

تشخیص بیماری آریتمی قلبی با استفاده از یادگیری عمیق

ایرج ناروئی^۱، بهزاد زمانی^۲

Diagnosis Of Cardiac Arrhythmia Using Deep learning

Iraj Naruei, Behzad Zamani

Email: irajnaruei@iauzah.ac.ir

چکیده

بیماری‌های قلبی یکی از شایع‌ترین انواع بیماری‌ها است که آمار بسیار بالایی از مرگ و میر را به خود اختصاص می‌دهد. آریتمی‌ها ضربان‌های غیر طبیعی هستند، که موجب می‌شوند قلب خیلی سریع (تاکی کارد) یا خیلی آهسته (برادی کارد) بزند و پمپاژ غیر مؤثر داشته باشد. تجزیه و تحلیل خودکار الکتروکاردیوگرام برای تشخیص و درمان بیماران قلبی حیاتی است. روشهای متعددی از قبیل درخت تصمیم، شبکه عصبی، SVM، بیزین و k نزدیکترین همسایگی برای تحلیل سیگنالهای ECG در تشخیص آریتمی مطرح گردیده اند. در این مقاله ضمن بررسی اجمالی این روش‌ها، بکارگیری شبکه عصبی عمیق برای تشخیص انواع آریتمی پیشنهاد شده است. در آزمایشات انجام شده روی دادگان آریتمی UCI عملکرد بهتر روش پیشنهادی مشاهده گردید.

کلمات کلیدی

بیماری آریتمی قلبی، ECG، یادگیری عمیق، طبقه بندی

۱. مقدمه

آریتمی‌ها خیلی شایع بوده و سالانه میلیون‌ها نفر را در جهان درگیر می‌کنند که علت اصلی مرگ ناگهانی قلبی در ایالات متحده هستند و سالیانه موجب ۴۰۰۰۰۰ مرگ می‌شوند [1]. بنابراین آریتمی‌ها می‌توانند در صورتی که کاهش شدیدی در عملکرد پمپاژی قلب ایجاد نمایند، تهدید کننده باشند. وقتی عملکرد پمپاژی قلب به مدت بیش از چند ثانیه به شدت کاهش یافت، گردش خون ضرورتاً قطع می‌شود و به ارگانهایی مثل مغز آسیب می‌رساند. در زمینه تشخیص آریتمی کارهای زیادی انجام شده که ناروئی و همکارش در سال ۲۰۱۵ با کمک روش Fisher و ماشین بردار پشتیبان حداقل مربعات سعی در کاهش بار محاسباتی و افزایش نرخ صحیح بازشناسی داشتند [2]. ناروئی و همکارش در سال ۲۰۱۵ با روش PCA ابعاد ویژگی را کاهش دادند و از MLP برای طبقه بندی استفاده کردند [3]. Samad و همکارانش در سال ۲۰۱۴ از سه مدل k نزدیکترین همسایگی، درخت تصمیم و Naive Bayes برای طبقه بندی استفاده کردند [4]. Jadhav و همکارانش در سال ۲۰۱۰ یک شبکه عصبی مدولار با تعداد لایه‌های پنهان مختلف از یک تا سه و با درصد آموزش مختلف در پارتیشن مجموعه داده ارائه دادند. آنها مقادیر ویژگی‌های گم شده این مجموعه داده‌ها را با مقادیر نزدیکترین کلاس مربوطه جایگزین کردند [5]. Jadhav و همکارانش در سال ۲۰۱۰ دوباره یک شبکه عصبی چند لایه با الگوریتم پس انتشار ارائه کردند که به دقت بهتری نسبت به روش قبلی خود رسیدند [6]. Malay و همکارش در سال ۲۰۱۳ با استفاده از انتخاب ویژگی مبتنی بر همبستگی (CFS) ابعاد ویژگی را کاهش داده و برای طبقه بندی از شبکه عصبی پس انتشار تدریجی و الگوریتم LM استفاده کردند [7]. Kohli و همکارش در سال ۲۰۱۱ از PCA برای استخراج ویژگی و از SVM به عنوان طبقه بند برای ۶ کلاس استفاده [8].

^۱ دانشگاه آزاد اسلامی، واحد زاهدان، دانشکده فنی و مهندسی، گروه کامپیوتر، زاهدان، ایران
^۲ دانشگاه آزاد اسلامی، واحد زاهدان، دانشکده فنی و مهندسی، گروه کامپیوتر، زاهدان، ایران

در این مقاله با توجه به اینکه روشهای متداول در تشخیص آریتمی دارای نرخ صحیح بازشناسی کمی بوده و از جهتی فاز کاهش ویژگی و یادگیرنده از هم جدا می باشد، در این مقاله از یادگیری عمیق شبکه عصبی ای با تعداد لایه زیاد و تعداد نودهای زیاد برای تشخیص آریتمی استفاده شده است. با توجه به اینکه سیستم یادگیری تنوع در دادگان را دارد انتظار می رود که روش پیشنهادی نسبت به دیگر روشها عملکرد بهتری داشته باشد.

ادامه این مقاله به این صورت است که در بخش دوم مقاله به معرفی یادگیری عمیق پرداخته می شود. در بخش سوم روش پیشنهادی آورده می شود. نتایج آزمایشات در بخش چهارم گزارش می شود. و در نهایت جمع بندی آورده می شود.


۲. یادگیری عمیق

یادگیری عمیق شاخه ای از بحث یادگیری ماشینی و مجموعه ای از الگوریتم هایی است که تلاش می کنند مفاهیم انتزاعی سطح بالا را با استفاده یادگیری در سطوح و لایه های مختلف مدل کنند [9]. یادگیری عمیق در واقع نگرشی جدید به ایده ی شبکه های عصبی می باشد که سالیان زیادی است وجود داشته و هر چند سال یکبار در قالبی جدید خود را نشان می دهد [10]. روشن کردن این نکته ضروری به نظر می رسد که شبکه های عصبی یک لایه ی مخفی درونی دارند و شبکه ای که چندین لایه ی مخفی درونی داشته باشد شبکه عمیق نامیده می شود. دو مزیت این شیوه ی یادگیری در زیر آمده است.

باز نمایی یادگیری: نیاز اصلی هر الگوریتم یادگیری ویژگی هایی است که از ورودی ها استخراج می شود. ممکن است این ویژگی ها از پیش به صورت دستی تهیه شده و به الگوریتم خورنده شود که این روش در الگوریتم های با ناظر به کار می رود. در مقابل روش های بدون نظارت خواهد بود که خود اقدام به استخراج ویژگی ها از ورودی خواهد نمود. استخراج دستی ویژگی ها علاوه بر اینکه زمانبر است معمولا هم ناقص و در عین حال بیش از حد نیاز ذکر شده می باشد. یادگیری عمیق برای ما یک راه استخراج خودکار ویژگی ها پدید می آورد [11].

یادگیری چندین لایه ی باز نمایی ها: یادگیری عمیق برای ما این امکان را به وجود می آورد که بتوانیم که مفاهیم با سطح انتزاع بالا را با استفاده از یادگیری چند لایه از پایین به بالا بسازیم به شکل ۱ توجه کنید. این تصویر مفهوم لایه لایه بودن مراحل یادگیری را در بازشناسی چهره ی انسان به خوبی نمایش می دهد

در پاسخ به این سوال که چرا اکنون دوباره به این ایده برگشته ایم و علت رستخیز مجدد یادگیری عمیق میتوان دلایل متعددی ذکر کرد از جمله به وجود آمدن روش های استخراج خودکار که از جمله ی آن ها میتوان RBMs , ... , AutoEncoder نام برد و همچنین رسیدن به درک بهتری از روش های منظم کردن مدل ها. منبع [12] بود که با نتایج جالب خود دوباره توجه ها را به شبکه های عصبی و یادگیری عمیق بازگرداند.



شکل ۱: لایه لایه بودن مراحل یادگیری

۳. روش پیشنهادی DL- Arrhythmia

ما یک شبکه عصبی عمیق با ۷ لایه که شامل یک لایه ورودی، ۵ لایه میانی که به ترتیب شامل ۲۰، ۳۰، ۴۰، ۵۰ و ۶۰ نرون هستند و یک لایه خروجی و ۱۴۰ ورودی را برای هر دو طبقه بندی باینری و چند کلاسه بکار گرفتیم. این شبکه بر مبنای الگوریتم پس انتشار خطا آموزش می بیند. بدین ترتیب که خروجی های واقعی با خروجی های دلخواه مقایسه می شوند و وزن ها به وسیله الگوریتم پس انتشار، به صورت تحت نظارت تنظیم می گردند تا الگوی مناسب بوجود آید. برای الگوی ورودی p ام، مربع خطای خروجی برای تمامی سلول های لایه خروجی شبکه به صورت زیر در می آید:

$$E_p = \frac{1}{2} (d^p - y^p)^2 = \frac{1}{2} \sum_{j=1}^s (d_j^p - y_j^p)^2$$

که در آن d_j^p خروجی دلخواه برای j امین سلول در لایه خروجی واقعی برای j امین سلول در لایه خروجی، s ابعاد بردار خروجی، y^p بردار خروجی واقعی و d^p بردار خروجی دلخواه هستند. مربع خطای کل E برای P الگو بصورت زیر در می آید:

$$E = \sum_{p=1}^P E_p = \frac{1}{2} \sum_{p=1}^P \sum_{j=1}^s (d_j^p - y_j^p)^2$$


وزن ها با هدف کاهش تابع هزینه E به مقدار مینیمم به روش گرادیان نزولی تنظیم می گردند. معادله به روز در آوردن وزن ها به صورت زیر است:

$$w_{ij}(t+1) = w_{ij}(t) + \eta \Delta w_{ij}(t) + \alpha \Delta w_{ij}(t-1)$$

که در آن $\Delta w_{ij}(t) = -\left(\frac{\partial E_p}{\partial w_{ij}(t)}\right)$ ، η ضریب یادگیری، α ضریب لحظه ای $w_{ij}(t+1)$ وزن جدید و $w_{ij}(t)$ وزن قبلی می باشد. همچنین در این روش، وزن ها به طور مکرر برای تمامی الگوهای یادگیری به روز درآورده می شوند. روند یادگیری هنگامی متوقف می شود که مجموع کل خطا، E ، برای p الگو از مقدار آستانه تعیین شده کمتر شود یا تعداد کل دوره تعلیم به پایان برسد. خروجی هر نرون تابع سیگموئید به صورت زیر است.

$$h_{\theta}(x) = \frac{1}{1 + e^{-\theta^T x}}, x = \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}, \theta = \begin{bmatrix} \theta_0 \\ \theta_1 \\ \vdots \\ \theta_n \end{bmatrix}$$

ما شبکه را با استفاده از پس انتشار بازگشتی و گرادیان تصادفی نزولی برای به حداقل رساندن تابع هزینه آموزش می دهیم. تنظیم پارامتر لامبدا برای جلوگیری از Overfitting با کاهش مقدار پارامتر انجام می شود. برای تثبیت تمام پارامترهای دیگر، ما LAMDA را تغییر می دهیم و برابر با ۰٫۱ تنظیم می کنیم. معماری شبکه عصبی عمیق به صورت شکل ۳ می باشد.




شکل ۳: شبکه عصبی عمیق با ورودی‌های زیاد و لایه‌های زیاد

۴. نتایج آزمایشات

۱.۴ دادگان

مجموعه داده مورد استفاده در این تحقیق، از آرشیو مجموعه داده‌های یادگیری ماشین UCI گرفته شده است [13]. این مجموعه داده شامل ۴۵۲ نمونه و ۲۷۹ ویژگی است که برای سهولت استفاده از آن در تعیین وجود یا عدم وجود بیماری آریتمی و برای شناسایی نوع آریتمی به سه دسته کلی تقسیم شده است. در این مجموعه داده کلاس "۱" اشاره به ECG نرمال، کلاس‌های "۲-۱۵" اشاره به کلاس‌های مختلف آریتمی و کلاس "۱۶" به بقیه داده‌های طبقه‌بندی نشده اشاره دارد. توزیع نمونه‌ها در هر کلاس در شکل ۲ نشان داده شده است. از آنجاییکه در دیتاست ما ویژگی‌هایی با مقادیر مفقودی وجود دارد، و ما نمی‌خواهیم این اطلاعات را از دست دهیم، لذا مقادیر مفقودی با استفاده از روش میانگین مقادیر هر ویژگی مقدارگذاری می‌گردد [14].



شکل ۲: تعداد نمونه‌ها در هر کلاس

۲.۴ نتایج

شبکه عصبی عمیق ما برای طبقه‌بندی دودویی به نرخ صحیح بازشناسی ۹۵٪ دست یافت که نسبت به روشهای k نزدیکترین همسایگی، درخت تصمیم، بیزین، شبکه عصبی و SVM دقت بهتری داشت. مقایسه این روشها برای طبقه‌بندی دودویی در جدول شماره ۱ نشان داده شده است.

جدول ۱: مقایسه روش‌ها برای طبقه‌بندی دودویی

روش	نرخ صحیح بازشناسی
Fisher-LSSVM[2]	۹۷
MLP-PCA[3]	۹۳٫۴
Knn[4]	۶۶٫۹۶
Decision Tree[4]	۵۹٫۷۷
Navie Bayes[4]	۴۵٫۸۵
NN Modular[5]	۸۲٫۲۲
MLP[6]	۸۶٫۶۷
شبکه عصبی پس‌اتشار تدریجی [7]	۸۶٫۲
LM[7]	۸۷٫۷۱
Random Forest[9]	۹۰
DL- Arrhythmia	۹۵

همچنین برای طبقه‌بندی چندکلاسه به نرخ بازشناسی ۷۶٫۸٪ دست یافتیم که نسبت به برخی روشها به دقت مطلوبتری رسیدیم که در جدول ۲ این نتایج را نشان می‌دهد.

جدول ۲: مقایسه روش‌ها برای طبقه‌بندی چند کلاسه

روش	نرخ صحیح بازشناسی
random forest[9]	۷۶
Fisher-LSSVM[2]	۹۰٫۷۱
MLP-PCA[3]	۷۸
DL- Arrhythmia	۷۶٫۸

۵. جمع بندی

آریتمی‌ها خیلی شایع بوده و سالانه میلیون‌ها نفر را در جهان درگیر می‌کنند که علت اصلی مرگ ناگهانی قلبی در ایالات متحده هستند و سالیانه موجب ۴۰۰۰۰۰ مرگ می‌شوند. بنابراین آریتمی‌ها می‌توانند در صورتی که کاهش شدیدی در عملکرد پمپاژی قلب ایجاد نمایند، تهدید کننده باشند. ما یک شبکه عصبی عمیق با ۷ لایه که شامل یک لایه ورودی، ۵ لایه میانی که به ترتیب شامل ۲۰، ۳۰، ۴۰، ۵۰ و ۶۰ نرون هستند و یک لایه خروجی و ۱۴۰ ورودی را برای هر دو طبقه بندی باینری و چند کلاسه بکار گرفتیم. این شبکه بر مبنای الگوریتم پس انتشار خطا آموزش داده شد. ما برای طبقه بندی دودویی به نرخ صحیح بازشناسی ۹۵٪ و برای طبقه بندی چندکلاسه به نرخ بازشناسی ۷۶٫۸٪ دست یافتیم. این نتایج مبین بهبودی قابل ملاحظه‌ای نسبت به برخی از کارهای اخیر در زمینه تفکیک آریتمی‌های قلبی است. بکارگیری روش پیشنهادی می‌تواند کمک شایانی در زمینه تشخیص دقیق و صحیح امراض قلبی به پزشکان نماید.



۶. منابع و مراجع

- [1] نارویی و زمانی، تشخیص آریتمی قلبی با استفاده از روش فیشر و ماشین بردار پشتیبان حداقل مربعات، همایش الکترونیکی پژوهش‌های نوین در علوم و فناوری، ۱۳۹۴
- [2] نارویی و زمانی، تشخیص آریتمی قلبی با استفاده از PCA و MLP، همایش الکترونیکی پژوهش‌های نوین در علوم و فناوری، ۱۳۹۴
- [3]. Sesselberg.HW, et al., Ventricular arrhythmia storms in post infarction patients with implantable defibrillators for primary prevention indications: A MADIT-II sub study, Heart Rhythm, Elsevier, Vol.4, 1395–1402, 2007.
- [4]. Saleha Samad, et al., Classification of Arrhythmia, International Journal of Electrical Energy, Vol. 2, No. 1, 2014.
- [5]. Shivajirao M. Jadhav, et al., ECG Arrhythmia Classification using Modular Neural Network Model, IEEE EMBS Conference on Biomedical Engineering & Sciences, 2010a.
- [6]. Shivajirao M. Jadhav, et al., Artificial Neural Network Based Cardiac Arrhythmia Classification Using ECG Signal Data, International Conference on Electronics and Information Engineering, 2010b.
- [7]. Malay Mitra and R. K. Samanta, Cardiac Arrhythmia Classification Using Neural Networks with Selected Features, International Conference on Computational Intelligence, 76 – 84, 2013.
- [8]. Narendra Kohli and Nishchal K. Verma, Arrhythmia classification using SVM with selected features, International Journal of Engineering, Science and Technology Vol. 3, No. 8, 2011, pp. 122-131, 2011.
- [9]. olanyi and A. Zaenen. 2006. Contextual valence shifters. In W. Bruce Croft, James The Information Retrieval Series
- [10]. Nakagawa, K. Inui, and S. Kurohashi. 2010. Dependency tree-based sentiment classification using CRFs with hidden variables. In NAACL, HLT.
- [11]. Bottou. From machine learning to machine reasoning : CoRR , 2011
- [12]. ImageNet Classification with Deep Convolutional Neural Networks
- [13]. Bache, K. and Lichman M., UCI machine learning repository,. URL <http://archive.ics.uci.edu/ml>, 2013
- [14]. Jose M. Jerez, et al., Missing data imputation using statistical and machine learning methods in a real breast cancer problem, Artificial Intelligence in Medicine vol. 50, pp. 105–115, 2010