

# بازشناسی گفتار توسط شبکه‌های عصبی مدولار بر مبنای بکارگیری توأم نواحی صوتی یکنواخت و گذرا

سید علی سید صالحی

استادیار

دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر

## چکیده

کارهای قبلی بر روی بازشناسی گفتار به کمک شبکه‌های عصبی غالباً بر تقطیع واحد و یا نگاشت مسیر بودار بازنمایی گفتار به فضای واحد ها متکی بوده‌اند. در این روش‌ها به علت نحوه بروجسبدهی در مرزهای واحد ها بخشی از اطلاعات مفید گفتار ممکن است از دست بروند. برخی نتایج اخیر نشان می‌دهند که اولاً نواحی مرزی و گذرا ای واحد ها برای شناسائی به عنوان واحد های صوتی پتانسیل خوبی دارند و دوم اینکه بازشناسی نواحی گذرا ای سریع آواها به عنوان نشانه های صوتی ثابت توسط شبکه های عصبی به کیفیت بازشناسی بالائی منجر گردیده است. بازشناسی مجزای نواحی یکنواخت و نواحی گذرا ای آواها بر مبنای تفکیک همخوان، واکه و ترکیب نتایج آنها را بر روی گفتار فارسی پیاده‌سازی نموده‌اند. بررسی خطاهای عملکرد این مدل نشان داده‌اند که برخی نکات نظری زبان‌شناختی پیرامون همخوان‌ها و واکه‌ها با نتایج پیاده‌سازی های مهندسی کاملاً طبیق نمی‌کنند.

## كلمات کلیدی

بازشناسی گفتار، شبکه‌های عصبی مدولار، نواحی صوتی یکنواخت و گذرا، واکه - همخوان، بازشناسی واحد.

## A Modular Neural Network Speech Recognizer Based on the Both Acoustic Steady Portions and Transitions

S. A. Seyyed Salehi

Asistant Professor

Biomedical Engineering Department,  
Amirkabir University of Technology

### Abstract

Previous works on speech recognition utilizing neural networks have often relied on either recognition through segmentation or mapping of the representation trajectories to the phoneme space. Here, information could be missed due to the method of border labeling techniques.

Recent works have indicated that firstly, phonetic borders and transitions would have a good potential to be recognized as acoustic units, and secondly, recognition of the fast transitions by neural networks, as fixed cues in time, results in high performance detection and recognition of those events. This approach was manifested through recognition of basic units formed from the VC and CV borders in Farsi (Persian) spoken language. Analysis of the resulting errors has indicated certain discrepancies amongst the theoretical linguistic points of view and implementation outcome.

### Keywords

Speech Recognition, Modular Neural Networks, steady & Transition, Vowel-Consonant, Phoneme Recognition.

بررسی نتایج تحقیقات قبلی در بازشناسی واج‌های<sup>۱</sup> گفتار و تجزیه و تحلیل خطاهای موجود در بازشناسی واج‌ها در روش‌های پیاده‌سازی شده پیشین نشان داده‌اند که اطلاعات صوتی و گفتاری مفید و قابل ملاحظه‌ای را از نواحی گذرای مرزی آواها می‌توان استخراج نمود.

مدل‌های شبکه عصبی پیاده‌سازی شده قبلی برای بازشناسی واج‌ها، غالباً یا متکی به بازشناسی واج‌ها پس از تقطیع<sup>۲</sup> بوده‌اند [۱] و یا اینکه بر مبنای نگاشت کل مسیر بردار بازنمائی به فضای واج‌ها عمل می‌کردد [۲، ۳، ۴]. در هر حال دقت در نتایج عملکرد این مدل‌ها نشان می‌دهد که در این روش‌ها به دلیل نحوه برچسب‌دهی در نواحی مرزی آواها، اطلاعات صوتی موجود و نهفته در این نواحی عمده‌تر مورد کم‌توجهی قرار می‌گرفته‌اند.

در هر دو روش ذکر شده فوق برای بازشناسی واج‌ها، نواحی با مشخصات طیفی سریعاً گذرای سیگنال گفتار در تقطیع و یا برچسب‌دهی در مرز ما بین واج‌ها قرار می‌گیرند و با توجه به وجود خطاهای متعددی نظیر خطا در تشخیص محل تقطیع یا برچسب‌دهی توسط انسان و نیز خطای در انطباق زمانی مدل بازشناسی با سیگنال صوتی در هنگام تعلیم و بازشناسی، ایجاد تنوعات و چندگونگی‌های زائدی می‌نماید که موجب اتلاف و ریزش اطلاعات صوتی مفید موجود در سیگنال گفتار در هنگام بازشناسی می‌گردد. این نکته می‌تواند به عنوان یکی از تنگناهای موجود در مسیر عملکرد سیستم‌های بازشناسی گفتار مورد توجه و ملاحظه قرار گیرد. برای رفع این مشکل لازم است که روش‌های رایج برچسب‌دهی خروجی مدل‌های بازشناسی واحدهای صوتی را تغییرداده و در خود واحدهای صوتی پایه نیز اصلاحاتی را به عمل آوریم.

در تعلیم واج‌ها به شبکه عصبی به صورت تقطیع شده، تقطیع آواها در نواحی‌ای از سیگنال گفتار که بیشترین سرعت تغییرات طیفی را دارند، یعنی مرزاوه‌ها انجام می‌شود. در چنین حالتی اولاً کوچکترین خطا در تشخیص مدل تقطیع، بیشترین تأثیرات نامطلوب را در تعلیم و بازشناسی مدل ایجاد می‌نماید و حساسیت پارامترهای طیفی به تغییرات محل تقطیع در این نواحی بیشینه<sup>۳</sup> است. این در حالی است که نواحی گذرا در تعلیم به مدل می‌بایست دارای کمترین مقدار خطا باشد. در تعلیم نگاشت کل مسیر بردار بازنمایی به فضای واج‌ها به شبکه عصبی، نیز گرچه سیگنال گفتار تقطیع نمی‌شود [۴، ۳، ۲] لیکن بازهم تغییر برچسب‌ها در خروجی شبکه در نواحی گذرای مرزی آواها، اتفاق می‌افتد که هم دارای خطای تشخیص انسانی ناشی از برچسب‌دهی دستی دادگان است و هم اینکه بطوریکه عملاً نتایج پیاده‌سازی‌های قبلی نشان داده‌اند بیشترین خطای بازشناسی را در نواحی مرزی آواها داریم. بنابراین اگر ما تغییراتی در نحوه بیان برچسب‌های سیگنال گفتار در هنگام تعلیم به شبکه بدھیم به نحوی که نقاط ضعف ذکر شده در بالا در آنها به حد کمینه<sup>۴</sup> رسیده باشند می‌توان انتظار داشت که به این وسیله به صحت بازشناسی بالاتری بتوان دست یافت [۵، ۶، ۷].

نکته دیگری که در این رابطه نیاز است مورد توجه قرار گیرد این است که در سیگنال گفتار، نواحی گذرا نسبت به نواحی یکنواخت خصوصاً و اکه‌ها، کمتر تحت تأثیر سرعت بیان قرار می‌گیرند و مشخصات دینامیکی پایدارتری دارند و به بیان دیگر اینکه طول‌های زمانی وقایع گذرای گفتار در عبارات مختلف، نسبت به نواحی ایستان گفتار دارای تغییرات کمتری هستند و افراد در هنگام تغییر سرعت بیان خود نوعاً بیشتر طول نواحی ایستان خصوصاً و اکه‌های گفتار خود را تغییر می‌دهند [۸] و این برای تعلیم نواحی گذرا به مدل شبکه عصبی یک مزیت نسبی به حساب می‌آید. زیرا تغییرات و جابجائی در مشخصات زمانی وقایع صوتی در هنگام تعلیم و بازشناسی توسط شبکه‌های عصبی، تأثیرات نامطلوبی در کیفیت عملکرد شبکه‌های عصبی باقی می‌گذارد. بنابراین اگر ما دسته‌ای از واحدهای صوتی مورد بازشناسی را در نواحی گذرای گفتار اختیار کنیم می‌توانیم با کمک آنها نقاط ضعف ذکر شده در بالا را تا حدی برطرف نمائیم.

## ۱- اصول و مبانی، ساختار و اجزاء مدل بازشناسی گفتار(نمودار۱)

مشخصات طیفی سیگنال گفتار متغیر با زمان است و وقایع صوتی درون آن متأثر از رفتار اجزای تولیدی گفتار<sup>۵</sup> در ناحیه صوتی است. هر تغییر موقعیت هر یک از این عناصر تولید گفتار، حداقل یک تغییر مشخصات طیفی را در سیگنال گفتار در پی دارد. دقت در نحوه ادراک گفتار توسط انسان نشان می‌دهد که این تغییرات طیفی در سیگنال گفتار دارای هویت و بار اطلاعاتی قابل ملاحظه‌ای بوده و به عنوان مشخصه‌ها و وقایع اصلی در سیگنال گفتار نقش ایفا می‌کنند. در رویکرد مطرح در

این مقاله، ما نواحی گذرای مابین دو واج مجاور با توجه به واکه یا همخوان بودن آنها یعنی مرزهای CV و VC را به عنوان واحدهای کمکی جهت بازشناسی درنظر گرفته‌ایم. همچنین در بررسی نتایج پیاده‌سازی مدل بازشناسی واج‌ها به کمک مشخصه‌های تولیدی که قبلًا انجام داده‌ایم، [۲، ۴] مشاهده گردید که مشخصه تولیدی هجائی<sup>۹</sup> که بیانگر واکه یا همخوان بودن یک واج است توسط شبکه عصبی با دقت بالائی قابل یاد گرفتن است و میزان صحت بازشناسی بالائی را نیز دارد. از سوی دیگر واکه‌ها با صحبت بالائی توسط شبکه‌های عصبی شناسائی می‌شوند و خطاهای بازشناسی عمدهاً مربوط به همخوان‌هاست. براین اساس در این جا مدل بازشناسی را به این صورت طراحی می‌کنیم که ابتدا توسط یک شبکه عصبی، نواحی واکه و همخوان شناسائی می‌شوند (VCS) و علاوه بر این به منظور تعیین دقیق موقعیت گذرای مابین واکه‌ها و همخوانها یک شبکه عصبی جداگانه توسط سیگنال طوری تعلیم داده می‌شود که برای هر مرز بین دو واج مجاور، یک خروجی شبکه بصورت لحظه‌ای فعال شود و یک پالس باریک مشابه ضربه در خروجی مربوطه بدهد. آزمایشات مقدماتی نشان دادند که شبکه عصبی توانایی خوبی در یادگیری واقعیت صوتی بصورت لحظه‌ای (ضربه‌ای)<sup>۱۰</sup> و ثابت با زمان دارد. هنگامیکه در این روش از شبکه عصبی برای بازشناسی واقعیت لحظه‌ای صوتی استفاده می‌کنیم می‌توانیم برای جبران خطای برچسب‌دهی دادگان، از روش بهترین انطباق نیز استفاده کنیم و شبکه عصبی را هنگام تعلیم و بازشناسی واقعیت ثابت صوتی ابتدا از نظر زمانی با سیگنال منطبق نماییم. با این عمل تنوعات موجود در الگوهای ورودی کاوش یافته و کار بازشناسی توسط شبکه عصبی تسهیل می‌گردد. تحقیقات زبانشناختی، ساختارهای CVCC, CVC, CV را برای هجاهای فارسی مطرح کرده‌اند [۹]. لذا ما ابتدا موقعیت واکه‌ها را به عنوان قلب و مرکز هجا در گفتار مشخص کرده و سپس نوع واکه را مورد شناسائی قرار می‌دهیم. از سوی دیگر به منظور تعیین دقیق نواحی گذرای مرزی مابین آواه، لحظات گذر ما بین آواها را به یک شبکه عصبی با سه خروجی به نحوی تعلیم می‌دهیم که هر خروجی، نوع مرز یعنی VC و CC را نیز مشخص نماید. در آغاز هر واکه بایستی یک خروجی CV بطور لحظه‌ای فعال گردد و در پایان هر واکه نیز خروجی VC باید فعال شود. علت تعیین جداگانه مرز واچ‌ها توسط این شبکه بدست آوردن دقت بالا در تعیین زمان گذر مابین دو واج مجاور است. در برچسب‌دهی خروجی این شبکه بصورت لحظه‌ای برای تعلیم، از یک تابع تقریباً به شکل ضربه به عرض سه فریم و با مقادیر خروجی به ترتیب  $0/0/0$  در خروجی شبکه استفاده می‌کنیم. برای هر مرز دو واج فقط خروجی مربوط به آن مرز یعنی فقط یکی از حالات VC, CV و CC به صورت ضربه فعال می‌شود. بیان خروجی شبکه بصورت ضربه، علاوه بر تعیین دقیق موقعیت زمانی مرز، بار یادگیری تنوعات صوتی در مرزهای واچ‌ها را برای شبکه به حداقل می‌رساند و کار شبکه را آسانتر می‌سازد.

پس از این مرحله، توسط شبکه‌های عصبی جداگانه‌ای نوع همخوان‌های موجود در قبل از واکه (CV) و بعد از واکه (VC) را شناسائی می‌کنیم. در این شناسائی، تعلیم و بازشناسی همخوان ابتدا بصورت ثابت و با توجه به برچسب دادگان انجام می‌شود و سپس به شبکه اجازه داده می‌شود که با استفاده از تکنیک بهترین انطباق، از نظر زمانی ورودی خود را با مرز بین دو واچ در سیگنال گفتار منطبق نماید و بدینوسیله خطاهای موجود در تشخیص انسانی موقعیت زمانی مرز بین واچ‌ها در برچسب‌دهی دادگان را به حداقل برساند و دادگان تعلیم و تست را برای شبکه عصبی بازشناس واضح و شفاف نماید.

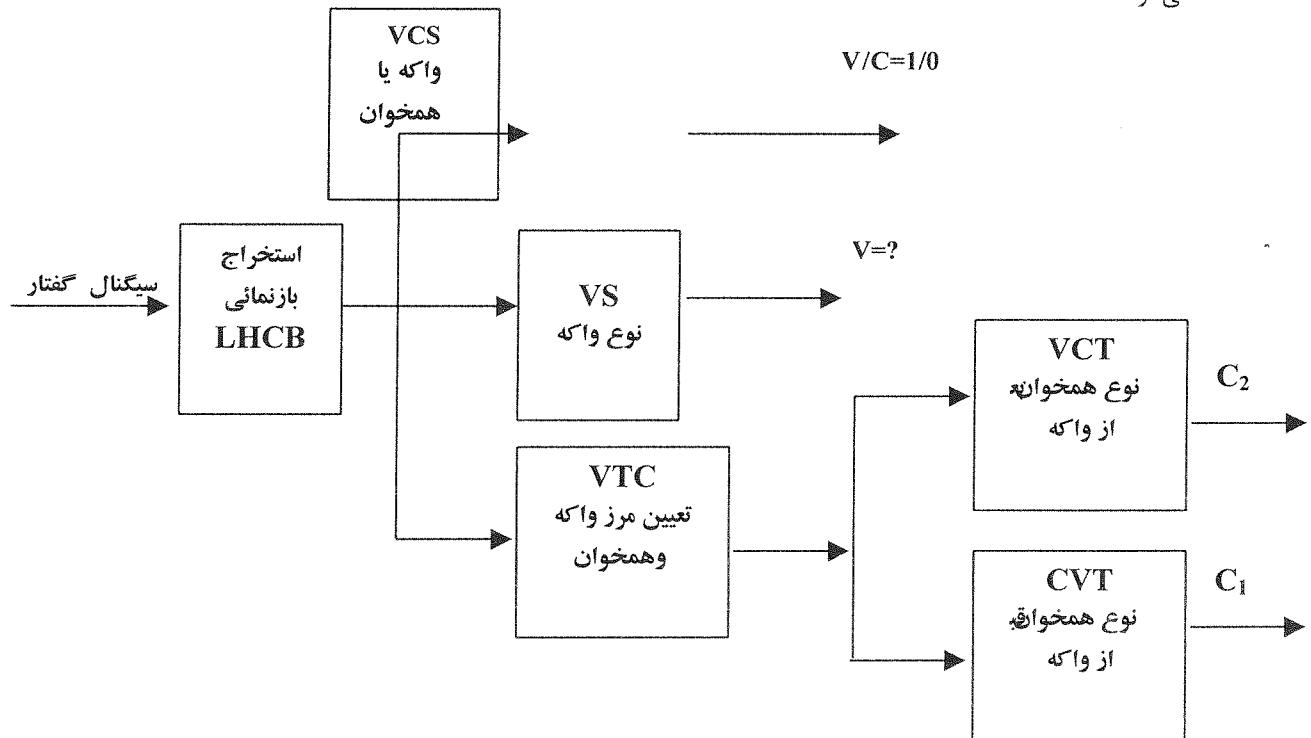
در این مقاله از شناسائی همخوان سوم در هجاهای نوع CVCC که در گفتار محاوره‌ای فارسی کمتر وجود دارد و نقش آن در تشخیص کلمات هم خیلی تعیین کننده نیست فعلًاً صرفنظر کرده‌ایم و عملًاً هجاهای فارسی را محدود به دو نوع CV و CVC در نظر گرفته‌ایم.

## ۱- بازنمایی گفتار

به عنوان بازنمایی در این مقاله ما از پارامترهای LHCb استفاده کرده‌ایم [۲، ۱۰]. بردار بازنمایی حاوی ۱۸ پارامتر است که هر یک لگاریتم انرژی درون یکی از فیلترهای بانک فیلترهای با باندهای بحرانی (CBFB) به شکل مجدور هنینگ به عرض یک در مقیاس فرکانسی بارک<sup>۱۱</sup> می‌باشد. در برخی شبکه‌ها از ۱۸ پارامتر تفاضلی بازنمایی LHCb نیز استفاده کرده‌ایم. عرض پنجره زمانی ۱۰۲۴، گام پیش روی فریمها ۵۱۲ و فرکانس نمونه برداری ۴۴۱۰۰ نمونه در ثانیه است و دادگان مورد استفاده فارسی دات [۱۱] است.

به منظور نرم‌الیزه کردن پارامترهای بازنمایی نسبت به بلندی صدا و فاصله میکروفون ما ابتدا فریم‌های گفتاری را بر حسب

انرژی مرتب می‌کنیم و ۱۰ درصد بالای پر انرژی ترین فریمها را اختیار کرده و میانگین انرژی آنها را محاسبه می‌کنیم و این کمیت را مبنای نرمالیزه و ثابت اختیار می‌کنیم. این به معنی آن است که معیار بلندی صدا در صحبت بیشتر واکه‌های بلند هستند و لذا آنها مبنای قرار داده می‌شوند و از طرفی انرژی موضعی و نسبی فریمها هم که حاوی اطلاعات مفید است حفظ می‌گردد.



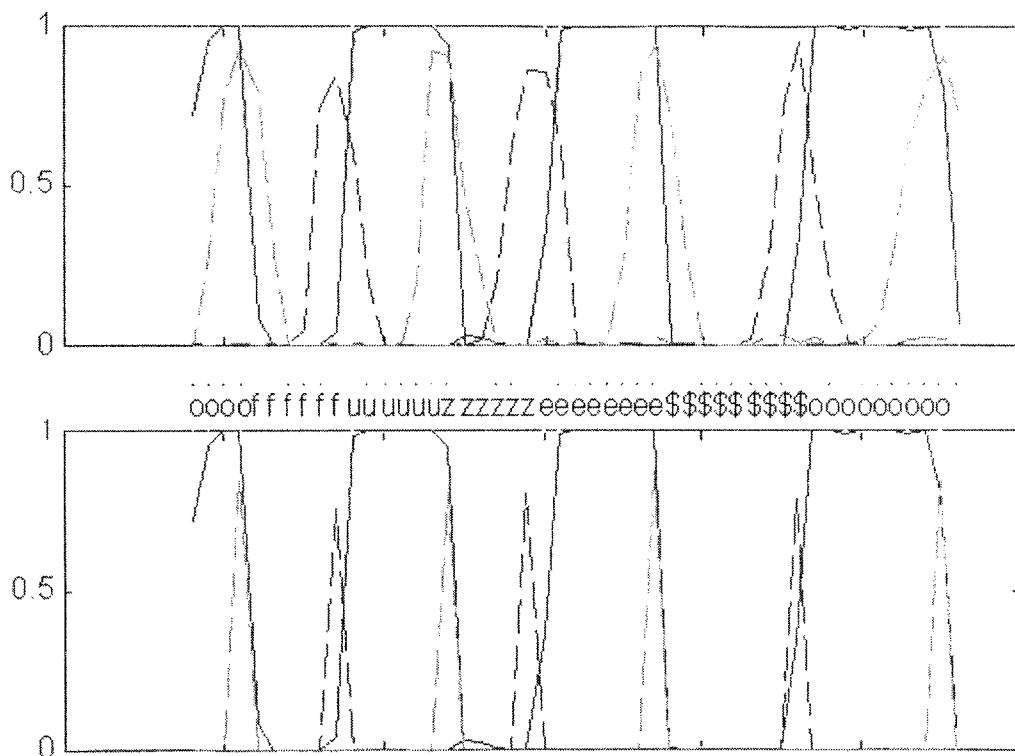
نمودار (۱) نمودار بلوکی و خروجی‌های مدل، VCS: لغزنده (تشخیص واکه یا همخوان بودن)، VS: ثابت با لغزنده (تشخیص نوع واکه)، VTC: لغزنده (تشخیص محل و نوع مرز واکه همخوان)، VCT و CVT و با بهترین انتباق (تشخیص نوع همخوان در قبل و بعد از واکه).

### ۱-۴- شبکه تمیزدهنده واکه - همخوان (VCS)<sup>۹</sup>

شبکه عصبی VCS با ساختار مشابه TDNN و با مقدار گرهای لایه‌ها به ترتیب ۳۷ در ورودی  $32 \times 7$  در لایه پنهان اول (۷ تعداد تأخیر زمانی)، ۶۴ در لایه پنهان دوم و ۱ در خروجی به منظور تمایز واکه از همخوان بکار رفته است. این شبکه روی مسیر زنجیره فریم‌های گفتاری رو به جلو حرکت می‌کند و در هر زمان مشخص می‌کند که ورودی شبکه در یک واکه (۱ در خروجی) و یا همخوان (صفر در خروجی) قرار گرفته است. در اینجا به عنوان ورودی؛ خود بردار بازنمائی، تفاضل دو بردار بازنائی متوالی و انرژی مورد استفاده قرار گرفته‌اند. در این شبکه ۷ فریم متوالی همزمان به شبکه داده می‌شوند که در لایه دوم باهم ترکیب می‌شوند. پس از تعلیم این شبکه با دادگان تعلیم، از آن برای تشخیص واکه و یا همخوان در مدل بارشناستی استفاده کردایم. خروجی این شبکه عمدها برای تجزیه و تحلیل عملکرد مدل از طریق مشاهده موقعیت هر فریم نسبت به واکه یا همخوان بودن آن و تفکیک چشمی قسمتهای مختلف هجایها و واجها و خصوصاً در تحلیل علت خطاهای موجود در عملکرد مدل، مورد استفاده قرار می‌گیرد (نمودار ۲).

### ۱-۵- شبکه تمیزدهنده مکان و نوع مرز بین واج‌ها (VTC)

شبکه عصبی VTC با ابعاد ۳۷ گره در ورودی،  $10 \times 32$  نورون در لایه پنهان اول، ۱۲۸ نورون در لایه پنهان دوم و ۳ نورون در خروجی برای طبقه‌بندی نوع مرزها (CC, CV, VC) بکار رفته است. ۳۷ ورودی در اینجا مشابه شبکه قبل است و ۱۰ فریم متوالی همزمان به شبکه داده می‌شوند (۵ فریم در هر طرف مرز) تا شبکه توان شناسائی دینامیکها را نیز داشته باشد.



نمودار(۲) نمونه عملکرد موفق شبکه VCS (خط پر) و تطابق آن با خروجی‌های VC و شبکه VTC (خط چین).

برچسبدهی خروجی بصورت ضربه باریک می‌باشد که قله ضربه مرز را مشخص می‌کند. برای این منظور ما از مقادیر متوالی ( $0/3, 0, 0/3, 1, \dots, 0, \dots$ ) در هنگام تعلیم شبکه استفاده کرده‌ایم. مقدار ۱ هنگامی در برچسب خروجی مطلوب شبکه داده می‌شود که موقعیت مرز در وسط ده فریم ورودی شبکه قرار می‌گیرد. در نواحی غیرمرزی خروجی‌ها همه صفرند و در مرزها، مقادیر غیرصفر فقط به آن خروجی مربوط به آن مرز داده می‌شود. این نحوه برچسبدهی، شبکه را قادر می‌سازد تا وقایع گذرای صوتی را بصورت ثابت و لحظه‌ای شناسائی کند و موقعیت آنها را نیز تشخیص دهد. علاوه بر این، این امکان به ما داده می‌شود که هنگام تعلیم و تست شبکه با دادگان از روش بهترین انطباق (Best-Matched, B.M.) استفاده کنیم. در بکارگیری این روش M. B. خروجی شبکه برای یک تعداد فریم متوالی بدست آورده می‌شود و سپس این خروجی‌ها با مقادیر برچسب دادگان مربوط به این فریمها از نظر شباهت مورد بررسی قرار می‌گیرند. با لغزاندن این دو الگوی خروجی شبکه و خروجی مطلوب بر رویهم و پیدا کردن بهترین موقعیت انطباق آنها، آنگاه شبکه را با الگوی برچسب خروجی که بهترین انطباق را یافته تعلیم می‌دهیم. با این روش ما اثر خطای موجود در برچسبدهی انسانی دادگان را تا حدی برطرف می‌کنیم و به شبکه این امکان را می‌دهیم که با دادگان واضح‌تر و شفاف‌تری تعلیم ببیند. به این ترتیب پس از تعلیم این شبکه، هنگام بازشناسی مرزها این شبکه بر روی فریم‌های متوالی به جلو حرکت می‌کند و برای هر مرز بین دو واج یکی از خروجی‌هایش فعال می‌شود و ضمن تعیین موقعیت مرزها، نوع مرز (CC, CV, VC) نیز توسط خروجی تعیین می‌گردد. ما به این تعیین نوع مرز از آن جهت نیاز داریم که بتوانیم نوع شبکه مربوط به آنرا برای تشخیص همخوان مجاور مرز مورد استفاده قرار دهیم.

با داشتن خروجی‌های این شبکه عملاً ساختار هجائی گفتار در اختیار ما قرار می‌گیرد (CVCC, CVC, CV) و برای انواع هجاهای به صورت دنباله‌ای متشكل از واکه‌ها (V) و همخوان‌ها (C) قابل نمایش می‌باشد. به کمک دو شبکه فوق عملاً ما می‌توانیم سیگنال گفتار را تنظیع واجی و هجائی نمائیم و به بیان دیگر موقعیت مکانی انواع وقایع صوتی موردنظر در اینجا (CC, CV, VC) را مشخص نمائیم. به نظر ما این نحوه برخورد در بازشناسی گفتار با واقعیت غیرخطی سیگنال گفتار تناسب بیشتری دارد. با این شیوه طراحی مدل شبکه عصبی ما توان آن را برای تحمل سرعتهای مختلف گفتار افزایش می‌دهیم و به مدل نسبت به تغییرات طول واج‌های پیوسته قدرت انعطاف بیشتری می‌دهیم.

## ۱-۴- شبکه واکه‌شناس (VS)

پس از مشخص شدن موقعیت واکه‌ها و همخوان‌ها می‌توانیم شناسائی نوع واکه‌ها و همخوان‌ها را انجام دهیم. به منظور تشخیص نوع واکه به دو راه می‌شود عمل کرد یکی اینکه یک شبکه عصبی بصورت ثابت روی واکه قرار گیرد و آنرا شناسائی نماید و دیگر اینکه مشابه روشی که برای تشخیص واکه یا همخوان بودن گفتار بکار گرفتیم، از یک شبکه عصبی که بر روی مسیر فریمهای گفتار به جلو می‌لغزد و بر حسب اینکه روی چه واکه‌ای قرار دارد خروجی مربوط به آن یک می‌شود، استفاده کنیم. در اینجا ما از روش اول استفاده می‌کنیم (شبکه VS). بعد این شبکه به ترتیب: ۳۷ گره در ورودی،  $10 \times 32$  نورون در لایه پنهان اول (۳۲ نورون برای هر فریم و  $10$  فریم متواالی به شبکه داده می‌شوند)،  $128$  نورون در لایه پنهان دوم و  $6$  نورون به تعداد واکه‌ها در خروجی، می‌باشند. خروجی شبکه نوع واکه را مشخص می‌کند و فریم اول ورودی این شبکه روی فریم اول واکه قرار داده می‌شود. با داشتن نوع واکه، کار بعدی ما این است که همخوانها را شناسائی کنیم.

در هجاهای فارسی ما سه نوع مدل هجایی داریم CVC, CV و CVCC. بر این اساس یک همخوان در یکی از موقعیت‌های  $C_1$  و  $C_2$  و  $C_3$  در این سه مدل هجایی می‌تواند قرار بگیرد. قبل از واکه  $C_1V$  در هر سه مدل، بعد از واکه در مدل دوم و سوم  $C_1VC_2$  و به عنوان همخوان سوم در مدل هجایی  $C_1VC_2C_3$ . ما این همخوان‌ها را توسط شبکه‌های ثابت جداگانه مورد تعلیم و شناسائی قرار می‌دهیم.

## ۱-۵- شبکه بازشناس نوع همخوان در موقعیت قبل از واکه (CVT)

برای این هدف از یک شبکه عصبی به بعد  $19$  گره در ورودی  $32 \times 11$  نورون در لایه پنهان اول،  $128$  نورون در لایه پنهان دوم و  $23$  نورون در خروجی استفاده می‌کنیم. تعداد  $23$  نورون در خروجی به تعداد  $23$  همخوان زبان فارسی انتخاب شده که در وضعیت CV می‌توانند بیایند. تعداد فریم اختیار شده در دو طرف مرز CV به تعداد  $7$  فریم در سمت همخوان و  $4$  فریم در سمت واکه می‌باشد. این شبکه بر روی مرزهای CV بصورت ثابت شده، طوری تعلیم داده می‌شود که بتواند در خروجی نوع همخوان قبل از واکه را شناسائی نماید. در تعلیم و بازشناسی این شبکه نیز از روش بهترین انطباق استفاده می‌کنیم. در اجرای روش بهترین انطباق برای تعلیم و تست باید توجه داشت که گاهی ممکن است دو مرز خیلی به هم نزدیک باشند و این موضوع را در برچسبدهی باید اعمال نمود. برچسبدهی در خروجی این شبکه هم بصورت ضربه باریک و لحظه‌ای می‌باشد. وقتیکه این شبکه در روی یک مرز CV قرار می‌گیرد بسته به اینکه نوع همخوان چه باشد یک خروجی از خروجی‌های آن که مربوط به آن همخوان است بصورت لحظه‌ای فعال می‌گردد و بقیه غیرفعال باقی می‌مانند. این شبکه وظیفه دارد که در روی مرزهای CV بصورت یک ضربه باریک در خروجی، نوع همخوان را شناسائی نماید. یک نکته که در دل این نحوه شناسائی همخوان نهفته است این است که در خیلی موارد اطلاعات مفیدی مرتبط با نوع همخوانها در سیگنال صوتی، در نواحی گذرای سیگنال هنگام ورود و خروج به آن همخوان، وجود دارد خصوصاً در مواردی که واج مجاور یک واکه باشد. با این روش خواسته‌ایم که این اطلاعات را از سیگنال صوتی استخراج نمائیم. نتایج پیاده‌سازی این شبکه نکات جالبی را دربردارد. هنگامیکه موقعیت مرز واج‌ها بدون خطای تشخیص داده شده باشد یعنی از خود برچسب‌های دادگان برای تعیین محل مرز CV در تعلیم و تست استفاده می‌کنیم، میزان صحت بازشناسی همخوان‌ها در حالت مستقل از گوینده بسیار بالا یعنی برابر  $85\%$  است.

همچنین درصد مواردیکه همخوان صحیح در یکی از دو انتخاب اول یا دوم باشد  $91/2\%$ ، درصد مواردیکه همخوان صحیح در یکی از سه انتخاب اول تا سوم باشد  $94/5\%$  و در یکی از چهار انتخاب اول برابر  $96/7\%$  است. این نتایج دو نکته را دربر دارد. اول اینکه نشان می‌دهد منشأ شناسائی غلط همخوان‌ها در روش‌های متعارف، عمدهاً به تشخیص غلط مرزهای CV و VC بر می‌گردد که یا محل آنها درست شناسائی نمی‌شود و یا اینکه مرز حذف شده و یا اینکه مرزهای CV و VC اضافی در مسیر گفتار درج شده است. و دوم اینکه اگر فضای شناسائی همخوان یا فضای تصمیم‌گیری بتواند به تعداد کمی از همخوان‌ها به طریقی محدود بشود، صحت بازشناسی بسیار بالا خواهد رفت. و این نکته مهمی است که بنظر می‌رسد سیستم ادراک انسان نیز به کمک آن به صحت بازشناخت بالائی در واج‌ها می‌رسد. در رابطه با این دو نکته در قسمت بررسی خطاهای مدل بیشتر صحبت خواهیم کرد.

## ۱-۶- شبکه بازشناسی نوع همخوان در موقعیت بعد از واکه (VCT)

شبکه مورد استفاده در اینجا تقریباً مشابه مورد قبلی است، با این تفاوت که این بار در ورودی ۷ فریم مربوط به همخوان در سمت راست قرار می‌گیرد و مورد دیگر نیز اینکه تعداد خروجی‌های شبکه در این حالت ۲۰ می‌باشد. علت این کاهش تعداد همخوان‌ها در اینجا این است که واچ‌های انفجاری واکار و بیواک دو بدو در قسمت ورود به واچ (بست واج) یکسان هستند. به عنوان مثال ماهیت صوتی سیگنال در دو مرز واچی «ab» و «ap» مشابه است و تفاوت دو واچ b و p عمدهاً در ناحیه رهش آن است. ولذا در خروجی این شبکه که از اطلاعات مربوط به ناحیه گذرای مرز VC نوع همخوان را مشخص می‌کند دو مرز فوق با یک خروجی مشخص می‌شوند در مواقعی که یک همخوان مابین دو واکه قرار می‌گیرد آنرا  $C_1$  درنظر گرفته و با کمک هر دو شبکه VCT و آنرا شناسائی و نتایج را باهم ترکیب می‌کنیم که در این حالت صحت بازشناسی نسبتاً بالاست. در حالاتی که دو یا سه همخوان در مابین دو واکه قرار می‌گیرند و به عنوان  $C_3$  و  $C_2$  و  $C_1$  باید شناسائی شوند ( $VC_2C_3C_1V$ ) خطای نسبتاً زیاد است. در چنین حالتی از یک شبکه‌ای که روی مرزهای CC ثابت و منطبق شود دو همخوان دوطرف این مرز را شناسائی نماید نیز می‌توانیم کمک بگیریم. در هر حال در این موارد خطای بازشناسی در تعداد و محل مرزهای CC و نوع همخوان‌ها نسبتاً زیاد است.

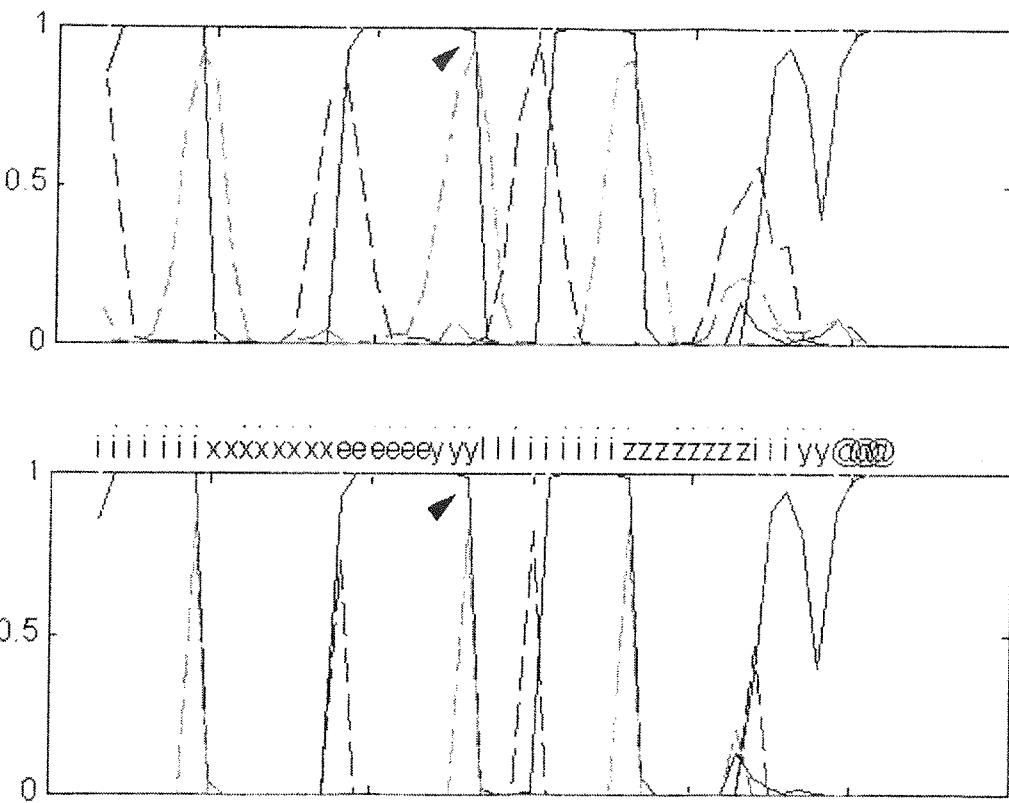
## ۲- تحلیل نتایج پیاده‌سازی مدل و آنالیز خطاهای بازشناسی

همانطور که قبلاً نیز اشاره کردیم صحت بازشناسی همخوانهایی که در مجاورت واکه قرار دارند توسط دو شبکه VCT و CVT، هنگامی که در تعیین مکان مرزهای CV و VC خطای نداشته باشیم در حدود ۸۵٪ بدست آمده است و این برای همخوان‌ها که نوعاً ضعیفتر از واکه‌ها شناسائی می‌شوند در سطح خوبی است.

مشاهده نتایج عملکرد شبکه VCS نشان می‌دهد که عملاً در موقعیت مشخصی این شبکه با مشکل مواجه است. یکی از این موارد در واچ‌های «i» و «y» است. وقت در محتوای صوتی این دو واچ نشان می‌دهد که در نواحی ایستان سیگنال گفتار این دو واچ مشابه هستند و آنچه که موجب تمیز دادن آنها از هم می‌شود به واچ‌های قبل و بعد آنها برمی‌گردد. ما این نکته را هنگام ادراک و شنیدن دو هجای «al» و «mil» می‌توانیم درباییم. ولذا در نواحی ایستان، هر دو واچ «y» و «i» باید در شبکه با یک خروجی بیان شود تا شبکه با تنافق روبرو نشود.

این نکته اساس مدل‌های هجایی بر مبنای C-V را تا حدی متزلزل می‌کند و نشان می‌دهند که انتساب «y» به عنوان همخوان و «i» به عنوان واکه که با توجه به ادراک انسان بوده با ماهیت کمی دو سیگنال در آنالیز مهندسی تطابق ندارد (نمودار ۳).

به عبارت دیگر این بررسی نشان می‌دهد که برخی نکات نظری زبانشناسی با نتایج پیاده‌سازی‌های کمی و مهندسی کاملاً تطبیق نمی‌کنند و نیاز است که پیاده‌سازی مهندسی نظریات زبانشناسی، به روش‌های هوشیارانه‌تری انجام پذیرد. یک نکته در این رابطه این است که عملاً مدل بازشناس بایستی قادر باشد که واچ قبل و بعد را نیز درنظر بگیرد و نکته دیگر اینکه برای ترکیب اطلاعات نواحی گذرا با نواحی ایستان آواها، استفاده از مدل همخوان - واکه V-C چندان مناسب نیست و بهتر است که از مدل‌های بر مبنای شناسائی مرزهای مابین هر دو واچ معین بصورت جداگانه استفاده کنیم که این به معنی شناسائی توازن دوآواها<sup>۱۱</sup> و نواحی ایستان گفتار توسط شبکه‌های عصبی خواهد بود. برای این منظور ما پیشنهاد می‌کنیم که برای عملکرد بهتر مدل، نواحی مرزی آواها باید برای هر دو واچ مشخص بصورت جداگانه، ثابت و با بکارگیری روش بهترین انطباق مورد تعلیم و بازشناسی قرار گیرند و نواحی ایستان آواها نیز توسط شبکه‌ای جداگانه بصورت طی مسیر بردار بازنمایی شناسائی شوند و نتایج این‌ها برای هر آوا در یک شبکه عصبی مدولار و سلسله مراتبی بایستی ترکیب گردد. این روش این امکان را می‌دهد که اطلاعات نواحی گذراها را با کیفیت بالائی حفظ و استخراج نمائیم و با اطلاعات سایر نواحی ترکیب کنیم. از سوی دیگر با محدود کردن فضای جستجو در بازشناسی مرزها به هر دو واچ مجاور، امکان تعلیم و شناسائی دقیق‌تر در مدل بازشناسی آواها در یک فضای تضمین‌گیری بهینه فراهم می‌گردد.



نمودار(۳) خطای شبکه VCS در طبقه بندی «i» و «y» به عنوان واکه یا همخوان.

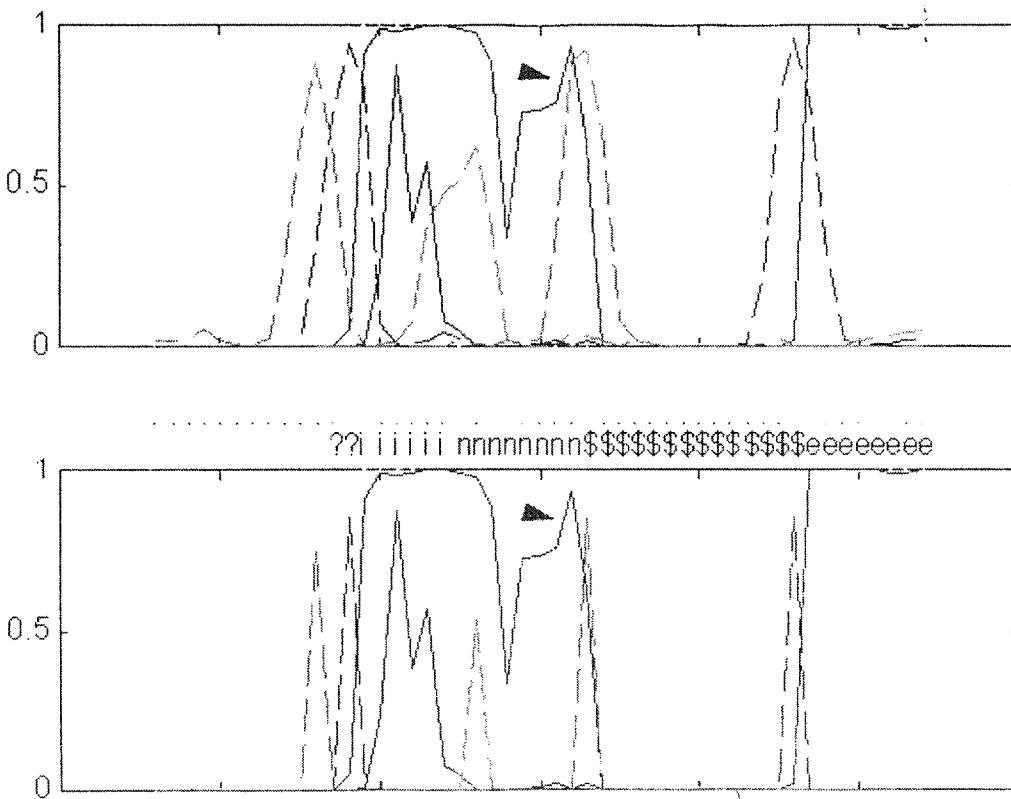
مشکل موجود در تفکیک دو واچ «y» و «i» باعث می‌شود که تشخیص مرزهای CV و VC توسط شبکه VTC نیز دچار اشکال شود و مرزهای CV و VC زائد در مسیر سیگنال درج گردد. از موارد دیگر خطای موجود در عملکرد این مدل این است که گهگاه همخوانهای شبه واکه<sup>۱۲</sup>، مانند «v»، «m»، «n»، «l» و «r» اکه خصوصاً «u» تشخیص داده می‌شوند و لذا مرز VC یا حذف شده و یا به بعد از این همخوانها منتقل می‌گردد. حذف مرزهای VC و یا CV در مسیر سیگنال عملکرد مدل را دچار اختلال می‌کند و موجب شناسائی غلط واچ‌ها می‌گردد. شناسائی مرز CV عمدتاً با دقت و صحت بالائی همراه است و لذا می‌تواند مبنای شناسائی هر هجا قرار گیرد. در شناسائی سایر واچ‌ها، مدل غالباً با کیفیت خوبی عمل می‌کند و واچ‌ها و هجاها را استخراج می‌نماید. در مرز ما بین همخوانهای شبه واکه با سایر همخوانها گاهی خروجی‌های CV و یا VC فعال می‌شوند و مشابهت شبه واکه‌ها با واکه‌ها ایجاد مشکل می‌نماید. همچنین نواحی میانی شبه واکه‌های طولانی، در برخی موارد واکه شناخته شده است.

خطاهای دیگری که در عملکرد این مدل مشاهده می‌شود وجود یک واکه کوتاه بعد از همخوانهای ساکن خصوصاً همخوان «r» و همچنین همخوانهای «q»، «k»، «h»، «l»، «n»، «y» است (نمودار ۴ و ۵).

عملأً ما در هنگام بیان این همخوانها در وضعیت ساکن در کلمات غالباً یک واکه کوتاه به دنبال آن می‌آوریم. این واکه کوتاه می‌تواند موجب درج یک هجا اضافی در این مدل در مسیر سیگنال گفتار بشود. در برخی نواحی از سیگنال، همخوان «v» با واکه «u» اشتباه می‌شوند و این به دلیل نزدیک بودن وضعیت ناحیه صوتی هنگام بیان این دو واچ است. نتیجه بسیار مهمی که از بررسی این خطاهای می‌توان فهمید این است که سیستم ادراک گفتار انسان، آواها را فقط براساس محتوای صوتی موضعی آنها شناسائی نمی‌کند بلکه آواهای مجاور بطور ناخودآگاه در شناسائی هر آوا دخالت می‌کند و هر آوا با توجه به موقعیت آن در زنجیره آواهای اطراف خود<sup>۱۳</sup> شناسائی می‌گردد. لذا در طراحی مدل‌های آتی بازناسی آواها و هجاها به این نکته مهم بایستی توجه نمود. به همین دلیل ما برای شناسائی هر آوا، بکارگیری اطلاعات قسمتهای ایستان و گذرای اطراف آنرا در یک شبکه عصبی مدولار و سلسله مراتبی پیشنهاد کرده‌ایم.

علاوه بر این، تحلیل نتایج پیاده‌سازی ما نشان می‌دهد که اگر سیگنال صوتی را زنجیره‌ای از وقایع و حالت‌های بدنbal هم در یک پردازش بر مبنای سیستم‌های وقایع گسسته<sup>۱۴</sup> درنظر بگیریم این مدل با ماهیت گفتار تناسب بهتری خواهد داشت.

ضرورت تحمل تغییرات طول آوا در حین صحبت با سرعت‌های متفاوت نیز دلیلی بر تأیید این مطلب است. برای این منظور ما بکارگیری شبکه‌های عصبی با تأخیرهای زمانی متغیر و سنکرون با وقایع را پیشنهاد می‌کنیم. ما در این رابطه مدلی طراحی و پیاده‌سازی کردۀایم که در یک مقاله جداگانه نتایج آنرا خواهیم آورد. در چنین مدلی امکان استخراج طول زمانی آواها به عنوان

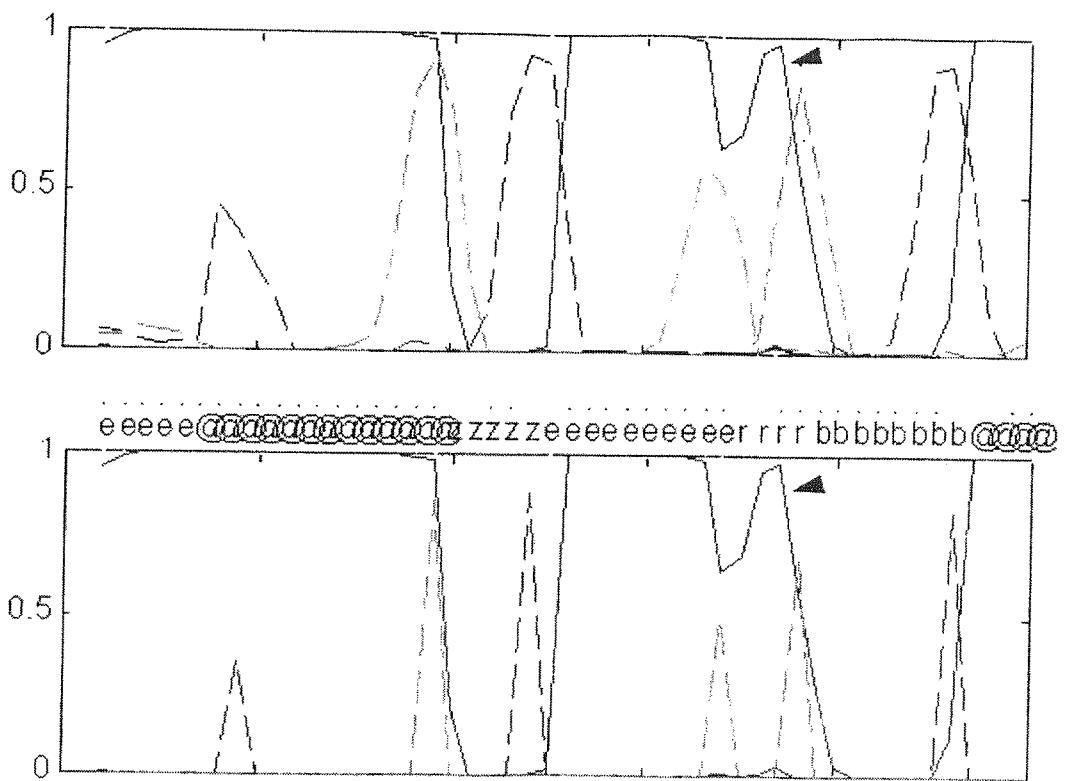


نمودار(۴) خطای در شناسایی «ن» به عنوان همخوان و درج یک واکه مجازی بعد از همخوان «ن» ساکن.

یک اطلاعات مفید نیز فراهم می‌شود و همچنین اطلاعات زنجیره وقایع<sup>۱۵</sup> و حالات<sup>۱۶</sup> گذشته می‌تواند به نحو مناسبی در جهت محدود کردن فضای جستجو و تصمیم‌گیری هنگام بازنگشتنی هر آوا و یا واقعه جدید بکار گرفته شود. این بوسیله روش بکارگیری شده در این مقاله همچنین می‌توان مستقیماً هجا را به عنوان واحد زبانی پایه شناسائی نمود. این عمل بوسیله وارد کردن نتایج شبکه‌های بازنگشتنی VCT, CVT, VS بصورت یکجا در یک ساختار شبکه عصبی واحد بصورت مدولار، امکان پذیر می‌گردد. نکته‌ای را هم که در اینجا می‌توان ذکر کرد این است که اگر ما بتوانیم موارد درج و حذف مرزهای CV و VC را در مدل به طریقی از بین ببریم و بدینوسیله مشکل حذف و یا افزایش هجا را حل نماییم آنگاه با این مدل ما قادر به خواهیم بود به درصد صحت بازنگشتنی واج و هجای بالائی دست یابیم و لذا باید به دنبال روش‌هایی باشیم که مانع از درج مرزهای اضافی و یا حذف مرزهای موجود در سیگنال بشوند. یک راه حل ممکن برای این مسئله، رفع مشکل واج‌های «y» و «z» و نیز دخالت دادن طول واکه برای تفکیک واکه‌های واقعی از واکه‌های کوتاه به غلط درج شده می‌باشد. در صورت وصول به چنین هدفی آنگاه می‌توانیم امید داشته باشیم که به صحت بازنگشتنی واج مستقل از گوینده حدود ۸۵ تا ۹۰ درصد بتوان رسید.

### ۳- جمع‌بندی

بررسی نتایج روش‌های رایج بازنگشتنی گفتار نشان داده‌اند که اطلاعات گفتاری مفید و قابل ملاحظه‌ای را از نواحی گذرای مرزی آواها می‌توان استخراج کرد. برای این منظور ما از شبکه‌های عصبی بصورت ثابت شده بر روی مرز و با بکارگیری روش بهترین انطباق استفاده می‌کنیم تا تلفات اطلاعات را در مرزها به حداقل برسانیم. سپس نتایج بازنگشتنی نواحی گذرای مرزی



نمودار(۵) درج واکه مجازی بعد از همخوان «۲» ساکن.

آواها را با نتایج شناسائی نواحی ایستان آواها به نحو مناسب ترکیب می‌کنیم. برای مشخص کردن مرزهای واکه‌ها و همخوان‌ها ما از شبکه عصبی با خروجی ضربه‌ای استفاده کردی‌ایم. ترکیب مناسب نتایج ما را به صحبت بازشناسی واج برتری می‌رساند. برای عملکرد بهتر این مدل ما درنظر داریم که بجای تشخیص مرزهای واکه‌ها و همخوان‌ها، مرزهای مربوط به هر دو واج معین را شناسائی کنیم و به این وسیله خطای عملکرد مدل را کاهش دهیم. ترکیب مناسب نتایج بازشناسی وقایع صوتی متوالی می‌تواند با محدود کردن فضای جستجو و تصمیم‌گیری، صحبت بازشناسی بالاتری را به ما بدهد. بکارگیری روش‌های مناسب جلوگیری از درج و حذف واکه‌ها و نیز مرزهای CV و VC زائد، می‌تواند به ما کمک کند تا به درصد صحبت بازشناسی واج مستقل از گوینده بالائی در حدود ۸۵٪ بررسیم.

## ۵- قدردانی

این تحقیق با حمایت و همکاری پژوهشکده پردازش هوشمند علائم به انجام رسیده است.

### زیرنویسها

- ۱-Phoneme
- ۲-Segmentation
- ۳-Maximum
- ۴-Minimum
- ۵-Articulators
- ۶-Syllabic
- ۷-Impulsive
- ۸-Bark Scale
- ۹ - دراین نامگذاری بلوکها با حروف مخفف، V برای واکه، C برای همخوان، S برای نواحی یکنواخت و T برای نواحی گذرا مورد استفاده قرار گرفته‌اند.
- 10-Release
- 11-Diphones
- 12-Semi-Vowels
- 13-Context
- 14-Discrete event systems
- 15-Events
- 16-States

## مراجع

- [1] Glaeser, A. "Modular Neural Networks with Task-Specific Input Parameters for Speaker Independent Speech Recognition", Proceedings of the ESCA. EUROSPEECH'95, pp. 1655 - 1658, Madrid, (1995).
- [۲] سید صالحی، س.ع، بازناخت گفتار پیوسته فارسی با استفاده از مدل عملکردی مغز انسان در درک گفتار، پایان نامه دکتری، دانشگاه تربیت مدرس، تهران، ۱۳۷۴.
- [۳] سید صالحی، س.ع. و همکاران، بررسی عملکرد شبکه های عصبی TDBP در بازناخت مستقل از گوینده و اح های فارسی، مجموعه مقالات کنفرانس بین المللی سیستم های هوشمند و شناختی، ص ۲۹-۲۴، ۱۳۷۵.
- [۴] سید صالحی، س.ع. و همکاران، بازناسی مستقل از گوینده و اح های فارسی با استفاده از مشخصه های تولیدی، مجموعه مقالات کنفرانس بین المللی سیستم های هوشمند و شناختی، ص ۹۷-۹۳، ۱۳۷۵.
- [۵] Yu, H.-J., oh, Y.-H. "A Neural Network Using Nonuniform Units for Continuous Speech Recognition", Proc. of EUROSPEECH'95, Vol. 3, pp. 1677-1680, Madrid (1995).
- [۶] Yu, H.-J., oh, Y.-H. "A Neural Network Using Acoustic Sub-word Units for Continuous Speech Recognition", Proc. of ICSLP'96, pp. 506-509 (1996).
- [۷] Morgan, N., et al. "Stochastic Perceptual Auditory-Event-Based Models for Speech Recognition", Proc. of ICSLP'94, pp. 1943-1946, Yokohama (1994).
- [۸] Duez, D. "Effects of Articulation Rate on Duration in Read French Speech", Proc. of EUROSPEECH'99-CD, Budapest (1999).
- [۹] بی جن خان، م.، بازنامی واجی و آوائی زبان فارسی و بکارگیری آن در بازناخت خودکار گفتار، پایان نامه دکتری، گروه زبان شناسی، دانشگاه تهران، تهران، ۱۳۷۴.
- [۱۰] سید صالحی، س.ع. و همکاران، ارزیابی عملکرد شبکه های عصبی در بازناسی مستقل از گوینده و اح ها با استفاده از چند بازنامائی الهام گرفته از سیستم شنواری، مجموعه مقالات سومین کنفرانس الکترونیک، ص ۱۱۴-۱۲۵، ۱۳۷۴، دانشگاه شیراز.
- [۱۱] Bijankhan, M., et al. "FARSDAT-The Speech Database of Farsi Spoken Language", Proceedings of SST-94, pp. 826-831, Perth, (1994).