



## تشخیص ندول های ریه از تصاویر CT با استفاده از الگوریتم YOLOv3

خدیجه آقاجانی

استادیار گروه مهندسی کامپیوتر دانشگاه مازندران بابلسر ایران

Kh.aghajani@umz.ac.ir

### چکیده

استفاده از رویکرد های مبتنی بر یادگیری عمیق به طور گسترده ای در تشخیص ندول های ریوی از اسکن های توموگرافی کامپیوتری (CT) رایج شده است. تشخیص زود هنگام ندول ها در ریه کمک بزرگی به درمان آن در مراحل ابتدایی بیماری است. در این مقاله در ابتدا پس از قطعه بندی از یک الگوریتم رایج تشخیص اشیا به نام YOLO نسخه سوم برای حل این مشکل استفاده شده است. این روش با دو ویژگی متمایز مشخص می شود: الف) یک استخراج کننده ویژگی چند مقیاسی خودکار برای غربالگری ویژگی ندول و ب) یک تولید کننده جعبه مرزی مبتنی بر ویژگی برای تعیین مکان و تخمین اندازه ندول. این شبکه بر روی تصاویر ImageNet آموزش داده شده است و در کاربرد های دیگر میتوان آنرا دوباره آموزش داد. در این پژوهش، جهت ارزیابی از مجموعه داده Lung-Pet-CT-DX استفاده شده است. نتایج تجربی نشان می دهد که این الگوریتم در تشخیص ندول در این پایگاه داده از دقت مطلوبی برخوردار است.

### واژه های کلیدی

تشخیص ندول ریه، یادگیری عمیق، الگوریتم YOLO.

### مقدمه

سرطان ریه هنوز هم یکی از شایع ترین علل مرگ و میر در سرتاسر جهان در مردان و زنان است، در حالی که تشخیص زود هنگام ندول های کوچک می تواند مرگ و میر ناشی از سرطان ریه را به میزان قابل توجهی کاهش دهد و عمر بیمار را طولانی تر کند [۱]. یکی از رایج ترین روش ها برای تشخیص زود هنگام آنالیز توموگرافی کامپیوتری (CT) است. سیستم های تشخیص به کمک رایانه می توانند به رادیولوژیست ها کمک کنند تا به جای یافتن ندول ها از صدها برش CT، روی مناطق مورد نظر تمرکز کنند. در ادامه به بررسی برخی از تحقیقات انجام شده در این زمینه می پردازیم.

به طور سنتی، روش های تشخیص ندول شامل دو مرحله استخراج ویژگی های دست ساز و استفاده از یک ابزار یادگیری ماشین جهت کاهش تعداد مثبت های کاذب است. توصیفگرهای ویژگی مبتنی بر شکل [۲]، ویژگی های بافت [۳ و ۴]، و ویژگی های موجک [۵ و ۶]،


خواص هندسی و اطلاعات لبه [۷] ویژگی های خمیدگی [۸]، نمونه هایی از موارد رایج هستند. روش های مورد استفاده در این زمینه در روش های سنتی، تعداد FP ها برای هر اسکن بسیار زیاد است. بنابراین طبقه بندی کننده ای مانند ماشین بردار پشتیبان (SVM)، جنگل تصادفی (RF)، شبکه های عصبی چند لایه، k-نزدیک ترین هم سایه (K-NN) می تواند برای کاهش FP ها استفاده شود [۷ و ۵]. علاوه بر این، در روش های سنتی، فیلترهای طراحی شده ممکن است در مواجهه با تغییرات سایز و مقیاس ندول دچار مشکل شوند.

اخیراً استفاده از رویکردهای مبتنی بر یادگیری عمیق در شبکه های مبتنی بر شبکه های کانولوشنی در بسیاری از کاربردها من جمله تشخیص ندول رایج شده است [۹-۱۱]. با توجه به قابلیت این شبکه ها در یادگیری استخراج ویژگی، مشکل روش های سنتی در طراحی فیلترها کاهش می یابد.

اخیراً استفاده از روش های تشخیص شی مبتنی بر یادگیری عمیق در تشخیص ندول مورد توجه قرار گرفته است. در [۱۲]، روش مبتنی بر r-CNN [۱۳، ۱۴] برای تشخیص ندول ریه استفاده شده است. r-CNN faster [۱۵] نیز در [۱۶، ۱۷] برای تشخیص ندول های ریه استفاده شده است. برخی از مطالعات از mask r-CNN برای شناسایی گره ها و بخش بندی آنها استفاده کرده اند [۱۸]. در [۱۹]، یک r-CNN سریعتر اصلاح شده برای تشخیص گره های ریه پیشنهاد شده است. ابتدا، تصویر با یک لایه de-convolutional وارد VGG16 می شود. سپس ویژگی های بدست آمده به شبکه پیشنهادی منطقه (RPN) ارسال می شود تا نامزدهای گره اولیه تولید شود. در نهایت، منطقه کاندید به همراه ویژگی های کانولوشن به لایه ادغام منطقه مورد علاقه (ROI) و به دنبال آن یک طبقه بندی چند وظیفه ای برای قرار دادن رگرسیون ناحیه کاندید وارد می شود.

یکی دیگر از دسته روش های تشخیص اشیا مبتنی بر یادگیری عمیق، الگوریتم YOLO [۲۰] است که در آن چهار گوش محدود کننده اشیا در تصویر به همراه احتمالات کلاس آنها توسط یک CNN پیش بینی می شوند. YOLO و انواع آن در برخی از مطالعات برای تشخیص ندول های ریه استفاده شده است [۲۱، ۲۲].

در این پژوهش از روش مبتنی بر YOLO نسخه سوم برای تشخیص مکان و اندازه ندول استفاده شده است. این الگوریتمی است



شکل ۱ نمونه‌ای از استخراج جسم ریه. الف) سی تی اسکن اصلی، ب) تصویر صفحه بیت (خروجی عملگر OR بیت شماره ۷ و بیت شماره ۸)، ج) خروجی اولیه مرز ناحیه د) مرز استخراج شده بهبود یافته، ه) ناحیه ریه استخراج شده با ضرب تصویر اصلی در ماسک به دست آمده.

### الگوریتم YOLOv3:

الگوریتم YOLO برای شناسایی اشیاء در یک تصویر است. ویژگی‌های کل تصویر توسط شبکه عصبی برای پیش بینی هر جعبه مرزی و احتمالات کلاس استفاده می‌شود. شبکه در مورد تصویر کامل و همچنین تمام اشیاء موجود در تصویر می‌آموزد. تصویر ورودی به یک شبکه معمولی تقسیم می‌شود. هر سلول شبکه دارای یک برچسب مرتبط با خود است که حاوی احتمال وجود شی در سلول شبکه است، مختصات پیکسل کادر جاوی آن شی را نسبت به مرکز مربع شبکه نشان می‌دهد.

در اینجا، تنها یک کلاس وجود دارد که باید شناسایی شود: ندول. بنابراین، در مجموع ۱ کلاس وجود دارد که در آن اشیاء را می‌توان به دسته بندی کرد. بنابراین، برای هر سلول شبکه، برچسب یک بردار شش بعدی با اطلاعات زیر خواهد بود: وجود و یا عدم وجود ندول، امتیاز وجود ندول، اگر ندولی وجود داشته باشد باقی عناصر نشان دهنده مختصات نقاط میانی شی، نسبت عرض و ارتفاع مرز است.

که اشیاء مختلف را در یک تصویر (در زمان واقعی) شناسایی و تشخیص می‌دهد. تشخیص اشیاء در YOLO به عنوان یک مسئله رگرسیون انجام می‌شود و همراه با مستطیل احاطه کننده شی، احتمالات کلاس شی شناسایی شده را ارائه می‌دهد. در این روش برای ارزیابی از پایگاه داده Lung-Pet-CT-DX استفاده شده است. ادامه مقاله شامل بخش‌های زیر است. در بخش دوم چارچوب پیشنهادی ارائه شده است. بخش سوم و چهارم به مشاهدات و نتیجه گیری اختصاص دارد.

### ۲. روش پیشنهادی

در این بخش به ارائه چارچوب پیشنهادی پرداخته شده است. در ابتدا پیش پردازش و در ادامه به روش پیشنهادی می‌پردازیم.

#### پیش پردازش:

با توجه به وجود پس زمینه و اطلاعات نامربوط به ندول در ابتدا با استفاده از روش قطعه بندی برشی از ناحیه دلخواه ایجاد می‌کنیم. از آنجایی که نیازی به در نظر گرفتن ناحیه حذف شده برای محاسبه بعدی نیست، انجام این عملیات می‌تواند تشخیص ندول را سریعتر کند. عبارتی هدف از پیش پردازش، کاهش اندازه تصاویر بدون از دست دادن اطلاعات مهم است. در اینجا، از روش تقسیم بندی مبتنی بر عملیات در سطح بیت استفاده شده است. در این روش، مقدار هر پیکسل به یک عدد صحیح بدون علامت ۸ بیتی تبدیل می‌شود. یک تصویر صفحه بیت (bit-plane) با OR کردن بیت شماره ۸ و بیت شماره ۷ ایجاد می‌شود. پس از اعمال آستانه بر روی تصویر به دست آمده، دنباله‌ای از عملیات مانند حذف حلقه‌های بیرونی و حلقه‌های کوچک و روش پر کردن سیلابی (flood filling) انجام می‌شود. فرآیند توضیح داده شده در شکل (۱) ارائه شده است. مانند تصویر نشان داده شده در این شکل، انجام این عملیات ممکن است منجر به حذف ندول‌های چسبیده به دیواره ریه شود. برای در نظر گرفتن آن نواحی، کادری حاوی ناحیه برش شده با حاشیه ۱۰ پیکسل برای اضلاع بیرونی به عنوان ماسک در نظر گرفته می‌شود. با اعمال این ماسک بر روی تصویر اصلی، برش مطلوب ایجاد می‌شود. پیکره‌های تولید شده به عنوان ورودی مدل استفاده می‌شوند.



با توجه به معماری YOLO، برای اشیاء احتمالی موجود در تصویر، یک مستطیل با امتیاز (score) به دست می آید. چهارضلعی ها با امتیاز بالاتر از یک آستانه حفظ می شوند. این حال، گاهی، هنوز چندین چهارضلعی همپوشانی دارند. منظور فیلتر کردن بهترین جعبه های مرزی، می توان از روش سرکوب غیر حداکثری (NMS) استفاده کرد. نسبت اشتراک به اجتماع (IoU) را می توان به عنوان یک معیار انتخاب مناسب استفاده کرد. IoU معمولاً برای تعیین کمیت در صد همپوشانی بین دو جعبه کران دار استفاده می شود. می توان آن را به صورت زیر نشان داد:

$$IoU(B_1, B_2) = \frac{\text{intersection} - \text{size}(B \cap B)}{\text{union} - \text{size}(B \cup B)} \quad (3)$$

در روش NMS ابتدا فهرستی از چهار ضلعی با امتیاز بالاتر از آستانه مشخص، ایجاد می شود. در هر تکرار، کادری با بالاترین امتیاز از لیست حذف شده و به خروجی فیلتر شده مورد نظر اضافه می شود. سپس کادرهای با IoU بالا با کادر حذف شده نیز از لیست حذف می شوند. این روند تا زمانی که لیست خالی شود تکرار می شود.

از آنجایی که برای هر تصویر متعلق به پایگاه داده استفاده شده تنها یک کادر محدود مشخص می شود، به نظر می رسد نیازی به استفاده از روش NMS نباشد. با این حال، در اینجا، به منظور محاسبه FP برای ارزیابی بهتر، روش NMS بر روی چهار ضلعی با امتیاز بالاتر از نمره اطمینان اعمال می شود.

### ۳. پیاده سازی و مشاهدات

در اینجا، به منظور ارزیابی روش تشخیص گره پیشنهادی، از مجموعه داده Lung-PET-CT-DX استفاده شده است [۲۳]. این مجموعه داده شامل تصاویر CT Dicom از سرطان ریه، موضوع با فایل های حاوی شیه نویسی XML برای هر تصویر CT است. محل ندول با یک کادر محدود نشان داده شده است. حاشیه نویسی هر تومور توسط پنج رادیولوژیست قفسه سینه با تخصص در سرطان ریه انجام می شود. چند نمونه از سی تی اسکن ریه با جعبه های محدود کننده آنها که گره ها را مشخص می کنند در شکل (۳) ارائه شده است. در اینجا از تصاویر ۲۳۵

YOLO یک شبکه عصبی کانولوشنال است. تعداد کل لایه ها در YOLO v3 107 لایه کانولوشن، با اتصالات پرش و لایه های up-sampling وجود دارد. در این مدل از پولینگ استفاده نمی شود و یک لایه کانولوشن با گام ۲ برای نمونه برداری از نقشه های ویژگی استفاده می شود.

این الگوریتم در سه مقیاس مختلف تشخیص را انجام میدهد. هر مقیاس وظیفه تشخیص اجسام با اندازه های مختلف را بر عهده دارد. تشخیص با اعمال هسته های تشخیص ۱×۱ بر روی نقشه های ویژگی با سه اندازه مختلف در سه مکان مختلف در شبکه بر روی تصاویر کاهش ابعاد داده شده به اندازه ۳۲، ۱۶ و ۴ انجام می شود.

### آموزش مدل :

فرآیند یادگیری در ۱۰۰ تکرار با اندازه دسته ای ۶۴ انجام شد. شبکه با استفاده از شیب نزولی تصادفی با بهینه ساز Adam و نرخ یادگیری استاندارد ۰,۰۰۱ آموزش داده شده است.

در اینجا از ترکیب خطی از دو تابع هزینه جداگانه برای تولید تابع ضرر نهایی - یکی برای جعبه مرزی و دیگری برای احتمال کلاس استفاده شد. خطای مربوط به جعبه مرزی خطای میانگین مربع (MSE) است که با استفاده از رابطه ۱ روی مختصات نقطه مرکزی و گوشه سمت چپ بالای مستطیل حاوی ندول محاسبه می شود.

$$\text{box\_loss} = \frac{1}{2N} \sum_1^N ((x'_1 - x_1^p) + (y'_1 - y_1^p) + (x'_2 - x_2^p) + (y'_2 - y_2^p))^2 \quad (1)$$

در این رابطه  $x'_1, x'_2, y'_1, y'_2$  مختصات نقاط دور مستطیل واقعی حاوی ندول و  $x_1^p, x_2^p, y_1^p, y_2^p$  مختصات نقاط دور مستطیل حاوی ندول تشخیص داده شده با مدل است. از تابع آنتروپی متقاطع باینری با فعال سازی لجستیک برای تابع هزینه تشخیص کلاس استفاده شده است.

$$\text{class\_loss} = -(y * \log(p) + (1-y) * \log(1-p)) \quad (2)$$

در اینجا منظور از  $\log$  لگاریتم طبیعی است،  $y$  یک مقدار باینری است که برای ندول واقعی مقدار ۱ و در غیر اینصورت مقدار صفر دارد و  $p$  احتمال پیش بینی شده است.

### نحوه ارزیابی :




بعد از اجرای مرحله آموزش، داده های تست به مدل اعمال میشود. نتایج به دست آمده حاصل از اعمال داده های تست به مدل در جدول زیر نمایش داده شده است.

در گزارش عملکرد دو رویکرد مورد توجه قرار گرفته شده است :

رویکرد اول: تمام چهارضلعی های به دست آمده پس از اعمال روش NMS به عنوان یک گره در نظر گرفته می شوند. واضح است که تعداد FN ها کاهش می یابد در حالی که تعداد FP ها افزایش می یابد.

رویکرد دوم: فقط یک چهارضلعی با بالاترین امتیاز به عنوان گره در نظر گرفته می شود. در اینجا، تعداد FN ها افزایش می یابد در حالی که تعداد FP ها کاهش می یابد. لازم به ذکر است که رد نکات مثبت واقعی می تواند کشنده باشد.

شکل (۳) نمونه هایی از خروجی روش YOLOv3 را نشان می دهد. در این شکل، دو نمونه از سی تی اسکن ها که در آنها بیش از یک ندول تشخیص داده شده است، ارائه شده است. در اینجا، جعبه های مرزی که تقریباً به درستی حاوی ندول های شناسایی شده هستند با رنگ سبز مشخص شده اند. مستطیل های با رنگ بنفش ندول کاذب را نشان میدهد.




شکل ۳ نتایج تشخیص ۴ نمونه از مجموعه تست. پیش بینی های صحیح و FP ها به ترتیب با مستطیل های سبز و بنفش مشخص شده است.

#### ۴. نتیجه گیری

در این مقاله، از روش YOLO که یک روش تشخیص اشیا مبتنی بر یادگیری عمیق است برای تشخیص ندول در سی تی

بیمار برای ارزیابی روش پیشنهادی استفاده شده است. ۱۴۸۰ تصویر متعلق به ۱۹ بیمار به عنوان مجموعه تست و ۱۱۵۰۴ اسکن مربوط به ۲۱۶ بیمار به عنوان مجموعه آموزش در نظر گرفته شده است.



شکل ۲ نمونه هایی از تصاویر پایگاه داده همراه با مستطیل های حاوی ندول

همانطور که گفته شد، برای هر تصویر، تنها یک کادر محدود کننده به عنوان محل گره مشخص شده است. جهت ارزیابی، یک جعبه مرزی شناسایی شده در صورتی مثبت واقعی (TP) در نظر گرفته می شود که IoU آن با حقیقت اصلی بیشتر از یک آستانه باشد و امتیاز اطمینان آن بیشتر از یک آستانه باشد. نقض هر یک از این دو شرط مثبت کاذب (FP) است. یک جعبه مرزی شناسایی شده که امتیاز اطمینان آن کمتر از یک آستانه باشد در حالی که قرار است یک ندول را تشخیص دهد به عنوان یک منفی کاذب (FN) در نظر گرفته می شود. یک جعبه مرزی شناسایی شده که امتیاز اطمینان آن کمتر از یک آستانه است در حالی که قرار نیست یک حقیقت پایه را تشخیص دهد به عنوان یک منفی واقعی (TN) به حساب می آید.

جدول ارزیابی تشخیص ندول

recall	precision	FN	FP	TP	
٪۸۲/۵۱	٪۷۹/۹۲	۲۵۹	۳۰۷	۱۲۲۲	رویکرد اول
٪۷۷/۲۹	٪۸۱/۴۲	۳۳۶	۲۶۱	۱۱۴۴	رویکرد دوم



- [9] Zuo, W., Zhou, F., Li, Z. and Wang, L., 2019. Multi-resolution CNN and knowledge transfer for candidate classification in lung nodule detection. *Ieee Access*, 7, pp.32510-32521.
- [10] Mittapalli, P.S. and Thanikaiselvan, V., 2021. Multiscale CNN with compound fusions for false positive reduction in lung nodule detection. *Artificial Intelligence in Medicine*, 113, p.102017.
- [11] Dutande, P., Baid, U. and Talbar, S., 2021. LNCDS: A 2D-3D cascaded CNN approach for lung nodule classification, detection and segmentation. *Biomedical Signal Processing and Control*, 67, p.102527.
- [12] Su, Y., Li, D. and Chen, X., 2021. Lung nodule detection based on faster R-CNN framework. *Computer Methods and Programs in Biomedicine*, 200, p.105866.
- [13] Kido, S., Hirano, Y. and Hashimoto, N., 2018, January. Detection and classification of lung abnormalities by use of convolutional neural network (CNN) and regions with CNN features (R-CNN). In 2018 International workshop on advanced image technology (IWAIT) (pp. 1-4). IEEE.
- [14] Girshick, R., Donahue, J., Darrell, T., and Malik, J. "Region-based convolutional networks for accurate object detection and segmentation". *IEEE transactions on pattern analysis and machine intelligence*, 38(1), 142-158, 2015.
- [15] Ren, S., He, K., Girshick, R., and Sun, J. "Faster r-cnn: Towards real-time object detection with region proposal networks". *Advances in neural information processing systems*, 28, 91-99, 2015.
- [16] Zhu, W., Liu, C., Fan, W., and Xie, X. "Deeplung: Deep 3d dual path nets for automated pulmonary nodule detection and classification". In 2018 IEEE Winter Conference on Applications of Computer Vision (WACV) (pp. 673-681). IEEE, March 2018.
- [17] Xie, H., Yang, D., Sun, N., Chen, Z., and Zhang, Y. "Automated pulmonary nodule detection in CT images using deep convolutional neural networks". *Pattern Recognition*, 85, 109-119, 2019.
- [18] Liu, M., Dong, J., Dong, X., Yu, H., and Qi, L. Segmentation of lung nodule in CT images based on mask R-CNN. In 2018 9th International Conference on Awareness Science and Technology (iCAST) (pp. 1-6). IEEE, September 2018.
- [19] Fan, W., Jiang, H., Ma, L., Gao, J., and Yang, H. "A modified faster R-CNN method to improve the performance of the pulmonary nodule detection". In 10th International Conference on Digital Image Processing (ICDIP 2018) (Vol. 10806, p. 108065A). International Society for Optics and Photonics, August 2018.
- [20] Redmon, J., Divvala, S., Girshick, R. and Farhadi, A., 2016. You only look once: Unified, real-time object detection. In *Proceedings of the IEEE conference on*

اسکن ریه استفاده شده است. ابتدا، پس زمینه و برخی از بخش‌های نامربوط تصاویر با استفاده از یک الگوریتم قطعه بندی مبتنی بر صفحه بیت حذف شدند. سپس برش های به دست آمده به مدل YOLO وارد شدند. خروجی مدل شامل مستطیل های با احتمال وقوع ندول است. الگوریتم NMS به عنوان یک مرحله پس از پردازش به منظور فیلتر کردن بهترین جعبه های مرزی استفاده شد. برای ارزیابی، پایگاه داده Lung-Pet-CT-DX مورد استفاده قرار گرفت. با در نظر گرفتن جعبه های کراندار با بالاترین امتیاز به عنوان ندول، از ۱۴۸۰ ندول،؟؟؟ ندول به درستی شناسایی شد.

مراجع:

- [1] Arenberg, D. "Update on screening for lung cancer. Translational lung cancer research", 8(Suppl 1), S77, 2019.
- [2] Taşçı, E. and Uğur, A., 2015. Shape and texture based novel features for automated juxtapleural nodule detection in lung CTs. *Journal of medical systems*, 39(5), pp.1-13.
- [3] Kumar, T.S., Narasimhan, G. and Umamaheswari, R., 2014. Texture pattern based lung nodule detection (TPLND) technique in ct images. *International Review on Computers and Software (IRECOS)*, 9(3), pp.415-426.
- [4] Fu, L., Ma, J., Ren, Y., Han, Y.S. and Zhao, J., 2017, March. Automatic detection of lung nodules: false positive reduction using convolution neural networks and handcrafted features. In *Medical Imaging 2017: Computer-Aided Diagnosis (Vol. 10134, pp. 60-67)*. SPIE.
- [5] Arulmurugan, R. and Anandakumar, H., 2018. Early detection of lung cancer using wavelet feature descriptor and feed forward back propagation neural networks classifier. In *Computational vision and bio inspired computing* (pp. 103-110). Springer, Cham.
- [6] Li, X., Shen, L. and Luo, S., 2017. A solitary feature-based lung nodule detection approach for chest X-ray radiographs. *IEEE journal of biomedical and health informatics*, 22(2), pp.516-524.
- [7] Naqi, S.M., Sharif, M. and Yasmin, M., 2018. Multistage segmentation model and SVM-ensemble for precise lung nodule detection. *International journal of computer assisted radiology and surgery*, 13(7), pp.1083-1095.
- [8] Murphy, K., van Ginneken, B., Schilham, A. M., De Hoop, B. J., Gietema, H. A., and Prokop, M. "A large-scale evaluation of automatic pulmonary nodule detection in chest CT using local image features and k-nearest-neighbor classification". *Medical image analysis*, 13(5), 757-770, 2009.



- computer vision and pattern recognition (pp. 779-788).
- [21] George, J., Skaria, S., and Varun, V. V. "Using YOLO-based deep learning network for real time detection and localization of lung nodules from low dose CT scans". In Medical Imaging 2018: Computer-Aided Diagnosis (Vol. 10575, p. 105751I). International Society for Optics and Photonics, February 2018.
- [22] Xinzhen, L., Wei, J., Gang, L., and Caoqian, Y. "YOLO V2 Network with Asymmetric Convolution Kernel for Lung Nodule Detection of CT Image". Chinese Journal of Biomedical Engineering, 2019.
- [23] A Large-Scale CT and PET/CT Dataset for Lung Cancer Diagnosis (Lung-PET-CT-Dx) The Cancer Imaging Archive (TCIA) Public Access, Cancer Imaging Archive Wiki.