

طراحی و شبیه‌سازی

یک کدکنندهٔ صحبت به صورت بلاذرنگ

مقالاتی از کارنامه پژوهشی «شیریف» سال ۷۰

تشخیص نوع تحریک در کدکنندهٔ صحبت LPC
توسط شبکه عصبی

محله شریف در ادامه چاپ مقالاتی از کارنامه پژوهشی شریف، در این
شماره نیز اقدام به چاپ یکی دیگر از این مقالات نموده است.

همایون برهانی (مری)
سید بهرام ظهیراعظمی
مرکز تحقیقات الکترونیک

چکیده

یکی از مسائل مهم در ساخت کدکننده‌های صحبت، تشخیص صحیح نوع تحریک است. در این گزارش ضمن توضیح مشکلات موجود در روش‌های معمول تشخیص نوع تحریک، روش جدیدی که مبتنی بر شبکه‌های عصبی است ارائه می‌گردد. قدرت این روش تا حدی است که روی حدود ۲۰۰۰ قطعهٔ صحبت نمونه که برای آموزش مورد استفاده قرار گرفته است بدون خطأ عمل کرد و میزان خطای برای قطعات انتخاب شده خارج از این مجموعه بسیار ناچیز بود.

مقدمه

در ساختمان کدکننده‌های صحبت، قسمت‌های مختلفی وجود دارد که یکی از آنها مربوط به تعیین نوع تحریک - متناوب یا غشوش - است.^[۱]

این پدیده را می‌توان با تماس آرام انگشتان دست روی ناحیه‌ای از گلو (کنار غدهٔ تیروئید) که تارهای صوتی و حنجره در پشت آن قرار گرفته‌اند، حس نمود.

ارتعاش تارهای صوتی (Vocal Cords) عامل متناوب شدن تحریک و واک‌داری (Voicing) یک قطعه (Frame) است. به این شکل که با قرار گرفتن این تارها در فاصله مناسبی از یکدیگر و دمیده

نصف محل ماکریم مطلق، صورت می‌گیرد.

این روش دارای خطای زیادی است، چرا که تجربه نشان داده است که با انتخاب تنها یک معیار نمی‌توان جداسازی قطعه‌های واکدار و بی‌واک را بدروستی انجام داد بلکه به اطلاعات بیشتری نیاز هست. حتی با افروزن (Zero Crossing Rate) و اطلاعات دیگری از قبیل نرخ عبور از صفر (Zero Crossing Rate) و انرژی قطعه نیز امکان جداسازی صحیح برای مجموعه‌ای گسترده از افراد و اجهای بیان شده، وجود ندارد.^[۴]

بنابراین لازم است از معیارهای بیشتری برای جداسازی استفاده شود. شکل‌های ۱ و ۲ به ترتیب نمایشگر قطعه‌های واکدار و بی‌واک صحبت هستند. در هر شکل منحنی زمانی، طیف و پوش طیف تخمین زده شده رسم گردیده است. تفاوت‌هایی که بین قطعه‌های واکدار و بی‌واک مشهود است به قرار زیر می‌باشند.^[۴]

- ۱- در منحنی زمانی، قطعه‌های واکدار حالت تناوبی و در قطعه‌های بی‌واک حالت مغشوش (نویزی) مشاهده می‌گردد.
- ۲- اغلب قطعه‌های واکدار نسبت به قطعه‌های بی‌واک دارای انرژی بیشتری هستند.
- ۳- معمولاً نرخ عبور از صفر در قطعه‌های بی‌واک بیش از قطعه‌های واکدار است.
- ۴- تابع خودبستگی قطعه‌های واکدار یکنواخت‌تر از قطعه‌های بی‌واک است.
- ۵- معمولاً قطعه‌های واکدار دارای مولفه‌های فرکانسی قوی در فرکانس‌های پایین تر از ۱۵۰۰ هرتز هستند، در حالی که قطعه‌های بی‌واک اغلب دارای مولفه‌های فرکانسی قوی در فرکانس‌های بالاتر از ۱۵۰۰ هرتز هستند.
- ۶- در طیف قطعات واکدار گلبرگهای (Lobe) هم عرض وجود دارد.

به عنوان مثالی از تفاوت اشاره شده در مورد ۳، میانگین نرخ عبور از صفر در قطعات واکدار، ۱۵۳۰ بار در ثانیه و برای قطعه‌های بی‌واک ۴۰۴۰ بار در ثانیه بوده است. علی‌رغم این مسئله چون قطعه‌های واکداری با حدود ۳۸۰۰ عبور از صفر در ثانیه وجود داشته‌اند، معیار نرخ عبور از صفر نمی‌تواند به تنها برای در جداسازی قطعات به کار رود.^[۴]

علاوه بر اینها باید توجه داشت که تاثیر نویز ممکن است بر روی یکی از این معیارها بیش از حد زیاد باشد - مثلاً یک نوع نویز می‌تواند سبب افزایش فوق العاده نرخ عبور از صفر شود - مسئله دیگر تفاوت‌هایی است که در محدوده تغیرات هر یک از این معیارها برای افراد، جنسیت‌ها، لهجه‌ها

در موقع بیان بسیاری از واج‌ها (Phonemes) این ارتعاش در تارهای صوتی وجود دارد. به طوری که از ۳۱ واج زبان فارسی تنها ده واج بی‌واک هستند. بسامد و قوی اجهای بی‌واک نیز معمولاً کمتر از اجهای واکدار است. به طوری که می‌توان ادعای کرد در حدود ۹۰ درصد از زمان صحبت، تارهای صوتی در حال ارتعاش هستند. با وجود کم بودن احتمال وقوع اجهای بی‌واک تشخیص صحیح قطعه‌های واکدار و بی‌واک از هم، دارای اهمیت بسیار زیادی است. زیرا اولاً بسیاری از اجهای واکدار دارای جفت بی‌واک هستند. بدین معنی که دو واج در کلیه علایم و مظاهر به یکدیگر شیوه هستند، به جز پارامتر واکداری که یکی واکدار است و دیگری بی‌واک. طبیعی است که بروز اشتباه در تشخیص واکداری در بین این قبیل اجهای می‌تواند موجب ایجاد اشتباه بین آنها گردد. از جفتهای واکدار و بی‌واک می‌توان موارد زیر را نام برد: (ب/b و پ/p)، (د/d و ت/t)، (گ/g و ک/k)، (ز/z و ش/sh)، (ز/z و س/s)، (و/v و ف/f)، (ج/j و چ/c) که در هر جفت به ترتیب، اولی واکدار و دومی بی‌واک است.^[۲]

به این صورت تشخیص غلط واکداری در یک کدکننده صحبت (Vocoder) ممکن است باعث گردد تا کلمه «سیب» /sib/ به اشتباه «زیپ» /zip/ شنیده شود. این موضوع در درک اجهای (Phoneme Recognition) نیز اهمیت پیدا می‌کند. البته نباید از نظر دور داشت که گرچه واکداری یکی از مشخصه‌های هر واج است ولی تا حد زیادی تحت تأثیر عوامل دیگر بیویزه بافتی که واج در آن قرار می‌گیرد نیز هست.

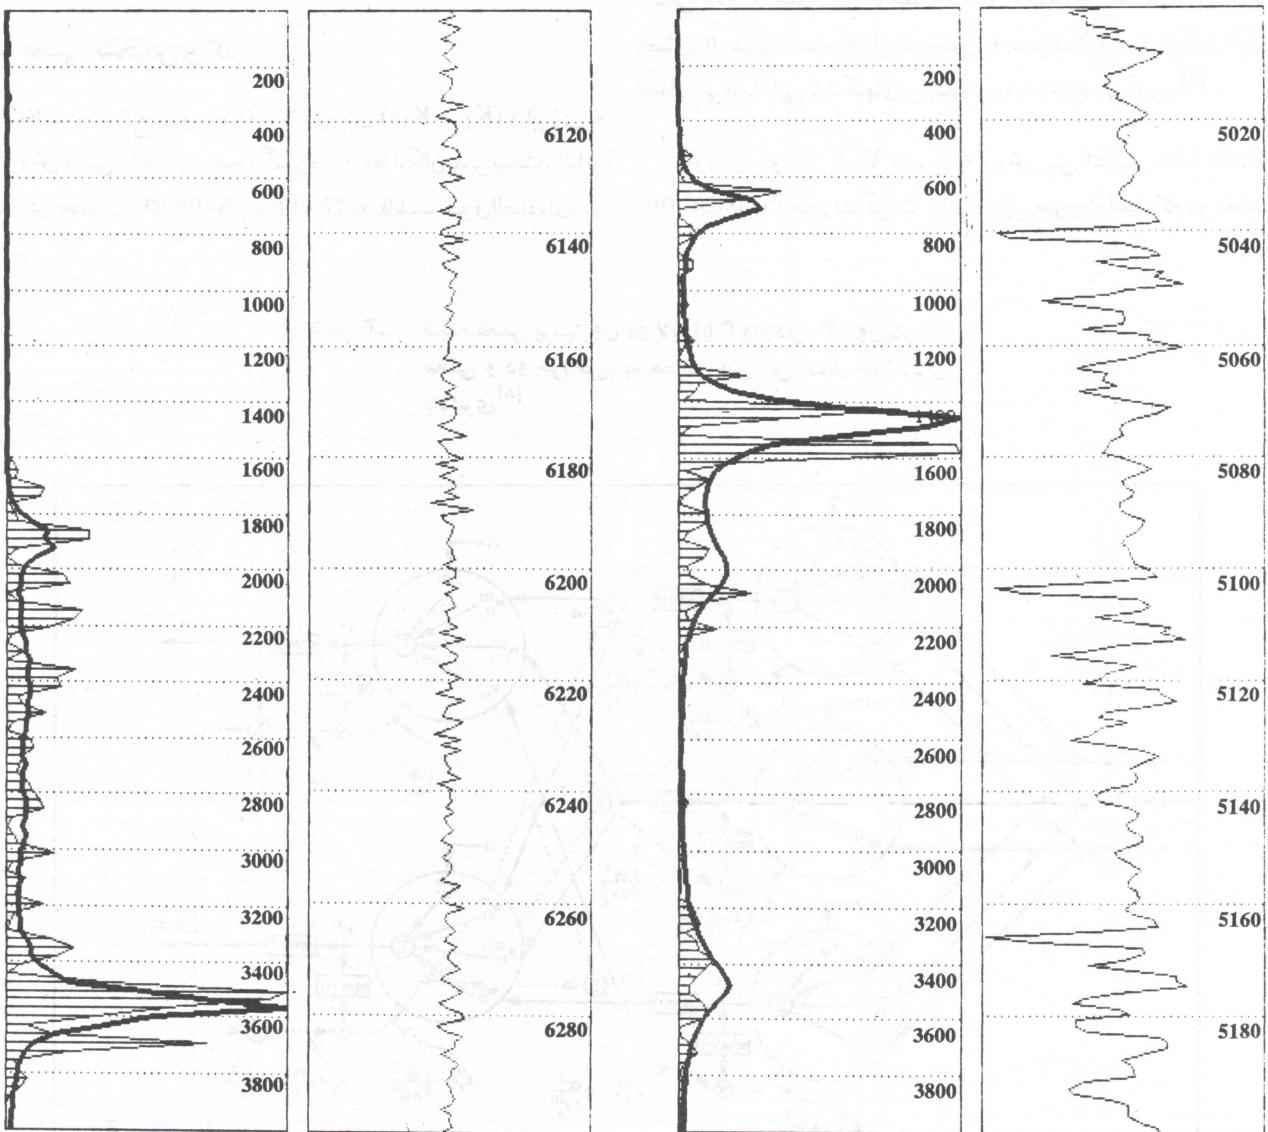
به علاوه اشتباه در تخمین واکداری - بسته به روش تخمین گام (Pitch Detection) که استفاده می‌شود - می‌تواند موجب تغییرات غیرهماهنگ در گام صحبت شود که چنین پدیده‌ای کیفیت صدای حاصله را شدیداً خراب می‌کند.

روش تشخیص واک

با بررسی چند کدکننده صحبت نمونه [۷ و ۵] ملاحظه شد که تشخیص واک در بسیاری از کدکننده‌های صحبت با انتخاب مقادیر آستانه روی کمیت‌هایی که در تخمین گام به کار می‌روند انجام می‌گردد. به عنوان مثال در روش کپستروم (Cepstrum)^[۵]، ماکریم تابع کپستروم در فاصله معقول برای گام - که اغلب حدود ۲۰ میلی ثانیه در نظر گرفته می‌شود - با یک مقدار آستانه مقایسه می‌شود و در صورتی که از این مقدار کمتر بود قطعه بی‌واک معرفی می‌گردد و در غیر این صورت قطعه واکدار بوده و محل ماکریم به عنوان گام معرفی می‌شود و در نهایت اصلاحاتی نیز با توجه به گام قطعه قبل و مقدار تابع کپستروم در

شکل ۲ - بالا منحنی تغییرات زمانی و پایین طیف (خطوط نازک) و پوش طیف (خط کلفت) مربوط به یک قطعه ۲۵ میلی ثانیه‌ای از صحبت بی‌واک

شکل ۱ - بالا منحنی تغییرات زمانی و پایین طیف (خطوط نازک) و پوش طیف (خط کلفت) مربوط به یک قطعه ۲۵ میلی ثانیه‌ای از صحبت واک‌دار



۲- حجم گسترهای از داده‌ها را - که از صحبت افراد مختلف و با جنسیت‌ها و سنین متفاوت که کلیه واج‌ها را بیان کرده‌اند جمع آوری شده - در نظر گرفته باشد.

۳- در صد خطای ناچیزی داشته باشد.

از آنجاکه در یک کدکننده LPC، ضرایب K_p - K_1 (کلیه اطلاعات پوش طیف تخمین زده شده را در بر دارند^[۲]، می‌توان با کمک این ضرایب و همچنین انرژی محاسبه شده، عمل تشخیص واک‌داری را به نحو مطلوب انجام داد. با توجه به اینکه ضرایب K_p - K_1 و انرژی

و سنین مختلف وجود دارد. با توجه به بند ۵ تفاوت‌های ذکر شده در بالا این فکر به وجود می‌آید که ممکن است بتوان با استفاده از تمام اطلاعات طیف سیگنال در هر قطعه، واک‌داری قطعه یا عدم آن را تعیین نمود. در مقاله حاضر نحوه انجام این عمل به نحوی که برای یک کدکننده صحبت چنین روشی برای تعیین واک‌داری باید تامین کننده خواسته‌های زیر باشد:

۱- در برداشت محاسبات اضافی قابل توجه، به طوری که تحقق آن در یک کدکننده صحبت بلاذرنگ امکان‌پذیر باشد.

استفاده قرارگرفت، یکی از انواع شبکه‌های عصبی است که رو به جلو (Feed Forward) و بدون حافظه (Memoryless) است. (شکل ۳)

هر یک از نرون‌های لایه نخست (لایه مخفی) در شبکه پرسپترون به تنهایی قادر به جداسازی توسط یک فوچه (Hyperplane) در فضای n بعدی است. عامل غیرخطی به همراه لایه دوم شبکه، امکان ایجاد زیرفضاهایی با شکل‌های پیچیده‌تر را به وجود می‌آورد.^[۸]

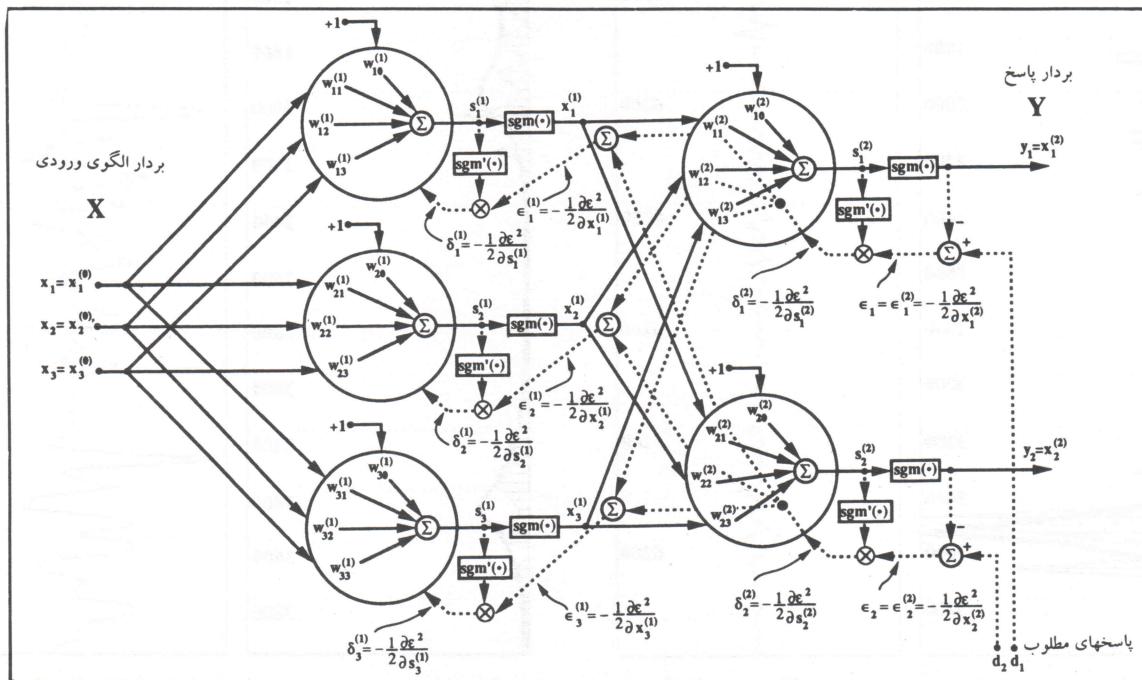
آموزش خودکار شبکه عصبی به روش پس انتشار خطای (Back Propagation) صورت گرفت و آن به این صورت است که در دفعات

لزوماً باید محاسبه گردد، استفاده از آنها در تشخیص واک داری متصمن محاسبات اضافی نبوده و از این جهت برای یک سیستم بلاذرنگ مناسب است.

شبکه عصبی تشخیص واک

انتخاب یک تابع از مجموعه ۱۱ ورودی ($K_1 - K_{10}$) و انرژی به یک روش دستی، با توجه به حجم گسترده داده‌ها امکان‌پذیر نیست، لذا از شبکه‌های عصبی (Neural Network) که قابلیت فوق العاده‌ای در

شکل ۳ - شبکه عصبی پرسپترون دو لایه (با ۳ ورودی، ۳ نرون در لایه مخفی و دو خروجی) به همراه روش پس انتشار خطای برای یادگیری^[۸]



متعدد هر بار یک ورودی نمونه به شبکه اعمال می‌گردد، سپس اگر خروجی حاصل با خروجی مطلوب و موردنظر متفاوت بود کلیه ضرایب شبکه به نحوی تغییر داده می‌شوند که خطای تقلیل داده شود. این روش به صورت مرحله به مرحله انجام می‌گردد تا به یک جواب نسبتاً بهینه برسد.

شبکه عصبی با ۵ نرون در لایه میانی - که به این صورت آموزش داده شد - توансنت شناسایی قطعات واک دار از بی واک را در مجموعه حدود ۲۰۰۰ قطعه که برای آموزش مورد استفاده قرار گرفته بود بدون هیچ مورد خطای انجام دهد و در خارج از محدوده داده‌های آموزشی نیز

دسته‌بندی (Classification) خودکار از خود نشان داده‌اند، استفاده شد.

شبکه عصبی از تعدادی پردازشگر کوچک موسوم به نرون (Neuron) تشکیل شده است. ورودی هر نرون مجموع وزن دار (Weighted) خروجی نرنویهای شبکه و ورودی خارجی به شبکه است. خروجی هر نرون نیز از اعمال یک تابع غیرخطی مانند تانژانت هذلولی (Hyperbolic Tangent) بر روی ورودی به دست می‌آید.

شبکه پرسپترون (Perceptron) که برای تشخیص واک مورد

عملکرد بسیار خوبی ارائه نمود. علت این است که خاصیت تعمیم‌دهی (Generalization) شبکه‌های عصبی باعث می‌گردد که در پاسخگویی به قطعات دیگری که در مجموعه یادگیری نبوده ولی خواص نسبتاً مشابهی با قطعات مجموعه داشته باشند، موفق باشند.

از آنجایی که برای افزایش سرعت همگرایی (convergence) شبکه عصبی در مرحله آموزش بهتر است ورودیها در محدوده عددی یکسانی قرار داشته باشند، مقدار انرژی نیز با یک تابع غیرخطی به عددی در محدوده $[10^{-1} - K_{10}]$ (مشابه ضرائب $K_1 - K_{10}$) تبدیل گردید.^[4]

منابع

۱- ب. ظهیر اعظمی، م. اکبر، ه. برهانی، «سیستم آنالیز و سنتز صحبت به روش پیشگویی خطی، کارنامه پژوهشی شریف، ۱۳۶۸.

۲- ی. ثمره، «آواشناسی زبان فارسی، آواها و ساخت آوایی هجا»، نشر دانشگاهی، ۱۳۶۴.

۳- ب. ظهیر اعظمی، ه. برهانی، «روشهای LPC» گزارش ۹۰-۶، مرکز تحقیقات الکترونیک دانشگاه صنعتی شریف.

۴- ب. ظهیر اعظمی، ه. برهانی، «تشخیص واک به کمک شبکه عصبی، گزارش ۹۰-۳، مرکز تحقیقات الکترونیک دانشگاه صنعتی شریف.

5- A. M. Null, "Cepstrum Pitch Determination" J. Acoust. Soc. Am., Vol. 41, Feb. 1967.

6- M.J.Ross, H.L. Shaffer, A. Cohen, R. Freudberg, H. J. Manley "Average Magnitude Difference Function Pitch Extraction" IEEE Trans. on ASSP, Vol. 22, Oct. 1974.

7- M.M. Sondhi, "New Methods of Pitch Extraction" IEEE Trans. on Audio Electroacoust., Vol. Au-16, June 1968.

8- B. Widrow, M.A. Lehr, "30 Years of Adaptive Neural Networks: Perceptron, Madaline & Back Propagation." IEEE Proc., Vol. 78, No. 9, Sep. 1990.

نتیجه‌گیری

توسط یک شبکه عصبی دو لایه با ۵ نرون در لایه مخفی می‌توان به درصد صحبت بسیار بالایی در تشخیص واک داری قطعات صحبت دست یافت. تحقق نرم افزاری این شبکه با حدود ۶۰ عمل ضرب و ۶۰ عمل جمع اعشاری و ۵ عمل تانزانت هیپربولیک به ازای هر قطعه ۲۵ میلی ثانیه‌ای امکان‌پذیر است. همچنین برنامه باید ۶۶ مقدار وزنه را ذخیره کند که آنها هم متغیرهای اعشاری هستند. در استفاده از این شبکه در کدکننده صحبت LPC نیاز به محاسبات اضافه بر آنچه در بالا گفته شد- به جز در مورد نرمالیزاسیون انرژی - نیست.

استفاده از شبکه عصبی یک لایه، یعنی تنها یک نرون و بدون لایه مخفی نیز بی‌آنکه خطای قابل توجهی ایجاد کند میزان محاسبات را تا حد فقط ۱۰ ضرب و ۱۰ جمع برای هر قطعه کاهش می‌دهد و بنابراین می‌تواند در ساخت کدکننده صحبت بلادرنگ مورد استفاده قرار گیرد.