

Prediction of Pulmonary Artery and Peripheral Vascular Pressure based on Echocardiography Data and Artificial Neural Network

Abbasi, Hamed¹ / Shojaei, Shahrokh^{2*} / Naderi, Nasim³

¹ - M.Sc. Student, Biomedical Engineering Department, Central Tehran Branch, Islamic Azad University, Tehran, Iran

² - Assistant Professor, Department of Medical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran

³ - Associate Professor, Department of Cardiology and Cardiology, Shahid Rajaie Cardiology, Medical and Research Center, Tehran University of Medical Sciences, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/IJBME.2019.98112.1421

Received: 21 November 2018

Revised: 30/1/2019-17/3/2019-19/6/2019

Accepted: 21 July 2019

KEYWORDS

Prediction
Artificial Neural Network
Pulmonary Vascular Resistance
Echocardiography


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_{cath}. 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, 14.67 and 10.76 for the second model, and 15.82 and 9.58 for the third model.

*Corresponding Author

Address	Department of Biomedical Engineering, Central Tehran Branch, Islamic Azad University, Tehran, Iran		
Postal Code	-	Tel	+98-21-44600057
E-Mail	s.shojaei@aut.ac.ir	Fax	+98-21-44600057





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

عباسی، حامد^۱ / شجاعی، شاهرخ^{۲*} / نادری، نسیم^۳

^۱ - دانشجوی کارشناسی ارشد، گروه مهندسی پزشکی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

^۲ - استادیار، گروه مهندسی پزشکی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران

^۳ - دانشیار، گروه قلب و پیوند قلب، قلب و عروق شهید رجایی، مرکز پزشکی و پژوهشی، دانشگاه علوم پزشکی تهران، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/IJBME.2019.98112.1421

پذیرش: ۳۰ تیر ۱۳۹۸

بازنگری: ۱۳۹۷/۱۱/۱۰ - ۱۳۹۷/۱۲/۲۶ - ۱۳۹۸/۳/۲۹

ثبت در سامانه: ۳۰ آبان ۱۳۹۷

چکیده

واژه‌های کلیدی

امروزه جهت تصمیم‌گیری در مورد بسیاری از عمل‌های جراحی قلب و بررسی شرایط و آمادگی بیمار برای انجام عمل جراحی، از روش اندازه‌گیری مقاومت عروق ریوی استفاده می‌شود. اگر مقدار این مقاومت از یک حد آستانه بالاتر باشد، بیمار به عنوان غیرقابل عمل در نظر گرفته شده و حتی گاهی درمان‌هایی برای کاهش مقاومت عروق ریوی در مراحل اولیه‌ی بیماری‌های این عروق انجام می‌شود که برای پیگیری کاهش مقاومت عروق ریوی نیز لازم است تا این پارامتر مجدداً اندازه‌گیری شود. در حال حاضر تنها معیار برای اندازه‌گیری این پارامتر، استفاده از روش‌های کاتتریسم است که روشی تهاجمی بوده و با عوارض جانبی زیادی همراه است. هدف از انجام این تحقیق، ارائه‌ی یک روش غیرتهاجمی به جای روش تهاجمی کاتتریزاسیون قلبی، از طریق پیش‌بینی مقاومت عروق ریوی بر مبنای داده‌های اکوکاردیوگرافی توسط شبکه‌های عصبی مصنوعی می‌باشد. این تحقیق روی ۵۹۱ بیمار صورت گرفته است. پس از انجام اکوکاردیوگرافی برای تمامی بیماران، داده‌های اکوکاردیوگرافی (CO, PCWP, sPAP, dPAP, mPAP) به عنوان ورودی شبکه‌ی عصبی و مقاومت عروق ریوی تمام بیماران (حاصل از کاتتریزاسیون قلبی) به عنوان خروجی شبکه‌ی عصبی مورد ارزیابی قرار گرفته و در نهایت ارتباط بین داده‌های اکوکاردیوگرافی و PVRcath به دست آمده است. برای بررسی عمل‌کرد شبکه‌ی عصبی پیشنهادی، به طور معمول از ۷۵٪ داده‌ها برای آموزش و از ۲۵٪ داده‌ها برای آزمون استفاده شده و هم‌چنین برای آموزش بهتر شبکه‌ی عصبی، این نسبت‌ها تغییر داده شده است. در نتایج پیاده‌سازی، میانگین مربعات خطا به ترتیب برای داده‌های آموزش و آزمون شبکه‌ی عصبی پیشنهادی در مدل اول برابر با ۰/۳۷ و ۰/۲۷، در مدل دوم برابر با ۱۴/۶۷ و ۱۰/۷۶ و در مدل سوم برابر با ۱۵/۸۲ و ۹/۵۸ به دست آمده است.

پیش‌بینی

شبکه‌ی عصبی مصنوعی

مقاومت عروق ریوی

اکوکاردیوگرافی

*نویسنده‌ی مسئول

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

کد پستی: -
تلفن: +۹۸-۲۱-۴۴۶۰۰۵۷

پست الکترونیک: s.shojaei@aut.ac.ir
دورنگار: +۹۸-۲۱-۴۴۶۰۰۵۷



۱- مقدمه

ریوی کمک می‌کند تا فشار خون ریوی پیش‌مویرگی از فشار خون ریوی پس‌مویرگی متمایز شده و با کاتریزاسیون بطن راست اندازه‌گیری شود [۱۱، ۱۲]. اخیراً از شبکه‌های عصبی بازگشتی^۴ با داده‌های ثبت الکترونیکی سلامت برای پیش‌بینی خطرات ناشی از بیماری استفاده می‌شود. در سال ۲۰۱۸ از یک شبکه‌ی عصبی بازگشتی بر اساس داده‌های واقعی EHR^۵ برای پیش‌بینی ریسک ابتلا به نارسایی قلبی استفاده شده است [۱۳]. در سال ۲۰۱۶ چنگ و هم‌کارانش یک رویکرد یادگیری عمیق در شبکه‌های عصبی را برای فنوتیپی از پیشینه‌ی الکترونیکی سلامت بیماران ارائه کرده و برای اولین بار EHR-ها را به عنوان یک ماتریس زمانی برای هر بیمار روی یک بعد نشان داده‌اند [۱۴]. در پژوهش‌های اخیر به طور وسیعی از ابزارهای هوش مصنوعی برای پیش‌بینی بیماری‌های مختلف استفاده شده است. برای مثال در مقاله‌ی [۱۵] از شبکه‌های عصبی بازگشتی برای پیش‌بینی نارسایی قلبی استفاده شده است. هم‌چنین می‌توان از سیستم‌های مقایسه‌ای شبکه‌های عصبی برای تشخیص تومورهای مغزی و سرطان سینه با انجام پردازش روی تصاویر MRI^۶ و ماموگرافی استفاده کرد. در سال ۲۰۱۵ مدل طبقه‌بندی اتوماتیک تومور مغزی در تصاویر MRI با استفاده از شبکه‌های عصبی مصنوعی بازگشتی ارائه شده است [۱۹].

به طور کلی هدف از انجام این تحقیق، حذف روش‌های تهاجمی اندازه‌گیری مقاومت عروق ریوی و جایگزین کردن یک سیستم هوشمند جهت تخمین این پارامتر با دقت بالا می‌باشد (با توجه به این که مقدار این پارامتر در افراد سالم کم‌تر از یک است).

۲- شبکه‌های عصبی مصنوعی

شبکه‌ی عصبی مصنوعی، مدل ساده شده‌ای از یک سیستم مرکزی است که در طراحی آن از مغز انسان الهام گرفته شده است. شبکه‌ی عصبی مصنوعی یک شبکه‌ی محاسباتی است که هدف آن شبیه‌سازی شبکه‌هایی از سلول‌های (نورون) سیستم عصبی مرکزی می‌باشد. ساختار یک شبکه‌ی عصبی شامل تعدادی واحد پردازش (نورون) و ارتباط‌های بین آن‌ها (اتصالات وزن‌دار) بوده که مقدار وزن این اتصالات نشان دهنده‌ی قدرت آن‌ها می‌باشد. به یک زیرگروه از عناصر پردازش در شبکه‌ی عصبی، لایه گفته می‌شود. شبکه‌ی عصبی مورد استفاده در این مطالعه شامل سه لایه‌ی مختلف است. لایه‌ی اول، لایه‌ی ورودی

امروزه جهت تصمیم‌گیری در مورد انجام بسیاری از عمل‌های جراحی قلب و بررسی شرایط و آمادگی بیمار برای انجام عمل جراحی، از روش اندازه‌گیری مقاومت عروق ریوی استفاده می‌شود. اگر مقدار این مقاومت از یک حد آستانه بالاتر باشد، بیمار شرایط عمل جراحی را ندارد. در حال حاضر تنها معیار برای بررسی مقاومت و فشار عروق ریوی و برون‌ده بطن راست، استفاده از روش‌های تهاجمی مانند کاتتریسم است. از روش اکوکاردیوگرافی نیز برای اندازه‌گیری مقاومت عروق ریوی استفاده می‌شود، اما دقت و ضریب اطمینان این روش کم‌تر از روش کاتتریسم است. هدف اصلی این پژوهش جایگزین کردن روشی غیرتهاجمی برای دستیابی به نتایج مطلوب و قابل اطمینان می‌باشد. هوش مصنوعی در حوزه‌ی سلامت به معنای استفاده از الگوریتم‌هایی است که در تجزیه و تحلیل اطلاعات پزشکی پیچیده از شناخت انسان استفاده می‌کنند. شبکه‌های عصبی مصنوعی^۱ یکی از جدیدترین زمینه‌های پژوهشی در حوزه‌ی هوش مصنوعی بوده که از مهم‌ترین شاخه‌های اصلی آن می‌توان به پردازش تکاملی، سیستم‌های فازی، سیستم‌های خبره، شبکه‌های عصبی و یادگیری عمیق اشاره کرد [۱]. شبکه‌های عصبی مصنوعی سامانه‌هایی کاملاً پیچیده و غیرخطی برای یادگیری و ایجاد دانش هستند که در پزشکی می‌توان از آن‌ها برای طبقه‌بندی افراد به دسته‌های بیمار یا سالم استفاده کرد. طبقه‌بندی و پیش‌بینی وضعیت بیمار بر اساس عوامل خطر یکی دیگر از کاربردهای شبکه‌های عصبی مصنوعی است [۲-۴]. به طور کلی شبکه‌های عصبی با یادگیری یک رویداد و یافتن روابط بین داده‌های ورودی و خروجی آن، می‌توانند تغییرات خروجی را نسبت به ورودی‌های مختلف پیش‌بینی کنند. در این مقاله، با توجه به اهمیت اندازه‌گیری مقاومت عروق ریوی در عمل‌های جراحی، پارامترهای وابسته به آن از طریق اکوکاردیوگرافی استخراج شده و مقدار مقاومت عروق ریوی پس از کاتتریسم قلبی بر اساس داده‌های اکوکاردیوگرافی و با استفاده از شبکه‌ی عصبی تخمین زده شده است. مقاومت عروق ریوی ارزیابی شده توسط کاتریزاسیون بطن راست، به عنوان معیار برای پیش‌بینی مرگ‌ومیر در بیماران مبتلا به PAH^۲ و ILD^۳ به شمار می‌رود [۵-۷]. مقاومت عروق ریوی یک معیار تشخیصی برای ارزیابی فشار خون ریوی در بیماران قلبی می‌باشد [۸-۱۰]. اندازه‌گیری مقاومت عروق

^۱ Recurrent Neural Network^۵ Electronic Health Record (EHR)^۶ Magnetic Resonance Imaging (MRI)^۱ Artificial Neural Network (ANN)^۲ Pulmonary Artery Hypertension^۳ Interstitial Lung Disease



۳- مقاومت عروق ریوی

مقاومت عروق ریوی دارای نقش پیش‌بینی کننده در فرایند ارزیابی وضعیت بیماران مبتلا به فشار خون ریوی و نارسایی‌های مزمن قلبی بوده و یک پارامتر مهم برای تشخیص بیماران مبتلا به نارسایی قلبی به شمار می‌رود [۱۱، ۱۲]. بیماران مبتلا به فشار خون ریوی بالا به عنوان موارد مشکوک به بیماری قلبی شناخته شده و برای ارزیابی پارامترهای همودینامیک مانند PVR، تحت عمل کاتتریزاسیون بطن راست قرار می‌گیرند. در روش‌های تهاجمی، مقاومت عروق ریوی با استفاده از نسبت گرادیان فشار درون ریوی به جریان درون ریوی حاصل شده در حالی که این مقدار در روش‌های غیرتهاجمی با استفاده از نسبت سرعت برگشت تریکوسپید به انتگرال زمان و سرعت جریان خروجی بطن راست به دست می‌آید (رابطه‌ی ۱) [۱۱، ۱۶، ۱۷].

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

در رابطه‌ی (۱)، PVR_{Recho} مقاومت عروق ریوی حاصل از اکوکاردیوگرافی (گرادیان)، TRV نارسایی در بجه‌ی تریکوسپید (cm/s) و $TVIRVOT$ انتگرال زمانی سرعت جریان خروجی بطن راست (cm) می‌باشد. هم‌چنین مقاومت عروق ریوی با استفاده از رابطه‌ی (۲) محاسبه می‌شود [۸، ۱۱].


$$(2) \quad PVR = \frac{m \text{ PAPeCHO} - PCWP}{CO_{eCHO}}$$

در رابطه‌ی (۲)، $m \text{ PAP}$ میانگین فشار شریان ریوی حاصل از اکوکاردیوگرافی (mmHg)، $PCWP$ فشار گوه مویرگی ریوی (mmHg) و CO برون‌ده قلبی اکو (lit/min) می‌باشد.

۴- روش جمع‌آوری داده‌ها و انتخاب بیماران

از میان بیماران قلبی که برای انجام کاتتریزاسیون بطن راست جهت ارزیابی همودینامیک ریوی به درمانگاه‌های مرکز تحقیقاتی، آموزشی و درمانی شهید رجایی مراجعه کردند، تنها افرادی برای انجام این مطالعه انتخاب شدند که به یکی از بیماری‌های HF ، CHF ، $ICMP$ ، $CTEPH$ ، PH ، PAH ، DCM یا $Ischemic Cardio Myopathy$ یا $Dilated Cardio Myopathy$ مبتلا بودند. به دلایل مختلف، تعدادی از بیماران در جمع‌آوری داده‌های اکو در نظر گرفته نشدند که از آن جمله می‌توان به بیماران دارای فلج یا فیبریلاسیون دهلیزی یا هر آریتمی دیگری

است که یک رابط با محیط را نشان داده و لایه‌ی آخر شبکه‌ی عصبی، خروجی نهایی را تولید می‌کند. طبقه‌بندی و پیش‌بینی وضعیت بیمار بر اساس عوامل خطر، یکی از کاربردهای شبکه‌های عصبی مصنوعی است. شبکه‌های عصبی مصنوعی در حل مسایلی که راه حل الگوریتمی ندارند، مسایلی که راه حل الگوریتمی بسیار پیچیده‌ای دارند و نیز مسایلی که برای انسان آسان اما برای کامپیوتر دشوار هستند (مانند تشخیص تصاویر یا پیش‌بینی بر اساس دانش گذشته) کاربرد زیادی دارند. یک شبکه‌ی عصبی مصنوعی با پردازش داده‌های موجود، دانش و قوانین نهفته در درون داده‌ها را به ساختار شبکه منتقل کرده و بر اساس محاسباتی که روی داده‌های آموزش انجام می‌دهد، قوانین کلی موجود در درون داده‌ها را فرا می‌گیرد. یکی از مهم‌ترین ویژگی‌های شبکه‌های عصبی، قابلیت یادگیری آن‌ها است. قابلیت یادگیری به معنای توانایی تنظیم پارامترهای شبکه در مسیر زمان و با شرایط مختلف است تا شبکه‌ی آموزش داده شده بتواند کارآمدی خود را در یک وضعیت خاص، با وجود تغییرات اندک شرایط محیطی، حفظ نماید. پس از یک آموزش مناسب، شبکه می‌تواند در صورت برخورد با یک ورودی جدید که در جریان آموزش با آن مواجه نشده است، با استفاده از فرایند درون‌یابی، خروجی مناسبی را ارائه دهد. ساختار کلی شبکه‌های عصبی مصنوعی در شکل (۱) نشان داده شده است [۱۸].



در شکل (۱)، لایه‌ی اول بیان‌گر لایه‌ی ورودی شبکه‌ی عصبی است. لایه‌ی دوم (لایه‌های پنهان) که در وزن‌ها ضرب می‌شود، به صورت بازگشتی و بر اساس تعداد دفعات آموزش^۱ داده، گرادیان نزولی را اصلاح کرده و خطای پیش‌بینی را کاهش می‌دهد که این عمل به منظور آموزش شبکه‌ی عصبی انجام می‌شود. لایه‌ی انتهایی نیز بیان‌گر خروجی شبکه‌ی عصبی (هدف مورد پیش‌بینی) می‌باشد.

^۱ Epoch

جدول (۱) - مشخصات بیماران انتخاب شده

pvalue	پس‌مویرگی (n=۳۱۳)	پیش‌مویرگی (n=۲۷۸)	
NS	۳۹±۱۱	۴۷/۳±۱۰/۵	سن
...	۲۲۱ / ۹۲	۱۱۱ / ۱۶۷	مرد / زن
۰/۰۰۱	۱/۶±۰/۱۲	۱/۵۲±۰/۰۹	BSA (m ²)
NS	۱۰۶/۲±۱۴	۱۰۷/۵±۱۸	(mmHg) Systolic BP
NS	۶۸±۱۲	۶۵±۱۱	(mmHg) Diastolic BP
NS	۸۶±۱۷	۸۱±۲۰	(beat/min) Heart Rate
۰/۰۰۰ ^a ۰/۰۰۰ ^b	۱۲/۸±۲/۸	۱۶/۵±۶	(mm) TAPSE
۰/۰۰۰ ^a ۰/۰۰۰ ^b	۱۲/۷±۴/۱	۱۲/۱±۵/۳	(cm ² /m ²) RAA Index

در این جدول، BSA مساحت سطح بدن، Systolic BP فشار خون در فاز سیستول، Diastolic BP فشار خون در فاز دیاستول، Heart Rate ضربان قلب، RAA مساحت دهلیز راست، a فشار خون ریوی پیش‌مویرگی در مقابل وضعیت نرمال، b فشار خون ریوی پس‌مویرگی در مقابل وضعیت نرمال و NS بیان‌گر غیرمعنی‌دار بودن می‌باشد.

۶- روش انجام مطالعه بر پایه‌ی کاتتریزاسیون بطن راست

تمام بیماران (افراد مورد مطالعه) در آزمایشگاه کاتتریزاسیون با کاتترهای ترمودیلوسیون^۴ سه‌حفره‌ی بالن‌دار مدل (FY) و مانیتورهای مراقبت مورد آزمایش قرار گرفته و تمام اندازه‌گیری‌ها در حالت استراحت (خوابیده به پشت)، در حالی که فرد در هوای اتاق تنفس می‌کنند، انجام شده است. فشار در سه ضربان متوالی قلب در پایان انقباض به طور میانگین اندازه‌گیری شده و متغیرهای میانگین فشار دهلیز راست، فشارهای سیستولیک و پایان دیاستولیک بطن راست، فشار شریان ریوی در فازهای سیستول، دیاستول و مقدار میانگین آن، فشار گوه‌ای مویرگی ریوی^۵، اشباع اکسیژن وریدی و خروجی قلب^۶ از طریق ترمودیلوسیون و تکنیک فیک برای هر بیمار محاسبه شده است. در نهایت، مقاومت عروق ریوی با استفاده از رابطه‌ی (۳) محاسبه شده است [۲، ۶، ۷].

$$PVR = \frac{m \text{ PAP} - \text{PCWP}}{CO} \quad (3)$$

^۴ Thermodilusion

^۵ Pulmonary Capillary Wedge Pressure

^۶ Cardiac Output

که مانع اندازه‌گیری‌های اکوکاردیوگرافی شود، بیماران دارای سابقه‌ی جراحی قلب مانند پیوند عروق کرونری و هر گونه ترمیم یا تعویض دریچه‌ی قلب، بیماران دارای مشکل ریوی پیشرفته و بیماران دارای مشکلات قلبی مادرزادی اشاره کرد. بیماران با توجه به تاریخچه، معاینه‌ی فیزیکی، اکوکاردیوگرافی، الکتروکاردیوگرافی و نتایج منفی آزمایش‌های غیرتهاجمی و تهاجمی برای بیماری‌های قلبی و عروقی در مردان و زنان انتخاب شدند. از میان ۵۹۱ فرد منتخب، ۴۱۴ بیمار از پایگاه اطلاعاتی داده‌های مرکز قلب و بقیه از میان مراجعه‌کنندگان انتخاب شدند. با توجه به لزوم دسترسی به تعداد بیماران بیش‌تر برای به دست آوردن نتایج دقیق‌تر و بهینه‌تر، بقیه‌ی داده‌های مورد نیاز از سیستم مدیریت انفورماتیک بیمارستان و مرکز تحقیقاتی، آموزشی و درمانی شهید رجایی و پرونده‌های بیمارانی که دارای معیارهای ورود بودند استخراج گردید.

۵- روش انجام اکوکاردیوگرافی

در این مطالعه، اکوکاردیوگرام داپلر دوبعدی رنگی برای هر فرد با استفاده از یک سیستم^۱ با مبدل فاز هارمونیک فرکانس متغیر سه‌بعدی در محدوده‌ی فرکانسی ۱/۷-۳/۴ MHz و عمق ۱۰/۰ cm درست قبل از انجام کاتتریزاسیون بطن راست انجام شده است. عمل کرد سیستولیک بطن چپ در زمان‌های کسر تخلیه با استفاده از روش سیمپسون دو وجهی مورد ارزیابی قرار گرفته و عمل کرد سیستولیک بطن راست، مطابق با دستورالعمل انجمن اکوکاردیوگرافی آمریکا برای ارزیابی اکوکاردیوگرافی بطن راست در بزرگسالان و با استفاده از پارامترهای TAPSE^۲ و TDTLASV^۳ مورد ارزیابی قرار گرفته است.

پارامتر TAPSE بیان‌گر حرکت رو به جلوی آنولوس دریچه‌ی تریکوسپید در زمان سیستول در واحد mm بوده و پارامتر TDTLASV بیان‌گر سرعت حرکت قسمت خارجی آنولوس دریچه‌ی سه‌لته با استفاده از داپلر بافتی در واحد cm/s می‌باشد.

مقادیر TAPSE کم‌تر از ۱۶ mm و TDTLASV کم‌تر از ۱۰ cm/s نشان دهنده‌ی وجود یک اختلال عمل‌کردی در بطن راست می‌باشد [۲].

در نهایت، مساحت دهلیز راست (cm²) در انتهای فاز سیستول در نمای چهار وجهی اندازه‌گیری شده است. مقادیر ارزیابی شده و مشخصات تمام بیماران در جدول (۱) ارائه شده است.

^۱ Gevidid7

^۲ Tricuspid Annular Plane Systolic Excursion (TAPSE)

^۳ TissueDopplerDerivedTricuspidLateralAnnularSystolic Velocity



شده، داده‌های عددی مرتب و نرمال‌سازی شده است (تمام داده‌ها به مقدار ماکزیمم داده‌ها تقسیم شده‌اند). همان‌طور که در بخش جمع‌آوری داده‌ها ذکر شد، تعداد کل بیماران انتخاب شده برابر با ۵۹۱ نفر بوده که به طور معمول از ۷۵٪ بیماران برای آموزش شبکه‌ی عصبی و از ۲۵٪ بیماران برای تست شبکه‌ی عصبی استفاده شده است. البته درصد بیماران آموزش و تست بنا بر شرایط مختلف، مانند زمانی که به دست آوردن بهترین خطا مد نظر باشد، می‌تواند تغییر کند. منظور از خطا، میانگین مربعات خطا^۱ یا اختلاف بین داده‌های واقعی و پیش‌بینی شده می‌باشد. شبکه با چهار لایه، تعداد نورون‌های مختلف در هر لایه، نرخ‌های آموزش متفاوت، epoch-ها (تعداد دوره‌های آموزش شبکه‌ی عصبی) و وزن‌های مختلف مورد آزمون قرار گرفته است. ساختارهای شبکه‌ی عصبی نقش بسیار مهمی در بهبود خروجی دارند، تا حدی که می‌تواند خطای خروجی شبکه را به میزان قابل توجهی کاهش یا افزایش دهد. نرخ یادگیری مناسب و تعداد دفعات یادگیری بیش‌تر می‌تواند در یادگیری بهتر شبکه و در نتیجه کاهش خطا در خروجی بسیار موثر باشد. همچنین ممکن است افزایش بیش از حد تعداد دفعات آموزش شبکه‌ی عصبی، باعث بروز پدیده‌ی سرریز و افزایش میزان خطا گردد. در تمامی مدل‌های ارائه شده، تعداد لایه‌ها، نورون‌های هر لایه، وزن‌ها و تعداد دفعات آموزش شبکه‌ی عصبی برای رسیدن به بهترین مدل با کم‌ترین خطای داده‌های آموزش و تست، با استفاده از روش سعی و خطا به دست آمده است.

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

در گام بعد جهت بررسی رابطه‌ی برخی از معادلات غیرخطی با مقاومت عروق ریوی، سعی شد تا مقاومت عروق ریوی حاصل از کاتتریزاسیون با استفاده از پارامترهای به دست آمده از اکوکاردیوگرافی محاسبه گردد. بنابراین از پارامترهای اکوکاردیوگرافی نظیر قطر ورید اجوف تحتانی^۲، فشار شریان ریوی در فاز سیستولیک، کسر جهشی بطن چپ^۳ و اختلال عمل کرد شدید بطن راست به عنوان داده‌های ورودی و از مقاومت عروق پولمونی کاتتریزاسیون به عنوان خروجی استفاده شده است. برخی از مقادیر داده‌های بایگانی شده به صورت کیفی بوده که به داده‌های کمی و عددی (زبان شبکه) تبدیل شدند. از برخی مقادیر بازه‌ای نیز میانگین‌گیری شده تا به داده‌های عددی تبدیل شوند (جدول ۳).

در این رابطه، mPAP میانگین فشار شریان ریوی در واحد mmHg، PCWP فشار گوهی مویرگی ریوی در واحد mmHg و CO برون‌ده قلبی در واحد lit/min می‌باشد. پارامترهای به دست آمده از کاتتریزاسیون قلب (بطن) راست در جدول (۲) ارائه شده است.

جدول (۲) - پارامترهای حاصل از کاتتریزاسیون بطن راست

پس‌مویرگی (n=۳۱۳)	پیش‌مویرگی (n=۲۷۸)	
۱۰/۵±۴۰۷	۹/۲±۳/۹	فشار RA (mmHg)
۵۶/۸±۱۷	۸۴/۲±۳۳/۱	فشار RVS (mmHg)
۱۱/۳±۵	۹/۳±۴	RVEDP (mmHg)
۵۸±۱۶/۲	۸۸/۸±۳۶	SPAP (mmHg)
۲۹/۳±۷/۹	۴۸/۲±۱۸/۴	DPAP (mmHg)
۳۹/۹±۱۰/۲	۶۰/۷±۲۱/۲	میانگین PAP (mmHg)
۲۶/۶±۸/۱	۱۰/۸±۳/۶	PCWP (mmHg)
۱۱/۳±۷	۵۰/۲±۲۱	TPG (mmHg)
۳/۳±۱/۹	۱۲/۲±۷/۴	PVR (wood)
۲/۹±۱/۷	۱۲/۳±۸/۳	Thermodilution PVR (wood)
۳/۹±۱/۱	۴/۶±۱/۳	FICK CO Thermodilution (Lit/min)
۲/۱±۰/۶	۲/۵±۰/۹	cl Thermodilution (Lit/min/m ²)
۳/۸±۱/۷	۴/۴±۱/۵	FICK CO (Lit/min)

در این جدول، cI شاخص قلبی، CO برون‌ده قلبی، DPAP فشار شریان ریوی در فاز دیاستول، PCWP فشار گوهی مویرگی ریوی، RA دهلیز راست، RV بطن راست، RVEDP فشار بطن راست در پایان دیاستول، RVSP فشار بطن راست در فاز سیستول، SPAP فشار شریانی ریوی در فاز سیستول و TPG گرادیان ترانسپولمونی می‌باشد.

۷- آموزش شبکه‌ی عصبی بر مبنای داده‌های واقعی PVR

برای پیاده‌سازی روش پیشنهادی و ارزیابی نتایج از نرم‌افزار متلب نسخه ۲۰۱۵ استفاده شده است. در ابتدا جهت بررسی توانایی شبکه در یادگیری دانش مربوط به داده‌های کاتتریزاسیون و ارتباط آن‌ها با مقاومت عروق ریوی (رابطه‌ی ۳)، پارامترهای ارتباطی mPAP-sPAP-dPAP-PCWP-CO به عنوان ورودی و مقاومت عروق پولمونی کاتتریزاسیون به عنوان خروجی در نظر گرفته

^۲ Left Ventricle Ejection Fraction

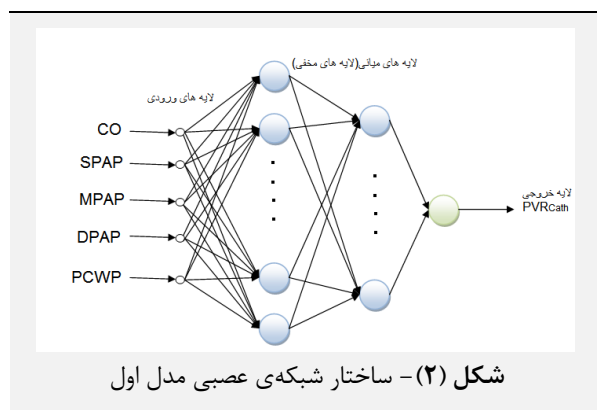
^۱ Mean Squared Error (Mse)

^۳ Inferior Vena Cava

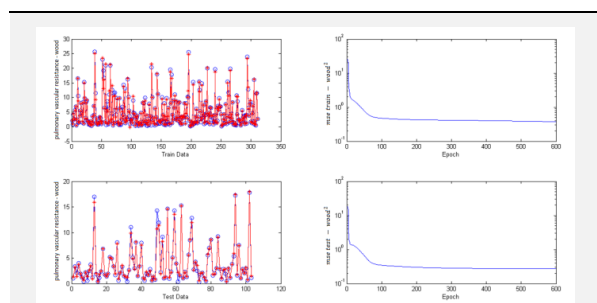
پارامترهای شبکه‌ی عصبی با استفاده از روش آزمون و خطا تعیین شده و بهینه‌ترین حالت ممکن انتخاب می‌شود. در تحقیقات آینده با دسترسی به داده‌های بیشتر و استخراج ویژگی‌های بیشتر می‌توان ساختار شبکه را با خطای کم‌تری آموزش داد.

۱۰- بررسی ساختار شبکه‌ی عصبی مدل اول

در مدل اول تنها ۴۲۵ داده از بیماران در دسترس بوده که از ۷۵٪ داده‌ها برای آموزش و از ۲۵٪ داده‌ها برای تست استفاده شده است. ساختار شماتیک این شبکه‌ی عصبی (۵-۲۰-۸-۱) با ۶۰۰ گام آموزش، محدوده‌ی وزنی ۰/۵- تا ۰/۵ و نرخ آموزش^۱ ۰/۰۱ در شکل (۲) ارائه شده است.



در این مدل، لایه‌ی اول دارای ۵ ورودی، لایه‌های میانی به ترتیب دارای ۲۰ و ۸ نورون و لایه‌ی خروجی دارای ۱ نورون می‌باشد. منحنی آموزش، تست رگرسیون مربوط به مدل اول در شکل‌های (۳) و (۴) ارائه شده است. مشاهده می‌شود که میزان خطا در حدود ۰/۱۹ بوده که نسبتاً قابل قبول می‌باشد.



شکل (۳) - نمودار آموزش و تست برای مدل اول، سمت چپ: محور عمودی بیان گر مقاومت عروق پولمونری در واحد (wood) و محور افقی بیان گر تعداد داده‌های مورد ارزیابی، سمت راست: محور عمودی بیان گر میانگین مربعات خطای آزمون (wood²) و تست و محور افقی بیان گر تعداد دفعات آموزش

جدول (۳) - تبدیل پارامترهای کیفی به کمی (عددی)

پارامتر کیفی	مقدار کمی معادل
Normal	۱
Mildly Enlarged	۲
Severely Enlarged	۶
Mild to Moderately Enlarged	۳
Moderately Enlarged	۴
Moderate to Severely Enlarged	۵
TopNormal	۱
Normal	۱
Mildly Reduced	۲
Moderate to Severely Reduced	۵
Moderately Reduced	۴
Mild to Moderately Reduced	۳
۲۵-۳۰	۲۷/۵
۲۰-۲۵	۲۲/۵
۱۵-۲۰	۱۷/۵
Normal	۱
Enlarged	۲
TopNormal	۱
No	۰
Mild	۱
Moderate	۲
Severe	۳
Severely Reduced	۶

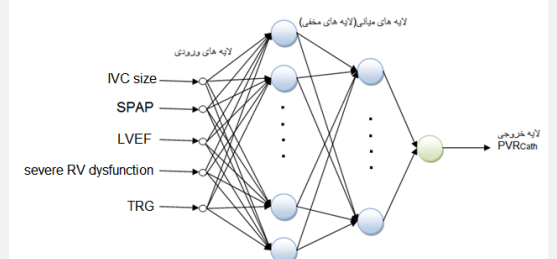
۹- داده‌های مربوط به اکوکاردیوگرافی

پس از کامل شدن اطلاعات بیماران، فرایند نرمال‌سازی داده‌ها انجام شده است. شبکه‌ی عصبی با چهار لایه، تعداد نورون‌های مختلف در هر لایه، نرخ آموزش و تعداد گام آموزش متفاوت مورد آموزش و آزمون قرار گرفته است. ویژگی‌های شبکه‌ی عصبی نقش بسیار مهمی در بهبود خروجی نهایی دارند، به طوری که با افزایش این ویژگی‌ها خطای خروجی شبکه‌ی عصبی می‌تواند کاهش قابل توجهی داشته باشد. این تست در سه مدل و ساختار مختلف شبکه‌ی عصبی مورد آزمون قرار داده شده است (بخش‌های ۱۰، ۱۱ و ۱۲) به طوری که ویژگی‌های شبکه‌ی عصبی از جمله تعداد نورون‌های هر لایه، نرخ‌های آموزش، تعداد گام آموزش و اتصال‌های بین لایه‌ها، در هر تست متغیر است. انجام این تست تا حدودی توانسته است به تخمین مقدار مقاومت عروق ریوی کمک کند، اما هنوز مقداری خطا در این تحقیق وجود دارد که این خطا وابستگی زیادی به تعداد داده‌های انتخاب شده و ساختار شبکه‌ی عصبی دارد. مقادیر بهینه‌ی

^۱ Learning Rate

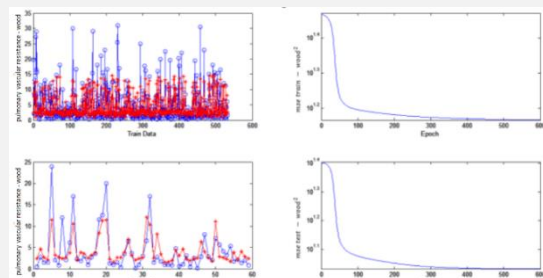


تقسیم‌بندی داده‌ها برای آموزش و تست قابل تغییر است، از این رو در این مدل از ۹۰٪ داده‌ها برای آموزش و از ۱۰٪ داده‌ها برای تست استفاده شده است. ساختار شماتیک این شبکه‌ی عصبی (۵-۱۷-۱۱-۱)، با ۶۰۰ گام آموزش، محدودی وزنی ۰/۵ تا ۰/۵ و نرخ آموزش ۰/۰۰۱ در شکل (۵) ارائه شده است.




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

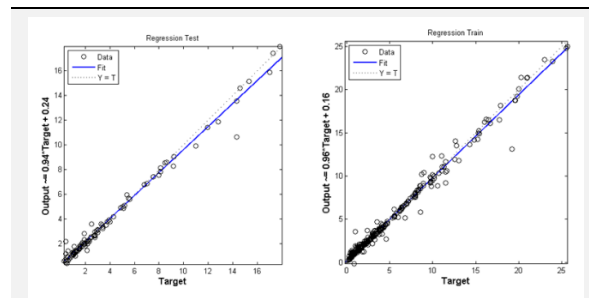
در این مدل، لایه‌ی اول با ۵ ورودی، لایه‌های میانی به ترتیب با ۱۷ و ۱۱ نورون و لایه‌ی خروجی با ۱ نورون مدل‌سازی شده است. منحنی آموزش، تست و هم‌چنین رگرسیون مربوط به مدل دوم در شکل‌های (۶) و (۷) ارائه شده است که خطایی در حدود ۱۰/۷۶ را نشان می‌دهد.



شکل (۶) - نمودار آموزش و تست برای مدل دوم (روش مبتنی بر آموزش الگو به الگو)، سمت چپ: محور عمودی بیان‌گر مقاومت عروق پولمونری در واحد (wood) و محور افقی بیان‌گر تعداد داده‌های مورد ارزیابی، سمت راست: محور عمودی بیان‌گر میانگین مربعات خطای آزمون (wood²) و تست و محور افقی بیان‌گر تعداد دفعات آموزش



شکل (۷) - رگرسیون آموزش و تست برای مدل دوم بر اساس آموزش الگو به الگو



شکل (۴) - رگرسیون آموزش و تست برای مدل اول

به طور کلی رگرسیون بین خروجی شبکه‌ی عصبی و داده‌های واقعی می‌باشد. معادله‌ی خط رگرسیون داده‌های آموزش و تست شبکه‌ی عصبی به ترتیب به صورت روابط (۴) و (۵) می‌باشد.

$$PVR_{echonn} = 0.96 \times PVR_{echoR} + 0.16 \quad (۴)$$

$$PVR_{echonn} = 0.94 \times PVR_{echoR} + 0.24 \quad (۵)$$

در روابط فوق، PVR_{echonn} مقاومت عروق ریوی اکو با استفاده از شبکه‌های عصبی و PVR_{echoR} مقاومت عروق ریوی اکو بر اساس داده‌های واقعی می‌باشد. خطاهای مربوط به مدل اول در جدول (۴) ارائه شده است.

جدول (۴) - نتایج حاصل از میانگین و انحراف معیار خروجی

(مقاومت عروق ریوی) شبکه‌ی عصبی مدل اول

ساختار شبکه	خطای آموزش	خطای تست
۵-۲۰-۸-۱	۰/۳۷۵۶±۰/۰۱۴۷	۰/۲۷۳۲±۰/۰۵۴۷

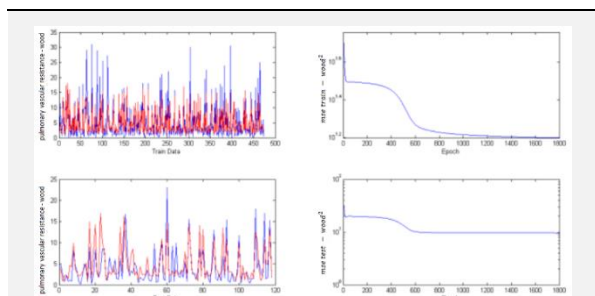
۱-۱۰- بررسی نتایج حاصل از آموزش شبکه‌ی عصبی مبتنی بر داده‌های PVR_{cath} (مدل اول)

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 شده است. با انجام این تست مشاهده می‌شود که پارامترهای ورودی همبستگی قابل قبولی با مقدار PVR_{cath} داشته و شبکه‌ی عصبی قادر به یادگیری رابطه‌ی موجود میان ورودی و خروجی با خطایی در حدود ۰/۳۱ است.

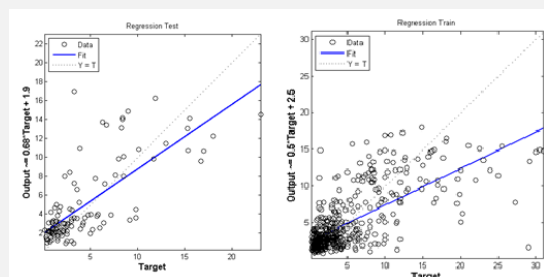
۱۱- مدل دوم با ورودی‌های اکو و خروجی PVR_{cath} (آموزش الگو به الگو)

در روش الگو به الگو، تمام الگوها به صورت جداگانه به شبکه‌ی عصبی آموزش داده می‌شوند. همان‌طور که پیش‌تر گفته شد،

و (۱۰) ارائه شده است. مشاهده می‌شود که میزان خطا در حدود ۹/۵۸ بوده که در مقایسه با مدل اول خطای نسبتاً زیادی است. بنابراین در این آزمون، خطا در میانگین مربعات خطای داده‌های آموزش بیش‌تر از میانگین مربعات خطای داده‌های تست بوده و این می‌تواند به دلیل تغییر در تعداد گام آموزش و یا تغییر در حدود وزن‌ها باشد.



شکل (۹) - نمودار آموزش و تست برای مدل دوم بر اساس آموزش الگوی دسته‌ای، سمت چپ: محور عمودی بیان‌گر مقاومت عروق پولمونی در واحد (wood) و محور افقی بیان‌گر تعداد داده‌های مورد ارزیابی، سمت راست: محور عمودی بیان‌گر میانگین مربعات خطای آزمون (wood²) و تست و محور افقی بیان‌گر تعداد دفعات آموزش



شکل (۱۰) - رگرسیون آموزش و تست برای مدل دوم بر اساس آموزش الگوی دسته‌ای

رگرسیون بین خروجی شبکه‌ی عصبی و داده‌های واقعی می‌باشد. معادله‌ی خط رگرسیون آموزش و تست شبکه‌ی عصبی به ترتیب به صورت روابط (۸) و (۹) می‌باشد.

$$PVR_{cathnm} = 0.5 \times PVR_{cathR} + 2.5 \quad (8)$$

$$PVR_{cathnm} = 0.68 \times PVR_{cathR} + 1.9 \quad (9)$$

هم‌چنین رگرسیون کاهش چشم‌گیری را در خطای تست نسبت به آزمون روش الگو به الگو نشان می‌دهد. میزان خطاهای خروجی مدل دوم جهت آموزش و تست در جدول (۶) ارائه شده است.

رگرسیون بین خروجی شبکه‌ی عصبی و داده‌های واقعی می‌باشد. معادله‌ی خط رگرسیون آموزش و تست شبکه‌ی عصبی به ترتیب به صورت روابط (۶) و (۷) می‌باشد.

$$PVR_{cathnm} = 0.48 \times PVR_{cathR} + 2.1 \quad (6)$$

$$PVR_{cathnm} = 0.46 \times PVR_{cathR} + 2.2 \quad (7)$$

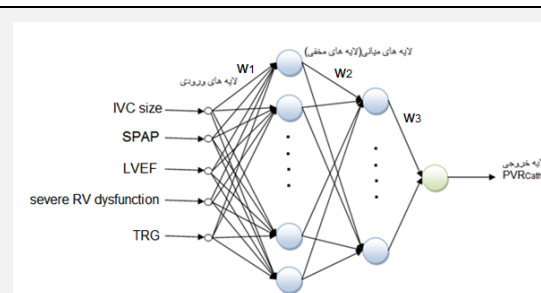
میزان خطاهای خروجی تست اول در آموزش و تست در جدول (۵) ارائه شده است.

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

ساختار شبکه	خطای آموزش	خطای تست
۱-۱۱-۱۷-۵	۶۷۳۶/۱۴ ± ۱۲۷/۰	۷۶۶۹/۱۰ ± ۱۱۹/۰

۱۲- مدل دوم شبکه‌ی عصبی در تست نهایی (روش مبتنی بر آموزش الگوی دسته‌ای)

در روش آموزش دسته‌ای^۱، تمام الگوها به صورت هم‌زمان به شبکه‌ی عصبی آموزش داده می‌شود. در این مدل از ۸۰٪ داده‌ها برای آموزش و از ۲۰٪ داده‌ها برای تست استفاده شده است. ساختار شماتیک شبکه‌ی عصبی (۵-۲۰-۱۲-۱)، با ۱۸۰۰ گام آموزش، محدوده‌ی وزنی ۰/۴- تا ۰/۴ و نرخ آموزش ۰/۰۰۱ در شکل (۸) نشان داده شده است.



شکل (۸) - ساختار شبکه‌ی عصبی در مدل دوم بر اساس آموزش الگوی دسته‌ای

در این مدل، لایه‌ی اول با ۵ ورودی، لایه‌های میانی به ترتیب با ۲۰ و ۱۲ نورون و لایه‌ی خروجی با ۱ نورون مدل‌سازی شده است. منحنی آموزش، تست و هم‌چنین رگرسیون مربوط به مدل دوم (مبتنی بر آموزش الگوی دسته‌ای) در شکل‌های (۹)

^۱ Batch Learning



مصنوعی، پیش‌بینی و محاسبه شده است. شبکه‌های عصبی به عنوان یکی از بهترین مدل‌های پیچیده‌ی یادگیری دانش از داده، دارای ویژگی‌های مهمی هستند که از آن جمله می‌توان به موارد زیر اشاره کرد:

۱- وابستگی زیاد دقت نتایج به اندازه‌ی مجموعه‌ی آموزش (تعداد نمونه‌های آموزش)

۲- آموزش شبکه ممکن است مشکل و یا حتی غیرممکن باشد به طور کلی می‌توان نتیجه گرفت که 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 کند، بسیار منعطف بوده و هم‌چنین نگاه‌داری آن‌ها بسیار آسان است. نکته‌ی دیگر این است که محاسبات شبکه‌ی عصبی معمولاً تعداد زیادی داده برای آموزش نیاز داشته و به دلیل پیشرفت‌های تکنیکی از قدرت پردازش بالایی برخوردار هستند. شبکه‌های عصبی با توجه به توانایی‌های منحصر به فرد خود به کمک علم پزشکی آمده و در مواردی که این علم هنوز نتوانسته نارسایی‌های خود را به تنهایی برطرف کند، کمک شایانی در زمینه‌ی رفع ناتوانایی‌های علم پزشکی ارائه داده است. کاهش هزینه‌ها و بالا بردن اطمینان و دقت کار پزشکان در تصمیم‌گیری‌های حیاتی در مورد بیماران از مزایای هوش مصنوعی می‌باشد. به طور کلی می‌توان نتیجه گرفت که اگر از داده‌های کامل و به تعداد زیاد جهت آموزش شبکه‌ی عصبی استفاده شود، این امکان فراهم می‌شود که بتوان رویدادهای بسیار مهم از جمله بیماری‌ها و پارامترهای آن‌ها را با خطای بسیار کم و قابل قبولی پیش‌بینی و درمان کرد. برای ادامه‌ی این تحقیق، پیشنهاد می‌شود که با توجه به اهمیت و جایگاه این موضوع در حوزه‌ی پزشکی، عدم توانایی بسیاری از بیماران برای انجام آزمایش‌های مرتبط با روش‌های تهاجمی و احساس نیاز به روش‌های جدید پزشکی جهت به دست آوردن مقاومت عروق ریوی، با جمع‌آوری داده‌های بسیار زیاد از بیماران قلبی عروقی، در جهت بهبود آموزش شبکه‌ی عصبی روی ساختارهای مناسب دیگر از جمله شبکه‌ی عصبی چندجمله‌ای (GMDH^۲) و بازه‌ی^۴ تمرکز شود.

۱۵- مراجع

[۱] تشنه‌لب، محمد، شبکه‌های عصبی و کنترل‌کننده‌های عصبی پیشرفته با رویکرد شبکه‌های راف، چاپ اول، تهران: انتشارات دانشگاه خواجه نصیرطوسی، ۱۳۹۴.

جدول (۶) - نتایج حاصل از میانگین و انحراف معیار خروجی

(مقاومت عروق ریوی) مدل دوم (آموزش الگوی دسته‌ای)

ساختار شبکه	خطای آموزش	خطای تست
۱-۱۲-۲۰-۵	۸۲۴۳/۱۵±۲۱۴/۰	۵۸۷۹/۹±۱۰۸/۰

۱۳- ارزیابی کلی

در مدل اول که ورودی‌ها و خروجی PVR هر کدام از کاتریزاسیون بطن راست استخراج شده و از معادله‌ی (۲) پیروی می‌کردند، نتایج به دست آمده قابل قبول بوده، هم‌چنین با افزودن پارامتر فشار شریانی ریوی در فازهای سیستول و دیاستول، رگرسیون‌ها همبستگی قابل قبولی را نشان داده و به دلیل مناسب بودن داده‌ها، کافی بودن تعداد افراد مورد مطالعه و کمی (عددی) بودن داده‌ها، میزان خطا بسیار کم و قابل قبول بوده است. در تست دوم به دلیل کم بودن تعداد داده‌های مناسب، استفاده از تعدادی پارامتر قلبی عروقی ریوی برای نخستین بار که هیچ رابطه‌ی ریاضی میان آن‌ها و مقاومت عروق ریوی وجود نداشت و هم‌چنین کیفی بودن برخی از پارامترها مانند اختلال شدید بطن راست^۱ که بر اساس شدت، یک مقدار عددی (از ۰ تا ۶) به هر یک از آن‌ها اختصاص داده شد، مقدار خطاها بیش‌تر از حد قابل قبول بوده است. البته استفاده از الگوریتم آموزشی لونبرگ-مارکوارت^۲، که یک روش مبتنی بر آموزش الگوی دسته‌ای است، باعث کم‌تر شدن خطا و حصول یک خروجی نزدیک‌تر به خروجی هدف شده است. به طور معمول از ۷۵٪ داده‌ها برای آموزش و از ۲۵٪ داده‌ها برای تست شبکه استفاده می‌شود. بنابراین یک آزمایش به طور اتفاقی انجام شد (آزمون مبتنی بر آموزش الگو به الگو). در این مدل به دلیل محدود بودن داده‌ها و ضرورت آموزش شبکه‌ی عصبی با داده‌های بیش‌تر، از ۹۵٪ داده‌ها برای آموزش و فقط از ۵٪ داده‌ها جهت تست استفاده شده و مشاهده گردید که میزان خطا نسبت به حالت‌های مشابه به طور چشم‌گیری کاهش پیدا کرده است. از این رو می‌توان نتیجه گرفت که کاهش و یا افزایش میزان خطا تا حد زیادی به تعداد داده‌ها وابسته است. به طور کلی این پژوهش نتایج مطلوب و قابل قبولی ارائه داده (به شرط استخراج ویژگی‌های مناسب و دقیق) و می‌تواند کاربردهای زیادی در سیستم‌های تشخیص و درمان پزشکی داشته باشد.

۱۴- نتیجه‌گیری

در این مقاله، میزان مقاومت عروق ریوی و فشار داخلی بطن راست بر مبنای داده‌های اکوکاردیوگرافی و شبکه‌ی عصبی

^۲ Group Method of Data Handling (Gmdh)

^۴ Rough

^۱ Severe Rv Dysfunction

^۲ Levenberg-Marquardt Algorithm



- 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, 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.
- [۱۹] کاکوئی، امیررضا و مهدی جعفری شهباززاده، ۱۳۹۴، طبقه‌بندی اتوماتیک تومور مغزی در تصاویر MRI با استفاده از شبکه عصبی مصنوعی ANN، کنفرانس بین‌المللی پژوهش در مهندسی، علوم و تکنولوژی، استانبول، موسسه مدیران ایده پرداز پایتخت ویرا.
- [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.
- [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 Haghghi, A. Amin, Naghashzadeh, H. Bakhshandeh, S. Taghavi, & M. Maleki, Utility of right