

Original article



Automatic Diagnosis of Pulmonary Emphysema Using Optimized Unet-based Deep Neural Network

Safura Oveisi^{1*}, Mohammad Jafar Tarokh², Mohammad Kazem Momeni³

1. Ph.D. Student, Faculty of Industrial Engineering, K. N. Toosi University of Technology, Department of Information Technology Engineering, Tehran, Iran

2. professor, Faculty of Industrial Engineering, K. N. Toosi University of Technology, Department of Information Technology Engineering, Tehran, Iran

3. Associate Professor, Faculty of Medicine, Zahedan University of Medical Sciences, Zahedan, Iran

Article History:

Received: 17 Jan 2024

Accepted: 29 May 2024

Published: 20 Jun 2024

*Corresponding Author:

Safura Oveisi

Email:

safura.oveisi@email.knt.ac.ir

Citation: Oveisi S, Tarokh MJ, Momeni MK. Automatic Diagnosis of Pulmonary Emphysema Using Optimized Unet-based Deep Neural Network. Journal of Health and Biomedical Informatics 2024; 11(1): 43-59. [In Persian]

Abstract

Introduction: Pulmonary emphysema is one of the lung diseases that usually remains unknown until old age and does not have a definitive treatment. A quick diagnosis of this disease helps a lot to the people involved in this disease and prevents the growth of emphysema masses. This research tries to in early diagnosis of this disease with the help of deep learning methods.

Method: This research tries to diagnose this disease faster with the help of Unet neural network optimized with GPC meta-heuristic algorithm. The data of this research were collected from Imam Ali and Bu Ali Sina hospitals, Zahedan city, Sistan and Baluchistan province. The data include 300 pieces with emphysema, including 65 cases of CLE, 97 cases of PSE, 138 cases of PLE, and 45 cases of normal data. These data were analyzed by Unet deep neural network and GPC optimization algorithm, and finally, with the help of accuracy criteria, recall, specificity, and F-measure were compared and investigated with other methods.

Results: In this research, the criteria used have much better results compared to other emphysema diagnosis methods with the help of the optimized Unet network, with accuracy of 18.97, prediction of 40.98, sensitivity of 48.23, and f score of 97.50, respectively, which shows a faster, more accurate, and more effective diagnosis of this disease with the help of the proposed method.

Conclusion: Using the right deep learning methods in combination with strong optimization algorithms can enable faster and more accurate treatment of diseases.

Keywords: Artificial intelligence, Neural networks, Pulmonary emphysema, Image processing, Deep Learning

© 2024 The Author(s); Published by Kerman University of Medical Sciences. This is an open-access article distributed under the terms of the Creative Commons Attribution License (<http://creativecommons.org/licenses/by/4.0/>), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cite



CrossMark

مقاله پژوهشی

تشخیص خودکار آمفیژم ریوی با استفاده از شبکه عصبی عمیق مبتنی بر Unet بهینه‌سازی شده

صفورا اویسی^{۱*}، محمدجعفر تارخ^۲، محمد کاظم مومنی^۳

۱. دانشجوی دکتری مهندسی فناوری اطلاعات، دانشکده صنایع، گروه مهندسی فناوری اطلاعات، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران

۲. استاد، دانشکده صنایع، گروه مهندسی فناوری اطلاعات، دانشگاه خواجه نصیرالدین طوسی، تهران، ایران

۳. دانشیار، دانشکده پزشکی، دانشگاه علوم پزشکی زاهدان، زاهدان، ایران

چکیده

مقدمه: یکی از بیماری‌های ریوی که معمولاً تا سنین بالا ناشناخته می‌ماند و درمان قطعی ندارد، آمفیژم ریوی است که تشخیص سریع این بیماری به افراد درگیر در این بیماری کمک زیادی می‌کند و از رشد توده‌های آمفیژم جلوگیری می‌کند. این تحقیق سعی در تشخیص زودهنگام این بیماری به کمک روش‌های یادگیری عمیق دارد.

روش کار: این تحقیق با کمک شبکه عصبی Unet بهینه‌سازی شده با الگوریتم فراابتکاری GPC، سعی در تشخیص سریع‌تر این بیماری دارد. داده‌های این پژوهش از بیمارستان‌های امام علی و بوعلی سینا شهرستان زاهدان استان سیستان و بلوچستان جمع‌آوری شده است. داده‌ها شامل ۳۰۰ قطعه با آمفیژم شامل ۶۵ مورد CLE، ۹۷ مورد PSE و ۱۳۸ مورد PLE و ۴۵ مورد داده نرمال است. این داده‌ها توسط شبکه عصبی عمیق Unet و با الگوریتم بهینه‌سازی GPC مورد بررسی قرار گرفتند و در نهایت به کمک معیارهای recall, accuracy, specificity و F-measure با سایر روش‌های انجام شده مورد مقایسه و بررسی قرار گرفتند.

یافته‌ها: در این پژوهش معیارهای به کاررفته به ترتیب با دقت ۹۷/۱۸، پیش‌بینی ۹۸/۴۰، حساسیت ۴۸/۲۳ و امتیاز f ۵۰/۹۷، نتایج بسیار بهتری در مقایسه با سایر روش‌های تشخیص آمفیژم به کمک شبکه Unet بهینه شده داشته است که نشان از تشخیص سریع‌تر و دقیق‌تر و اثر بخش‌تر این بیماری به کمک روش پیشنهادی دارد.

نتیجه‌گیری: استفاده از روش‌های درست یادگیری عمیق در ترکیب با الگوریتم‌های بهینه‌سازی قوی می‌تواند درمان سریع‌تر و دقیق‌تر بیماری‌ها را امکان‌پذیر سازد.

اطلاعات مقاله:

سابقه مقاله:

دریافت: ۱۴۰۲/۱۰/۲۷

پذیرش: ۱۴۰۳/۳/۹

انتشار برخط: ۱۴۰۳/۳/۳۱

*نویسنده مسئول:

صفورا اویسی

ایمیل:

safura.oviesi@mail.knt.ac.ir

ارجاع:


اویسی صفورا، تارخ محمدجعفر، مومنی محمدکاظم. تشخیص خودکار آمفیژم ریوی با استفاده از شبکه عصبی عمیق مبتنی بر Unet بهینه‌سازی شده. مجله انفورماتیک سلامت و زیست

مقدمه

امروزه با افزایش استعمال دخانیات در جامعه، بیماری‌های ریوی تا حدود زیادی افزایش یافته است. یکی از بیماری‌های ریوی که تحت تأثیر مستقیم استعمال دخانیات بالاخص مصرف زیاد سیگار می‌باشد، بیماری آمفیزم ریوی است [۱]. آمفیزم یک بیماری ریوی است که در آن آلوئول‌های داخل ریه آسیب می‌بینند. آلوئول‌ها که به آن‌ها کیسه‌های هوایی نیز می‌گویند، ساختارهایی هستند که از طریق آن‌ها اکسیژن وارد خون می‌شود. آسیب به آلوئول‌ها و از بین رفتن آن‌ها، باعث می‌شود که تبادل هوا در ریه‌ها قطع شود. مواردی مانند: سیگار کشیدن، کمبود آلفا ۱ آنتی تریپسین (AAT) و آلودگی هوا از عوامل متعددی هستند که می‌توانند باعث ابتلا به این بیماری شوند [۱]. آمفیزم ریوی ۳ نوع مختلف دارد که عبارت‌اند از: آمفیزم سنتروآسینار که بخش‌های میانی ریه را درگیر می‌کند (۲) آمفیزم پان آسینار که در این نوع آمفیزم آلوئول‌های تنفسی افزایش حجم دارند و برخلاف نوع سنتروآسینار که میانه ریه را دربر می‌گیرد، این نوع آمفیزم از ابتدای برونکیول تنفسی (جایی که آلوئول شروع شده و تنفس آناتومیک آغاز می‌شود) تا آخرین آلوئول در کف شش‌ها را درگیر می‌کند و در حقیقت بیشترین صدمه را بخش پایینی شش‌ها می‌بینند. (۳) آمفیزم پاراسکتال که ین نوع آمفیزم تنها بخش‌های دیستال شش را دربر گرفته و صدمه به آسینارها در انتهای دیواره‌های همبندی (کانکتیو) و بخش مجاور به پرده جنب (پلئور) در ریه است [۲]. روش‌های مختلفی برای تشخیص آمفیزم وجود دارد که امروزه روش hrct و استفاده از عکس‌های سی تی اسکن برای بررسی میزان و شدت آمفیزم به کار می‌رود که توسط پزشک متخصص و سایر روش‌های نوین تجزیه و تحلیل می‌شوند [۳].

در سال‌های اخیر، تلاش‌های قابل توجهی در تشخیص تصاویر پزشکی به کمک کامپیوترها، برای بهبود اعتماد پزشک در تجزیه و تحلیل تصاویر پزشکی انجام شده است. ارزیابی تصاویر پزشکی توسط پزشک ماهیت کیفی دارد و ممکن است از فردی به فرد دیگر متفاوت باشد. تلاش‌های تحقیقاتی زیادی در زمینه «تحلیل تصویر پزشکی» با هدف کمک به تشخیص و مطالعات بالینی انجام شده است [۴]. تجزیه و تحلیل تصاویر پزشکی به دست آمده از سیستم‌های تصویربرداری مختلف مانند MRI، سی تی اسکن و سونوگرافی، به کمک کامپیوتر شامل چهار مرحله اساسی است: الف) فیلتر کردن یا پیش پردازش تصویر، ب) تقسیم بندی تصویر، ج) استخراج ویژگی، و د) طبقه بندی یا تجزیه و تحلیل ویژگی‌های استخراج شده توسط طبقه بندی کننده یا سیستم تشخیص الگو که در این بین تقسیم بندی تصاویر و طبقه بندی آن از اهمیت ویژه ای برخوردار است و هوش مصنوعی با کمک روش‌های یادگیری ماشینی نقش بسیار مهمی در انجام این دو مرحله دارد. امروزه پژوهش‌های زیادی در مورد تشخیص بیماری‌های تنفسی به کمک روش‌های یادگیری ماشینی نوشته شده است؛ اما متأسفانه مطالعات کمی در زمینه تشخیص آمفیزم ریه انجام شده است که این تحقیق تکمیل کننده سایر مطالعات در زمینه تشخیص این بیماری است تا به تشخیص هر چه سریع‌تر و دقیق‌تر این بیماری کمک کند و این خود، ضرورتی برای انجام این پژوهش است. با توجه به انواع آمفیزم ریه و درگیری نواحی مختلف ریه، نیازمند روشی است تا بتوان با تقسیم بندی مناسب نواحی درگیر، تشخیص سریع‌تری در زمینه آمفیزم داشت. یکی از بهترین روش‌های قطعه بندی استفاده از شبکه‌های Unet است که به ویژه برای داده‌های کوچک بسیار موفق است و چون داده‌های ما نسبتاً محدود است Unet می‌تواند در تقسیم بندی سریع و صحیح این داده‌ها به ما بهتر کمک کند [۵]، اما با توجه به تعداد زیاد پارامترهای استخراج شده، استفاده از روش‌های بهینه سازی که می‌تواند کمک زیادی به در بهینه سازی تعداد زیاد پارامترها کند، می‌تواند بسیار مؤثر باشد، بنابراین استفاده از یک روش بهینه سازی که در این زمینه کمک کند و نتایج بهتری در ترکیب با شبکه Unet داشته باشد، بسیار مؤثر خواهد بود و ما برای نتایج عالی GPC نسبت به سایر الگوریتم‌های بهینه سازی، از الگوریتم GPC به عنوان یک الگوریتم بهینه سازی ترکیبی استفاده می‌کنیم [۶].

شبکه U-net به ما کمک می‌کند تا این بیماری را سریع‌تر تشخیص داد و در عین حال آمفیزم به درستی تقسیم‌بندی شود. شکل ۱ انواع مختلف آمفیزم را نشان می‌دهد.



شکل ۱: (a) آمفیزم سانتریال سینار (b) آمفیزم پانلوبولار (c) آمفیزم پاراسپتال (d) نرمال

Mondal و همکاران به تشخیص خودکار آمفیزم ریوی به کمک روش چند هدفه از آستانه باینری و کلاس‌بندی ترکیبی پرداختند. در این روش ابتدا به پیش پردازش مجموعه داده‌ها پرداخته شد و سپس تصاویر به کمک روش بهینه‌سازی باینری محلی قطعه بندی شدند، در مرحله سوم استخراج ویژگی‌ها به کمک توصیفگر wlbپ انجام شد و سپس طبقه‌بندی تصاویر به دست آمده به کمک شبکه‌های عصبی و شبکه‌های عصبی پیچشی انجام شد که منجر به طبقه‌بندی ریه طبیعی، آمفیزم خفیف، آمفیزم متوسط (متوسط) و آمفیزم شدید شد. در این روش از الگوریتم‌های فراابتکاری ترکیبی (BOA) (Barnacles Mating Optimization) و الگوریتم بهینه‌سازی پروانه (BOA) که به نام الگوریتم بهینه‌سازی پروانه مبتنی بر جفت گیری (BM-BOA) نامیده می‌شود، استفاده شده است و دقت این روش ۹۳/۷۵ شناسایی شد [۲].

Parui و همکاران رویکرد جدیدی را برای تعیین آمفیزم ریه از طریق عکس‌های سی تی اسکن قفسه سینه مورد بررسی قرار دادند. آن‌ها تشخیص آمفیزم را در سه گام ۱- جمع‌آوری داده ۲- پیش پردازش داده و ۳- طبقه بندی تصاویر انجام دادند. تصاویر به دو گروه طبیعی و C.T حاوی ریه با آمفیزم تقسیم می‌شوند. در این روش از یک شبکه عصبی پیچشی برای طبقه بندی تصاویر استفاده می‌شود و میزان دقت شناسایی تصاویر درست به ۵۴ درصد می‌رسد سپس از یک شبکه VGG16 از قبل آموزش دیده برای طبقه بندی عکس‌های سی تی اسکن استفاده شد که تصاویر آمفیزم را بهتر از شبکه عصبی پیچشی با دقت ۸۸ درصد شناسایی می‌کرد [۳].

Isaac و همکاران یک سیستم تشخیص به کمک رایانه را برای کمک به رادیولوژیست‌ها در تشخیص آمفیزم از برش‌های سی تی سی تی سینه (CT) توسعه دادند. در این روش ابتدا قطعه‌بندی تصاویر، به کمک الگوریتم فازی صورت می‌گرفت سپس به استخراج نواحی موردنظر و بردار ویژگی پرداخته می‌شد، انتخاب ویژگی توسط دو الگوریتم بهینه سازی میمون عنبکوتی و میدان برنجی صورت می‌گرفت و سپس طبقه‌بندی تصاویر به کمک کلاس بند انجام می‌شد و در نهایت، نتیجه پیش بینی بیمار، دارای آمفیزم یا نرمال مشخص می‌شد. دقت به دست آمده از این روش ۹۱/۸۹ است [۱،۷].

Oh و همکاران یک تکنیک یادگیری عمیق را برای آمفیزم خودکار معرفی کرده‌اند. در این روش به مقایسه پیش‌بینی‌های حاصل از روش یادگیری عمیق با نتایج واقعی بیماران دارای آمفیزم پرداخته شد. نمرات آمفیزم پیش‌بینی‌شده توسط مدل یادگیری عمیق، نشان

داد که مدل پیش بینی شده ارتباط معنی داری با PFTs، سابقه سیگار کشیدن و SGRQ داشت که مشابه با آنچه در مقایسه با نمرات بصری مشاهده شده بود، بود [۴].

Sorensen و همکاران از یک سیستم طبقه بندی مبتنی بر بافت برای کمی سازی آمفیژم موجود در تصاویر CT استفاده کردند تا از این طریق به پیش بینی شدت آمفیژم بپردازند. در این روش، پیش پردازش داده ها به کمک روش هیستوگرام و فیلتر گاوسی صورت گرفت و پس از مشخص شدن ROI ها، طبقه بندی تصاویر به کمک الگوریتم K-MEN (نزدیک ترین همسایه) انجام شد که سبب شد دقت طبقه بندی تصاویر در این روش به ۹۵/۲٪ برسد [۵].

Peng و همکاران به طبقه بندی آمفیژم به کمک یک روش یادگیری عمیق پرداختند در این روش ابتدا قطعه های مورد نظر پیش پردازش و از هر قطعه، بافت های مورد نظر حاوی آمفیژم استخراج شد، سپس هر بافت توسط دو روش MSLF و MSCF مورد بررسی قرار گرفت و در نهایت توسط شبکه RESNET طبقه بندی مورد نظر انجام شد. دقت طبقه بندی این روش به ۹۳/۷۴ درصد می رسد [۶].

Tang و همکاران استفاده از شبکه های باقی مانده عمیق، که نوعی شبکه باقی مانده مصنوعی است را برای تشخیص خودکار COPD مورد بررسی قرار دادند [۸].

الگوریتم ساخت اهرام ثلاثه جیزه با پنج الگوریتم مشهور و کارآمد از جمله الگوریتم ژنتیک (Genetic Algorithms) [۹]، رقابت امپریالیستی (Imperialist Competitive Algorithm) [۱۰]، بهینه سازی ازدحام ذرات (Particle Swarm Optimization) [۱۱]، تکامل تفاضلی (Differential Evolution Algorithm) [۱۲] و الگوریتم کرم شب تاب (Firefly Algorithm) [۱۳] مقایسه می شود. در این مقایسه از توابع تست برای ارزیابی ویژگی های الگوریتم های بهینه سازی استفاده شده است این توابع برای ارزیابی دقت، کارایی، عملکرد و نرخ همگرایی الگوریتم ها استفاده می شوند. برای این که نتایج آزمایش با هم قابل مقایسه باشند تنظیمات همه الگوریتم ها مشابه یکدیگر است. برای این هدف، جمعیت اولیه برای همه الگوریتم ها ۲۰ در نظر گرفته شده است. همچنین تعداد متغیرهای تصمیم گیری برای همه الگوریتم ها ۳۰ در نظر گرفته شده است، همچنین متغیرهای تصمیم گیری ابعاد هر مسئله را مشخص می کنند و هر الگوریتم ۵۰ بار اجرا می شود [۱۴]. انحراف استاندارد این ۵۰ اجرا به صورت مستقل ثبت می شود. شرط توقف همه الگوریتم ها تعداد ارزیابی عملکرد (NEE) است به عبارتی هر وقت تابع NEE فراخوانی شود تمام الگوریتم ها متوقف می شوند. میانگین و انحراف معیار ۵۰ اجرای مستقل از تمامی الگوریتم ها در جدول ۱ نشان داده شده است [۱۵].

جدول ۱: مقایسه روش GPC با سایر الگوریتم‌های بهینه‌سازی

Fn	NFE	Algorithms					
		PSO		DE		GPC	
		dim = 5000	dim = 10,000	dim = 5000	dim = 10,000	dim = 5000	dim = 10,000
f_1	10^3	17.4625 ± 0.4382	17.5663 ± 0.3181	21.2406 ± 0.0068	21.2453 ± 0.0056	0.0002 ± 0.0001	$0.0002 \pm 9.83e-05$
f_2	10^3	0.1524 ± 0.3213	0.1571 ± 0.3312	0.0258 ± 0.0206	0.0266 ± 0.0343	0.0215 ± 0.0228	0.0210 ± 0.0233
f_3	10^3	0.1533 ± 0.1833	0.1934 ± 0.1997	0.5515 ± 0.2689	0.6216 ± 0.3458	0.0000 ± 0.0000	0.0000 ± 0.0000
f_4	10^3	0.5543 ± 0.6417	0.1180 ± 0.3034	0.3446 ± 0.2294	0.2900 ± 0.3844	0.0005 ± 0.0004	0.0002 ± 0.0003
f_5	10^3	1.1992 ± 0.7266	0.9579 ± 0.5248	1.9607 ± 1.1478	2.2840 ± 1.3836	$0.1000 \pm 2.21e-05$	0.1800 ± 0.2531
f_6	10^3	$-1.0315 \pm 9.6e-05$	-1.0315 ± 0.0001	-1.0298 ± 0.0011	-1.0286 ± 0.0033	$-1.0316 \pm 2.34e-16$	$-1.0316 \pm 2.34e-16$
f_7	10^3	$1.34e-05 \pm 1.7e-05$	$4.08e-05 \pm 4.6e-05$	0.0013 ± 0.0019	0.0028 ± 0.0062	$3.15e-21 \pm 9.25e-21$	$2.81e-19 \pm 8.76e-19$
f_8	10^3	$-2.0625 \pm 3.1e-05$	-2.0626 ± 0.0000	-2.0624 ± 0.0001	-2.0624 ± 0.0002	-2.0624 ± 0.0001	-2.0625 ± 0.0001
f_9	10^3	7.4621 ± 3.6801	5.1256 ± 3.7951	2.2932 ± 1.9248	2.8160 ± 2.4803	0.9780 ± 0.0632	2.1851 ± 1.7851
f_{10}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	0.9998 ± 0.0005	0.9096 ± 0.2844
f_{11}	10^3	-0.9695 ± 0.0298	-0.9677 ± 0.0299	-0.9301 ± 0.0113	-0.9386 ± 0.0214	-1.0000 ± 0.0000	-1.0000 ± 0.0000
f_{12}	10^3	-0.9887 ± 0.0123	-0.9797 ± 0.0360	Infeasible	Infeasible	-0.9894 ± 0.0144	-0.9887 ± 0.0140
f_{13}	10^3	Infeasible	Infeasible	-905.85 ± 30.481	-903.60 ± 50.648	-932.03 ± 33.306	-911.32 ± 59.638
f_{14}	10^3	Infeasible	Infeasible	Infeasible	Infeasible	159.34 ± 160.23	302.43 ± 231.76
f_{15}	10^3	-18.3868 ± 2.5713	-18.7544 ± 0.4270	-18.8650 ± 0.3702	-19.0553 ± 0.3666	-19.1772 ± 0.0273	-19.2031 ± 0.0080
f_{16}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	$6.87e-12 \pm 2.62e-12$	$4.99e-10 \pm 4.25e-10$
f_{17}	10^3	$12,104 \pm 1240$	$24,421 \pm 2681$	$62,575 \pm 671$	$126,570 \pm 708$	454.48 ± 0.040	908.72 ± 0.089
f_{18}	10^3	0.0005 ± 0.0007	0.0019 ± 0.0018	0.6235 ± 0.5093	0.5282 ± 0.4862	0.0113 ± 0.0092	0.0344 ± 0.0326
f_{19}	10^3	$1.05e-05 \pm 1.5e-05$	$1.10e-05 \pm 1.4e-05$	0.0365 ± 0.0770	0.0295 ± 0.0343	$8.31e-21 \pm 2.62e-20$	$3.93e-20 \pm 1.22e-19$
f_{20}	10^3	Infeasible	Infeasible	Infeasible	Infeasible	Infeasible	Infeasible
f_{21}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	$4.31e-16 \pm 4.14e-16$	$2.13e-15 \pm 1.57e-15$
f_{22}	10^4	$49,407 \pm 998$	$103,949 \pm 1711$	Infeasible	Infeasible	0.0000 ± 0.0000	0.0000 ± 0.0000
f_{23}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	499.878 ± 0.329	999.879 ± 0.325
f_{24}	10^3	0.0005 ± 0.0010	0.0004 ± 0.0005	0.0435 ± 0.0363	0.0965 ± 0.0557	0.0000 ± 0.0000	0.0000 ± 0.0000
f_{25}	10^3	$0.5001 \pm 1.5e-05$	$0.5001 \pm 4.5e-05$	$0.5001 \pm 7.8e-06$	$0.5001 \pm 1.5e-05$	$0.5000 \pm 6.9e-06$	$0.5000 \pm 1.2e-05$
f_{26}	10^3	-155.04 ± 30.968	-157.40 ± 32.344	-157.17 ± 19.980	-168.52 ± 21.645	-183.52 ± 6.5020	-186.27 ± 0.9449
f_{27}	10^3	7277.5 ± 829	$14,849.9 \pm 1228$	$42,690.2 \pm 302$	$86,051.3 \pm 258$	$1.20e-07 \pm 1.17e-07$	$1.29e-07 \pm 1.03e-07$
f_{28}	10^3	1.1608 ± 1.9391	5.3391 ± 0.8236	4.0833 ± 0.8357	4.8182 ± 0.6840	$3.22e-23 \pm 1.00e-22$	$1.01e-25 \pm 1.90e-25$
f_{29}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	$5.01e-13 \pm 4.58e-13$	$3.10e-12 \pm 4.02e-12$
f_{30}	10^4	Infeasible	Infeasible	Infeasible	Infeasible	$2.52e-07 \pm 4.83e-07$	$8.70e-05 \pm 0.0002$

یکی از نقاط قوت الگوریتم GPC این است که از اطلاعات موجود جمعیت به طور کامل برای جهت‌دهی هوشمندانه فرآیند جستجو و بهینه‌سازی استفاده می‌کند و در نتیجه راه‌حل‌های بهتری به دست می‌آورد. طبیعت استفاده از الگوریتم GPC این است که اطلاعات قبلی را به خوبی حفظ می‌کند به این معنی که الگوریتم حافظه دارد. این ویژگی در GA وجود ندارد؛ اما مشابه این ویژگی [۱۶] در الگوریتم PSO مشاهده می‌شود. در GA هنگامی که جمعیت تغییر می‌کند، دانش قبلی ناپدید می‌شود؛ اما همان‌طور که ذکر شد در GPC اطلاعات مطلوب حفظ می‌شود. در الگوریتم پیشنهادی در هر تکرار، جمعیت با عضو برتر این جا، یعنی عامل ویژه فرعون، مقایسه می‌شود به این ترتیب، مردم در واقع اطلاعات خود را به اشتراک می‌گذارند و دانش مشابه این ویژگی در PSO وجود دارد. این الگوریتم علاوه بر ویژگی‌های خوب GA و الگوریتم‌های PSO، ویژگی سرعت بالا، نیز که از الگوریتم DE که یک الگوریتم سریع و کارآمد است و از اطلاعات جهت و فاصله اعضا برای یافتن راه‌حل بهینه استفاده می‌کند به ارث برده است. این ویژگی در الگوریتم GPC وجود دارد [۱۷]. سرعت همگرایی و سرعت یافتن بهینه عمومی بسیار زیاد است، زیرا موقعیت کل جمعیت در حال تغییر است به این معنی است که هر یک از اعضا امیدوار به یافتن راه حل بهینه هستند. جایگزینی کارگران یک عملیات بسیار مفید است که تعادل بین اکتشاف و بهره‌برداری را افزایش می‌دهد. برخلاف PSO، GPC همگرایی زودرس ندارد. اجرای الگوریتم‌ها در ابعاد بالا نشان می‌دهد که برخی از راه‌حل‌های به دست آمده از برخی الگوریتم‌ها در محدوده قابل قبولی نیستند؛ بنابراین چنین راه‌حل‌هایی در جدول به عنوان «غیر قابل اجرا» مشخص شده است. این بدان معنا است که الگوریتم قادر به ارائه یک راه‌حل مناسب نیست؛ ولی همان‌طور که جدول ۱ نشان می‌دهد، الگوریتم GPC برای همه ابعاد بالا به خوبی کار می‌کند و راه حل قابل قبولی ارائه می‌دهد به جز تابع ۲۰، در حالی که الگوریتم PSO در ۹ تابع از ۳۰ تابع غیرقابل قبول است. الگوریتم DE نیز در ۱۰ مورد به خوبی عمل نمی‌کند و اگر راه‌حل‌های امکان‌پذیر با هم مقایسه شود راه حل‌های این الگوریتم بسیار بهتر از راه‌حل‌های ارائه شده توسط PSO و DE می‌باشد. با این اوصاف این الگوریتم نسبت به سایر الگوریتم‌های بهینه‌سازی برتری ویژه‌ای از لحاظ سرعت و یافتن جواب بهینه در ابعاد بالا دارد که الگوریتم مناسبی برای این تحقیق می‌باشد.


روش کار

مجموعه داده

داده‌های این پژوهش از بیمارستان‌های امام علی و بوعلی سینا شهرستان زاهدان در استان سیستان و بلوچستان در سال ۱۴۰۱ جمع آوری شد. این داده‌ها شامل ۳۰۰ قطعه با آمفیزم و ۴۵ قطعه طبیعی است. به طور کلی داده‌ها از یک گروه ۱۱۵ نفری جمع آوری و هر برش از سه زاویه پایین، وسط و بالا مورد بررسی قرار گرفت و سپس هر قطعه به عنوان نام منطقه مورد نظر (پایین، وسط، بالا) نام‌گذاری شد. عکس‌ها ابتدا توسط رادیولوژیست خبره ارزیابی و سپس در ابزار ITKSNAP قطعه بندی و نواحی دارای ضایعات آمفیزم استخراج شد.

برش‌های ۲۵۶*۲۵۶ پیکسلی در قسمت بالایی، میانی و پایینی ریه هر فرد به دست آمد و این برش‌ها همگی از یکدیگر متمایز بودند؛ بنابراین در مجموع ۱۰۰ برش سی تی اسکن موجود است. یک رادیولوژیست با تجربه قفسه سینه و یک فوق تخصص ریه با تجربه CT هر کدام تصاویر اصلی (یا بافت طبیعی (Normal)، آمفیزم مرکز لوبولار (center lobular Emphysema)، آمفیزم پاراستاتال (par septal emphysema) یا آمفیزم پانلوبولار (pan lobular emphysema) را مورد بررسی قرار دادند و با برچسب زدن نوع هر مورد کمک زیادی به ما در تشخیص این بیماری کردند.

در مجموع از ۳۴۵ برش انجام شده ۴۵ مورد طبیعی، ۶۵ مورد CLE، ۹۷ مورد PSE و ۱۳۸ مورد PLE مشاهده شدند. در این پژوهش از ۷۵ درصد داده‌ها برای آموزش و ۱۵ درصد از داده‌ها برای اعتبار سنجی و ۱۰ درصد داده‌ها برای آزمون استفاده شد.




شکل ۲: تشخیص انواع مختلف آمفیوزم در بخش‌های مختلف ریه

روش و الگوریتم به کاررفته در این تحقیق

شبکه U-Net

در میان الگوریتم‌های یادگیری عمیق، الگوریتم U-Net مزایای بیشتری نسبت به سایر الگوریتم‌های قطعه‌بندی تصاویر پیدا کرده است که از جمله این مزایا می‌توان به سرعت و دقت بالا در آموزش و یادگیری و عدم نیاز به مجموعه داده‌های بزرگ و سخت افزار پیچیده و گران قیمت اشاره کرد که این خود سبب شده در قطعه‌بندی تصاویر به خصوص تصاویر پزشکی محبوبیت ویژه‌ای پیدا کند [۵]. معماری U-Net یک شبکه عصبی پیچشی است که در اصل برای بخش بندی تصاویر در حوزه پزشکی طراحی شده است. شمایل این معماری شبیه حرف U انگلیسی است و به همین دلیل نیز U-Net یا شبکه U شکل نامیده می‌شود. معماری این شبکه از دو بخش تشکیل شده است؛ بخش سمت چپ، مسیر فشرده‌سازی و بخش سمت راست، مسیر گسترده‌سازی است. هدف از مسیر فشرده‌سازی درک مفهوم کلی تصویر و هدف از مسیر گسترده‌سازی کمک کردن در فرآیند مکان‌یابی دقیق اشیاء است. مسیر فشرده‌سازی متشکل از ۲ لایه ۳*۳ پیچشی است. هر یک از این لایه‌های پیچشی، یک تابع فعال‌سازی Relu و یک الگوریتم max-pooling ۲*۲ برای کاهش نمونه‌گیری و نگاشت ویژگی دارد [۵]. شکل ۳ این معماری را به درستی نشان می‌دهد.




شکل ۳: ساختار شبکه U-Net

الگوریتم فراابتکاری ساخت اهرام جیزه

الگوریتم ساخت اهرام جیزه [۱۸] یک روش الهام گرفته از گذشته یا باستان می‌باشد. در دوران باستان محدودیت‌های متعددی وجود داشت؛ اما سازه‌های مختلف دست‌ساخته کارگران و صنعتگران، نشان می‌دهد که محدودیت‌ها و کمبود امکانات سخت‌افزاری و نرم‌افزاری به نوعی به عنوان بهینه‌ساز، عمل کرده است. کارگران اهرام جیزه، برده، سنگ تراش، فلزکار، نجار هستند که توسط یک عامل متخصص رهبری می‌شوند. این مأمور متخصص، مأمور ویژه فرعون است. کارگران بلوک‌های سنگی را حمل می‌کنند و این کار تحت نظارت مستقیم عامل فرعون انجام می‌شود. ممکن است در این میان، کارگران مختلفی وجود داشته باشند که هر کدام مسئول حمل یک بلوک سنگی هستند.

برای ساخت هرم از سطح شیبدار استفاده شده است و کارگر مسئول، وظیفه دارد فاصله بلوک سنگ تا محل نصب آن در هرم را بسنجد. مسافت طی شده برای هل دادن سنگ با توانایی کارگران سنجیده می‌شود و در طول روز کاری، اگر نیروی کافی در دسترس باشد؛ حمل و نقل بیشتری توسط کارگران انجام می‌شود یا بلوک را به محل نصب در هرم نزدیک‌تر می‌کند. علاوه بر آن، گرادیان سطح شیب دار، سرعت اولیه و نیروی اصطکاک بر حرکت بلوک سنگ تأثیر می‌گذارد. نحوه کار این الگوریتم در شکل ۴ نشان داده شده است.



شکل ۴: نحوه کار در ساخت اهرام جیزه



الگوریتم پیشنهادی یک الگوریتم مبتنی بر جمعیت است که با حرکات کارگران و هل دادن بلوک‌های سنگی روی سطح شیب دار کنترل می‌شود. این الگوریتم می‌تواند به عنوان یک روش بهینه‌سازی اساسی در بسیاری از حوزه‌های دانش از جمله علوم مهندسی، مورد استفاده قرار گیرد. آزمایش‌ها نشان داده است که الگوریتم پیشنهادی قادر به مقابله با مسائل با ابعاد بالا است. ارزیابی‌ها همچنین نشان داده اند که الگوریتم پیشنهادی برای استفاده در پردازش تصویر و بخش بندی به خوبی کار می‌کند. الگوریتم ساخت اهرام ثلاثه جیزه به شکل زیر می‌باشد [۱۸].

Algorithm 1: Pseudo-code of the Giza Pyramids Construction (GPC) Algorithm.

STEP 1:

generate initial population array of stone blocks or workers (Population size);
generate position and cost of stone block or worker;
determine best worker as Pharaoh's agent;

STEP 2: for FirstIteration to MaxIteration do

STEP 3: for i=1 to n do (all n stone blocks or workers)

calculate amount of stone block displacement (Eq. 4);
calculate amount of worker movement (Eq. 7);
estimate new position (Eq. 8);
investigate possibility of substituting workers (Eq. 9);
determine new position and new cost;
if new_cost < Pharaoh's agent cost then
set new_cost as Pharaoh's agent cost;

end if

END STEP 3

Sort solutions for next iteration;

END STEP 2

END STEP 1


فرآیند روش پیشنهادی

روش پیشنهادی این مطالعه شامل ۳ مرحله اصلی است: ۱- پیش پردازش تصاویر دریافتی ۲- تقسیم بندی تصاویر ۳- طبقه بندی تصاویر

پیش پردازش تصاویر

پیش پردازش فرآیندی است که برای افزایش دقت و قابلیت تفسیر استفاده می‌شود. پیش پردازش تصویر یک عامل مهم و چالش برانگیز در سیستم‌های تشخیصی به کمک رایانه است. در پردازش تصویر پزشکی، وظیفه تقسیم‌بندی، پیش پردازش تصویر بسیار مهم است تا الگوریتم‌های تقسیم‌بندی و استخراج ویژگی به درستی کار کنند. در این زمینه، تکنیک‌های اصلی برای پیش پردازش عبارت‌اند از: فیلتر میانی تطبیقی، فیلتر میانگین آلفا، فیلتر گاوسی، فیلتر گابور، فیلتر بالاگذر، فیلتر لاپلاسین، فیلتر دوطرفه [۲۰]، تحقیقات نشان می‌دهد که فیلتر دوطرفه در پیش پردازش سی تی اسکن ریه دارای MSE و PSNR بهتری است. (برای اندازه‌گیری میزان اعوجاج تصویر استفاده می‌شود)؛ بنابراین از فیلتر دوطرفه نیز استفاده شد که یک نمونه از تصاویر پیش پردازش شده در شکل ۵ نشان داده شده است. سطوح خاکستری رنگ آن به نزدیکی هندسی و مقایسه نورسنجی آن‌ها بستگی دارد و به سمت مقادیر نزدیک به مقادیر غیرقابل دسترس در هر دو حوزه و محدوده متمایل است. یک فیلتر دوطرفه رنگ‌ها را صاف می‌کند و لبه‌های محافظتی را به گونه‌ای تنظیم می‌کند که برای تشخیص انسان تنظیم شده است. خروجی فیلتر دوطرفه از معادله ۶ به دست می‌آید:

$$BF[I]_p = \frac{1}{W_p} \sum_{q \in s} G_{\sigma_s}(\|p - q\|) G_{\sigma_r}(\|I_p - I_q\|) I_q$$




شکل ۵: یک نمونه از عکس‌های پیش پردازش شده ریه

قطعه‌بندی و کلاس‌بندی تصاویر


پس از پیش‌پردازش تصاویر و انتخاب ROIهای مورد نظر، تصاویر انتخاب شده برای تقسیم‌بندی وارد Unet شدند. Unet یک چارچوب تقسیم‌بندی نمونه شیء عمومی کوچک و انعطاف‌پذیر است. این نه تنها اهداف را در تصویر شناسایی می‌کند، بلکه یک نتیجه تقسیم‌بندی با کیفیت بالا برای هر هدف ارائه می‌دهد. Unet بهترین نتایج را در برخی از وظایف چالش برانگیز COCO به دست آورده است، از جمله تقسیم‌بندی نمونه، تشخیص شیء با کس محدود، و تشخیص نقاط کلیدی شخصی [۲۱] است؛ بنابراین در این مطالعه از آن برای تقسیم‌بندی استفاده شد.

علاوه بر این، شش لایه شبکه رمزگذاری با عملیات کانولوشن 64×64 هسته و کانولوشن 3×3 (ReLU) مکس پولینگ (لایه ادغام) 2×2 ، کانولوشن انتقال 2×2 و سیگموئید 1×1 در نظر گرفته شده اند [۲۲]. این مدل تقسیم‌بندی ریه مبتنی بر Unet با استفاده از الگوریتم GPC پیشنهاد شده است.

در طبقه‌بندی تصاویر، ۷۵ درصد از داده‌ها برای آموزش و ۱۵ درصد استفاده از داده‌ها برای اعتبارسنجی استفاده شد، در ابتدا ماسک برش‌هایی را از تصاویر سی تی اسکن ایجاد، سپس هر تصویر به کمک روش فیلتر دوطرفه پیش پردازش شدند و سپس به کمک شبکه UNET تصاویر قطعه‌بندی و ROIهای مورد نظر استخراج و سپس به کمک الگوریتم GPC ویژگی‌های مورد نظر استخراج و سپس به کمک شبکه عصبی به کلاس‌بندی تصاویر پرداخته شد. مراحل روش پیشنهادی در شکل ۶ نشان داده شده است. شکل ۷ یک نمونه از تشخیص آمفیژم به کمک این شبکه پیشنهادی را نشان می‌دهد.



شکل ۶: مراحل روش پیشنهادی



شکل ۷: تشخیص توده‌های آمفیژم با شبکه Unet



نتایج

به منظور ارزیابی عملکرد روش پیشنهادی، از معیارهای عملکرد مانند دقت، یادآوری، ویژگی، دقت و امتیاز f استفاده شده است. این معیارها برای نشان دادن اثربخشی روش پیشنهادی اندازه‌گیری می‌شوند. فرمول دقیق این معیارها به شرح زیر است [۲۳]

- دقت (Ac) اندازه‌گیری بیماری درست پیش‌بینی شده از تعداد کل سوابق بیماری است.

$$Ac = \frac{pT + NT}{pT + NT + pF + NF}$$

- Recall (Re) Recall کلاس‌های بیمارانی را که به درستی پیش‌بینی شده‌اند به تعداد کل کلاس‌هایی که به درستی پیش‌بینی نشده‌اند.

$$Re = \frac{pT}{pT + NF}$$

هرچه مواردی که ما انتظار داشتیم پیش‌بینی شوند؛ ولی برنامه پیش‌بینی نکرده است که به آن False Negative می‌گوییم نسبت به پیش‌بینی‌های درست یا True Positive بیشتر باشد مقدار Recall کمتر خواهد شد.

- Specificity (sp) نسبت کلاس‌های غیر بیمار به درستی پیش‌بینی شده به مجموع منفی‌های واقعی و مثبت کاذب است.

$$Sp = \frac{NT}{pF + NT}$$

- پیش‌بینی (Pr) نسبت کلاس‌های بیمار به درستی پیش‌بینی شده به کل رکوردهای بیمار در مجموعه داده.

$$Pr = \frac{pT}{pT + pF}$$

- امتیاز F که با نام F-measure نیز شناخته می‌شود، به یک معاوضه بین دقت و فراخوانی می‌رسد.

$$Fs = 2 * (\frac{Re * Pr}{Re + Pr})$$

از معادلات فوق، عباراتی مانند pT ، NT ، pF و NF به ترتیب نشان دهنده مثبت واقعی، منفی درست، مثبت کاذب و منفی کاذب است. همچنین در این تحقیق به پیاده‌سازی تمامی روش‌های مقایسه شده با روش بهینه‌سازی GPC به کمک شبکه U-net و روی مجموعه داده موجود پرداخته شد که جدول ۱ نشان دهنده نتیجه این مقایسه است.

جدول ۱: مقایسه روش پیشنهادی با سایر روش‌های بهینه‌سازی شده توسط UNET


	GA-Unet [۲۴]	ICA-Unet [۲۵]	PSO-Unet [۲۶]	DE-Unet [۲۷]	GPC-Unet
دقت	۹۵/۱۶	۹۵/۲۱	۹۴/۹۵	۹۵/۸۱	۹۷/۱۸
پیش‌بینی	۹۸/۰۱	۹۷/۹۳	۹۷/۷۵	۹۷/۹۸	۹۸/۴۰
حساسیت	۵۰/۴۳	۵۱/۴۷	۴۷/۱۹	۵۱/۲۱	۴۸/۲۳
F امتیاز	۹۷/۴۷	۹۷/۴۹	۹۷/۳۶	۹۷/۱۱	۹۷/۵۰

جدول ۲ دقت، ویژگی، امتیاز F و دقت به دست آمده توسط روش ما را برای زیرگروه‌های آمفیزم و ریه طبیعی از نظر کلاس نشان می‌دهد.

جدول ۲: کارایی انواع مختلف آمفیزم ریوی

کلاس	پیش بینی	حساسیت	F امتیاز	دقت
center lobular Emphysema (CLE)	%۹۵	%۴۷/۴	%۹۸	%۹۷
par septal emphysema (PSE)	%۹۷	%۵۴/۳	%۹۶	%۹۸/۶
pan lobular emphysema (PLE)	%۹۸	%۶۰	%۹۹	%۹۶
normal	%۹۴	%۳۱	%۹۷/۲	%۹۶
Mean	%۹۶	%۰/۹۸	%۰/۹۵	%۰/۹۷

همچنین منحنی مشخصه عملکرد گیرنده (Receiver operating characteristic) و ناحیه زیر منحنی مربوطه آن (Area under the ROC Curve) رسم شده است تا به صورت گرافیکی مبادله بین نرخ مثبت کاذب (ویژگی ۱) و نرخ مثبت واقعی (حساسیت) را نشان دهد. طبقه بندی کامل با منحنی ROC که از گوشه سمت چپ بالا عبور می‌کند نشان داده می‌شود. مقدار AUC از ۰/۰ تا ۱ متغیر است، $AUC < ۰/۵$ به معنای طبقه بندی ضعیف و مقدار AUC نزدیک به ۱ به معنای طبقه بندی عالی است. از شکل ۵، مشاهده می‌شود که مقادیر AUC برای هر چهار کلاس بالاتر از ۰/۹ است که نشان دهنده عملکرد متعادل در تشخیص زیرگروه‌های آمفیزم و ریه‌های سالم است. علاوه بر این، منحنی ROC آمفیزم مرکز لوبولار به گوشه سمت چپ بالا با ۰/۹۷، AUC نزدیک‌تر است و به دنبال آن الگوی نرمال با AUC ۰/۹۴، و آمفیزم پانلوبولار با مقدار AUC ۰/۹۳ قرار دارد. این بدان معناست که تشخیص آمفیزم مرکز لوبولار نسبت به بافت طبیعی و آمفیزم پان لوبولار و آمفیزم سیتوم پارتیومی برتر است.




شکل ۸: نمودار ROC انواع مختلف آمفیزم

عملکرد طبقه‌بندی رویکرد پیشنهادی این مطالعه با مطالعات مشابه انجام شده بر روی مجموعه داده‌های استاندارد Bruijne و Sorensen که در جدول ۳ نشان داده شده است، مقایسه می‌شود.




جدول ۳: عملکرد طبقه بندی Unet بهینه شده با مطالعات دیگر


روش	دقت
Optimized Unet	۰/۹۷
Peng و همکاران [۲۱]	۰/۹۳
Narayanan و همکاران	۰/۸۷
Nava و همکاران [۱۷]	۰/۹۱
Pei و همکاران [۱۶]	۰/۹۳
Sorensen و همکاران [۱۵]	۰/۹۵




a



b



c



d

شکل ۹: مقایسه روش پیشنهادی با سایر روش‌های بهینه شده توسط Unet

بحث و نتیجه‌گیری

در مطالعه حاضر، تشخیص و کلاس‌بندی آمفیزم به کمک Unet بهینه شده توسط Giza Pyramids Construction انجام شده است و مجموعه داده‌های بیمارستانی برای آموزش، اعتبارسنجی و آزمون استفاده شد. برای ارزیابی روش پیشنهادی، ابتدا مجموعه داده‌ها به کمک شبکه Unet و با سایر روش‌های بهینه‌سازی معروف به صورت جداگانه پیاده‌سازی و مورد بررسی قرار گرفتند و نتایج حاصل از پیاده‌سازی روش پیشنهادی و سایر روش‌ها نشان داد که استفاده از شبکه Unet که به کمک روش بهینه‌سازی GPC پیاده‌سازی شده کارایی بالاتری در قیاس با استفاده از سایر روش‌های بهینه‌سازی دارد به‌طوری‌که دقت حاصل از روش پیشنهادی در تشخیص آمفیزم ریوی نسبت به سایر روش‌های بهینه‌سازی حدود ۵/۲ درصد افزایش داشته است. نتایج نشان داد دقت تشخیص آمفیزم ریوی از نوع PSE (Par Septal Emphysema) با ۹۸/۶ نسبت به سایر انواع آمفیزم بیشتر است که قاعدتاً به دلیل تعداد داده‌های بیشتر این مورد نسبت به سایر نوع‌ها است. در نهایت برای ارزیابی دقیق‌تر روش پیشنهادی، دقت تشخیص این بیماری در روش پیشنهادی با سایر روش‌هایی که به تشخیص آمفیزم ریوی پرداختند؛ مورد بررسی قرار گرفت که نشان داد این روش با میانگین دقت ۹۷ درصد به موفقیت بیشتری نسبت به سایر روش‌ها دست پیدا کرده است. مقایسه عملکرد به وضوح نشان می‌دهد که استفاده از Giza Pyramid Construction به عنوان بهینه‌ساز شبکه Unet، توانسته است به نتایج پیش‌بینی و طبقه‌بندی بهتری با تعداد نمونه‌های آموزشی کمتر در مقایسه با سایر رویکردهای یادگیری ماشین دست یابد. همچنین با بررسی‌های انجام شده، این نتیجه قابل حصول است که استفاده از مفاهیم جدیدتر حوزه یادگیری ماشین از جمله استفاده از شبکه‌های عصبی کوانتوم برای کارهای آینده، می‌تواند تا حدود زیادی به پیشرفت در تشخیص سریع و دقیق این بیماری کمک کند.

تشکر و قدردانی

نویسندگان این مقاله هیچ گونه کمک هزینه تحقیقاتی از هیچ نهاد و سازمانی برای انجام این مطالعه دریافت نکرده‌اند و از بیمارستان علی ابن ابیطالب (ع) زاهدان و بیمارستان بوعلی سینا بابت در اختیار گذاشتن تصاویر پزشکی مربوط به مطالعه بسیار متشکریم.

تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.

کد اخلاق

کد اخلاق این مطالعه با شماره IR.ZAUMS.REC.1402.169 از دانشگاه علوم پزشکی زاهدان گرفته شده است.



سهام مشارکت نویسندگان

نویسنده اصلی صفورا اویسی، استاد راهنما: دکتر تارخ، استاد مشاور: دکتر مومنی

References

- [1]. Isaac A, Nehemiah HK, Isaac A, Kannan A. Computer-Aided Diagnosis system for diagnosis of pulmonary emphysema using bio-inspired algorithms. *Computers in Biology and Medicine* 2020;124:103940. <https://doi.org/10.1016/j.compbimed.2020.103940>
- [2]. Mondal S, Sadhu AK, Dutta PK. Automated diagnosis of pulmonary emphysema using multi-objective binary thresholding and hybrid classification. *Biomedical Signal Processing and Control* 2021;69:102886. <https://doi.org/10.1016/j.bspc.2021.102886>
- [3]. Parui S, Parbat D, Chakraborty M. A deep learning paradigm for computer aided diagnosis of emphysema from lung hrct images. In *International Conference on Computing in Engineering & Technology*; 2022 Feb 12; Singapore: Springer Nature; 2022. p. 198-207.
- [4]. Oh AS, Baraghoshi D, Lynch DA, Ash SY, Crapo JD, Humphries SM. COPD Gene Investigators. Emphysema progression at CT by deep learning predicts functional impairment and mortality: results from the COPD Gene study. *Radiology* 2022;304(3):672-9. <https://doi.org/10.1148/radiol.213054>
- [5]. Sorensen L, Shaker SB, De Bruijne M. Quantitative analysis of pulmonary emphysema using local binary patterns. *IEEE Transactions on Medical Imaging* 2010;29(2):559-69. doi: 10.1109/TMI.2009.2038575
- [6]. Peng L, Lin L, Hu H, Li H, Chen Q, Ling X, et al. Classification and quantification of emphysema using a multi-scale residual network. *IEEE Journal of Biomedical and Health Informatics* 2019;23(6):2526-36. doi: 10.1109/JBHI.2018.2890045
- [7]. Isaac A, Nehemiah HK, Dunston SD, Christo VE, Kannan A. Feature selection using competitive coevolution of bio-inspired algorithms for the diagnosis of pulmonary emphysema. *Biomedical Signal Processing and Control* 2022;72:103340. <https://doi.org/10.1016/j.bspc.2021.103340>
- [8]. Tang LY, Coxson HO, Lam S, Leipsic J, Tam RC, Sin DD. Towards large-scale case-finding: training and validation of residual networks for detection of chronic obstructive pulmonary disease using low-dose CT. *The Lancet Digital Health* 2020;2(5):e259-67. doi:[https://doi.org/10.1016/S2589-7500\(20\)30064-9](https://doi.org/10.1016/S2589-7500(20)30064-9)
- [9]. Ross JC, Castaldi PJ, Cho MH, Chen J, Chang Y, Dy JG, et al. A Bayesian nonparametric model for disease subtyping: application to emphysema phenotypes. *IEEE Transactions On Medical Imaging* 2016;36(1):343-54. doi: 10.1109/TMI.2016.2608782
- [10]. Sweetlin JD, Nehemiah HK, Kannan A. Feature selection using ant colony optimization with tandem-run recruitment to diagnose bronchitis from CT scan images. *Computer Methods and Programs in Biomedicine*. 2017;145:115-25. <https://doi.org/10.1016/j.cmpb.2017.04.009>
- [11]. Dhalia Sweetlin J, Khanna Nehemiah H, Kannan A. Patient-Specific Model Based Segmentation of Lung Computed Tomographic Images. *Journal of Information Science & Engineering* 2016;32(5): 1373.
- [12]. Emary E, Zawbaa HM, Grosan C, Hassenian AE. Feature subset selection approach by gray-wolf optimization. In *Afro-European Conference for Industrial Advancement: Proceedings of the First International Afro-European Conference for Industrial Advancement AECIA*; 2014. Switzerland: Springer; 2014. p. 1-13. doi:10.1007/978-3-319-13572-4_1
- [13]. Zawbaa HM, Emary E, Grosan C, Snasel V. Large-dimensionality small-instance set feature selection: A hybrid bio-inspired heuristic approach. *Swarm and Evolutionary Computation* 2018;42:29-42. <https://doi.org/10.1016/j.swevo.2018.02.021>
- [14]. Anter AM, Ali M. Feature selection strategy based on hybrid crow search optimization algorithm integrated with chaos theory and fuzzy c-means algorithm for medical diagnosis problems. *Soft Computing* 2020;24(3):1565-84. doi:10.1007/s00500-019-03988-3
- [15]. Chen DY, Peng L, Li WC, Wang YD. Building extraction and number statistics in WUI areas based on UNet structure and ensemble learning. *Remote Sensing* 2021;13(6):1172. <https://doi.org/10.3390/rs13061172>
- [16]. Schlemper J, Oktay O, Schaap M, Heinrich M, Kainz B, Glocker B, Rueckert D. Attention gated networks: Learning to leverage salient regions in medical images. *Medical Image Analysis* 2019;53:197-207. <https://doi.org/10.1016/j.media.2019.01.012>
- [17]. Rad RM, Saeedi P, Au J, Havelock J. Trophoblast segmentation in human embryo images via inceptioned U-Net. *Medical Image Analysis* 2020;62:101612. <https://doi.org/10.1016/j.media.2019.101612>
- [18]. Harifi S, Mohammadzadeh J, Khalilian M, Ebrahimnejad S. Giza Pyramids Construction: an ancient-inspired metaheuristic algorithm for optimization. *Evolutionary Intelligence* 2021;14(4):1743-61. doi:10.1007/s12065-020-00451-3
- [19]. Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of Global Optimization*. 2007;39:459-71. doi:10.1007/s10898-007-9149-x

- [20]. Liu X, Song L, Liu S, Zhang Y. A review of deep-learning-based medical image segmentation methods. Sustainability 2021;13(3):1224. <https://doi.org/10.3390/su13031224>
- [21]. Huang H, Lin L, Tong R, Hu H, Zhang Q, Iwamoto Y, et al. Unet 3+: A full-scale connected unet for medical image segmentation. In ICASSP 2020-2020 IEEE international conference on acoustics, speech and signal processing (ICASSP); 2020 May 4-8; Barcelona, Spain: IEEE; 2020. p. 1055-9. doi: 10.1109/ICASSP40776.2020.9053405
- [22]. Alom MZ, Hasan M, Yakopcic C, Taha TM, Asari VK. Recurrent residual convolutional neural network based on u-net (r2u-net) for medical image segmentation. arXiv preprint arXiv:1802.06955. 2018. <https://doi.org/10.48550/arXiv.1802.06955>
- [23]. Orozco-Arias S, Piña JS, Tabares-Soto R, Castillo-Ossa LF, Guyot R, Isaza G. Measuring performance metrics of machine learning algorithms for detecting and classifying transposable elements. Processes 2020; 27;8(6):638. <https://doi.org/10.3390/pr8060638>
- [24]. Holland JH. Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications To Biology, Control, And Artificial Intelligence. London: Bradford Books; 1992.
- [25]. Atashpaz-Gargari E, Lucas C. Imperialist competitive algorithm: an algorithm for optimization inspired by imperialistic competition. IEEE Congress on Evolutionary Computation; 2007 Sep 25-28; Singapore: IEEE; 2007. p. 4661-7. doi: 10.1109/CEC.2007.4425083
- [26]. Kennedy J, Eberhart R. Particleswarmoptimization, in Proceedings of ICNN'95-International Conference on Neural Networks; 1995 Nov Dec; 27-1; Perth, WA, Australia: IEEE; 1995. doi: 10.1109/ICNN.1995.488968
- [27]. Storn R, Price K. Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces. Journal of Global Optimization 1997;11:341-59. doi:10.1023/A:1008202821328