



Makale / Research Paper

Açıklanabilir Evrişimsel Sinir Ağları ile Beyin Tümörü Tespiti

Abdullah ORMAN^a, Utku KÖSE^{b*}, Tuncay YİĞİT^c

^aAnkara Yıldırım Beyazıt Üniversitesi, Meslek Yüksekokulu, Bilgisayar Teknolojileri Bölümü, Ankara/TÜRKİYE

^{b,c}Süleyman Demirel Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Isparta/TÜRKİYE
utkukose@sdu.edu.tr

Received/Geliş: 21.04.2021

Accepted/Kabul: 08.07.2021

Öz: Derin öğrenme teknikleri özellikle 2000'li yılların başından bu yana yapay zeka alanının en önemli temsilcileri olarak bilinmektedir. Bu teknikler birçok farklı alanda yaygın bir biçimde kullanılıyor olsa da özellikle sağlık alanındaki başarılı performansları dikkatleri daha çok çekmektedir. Ancak bu tekniklerin geleneksel makine öğrenmesi tekniklerine göre çok daha fazla sayıda parametrelerle optimize ediliyor olması, çözüm süreçlerinin karmaşık olmasına ve insan taraflı algı düzeyine kapalı olmalarına sebep olmaktadır. Bu sebeple kara-kutu olarak da adlandırılan derin öğrenme tekniklerden oluşan zeki sistemleri insan gözünde güvenilir yapmak ve söz konusu sistemlerin sınırlılıklarını ya da hata yapma eğilimlerini anlayabilmek adına alternatif çalışmalar gerçekleştirilmeye başlanmıştır. Gelişmeler neticesinde açıklanabilir yapay zeka olarak adlandırılan bir alt-alanın doğmasına yol açan çözümler, derin öğrenme tekniklerinin sunduğu çözümlerin güvenli olup olmadığının anlaşılmasına olanak sağlamaktadır. Bu çalışmada, beyin tümörü tespiti için bir Evrişimsel Sinir Ağları (ESA) modeli kullanılmış ve modelin güvenlik düzeyi, Sınıf Aktivasyon Haritalama (SAH / CAM: Class Activation Mapping) destekli açıklanabilir bir modül üzerinden anlaşılabilmiştir. Geliştirilen ESA-SAH sistemi, hedef veri seti üzerindeki uygulama sürecinde ortalama %96,53 doğruluk, %96,10 duyarlılık ve %95,72 özgüllük sağlamıştır. Yine doktorların sistemdeki SAH görsellerine ve genel sistem performansına yönelik sundukları dönütler de ESA-SAH tabanlı çözümün pozitif yönde kabul edildiğini göstermiştir. Bu bulgular, ESA-SAH sisteminin tümör tespitinde güvenilir ve anlaşılır olduğunu ortaya koymaktadır.

Anahtar Kelimeler: Evrişimsel sinir ağları; açıklanabilir yapay zeka; beyin tümörü; derin öğrenme.

Brain Tumor Detection via Explainable Convolutional Neural Networks

Abstract: Especially since the early 2000s, deep learning techniques have been known as the most important actors of the field of artificial intelligence. Although these techniques are widely used in many different areas, their successful performance in the field of healthcare attracts more attention. However, the situation that these techniques are optimized with much more parameters than traditional machine learning techniques causes complex solution processes and they become opaque against human-sided perception level. For this reason, alternative studies have been carried out in order to make such black-box intelligent systems consisting of deep learning techniques reliable and understandable in terms of their limitations or error-making tendencies. As a result of the developments, the solutions that led to the introduce of a sub-field called as explainable artificial intelligence allow understanding whether the solutions offered by deep learning techniques are safe. In this study, a Convolutional Neural Networks (CNN) model was used for brain tumor detection and the safety level of that model could be understood through an explanatory module supported by the Class Activation Mapping (CAM). For the application process on the target data set, the developed CNN-CAM system achieved an average accuracy of 96.53%, sensitivity of 96.10% and specificity of 95.72%. Also, feedback provided by the doctors regarding the CAM visuals and the overall system performance showed that the CNN-CAM based solution was accepted positively. These findings reveal that the CNN-CAM system is reliable and understandable in terms of tumor detection.

Keywords: Convolutional neural networks; explainable artificial intelligence; brain tumor; deep learning.

Bu makaleye atıf yapmak için

Orman, A., Köse, U., Yiğit, T., "Açıklanabilir Evrişimsel Sinir Ağları ile Beyin Tümörü Tespiti" El-Cezeri Fen ve Mühendislik Dergisi 2021, 8 (3); 1323-1337.

How to cite this article

Orman, A., Köse, U., Yiğit, T., "Brain Tumor Detection via Explainable Convolutional Neural Networks" El-Cezeri Journal of Science and Engineering, 2021, 8 (3); 1323-1337.

ORCID ID: ^a0000-0002-3495-1897; ^b0000-0002-9652-6415; ^c0000-0001-7397-7224

1. Giriş

Yapay zeka, bilim dünyasında yer edindiği ilk zamanlardan bu yana birçok farklı gelişim evresinden geçmiştir. Geliştirilen yapay zeka tekniklerinin etkinliği dışında, problem verilerinden öğrenerek yeni senaryolara hazır hale getirilebilen ve makine öğrenmesi (yapay öğrenme / machine learning) adı verilen alt-alan kapsamındaki tekniklerin birçok farklı probleme karşı kazandıkları başarılar sıklıkla dikkatleri çekmiştir [1-10]. Temelinde veri manipülasyonlarına duyarlı matematiksel ve mantıksal mekanizmaların çeşitli parametreleri optimize etmesi suretiyle, hedef veriye adaptasyon sağlamaya dayanan makine öğrenmesi algoritmaları, özellikle 2000'li yıllarda yaşanan teknolojik gelişmelere (donanımsal ve yazılımsal ilerlemeler) uyum sağlayarak, daha gelişmiş formlara kavuşmuştur [11-13]. Özellikle büyük ve karmaşık verilerle baş edebilme noktasında geleneksel makine öğrenmesi algoritmalarından daha etkin sonuçlar üretebilen yeni algoritmalar (teknikler) artık derin öğrenme adı altında incelenmektedir [14-16]. Derin öğrenme artık günümüzün en etkili yapay zeka çözümü olarak kabul edilmektedir.

Derin öğrenme, günümüzde standart yapay sinir ağları mimarilerinin geliştirilmesi suretiyle oluşturulmuş tekniklerden oluşmaktadır. Söz konusu teknikler, farklı problem alanlarının ortaya çıkardığı ihtiyaçlar ve alternatif çözüm mekanizmaları neticesinde tasarlanmıştır. Özünde veri ön-işleme ihtiyaçlarını da giderme yönünde uzmanlaşmış katmanlardan oluşan derin öğrenme teknikleri, insan odaklı veri işlemeyi kolaylaştırması (hatta ortadan kaldırması) bakımından oldukça kritik öneme sahiptir [17, 18]. Bu durum her türden verinin yapay zeka modellerinde etkin kullanımını sağlamıştır. Örneğin, görüntü işleme kendi özünde etkin bir alan olarak bilinirken, derin öğrenme ile yapay zeka literatürüyle tam bir entegrasyon içerisine de girmiştir [19-21]. Bu noktada, yaygınlığı en çok bilinen tekniklerden biri de Evrişimsel Sinir Ağları (ESA / CNN: Convolutional Neural Networks) olarak bilinmektedir [22, 23]. ESA modelleri özellikle entegre özellik çıkartım mekanizmaları ve birincil öncelikte görüntü tabanlı verilere dayalı tasarlanmış katman yapıları sayesinde görüntüye dayalı problemlerde etkin bir biçimde kullanılagelmiştir [24-26]. Geleneksel yapay sinir ağlarında yer alan ortak görevde çalışan katmanlardan [27, 28] farklı olarak, ESA modellerinin spesifik katman yapıları veriler üzerinde daha etkin analiz süreçleri oluşturabilmektedir. Bu nedenle özellikle sağlık alanı gibi yapay zeka ile yakın ilişkideki (kritik) alanlarda ESA modellerinin uygulanması oldukça yaygındır. ESA modellerinin sağlık alanında özellikle hastalık teşhisi süreçlerinde oldukça etkili bir biçimde kullanılabildiği, hatta doktorlara ve görüntüleme uzmanlarına göre daha hassas, hatta erken tespitlerde bulunabildikleri sıklıkla rapor edilmektedir [29-32]. Yine güncel problemlerin çözülmesinde, ilaç, tedavi tasarlanması ve daha birçok sağlık yönelimli konularda ESA modellerinin etkin bir biçimde kullanıldığı görülmektedir [33-39].

ESA tekniği ve farklı derin öğrenme teknikleri yapay zeka uygulamalarının sağlık alanındaki başarılarını hızlı bir şekilde artırmaktadır. Ancak günümüz koşulları altında incelendiğinde, derin öğrenme tekniklerinin tasarlanabilmesine imkan sağlayan ve zaman konusunda insanlara avantaj sağlayan teknolojiler bir kenara bırakıldığında; söz konusu derin öğrenme modellerinin çözüm mekanizmalarının insan algısının ötesine geçtiği de görülmektedir. Normal şartlarda geleneksel makine öğrenmesi algoritmalarında tespiti ve takibi daha kolay olan; nispeten az sayıdaki parametre, derin öğrenme teknikleriyle devasa boyutlara çıkmıştır. Tipik bir ESA modelinin tasarimsal yapısına bağlı olarak yüzlerce (hatta binlere) ulaşan parametre sayıları, ağ tabanlı sistemlerdeki çözüm hengesini arasında takip edilebilirliklerini iyiden iyiye kaybetmektedir. Dolayısıyla derin öğrenme teknikleri çözüm üretirken hangi parametrelerin ne yönde değiştiği konusunda insan algı düzeyine karşı kara kutu (black-box) seviyesine ulaşmış durumdadır [40-42]. Daha genel anlamda makine öğrenmesi çözümleri olan söz konusu derin öğrenme tekniklerinin kara-kutu olması durumu kısaca giriş verilerinden çıkış verilerine (yani karara) ulaşırken hangi mekanizmaları işlettiklerinin insanlar (kullanıcılar) tarafından takip edilememesi (anlaşılamaması)

anlamına gelmektedir. Böyle bir durumda derin öğrenme teknikleriyle tasarlanan zeki sistemlerin kararlarında şansın ne kadar olduğu, sınırlarının neler olduğu, hata yaptıklarının ne zaman anlaşılacağı ve hatta veri odaklı önyargı (bias) oluşturup oluşturmadıkları gibi hususlar cevapsız kalabilmektedir [43, 44]. Bu durum sağlık alanı gibi kritik bir uygulama alanı düşünüldüğünde kara-kutu derin öğrenme tekniklerinin anlaşılabilir olmasını sağlamak adına çeşitli araştırma çalışmalarının gerçekleştirilmesine sebep olmuştur. Geleneksel makine öğrenmesi teknikleri için yorumlanabilir olma olarak da lanse edilen anlaşılabilirlik düzeyi, derin öğrenme tekniklerine alternatif entegrasyonların tasarlanmasıyla sağlanabilmiş, nihayetinde bu kapsamda gerçekleştirilen çalışmalar da açıklanabilir yapay zeka (XAI: explainable artificial intelligence) olarak adlandırılan bir araştırma alt-alanının oluşmasına sebep olmuştur [45, 46]. Söz konusu alt-alan, geleneksel makine öğrenmesi tekniklerinde (örneğin, kNN, karar ağaçları, bayes tabanlı teknikler) görülen yorumlanabilirlik faktörünü genişletmekte ve mevcut çözümlere entegrasyonlarla; insan algısı seviyesine incek modeller tasarlanmasını mümkün hale getirmektedir [47]. Özellikle 2010'lu yıllardan bu yana önemini artıran açıklanabilir yapay zeka alanı, alternatif uygulamalarla popüleritesini giderek artırmaktadır. Bu durum özellikle güvenliği ve etikliği tartışılan yapay zekanın geleceği için de önem arz etmektedir [47, 48].

Bu çalışmanın amacı, derin öğrenme süreçlerinin etkin bir biçimde uygulanabildiği görüntü tabanlı bir teşhis problemi olan beyin tümörü tespiti için açıklanabilir bir Evrişimsel Sinir Ağları (ESA) modeli ortaya koymaktır. Derin öğrenme teknikleri ve özellikle ESA, farklı görüntü verileri (MRI, CT, ultrason...vs.) üzerinden hastalık teşhisleri ve özellikle tümör / kanser teşhisi araştırmalarında oldukça yaygın kullanılmaktadır [49-53]. Bu noktada özellikle beyin tümörü tespiti ile ilgili çalışmalar da son yıllarda oldukça büyük bir ivme kazanmıştır [54-56]. Bu çalışma kapsamında ilgili ESA modeli, beyin taramalarının olduğu veri seti üzerinde başarı oranı yüksek bir şekilde organize edilmiş (bilinen metriklerle değerlendirilmiş), ardından kara-kutu düzeyindeki bu modelin görüntü verileri üzerinde hangi alanlara odaklanarak çıktı kararı verildiğini gösteren Sınıf Aktivasyon Haritalama (SAH / CAM: Class Activation Mapping) yöntemiyle desteklenerek nispeten insan algısına açık bir seviyeye taşınması sağlanmıştır. Kısaca ESA-SAH olarak adlandırılan bu modelin güvenli ve anlaşılır olup olmadığını anlamak adına SAH ile üretilen ısı haritalarına bakılmış ve yine toplam 10 doktorun görüşüne başvurulmuştur.

Çalışmanın amaç ve kapsamından hareketle ilerleyen bölümler şu şekilde organize edilmiştir: Bir sonraki bölüm altında ilgili açıklanabilir ESA modelinin (ESA-SAH) oluşturulması aşamasında kullanılan teknikler ve yine işe koşulan veri seti ile uygulama düzeneği anlatılmıştır. Bu bölümü takiben üçüncü bölüm altında ilgili uygulama süreçleri ve elde edilen bulgular, değerlendirme süreçleriyle birlikte ortaya konulmuş, dördüncü bölüm altında da çalışma ile ulaşılan sonuçlar tartışılmıştır. Metin, süreç ile elde edilen sonuçların ve çeşitli önerilerin açıklandığı son bölüm ile desteklenmiştir.

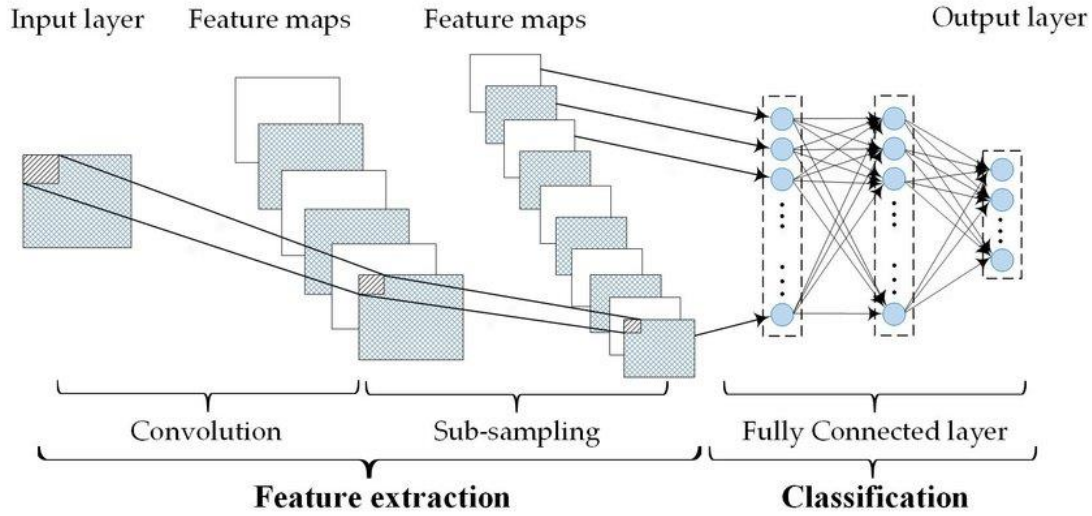
2. Materyal ve Metot

Bu bölüm altında söz konusu ESA-SAH modelinin oluşturulması aşamasında faydalanılan ESA modeli ve açıklanabilirlik düzeyini oluşturan SAH çözümü irdelenmiş, akabinde beyin tümörü tespiti uygulamasına konu olan veri seti ve genel uygulama düzeneği genel olarak açıklanmıştır.

2.1. Evrişimsel Sinir Ağları (ESA)

Evrişimsel Sinir Ağları (ESA), derin öğrenme kapsamında yaygın bir kullanım alanı olan, sağlık alanındaki uygulamalarla da ön plana çıkan gelişmiş bir sinir ağları tekniği olarak bilinmektedir. Geleneksel makine öğrenmesi içerisindeki yapay sinir ağları (YSA) tekniğinden farklı olarak ESA tekniğinde geliştirilen modeller, birbirine bağlı yapay nöronların (algılayıcı / perceptron) yoğun bir

biçimde kullanımından ziyade, girdi verisinden etkin bir biçimde özellik çıkartımı mekanizmasında uzmanlaşmış özel katman yapılarından oluşmaktadır [13, 14]. Nihayetinde problem çözümüne göre tam bağlantılı (fully connected) katman yapısıyla sonlandırılan ESA modellerinin, çözüm mekanizmaları özellikle görüntü verileri üzerinde uygulamalarla daha iyi anlaşılır olan evrişimsel katman (convolutional layer), havuzlama katmanı (pooling layer), düzleştirme katmanı (flattening layer) gibi katmanlarla tasarlanması sağlanmaktadır [13-15, 57] (Şekil 1). Yine literatürdeki gelişmelerle alternatif katman yapılarıyla da desteklenen ESA tekniğinin temel felsefesinin, gerçek dünyada görsel unsurları özellik benzeştirmeleriyle algılayan, canlılardaki görsel algılama süreçlerinin bir tür sayısal esinlenmesine dayandığını ifade etmek mümkündür. Bu bağlamda, evrişimsel katmanlar farklı filtrelerin uygulanması suretiyle giriş verisindeki alternatif özelliklerin algılanmasını sağlamakta (yine YSA'ya alternatif olarak ReLU gibi aktivasyon fonksiyonlarından güç almakta), havuzlama katmanı algılanan özelliklerin optimum seviyeye indirgenmesinde rol oynamakta, düzleştirme katmanları ise geleneksel YSA modellerinden gelen ve çıktıyı üretmekle görevli tam bağlantılı katman için veriyi düzenleme görevlerini yerine getirmektedir [14, 15, 58]. Böylelikle geleneksel makine öğrenmesi ve özellikle YSA modellerinde ihtiyaç duyulan özellik çıkartımı süreçlerinin esasında ESA'nın kendi içerisinde çözümlenmesini de içeren ve bu noktada elde edilen verinin her karışına daha detaylı odaklanarak daha etkin çözüm üreten bir sinir ağları modeli elde edilmektedir [58-60]. ESA modellerinin sahip oldukları mekanizmaları itibariyle eğitim süreçleri çok daha fazla zaman almakta, ancak elde edilen sonuçlar nedeniyle ve günümüz hesaplama teknolojilerinin söz konusu zamanı makul düzeylere çekebilme yeterlikleri sayesinde ESA tekniği derin öğrenmeyi yaygın hale getiren önemli tekniklerden biri olmuştur.



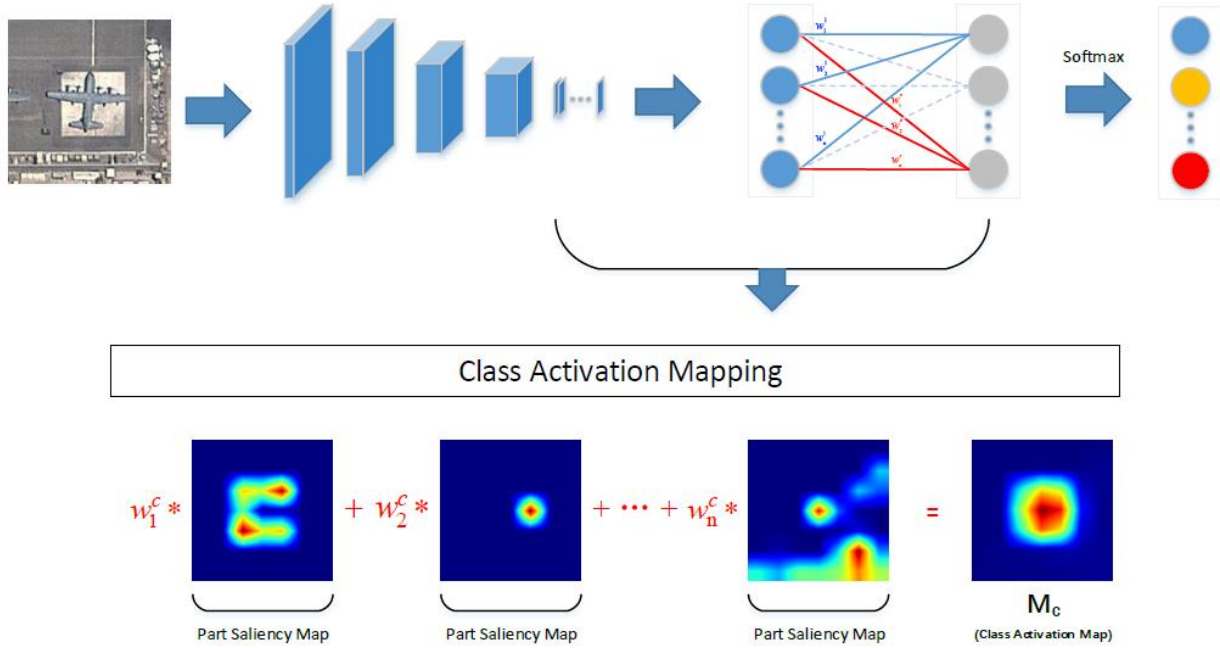
Şekil 1. Tipik bir Evrişimsel Sinir Ağları (ESA) model yapısı [57].

ESA modelleri özellikle geleneksel YSA modellerine göre hem hesap karmaşıklığını azaltmak hem de daha zorlu verilere (özellikle görüntü verilerine) karşı daha başarılı çözümler üretebilme noktasında etkili mekanizmalar işletmektedir. Ancak bütün bu süreç, geleneksel YSA modellerine göre daha fazla parametrenin optimize edilmesi gerektiği, daha kapsamlı ve algı düzeyi zor matematiksel yapıların oluşmasına da sebep olmaktadır. Geleneksel YSA modellerinde (örneğin, çok katmanlı algılayıcı / MLP) bile daha karmaşık yapılar daha zorlu anlaşılabilirliğe sebep oluyorken, bu durum derin öğrenme tarafında ve dolayısıyla ESA modellerinde kara-kutu yapıların oluşmasına sebep olmaktadır. Kısaca kara-kutu durumu, bir ESA modelinde giriş verisine göre üretilen çıktının (kararın) hangi bağlantılar kurularak elde edildiğinin anlaşılabilmesi durumuyla ifade edilebilmektedir. Sağlık alanı düşünüldüğünde, nasıl ki doktorlar ya da radyologlar bir görüntü verisi üzerinden teşhise / tespiti nasıl ulaştıklarını açıklayabiliyorlarsa, ESA gibi bir derin öğrenme modelinin de bu durumu insan tarafına anlatabilmesi ve böylelikle insan-zeki sistem arasında istendik düzeyde bir güven seviyesinin oluşmasına destek olması gerekmektedir. Bu seviye,

kullanılan zeki sistemin sınırlılıklarını ya da hata yaptığı zamanları anlayarak, insanların gereken aksiyonları almasına da sebep olabilecektir. Söz konusu ihtiyaçtan hareketle açıklanabilir yapar zeka olarak adlandırılan alt-alan kapsamında ESA modellerine entegre edilebilen çeşitli teknikler geliştirilmiştir. Sınıf Aktivasyon Haritalama tekniği bu tekniklerden biri olarak bilinmektedir.

2.2. Sınıf Aktivasyon Haritalama (SAH) ile Açıklanabilir Yapay Zeka

Görüntü tabanlı veriler üzerinde çalışan derin öğrenme tekniklerini açıklanabilir düzeye getirmek için temel olarak hedef tekniğin içerisine çeşitli entegrasyonlar gerçekleştirilmektedir. Bu yaklaşım, yorumlanabilir (interpretable) olduğunu bilinen geleneksel makine öğrenmesi tekniklerinin hibrit oluşum içerisinde kullanımıyla [47, 61] ya da var olan sinir ağları modelindeki birtakım matematiksel süreçlerin ek çözümlerle desteklenerek giriş verisi üzerinde anlamlı görseller bırakacak şekilde sonuçlar elde edilmesi yoluyla çözülebilmektedir. İkinci çözüm süreci için Sınıf Aktivasyon Haritalama (SAH / CAM: Class Activation Mapping) sıklıkla tercih edilen tekniklerden biri olarak bilinmektedir. Söz konusu teknik, ağırlıklı özellik haritalarının, farklı sınıf sonuçları doğrultusunda bir araya toplanarak, aktivasyon haritaları oluşturulması ve bu haritaların giriş verisi üzerinde modelin odaklandığı görsel bölgeleri gösterecek şekilde bir bakıma ısı haritası (heat map) gösterimiyle kullanıcıya yansıtılmasına imkan sağlamaktadır [62] (Şekil 2).



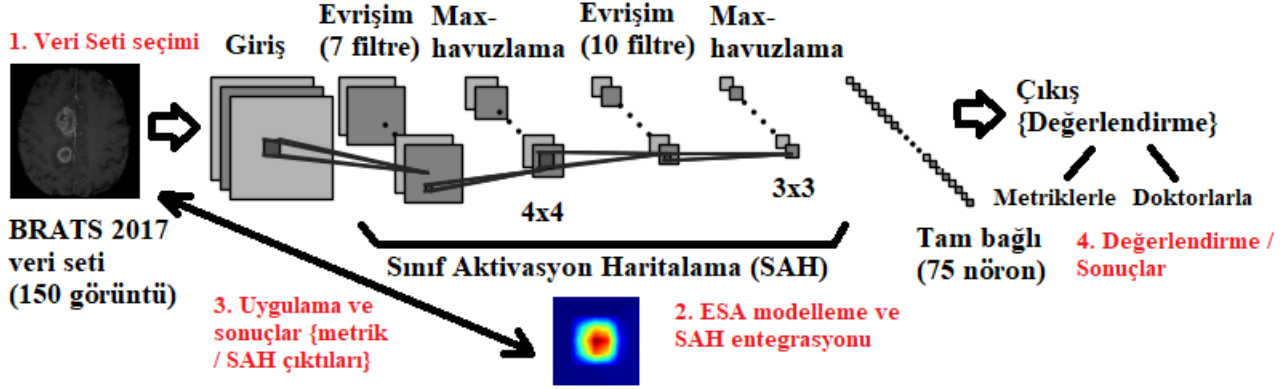
Şekil 2. Sınıf Aktivasyon Haritalama (SAH / CAM: Class Activation Mapping) tekniğinin çalışma mekanizması [62].

Açıklanan süreç, bu çalışmada tümör tespiti için kullanılan ESA modelinde giriş görüntüleri üzerinde özellikle tümörlü bölgelere odaklanma sağlanıp sağlanmadığı konusunda bilgi sağlayabilecek yeterlikte olduğu için ESA modeline entegre edilmiştir. Böylelikle kısaca ESA-SAH olarak adlandırabileceğimiz sistem yapısı oluşturulmuştur. Şekil 3 ESA-SAH modelinin genel mimarisini ve yine takip edilen araştırma sürecini göstermektedir.


2.3. Beyin Tümörü Tespiti İçin Veri Seti ve Uygulama Düzeni

Çalışmaya konu olan beyin tümörü tespiti sürecinde, literatürde bir süredir gerçekleştirilen Multimodal Brain Tumor Segmentation Challenge etkinliği kapsamında da araştırmacılara sunulan ve kısaca (BRATS) olarak adlandırılan veri setinin 2017 versiyonu [63, 64] kullanılmıştır. Veri seti

toplamda 285 MR görüntüsünden oluşmakta her farklı bireye ait görüntü taraması T1, T1ce, T2 ve Flair beyin görüntüleriyle sunulmaktadır (Şekil 4). Çalışma kapsamına veri setinden toplam 150 görüntü dahil edilmiştir. Bu noktada 150 görüntü uzman görüşleri ekseninde oluşturulmuş; böylelikle dengeli görüntü dağılımı (örneğin ağır veya hafif teşhislerin eşit sayıda olması) sayesinde önyargıyı engelleyecek bir eğitim-test setinin oluşturulması sağlanmıştır.



Şekil 3. Oluşturulan ESA-SAH mimarisi ve genel araştırma süreci.



Şekil 4. BRATS 2017 veri setinden örnek beyin MR görüntüleri [63, 64].

Veri seti kapsamında uygulamaya konu olan ESA modeli ise kısaca şu şekilde organize edilmiştir: Model yapısı 6 katman içermekle beraber ilk katman giriş katmanı olarak düzenlenmiş, ikinci katman 7 adet evrişim filtresi kullanılan bir evrişim süreci üzerine kurulmuş, akabinde bu evrişim katmanı havuzlama katmanı ile (4x4'lük boyutta) maksimum havuzlama yapan bir katman ile desteklenmiştir.

Ardından dördüncü ve beşinci katmanlar evrişim (10 adet filtre içeren) katmanı ve yine maksimum havuzlama yapan ancak bu sefer 3x3'lük boyut kullanan bir havuzlama katmanı şeklinde organize edilmiştir. Model son olarak 75 yapay nöronlu oluşan bir tam bağı katman ile sona erdirilmiştir. Model içerisinde standart SAH entegrasyonu da gerçekleştirilerek açıklanabilir ESA modeli elde edilmiştir (Şekil 3). Tasarlanan model ilgili veri setinde 130 adet görüntünün test sürecinde kullanıldığı, geri kalan 20 görüntünün ise test sürecinde işe koşulduğu bir uygulama düzeneğinde kullanılmış ve ESA modelinin tutarlı değerlendirilebilmesi adına 10 farklı uygulama sürecinin gerçekleştirilmesi yönünde bir düzenek oluşturulmuştur. Uygulama sürecinde ise Adam Optimizer algoritması ile eğitim sağlanmış, cross-entropy loss fonksiyonu bağlamında, toplamda 250 epoch ve $1e^{-8}$ learning rate parametre değerleri eşliğinde bir çözüm yolu işletilmiştir.

3. ESA-SAH ile Tümör Tespiti

ESA-SAH ile beyin tümörü tespit süreci, modelin amaçladığı açıklanabilme ihtiyacı dolayısıyla standart değerlendirme metriklerine ek olarak insan (doktor) katılımı farklı değerlendirme süreçlerini de gerekli kılmıştır. Bu bölüm altında genel uygulama süreci ve değerlendirmeler ile elde edilen bulgular ifade edilmiştir.

3.1. Uygulama ve Değerlendirme Süreci

Daha önce de ifade edildiği üzere, ilgili BRATS 2017 veri setinden seçilen ve 130 eğitim / 20 test süreci bağlamında ayrılan toplam 150 görüntü, tasarlanan ESA modelinin 10 farklı bağımsız eğitim-test sürecinden geçirildiği bir uygulama planının izlenmesi sağlanmıştır. ESA-SAH sistemi kapsamında açıklanabilir olma düzeyi değerlendirilmeden önce ESA modelinin ilgili veri setindeki temel başarımı 10 farklı çalışmanın ortalamaları literatürde sıklıkla tercih edilen şu metrikler üzerinden sayısal olarak tespit edilmiştir [65-68]:

$$\text{Doğruluk} = \frac{\text{DoğruPozitif} + \text{DoğruNegatif}}{\text{DoğruPozitif} + \text{YanlışPozitif} + \text{DoğruNegatif} + \text{YanlışNegatif}} \quad (1)$$

$$\text{Duyarlılık} = \frac{\text{DoğruPozitif}}{\text{DoğruPozitif} + \text{YanlışNegatif}} \quad (2)$$

$$\text{Özgüllük} = \frac{\text{DoğruNegatif}}{\text{DoğruNegatif} + \text{YanlışPozitif}} \quad (3)$$

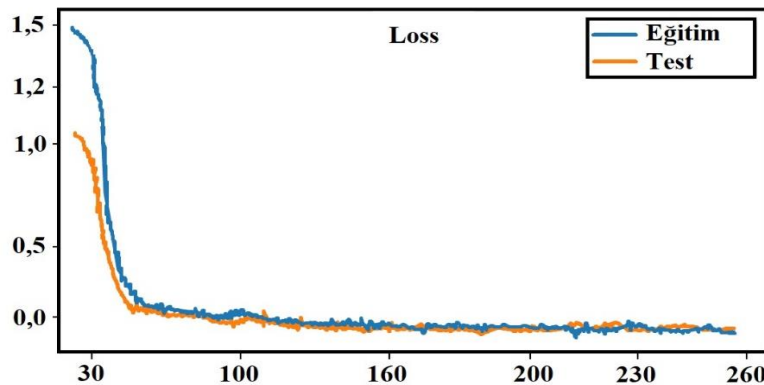
Elde edilen bulgulara ek olarak, 10 farklı doktorun ESA-SAH modelinin açıklanabilir olma düzeyini değerlendirmek adına dahil oldukları iki farklı değerlendirme yöntemi daha gerçekleştirilmiştir. Buna göre (1) doktorların ilgili MR görüntüleri karşısında ESA-SAH modelinin oluşturduğu ısı haritalarını değerlendirmeleri istenmiş, (2) ardından bir anket üzerinden sistemin gerek performans gerekse açıklanabilir olma yönünden durumuna yönelik 5'li Likert Ölçeği'nde dönütlerde bulunmuşlardır.

3.2. Bulgular

Gerçekleştirilen uygulama süreci neticesinde ESA-SAH sistemi için eşitlik 1-3 kapsamında elde edilen ortalama bulgular Tablo 1 altında sunulmuştur. Bulgulardan görüleceği üzere sistemin ortalama %95 üzerinde sonuç vermesi sistemin hedef problem kapsamındaki model performansının yeterli düzeyde olduğu anlaşılmaktadır. Yine Şekil 5 altında sunulan eğitim-test-loss eğrisi de sürecin sağlıklı işlediğini göstermektedir. Böylelikle ESA modelinin açıklanabilir olma durumu kontrol edilmeden önce kullanıcı düzeyinde kabul edilirliliğinin yeter düzeyde olduğu tespit edilmiştir.


Tablo 1. ESA modelinin BRATS 2017 veri setine karşı genel ortalama performansı.

Doğruluk	Duyarlılık	Özgüllük
%96,53	%96,10	%95,72



Şekil 5. ESA-SAH modeli uygulama sürecinden eğitim-test-loss eğrisi.

ESA-SAH modelinin açıklanabilir olma açısından giriş MR görüntüleri üzerinde oluşturduğu ısı haritalarının 10 farklı doktor tarafından değerlendirilmesi üç farklı ölçekte: (1): *yanlış*, (2): *kararsızım*, (3): *doğru* şeklinde dönütlerle puanlanmış ve ardından her doktorun ortalama dönüt değeri, 20 test verisi üzerinden incelenmiştir. Şekil 6 örnek bir ısı haritası sonucunu göstermekte, Tablo 2 ise doktorlar tarafından elde edilen dönüt ortalama değerlerini göstermektedir.



Şekil 6. ESA-SAH modelinin örnek ısı haritası oluşturma bulgusu.

Tablo 2. ESA-SAH sisteminin test verilerindeki odaklanma (ısı haritası) çıktılarına doktorların verdiği dönütler.

Doktor	(1): yanlış	(2): kararsızım	(3): doğru	Ortalama
1	1	3	6	2,5
2	0	2	8	2,8
3	0	3	7	2,7
4	2	1	7	2,5
5	2	2	6	2,4
6	0	1	9	2,9
7	0	2	8	2,8
8	0	3	7	2,7
9	0	2	8	2,8
10	1	1	8	2,7

Şekil 6'dan görüleceği üzere ESA-SAH sisteminin özellikle tümör olan bölgelerde gösterdiği odaklanma, giriş verisinden çıkış kararına ulaşırken doğru bölgelere odaklanıldığını kanıtlamaktadır. Benzer şekilde Tablo 2'deki bulgular dikkate alındığında ise 20 farklı görüntü üzerindeki ısı haritalarına doktorların verdiği dönütler de sistemin tespit ile birlikte odaklanma durumunun yüksek oranda doğru olduğunu göstermektedir.

Değerlendirme sürecinde yer alan doktorların yine ESA-SAH modelinin performansına ve açıklanabilir yapay zeka karakteristiğine yönelik dönütleri, hem sistemin hedef problemde hem de açıklanabilirlik yönünde etkinliğini anlamak adına oldukça değerlidir. Bu amaçla düzenlenen ve ilgili doktorların, 6 farklı sorudan oluşan anket tabanlı değerlendirme süreci kapsamında vermiş oldukları dönütlere dair bulgular Tablo 3 altında sunulmuştur.

Tablo 3'den görüleceği üzere doktorlar genel olarak hedef beyin tümörü tespit sürecinde ESA-SAH sisteminin performansını ve açıklanabilir olma düzeyini pozitif yönde değerlendirmiştir. Bu bağlamda ilgili tümör tespit süreci dışında alternatif tespit uygulamalara dair pozitif yönde eğilim de tasarlanan sistemin gelecek çalışmalar yönündeki potansiyeline vurgu yapmıştır.

Tablo 3. ESA-SAH sisteminin performans ve açıklanabilir olma düzeyine karşı doktor anketi kapsamında elde edilen bulgular.

İfade No	İfade	(1): tamamen katılmıyorum	(2): katılmıyorum	(3): kararsızım	(4): katılıyorum	(5): tamamen katılıyorum	Ortalama
1	“Bu sistem beyin tümörü tespitinde başarılıdır.”	0	0	2	2	6	4,4
2	“Sistemin çalışma hızı uygulamalar için uygundur.”	0	1	2	2	5	4,1
3	“Sistemin tümör tespitinde odaklandığı bölgeler doğrudur.”	0	1	1	2	6	4,3
4	“Bu sistemin kararlarında güvenli olduğunu düşünüyorum.”	1	1	1	2	5	3,9
5	“Bu sistemi tümör tespitinde kullanmak istemem.”	5	3	1	1	0	1,8
6	“Bu sistem ile alternatif tespit süreçleri de gerçekleştirilebilir.”	0	1	1	4	4	4,1

4. Tartışma

Çalışmada tasarlanan ESA modelinin özellikle BRATS 2017 beyin tümörü veri setine karşı üç farklı metrik açısından en az %95 ve üzeri performans göstermesi genel olarak modelin uygulanabilirliği açısından dikkate değer bir bulgu olmuştur. Ancak bu bulgular sistemin güvenli ve anlaşılabilir olma düzeyini doğrudan ifade etmediği için 10 farklı doktorla açıklanabilir yapay zeka ve etkileşim bağlamında ele alınan değerlendirmelerdeki bulguların da yorumlanması gerekli olmuştur. Bu noktada sistemin SAH mekanizmasının oluşturduğu ısı haritalarının yine doktorlar tarafından yüksek oranda isabetli olduğu yorumlanmış, yine performans ve açıklanabilir yapay zeka açısından da olumlu yönde dönütlerde bulunulmuştur. Bu bulgulardan hareketle ESA-SAH sisteminin tümör tespiti sürecindeki performansı bir kenara bırakıldığında açıklanabilir olma; yani insanlar açısından güvenli bulunması ve etkin kullanılabilmesi açısından sağlık alanında etkin bir araç olarak kullanılmasının kabul edildiği değerlendirilmiştir.

Gerçekleştirilen çalışmada ESA modeli üzerinde alternatif parametrelerin denenmesi (hatta hiper-parametre optimizasyonu işletilmesi) açık problem uygulamaları kapsamında değerlendirilmektedir. Çalışmada seçilen 150 görüntü dengeli çözüm için tercih edilmiş olsa da farklı çalışmalarda bütün görüntülerin kullanımı ya da aynı sayıda ancak farklı görüntülerin seçilmesiyle oluşturulacak alternatif setlerle uygulamalar gerçekleştirilebilecektir. Diğer yandan, seçilen beyin görüntüleri dışında alternatif görüntüler de kullanılabilir (Bu husus da mevcut araştırmanın kısıtları kapsamına girmekte; yine açık problem bağlamında kabul edilmektedir). Kurulan ESA-SAH sisteminin sadece beyin görüntüleri değil diğer medikal görüntülerde de kullanılabilir. Yine literatürde varsayılan SAH tekniğinin farklı varyasyonları da olmakla beraber [69-71], bu varyasyonlar da denenerek bulguların karşılaştırılması yaklaşımı yine ilgili araştırmacılar için yeni çalışmalara yönelik bir yol olarak tercih edilebilecektir. Günümüz teknolojileri nesnelerin interneti (IoT) ve bu bağlamda sağlık nesnelerinin interneti (IoHT) yönünde de ilerlemektedir [72, 73]. Bu

çalışma altında ortaya konulan yaklaşım / sistem tipik bir IoHT çözümü için arayüz görevi görebilecek, kullanıcıların ihtiyaç duyduğu açıklanabilirlik faktörü sayesinde etkin bir donanım-yazılım sinerjisi oluşturabilecektir. Diğer yandan COVID19 süreciyle birlikte sağlık, eğitim ve işletme-iletişim gibi farklı alanlarda çıkan tartışmalar [74-76] uzaktan çözümlere olan ihtiyacı tetiklemiştir. Bu bağlamda çözümün yine kablolu-kablosuz iletişim süreçleri ve donanımsal uzaktan çözümler çerçevesinde ele alınması, ESA varyasyonlarının kullanılması (örneğin, kapsül ağları, U-Net, AlexNet) ve yine artan veri karmaşıklığı ile birlikte açıklanabilirlik ekseninde dengeye oturtulması [77-83] yüksek öncelikli bir araştırma motivasyonu olacaktır.

5. Sonuç ve Öneriler

Bu çalışma kapsamında derin öğrenme uygulamalarında yaygın bir düzeyde kullanılan Evrişimsel Sinir Ağları (ESA) tekniğinin tümör tespiti yönünde kullanılacak şekilde modellemesi gerçekleştirilmiş ve söz konusu modelin güvenlik düzeyi, Sınıf Aktivasyon Haritalama (SAH / CAM: Class Activation Mapping) tekniği sayesinde açıklanabilir bir şekilde kullanıma sunulmuştur. Özellikle derin öğrenme teknikleri tarafında görülen kara-kutu (black-box) olma sorunu, tümör tespiti gibi önemli bir problemin çözümünde kullanılan ESA modelinin ekstra çabalarla kullanıcılar açısından anlaşılabilir bir yapıya dönüştürülmesini gerekli kılmaktadır. Bu tür modellerin anlaşılabilir ve güvenli olmasını sağlama yolunda ‘açıklanabilme’ faktörünü devreye sokan alternatif teknikler bulunmakla beraber, SAH kullanımı sayesinde elde edilen ısı haritaları üzerinden görüntü tabanlı giriş verilerinin hangi bölgelerinin karar aşamasında kullanıldığını tespit etmek oldukça kolay bir hale gelmektedir. Bu bağlamda, söz konusu çalışmada ESA içerisine SAH entegrasyonu sayesinde kurulan ESA-SAH sistemi, beyin tümörü tespitinde açıklanabilir bir yaklaşım sunarak insan ile sistem arasında sağlıklı bir etkileşim kurulmasını sağlamıştır. SAH katkısının değerlendirilmesi öncesinde yapılan teşhis odaklı değerlendirmeler, kurulan ESA modelinin yeter düzeyde başarımını ortaya koymuş, ardından 10 doktorun katılımıyla gerçekleştirilen ek değerlendirme süreçlerinde modelin açıklanabilir olma katkısı pozitif yönden değerlendirilmiştir. Neticede geliştirilen sistemin beyin tümörü tespiti özelinde yetkin bir açıklanabilir teşhis aracı olduğunu ifade etmek mümkündür.

Gerçekleştirilen çalışma gelecek çalışmalar bağlamında alternatif teşhis süreçlerine konu olabilecek, hatta farklı açıklanabilir yapay zeka tekniklerinin de kullanımıyla farklı değerlendirmelerle literatüre katkıda bulunulabilecektir. Bu doğrultuda bir önceki bölüm altında ifade edilen açık problem odaklı açıklamalar alternatif çalışma önerileri olarak değerlendirilebilecektir. Özellikle ESA modelinin farklı yapılanmaları ya da varyasyonlarıyla; hatta ESA yerine farklı derin öğrenme modellerinin kullanımıyla analiz edilmesi gerektiği yazarlar tarafından yüksek öncelikli olarak önerilmektedir. Yine yazarlar, açıklanabilir yapay zeka faktörünün sağlık alanında günümüzün ve geleceğin yapay zeka uygulamalarında önemli bir yer tuttuğunu düşünmekte, bu nedenle gelecek çalışma süreçlerinin de bu ekseninde ilerletilmesinin faydalı olacağını düşünmektedir.

Yazarların Katkıları

AO ve TY hedef problem için kullanılacak olan evrişimsel sinir ağları modelinin genel tasarımını tamamladı. UK tasarlanan evrişimsel sinir ağları modeline sınıf aktivasyon haritalama (açıklanabilir yapay zeka) entegrasyonunu gerçekleştirdi. AO ilgili beyin tümörü veri setini uygulamaya hazır hale getirdi, uygulama ve bütün değerlendirme çalışmalarını yaptı. Elde edilen bulgularlar birlikte AO, UK ve TY her birlikte makaleyi yazdı. Makalenin son okuması ve düzenlemeleri AO ve UK tarafından tamamlandı. UK tasarlanan ESA-SAH modeli ve beyin tümör tespiti çözümünün orijinal ilk fikrini ortaya atan kişi olup çalışmanın genel yürütücüsüdür.

Bütün yazarlar da makalenin son halini okudu ve onayladı.

Çıkar Çatışması

Yazarlar, çıkar çatışması olmadığını beyan eder.

Kaynaklar

- [1]. Kumar, U., Yadav, S., “Application of Machine Learning to Analyse Biomedical Signals for Medical Diagnosis”, Handbook of Research on Disease Prediction Through Data Analytics and Machine Learning, Vol. 1, IGI Global, Hershey: USA, (2021).
- [2]. Srivastava, R., Nguyen, N. G., Khanna, A., Bhattacharyya, S., “Predictive Intelligence in Biomedical and Health Informatics”, Vol. 2, De Gruyter, Blaufelden: Germany, (2020).
- [3]. Gupta, B. B., Sheng, Q. Z., “Machine Learning for Computer and Cyber Security: Principle, Algorithms, and Practices”, Vol. 1, CRC Press, Boca Raton: USA, (2019).
- [4]. Zhang, D., Tsai, J. J., “Advances in Machine Learning Applications in Software Engineering”, IGI Global, Hershey: USA, (2006).
- [5]. Güraksın, G. E., Ergün, U., Deperlioğlu, Ö., Classification of the heart sounds via artificial neural network, International Journal of Reasoning-based Intelligent Systems (IJRIS), 2020, 2 (3-4): 272-278.
- [6]. Boz, H., Köse, U., Emotion extraction from facial expressions by using artificial intelligence techniques, Broad Research in Artificial Intelligence and Neuroscience (BRAIN), 2018, 9 (1): 5-16.
- [7]. Köse, U., Arslan, A., Forecasting chaotic time series via anfis supported by vortex optimization algorithm: Applications on electroencephalogram time series, Arabian Journal for Science and Engineering (AJSE), 2017, 42 (8): 3103-3114.
- [8]. Aksu, N., Uçan, K., Zaman ve konum girdileri kullanılarak yapay sinir ağlarıyla referans evapotranspirasyonun tahmin edilmesi, El-Cezeri Journal of Science and Engineering, 2016, 3 (2): 204-221.
- [9]. Şentürk, A., Şentürk, Z. K., Yapay sinir ağları ile göğüs kanseri tahmini, El-Cezeri Journal of Science and Engineering, 2016, 3 (2): 345-350.
- [10]. Sivari, E., Civelek, Z., Genel anestezide kullanılan propofolün başlangıç dozunun bulanık mantık ile tahmini, El-Cezeri Journal of Science and Engineering, 2019, 6 (3): 808-816.
- [11]. Hutter, F., Kotthoff, L., Vanschoren, J., “Automated Machine Learning: Methods, Systems, Challenges”, Springer Nature, Heidelberg: Germany, (2019).
- [12]. Burkov, A., “Machine Learning Engineering”, Vol. 1, True Positive Incorporated, Quebec: Canada, (2020).
- [13]. Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., Campbell, J. P. Introduction to machine learning, neural networks, and deep learning, Translational Vision Science & Technology (TVST), 2020, 9 (2): 14-14.
- [14]. Goodfellow, I., Bengio, Y., Courville, A., Bengio, Y., “Deep Learning”, Vol. 1, MIT Press, Cambridge: USA, (2016).
- [15]. LeCun, Y., “Deep learning hardware: Past, present, and future”, IEEE International Solid-State Circuits Conference-(ISSCC), San Francisco: USA, 12-19, (2019).
- [16]. Çakıroğlu, M. A., Süzen, A. A., Assessment and application of deep learning algorithms in civil engineering, El-Cezeri Journal of Science and Engineering, 2020, 7 (2): 906-922.
- [17]. Dara, S., Tumma, P., “Feature extraction by using deep learning: A survey”, International Conference on Electronics, Communication and Aerospace Technology (ICECA), Coimbatore: India, 1795-1801, (2018).
- [18]. Du, X., Cai, Y., Wang, S., Zhang, L., “Overview of deep learning”, Youth Academic Annual Conference of Chinese Association of Automation (YAC), Wuhan: China, 159-164, (2016).
- [19]. Jiao, L., Zhao, J., A survey on the new generation of deep learning in image processing, IEEE Access, 2019, 7: 172231-172263.

- [20]. Özsoy, K., Aksoy, B., Salman, O. K. M., Investigation of the dimensional accuracy using image processing techniques in powder bed fusion, *Institution of Mechanical Engineers Journal of Process Mechanical Engineering-Part E (JPME)*, 2021, E: 09544089211011011.
- [21]. Hassaballah, M., Awad, A. I., “Deep Learning in Computer Vision: Principles and Applications”, Vol. 1, CRC Press, Boca Raton: USA, (2020).
- [22]. Albawi, S., Mohammed, T. A., Al-Zawi, S., “Understanding of a convolutional neural network”, *International Conference on Engineering and Technology (ICET)*, Antalya: Turkey, 1-6, (2017).
- [23]. Lee, H., Song, J., Introduction to convolutional neural network using Keras; an understanding from a statistician, *Communications for Statistical Applications and Methods (CSAM)*, 2019, 26 (6): 591-610.
- [24]. Lu, L., Zheng, Y., Carneiro, G., Yang, L., Deep learning and convolutional neural networks for medical image computing, *Advances in Computer Vision and Pattern Recognition (ACVPR)*, 2017, 10: 978-983.
- [25]. Sewak, M., Karim, M. R., Pujari, P., “Practical Convolutional Neural Networks: Implement Advanced Deep Learning Models Using Python”, Vol. 1, Packt Publishing Ltd, Birmingham: UK, (2018).
- [26]. Ren, Y., Cheng, X., “Review of convolutional neural network optimization and training in image processing”, *International Symposium on Precision Engineering Measurements and Instrumentation*, Chongqing: China, 1105331, (2019).
- [27]. Etyemez, A., Kurt, M., Yapay sinir ağları yöntemi ile optimum takım seçimi, *El-Cezeri Journal of Science and Engineering*, 2019, 6 (2): 323-332.
- [28]. Kaya, H., Paralel bağlı vorteks tüplerinin performansı için yapay sinir ağları analizi, *El-Cezeri Journal of Science and Engineering*, 2020, 7 (3): 1509-1517.
- [29]. Tschandl, P., Rosendahl, C., Akay, B. N., Argenziano, G., Blum, A., Braun, R. P., ..., Kittler, H., Expert-level diagnosis of nonpigmented skin cancer by combined convolutional neural networks, *JAMA Dermatology*, 2019, 155 (1): 58-65.
- [30]. Zhang, C., Sun, X., Dang, K., Li, K., Guo, X. W., Chang, J., ..., Zhong, W. Z., Toward an expert level of lung cancer detection and classification using a deep convolutional neural network, *The Oncologist*, 2019, 24 (9): 1159.
- [31]. Yala, A., Lehman, C., Schuster, T., Portnoi, T., Barzilay, R., A deep learning mammography-based model for improved breast cancer risk prediction, *Radiology*, 2019, 292 (1): 60-66.
- [32]. Biswal, S., Sun, H., Goparaju, B., Westover, M. B., Sun, J., Bianchi, M. T., Expert-level sleep scoring with deep neural networks, *Journal of the American Medical Informatics Association*, 2018, 25 (12): 1643-1650.
- [33]. Shao, K., Zhang, Z., He, S., Bo, X., “DTIGCCN: Prediction of drug-target interactions based on GCN and CNN”, *IEEE International Conference on Tools with Artificial Intelligence (ICTAI)*, Portland: USA, 337-342, (2020).
- [34]. Lee, S., Woo, S., Yu, J., Seo, J., Lee, J., Lee, C., Automated CNN-based tooth segmentation in cone-beam ct for dental implant planning, *IEEE Access*, 2020, 8: 50507-50518.
- [35]. Yarğı, V., Postalcioglu, S., EEG işareti kullanılarak bağımlılığa yatkınlığın makine öğrenmesi teknikleri ile analizi, *El-Cezeri Journal of Science and Engineering*, 2021, 8 (1): 142-154.
- [36]. Deepal, D. A. A., Fernando, T. G. I., “Convolutional Neural Network Approach for the Detection of Lung Cancers in Chest X-Ray Images”, *Deep Learning for Cancer Diagnosis*, Vol. 1, Springer Nature, Heidelberg: Germany, (2021).
- [37]. Ismail, W. N., Hassan, M. M., Alsalamah, H. A., Fortino, G., CNN-based health model for regular health factors analysis in internet-of-medical things environment, *IEEE Access*, 2020, 8: 52541-52549.
- [38]. Zhang, Y., Lobo-Mueller, E. M., Karanicolas, P., Gallinger, S., Haider, M. A., Khalvati, F., CNN-based survival model for pancreatic ductal adenocarcinoma in medical imaging, *BMC Medical Imaging*, 2020, 20 (1): 1-8.

- [39]. Gerlach, S., Fürweger, C., Hofmann, T., Schlaefer, A., Feasibility and analysis of CNN-based candidate beam generation for robotic radiosurgery, *Medical Physics*, 2020, 47 (9): 3806-3815.
- [40]. Castelvechi, D., Can we open the black box of AI?. *Nature News*, 2016, 538 (7623): 20.
- [41]. Rai, A., Explainable AI: From black box to glass box, *Journal of the Academy of Marketing Science (JAMS)*, 2020, 48 (1): 137-141.
- [42]. Tjoa, E., Guan, C., A survey on explainable artificial intelligence (xai): Toward medical xai, *IEEE Transactions on Neural Networks and Learning Systems*, 2020.
- [43]. Adadi, A., Berrada, M., Peeking inside the black-box: A survey on explainable artificial intelligence (xai), *IEEE Access*, 2018, 6: 52138-52160.
- [44]. Xu, F., Uszkoreit, H., Du, Y., Fan, W., Zhao, D., Zhu, J., “Explainable AI: A brief survey on history, research areas, approaches and challenges”, *CCF International Conference on Natural Language Processing and Chinese Computing*, Zhengzhou: China, 563-574, (2019).
- [45]. Gunning, D., Stefik, M., Choi, J., Miller, T., Stumpf, S., Yang, G. Z., XAI-Explainable artificial intelligence, *Science Robotics*, 2019, 4 (37).
- [46]. Core, M. G., Lane, H. C., Van Lent, M., Gomboc, D., Solomon, S., Rosenberg, M. “Building explainable artificial intelligence systems”, *USA National Conference on Artificial Intelligence (AAAI)*, Boston: USA, 1766-1773, (2006).
- [47]. Arrieta, A. B., Díaz-Rodríguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., ..., Herrera, F., Explainable artificial intelligence (xai): Concepts, taxonomies, opportunities and challenges toward responsible AI, *Information Fusion*, 2020, 58: 82-115.
- [48]. Köse, U., Are we safe enough in the future of artificial intelligence? A discussion on machine ethics and artificial intelligence safety, *Broad Research in Artificial Intelligence and Neuroscience (BRAIN)*, 2018, 9 (2): 184-197.
- [49]. Sun, W., Tseng, T. L. B., Zhang, J., Qian, W., Enhancing deep convolutional neural network scheme for breast cancer diagnosis with unlabeled data, *Computerized Medical Imaging and Graphics (CMIG)*, 2017, 57: 4-9.
- [50]. Zhang, N., Cai, Y. X., Wang, Y. Y., Tian, Y. T., Wang, X. L., Badami, B., Skin cancer diagnosis based on optimized convolutional neural network, *Artificial Intelligence in Medicine*, 2020, 102: 101756.
- [51]. Köse, U., Deperlioğlu, Ö., Alzubi, J., Patrut, B., “A Brief View on Medical Diagnosis Applications with Deep Learning”, *Deep Learning for Medical Decision Support Systems*, Vol. 1, Springer Nature, Heidelberg: Germany, (2021).
- [52]. Köse, U., Alzubi, J., “Deep Learning for Cancer Diagnosis”, Vol. 1, Springer Nature, Heidelberg: Germany, (2020).
- [53]. Moon, W. K., Huang, Y. S., Hsu, C. H., Chien, T. Y. C., Chang, J. M., Lee, S. H., ..., Chang, R. F., Computer-aided tumor detection in automated breast ultrasound using a 3-D convolutional neural network, *Computer Methods and Programs in Biomedicine*, 2020, 190: 105360.
- [54]. Toğaçar, M., Ergen, B., Cömert, Z., BrainMRNet: Brain tumor detection using magnetic resonance images with a novel convolutional neural network model, *Medical Hypotheses*, 2020, 134: 109531.
- [55]. Khan, H., Shah, P. M., Shah, M. A., ul Islam, S., Rodrigues, J. J., Cascading handcrafted features and convolutional neural network for IoT-enabled brain tumor segmentation, *Computer Communications (ComCom)*, 2020, 153: 196-207.
- [56]. Rehman, A., Khan, M. A., Saba, T., Mehmood, Z., Tariq, U., Ayesha, N., Microscopic brain tumor detection and classification using 3D CNN and feature selection architecture, *Microscopy Research and Technique*, 2021, 84 (1): 133-149.
- [57]. Zhang, S., Bamakan, S. M. H., Qu, Q., Li, S., Learning for personalized medicine: a comprehensive review from a deep learning perspective, *IEEE Reviews in Biomedical Engineering*, 2018, 12: 194-208.

- [58]. Deperlioğlu, Ö., Classification of phonocardiograms with convolutional neural networks, *Broad Research in Artificial Intelligence and Neuroscience (BRAIN)*, 2018, 9 (2): 22-33.
- [59]. Sagayam, K. M., Andrushia, A. D., Ghosh, A., Deperlioğlu, Ö., Elngar, A. A., Recognition of hand gesture image using deep convolutional neural network, *International Journal of Image and Graphics (IJIG)*, 2021, 2140008.
- [60]. Köse, U., Deperlioğlu, Ö., Alzubi, J., Patrut, B., “Diagnosing Diabetic Retinopathy by Using a Blood Vessel Extraction Technique and a Convolutional Neural Network”, *Deep Learning for Medical Decision Support Systems*, Vol. 1, Springer Nature, Heidelberg: Germany, (2021).
- [61]. Samek, W., Montavon, G., Vedaldi, A., Hansen, L. K., Müller, K. R., *Explainable AI: Interpreting, Explaining and Visualizing Deep Learning*, Vol. 1, Springer Nature, Heidelberg: Germany, (2019).
- [62]. Fu, K., Dai, W., Zhang, Y., Wang, Z., Yan, M., Sun, X., Multicam: Multiple class activation mapping for aircraft recognition in remote sensing images, *Remote Sensing*, 2019, 11 (5): 544.
- [63]. Menze, B. H., Jakab, A., Bauer, S., Kalpathy-Cramer, J., Farahani, K., Kirby, J., ..., Van Leemput, K., The multimodal brain tumor image segmentation benchmark (BRATS), *IEEE Transactions on Medical Imaging*, 2014, 34 (10): 1993-2024.
- [64]. Lloyd, C. T., Sorichetta, A., & Tatem, A. J., High resolution global gridded data for use in population studies, *Scientific Data*, 2017, 4 (1): 1-17.
- [65]. Deperlioğlu, Ö., & Köse, U., “Diagnosis of Diabete mellitus Using Deep Neural Network”, *Medical Technologies National Congress (TIPTEKNO)*, Magusa: Cyprus, 1-4, (2018).
- [66]. Keskenler, M. F., Dal, D., Aydin, T., Yapay zeka destekli ÇOKS yöntemi ile kredi kartı sahtekarlığının tespiti, *El-Cezeri Journal of Science and Engineering*, 2021, 8 (2): 1007-1023.
- [67]. Öziç, M. Ü., Özşen, S., 3B alzheimer MR görüntülerinin hacimsel kayıp bölgelerindeki voksel değerleri kullanılarak sınıflandırılması, *El-Cezeri Journal of Science and Engineering*, 2020, 7 (3): 1152-1166.
- [68]. Kaya, D., Türk, M., Kaya, T., Examining the effect of dimension reduction on EEG signals by k-nearest neighbors algorithm, *El-Cezeri Journal of Science and Engineering*, 2018, 5 (2): 591-595.
- [69]. Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., Batra, D., “Grad-cam: Visual explanations from deep networks via gradient-based localization”, *IEEE International Conference on Computer Vision*, Venice: Italy, 618-626, (2017).
- [70]. Fu, R., Hu, Q., Dong, X., Guo, Y., Gao, Y., Li, B., Axiom-based grad-cam: Towards accurate visualization and explanation of CNNs. *arXiv preprint*, 2020, arXiv: 2008.02312.
- [71]. Fukui, H., Hirakawa, T., Yamashita, T., Fujiyoshi, H., “Attention branch network: Learning of attention mechanism for visual explanation”, *IEEE Conference on Computer Vision and Pattern Recognition*, Long Beach: USA, 10705-10714, (2019).
- [72]. Rodrigues, J. J., Segundo, D. B. D. R., Junqueira, H. A., Sabino, M. H., Prince, R. M., Al-Muhtadi, J., De Albuquerque, V. H. C., Enabling technologies for the internet of health things, *IEEE Access*, 2018, 6: 13129-13141.
- [73]. Shankar, K., Perumal, E., Gupta, D., “Artificial Intelligence for the Internet of Health Things”, Vol. 1, CRC Press, Boca Raton: USA, (2021).
- [74]. Liu, N., Chee, M. L., Niu, C., Pek, P. P., Siddiqui, F. J., Ansah, J. P., ..., Ong, M. E. H., Coronavirus disease 2019 (COVID-19): An evidence map of medical literature, *BMC Medical Research Methodology*, 2020, 20 (1): 1-11.
- [75]. Süt, H. M., Öznaçar, B., Effects of COVID-19 period on educational systems and institutions, *International Journal of Curriculum and Instruction (IJCI)*, 2021, 13 (1): 537-551.
- [76]. Blanchard, A. L., The effects of COVID-19 on virtual working within online groups, *Group Processes & Intergroup Relations*, 2021, 24 (2): 290-296.

- [77]. Liao, Q. V., Gruen, D., Miller, S., “Questioning the AI: informing design practices for explainable AI user experiences”, CHI Conference on Human Factors in Computing Systems, Honolulu: USA, 1-15, (2020).
- [78]. Gheisari, M., Alzubi, J., Zhang, X., Köse, U., Saucedo, J. A. M., A new algorithm for optimization of quality of service in peer to peer wireless mesh networks, *Wireless Networks*, 2020, 26 (7): 4965-4973.
- [79]. Aksoy, B., Salman, O. K. M., Detection of COVID-19 disease in chest x-ray images with capsule networks: Application with cloud computing, *Journal of Experimental & Theoretical Artificial Intelligence*, 2021, 1-15.
- [80]. Yalçın, N., Altun, Y., Köse, U., Educational material development model for teaching computer network and system management, *Computer Applications in Engineering Education*, 2015, 23 (4): 621-629.
- [81]. Hughes, R., Edmond, C., Wells, L., Glencross, M., Zhu, L., Bednarz, T., “eXplainable AI (xai) An introduction to the XAI landscape with practical examples”, ACM SIGGRAPH Asia Conference, Seoul: South Korea, 1-62, (2020).
- [82]. Alom, M. Z., Yakopcic, C., Hasan, M., Taha, T. M., Asari, V. K., Recurrent residual U-Net for medical image segmentation, *Journal of Medical Imaging*, 2019, 6 (1): 014006.
- [83]. Lu, S., Lu, Z., Zhang, Y. D., Pathological brain detection based on AlexNet and transfer learning, *Journal of Computational Science (JCS)*, 2019, 30: 41-47.