

## Prediction of Pulmonary artery and peripheral vascular pressure based on echocardiography data and artificial neural network

H. Abbasi<sup>1</sup>, SH. Shojaei<sup>2\*</sup>, and N. Naderi<sup>3</sup>

<sup>1</sup>M.Sc Student, BioMedical Engineering Department, Central Tehran Branch, Islamic Azad University, Tehran, Iran

<sup>2</sup>Assistant Professor, Department of Medical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

<sup>3</sup>Associate Professor, Department of Cardiology and Cardiology, Shahid Rajaie Cardiology, Medical and Research Center, Tehran University of Medical Sciences, Tehran, Iran

Receipt in the Online Submission System: 21/11/2018, Received in Revised Form: 19/6/2019, Accepted: 21/7/2019

### Abstract

Today, in order to decide on many cardiac surgeries, and whether the patient is able to get under surgery or the time of surgery is passed, it is necessary to measure pulmonary vascular resistance and if the resistance is above a threshold, the patient is considered to be non-surgery; and sometimes, some therapies are used to reduce the resistance of the pulmonary arteries to the initial disease of the arteries, in which, in order to track down the resistance of the pulmonary vascular, a re-measurement of this parameter is required. Currently, the golden standard of this measure is the use of catheterization procedures, which are aggressive and associated with complications. The purpose of this study is to replace a non-invasive method, rather than an invasive method of cardiac catheterization, by predicting pulmonary vascular resistance, based on echocardiographic data, by artificial neural networks. Research was performed on 591 patients. Echocardiography was recorded for all subjects, and the echocardiographic data (mPAP, dPAP, sPAP, PCWP, CO) as the neural network input and pulmonary vascular resistance of all patients who were subjected to previous catheterization was evaluated as the output of the neural network and thus, it was obtained, the relationship between echocardiography data and PVR<sub>cath</sub>. The proposed neural network was typically learned with 75% of the data, and was tested with 25% of the data, and these ratios were modified to better learn the neural network. As a result of implementation, the mean squared error, respectively, for the learning and testing data for the proposed neural network, was 0.37 and 0.27 for the first model, and was 14.67 and 10.76 for the second model, and was 15.82 and 9.58 for the third model.

Key words: prediction, artificial neural networks, pulmonary vascular resistance, echocardiography

Corresponding author

Address: Department of Bio Medical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

E-mail: [s.shojaei@aut.ac.ir](mailto:s.shojaei@aut.ac.ir)



## پیش‌بینی مقاومت عروق ریوی و فشار داخلی بطن راست بر مبنای داده‌های اکوکاردیوگرافی و شبکه عصبی مصنوعی

حامد عباسی<sup>۱</sup>، شاهرخ شجاعی<sup>۲\*</sup>، نسیم نادری<sup>۳</sup>

<sup>۱</sup> دانشجوی کارشناسی ارشد، گروه مهندسی پزشکی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

<sup>۲</sup> استادیار، گروه مهندسی پزشکی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

<sup>۳</sup> دانشیار، گروه قلب و پیوند قلب، قلب و عروق شهید رجایی، مرکز پزشکی و پژوهشی، دانشگاه علوم پزشکی تهران، تهران، ایران

تاریخ ثبت در سامانه: ۱۳۹۷/۸/۳۰، بازنگری: ۱۳۹۸/۳/۲۹، پذیرش قطعی: ۱۳۹۸/۴/۳۰

### چکیده

امروزه جهت تصمیم‌گیری بسیاری از اعمال جراحی قلب و اینکه بیمار شرایط عمل جراحی را دارد یا خیر، نیاز به اندازه‌گیری مقاومت عروق ریوی می‌باشد و چنانچه این مقاومت از یک حد آستانه بالاتر باشد، بیمار غیرقابل عمل تلقی می‌گردد. و حتی گاهی درمان‌هایی برای کاهش مقاومت عروق ریوی در بیماری‌های اولیه‌ی این عروق انجام می‌شود که برای پیگیری کاهش مقاومت عروق ریوی، نیاز به اندازه‌گیری مجدد این پارامتر می‌باشد. در حال حاضر تنها معیار طلایی این اندازه‌گیری، استفاده از روش‌های کاتتریسم می‌باشد که تهاجمی بوده و با عوارضی همراه است. هدف از انجام این تحقیق جایگزین نمودن یک روش غیرتهاجمی به جای روش تهاجمی کاتتریسم قلبی از طریق پیش‌بینی مقاومت عروق ریوی بر مبنای داده‌های اکوکاردیوگرافی توسط شبکه‌های عصبی مصنوعی می‌باشد. نتایج این تحقیق بر روی ۵۹۱ بیمار انجام گرفته شده است. پس از انجام اکوکاردیوگرافی برای تمامی بیماران، داده‌های اکوکاردیوگرافی (mPAP, dPAP, sPAP, PCWP, CO) به عنوان ورودی شبکه‌عصبی و مقاومت عروق ریوی تمام بیماران که تحت عمل کاتتریسم قلبی حاصل گردید، به عنوان خروجی شبکه‌عصبی مورد ارزیابی قرار گرفتند، در نتیجه ارتباط بین داده‌های اکوکاردیوگرافی و PVRcath حاصل گردید. شبکه‌عصبی پیشنهادی به طور معمول با ۷۵٪ داده‌ها آموزش و با ۲۵٪ داده‌ها مورد تست قرار گرفته است، و همچنین برای آموزش بهتر شبکه‌عصبی، این نسبت‌ها تغییر داده شده است. در نتایج پیاده‌سازی، میانگین مربعات خطا به ترتیب برای داده‌های آموزش و تست شبکه‌عصبی پیشنهادی برای مدل اول ۰/۳۷ و ۰/۲۷، مدل دوم ۴/۶۷ و ۱۰/۷۶، مدل سوم ۱۵/۸۲ و ۹/۵۸ حاصل گردیده است.

کلیدواژه‌ها: پیش‌بینی، شبکه‌های عصبی مصنوعی، مقاومت عروق ریوی، اکوکاردیوگرافی

\*نویسنده مسئول

نشانی: گروه مهندسی پزشکی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

پست الکترونیکی: s.shojaei@aut.ac.ir

## ۱- مقدمه

امروزه جهت تصمیم‌گیری بسیاری از اعمال جراحی قلب و اینکه بیمار شرایط عمل جراحی را دارد یا خیر، نیاز به اندازه‌گیری مقاومت عروق ریوی می‌باشد و چنانچه این مقاومت از یک حد آستانه بالاتر باشد، بیمار شرایط عمل جراحی را ندارد. در حال حاضر تنها معیار طلایی بررسی مقاومت و فشار عروق ریوی و برون ده بطن راست، استفاده از روشهای تهاجمی مانند کاتتریسیم است. روش دیگری که برای اندازه‌گیری مقدار مقاومت عروق ریوی استفاده می‌شود، اکوکاردیوگرافی است، بنابراین دقت و ضریب اطمینان اکو برای تیم پزشکان کمتر از روش کاتتریسیم است. جایگزین نمودن روشی غیر تهاجمی برای دست یافتن به نتایج مطلوب و قابل اطمینان، از جمله مهمترین اهداف این پژوهش می‌باشد. هوش مصنوعی در حوزه سلامت به معنای استفاده از الگوریتم‌هایی است که تقریباً شناخت انسان را در تجزیه و تحلیل اطلاعات پزشکی پیچیده مورد استفاده قرار می‌دهد. شبکه‌های عصبی مصنوعی یکی از جدیدترین زمینه‌های پژوهشی در حوزه هوش مصنوعی می‌باشند. شاخه‌های اصلی هوش مصنوعی به چند دسته تقسیم می‌شوند که عبارتند از: پردازش تکاملی، سیستم‌های فازی، سیستم‌های خیره، شبکه‌های عصبی و یادگیری عمیق می‌باشد [۱]. شبکه‌های عصبی مصنوعی<sup>۱</sup> یک سامانه کاملاً پیچیده و غیرخطی به منظور یادگیری و ایجاد دانش است که در حیطه پزشکی براساس متغیرهای ورودی نسبت به طبقه بندی افراد به بیمار یا سالم اقدام میکند. طبقه‌بندی و پیش‌بینی وضعیت بیمار بر اساس عوامل خطر یکی از کاربردهای شبکه‌های عصبی مصنوعی است [2,3,4]. به طور کلی شبکه‌های عصبی با یادگیری دانش یک رویداد و روابط بین داده‌های ورودی و خروجی، می‌توانند تغییرات خروجی را نسبت به ورودی‌ها پیش‌بینی کنند. در این مطالعه، با توجه به اهمیت مقاومت عروق ریوی در عمل‌های جراحی، پارامترهای وابسته به آن از طریق اکوکاردیوگرافی استخراج شده است، و سعی می‌شود مقدار مقاومت عروق ریوی حاصل از کاتتریسیم قلبی در بیماران براساس داده‌های اکوکاردیوگرافی با استفاده از شبکه‌های عصبی تخمین زده شود. مقاومت عروق پولمونری ارزیابی شده توسط کاتتریزاسیون قلب راست یک پیش‌بینی جهت مرگ و میر در بیماران مبتلا به PAH<sup>۲</sup> و ILD<sup>۳</sup>

است [۵,۶,۷]. مقاومت عروق ریوی دارای مفاهیم تشخیصی در ارزیابی فشارخون ریوی بیماران قلبی می‌باشد [۸-۱۰]. اندازه‌گیری مقاومت عروق ریوی کمک می‌کند تا فشارخون ریوی پیش‌مویریگی از فشارخون ریوی پس‌مویریگی متمایز شده و با کاتتریزاسیون قلب راست اندازه‌گیری شود [۱۱,۱۲]. اخیراً، شبکه‌های عصبی بازگشتی<sup>۴</sup> در پیش‌بینی خطرات ناشی از بیماری با داده‌های ثبت الکترونیکی سلامت مورد استفاده قرار گرفته‌اند. در سال ۲۰۱۸ از یک مدل بازگشتی شبکه عصبی بر اساس داده‌های واقعی EHR<sup>۵</sup> برای پیش‌بینی ریسک ابتلا به نارسایی قلبی استفاده شد [13]. در سال ۲۰۱۶ آقای چنگ و همکارانش یک رویکرد یادگیری عمیق در شبکه‌های عصبی برای فوتوتیپی از پیشینه الکترونیکی سلامت بیماران ارائه نمود و برای اولین بار EHR ها را برای هر بیمار به عنوان یک ماتریس زمانی با زمان بر روی یک بعد نشان داد [14]. در پژوهش‌های اخیر کاربردهای وسیعی از استفاده از ابزارهای هوش مصنوعی جهت پیش‌بینی بیمارهای مختلف استفاده شده است، از جمله پیش‌بینی نارسایی قلبی با استفاده از شبکه‌های عصبی بازگشتی انجام گرفته شده است [15]، و همچنین می‌توان از سیستم‌های مقایسه‌ای شبکه‌های عصبی در تشخیص تومورهای مغزی و سرطان سینه با انجام پردازش روی تصاویر MRI<sup>۶</sup> و ماموگرافی استفاده کرد. در سال ۲۰۱۵ مدل طبقه بندی اتوماتیک تومور مغزی در تصاویر MRI با استفاده از شبکه‌های عصبی مصنوعی بازگشتی ارائه شد [19]. به طور کلی هدف از انجام این تحقیق حذف روش‌های تهاجمی مانند کاتتریسیم برای حصول مقدار عددی مقاومت عروق ریوی جهت آمادگی قبل از اعمال جراحی قلب، عروق و جایگزین نمودن یک سیستم هوشمند جهت تخمین با دقت بالای مقاومت عروق پولمونری می‌باشد (با نظر به اینکه در افراد سالم مقدار آن کمتر از یک است).

## ۲- شبکه‌های عصبی مصنوعی

شبکه‌های عصبی مصنوعی، مدل ساده شده‌ای از یک سیستم مرکزی است که الهام گرفته شده از مغز انسان است. یک شبکه‌های عصبی مصنوعی شبکه‌های محاسباتی است که تلاش می‌کند شبکه‌هایی از سلول (نورونی) سیستم عصبی مرکزی

<sup>۳</sup> Interstitial Lung Disease

<sup>۴</sup> recurrent neural network

<sup>۵</sup> electronic health record (EHR)

<sup>۶</sup> Magnetic resonance imaging (MRI)

<sup>۱</sup> Artificial Neural Network (ANN)

<sup>۲</sup> Pulmonary Artery hypertension

در شکل (۱) لایه اول، لایه ورودی شبکه عصبی، لایه دوم (لایه‌های پنهان) که در وزن‌ها ضرب می‌شوند و به صورت بازگشتی، براساس تعداد دفعات آموزش<sup>۷</sup> داده، اصلاح گرادیان نزولی و خطای پیش‌بینی کاهش می‌گردد و این عمل جهت آموزش شبکه عصبی انجام می‌پذیرد و لایه نهایی، خروجی شبکه عصبی (هدف مورد پیش‌بینی) می‌باشد.

### ۳- مقاومت عروق ریوی

مقاومت عروق ریوی در ارزیابی بیماران مبتلا به فشارخون ریوی و نارسایی‌های مزمن قلبی، دارای پیامدهای مهم پیش‌آگهی و یک پارامتر مهم برای تشخیص بیماران مبتلا به نارسایی قلبی است [۱۱، ۱۲]. بیماران مبتلا به پرفشاری خون ریوی شناخته شده و مشکوک به بیماری قلبی تحت عمل کاتتریزاسیون بطن راست برای ارزیابی پارامترهای همودینامیک، از جمله PVR، قرار می‌گیرند.

به طور تهاجمی، مقاومت عروق ریوی از نسبت گرادیان فشار درون ریوی به جریان درون ریوی حاصل می‌شود و در روش غیرتهاجمی نسبت سرعت برگشت تریکوسپید به انتگرال زمان و سرعت جریان خروجی بطن راست حاصل می‌شود [۱۷، ۱۶، ۱۱]:

$$\frac{TRV}{TVIRVOT} * 10 + 0.16 (PVRecho) \quad (1)$$


در رابطه فوق PVRecho مقاومت عروق ریوی حاصل از اکوکاردیوگرافی در واحد Wood Unit، TRV گرادیان نارسایی دریچه تریکوسپید در واحد cm/s و TVIRVOT انتگرال زمانی سرعت جریان خروجی بطن راست در واحد سانتی‌متر می‌باشد.

همچنین مقاومت عروق ریوی از معادله زیر می‌تواند محاسبه گردد [۸، ۱۱]:

$$PVR = \frac{mPAPeCHO - PCWP}{COeCHO} \quad (2)$$

در معادله فوق mPAP میانگین فشار جریان ریوی حاصل از اکوکاردیوگرافی در واحد mm Hg، PCWP فشار گوه مویرگی ریوی در واحد mm Hg و CO برون ده قلبی اکو در واحد lit/min می‌باشد.

بیولوژیکی را شبیه‌سازی کند. معماری یک شبکه عصبی توسط تعدادی از واحد پردازش (نورون) و ارتباط بین آنها (اتصالات وزن‌دار) شکل گرفته است، مقدار وزن این اتصالات نشان دهنده قدرت این اتصالات می‌باشد، یک زیرگروه عناصر پردازش در شبکه، لایه نامیده می‌شود. شبکه عصبی مورد استفاده در این مطالعه شامل سه لایه مختلف است. لایه اول، لایه ورودی است که یک رابط با محیط را نشان می‌دهد و نورون آخر شبکه عصبی، خروجی نهایی را تولید می‌نماید. طبقه‌بندی و پیش‌بینی وضعیت بیمار بر اساس عوامل خطر یکی از کاربردهای شبکه‌های عصبی مصنوعی است. شبکه عصبی مصنوعی در حل مسائلی که دارای راه‌حل الگوریتمی نیستند یا مسائلی که راه‌حل الگوریتمی بسیار پیچیده‌ای دارند و نیز مسائلی که برای انسان‌ها آسان، اما برای کامپیوترهای رایج دشوار هستند مانند تشخیص تصاویر و پیش‌بینی‌ها بر پایه دانش گذشته، به خوبی مورد استفاده قرار گرفته است. شبکه‌ی عصبی مصنوعی با پردازش داده‌های موجود، دانش و قوانین نهفته درون داده‌ها را به ساختار شبکه منتقل می‌کند و بر اساس محاسباتی که بر روی داده‌های آموزش انجام می‌دهد، قوانین کلی موجود در درون داده‌ها را فرا می‌گیرد. از مهمترین ویژگیهای شبکه‌های عصبی، قابلیت یادگیری آنها است. قابلیت یادگیری عبارت از توانایی تنظیم پارامترهای شبکه در مسیر زمان و با شرایط مختلف است، با این هدف که شبکه آموزش داده شده برای یک وضعیت خاص، علیرغم تغییرات کوچک شرایط محیطی، بتواند کارآمدی خود را حفظ نماید. پس از آموزش لازم و کافی، شبکه می‌تواند در صورت برخورد با یک ورودی جدید که در جریان آموزش با آن مواجه نشده باشد، از فرآیند درون‌یابی استفاده کند و خروجی مناسبی را ارائه نماید، ساختار کلی شبکه‌های عصبی مصنوعی مطابق شکل (۱) نشان داده شده است [۱۸].



شکل (۱) - ساختار کلی شبکه‌های عصبی مصنوعی چند لایه

<sup>۷</sup> epoch

بطن راست در بزرگسالان با استفاده از پارامترهای زیر مورد ارزیابی قرار گرفت:

۱-TAPSE: Tricuspid Annular Plane Systolic Excursion (TAPSE)  
۲-Tissue Doppler-derived tricuspid lateral annular systolic velocity

پارامتر شماره (۱) TAPSE حرکت رو به جلوی آنولوس دریچه تریکوسپید در زمان سیستول در واحد میلی متر می‌باشد و پارامتر شماره (۲) سرعت حرکت قسمت خارجی آنولوس دریچه سه لتی با استفاده از داپلر بافتی در واحد cm/s می‌باشد.

همچنین اگر:  $velocity < 10\text{cm/s}$  ,  $TAPSE < 16\text{mm}$  باشد، نشانه اختلال عملکرد بطن راست است [۲].

در نهایت مساحت دهلیز راست در واحد سانتی‌متر مربع در انتهای فاز سیستول در نمای چهار وجهی اندازه‌گیری شد. در جدول (۱) مقادیر ارزیابی شده و مشخصات همه بیماران قابل مشاهده است.

جدول (۱) مشخصات بیماران انتخاب شده			
	پیش مویرگی (n=278)	پس مویرگی (n=313)	pvalue
سن	47.3 ± 10.5	39 ± 11	NS
مرد / زن	167 / 111	92 / 221	....
BSA (m <sup>2</sup> )	1.52 ± 0.09	1.6 ± 0.12	0.001
systolic BP (mm Hg)	107.5 ± 18	106.2 ± 14	NS
Diastolic Bp (mm Hg)	65 ± 11	68 ± 12	NS
Heart rate (beat/min)	81 ± 20	86 ± 17	NS
TAPSE(mm)	16.5 ± 6	12.8 ± 2.8	0.000 <sup>a</sup> 0.000 <sup>b</sup>
RAA index (cm <sup>2</sup> /m <sup>2</sup> )	12.1 ± 5.3	12.7 ± 4.1	0.000 <sup>a</sup> 0.000 <sup>b</sup>

BSA: مساحت سطح بدن، NS: غیر معنی دار، Systolic BP: فشارخون در فاز سیستولیک، Diastolic BP: فشارخون در فاز دیاستولیک، Heart rate: ضربان قلب، TAPSE: حرکت رو به جلوی آنولوس دریچه تریکوسپید در زمان سیستول، RAA: مساحت دهلیز راست، a: فشار خون ریوی پیش مویرگی در مقابل وضعیت نرمال، b: فشار خون ریوی پس مویرگی در مقابل وضعیت نرمال

۶- نحوه انجام مطالعه بر پایه کاتتریزاسیون بطن راست تمام بیماران (افراد مورد مطالعه) در آزمایشگاه کاتتریزاسیون با کاتترهای ترمودیلوسسیون<sup>۹</sup> سه حفره

#### ۴- روش جمع آوری داده‌ها و نحوه انتخاب بیماران

در میان گروه بیماری‌های قلبی افراد مراجعه کننده به درمانگاه‌های مرکز تحقیقاتی آموزشی و درمانی شهید رجایی که برای انجام کاتتریزاسیون قلب راست جهت ارزیابی همودینامیک ریوی ثبت نام شدند، معیارهای زیر در نظر گرفته شد و فقط افرادی مورد مطالعه قرار گرفتند که به یکی از بیماری‌های ذیل مبتلا بودند:

DCM, PAH, PH, CTEPH, ICMP, CHF, HF, Ischemic Cardio myopathy, Dilated Cardio myopathy

به دلایل مختلف یکسری از بیماران در جمع‌آوری داده‌های اکو در نظر گرفته نشدند که عبارت از فلج یا فیبریلاسیون دهلیزی یا هر آریتمی دیگری که مانع اندازه‌گیری‌های اکوکاردیوگرافی، سابقه جراحی قلب مانند پیوند عروق کرونر قلب و هرگونه تعمیر یا تعویض دریچه قلبی، بیماری ریوی پیشرفته، بیماری‌های قلبی مادرزادی بود. بیماران کنترل شده با توجه به تاریخچه، معاینه فیزیکی، الکتروکاردیوگرافی، اکوکاردیوگرافی و نتایج منفی آزمایش‌های غیرتهاجمی و تهاجمی اخیر برای بیماری‌های قلبی و عروقی در مردان و زنان انتخاب شدند. از بین ۵۹۱ فرد منتخب، ۴۱۴ بیمار از پایگاه اطلاعاتی داده‌های مرکز قلب و مابقی از میان مراجعه کنندگان بودند. از آنجا که به تعداد بیماران بیشتری جهت حصول نتیجه دقیق‌تر و بهینه‌تر نیاز است و محدودیت زمانی جهت ثبت داده‌های بیشتر وجود دارد، لذا مابقی داده‌های مورد مطالعه از سیستم مدیریت انفورماتیک بیمارستان و مرکز تحقیقاتی آموزشی و درمانی شهید رجایی و پرونده‌های بیمارانی که دارای معیارهای ورود بودند در فایل اکسل، استخراج گردید.

#### ۵- روش انجام اکوکاردیوگرافی در این مطالعه

اکوکاردیوگرام داپلر دو بعدی رنگی در هر فرد مورد مطالعه با استفاده از یک سیستم<sup>۸</sup> با مبدل فاز هارمونیک فرکانس متغیر سه بعدی در محدوده فرکانسی ۱/۷-۳/۴ MHz و عمق ۱۰/۰ cm درست قبل از انجام کاتتریزاسیون بطن راست انجام شد. عملکرد سیستولیک بطن چپ در زمان‌های کسر تخلیه با استفاده از روش سیمپسون دو وجهی مورد ارزیابی قرار گرفت. عملکرد سیستولیک بطن راست مطابق با دستورالعمل انجمن اکوکاردیوگرافی آمریکا برای ارزیابی اکوکاردیوگرافی

<sup>۹</sup> Thermodilusion

<sup>۸</sup> GEvivid7



فشار شریانی ریوی در فاز سیستول، TPG: گرادیان ترانسپولمونی

#### ۷- آموزش شبکه عصبی بر مبنای داده‌های واقعی PVR

برای پیاده‌سازی و ارزیابی نتایج روش پیشنهادی از نرم افزار متلب نسخه ۲۰۱۵ استفاده شده است. در قدم اول جهت اینکه توانایی شبکه در یادگیری دانش مربوط به داده‌های کاتتریزاسیون و ارتباط آنها با مقاومت عروق ریوی که از فرمول غیرخطی (۳) پیروی می‌کند، محرز گردد، پارامترهای این فرم (mPAP-sPAP-dPAP-PCWP-CO) را به عنوان ورودی و مقاومت عروق پولمونی کاتتریزاسیون را به عنوان خروجی استفاده و داده‌های عددی مرتب شده و نسبت به بیشترین مقدار داده‌ها نرمالسازی شده‌اند (تمام داده‌ها به مقدار ماکزیمم داده‌ها تقسیم شدند). چنانچه در بخش جمع‌آوری داده‌ها ذکر شد، تعداد کل بیماران انتخاب شده ۵۹۱ نفر می‌باشد که به طور معمول برای آموزش شبکه عصبی ۷۵٪ بیماران انتخاب شدند و ۲۵٪ بیماران در تست شبکه عصبی مورد استفاده قرار گرفتند. البته درصد بیماران آموزش و تست بنا بر شرایط مختلف، مانند زمانی که حصول بهترین خطا مدنظر باشد، می‌تواند تغییر کند. منظور از خطا، میانگین مربعات خطا<sup>۱۲</sup> اختلاف بین داده‌های واقعی و پیش‌بینی شده می‌باشد. شبکه با چهار لایه و تعداد نورون‌های مختلف در هر لایه و نرخ آموزش‌های متفاوت و epoch ها (تعداد دوره‌های آموزش شبکه عصبی) و وزن‌های مختلف مورد آزمون قرار گرفت. ساختارهای شبکه عصبی نقش بسیار مهمی در بهبود خروجی دارند. یعنی تاحدی که می‌توان خطای خروجی شبکه را تا حد قابل توجهی کاهش و یا افزایش داد. نرخ یادگیری مناسب و تعداد دفعات یادگیری بیشتر می‌تواند به یادگیری بهتر شبکه و در نتیجه کاهش خطا در خروجی کمک بسیار زیادی کند، بنابراین ممکن است اگر تعداد دفعات آموزش شبکه عصبی از یک اندازه مشخص بیشتر شوند، پدیده سرریز رخ داده و خطا مجدداً افزایش پیدا کند. در تمامی مدل‌های ارائه شده، جهت پیش‌بینی، با روش سعی و خطا تعداد لایه‌ها، نورون‌های هر لایه، وزن‌ها و تعداد دفعات آموزش شبکه عصبی برای رسیدن به بهترین مدل با کمترین خطای داده‌های آموزش و تست به کار برده شد.

بالن دارمدل (FV) و مانیتورهای مراقبت مورد آزمایش قرار گرفتند. تمام اندازه‌گیری‌ها در حالت استراحت و در حالت خوابیده به پشت، زمانی که افراد مورد مطالعه در هوای اتاق تنفس می‌کنند، انجام گرفت. فشار در سه ضربان متوالی قلب در پایان انقباض به طور میانگین اندازه‌گیری شد. متغیرهای زیر برای هر بیمار اندازه‌گیری از قبیل: میانگین فشار دهلیز راست، فشارهای سیستولیک و پایان دیاستولیک بطن راست، فشار شریانی ریوی در فازهای سیستول، دیاستول و مقدار میانگین آن، فشار گوه ای مویرگی ریوی<sup>۱۰</sup>، اشباع اکسیژن وریدی و خروجی قلب<sup>۱۱</sup> از طریق ترمودیلوسیون و تکنیک فیک انجام شد.

در نهایت مقاومت عروق ریوی را می‌تواند بر اساس رابطه (۳) محاسبه شود [۷،۶،۲].

$$PVR = \frac{mPAP - PCWP}{CO} \quad (3)$$

که در معادله فوق mPAP میانگین فشار شریانی ریوی در واحد mm Hg، PCWP، فشار گوه مویرگی ریوی در واحد mm Hg و CO برون ده قلبی در واحد lit/min می‌باشد. در جدول (۲) پارامترهای به دست آمده از کاتتریزاسیون قلب (بطن) راست قابل مشاهده است.

جدول (۲): یافته‌های کاتتریزاسیون قلب راست		
	پیش‌مورگی (n=278)	پس‌مورگی (n=313)
RA pressure (mm Hg)	9.2 ± 3.9	10.5 ± 4.07
RVS pressure (mm Hg)	84.2 ± 33.1	56.8 ± 17
RVEDP (mm Hg)	9.3 ± 4	11.3 ± 5
SPAP (mm Hg)	88.8 ± 36	58 ± 16.2
DPAP (mm Hg)	48.2 ± 18.4	29.3 ± 7.9
Mean PAP (mm Hg)	60.7 ± 21.2	39.9 ± 10.2
PCWP (mm Hg)	10.8 ± 3.6	26.6 ± 8.1
TPG (mm Hg)	50.2 ± 21	11.3 ± 7
PVR (wood)	12.2 ± 7.4	3.3 ± 1.9
thermodilution PVR (wood)	12.3 ± 8.3	2.9 ± 1.7
FICK		
CO,thermodilution (Lit/min)	4.6 ± 1.3	3.9 ± 1.1
cl,thermodilution (lit/min/m2)	2.5 ± 0.9	2.1 ± 0.6
Co.FICK (lit/min)	4.4 ± 1.5	3.8 ± 1.7

ci: شاخص قلبی، CO: برون ده قلبی، DPAP: فشار شریانی ریوی در فاز دیاستول، PCWP: فشار گوه مویرگی ریوی، RA: دهلیز راست، RV: بطن راست، RVEDP: فشار بطن راست در پایان دیاستول، RVSP: فشار بطن راست در فاز سیستول، SPAP:

<sup>۱۰</sup> Pulmonary Capillary Wedge Pressure


<sup>۱۱</sup> Cardiac Output

<sup>۱۲</sup> Mean Squared Error (MSE)

آزمون قرار داده شد که در بخش‌های (۱۰) و (۱۱) و (۱۲) قابل مشاهده می‌باشد. به این معنی که در هر تست ویژگی‌های شبکه عصبی از جمله تعداد نورون‌های هر لایه، نرخ‌های آموزش، تعداد گام آموزش و اتصال‌های بین لایه‌ها متغیر است. انجام این تست تا حدودی توانسته است به تخمین مقدار مقاومت عروق ریوی کمک کند، بنابراین هنوز مقداری خطا در این تحقیق وجود دارد که این مقدار از خطا به تعداد داده‌های انتخاب شده و ساختار شبکه عصبی وابستگی زیادی دارد. مقادیر بهینه پارامترهای شبکه عصبی با آزمون و خطا تعیین می‌گردد و بهینه‌ترین حالت ممکن انتخاب می‌شود که البته در تحقیقات آینده با داده‌ها و استخراج ویژگی‌های بیشتر می‌توان با خطای کمتری ساختار شبکه را آموزش داد.


### ۱۰- بررسی ساختار شبکه عصبی مدل اول

در مدل اول به دلیل کمبود داده‌ها تنها ۴۲۵ داده از بیماران در دسترس و قابل استفاده گردید که ۷۵ درصد داده‌ها برای آموزش و ۲۵ درصد داده‌ها برای تست استفاده شد. ساختار شماتیک [۱-۵-۲۰-۸] شبکه عصبی با ۶۰۰ گام آموزش و حدود وزن (۰/۵ و ۰/۵-) و نرخ آموزش<sup>۱۶</sup> برابر ۰/۰۱ نیز به صورت ذیل می‌باشد:



شکل ۲- ساختار شبکه عصبی در مدل اول

لایه اول با پنج ورودی، تعداد نورون لایه‌های میانی به ترتیب ۲۰، ۸ است. و همچنین لایه خروجی با یک نورون مدل شده است.



<sup>۱۶</sup> Learning rate

### ۸- آموزش شبکه عصبی بر مبنای ورودی اکو و خروجی واقعی PVRcath

در قدم بعدی جهت بررسی رابطه برخی روابط غیرخطی با مقاومت عروق ریوی، روش کار به این ترتیب شد که از پارامترهای بدست آمده از اکوکاردیوگرافی به مقاومت عروق ریوی حاصل از کاتتریزاسیون دست پیدا شود. بنابراین در داده‌های ورودی، از پارامترهای اکوکاردیوگرافی نظیر قطر ورید اجوف تحتانی، فشار شریان ریوی در فاز سیستولیک، کسر جهشی بطن چپ، اختلال عملکرد شدید بطن راست (RV dysfunction) و در نورون خروجی مقاومت عروق پولمونری کاتتریزاسیون استفاده شد. برخی از مقادیر داده‌های بایگانی شده به صورت کیفی بودند و به صورت کمی و عددی (که زبان شبکه است) تبدیل شدند و از برخی مقادیر بازه‌ای، میانگین‌گیری و مطابق جدول (۳) به صورت عددی، تبدیل و مرتب شد.

پارامتر کیفی	مقدار کمی معادل	پارامتر کیفی	مقدار کمی معادل
normal	1	25-30	27.5
mildly enlarged	2	20-25	22.5
severely enlarged	6	15-20	17.5
mild to moderately enlarged	3	normal	1
moderately enlarged	4	enlarged	2
moderate to severely enlarged	5	Top Normal	1
TopNormal	1	no	0
normal	1	mild	1
mildly reduced	2	moderate	2
moderate to severely reduced	5	severe	3
moderately reduced	4	severely reduced	6
mild to moderately reduced	3		

### ۹. داده‌های مربوط به اکوکاردیوگرافی

بعد از تکمیل شدن اطلاعات بیماران، داده‌ها نرمالسازی شدند. شبکه عصبی با چهار لایه و تعداد نورون‌های مختلف در هر لایه، نرخ آموزش و تعداد گام آموزش متفاوت مورد آموزش و تست قرار گرفت. ویژگی‌های شبکه عصبی نقش بسیار مهمی در بهبود خروجی نهایی دارند، با افزایش این ویژگی‌ها خطای خروجی شبکه عصبی می‌تواند کاهش قابل توجهی داشته باشد. این تست در سه مدل و ساختار مختلف شبکه عصبی مورد

<sup>۱۲</sup> Inferior Vena Cava

<sup>۱۴</sup> Tricuspid Regurgitation Grading

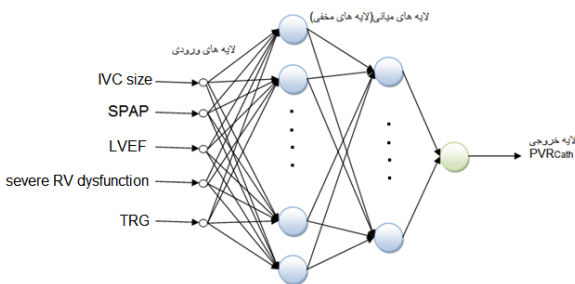
<sup>۱۵</sup> Left Ventricle Ejection Fraction

### ۱-۱۰- بررسی نتایج حاصل از آموزش شبکه عصبی مبتنی بر داده‌های PVR cath (مدل اول)

پس از بررسی نتایج تحقیقات قبلی، تحلیل‌های انجام شده در زمینه تخمین مقاومت عروق ریوی و بیان نحوه انجام آزمایش برای بررسی نحوه عملکرد شبکه عصبی در زمینه یادگیری و تست پیش‌بینی و تخمین مقاومت عروق ریوی، در این بخش به بررسی نتایج به دست آمده از تحلیل تست داده‌ها بر اساس داده‌های استخراج شده برای تمام بیماران و بررسی میزان همبستگی پارامترهای جدید اکوکاردیوگرافی با مقاومت عروق ریوی حاصل از کاتتریزاسیون قلب راست در بیماران مختلف پرداخته می‌شود. انجام این تست نشان داد که پارامترهای ورودی مزبور همبستگی قابل قبولی با مقدار PVRcath دارند و اینکه شبکه عصبی قادر به یادگیری دانش مابین ورودی و خروجی با خطایی نسبی حدود ۰/۳۱ است.

### ۱-۱۱- مدل دوم آموزش شبکه عصبی پیشنهادی با ورودی‌های اکو و خروجی PVRcath (روش مبتنی بر آموزش الگو به الگو)

در روش الگو به الگو، تمام الگوها به صورت جداگانه به شبکه عصبی آموزش داده می‌شوند. چنانچه در چکیده و بخش ۷ ذکر شد، تقسیم بندی داده‌ها برای آموزش و تست قابل تغییر است و در این مدل ۹۰ درصد داده‌ها برای آموزش و ۱۰ درصد داده‌ها برای تست اختصاص داده شد. ساختار شماتیک [۱-۱۱-۱۷-۵] شبکه عصبی با ۶۰۰ گام آموزش و حدود وزن (۰/۵ و ۰/۵-) و نرخ آموزش ۰/۰۰۱ در شکل (۵) نمایش داده شده است.




### شکل ۵- ساختار شبکه عصبی در مدل دوم (روش مبتنی بر آموزش الگو به الگو).

لایه اول با پنج ورودی، تعداد نورون لایه‌های میانی به ترتیب ۱۷، ۱۱ است. و همچنین لایه خروجی با یک نورون مدل شده است.

شکل ۳- نمودار آموزش و تست برای مدل اول- محور عمودی نمودارهای سمت چپ مقاومت عروق پولمونری در واحد (wood) و محور افقی تعداد داده‌های مورد ارزیابی می‌باشد- محور عمودی منحنی‌های سمت راست میانگین مربعات خطای آزمون ( $wood^2$ ) و تست و محور افقی تعداد دفعات آموزش

منحنی آموزش، تست و همچنین رگرسیون مربوط به مدل اول به دست آمد در شکل (۳) و (۴) قابل مشاهده است که خطایی در حدود ۰/۱۹ را نشان می‌دهد و خطایی نسبتاً قابل قبول است.<sup>۱۷</sup>



### شکل ۴- رگرسیون آموزش و تست برای مدل اول

به طور کلی رگرسیون بین خروجی شبکه عصبی و داده‌های واقعی می‌باشد. معادله خط رگرسیون داده‌های آموزش شبکه عصبی به صورت

$$PVR_{Rechnn} = 0.96 \times PVR_{Rechor} + 0.16$$

و معادله خط رگرسیون داده‌های تست

$$PVR_{Rechnn} = 0.94 \times PVR_{Rechor} + 0.24$$

می‌باشد.

خطاهای مربوط به مدل اول در جدول (۴) نمایش داده شده است.

### جدول ۴- نتایج حاصل از میانگین و انحراف معیار خروجی (مقاومت عروق ریوی) شبکه عصبی مدل اول

ساختار شبکه	خطای آموزش - $wood^2$	خطای تست - $wood^2$
۵-۲۰-۸-۱	$0.3756 \pm 0.0147$	$0.2732 \pm 0.0547$

<sup>۱۷</sup> میانگین مربعات خطای آموزش Mse train

میانگین مربعات خطای تست Mse test

تعداد دفعات آموزش و تست Epoch

داده‌های آموزش Train Data

داده‌های تست Test Data

خروجی شبکه عصبی Output

<sup>۱۸</sup> مقاومت عروق ریوی اکو با استفاده از شبکه‌های عصبی

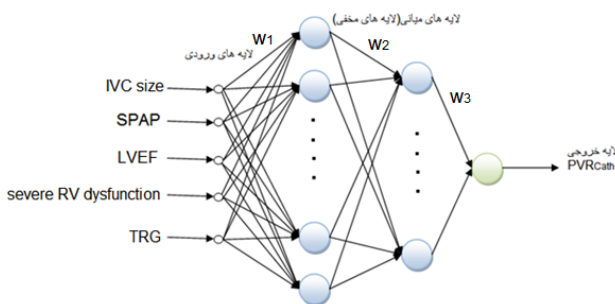
<sup>۱۹</sup> مقاومت عروق ریوی اکو براساس داده‌های واقعی



## ۱۲. مدل دوم شبکه عصبی در تست نهایی (روش مبتنی بر آموزش الگو دسته‌ای)<sup>۲۱</sup>


در روش آموزش دسته‌ای تمام الگوها به یکباره به شبکه عصبی آموزش داده می‌شود. در این مدل نیز ۸۰ درصد داده‌ها برای آموزش و ۲۰ درصد داده‌ها برای تست مورد استفاده قرار گرفت.

ساختار شماتیک [۱-۱۲-۲۰-۵] شبکه عصبی با ۱۸۰۰ گام آموزش و حدود وزن (۰/۴ و -۰/۴) و نرخ آموزش ۰/۰۰۱ نیز به صورت ذیل می‌باشد:



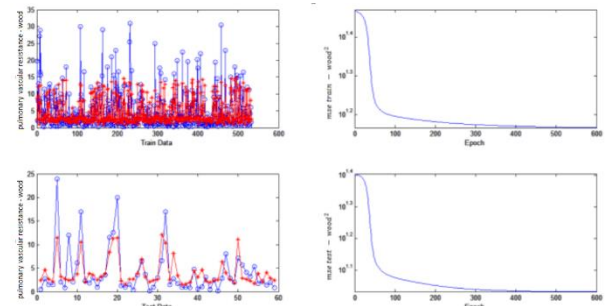
شکل ۸- ساختار شبکه عصبی در مدل دوم براساس آموزش الگو دسته‌ای.

لایه اول با پنج ورودی، تعداد نورون لایه‌های میانی به ترتیب ۲۰، ۱۲ است. و همچنین لایه خروجی با یک نورون مدل شده است.



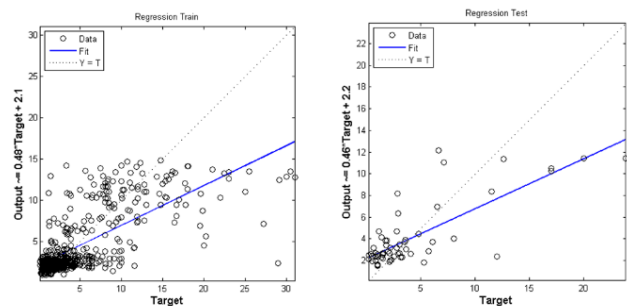
شکل ۹- نمودار آموزش و تست برای مدل دوم براساس آموزش الگو دسته‌ای. محور عمودی نمودارهای سمت چپ مقاومت عروق پولمونری در واحد (wood) و محور افقی تعداد داده‌های مورد ارزیابی می‌باشد - محور عمودی منحنی‌های سمت راست میانگین مربعات خطای آزمون ( $wood^2$ ) و تست و محور افقی تعداد دفعات آموزش.

منحنی آموزش، تست و همچنین رگرسیون مربوط به مدل دوم (مبتنی بر آموزش الگو دسته‌ای) در شکل (۹) و (۱۰) قابل مشاهده است که خطایی در حدود ۹/۵۸ را نشان می‌دهد و خطایی نسبتاً زیاد در مقایسه با مدل اول است. بنابراین در این



شکل ۶- نمودار آموزش و تست برای مدل دوم روش مبتنی بر آموزش الگو به الگو. محور عمودی نمودارهای سمت چپ مقاومت عروق پولمونری در واحد (wood) و محور افقی تعداد داده‌های مورد ارزیابی می‌باشد - محور عمودی منحنی‌های سمت راست میانگین مربعات خطای آزمون ( $wood^2$ ) و تست و محور افقی تعداد دفعات آموزش.

منحنی آموزش، تست و همچنین رگرسیون مربوط به مدل دوم به دست آمد و در شکل (۶) و (۷) قابل مشاهده است که خطایی در حدود ۱۰/۷۶ را نشان می‌دهد.



شکل ۷- رگرسیون آموزش و تست برای مدل دوم براساس آموزش الگو به الگو.

رگرسیون بین خروجی شبکه عصبی و داده‌های واقعی می‌باشد. معادله خط رگرسیون آموزش شبکه عصبی به صورت  $PVRcath_n = 0.48 \times PVRcath_r + 2.1$  و معادله خط رگرسیون تست  $PVRcath_n = 0.46 \times PVRcath_r + 2.2$  می‌باشد.<sup>۲۰</sup>

در جدول (۵) میزان خطاهای خروجی تست اول در آموزش و تست نشان داده شده است.

جدول ۵- نتایج حاصل از میانگین و انحراف معیار خروجی (مقاومت عروق ریوی) شبکه عصبی مدل دوم روش مبتنی بر آموزش الگو به الگو

ساختار شبکه	خطای آموزش $wood^2$	خطای تست $wood^2$
۱-۱۱-۱۷-۵	$14/6726 \pm 127.0$	$10/7669 \pm 119.0$

<sup>۲۰</sup> مقاومت عروق ریوی کاتر بسم با استفاده از شبکه‌های عصبی  $PVRcath_n$  مقاومت عروق ریوی کاتر بسم براساس داده‌های واقعی  $PVRcath_r$

<sup>۲۱</sup> Batch Learning

نداشته است و همچنین کیفی بودن برخی از پارامترها مانند اختلال شدید بطن راست<sup>۲۲</sup> که بر اساس شدت هر کدام مقدار عددی (از ۰ تا ۶) به هر یک تعلق گرفت، باعث گردید مقدار خطاها بیشتر از حد قابل قبول گردد. البته استفاده از الگوریتم آموزشی لونیبرگ مارکوآرت<sup>۲۳</sup>، که یک روش مبتنی بر آموزش الگو دسته‌ای می‌باشد، باعث کمتر شدن خطا و حصول یک خروجی نزدیک‌تر به خروجی هدف گردید. به طور معمول ۷۵٪ از داده‌ها برای آموزش شبکه و ۲۵٪ داده‌ها جهت تست استفاده می‌گردد، بنابراین یک آزمایش به طور اتفاقی انجام شد که این آزمون مبتنی بر آموزش الگو به الگو بود و در این مدل به دلیل محدود بودن داده‌ها و ضرورت آموزش شبکه عصبی با داده‌های بیشتر، ۹۵٪ داده‌ها برای آموزش و فقط ۵٪ داده‌ها جهت تست استفاده شد و مشاهده گردید که خطا نسبت به حالات مشابه به اندازه چشمگیری کاهش پیدا کرد و می‌توان نتیجه گرفت که کاهش و یا افزایش خطا به میزان زیادی وابسته به تعداد (کمی) داده‌ها می‌باشد. به طور کلی این پژوهش (به شرط استخراج ویژگی‌های مناسب و دقیق) می‌تواند نتیجه‌ای مطلوب و قابل قبول ارائه دهد و در سیستم‌های تشخیص و درمان پزشکی بسیار کاربردی واقع گردد.

#### ۱۴- نتیجه‌گیری و پیشنهادات جهت ادامه و بهبود نتایج تحقیق


در این مقاله، پیش‌بینی مقاومت عروق ریوی و فشار داخلی بطن راست بر مبنای داده‌های اکوکاردیوگرافی و شبکه عصبی مصنوعی انجام گرفته شده است. شبکه‌های عصبی به عنوان یکی از بهترین مدل‌های پیچیده یادگیری دانش از داده، دارای یکسری ویژگی‌ها می‌باشند که می‌توان به موارد ذیل اشاره نمود:

- وابستگی زیاد دقت نتایج به اندازه مجموعه آموزش (تعداد نمونه‌های آموزش).

- آموزش شبکه ممکن است مشکل و یا حتی غیر ممکن باشد. به طور کلی نتیجه می‌شود این تکنیک قادر است، در مواقعی که داده‌ها در شرایط عدم اطمینان (ناقص یا دارای نویز) هستند، جوابی منطقی ارائه دهد. محاسبه‌گرهای شبکه‌های عصبی در مواقعی که شرایط تغییر کنند، بسیار منعطف هستند و همچنین نگهداری آنها بسیار آسان است. نکته دیگر اینکه، محاسبات شبکه عصبی معمولاً نیازمند مقادیر زیادی داده برای آموزش است و به دلیل پیشرفت‌های تکنیکی از قدرت

آزمون، خطا در میانگین مربعات خطای داده‌های آموزش بیشتر از میانگین مربعات خطای داده‌های تست می‌باشد و این می‌تواند به دلیل تغییر در تعداد گام آموزش و یا تغییر در حدود وزنها باشد.

همچنین رگرسیون مربوط به ساختار دوم در شکل (۱۰) نمایش داده شده است.



شکل ۱۰- رگرسیون آموزش و تست برای مدل دوم براساس آموزش الگو دسته‌ای.

رگرسیون بین خروجی شبکه عصبی و داده‌های واقعی می‌باشد. معادله خط رگرسیون آموزش شبکه عصبی به صورت  $PVR_{cathL} = 0.5 \times PVR_{cathR} + 2.5$  و معادله خط رگرسیون تست  $PVR_{cathL} = 0.68 \times PVR_{cathR} + 1.9$  می‌باشد. همچنین رگرسیون کاهش چشمگیری در خطای تست را نسبت به آزمون روش الگو به الگو نشان می‌دهد. در جدول (۶) میزان خطاهای خروجی مدل دوم جهت آموزش و تست نشان داده شده است.

جدول ۶- نتایج حاصل از میانگین و انحراف معیار خروجی (مقاومت عروق ریوی) شبکه عصبی مدل دوم براساس آموزش الگو دسته‌ای.

ساختار شبکه	خطای آموزش $wood^2$	خطای تست $wood^2$
۱-۱۲-۲۰-۵	$15/8243 \pm 214.0$	$9/5879 \pm 108.0$

#### ۱۳- ارزیابی کلی

نتایج در مدل اول که ورودی‌ها و خروجی PVR هر کدام استخراج شده از کاتتریژاسیون بطن راست بودند و از معادله (۲) پیروی می‌کردند و همچنین با افزودن پارامتر فشار شریانی ریوی در فازهای سیستول و دیاستول، رگرسیون‌ها همبستگی قابل قبولی را نشان دادند و خطا در مدل اول به دلیل مناسب بودن داده‌ها و تعداد افراد مورد مطالعه کافی و کمی (عددی) بودن داده‌ها، بسیار کم و قابل قبول بود. از این رو در تست دوم به دلیل کم بودن داده‌های مناسب و استفاده از تعدادی پارامتر قلبی عروقی ریوی برای اولین بار که در هیچ معادله‌ای، رابطه ریاضی برای آنها با مقاومت عروق ریوی وجود

<sup>۲۲</sup> Severe RV Dysfunction

<sup>۲۳</sup> Levenberg-Marquardt algorithm

- [6] K. Yasui, S. Yuda, K. Abe, A. Muranaka, M. Otsuka, H. Ohnishi, & T. Miura, Pulmonary vascular resistance estimated by Doppler echocardiography predicts mortality in patients with interstitial lung disease. *Journal of cardiology*, 68(4), 300-307, 2016.
- [7] Y. Chaowu, X. Zhongying, J. Jinglin, L. Jinglin, L. Qiong, et al. A feasible method for non-invasive measurement of pulmonary vascular resistance in pulmonary arterial hypertension: Combined use of transthoracic Doppler-echocardiography and cardiac magnetic resonance. *Non-invasive estimation of pulmonary vascular resistance. IJC Heart & Vasculature. Cardiovascular Institute and Fuwai Hospital, Chinese Academy of Medical Sciences, Beijing 100037, China, 2015.*
- [8] A.E. Abbas, L.M. Franey, T. Marwick, M.T. Maeder, D.M. Kaye, A.P. Vlahos, & S.J. Lester, Noninvasive assessment of pulmonary vascular resistance by Doppler echocardiography. *Journal of the American Society of Echocardiography*, 26(10)2013.
- [9] P. Lindqvist, S. Söderberg, M. C. Gonzalez, E. Tossavainen, M.Y. Henein, "Echocardiography based estimation of pulmonary vascular resistance in patients with pulmonary hypertension: a simultaneous Doppler echocardiography and cardiac catheterization study," 2011.
- [10] R.R. Vanderpool, and R. Naeije, Hematocrit-corrected Pulmonary Vascular Resistance. *American journal of respiratory and critical care medicine*, 2018.
- [11] N. Naderi, Z. Ojaghi Haghighi, A. Amin, Naghashzadeh, H. Bakhshandeh, S. Taghavi, & M. Maleki, Utility of right ventricular strain imaging in predicting pulmonary vascular resistance in patients with pulmonary hypertension. *Congestive Heart Failure*, 19(3), 116-122, 2013.
- [12] W. Huang, R.K. Oliveira, H. Lei, D.M. Systrom, and Waxman, A.B., Pulmonary vascular resistance during exercise predicts long-term outcomes in heart failure with preserved ejection fraction. *Journal of cardiac failure*, 24(3), 169-176, 2018.
- [13] L.R. Bekhet, Y. Wu, N. Wang, X. Geng, W.J. Zheng, F. Wang, H. Wu, H. Xu, and Zhi, D., A study of Generalizability of Recurrent Neural Network-Based Predictive Models for Heart Failure Onset Risk using a Large and Heterogeneous EHR Data set. *Journal of biomedical informatics*, 2018.
- [14] Y. Cheng, F. Wang, P. Zhang, and J. Hu, June. Risk prediction with electronic health records: A deep learning approach. In *Proceedings of the 2016 SIAM International Conference on Data Mining* (pp. 432-440). Society for Industrial and Applied Mathematics, 2016.
- [15] Acharya, U.R., Fujita, H., Oh, S.L., Hagiwara, Y., Tan, J.H., Adam, M. and Tan,

پردازشی بالای برخوردار می‌باشند. شبکه‌های عصبی باتوجه به توانایی‌های منحصر به فرد خود به کمک علم پزشکی آمده اند و در مواردی که این علم هنوز نتوانسته نارسایی‌های خود را به تنهایی برطرف کند، شبکه‌های عصبی کمک شایانی در زمینه رفع ناتوانایی‌های آن ارائه می‌دهد. کاهش هزینه‌ها، بالابردن اطمینان و دقت پزشکان در تصمیم‌گیری‌های حیاتی و طلایی در مورد بیماران از مزایای هوش مصنوعی می باشد. به طور کلی می‌توان نتیجه گرفت، اگر داده‌های کامل و به تعداد زیاد، جهت آموزش شبکه‌عصبی استفاده شود، این امکان حاصل خواهد شد که بتوان رویدادهای بسیار مهم از جمله بیماری‌ها و پارامترهای آنها را با خطایی بسیار کم و قابل قبول پیش‌بینی و درمان نمود. در ادامه تحقیق، پیشنهاد می‌شود با توجه به اهمیت و جایگاه این موضوع در حوزه پزشکی و اینکه بسیاری از بیماران توانایی انجام آزمایش‌های مرتبط با روش‌های تهاجمی را ندارند و احساس نیاز به روش‌های جدید پزشکی جهت بدست آوردن مقاومت عروق ریوی احساس می شود، با جمع آوری داده‌های بسیار زیاد بیماران قلبی عروقی، در جهت بهبود آموزش شبکه‌عصبی با ساختارهای مناسب دیگر از جمله شبکه‌عصبی چندجمله‌ای (GMDH)<sup>۲۴</sup> و بازه‌ای<sup>۲۵</sup> مطالعه انجام گردد.

## ۱۵- مراجع

- [1] تشنه لب، محمد، شبکه‌های عصبی و کنترل کننده‌های عصبی پیش‌رفته با رویکرد شبکه‌های راف، چاپ اول، تهران: انتشارات دانشگاه خواجه نصیرطوسی، ۱۳۹۴.
- [2] N. Ajam, Heart Diseases Diagnoses using Artificial Neural Network. *IISTE Network and Complex Systems*, 5(4), 2015.
- [3] Y. Sharafi, S. Setayeshi, A. Falahiazar, An Improved Model of Brain Emotional Learning Algorithm Based on Interval Knowledge. *Journal of mathematics and computer science* 14, 42-53, 2015.
- [4] E. Choi, A. Schuetz, W.F. Stewart, and J. Sun, Using recurrent neural network models for early detection of heart failure onset. *Journal of the American Medical Informatics Association*, 24(2), 361-370, 2016.
- [5] P. Naing, H. Kuppusamy, G. Scalia, G.S. Hillis, G.S. Playford, non- Invasive Assessment of Pulmonary Vascular Resistance in Pulmonary Hypertension: Current Knowledge and Future Direction, *Heart, Lung and Circulation*, 2016.

<sup>۲۴</sup> Group method of data handling (GMDH)

<sup>۲۵</sup> Rough

- R.S., Deep convolutional neural network for the automated diagnosis of congestive heart failure using ECG signals. *Applied Intelligence*, 1-12, 2018.
- [16] D. Markush, R.D. Ross, R. Thomas, and S. Aggarwal, Noninvasive echocardiographic measures of pulmonary vascular resistance in children and young adults with cardiomyopathy. *Journal of the American Society of Echocardiography*, 2018.
- [17] J. Muneuchi, Y. Ochiai, N. Masaki, S. Okada, C. Iida, Y. Sugitani, Y. Ando, and M. Watanabe, Pulmonary arterial compliance is a useful predictor of pulmonary vascular disease in congenital heart disease. *Heart and vessels*, 1-7, 2018.
- [18] D.P. Perrin, A. Bueno, A. Rodriguez, G.R. Marx, and J. Pedro, March. Application of convolutional artificial neural networks to echocardiograms for differentiating congenital heart diseases in a pediatric population. In *Medical Imaging 2017: Computer-Aided Diagnosis*. International Society for Optics and Photonics, 2017.
- [19] کاکوتی، امیررضا و مهدی جعفری شهپاززاده، ۱۳۹۴، طبقه بندی اتوماتیک تومور مغزی در تصاویر MRI با استفاده از شبکه عصبی مصنوعی ANN، کنفرانس بین المللی پژوهش در مهندسی، علوم و تکنولوژی، استانبول، موسسه مدیران ایده پرداز پایتخت ویرا،