

“Advances in Diagnosis, Therapy, And Prognosis Of Coronary Artery Disease Powered By Deep Learning Algorithms” Çalışma Değerlendirmesi

Dr. Ali Nail KAYA

“Advances in Diagnosis, Therapy, And Prognosis Of Coronary Artery Disease Powered By Deep Learning Algorithms” Çalışma Değerlendirmesi

Hazırlayan: Dr. Ali Nail KAYA
Hakkari Devlet Hastanesi

1) Çalışmanın Adı: Advances in Diagnosis, Therapy, and Prognosis of Coronary Artery Disease Powered by Deep Learning Algorithms 1

2) Çalışmanın Yayınlandığı Dergi: JACC: Asia

3) Çalışmanın Yayınlandığı Tarih:15 Şubat 2023

4) Çalışmanın Sponsoru:Natural Science Foundation of China

5) Çalışmanın Amacı:

Bu çalışma, derin öğrenme algoritmalarının gelişimini ve bunlara karşılık gelen değerlendirme ölçülerini klinik uygulamalarıyla birlikte tartışmaktadır. Gelişmiş derin öğrenme algoritmaları, yüksek derecede otomasyon, azaltılmış radyasyon ve gelişmiş risk sınıflandırması ile kesin teşhis ve kişiye özel tedavi için yeni fırsatlar yaratır.

6) Çalışmanın Dizaynı:

Koroner arter hastalarına yönelik perkütan koroner girişimin (PCI) prognozu ve sonuçları, teknoloji ve uygulanan tekniklerdeki dikkate değer ilerlemeler nedeniyle son on yılda önemli ölçüde iyileşmiştir. Yapay zeka (AI) özellikle de derin öğrenme (DL) metodları hızla gelişmektedir ve kardiyoloji dünyasının manzarasını değiştirmektedir; bu durum girişimsel işlemlerin birçok yönünü iyileştirmek için yeni fırsatlar yaratmaktadır. DL teknolojisi, özellikle kardiyovasküler görüntülemenin bazı modalitelerinde olmak üzere, hızla artan miktardaki verilerden güç almaktadır.

DL Ağının GeliştirilmesiDL modelleri, temel mekanizmaları veya biyofizik yasalarını anlamaya gerek kalmadan girdiyi doğrusal olmayan bir şekilde çıktıya dönüştüren, eğitilecek parametrelere sahip çok sayıda yapay sinir katmanından oluşur. Bir DL modelinin geliştirilmesine yönelik tipik bir işlem hattı, eğitim, doğrulama ve test aşamalarını içerir. Eğitim aşaması sırasında model, eğitim veri seti adı verilen belirli bir veri setini kullanarak görevini verimli bir şekilde gerçekleştirmek için parametreleri öğrenir. Doğrulama aşamasında model, farklı bir veri seti, yani doğrulama veri seti kullanarak, model performansı için eğitim stratejisiyle ilgili parametrelere hassas ayar yapar. Son olarak test aşaması, modelin bağımsız bir veri seti (yani test veri seti) üzerindeki objektif ve tarafsız performansını değerlendirir.

Maliyet fonksiyonu, DL modeli tarafından tahmin edilen çıktı ile uzmanların sağladığı temel gerçek arasındaki tutarsızlığı yansıtır. Geri yayılım algoritması yoluyla maliyet fonksiyonunun en aza indirilmesi, modelin eğitim aşaması sırasında katmanlarının optimal parametrelerini yinelemeli olarak öğrenmesine rehberlik eder. Değerlendirme ölçüleri, doğrulama aşamasında parametrelerin (ör. öğrenme hızı) ayarlanması ve test aşamasında modelin nihai performansının raporlanması için kullanılır.

İnsan beynindeki nöron bağlantısından ilham alan ileri beslemeli sinir ağının (FNN) kökenleri 1943'e kadar uzanmaktadır. Tekrarlayan sinir ağı (RNN), mevcut nöron durumunun yalnızca mevcut girişe değil aynı zamanda önceki durumlara da bağlı olmasını sağlayacak şekilde geri bildirim döngüleriyle tasarlanmıştır. Evrimsel sinir ağı (CNN), 1990'larda LeCun ve diğerleri tarafından önerilmiştir; Sabit boyutlu ve öğrenilebilir parametrelere sahip evrimsel çekirdekler, görüntü özelliklerini çıkarmak için tüm görüntüyü kayan bir pencere olarak taramak için kullanılmıştır. Paylaşılan parametreler ve daha az hesaplama maliyeti dahil olmak üzere CNN'nin FNN'ye göre avantajları, CNN'nin DL alanında baskın konumunu desteklemiştir. Grafik sinir ağı (GNN), CNN'nin verilerin işlenmesinden, içsel örnekler arası ilişkinin korunması gereken bir molekül yapısı gibi sırasız verilere kadar genelleştirilmesi olarak kabul edilebilir. Goodfellow ve arkadaşları, 2014 yılında birbirleriyle rekabet ederek optimize edilen ve eğitimin sonunda dinamik bir dengeye yol açan bir çift ağ tasarlayarak üretken çekişmeli ağı (GAN) önermişlerdir. Transformer, 2017 yılında Google Brain tarafından sıralı verileri işlemek üzere tasarlanmış, dikkat temelli bir DL modelidir.

Bilgisayarlı Görevler

Koroner görüntülemelerde DL modelinin uygulanması kabaca 5 hesaplama görevine ayrılabilir: sınıflandırma, segmentasyon, tespit, yeniden yapılandırma ve regresyon. DL modellerinin performansı, seçimi spesifik göreve bağlı olan farklı ölçümlerle değerlendirilir.

Sınıflandırma:

Görüntü sınıflandırma, görüntüdeki hedef nesneye göre görüntünün tamamına belirli bir etiket atanmasını ifade eder. Bir

sınıflandırma görevi olarak çok sayıda klinik senaryo formüle edilebilir. DL modellerini büyük ölçekli veri kümeleri üzerinde önceden eğitmek ve ardından bunlara alana özgü verilerle ince ayar yapmak, model performansını artırmak için etkili bir çözümdür. Doğruluk, sınıflandırma modellerinin performansını değerlendirmek için en yaygın kullanılan ölçümdür.

Segmentasyon:

Semantik segmentasyon, sırasıyla 2 boyutlu (2D) veya 3 boyutlu (3D) bir görüntüdeki her piksel veya vokselin bir etiket halinde yoğun bir sınıflandırma olarak düşünülebilir. Arterlerin, plakların ve stentlerin segmentasyonu koroner görüntülemenin yaygın bir görevidir.

Tespit Etme:

Algılama görevi, hedef nesneyi çevreleyen bir sınırlayıcı kutunun çıktısını alarak tanımlar. Stenoz ve plakların tespiti koroner görüntülemeye paradigmatik uygulamalardır. Tespit performansını değerlendirmek için hassasiyet, geri çağırma ve F1 puanı gibi nesne düzeyinde ölçümler hesaplanabilir. Hassasiyet-geri çağırma eğrisi de modelin ortalama doğruluğunu bildirmek için çizilir.

Yeniden Yapılandırma:

Genel olarak görüntünün yeniden yapılandırılması, ham görüntüye ve son işleme uygulamalarına bölünebilen kaynak alan sinyallerinden bir hedef alan görüntüsünün oluşturulmasını ifade eder.

Regresyon:

Regresyon, model yapılarındaki sınıflandırmaya benzer, ancak regresyon modelinin çıktısı, ayrık bir tam sayıdan ziyade sürekli bir gerçek sayıdır. Anatomi veya fizyoloji indeksleri (örn. çap darlığı, kalsiyum skoru ve fraksiyonel akış rezervi [FFR]), iyi tasarlanmış regresyon modelleri ile koroner görüntülemeye tahmin edilebilir. Bir regresyon modelinin performansı genellikle ortalama mutlak hata ve ortalama karesel hata yoluyla tahmin edilen ve referans değerler arasındaki farkla değerlendirilir.

Klinik Uygulamalar

DL'nin klinik uygulamaları hızla gelişmektedir ve kardiyoloji topluluğunun manzarasını değiştirip girişimsel işlemlerin birçok yönünü iyileştirmek için yeni fırsatlar yaratmaktadır. Bu uygulamaları, kateter laboratuvarında görüntü elde etme, teşhis ve risk sınıflandırması, girişimsel navigasyon ve tedavi değerlendirmesi ve optimizasyonunu içeren görüntüleme kılavuzluğunda koroner girişimlerin doğrultusunda özetledik.

Görüntü Alımı:

DL'nin görüntü rekonstrüksiyonuna uygulanması, koroner manyetik rezonans anjiyografide (CMRA) örneklendiği gibi, artefaktları azaltırken görüntüleme kalitesini artırır. Serbest nefes alan kalp 3D CMRA, koroner arterlerin görüntülenmesine olanak tanır, ancak bu durum engelleyici derecede uzun bir tarama süresi gerektirir.

DL modelleri aynı zamanda koroner bilgisayarlı tomografi anjiyografi (CCTA) rekonstrüksiyonuna da uygulanmıştır. Klinik çalışmalar, DL destekli CCTA rekonstrüksiyonunun, stenoz veya plak değerlendirmesinden ödün vermeden radyasyon dozunun azaltılmasına ve görüntü kalitesinin iyileştirilmesine yol açtığını doğrulamıştır.

Son olarak, kalp hareketi artefaktlarının düzeltilmesi için intravasküler görüntülemeye, özellikle intravasküler ultrasona (IVUS) yeni rekonstrüksiyon prosedürleri de uygulanmıştır.

Hastalık Teşhisi ve Risk Sınıflandırılması:

DL modelleri, son teknoloji özellik çıkarma ağı ve uzay-zamansal dikkat modülü gibi özel CNN mimarilerini kullanarak stenoz tanısında mükemmel performansını kanıtlamıştır. Du ve arkadaşları, 20.000'den fazla anjiyogramdan oluşan geniş bir veri seti kullanarak sırasıyla koroner arter segmentlerinin tanımlanması ve lezyon morfolojisinin tanınması için 2 DL modelini eğitmişlerdir. Modeller, damar segmenti tanımda %98,4 doğruluk ve stenotik lezyon tespitinde 0,829 F1 puanı elde etmiştir. Yüksek riskli hastalarda gelecekteki koroner olayların öngörülmesinde plak karakterizasyonunun prognostik önemi, farklı görüntüleme yöntemlerinin kullanıldığı farklı çalışmalarda tutarlı bir şekilde rapor edilmiştir. Lin ve arkadaşları, stabil göğüs ağrısı olan geniş bir hasta kohortunda gelecekteki miyokard enfarktüsü riskini öngörmede prognostik değeri kanıtlayan CCTA'dan DL'nin etkin olduğu plak ve stenoz ölçümünü geliştirmiş ve doğrulamıştır.

Ayrıca, perivasküler yağ dokusundaki kalıcı yapısal değişiklikleri yakalayabilen ve olumsuz koroner olaylara ilişkin risk öngörüsünü önemli ölçüde geliştirebilen epikardiyal yağ dokusunun radyomik profili analiz edilerek CCTA'dan prognozun yeni görüntüleme belirleyicileri elde edilmiştir.

Bu eğilim, CCTA'nın büyük popülasyonlarda varsayılan tarama testi olarak kullanılmasını gerektirmektedir; bu nedenle CCTA'nın iş akışında DL odaklı iyileştirmelerin sağlık sistemleri üzerinde büyük etkisi olacaktır. Bununla birlikte CCTA, klinik uygulamada kesin risk sınıflandırması veya girişimsel stratejinin planlanması için gerekli olan ayrıntılı plak karakterizasyonu açısından doğası gereği sınırlıdır. Gelişmiş plak karakterizasyonu için invaziv görüntüleme altın standart olmaya devam etmektedir.

Girişimsel Navigasyon:

KAH tanısına ve risk sınıflandırmasına fayda sağlamanın yanı sıra DL, gelişmiş prosedür verimliliği ve rahatlığıyla PCI navigasyonuna yardımcı olmak için de uygulanmıştır. Önemli uygulamalardan biri, koroner arterleri dinamik, gerçek zamanlı bir şekilde floroskopik bir görüntü üzerine bindirerek müdahale sırasında kardiyologlara sürekli görsel geri bildirim sağlayan dinamik koroner yol haritasıdır (DCR). Ticari bir DCR sistemini (Philips Healthcare) temel alan klinik çalışmalar, kontrast hacminde (%22) ve floroskopi süresinde (%30) önemli bir azalma olduğunu bildirmişlerdir. **Tedavi Değerlendirmesi ve Optimizasyonu:**

Stent yerleştirme sonrası sonucu değerlendirmek ve sonunda optimizasyon gerektiren optimal olmayan bulguları tespit etmek için intravasküler görüntüleme kullanılabilir. Bununla birlikte, tüm geri çekmenin kare başına kare analizi veya hatta seçilen karelerin periyodik aralıklarla (örneğin 1 mm) sistematik analizi, klinik karar verme amacıyla kateterizasyon laboratuvarında rutin olarak uygulanması zahmetli ve zaman alıcıdır. Stent genişlemesinin ve yerleştirilmesinin hızlı ve otomatik olarak ölçülmesi, PCI optimizasyonunun iş akışını kolaylaştırmak için çok önemlidir. Bu amaçla stent segmentasyonu ve tespiti için bazı DL modelleri geliştirilmiştir. Wu ve arkadaşları, bitişik OCT çerçevelerinden gelen bilgileri toplamak için çok ölçekli kısayol bağlantılarına ve 3D girişe sahip bir CNN modeli tasarlamışlardır. Model, 10.000'den fazla kesitsel görüntü üzerinde eğitilmiştir ve 170 OCT geri çekmesinden elde edilen 21.000'den fazla görüntüde bağımsız olarak test edilmiştir. Farklı görüntü kaynakları için mükemmel segmentasyon (Dice = 0,907) ve algılama (Hassaslık = 0,943) performansları elde edilmiştir.

Gelecek Görünüşü

Her ne kadar DL modelleri şimdiye kadar KAH tanısı, tedavisi ve prognozunun tüm yelpazesinde umut verici bir performans gösterse de, DL'nin hala sınırlamaları ve ele alınmamış zorlukları vardır. Birincisi, DL modelleri rakip girdilere karşı savunmasızdır çünkü girdileri insani anlamda anlamak yerine verilerin istatistiksel modellerine dayanırlar. Veri dağılımının eğitim veri setinden değişmesi, DL modellerinin tamamen farklı çıktılara yol açmasına neden olabilir. Tıbbi görüntüleme, farklı satıcılara ve satın alma stratejilerine göre değişiklik gösterir. Bu nedenle, DL modellerinin farklı klinik senaryolarda genelleme yeteneği konusunda büyük bir endişe yaratmaktadır. İlgili diğer bir konu ise yorumlanabilirlik ve şeffaflıktır. DL modelleri, özellikle risk sınıflandırması ve prognoz tahmini gibi yüksek seviyeli akıllı görevler için, doğasında bulunan "kara kutu" özelliğiyle ünlüdür. Modellerin davranışları ve karar verme süreçleri konusunda anlayış eksikliği vardır. Önceki bilgilerin, biyofiziksel modellemenin ve mekanik teorinin entegrasyonu, tamamen veriye dayalı DL modellerini tamamlayıcı nitelikte olacaktır ve modelin genellenebilirliğini ve yorumlanabilirliğini geliştirmeye yardımcı olabilir. İkincisi, model davranışı büyük ölçüde, genellikle deneyimli uzmanlardan alınan federal karara (veri açıklaması) bağlıdır. Son olarak yapay zeka modellerinin çoğunluğu, konseptin kanıtlanması aşamasındadır ve geniş hasta gruplarından ileriye dönük klinik denemeler beklenmektedir.

Yapay zeka teknolojisinin hızlı gelişimini ve klinik uygulamalarda yaygınlaşmasını daha iyi standartlaştırmak için düzenleyici otoritelerin yeni kılavuzlarının artık uygulamaya konulduğunu görmek güven verici olacaktır.

Sonuçlar

Gelişmiş DL algoritmaları, kardiyolojide yüksek derecede otomasyon, azaltılmış radyasyon ve gelişmiş risk sınıflandırması ile hassas teşhis ve kişiye özel tedavi için yeni fırsatlar açar. Genelleme, yorumlanabilirlik ve düzenleme konuları, multidisipliner topluluğun ortak çabalarıyla çözülmesi gereken zorluklardır.

Kaynaklar

1. Chu M, Wu P, Li G, Yang W, Gutiérrez-Chico JL, Tu S. Advances in Diagnosis, Therapy, and Prognosis of Coronary Artery Disease Powered by Deep Learning Algorithms. JACC Asia. 2023;3(1):1-14. Published 2023 Feb 15. doi:10.1016/j.jacasi.2022.12.005.
2. McCulloch WS, Pitts W. A logical calculus of the ideas immanent in nervous activity. Bull Math Biophys. 1943;5:115–133.
3. Jordan MI. Serial order: a parallel distributed processing approach. Adv Psychol. 1997;121:471–495.
4. Elman JL. Finding structure in time. Cogn Sci. 1990;14:179–211.
5. LeCun Y, Bottou L, Bengio Y, Haffner P. Gradient-based learning applied to document recognition. Proc IEEE. 1998;86:2278–2324.
6. Scarselli F, Gori M, Tsoi AC, Hagenbuchner M, Monfardini G. The graph neural network model. IEEE Trans Neural Netw. 2008;20:61–80.
7. Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. Adv Neural Inf Process Syst. 2014;27:2672–2680.
8. Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Adv Neural Inf Process Syst. 2017;30:arXiv, 1706.03762.
9. Du T, Xie L, Zhang H, et al. Training and validation of a deep learning architecture for the automatic analysis of coronary angiography. EuroIntervention. 2021;17:32–40.
10. Lin A, Manral N, McElhinney P, et al. Deep learning-enabled coronary CT angiography for plaque and stenosis quantification and cardiac risk prediction: an international multicentre study. Lancet Digit Health. 2022;4:e256–e265.
11. Piayda K, Kleinebrecht L, Afzal S, et al. Dynamic coronary roadmapping during percutaneous coronary intervention: a feasibility study. Eur J Med Res. 2018;23:36.
12. Wu P, Gutiérrez-Chico JL, Tauzin H, et al. Automatic stent reconstruction in optical coherence tomography based on a

deep convolutional model. Biomed Opt Express. 2020;11:3374–3394.