



مدل‌سازی نوای گفتار کانونی در فارسی: رویکردی تولیدی - نقش‌گرا*

مرتضی طاهری اردلی^۱

مصطفی عاصی^۲

حسین صامتی^۳

محمود بی‌جن‌خان^۴

چکیده

مقاله حاضر تلاشی است در جهت مدل‌سازی نوای گفتار کانونی فارسی که با اتخاذ رویکردی تولیدی - نقش‌گرا یعنی رمزگذاری موافقی و تقریب هدف (PENTA) انجام شده است. داده‌های مورد استفاده برای مدل‌سازی شامل ۱۵۰ پاره گفتار است که در شرایط مختلف کانونی و غیرکانونی تولید شده‌اند. در راستای رسیدن به این هدف، از بازسازی کننده PENTAtainer2 تحت نرم‌افزار Praat استفاده شده است. این بازسازی کننده در قالب رویکرد PENTA تولید شده است. از اهداف زیرو逼ی مقوله‌ای را بهینه می‌کند که هر یک از این اهداف با نقش‌های ارتباطی خاصی مرتبط می‌باشدند. ارزیابی عینی از مقایسه منحنی بسامدپایه بازسازی شده با منحنی بسامدپایه طبیعی حاکی از آن است که منحنی بازسازی شده با خطای جذر میانگین مربعات $1/94$ و میزان ضریب همبستگی 0.84 ، به منحنی طبیعی شباهت بسیار دارد. همچنین ارزیابی ذهنی از جایگاه کانون و همچنین قضاؤت آزمودنی‌ها از میزان طبیعی بودن صدای‌های بازسازی شده، نشان دهنده شباهت بسیار زیاد هر دو منحنی طبیعی و بازسازی شده است.

کلیدواژه‌ها: رمزگذاری موافقی، تقریب هدف، بازسازی، کانون، بسامدپایه.

* این مقاله برگرفته از رساله دکترای نگارنده است.

۱- دانشجوی دکتری پژوهشگاه علوم انسانی و مطالعات فرهنگی

۲- استاد پژوهشگاه علوم انسانی و مطالعات فرهنگی

۳- دانشیار دانشگاه صنعتی شریف

۴- استاد دانشگاه تهران

مقدمه

نوای گفتار به عنوان بخش اصلی و جدایی‌نپذیر گفتار همواره چالشی برای علم فناوری گفتار بوده است. برای نمونه، تولید نوای گفتار طبیعی در سیستم‌های تبدیل متن به گفتار^۱ هنوز به عنوان یک مسئله حل نشده باقیمانده است. پاسخی قانع کننده به این مسئله، نه تنها کمک شایانی به پیشرفت فناوری گفتار می‌کند بلکه درک فرایند گفتار را برای دیگر محققان در این زمینه هموار می‌کند. در سالیان گذشته، در راستای حل این مسئله زبان‌شناسان و متخصصین پردازش گفتار نظریه‌ها و الگوهای مختلفی ارائه کرده‌اند. در اوایل دهه هشتاد از قرن بیستم، رویکرد خود واحد - وزنی^۲ به عنوان معتبرین رویکرد زبان‌شناسی به عناصر زبرزنگیری، به معروفی چارچوبی پرداخت که با استفاده از آن بتوان الگویی نظری برای آهنگ گفتار زبان‌های مختلف ارائه داد. نخستین بار پیرهامترب^۳ (۱۹۸۰) چارچوب کلی و مقایمه نظری این رویکرد را معرفی کرد. این رویکرد بعدها چار تعديل‌هایی شد اما مبانی اولیه و اصول نظری آن بدون تغییر تا به امروز باقی‌مانده است. در این چارچوب از دو نواخت بالا^۴ و پایین^۵ برای توصیف آهنگ استفاده شده است که در قالب نواخت‌های مرزنما^۶ و تکیه‌های زیروبمی^۷ تجلی پیدا می‌کنند. حاصل تحقیقات گسترده در این زمینه معرفی نظامی برچسب‌گذاری است که نخستین بار برای زبان انگلیسی امریکایی تحت عنوان برچسب‌گذاری نواخت‌ها و فاصله‌نماها^۸ تدوین شده است (سیلورمن^۹ و همکاران، ۱۹۹۲). یکی از دلایل معرفی چنین نظامی به منظور بهره‌برداری از آن در مدل‌سازی نوای گفتار در سیستم‌های TTS بوده است که در دهه پایانی قرن پیش، توجه بسیاری از محققین این حوزه را به خود جلب کرد و تلاش‌های بسیار در این زمینه به‌ویژه برای زبان انگلیسی صورت گرفت. در فارسی، طاهری اردلی و خرم (۱۳۹۱) در پژوهشی با استفاده از نظام توصیفی ارائه‌شده در قالب رویکرد خود واحد - وزنی که سادات‌تهرانی (۲۰۰۷) پیشنهاد کرده است، به پیاده‌سازی نوای گفتار در یک سیستم بازسازی گفتار^{۱۰} با پشتونه دادگانی مشتمل بر ۱۳۰۰ پاره گفتار پرداختند. این سیستم که پیاده‌سازی آن مبتنی بر مدل مخفی مارکوف^{۱۱} بوده است، کیفیت خروجی آن با میانگین امتیازات نظردهی^{۱۲} ۴۶ ارزیابی شده است.

-
1. text-to-speech system (TTS)
 2. Auto segmental-Metrical
 3. Pierrehumbert
 4. high tone (H)
 5. low (L)
 6. boundary
 7. pitch accent
 8. Tones and Break Indices (ToBI)
 9. Silverman
 10. speech synthesis
 11. Hidden Markov Model (HMM)
 12. Mean Opinion Score (MOS)

رویکرد فوجی‌ساکی^۱ چارچوبی دیگر است که با نگرشی نسبتاً متفاوت، به صورت جمع آثار^۲ به توصیف دقیقی از منحنی سامدپایه^۳ پرداخته است (فوجی‌ساکی و ناگاشیما^۴، ۱۹۶۹؛ فوجی‌ساکی و هیروسه^۵، ۱۹۸۴). ورودی این الگو در قالب تکانه‌ها^۶ و توابع پله‌ای^۷ است که به ترتیب برای تولید گروه^۸ و تکیه زیروبیمی به عنوان دو مولفه اصلی این رویکرد، مورد استفاده قرار می‌گیرند. هر گروه با یک تکانه آغاز می‌شود که با عبور از صافی درجه دوم میرا^۹ باعث می‌شود تا منحنی سامدپایه به ارزش حداکثری خود برسد و سپس رو به زوال حرکت کند. اما تکیه زیروبیمی با استفاده از یک تابع پله‌ای آغاز می‌شود و زمانی که این تابع از صافی عبور می‌کند پاسخ‌هایی را تولید می‌کند. از جمع آثار و ترکیب همزمان دو مولفه گروه و تکیه زیروبیمی به همراه ارزش مبنای^{۱۰} بسامدپایه، منحنی نهایی بدست می‌آید. این رویکرد برای زبان‌های بسیاری مورد آزمایش قرار گرفته است. در فارسی، نهبات و کوچاری (۱۳۸۶) با استفاده از پایگاهدادگان^{۱۱} فارس‌داد بزرگ (بی‌جن‌خان، ۱۹۹۴) به استخراج خودکار پارامترهای فوجی‌ساکی پرداختند. نتایج تحقیق آنها نشان می‌دهد که بازسازی نوای گفتار فارسی با حداقل پارامترها یعنی بدون نیاز به فرمان^{۱۲} تکیه زیروبیمی نیز عملی است. در پژوهش آنها، مقایسه منحنی طبیعی و منحنی تولیدی، ضریب همبستگی^{۱۳} حدود ۹۷ درصد و خطای جذر میانگین مربعات^{۱۴} برابر با ۴/۶۵ هرتز را نشان می‌دهد.

یکی دیگر از رویکردها با نگرشی مهندسی به نوای گفتار، تیلت^{۱۵} است (تیلور، ۱۹۹۲؛ ۲۰۰۰). این الگو، آهنگ گفتار را به عنوان مجموعه‌ای از رخدادهای نواختی در نظر می‌گیرد. در این الگو، به مانند رویکرد خود واحد – وزنی از دو نوع رخداد یعنی تکیه زیروبیمی و نواخت مرزنما استفاده می‌شود اما برخلاف خود واحد – وزنی که از مجموعه‌ای ثابت از مقوله‌ها بهره می‌گیرد، از پارامترهای پیوسته استفاده می‌کند. هر یک از این رخدادها از دو بخش خیز^{۱۶} و افت^{۱۷} تشکیل شده است و بین آنها خطوط مستقیمی وجود دارد که خطوط اتصال^{۱۸} نامیده می‌شوند. تنوع و تفاوتی که در تکیه زیروبیمی و نواخت مرزنما وجود دارد تحت تاثیر اندازه

-
1. Fujisaki
 2. Super positional
 3. F0 contour
 4. Nagashima
 5. Hirose
 6. impulse
 7. step function
 8. phrase
 9. damped second order filter
 10. baseline
 11. database
 12. command
 13. correlation
 14. Root Mean Square Error (RMSE)
 15. Tilt
 16. rise
 17. fall
 18. connection

نسبی خیز و افتهاست و اینکه چگونه این رخدادها با عناصر زنجیری گفتار برهم‌نهاده^۱ می‌شوند. در مجموع، Tilt شش پارامتر را شامل می‌شود. چهار پارامتر که شکل رخدادها را توصیف می‌کند و دو پارامتر دیگر، چگونگی برهم‌نهادگی رخدادها با عناصر زنجیری را نشان می‌دهد. در راستای بکارگیری این رویکرد، نمبات و همکاران (۱۳۸۴) در پژوهشی به توصیف F_0 در فارسی پرداختند سپس با استفاده از درخت طبقه‌بندی و رگرسیون^۲ به مدل سازی پارامترها همت گماشتند که در نهایت مقایسه منحنی تخمینی و طبیعی برای مجموعه آزمون^۳، ضریب همبستگی ۶۱/۱ درصد و خطای جذر میانگین مربعات برابر ۲۵/۳۸۶ هرتز را نشان می‌دهد.

از رویکردهای متاخر در این زمینه، الگوی رمزگذاری موازی و تقریب هدف^۴ است که پیاده‌سازی آن را می‌توان در نگاهی کمی، یعنی تقریب کمی هدف^۵ مشاهده کرد (ژو، ۲۰۰۵؛ پروم - آن^۶ و همکاران، ۲۰۰۹؛ ژو و پروم - آن، ۲۰۱۴). پیش از این، قدرت پیش‌بینی بالای بازسازی منحنی F_0 با استفاده از این الگو در زبان‌های انگلیسی، ماندرين، ژاپنی و تایلندی گزارش شده است (ژو و پروم - آن، ۲۰۱۴) در مقاله حاضر، با اتخاذ الگوی مذکور و با استفاده از مجموعه دادگانی بالغ بر ۱۵۰ پاره‌گفتار در شرایط مختلف کانونی، تحلیل و بازسازی نوای گفتار کانونی جملات خبری در فارسی، مورد مطالعه و بررسی قرار می‌گیرد. لازم به ذکر است که برای نخستین بار است که مدل سازی نوای گفتار با استفاده از این رویکرد در فارسی انجام می‌گیرد. اهمیت انجام این پژوهش برای نگارندگان از آن جهت است که در صورت موفقیت در دستیابی به کیفیت مطلوبی از منحنی بسامدپایه تولیدی، برخلاف رویکردهای دیگر، می‌توان به راحتی از آن در سیستم‌های TTS بهره گرفت.

در ادامه، در بخش ۲ چارجوب کلی PENTA توضیح داده خواهد شد که خود مشتمل بر سه زیربخش نقش‌های ارتباطی^۷، تقریب هدف و PENTAtrainers است. در بخش ۳ به طور مختصر به کانون نوایی خواهیم پرداخت. در بخش ۴ به روش‌شناسی تحقیق اشاره شده است که دربردارنده توضیحاتی پیرامون داده‌های تحقیق، برچسب‌گذاری نقشی، آزمون ادراکی و نتایج تحقیق است. در نهایت، بخش ۵ پیش از منابع، به بحث و نتیجه‌گیری اختصاص یافته است.


-
1. align
 2. Classification and Regression Tree (CART)
 3. test set
 4. Parallel Encoding and Target Approximation (PENTA)
 5. quantitative Target Approximation (qTA)
 6. Xu
 7. Prom-on
 8. communicative function

الگوی PENTA

الگوی PENTA، چارچوب مورد استفاده در این تحقیق، با اتکا به نگرشی تولیدی - نقش‌گرا^۱ به گفتار، بین معنای ارتباطی و نوای گفتار پیوند برقرار می‌کند (ژو، ۲۰۰۵؛ ژو و پروم - آن، ۲۰۱۴) این الگو از ابتداء، برروی دو جنبه از نوای گفتار یعنی نقش (کارکرد)‌های ارتباطی و سازوکارهای تولیدی تاکید داشته است (ژو، ۲۰۰۵). این دو جنبه هر یک به طور مجزا در ادامه توضیح داده شده است.

نقش‌های ارتباطی

در الگوی PENTA، نقش ارتباطی یک معنای ارتباطی خاص است که گوینده با بهره‌گیری از عناصر زبرزنگیری قصد انتقال آن را به شنونده دارد. همانطور که در شکل ۱ ترسیم شده است مستطیل‌های سمت راست، نقش‌های ارتباطی جداگانه‌ای هستند که به عنوان نیروی محرک الگو ایفای نقش می‌کنند. هر یک از این نقش‌ها، طرحوارهٔ رمزگذاری^۲ منحصر‌بفردی دارند که مشکل از پارامترهای اهداف زیروبیمی^۳ هستند. اهداف زیروبیمی، کوچکترین واحدایی هستند که با واحدهای زیروبیمی زبان‌شناختی مانند نواخت و تکیه زیروبیمی در پیوندند (ژو و ونگ، ۲۰۰۱). پارامترها در مستطیل «پارامترهای تقریب هدف» در میانه شکل ۱ آورده شده است. اهداف زیروبیمی به لحاظ تولیدی از طریق تقریب هدف که منحنی F_0 نهایی را تولید می‌کند، پیاده‌سازی می‌شوند. در نتیجه، چارچوب نظری PENTA، تولید نوای گفتار به مثابه فرایند رمزگذاری نقش‌های ارتباطی از طریق تقریب هدف را توصیف می‌کند.




شکل ۱. طرحواره‌ای از بخش‌های مختلف چارچوب نظری رمزگذاری موازی و تقریب هدف (PENTA). این شکل برگرفته از ژو (۲۰۰۵) است.

1. articulatory - functional
2. encoding schema
3. pitch target

تقریب هدف

در شکل ۲ فرآیند تقریب هدف به تصویر کشیده است که توسط ژو و ونگ (۲۰۰۱) مطرح شده است. خط خمیده سیاهرنگ، منحنی F_0 را نشان می‌دهد که به صورت مجانب^۱ به سمت دو هدف زیروبومی متواالی حرکت می‌کند. این دو هدف یکی پویا^۲ و دیگری ایستاست^۳ که در شکل زیر به صورت خطوط بریده نمایش داده شده است. در توضیح هدف زیروبومی پویا و ایستا باید اشاره کرد که نوع اول دربردارنده نواختهای خیزان و افتتان است و نوع دوم، یعنی ایستا، شامل نواخت بالا، پایین و یا متوسط^۴ است (ژو و ونگ، ۲۰۰۱).



شکل ۲. فرآیند تقریب هدف

منحنی سیاه نشان دهنده منحنی F_0 است که به صورت مجانب از سمت راست به طرف دو هدف زیروبومی متواالی که با خط بریده نشان داده شده است حرکت می‌کند. خط خاکستری رنگ عمودی در وسط، بیانگر مرز هجاست که از مسیر آن مرحله پویایی F_0 پایانی، به هجای بعدی منتقل می‌شود. پیکان خاکستری، مسیر انتقال مرحله پویایی F_0 را نشان می‌دهد. این شکل برگرفته از ژو و پروم - آن (۲۰۱۴) است.

این الگوی مفهومی، اخیراً به عنوان الگوی تقریب کمی هدف توسط پروم - آن و همکاران (۲۰۰۹) پیاده‌سازی شده است. در تقریب کمی هدف یا همان qTA بسامدپایه هر هجا با استفاده از معادله خطی درجه دوم زیر بدست می‌آید:

$$f_0(t) = (mt + b)(c_1 + c_2t + c_3t^2)e^{-\lambda t} \quad (1)$$

1. asymptotically
2. dynamic
3. static
4. mid
5. Wang

که در آن m و b به ترتیب شیب^۱ و ارتفاع^۲ اهداف زیروبمی هستند و λ توان یا قدرت^۳ تقریب هدف است. همچنین سه ضریب گذرا^۴ در معادله بالا یعنی c_1 , c_2 و c_3 از طریق فرمول زیر محاسبه می‌شوند:

$$c_1 = f_0(0) - b \quad (۲)$$

$$c_2 = f'_0(0) + c_1\lambda - m \quad (۳)$$

$$c_3 = (f''_0(0) + 2c_2\lambda - c_1\lambda^2)/2 \quad (۴)$$

از سه پارامتر فوق یعنی m , b و λ استفاده می‌کند تا بروی هر یک از منحنی‌های F_0 در هر هجا نظارت داشته باشد. ذکر این نکته ضروری است که در الگوی مذکور، هجا به عنوان واحد پایه حامل نوای گفتار در نظر گرفته شده است.

ابزار بازسازی‌کننده PENTAtrainers

پارامترهای هدف در qTA به شیوه‌های مختلفی بدست می‌آیند. آن‌ها را می‌توان به صورت دستی مشخص کرد و یا به صورت خودکار از طریق آموزش^۵ از روی داده‌های واقعی گفتار بدست آورد. برای دستیابی به PENTAtrainer1 (پروم - آن و همکاران، ۲۰۰۹) و PENTAtrainer2 (پروم - آن، ۲۰۱۴) عمل می‌کنند توسعه یافت. این دو برنامه، پارامترهای هدف را از طریق تحلیل به شیوه بازسازی^۶ استخراج می‌کنند. تفاوت نسخه نخست و نسخه دوم در نحوه بهینه‌سازی^۷ است. نحوه عملکرد برنامه PENTAtrainer1 به این نحو است که یک جستجوی جامع^۸ انجام می‌دهد و همه هدف‌های ممکن را در یک دامنه^۹ مورد آزمایش قرار می‌دهد سپس از بین این اهداف، هدفی را انتخاب می‌کند که مناسب‌ترین گزینه (به لحاظ شباهت به F_0 طبیعی) برای هر یک از هجاهاست. با این روش، اهداف مقوله‌ای با نقش‌های ارتباطی یکسان، تنها می‌توانند از طریق میانگین‌گیری اهدافی که به مقوله‌های مشابه تعلق دارند بدست آیند (پروم - آن، ۲۰۰۹). در مقابل، PENTAtrainer2 اهداف مقوله‌ای بهینه را مستقیماً با یک جستجوی تصادفی^{۱۰} "همه‌جانبه"^{۱۱} در کل

1. slope
2. height
3. strength
4. transient coefficient
5. train
6. Boersma & Weenink
7. analysis-by-synthesis
8. optimization
9. exhaustive search
10. range
11. stochastic
12. global

پایگاهدادگان گفتاری بدست می‌آورد. در تحقیق حاضر با بکارگیری برنامه PENTAtrainer2 اهداف مقوله‌ای به صورت خودکار از یک مجموعه دادگان گفتاری استخراج شده است. در بخش بعدی به کانون نوایی می‌پردازیم که هدف نهایی از پژوهش حاضر بازسازی این جنبه از نوای گفتار فارسی است.

کانون نوایی

کانون، کارکردی ارتباطی است که به منظور برجسته کردن یا مورد تاکید قراردادن بخشی از پاره گفتار اعمال می‌شود و می‌تواند با استفاده از ابزارهای صرفی- نحوی از جمله استنادسازی^۱ نمود پیدا کند. این تأکید^۲ می‌تواند با استفاده از ابزارهای نوایی نیز تحقق پیدا کند. عنصر کانونی غالباً با F_0 بیشتری نسبت به همتای غیرکانونی خود نمود پیدا می‌کند اما شواهد متعدد نیز وجود دارد دال بر اینکه کانون در بسیاری از زبان‌های دنیا نه تنها با افزایش F_0 بروی عناصر کانونی، بلکه با تراکم دامنه زیروبیمی عناصر پسکانونی نیز نمود پیدا می‌کند که از این پدیده تحت عنوان تراکم پسکانونی^۳ یاد می‌شود (چن^۴ و همکاران، ۲۰۰۹). طاهری اردلی و ژو (۲۰۱۲) در پژوهشی نشان دادند که در فارسی، F_0 به عنوان همبسته اصلی کانون نوایی، در ناحیه پیش کانون تغییر معناداری را نشان نمی‌دهد اما در ناحیه کانون و پس کانون این تغییرات کاملاً معنادار است؛ یعنی، عناصر کانونی به طور ملموسی با F_0 بالاتری نسبت به همتای غیرکانونی خود نمود پیدا می‌کنند در عناصر پسکانونی، F_0 جملات کانونی نسبت به معادل فاقد کانون خود پایین‌تر است (شکل ۳ و ۵ نمونه‌ای از منحنی F_0 کانونی را در فارسی نشان می‌دهد).

در یک نگاه کلی، از چشم‌انداز رده‌شناسی نوایی^۵، نوای گفتار فارسی به عنوان یک زبان تکیه‌بر^۶ در سطح کلمه (فرگوسن^۷؛ ۱۹۵۷؛ لازار^۸؛ ۱۹۵۷؛ کهنموبی‌پور^۹؛ ۲۰۰۳؛ جان^{۱۰}؛ ۲۰۰۵) و در سطح جمله، شامل گروه‌های تکیه‌ای^{۱۱} است که حاوی تکیه زیروبیمی منفرد هستند و در انتهای، بسته به نوع عبارت با نواخت‌های مرزنمایی بالا یا پایین خاتمه پیدا می‌کنند (ماهجانی، ۲۰۰۳؛ سادات‌تهرانی، ۲۰۰۷؛ ابوالحسنی‌زاده و همکاران، ۲۰۱۲).

-
1. clefting
 2. emphasis
 3. post-focus compression (PFC)
 4. Chen
 5. prosodic typology
 6. stress language
 7. Ferguson
 8. Lazard
 9. Kahnemuyipour
 10. Jun
 11. accentual phrases

روش‌شناسی پژوهش دادگان، آزمودنی‌ها و ابزارهای تحقیق

جمله محرک مورد استفاده در این تحقیق «ماها ببابی نیلی رو لندن دیدیم» است که پنج گویشور مرد با میانگین سنی ۲۵ سال، آن را در شش حالت مختلف کانونی و غیرکانونی تولید کردند. هر یک از این حالتا پنج بار تکرار شد که در مجموع ۱۵۰ پاره‌گفتار بدست آمد. یعنی: ۶ حالت کانونی \times ۵ گوینده \times ۵ بار تکرار = ۱۵۰ پاره‌گفتار.


نتایج آزمون عینی^۱، یعنی ضریب همبستگی و خطای جذر میانگین مربعات، حاصل از بازسازی کلیه ۱۵۰ پاره‌گفتار است. اما در آزمایش ادراکی (ذهنی)^۲، به منظور مقایسه نتایج جملات بازسازی شده با نتایج آزمایش ادراکی انجام شده با استفاده از جملات طبیعی (طاهری اردلی و ژو، ۲۰۱۴)، پاره‌گفتارهای محرک سه نفر از گویندها در این پژوهش استفاده شد. معیار انتخاب گویندها بر این اساس است که این سه نفر، کمینه، بیشینه و میانه انحراف معیار^۳ بسامد پایه پنج گوینده حاضر در تحقیق را دارا هستند. در مجموع ۹۰ پاره‌گفتار بازسازی شده مورد استفاده قرار گرفت. یعنی: ۶ حالت کانونی \times ۳ گوینده \times ۵ بار تکرار = ۹۰ پاره‌گفتار. در نهایت، در این بخش یعنی آزمون ادراکی، پنج آزمودنی مرد و پنج آزمودنی زن مشارکت داشتند که به این ۹۰ پاره‌گفتار و همتای طبیعی آنها یعنی در مجموع ۱۸۰ پاره‌گفتار گوش فرا دادند و قضاؤت خود را با کلیک بروی گزینه‌های مورد نظر ببروی صفحه رایانه ثبت کردند. این افراد هیچ‌گونه اختلال گفتاری یا شنیداری را به آزمون گیرنده گزارش نکردند. در ضمن، هزینه شرکت در آزمون به آزمودنی‌ها پرداخت شد.

به منظور انجام آزمون‌های ادراکی از ExperimentMFC در نرم‌افزار پرت استفاده شد که یک شیوه بسیار رایج در انجام چنین آزمون‌هایی است. در ابتدا، آزمودنی‌ها برای چگونگی انجام دو آزمون آموزش دیدند و از این اختیار برخوردار بودند تا هر تعداد از فایل‌ها را مایل هستند قبل از انجام آزمون اصلی بشنوند. سپس پاره‌گفتارهای محرک برای آزمودنی‌ها به صورت تصادفی پخش شد تا نظر خود را اعلام کنند.

برچسب‌گذاری نقشی و بازسازی نوای گفتار

با پیروی از مفروضات الگوی PENTA یعنی رمز‌گذاری موادی و نقش‌های ارتباطی، داده‌های تحقیق با سه لایه نقشی یعنی تکیه (تکیه‌بر، بی‌تکیه)، جایگاه هجا (آغازی، ماقبل پایانی، پایانی) و شرایط کانونی (پیش کانون، کانون، پس کانون) برچسب‌گذاری شدند. شکل ۳ نمونه‌ای از این برچسب‌گذاری را در برنامه پرت نشان می‌دهد.


-
1. objective
 2. subjective
 3. median standard deviation



شکل ۳. برچسب‌گذاری لایه‌ای نقش‌های ارتباطی

لایه‌ها از بالا به پایین عبارتند از تکیه، جایگاه هجا و شرایط کانونی. در این برچسب‌گذاری U و S به ترتیب به هجای تکیه‌بر و بی‌تکیه اشاره دارد. I و F به ترتیب هجا در جایگاه آغازی، پایانی و ماقبل پایانی است و در نهایت، PRE و POS به ترتیب معرف هجا در حالت پیش کانون، کانون و پس کانون است.

پس از برچسب‌گذاری با استفاده از یکی از سه ابزار موجود در PENTAtainer2 یعنی Tool، ابزار یادگیری^۱ به عنوان ابزار دوم در برنامه مورد استفاده قرار گرفت تا اهداف زیروبومی چندنقشی (در مجموع ۱۸ مورد) را بدست آورد. ترکیب نقش‌های ارتباطی بدست آمده که در نهایت منجر به استخراج ۱۸ هدف زیروبومی متفاوت است در شکل ۴ به تصویر کشیده شده است. در هر دو تصویر ۳ و ۴ لایه اول، لایه نقشی تکیه است که شامل دو هجای تکیه‌بر (U) و غیرتکیه‌بر (S) است. لایه دوم جایگاه هجا را درون کلمه نشان می‌دهد که شامل هجای آغازی (I)، پایانی (F) و ماقبل پایانی (P) است. لایه آخر، موقعیت هجای مورد نظر را در جایگاه پیش کانون (PRE)، کانونی (ON) و پس کانون (POS) ترسیم کرده است.




شکل ۴. ترکیب نقش‌های ارتباطی بدست آمده که شامل ۱۸ ترکیب مختلف است.

در این برچسب‌گذاری نیز U و S به ترتیب هجای تکیه‌بر و بی‌تکیه هستند، I و F به ترتیب به هجا در جایگاه آغازی، پایانی و ماقبل پایانی اشاره دارد و در نهایت، PRE و ON و POS به ترتیب معرف هجا در حالت پیش کانون، کانون و پس کانون است.

در ادامه، ابزار بازسازی^۱ مورد استفاده قرار گرفت تا منحنی بازسازی نهایی هر یک از پاره‌گفتارها را تولید کند. لازم به ذکر است که بخش یادگیری و بازسازی به شیوه مستقل از گوینده انجام گرفت. یعنی در ابتدا اهداف زیروبمی از کلیه گویندها استخراج شد و سپس از بین گویندها میانگین گیری شد. در ادامه، از اهداف زیروبمی میانگین گیری شده استفاده شد تا بازسازی پاره‌گفتارهای کل گویندها انجام گیرد. در نهایت، ۱۵۰ پاره‌گفتار مورد نظر به همراه منحنی F_0 بازسازی شده آنها بر روی رایانه ذخیره شد.

نتایج آزمون عینی


شکل ۵ نمونه‌ای از F_0 بازسازی شده با استفاده از ابزار بازسازی² PENTAtrainer را نشان می‌دهد. محور افقی، زمان و محور عمودی، منحنی F_0 گفتار است. در شکل زیر، منحنی برباید، خطوط مورب و منحنی نقطه‌چین به ترتیب، منحنی F_0 اصلی، اهداف زیروبمی و منحنی بازسازی شده را نشان می‌دهد. در ادامه، شکل ۶ منحنی اصلی و بازسازی شده در شرایط کانونی و غیرکانونی کلیه پاره‌گفتارها را که به طور میانگین در محور زمان بهنجارشده^۳ است نمایش می‌دهد. هر یک از منحنی‌ها، میانگین بسامدپایه ۲۵ پاره‌گفتار است. در شکل ۶ مرز کلمات برای هر یک مشخص شده است. در ضمن، کلماتی که به صورت برجسته نشان داده شده‌اند، عناصر کانونی هستند.



شکل ۵. نمونه بازسازی شده با استفاده از PENTAtrainer²

منحنی F_0 اصلی (خط برباید)، اهداف زیروبمی فراگیری شده (خطوط مورب) و منحنی بازسازی شده (منحنی نقطه‌چین) در تصویر فوق هویداست.

1. Synthesis Tool
2. mean time-normalized



شکل ۶: میانگین منحنی بسامد پایه اصلی و بازسازی شده (هر یک میانگین ۲۵ پاره گفتار) که در محور زمان بهنجار شده است.

بسامد پایه اصلی به صورت خط خاکستری و منحنی بازسازی شده به صورت بریده نشان داده شده است. آوانویسی و مرز هر یک از کلمات نیز نمایش داده شده است. کلماتی که به صورت برجسته‌اند کلمات کانونی هستند.

به منظور ارزیابی عینی کیفیت منحنی تولید شده از خطای جذر میانگین مربعات و ضریب همبستگی استفاده شده است. این دو معیار به صورت خودکار توسط نرم‌افزار PENTATrainer2 استخراج و ذخیره شده است. جدول ۲ نتایج حاصل از این دو معیار را بین منحنی خطای جذر میانگین مربعات و ضریب همبستگی را برای پاره گفتارهای محرک کانونی و غیرکانونی نشان می‌دهد. نتایج بدست آمده بیانگر میزان نیکویی برازش^۱ بسیار خوب بین منحنی بازسازی شده و منحنی اصلی است.

جدول ۲: میانگین ضریب همبستگی Pearson's r و خطای جذر میانگین مربعات بین دو نوع پاره گفتارهای محرک کانونی و غیرکانونی

RMSE	همبستگی	نوع جمله
۱/۶۲	.۰/۷۶	غیرکانونی
۲/۰۱	.۰/۸۶	کانونی

1. goodness of fit

نتایج فوق حاکی از عملکرد بسیار مطلوب PENTAtainer2 برروی دادگان کانونی زبان فارسی است. این یافته‌ها قابل مقایسه با یافته‌های تحقیق لی و همکاران (۲۰۱۴) و ژو و پروم - آن (۲۰۱۶) است که شباهت بسیار خوب منحنی تخمینی در مقایسه با منحنی اصلی را نشان می‌دهد.


آزمون ادراکی

همان‌طور که اشاره شد برای بررسی کیفیت پاره‌گفتارهای با منحنی بازسازی شده، در کنار دو آزمون عینی که در بخش پیشین به آن‌ها اشاره شد، از دو آزمون مجزای ادراکی یعنی شناسایی جایگاه کانون و قضاوت میزان طبیعی بودن^۱ نیز استفاده شد. در آزمون شناسایی جایگاه کانون، آزمودنی‌ها می‌باشند و وجود یا عدم وجود کانون و در صورت وجود جایگاه آن را در هر یک از محرک‌ها مشخص کنند. از آنجایی که F_0 مهمترین همبسته^۲ کانون نوایی در فارسی است (طاهری اردلی و ژو، ۲۰۱۲؛ ابوالحسنی‌زاده، ۲۰۱۲)، در صورتی که بازسازی منحنی به خوبی انجام شده باشد، نتایج بدست آمده از این آزمون با آزمون شنیداری انجام شده با پاره‌گفتارهای محرک طبیعی قابل مقایسه است، در غیر این صورت، چنانکه میزان پاسخ‌های صحیح شنونده‌ها کمتر از میزان شناسایی صحیح جایگاه کانون در پاره‌گفتارهای طبیعی باشد، می‌تواند حاکی از بازسازی نامطلوب باشد. در آزمون دوم، یعنی قضاوت پیرامون میزان طبیعی بودن، شنونده‌ها باید از بین ۱۸۰ محرک مشخص کنند که هر یک به کدام گروه «طبیعی» یا «بازسازی شده» تعلق دارند. اگر میزان تشخیص طبیعی بودن هر دو نوع محرک به یک اندازه باشد نشان از بازسازی با کیفیت مطلوب منحنی است.

نتایج آزمون ادراکی


شکل ۷ نتایج حاصل از ارزیابی ذهنی شناسایی کانون در آزمایش شنیداری در پاره‌گفتارهای بازسازی شده را نشان می‌دهد. بیشترین و کمترین میزان صحیح بازنگاری کانون، متعلق به پاره‌گفتارهایی است که به ترتیب کانون برروی کلمه دوم یعنی «بابای» (۹۳.۳ درصد) و کلمه پنجم «دیدیم» (۶۴ درصد) قرار دارد.

1. naturalness judgment
2. correlate



شکل ۷. درصد شناسایی صحیح کانون بروی کلمه نخست تا پنجم و نیز در حالت غیرکانونی در پاره‌گفتارهای بازسازی شده. نوار خط، خطای معیار را نشان می‌دهد.

به منظور مقایسه، نمودار میله‌ای آزمون شنیداری پاره‌گفتارهای اصلی از پژوهش طاهری اردلی و همکاران (۲۰۱۴) در کنار نتایج پژوهش حاضر در شکل ۸ آمده است.



شکل ۸. درصد شناسایی صحیح کانون بروی کلمه نخست تا پنجم و نیز حالت غیرکانونی در دو پاره‌گفتار طبیعی (سیاهرنگ) و بازسازی شده (خاکستری‌رنگ). نوار خط، خطای معیار را نشان می‌دهد.

همچنین، جدول ۳ در زیر ماتریس درهم‌ریختگی^۱ ادراک جایگاه کانون را نشان می‌دهد. بیشترین درصد خطای آزمودنی‌ها در بازشناسی جایگاه کانون به شنیدن عبارت کانونی کلمه پنجم یعنی «دیدیم» به عنوان عبارت غیرکانونی است. به بیان دیگر، ۲۸.۶ درصد از عبارتهایی که با تأکید بروی «دیدیم» بودند به اشتباه

1. confusion matrix

توسط شنوندگان به عنوان عبارات غیرکانونی قلمداد شده‌اند که با نتیجه بدست آمده در پاره‌گفتارهای طبیعی قابل مقایسه است (قس. طاهری اردلی و همکاران، ۲۰۱۴).

جدول ۳. ماتریس درهم‌ریختگی ادراک کانون پاره‌گفتارهای بازسازی شده (به درصد)

اعدادی که به صورت برجسته نمایش داده شده‌اند درصد صحیح شناسایی جایگاه کانون است.

کلمه پنجم	کلمه چهارم	کلمه سوم	کلمه دوم	کلمه اول	غیرکانونی	شنبیده شده حالات اصلی
۱/۶	۳/۶	۱/۶	.۰/۰	۳/۶	۸۸/۶	غیرکانونی
.۰/۰	.۰/۰	.۰/۰	۲	۸۵/۳	۱۲	کلمه اول
.۰/۰	.۰/۰	.۰/۰	۹۳/۳	۲	۴/۶	کلمه دوم
.۰/۰	۲/۶	۷۹/۳	۳/۳	۱/۳	۱۳/۳	کلمه سوم
.۰/۶	۹۱/۳	.۰/۰	.۰/۰	.۰/۰	۸/۰	کلمه چهارم
۶۶/۰	۵/۰	.۰/۰	.۰/۰	.۰/۰	۲۸/۶	کلمه پنجم

همچنین، جدول ۴ نتایج مقایسه دوبه‌دوی^۱ حالات مختلف عبارات کانونی بازسازی شده با تعديل بونفرونی^۲ را نشان می‌دهد. تنها تفاوت معنادار بین حالت کانونی روی کلمه پنجم در مقایسه با کلمه دوم یعنی «بابای» و کلمه چهارم «لندن» است. به بیان دیگر، میزان شناسایی صحیح کانون برای کلمه پنجم به طور معناداری کمتر از شناسایی صحیح کانون بروی کلمه دوم و چهارم است. این نتایج، با نتایج بدست آمده در تحقیق پیرامون پاره‌گفتارهای طبیعی (طاهری اردلی و همکاران، ۲۰۱۴) قابل مقایسه است. تنها تفاوت بین دو نوع پاره‌گفتار طبیعی و بازسازی شده، تفاوت معنادار بین کانون بروی کلمه پنجم و عبارت فاقد کانون است که چنین تفاوت معناداری در تحقیق حاضر (عبارات بازسازی شده) مشاهده نشده است.

جدول ۴. نتایج مقایسه دو به دو تعقیبی^۳

معناداری	خطای معیار	تفاوت میانه (I-J)	نوع کانون (J)	نوع کانون (I)
۱/۰۰۰	۵/۶۹۲	۵/۳۳۳	کلمه اول	غیرکانونی
۱/۰۰۰	۴/۳۵۵	-۲/۶۶۹	کلمه دوم	
۱/۰۰۰	۸/۸۳۶	۱۱/۳۳۳	کلمه سوم	
۱/۰۰۰	۵/۹۱۸	-۰/۶۶۸	کلمه چهارم	
.۰/۰۵۱	۶/۴۲۶	۲۵/۳۳۴	کلمه پنجم	



1. pairwise comparison


2. Bonferroni adjustment

3. post-hoc

۱/۰۰۰	۴/۰۷۴	-۸/۰۰۲	کلمه دوم	کلمه نخست
۱/۰۰۰	۷/۵۳۳	۸/۰۰۰	کلمه سوم	
۱/۰۰۰	۵/۴۸۴	-۶/۰۰۱	کلمه چهارم	
-۰/۷۴۸	۸/۸۳۵	۲۰/۰۰۱	کلمه پنجم	
۰/۸۴۶	۶/۳۹۹	۱۴/۰۰۲	کلمه سوم	کلمه دوم
۱/۰۰۰	۳/۱۵۱	۲/۰۰۱	کلمه چهارم	
+۰/۰۲۰	۶/۱۱۱	۲۸/۰۰۳*	کلمه پنجم	
۰/۳۵۸	۴/۴۲۳	-۱۲/۰۰۱	کلمه چهارم	کلمه سوم
۱/۰۰۰	۸/۳۴۳	۱۴/۰۰۱	کلمه پنجم	
+۰/۰۱۱	۵/۲۰۸	۲۶/۰۰۲*	کلمه پنجم	کلمه چهارم

نتیجه جالب توجه در میزان شناسایی کانون برای پاره‌گفتارهای بازسازی شده است که بیشتر از درصد شناسایی جایگاه کانون در پاره‌گفتارهای طبیعی است (۸۴٪ در مقابل ۷۵٪). این افزایش در میزان بازشناسی برای کلیه حالت‌های کانونی و غیرکانونی بدست آمده است که در شکل ۸ قابل مشاهده است.

شکل ۹ نتایج دومین آزمون ادراکی یعنی قضاوت میزان طبیعی بودن هر دو نوع محرک‌های طبیعی و تولیدشده را نشان می‌دهد. اگر چه در هر دو حالت کانونی و غیرکانونی، محرک‌های بازسازی شده به میزان کمی درصد پایین‌تری را به خود اختصاص داده‌اند اما تفاوت معناداری در دو حالت کانونی [F(1,9) = 2.969, p = 0.775] و غیرکانونی [F(1,9) = 0.87, p = 0.119] مشاهده نشده است.



شکل ۹. میانگین (میله‌ها و اعداد روی آنها) و خطای معیار (خطوط عمودی) ارزیابی طبیعی بودن پاره‌گفتارهای بازسازی شده در شرایط کانونی و غیرکانونی

نتایج حاصل از نبود تفاوت معنادار آماری در میزان طبیعی بودن هر دو نوع محرک، نشان‌دهنده نتیجه مطلوب حاصل از فرایند بازسازی منحنی زبروبمی پاره‌گفتارهای کانونی با استفاده از رویکردی تولیدی- نقش‌گرا به تحلیل و بازسازی نوای گفتار است.

نتیجه‌گیری

مهمنترین همبسته نوای گفتار بسامدپایه است از این رو اغلب تحقیقات انجام گرفته در این زمینه در راستای تحقق مدل‌سازی رایانشی این منحنی بوده است. اما در زبان فارسی، خلاصه پردازش نوای گفتار با نگاهی زبان‌شناختی به‌ویژه در سیستم‌های تبدیل متن به گفتار بهخوبی احساس می‌شود. دلیل چنین خلاصی را می‌توان در مواردی چون دشواری ذاتی مطالعات در این حوزه، نبود تحقیقات منسجم و پیوسته برپایه یک نظریه واحد و همچنین نبود تعامل لازم بین زبانشناسان و متخصصان علم فناوری گفتار دانست. در مقاله حاضر در اولین گام، به منظور پرکردن بخش کوچکی از این خلاصه، مدل‌سازی نوای گفتار کانونی فارسی با استفاده از رویکردی جدید یعنی رمزگذاری موازی و تقریب هدف، انجام گرفت. نتایج بدست آمده نشان داد که تخمين نسبتاً دقیق F_0 در جملات خبری کانونی فارسی امکان‌پذیر است. نکته حائز اهمیت در نتایج، میزان درک کانون برای پاره‌گفتارهای بازسازی شده در مقایسه با نتایج حاصل از درک کانون در پاره‌گفتارهای طبیعی است که میزان درک کانون در جملات همانندسازی شده در کلیه حالت‌های کانونی و غیرکانونی، بهتر از همتای آن‌ها بوده است. همچنین، ارزیابی ذهنی و عینی منحنی‌های تولیدشده حاکی از نتایج مطلوبی است که با دیگر نتایج حاصل از زبان‌هایی مانند انگلیسی، ماندرین، ژاپنی و تایلندی (لى و همکاران، ۲۰۱۴؛ ژو و پروم - آن، ۲۰۱۴) قابل مقایسه است. بنابراین، PENTAtrainer² نشان داد که می‌تواند یک ابزار کارآمد برای همانندسازی نوای گفتار کانونی در فارسی باشد. این بسته نرم‌افزاری که به صورت نیمه‌خودکار عمل می‌کند با ترکیبی از همانندسازی سازوکار تولیدی در تولید F_0 ، برچسب‌گذاری نقشی و بهینه‌سازی تصادفی، برای مطالعه نوای گفتار زبان‌های مختلف مورد استفاده قرار می‌گیرد. اما در مقایسه با رویکردهای دیگر مانند خود واحد - وزنی که پیش از این در فارسی مورد استفاده قرار گرفت (طاهری اردلی و خرم، ۱۳۹۱) باید اشاره کرد که این رویکرد و استفاده از برچسب‌گذاری نواخته‌ها و فاصله‌نمایها دارای موانعی است که امر مدل‌سازی را به طور کلی با مشکل مواجهه می‌کند. از آن جمله می‌توان به انجام برچسب‌گذاری به شیوه دستی اشاره کرد که نه تنها انسجام و یکپارچگی لازم را ندارد بلکه بسیار زمان بر و هزینه‌بر است که عملاً مدل‌سازی نوای گفتار با استفاده از پایگاه‌دادگان‌های حجیم را غیرممکن می‌کند. دومین مشکل آن، خروجی منحنی F_0 به شکل ناپیوسته است که خود نیازمند پردازش پسین منحنی تولیدشده است. رویکرد فوجی‌سکی شاید مطرح‌ترین و پرکاربردترین رویکرد در زمینه بازسازی و مدل‌سازی نوای گفتار باشد که تاکنون برای زبان‌های متعددی چون انگلیسی، چینی، هندی، یونانی و غیره با میزان بالایی از موفقیت مورد استفاده قرار گرفته است. اما در این مدل به دلیل تأثیر مولفه‌های مختلف بریکدیگر و ساخت منحنی F_0 با استفاده از اثر جمعی مولفه‌ها، تعیین دستی پارامترهای مدل تقریباً غیرممکن است. لذا باید درصد بود تا پارامترها به صورت

خودکار از روی منحنی اصلی استخراج شوند. اگر چه این کار با موقفيت بالايی توسط نهبات و کوچاري (۱۳۸۶) انجام گرفته است اما مسئله پيش‌رو، بدست آوردن پaramترهای Mورد نظر از روی متن است که پياده‌سازی آن را در سистем‌های تبدیل متن به گفتار فارسي با مشکل موواجه می‌کند. تيلت، مدل دیگري است که به الگوي خود واحد - وزني شباخت دارد. نهبات و همکاران (۱۳۸۴) در پژوهشی با استفاده از اين رو يك‌رد به مدل‌سازی نوای گفتار در فارسي و تخمين بسامدپايه از روی متن پرداختند و به ميزان همبستگي حدود ۶۱٪ برای داده آزمون خود دست پيدا کردند. اين ميزان از همبستگي نشان مي‌دهد که به مانند مدل فوجي‌ساكي، بدست آوردن پaramترهای Mدل از روی متن امر ساده‌اي نيسنت. از اين رو، به باور نگارندگان اين سطور، رو يك‌رد توليدی - نقش‌گرای PENTA برخلاف رو يك‌رد خود واحد - وزني داراي قطعieit بسيار بالايی در برچسب‌های Mورد استفاده است و با توجه به اينکه بسياری از نقش‌های ارتباطي که به عنوان برچسب‌های ورودی Mورد استفاده قرار گرفتند می‌توانند به شيوه خودکار اعمال شوند، Mدل‌سازی نوای گفتار در پايگاه‌دادگان‌های حجيم و سيستم‌های تبدیل متن به گفتار فارسي را بالقوه عملي مي‌سازد. همانطور که اشاره شد از مشكلات رو يك‌دهاي مانند فوجي‌ساكي و تيلت بدست آوردن پaramترها از روی متن است. از اين رو به نظر مي‌رسد رو يك‌رد PENTA به خاطر شفافيت، انسجام و يكپارچگي آن مي‌تواند به عنوان يك گزينه در Mدل‌سازی نوای گفتار فارسي با استفاده از داده آموزش و آزمون مجزا Mورد استفاده قرار گيرد. با توجه به نتائج مطلوب حاصل از پژوهش حاضر، نگارندگان در تحقيقات آتي درصدند تا اين چارچوب را با تعداد نقش‌های ارتباطي فرضي بيشتر و با يك پايگاه‌دادگان گفتاري جملات خبری (طاهرى اردى و همکاران، ۱۳۹۴) که به منظور استفاده در سيستم‌های تبدیل متن به گفتار طراحي شده است، Mورد آزمایش قرار دهند. يعني، آزمودن اين چارچوب با نمونه‌جملات بيشتر و با نمونه‌جملاتي که بدون نظارت مستقيم در شيوه توليد، تهييه و ضبط شده‌اند. در صورت كسب نتائج قابل قبول می‌توان Mدل‌سازی نوای گفتار فارسي در سيستم‌های تبدیل متن به گفتار فارسي را با استفاده از اين رو يك‌رد پياده‌سازی کرد.

منابع

- اسلامي، محرم (۱۳۸۴)، واج‌شناسي، نظام تحليل آهنگ زبان فارسي. تهران، انتشارات سمت.
- طاهرى اردى، مرتضى و سهيل خرم (۱۳۹۱)، «Mدل‌سازی نوای گفتار در سيستم‌های سنتز گفتار فارسي»، مجموعه مقالات هشتمين همايش زيان‌شناسي ايران، به کوشش محمد دبير‌مقدم، تهران: دانشگاه علامه طباطبائي، صفحات ۴۸۰-۴۹۲.
- طاهرى اردى، مرتضى، خرم، سهيل، عاصي، مصطفى، صامتى، حسين و محمود بى‌جن خان (زير چاپ)، «طراحي و ضبط پايگاه‌دادگان گفتاري برای سيستم‌های تبدیل متن به گفتار فارسي»، دو فصلنامه علمي-پژوهشی پژوهش‌های زيان‌شناسي تطبيقی.

- نهبات مجید و عباس کوچاری (۱۳۸۵)، «تخمین منحنی گام در زبان فارسی برای یک سیستم تبدیل متن به گفتار با کمک درخت کلاس‌بندی و رگرسیون»، مجموعه مقالات دوازدهمین کنفرانس ملی انجمن کامپیوتر ایران.

- نهبات مجید و عباس کوچاری (۱۳۸۶)، «استخراج اتوماتیک پارامترهای مدل فوجی‌سакی برای زبان فارسی»، مجموعه مقالات پانزدهمین کنفرانس مهندسی برق ایران.

- Abolhasanizadeh, V., Bijankhan, M., & Gussenhoven, C. (2012), "The Persian pitch accent and its retention after the focus", Lingua, 122(13), 1380-1394.
- Bijankhan, M., Sheikhzadegan, M. J., Roohani, J., Samareh, Y., Lucas, C., & Tebyani, M. (1994), "FARSDAT-the Farsi spoken language database", Paper presented at the Proceedings of International Conference on Speech Sciences and Technology.
- Boersma, P. & D. Weenink (2001), "Praat, a system for doing phonetics by computer." Glot international (5): 341–345.
- Chen, Y., Guion-Anderson, S., & Xu, Y. (2012), "Post-Focus compression in second language Mandarin". Speech Prosody 2012, Shanghai.
- Ferguson, C. (1957), "Word stress in Persian". Language 33, 123-135.
- Fujisaki, H. & K. Hirose (1984), "Analysis of voice fundamental frequency contours for declarative sentences of Japanese." Journal of the Acoustical Society of America 5(4): 233-242.
- Fujisaki, H. & S. Nagashima (1969), "A model for the synthesis of pitch contours of connected speech." Annual Report of the Engineering Research Institute 28: 53-60.
- Jun, S.-A. (2005), Prosodic Typology: The Phonology of Intonation and Phrasing. Oxford: Oxford University Press.
- Kahnemuyipour, A. (2003), "Syntactic categories and Persian stress." Natural Language & Linguistic Theory, 21(2), 333-379.
- Ladd, R. (2008). Intonational Phonology. Cambridge, Cambridge University Press.
- Lazard, G. (1957), Grammaire du Persan Contemporain. Klincksieck, Paris, New Edition published by Peeters, Paris, 2006.
- Lee, A., Xu, Y., & Prom-on, S. (2014), "Modeling Japanese F0 contours using the PENTATrainers and AMtrainer". Fourth International Symposium on Tonal Aspects of Languages. Nijmegen, Netherlands.
- Mahjani, B. (2003), An Instrumental Study of Prosodic Features and Intonation in Modern Farsi (Persian), M.Sc. thesis, retrieved from: http://www.ling.ed.ac.uk/teaching/postgrad/mscslp/archive/dissertations/2002-3/behzad_mahjani.pdf.
- Pierrehumbert, J. B. (1980), The phonology and phonetics of English intonation. (PhD dissertation), Massachusetts Institute of Technology.
- Prom-on, S., Xu, Y., Thipakorn, B. (2009), "Modeling tone and intonation in Mandarin and English as a process of target approximation." The Journal of the Acoustical Society of America 125(1): 405–424.
- Sadat-Tehrani, N. (2007), The Intonational Grammar of Persian. (PhD dissertation), University of Manitoba, Manitoba.
- Silverman, K. E., Beckman, M. E., Pitrelli, J. F., Ostendorf, M., Wightman, C. W., Price, P., & Hirschberg, J. (1992), "TOBI: a standard for labeling English prosody". In The Second International Conference on Spoken Language Processing, ICSLP 1992, Banff, Alberta, Canada, October 13-16.

- Taheri-Ardali, M., Rahmani, H., & Xu, Y. (2014), "The perception of prosodic focus in Persian". *Speech Prosody 2014*. Dublin: 515-519.
- Taheri-Ardali, M. & Y. Xu (2012), "Phonetic realization of prosodic focus in Persian". *Speech Prosody 2012*, Shanghai.
- Taylor, P. (1992), A Phonetic Model of English Intonation. (PhD dissertation), University of Edinburgh, Edinburgh.
- Taylor, P. (2000), "Analysis and synthesis of intonation using the tilt model." *Journal of the Acoustical Society of America* 107(4): 1697–1714.
- Xu, Y. (2005), "Speech melody as articulatorily implemented communicative functions." *Speech Communication* 46(3–4): 220–251.
- Xu, Y. & S. Prom-on (2014), "Toward invariant functional representations of variable surface fundamental frequency contours: Synthesizing speech melody via model-based stochastic learning." *Speech Communication* 57: 181–208.
- Xu, Y. & E. Q. Wang (2001), "Pitch targets and their realization: Evidence from Mandarin Chinese." *Speech Communication* 33: 319-337.