılar hiçbir şey göremeyecektir. Bir araştırmacı için çalışma kurallarını listelemek gerekirse aşağıdaki öneriler sıralanabilir.

- 1. Parazitolog, konak canlının yasal toplama izni gereklerini ve toplama ile ilgili düzenleme kurallarını bilmelidir.
- 2. Parazitolog uzun ve zorlu bir çalışmaya hazır olmalıdır.
- 3. Parazit toplama sürecinde hiçbir engele izin vermemelidir.
- 4. Araştırmacı hayvan hakları ile ilgili genel kurallara uymak zorundadır.
- 5. Bir defada toplanan numuneler hemen işleme alınmalıdır (zorlukla elde edilen numuneler ertesi güne bırakılırsa laboratuvar prosedürleri bakımından çoğunlukla bozulmuş sayılabilir).
- 6. Parazitolog karşılaştığı bazı özel problemleri kendi becerisini ve hünerini kullanarak çözmelidir.

Parazit Toplamak İçin Gerekli Materyallerin Listesi

Parazitlerin toplanması ve korunması için gerekli solüsyonlar ile araç-gereçler aşağıdaki şekilde listelenebilir:

Disseksiyon mikroskobu veya güçlü el merceği

Disseksiyon makasları (Sivri uçlu ve küt uçlu)

Pensler (Sivri uçlu küt uçlu)

Disseksiyon iğneleri (böcek iğnesi cam çubuğun içine gömülerek güçlendirilebilir)
Petri kapları (çeşitli büyüklüklerde)
Beherler (500 ml veya daha büyük, silindirik ve uzun tipte)
İspirto ocağı ve kibrit
Lam, Lamel, Pipetler
Küçük fırça
Şişeler (çeşitli büyüklükte)
Kağıt havlu, Cetvel, Elmas uçlu kalem, Daimi mürekkepli dolmakalem veya kurşunkalem
Kağıt (şişeleri etiketlemek için beyaz, yapıştırıcı ve toplama kabının altına sermek için siyah)
Çantalar (kağıt veya plastik)
Toplama defteri.
Solüsyonlar: %70 Etil Alkol, Formalin, AFA (Alkol-Formalin-Asetik Asit), Glasiyal asetik asit, Glycerol, Fizyolojik su veya çeşme suyu.

Konak Canlılar

Konak türlerinin saptanması parazit kolleksiyonun yapılabilmesi için gereklidir. Toplayan kişi eğer konak taksonomisinde hakim değil ise, konak uzmanlarınca doğru bir şekilde tanımlanmalıdır. Referans numarası konak türünün yanında bulunmalıdır.

Kurban edilecek konak hayvan canlıyken öldürülmeli ve hemen incelenmelidir. Çünkü tüm iç enzimler ve bakteri gibi dış ajanlar hücrelerin çabuk yıkılmasına neden olmaktadır. Parazitler soğuk kanlı hayvanlarda ve kist basamağında daha uzun süre hayatta kalırlar, fakat birçok parazit ölü veya ölmekte olan hücrelerde kısa sürede bozulmaktadır, bu nedenle bir birim zamanda parazitolojik yönden sadece bir konak incelenmeli, daha sonra diğerine geçilmelidir.

Bazı parazitler (örneğin, arthropodlar) konağın ölümü ile en kısa zamanda konağı terk ederler, ve bazıları da konak içerisinde farklı yere göç ederler. Konağın incelenme sürecindeki etkileri parazitler fark eder ve çevrelerindeki herhangi bir değişime tepki gösterirler. Bu değişimler parazitlerin konakta bulundukları mikrohabitat yerleri hakkında yanıltıcı bilgiye neden olabilir.

Eğer birçok konak bir anda mevcut halde ise ve bunları hemen otopsi yapmak toplayan kişi için imkansız ise araştırmacı, konak örneklerini aşağıdaki takip eden metotlardan biri ile müdahale edebilir.

Konağı Canlı Tutabilme

Küçük hayvanlar günlerce ya da haftalarca akvaryumda ya da kafeste canlı tutulabilir. Bu zamanın uzunluğu; konak türüne, yeterli beslenmesinin

sağlanabilirliği, kafes yada akvaryum şartlarına ve parazit enfeksiyonunun tehlikeliliğine bağlı olarak değişir. İki önemli konu hatırlanmalıdır:

- 1. Bazı parazitler, özellikle bağırsak helmintleri, ilk günlerde, saatlerde ya da konağın yakalanmasından sonra konağından ayrılabilir.
- 2. Diğer parazitler, özellikle ektoparazitler, çoğalabilirler ve/veya kendi konağından diğer bir konağa geçiş yapabilirler.

Eğer konağı canlı tutabilmek imkansız ise bu durumda parazitleri korumaya ve konakta uygun konumda tutmaya yardımcı aşağıdaki metotlar uygulanabilir.

Konak Canlıyı Soğutma

Konak otopsi yapıncaya kadar olabildiğince soğuk ortamda tutulmalıdır. Soğutma işlemi, ölen hayvanlarda devam eden lizozom reaksiyonlarını yavaşlatır. Soğutma ya da dondurma işlemi etkili olur. Eğer zaman ve konum uygunsa, organları parçalayıp tuzlu konteynirlara koymak ve sonrasında soğutmak daha çok tercih edilebilir.

Konağa Sıcaklık Yöntemi Uygulama

Taze organlar içine kaynar su eklenir olan behere alınabilir. Organların tamamen ısınmasına izin verilir, sonra fiksatif içine alınır. Birçok helmint fiksatif onlara ulaşmadan önce tamamen gevşeyecektir. Daha sonra yeniden bakıldığında sonraki aşamalar için kusursuz bir halde bulunabileceklerdir.

Kimyasal Koruma

Birçok araştırmacı örnekleri %5-10 lık formalin de korurlar. Bu metot paraziti olduğu gibi korur ve müze koleksiyonlarının ve konaklardan toplanan parazit koleksiyonunun uzun zaman dönemleri için korunmasına izin verir. Konak büyük ise karın yarılr ya da biraz formalin sölomik duvarına şırınga ile enjekte edilerek ve vücut içindeki parazitler daha hızlı fiske edilebilir.

Fiksatifin miktarı fiske edilecek dokunun veya organizmanın miktarından her zaman 9 kat daha fazla olmalıdır. Sıcak fiksatif soğuk fiksatife göre dokuya çok daha hızlı nüfuz etmektedir. Örnekleri uzun zaman döneminde saklamak için her zaman 48 saat sonra solüsyon değiştirilmeli ve her zaman yeni taze fiksatif kullanılmalıdır.

Konağı Dondurma

Toplamadan sonra konakları dondurma pek tavsiye edilmez, ama bu uygulama tercih edilecek ise dondurma işlemini hızlı uygulanmalıdır. Parazit, yavaş soğutma sürecinde, donmadan önce otoliz olmaya başlar.

Çözünme süreci boyunca örnekler yumuşamaya uğrar. Donmuş konakta bulunan küçük parazitlerin hemen fiksatifte alınması önerilir.

Yukarıdaki metotlar parazit örneklerini en iyi koruma ve inceleme yöntemleridir. Bu metotlar numuneleri en iyi inceleme ve korumadan en kötü veya en az tavsiye edilen inceleme ve muhafaza yöntemi sırasına göre düzenlenmiştir. Yine de en iyi preparasyonlar, parazitler canlı toplandığında ve uygun bir şekilde muamele edildiğinde sağlanır.

Konaktan Parazitleri Toplama

Canlı örnekleri yeni ve tazece toplama, her zaman hassas yapılı ve kararlı yumuşama uygulanmış numunelerden daha fazla tatmin edici örnek çalışması yapılmasını sağlar. Ayrıca çalışma sürecinde, konak organizmaların vücut kısımlarının doğru sırada ve tam incelenmesi bir bölümün parazitlerine bakarken diğerlerini kaybetmeyi engellemek için önemlidir. Tercih edilen sıra: (1) kan, (2) solungaçlar (varsa) ve deri, (3) iç organlar ve (4) kaslar şeklinde olmalıdır. Eğer mümkünse enfeksiyonun ve bulgunun tam yerini kaydetmek önemlidir.

Veri Toplama

İncelenen her bir konak için bir otopsi kaydı oluşturulur. Her bir organda bulunan parazitlerin sayısı ve çeşitleri kaydedilir. Parazitler yer değiştirdiğinde de uygun bir şekilde işlenmelidir. Otopsi kayıtları tayin edilen konak, numaraları ile uygun bir konteynırda muhafaza edilmelidir. Etiketler, senet kağıdına veya yazımı iyi bir kağıt (örneğin çizgili defter kağıdına) olmalı ve çalışma örneklerine ait bilgiler kurşun kalemle ya da sugeçirmez mürekkeple (Hint mürekkebi tavsiye edilmez, sadece bazı çeşitlerine güvenilebilir) yazılmalıdır. Etiket, örneklerle birlikte etanol ya da diğer fiksatiflerin bulunduğu konteynıra batırılarak yerleştirilir.

Kan Örnekleme

Kan numuneleri için temiz lam gereklidir. Lamalar distile su ile çalkalanmalı yada %95 EtOH ve %100 asetonun 1:1 oranındaki karışım ile yıkanmalı ve yumuşak ve tiftiksiz bir bezle dikkatlice kurutulmalıdır.

Kan pıhtılaşma meydana gelmeden önce, hayvanın ölümünden hemen sonra alınmalıdır. Eğer konağın ölümü ve kan numunesinin yapılması arasında çok fazla zaman geçerse, pek çok eritrositler çöker.

Bir damla kan temiz bir numune lamın sonuna konur. Bir başka bir yayma lamın son kısmı ile ilkinin merkezine doğru dokundurulur ve kan damlasına doğru sürülür. Temastan halinde, kan yayma lamın kenarı boyunca akacaktır. 2 lam birbirlerine 20-40° lik açı ile tutulmalıdır. Yayma lamı düz pürüzsüz bir hareketle itilir, kan arkasından sürüklenir. Numunenin kalınlığı lamların açısı değiştirilerek kontrol edilir (örneğin, aradaki açıyı arttırarak inceleştirilebilir. Kan numuneleri oda sıcaklığı ortamında hava ile

kurutulur. Boyandıktan sonra stoklanabilir. Lamaların bir kenarına elmas kalemle konak ve benzeri toplama bilgileri işaretlenir.

- 1. *İnce Kan Yayma Örnekleme*: Giemsa ve Wright's boyası ile daha sonra boyamak için ince kan preparatları yapılır. Eğer mümkünse, kan konağın farklı bölgelerinden alınır. Kan bir venden yada kalpten yada açık bir kaynaktan bir şırınga ile çekilir. Eğer kan bağırsak ya da diğer organ ve dokularca kirlenebilen vücut boşluğu gibi açık bir kaynaktan çekilecek ise tedbir almak gerekir.
- 2. *Kalın Yayma Örnekleme*: İki ya da üç damla kan, temiz bir lamın 4cm²lik bir kısmına bir iğne, kürdan ya da ikinci bir lamın köşesi kullanılarak dairesel hareketlerle sürülür. Pıhtılaşmasına izin verilir ve tamamen kurutulur. Daha sonra boyama yapılıncaya kadar stoklanabilir. Fakat öncesinde, kalın yayma kan filmleri etanol ve benzeri ortamda fiske edilmelidir.

Numuneyi boyamak için destile su ile 20 dakika ya da renk kayboluncaya kadar süzülür. Eğer bir lamın ucu cam çubuk kullanılarak kaldırılırsa, serbest kırmızı kan hücreleri temizlenir ve lökositler ile parazitler daha görülebilir hale gelir. Kan filmi tekrar kurulanır ve boyanır. Kalın yayma ortamlarda parazitler yoğun olarak bulunabilir ve bunları yorumlamak ince yaymalardan daha zordur. Lamaların üzerine elmas kalem yardımıyla toplama numaraları işaretlenir. Eğer kalın yayma numuneler uzun bir zaman depo halinde tutulursa, hemolizi arttırmak için distile suya 1-3 damla kadar soğuk asetik asit damlatılır.

Doku Örnekleri

Dokulardaki protozoon ve metazoon parazitleri taze bir organın boyuna kesilmesi ile sergilenebilir. Bir doku numunesi için dissekte organ veya doku yüzeyi lam üzerine bırakılır ve iyice bastırılır. Hava ile kurutulmuş doku numunesi uzun süre bu haliyle muhafaza edilebilir ve daha sonra boyanabilir. Lamaların köşelerine toplama numaraları yazılmalıdır.

Birçok doku bilimci kan ve doku numuneleri için Giemsa ya da Wright's boyasını kullanmayı tercih ederler. Giemsa boyası birçok kan numunesi için en iyi boya olmasına karşın Wright's boyası daha basit bir alternatiftir.

Deri Parazitleri

Deri dikkatli bir şekilde incelenmelidir. Ektoparazitler, özellikle pireler, konağı ölürl ölmez terk ederler. Konak canlıların yaşam ortamlarına göre uygulanan metotlar farklı olabilir.

- 1. Karada Yaşayan Konaklar: Konağın taşımak için plastik ya da kağıt bir çanta içine sıkıca kapatılması tavsiye edilir. Bazı çalışmacılar memeli ya da kanatlı konak ile birlikte çantanın içine eter ya da kloroforma batırılmış bir parça pamuk koyar. Ektoparazitleri toplamanın basit bir metodu konağın bir parça beyaz kağıt üzerinde silkelenmesidir. Koyu renkli parazitler beyaz zemin üzerine düştüklerinde dikkat çekerler. Çanta içindeki maddeler de çıkarılır ve bir disseksiyon mikroskobu ile incelenir.

Kıllı ya da tüyü hayvanlar belki düzenli aralıklarla sabunlu suya batırılan eski bir diş fırçası gibi sert kıllı bir fırça ile fırçalanabilir. Ayıklanan örnekler bir konteynıra toplanır ve bir disseksiyon mikroskobu ile incelenir.

Büyük ektoparazitler yaşayan hayvanlardan iyi bir pens ile direkt koparılır. Gliserole batırılmış bir neşterle kesik atılarak yada enfekte olmuş bölgenin kılları veya tüyleri kesilerek de toplanabilir.

Deri, yara kabuğu ya da lezyonlar neşter ile kesilebilir ve kesilmiş numune inceleme için bir lam üzerine alınır ve üzeri bir lamel ile kapatılır ve incelenir.

Arthropdlar dikkatlice incelenmelidir, çünkü kolaylıkla kırılabilen bacakları ve setaları mekanik davranışlarla zarar görebilir. Alkolle ıslatılmış ince uçlu bir fırça, parazitleri toplamak için mükemmel bir alettir.

- 2. Sucul Konaklar: Birçok sucul konak protozoonlar, monogenler, sülükler, copepodlar, isopodlar ve glochidialar gibi pek çok parazitlerin sığınağıdır. Sucul konakların derisindeki kistler genellikle protozoonları ve trematodları içerir. Türlerin tespiti için kistler tek tek ayrılmalıdır.

- 3. Helmintlerin Kistleri: Larval trematodalar için çeşitli kimyasal metodlar ya da yapay sistem teknikleri kistik larvaya uygulanır. Protozoan kistlerini patlatmak için bir lamel ile ya da ikinci bir lam ile bastırılarak ezilmiş bir doku yapılır. Preperatın kurumasına izin verilir ve doku numunelerindeki gibi Giemsa ile boyanır. Kistli doku kesit ve kısımlarına ayırmak için %10 formalin ya da TEM çalışmaları için %3 gluteraldehit içinde fiske edilir.

Ağız ve Nasal Parazitleri

Oral duvar güçlü bir makasla ya da bir kemik kesici ile ağzın kenarları boyunca kesilerek daha kolaylıkla açılabilir. Bazı parazitler yanak duvarı içinde yaşarlar, ama konak öldükten sonra diğerlerinin de o kısma göç ettiklerinin de farkında olmak gerekir. Nasal duvar, başın aşağı doğru tutulması sonrası geniş ağızlı bir pipetten akan güçlü bir su ile temizlenir. Eğer mümkünse, solungaçlar kesilir ve parazitler hemen incelenir.

Bağırsak Parazitleri

Daha küçük hayvanlarda, konağın vücut duvarı ventral yüzeyi boyunca kesilir ve eğer mümkünse geriye doğru kasık kemiği boyunca, anüsün ve ürogenitalin etrafından yararlanarak açılır. Ön kısımda çene kemiklerinin ortasından bir noktadan kesme yapılır, eğer gerekli olursa kaburgalar ve sternum arasından kesmeye devam edilir.

Büyük hayvanlarda (memelilerde) yarma işini yapmak daha kolaydır. Hayvanı sırtı üzerine yatırın, ayaklarını kaldırın ve derisini ön ve arka ayaklarının birleşme yerinin ortasından ortalayarak farinkse kadar kesin. Hayvanın diğer tarafını çevirin ve aynı işlemi gene yapın. Farangal bölgenin derisini kaldırın ve geriye doğru sternum ve diyaframı keserek itin.

İç organları tamamen açığa çıkartın. Parazitler vücut boşluğunda mezenterde ya da karın zarı boşluğunda serbest dolaşıyor olabilir, onları dikkatlice aramanız gerekir. Organları kist var mı diye iyice inceleyin.

İç organları çıkarın ve organları tek tek tuzlusu konteynırlarına alın. Organları parçalara ayırma işlemi enfeksiyonun asıl yeri ile ilgili soruları ortadan kaldırır. Arazide çalışırken, konteynırlar soğukta ya da gölgede tutulmalıdır. Eğer bir av hayvanı bu arazide vurulduysa, iç organları ölümden mümkün olduğunca kısa zaman içinde tuzlu suda depolanmalıdır ya da diğer koruma teknikleri seçilebilir. Bu gibi iç organların kapalı kapları eğer parazitler bir ya da daha fazla gün yaşatılacaksa soğuk tutulmalıdır.

Organlar keskin bir makasla kesilmeli ya da parçalara ayrılmalıdır. Bu parazitlerin açığa çıkmasını sağlayacaktır ve mevcut numuneye en az zararı verecektir. Eğer organlar bir saatten daha fazla suda bırakılırsa, parazitler kendilerini serbest bırakacaklardır.

Karın boşluğu bakışı için, karın boyuna kesilir ve iç organlar karasal ve tatlı su canlıları için fizyolojik su ortamına, deniz hayvanları için 1/3 deniz suyu ve 2/3 oranında normal su kullanılan ortama aktarılır. Bisturi ile karın zarının iç yüzeyini derince kazıyın. Sindirim sisteminin diğer parçalarında da aynı şekilde muamele yapılır.

Bağırsak mezenterler boyunca sıyrılmalıdır ve köreltilmiş bir makasla tercihen enterotome işlemi ile açılır. Eğer bağırsak çok uzun ise, uygun ölçülerde kesilebilir, bağırsağın ölçüsü ve parazitlerin yeri kaydedilir.

Bağırsağı boşaltma ve kazımanın en iyi yolu büyük bir konteynırda, bağırsağı bir çift forseps ile sonundan kavradıktan sonra, iç astarı

konteynırda bir bisturi ile sürükleyerek kazınır. Büyük bağırsak parazitleri hemen görünecektir.

Bağırsak içeriği serum fizyolojik su ile karıştırılarak ta incelenir. Daha kolay bir yol da içeriği uzun, ince vida kapaklı bir konteynıra alınarak 15 dakika boyunca kuvvetlice çalkalamaktır. 3 ile 10 dakika kadar parazitlerin çökmesi için çalkantının durulmasına izin verilir. Bu süreç mukusun, dışkıya ait maddelerin ve doku parçalarının uzaklaşmasına yardımcı olur.

Durulma sonrası bulanık sıvıyı boşaltın. Eğer çok fazla mukus var ise birçok kez yıkamak gerekebilir. Eğer çözelti ortamda bulunan parazitlerin görünmesini engelleyecek kadar çok yoğunsa inceleme için sulandırılmalıdır. Çözeltiyi diseksiyon mikroskobu altında siyah zemin üzerinde inceleyiniz.

Eğer varsa bir dizi değişik boyutlu elekten geçirilmesi çözeltinin incelenme hızını arttıracaktır. Parazitler hareketleri, boyutları, şekilleri ve renkleri ile kolaylıkla fark edileceklerdir. Karaciğer gibi yoğunluğu fazla olan organlar da birbirinden ayrılmalı ve tuzlu suya kıyılmalıdır. Yukarda bahsedildiği gibi süspansiyon ortamında incelenir. Tuzlu sudan temizlemek için konaktan parazitler uzaklaştırılır ve yıkanır. Bağlı kalan mukusu ve artıkları yumuşak bir fırça kullanarak hafifçe uzaklaştırın çünkü çalkalamakla uzaklaşmayabilirler. Fiksatif, mukusu dondurabilir ve uzaklaştırılması zor hale getirebilir.

Bazı uzmanlar küçük beherlerde izole edilmiş organların üzerine kaynar su dökülmesini ve bu şekilde tutulmasını tavsiye eder. Kesilmiş bağırsağı kaynatmak ve tatmin edici sonuçlar alabilmek için gerekli asgari süre küçük amfibiler için 10 saniye, küçük kuşlar ve balıklar için 30 saniye, büyük hayvanlar için ise 2 dakika kadar süre yeterlidir. Çok sayıda preperasyon bu yolla tek bir seferde yapılabilir. Bu muameleden sonra, organlar inceleme yapılcaya kadar fiksasyon ve depolama için ayrılmış AFA bulunan konteynırlara aktarılır. Solucanlar bu metotla kendi yaşam ortamlarında kalarak fiske edilir, fakat konak dokusundan ayrılmıştır. Derlenip toplanıp fiske edilmiş organların lifleri EtOH(%30 ila %50) ortamında petri kaplarında tel tel ayrıldığında iyice gevşemiştir ve fiske edilmiş solucanlar çıkarılmaya hazırdır.

Elimizde bulunan parçacıkları mikroskobik inceleme yaparken, sıvının miktarı en az ve en berrak hale getirilmelidir. Bu süreçte organları ayrı tablolara transfer edin, üzerine pipetle birkaç damla tuzlu su ya da çeşme suyu damlatın ve nemli bir mendille üzerini incelenecek zamana kadar örtün. Organları kesin ve büyük kan damarlarını boyunca lümen içeriğine birkaç damla tuzlu su ekleyin ve diseksiyon mikroskobu ile inceleyin. Yaşayan helmintler hareketli olmaları sebebiyle hemen yerleri tespit edilir ve fiksasyon için lamel üzerine alınır. Ufak parçaların çökeltisi çok az sıvı eklenerek ya da hiç eklenmeksizin çok az miktarlarda alınarak incelenebilir veya daha sonraki incelemeler için fiske edilirler.

Küçük omurgalıların bağırsakları boyuna disseksiyon yapıldıktan sonra villus boyunca disseksiyon mikroskobu ile inceleyin. Bisturi ile yüzeyini sıyırın. Duvarındaki küçük kistler ve larvalar bisturi ile kazındıktan sonra açığa çıkacaktır.

Tümörler için herhangi bir dokuda ortaya çıkan anormallik gösteren kısım kesilir ve ışık mikroskobu için %10 formalinde ya da TEM için %3 glateraldehitde fiske edilir. Eğer tümör büyükse, en iyi etkiyi ya da fiksasyonu elde edebilmek için en iyi yol keskin bir çapraz kesim yapmaktır.

Parazit Örneklerinin Korunması

Hayvan dokusunun korunması için fiske edilmesi gerekir. Fiksasyonun amacı, mikrobial etki ile çürüme veya otolizi daha dirençsiz duruma getiren süreçte doku formlarını sabitlemektir. Parazitologlar örnekleri kurban etme ve fiske etme metotlarını seçerek, kaliteyi, zamanı ve koşulları dengeler. Arazi kampında, denizde ve benzeri ortamlarda örnekler üzerinde ne kadar zaman harcanacağı hala bir sorudur.

Örnekleri Gevşetme ve Fiksasyon

Helminth parazitlerinin uygunsuz olarak öldürülmesi veya kurban edilmesi, sıklıkla parazitlerin tanımlanması için pratik olarak kullanışsız hale getirir. Parazitler kasılma, kıvrılma gibi ya da ölmeden önce bükülme ve bozulmalar yapma eğilimine sahiptirler

Eğer tamamen mümkün olursa, parazitlerin en gevşemiş durumlarında öldürülmesi ve aynı zamanda da fiske edilmesi istenir. Asıl sır, uygun gevşeme ve fiksasyonda yatar. Bu yüzden örnekler mümkün olduğunca canlı ve doğal formlarındaki duruşa göre korunmalıdır. Örnekleri gevşetmenin fiziksel yolları ısıtma ve dondurmadır. Fakat helminth grupları için zaman zaman kimyasal metotlar da tercih edilir.

Çok sayıda parazit kurban etme veya öldürme metodu kullanılabilir. İyi bir öldürme ve fiske etme maddesi, hızlı nüfuz etme işlemi ile metabolik aktiviteleri durdurur. Bir çok fiksasyon maddesi biraz sıcak iken daha hızlı nüfuz etkisine sahiptir.

Daimi fiksasyon mümkün olduğunca organizmanın şekli düzgün olacak şekilde yapılmalıdır. Helminth preparasyonun yapılış şekli, paraziti tanımlama aşamasının beklide en önemli adımıdır. Kararların bireysel alınması nedeni ile, çalışmacı açısından tecrübenin olması, fiksasyon için gereklidir.

Kullanılan fiksatif çeşidi, preparasyondaki boya farklılıklarına ve boyamaya etki edecektir. Genelde, asit içeren fiksatifler, daha iyi boyamaya izin verir. Çalışmalarda kullanılan Alkol-Formalin-Asetik Asit (AFA), her bakımdan iyi bir fiksatif olduğu için tüm helmint preparasyonları için kullanışlıdır.

Örnekler, bazen fiksatif içinde saklanabilir. Fakat 4-48 saat fiksasyondan sonra %70 Etil Alkolde yıkanmaları önerilir. Daha sonra yeni bir taze %70 Etil Alkolde saklanır. Aniden elde edilen bir örnek için fiksatif veya koruyucu olarak, herhangi bir lokal içki, örneğin; schopps, votka, cin, rom yada viski'de kurban edilip fiske edilebilir. Hatta metillendirilmiş ispiro kullanılabilir. Uygun olduktan sonra, mümkün olduğunca kısa bir zaman içinde, parazitler %70 Etil Alkole transfer edilmelidir.

Koleksiyon Bilgileri

Koleksiyon bilgileri eğer örneğe uymaz ise, örneğin herhangi bir bilimsel değeri yoktur. Bunun için örnek ile beraber küçük bir bilgi etiketi olmalıdır.

Fiksatiflerde, etil alkolde ve diğer sıvılarda daldırma etiketler kullanılabilir. Bilgiler yumuşak kalem veya su geçirmeyen boya (çini mürekkebi değil) ile beyaz bond kağıdı üzerine yazılmalıdır. Eğer etiket boya ile yazılmışsa, artan mürekkep sıvıya daldırılmadan durulanmalıdır. Eğer bu metot uygulanabilir değilse, bilgilendirme numarası şişenin içinde örnek ile birlikte bulundurulmalı ve bütün kayıtlar toplama kitabında veya kart dosyasında tutulmalıdır.

Konağın hangi lokaliteden toplandığı (köy, kasaba, eyalet, ırmak, göl veya coğrafik koordinatlar), deniz ve tatlı sudan toplandığında (ağ şekli, derinliği) parazit sayısı, parazitin konak canlıda bulunduğu yer ve tarihini de içermelidir. Eğer toplama bir diğer çalışma için yapılıyorsa, verilerde toplayıcı da tanımlanmalıdır.

Örneklerin Taşıma İçin Paketlenmesi

Güvenli taşıma sürecinde küçük cam şişelerin taşınması bazen problemdir. Bunun için plastik mühimmat kutuları kullanılır. Bunun için tasarlanan ve her bir küçük cam şişe için bir plastik hücre oluşturulan mühimmat kutuları tercih edilebilir.

Diğer bir metot, kullanılan küçük şişelerle aynı konumda dikçe doldurulmuş, birçok küçük şişeyi üst üste yerleştirmektir. Her bir küçük şişe bir plastik kapak veya tıpa ile kapatılmalıdır Bu işlem sırasında şişelerin içinde pamuk kullanmayın, çünkü örnekler karmakarışık hale gelebilir veya kaybolabilir. Pamuk tabakaları kavonozun tabanına ve tüpleri sımsıkı yerlerinde tutmak için, tüplerin üst kısmına da yerleştirilmelidir.

Eğer küçük şişeler tamamen sıvı ile doldurulursa örnekler daha az bir şekilde taşınma anında çalkalanmadan ötürü zarar görürler. Buharlaşmaya karşı önlem olarak özellikle sıcak havalarda mumlu kağıt veya parafilm şişenin ağzına kapak yerleştirilmeden yani turlanmadan önce gerdirilebilir. Plastik elektrik bandı her bir kapağın çevresine sarılarak ambalaj yapılabilir.

Örneklerin Sıvı İçerisinde Depolanması

Birçok müze, örnekleri aynı koruyucu ile doldurulmuş kapları iç içe ve alt-üst şekilde yerleştirilmiş küçük şişelerdeki sıvı örnekleri depolar. Bu yöntem ile eğer koruyucu buharlaşırsa küçük şişenin içindeki sıvı, en son giden olacaktır. Küçük şişelerin veya kavanozların kapakların kenarlarında parafilm kullanımı ve düzenli gözlem, örnekleri kuruma olayından korumanın en iyi yoludur. Buharlaşımadan korumanın diğer bir yolu, erimiş parafilm balmumu içine, küçük şişelerin kapalı hale getirilmiş sonlarını daldırmaktır.

Uyarı: Sıcaklıktaki aşırı değişimler, küçük şişelerin içindeki havanın genişlemesine bağlı olarak, parafilmin kabarmasına neden olabilir.

Eklenmiş güvenlik önlemi olarak, uzun süreli korumalar için %70'lik Etil alkolle %5'lik gliserol kullanımıdır. Bu örnekleri boyamak için alkol serilerinden geçirmeden önce, gliserolden kurtarmak için %70 etil alkolde bir çok kez yıkanmalıdır.

Kalıcı Preparatların Hazırlanması

Kalıcı preparatların hazırlanması, tüm parazit grupları için aynı olan birçok adımı içerir. Tekrarı önlemek için bu basamaklar aşağıda listelenmiştir. Helminth yumurtaları veya farklı parazit yumurtaları için gerekli olan özel teknikler, özel başlıklar altında listelenmiştir.

Boyama, Dehidratasyon ve Saydamlaştırma

Çoğu parazitin içyapıları histolojik preparasyon dışında tanımlanamaz. Parazitin farklı yapıları farklı derecelerde boyaları absorbe eder. Bu şekilde bazı yapılar daha az renkte boyansa bile, bazı kısımları göze çarpan bir şekilde boyamak mümkündür.

Boya seçiminde dikkat edilecek hususlar şunlar olmalıdır: Numunenin anatomisini farklı renklerde açıkça ortaya çıkmasını sağlamaya uygun yetenekte olmalıdır. Ayrıca güvenilir ve kullanımı kolay olmalıdır. Fiske edici maddelere uygun olmalıdır. Örnekler yıllarca aynı boyama özelliklerinde durmalıdır. Bunun için karmin ve hematoxilen boyaları en çok kullanılan gruplardır.

Karmin boyalar alkolde, hematoxylin boyalar da sucül solüsyon ortamlarında kullanıldıkları için, boyanacak tüm örnekler derecelenmiş alkol konsantrasyonlarından boya seviyelerine uygun prosedüre göre geçirilmek zorundadır. Bununla birlikte nemotod gibi bazı parazit türleri boyanamaz.

Boyama İçin Laboratuvar Kurulumu ve Malzemeleri

Boyama için başlıca boya malzemeleri; boyama kapları, boyama sepetleri, musluk suyu, distile su, alkol serileri (%35, 50, 70, 85, 95), asit alkol, saydamlaştırma ajanı, boya, pipet, pens.

Plastik tüplerin kısa bölümü birbirinin içine geçmiş ince naylon küçük daire kısımlı (Tabağa değmeyen), örnekleri alkol ve boya içinden taşıma için harikadırlar. Örnekleri sepet içindeki temizleme ajanlarına transfer etmeyin.

Not: Sepetin duvarlarının, sıvının derinliğinden daha derin olduğundan emin olun, yoksa örnekler üst kısımda yüzer. Bu uyarı özellikle farklı toplama numaraları bulunan parazitlerin beraberce işleme konulduğunda önemlidir. Sepet içindeki parazitleri etiket üzerinde bulunan toplama numarası ile tutun.

Örnekler küçük sepetler içinde boyama serilerinden geçirilir. Bu süreçte her bir alkol serisi arasında sepetlerdeki fazla alkolü almak için kağıt havlularla sepetlere dokunun fakat örneklerin kurumasına izin vermeyin. Eğer zaman ve donanım uygunsa, bir kap serisi kurun, böylelikle örnekler devamlı ileri yönde taşınabilir. Bu sıraya koyma, çok sayıda örneğin etkili bir şekilde çalışmasına izin verir. Uyarı: Solüsyonları başlangıçta veya her bir aralıklı kullanım periyodunda değiştirilir.

Boyama

Boyama, ilerleyen veya gerileyen bir konumda uygulanabilir. İlerleme uygulamasında örnekler, istenilen yoğunluk elde edilinceye kadar boyama ortamında bekletilir. Gerileme uygulamasında, fazla boyayı veya farklı boyalarla tekrarlanan boyamalardan sonra istenilen yoğunluğa ulaşıncaya kadar boyayı çıkarma işlemidir. Mayer's hematoxylin, genel iyi bir boyadır, fakat muhafaza ortamındaki maddeler asidik ise yıllar içinde boya rengi solma eğilimlidir. Uyarı: Fikse edilmiş ve formalinde depolanmış örnekler, bir gece boyunca musluk suyunda yıkanmak zorundadır. Yıkama sonrası 15 dakika süreliğine örnekleri glasiyal asedik asite aktarmak gerekir.

Dehidrasyon

Dehidrasyon, solüsyon ile suyun yerine başka bir maddenin konması işlemidir. Dehidrasyonun tersi hidrasyondur. Dehidrasyonda genellikle olağan adım olarak %35, 50, 70, 85, 95 ve absölü alkol serileri kullanılır. Her bir adımda 30 dakika beklenir. Bu süreçte alkol su ile yer değiştirir. Seri kaplarındaki solüsyonları buharlaşma ve atmosferden nem emme gibi olaylardan korumak için kapalı tutarak koruyun.

Saydamlaştırma

Saydamlaştırma, örnekteki tüm suyun çıkarılmasından sonra seçilen saydamlaştırma ajanına transfer edilmesi olayına denir. Saydamlaştırma maddesi paraziti saydam duruma getirir ve kapama ortamı ile uyumludur. Farklı saydamlaştırma maddelerinin avantajlarına rağmen xylene, laboratuarda geniş bir alanda saydamlaştırma maddesi olarak kullanılır.

Lam Üzerine Tespit (Daimi Preparat Yapımı)

Örnekleri Lam üzerine tespit ederek kalıcı preparat haline getirmek için, örneklerin içine bırakıldıktan sonra içerisindeki çözücü maddelerin buharlaşmasıyla katılaştıran bazı reçine solüsyonları kullanılır. Birçok sayıda sentetik kalıcı preparat gömme maddesi vardır. Fakat bunların pek çoğu müze materyalleri için kullanılmamalıdır. Kanada balsamı nem, sıcaklık ve benzer değişen çevre şartlarına çok az yanıt veren kanıtlanmış bir kalıcı preparat ortamı olarak hala kullanılmaktadır.

SONUÇ

Bilimsel çalışmalarda, hayvan parazitlerinin doğru şekilde yaşam ortamlarından toplanması, uygun şartlarda muhafaza edilmesi ve tanımlanması, hem temel biyolojik araştırmaların hem de tıp, veteriner, ziraat gibi uygulamalı bilim alanlarının çalışma verimliliği açısından büyük önem taşımaktadır. Konak canlılardan toplanan parazitlerin morfolojik ve moleküler özelliklerinin güvenilir biçimde incelenebilmesi, yalnızca doğru ve güvenilir metotlara dayalı örnekleme ve saklama yöntemlerinin titizlikle uygulanmasıyla mümkündür. Bu anlayış kapsamında geliştirilen bu rehber, parazitoloji araştırmalarında ortak bir çalışma yöntemi çerçevesi sunmakta, farklı disiplinlerde yürütülen parazitolojik araştırmalar arasında çalışma bütünlüğü ve uyumluluk sağlamayı hedeflemektedir. Ayrıca, çalışmalarda elde edilen bulguların konak-parazit ilişkilerinin ekolojik, epidemiyolojik ve evrimsel yönlerinin açıklığa kavuşturulmasına katkı sunması beklenmektedir. Böylece, doğada biyolojik çeşitliliğin korunması, evcil ve yabani ortamlardaki zoonotik hastalıkların önlenmesi ve sürdürülebilir sağlık programlarının oluşturulması aşamalarında, parazitoloji biliminin sunduğu temel verilerin bilimsel güvenilirlik kapsamında kullanılmasına katkı sağlanacaktır.

REFERANSLAR

Soulsby, E. J. L. (1982). *Helminths, Arthropods and Protozoa of Domesticated Animals*. 7th Edition, Baillière Tindall, London.

Thrusfield, M. (2018). *Veterinary epidemiology*. John Wiley & Sons.

Klein Kuadriğin Greek ve Latin Düzlemlerinin Etiketlenmesi Üzerine

Mine Münevvere KARAKAYA ¹

Ziya AKÇA ²

- 1- Dr.; Eskişehir Osmangazi Üniversitesi Fen Fakültesi Matematik ve Bilgisayar Bilimleri Bölümü, mine.zumruttas@gmail.com ORCID No: 0000-0003.-1517-3409.....
- 2- Prof. Dr.; Eskişehir Osmangazi Üniversitesi Fen Fakültesi Matematik ve Bilgisayar Bilimleri Bölümü. zakca@ogu.edu.tr ORCID No:0000.-0001-6379-0546.

ÖZET

Biz bu çalışmada, 5-boyutlu projektif uzay $PG(5,2)$ de Klein Kuadriğin Fano düzlemlerinin etiketlenmesi için bir yöntem veriyoruz ve projektif uzay $PG(5,2)$ nin alt uzaylar zincirinden oluşturulan bir maksimal flag kullanarak kuadriğin noktalarının bulundukları altuzaya göre bütün Fano düzlemlerini etiketliyoruz.

Anahtar Kelimeler – Projektif uzay, Klein Kuadrik, Fano düzlemi, Latin düzlem, Greek düzlem

GİRİŞ

Sonlu mertebeye sahip projektif düzlemler, hem cebirsel yapıların hem de kombinatorik konfigürasyonların kesişim noktasında yer alır ve özellikle sonlu cisimler kuramı ile sıkı bir ilişki içindedir. Bu düzlemler, belirli sayıda nokta ve doğru içerir ve belirli aksiyomlara uyan şekilde birbirleriyle ilişkilidir.

Bir projektif düzlemin sonlu mertebeli olması, her doğrunun üzerinde sabit sayıda nokta bulunması anlamına gelir ve bu mertebe cebirsel yapı $GF(q)$ Galois cismi ise q ile gösterilir. Eğer bir projektif düzlemin mertebesi q ise, her doğru üzerinde $q + 1$ tane nokta vardır ve toplamda $q^2 + q + 1$ nokta ve aynı sayıda doğru içerir. Bu özellikler, projektif düzlemlerin oldukça simetrik yapılar olmasına yol açar. Bu düzlemler aynı zamanda kombinatorik tasarımlar, hata düzeltici kodlar, cebirsel eğriler ve sonlu geometri gibi birçok alanda önemli uygulamalara sahiptir.

Sonlu projektif düzlemler üzerine yapılan araştırmalar, yalnızca klasik yapıların (örneğin Desarguesyen düzlemler) ötesine geçmekle kalmayıp, aynı zamanda Desarguesyen olmayan örneklerin varlığı, sınıflandırılması ve özellikleri üzerine de yoğunlaşmaktadır. Özellikle bir projektif düzlemin altdüzlemleri, otomorfizma grupları, yayları (arc), blok tasarımlar ve konfigürasyonlar gibi konular bu çalışmaların merkezinde yer almaktadır. Eğer mertebe $q = 2$ ise 7 noktaya sahip projektif düzlem Fano düzlemi olarak bilinir. Fano düzlemi, sonlu projektif düzlemlerin en küçük ve en basit örneğidir. Bu düzlem 2 elemanlı sonlu cisim $(GF(2))$ üzerinde tanımlı projektif düzlem ise $PG(2,2)$ olarak gösterilir. $X = \{1, 2, 3, 4, 5, 6, 7\}$ kümesi ile oluşacak Fano düzleminin doğruları $\{1,2,3\}, \{1,4,5\}, \{1,6,7\}, \{2,4,6\}, \{2,5,7\}, \{3,4,7\}, \{3,5,6\}$ kümeleri olarak elde edilir ve aşağıdaki klasik şekilde gösterilir.

Fano düzlemi kombinatorik tasarım kuramı içinde $(7,3,1)$ –tasarımı olarak yer alır. Kuvvetli simetri özelliğinden dolayı hata düzeltici kodlar ve blok tasarımları içinde örnek olarak kullanılır. Lineer cebir ve homojen

koordinatlar kullanılarak inşa edilebilir. Grup kuramı açısından da ilgi çekicidir: Otomorfizma grubu, 168 elemanlı $PGL(3,2)$ grubudur.

Bu 7 elemanlı $X = \{1, 2, 3, 4, 5, 6, 7\}$ kümesi ile etiketlenmiş Fano Düzlemlerinin kombinasyonları Fano düzleminin otomorfizmalar grubu 168. mertebeden olduğundan

$7!/168 = 30$ farklı etiketlemeye sahiptir.

Şimdi, $n > 0$ olmak üzere ve K herhangi bir cisim olmak üzere, n -boyutlu projektif uzay $PG(n, K)$ yı tanımlıyoruz.

V, K cismi üzerinde tanımlı boyutu $n + 1$ olan bir vektör uzayı olsun.

O zaman $PG(n, K), K$ üzerinde tanımlı n –boyutlu projektif uzay, V 'nin sıfır altuzayı $\{0\}$ ve V nin kendisi hariç tüm altuzaylarının kümesidir.

V' nin bir boyutlu altuzaylarına $PG(n, K)$ nin noktaları,

İki boyutlu altuzaylara $PG(n, K)$ nin (projektif) doğruları,

Üç boyutlu altuzaylara ise $PG(n, K)$ nin (projektif) düzlemleri denir.

V nin sıfır olmayan herhangi bir $(k + 1)$ -boyutlu altuzayına, $PG(n, K)$ iin bir k -altuzayı veya kısaca bir altuzayı denir.

Her altuzay aynı zamanda bir vektör uzayı olduğundan, $PG(n, K)$ nin herhangi bir altuzayı, bir projektif uzay olarak da görülebilir.

Eğer $|K| = q + 1$ yani K sonlu elemanlıysa, o zaman projektif uzayın mertebesi olarak q kabul edilir.

Klein kuadrik, 3 –boyutlu projektif uzay $PG(3, K)$ içindeki tüm doğruların cebirsel-geometrik temsilidir. Ancak bu temsil 5 –boyutlu projektif uzayda gerçekleşir. Bu kuadrik, tüm doğruların Plücker koordinatları kullanılarak elde edilen cebirsel bir parametrisasyonunu sağlar. Her nokta bir doğruyu temsil eder. Yani, Klein kuadrik, 3-boyutlu projektif uzaydaki $(PG(3, q))$ doğruları temsil eden, 5 –boyutlu projektif uzay $PG(5, q)$ da yer alan bir kuadrik yüzeydir. $PG(3, 2)$ daki her doğru, her nokta ve her düzlem sırasıyla Klein dönüşümü ile bu kuadriğin bir noktasına, bir Latin düzlemine ve bir Greek düzlemine dönüşür.

Biz bu çalışmada 5 –boyutlu projektif uzay $PG(5, 2)$ de Klein Kuadriğin Fano düzlemlerinin etiketlenmesi için bir yöntem vereceğiz ve bütün Fano düzlemlerini etiketleyeceğiz.

KLEİN KUADRIĞIN α VE β DÜZLEMLERİ

$PG(5, 2)$ de Klein Kuadriğin 15 tane Latin, 15 tane de Greek düzlemi vardır. Bu düzlemler α ve β düzlemleri olarak da adlandırılır. Bu bölümde α ve β düzlemlerinin noktalarının etiketlenmesi verilecektir.

Öncelikle $PG(5, 2)$ projektif uzayında alt uzaylar zincirinin oluşturulacağı bir maksimal flag elde edilecektir. Bunun için uzayın seçilen bir noktası taban nokta ve bu noktadan geçen herhangi bir doğru taban doğru olacak şekilde seçilecektir. Biz bu çalışmada aşağıdaki seçtiğimiz taban nokta ve taban doğru

ile alt uzaylar zincirini oluşturacağız ve oluşturduğumuz bu maksimal flag içinde Klein kuadriğin Latin ve Greek düzlemlerinin noktalarını bulundukları alt uzaya göre belirlenen renklerle etiketleyerek bu düzlemlerdeki noktalarının bir parçalanmasını içeren iki tablo sunacağız.

$PG(5,2)$ projektif uzayında $q = (0,0,0,1,0,0)$ taban noktası ve bu taban noktadan geçen taban doğrusu

$$U'_1 = \{(0,0,0,1,0,0), (1,0,0,0,1,0), (0,0,1,1,0,0)\}$$

seçilip ve bu taban doğru üzerinde olmayan $(0,0,0,0,1,0)$ noktası ile gerilen

$$U'_2 = \{(1,0,0,0,0,0), (1,0,0,0,1,0), (0,0,1,1,0,0), (0,0,0,0,1,0), \\ (0,0,0,1,1,0), (0,0,1,0,1,0), (0,0,1,1,1,0)\}$$

taban düzlemi elde edilir.

U'_2 taban düzlemi ile bu düzlem dışındaki $(1,0,0,0,1,0)$ noktasının gerdiği üç boyutlu uzay $U'_3 = [x_1, x_2, x_3, x_4, x_5, x_6]$ olsun. Bu uzayın noktalarını bulmak için $(1,0,0,0,1,0)$ noktası ve bu düzleminin 7 noktası ile bu uzayda yazılıp üzerinde bulunma bağıntısı kullanılırsa;

$$\begin{aligned} (1,0,0,0,1,0) &\rightarrow x_1 + x_5 = 0 \\ (0,0,0,1,0,0) &\rightarrow x_4 = 0 \\ (0,0,0,0,1,0) &\rightarrow x_5 = 0 \\ (0,0,0,1,1,0) &\rightarrow x_4 + x_5 = 0 \\ (0,0,1,1,0,0) &\rightarrow x_3 + x_4 = 0 \\ (0,0,1,1,1,0) &\rightarrow x_3 + x_4 + x_5 = 0 \\ (0,0,1,0,0,0) &\rightarrow x_3 = 0 \\ (0,0,1,0,1,0) &\rightarrow x_3 + x_5 = 0 \end{aligned}$$

denklemleri elde edilir. Bu denklemlerden $x_1 + x_5 = 0$, $x_3 = 0$, $x_4 = 0$, $x_5 = 0$ bulunur. O halde $U'_3 = [0, x_2, 0, 0, 0, x_6]$ biçimindedir. U'_3 uzayında 15 nokta bulunur. Bu noktalar aşağıdaki noktalardır. Projektif 3-uzaylarda 15 nokta bulunduğundan U'_3 bir 3-uzaydır.

$H^5(2) \cap U'_3$ nün noktaları aşağıdaki gibidir:

$$\begin{aligned} U''_3 &= H^5(2) \cap U'_3 \\ &= \{(0,0,0,1,0,0), (0,0,0,0,1,0), (0,0,1,0,0,0), (0,0,1,0,1,0), (0,0,0,1,1,0), \\ &(0,0,1,1,0,0), (0,0,1,1,1,0), (1,0,0,0,1,0), (1,0,0,0,0,0), (1,0,1,0,0,0), (1,0,1,0,1,0)\} \end{aligned}$$

U'_3 uzayı ve bu 3-uzay dışındaki $(1,0,0,0,0,1)$ noktasının gerdiği uzay

$U'_4 = [x_1, x_2, x_3, x_4, x_5, x_6]$ olsun. U''_3 3-uzayının 15 noktası ve $(1,0,0,0,1)$ noktası kullanılırsa $x_1 = 0, x_3 = 0, x_4 = 0, x_5 = 0, x_6 = 0$ elde edilir. O halde $U'_4 = [0, x_2, 0,0,0,0]$ biçimindedir. U'_4 uzayında 31 nokta bulunur. Projektif 4-uzaylarda 31 nokta bulunduğundan U'_4 bir 4-uzaydır. Bu $U''_4 = H^5(2) \cap U'_4$ nün noktaları aşağıdaki gibidir:

$$\begin{aligned} U''_4 &= H^5(2) \cap U'_4 \\ &= \{(0,0,0,1,0,0), (0,0,0,0,1,0), (0,1,0,0,0,0), (0,0,1,0,1,0), (0,0,0,1,1,0), \\ &(0,0,1,1,1,0), (1,0,0,0,1,0), (1,0,0,0,0,0), (1,0,1,0,0,0), (1,0,1,0,1,0), (1,0,0,0,0,1), \\ &(0,0,0,0,0,1), (0,0,0,0,1,1), (0,0,0,1,0,1), (0,0,0,1,1,1), (1,0,0,0,1,1), (1,0,1,1,0,1), \\ &(0,0,1,1,0,0), (1,0,1,1,1,1)\} \end{aligned}$$

Böylece $PG(5,2)$ de $(q, U'_1, U'_2, U'_3, U'_4, PG(5,2))$ maksimal flagdır.

$(q, U'_1, U'_2, U'_3, U'_4, PG(5,2))$ maksimal flagında taban noktayı siyah, U'_1/q daki noktaları kırmızı, U'_2/U'_1 daki noktaları yeşil, U'_3/U'_2 daki noktaları mavi, U'_4/U'_3 daki noktaları sarı , $PG(5,2)/U'_4$ daki noktaları pembe renkli gösterelim.


Bu renklendirmeye göre $PG(5,2)$ deki Klein Kuadrık $H^5(2)$ nin α ve β düzlemlerindeki noktalarının maksimal flag içindeki dağılımları aşağıdaki Çizelge deki gibidir.

Tablo 1 Klein Kuadrığının α ve β düzlemlerinin Noktalarının dağılımları


	Düzlemdeki q taban nokta sayısı (siyah)	Düzlemdeki U'_1/q daki nokta sayısı (kırmızı)	U'_2/L nokta sayısı (yeşil)	$H^5(2) \cap (U'_3/\alpha_1)$ daki nokta sayısı (mavi)	$H^5(2) \cap (U'_4/U'_3)$ daki nokta sayısı (sarı)	$H^5(2)/U'_4$ daki nokta sayısı (pembe)
α_1	1	2	4			
α_2	1				2	4
α_3	1				2	4
α_4			1	2	4	
α_5			1	2	4	
α_6			1		2	4
α_7			1		2	4

α_8		1		2		4
α_9		1		2		4
α_{10}		1			2	4
α_{11}		1		4	2	
α_{12}			1	2	4	
α_{13}			1	2		4
α_{14}			1	2		4
α_{15}			1		2	4
β_1				1	2	4
β_2		1	2	4		
β_3				1	2	4
β_4	1	2				4
β_5				1	2	4
β_6		1	2			4
β_7				1	2	4
β_8	1		2		4	
β_9				1	2	4
β_{10}		1	2		4	
β_{11}				1	2	4
β_{12}	1		2			4
β_{13}				1	2	4
β_{14}		1	2			4
β_{15}				1	2	4


Bundan sonraki bölümde α ve β düzlemlerinin noktaları verilip, yukarıdaki tablolara göre renklendirilerek şekilleri çizilecektir.




Şekil 1 α_1 Düzlemi




Şekil 2 α_2 Düzlemi




Şekil 3 α_3 Düzlemi




Şekil 4 α_4 Düzlemi




Şekil 5 α_5 Düzlemi




Şekil 6 α_6 Düzlemi




Şekil 7 $\propto_7$ Düzlemi




Şekil 8 $\propto_8$ Düzlemi




Şekil 9 α_9 Düzlemi




Şekil 10 α_{10} Düzlemi




Şekil 11 α_{11} Düzlemi




Şekil 12 α_{12} Düzlemi



Şekil 13 α_{13} Düzlemi




Şekil 14 α_{14} Düzlemi




Şekil 15 α_{15} Düzlemi


β –Greek Düzlemleri




Şekil 16 β_1 Düzlemi




Şekil 17 β_2 Düzlemi




Şekil 18 β_3 Düzlemi




Şekil 19 β_4 Düzlemi




Şekil 20 β_5 Düzlem




Şekil 21 β_6 Düzlemi




Şekil 22 β_7 Düzlemi




Şekil 23 β_8 Düzlemi




Şekil 24 β_9 Düzlemi




Şekil 25 β_{10} Düzlemi




Şekil 26 β_{11} Düzlemi




Şekil 27 β_{12} Düzlemi



Şekil 28 β_{13} Düzlemi



Şekil 29 β_{14} Düzlemi



Şekil 30 β_{15} Düzlemi

$PG(5,2)$ projektif uzayındaki herhangi bir α Latin düzlemi üzerinde $PG(3,2)$ deki bir noktadan geçen 7 tane doğrunun Klein dönüşümü altında görüntülerinden oluşan 7 nokta vardır.

$PG(5,2)$ nin her noktasından mertebe $q = 2$ olduğundan 6 düzlem geçer. Yani bir noktadan 3 tane α düzlemi ve 3 tane β düzlemi geçmektedir. Burada bir noktada kesişen Latin ve Greek düzlemleri listelenmektedir.

Bir noktada kesişen Latin düzlemleri aşağıdadır.

$\alpha_1, \alpha_2, \alpha_3$ düzlemleri (0,0,0,1,0,0) noktasında kesişmektedir.
 $\alpha_1, \alpha_4, \alpha_5$ düzlemleri (0,0,0,0,1,0) noktasında kesişmektedir.
 $\alpha_1, \alpha_6, \alpha_7$ düzlemleri (0,0,0,1,1,0) noktasında kesişmektedir.
 $\alpha_1, \alpha_8, \alpha_9$ düzlemleri (0,0,1,0,0,0) noktasında kesişmektedir.
 $\alpha_1, \alpha_{10}, \alpha_{11}$ düzlemleri (0,0,1,1,0,0) noktasında kesişmektedir.
 $\alpha_1, \alpha_{12}, \alpha_{13}$ düzlemleri (0,0,1,0,1,0) noktasında kesişmektedir.
 $\alpha_2, \alpha_4, \alpha_6$ düzlemleri (0,0,0,0,0,1) noktasında kesişmektedir.
 $\alpha_2, \alpha_5, \alpha_7$ düzlemleri (0,0,0,1,0,1) noktasında kesişmektedir.
 $\alpha_2, \alpha_8, \alpha_{10}$ düzlemleri (0,1,0,0,0,0) noktasında kesişmektedir.
 $\alpha_2, \alpha_9, \alpha_{11}$ düzlemleri (0,1,0,1,0,0) noktasında kesişmektedir.
 $\alpha_2, \alpha_{13}, \alpha_{15}$ düzlemleri (0,1,0,1,0,1) noktasında kesişmektedir.
 $\alpha_3, \alpha_4, \alpha_7$ düzlemleri (0,0,0,0,1,1) noktasında kesişmektedir.
 $\alpha_3, \alpha_5, \alpha_6$ düzlemleri (0,0,0,1,1,1) noktasında kesişmektedir.
 $\alpha_2, \alpha_{12}, \alpha_{14}$ düzlemleri (0,1,0,0,0,1) noktasında kesişmektedir.
 $\alpha_3, \alpha_{11}, \alpha_8$ düzlemleri (0,1,1,0,0,0) noktasında kesişmektedir.
 $\alpha_3, \alpha_9, \alpha_{10}$ düzlemleri (0,1,1,1,0,0) noktasında kesişmektedir.
 $\alpha_3, \alpha_{12}, \alpha_{15}$ düzlemleri (0,1,1,0,1,1) noktasında kesişmektedir.
 $\alpha_3, \alpha_{13}, \alpha_{14}$ düzlemleri (0,1,1,1,1,1) noktasında kesişmektedir.
 $\alpha_2, \alpha_7, \alpha_5$ düzlemleri (0,0,0,1,0,1) noktasında kesişmektedir.
 $\alpha_5, \alpha_{11}, \alpha_{14}$ düzlemleri (1,0,1,1,1,1) noktasında kesişmektedir.
 $\alpha_5, \alpha_{13}, \alpha_{18}$ düzlemleri (1,0,1,0,0,0) noktasında kesişmektedir.
 $\alpha_5, \alpha_9, \alpha_{12}$ düzlemleri (1,0,1,0,1,0) noktasında kesişmektedir.
 $\alpha_5, \alpha_{15}, \alpha_{10}$ düzlemleri (1,0,1,1,0,1) noktasında kesişmektedir.
 $\alpha_6, \alpha_8, \alpha_{14}$ düzlemleri (1,1,0,0,0,0) noktasında kesişmektedir.
 $\alpha_6, \alpha_{12}, \alpha_{10}$ düzlemleri (1,1,0,0,0,1) noktasında kesişmektedir.
 $\alpha_6, \alpha_{15}, \alpha_9$ düzlemleri (1,1,0,1,1,0) noktasında kesişmektedir.
 $\alpha_6, \alpha_{13}, \alpha_{11}$ düzlemleri (1,1,0,1,1,1) noktasında kesişmektedir.
 $\alpha_7, \alpha_8, \alpha_{15}$ düzlemleri (1,1,1,0,0,0) noktasında kesişmektedir.
 $\alpha_7, \alpha_{11}, \alpha_{12}$ düzlemleri (1,1,1,0,1,1) noktasında kesişmektedir.
 $\alpha_7, \alpha_{13}, \alpha_{10}$ düzlemleri (1,1,1,0,1,1) noktasında kesişmektedir.
 $\alpha_7, \alpha_{13}, \alpha_{10}$ düzlemleri (1,1,1,1,0,1) noktasında kesişmektedir.
 $\alpha_7, \alpha_9, \alpha_{14}$ düzlemleri (1,1,1,1,1,0) noktasında kesişmektedir.
 $\alpha_4, \alpha_8, \alpha_{12}$ düzlemleri (1,0,0,0,0,0) noktasında kesişmektedir.
 $\alpha_4, \alpha_9, \alpha_{13}$ düzlemleri (1,0,0,0,1,0) noktasında kesişmektedir.
 $\alpha_4, \alpha_{11}, \alpha_{15}$ düzlemleri (1,0,0,0,1,1) noktasında kesişmektedir.
 $\alpha_1, \alpha_{14}, \alpha_{15}$ düzlemleri (0,0,1,1,1,0) noktasında kesişmektedir.
 $\alpha_4, \alpha_{10}, \alpha_{14}$ düzlemleri (1,0,0,0,0,1) noktasında kesişmektedir.

Benzer şekilde bir noktada kesişen Greek düzlemleri aşağıdadır.

$\beta_1, \beta_6, \beta_7$ düzlemleri $(1,1,0,0,0,0)$ noktasında kesişmektedir.
 $\beta_1, \beta_8, \beta_9$ düzlemleri $(0,0,0,0,0,1)$ noktasında kesişmektedir.
 $\beta_1, \beta_4, \beta_5$ düzlemleri $(0,1,0,0,0,1)$ noktasında kesişmektedir.
 $\beta_1, \beta_{12}, \beta_{13}$ düzlemleri $(0,1,0,0,0,1)$ noktasında kesişmektedir.
 $\beta_1, \beta_2, \beta_3$ düzlemleri $(1,0,0,0,0,0)$ noktasında kesişmektedir.
 $\beta_1, \beta_{10}, \beta_{11}$ düzlemleri $(1,0,0,0,0,1)$ noktasında kesişmektedir.
 $\beta_1, \beta_{14}, \beta_{15}$ düzlemleri $(1,1,0,0,0,1)$ noktasında kesişmektedir.
 $\beta_2, \beta_8, \beta_{10}$ düzlemleri $(0,0,0,0,1,0)$ noktasında kesişmektedir.
 $\beta_2, \beta_4, \beta_6$ düzlemleri $(0,0,1,0,0,0)$ noktasında kesişmektedir.
 $\beta_1, \beta_6, \beta_7$ düzlemleri $(1,1,0,0,0,0)$ noktasında kesişmektedir.
 $\beta_2, \beta_{12}, \beta_{14}$ düzlemleri $(0,0,1,0,1,0)$ noktasında kesişmektedir.
 $\beta_2, \beta_{13}, \beta_{15}$ düzlemleri $(1,0,1,0,1,0)$ noktasında kesişmektedir.
 $\beta_2, \beta_5, \beta_7$ düzlemleri $(1,0,1,0,0,0)$ noktasında kesişmektedir.
 $\beta_2, \beta_9, \beta_{11}$ düzlemleri $(1,0,0,0,1,0)$ noktasında kesişmektedir.
 $\beta_3, \beta_{12}, \beta_{15}$ düzlemleri $(0,1,1,0,1,1)$ noktasında kesişmektedir.
 $\beta_3, \beta_9, \beta_{10}$ düzlemleri $(1,0,0,0,1,1)$ noktasında kesişmektedir.
 $\beta_3, \beta_5, \beta_6$ düzlemleri $(1,1,1,0,0,0)$ noktasında kesişmektedir.
 $\beta_3, \beta_{13}, \beta_{14}$ düzlemleri $(1,1,1,0,1,1)$ noktasında kesişmektedir.
 $\beta_4, \beta_{10}, \beta_{14}$ düzlemleri $(0,0,1,1,0,0)$ noktasında kesişmektedir.
 $\beta_3, \beta_8, \beta_{11}$ düzlemleri $(0,0,0,0,1,1)$ noktasında kesişmektedir.
 $\beta_3, \beta_4, \beta_7$ düzlemleri $(0,1,1,0,0,0)$ noktasında kesişmektedir.
 $\beta_4, \beta_{11}, \beta_{15}$ düzlemleri $(0,1,1,1,0,0)$ noktasında kesişmektedir.
 $\beta_4, \beta_9, \beta_{13}$ düzlemleri $(0,1,0,1,0,0)$ noktasında kesişmektedir.
 $\beta_4, \beta_8, \beta_{12}$ düzlemleri $(0,0,0,1,0,0)$ noktasında kesişmektedir.
 $\beta_5, \beta_9, \beta_{12}$ düzlemleri $(0,1,0,1,0,1)$ noktasında kesişmektedir.
 $\beta_5, \beta_{10}, \beta_{15}$ düzlemleri $(1,0,1,1,0,1)$ noktasında kesişmektedir.
 $\beta_5, \beta_{10}, \beta_{15}$ düzlemleri $(1,0,1,1,0,1)$ noktasında kesişmektedir.
 $\beta_5, \beta_{11}, \beta_{14}$ düzlemleri $(1,1,1,1,0,1)$ noktasında kesişmektedir.
 $\beta_6, \beta_{10}, \beta_{12}$ düzlemleri $(0,0,1,1,1,0)$ noktasında kesişmektedir.
 $\beta_6, \beta_9, \beta_{15}$ düzlemleri $(1,1,0,1,1,0)$ noktasında kesişmektedir.
 $\beta_6, \beta_8, \beta_{14}$ düzlemleri $(0,0,0,1,1,0)$ noktasında kesişmektedir.
 $\beta_6, \beta_{11}, \beta_{13}$ düzlemleri $(1,1,1,1,1,0)$ noktasında kesişmektedir.
 $\beta_7, \beta_{11}, \beta_{12}$ düzlemleri $(0,1,1,1,1,1)$ noktasında kesişmektedir.
 $\beta_7, \beta_{10}, \beta_{13}$ düzlemleri $(1,0,1,1,1,1)$ noktasında kesişmektedir.
 $\beta_7, \beta_9, \beta_{14}$ düzlemleri $(1,1,0,1,1,1)$ noktasında kesişmektedir.
 $\beta_7, \beta_8, \beta_{15}$ düzlemleri $(0,0,0,1,1,1)$ noktasında kesişmektedir.
 $\beta_5, \beta_8, \beta_{13}$ düzlemleri $(0,0,0,1,0,1)$ noktasında kesişmektedir.

SONUÇ

Klein dönüşümü ile $PG(3,q)$ projektif uzayı $PG(5,q)$ projektif uzayına gömülerek Klein Kuadrik elde edilmektedir. Bu dönüşüm ile $PG(3,q)$ nun noktaları, doğruları ve düzlemleri sırasıyla Klein Kuadriğin α düzlemlerine, noktalarına ve β düzlemlerine dönüşmektedir.

Bu çalışmada $PG(5,2)$ de Plücker koordinatları kullanılarak Klein Kuadriğin α ve β düzlemleri seçilen maksimal flaga göre renklendirilmiştir.

REFERANSLAR

- [1] Akça, Z., & Altıntaş, A. (2023). Fuzzy Counterpart of Klein Quadric. International Electronic Journal of Geometry, 16, s. 680-688.
- [2] Akça Z, Bayar A, Ekmekçi S, Van Maldeghem H. Fuzzy Projective Spreads of Fuzzy Projective Spaces, Fuzzy Sets and Systems, 2006; 157(24): 3237-3247.
- [3] Akça, Z., Bayar, A., & Ekmekçi, S. (2007). On the classification of Fuzzy projective lines of Fuzzy 3-dimensional projective spaces. Communications Mathematics and Statics, 55(2), s. 17-23.
- [4] Akça, Z., Bayar, A., Ekmekçi, S., Kaya, R., Thas, J. A., & Van Maldeghem, H. (2012). Generalized lax Veronesean embeddings of projective spaces. Ars Combin, 103, s. 65-80.
- [5] Bayar, A., Akça, Z., & Ekmekçi, S. (2008). : A Note on Fibered Projective Plane Geometry. Information Science 178, s. 1257-1262.
- [6] Ekmekçi, S., Bayar, A., & Akça, Z. (2009). On the classification of Fuzzy projective planes of Fuzzy 3-dimensional projective spaces,. Chaos, Solitons and Fractals 40, s. 2146-2151.
- [7] Hirschfeld, J., & Thas, J. (2016). General Galois Geometries. Springer Monographs in Mathematics.
- [8] Karakaya, M. M., & Akça, Z. (2024). On The Fuzzification of Greek Planes of Klein Quadric. Eskişehir Technical University Journal of Science And Technology.
- [8] Klein, F. (1884). Über die Transformation der Allgemeinen Gleichung des zweiten Grades zwischen Linien - Koordinaten auf eine kanoishche Form. Mathematische Annalen, 23, s. 539-578.
- [9] Klein, F. (1884). Über die Transformation der Allgemeinen Gleichung des zweiten Grades zwischen Linien - Koordinaten auf eine kanoishche Form. Mathematische Annalen, 23, s. 539-578.

- [10] Kuijken, L., & Maldeghem, H. (2003). On the definition and some conjectures of fuzzy projective planes by Gupta and Ray, and a new definition of fuzzy building geometries. *Fuzzy Sets And Systems*, 138(3), s. 667–685.
- [11] Kuijken, L., Van Maldeghem, H., & Kerre, E. E. (1998). Fuzzy projective geometries from fuzzy vector spaces. A. Billot et al. (Eds.), *Information Processing and Management of Uncertainty in Knowledge-based Systems*, Editions Medicales et Scientifiques, Paris, La Sorbonne,, s. 1331-1338.
- [12] Lubczonok, P. (1990). Fuzzy Vector Spaces. *Fuzzy Sets and Systems*, 38, s. 329-343.
- [13] Plücker, J. (1865). On a New Geometry of Space. *Philosophical Transactions of the Royal Society of London*, 155, s. 725-791.
- [14] Zadeh, L. (1965). Fuzzy Sets. *Information and Control*, 8, s. 338-353.

Akçadağ Yöresinde Doğal Olarak Yetişen *Salvia sclarea* Bitkisinin Uçucu Yağ Bileşenleri

Ülkü YILMAZ¹

¹ Prof. Dr. Ülkü YILMAZ, Malatya Turgut Özal Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Mühendislik Temel Bilimleri Bölümü, 44900, Yeşilyurt, Malatya, Türkiye, ulku.yilmaz@ozal.edu.tr, ORCID ID: 0000-0002-2806-4781

ÖZET

Bu çalışmada Malatya Akçadağ yöresinde doğal olarak yetişen *Salvia L.* cinsine ait birçok türden biri olan *Salvia sclarea* bitki türüne ait esansiyel yağın hidrodistilasyon yöntemiyle elde edilerek kimyasal içeriğinin belirlenmesi ve farklı konumlardan elde edilen bitkinin literatür verileriyle kıyaslanması gerçekleştirildi. Yapılan çalışmada kimyasal içeriğin ana bileşenleri linalil bütirat (%54.74), linalol (%15.08), karyofilen (%7.08), α -terpineol (%4.20) olarak belirlendi.

Anahtar Kelimeler – *Salvia sclarea*, Clevenger aparatı, hidrodistilasyon, GC-MS, kimyasal bileşen

GİRİŞ

Lamiaceae familyasına ait *Salvia L.* cinsinden bitkiler dünyada bine yakın tür ile temsil edilmektedir. Türkiye’de de seksenin üzerinde *Salvia L.* türü bulunmaktadır. Monoterpen içeriğiyle zengin olan bitkinin türleri antiseptik, antikanser, antibakteriyel, antioksidan etki göstermelerinin yanı sıra binlerce yıldır şifalı bitkiler olarak halk tıbbında ilaç, kozmetik ürün ve baharat olarak kullanılmaktadırlar. (Özdemir ve Şenel, 1999; Nakipoğlu, 1993; Russo vd., 2013).

Salvia sclarea

Salvia L. bitki türlerinden biri olan *Salvia sclarea* koku kaynağı olarak parfümlerde, diğer kozmetik ürünlerinde, tıpta ve yemeklerde tatlandırıcı olarak kullanılmaktadır (Özdemir ve Şenel, 1999; Durling vd., 2007; Kong vd., 2010). Bu tür iki ya da çok yıllık olabilmektedir. Güney Avrupa’ya özgü bir bitki olup Türkiye’de de bazı bölgelerde doğal olarak yetişmektedir. Bir metreyi aşan boya sahip olabilen bitkinin çiçek sapları yaklaşık 40 cm ye kadar uzanabilmektedir. Yapılan makale çalışmasında yaprak ve çiçeklerde bulunan peltat tüylerinden dolayı bitkiye has karakteristik kokunun salgılandığı kaydedilmiştir (Özdemir ve Şenel, 1999). Bitkinin ekstrakt ya da uçucu yağlarının antioksidan, antimikrobiyal ve asetilkolinesteraz etkinlikleri rapor edilmiştir (Yücel ve Nath, 2023; Gülçin vd., 2004).

Bu tür tıbbi aromatik bitkilerin kimyasal bileşenleri gösterecekleri biyo-aktivite açısından önemlidir. Bu anlamda bitkilerin doğal olarak

yetiřtięi alanların çevresel ve iklimsel farklılıkları içerdikleri ana kimyasalları ve bileřenler arasındaki oranlarını deęiřtirmektedir. Bu durumda bitkilerin biyo-aktiviteleri bitkinin toplandıęı alana göre deęiřmektedir. Bu durumu örneklerle açıklamaya çalışalım.

Fransa’da toplanan bitki örneęinin antibakteriyel özellik gösteren uçucu yaęına ait bileřenler incelendięinde karıřımdaki ana bileřiklerin isimleri ve karıřımdaki yüzde oranlarının;

- Linalil asetat, %74.56,
- Linalol, %12.33, ve
- Germakren D, %1.93 olduęu kaydedilmiřtir (Cui vd., 2015).

İtalya-Toskana bölgesinde 2022’de toplanan bitki örneęinden elde edilmiř olan uçucu yaęın antibakteriyel özellik gösterdięi rapor edilmiř ve kimyasal bileřenlerinden en dikkat çekici olanlar ise sırayla,

- Linalil asetat, %59.3,
- Linalol, %11.3,
- Germakren D, %10.5,
- β -Karyofilen, %3.7, ve
- Geranil asetat, %2.5 olarak ölçölmüřtür (Ben Akacha vd., 2023).

Bařka bir çalışmada Slovakya-Nitra’dan toplanan *Salvia sclarea* örneęinin antibakteriyel özellikli uçucu yaęına ait bileřen içerięi deęerlendirildięinde en yüksek oranda bulunan bileřenler sırayla ařaęıdaki gibidir (Kačániová vd., 2023).

- Linalol asetat, %49.1,
- Linalol, %20.6,
- (E)-Karyofilen, %5.1
- *p*-Simen, %4.9,
- Geranil asetat, %4.4,
- α -Terpineol, %4.9,

Tacikistan’da Yovan bölgesinden 2010 yılında toplanan bitkinin uçucu yaę bileřen oranları (Sharopov ve Setzer, 2012) aęırlıkça;

- Linalil asetat, %39.2,
- Linalol, %12.5,
- Germakren D, %11.4,
- α -Terpineol, %5.5,
- Geranil asetat, %3.5, ve
- (E)-Karyofilen, %2.4 olarak kaydedilmiştir.

Nahçıvan'dan elde edilen bitkinin (Gul vd., 2020) esansiyel yağ oranının kuru bitkinin % 0.3 ila % 0.4 ü arasında olduğu bildirilmiş olup, yağın antihelmintik etki gösterdiği vurgulanmıştır. Kimyasal olarak ağırlıkça yüksek oranda belirlenen bileşenler ise,

- Linalil asetat, %41.2,
- Linalol, %18.9,
- Germakren D, %9.4,
- Geranil asetat, %5.3, ve
- Karyofilen, %3.1 şeklinde sıralanmaktadır.

Sırbistan'da 2018 yılında elde edilen bitki kurusundan sağlanan esansiyel yağın ana bileşenleri,

- Linalil asetat, %43.6,
- Linalol, %25.3,
- α -Terpineol, %5.0,
- Geranil asetat, %4.3 şeklinde kaydedilmiştir (Acimovic vd., 2022).

Tunceli-Ovacık'ta 2010 yılında toplanan aynı bitkinin kimyasal içeriği üstte bahsedilen örnek konumlardan elde edilen esansiyel yağ bileşen oranlarından farklı olarak aşağıdaki gibi sıralanmaktadır (Dogan vd., 2015).

- Spathulenol, %19.0,
- Karyofilen oksit, %15.5,
- Linalil asetat, %11.3,
- Linalol-L, %8.5, ve
- 1H-Nafto[2,1-b]piran, %7.0.

2014 yılında Yunanistan'dan toplanan ve kurutularak hidrodistilasyon yöntemiyle uçucu yağ bileşenleri tespit edilen bitkinin ana bileşenleri (Koutsaviti vd., 2016),

- Linalol asetat, %37.6,
- Linalol, %35.8,
- α -Terpineol, %11.0,
- Germakren D, %5.2,
- Mirsen, %3.0 şeklinde kaydedilmiştir.

Tunceli Munzur vadisinde toplanan bitkinin uçucu yağ oranı %0.1 (v/w) olarak belirlenmiş (Yuce vd., 2014) ve antifungal, antioksidan özellik gösteren yağın ana bileşenleri,

- Karyofilen oksit, %24.1,
- Spathulenol, %11.4,
- Sclareol, %11.5,
- 1H-Nafto[2,1-b]piran, %8.6,
- β -Karyofilen, %5.1, ve
- α -Kopaen, %4.0 olarak kaydedilmiştir.

Bunların yanı sıra 2005 yılında Avusturya'dan sağlanan bitkinin ağırlıkça %63.3 oranında linalil asetat, %17.9 oranında linalol ve %5.9 oranında ise sclareol içerdiği kaydedilmiştir (Schmiderer vd., 2008).

Bu çalışmanın amacı, Akçadağ-Malatya bölgesinde doğal olarak yetişen *Salvia sclarea* bitki türünün kimyasal içeriğinin yukarıdaki literatür verileri ile belirlenen yöresel farklılıklara bağlı olarak değişen kimyasal yapılarının kıyaslanmasıdır. Daha önce bahsi geçen bölgede bu tür bir araştırma yapılmadığından bu çalışmayla literatüre yeni veriler kazandırılmıştır.

MATERYAL METOT

Bitki kaynağı ve analiz için hazırlanması

Salvia sclarea bitki örneği, Malatya Akçadağ bölgesinde Yukarıörükçü Mahallesinde toplandı (Figür 1). Bitkiler güneş ışığı ve nem olmayan bir ortamda kurutuldu. Çiçekli bitkinin toprak üstü kısımlarının uçucu yağına ait kimyasal bileşenler belirlenmek üzere hazırlandı.

100 g kurutulmuş bitkiden 0,3 mL uçucu yağ, Clevenger tipi cam düzenek kullanılarak 4 saat boyunca hidrodistilasyon yöntemiyle elde edildi. Uçucu yağ, sodyum sülfat üzerinde kurutuldu ve +3 °C' den düşük sıcaklıkta buzdolabında analiz edilinceye kadar saklandı (Figür 2).



Figür 1. Haziran ayında çiçeklenen *Salvia sclarea* bitkisi (Yukarıörükçü M., Akçadağ, Malatya, Türkiye-2025)

GC-MS (Gaz Kromatografisi-Kütle Spektroskopisi)

Esansiyel yağın kimyasal bileşim analizi, Agilent Technologies 6890N Ağ GC Sistemi ve 5973 İnert Kütle Seçici Dedektör cihazı ile 19091N-136 HP-INNOWAX (60mx0,25x0,25) kolon kullanılarak gerçekleştirildi. Esansiyel yağ analizi sırasında cihaz parametreleri; taşıyıcı gaz: helyum, kolon akış hızı: 0,9 ml/dak, basınç: 41,8 kPa, enjeksiyon sıcaklığı: 250 °C ve iyon kaynağı sıcaklığı: 200 °C'dir. Kolon sıcaklığı başlangıçta 2 dakika boyunca 40 °C'ye ayarlanmış, ardından 4°C/dak hızla 260 °C'ye çıkarılmış ve bu koşullar altında 5 dakika bekletilmiştir.




Figür 2. Clevenger aparatı ile hidrodistilasyon ve uçucu yağ eldesi

SONUÇLAR TARTIŞMA

Hekzan kullanılarak yapılan GC-MS analizi sonucunda (Figür 3), uçucu yağın 15 farklı bileşikten oluştuğu tespit edildi. Bu bileşikler Tablo 1'de gösterilmiştir. Bileşenler, kütle spektrometresinde Wiley ve Nist GC/MS Kütüphanesi (W10N14) ile karşılaştırılarak tanımlanmıştır. Bitki Haziran ayında çiçeklenme dönemi başladığında toplanmıştır.

Tablo 1 de görüldüğü üzere uçucu yağ bileşenlerinden GC-MS analizi sonucunda toplamda 15 bileşen belirlenmiştir. Bu bileşenlerin çoğu monoterpen, monoterpenoid ve seskiterpenlerden oluşmaktadır.

Bileşimdeki ana bileşenler (Figür 4) yüzde oranlarına göre bir monoterpenoid olan linalil bütirat (% 54.74), linalol (% 15.08), karyofilen (% 7.08), α -terpineol (% 4.20), metil öjenol (% 2.36), geraniol (% 2.26) ve karyofilen osit (% 1.85) olarak gözlemlenmiştir. En yüksek orana sahip olan bileşen linalil bütanoat kolondaki alıkonma zamanı 23.837 dakika olarak gözlemlenmiştir.



Figür 3. *Salvia sclarea* bitkisinin esansiyel yağına ait GC-MS kromatogramı




Figure 4. *Salvia sclarea* bitkisine ait uçucu yağın kimyasal bileşenleri ve açık formülleri

Tablo 1. *Salvia sclarea* bitkisinin kimyasal bileşenleri ve oranları

Sıra	RT(dk)	% Alan	Kalite	Kapalı Formül	Bileşen adı
1	11.072	0.10	93	C ₁₀ H ₁₆	β-Pinen
2	15.300	0.31	87	C ₁₀ H ₁₆	δ-3-Karen
3	16.645	1.44	86	C ₁₀ H ₂₀ O ₂	İzoamil izovalerat
4	23.042	15.08	97	C ₁₀ H ₁₈ O	Linalol
5	23.837	54.74	90	C ₁₄ H ₂₄ O ₂	Linalil bütirat
6	26.778	7.08	99	C ₁₅ H ₂₄	Karyofilen
7	27.253	4.20	87	C ₁₀ H ₁₈ O	α-Terpeneol
8	28.140	1.32	85	C ₁₅ H ₂₄	β-Farnesen
9	28.781	1.41	87	C ₁₂ H ₂₀ O ₂	Geranil asetat
10	29.342	1.75	93	C ₁₅ H ₂₄	Germakren D
11	29.782	1.78	93	C ₁₅ H ₂₄	γ-Element
12	30.194	2.26	92	C ₁₀ H ₁₈ O	Geraniol
13	36.811	2.36	98	C ₁₁ H ₁₄ O ₂	Metil öjenol
14	37.507	1.85	93	C ₁₅ H ₂₄ O	Karyofilen oksit
15	43.893	1.29	86	C ₁₅ H ₂₄ O	Spatulenol
Toplam =		96.97			

SONUÇ

Bu çalışmada Malatya'nın Akçadağ ilçesine bağlı Yukarıörükçü mahallesinde doğal olarak yetişen ve hoş kokulu bir adaçayı türü olan *Salvia sclarea* bitkisine ait esansiyel yağın Clevenger aparatı ile eldesi gerçekleştirilerek GC-MS analizi ile kimyasal bileşenlerinin tayini yapıldı. Daha önce bilindiği kadarıyla literatürde bu bölgeye ait bitki için bu tür bir çalışma kaydedilmemiştir. Bu nedenle bölgede doğal yayılım gösteren bitkinin kimyasal içeriği belirlenerek sonuçlar literatür verileri ile kıyaslandı. Buna göre birçok araştırma grubunun yaptığı çalışmada ana bileşenler linalol ve linalil asetat olarak rapor edilmiştir. Bu çalışmadaki sonuçlar benzer olmasına rağmen linalil asetat yerine yüksek oranda (%54.74) linalil bütirat gözlemlenmiştir.

REFERANSLAR

- Acimović, M.G., Cvetković, M.T., Stanković Jeremić, J.M., Pezo, L.L., Varga, A.O., Cabarkapa, I.S., Kiprovski, B. (2022) Biological activity and profiling of *Salvia sclarea* essential oil obtained by steam and hydrodistillation extraction methods via chemometrics tools. *Flavour Fragr J.*, 37, 20- 32.
- Ben Akacha, B., Ben Hsouna, A., Generali'c Mekini'c, I., Ben Belgacem, A., Ben Saad, R., Mnif, W., Kačániová, M., Garzoli, S. (2023) *Salvia officinalis* L. and *Salvia sclarea* Essential Oils: Chemical Composition, Biological

Activities and Preservative Effects against *Listeria monocytogenes* Inoculated into Minced Beef Meat. *Plants*, 12, 3385, 1-24.

Cui, H., Zhang, X., Zhou, H., Zhao, C., Lin, L. (2015) Antimicrobial activity and mechanisms of *Salvia sclarea* essential oil. *Botanical Studies*, 56, 16, 1-8.

Dogan, G., Hayta, S., Yuce, E., Bagcı, E. (2015) Composition of the essential oil of two *Salvia* taxa (*Salvia sclarea* and *Salvia verticillata* subsp. *verticillata*) from Turkey. *Natural Science and Discovery*, 1(3), 62-67.

Durling, N.E., Catchpole, O.J., Grey, J.B., Webby, R.F. (2007) Extraction of phenolics and essential oil from dried sage (*Salvia officinalis*) using ethanol-water mixtures. *Food Chemistry* 101, 1417-1424.

Gul, V., Huseynova, A., Maharramov, S. (2020) Anthelmintic effect of essential oil and extract produced from *Salvia Sclarea* L., (Lamiacea) on nematodes living in gastrointestinal system of sheep. *Annals of Medical Research*, 27(1), 252-8.

Gülçin, İ., Uğuz, M.T., Oktay, M., Beydemir, Ş., Küfrevioğlu, Ö.İ. (2004) Evaluation of the Antioxidant and Antimicrobial Activities of Clary Sage (*Salvia sclarea* L.). *Turkish Journal of Agriculture and Forestry*, 28(1), 25-33.

Kačániová, M., Vukovic, N.L., Ľ Cmíková, N., Galovičová, L., Schwarzová, M., Šimora, V., Kowalczewski, P.Ł., Kluz, M.I., Puchalski, C., Bakay, L., Vukic, M.D. (2023) *Salvia sclarea* Essential Oil Chemical Composition and Biological Activities. *Int. J. Mol. Sci.*, 24, 5179, 1-22.

Kong, B.H., Zhang, H.Y., Xiong, Y.L. (2010) Antioxidant activity of spice extracts in a liposome system and in cooked pork patties and the possible mode of action. *Meat. Sci.*, 85, 772-778.

Koutsaviti, A., Tzini, D.I., Tzakou, O. (2016) Greek *Salvia sclarea* L. Essential Oils: Effect of Hydrodistillation Time, Comparison of the Aroma Chemicals Using Hydrodistillation and HS-SPME Techniques. *Rec. Nat. Prod.*, 10(6), 800-805.

Nakipoğlu, M. (1993) Bazı Adaçayı (*Salvia* L.) türleri ve bu türlerin ekonomik önemi. Dokuz Eylül Üniversitesi Yayınları, Eğitim Fakültesi, Eğitim Bilimleri Dergisi, 6, 45-58.

Özdemir, C., Şenel, G. (1999) The Morphological, Anatomical and Karyological Properties of *Salvia sclarea* L. *Turkish Journal of Botany*, 23, 7-18.

Russo, A., Formisano, C., Rigano, D. (2013) Chemical composition and anticancer activity of essential oils of Mediterranean sage (*Salvia officinalis* L.) grown in different environmental conditions. *Food Chem. Toxicol.*, 55, 42-47.

- Schmiderer, C., Grassi, P., Novak, J., Weber, M., Franz, C. (2008) Diversity of essential oil glands of clary sage (*Salvia sclarea* L., Lamiaceae). *Plant Biology*, 10, 433-440.
- Sharopov, F.S., Setzer, W.N. (2012) The Essential Oil of *Salvia sclarea* L. from Tajikistan. *Rec. Nat. Prod.*, 6(1), 75-79.
- Yuce, E., Yildirim, N., Yildirim, N.C., Paksoy, M.Y., Bagcı, E. (2014) Essential Oil Composition, Antioxidant and Antifungal Activities of *Salvia sclarea* L. from Munzur Valley in Tunceli, Turkey. *Cell. Mol. Biol.*, 60(2), 1-5.
- Yücel, Y.Y., Özdemir Nath, E. (2023) Determination of Antioxidant Activity of *Salvia sclarea* L. and Its Inhibitory Effects on Acetylcholinesterase and Monoamine Oxidase A. *FABAD J. Pharm. Sci.*, 48, 255-264.

Nonlinear Diferansiyel Denklemlerin Yaklaşık Çözümü İçin En Küçük Kareler Metodu

Öğr.Gör. Dr. Birkan DURAK¹

Öğr.Gör. Dr. İbrahim Tamer EMECAN²

¹ İstanbul Üniversitesi-Cerrahpaşa, Teknik Bilimler Meslek Yüksek Okulu, Uçak Teknolojisi Programı, birkand@iuc.edu.tr, ORCID No: 0000-0002-8196-5407

² İstanbul Üniversitesi-Cerrahpaşa, Teknik Bilimler Meslek Yüksek Okulu, Sualtı Teknolojisi Programı, emecan@iuc.edu.tr, ORCID No: 0000-0002-4312-7947

ÖZET

Mühendislik ve fizikteki birçok karmaşık problem, sıklıkla lineer ya da lineer olmayan diferansiyel denklemlerle modellenir. Örneğin, optik fiberlerde ışık darbelerinin yayılımı dördüncü mertebeden doğrusal olmayan bir denklemle ifade edilirken, akışkanlar mekaniğinde yarı sonsuz bir plaka üzerindeki laminer akışın davranışı üçüncü mertebeden bir nonlinear denklemle tanımlanır. Benzer şekilde, ısı iletimi, difüzyon, finansal modelleme ve nükleer süreçlerde de nonlinear diferansiyel denklemlerle modellemeler yapılır. Lineer denklemler, süperpozisyon ilkesi işe yaradığı için daha kolay çözülebilirken, lineer olmayan denklemler çoğu zaman analitik olarak çözülemez. Bu nedenle, bu tür problemlerde sayısal yöntemlerden yararlanılmak zorunda kalınır. Özellikle iterasyon tabanlı teknikler, yaklaşık çözümler elde etmede sıkça kullanılır.

Bu çalışmada incelenen ilk problem, bir başlangıç değer problemidir. En küçük kareler yöntemiyle elde edilen yaklaşık çözüm, analitik çözümle yüksek düzeyde uyum göstermektedir. İkinci ve üçüncü test problemlerinde, polinom derecesinin artırılmasıyla birlikte nokta bazında hata oranlarının azaldığı gözlemlenmiştir. Son test probleminde ele alınan doğrusal olmayan sınır değer denklemi için de benzer biçimde oldukça düşük hata oranları elde edilmiştir. Yöntemde polinomların kullanımı, hem hesaplama süresi hem de çözüm hassasiyeti açısından optimum sonuçlar vermektedir. Elde edilen sonuçlar, en küçük kareler yönteminin doğrusal olmayan diferansiyel denklemlerin yaklaşık çözümünü bulmakta etkili, kararlı ve güvenilir bir teknik olduğunu göstermektedir. Genel olarak, önerilen bu yöntem; basit yapısının yanı sıra, hesaplama kolaylığı ve yüksek doğruluk potansiyeliyle, analitik çözümü zor veya mümkün olmayan problemlerin yaklaşık çözümünü bulmakta kullanılabilecek güçlü bir sayısal araç olarak değerlendirilebilir.

Anahtar Kelimeler – Nonlinear Denklem, Diferansiyel denklem, En Küçük Kareler, Yaklaşık Çözüm, Sayısal Analiz

GİRİŞ

Mühendislik ve fizikteki birçok problem lineer olan veya olmayan diferansiyel denklemlerle modellenir. Örneğin optik fiberlerde ışık darbelerinin yayılımı modellenirken dördüncü mertebeden doğrusal olmayan bir kısmi diferansiyel denklem kullanılır (Yanardağ, 2025). Akışkanlar mekaniğinde, sabit bir tek yönlü akışa paralel tutulan yarı sonsuz bir plaka üzerinde oluşan sabit iki boyutlu laminer sınır tabakasını tanımlayan Blasius denklemi üçüncü mertebeden bir nonlinear diferansiyel denklemdir (Parveen,

2016). Ayrıca ısı iletimi ve transferi, difüzyon, finansal matematik ve nükleer fizik gibi problemlerin birçok makalede nonlinear diferansiyel denklemlerle modellendiği görülmektedir (Biçer ve Dağ, 2019). Diferansiyel denklemlerin, lineer ve lineer olmayan denklem şeklinde olarak iki ana gruba ayrılarak incelenmesi genel kabul gören bir yöntemdir. Lineer diferansiyel denklemlerin çözüm yöntemleri daha basit bir yapıya sahiptir ve genellikle bunlara süperpozisyon ilkesi uygulanabilir. Ancak aynı avantajlar Nonlinear diferansiyel denklemlerde mevcut değildir. Bu yüzden nonlinear denklemler çözülürken bazı sayısal tekniklere ihtiyaç vardır. Mesala, iterasyon bu türden denklemlerin çözümleri için yaklaşık sonuçlar elde etme amacıyla kullanılan yöntemlerden birisidir (Gülecan, 2019).

Bu çalışmada öncelikle en küçük kareler yöntemi tanıtılmış ve ardından literatürden seçilmiş olan bazı problemlerin yaklaşık çözümleri bu yöntemle bulunmuştur.

1- En Küçük Kareler (Least Square) Metodu

Nonlinear bir sınır değer problemi p terimi x' 'e bağlı en yüksek türevin derecesini göstermek üzere

$$\begin{aligned} y^{(p)} + y^k + f(x, y, y', \dots, y^{(p-1)}) &= 0 \\ y(x_1) &= a \\ y(x_2) &= b \end{aligned} \quad (1)$$

ile gösterilebilir. Burada k bağımlı değişken y' 'nin kuvvetini göstermektedir. Bu probleme önerilen yaklaşık çözüm N polinomun derecesi olmak üzere

$$y_{\text{yaklaşık}} = \sum_{n=0}^N C_n x^n \quad (2)$$

şeklinde kabul edilsin. Bu çözümdeki C_N katsayılarını bulmak için öncelikle kalan

$$R(x) = y_{\text{yaklaşık}}^{(p)} + y_{\text{yaklaşık}}^k + h(x) \quad (3)$$

formülü ile kurulur. Ardından, bu kalan W_n ağırlık fonksiyonları olan ve

$$W_n = \frac{\partial R}{\partial C_n}, \quad n = 1, 2, 3, \dots, N \quad (4)$$

denklem (4) ile verilen fonksiyonlarla çarpılarak denklem (1)'in sınırlarında integre edilerek bir denklem sistemi kurulur. Bu denklem sistemi

$$\int_{x_1}^{x_2} RW_n dx = 0 \quad (5)$$

şeklinde dir. Denklem (5) ile verilen bu sistemin çözümü denklem (2) deki $C_0, C_1, C_2, \dots, C_N$ katsayılarını verecektir. Bu katsayıların bulunması ve yerine yazılmasıyla denklem (1) ile verilmiş olan probleme en küçük kareler yöntemiyle yaklaşık bir çözüm bulunmuş olur.

2- En Küçük Kareler Metodunun Diferansiyel Denklemlere Uygulanması

En küçük Kareler Yöntemini ilk olarak verilen probleme uygulayalım (Hermann ve Saravi, 2016)

$$\begin{aligned} y'(x) + y^2 &= 0 \\ y(0) &= 1 \end{aligned} \quad (6)$$

Problemin çözümü $y(x) = \frac{1}{(1+x)}$ dir. Yaklaşık çözümün

$$y = \sum_{n=0}^5 C_n x^n \quad (7)$$

şeklinde olduğu kabul edilsin. Denklem (6) daki başlangıç değ er şartı dikkate alınırsa (7) deki yaklaşık çözüm

$$y = 1 + \sum_{n=1}^5 C_n x^n \quad (8)$$

olacaktır. Bu çözümdeki bilinmeyen C_1, C_2, C_3, C_4 ve C_5 katsayılarının bulunması için kurulması gereken dört tane denklem gerekmektedir. Öncelikle kalan

$$R(x) = C_1 + 2xC_2 + 3x^2C_3 + 4x^3C_4 + 5x^4C_5 + \left(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5\right)^2 \quad (9)$$

şeklinde yazılır. Yöntemde kullanılacak ağırlık fonksiyonları ise

$$W_i = \frac{\partial R}{\partial C_i}, \quad i = 1, 2, 3, 4, 5 \quad (10)$$

formülünden sırasıyla

$$\begin{aligned}
W_1 &= 1 + 2x(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5) \\
W_2 &= 2x + 2x^2(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5) \\
W_3 &= 3x^2 + 2x^3(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5) \\
W_4 &= 4x^3 + 2x^4(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5) \\
W_5 &= 5x^4 + 2x^5(1 + xC_1 + x^2C_2 + x^3C_3 + x^4C_4 + x^5C_5)
\end{aligned} \tag{11}$$

olarak yazılabilir. Bu fonksiyonlardan yararlanılarak kapalı formu

$$\int_0^1 R.W_i dx = 0, \quad i = 1, 2, 3, 4, 5 \tag{12}$$

olan beş bilinmeyenli beş adet denklemden oluşan sistem bulunur. Bu denklem sisteminin çözümü yaklaşık çözümün C_1, C_2, C_3, C_4, C_5 katsayılarını

$$\begin{aligned}
C_1 &= -0.997697, C_3 = -0.788627, C_5 = -0.109759 \\
C_2 &= 0.961721, C_4 = 0.434364
\end{aligned} \tag{13}$$


olarak verir. Bu katsayılar (8) denkleminde yerine yazılırsa (7) ile verilen başlangıç değer probleminin beşinci dereceden bir polinom kullanılarak bulunan yaklaşık çözümü

$$\begin{aligned}
y_5(x) &= -0.109759x^5 + 0.434364x^4 - 0.788627x^3 + 0.961721x^2 \\
&\quad - 0.997697x + 1
\end{aligned} \tag{14}$$

gibi olacaktır. Denklem (15) ile altıncı ve yedinci dereceden polinomlar kullanılarak elde edilen yaklaşık çözümler verilmiştir.

$$\begin{aligned}
y_6(x) &= 0.07x^6 - 0.33x^5 + 0.68x^4 - 0.91x^3 + 0.98x^2 - 0.99x + 1 \\
y_7(x) &= -0.05x^7 + 0.25x^6 - 0.58x^5 + 0.84x^4 - 0.96x^3 + 0.99x^2 - 0.99x + 1
\end{aligned} \tag{15}$$

Şekil 1 de Analitik ve yaklaşık çözümler karşılaştırılmıştır.



Şekil 1: Birinci başlangıç değer problemi için kesin ve yaklaşık çözümler

N en küçük kareler yönteminde kullanılan yaklaşık polinomun en yüksek derecesi olmak üzere, Tablo 1 de yaklaşık çözümde yapılan mutlak hatalar farklı x değerleri için gösterilmiştir.

Tablo 1: Birinci başlangıç değer problemi için yaklaşık çözüm için yapılan mutlak hatalar

x	Mutlak Hatalar		
	N=5	N=6	N=7
0.0	0.000000	0.000000	0.000000
0.1	1.02x10 ⁻⁵	3.57x10 ⁻⁶	1.26x10 ⁻⁶
0.2	5.32x10 ⁻⁵	6.99x10 ⁻⁶	1.11x10 ⁻⁷
0.3	2.66x10 ⁻⁵	5.83x10 ⁻⁶	1.57x10 ⁻⁶
0.4	3.40x10 ⁻⁵	8.57x10 ⁻⁶	3.91x10 ⁻⁷
0.5	5.38x10 ⁻⁵	1.60x10 ⁻⁶	1.55x10 ⁻⁶
0.6	1.57x10 ⁻⁵	8.87x10 ⁻⁶	1.43x10 ⁻⁷
0.7	3.65x10 ⁻⁵	2.79x10 ⁻⁶	1.42x10 ⁻⁶
0.8	4.07x10 ⁻⁵	6.93x10 ⁻⁶	2.64x10 ⁻⁷
0.9	1.42x10 ⁻⁵	1.53x10 ⁻⁶	8.45x10 ⁻⁷
1.0	9.99x10 ⁻⁷	3.53x10 ⁻⁹	1.52x10 ⁻¹⁰

En küçük kareler yöntemini aşağıdaki yüksek mertebeden başlangıç değer problemine uygulayalım (Hosseini, vd., 2015).

$$y''(x) + \frac{2}{x} y'(x) + y^5$$

$$y(0) = 1 \quad y'(0) = 0 \quad (16)$$

Bu problem için Analitik çözüm

$$y_{analitik} = \frac{1}{\sqrt{1 + \frac{x^2}{3}}} \quad (17)$$

olmaktadır. Bu problemin yaklaşık çözümü (16) denklemindeki şartlar göz önüne alınarak

$$y(x) = 1 + \sum_{n=2}^3 C_n x^n \quad (18)$$

şekilde kabul edilirse ve denkleme yazılırsa kalan

$$2C_2 + 6xC_3 + \frac{2(2xC_2 + 3x^2C_3)}{x} + (1 + x^2C_2 + x^3C_3)^5 \quad (19)$$

olarak bulunur. Bu durumda katsayıları verecek olan denklem sistemi aşağıdaki gibidir.

$$\begin{aligned} & 7.666666666666667 + 0.23809523809523808C_2^9 + C_2^8(2.3684210526315788 + \\ & 2.0454545454545454C_3) + C_2^7(10.588235294117647 + C_3(18. + 7.826086956521739C_3)) + \\ & C_2^6(28. + C_3(70. + C_3(60. + 17.5C_3))) + C_2^5(51.73426573426573 + C_3(157.5 + \\ & C_3(198.94736842105263 + C_3(114.54545454545455 + 25.2C_3)))) + C_2^4(73.93939393939394 + \\ & C_3(242.5 + C_3(370.5882352941176 + C_3(315. + C_3(136.95652173913044 + \\ & 24.23076923076923C_3))))) + C_2^3(80.95238095238095 + C_3(282. + C_3(456.9230769230769 + \\ & C_3(466.66666666666667 + C_3(300. + C_3(105. + 15.555555555555555C_3))))) + \\ & C_2^2(61.714285714285715 + C_3(238.5 + C_3(405.31468531468533 + C_3(432.32142857142856 + \\ & C_3(331.57894736842104 + C_3(171.8181818181818 + C_3(50.4 + \\ & 6.428571428571429C_3))))) + C_3(66. + C_3(62.857142857142854 + C_3(77. + \\ & C_3(62.76923076923077 + C_3(39.125 + C_3(20. + C_3(7.5 + (1.6666666666666667 + \\ & 0.16666666666666666C_3)C_3))))) + C_2(65. + C_3(125. + C_3(234.54545454545453 + C_3(260. + \\ & C_3(205.2941176470588 + C_3(126. + C_3(54.78260869565217 + C_3(13.846153846153847 + \\ & 1.5517241379310345C_3))))) + \end{aligned} \quad (20)$$

$$\begin{aligned} & 7.25 + 0.22727272727272727C_2^9 + C_2^8(2.25 + 1.9565217391304348C_3) + C_2^7(10. + \\ & C_3(17.142857142857142 + 7.5C_3)) + C_2^6(26.25 + C_3(66.3157894736842 + \\ & C_3(57.27272727272727 + 16.8C_3))) + C_2^5(48.5 + C_3(148.23529411764707 + C_3(189. + \\ & C_3(109.56521739130434 + 24.23076923076923C_3)))) + C_2^4(70.5 + C_3(228.46153846153845 + \\ & C_3(350. + C_3(300. + C_3(131.25 + 23.333333333333332C_3)))) + C_2^3(79.5 + \\ & C_3(270.2097902097902 + C_3(432.32142857142856 + C_3(442.10526315789474 + \\ & C_3(286.3636363636364 + C_3(100.8 + 15.C_3))))) + C_2^2(62.5 + C_3(234.54545454545453 + \\ & C_3(390. + C_3(410.5882352941176 + C_3(315. + C_3(164.34782608695653 + \\ & C_3(48.46153846153846 + 6.206896551724138C_3))))) + C_3(78.42857142857143 + C_3(63. + \\ & C_3(75.94405594405595 + C_3(60.80357142857143 + C_3(37.39318885448916 + \\ & C_3(19.09090909090909 + C_3(7.2 + (1.6071428571428572 + \\ & 0.16129032258064516C_3)C_3))))) + C_2(66. + C_3(125.71428571428571 + C_3(231. + \\ & C_3(251.07692307692307 + C_3(195.625 + C_3(120. + C_3(52.5 + C_3(13.333333333333334 + \\ & 1.5C_3))))) + \end{aligned} \quad (21)$$


Bu sistemin çözümüyle $C_2 = -0.1786930365031$ ve $C_3 = 0.04612668250397$ olarak bulunacaktır. Böylece denklem (18) ile verilmiş olan yaklaşık çözüm

$$y_3(x) = 0.04612668250397826x^3 - 0.1786930365031367x^2 + 1 \quad (22)$$

Eğer yaklaşık çözüm dördüncü dereceden bir polinom olarak önerilseydi.

$$y_4(x) = 0.015094321220504187x^4 + 0.021208561905267733x^3 - 0.1703483667628002x^2 + 1 \quad (23)$$

olan bir çözüm bulunacaktı. Şekil 2’de ikinci problem için bulunan bu iki yaklaşık çözümde nokta bazında yapılan mutlak hatalar grafik olarak gösterilmiştir.



Şekil 2: İkinci başlangıç değer problemindeki mutlak hatalar

Üçüncü bir problem olarak nonlinear ve değişken katsayılı homojen bir denklemi göz önüne alalım (Lu vd., 2020).

$$y''(x) - \frac{y^3 - 2y^2}{2x^2} = 0 \quad (24)$$

$$y(1) = 1 \quad , \quad y(2) = \frac{4}{3}$$

İncelenen bu problemin yaklaşık çözümü aşağıdaki formda olsun

$$y(x) = \sum_{n=0}^4 C_n x^n \quad (25)$$

Denklem (24) verilmiş olan iki sınır şartı bu çözüme uygulanırsa

$$y(x) = \left(\frac{2}{3} + 2C_2 + 6C_3 + 14C_4 \right) + \left(\frac{1}{3} - 3C_2 - 7C_3 - 15C_4 \right) x + \sum_{n=2}^4 C_n x^n \quad (26)$$

çözüm haline gelir. İlk parantezin içindeki terimler C_0 katsayısını gösteriyorken ikinci parantez içerisindekiler ise C_1 katsayısını ifade etmektedir. Buna göre önce kalan ve bu kalan kullanılarak ardından ağırlık fonksiyonları

$$W_i = \frac{\partial R}{\partial C_i}, \quad i = 2, 3, 4 \quad (27)$$


formülüyle hesaplanır. Ayrıca C_2, C_3 ve C_4 katsayılarını verecek olan denklem sistemi ise

$$\int_1^2 (R W_i) dx \quad (28)$$

ile oluşturulur. Bu sistemin çözümü ile bulunan bu katsayılar (25) denkleminde yerine yazılarak aranan yaklaşık çözüm


$$y_4(x) = -0.021916x^4 + 0.185770x^3 - 0.667932x^2 + 1.365491x + 0.138587 \quad (29)$$

olarak elde edilir. Şekil 3 de üçüncü problem için analitik ve yaklaşık çözümler grafik olarak verilmiştir.



Şekil 3: Üçüncü problem için analitik ve yaklaşık çözümler

Şekil 4 de ise mutlak hatalar farklı x 'lere karşılık hesaplama sırasında yapılan mutlak hatalar görülmektedir.



Şekil 4: Üçüncü problem için mutlak hatalar

Son olarak yöntemi aşağıda verilen diferansiyel denkleme uygulayalım (Yarcı, 2008).

$$y''(x) - \frac{1}{2}y^3(x) = 0$$

$$y(1) = \frac{2}{3}, \quad y(3) = \frac{2}{5} \quad (30)$$

Verilen problemin analitik çözümü $\frac{2}{2+x}$ dir. Yaklaşık çözüm olarak aşağıdaki dördüncü dereceden polinom önerilmiş olsun.

$$y(x) = \sum_{n=0}^4 C_n x^n \quad (31)$$

Sınır şartlarına göre bu çözüm

$$y(x) = \left(\frac{4}{5} + 3C_2 + 12C_3 + 39C_4 \right) + \left(-\frac{2}{15} - 4C_2 - 13C_3 - 40C_4 \right) x + \sum_{n=2}^4 C_n x^n \quad (32)$$

ile verilen formda olmalıdır. Diğer örneklerdeki işlem adımları uygulanarak yaklaşık çözüm

$$y_4(x) = 0.002243x^4 - 0.026820x^3 + 0.138133x^2 - 0.426941x + 0.980051 \quad (33)$$

Tablo 2 problemin analitik çözüm ve bu yaklaşık çözümün çeşitli x 'lere karşılık gelen değerleri ve hesaplama sırasında yapılan nokta bazındaki hatalar verilmiştir.

Tablo 2: Son problem için farklı x 'ler için analitik ve yaklaşık çözümler, mutlak hatlar

x	$y_{Analitik}$	$y_{yaklaşık}$	Mutlak Hata
1.0	0.666667	0.666667	1.11×10^{-16}
1.2	0.625000	0.624940	5.96×10^{-5}
1.4	0.588235	0.588098	1.36×10^{-4}
1.6	0.555556	0.555413	1.42×10^{-4}
1.8	0.526316	0.526243	7.21×10^{-5}
2.0	0.500000	0.500034	3.45×10^{-5}
2.2	0.47619	0.476317	1.26×10^{-4}
2.4	0.454545	0.454708	1.63×10^{-4}
2.6	0.434783	0.434912	1.29×10^{-4}
2.8	0.416667	0.416717	5.06×10^{-5}
3.0	0.400000	0.400000	2.22×10^{-16}

SONUÇ

İncelenen ilk problem bir başlangıç değer problemidir. Bu probleme en küçük kareler yöntemiyle bulunan yaklaşık çözüm, Şekil 1’de görüldüğü gibi analitik çözümle uyumludur. İkinci test probleminin mevcut yöntemle üçüncü ve dördüncü dereceden yaklaşık çözümlerinde yapılan hatalar Şekil 2’ de verilmiştir ve buna göre polinom derecesi arttıkça mutlak hata azalmaktadır. Bir sınır değer problemi olan üçüncü test probleminde yaklaşık çözüm için dördüncü dereceden bir polinomun önerilmesi yeterli olmuştur. Şekil 3 bu çözümle, analitik çözümün uyumluluğunu göstermektedir. Şekil 4’ e göre bu problem için hesaplamada yapılan mutlak hatalar kabul edilebilecek kadar küçük olmaktadır. Son test problemi ise nonlinear bir sınır değer problemidir. Bir önceki problemde olduğu gibi burada da dördüncü dereceden bir yaklaşık çözüm oldukça küçük hesaplama hatalarına sahiptir.

Bu çalışmada önerilen en küçük kareler yöntemiyle nonlinear diferansiyel denklemlere uygun yaklaşık çözümler bulunmuştur. Polinom şeklinde yaklaşık çözümün önerilmesi hem işlem hem de programlama kolaylığı sağlamaktadır. Yöntem basit ve etkili bir yaklaşık çözüm bulmaya imkan verir.

REFERANSLAR

- Biçer K. E., and Dağ H. G. (2023). Numerical solutions of differential equations having cubic nonlinearity using Boole collocation method. *Turkish Journal of Mathematics*, 47(2), 732–745. <https://doi.org/10.55730/1300-0098.3391>
- Gülecan, T. (2019). Lineer olmayan diferansiyel denklemlerin çözümüne farklı bir yaklaşım (Yüksek Lisans Tezi). Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Hermann, M. and Saravi, H. (2016). Nonlinear ordinary differential equations : Analytical Approximation and Numerical Methods (1 st). Springer India.
- Hosseini, S.Gh. and Abbasbandy, S. (2015). Solution of lane-emden type equations by combination of the spectral method and adomian decomposition method. *Mathematical Problems in Engineering, Volume 2015*, Article ID 534754 <https://doi.org/10.1155/2015/534754>
- Lu, Y., Yin, Q., Li, H., Sun, H., Yang, Y., and Hou, M. (2020). Solving higher order nonlinear ordinary differential equations with least squares support vector machines. *Journal of Industrial and Management Optimization*, 16(3), 1481–1502. <https://doi.org/10.3934/jimo.2019012>
- Summiya Parveen, S. (2016). Numerical Solution of Non Linear Differential Equation by Using Shooting Techniques. *International Journal of Mathematics And Its Applications*, 4(1 - A), 93–100.
- Yanardağ, Y. (2025). Bazı lineer olmayan kısmi diferansiyel denklemler ve tam çözüm yöntemleri (Yüksek Lisans Tezi). Bilecik Şeyh Edebali Üniversitesi, Lisansüstü Eğitim Enstitüsü, Bilecik.
- Yarç, H. (2008). On the Solutions of Non-Linear Boundary Value Problems (Yüksek Lisans tezi). Dokuz Eylül University Graduate School Of Natural And Applied Sciences, İzmir.

Görülmesi Gereken Doğa Harikası Egzotik ve Görkemli Ağaçlar

Serkan ÖZER¹

Oğuzhan DİKMEN²

- 1- Prof. Dr.; Atatürk Üniversitesi Mimarlık ve Tasarım Fakültesi Peyzaj Mimarlığı Bölümü.
sozer@atauni.edu.tr ORCID No: 0000-0002-1220-206X
- 2- Arş. Gör.; Atatürk Üniversitesi Mimarlık ve Tasarım Fakültesi Peyzaj Mimarlığı Bölümü.
oguzhandikmen@hotmail.com ORCID No: 0000-0002-3426-9089

1. GİRİŞ

Ağaçlar, yeryüzünün en eski ve en önemli canlı organizmalarından biri olarak ekosistemlerin işleyişinde merkezi bir konuma sahiptir. Günümüzde yaklaşık 3.04 trilyon ağacın bulunduğu hesaplanmakta ve bu değer kişi başına ortalama 400 ağaca karşılık gelmektedir (Crowther et al., 2015). Ağaçlar; karbon tutma kapasitesi, toprak stabilizasyonu, biyokütle yoğunluğu ve orman yapısındaki işlevsel bağlantılar yoluyla, aynı zamanda atmosferdeki kirleticileri filtreleyerek hava kalitesini artırır, su döngüsünü destekler ve mikroiklimin dengelenmesine katkı sağlar; doğanın sürekliliğinin korunmasında temel yapı taşlarıdır (Kempes et al., 2011; Pan et al., 2011; Demircioğlu Yıldız, 2024).

Günümüzde yaşanan biyoçeşitlilik krizi, habitat tahribatı, iklim değişikliği, tür kayıpları ve ekosistem bozulmalarının birleşik etkileriyle küresel ölçekte canlı çeşitliliğinde ciddi azalışlara yol açmaktadır. Biyoçeşitlilik ve Ekosistem Hizmetlerine İlişkin Küresel Değerlendirme Raporu'na göre, kara ve deniz ekosistemlerinin büyük kısmı insanlar tarafından önemli ölçüde dönüştürülmüş; memeli, kuş, amfibi ve bitki türlerinin çok önemli bir bölümü yok olma tehlikesiyle karşı karşıya kalmıştır (Ceballos et al., 2017; IPBES, 2019; WWF, 2022).

Ağaçların önemi yalnızca ekolojik katkılarla sınırlı değildir; pek çok tür, estetik görünümleri, sembolik anlamları ve sosyal yaşamda taşıdıkları rollerle kültürel peyzajların ayrılmaz bir parçasını oluşturmaktadır. Büyük ve eski ağaçların, tarih boyunca ritüel pratiklerde, dini inançlarda ve toplumsal hafızada özel bir konuma sahip oldukları bilinmektedir (Watson et al., 2018; Bhagwat & Rutte, 2006). Bu nedenle, ağaçlar ekolojik işlevlerinin yanı sıra estetik ve kültürel değerleriyle de “yaşayan anıtlar” olarak tanımlanmakta ve korunmaları yalnızca doğal değil aynı zamanda kültürel miras bağlamında da önem kazanmaktadır (Borrajo Millán et al., 2025; Budău et al., 2025).

2. EGZOTİK VE GÖRKEMLİ AĞAÇLAR

Egzotik ve görkemli ağaçlar dünyada az sayıda ve nadir yerlerde yaşayan genellikle insanların büyük çoğunluğunun tanımadığı ağaçlardır.

Görkemli ağaçlar, genelde iri yapıları, yaşları, gövde yapıları ve sembolik değerleri gibi özellikleriyle dikkat çeken ağaçlardır.

Egzotik ağaçlar ise pek bilinmeyen renkleri, farklı kabuk ve yaprak dokuları, çarpıcı çiçekleri, değişik formlu meyveleri ve kokuları gibi özellikleriyle diğer ağaçlardan çok farklı büyüleyici özellikleri olan ağaçlardır. Bu ağaçlar insan üzerinde derin bir hayranlık ve saygı uyandıran, peyzajda odak noktası oluşturan anıtsal bitkilerdir.

2.1. GÖRKEMLİ AĞAÇLAR

2.1.a. *Pinus longaeva* (Bristlecone Çamı)

Kuzey Amerika'nın batısındaki yüksek dağlık bölgelerde, 3000 metreyi aşan rakımlarda yetişen Bristlecone çamı, aşırı soğuk, rüzgâr ve kuraklığa dayanıklı yapısıyla bilinir (Şekil 1). Yaklaşık 5000 yılı aşan yaşıyla dünyanın en eski ağaç türlerinden biridir; yavaş büyüme hızı ve reçinece zengin odun yapısı bu olağanüstü ömrün temelini oluşturur. Aşırı uzun ömrü sayesinde yüzyıllar boyunca karbonu bünyesinde tutarak atmosferdeki sera gazlarının azaltılmasına katkıda bulunur (Fritts, 2012; Currey, 1965; Luyssaert et al., 2008).

2.1.b. *Sequoia sempervirens* (Sahil Sekoyası)

Kuzey Kaliforniya ve güney Oregon'un nemli kıyı ormanlarında yetişen Sahil sekoyası, 100 metreyi aşan boyu ve 10 metreye varan gövde çapıyla dünyanın en yüksek ağaç türlerinden biridir (Şekil 1). Lifli, kırmızımsı kabuğu yangınlara karşı doğal koruma sağlar. Yüksek biyokütle yoğunluğu sayesinde yeryüzündeki en önemli karbon yutaklarından biri olarak iklim düzenlemede kritik rol oynar (Sillett et al., 2015; Luyssaert et al., 2008). Olağanüstü boyutları ve uzun ömürlülüğü nedeniyle Amerika Birleşik Devletleri ulusal park sisteminde “yaşayan anıt” statüsüne sahip kültürel bir simge kabul edilmektedir (National Park Service, 2025; Stephenson et al., 2014).

2.1.c. *Sequoiadendron giganteum* (Dev Sekoya)

ABD'nin Sierra Nevada dağlarında yetişen Dev sekoyalar, 100 metreye yaklaşan boyu ve 10 metreyi bulan gövde çapıyla dünyanın en büyük odunsu ağaçlarındandır (Şekil 1). Kalın lifli kabuğu yangınlara karşı direnç sağlamasının yanında 3000 yıl yaşında olan örnekleri bulunmaktadır. Yüksek biyokütle yoğunluğu sayesinde yeryüzündeki en önemli karbon yutaklarından biri olarak iklim düzenlemede kritik rol oynar (Sillett et al., 2015; Luyssaert et al., 2008; National Park Service, 2025). Olağanüstü boyutları ve habitat kaybı nedeniyle IUCN tarafından “Tehlikede” kategorisinde değerlendirilmektedir (IUCN, 2025).

2.1.d. *Ceiba pentandra* (Kapok Ağacı)

Orta ve Güney Amerika kökenli Kapok ağacı, 60 metreyi aşan boyu ve geniş payanda kökleriyle dikkat çeker (Şekil 1). Geniş gövde ve taç yapısı, kuşlar, yarasalar ve böcekler için önemli bir yaşam alanı oluşturur (Wickens, 2008; Gribel et al., 1999). Orta ve Güney Amerika'daki yerli toplulukların kozmolojilerinde “dünya ağacı” olarak kabul edilir (Atindehou et al., 2022).



Şekil 1. Görkemli Pinus longaeva, Sequoia sempervirens, Sequoiadendron giganteum ve Ceiba pentandra ağaç türlerinin görselleri (Url-1, 2, 3, 4)

2.1.e. *Ficus benghalensis* (Banyan Ağacı)

Hindistan ve Güneydoğu Asya’da geniş alanlara yayılışıyla bilinen banyan ağacı gövdesinden gelişen hava kökleri sayesinde çoklu gövde görünümü sergileyerek büyük alanlara yayılır (Şekil 2). Hinduizm’de kutsal kabul edilir; gölgesi altında gerçekleştirilen törenler toplumsal dayanışmayı pekiştirir. Uzak Doğu’da, özellikle Çin ve Tayvan’da yaşlı banyanlar tapınak bahçelerinde koruma altına alınmış, böylece dini ritüeller ile doğa koruma arasında doğrudan bir bağ kurulmuştur (Wickens, 2008; Del Tredici, 2000).

2.1.f. *Adansonia spp.* (Baobab Ağaçları)

Afrika savanlarında, Madagaskar ve Avustralyada yayılış gösteren Baobab ağaçları, şişkin gövdelerinde binlerce litre su depolayarak uzun kurak dönemlere dayanır. 25 m’ye ulaşan boyları ve kalın gövdeleriyle tanınmaktadırlar (Şekil 2). Bu su depolama kapasitesi, kurak mevsimlerde ekosistem süreçleri ve yerel topluluklar için yaşamsal bir destek sağlar. Ayrıca yerel kültürde bu nedenle “yaşam ağacı” olarak anılır ve anıtsal değer taşır (Wickens, 2008). Son yıllarda kuraklık ve sıcaklık artışı, dağınık ve yaşlı popülasyonlarda nesil kaybı riskini artırmaktadır (Weir et al., 2015).

2.1.g. *Agathis australis* (Kauri Ağacı)

Yeni Zelanda'nın kuzeyinde yetişen Kauri ağacı, 50 metreyi aşan boyu, reçineli kalın gövdesi ve geniş taç yapısıyla bilinmesinin yanında lifli odun dokusu ve pürüzsüz kabuğu karakteristik özelliklerindendir (Şekil 2). Yavaş büyüme hızı popülasyonları hassas kılar ve “Kauri dieback” hastalığı nedeniyle Yeni Zelanda’da tehdit altındadır. (Weir et al., 2015)



Şekil 2. Görkemli *Ficus benghalensis*, *Adansonia* spp., *Agathis australis* ağaç türlerinin görselleri (Url-5, 6, 7)

2.2. EGZOTİK AĞAÇLAR

2.2.a. *Eucalyptus deglupta* (Gökkuşaağı Okaliptüsü)

Filipinler, Endonezya ve Papua Yeni Gine kökenli Gökkuşaağı okaliptüsü, yıl boyunca dökülen çok katmanlı kabuğuyla yeşil, mavi, turuncu ve mor tonlarında eşsiz bir gövde görünümü bulunmaktadır (Şekil 3). Bu eşsiz renklenme, “renkli gövde adaptasyonu” olarak bilinir ve *Eucalyptus deglupta* türünü peyzaj çalışmalarında estetik bir ikon hâline getirir (Royal Botanic Gardens, Kew, t.y.).


2.2.b. *Dracaena cinnabari* (Ejderha Kanı Ağacı)

Yalnızca Yemen’in Socotra Adası’nda endemik olan Ejderha kanı ağacı, şemsiye biçimli taç yapısıyla su kaybını azaltan bir morfoloji sergilemektedir (Şekil 3) (Royal Botanic Gardens, Kew, t.y.; Al-Awthan & Bahattab, 2021). Bu taç formu alt tabakada gölge ve nem dengesi oluşturarak diğer türlerin yaşamasına olanak tanır. Gövdesinden elde edilen kırmızı reçine, geleneksel tıpta antiseptik, yara iyileştirici ve ateş düşürücü etkilerle ilişkilendirilir; dinsel uygulamalarda sembolik bir anlam taşır ve bölgesel mitolojide özel bir yere sahiptir (Miller & Morris, 2004; Attorre et al., 2007;

Al-Awthan et al., 2021). Ancak reçinenin tıbbi ve dinsel kullanım için aşırı toplanması, doğal habitatın hızla daralmasına ve popülasyonların azalmasına yol açmaktadır (Al-Awthan et al., 2021).

2.2.c. *Fouquieria columnaris* (Boojum Ağacı)

Meksika'nın Sonora Çölü'ne özgü endemik bir tür olan *Fouquieria columnaris*, dikey uzanan sukulent benzeri uzun gövdesi ve dar dallarıyla tanınmaktadır (Şekil 3). Yavaş büyür ve yüksek su tutma kapasitesi sayesinde aşırı kuraklığa uyum sağlar. Kolon gövde formu, dar dallanma ve destekleyici gövde-kök organizasyonu gibi morfolojik özellikleri, yüksek çevresel toleransla birleşerek türün bölgenin en dikkat çekici sukkulent örneklerinden biri olmasını sağlar. Yerel kültürlerde gizemli ve koruyucu bir varlık olarak görülmektedir. (Escoto-Rodríguez & Bullock, 2002)



Şekil 3. Egzotik *Eucalyptus deglupta*, *Dracaena cinnabari*, *Fouquieria columnaris* ağaç türlerinin görselleri (Url-8, 9,10)

2.2.d. *Rhizophora mangle* (Kırmızı Mangrov)

Asya, Afrika ve Latin Amerika'nın tropikal kıyılarında yayılış gösteren kırmızı mangrov, karmaşık kök sistemiyle sediman tutarak kıyı erozyonunu önler ve fırtına/tsunamilere karşı doğal bir tampon oluşturur; aynı zamanda karbon depolama ve habitat sağlama işlevleriyle öne çıkar (Şekil 4). Mangrov kuşakları, balıklar, kabuklular ve kuşlar için üreme ile beslenme alanları sunarak biyolojik çeşitliliğin sürekliliğini destekler (Alongi, 2008; Friess et al., 2019). Ancak tarım ve turizm amaçlı kıyı dolgu projeleri nedeniyle habitat kaybı yaşamaktadır. (Friess et al., 2019; Spalding et al., 2010)

2.2.e. *Colophospermum mopane* (Mopane Ağacı)

Güney Afrika savanlarında yaygın olan mopane, yarı kurak alanlarda sıcaklık arttığında yapraklarını bükerek su kaybını azaltır (Şekil 4). Bu fizyolojik adaptasyon, bitki topluluklarının sürekliliğini destekleyerek çölleşmeye karşı direnç sağlar. Endemik Mopane kelebeği gibi canlılar için besin kaynağı oluşturur (Timberlake, 1995).

2.2.f. *Hura crepitans* (Dinamit Ağacı)

Orta ve Güney Amerika'nın tropikal ormanlarında görülen Hura crepitans, gövdesinde barındırdığı kapsüller olgunlaştığında patlayarak tohumlarını metrelerce uzağa fırlatmasıyla tanınmaktadır (Şekil 4). Bu yayılış mekanizması ekolojik olarak dikkat çekici olmasının yanında halk arasında da “patlayan ağaç” olarak bilinmektedir (Stevens et al., 2001).



Rhizophora mangle (Kırmızı Mangrov)



Colophospermum mopane (Mopane Ağacı)



Hura crepitans (Dinamit Ağacı)

Şekil 4. Egzotik Rhizophora mangle, Colophospermum mopane, Hura crepitans ağaç türlerinin görselleri (Url-11, 12,13)

2.2.g. *Hippomane mancinella* (Manşinel Ağacı)

Karayipler ve Orta Amerika kıyılarında yetişen manşinel ağacı, dünyanın en zehirli ağaçlarından biri olarak tanımlanmaktadır (Şekil 5). Meyveleri ve sütlü özsuğu ciddi sağlık tehditleri yaratır. Toksik özelliklerine rağmen, kıyı bölgelerindeki varlığı dalga ve erozyon kontrolü gibi ekosistem hizmetleri sunar. Ancak insan sağlığı açısından tehlikeli biyokimyasal özellikleri nedeniyle genellikle kesilmekte, bu da kıyı ekosistemlerinin işlevlerinin zayıflamasına yol açmaktadır (Andreu et al., 2010).



Şekil 5. Hippomane mancinella ağaç türünün görselleri (Url-14)

2.2.h. *Kigelia africana* (Sosis ağacı)

Afrika’da özellikle nehir kenarları, alüvyal–açık ormanlık alanlar, yüksek yağışlı savanlar ve yağmur ormanlarında, deniz seviyesinden yaklaşık 3000 m’ye kadar yayılış gösterir (Şekil 6) (Nabatanzi et al., 2020). *Kigelia africana* 20-24 m’ye kadar boylanır; yağışın yıl geneline yayıldığı bölgelerde herdemyeşil, uzun kurak mevsimlerde yaprak döken fenoloji sergiler (Nabatanzi et al., 2020; Olatunji & Atolani, 2009). Çiçekler gece belirginleşen koku ile yarasalar tarafından ziyaret edilerek tozlaşması sağlanır. Meyveleri odunsu yapıda 30-100 cm uzunluğa ve 5-10 kg ağırlığa ulaşabilir (Nabatanzi et al., 2020). Bitkinin meyve, kabuk, kök ve yaprakları dermatolojik hastalıklar başta olmak üzere çeşitli geleneksel tedavi uygulamalarında kullanılmaktadır. (Halder & Sharma, 2017).

2.2.i. *Cupressus cashmeriana* (Keşmir–Bhutan selvisi)

Himalaya bölgesinin yüksek kesimlerinde doğal olarak yetişen, iğne yapraklı ve herdem yeşil bir türdür. 45 metreye kadar boylanabilir (Şekil 6). Tür, mavi-yeşil yaprak rengi ve zarif sarkık dallarıyla ayırt edilir. Ahşabı dayanıklılığı ve hoş kokusuyla tarih boyunca inşaat, dini yapı ve geleneksel oymacılıkta kullanılmıştır. Ayrıca tür, yüksek nemli dağ ekosistemlerinde toprak stabilizasyonu ve erozyon kontrolü gibi önemli ekolojik işlevler üstlenmektedir (Román-Jordán et al., 2016; Farjon, 2005; Esteban et al., 2004).

2.2.j. *Plinia cauliflora* (Jabuticaba ağacı)

Brezilya’nın Atlantik yağmur ormanları başta olmak üzere Arjantin ve Paraguay’daki alüvyal düzlükler ile açık ormanlarda yetişen, gövde ve kalın dallar üzerinde doğrudan çiçek ve meyve (kauliflori) oluşturan, 10-15 m’ye kadar boy yapabilen bir türdür (Şekil 6). Meyveler taze tüketilir, kısa raf ömrü nedeniyle reçel, meyve suyu ve fermente içecek yapımında değerlendirilmez. Geleneksel kullanımda kabuk ve yaprakları ishal ve üst solunum yolu tedavilerinde kullanılmaktadır (Gasparotto Junior et al., 2019).



Şekil 6. *Kigelia africana*, *Cupressus cashmeriana*, *Plinia cauliflora* ağaç türlerinin görselleri (Url-15, 16, 17)

2.2.k. *Eucalyptus viminalis* (Sakız ağacı / Manna okalıptüsü)


Doğal olarak Avustralya'nın güneydoğusunda, Tazmanya'dan Yeni Güney Galler-Queensland sınırına kadar deniz seviyesinden yaklaşık 1.300 m'ye kadar, yıllık 500-1.700 mm yağış ve değişken don sıklığı koşullarında yayılış gösterir (Şekil 7) (Cappa et al., 2010). Odun kalitesi ve büyüme performansı nedeniyle plantasyonlarda değerlendirilen türün yaprak uçucu yağında monoterpenler baskındır. Bu kimyasal profil antiseptik/antimikrobiyal olarak kullanılmaktadır (Maghsoodlou et al., 2015). Ormancılıkta plantasyon amacıyla yetiştirilir; hızlı büyümesi ve odun kalitesi nedeniyle kereste/odun hammaddesi olarak değerlendirilir (Cappa et al., 2010).

2.2.l. *Eucalyptus camaldulensis* (Kızıl sakız ağacı)

Avustralya'da en geniş coğrafi yayılışa sahip olan Kızıl sakız okalıptüsü doğal olarak nehir/akarsu kenarı habitatlarda görülmektedir (del Moral & Muller, 1970; Mullins et al., 1997). Herdemyeşil ve uzun boylu bir ağaçtır; sanayi odunu, yakacak odun, uçucu yağ, gölge ve rüzgâr kıran olarak kullanılmaktadır (Şekil 7) (Mullins et al., 1997). Ekolojik açıdan dikkat çekici biçimde, yaprak ve örtü tabakasından salınan uçucu monoterpenler ile fenolik asitler çevredeki otsu türlerin çimlenme ve gelişimini baskılayabilir, "bare zone" adı verilen bitkisiz şeritler oluşturabilir. Allelopatik etki, türün yer seçimi ve yönetiminde dikkate alınması gereken bir özelliktir (del Moral & Muller, 1970).

2.2.m. *Ceiba speciosa* (Pembe ipek ağacı)

Güney Amerika'nın tropik-subtropik ormanlarına özgü olan bu tür, genç dönemde şişe biçimli, dikenli gövde ve gösterişli pembe çiçekleri ile kolay tanınır (Şekil 7). Kentsel ortamlarda belirgin yıllık halkalar oluşturur ve kirliliğe rağmen çevre koşullarına iyi uyum sağladığı için çevresel durumun izlenmesinde biyogösterge olarak kullanılabilir. (Vasconcellos et al., 2019). Kabuğunda ve tohumunda bulunan yağ asitleri sayesinde yağ ve şeker sindiriminde görevli enzimleri yavaşlattığı ve antioksidan etki gösterdiği saptanmıştır (Rosselli et al., 2020).



Şekil 7. Eucalyptus viminalis, Eucalyptus camaldulensis, Ceiba speciosa ağaç türlerinin görselleri (Url-18, 19, 20)

SONUÇ

Ağaçlar, insan yaşamının vazgeçilmez bir parçası olarak ekonomik, ekolojik ve estetik faydalar sunmaktadır. Görkemli ağaçlar heybetli yapıları ile, Egzotik ağaçlar ise benzersiz fizyolojik özellikleri ile diğer ağaçlardan ayrılarak doğa harikası statüsüne ulaşmaktadır.

Egzotik ve görkemli ağaçların hikâyelerini daha geniş kitlelere ulaştırmak yalnızca bir farkındalık değil aynı zamanda önemli bir koruma stratejisidir (Demir & Özer, 2014). Yerel halk tarafından kanıksanan bu ağaçlar dünyanın farklı bir coğrafyasındaki insanlar için çok özel canlılar olabilir.

Genellikle dünyada çok az yerde ve sınırlı sayılarda bulunan bu türler, çok küçük ve beklenmeyen bazı müdahaleler karşısında dahi yok olma tehlikesiyle karşı karşıya kalabilir. Bu ağaç türlerinin yaşam alanlarının

detaylı arařtırmalar sonucunda belirlenmesi bunların yakın çevresine tehlike oluřturabilecek müdahalelere karřı etkin ve ciddi bilimsel çalıřmalar yapılmalıdır. Bu harika ağaç türlerinin korunması ve varlıklarının gelecek nesillere aktarılması, insanlığın ortak doęal mirasına karřı en temel görevlerinden biridir.

Sonuç olarak, bu büyüleyici ağaç türleri yalnızca ait oldukları coęrafyanın ve yöre halkının mirası olarak deęil, tüm insanlığın ortak doęal hazinesi olarak görülmelidir. Bunların yařamlarının garantiye alınması için tüm dünyadaki insanlara çok iyi tanıtılması gerekmektedir. Bu sayede oluřacak kamuoyu baskısıyla bu türler için ciddi bilimsel arařtırma ve koruma çalıřmaları yapılması saęlanmalıdır.

REFERANSLAR

- Al-Awthan, Y. S., & Bahattab, O. S. (2021). Phytochemistry and pharmacological activities of *Dracaena cinnabari* resin. *Evidence-Based Complementary and Alternative Medicine*, 2021, Article 8561696.
- Alongi, D. M. (2008). Mangrove forests: Resilience, protection from tsunamis, and responses to global climate change. *Estuarine, Coastal and Shelf Science*, 76(1), 1–13. <https://doi.org/10.1016/j.ecss.2007.08.024>
- Andreu, M. G., Friedman, M. H., & McKenzie, M. (2010). *Hippomane mancinella*, *Manchineel*. EDIS, FOR29, EE-242. University of Florida IFAS Extension. <https://edis.ifas.ufl.edu/publication/FR370>
- Atindehou, M. M. L., Avakoudjo, H. G. G., Idohou, R., Azihou, F. A., Assogbadjo, A. E., Adomou, A. C., & Sinsin, B. (2022). Old sacred trees as memories of the cultural landscapes of southern Benin (West Africa). *Land*, 11(4), 478. <https://doi.org/10.3390/land11040478>
- Attorre, F., Francesconi, F., Taleb, N., Scholte, P., Saed, A., Alfo, M., & Bruno, F. (2007). Will dragonblood survive the next period of climate change? Current and future potential distribution of *Dracaena cinnabari* (Socotra, Yemen). *Biological Conservation*, 138(3–4), 430–439. <https://doi.org/10.1016/j.biocon.2007.05.009>
- Bhagwat, S. A., & Rutte, C. (2006). Sacred groves: Potential for biodiversity management. *Frontiers in Ecology and the Environment*, 4(10), 519–524.
- Borrajó Millán, J. M., Pérez Daniëls, P. J., Aguiló Vidal, I., & González, R. (2025). Assessing biodiversity associated with four monumental trees in Madrid Region (Spain). *Arboriculture & Urban Forestry*, 51(3), 252–273. <https://doi.org/10.48044/jauf.2025.010>
- Budău, R., Timofte, C. S. C., Mirisan, L. V., Bei, M., Dinca, L., Murariu, G., & Racz, K. A. (2025). Living landmarks: A review of monumental trees and their role in ecosystems. *Plants*, 14(13), 2075. <https://doi.org/10.3390/plants14132075>
- Cappa, E. P., Pathauer, P. S., & López, G. A. (2010). Provenance variation and genetic parameters of *Eucalyptus viminalis* in Argentina. *Tree Genetics & Genomes*, 6, 981–994. <https://doi.org/10.1007/s11295-010-0307-9>
- Ceballos, G., Ehrlich, P. R., & Dirzo, R. (2017). Biological annihilation via the ongoing sixth mass extinction signaled by vertebrate population losses and

- declines. *Proceedings of the National Academy of Sciences*, 114(30), E6089–E6096. <https://doi.org/10.1073/pnas.1704949114>
- Crowther, T. W., Glick, H. B., Covey, K. R., Bettigole, C., Maynard, D. S., Thomas, S. M., ... Bradford, M. A. (2015). Mapping tree density at a global scale. *Nature*, 525(7568), 201–205. <https://doi.org/10.1038/nature14967>
- Currey, D. R. (1965). An ancient bristlecone pine stand in eastern Nevada. *Ecology*, 46(4), 564–566.
- del Moral, R., & Muller, C. H. (1970). The allelopathic effects of *Eucalyptus camaldulensis*. *The American Midland Naturalist*, 83(1), 254–282.
- Del Tredici, P. (2000). The evolution, ecology, and cultivation of *Ginkgo biloba*. In T. A. Van Beek (Ed.), *Ginkgo biloba* (pp. 7-23). Harwood Academic Publishers.
- Demir, M., & Özer, S. (2014). Evaluation of Tortum Waterfall according to the criteria used in the selection of protected areas in Turkey. *Polish Journal of Environmental Studies*, 23(5), 1555–1563.
- Demircioğlu Yıldız, N. (2024). Analysis of urban green area accessibility and quality for ecosystem services as a spatial decision support: In the city of Erzurum (Turkey). *Polish Journal of Environmental Studies*, 33(1), 915–926.
- Escoto-Rodríguez, M., & Bullock, S. H. (2002). Long-term growth rates of cirio (*Fouquieria columnaris*), a giant succulent of the Sonoran Desert in Baja California. *Journal of Arid Environments*, 50(4), 593–611. <https://doi.org/10.1006/jare.2001.0921>
- Esteban, L. G., De Palacios, P., & Fernández, F. G. (2004). Anatomical differences between American and Eurasian Cupressus species. *IAWA Journal*, 25(2), 213–230.
- Farjon, A. (2005). Monograph of Cupressaceae and Sciadopitys. Royal Botanic Gardens, Kew.
- Friess, D. A., Rogers, K., Lovelock, C. E., Krauss, K. W., Hamilton, S. E., Lee, S. Y., ... Shi, S. (2019). The state of the world's mangrove forests: Past, present, and future. *Annual Review of Environment and Resources*, 44, 89–115. <https://doi.org/10.1146/annurev-environ-101718-033302>
- Fritts, H. C. (2012). *Bristlecone pine in the White Mountains of California: Growth and long tree-ring chronologies*. University of Arizona Press.
- Gasparotto Junior, A., et al. (2019). *Journal of Ethnopharmacology*, 245, 112169. <https://doi.org/10.1016/j.jep.2019.112169>
- Gribel, R., Gibbs, P. E., & Queiróz, A. L. (1999). Flowering phenology and pollination biology of *Ceiba pentandra* (Bombacaceae) in Central Amazonia. *Journal of Tropical Ecology*, 15(3), 247–263. <https://doi.org/10.1017/S0266467499000796>
- Halder, S., & Sharma, A. (2017). A review on *Kigelia africana*. *World Journal of Pharmaceutical Research*, 6(11), 389–411. <https://doi.org/10.20959/wjpr201711-9633>
- Intergovernmental Science-Policy Platform on Biodiversity and Ecosystem Services (IPBES). (2019). *Global assessment report on biodiversity and ecosystem services*. IPBES. <https://doi.org/10.5281/zenodo.3831673>
- International Union for Conservation of Nature (IUCN). (2025). *The IUCN Red List of Threatened Species (Version 2025-1)*. Erişim tarihi: 25 Eylül 2025, <https://www.iucnredlist.org>

- Kempes, C. P., West, G. B., Crowell, K., & Girvan, M. (2011). Predicting maximum tree heights and other traits from allometric scaling and resource limitations. *PLoS ONE*, 6(6), e20551. <https://doi.org/10.1371/journal.pone.0020551>
- Luyssaert, S., Schulze, E.-D., Börner, A., Knohl, A., Hessheimer, D., Law, B. E., ... Grace, J. (2008). Old-growth forests as global carbon sinks. *Nature*, 455(7210), 213–215. <https://doi.org/10.1038/nature07276>
- Maghsoodlou, M. T., Kazemipoor, N., Valizadeh, J., Falak Nezhad Seifi, M., & Rahneshan, N. (2015). Essential oil composition of *Eucalyptus microtheca* and *Eucalyptus viminalis*. *Avicenna Journal of Phytomedicine*, 5(6), 540–552.
- Miller, A. G., & Morris, M. (2004). *Ethnoflora of the Soqotra Archipelago*. Royal Botanic Garden.
- Mullins, K. V., Llewellyn, D. J., Hartney, V. J., Strauss, S., & Dennis, E. S. (1997). Regeneration and transformation of *Eucalyptus camaldulensis*. *Plant Cell Reports*, 16, 787–791.
- Nabatanzi, A., Nkadameng, S. M., Lall, N., Kabasa, J. D., & McGaw, L. J. (2020). Ethnobotany, phytochemistry and pharmacological activity of *Kigelia africana* (Lam.) Benth. (Bignoniaceae). *Plants*, 9(6), 753. <https://doi.org/10.3390/plants9060753>
- National Park Service (NPS). (2025). *Coast redwood (Sequoia sempervirens)*. U.S. Department of the Interior. Erişim tarihi: 13 Ekim 2025, <https://www.nps.gov/redw/>
- Olatunji, A. G., & Atolani, O. (2009). Comprehensive scientific demystification of *Kigelia africana*: A review. *African Journal of Pure and Applied Chemistry*, 3(9), 158–164.
- Pan, Y., Birdsey, R. A., Fang, J., Houghton, R., Kauppi, P. E., Kurz, W. A., & Hayes, D. (2011). A large and persistent carbon sink in the world's forests. *Science*, 333(6045), 988–993.
- Román-Jordán, E., Esteban, L. G., De Palacios, P., & Fernández, F. G. (2016). Wood anatomy of *Cupressus* and its relation to geographical distribution. *IAWA Journal*, 37(1), 48–68. <https://doi.org/10.1163/22941932-20160120>
- Rosselli, S., Tundis, R., Bruno, M., Leporini, M., Falco, T., Gagliano Candela, R., ... Loizzo, M. R. (2020). *Ceiba speciosa* seeds oil: Fatty acids profiling by GC–MS and NMR and bioactivity. *Molecules*, 25(5), 1037. <https://doi.org/10.3390/molecules25051037>
- Royal Botanic Gardens, Kew. (t.y.). *Plants of the World Online (POWO)*. Erişim tarihi: 13 Ekim 2025, <https://powo.science.kew.org>
- Sillett, S. C., Van Pelt, R., Carroll, A. L., Kramer, R. D., Ambrose, A. R., & Trask, D. (2015). How do tree structure and old age affect growth potential of California redwoods? *Ecological Monographs*, 85(2), 181–212.
- Spalding, M., Kainuma, M., & Collins, L. (2010). *World atlas of mangroves*. Earthscan. <https://doi.org/10.4324/9781849776608>
- Stephenson, N. L., Das, A. J., Condit, R., Russo, S. E., Baker, P. J., Beckman, N. G., Coomes, D. A., Lines, E. R., Morris, W. K., Ruger, N., Álvarez, E., Blundo, C., Bunyavejchewin, S., Chuyong, G., Davies, S. J., Duque, Á., Ewango, C. N., Flores, O., Franklin, J. F., ... Zavala, M. A. (2014). Rate of tree carbon accumulation increases continuously with tree size. *Nature*, 507(7490), 90–93. <https://doi.org/10.1038/nature12914>

- Stevens, W. D., Ulloa, C. U., Pool, A., & Montiel, O. M. (2001). *Flora de Nicaragua*. Monographs in Systematic Botany from the Missouri Botanical Garden, 85, 1–2666.
- Timberlake, J. (1995). *Colophospermum mopane annotated bibliography*. Zimbabwe Bulletin of Forestry Research, 11.
- Vasconcellos, T. J., Tomazello-Filho, M., & Callado, C. H. (2019). Dendrochronology and dendroclimatology of *Ceiba speciosa* exposed to urban pollution in Rio de Janeiro, Brazil. *Dendrochronologia*, 53, 104–113. <https://doi.org/10.1016/j.dendro.2018.12.004>
- Watson, J. E. M., Evans, T., Venter, O., Williams, B., Tulloch, A., Stewart, C., Thompson, I., Ray, J. C., Murray, K., Salazar, A., McAlpine, C., Potapov, P., Walston, J., Robinson, J. G., Painter, M., Wilkie, D., Filardi, C., Laurance, W. F., Houghton, R. A., ... Lindenmayer, D. (2018). The exceptional value of intact forest ecosystems. *Nature Ecology & Evolution*, 2(4), 599–610. <https://doi.org/10.1038/s41559-018-0490-x>
- Weir, B. S., Paderes, E. P., Anand, N., Uchida, J., Pennycook, S. R., Bellgard, S. E., & Beever, R. E. (2015). A taxonomic revision of *Phytophthora* Clade 5 including the kauri pathogen *Phytophthora agathidicida*. *Phytotaxa*, 205(1), 21–38. <https://doi.org/10.1146/phytotaxa.205.1.2>
- Wickens, G. E. (2008). *The baobabs: Pachycauls of Africa, Madagascar and Australia*. Springer. <https://doi.org/10.1007/978-1-4020-6431-9>
- WWF. (2022). *Living Planet Report 2022 - Building a nature-positive society*. R.E.A. Almond, M. Grooten, D. Juffe Bignoli, & T. Petersen (Eds.). WWF.

İnternet Kaynakları

- Url-1, <https://www.aa.com.tr/tr/dunya/yeryuzunun-en-yaslisi-5-bin-yillik-cam-agaci-/840712> Erişim tarihi: 1 Ekim 2025
- Url-2, https://www.thelivingurn.com/blogs/news/79478849-the-largest-living-tree-the-general-sherman-giant-sequoia?srsId=AfmBOoprXoP7hVR-mb8TmtHNugBmqUGUqzivx8Y9p5PamXeGLngfg4_W Erişim tarihi: 6 Ekim 2025
- Url-3, <https://cdn.britannica.com/98/214598-050-9879F2FA/giant-sequoia-tree-Sequoia-National-Park-California.jpg> Erişim tarihi: 4 Ekim 2025
- Url-4, <https://tr.pinterest.com/pin/28710516369538377/> Erişim tarihi: 2 Ekim 2025
- Url-5, <https://okdiario.com/curiosidades/caracteristicas-ficus-banyan-1443354#close>
- Url-6, <https://www.facebook.com/photo/?fbid=955597270083460&set=pcb.955597296750124> Erişim tarihi: 10 Ekim 2025
- Url-7, <https://www.theguardian.com/world/2022/aug/14/salvation-of-new-zealands-dying-giant-kauri-trees-may-have-roots-in-maori-wisdom> Erişim tarihi: 10 Ekim 2025
- Url-8, https://www.etsy.com/no-en/listing/1146358406/rainbow-eucalyptus-eucalyptus-deglupta?dd_referrer=https%3A%2F%2Fwww.google.com%2F Erişim tarihi: 14 Ekim 2025
- Url-9, https://www.flickr.com/photos/rod_waddington/31104074782/ Erişim tarihi: 12 Ekim 2025
- Url-10, <https://www.spadefootnursery.com/fouquieria/boojum-tree-fouquieria-columnaris> Erişim tarihi: 1 Ekim 2025
- Url-11, <https://www.facebook.com/photo/?fbid=3457457227679700&set=pcb.3457459311012825> Erişim tarihi: 1 Ekim 2025

- Url-12, https://en.wikipedia.org/wiki/Mopane#/media/File:Colophospermum_mopane_-_Mopane-2266_-_Flickr_-_Ragnhild_&_Neil_Crawford.jpg Eriřim tarihi: 13 Ekim 2025
- Url-13, <https://tr.pinterest.com/pin/807270301995131394/> Eriřim tarihi: 8 Ekim 2025
- Url-14, <https://www.britannica.com/plant/manchineel> Eriřim tarihi: 7 Ekim 2025
- Url-15, <https://wellsforzoe.org/portfolio/kigelia-africana-mvunguti/> Eriřim tarihi: 4 Ekim 2025
- Url-16, https://floridaseeds.net/products/copy-of-kashmir-cypress-cupressus-cashmeriana-20-seeds?srsItd=AfmBOor2kMtBtLRifCvK_9mWWVvC_rBxBzkHTaeQr7oROtClxCT-wEfY Eriřim tarihi: 1 Ekim 2025
- Url-17, https://cdn.zmescience.com/wp-content/uploads/2016/05/Myrciaria_cauliflora.jpg Eriřim tarihi: 9 Ekim 2025
- Url-18, <https://resources.austplants.com.au/plant/eucalyptus-viminalis/>
- Url-19, https://www.researchgate.net/publication/340163911_Towards_more-than-human_heritage_arboreal_habitats_as_a_challenge_for_heritage_preservation/figures?lo=1, <https://built-heritage.springeropen.com/articles/10.1186/s43238-020-00003-9> Eriřim tarihi: 1 Ekim 2025
- Url-20, <https://redlily.ru/articles/161/#prettyPhoto> Eriřim tarihi: 6 Ekim 2025

