

Yapay zeka uygulamalarının sağlık sektöründe kullanımı: Derin öğrenme yöntemiyle ön tanı

Muhammed Akif Yenikaya^a, Onur Oktaysoy^b

^aKafkas Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, e-posta: akif.yenikaya@kafkas.edu.tr, ORCID: 0000-0002-3624-722X

^bKafkas Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, Yönetim Bilişim Sistemleri Bölümü, e-posta: onurkavak@kafkas.edu.tr, ORCID: 0000-0002-8623-614X

MAKALE BİLGİLERİ

Araştırma Makalesi

Geliş Tarihi: 22 Kasım 2023

1. Revizyon Tarihi: 30 Kasım 2023

2. Revizyon Tarihi: 7 Aralık 2023

3. Revizyon Tarihi: 13 Aralık 2023

Kabul Tarihi: 15 Aralık 2023

Öz

Amaç: Bilgi çağı olarak adlandırılan günümüz dünyasında dijitalleşme her sektörde olduğu gibi sağlık sektöründe de kendisine önemli bir yer edinmiştir. Özellikle yapay zekâ teknolojilerinin sağlık sektörü üzerinde muazzam denilebilecek bir değişim etkisi söz konusudur. Tanı ve teşhis yapabilmeyen yanı sıra, sektörde yer alan nitelikli insan kaynağına alternatif olabileceği beklenen yapay zekâ, bu araştırma da alt kümeleri olan derin öğrenme ağları perspektifinden ele alınmıştır. Çalışmada derin öğrenme ağlarından olan ResNet101 ve GoogleNet bağlamında yapay zekânın hastalık teşhisindeki başarı düzeyinin belirlenmesi amaçlanmaktadır.

Yöntem: Araştırma amacı doğrultusunda açık erişimli Kaggle web sitesinden beyin tümörü türlerinden olan Glioma, Meningioma ve Pituitary içeren toplamda 2124 adet MR görüntü veri seti elde edilmiş, bu verilerle %70 eğitim, %30 test oranı ile çalışmada kullanılan derin öğrenme ağlarının, görüntü ayrıştırma ve tanımlama başarı düzeyleri karşılaştırılmıştır.

Bulgular: Analiz bulguları derin öğrenme ağlarının üç farklı beyin tümörü hastalığını ayrıştırma ve tanımlama noktasında başarılı olduğunu göstermiştir. Derin öğrenme ağlarının başarı düzeyleri incelendiğinde ResNet101 derin öğrenme ağının %91.5, GoogleNet derin öğrenme ağının ise %87.9 başarı düzeyine sahip olduğu tespit edilmiştir.

Sonuç: Araştırmanın bulguları doğrultusunda ResNet101 ve GoogleNet derin öğrenme ağlarının beyin tümörü türlerini tanımlama ve ayrıştırma noktasında kullanılabilir olduğu, ResNet101 derin öğrenme ağının araştırma özetinde daha yüksek başarı oranı kaydettiği ve son olarak yapay zekâ teknolojilerinin sağlık sektöründe önemli bir yer edinme potansiyelinin olduğu tespit edilmiştir.

Anahtar Kelimeler: *Yapay zeka, Derin öğrenme, Sağlık sektörü, Hastalık teşhisi, Yönetim bilişim.*

Use of artificial intelligence applications in the health sector: Preliminary diagnosis with deep learning method

Abstract

Aim: In today's world, known as the Information Age, digitization has gained a significant place in every sector, including the healthcare industry. Particularly, artificial intelligence technologies have an enormous transformative effect on the healthcare sector. Beyond enabling diagnosis and identification, artificial intelligence, which is expected to serve as an alternative to the qualified human workforce in the field, is addressed in this research from the perspective of its subcategories, namely deep learning networks. The aim of this study is to determine the success level of artificial intelligence in disease diagnosis within the context of deep learning networks, specifically ResNet101 and GoogleNet.

Method: In line with the research objective, a dataset consisting of a total of 2124 MRI images, encompassing brain tumor types such as Glioma, Meningioma, and Pituitary, was obtained from the openly accessible Kaggle website. The success levels of the deep learning networks used in the research for image segmentation and identification were compared using a training-test split of 70-30%.

Findings: The analysis findings revealed the success of the deep learning networks in distinguishing and identifying three different brain tumor diseases. Upon examining the success rates of these networks, it was determined that the ResNet101 deep learning network achieved a success rate of 91.5%, while the GoogleNet deep learning network achieved a success rate of 87.9%.

Results: The findings of the study indicate that both ResNet101 and GoogleNet deep learning networks are applicable for identifying and distinguishing types of brain tumors. Specifically, ResNet101 achieved a higher success rate within the scope of this research. Additionally, the study highlights the significant potential of artificial intelligence technologies in the healthcare sector.

Keywords: *Artificial intelligence, Deep learning, Health sector, Disease diagnosis, Management informatics.*

ARTICLE INFO

Research Article

Received: November 22, 2023

Received in 1st revised form: November 30, 2023

Received in 2nd revised form: December 7, 2023

Received in 3rd revised form: December 13, 2023

Accepted: December 15, 2023

Giriş

Yapay Zekâ ve Makine Öğrenimi, günümüz dünyasında hemen hemen her sektörde kendisine yer bulmuş (sanayi, tarım, turizm, lojistik, banka-finans, güvenlik, eğitim vb.) ve alışıla gelmiş tabuları temelinden sarsmıştır. Söz konusu sektörlerden biri de sağlık sektörüdür. Yapay zekâ teknolojilerinin sağlık alanında kullanıldığı çok sayıda çalışma son zamanlarda literatüre girmekte ve bu teknolojilerin sağlık sektöründeki yerini genişletmektedir. Bu çalışmalardan bazıları, kalp hastalıkları ve yapay zekâ (Shao vd., 2014), Çölyak Hastalığının yapay zekâ ile tespiti (Saken, 2020), uyku apnesi tespiti (Nazlı, 2021), yapay zekâ ile anemi teşhisi (Yıldız, 2021), Parkinson teşhisi (Alkan, 2019) şeklinde sıralanabilir. Tanı ve teşhis uygulamalarının yanı sıra, hasta yönetimi, kişiselleştirilmiş bakım, operasyon yönetimi gibi önemli faaliyetlerde de sağlık sektöründe yapay zekâ uygulamalarına rastlanmaktadır (Moon vd., 2020). Bu çalışmada yapay zekânın tanı ve teşhis süreçlerine olan etkisi incelenmektedir. Yapay Zekâ ve Makine Öğrenimi teknolojileri, görüntü tanıma ve analizinde oldukça önemli bir role sahiptir. Bahse konu teknolojiler Manyetik Rezonans (MR), Bilgisayarlı Tomografi (BT) ve Röntgen gibi görüntüleme tekniklerinin çözülmesinde, insanlara göre bazı noktalarda üstünlük ortaya koyabilmektedir. Bu noktalardan bazıları şu şekildedir; Yapay zekâ algoritmaları, büyük miktarda veriyi insanlara göre çok daha hızlı bir şekilde işleyebilmektedir. İnsanlar kimi zaman duygusal veya önyargılı olabilmekte ve bu durum bazen yapılan teşhisin doğruluğuna engel teşkil edebilmektedir. Yapay zekâ objektif olması bakımından teşhislerde veriyi dayalı karar almakta, duygusallık ve tutarsızlık göstermemektedir (Akalın ve Veranyurt, 2021). Yine yapay zekâ insana göre çok daha çeşitli kaynaklardan veri edinebilmekte, bunları bir araya getirerek daha zengin gerekçelere dayalı çıkarımda bulunabilmektedir. Aynı performans ile sürekli çalışabilen yapay zekâ doğru teşhise engel teşkil edebilecek yorgunluk, dikkatsizlik, odaklanamama vb. nedenlerden etkilenmemektedir. Son olarak her bir veriyle daha da zenginleşen altyapısıyla yapay zekâ sürekli gelişim kaydetmekte ve doğruluk oranını arttırmaktadır. Özellikle ifade edilmelidir ki, bu çalışmada yapay zekâ teknolojisinin, sağlık sektöründe bağımsız bir tanı ve teşhis unsuru olarak değil, hekimlerin iş yükünü azaltan, hızlı ve doğru teşhis yapmaya yardımcı bir araç olarak değerlendirilmesi önerilmektedir. Özellikle erken teşhis gerektiren hastalıklarda bu teknolojilerden istifade edilmesi hayat kurtarıcı olabilmektedir. Erken teşhisin oldukça önemli olduğu sağlık sorunlarından biri olan beyin tümörleri, görüntü analizi yoluyla söz konusu teknolojilerden istifade edilebilecek erken teşhis edilebilecek hastalıklardandır.



Beyin tümörleri, beyindeki anormal hücre büyümesinin ve kontrolsüz hücre çoğalmasının bir sonucu olan, oldukça önemli sağlık sorunlarını beraberinde getiren hatta ölüme neden olabilen bir hastalık olarak tanımlanabilir (Kaplan ve Sadock, 2003). Beyin tümörlerinde iyi huylu (kanseri olmayan) ve kötü huylu (kanseri) olmak üzere iki ana tür bulunmaktadır (Tiwari vd., 2020). Kötü huylu tümörler, hızlı beyin dokusuna yayılarak hastanın durumunu ciddi şekilde etkileyebilmekte dahası kişinin ölümüne sebebiyet verebilmektedir. Beyin tümörlerinin boyutu, şekli, konumu ve çeşidi her hastada farklılık gösterebilmektedir. Söz konusu bu durum, beyin tümörlerinin tespitini tıbben karmaşık ve zorlu hale getirmektedir (Hazra vd., 2017). Dünya Sağlık Örgütü (WHO) tarafından paylaşılan raporlara göre, beyin tümörleri, dünya genelindeki insan ölüm nedenleri arasında önemli bir yer tutmaktadır (WHO, 2023). Beyin tümörlerinin erken evrede tespit edilmesi ve tedaviye hemen başlanması, ölüm oranının önemli oranda azaltılmasıyla bağlantılıdır (Yardımcı, 2009; Vieira vd., 2017). Dolayısıyla, beyin tümörlerinin doğru teşhis ve sınıflandırılması için etkili tanı yöntemlerinin geliştirilmesi büyük önem taşımaktadır. WHO (2023) tarafından paylaşılan verilerine göre, küresel çapta en ölümcül kanser türlerinden biri olduğu belirtilen beyin tümörü, her yaşta kendini gösterebilmekte dahası 40 yaş altı hastalarda daha ölümcül olabilmektedir (Abd El Kader, 2021). Bu bağlamda beyin tümörlerinin erken teşhis edilmesi, hastaların tedavi edilmesi ve hayatta kalabilmeleri için son derece önemlidir (Ilçge ve Totur, 2010).

Beyin tümörlerini tespit etmeye yönelik birincil yöntemler büyük ölçüde radyologların uzmanlığına dayanmaktadır (Afshar vd., 2019). Bu tespit sürecinde öncelikle hastalıkla ilgili hekimin istemi üzerinde radyolojik görüntüleme yapılır, elde edilen görüntü uzman radyologlar tarafından çözümlenerek raporlanır ve istemle bulunan hekime iletilir. Hekim, gelen rapor doğrultusunda teşhis ve tedavi sürecine başlar. Söz konusu bu süreç, hasta yoğunluğu ve uzman personel yetersizliği gibi nedenlerle kimi zaman aylarca sürebilmektedir. Bu noktada yapay zekâ destekli sistemler elde edilen görüntüleri dakikalarla ifade edilecek kadar kısa sürelerde çözümlenerek tanı yapabilmekte ve erken teşhis ile hayat kurtarıcı olabilmektedir (Arrieta vd., 2020). Dijital tanıma ve hesaplamalı zekâ metodolojilerinde yaşanan ilerlemeler, tıbbi görüntülerin anlaşılmasını önemli ölçüde geliştirerek erken tespite yardımcı olmuştur. Naive Bayes Sınıflandırıcısı (Rish, 2001), Gizli Markov Modeli (HMM) (Kaur ve Doegar, 2019), Gauss Karışım Modeli (GMM) (Reynolds, 2008), ve Destek Vektör Makinesi (SVM) ise büyük miktarda görüntülerin sınıflandırılması sürecinde en yaygın olarak kullanılan sınıflandırma teknikleri olarak karşımıza çıkmaktadır. Bu tekniklerden Naive Bayes Sınıflandırıcısı, Basit, hızlı ve küçük boyutlu veri setlerinde iyi sonuçlar verebilmektedir. Ancak değişkenler arasındaki bağımsızlık varsayımı yetersizliği, performansını etkileyebilmektedir. Gizli Markov Modeli, Sıralı verileri (zaman serileri gibi) işlemek için etkilidir. Birbirini izlemesi gereken durumları modellemek için kullanılabilir fakat öğrenme sürecinin genellikle hesaplamalar açısından yoğun olması bu yöntemin zayıf yanıdır. Gauss Karışım Modeli, verinin karmaşık yapılarını yakalamak için etkilidir fakat kimi zaman küme sayısını önceden belirlemenin zorluğu nedeniyle yoğun karmaşık yapıları yakalayamayabilir. Destek Vektör Makinesi, hem sınıflandırma hem de regresyon için kullanılabilir, yüksek boyutlu veri setlerinde etkilidir ve lineer veya non-linear karar sınırları çizebilmektedir. Bu yöntemde büyük veri setlerinde hesaplama yoğunluğu yüksek olabilir bu sebeple hesap sınırı çözmek gerekebilir. Hangi modelin kullanılacağı, veri setinin özelliklerine, problemin gereksinimlerine ve modelin avantajlarına bağlı olmaktadır. Örneğin, sınırlı veri setleri için Naive Bayes'in tercih edilmesi gerekirken, sıralı veri setleri için Gizli Markov daha uygun olabilmektedir.

Tıbbi görüntüleme teknolojileri ile yapay zekâ uygulamalarının ilişkilendirildiği ve yapay zekânın, tıbbi görüntü ayrıştırma yoluyla ön tanı yapabilme kabiliyetinin ele alındığı çok sayıda çalışma bulunmaktadır. Bahse konu bu çalışmalardan bazıları şu şekildedir. Vakanski vd. (2020) tarafından Meme kanseri teşhisinde ultrason görüntülerinin U-Net Modeli tanımlanması üzerine yapılan çalışmada %95,7'lik doğruluk oranı elde edilmiş, Shia ve Chen (2020) tarafından yapılan çalışmada iyi huylu ve kötü huylu tümör sınıflandırması için Doppler Ultrason görüntülerinin derin öğrenme vasıtasıyla ayrıştırılmasına yönelik yapılan çalışmada %77.08 duyarlılık, %91.07 özgüllük oranları elde edilmiştir. Yine Talo (2019) tarafından Akciğer radyografi görüntüleri ile pnömoni hastalığının teşhisine yönelik ResNET-152 Ağ yapısı üzerinden bir çalışma yürütülmüş ve çalışma neticesinde Doğruluk = 0.974 olarak tespit edilmiştir. Ekrem ve diğerleri (2020) tarafından yapay zekâ ile kalp hastalığının tespit edilmesine ilişkin çalışma yürütülmüş, mevcut görsellerin ayrıştırılmasında doğruluk oranı %86.88 olarak tespit edilmiştir. Sıralanan bu çalışmalar, hastalıklara ait tanı konulması ve hekimlere yardımcı olması bakımından yapay zekâ uygulamalarının işlevselliğini ortaya koymasına bakımından oldukça önemlidir. Yapılan alan yazın araştırmalarında beyin tümörlerinin tespitinde görsel verilerin yapay zekâ aracılığıyla tespitine yönelik bazı çalışmalar yapıldığı, fakat Resnet101 ve GoogleNet ağ yapılarının işlevselliği üzerine yapılmış her hangi bir çalışma olmadığı tespit edilmiştir. Söz konusu bu boşluğa katkı sunabilmek için MR görselleri üzerinde derin öğrenme ağları vasıtasıyla beyin tümörlerinin ön tanısını odağa alan araştırmanın gerçekleştirilmesine karar verilmiştir.

Derin öğrenme, giriş ve çıkış katmanları arasında konumlandırılmış birden fazla gizli katman içeren sinir ağı mimarisinden yararlanan makine öğrenimi metodolojilerinin önemli bir bölümünü oluşturmaktadır. Biraz basitleştirmek gerekirse derin öğrenme teknolojisi, bir insanın düşünme şekline benzemektedir. Örneğin, eğitim sırasında bir insan çeşitli konuları öğrenir ve bu bilgileri birbirine bağlar ve öğrenme süreci gerçekleşir. Derin öğrenme de bir buna benzer şekilde, veriyi analiz eder, farklı seviyelerdeki özellikleri öğrenir ve bu özellikler arasındaki ilişkileri keşfederek geri bildirimde bulunur. Bu yöntemler, nesne algılama (Ouyang vd., 2015) ve görüntü sınıflandırma (Chan vd. 2015) gibi çeşitli problem sahalarında, kapsamlı uygulama alanı bulmaktadır. Bu niteliğiyle sağlık sektöründe de istifade edilebilen derin öğrenme teknolojilerinin, tıbbi görüntü analizinde, özellikle akciğer kanseri tanısı (Sun vd., 2017) ve beyin tümörlerinin tespiti (Amin ve Mageed, 2012; Goswami ve Bhaiya, 2013), göz hastalıklarının tespiti (Yenikaya, 2022) gibi görevlerde oldukça etkili olabileceği ileri sürülmektedir. Burada etkili olmak ifadesinden kasıt, derin öğrenme yöntemlerinin, hastalıklara ilişkin kapsamlı MR görüntülerini analiz etmeleri neticesinde tıbbi araştırma ve teşhis bağlamında başarılı sonuçlar sunmalarıdır (Goswami ve Bhaiya, 2013; Vieira vd., 2017).

Evrişimli Sinir Ağları (ESA) yaygın bir derin öğrenme mimarisini temsil etmektedir (Jmour vd., 2018). Tipik bir ESA, yalnızca yerleştirilmiş bilgilere dayanmadan, bir görüntü içindeki bir nesnenin varlığını belirleyebilir. Spesifik olarak, beyin tümörleri için otomatik MRI segmentasyonuna uygulanan ESA tabanlı algoritmalar, benzersiz ve ayırt edici özellikleri, etkili bir şekilde ayırt ederek başarılı sonuçlar ortaya koymuştur (Urban vd., 2014). Bu noktada araştırma sorularından ilki oluşturulmuştur; Araştırma Sorusu 1: Beyin Tümörleri MR görüntülerinin tanı ve tespitinde derin öğrenme ağları (ResNet101 ve GoogleNet) başarılı olabilir mi?

Bu çalışmanın birincil odak noktası, derin öğrenme modellerinden olan Resnet101 ve GoogleNet ağının beyin tümörü türlerinin sınıflandırılmasındaki başarı oranlarının belirlenmesi ve iki derin öğrenme modelinin başarı düzeylerinin kıyaslanmasıdır. Araştırmada ResNet101 ve GoogleNet, ağlarının kullanılmasının temel nedeni, derin öğrenme modelleri içinde öne çıkan ve görüntü tanıma alanında kullanılan iki önemli mimari olmalarıdır. Yapılan bu araştırmanın, ele alınan konular ve elde edilmek istenen bulgular itibarıyla literatüre bazı önemli katkılarda bulunulması amaçlanmaktadır. Bunlardan ilki çalışmanın sağlık sektöründe yapay zekânın (derin öğrenmenin) beyin tümörlerini ayrıştırma ve tanımlama noktasındaki etkinliğini tespit etmektir. Bir diğer amaç, beyin tümörlerinin tespitinde hangi derin öğrenme modelinin daha başarılı sonuçlar sunduğunun belirlenmesidir. Bu bağlamda araştırma sorularından ikincisi oluşturulmuştur; Araştırma Sorusu 2: Eğer başarı elde ediliyorsa, başarı düzeyi yüksek olan ağ hangisidir?

Yapılan bu çalışmada araştırma sorularının cevaplanması ile derin öğrenme modellerinin beyin tümörünün tespit noktasında ne derece başarılı olduğunun belirlenmesi amaçlanmaktadır. Erişilmek istenen bu bulgu sayesinde beyin tümörü vakalarında ön tanı amacıyla bu yöntemlerden istifade edilmesi, hekim hata oranının en aza indirgenmesi, işlem hızı sayesinde hastanelerin iş yükü yoğunluğunun azaltılması, erken teşhis sayesinde can kayıplarının önüne geçilmesi amaçlanmaktadır. Bunların yanı sıra yapay zekâ uygulamalarının sağlık sektöründe kullanım yaygınlığına katkıda bulunmak bu araştırmanın bir diğer amacıdır.


Materyal Metot

Önerilen araştırma çerçevesi, tıbbi görüntülerdeki beyin tümörlerini tanımlamak ve bölümlere ayırmak için tasarlanmıştır. Yaklaşım, özellikle Evrişimsel Sinir Ağı (ESA) algoritmasını kullanan derin öğrenme tekniklerine dayanmaktadır. Sistem, bu çalışmanın geliştirilmesi için gerekli olan birkaç aşamadan oluşmaktadır. Şekil 1, önerilen sistem içindeki beyin tümörlerinin saptanmasında yer alan farklı aşamaları gösteren genel blok diyagramı göstermektedir.

Bu çalışmada, beyin tümörü türlerinden olan Glioma, Meningioma ve Pituitary içeren MR görüntü veri seti, açık erişimli Kaggle web sitesinden elde edilmiştir. Sağlanan veri setine uygun olarak belirtilen Evrişimli Sinir Ağları kullanılmış ve görüntü iyileştirmeleri gibi değişiklikler yapılarak giriş boyutları uyarlanmıştır. Bu veri setinde bulunan 708 adet Glioma, 708 adet Meningioma ve 708 adet Pituitary görüntüsü olmak üzere toplam 2124 adet MR görüntüsü derin öğrenme ağlarında eğitim ve test amacı ile kullanılmıştır. Makina öğrenmesinde kullanılacak tüm veriler belli bir nitelikte olmak zorunda olduğundan (Türk Radyoloji Derneği, 2018) standart kalite, çözünürlük, boyuttaki görseller ile eğitim ve test aşaması gerçekleştirilmiştir. Görüntülerin eğitimi için %70, test için ise %30

oranında ayrıştırma yöntemi uygulanmıştır (Litjens vd., 2017). Veri kümelerinin eğitim ve test için nasıl ayrıldığı, kullanacak modelin doğruluğunu ve genelleme yeteneğini etkileyebilmektedir. %70 eğitim ve %30 test ayırma yöntemi, oldukça yaygın bir uygulamadır ve genellikle iyi sonuçlar vermektedir. %70 - %30 oranı, genellikle modelin eğitimde daha fazla veri görmesini ve daha az veriyle test edilmesini sağlamaktadır. Bu, modelinizin eğitim sırasında genel yapıları ve desenleri daha iyi öğrenmesine yardımcı olmaktadır (Litjens vd., 2017).

Derin öğrenme ağı, beyin tümörlerinin MR görüntülerinden özellikler çıkararak öğrenecek şekilde inşa edilmiştir. Ağın amacı, her bir görüntüden elde edilen bu çıkarılan özelliklerden öğrenerek, beyin tümörleriyle ilişkili altta yatan kalıpları etkili bir şekilde yakalamak ve anlamak olacaktır. Bu özelliklerin anlamı, ağın tümör varlığını ya da türünü doğru bir şekilde tahmin etmesine yardımcı olmaktadır. Bu özelliklerin derin öğrenme ağı tarafından öğrenilmesi, hastalığın teşhisinde ve sınıflandırılmasında önemli bir rol oynamaktadır.




Şekil 1. Beyin Tümörünün Tespiti ve Sınıflandırılması için Genel Yapı Tasarımı.

Deneysel Sonuçlar

Çalışma, 64 GB RAM ve NVidia RTX 4000 Quadro ekran kartı donanımlarına sahip bir bilgisayarda Matlab uygulaması sürüm 2019b kullanılarak gerçekleştirilmiştir. Derin öğrenme ağının eğitim aşamasında, zaman alıcı olabilecek eğitim sürecinin tekrarlanmasını önlemek için model kaydedilmiştir. Ağların eğitimi, 55 yineleme ve 5 epokta 0,001 öğrenme oranıyla gerçekleştirilmiştir. Beklendiği gibi, doğruluk oranları her yinelemede giderek artarken, hesaplanan kayıp her yinelemeden sonra tutarlı bir şekilde azalmıştır.

Şekil 2 ResNet101 ağının döngü doğruluğu ve döngü kaybı grafiğini gösterirken Şekil 3 ise aynı ağın hata matrisini göstermektedir.



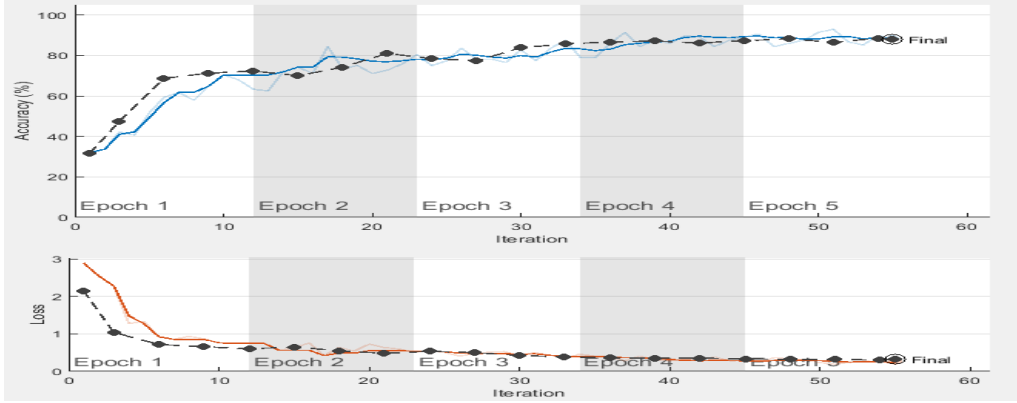
Şekil 2. ResNet101 Döngü Doğruluğu ve Döngü Kaybı Grafiği

Confusion Matrix					
Output Class	Glioma	181 28.5%	12 1.9%	1 0.2%	93.3% 6.7%
	Meningioma	26 4.1%	194 30.5%	4 0.6%	86.6% 13.4%
	Pituitary	5 0.8%	6 0.9%	207 32.5%	95.0% 5.0%
		85.4% 14.6%	91.5% 8.5%	97.6% 2.4%	91.5% 8.5%
		Glioma	Meningioma	Pituitary	
		Target Class			

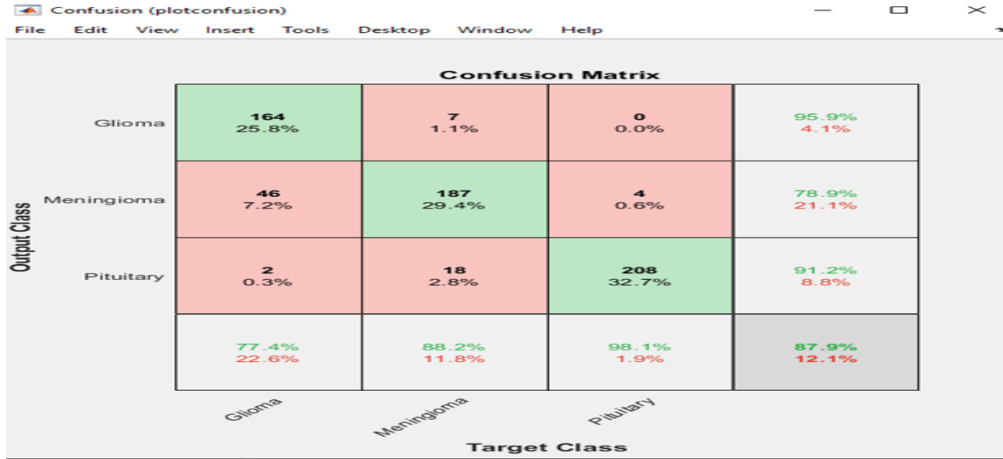
Şekil 3. ResNet101 Hata Matrisi

ResNet101 derin öğrenme ağının Şekil 3'te belirtilen hata matrisine göre, veri setinden %30 oranında test için ayrılmış MR görüntülerinden Glioma görüntülerini %93.3 doğruluk oranında, Meningioma görüntülerini %86.6 doğruluk oranında, Pituitary görüntülerini %95 doğruluk oranında ve genel olarak toplamda %91.5 doğruluk oranında verileri sınıflandırdığı görülmüştür.

Şekil 4 GoogLeNet ağının döngü doğruluğu ve döngü kaybı grafiğini gösterirken Şekil 5 ise aynı ağın hata matrisini göstermektedir.



Şekil 4. GoogLeNet Döngü Doğruluğu ve Döngü Kaybı Grafiği



Şekil 5. GoogLeNet Hata Matrisi

GoogLeNet derin öğrenme ağının Şekil 5'te belirtilen hata matrisine göre, veri setinden %30 oranında test için ayrılmış MR görüntülerinden Glioma görüntülerini %95.9 doğruluk oranında, Meningioma görüntülerini %78.9 doğruluk oranında, Pituitary görüntülerini %91.2 doğruluk oranında ve genel olarak toplamda %87.9 doğruluk oranında verileri sınıflandırdığı görülmüştür.

Hata matrisinde görüntülenecek doğruluğun tahmin edilmesi aşamasında aşağıda verilen formüle göre sınıflar için genel doğruluk hesaplanmıştır.

$$\text{Doğruluk} = \frac{\text{Doğru sınıflandırılan görüntü sayısı}}{\text{Toplam görüntü sayısı}} * 100\%$$

Doğrulukta eşitsizlik aslında veri kümesi içindeki parlaklık, aydınlatma ve genel görüntü kalitesi gibi görüntü özellikleri gibi faktörleri kapsayan değişikliklere atfedilebilir. Görüntülerdeki bu tutarsızlıklar modelin tahminlerinin doğruluğunu etkileyebilir. Çalışmada bahsedilen önemli bir husus, %70'inin eğitim veri kümesine ve %30'unun test veri kümesine ayrıldığı veri kümesi bölümüdür. Farklı eğitim ve test kümelerine yapılan bu ayırma, modelin görünmeyen veriler üzerindeki performansının değerlendirilmesine yardımcı olur ve böylece genelleştirme yeteneklerinin daha doğru bir şekilde değerlendirilmesini sağlar.

Hata matrisinde görülen her bir sınıfın doğruluğunun özetlenmesi ve sınıf sayısına bölünmesiyle hesaplanan genel doğruluk oranı ResNet101 ağı için %91.5 ve GoogLeNet ağı için %87.9 doğruluk oranıyla sonuçlanmıştır. Bu genel doğruluk ölçüsü, kullanılan modelin tüm sınıflardaki örnekleri doğru şekilde sınıflandırma yeteneğini göstermektedir.

Tartışma

Bilginin en önemli değer olarak tanımlandığı günümüz dünyasında dijital teknolojiler son derece büyük bir hızla gelişim kaydetmekte ve hayatın her alanına sirayet etmektedir. Özellikle insan unsurunun kırılabilir ve zayıf olduğu sektörlerde insana alternatif olabilmesi bakımından önemli bir dönüşüm yaratan dijital teknolojiler, yapısal dinamikleri nedeniyle sağlık sektöründe de kendisine önemli bir yer edinmiştir. İş yükü fazlalığı, nitelikli insan ihtiyacı, tanı ve teşhis aşamalarında yaşanan insan hataları gibi sebepler, dijital teknolojilerin sağlık sektöründe kullanım yaygınlığının artmasına neden olmuştur. Bu çalışmada yapay zekâ teknolojilerinin sağlık sektöründe kullanımı noktasında ResNet101 ve GoogLeNet derin öğrenme ağları incelenmiş, farklı beyin tümörü türlerinde görsel çözümleme yoluyla ilgili derin öğrenme ağların tanı başarısı belirlenmeye çalışılmıştır.

Çalışma neticesinde elde edilen bulgu ve katkılar aşağıda sunulmaktadır:

- Çalışma kapsamında her bir beyin tümörü türü için 708 toplamda ise 2124 adet açık kaynak beyin tümörü MR görüntüsünden istifade edilmiştir. Hem ResNet101 hem de GoogLeNet aynı veri setleriyle sinanmış ve ağların eriştikleri başarı seviyeleri tespit edilmiştir. Bu bağlamda veri ayırıştırma, ayıklama ve tanıda bulunma noktasında kullanılan her iki derin öğrenme ağıda (%88-%91 oranında) başarı kaydetmiştir. Elde edilen bu sonuç, yapay zekânın (derin öğrenme) beyin tümörlerinin tanısında kullanılabilir bir araç olduğunu ortaya koymakta ve araştırma sorularından ilkinin cevap teşkil etmektedir. Bu noktada Beyin Tümörlerinin MR görüntüleri kullanılarak derin öğrenme ağları (ResNet101 ve GoogLeNet) vasıtasıyla tanı ve tespitinin mümkün olduğu belirlenmiştir.
- Çalışma bağlamında üzerinde durulan bir husus da, hangi derin öğrenme ağının, beyin tümörlerinin tanısında daha başarılı olduğudur. Bu doğrultuda sunulan görüntüleri tanımlama, ayırıştırma ve doğru tanıda bulunma noktasında %91.8 oranla ResNet101 ağının daha başarılı olduğu tespit edilmiştir. Elde edilen bu değer bu çalışma özelinde erişilen başarı olduğu önemle vurgulanmalıdır. Söz konusu tespit araştırmanın ikinci sorusuna cevap niteliğindedir. Bu çalışma özelinde beyin tümörlerinin tespitinde ResNet101 derin öğrenme ağının başarı düzeyinin daha yüksek olduğu bulgulanmıştır.

Sağlık sektörü, insan hayatını odağa alması bakımından son derece önemli role sahip olan bir sektör olarak tanımlanabilir. Yapısal dinamikleri bakımından hataya ya da ertelemeye yer olmayan sağlık sektöründe, taleplere zamanında ve kusursuz bir biçimde cevap verebilmek çok kolay değildir. Özellikle nitelikli insan kaynağına diğer bütün sektörlerden daha fazla ihtiyaç duyan sağlık sektöründe insan faktörüne alternatif olacak dijital teknolojiler son derece önemlidir. Söz konusu durumun ehemmiyeti dünya sağlık örgütü tarafından da vurgulanmaktadır. Bu noktada artan insan nüfusu, çevresel etkenlerin neden olduğu kronik

hastalıklar, yaş ortalamasının giderek artması gibi nedenler dolayısıyla sağlık sektöründe nitelikli insan talebinin karşılanamayacak duruma gelmesi ve küresel anlamda sağlık sisteminde bir çöküşün yaşanabileceği ileri sürülmektedir (WHO, 2022). Dolayısıyla nitelikli insan kaynağı sorununa, teşhis sürecinin kısalmasına, teşhis hatalarının azaltılmasına çözüm sunması bakımından yapay zekâ teknolojilerinin sağlık sektöründe yaygın olarak kullanılması önemlidir. Bu araştırma beyin tümörü türleri özelinde yürütülmüş, erişilen bulgular ve derin öğrenme modellerinin başarıları bu kısıtlılık çerçevesinde ortaya koymuştur. Yine bu araştırmada her bir beyin tümörü türü için 708 adet veri kullanılmak suretiyle analizler gerçekleştirilmiştir. Söz konusu bu rakamların son derece kısıtlı rakamlar olduğu vurgulanmalı ve derin öğrenme eğitimlerinin başarı düzeylerinde işlenen görüntü sayılarının son derece önemli olduğu ifade edilmelidir. Artan eğitim görüntüsü derin öğrenme ağlarının hata oranının azalmasına, dolayısıyla başarı oranının artmasına neden olmaktadır. Bu bağlamda gelecekte yapılacak çalışmaların daha fazla görüntü ve farklı veri setleriyle yapılması önerilmekte, farklı çalışmalarca elde edilecek bulguların, ilgili literatürün zenginleşmesine önemli katkı sunacağı düşünülmektedir.

Kaynakça

- Abd El Kader, I., Xu, G., Shuai, Z., Saminu, S., Javaid, I. ve Salim Ahmad, I. (2021). Differential deep convolutional neural network model for brain tumor classification. *Brain Sciences*, 11(3), 352.
- Afshar, P., Plataniotis, K. N. ve Mohammadi, A. (2019). *Capsule networks for brain tumor classification based on MRI images and coarse tumor boundaries*. In ICASSP 2019-2019 IEEE international conference on acoustics, speech and signal processing (ICASSP), 1368-1372.
- Akalin, B. ve Veranyurt, U. (2021). Sağlık hizmetleri ve yönetiminde yapay zeka. *Acta Infologica*, 5(1), 231-240.
- Amin, S. E. ve Megeed, M. A. (2012). *Brain tumor diagnosis systems based on artificial neural networks and segmentation using MRI*. In 2012 8th International Conference on Informatics and Systems (INFOS), 102-119.
- Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ... ve Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82-115.
- Chan, T. H., Jia, K., Gao, S., Lu, J., Zeng, Z. ve Ma, Y. (2015). PCANet: A simple deep learning baseline for image classification?. *IEEE Transactions on Image Processing*, 24(12), 5017-5032.
- Ekrem, Ö., Salman, O. K. M., Aksoy, B. ve İnan, S. A. (2020). Yapay zeka yöntemleri kullanılarak kalp hastalığının tespiti. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(5), 241-254.
- Goswami, S. ve Bhaiya, L. K. P. (2013). *Brain tumour detection using unsupervised learning based neural network*. In 2013 International Conference on Communication Systems and Network Technologies, 573-577.
- Hazra, A., Dey, A., Gupta, S. K. ve Ansari, M. A. (2017). *Brain tumor detection based on segmentation using MATLAB*. In 2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS), 425-430
- İlçe, A., Totur, B. ve Özbayır, T. (2010). Beyin tümürlü hastaların uluslararası NANDA hemşirelik tanılarına göre değerlendirilmesi: Bakım önerileri. *Journal of Neurological Sciences*, 27(2), 178-184.
- Jmour, N., Zayen, S. ve Abdelkrim, A. (2018). *Convolutional neural networks for image classification*. In 2018 international conference on advanced systems and electric technologies (IC_ASET), 397-402.
- Kaplan, H. I. ve Sadock, B. J. (2003). *Brain tumors*. In: Synopsis of Psychiatry, Robert Cancro, James Emondson (editors). Ninth ed., Baltimore: Williams & Wilkins, 260-261.
- Kaur, R. ve Doegar, A. (2019). Localization and classification of brain tumor using machine learning & deep learning techniques. *International Journal of Innovative Technology and Exploring Engineering (IJITEE)*, 8(9), 2278-3075.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... ve Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60-88.
- Moon, W. K., Huang, Y. S., Hsu, C. H., Chien, T. Y. C., Chang, J. M., Lee, S. H., ... ve Chang, R. F. (2020). Computer-aided tumor detection in automated breast ultrasound using a 3-D convolutional neural network. *Computer Methods and Programs in Biomedicine*, 190, 105360.
- Nazli, B. (2021). *Evaluation of different machine learning algorithms for classification of sleep apnea*. In 2021 29th Signal Processing and Communications Applications Conference (SIU), 1-4.
- Ouyang, W., Wang, X., Zeng, X., Qiu, S., Luo, P., Tian, Y. ve Tang, X. (2015). *Deepid-net: Deformable deep convolutional neural networks for object detection*. In Proceedings of the IEEE conference on computer vision and pattern recognition, 2403-2412.
- Reynolds, D. A. (2009). Gaussian mixture models. *Encyclopedia of Biometrics*, 741, 659-663.
- Rish, I. (2021). An empirical study of the naive Bayes classifier. *IJCAI 2001 Workshop on Empirical Methods in Artificial Intelligence*, 3(22), 41-46.
- Sakem, M. (2020). *Çölyak hastalığının teşhis edilmesi ve sınıflandırılmasında yapay zekâ algoritmalarının kullanılması* [Yayınlanmamış Doktora tezi]. Sakarya Üniversitesi.
- Shao, Y. E., Hou, C. D. ve Chiu, C. C. (2014). Hybrid intelligent modeling schemes for heart disease classification. *Applied Soft Computing*, 14, 47-52.
- Shia, W. ve Chen, D. (2020). Using deep residual networks for malignant and benign classification of two-dimensional Doppler breast ultrasound imaging. *Cancer Research*, 80(4), 2-10.
- Shrutika, S., Akshata, R. ve Swati, K. (2017). *Implementation of image processing for detection of brain tumors*. In International Conference on Intelligent Computing and Control Systems.
- Sun, W., Zheng, B. ve Qian, W. (2017). Automatic feature learning using multichannel ROI based on deep structured algorithms for computerized lung cancer diagnosis. *Computers in Biology and Medicine*, 89, 530-539.
- Talo, M. (2019). *Pneumonia Detection from Radiography Images using Convolutional Neural Networks*. In 2019 27th Signal Processing and Communications Applications Conference (SIU), 1-4.
- Tiwari, A., Srivastava, S. ve Pant, M. (2020). Brain tumor segmentation and classification from magneticresonance images: Review of selected methods from 2014 to 2019. *Pattern Recognition Letters*, 131, 244- 260.
- Türk Radyoloji Derneği (2018). *MRG ve BT İnceleme standartları*. <https://www.turkrad.org.tr/assets/DernektenHaberler-Pdf/STANDARTLAR2018.pdf> (Erişim Tarihi: 11.10.2023).
- Urban, G., Bendszus, M., Hamprecht, F. ve Kleesiek, J. (2014). *Multi-modal brain tumor segmentation using deep convolutional neural networks. MICCAI BraTS (brain tumor segmentation) challenge*. Proceedings, winning contribution, 31-35.
- Vakanski, A., Xian, M. ve Freer, P. E. (2020). Attention-Enriched deep learning model for breast tumor segmentation in ultrasound images. *Ultrasound in Medicine & Biology*, 46(10), 2819-2833.
- Vieira, S., Pinaya, W. H. L. ve Mechelli, A. (2017). Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications. *Neuroscience and Biobehavioral Reviews*, 74, 58-75.
- Yenikaya, M. A. (2022). *Optik Koherens tomografi görüntülerinden yaşa bağlı makular dejenerasyon tiplerinin yapay zekâ kullanılarak tespiti* [Yayınlanmamış Doktora Tezi]. Maltepe Üniversitesi.
- Yıldız, K. T. (2021). *Hematolojik hastalıkların teşhisinde yapay zeka tekniklerinin performans karşılaştırması* [Yayınlanmamış Yüksek Lisans Tezi]. Sakarya Üniversitesi.
- World Health Organization—Cancer. Available online: <https://www.who.int/news-room/fact-sheets/detail/cancer>. (accessed on 19 November 2023).
- Yardımcı, A. (2009). *Applications of soft computing to medical problems*. In 2009 Ninth International Conference on Intelligent Systems Design and Applications, 614-619.