

طراحی شبکه عصبی بهینه جهت تشخیص فیبریلاسیون دهلیزی

مریم سادات جلالی شهری^۱، دانشجوی دکترا / فرزانه خطیب^۲، استادیار / سید جواد سید مهدوی چابک^۳، دانشیار / علیرضا حیدری بکاولی^۴،

دانشیار / مهدی کهرم^۵، استادیار

۱- گروه برق دانشکده مهندسی - واحد مشهد-دانشگاه آزاد اسلامی - مشهد- ایران- sh.jalali@mshdiau.ac.ir

۲- گروه برق دانشکده مهندسی - واحد مشهد-دانشگاه آزاد اسلامی - مشهد- ایران- khatib@mshdiau.ac.ir

۳- گروه برق دانشکده مهندسی - واحد مشهد-دانشگاه آزاد اسلامی - مشهد- ایران- mahdavi@mshdiau.ac.ir

۴- گروه قلب و عروق دانشکده پزشکی- دانشگاه علوم پزشکی مشهد - مشهد- ایران- heydaria@mums.ac.ir

۵- گروه جراحی قلب و عروق دانشکده پزشکی- دانشگاه علوم پزشکی مشهد - مشهد- ایران- KahromMH@mums.ac.ir

چکیده: فیبریلاسیون دهلیزی یکی از عارضه‌های شایع قلبی در تمام جهان است که عدم تشخیص به موقع آن می‌تواند خطر سکتة مغزی و یا حتی مرگ را به دنبال داشته باشد. تاکنون روش‌های متفاوتی جهت تشخیص این آریتمی مورد تحقیق و بررسی قرار گرفته است، اما یکی از روش‌های بسیار پر کاربرد جهت شناسایی آن که در سال‌های اخیر بیش از پیش مورد توجه واقع شده، یادگیری عمیق است. از میان شبکه‌های عصبی عمیق مطرح در این حوزه، شبکه‌های عصبی (long short term memory) LSTM به دلیل خاصیت تحلیل زمان پیوسته جهت تحلیل داده‌های سری زمانی مانند ECG عملکرد بسیار خوبی از خود نشان داده‌اند. از این رو در این تحقیق از یک ساختار LSTM که دارای کمترین تعداد لایه در هر سطح می باشد، به منظور کاهش زمان یادگیری شبکه و در نتیجه افزایش سرعت در تشخیص عارضه مورد نظر بهره برده شده است. همچنین طراحی مورد نظر با دو شبکه عمیق پر کاربرد BILSTM و CNN نیز مورد بررسی و مقایسه قرار گرفت و مشخص گردید، ساختار LSTM مطرح نسبت به دو ساختار دیگر از دقت (۸۶٪) و سرعت بالاتری (۲ و ۱۹ برابر سریع تر) در تشخیص برخوردار است. علاوه بر این در این پژوهش با محاسبه ضریب همبستگی برای سه ویژگی سن، جنس و ضربان میزان اثرگذاری هر پارامتر در شناسایی فرد بیمار مورد بررسی قرار گرفت.

واژه‌های کلیدی: شبکه‌های عصبی عمیق، یادگیری عمیق، الکتروکاردیوگرام، فیبریلاسیون دهلیزی، حافظه‌ی کوتاه مدت طولانی

Design optimized neural network for diagnosis of atrial fibrillation

Maryam Sadat Jalali shahri¹, Ph.D. candidate/ Farzaneh khatib², Assistant Professor / Seyed Javad Seyed Mahdavi³, Associate Professor / Alireza Heidari Bakavoli⁴, Associate Professor / Mahdi Kahrom⁵, Assistant Professor

1-Department of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, sh.jalali@mshdiau.ac.ir

2- Department of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, khatib@mshdiau.ac.ir

3- Department of Electrical Engineering, Mashhad Branch, Islamic Azad University, Mashhad, Iran, mahdavi@mshdiau.ac.ir

4 -Department of Medicine, Mashhad University of Medical Sciences. Mashhad, Iran, heydaria@mums.ac.ir

5 -Department of Medicine, Mashhad University of Medical Sciences. Mashhad, Iran, KahromMH@mums.ac.ir

Abstract: Atrial fibrillation (AF) is one of the most common arrhythmias, a lack of timely diagnosis can result in stroke or even mortality. To date, various techniques have been used to recognize this type of arrhythmia. However, deep learning has been one of the most commonly used methods in this area, attracting researchers' attention in recent years. Meanwhile, long short-term memory (LSTM) has had an efficient performance among deep neural networks used in this area owing to its continuous analysis feature for analyzing time-series data such as ECG. Therefore, the present study applied and LSTM structure with the least number of layers at each level has been used to reduce network learning time, thereby, increasing the detection speed of diagnosing the desired problem. Also, the proposed design was discussed and compared with two highly applied deep learning of BILSTM and CNN, and the results were indicative of higher accuracy(86%) and detection speed(2 and 19 times faster) of LSTM compared to the other two structures. In addition, in this research by calculating the correlation coefficient for the 3 parameters of age, sex, and heart rate the effectiveness of each parameter in identifying the patient was examined.

Keywords: Deep Neural Networks, Deep Learning, Electrocardiogram, Atrial Fibrillation, Long short term memory

تاریخ ارسال مقاله: ۱۴۰۱/۰۳/۰۱

تاریخ اصلاح مقاله: ۱۴۰۱/۰۹/۱۳

تاریخ پذیرش مقاله: ۱۴۰۱/۱۲/۰۱

نام نویسنده مسئول: فرزانه خطیب

نشانی نویسنده مسئول: گروه برق دانشکده مهندسی - واحد مشهد-دانشگاه آزاد اسلامی - مشهد- ایران.

۱- مقدمه


فیبریلاسیون دهلیزی (AF) به عنوان یکی از شایع ترین آریتمی ها است که در حدود ۱٪ از جمعیت جهان به آن مبتلا می باشند [۱]. این عارضه یک تاکی آریتمی (ریتم قلبی سریع، بیش از ۱۰۰ بار در دقیقه) فوق بطنی است که با فعالیت دهلیزی نامنظم و غیر هماهنگ و متعاقب آن با نارسایی مکانیکی دهلیز تشخیص داده می شود [۲].

اگرچه تصور می شود که بروز فیبریلاسیون دهلیزی می تواند به صورت موقت باشد، اما شواهد زیادی هست که نشان می دهد عدم تشخیص به موقع این آریتمی می تواند خطر سکتة مغزی^۱، نارسایی تنفسی و حتی مرگ را افزایش دهد [۳].

در سال های اخیر تحقیقات فراوانی در زمینه تشخیص بهنگام این بیماری صورت گرفته است، که از جمله ی آن ها می توان به استفاده از شبکه عصبی^۲ [۴]، شبکه عصبی عمیق (یادگیری عمیق) [۵-۷] و سایر روش هایی که کمتر مورد استفاده قرار گرفته اند [۸-۱۲] اشاره نمود.

از میان روش های مطرح شده یادگیری عمیق (DL) به عنوان انقلابی در حوزه پزشکی شناخته می شود که توانایی یادگیری الگوهای پیچیده ای مانند AF^۴ را با استفاده از سیگنال ECG^۵ داراست [۱۳].

با توجه به اینکه یکی از پارامترهای مهم و مؤثر در تشخیص سلامتی هر فرد سیگنال قلبی (ECG) است که به صورت پیوسته رصد می گردد، پزشکان و کادر درمان اطلاعات مورد نیاز در زمینه غیرعادی بودن وضعیت قلب بیمار مانند ضربان قلب^۶ را از آن استخراج می نمایند (شکل ۱) [۱۴].



شکل ۱: سیگنال ECG [۱۵]

توجه به این نکته بسیار حائز اهمیت است که این سیگنال به دلیل دارا بودن نویز بالا کار تشخیص را سخت، کند و همچنین در برخی مواقع توأم با خطا می نماید. از این رو یکی از چالش های پیش رو برای محققان در تشخیص آریتمی های قلبی با استفاده از سیگنال ECG، حذف نویزهای موجود در این سیگنال و آماده سازی آن (عملیات پیش پردازش) جهت ورود به ساختار شبکه عصبی عمیق می باشد. یکی از روش هایی که به جهت حذف نویز در سال های اخیر بکار گرفته شده استفاده از تبدیل موجک می باشد، این روش بسیار پیچیده و طولانی است [۱۶]. یانگ و همکارانش در تحقیقی که در سال ۲۰۱۸ به انجام رساندند از این روش بهره بردند [۱۷]. همچنین در سال ۲۰۲۰ نریمانی و همکارانش نیز از این روش به جهت پیش پردازش سیگنال ECG استفاده نمودند [۱۸]. در سال ۲۰۲۲ نیز شرما و همکارش از این روش به همراه یک فیلتر پایین

گذر جهت حذف نویزهای موجود بر روی سیگنال ECG استفاده نمودند. [19]

چالش دیگری که همواره محققان در زمان به کارگیری یادگیری عمیق در تشخیص آریتمی های مختلف و بخصوص AF با آن مواجه هستند، طراحی یک شبکه با بالاترین سرعت عملکرد و بیشترین میزان دقت در تشخیص است. طراحان اغلب به منظور افزایش دقت خروجی از یک شبکه عصبی عمیق با تعداد لایه های زیاد استفاده می نمایند که این خود منجر به کاهش سرعت عملکرد شبکه در روند شناسایی بیماری می گردد. به عنوان مثال در تحقیقی که در سال ۲۰۱۷ توسط زانگ و همکارانش صورت پذیرفت از یک شبکه عمیق ۱۶ لایه جهت تشخیص استفاده شد [۲۰]، که ساختاری نسبتاً بزرگ از منظر تعداد لایه های مورد استفاده به شمار می آید.

از این رو در این تحقیق به جهت فائق آمدن بر چالش های مطرح شده از یک شبکه عصبی عمیق بازگشتی استفاده شده که قابلیت یادگیری توالی سری زمانی را دارد و برخلاف سایر شبکه های عصبی نیازمند مراحل پیش پردازش طولانی داده های ورودی نیست. همچنین این شبکه به دلیل ساختار ساده تر نسبت به سایر شبکه های عمیق مرسوم از سرعت بالاتری در تشخیص برخوردار است (مراحل آموزش و آزمون). در ادامه این مقاله ابتدا در بخش ۲ توضیحات مختصری در زمینه ی ساختار شبکه های عصبی عمیق پرکاربرد بیان خواهد شد. سپس در بخش ۳ به تشریح روش پیاده سازی و ساختار شبکه مورد نظر پرداخته می شود. سرانجام در بخش ۴ نتیجه گیری حاصل از این طراحی مورد بحث و بررسی قرار خواهد گرفت.

۲- شبکه های عصبی عمیق

شبکه عصبی عمیق یک ساختار توانمند جهت استخراج ویژگی از داده های اولیه ورودی دارد و در ناسازگاری هایی مانند انتقال، چرخش و نویز قدرتمند عمل می نماید [۲۱].

شبکه عصبی بازگشتی (RNN) نوعی از معماری شبکه عصبی عمیق است که به طور خاص برای در برگرفتن اطلاعات متوالی طراحی شده است. این گونه از شبکه ها معمولاً در طبقه بندی توالی استفاده می شوند. ساختار RNN برخلاف یک شبکه عصبی منظم قادر به یادگیری وابستگی های زمانی است، به همین دلیل به جهت کار با داده های سری زمانی مانند سیگنال ECG بسیار مناسب می باشد [۲۲]. دو شبکه عصبی پرکاربرد از زیرمجموعه شبکه های عصبی بازگشتی که در این تحقیق مورد بررسی و مقایسه قرار گرفته اند عبارتند از: LSTM^۸ و BILSTM^۹.

۲-۱-LSTM

ایده واحد LSTM در ابتدا توسط Hochreiter و Schmidhuber در سال ۱۹۹۷ مطرح گردید. از آن زمان تاکنون مقداری تغییرات جزئی در واحد اصلی LSTM صورت پذیرفته است. شکل ۲ ساختار یک واحد LSTM را نشان می دهد که در زیر به تشریح روابط و عملکرد حاکم بر

۲-۲-BILSTM


از نظر معماری BILSTM شامل لایه‌های LSTM پیشرو و پس‌رو است (شکل ۳). ورودی‌های لایه‌های پیشرو و پس‌رو به‌طور هم‌زمان توسط لایه خروجی پردازش می‌گردند. لایه خروجی در BILSTM از طریق دنباله نهان پیش رو $\vec{h}_t$ ، دنباله نهان پس رو $\overleftarrow{h}_t$ و دنباله خروجی y_t با تکرار لایه پس‌رو از لحظه ۱ تا $t=T$ و لایه پیش‌رو از $t=1$ تا محاسبه می‌گردد. به‌روزرسانی این شبکه عصبی را می‌توان به‌صورت زیر فرموله کرد:

$$\vec{h}_t = H(W_1 x_t + W_2 \vec{h}_{t-1} + \vec{b}) \quad (7)$$

$$\overleftarrow{h}_t = H(W_3 x_t + W_5 \overleftarrow{h}_{t-1} + \overleftarrow{b}) \quad (8)$$

$$y_t = (W_4 \vec{h}_t + W_6 \overleftarrow{h}_t + b_y) \quad (9)$$

$\vec{h}_t$ ، $\overleftarrow{h}_t$ و y_t به ترتیب بردارهای انتشار پیشرو، پس‌رو و لایه خروجی هستند. W ها ضرایب وزن‌ها می‌باشند. $\vec{b}$ ، $\overleftarrow{b}$ و b_y نیز به ترتیب بردارهای بایاس مربوطه هستند [۲۵].



شکل ۳: ساختار واحد BILSTM

علاوه بر دو شبکه بازگشتی مطرح‌شده یکی دیگر از شبکه‌های عصبی عمیق پرکاربرد که در این تحقیق مورد بحث و بررسی قرار خواهد گرفت شبکه CNN است.

۲-۳-CNN

شبکه‌های عصبی کانولوشن یک دسته از شبکه‌های عصبی می‌باشند که از یک دسته‌بندی بیولوژیکی الهام گرفته‌شده و توسط لیکن و همکارانش معرفی شدند. این شبکه‌ها در طیف وسیعی از مسائل یادگیری عمیق نتایج قابل توجهی نشان داده‌اند. شکل ۴ یک معماری معمول CNN را نشان می‌دهد.

آن پرداخته خواهد شد. ساختار هر واحد LSTM به گونه ایست که یک سلول حافظه C_t^j را در زمان t حفظ می‌نماید و خروجی یا فعال‌ساز آن h_t^j از رابطه زیر به دست می‌آید (j شماره واحد LSTM است):

$$h_t^j = o_t^j \tanh(c_t^j) \quad (1)$$

در رابطه (۱) o_t^j یک گیت خروجی است که میزان استفاده از محتوای حافظه را تعیین می‌نماید. مقدار گیت خروجی از طریق معادله ۲ محاسبه می‌گردد:

$$o_t^j = \sigma(W_o x_t + W_o h_{(t-1)} + b_o C_t^j) \quad (2)$$

در رابطه (۲) σ یک تابع سیگموئید منطقی و b_o یک ماتریس قطری است. در LSTM سلول حافظه C_t^j با فراموش نمودن بخشی از حافظه موجود و افزودن یک حافظه جدید با محتوای $\tilde{C}_t^{(j)}$ به‌روز می‌گردد.

$$C_t^j = f_t^j c_{(t-1)}^j + i_t^j \tilde{C}_t^{(j)} \quad (3)$$

محتوای حافظه $\tilde{C}_t^{(j)}$ برابر است با:


$$\tilde{C}_t^{(j)} = \tanh(W x_t + W h_{(t-1)})^j \quad (4)$$

میزان فراموشی حافظه موجود، توسط یک گیت فراموشی f_t^j تنظیم‌شده و میزان افزودن محتوای حافظه جدید به سلول حافظه توسط یک گیت ورودی i_t^j تعیین می‌گردد. گیت‌ها مورد نظر با روابط زیر محاسبه می‌شوند:

$$f_t^j = \sigma(W_f x_t + W_f h_{(t-1)} + b_f) \quad (5)$$

$$i_t^j = \sigma(W_i x_t + W_i h_{(t-1)} + b_i) \quad (6)$$

b_f و b_i نیز در اینجا ماتریس‌های قطری هستند [۲۳].




شکل ۲: ساختار واحد LSTM [۲۴]

قلبی (ECG)، سن و جنسیت بیمار نیز در این پایگاه داده لحاظ شده است.

۳-۲- محاسبه ضربان:

به طور معمول برای محاسبه میانگین ضربان قلب در یک بازه زمانی از فواصل R-R سیگنال ECG استفاده می‌گردد (شکل ۵).




شکل ۵: فاصله R-R سیگنال

بدین منظور در این تحقیق ابتدا سیگنال ECG ضبط شده برای هر فرد، خوانده شده و سپس محل نقاط پیک سیگنال با توجه به بلندترین قله به دست می‌آید (شکل ۶). بدین مفهوم که ابتدا بلندترین نقطه پیک سیگنال شناسایی شده، سپس سایر نقاطی که ارتفاع دامنه آن‌ها از نصف دامنه نقطه مورد نظر بلندتر باشد به عنوان نقاط پیک سیگنال شناسایی خواهند شد. این نحوه شناسایی بدین سبب صورت می‌پذیرد که سیگنال ECG دریافت شده از بدن بیمار همواره به دلایلی همچون حرکت بیمار در حین ضبط سیگنال یا تداخل امواج و... با نویز همراه بوده و این نویزها می‌تواند موجب بروز خطا در سیگنال دریافتی و عدم شناسایی درست نقاط پیک گردد.

در ادامه و پس از یافتن نقاط پیک سیگنال، جهت محاسبه میانگین ضربان قلب در بازه زمانی ۱۰ ثانیه از رابطه زیر استفاده می‌گردد:

$$Heart\ Beat = 60 * 100 / \text{mean}(R - R) \text{ ms per beat} \quad (13)$$

ضربان قلب محاسبه شده در این مرحله، به داده‌های جدول مشخصات مربوط به افراد سالم و بیمار (افراد بدون عارضه و افراد با عارضه AF) جهت ورود به شبکه عصبی اضافه می‌گردد.



شکل ۶- نقاط پیک شناسایی شده سیگنال ECG ورودی

۳-۳- طراحی شبکه عصبی:

شبکه عصبی کانولوشن دارای یک معماری سلسله مراتبی است که از سیگنال ورودی x آغاز شده و x_j هر لایه بعدی به صورت زیر محاسبه می‌گردد.

$$x_j = \rho w_j x_{j-1} \quad (10)$$


w_j در رابطه ۱۰ یک عملگر خطی است و ρ یک عملگر غیرخطی است. به طور معمول در یک CNN، w_j یک کانولوشن ρ یک یکسوساز حد اکثری $(x, 0)$ یا یک زیگموئید $1/(1 + \exp(-x))$ است. بهتر است w_j را به عنوان مجموعه‌ای از فیلترهای کانولوشن در نظر بگیریم؛ بنابراین لایه‌ها طرحی از فیلتر هستند و هر لایه می‌تواند به صورت مجموعی از کانولوشن‌های لایه‌های قبلی نوشته شود.

$$x_j(u, k_j) = \rho \left(\sum_k (x_{j-1}(0, k) * w_{j,k_j}(0, k))(u) \right) \quad (11)$$

در رابطه ۱۱ * عملگر کانولوشن گسسته است.

$$(f * g)(x) = \left(\sum_{u=-\infty}^{\infty} f(u)g(x-u) \right) \quad (12)$$

به طور معمول با کاهش گرادین تصادفی، وزن‌های w_j با استفاده از الگوریتم پس انتشار برای محاسبه گرادین آموزش داده می‌شوند [۲۴].



شکل ۴: ساختار معمول شبکه عصبی CNN [۲۴]

۳-۳-۱- پایگاه داده:

در این بخش ابتدا پایگاه داده مورد استفاده معرفی و سپس روش محاسبه ضربان قلب شرح داده خواهد شد. در ادامه نیز طراحی شبکه عصبی مورد نظر به تفصیل بیان می‌گردد.

۳-۳-۱- پایگاه داده

پایگاه داده استفاده شده در این تحقیق PTB-XL از مجموعه بانک اطلاعاتی سایت فیزیوت می‌باشد. این پایگاه داده مجموعه بزرگی شامل ۲۱۸۳۷ ECG ضبط شده است؛ که از مجموع ۱۸۸۸۵ بیمار با طول نمونه برداری ۱۰ ثانیه و با دو فرکانس نمونه برداری ۱۰۰ و ۵۰۰ هرتز جمع‌آوری شده است. افرادی که نمونه برداری از آن‌ها صورت پذیرفته، ۵۲٪ مرد و ۴۸٪ زن و سن آن‌ها بین ۲۰ تا ۹۵ سال است. علاوه بر سیگنال

تعداد ۳ لایه کانولوشن با طول کرنل ۱۰، maxpooling ۲ و تعداد ۵۰ فیلتر که به جهت مقایسه منصفانه میان این شبکه با دو شبکه دیگر که شامل ۵۰ لایه نهان می باشند استفاده گردیده است. این ساختار CNN نسبت به سایر ساختارهای CNN مطرح در گذشته بسیار کم حجم تر و کوچک تر می باشد.

۴- یافته ها و بحث:

تمامی مراحل پردازش و آماده سازی داده ها در این تحقیق با استفاده از نرم افزار متلب صورت پذیرفته است. درصد دقت حاصل از تشخیص آریتمی مورد نظر (AF) توسط شبکه های مطرح در این مقاله را می توان در جدول ۱ مشاهده نمود.

جدول (۱): مشخصه های ارزیابی شبکه های عصبی طراحی شده

نوع شبکه	دقت (درصد)	حساسیت (درصد)	ویژگی (درصد)
LSTM	86%	76%	88%
BiLSTM	86%	76%	88%
CNN	80%	70%	80%

همان طور که در جدول ۱ مشاهده می گردد شبکه عصبی LSTM نسبت به شبکه عصبی CNN از درصد دقت بالاتری در تشخیص عارضه مورد نظر برخوردار است. همچنین با توجه به عامل مهم زمان در تشخیص به موقع این آریتمی شبکه LSTM به دلیل ساختار ساده تر در یک سیستم یکسان جهت شبیه سازی، نسبت به دو شبکه CNN و BiLSTM به ترتیب ۲ برابر و ۱۹ برابر سریع تر در آموزش و آزمون و در نتیجه در تشخیص عمل می نماید.

علاوه بر میزان دقت، ضریب همبستگی برای سه ویژگی سن، جنس و ضربان در ساختار LSTM به جهت تعیین میزان تأثیر آن ها در تشخیص درست فرد بیمار از سالم مورد محاسبه قرار گرفت؛ و نتایج زیر به ترتیب برای سه ویژگی سن، جنس و ضربان حاصل گردید: ۰،۰۸۷، ۰،۰۷۸ و ۰،۰۱۳۸.


با توجه به این نکته که داشتن ضریب همبستگی بزرگ تر (نزدیک به ۱) نشان دهنده ی اثرگذاری بیش تر آن پارامتر در تصمیم گیری و در نتیجه تشخیص می باشد، می توان دریافت ضربان قلب نسبت به دو ویژگی دیگر تأثیر بیش تری در شناسایی فرد بیمار از سالم دارد.

در ادامه اگر مقایسه ای میان روش و نتایج حاصل از طراحی صورت گرفته در این مقاله با سایر مقالاتی که از این پایگاه داده استفاده نموده اند صورت پذیرد در خواهیم یافت: ساختار طراحی شده در این مقاله نسبت به [6] علاوه بر دقت بالاتر در تشخیص (۸۶ درصد در این مقاله و ۸۱ درصد در [6])، به جهت استفاده از سایر متغیر ها از قابلیت اطمینان بالاتری برخوردار است. همچنین از مراحل پیش پردازش پیچیده و طولانی سیگنال ورودی موجود در [6]، در این مقاله اثری نیست.

در [۱۹] بر خلاف این مقاله، در طراحی شبکه های مورد نظر تمرکز فقط بر روی افزایش دقت بوده و در نتیجه ابعاد شبکه ها در هر مرحله بزرگتر و پیچیده تر گردیده است. علاوه بر این جهت تشخیص نیز تنها از

در این مقاله از میان روش های یادگیری عمیق مطرح، از شبکه LSTM که دارای ساختاری هوشمند جهت تحلیل داده های زمان پیوسته می باشد، استفاده گردیده است. طراحی ساختار شبکه مورد نظر به گونه ای است که بتوان با کمترین تعداد لایه در هر سطح، بدون طی نمودن مراحل پیش پردازش طولانی مطرح در مقالات گذشته با سرعت و دقت نسبتاً بالا فرد بیمار را شناسایی نمود.

ساختار مورد طراحی به همراه تعداد لایه های مورد استفاده در هر سطح در شکل ۷ نمایش داده شده است.



شکل ۷: ساختار شبکه عصبی مورد طراحی

تعداد داده های مورد استفاده از بانک اطلاعاتی جهت ورود به شبکه عصبی مجموعاً تعداد ۳۲۵۱ ضبط می باشد. ورودی مورد نظر برای شبکه شامل ۱۰۰۳ مقدار (ویژگی) برای هر فرد بوده که عبارت است از: سن، جنس، ضربان قلب و سیگنال قلبی ضبط شده در بازه زمانی ۱۰ ثانیه با فرکانس ۱۰۰ هرتز.

از مجموعه داده های ورودی در این تحقیق، ۹۰٪ به منظور آموزش شبکه و ۱۰٪ به جهت آزمون در نظر گرفته شده اند. نرخ یادگیری نیز ۰،۰۰۰۱ لحاظ شده است.

به جهت مقایسه عملکرد حاصل از ساختار مطرح شده در اینجا نسبت به سایر ساختارهای عمیق پرکاربرد، طراحی نسبتاً مشابهی با دو شبکه عمیق CNN و BiLSTM نیز به انجام رسیده است. در طراحی این دو ساختار همانند طراحی شبکه LSTM، از کمترین تعداد لایه در هر سطح استفاده شده است. همچنین تعداد ورودی ها و نرخ یادگیری برای تمامی ساختارهای مطرح شده یکسان در نظر گرفته شده است.

قابل ذکر است تعداد لایه های استفاده شده در شبکه عصبی BiLSTM با تعداد لایه های مورد استفاده در ساختار شبکه LSTM برابر بوده (۵۰ لایه) اما حجم این شبکه به دلیل ساختار پیشرو و پسرو ۲ برابر شبکه LSTM می باشد. همچنین به جهت پیاده سازی ساختار CNN نیز از

- یک متغیر (سیگنال قلبی) استفاده گردیده که این خود موجب کاهش قابلیت اطمینان در نتیجه نهایی بدست آمده می گردد.
- ### ۵- نتیجه گیری
- در این تحقیق طراحی و پیاده سازی ۳ شبکه عصبی عمیق LSTM، BILSTM و CNN که در تشخیص عارضه AF بکار می روند، مورد بحث و مقایسه قرار گرفت. در این مقاله برخلاف سایر ساختارهای مطرح در گذشته، از مراحل پیش پردازش طولانی، پیچیده و گاه طاقت فرسای داده ورودی اثری نیست. همچنین ساختار بهینه شبکه CNN طراحی شده در اینجا نسبت به سایر ساختارهای CNN مطرح در گذشته از سرعت بالاتری در تشخیص آریتمی مورد نظر برخوردار است. علاوه بر این، میزان اثرگذاری ۳ عامل مهم سن، جنس و ضربان در تشخیص AF در اینجا مورد بررسی قرار گرفت. نکته ی بسیار مهمی که در تحقیقات گذشته همواره مغفول مانده و در این تحقیق به آن پرداخته شده، توجه به طراحی یک شبکه عصبی عمیق بهینه با سرعت عملکرد بالایی باشد. در گذشته تنها شبیه سازی نرم افزاری را مدنظر قرار داده، طراحی چنین شبکه ی بهینه ای با رویکرد بکارگیری در پیاده سازی سخت افزاری امکان طراحی یک سیستم واقعی شناسایی بیماری را میسر می سازد. از این رو می توان در آینده با استفاده از شبکه بهینه طراحی شده یک ساختار سخت افزاری با توان و منابع مصرفی بسیار پایین (به علت کم بودن لایه های شبکه و عدم وجود مراحل پیش پردازش طولانی) و سرعت عملکرد بسیار بالا در تشخیص طراحی نمود.
- ### مراجع
- [۱] سپهری نیا و پویان ((سنجش استعداد ابتلا به فیبریلاسیون دهلیزی با استفاده از تحلیل های غیرخطی سیگنال الکتروکاردیوگرام))، نشریه مهندسی برق و الکترونیک ایران، شماره ۲، صفحه: ۱۱۹-۱۲۸، ۲۰۱۵.
 - [۲] آبادی ((فرآیند درمانی فیبریلاسیون دهلیزی در بیمارستان های ایران))، مجله علوم پزشکی رازی، شماره ۱۲۶ صفحه: ۴۳-۵۴، ۲۰۱۴.
 - [3] R. Skaria et al. "Path to precision: prevention of postoperative atrial fibrillation," Journal of Thoracic Disease, vol. 12, no. 5, p. 2735, 2020
 - [4] F. Ma, J. Zhang, W. Liang, and J. Xue, "Automated classification of atrial fibrillation using artificial neural network for wearable devices," Mathematical Problems in Engineering, vol. 2020
 - [5] M. D. Ivanovic, V. Atanasoski, A. Shvilkin, L. Hadzievski, and A. Maluckov, "Deep learning approach for highly specific atrial fibrillation and flutter detection based on RR intervals," in 2019 1st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), 2019, pp. 1783: IEEE.
 - [6] S. Śmigiel, K. Pałczyński, and D. Ledziński, "ECG signal classification using deep learning techniques based on the PTB-XL dataset," Entropy, vol. 23, no. 9, p. 1121, 2021.
 - [7] C. Yuan, Y. Yan, L. Zhou, J. Bai, and L. Wang, "Automated atrial fibrillation detection based on deep learning network," in Information and Automation (ICIA), 2016, pp. 1159-1164: IEEE
 - [8] S. Datta et al., "Identifying normal, AF and other abnormal ECG rhythms using a cascaded binary classifier," in Computing in cardiology (cinc), 2017, pp. 1-4: IEEE.
 - [9] S. Parvaresh and A. Ayatollahi, "Automatic atrial fibrillation detection using autoregressive modeling," in International Conference on Biomedical Engineering and Technology, 2011, vol. 4, no. 5.
 - [10] Y. Trardi, B. Ananou, Z. Haddi, and M. Ouladsine, "A Novel method to identify relevant features for automatic detection of atrial fibrillation," in 2018 26th Mediterranean Conference on Control and Automation (MED), 2018, pp. 613-618: IEEE.
 - [11] B. Weng, J. J. Wang, F. Michaud, and M. Blanco-Velasco, "Atrial fibrillation detection using stationary wavelet transform analysis," in 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2008, pp. 1128-1131: IEEE.
 - [۱۲] بهبهانی، کریمی مریدانی و کیانفر، ((پردازش سیگنال قلبی جهت ایجاد تمایز بین سیگنال های نرمال و فیبریلاسیون دهلیزی))، هفتمین همایش مهندسی برق، ۱۳۹۷.
 - [13] L. Khriji, M. Fradi, M. Machhout, and A. Hossen, "Deep learning-based approach for atrial fibrillation detection," in International Conference on Smart Homes and Health Telematics, 2020, pp. 100-113: Springer.
 - [14] M. A. Riyadi, I. A. Iskandar, and A. Rizal, "Development of FPGA-based three-lead electrocardiography," in 2016 International Seminar on Intelligent Technology and Its Applications (ISITIA), 2016, pp. 67-72: IEEE.
 - [15] R. J. Oweis and B. O. Al-Tabbaa, "QRS detection and heart rate variability analysis: A survey," biomedical science and engineering, vol. 2, no. 1, pp. 13-34, 2014.
 - [16] V. Seena and J. Yomas, "A review on feature extraction and denoising of ECG signal using wavelet transform," in 2014 2nd international conference on devices, circuits and systems (ICDCS), 2014, pp. 1-6: IEEE.
 - [17] Y. Xia, N. Wulan, K. Wang, and H. Zhang, "Detecting atrial fibrillation by deep convolutional neural networks," Computers in biology and medicine, vol. 93, pp. 84-92, 2018.
 - [18] S. Nurmaini et al., "Robust detection of atrial fibrillation from short-term electrocardiogram using convolutional neural networks," Future Generation Computer Systems, vol. 113, pp. 304-317, 2020.
 - [19] K. Sharma and R. Eskicioglu, "Deep Learning-based ECG Classification on Raspberry PI using a Tensorflow Lite Model based on PTB-XL Dataset," arXiv preprint arXiv:2209.00989, 2022.
 - [20] Z. Xiong, M. K. Stiles, and J. Zhao, "Robust ECG signal classification for detection of atrial fibrillation using a novel neural network," in 2017 Computing in Cardiology (CinC), 2017, pp. 1-4: IEEE.
 - [21] Z. Yao, Z. Zhu, and Y. Chen, "Atrial fibrillation detection by multi-scale convolutional neural networks," in 2017 20th International Conference on Information Fusion (Fusion), 2017, pp. 1-6: IEEE.
 - [22] R. S. Andersen, A. Peimankar, and S. Puthusserypady, "A deep learning approach for real-time detection of atrial fibrillation," Expert Systems with Applications, vol. 115, pp. 465-473, 2019.
 - [23] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical evaluation of gated recurrent neural networks on sequence

Artificial neural network	۲
Deep learning	۳
Atrial Fibrillation	۴
Electrocardiogram	۵
heart beat	۶
Recurrent neural network	۷
Long short-term memory	۸
Bidirectional Long short-term memory	۹
Conventional neural network	۱۰

- [24] S. Varsamopoulos, K. Bertels, and C. G. Almudever, "Designing neural network based decoders for surface codes," arXiv preprint arXiv:1811.12456, 2018.
- [25] A. Kulshrestha, V. Krishnaswamy, and M. Sharma, "Bayesian BILSTM approach for tourism demand for casting," Annals of tourism research, vol.83, p.102925, 2020.
- [26] J. Koushik, "Understanding convolutional neural networks," arXiv preprint arXiv:1605.09081, 2016.

زیر نویس ها

Stroke ۸