X-Ray Filmlerinden Transfer Öğrenmeli Faster R-CNN Derin Öğrenme ile Zatürre Tespiti[i]

[1,*]Mehmet Uğur Türkdamar, [2]Murat Taşyürek, [3]Celal Öztürk
[1]Niğde Ömer Halisdemir Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü
[2]Kayseri Üniversitesi, Mühendislik Mimarlık ve Tasarım Fakültesi, Bilgisayar Mühendisliği Bölümü
[3]Erciyes Üniversitesi, MühendislikFakültesi, Bilgisayar Mühendisliği Bölümü
[*]uturkdamar@ohu.edu.tr

Özet: Yapay zeka alanında yapılan çalışmalar ve teknolojik gelişmeler sayesinde görsel verilerin içerdiği bilgiler medikal tanı uygulamalarına da kaynak oluşturmaktadır. Hastalık teşhisinde kullanılan yardımcı araçlardan biri de kolay erişilebilen röntgen görüntüleridir. Radyoloji görüntüleme teknikleri kullanılarak elde edilen bulgular, zatürre hastalığının tespitinde yardımcı olmaktadır. Günümüzde yapay zeka tabanlı görüntü işleme teknolojilerinin temelinde derin öğrenme yöntemleri bulunmaktadır. Evrişimli sinir ağı (CNN), derin öğrenmede yaygın olarak bilgisayarla görme ve doğal dil işleme çalışmalarına uygulanan derin sinir ağlarındandır. Bu çalışmada röntgen veri seti üzerinde CNN modeli ile zatürre hastalığı tespit edilmeye çalışılırken insanın öğrenme modelinden etkilenerek geliştirilen transfer öğrenme yaklaşımının etkisi incelenmiştir. Transfer öğrenme uygulanmamış Faster R-CNN modeli ile transfer öğrenmeli Faster R-CNN modelleri karşılaştırılmış ve gerçekleştirilen çalışmalar sonucunda transfer öğrenmeli Faster R-CNN ağının daha başarılı sonuçları daha kısa zaman diliminde elde ettiği görülmüştür.
Anahtar Kelimeler: Yapay zeka, Derin öğrenme, Nesne tespiti, Faster R-CNN

1. Giriş

Günümüzde herhangi bir işi daha kısa sürede daha doğru yapma ile yarışır hâle geldik. Yapay zeka teknolojisi kullanan bilgisayarlar, bu yarışta; evde asistan, hastanede robot, tarımda sulama makinesi, telefonda görüntüleme ile yanımızda olmaktadır. Hayatımızın her alanında ortaya çıkan veriden öğrenerek, işlerimizi otomatikleştiren makine öğrenmesine; internet kullanımının yaygınlaşması ile veri setlerinin büyümesi, bilgisayar donanımı iyileşmeleri ile işlem gücünün artması, bilimsel çalışmaların yapılması ile de yeni algoritmaların geliştirilmesi sayesinde popülerlik kazanmıştır. Geleneksel programlamada bilgisayara girdi ve girdinin işlenme yöntemi verilerek çıktı alınırken, makine öğrenmesinde girdi ve çıktı verilerek ikisi arasındaki ilişki (özellik) çıkarılmaya çalışılmaktadır. Derin öğrenme, makine öğrenmesinden farklı olarak bu ilişki çıkarımını otomatikleştirmekte ve görüntü, ses gibi yüksek boyutlu verilerden daha doğru çıkarımların yapılmasını sağlamaktadır. Derin öğrenmenin görüntü verisini işlemede kullandığı evrişimli sinir ağı (CNN), bilgisayarla görme teknolojisi sayesinde görüntüleri anlamlandırmaktadır. Görüntüde vâr olan çeşitli renk ve şekildeki nesnelerin tespiti (sınıflandırma ve konumlandırma) ise CNN tabanlı derin öğrenme ve bilgisayarla görmenin birleşimiyle gerçekleşmektedir. Sağlıkta en genel başlık olarak yapay zeka tabanlı bilgisayar destekli tanı ile görüntü verisinden, hastalığa neden olan nesneyi veya hastalığı geçiren organı tespit sayesinde, yanlış teşhisi ve uzmana ihtiyacı en aza indirmek mümkündür.

Dünya Sağlık Örgütü zatürre hastalığının, 2019 yılında 5 yaşın altındaki 740.180 çocuğun ölümüne sebep olduğunu belirtmiştir (WHO, 2021). Bulaşıcı bir hastalık olan zatürrenin virüs ve bakteri olmak üzere iki çeşidi bulunmaktadır. Çoğu hastalıkta olduğu gibi erken teşhis ile hastanın; ölümüne yol açabilen durumunun kötüye gitmesi engellenebilmektedir (Aydogdu vd., 2010). Hastalık teşhisinde uzmana yardımcı

tekniklerden biri de görüntüleme teknolojileridir. Görüntüleme tekniklerinden röntgen geçmişte,uzmanın zatürre geçiren göğsü tespit etmesine yardımcı olan en başarılı eleman iken günümüzde, tomografi görüntüsü daha doğru tespitlere aracılık etmektedir (WHO, 2001). Ancak tomografi görüntüsünün eldesi için kullanılan cihazın ortama yaydığı radyasyon seviyesi daha fazladır ve bu cihaza erişim, röntgen cihazına erişimden daha zordur. Bu sebeplerden ötürü röntgen, tomografiye göre hâlâ daha sık tercih edilen bir görüntüleme tekniğidir.Bakteri veya virüs kökenli zatürre geçiren akciğerin röntgen görüntüleri uzman tarafından doğru yorumlanamadığında hastanın durumunu daha kötüye götüren tedavilere başlanabilmektedir (Davies vd., 1996; Hopstaken vd., 2004; Neuman vd., 2011). Aynı zamanda düşük gelirli ülkelerin özellikle kırsal alanlarındaki uzman sayısı az olduğu için uzun bekleme süreleri meydana gelebilmektedir. Bu yüzden uzmana ihtiyacı minimum düzeyde tutarak uzun bekleme sürelerini engellemek ve düşük doğruluklu teşhisi azaltmak adına yapay zeka teknolojisi kullanan bilgisayar destekli tanı (BDT) sistemlerinin göğüs röntgen filmlerinden zatürre tespiti yapmasında hayatımıza artı katacağı aşikârdır.

Gündelik hayatta karşılaştığımız problemlere istemli veya istemsiz olarak çözümler üretiriz. Çözümlerimize yön veren tecrübe, farklı tip problemler için aynı kalabilir. Örneğin masa tenisi oynamayı bilen biri, tenis oynamayı öğrenirken fazla zorlanmayacaktır çünkü iki oyunun yetenek seti benzeşmektedir ve kişi,masa tenisi bilgisini tenise rahatlıkla aktarabilecektir. Veya sobada elini bir kere yakmış birisi,ocağa yaklaşırken daha dikkatli olacaktır. Bir makine öğrenmesi tekniği olarak transfer öğrenme de insanın bu tecrübe aktarımından ilham almıştır. Başarılı sonuç almak için eğitilen her bir derin öğrenme ağı, büyük veri setlerine ihtiyaç duymaktadır. Fakat çoğu zaman, ilgili alana ait büyük veri setine sahip olmayız. Bu sebeple önceden büyük veri setinden öğrenmiş ağın çıktısını (ağırlık), yeterince büyük olmayan veri setli alana ait ağın eğitimine aktarırız. Tenis örneğindeki yetenek setinin benzeşmesi gibi, ağda eğitilen verinin türü (ses, görüntü, yazı), her iki alanda (aktaran, aktarılan) da aynı olmalıdır. Kısıtlı veri seti probleminin üstesinden gelen bu tekniğe transfer öğrenme denmektedir.

Sıradaki bölümler sırasıyla konu bağlamında taranan ilgili çalışmalar, kullanılan veri setinin açıklanması ve ön işlem, derin öğrenme bağlamında CNN ve Faster R-CNN çalışma mantıkları, çalışmada uygulanan transfer öğrenme tekniği, model başarım ölçütünü veren karşılaştırma metrikleri, eğitimlerin gerçekleştiği ortamı ve elde edilen bulguları sunan deneysel çalışmalar ve planların da yer aldığı sonuç kısmıdır.

2. İlgili Çalışmalar

Uzmanın göğüs hastalıklarını teşhis etmesine yardımcı olan röntgen görüntüleri bilgisayar alanında da yaygın bir kullanıma sahiptir. Akciğerle ilgili problemleri anlamak için tomografinin; röntgene göre daha etkili olduğunu fakat daha maliyetli, daha fazla radyasyon yaydığını ve daha zor erişiminin olduğunu ifade eden yazarlar Kaggle'dan sağladıkları 6.432 röntgen görüntüsüne öncelikle temizleme ve çoklama uygulamışlardır. Daha sonra bu görüntüler ile 3 farklı ağda eğitim gerçekleştirerek en yüksek doğruluk skorunu %97 bulmuşlardır (Jain vd., 2021).

CNN tabanlı derin öğrenme yöntemlerinden Faster R-CNN ile göğüs röntgen görüntülerinden COVID-19 tespiti yapan yazarlar, %97.36 doğruluk skoru elde etmişlerdir (Shibly vd., 2020). Bir başka çalışmada bilek röntgen görüntüleri kullanan yazarlar, kırık tespitini Faster R-CNN aracılığıyla %96 doğruluk skoruyla gerçekleştirmişlerdir (Yahalomi vd., 2019). COVID-19 ve zatürre teşhisinde Faster R-

CNN kullanılan çalışmada ise ağın zatürre tespitinde COVID-19 tespitine göre daha başarılı olduğu bulunmuştur (Farhat vd., 2022). Diğer bir çalışmada, akciğer nodülü tespiti için çalıştırdıkları Faster R-CNN ile %91.2 doğruluğa ulaşmışlardır (Sua vd., 2021).

Literatürde CNN tabanlı derin öğrenme ile göğüs röntgen görüntülerinden COVID-19, zatürre ve tüberküloz hastalıkları teşhisi koyan daha birçok çalışma mevcuttur. Transfer öğrenmenin etkinliği araştıran çalışmalardan; sahip oldukları görüntüleri 4 çeşit ön eğitimli (transfer öğrenmeli) CNN'e girdileyen yazarlar, zatürre tespitini gerçeklemişlerdir (Rahman vd., 2020). Başka bir çalışmada ise önceden ImageNet veri setinde eğitilmiş ağın ağırlıklarını kendi CNN ağlarına transfer ederek COVID-19 ile enfekte zatürre hastalığının teşhisini otomatik olarak yapmışlardır(Heidari vd., 2020). COVID-19 tespiti için bir CNN'i en baştan eğiterek ve 12 CNN'i transfer öğrenme yöntemiyle eğiterek karşılaştırma yapmışlardır. Transfer öğrenme kullanılan ağların daha başarılı sonuçlar verdiğini bulmuşlardır (Majeed vd., 2020).

3. Metot

3.1. Veri seti ve ön işlem

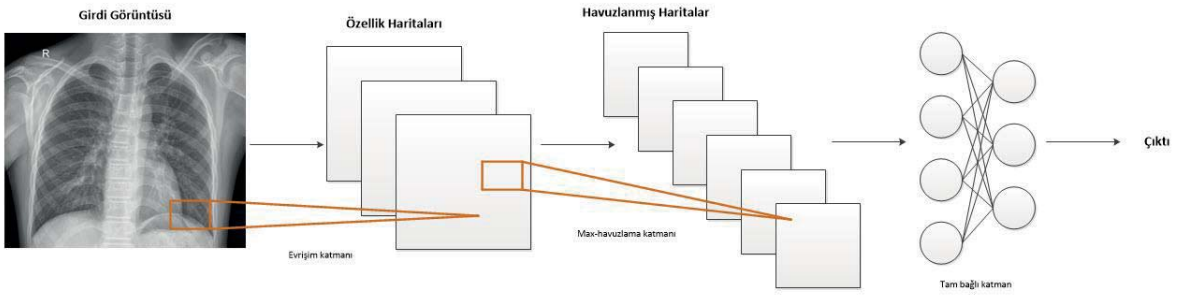
Çalışmada kullanılan veri seti Kaggle'dan edinilmiş olup bir ile beş yıl arasındaki hastaların 1.582 adet normal, 4.272 adet zatürreli akciğer görüntüsünü içermektedir (Kermany vd., 2018). Kullanılan görüntülerin kaliteleri; tarayıcı cihaza, operatöre (radyalog) ve pozisyon problemine göre farklı farklıdır. Dengeli sınıf dağılımının gözetilmesi açısından sayıca fazla olan sınıftan rasgele olarak görüntülerin çıkarılması işlemi, RUS (Random Undersampling) kullanılmıştır. Sezgisel olmayan RUS, dengesiz veri setine çözümdür (Batista vd., 2004). Sonuçta zatürreli akciğer görüntüsünden de 1.582 adet çalışmaya dahil edilmiştir. Toplam görüntünün; %70'i model eğitimi, %15'i eğitim ayarı ve %15'i nihai doğruluk ataması için ayrılmıştır.

Çalışmada kullanılan Faster R-CNN modeli gözetimli makine öğrenmesi başlığı altına girdiği için olması gereken değerler makineye tanıtılmıştır. Bunun için görüntülerdeki nesnelerin; hangi sınıf ve konumda olduğunu belirten etiketleme işlemi gerçekleştirilmiştir. Etiketleme işlemi için GPLv3 lisanslı (kullanımı serbest), açık kaynak kodlu makesense.ai tercih edilmiştir (Skalski, 2019). Program aracılığıyla oluşturulan etiketlerin formatı xml olup içeriği sırasıyla görüntüde tespiti yapılması istenen nesnelerin; sınıfı (zaturre/saglikli), bulunduğu konumun yataydaki ve düşeydeki merkez koordinatları, etrafına çizilensınırlayıcı kutunun (dikdörtgenin) genişlik ve yüksekliğidir. CNN tabanlı modellerde eğitim işleminin başarılı olması için her bir sınıftan (tespiti istenen nesneden) en az 1.000 adet etiketleme işlemi yapılması gerekmektedir. Problemimiz iki sınıflıdır ve etiketleme işleminin yapıldığı toplam görüntü sayısı 2.688'dir (eğitim ve validasyon).

3.2. CNN

Katmanlı bir yapıya sahip olan evrişimli sinir ağı (CNN), görüntü sınıflandırmadaki gelişmiş performansı ile popüler olmuştur. Birer evrişim, havuzlama ve sınıflandırma katmanı kullanan Neocognitron, ilk evrişimli sinir ağı (CNN) olarak kabul edilmektedir (Fukushima, 1980). Zamanla katman sayısının artması ve ağın kendi içinde daha iyi organize olması ile gelişmiş versiyonları üretilmiştir. Ağda temel olarak ileri ve geri yönlü geçiş işlemleri vardır. İleri yönlü geçişte gerçekleştirilen evrişim işlemi ile görüntüde filtre kaydırılarak özellik çıkarımı yapılırken, geri yönlü geçişte olması gereken değer ile tahmin edilen değer arasındaki hata değeri azaltılmaya

çalışılmaktadır. İleri yönlü geçişte CNN'in kullandığı 3 blok; (i) görüntü özelliklerini çıkaran evrişimsel katman, (ii) özellik boyutunu, dolayısıyla hesaplama maliyetini düşüren havuzlama katmanı, (iii) ağa sınıflandırma yetisi kazandıran tam bağlı katmandır (Bailer vd., 2018). Ayrıca evrişimli sinir ağı (CNN); diğer sinir ağlarından farklı olarak hesaplama maliyetini daha da düşüren alıcı alanı ve parametre paylaşımı tekniklerini kullanmaktadır. Bir katmandaki birimlerin (nöronların), bir sonraki (daha derindeki) katmandaki birimlerin hepsine bağlanması yerine az bir miktarına bağlanması, kullandığı alıcı alanı tekniği iken katmanlardan geçen görüntünün özellik parametrelerinin tüm katmanlar arasında paylaşılması, CNN'in kullandığı ikinci tekniktir (Albawi vd., 2017; Goyal vd., 2019). CNN mimarisinin genel (basitleştirilmiş) yapısı Şekil 1'de gösterildiği gibidir.



Şekil 1. CNN Mimarisi

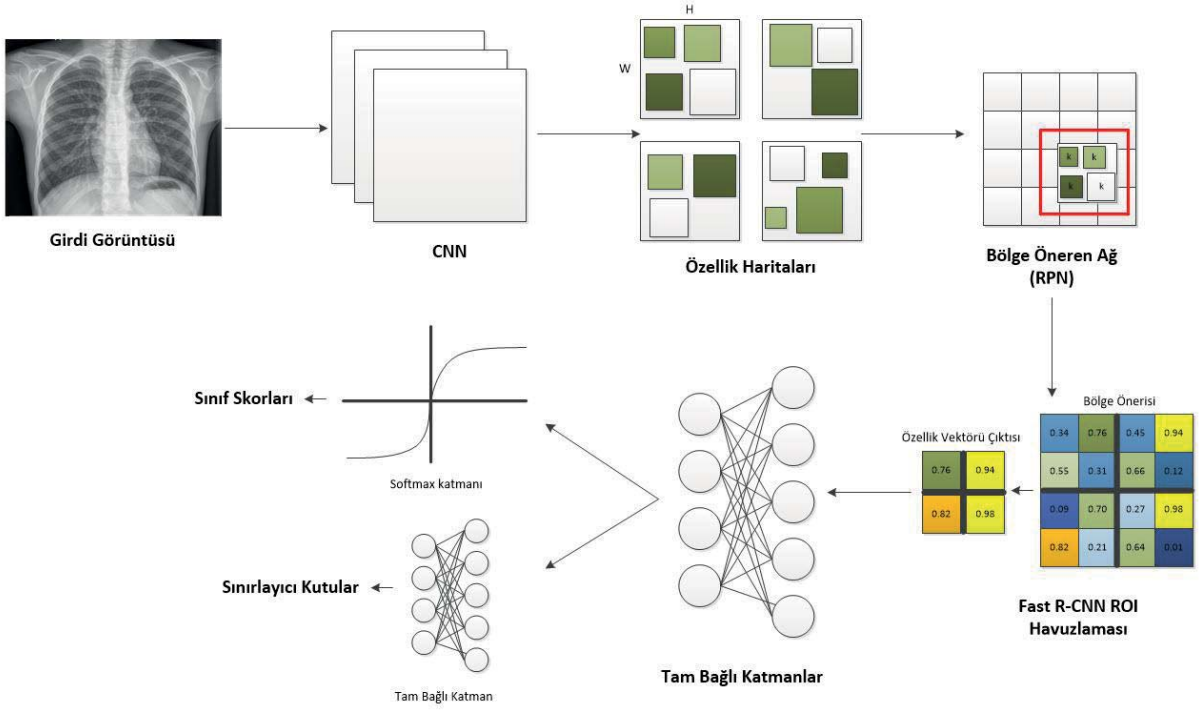
Her derin öğrenme ağının olduğu gibi CNN'in de başarılı olması için çokça veriye ihtiyacı vardır. Fakat çalışmada kullanılan röntgen görüntü veri seti çok büyük değildir. Bu yüzden çalışmada,önceden büyük veri setlerinde eğitilmiş katmanların çıktılarını, nispeten küçük veri setlerinde eğitilecek katmanlarda kullanan transfer öğrenme tekniği uygulanacaktır. Transfer öğrenme, kısıtlı veri seti probleminin üstesinden gelirken sınıflandırma skorunu geliştirebilmektedir.

3.3. Faster R-CNN

Nesne tespitleyici ağlar; omurga, boyun ve kafa olmak üzere 3 bölümden oluşur. Bu ağlar; tek ve çift aşamalı olarak ikiye, kafa kısmında ayrılmaktadır. Sınırlayıcı kutu tespiti ve sınıflandırma işlemlerini; tek seferde (yoğun) yapan ağlar tek aşamalı iken iki aşamada (seyrek) yapan ağlar çift aşamalıdır. Çalışmada kullanılan Faster R-CNN, çift aşamalı bir CNN tabanlı derin öğrenme ağıdır.

Ağa giren görüntüler ilk olarak tam bağlı katmanları çıkarılmış (sınıflandırma yapamayan), görüntünün sadece önemli özelliklerini çıkaran CNN'den (omurga) geçmektedir. Daha sonra omurgadan elde edilen özelliklerin; Faster R-CNN'in önceki versiyonlarında olmayan, 3 farklı evrişim katmanı içeren RPN'ye girdilenmesi sağlanmaktadır. Tüm özellikler, birinci evrişim katmanından geçerken ikinci ve üçüncü evrişim katmanlarından geçen özellikler, sınıflandırma yapmaya yarayan nesne var/yok tespiti için 2 x 9 sayıda ançor kutusu ve regresyon yapmaya yarayan, nesneye çizilecek sınırlayıcı kutu parametreleri için 4 x 9 sayıda ançor kutusu üretiminde kullanılmaktadır. Üretilen ançor kutularının sahip olduğu ölçek ve en, boy oranı parametreleri sayesinde oluşturulan her öneri (bölge), nesnenin olası yerini belirtmektedir. Bu parametrelerin ayarlanması ile de görüntüde çeşitli boyuttaki(küçük/büyük) nesnelerin tespiti kolaylaşmaktadır.

Üretilen bölgeler Fast R-CNN ROI havuzlamasına girdilenerek ızgaralara bölünmektedir, her ızgaradan en yüksek skorlu değer alınarak tek boyutlu özellik vektörü oluşturulmaktadır. Bu vektör ile ağın, son adım olan kafadaki iki aşamalı tespite hazırlanması sağlanmaktadır.Ardışık tam bağlı katmanların sonuncusundan çıkan özellik vektörünün bir kısmı, tespiti istenen sınıflara atanan puanların eldesi için kullanılmak üzere softmax (çoklu-sınıf problemlerinde sıkça kullanılan) katmanına girdilenirken bir kısmı da tespiti gerçekleştirilen nesnelere sınırlayıcı kutu tahmininde kullanılmak üzere başka bir tam bağlı katmana girdilenmektedir.



Şekil 2. Faster R-CNN Mimarisi

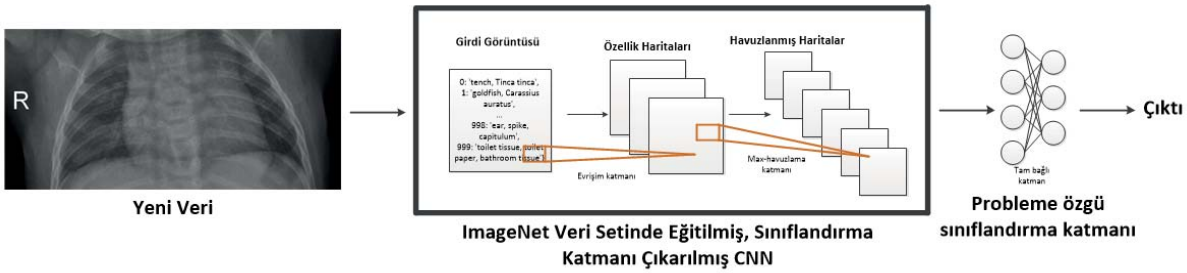
Çalışmada Faster R-CNN'in özellik çıkarıcısı, omurga ağı olarak katmanlarında artık ve altörnekleme bloklarını kullanan, ResNet50 ağı tercih edilmiştir (He vd., 2016). ResNet, transfer öğrenmenin sıkça uygulandığı biyomedikal görüntü sınıflandırmasındaki başarısı ile bilinmektedir (LeCun vd., 2010). Birçok versiyonu (katman sayısına göre) bulunan ağın asıl ortaya çıkış amacı, kaybolan eğim ve bozulma problemlerini artık öğrenme ile çözmedir (ResNet vd., 2019). Artık bloklar; ağdaki bir katmanın çıktısını alarak daha derindeki (ilerideki) başka bir katmana eklemeye yararken altörnekleme blokları; görüntüye adımlı (görüntü üzerinde kaydırılan filtrenin kayma miktarı) evrişimler uygulayarak, görüntüyü alt örneklere ayırmaya, dolayısıyla hesaplama maliyetini düşürmeye yaramaktadır. Çalışmada versiyon olarak ResNet50 tercih edilmesindeki sebep; kendi içindeki daha az katmanlı versiyonlarına göre görüntüden daha derin özellikleri çıkarabilmesi, daha çok katmanlı versiyonlarına göre de daha az hesaplama maliyetinin olmasıdır.

3.4. Transfer Öğrenme:

Derin öğrenme modellerinin başarısı, eğitim aşamasında kullanılan veri miktarına oldukça bağlıdır. İnternet kullanımının yaygınlaşması ile veri setlerinin artışı paralellik göstermektedir fakat sağlık, uzay ve canlı izleme gibi bazı alanlarda derin öğrenmenin

başarıyla uygulanabilmesi için yeterli sayıda veri, hâlâ yoktur.İnsanın dış dünyadan öğrenmesi gibi makinenin de verilerden öğrenmesinden ilham alan makine öğrenmesinin bir tekniği olan transfer öğrenme, veri seti azlığı durumunda kullanılmakta olup ağın eğitim süresini, en baştan eğitime göre ciddi oranda düşürmektedir. Yakın zamanlı MIT çalışmasına göre 200 milyon veya daha üstü parametreli bir derin sinir ağının Bulut TPU'daki (tensör işleme birimi) en baştan eğitimi, 6 arabanın kullanım ömrü boyunca ürettiği CO_2'ye eşdeğerdir (Haoarchive, 2019). Transfer öğrenmenin; eğitim süresini düşürmesinden yola çıkarak yapılacak bir yorum da doğaya salınan zararlı gazı minimum düzeye indirerek sağladığı faydadır.En basit tanımla büyük veri setinde eğitilmiş ağın çıktılarını,daha küçük veri setli problem alanındaki ağın eğitiminde kullanmaya, transfer öğrenme denmektedir(Tan vd., 2018; Koçer, 2012; Chollet, 2020; Eyiokur, 2018). Transfer öğrenmenin dört temel adımı aşağıda verildiği gibidir:

1. Önceden eğitilmiş modelin katmanlarının alınması.
2. İleriki eğitim turlarında bilgi kaybı yaşamamak için katmanların dondurulması.
3. Eski bilgileri, yeni veri seti üzerinde tahminler yapmaya dönüştürmeyi öğrenen donmuş katmanların üzerine yeni, eğitilebilir katmanların eklenmesi.
4. Yeni katmanların yeni veri seti üzerinde eğitilmesi.



Şekil 3. Transfer Öğrenme

Çalışmada eğitilen iki Faster R-CNN modelinin omurgasında da ResNet50 ağı kullanılmıştır. Fakat bir modelin omurgasındaki ResNet50 ağı, ön eğitimlidir yani bilindik büyük veri setinde (1.2 milyon görüntülü, 1.000 kategorili ImageNet (Deng vd., 2009)) önceden eğitilmiştir. Özellik çıkarıcı olarak görev yapan omurga ağının ön eğitimli olması sayesinde gündelik hayatta sürekli olarak karşılaştığımız nesnelerin renk, leke, kenar gibi temel özellikleri, çalışmada kullandığımız ağın öğrenmesi için transfer edilecektir. Ağın kendi başına temel özellikleri öğrenmesine gerek kalmadığı, sadece probleme özgü olarak zatürreli ve sağlıklı akciğer görüntülerini öğrenmeye çalıştığı için başarı oranının artması beklenmektedir. Transfer öğrenmenin; model doğruluğunu artıran bir teknik olup olmadığını araştırdığımız bu çalışmada, bir derin öğrenme modeli olan Faster R-CNN'i transfer öğrenme uygulayarak ve en baştan eğiterek karşılaştırmalar gerçekleştirilmiştir.

4. Karşılaştırma Metrikleri

Çalışmada bir makine öğrenmesi modelinin başarı ataması için kullanılan metriklerden Doğruluk, Hassaslık, Duyarlılık ve F1 Skor dikkate alınmıştır. Bu metriklerin hesaplanması için TP, TN, FP ve FN değerlerinin eldesi gereklidir. Doğru değerlerin

(TP, TN), tüm değerlere oranıyla hesaplanan Doğruluk literatürde en sık kullanılan metriktir. FP'lere önem veren Hassaslık ve FN'lere önem veren Duyarlılık metriklerinin harmonik ortalaması ile bulunan F1 Skor ise dengesiz veri setlerinde Doğruluk metriğine göre daha doğru sonuç vermektedir. Görüntüde tespiti istenen nesne; var ve sınırlayıcı kutusu (dikdörtgen) çizilmişse TP, yok ve sınırlayıcı kutusu çizilmemişse TN, yok fakat sınırlayıcı kutu çizilmişse FP, var fakat sınırlayıcı kutusu çizilmemişse FN değeri bir artırılmaktadır. Bu değerlerin test veri setindeki tüm görüntülerdeki tespiti istenen nesneler için oluşturulması ve en sonda toplanmasıyla aşağıda eşitlikleri verilen metrikler hesaplanmaktadır.

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

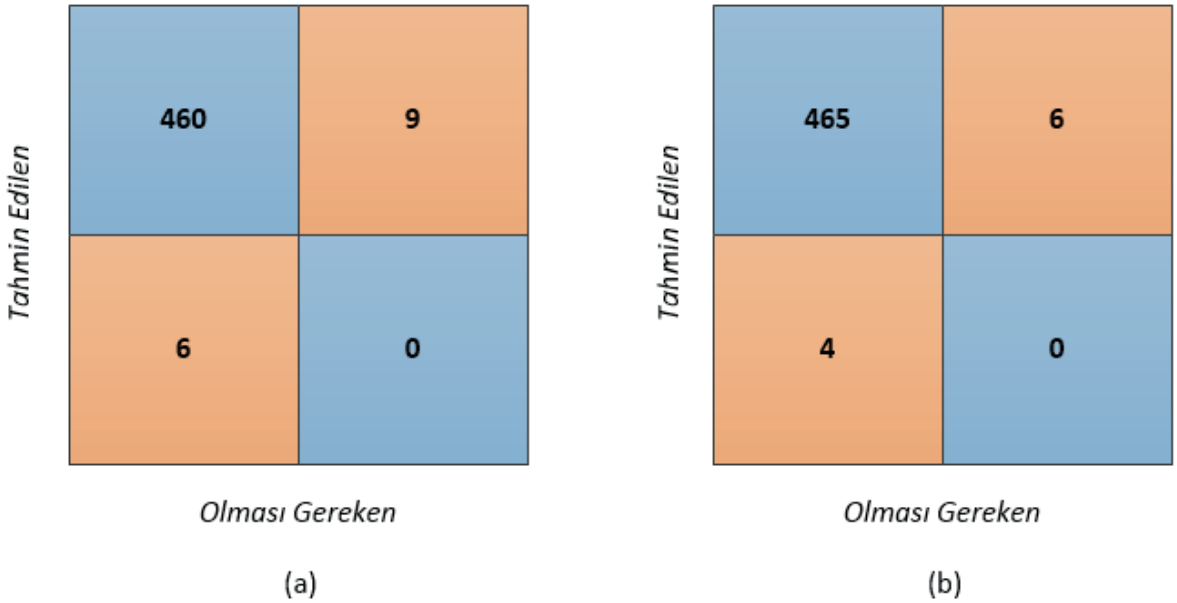
$$\text{Hassaslık} = \frac{\text{TP}}{\text{TP}+\text{FP}} \quad (2)$$

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

$$\text{F1 Skor} = \frac{2*\text{Hassaslık}*\text{Duyarlılık}}{\text{Hassaslık}+\text{Duyarlılık}} \quad (4)$$

5. Deneysel Çalışmalar

Ağ eğitiminin başarısını gösteren iki unsur; zaman geçtikçe yitim değerinin düşmesi ve doğruluğun artmasıdır. Deneylerde kullanılan; kişisel bilgisayar özellikleri, Inteli7-8750H (6 çekirdek, 2.20 GHz) işlemci ve 16 GB RAM, çerçeve yazılım, bilgisayarın işlemci threadlerinin paralel çalışmasını sağlayarak eğitimi daha kısa sürede tamamlama imkânı veren PyTorch'tur (FAIR, 2016). Doğru sonuçların alınması için model eğitimleri, aynı donanım ve yazılım şartları altında gerçekleştirilmiştir. Her iki model eğitimi için de 200 epok belirlenmiştir. Transfer öğrenmenin uygulanmadığı Faster R-CNN modelinin doğruluk skoru%97, transfer öğrenmenin uygulandığı Faster R-CNN modelinin doğruluk skoru ise%98 çıkmıştır. Şekil 4'te modellerin karışıklık matrisleri verilmiştir. Şekil 4'ten anlaşılacağı üzere 475 adetlik test veri seti (her görüntüde bir nesne) üzerinde; transfer öğrenmenin uygulanmadığı modelin TP değeri 460, transfer öğrenmenin uygulandığı modelin TP değeri ise 465 çıkmıştır. Transfer öğrenme tekniğinin uygulandığı model eğitimi 63.58 saat, transfer öğrenmenin uygulanmadığı model eğitimi ise 63.53 saat sürmüştür. Tablo 1'de modellerin doğruluk skoru ve eğitim süreleri bağlamında karşılaştırması sunulmuştur.

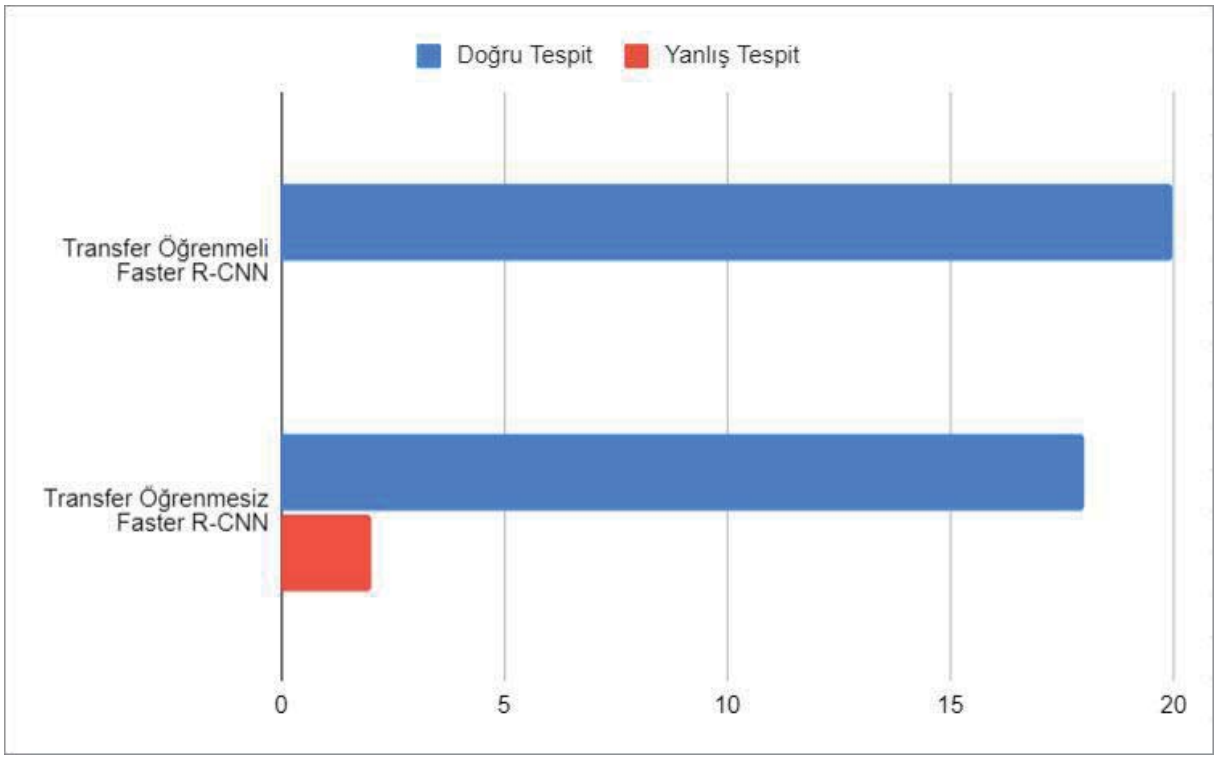


Şekil 4. Transfer Öğrenmesiz (a) ve Transfer Öğrenmeli (b) Modellerin Karışıklık Matrisleri

Tablo 1 Modellerin Doğruluk ve Eğitim Süresi Karşılaştırması

	Doğruluk Skoru	Eğitim Süresi
Transfer Öğrenmesiz Model	%97	62.53
Transfer Öğrenmeli Model	%98	63.58

Test veri setinin yaklaşık 23'te biri olan 20 görüntüde gerçekleştirilen tespit başarım karşılaştırması Şekil 5'te sunulmuştur. Rasgele seçilen 20 görüntünün 10'u zatürreli akciğer görüntüsü, kalan 10'u sağlıklı akciğer görüntüsüdür. Şekil5'ten görüleceği üzere transfer öğrenmenin uygulanmadığı Faster R-CNN, 20 görüntünün 18'ini doğru sınıflandırarak %90 başarıya ulaşmıştır. Model her iki yanlış tespitinde de görüntüleri sağlıklı yerine zatürreli olarak sınıflandırmıştır. Transfer öğrenmenin uygulandığı Faster R-CNN ise 20 görüntüdeki 20 nesnenin tümünü doğru tespit ederek %100 doğruluk elde etmiştir.



Şekil 5. Test Veri Setinin Yaklaşık 23'te Biri Olan 20 Görüntüde Modellerin Tespit Başarım Karşılaştırması

6. Sonuç

Bu çalışmada röntgen görüntülerinden göğsün zatürreli veya sağlıklı tespiti için transfer öğrenmenin uygulanmadığı ve transfer öğrenmeli CNN tabanlı derin öğrenme modeli Faster R-CNN, doğruluk ve eğitim süresi açısından değerlendirilmiştir. Deneysel sonuçlar, transfer öğrenmeli Faster R-CNN'in transfer öğrenmenin uygulanmadığı Faster R-CNN'e göre daha başarılı fakat daha uzun eğitim süresine sahip olduğunu göstermiştir. Bu çalışma sayesinde insan yaşamını doğrudan etkileyen hastalık teşhisi koymada yapay zeka tabanlı bilgisayar destekli sistemlerin daha çok tercih edilmesine ve geliştirilmesine yol açağına inanmaktayız. Yapılması planlanan çalışmalar arasında sıralı görüntülerden hastalık tespiti için hibrit yaklaşım olarak CNN-LSTM tabanlı derin öğrenmeyi uygulamak vardır.

Kaynaklar

- Albawi, S., Mohammed, T.A. ve Al-Azawi, S. (2017). Understanding of a convolutional neural network. In:2017 International Conference on Engineering and Technology (ICET) In Proceedings of the 2017 International Conference on Engineering and Technology (ICET), Antalya: Turkey.
- Aydogdu M., Ozyilmaz, E., Aksoy, H. Gursel, G. ve Ekim, N. (2010). Mortality prediction in community-acquired pneumonia requiring mechanical ventilation; values of pneumonia and intensive care unit severity scores,Tuberk Toraks, 58(1), pp. 25-34.
- Bailer, C., Habtegebrial, T., Varanasi, K. ve Stricker, D. (2018). Fast Feature Extraction with CNNs with Pooling Layers. arXiv.

- Batista, G.E.A.P.A.; Prati, R.C.; Monard, M.C. A study of the behavior of several methods for balancingmachine learning training data. ACM Sigkdd Explor. Newsl. 2004, 6, 20.
- Bhandary, A., Prabhu, G. A., Rajinikanth,V., Thanaraj, K. P., Satapathy, S. C., Robbins, D. E., Shasky, C., Zhang, Y-D., Tavares, J. M. R. S. ve Raja, N. S. M. (2020). Deep-learning framework to detect lung abnormality – A study with chest X-Ray and lung CT scan images. Pattern Recognition Letters, 129, pp. 271-278.
- Chollet, F. (2020). Transfer learning & fine-tuning. (https://keras.io/guides/transfer-learning/) Accessed 23 Apr. 2022.
- Davies,H. D., Wang, E.E., Manson, D., Babyn, P. veShuckett, B. (1996). Reliability of the chest radiograph in the diagnosis of lower respiratory infections in young children. Pediatr. Infect. Dis. J., 15(7), pp. 600–604.
- Deng, J., Dong, W., Socher, R., Li, L. J., Li, K. ve Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. In:2009 IEEE Conference on Computer Vision and Pattern Recognition.Miami: USA.
- Eyiokur, F. İ. (2018). Deep convolutional neural network based unconstrained ear recognition. Yüksek Lisans tezi. İstanbul Teknik Üniversitesi.
- Farhat, H. J., Sakr, G. E., Kilany, R., Smayra, T. ve Mallak, I. (2022). Pneumonia and COVID-19 Classication in Chest Xrays Using Faster Region-Based Convolutional Neural Networks (Faster R-CNN). ResearchSquare.
- Fukushima, K.(1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biol. Cybernetics 36, pp. 193–202.
- Goyal, M., Goyal, R. ve Lall, B. (2019). Learning Activation Functions: A new paradigm of understanding Neural Networks. arXiv.
- Haoarchive, K. (2019). Training a single AI model can emit as much carbon as five cars in their lifetimes. (https://www.technologyreview.com/2019/06/06/239031/training-a-single-ai-model-can-emit-as-much-carbon-as-five-cars-in-their-lifetimes/) Accessed 12 Mar. 2022.
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep Residual Learning for Image Recognition. In:2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: NV, pp. 770–778.
- Hopstaken, R., Witbraad, T., Engelshoven, J. V. ve Dinant, G. (2004). Inter-observer variation in the interpretation of chest radiographs for pneumonia in community-acquired lower respiratory tract infections. Clin. Radiol., 59, pp. 743–752.
- Jain, R., Gupta, M., Taneja, S. ve Hemanth, D. J.(2021). Deep learning based detection and analysis of COVID-19 on chest X-ray images. Applied Intelligence.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., McKeown, A., Yang, G., Wu, X., Yan, F., Dong, J., Prasadha, M. K., Pei, J., Ting, M. Y. L., Zhu, J., Li, C., Hewett, S., Dong, J., Ziyar, I., Shi, A., Zhang, R., Zheng, L., Hou, R., Shi, W., Fu, X., Duan, Y., Huu, V. A. N., Wen, C., Zhang, E. D., Zhang, C. L., Li, O., Wang, X., Singer, M. A., Sun, X., Xu, J., Tafreshi, A., Lewis, M. A., Xia, H. ve Zhang, K. (2018). Identifying Medical

Diagnoses and Treatable Diseases by Image-Based Deep Learning.Cell, 172(5), pp. 1122-1131.

- Koçer, B. (2012). Transfer öğrenmede yeni yaklaşımlar. Doktora tezi. Selçuk Üniversitesi.
- Lab FAIR (2016). Pytorch. (https://pytorch.org/) Accessed 18 Apr. 2022.
- LeCun, Y., Kavukcuoglu, K. ve Farabet, C. (2010). Convolutional networks and applications in vision. In:2010 IEEE International Symposium on Circuits and Systems. Paris: France, pp. 253–256.
- Majeed, T., Rashid, R., Ali, D. ve Asaad, A. (2020). Issues associated with deploying CNN transfer learning to detect COVID-19 from chest X-rays. Physical and Engineering Sciences in Medicine.
- Neuman, M.I., Lee, E.Y., Bixby, S., DiPerna, S., Hellinger, J., Markowitz, R., Servaes, S., Monuteaux, M.C. ve Shah, S. (2011). Variability in the interpretation of chest radiographs for the diagnosis of pneumonia in children. J. Hosp. Med., 7, pp. 294–298.
- ResNet, AlexNet, VGGNet, Inception: Understanding various architectures of Convolutional Networks (2019). (https://cv-tricks.com/cnn/understand-resnet-alexnet-vgg-inception/)Accessed11 Apr.2022.
- Shan, B. ve Fang, Y.(2020). A Cross Entropy Based Deep Neural Network Model for Road Extraction from Satellite Images. Entropy, 22(5).
- Shibly, K. H., Dey, S. K., Islam, M. T-U. ve Rahman, M. M. (2020). COVID faster R–CNN: A novel framework to Diagnose Novel Coronavirus Disease (COVID-19) in X-Ray images. Informatics in Medicine Unlocked.
- Skalsi, P (2019). Makesense.(https://github.com/SkalsiP/make-sense) Accessed 08 Apr. 2022.
- Sua, Y., Lia, D. ve Chen, X. (2021). Lung Nodule Detection based on Faster R-CNN Framework. Computer Methods and Programs in Biomedicine.
- Tan, C., Sun, F., Kong, T., Zhang, W., Yang, C. ve Liu, C. (2018). A Survey on Deep Transfer Learning. arXiv.
- WHO (2021). Pneumonia. (https://www.who.int/news-room/fact-sheets/detail/pneumonia#:~:text=Pneumonia%20killed%20740%20180%20children,Asia%20and%20sub%2DSaharan%20Africa) Accessed 12 Apr. 2022.
- WHO (2001). Standardization of Interpretation of Chest Radiographs for the Diagnosis of Pneumonia in Children, Geneva: Switzerland.
- Yahalomi, E., Chernofsky, M. ve Werman, M. (2019). Detection of Distal Radius Fractures Trained by a Small Set of X-Ray Images and Faster R-CNN. Intelligent Computing, pp.971-981.