

Akciğer Nodül Tespitinde CNN Tabanlı Yöntemlerin Karşılaştırılması

Merve Kayar¹

Ali Rıza Kul²

Özet

Dünya geneline bakıldığında, kanser kaynaklı ölümlerin başlıca nedenlerinden birinin akciğer kanseri olduğu görülmektedir. Bu hastalığın erken evrelerde teşhis ve tedavi edilmesi durumunda yaşam süresi önemli ölçüde artmaktadır. Hastalığın erken teşhis edilmesinde, bilgisayarlı tomografi (BT) ile görüntülerinin alınması ve bu görüntüler üzerinde akciğer nodüllerinin doğru tespit edilmesi kritik bir öneme sahiptir. Derin öğrenme alanında, özellikle de Convolutional Neural Network (CNN) tabanlı gelişmeler akciğer nodülü tespiti için umut verici çözümler sunmaktadır. Bu çalışmada, U-Net, VGGNet, ResNet gibi farklı CNN mimarilerinin akciğer nodülü tespiti üzerindeki etkileri incelenmektedir. Diğer bir taraftan, kullanılan modellerin performansları, klinik uygulamalardaki başarıları ve mevcut sınırlılıkları analiz edilmektedir. Elde edilen bulgular, CNN tabanlı sistemlerin, radyoloji ve görüntü işleme alanında güçlü bir karar destek aracı olabileceğini göstermektedir.

1.GİRİŞ

Akciğer kanseri, dünyada kansere dayalı ölümlerden en yaygın olarak bulunan türlerden biridir (American Cancer Society, 2024). Akciğer nodülleri erken dönemlerde tespit edilir ve uygun tedavi bulunursa, hayatta kalma oranını büyük ölçüde artırabilir. Bu noktada, Bilgisayarlı Tomografi gibi görüntüleme teknikleri önem kazanmaktadır. Her ne kadar bu görüntüleme teknikleri ile düzenli taramalar yapılıyor ve erken teşhis sağlanıyor ise de, radyologların sınırlı süreye sahip olması ve bir çok vakayla

1 Karabük Üniversitesi Tıp Mühendisliği, ORCID ID:0000-0002-6066-9414

2 Van Yüzüncü Yıl Üniversitesi, Fen Fakültesi, Kimya Bölümü, Van, Türkiye
ORCID ID: <https://orcid.org/0000-0001-9331-775X>

ilgilileniyor olmaları insan hata riskini arttırmakta ve bazı durumlarda verimli sonuçlar verebilmektedir (Litjens vd., 2017).

Tanıya ilişkin geliştirilen yapay zeka araçları, hata payını azaltmak için tıbbi görüntüleme alanında giderek daha çok kullanılmaktadır (Litjens vd., 2017). Özellikle derin öğrenmenin bir dalı olan Evrişimli Sinir Ağları (Convolutional Neural Networks, CNN), görsel verilerin işlenmesinde oldukça başarılı sonuçlar vermektedir (Krizhevsky, Sutskever, & Hinton, 2012). Akciğerdeki nodül tespiti ve sınıflandırılması için kullanılan CNN'ler, iyi bir doğruluk oranı vermekle beraber bu işlem süreçlerinde de başarılı sonuçlar vermektedir (Wang, Liu, Yang, & Cao, 2020; Setio vd., 2017).

Bu bölümde, akciğer nodülleri tanı ve tespiti için geliştirilen CNN yöntemleri karşılaştırmalı olarak ele alınmaktadır. Ağ mimarileri ve veri kümeleri gibi farklılıklar değerlendirilerek başarı oranları ve sınırlılıklar karşılaştırılmıştır. Diğer bir taraftan, etik kaygılarla birlikte klinik uygulamadaki süreç ve gelecekte yönelimler tartışılmaktadır (Litjens vd., 2017).

2. AKCİĞER NODÜL GÖRÜNTÜLEME TEKNİKLERİ

Akciğer kanseri yönetiminde nodüllerinin erken ve doğru bir şekilde tespit edilmesi, kritik bir rol oynamaktadır. Bu nedenle hem tarama hem de teşhis süreçlerinde yüksek çözünürlüklü görüntüleme teknikleri önemli araçlardır. Günümüzde akciğer nodülleri değerlendirmek için en sık kullanılan görüntüleme yöntemi bilgisayarlı tomografi (BT)'dir. Özellikle düşük doz bilgisayarlı tomografi (LDCT), yaygın şekilde tercih edilmektedir (MacMahon vd., 2017).

2.1 Bilgisayarlı Tomografi (BT)

Bilgisayarlı tomografi, X-ışınlarını kullanarak vücut iç yapılarının kesitsel görüntülerini oluşturur ve yüksek uzaysal çözünürlüğü sayesinde oldukça ufak boyutlardaki (1–2 mm) akciğer nodüllerini bile tespit edilebilmektedir. Geleneksel akciğer grafileri ile kıyaslandığında, bilgisayarlı tomografi çok daha yüksek duyarlılık sunar. Bu sebeplerle BT, akciğer kanseri tarama programlarında altın standart olarak kabul edilir.

BT'nin temel avantajları şunlardır:

- Farklı doku tiplerini ayırt edebilmek için yüksek kontrast çözünürlük,
- Nodül morfolojisinin ayrıntılı analizi için 3 boyutlu görüntüleme,
- Ardaşık çekimler ile nodül büyüme hızının takip edilmesine olanak tanımak (Armato vd., 2011).

2.2 Düşük Doz BT (LDCT)

LDCT, standart bilgisayarlı tomografiye (BT) göre daha düşük radyasyon dozu ile çekim yapılmasını sağlar. Bu teknik özellikle asemptomatik bireylerde tarama amacıyla kullanıldığında, fayda-risk oranını dengede tutmaktadır. *National Lung Screening Trial (NLST)* gibi büyük ölçekli yapılan çalışmalar, LDCT'nin akciğer kanserine bağlı olan mortaliteyi %20 oranında azalttığını göstermektedir (National Lung Screening Trial Research Team, 2011).

LDCT'nin öne çıkan özellikleri:

- Uzun dönemli tarama için uygundur (yılda bir kez uygulanabilirlik),
- Küçük nodüllerin tespiti konusunda yüksek oranda başarı sağlamaktadır ve
- Radyasyon dozunun düşüklüğü ile daha güvenlidir.

2.3 Diğer Görüntüleme Teknikleri

BT dışında manyetik rezonans görüntüleme (MR), pozitron emisyon tomografisi (PET) ve akciğer ultrasonografisi gibi yöntemler de farklı durum ve şartlarda kullanılabilir. Fakat sınırlı çözünürlük, yüksek maliyet ve sınırlı erişilebilirlik nedeniyle nodül taramasında rutin olarak tercih edilmemektedir. Örneğin PET veya BT gibi görüntüleme yöntemleri, malign (kötü huylu) nodüllerin metabolik aktivitesini değerlendirmek için tercih edilirken, MR daha çok yumuşak doku kontrastı gerektiren durumlarda kullanılır. Diğer bir görüntüleme yöntemi olan ultrason ise, akciğerin yüzeysel kısımlarında sınırlı bir kullanım alanına sahiptir (MacMahon vd., 2017).

2.4 Görüntüleme Verilerinin Dijitalleştirilmesi

Modern görüntüleme cihazları, DICOM (Digital Imaging and Communications in Medicine) formatında veri üretmektedir. Derin öğrenme modellerinin eğitimi ve değerlendirilmesi için bu dijital veriler yapılandırılmış veri kümeleri haline getirilebilir ve bu sayede CNN tabanlı sistemler için nitelikli giriş verileri elde edilmiş olur (Armato vd., 2011).

3. CNN TABANLI GÖRÜNTÜ İŞLEME YAKLAŞIMLARI

Konvolüsyonel Sinir Ağları (Convolutional Neural Networks – CNN), görüntü işleme alanında devrim yaratan derin öğrenme mimarilerinden biridir. Özellikle tıbbi görüntülerde yüksek doğrulukla sınıflandırma, segmentasyon ve tespit yapabilme kapasiteleri sayesinde, akciğer nodülü gibi küçük ve karmaşık yapıların analizinde büyük avantaj sağlamaktadır. CNN'ler, öğrenme sürecinde görüntüdeki düşük seviyeli (kenar, doku) ve

yüksek seviyeli (şekil, yapı) özellikleri otomatik olarak çıkartabilir (LeCun, Bengio & Hinton, 2015).

3.1 CNN Mimarilerinin Temel Yapısı

CNN'ler genellikle üç ana katmanda değerlendirilir: konvolüsyon katmanı, havuzlama (pooling) katmanı ve tam bağlantılı (fully connected) katman.

Konvolüsyon katmanları, filtreler kullanarak, giriş görüntüsü ile özellik haritaları çıkarırken, havuzlama katmanları, bu haritaların boyutunu küçülterek önemli bilgileri korur. Aynı zamanda hesaplama maliyetini azaltmaktadır. Tam bağlantılı katmanlar ise öğrenilen özellikler ile sınıflandırma işlemi gerçekleştirir.

Klasik makine öğrenmesi yöntemleri ile kıyaslandığında, bu yapılar sayesinde CNN'ler ön işlem adımlarına (özellik çıkarımı gibi) ihtiyaç duymadan veriler üzerinde doğrudan öğrenme gerçekleştirebilir (LeCun vd., 2015).

3.2 Tıbbi Görüntü İşlemede CNN'lerin Üstünlükleri

CNN tabanlı modeller, kullanılan tıbbi görüntülerin çözünürlük, varyasyon ve gürültüsüyle başa çıkmak için ideal yapılardır. Akciğer nodülü tespitinde:

- Yüksek doğruluk sağlamaktadır. Küçük nodüllerin fark edilmesinde avantajlıdır.
- Genelleme kabiliyeti ile farklı hasta verilerinden öğrenilen özelliklerin yeni verilerde de kullanılması mümkündür.
- Transfer öğrenme ile medikal görüntü verilerinin sınırlı olma sorununa çözüm sağlayabilir (Shen, Wu & Suk, 2017).

3.3 Yaygın CNN Mimarileri ve Kullanım Alanları

CNN mimarileri, çeşitli tıbbi görüntüleme görevlerinde başarıyla kullanılmaktadır:

- AlexNet: Basit yapısı sayesinde temel sınıflandırma görevlerinde kullanılır.
- VGGNet: Derin mimarisi ile nodül boyutu ve sınırlarının analizinde etkili bir mimaridir.

- ResNet: Atlamalı bağlantıları sayesinde daha derin ağların eğitilmesine etkilidir. Akciğer (bilgisayarlı tomografi görüntülerinde) nodül tespiti için tercih edilir.
- U-Net: Bu mimari, segmentasyon görevleri için özel olarak geliştirilmiştir. Akciğer loblarının veya nodül çevre dokularının ayrımı için ideal bir kullanım sunar (Ronneberger, Fischer & Brox, 2015).

3.4 Eğitim ve Doğrulama Süreci

CNN'lerin başarısı, büyük-etiketlenmiş veri kümelerine ve dengeli bir eğitim-doğrulama sürecine bağlı olarak değerlendirilir.

- Veri artırma (augmentation) teknikleri, eğitim verisinin çeşitliliğini artırmak için uygulanır. Döndürme, yakınlaştırma veya gürültü ekleme gibi işlemler bu tekniğe örnek verilebilir.
- Çapraz doğrulama yöntemleri, modelin genelleme kapasitesini değerlendirmek için kullanılmaktadır.
- Loss function (kayıp fonksiyonu) ve optimizasyon seçimi de doğruluk üzerinde önemli rol oynamaktadır.

Akciğer nodülü tespiti için eğitilen CNN modelleri, LIDC-IDRI gibi geniş çaplı etiketli BT görüntü veri kümeleri üzerinden eğitilip test edilmektedir (Armato vd., 2011).

4. AKCİĞER NODÜLÜ TESPİTİNDE KULLANILAN CNN MODELLERİNİN KARŞILAŞTIRILMASI

Konvolüsyonel Sinir Ağları (CNN), akciğer erken teşhisinde radyolojik görüntüleri otomatik analiz ederek, kanser tanısının doğruluğunu önemli ölçüde artırırken, işlem süresini de azaltmaktadır. Bu derin öğrenme mimarisi, birçok farklı model ile akciğer nodülü tespiti üzerine çalışmalar yapabilmektedir. Bu bölümde, yaygın olarak kullanılan CNN tabanlı modeller açıklanmakta ve bu modellerin mimari özellikleri, doğruluk oranları ve avantajları karşılaştırmalı olarak sunulmaktadır.

4.1 AlexNet, VGGNet, ResNet ve U-Net

AlexNet, tıbbi görüntü işleme alanındaki ilk başarılı uygulamalarından biridir. Basit yapısı ile küçük veri kümelerinde hızlı eğitim avantajı sunar ama daha küçük nodüllerin tespiti konusunda performansı düşük olabilir (Krizhevsky, Sutskever & Hinton, 2012). VGGNet, daha derin yapıya sahiptir, bu sayede yapısal özelliklerin çıkarımında ve nodül kenarlarının belirlemede daha başarılıdır. Bununla beraber, daha fazla eğitim verisine

ihtiyaç duyar ve hesaplama maliyeti yüksektir (Simonyan & Zisserman, 2015). ResNet, atlamalı bağlantılara sahiptir ve bu özellik ile çok derin ağların eğitilmesini mümkün kılar. Eğitim sırasında bilgi kaybını azaltarak daha kararlı sonuçlar üretimini sağlayan bir mimariye sahiptir. ResNet modellerinin bir diğer avantajı ise, LIDC-IDRI gibi büyük veri kümeleriyle eğitildiğinde nodül tespitinde yüksek hassasiyet ve doğruluk sağlayabilmesi (He vd., 2016) ve küçük boyutlu nodüllerin tespitinde overfitting'e karşı daha dayanıklı olmasıdır. Segmentasyon görevlerinde yaygın olarak kullanılan U-Net modeli de bir CNN mimarisidir. Nodül tespitinde, nodülün varlığıyla beraber konumunu ve sınırlarını da belirleyebilmektedir. Encoder-decoder yapısı ile yüksek çözünürlüklü segmentasyon haritaları oluşturabilen U-Net, Attention U-Net, 3D U-Net gibi çeşitli varyasyonları sayesinde daha karmaşık nodül yapılarının ayırımında etkili sonuçlar vermektedir (Ronneberger, Fischer & Brox, 2015; Zhou vd., 2019).

4.2 Transfer Öğrenme ve Hibrit Modeller

Transfer öğrenme ve hibrit mimariler, CNN tabanlı modellerin daha verimli hale getirilmesi için sıklıkla kullanılmaktadır. Özellikle önceden eğitilmiş modeller, sınırlı etiketli veri ile daha başarılı sonuçlar alınmasına olanak tanımaktadır (Tajbakhsh vd., 2016). Diğer bir taraftan, CNN'lerin geleneksel özellik çıkarım yöntemleriyle birleştirilmesi, hibrit sistemler geliştirilerek tespit performansını daha da artırılabilir.

5. KLİNİK UYGULAMALAR VE GERÇEK HAYAT SENARYOLARI

Akciğer nodülü tespitindeki kullanılan CNN tabanlı modellerin başarısı, hem akademik çalışmalarda hem de gerçek klinik uygulamalarda önemli bir etki yaratmaya başlamıştır. Bu gelişmeler, erken tanının doğruluğu arttırılarak tedavi planlamasının etkinliği sağlanmakta ve hasta sağkalım oranlarını doğrudan etki etmektedir.

5.1 Klinik Tanı Süreçlerinde CNN Modellerinin Rolü

Geleneksel tanı sürecinde radyologlar, bilgisayarlı tomografi (BT) görüntüleri üzerinde nodül arayışı yaparken CNN tabanlı modeller insan hatasını olabildiğince minimuma indirerek milimetrik boyuttaki nodüllerin dahi tespit edilmesi için geliştirilmektedir. Bu yeni yaklaşımın, hataların azaltılmasında tamamlayıcı bir araç olarak kullanılması amaçlanmaktadır. Örneğin, U-Net ve ResNet modellerinin, LIDC-IDRI veri seti üzerinde eğitildiğinde ve radyologlar ile karşılaştırıldığında %5–10 oranında daha yüksek nodül tespit ettiği saptanmıştır (Setio vd., 2017).

Bu modeller ile nodül tespit edilirken, öte yandan nodülün boyut, şekil özellikleri ve malignite ihtimalini de belirlenebilmektedir (Lakhani & Sundaram, 2017). Özellikle malign olarak ifade edilen kötü huylu nodüllerin erken, hızlı ve güvenilir bir şekilde tespit edilmesi, biyopsi gibi invaziv prosedürlerin gerekliliğini azaltabilir.

5.2 Klinik Entegrasyon ve Kullanılan Sistemler

Günümüzde bazı hastanelerde, CNN tabanlı mimarileri entegre ederek klinik karar destek sistemleri (CDSS) olarak adlandırılan ticari sistemler hizmet vermektedir. Google Health ve Siemens Healthineers ile geliştirilen bir takım sistemler, otomatik nodül tespiti ve risk skorlama işlemlerinde kullanılmaktadır (Ardila vd., 2019). Ayrıca, akciğer nodüllerinin saptanması için geliştirilmiş ve FDA (Amerikan Gıda ve İlaç Dairesi) tarafından onaylanmış bazı yapay zeka tabanlı yazılımlar, güvenle kullanılmaktadır. Bu örneklerle bakılarak, klinik pratikte yapay zekâ uygulamalarının sadece deneysel bir araç olarak değil, aynı zamanda güvenilir bir yardımcı olarak da benimsendiğini göstermektedir (Hussein vd., 2020).

5.3 Zorluklar ve Etik Sorunlar

Günümüzde yapılan çalışmalar ile CNN modelleri yüksek doğruluklar sağlıyor olsa da, klinik uygulamalarda bazı zorluklar beklenmektedir. Örneğin farklı cihazlardan gelen görüntüler, bir takım kalite farkları barındırmakta ve bu durum da modellerin genellenebilirliğini olumsuz etkileyebilir (Esteve vd., 2019). Bu sebeple ortaya çıkan yanlış pozitif sonuçlar, gereksiz endişeye ve müdahalelere neden olabilir.

Etik açıdan bakıldığında, yapay zekâ sistemlerinin nasıl kullanılacağı ve karar verme noktasında sorumluluğun kime ait olacağı tartışmalıdır. CNN modellerinin “neden bu kararı verdiği” konusunun anlaşılabilmesi, bazı klinik çalışanları açısından güven problemleri yaratabilir (Holzinger vd., 2017).

6. SONUÇ VE GENEL DEĞERLENDİRME

Akciğer kanserinin önlenmesi ve tedavisinde, akciğer nodüllerinin erken tespiti büyük önem taşımaktadır. Hem akademik araştırmalar hem klinik uygulamalar, Convolutional Neural Network (CNN) tabanlı yöntemlerin yüksek doğrulukla nodül tespiti yapabildiğini ortaya koymuştur. Bu nedenle, bu yöntemlerin medikal görüntü analizine entegre edilmesi, önemli ölçüde katkılar sunacaktır (Setio vdl., 2017; Lakhani & Sundaram, 2017).

Bu çalışma kapsamında, farklı CNN mimarilerinin (U-Net, VGGNet, ResNet) akciğer nodülü tespitinde nasıl kullanıldığı, bu mimarilerin karşılaştırılması ve klinik senaryolardaki uygulamaları incelenmiştir. Yapılan karşılaştırmalar ile başarı oranının, veri çeşitliliği, modelin eğitildiği örneklerin kalitesi ve kullanılan mimarinin derinliğine doğrudan bağlı olduğu görülmektedir (Ardila vd., 2019; Hussein vd., 2020).

Bu teknolojilerin klinik ortamlarda uygulanması büyük kolaylıklar sağlasa da; model genellenabilirliği, veri gizliliği, gibi bazı zorlukları da beraberinde getirmektedir. Diğer yandan, yapay zekânın karar verme sürecindeki rolü, etik sorumluluklar alanında gelecekte çözülmesi gereken konular arasında yer almaktadır (Holzinger vd., 2017; Esteva et vd., 2019).

Önümüzdeki araştırmalardan, klinik çalışanları için model şeffaflığı ve açıklanabilirliğini artırma beklenmektedir. Yine, klinisyenlerin bu teknolojileri etkin biçimde kullanmalarını sağlayacak ara-yüzlerin tasarımına odaklanmalıdır. Mevcut sistemin, farklı veri kaynakları ile uyumluluğunu geliştirmek öncelikli hale getirilmelidir. Ayrıca tanı sürecinin doğruluğunu daha da artırmak adına, genetik bilgilerle BT görüntülerinin birleştirilmesi gibi çeşitli multimodal verilerden faydalanan modellerin geliştirilmesi ile de büyük gelişmeler kaydedilecektir.

Sonuç olarak, akciğer nodülü tespitinde CNN tabanlı yaklaşımlar güvenilir, hızlı ve etkili çözümler sunarken, sağlık sistemlerinin gelişmesinde de önemli katkılar sunmaktadır. Bununla beraber bu sistemlerin etkin ve etik biçimde kullanılabilmesi için multidisipliner bir çalışma sürdürülmesi ve bu süreçte gerekli özenin gösterilmesi gerekmektedir.

Kaynakça

- American Cancer Society. (2024). *Key statistics for lung cancer*. <https://www.cancer.org>
- Ardila, D., Kiraly, A. P., Bharadwaj, S., Choi, B., Reicher, J. J., Peng, L., ... & Shetty, S. (2019). End-to-end lung cancer screening with three-dimensional deep learning on low-dose chest computed tomography. *Nature Medicine*, 25(6), 954–961.
- Armato, S. G., McLennan, G., Bidaut, L., McNitt-Gray, M. F., Meyer, C. R., Reeves, A. P., ... & Clarke, L. P. (2011). The Lung Image Database Consortium (LIDC) and Image Database Resource Initiative (IDRI): A completed reference database of lung nodules on CT scans. *Medical Physics*, 38(2), 915–931.
- Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., ... & Dean, J. (2019). A guide to deep learning in healthcare. *Nature Medicine*, 25(1), 24–29.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770–778).
- Holzinger, A., Biemann, C., Pattichis, C. S., & Kell, D. B. (2017). What do we need to build explainable AI systems for the medical domain? *arXiv preprint arXiv:1712.09923*.
- Hussein, S., Cao, K., Song, Y., & Bagci, U. (2020). Risk stratification of lung nodules using 3D CNN-based multi-task learning. *Medical Image Analysis*, 60, 101606.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems* (Vol. 25, pp. 1097–1105).
- Lakhani, P., & Sundaram, B. (2017). Deep learning at chest radiography: Automated classification of pulmonary tuberculosis by using convolutional neural networks. *Radiology*, 284(2), 574–582.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88.
- MacMahon, H., Naidich, D. P., Goo, J. M., Lee, K. S., Leung, A. N., Mayo, J. R., ... & van Schil, P. E. (2017). Guidelines for management of incidental pulmonary nodules detected on CT images: From the Fleischner Society 2017. *Radiology*, 284(1), 228–243.

- National Lung Screening Trial Research Team. (2011). Reduced lung-cancer mortality with low-dose computed tomographic screening. *New England Journal of Medicine*, 365(5), 395–409.
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). Springer.
- Setio, A. A. A., Traverso, A., de Bel, T., Berens, M. S., van den Bogaard, C., Cerello, P., ... & van Ginneken, B. (2017). Validation, comparison, and combination of algorithms for automatic detection of pulmonary nodules in computed tomography images: The LUNA16 challenge. *Medical Image Analysis*, 42, 1–13.
- Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221–248.
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *International Conference on Learning Representations (ICLR)*.
- Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning? *IEEE Transactions on Medical Imaging*, 35(5), 1299–1312.
- Wang, G., Liu, J., Yang, J., & Cao, J. (2020). Pulmonary nodule classification with deep convolutional neural networks on computed tomography images. *Computers in Biology and Medicine*, 120, 103732.
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2019). UNet++: A nested U-Net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support* (pp. 3–11). Springer.