

“Role of Deep Learning in Computed Tomography” Çalışma Değerlendirmesi

Dr. Hidayet Ozan ARABACI

“Role of Deep Learning in Computed Tomography” Çalışma Değerlendirmesi

Hazırlayan: Dr. Hidayet Ozan ARABACI
İstanbul Üniversitesi Cerrahpaşa Kardiyoloji Enstitüsü

1) Çalışmanın Adı: Role of Deep Learning in Computed Tomography1
2) Çalışmanın Yayınlandığı Dergi: Cureus, Journal of Medical Science, Springer

3) Çalışmanın Yayınlandığı Tarih: 17 Mayıs 2023

4) Çalışmanın Sponsoru: (-)

5) Çalışmanın Amacı ve Giriş:

Kardiyovasküler görüntülemedeki hızlı gelişmeler ve bu modalitelerin yaygın kullanımı ile birlikte, kardiyoloji alanındaki veri girdisi çok hızlı bir şekilde artmaktadır. Ayrıca giyilebilir cihazlar, akıllı saat uygulamaları gibi birçok invazif ya da non-invazif takip yöntemlerindeki gelişmeler bu veri ağının büyük ölçüde yoğun ve karmaşık hale getirebilmektedir. Bu karmaşık labirente dolaşabilmek, doğru veriyi doğru şekilde değerlendirip işlemek için yapay zeka (YZ) hayati bir gereklilik halinde gelmektedir. YZ'nin çeşitli algoritmaları arasında, derin öğrenme en devrim niteliğinde ve büyük bir potansiyele olan bir algoritmadır. Derin öğrenme, görüntüleme alanında görüntü sınıflandırma ve bölümlendirme yapabilme yeteneğine sahiptir. Derin öğrenme, bilgisayarlı tomografinin (BT) çeşitli metodlarında tekrarlayan görevleri otomatikleştirebilir ve BT anjiyonun tanıs ve prognostik yeteneklerini artırabilir. Bu derleme makalesinde, derin öğrenmenin bilgisayarlı tomografi ile entegrasyonundan ve özellikle kardiyolojik açıdan farklı anatomik alanlardaki veri işleme konusundaki öneminden bahsedilmektedir.

6) Çalışmanın Dizaynı ve Genel Bilgiler:

Derleme şeklinde yazılan makalelerin genel özellikler; makalenin ana konusu hakkında literatürdeki birçok veriyi değerlendirmek, uygun kriterler ile sınıflamak ve bu doğrultuda sonuçları paylaşmaktır. Burada anlattığımız derleme YZ'nin bir alt kategorisi olan derin öğrenme ile kardiyovasküler alanda uygulanan BT ve BT anjiyonun işlevsel entegrasyonu hakkındaki yayınlardan ve bu yayınların sonuçlarından oluşmaktadır. Derlemede özellikler değerlendirilen derin öğrenme metoduna geçmeden önce kısaca YZ, makine eşliğinde öğrenme ve nöronal ara yüz gibi kavramdan bahsetmek gerekmektedir.

Makine öğrenimi (ML), çok çeşitli algoritmaları kapsayan bir şemsiye terimdir. Bunlar genel olarak denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme olarak kategorize edilebilir. Mevcut algoritmaların çeşitliliği arasında, derin öğrenme (DL) algoritmaları en üstün potansiyele sahiptir. "Derin" teknik olarak çok katmanlı bir ayrımı ifade eder. DL'nin mimarisi insan nöron yapısına benzemekte olup, DL algoritmaları bir dizi hiyerarşik katmanda bilgi işleyebilir ve çıkarabilir. DL, çağdaş makine öğrenimi algoritmalarından büyük ölçüde farklı özelliklere sahiptir. Denetimli ve denetimsiz öğrenme algoritmaları, kabul edilebilir sonuçlar ve doğruluk elde etmek için genellikle daha uzun eğitim ve deneyim gerektirmektedir. Buna karşılık, derin öğrenme algoritmalarının doğruluğu, eğitim veri kümesini artırarak veya ağ kapasitesini yükselterek daha kolay geliştirilebilir. DL, çeşitli algoritmaları gerçekleştirmek için tasarlanmış çok sayıda algoritmayı kapsar. Örneğin; Fully Connected Networks (FNNs), Deep Belief Networks (DBNs), Convolutional Neural Networks (CNNs) Autoencoders (AE), Recurrent Neural Networks (RNNs). DL algoritmaları arasında CNN'ler kardiyovasküler görüntüleme sıklıkla kullanılmaktadır. CNN'ler, konvolüsyonel katmanlar aracılığıyla verileri incelerken özellik optimizasyonuna öncelik verir. DL'nin CNNs formu bize, özellikle görüntüleme alanında saptanan bulguları yorumlama, sınıflama ve gerektiğinde belli sonuçlar doğrultusunda klinisyeni yönlendirme açısından büyük önem arz etmektedir.

7) Çalışmanın Sonuçları ve Önemli Noktaları:

Koroner arter hastalığının (KAH) değerlendirilmesi için kardiyak BT non-invaziv ve iyi bilinen bir yöntemdir. Kardiyak BT, koroner arter ağacındaki aterosklerotik sürecin progresyonunu, yaygınlığını ve ciddiyetini gösterebilmektedir, ayrıca koroner lezyonların fonksiyonel değerlendirmesini de yapabilmektedir. Koroner arter kalsiyum (CAC) skorlaması aterosklerotik hastalığın boyutunu değerlendirmeye yardımcı olur ve kardiyovasküler risk sınıflandırması için kullanılan önemli bir parametredir. Kardiyovasküler alanda ML algoritmalarının kardiyak BT ve diğer görüntüleme yöntemleriyle entegrasyonuna yönelik artan bir ilgi bulunmaktadır. Bu algoritmalar klinisyenlere karar verme sürecinde yardımcı olabilmekte ve bazen bu süreci oldukça hızlandırabilmektedir.

Lessman ve ark. CAC'ı değerlendirmek için bir CNN çerçevesi kullanmışlardır. CNN algoritmaları kalbin etrafında bir sınırlayıcı kutu oluşturmaktadır. Bu sınırlayıcı kutu Hounsfield birimlerine karşılık gelmektedir. Hastalar Hounsfield üniteleri için belirli eşiklerin üzerindeyse KAH açısından riskli kabul edilmişlerdir.

Cano-Espinosa ve ark. 5973 BT görüntüsünde CAC için otomatik olarak Agaston skoru oluşturan bir CNN algoritması oluşturmuşlardır. Bu algoritmanın 0,932'lik bir Pearson korelasyon katsayısına sahip olması tanıs ve doğruluk açısından oldukça anlamlıdır.

Santini ve arkadaşları, BT ile koroner lezyonların sınıflandırılması için çok katmanlı bir CNN algoritması kullanmışlar ve CNN algoritmaları 0,983'lük bir Pearson korelasyonu ortaya çıkarabilmiştir. Bu korelasyon değerleri ileri düzeyde Kardiyak BT yorumlayabilen klinisyenlerle benzer sonuçlara sahip olup ve CNN'ler bu sonuçları dakikalar içinde analiz ederek elde edilmektedir.

Biz BT'yi sadece koronerleri değerlendirmek için kullanmıyoruz, kalbi yapısal ve fonksiyonel olarak değerlendirmek aynı zamanda tüm Aortik arkı ve distal dalları değerlendirmek için de kullanılmaktadır. Bu değerlendirmenin temel yolu segmentasyon adı verilen bir metod ile yapılabilmektedir. DL bu konuda klinisyenlere oldukça yardımcı olmaktadır. Segmentasyon ile ilgili çalışma verilerine geçmeden önce önemli bir parametre olan DICE indeksinden kısaca bahsetmek yerinde olacaktır. Dice Benzerlik Katsayısı olarak da bilinen Dice skoru, genellikle ikili diziler olarak temsil edilen iki veri kümesi arasındaki benzerliğin bir ölçüsüdür. Örneğin görüntü segmentasyonu bağlamında, Dice skoru tahmin edilen segmentasyon maskesi ile temel gerçek segmentasyon maskesi arasındaki benzerliği değerlendirmek için kullanılabilir. Dice skoru, örtüşme olmadığını gösteren 0 ile mükemmel örtüşmeyi gösteren 1 arasında değişir. Yani segmentasyon analizi yapabilen DL algoritmaları ne kadar 1 değerine yakın Dice skoruna ulaşabilirse doğruluk indeksleri de o kadar fazla olacaktır. Liu ve ark. 3D BT hacimlerinde sol atriyumun otomatik segmentasyonu için çok katmanlı bir FCN kullanmışlardır ve algoritmayı daha da geliştirerek %93'lük bir Dice indeksine ulaşmışlardır. Hong ve ark. BT'den abdominal aort anevrizmasının segmentasyonu ve sınıflandırılması için bir DBN algoritmasını değerlendirmiştir.

Baskaran ve ark. BT'de kardiyak yapıların otomatik segmentasyonunda derin öğrenmenin potansiyelini araştırmışlardır. Büyük damarlarla birlikte kalbin sol ve sağ taraflarındaki çeşitli yapıları içeren on yapıyı otomatik olarak segmente etmek için bir U-Net derin öğrenme algoritması kullanmışlardır. Genel Dice skoru 0,932 idi ve sonuçlar çeşitli alt kümeler arasında tutarlı olarak izlenmiştir. Çarpıcı bir şekilde, otomatik segmentasyon vaka başına ortalama 440 saniye sürmüştür ve bu da beş saatlik manuel segmentasyonla anlamlı derece zamansal farka sebep olmuştur.

De Vos ve ark. BT kesitlerinden elde edilen 2D görüntülerde kardiyak ve aortik bölgeleri tanımlamak ve 3D'de karşılık gelen bölgeleri bulmak için bir CNN algoritması kullanmıştır. Zreik ve ark. 60 hastada BTA taramalarından sol ventrikülün otomatik segmentasyonu için bir CNN algoritması uygulamıştır.

Başka bir çalışmada, Baskaran ve ark. BTA'dan kardiyovasküler yapıların tanımlanması ve ölçülmesinde derin öğrenme algoritmalarının rolünü araştırmışlardır. Sol ventrikül hacmini, sol atriyal hacmi, sağ ventrikül hacmini ve sağ atriyal hacmi ve sol ventrikül miyokardiyal kütlelerini değerlendirmek için BTA uygulanan 166 hastada bir U-Net mimarisi kullanmışlardır ve birleştirilmiş Dice skorunu 0,924 gibi oldukça yüksek değer elde etmeyi başarmışlardır.

Motwani, beş yıllık tüm nedenlere bağlı mortaliteyi tahmin etmek için KAH şüphesi olan 10.300 hastaya BTA'da bir DL algoritması uygulamıştır. İlginç bir şekilde, ML çerçevesi, tüm nedenlere bağlı mortaliteyi tahmin etmede Framingham risk skorları (0,79'a karşı 0,61) veya BTA ciddiyet skorlarına (0,79'a karşı SSS 0,64, SIS 0,64, DI 0,62) göre daha yüksek bir eğri altında kalan alana ulaşabilmiştir ($p < 0.0001$).

8) Çalışma Hakkında Yorumlar:

Günümüzde hekimlerin iş yükünde ve hasta sayılarındaki artış, bu sayılar karşısında hekimlerin görece olarak kısıtlı zamana sahip olmaları hastaları ve birçok görüntüleme verisi ile klinik verileri incelemede zorluklara sebep olabilmektedir. Ayrıca bu artan iş yükünde tüm bu süreçlerin bizzat hekim tarafından uygulanması iş gücünde hatta kalite de bile azalmalara neden olabilmektedir. Manuel süreçlerin gözlemciler arası önemli değişkenliğe ve tekrarlanabilirliğin azalmasına neden olduğu bilinmektedir. Derin öğrenme bu açıdan oldukça fayda sağlayabilmektedir. DL bilgiyi bir katmanlar hiyerarşisi aracılığıyla işler. DL'nin performansı, daha büyük veri setleriyle katlanarak artmaktadır. Bu algoritma, karmaşık verilerden bilgi çıkarabilir ve büyük bir doğrulukla tahmin yapabilir. DL bir dizi temel görevi otomatikleştirebilir ve bir dizi klinik süreci hızlandırabilir. DL'nin herhangi bir sağlık personelinin yerini almayacağı, ancak biz kardiyologlara paha biçilmez bir yardımcı olarak hizmet edeceği vurgulanmalıdır.

Lakin DL'nin tuzakları, çelişkili yönleri de bulunmaktadır.

- Derin öğrenmenin 'kara kutu' doğası kolayca anlaşılabilir ve klinik yorumlama için zor olabilir.
- 'Aşırı uyum' adı verilen bir sorun daha küçük veri örneklerinde veya aşırı karmaşık algoritmalarda ortaya çıkabilir.
- Derin öğrenme, önyargı veya bulguların kasıtlı manipülasyonu ile ilgili bazı etik kaygılarla da ilişkili olabilir.
- Aynı algoritma ile değerlendirilen sonuçlar merkezler arası farklılıklar gösterebilir. Derin öğrenme algoritmalarının şuan için herhangi bir standardizasyonu yoktur.
- Önceki çalışmaların çoğu derin öğrenme sonuçlarını C-istatistiği ve alıcı işletim eğrisi altında kalan alan ile karşılaştırmaktadır. C-istatistiği için net bir kesme değeri yoktur.

Tablo 1. Bu Derlemede Değerlendirilen Çalışmalar

Çalışmanın Adı	Kullanılan Veri Analizi (DL)	Çalışmanın Yılı	Çalışmanın Amacı
Lessman et al.	CNN framework	2016	CAC'ı tespit etmek için otomatik ve doğru yöntem
Wolternick et al.	CNN framework	2016	CAC'ı tespit etmek için otomatik ve doğru yöntem
Cano- Espinosa et al.	CNN framework	2018	CAC yükü için Agaston skoru oluşturmak
Liu et al.	FCN	2017	BT hacimlerinde Sol Atriyal Segmentasyon için otomatik bir yöntem geliştirmek
Lopez et al.	Deep CNN Framework	2017	Aortik trombus segmentasyonu ve kantifikasyonu için otomatik ve doğru yöntem geliştirmek
Jin et al.	FCN and Conditional Random Field	2018	BT hacimlerinde LAA segmentasyonu için otomatik ve doğru yöntem geliştirmek
Dormer et al.	CNN Framework	2018	Kalp odacık segmentasyonu için otomatik yöntem geliştirmek
Baskaran et al .	U-Net Architecture	2019	CCTA'da kardiyovasküler yapıların akut ve etkili segmentasyonu için yöntemler
De Vos et al.	Deep Learning Framework	2016	BT kesitlerinden elde edilen 2D görüntülerde kardiyak ve aortik bölgeleri tanımlama ve 3D'de karşılık gelen bölgeleri bulma
Moradi et al.	CNN Framework and Conditional Random Field	2016	Kardiyak BT kesitlerinin şematik etiketlenmesi ve vücut pozisyonunun tanınması için derin öğrenme aracını değerlendirmek
Zreik et al.	Deep Learning Model	2018	CCTA'te miyokardiyumu değerlendirmek ve fonksiyonel olarak önemli koroner arter darlığı olan hastaları belirlemek
Motwani et al.	Deep Learning Algorithm	2016	CCTA ile KAH tanısı konan hastalarda tüm nedenlere bağlı mortaliteyi öngörmek
Commanduer et al.	Deep Learning Algorithm	2018	BT'de epikardiyal yağ dokusunu değerlendirmek
Gulsun et al.	CNN Framework	2016	CCTA taramalarından koroner merkez çizgilerini çıkarmak

Kaynak

1. Garg Y, Seetharam K, Sharma M, et al. (May 17, 2023) Role of Deep Learning in Computed Tomography. Cureus 15(5): e39160. DOI 10.7759/cureus.39160