

ارائه روش^(۱) TD-VQSS برای سنتز گفتار سیستم‌های^(۲) TTS

ابوالقاسم صیادیان

دانشیار

دانشکده مهندسی برق، دانشگاه صنعتی امیرکبیر

چکیده

هرسیستم TTS از دو قسمت اساسی؛ الف) قسمت^(۳) LA یا^(۴) NLPP ب) قسمت^(۵) SS تشکیل شده است. وظیفه قسمت LA تشخیص و تعیین نوع جمله (سؤالی، خبری، ...) تعیین موقعیت و نقش معنائی یا دستوری کلمه در جمله، تعیین زنجیره آوانی (یا سیلابی) کلمات همراه با نوع لحن و تأکید بیان و ... می‌باشد. وظیفه قسمت SS تولید سیگنال صحبت از روی زنجیره آوانی (یا سیلابی) خروجی قسمت LA و اعمال لحن و تأکید بیان مطلوب بر روی آنها می‌باشد. تحقیق این نوشتار بر روی قسمت SS متمرکز می‌باشد. پس از معرفی روش‌های کلاسیک مطرح برای قسمت SS، روش جدیدی به نام TD-VQSS برای این منظور ارائه می‌شود. این روش دارای ویژگی‌های زیر می‌باشد: نیاز به حجم حافظه کم - نیاز به بار محاسباتی پایین - تولید صدای کاملاً طبیعی و قابل فهم - امکان تغییر لحن و تأکید بیان گفتار و ...

TD-VQSS a New Speech Synthesizer for TTS Systems

A. Sayadian.

Associate Professor

Electrical Engineering Department,
Amirkabir University of Technology

Abstract

Every TTS system has two principal sections:

a) Language Analyzer (LA) or Natural Language parser (NLP)

b) Speech synthesizer (SS). The tasks of LA section are determination of: sentence type, phoneme sequence of words, prosodic contour of phonemes The task of SS section is production of speech signal from phonemes sequences with proper prosody. The research of this paper is concentrated on SS section. After survey of existing method, we propose a new speech synthesizer with the name of TD-VQSS. The features of this new method are: Very high naturalness speech production, possibility of prosodic variation, low storage, low computational load.

۲- روش‌های کلاسیک در سنتز گفتار

اگر سنتز گفتار برای تعداد کلمات یا جملات محدودی مورد نظر باشد، ساده‌ترین روش استفاده از ضبط کلمات یا جملات به صورت کامل از یک یا چند گوینده است. این روش اگرچه در تعداد محدودی از کاربردها استفاده می‌شود، ولی انعطاف‌پذیری لازم برای اغلب کاربردها را ندارد. در سیستم‌های TTS که برای تولید نامحدود کلمات یا جملات یک زبان طراحی می‌شوند، ضرورت دارد که از واحدهای کوچکتر زبانی مانند سیلاب^(۸)، نیمه سیلاب^(۹)، واج ترکیبی^(۱۰) یا واج^(۱۱) استفاده شود، [۸] ... [۵]. هر قدر واحد زبانی کوچکتر انتخاب گردد، تعداد آنها کمتر (مانند واج)، ولی مکانیزم‌های کنترلی برای اتصال آنها^(۱۲) پیچیده‌تر و امکان تولید صدای کاملاً طبیعی مشکل‌تر خواهد بود. بر عکس هر قدر واحد زبانی بزرگتر باشد (مثل سیلاب)، صدای تولید شده طبیعی تر و مکانیزم‌های کنترلی ساده‌تر شده و در عوض حجم حافظه مورد نیاز برای نگهداری آنها بیشتر می‌گردد. پس از انتخاب نوع واحد زبانی، مسئله بعدی انتخاب نوع سنتز کننده سیگنال گفتار در سطح فریم (۵ - ۲۰ ms) می‌باشد. اگر سنتز کننده گفتار برای تولید نامحدود کلمات یک زبان به کار رود، با شاخص‌های زیر مورد ارزیابی قرار می‌گیرد: (الف) امکان سنتز صدای قابل فهم، (ب) امکان تغییر فرکانس پیج و گین (برای تغییر لحن و نوع تأکید بیان)، (ج) امکان سنتز صدای طبیعی، (د) امکان تشخیص گوینده، (ذ) حجم حافظه مورد نیاز (ر) بار محاسباتی سنتز کننده. روش‌هایی که از سنتز در حوزه زمان استفاده می‌نمایند (مانند روش PSOLA^(۱۳)، ...، [۱۲]) از صدای طبیعی و قابل فهم بسیار بالایی برخوردار بوده ولی در عوض به حجم حافظه نسبتاً بالایی نیاز دارند. روش‌هایی که از سنتز پارامتریک غیرزمانی (مانند سنتی سایزr^(۱۴)) فرمت کلات [۶] [۹] [۶] و یا سنتی سایزr^(۱۵) LSPF [۷] استفاده می‌نمایند، صدای قابل فهم تولید نموده ولی در تولید صدای طبیعی دچار مشکل بوده و علاوه بر آن دارای بار محاسباتی

کلمات کلیدی

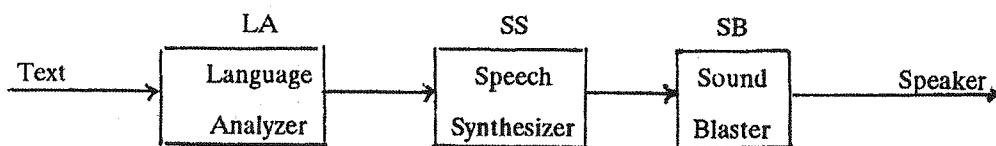
Text-to-Speech, Speech Synthesizer, Pitch Synchronous Overlap Add (PSOLA)

مقدمة

ارتباط گفتاری بین انسان و ماشین (کامپیوتر، ربات و ...) مشتمل بر دو سرفصل اساسی در پردازش گفتار و پردازش زبان طبیعی می باشد. سرفصل اول شامل روش های تبدیل گفتار به متن و سرفصل دوم شامل روش های تبدیل متن به گفتار (به یک یا چند زبان شخص) می باشد. زمینه تحقیقات این نوشتار مربوط به سرفصل دوم یعنی سیستم های تبدیل متن به گفتار (TTS) است. ورودی هر سیستم TTS نوعاً یک جمله نوشتاری^(۶) یا یک فایل نوشتاری^(۷) است (که می تواند مشتمل بر دهها یا صدها جمله باشد). مجموعه وظایف هر سیستم TTS به دو قسمت اساسی به نام های LA و SS تقسیم شده^[۴] .

وظیفه قسمت LA، تشخیص نوع جمله (خبری، تعجبی، امری، سؤالی و ...) تعیین نقش معنائی و دستوری کلمات در جمله، تعیین زنجیره آوایی (یا سیلابی) کلمات جمله، تعیین نوع لحن و تأکید بیان (در نتیجه تعیین نوع الگوی کانتور تغییرات فرکانس پیج و گین و نسبت‌های طول و اجهاؤ سکوت و ...) و ... می‌باشد. وظیفه قسمت SS تولید سیگنال صحبت حتی الامکان بالحن طبیعی و با نوع تأکید بیان مطلوب و صدای گوینده مورد نظر (زن یا مرد) می‌باشد. تحقیقات اصلی این نوشتار بر روی قسمت SS سیستم‌های TTS متمرکز می‌باشد.

در بخش دوم روش های موجود سنتی سایزرهای کفتار را موردن بررسی و تحلیل مختصر قرار می دهیم. در بخش سوم به معرفی و تحلیل روش جدید TD-VQSS می پردازیم. سرانجام در بخش چهارم جمع بندی از نتایج تحقیقات این نوشتار خواهیم داشت.



شکل (۱) شمای گلی پک سیستم TTS.

۱-۳- آشکارسازی نقطه تحریک برای فریم‌های با صدا

در تئوری تولید سیگنال صحبت، هر فریم زمانی ($5-20\text{ ms}$) را می‌توان به دو کلاس کلی با صدا و بی صدا تقسیم نمود. اطلاعات فاز و نقطه تحریک در فریم‌های بی صدا اهمیتی برای گوش انسان ندارند، ولی چنانچه بخواهیم سیگنال گفتار کاملاً طبیعی و قابل فهم تولید نماییم، اطلاعات فاز (نسبی) و نقطه تحریک برای فریم‌های با صدا بسیار حائز اهمیت می‌باشدند. برای درک اهمیت آشکارسازی صحیح نقطه تحریک در سنتز زمانی، سیگنال صحبت تعدادی از جملات را با اتصال متوالی یک پریود پیچ (با گین‌های متناظر) برای قسمت‌های با صدا و اتصال متوالی قطعاتی به طول 10 ms برای قسمت‌های بی صدا تولید نمودیم. فرض می‌کنیم در برش هر فریم زمانی، به جای نقطه تحریک از نقطه‌ای به طول 1 ms از نقطه تحریک $\text{PP}/2 \leq 1 \leq \text{PP}$ طول پریود پیچ برحسب نمونه‌های سیگنال می‌باشد عمل نمائیم. صدای بازسازی شده را مورد آزمون‌های شنیداری قرار دادیم. نتیجه در جدول (۱) درج شده است. اعداد ردیف اول جدول نسبت $\text{PP}/1$ بوده که به صورت درصد بیان شده‌اند.

جدول (۱) نتیجه آزمون‌های شنیداری برش فریم‌های زمانی نسبت به نقطه تحریک.

بایاس نقطه تحریک	%۰	%۱۰	%۲۰	%۳۰	%۴۰	%۵۰
نتیجه آزمون شنیداری	٪۹۸/۵	٪۹۴/۲	٪۸۲/۴	٪۷۵/۷	٪۷۴/۵	٪۷۲/۶

روش آزمون بدینگونه بوده است که جملات بازسازی شده برای 10 نفر پخش شده است، شتوندگان با مقایسه کیفیت صدای بازسازی شده و صدای اصلی تمره‌ای بین صفر تا صد به صدای بازسازی شده داده‌اند. آنچه در جدول (۱) درجه گردیده متوسط نمرات پاسخ 10 نفر می‌باشد. صدای بازسازی شده برای $>10\text{ نفر}$ حالت گلوگرفتگی و همچنین کلیک‌های پریودیک می‌باشد. بنابراین به نظر می‌رسد که آشکارسازی نقطه تحریک فریم‌های با صدا برای سنتز زمانی گفتار به صورت اتصال متوالی فریم‌هایی به طول پریود پیچ، امری ضروری است. روش‌های مختلفی برای آشکارسازی نقطه تحریک پیشنهاد و مورد استفاده قرار می‌گیرند. با توجه به اینکه فرآیند آشکارسازی در طی این تحقیق به

بالائی در هنگام سنتز می‌باشدند. در عوض حجم حافظه مورد نیاز برای نگهداری پارامترها نسبتاً پایین است (در مقایسه با سنتز کننده‌های حوزه زمان). آنچه تاکنون در سیستم‌های حرفه‌ای مورد استفاده قرار گرفته، روش‌های پارامتریک غیرزمانی می‌باشد (مانند سیستم ME8000, Votrax SCO1A Digital DTC-05, General Instrument SP256-ALZ, NEC-PD7752C, Silicon Systems SSI263, Philips Electronic Dectalk و ...) [۱۵]، [۱۶]. این نوع سنتز سایزرها به علت نیاز به حجم محاسبات بالا، نوعاً توسعه یک یا دو چیپ ارائه می‌شوند. با توجه به اینکه هدف عده این تحقیق آن است که با رام محاسباتی قسمت سنتز سایزر کم بوده، به قسمی که بر روی کامپیوتراهای PC (بدون استفاده از چیپ‌های مخصوص) به راحتی قابل پیاده‌سازی باشد، به نظر می‌رسد که روش‌های زمانی کاندید مناسبی برای اهداف فوق می‌باشند. عده‌ترین روش زمانی مطرح که قادر به تغییر لحن و تأکید بیان نیز هست روش PSOLA می‌باشد. با اینکه روش فوق قادر به تولید صدای کاملاً طبیعی و قابل فهم با رام محاسباتی کم می‌باشد، متأسفانه به علت نیاز به حجم حافظه بالا، هنوز وارد سیستم‌های حرفه‌ای نشده و در مراکز تحقیقاتی و دانشگاهی مورد استفاده قرار می‌گیرد. دلیل اصلی نیاز به حجم حافظه بالا این است که، در این روش کل قطعات زبانی (واج، واژه ترکیبی یا ...) را یکجا و به صورت زمانی (با فرکانس 0.25 KHZ -۸-۱۱) و به صورت ۸ یا ۱۶ بیتی) ذخیره می‌نمایند. آنچه تحقیق این نوشتار را به خود معطوف نموده، ارائه روشی است که ضمن دارا بودن محسان روش PSOLA، به حجم حافظه کمتری نیاز داشته به قسمی که برای سیستم‌های TTS با تعداد کلمات نامحدودی قابل استفاده باشد.

۳- ارائه روش TD-VQSS

توانایی روش ارائه شده در کاهش حجم حافظه مورد نیاز قسمت SS سیستم‌های TTS می‌باشد. این روش از سه نوع تئوری و مدل‌سازی به شرح زیر استفاده می‌نماید: (الف) آشکارسازی نقطه تحریک^(۱۶) برای فریم‌های با صدا^(۱۷) [۱۶] ب) چندی کننده برداری^(۱۸) VQ برای کاهش نرخ بیت (ج) درون یابی^(۱۹) و چند به یک کردن^(۲۰) سیگنال در حوزه زمان.

- آن را S_i می‌نامیم.
- ۶ - با استفاده از روش درون‌یابی با باند محدود^(۲۶) [۲۰] [۱۹]، طول قطعات زمانی منتظر C_i ها به $12/5 \text{ ms}$ ماکریزیم طول پریود پیج عملیاتی یعنی $12/5 \text{ ms}$ می‌رسانیم (فرآیند مرحله ۶ فقط برای قطعات زمانی که دارای برچسب با صدا می‌باشند اجرا می‌شود).
- ۷ - در بازنمائی^(۲۷) هر فریم 10 میلی ثانیه‌ای قطعات زبانی سیستم TTS، فقط از یک کد 10 بیتی استفاده می‌نماییم (که منتظر با ایندکس کد آن قطعه در کتاب کد می‌باشد). البته برای هر نقطه کانتور پیج و گین، $2 \text{ عدد } 8 \text{ بیتی}$ (یکی برای پریود پیج و دیگری برای اندازه گین) نیز ذخیره می‌شود (در قسمت LA سیستم TTS).
- بنابراین پس از اتمام فرآیند طراحی کتاب کد، تعداد 10×22 الگوی زمانی به طول حداقل $12/5 \text{ میلی ثانیه}$ (و یا 10 میلی ثانیه برای قطعات بی صدا) خواهیم داشت. در بازنمائی قطعات زمانی فقط از ایندکس این الگوهای زمانی استفاده می‌نماییم.

۳-۳- درصد فشرده‌سازی روش بازنمایی VQ

فرض می‌کنیم کوچکترین واحد زبانی مورد استفاده در سیستم TTS، نیمه سیلاپ با طول متوسط 150 میلی ثانیه باشد (واحد زبانی مورد استفاده در شبیه‌سازی این تحقیق). تعداد نیمه سیلاپ‌های زبان‌های زنده در رنج $2000 - 1000$ قطعه قرار دارد. فرض می‌کنیم نمونه‌های زمانی به صورت 8 بیتی (با فشرده‌سازی A-law یا μ -law) ذخیره شده و فرکانس نمونه برداری 0.25 KHZ باشد (چون برنامه‌ها تحت سیستم عامل window بوده و این سیستم عامل، فقط سه فرکانس نمونه برداری $0.25 / 0.25 / 0.25$ و $44 / 44 / 44$ کیلو هرتز را پشتیبانی می‌نماید). اگر قطعات زبانی به صورت معمولی (روش PSOLA) ذخیره شوند، حجم حافظه مورد نیاز برابر خواهد بود با:

$$N_p = 2000 \times 150 \times 11/025 \times 8 = 3/3075 \text{ Mbyte}$$

در روش بازنمایی VQ، دو نوع حافظه مورد نیاز می‌باشد، الف - حافظه‌ای که برای ذخیره‌سازی کد قطعات زمانی لازم است. ب - حافظه‌ای که برای ذخیره‌سازی 10×22 قطعه زمانی به طول حداقل $12/5 \text{ میلی ثانیه}$ لازم است. در نتیجه حافظه مورد نیاز روش بازنمایی VQ برابر است با:

صورت زمان زنده^(۲۸) مورد نظر نبوده و همچنین دقت آن روش مورد توجه می‌باشد، از روش مندرج در مرجع [۱۶] استفاده شده است.

۲-۳- استفاده از چندی کنده برداری QV برای کاهش حجم حافظه

در مبحث مربوط به کد کنده‌های صحبت با نرخ پایین نشان داده می‌شود که بهترین راه، جهت وصول به نرخ‌های خیلی پایین ($800 - 2400 \text{ BPS}$) استفاده از چندی کنده‌های برداری است [۱۸] [۱۷]. برای استفاده از توانایی چندی کنده‌های برداری در کاهش حجم حافظه مورد نیاز سیستم TTS، به شرح زیر عمل می‌نماییم. ابتدا پس از ضبط و پالایش و طراحی قطعات زبانی مورد نظر (واج، ترکیب واج، نیمه سیلاپ و ...) به هر فریم 10 میلی ثانیه از قطعات فوق الذکر، یک برچسب UV یا (با صدا یا بی صدا) می‌زنیم. سپس فرآیندهای زیر را انجام می‌دهیم:

- برای فریم‌های با صدا، ابتدا با استفاده از روش مندرج در بخش قبل، محل نقطه تحریک و پریود پیج را تخمین می‌زنیم. برای فریم‌های بی صدا نیازی به تخمین نقطه تحریک و پریود پیج نداریم.
- قطعه زمانی به اندازه یک پریود پیج از نقطه تحریک (برای فریم‌های با صدا) و یا یک قطعه به طول 10 میلی ثانیه از نقطه شروع فریم (برای فریم‌های بی صدا)، منتظر با کلیه فریم‌های موجود را به دست آورده و ذخیره می‌نماییم.
- هر قطعه زمانی را به صورت پریودیک به دنبال هم سه بار تکرار نموده و آنگاه نمونه‌های زمانی حاصل را در یک پنجره همینگ به طول $2/5$ برابر پریود قطعه (و یا 20 میلی ثانیه برای فریم‌های بی صدا) ضرب می‌نماییم. با استفاده از آنالیز^(۲۹) LPC 12 ، ضریب LSPF^(۳۰) منتظر را برای هر قطعه زمانی فوق الذکر به دست می‌آوریم.

۴ - با استفاده از پارامترهای LSPF و روش‌های طراحی LBG کتاب کد سیستم VQ همانند روش‌های^(۳۱) FSL^(۳۵) [۱۸] یا [۱۷]، تعداد 10×22 کلمه کد برای قسمت SS سیستم TTS طراحی می‌نماییم.

۵ - فرض می‌کنیم $C = \{C_1, C_2, \dots, C_{1024}\}$ بردارهای کتاب کد C تزدیکترین الگو از میان کلیه بردارهای آموزشی را به دست آورده و سیگنال زمانی منتظر

محاسباتی) کاملاً قابل قبول به نظر می رسد.

جدول (۲) مقایسه کیفیت سنتز روش TD-VQSS با روش PSOLA

مشخصات گوینده	از نظر حفظ بودن	از نظر طبیعی	از نظر فهم	
%۱۰۰	%۹۸/۳	%۱۰۰		یکسان است
%۰	%۱/۷	%۰		کمی بدتر است
%۰	%۰	%۰		بدتر است

۵- جمع بندی و نتیجه گیری

سنتی سایزر سیکنال گفتار، یک قسمت اساسی از سیستم TTS می باشد. روش هایی که برای سنتز گفتار در این سیستم ها تاکنون مورد استفاده قرار گرفته اند، روش های پارامتریک غیرزمانی می باشند. این روش ها دارای دو اشکال اساسی، (الف) عدم تولید صدای کاملاً قابل فهم و طبیعی با حفظ ویژگی های گوینده (ب) بالا بودن با رامحاسباتی سنتی سایزر در کاربردهای عام منظوره می باشند (بر روی کامپیوترهای PC معمولی و بدون چیپ های مخصوص).

روش موفقی که در مرحله تحقیقاتی مطرح بوده و دو مشکل متنزکر را در بر ندارد روش PSOLA می باشد. این روش یک روش سنتز سیکنال گفتار در حوزه زمان است. علت عدم مقبولیت حرفة ای این روش با وجود تولید صدای کاملاً قابل فهم و طبیعی با رامحاسباتی پایین، نیاز به حجم حافظه نسبتاً بالا است. روشی به نام TD-VQSS در طی این تحقیق ارائه گردید که ضمن دارا بودن خواص تقریباً یکسان با روش PSOLA، به حجم حافظه ای حدود ۱۸/۵ برابر کمتر از روش PSOLA نیاز دارد. این مقدار کاهش در حافظه مورد نیاز با استفاده از بازنمایی VQ در حوزه زمان حاصل گردیده است.

زیرنویس ها

- 1 - time Domain Vector quantization Based Speech Synthesize
- 2 - Text - to - Speech
- 3 - Language analyzer
- 4 - Natural Language Processing Parser
- 5 - Speech Synthesizer
- 6 - Text Sentence

$$N_V = 2000 \times 15 \times 10 + 1024 \times 12/5 \times 11/025 \times 8 = \\ 0.17862 \text{ Mbyte}$$

بنابر این نسبت فشرده سازی برابر است با:

$$r = \frac{3/3075}{0/17862} \approx 18/52$$

در نتیجه حجم حافظه مورد نیاز روش بازنمایی QV حدود ۱۸/۵ برابر کمتر از روش PSOLA گردیده است. تخصیص حافظه به اندازه ۱۸/۰ مگابایت برای قسمت SS سیستم TTS (در سیستم های PC فعلی) امری بسیار مقبول می باشد (در مقابل ۳/۲ مگابایت روش PSOLA).

۴- ۳- روش تغییر پریود پیج

تمامی قطعات زمانی با صدای ذخیره شده در روش VQ دارای طول ۱۲/۵ms می باشند، در مرحله سنتز نهایی سیستم TTS، علاوه بر تنظیم طول واچگونه ها، ضرورت دارد که کانتور پریود پیج (وگین) مطابق الگوی مشخص (بسته به نوع لحن و تأکید بیان) تغییر نماید. بنابر این می بایستی طول قطعه را باندازه پریود پیج متناظر در کانتور پیج تنظیم نمائیم. این عمل با استفاده از روش های درون یابی (یا چند به یک کردن) مناسب انجام می پذیرد. در این تحقیق از همان روش مطرح در سنتی سایزر PSOLA استفاده شده است.

۴- نتایج آزمون های عملی

برای بررسی کیفیت روش ارائه شده در سنتز قابل فهم و طبیعی گفتار، ۲۰ جمله مناسب (تقریباً بالانس از نظر واچ های زبان فارسی) طراحی گردید. این جملات توسط دو روش PSOLA و TD-VQSS سنتز گردیدند. از ۱۰ نفر برای مقایسه کیفیت دو روش با همدیگر آزمون های شنیداری انجام پذیرفت. نتیجه آزمون ها در جدول (۲) ندرج گردیده است. همانطوری که در جدول مشاهده می گردد، کیفیت روش ارائه شده از نظر فهم گفتار و حفظ مشخصات گوینده کاملاً مشابه روش PSOLA است. در مورد طبیعی بودن ۷/۱٪ تنزّل مشاهده می شود. به نظر می رسد که این امر خطای ناشی از تصمیم گیری یا عدم تمرکز شنونده باشد. حال اگر ۷/۱٪ را به عنوان کاهش کیفیت روش TD-VQSS در مقابل روش PSOLA پذیریم، باتوجه به کاهش ۱۸/۵ برابر در حجم حافظه مورد نیاز (بدون افزایش بار

- | | |
|------------------------------------|-----------------------------------|
| 7 - Text File | 18 - Vector Quantization |
| 8 - Syllable | 19 - Interpolation |
| 9 - Demi Syllable | 20 - Decimation |
| 10 - Diphone | 21 - Real Time |
| 11 - Phone | 22 - Linear Predicting Coding |
| 12 - Concatenation Rules | 23 - Line Spectrum Pair Frequency |
| 13 - Pitch Synchronous Overlap Add | 24 - Line, Bazo, Gray |
| 14 - Klatt Formant Synthesizer | 25 - Frequency Sensitive Learning |
| 15 - Line Spectrum Pair Frequency | 26 - Band Limited Interpolation |
| 16 - Epoch Detection | 27 - Representation |
| 17 - Voiced Frames | |

مراجع

- [1] C. C. Smyth, "Computer Programs of Speech Synthesizing", U.S. Army Human Engineering Lab., Tech. Report, 1989.
- [2] I. H. Witten, "Making Computers Talk: An Introduction to Speech Synthesis", Prentice-Hall, Englewood Cliffs, New Jersey, 1986.
- [3] J. Martin, "Design of Man-Computer Dialogues", Prentice Hall, Englewood Cliffs, New Jersey, 01973.
- [4] H. T. Smith, T. R. G. Green, "Human Interaction with Computers", Academic Press, London, England, 1980.
- [5] J. Holmes, "Formant Synthesizers: Cascade or Parallel", Speech Comm. 2, PP. 251-273, 1983.
- [6] D. Klatt, "Software for a Cascade Parallel Formant Synthesizer", Speech Comm. 2, PP. 251-273, 1980.
- [7] C. Browman, "Rules for Demisyllable Synthesis Using LINGWA, a Language Interpreter", Proc. IEEE on ICASSP, PP. 561-592, 1980.
- [8] H. Dettweiler, W. Hess, "Concatenation Rules for Demisyllable Speech Synthesis", Acustica, 57, PP. 268-283, 1985.
- [9] D. Klatt, "Text to Speech: Present and Future", Speech Tech., PP. 221-226, 1986.
- [10] C. Hamon, F. Charpentier, "A Diphone Synthesis System Based on Time Domain Prosodic Modification of Speech", IEEE Proc. on ICASSP, 1989.
- [11] D. Bigorgne, S. White, "Multilingual PSOLA Text to Speech System", IEEE Proc. on ICASSP, 1993.
- [12] H. Kwa, S. Yamamoto, "Development of a Text to Speech for Japanese Based on Waveform Splicing", IEEE Proc. on ICASSP, 1994.
- [13] F. M. Galanes, M. H. Savojo, H. M. Pardo, "Speech Synthesis System Based on a Variable Decimation Interpolation Factor", IEEE Proc. on ICASSP 1995.
- [14] J. Mullen, "Speech Synthesis IC for Low-Cost Application", New Electronic, PP. 99-101, June, 1994.
- [15] G. Kaplan, E. Lerner, "Realism in Synthetic Speech", IEEE Spectrum, 22, PP. 32-37, April 1994.
- [16] R. W. Schafer, J. Markel, "Speech Analysis", IEEE Press 1979.
- [17] R. M. Gray, "Vector Quantization", IEEE ASSP Magazine, April 1982.
- [18] S. C. Ahalt, P. Chen, "Vector Quantization Using Frequency Sensitive Learning", IEEE Proc. on ICSE, 1989.
- [19] A. V. Oppenheim, "Advance Topics in Signal Processing", Prentice Hall, 1988.
- [20] P.P. Vaidyanathan, "Multirate Systems and Filter Banks", Prentice Hall, 1993.