

音声を扱うためのパーソナル・コンピュータを 用いた心理学実験装置

— 音声言語認知、音楽認知、両耳分離聴取、クロス・モダリティの研究のために —

内 田 照 久¹⁾

I. 問題

今日、コンピュータの発展に伴い、心理学においても認知心理学などの領域を中心として、データ処理ばかりでなく、実験刺激の提示や反応時間の測定など、実験操作そのもののためにパーソナル・コンピュータが頻繁に用いられるようになってきた。このように心理学の実験において、パーソナル・コンピュータの利用がこれほど進んだ理由としては、パーソナル・コンピュータは大型計算機などと違い、実験場面でCPUを占有し、試行ごとのリアル・タイムの処理が可能である点、また、単体でも心理学が取り扱うような文字や図形などの実験刺激の表示や制御が可能であることに加え、比較的容易に実験に必要な反応スイッチを取り付けたり、外部機器を連動して制御するような拡張性の高さが上げられよう。また、コンピュータ全般の発展もあり、従来の性能と比較して、格段のコスト・パフォーマンスを得られるようになった点も見逃せない。

これまで心理学実験のためのパーソナル・コンピュータの利用については、一般的な心理学実験の実施を意図して、中谷(1985)や阿部(1988)などが汎用性の高い利用方法などを示している。

このように、心理学実験において、パーソナル・コンピュータの利用が格段に進んできたが、現在、我が国で主に使われているパーソナル・コンピュータには、音声の入出力が必ずしもサポートされていないこともあり、文字や図形を中心とした視覚的な実験と比較すると、音声刺激を用いた聴覚的な研究には、まだ十分に活用されていない側面がある。

聴覚的実験の例を挙げると、大脳半球優位差の研究などで用いられる両耳分離聴取(dichotic listening)などでは、異なる音声を極めて細かいタイミングで制御して、2つのチャンネルから同時に提示することが必要と

なる。その目的のために従来のテープ・デッキなどのアナログ機器を利用するような場合には、同期して提示を行うために専用のハード・ウェアを作成する必要があった。これには、専門の知識が必要な上、作成した機器は専用機となってしまうため、汎用性に乏しいという欠点がある。

また、視覚と聴覚の相互作用を扱うようなクロス・モダリティの研究では、視覚刺激と聴覚刺激の同時提示などの時間制御の方法を工夫する必要がある。

さらに、音声言語認知や音楽認知に研究においては、音声の音響特性そのものを操作して、人間の認知過程を探求することが求められる。そのような場合には、現在も発展しつつある音声情報処理技術の利用が不可欠であり、そのような技術を利用できる環境を整えることが必須である。

このように考えると、音声を扱う心理学的な実験においてもパーソナル・コンピュータを活用することにより、実験環境を改善できる点が多い。このような要望に対して、これまでにも河合・吉崎・伊藤(1989)などは、心理学実験において音声を取り扱うための装置を開発している。

ここでは、さらに汎用的に音声を扱うためのパーソナル・コンピュータを用いた心理学実験装置について述べるとともに、音声を扱う上で特に配慮すべき点についても述べていく。まず1章では、名古屋大学の教育心理学教室に設置されている『聴覚及び認知実験用多目的装置』とその周辺機器の概観を紹介しながら、音声を扱うための留意点も述べる。次に2章では、心理学実験での音声刺激の選定の際に必要となる、標準化された音声データ・ベースの利用を視野に入れて、本装置での利用のためのデータ互換性を検討する。また3章では、音声を扱うために民生用の音響機器を利用する場合の留意点について検討する。4章では、パーソナル・コンピュータがマルチ・メディア化していく流れの中で、音声を扱う心理学実験装置としての関わりを考える。さらに、5

1) 名古屋大学大学院博士課程(後期課程)研究生

章では、本装置で心理学の実験に実際に利用されている音声情報処理技術を紹介する。そして、最後の6章では、本装置の今後の進展について検討する。

1. 実験装置の概観

名古屋大学の教育心理学教室に設置されている『聴覚及び認知実験用多目的装置』とその周辺機器を中心に紹介しながら、音声を扱うためのパーソナル・コンピュータを用いた心理学実験装置における留意点を検討していく(図1)。記述にあたっては、心理学実験の実施の手順に沿って行う。まず、実験に用いる原音声を録音したり、被験者や学習者が発声した音声を録音する段階に相当する音声入力系について述べる。次に、実験の目的に応じた音声実験刺激を作成し、加工するための音声処理系について触れる。なお、この音声処理系の一部については、後述の別の章で改めて詳細に述べる。そして最後に、実際に聴覚実験を行う際の音声出力系について記述する。

1.1 音声入力系

音声の録音は、静謐なところで行われる必要があるということは周知の事柄であるが、特に音声を対象とした心理学実験を検討する場合には、さらに細心の配慮が必要となる。実験刺激の作成のために、特に音声情報処理技術を利用した加工などを行う場合には、録音時の静謐性は極めて重要な必須の事項となる。

音声情報処理技術の多くは、雑音などが伴わない單一

音源からの音声であることが前提とされており、その仮定が満たされた上で、はじめて有効に機能する。一方、例えば蛍光灯などから発生するノイズでさえも、条件によっては録音音声に悪影響を与えることがある。このようなノイズは、交流電源などの50Hz、または60Hzの周期を持っており、男性の声の高さ(pitch)と重複する部分がある。そのため、音声の加工にあたってpitchを利用するような音声情報処理においては、無聲音などの音圧レベルの低い部分では致命的な影響を与えてしまうことがある。

人間であれば、カクテル・パーティー現象で知られるように、自分の周囲の喧噪の中から、自分に必要な情報を持つ音声に、それほど労力を費やすことも注意を向けて分離して聞くことができる。すなわち、外ではセミが鳴き、道路を幾種類のもの車が通る音がし、机の上ではラジオが音楽を奏で、隣の家では子どもが叱られている声が聞こえてくる中でも、階段の下で自分を呼んでいる微かな声を聞き取ることができる。しかし、実はこのことは驚くべき事柄なのである。私たちが耳にする現実の音は、今述べたような全てのものが、実に一次元の空気の振動として畳み込まれて集約されてしまったものである。もちろん、両耳聴取による、音の位相差や時間差、強弱差などの情報も音の認知に重要な影響を与えていく。しかし、人間は片耳の聴取でさえも、上述のようなノイズの中から、音圧レベルの上では遙かに小さい対象の音声を難なく分離して意識化させることができるのである。

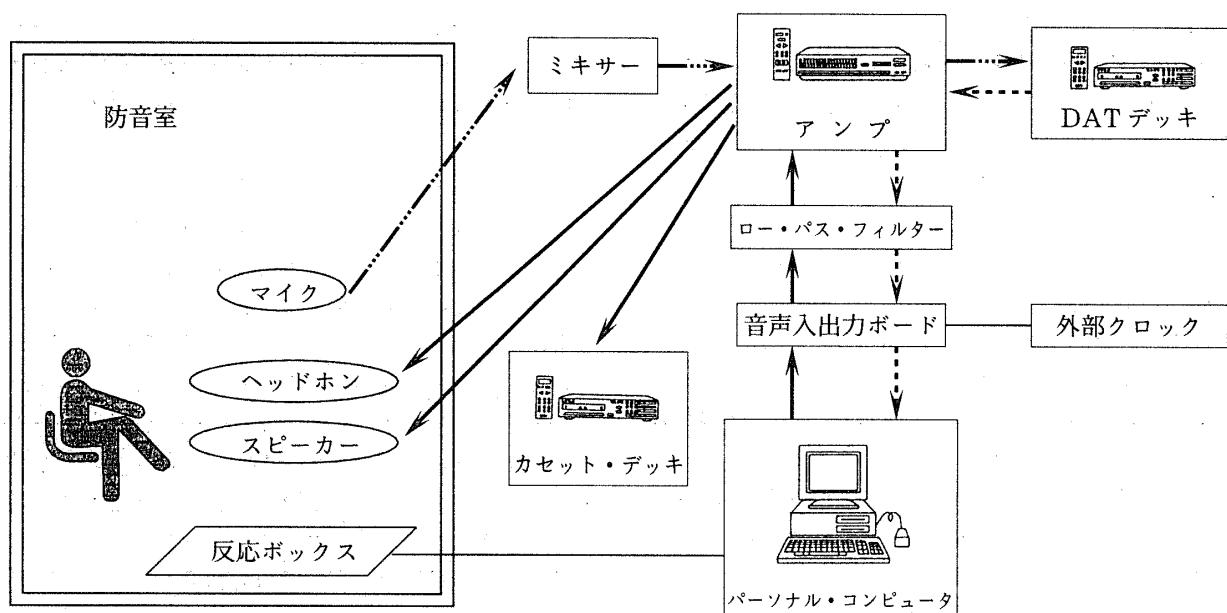


図1 「聴覚及び認知実験用多目的装置」及び周辺機器の概要

このようなノイズと対象音声の分離は、それ自体が工学的な研究の重要なテーマである。例えば、工場内での騒音の中での音声認識の精度を上げたり、車中での音声通信のためのノイズ成分の低減といったことが精力的に検討されている。このことは、逆にノイズと対象音声の分離がいかに困難なことかを示している。

従って、一般的にはノイズと対象音声の分離は、録音後は事実上困難であると考えておくべきである。したがって、心理学実験に用いる音声刺激などの録音時の静謐性の重要性を改めて指摘できよう。

このような録音時の静謐性を達成する上で、本装置では、遮音特性の優れた防音室（理研音響：聴力検査室 AT-80S）を使用している。この防音室は実測値として、500Hzの音に対して60dB以上、1kHzの音に対して70dB以上の遮音能力を有している。そして、さらに消音処理を施した換気用ダクトに接続されたエア・コンディショナーが装備されているため、被験者にとって負担の少ない実用上快適な環境をもたらしている。

録音にあたっては、防音室内で発声した音声を、まずマイク（ソニー：ECM-23FⅡ）でとらえ、その出力を防音室の外に取り出している。そして、ミキサー（ティアック：M-06）で出力を民生機用ライン・レベルに上げた上で、オーディオ・アンプ（デンオン：PMA-910V）を介し、デジタル・オーディオ・テープ・デッキ（以後 DAT と記す）（ソニー：DTC-300ES）に収録している。

ところで、マイクの出力は信号レベルが極めて低いため、外部雑音の影響を受けやすい。一方、コンピュータ関連機器などでは、そこから発生する電磁波により電気的ノイズ・レベルが極めて高い。特にCRTディスプレーなどのノイズは凄まじい。従って、音声入力系では、コンピュータ関連機器は全て停止させた上で、録音作業のみに専念している。そして、コンピュータを使用する次の音声処理系の作業段階とは、常に分離させたステップでの実施に留意している。

1. 2 音声処理系

音声処理系は、録音された音声から、当該の心理学実験の目的に応じた音声実験刺激を作成し、加工するステップである。

このステップでは、まず録音された原音声の単語や短い文章などをコンピュータに取り込み、実験に応じた必要な単位ごとに切りとて、それぞれを音声材料の音声ファイルとして保存していく。

音声をコンピュータに取り込むのにあたっては、DATからのアナログ音声信号を A/D 変換して行って

いる。具体的な装置について述べると、先述の DAT からの音声信号を、まずエイリアシング・ノイズの除去のため、遮断周波数 7.2kHz、低減率 110dB/oct のロー・パス・フィルタ（エヌエフ回路設計ブロック：RT-8FLB2 を使用した自作品）を通過させる。そして、次の A/D 変換にあたっては、音声入出力ボード（カノープス電子：Sound Master）を用いている。この A/D 変換は、主にサンプリング周波数 16kHz、量子化 16bit で行っている。その後、パーソナル・コンピュータ（日本電気：PC-9801VX21）に取り込み、音声データ・ファイルとしてハード・ディスク上に保存している。

ここで、音声信号のデジタル化に関連した事柄について、古井（1985）を参考にして簡単に説明しておく。まず、はじめから考えていくと、音声は空気の振動、すなわち空気の圧力の微細な変化である。そして、これをマイクなどの音響機器でその圧力の強さを、逐次、電気信号としてアナログ量の電圧に変換する。この電圧は、時間軸上では連続量として常に変化するものである。しかし、このままでは、コンピュータに取り込むには適していない。そこで、この電圧の高さを一瞬ごとにデジタル量である数値に変換し、その連続として、電圧の変化、すなわち音声の情報を記録しようとするのが Analog to Digital 変換、すなわち A/D 変換の考え方である。

したがって、特定の一瞬の電圧を数値化するステップをどれだけ短い時間間隔ごとに行うか、そして、その電圧をどれだけ細かいきざみで数値化するかによって、音声の持つ情報をどれだけ保持できるかが決まる。よって、より繊細な音声情報を保存しようとすると、それに応じて膨大な記憶容量が必要になる。

まず、数値化を行う時間の間隔は、サンプリング周波数で示されることが多い。例えば、サンプリング周波数が 48kHz の場合は、一秒間に 48,000 回の A/D 変換が行われることを示す。このサンプリング周波数は、A/D 変換された音声における再生可能な周波数域に影響を与える。結論からいえば、A/D 変換される当該の音声に含まれている周波数成分の情報の内、サンプリング周波数の 1/2 の周波数（特にナイキスト周波数と呼ぶ）までの情報は、A/D 変換によるサンプリングによって完全に保持されることが、情報理論におけるサンプリング定理によって確かめられている。したがって、高いサンプリング周波数で A/D 変換を行う程、高域の周波数についてまで忠実な音声情報を保持することができる。この例では 24kHz までの情報までが保持され、人間の可聴域である 20Hz～20kHz をカバーすることになる。

しかし、A/D 変換の対象となっている音声に、ナイ

キスト周波数以上の周波数成分の音が含まれている場合には、それがエイリアシング・ノイズとしてデータに混入し、元来の周波数域の音声情報に対しての誤差となって多大な影響を与える。したがって、原音声に含まれる不要な高域成分をカットし、エイリアシング・ノイズの影響を受けないようにするため、A/D変換の前段にアンチ・エイリアシング・フィルタとして、ロー・パス・フィルタを設置することが必須である。このロー・パス・フィルタの遮断周波数は、常に先述のサンプリング周波数と対応するナイキスト周波数に応じたものを設定しなければならない。

一方、電圧をどれだけの細かいきざみで数値かするかは、量子化bit数で示される。例えば、量子化16bitでサンプリングした場合は、当該の電圧は $2^{16} = 65536$ 段階の数値で表される。この量子化bit数は、当該の音声のダイナミック・レンジやS/N比に影響を与える。当然量子化bit数が大きい程、広いダイナミック・レンジと優れたS/N比を得ることができる。

現在、本装置では、A/D変換ボードに接続するためのクオーツ発振による外部クロック・ユニットを自作し、サンプリング周波数を16kHzで行えるようにして、量子化16bitでA/D変換を実施しているが、音声刺激作成のために適切な条件については、後述の2～4章でも検討する。

さて、上述の条件での実際の作業により、実験刺激の単語や短文が一つ一つの音声ファイルとして保存されれば、例えば、両耳分離聴取などの課題の場合、右と左のそれぞれのチャンネルに、どの実験刺激を割り当てて再生するかを定めるだけで、提示にあたっての同期の問題などにも比較的容易に対処できる。

しかし、実験の目的として、音声の音響的加工が必要な場合は、さらにまず、対象となる音声の音響的特性を調べる必要がある。すなわち、ここでは実験刺激の作成に先立ち、音声波形、サウンド・スペクトロ・グラフ、パワー、ピッチなどについて分析を行い、実験のために音声の加工すべき箇所をms単位で確定している。本装置では、この作業のため、パーソナル・コンピュータ上で動作する音声分析用ソフト・ウェア（NTTアドバンステクノロジ：音声工房、及びVoice Plotter）などを主に使用している。

このような、アプリケーション的な専用ソフト・ウェアの使用にあたっては、ソフト・ウェアごとの音声ファイルの形式の相違に留意する必要がある。音声データのファイル形式は、他のアプリケーション・ソフト・ウェアのファイル形式と比較すると、極めて単純な形式なものではあるが、それでもそれぞれ微妙に異なっている。

極めて遺憾なことではあるが、音声に関連した種々な学会や研究会においてでさえも、不適切なファイル形式の音声データを分析したもの、そのまま発表てしまっているものが散見される。そのような基本的な誤りは、そこから得られたデータや結果の信憑性にまで疑問を与えてしまうものであり、十分に配慮がなされるべきことである。本装置においては、各種のファイル形式やデータ形式に対応するためのコンバータを作成し、それを利用することで、このような問題に対処している。

さて、音声の加工すべき箇所が確定された後、実験的目的に応じた音声情報処理技術を利用して、音声刺激の加工を行うことになる。本装置では、音声内の指定区間について時間軸上での伸長圧縮処理が行われることが多い。その詳細については、5章で改めて述べる。

本装置では、以上のような音声処理系の作業を通して、心理学実験用の音声刺激を作成している。

1.3 音声出力系

実際に被験者を迎えて、音声を用いた心理学実験を行うステップがこの音声出力系にあたる。この音声出力系では、音声刺激の制御をパーソナル・コンピュータ上で行うことができるため、実験者が実験用のプログラムを作成すれば、実験者の意図に応じた様々な実験条件を実現することができる。

利点としては、例えばカセット・テープ・デッキなどでは、なかなか実現が困難な、被験者ペースでの実験の実施などが挙げられよう。また、被験者ごとの刺激提示順序のランダム化なども容易である。さらに、既存の反応時間測定プログラムなどと組み合わせることにより、実験自体の時間制御や、ms単位での反応時間測定も可能である。また、阿部ら（1988）の図形提示のプログラム・ルーチンを組み合わせることにより、視覚と聴覚のクロス・モダリティの実験などのため、異なった刺激を同期させて提示することなども可能であろう。

さらに、パーソナル・コンピュータからの音声出力に関しては、深田（1992）が、最近多く使われるようになってきたEMSメモリの利用を試みたり、より長時間の音声の再生をするために、音声データの圧縮を行っている。本装置の構成においても、必要に応じて、このような成果を活用していくことが可能である。

さて、この音声出力系では、音声刺激はまずパーソナル・コンピュータから出力される。そして、次に先述のロー・パス・フィルタを、今度はスマージング・フィルタとして通過する。そして、オーディオ・アンプで音量が調節された上で防音室内に入り、実験に応じてヘッドホン（ティック：HP-200PRO）、またはスピーカー

資料

(三菱電機: DS-11XL) から被験者に提示される。

なお、必要があれば、被験者の反応を得るためにスイッチ・ボックス(自作品)や図形表示用のCRTディスプレーを防音室内に設置し、防音室外に実験者のモニター用のサブ・ディスプレーを設置することもある。

また、実験によっては必ずしも防音室内で実験を実施せず、カセット・テープ・デッキ(ソニー: TC-WR870)を使用して、音声刺激を実験条件に沿って録音したテープを作成し、それを用いて当該の施設で実験を行うこともある。

以上が、実験実施のステップとしての音声出力系の概略である。

2. 各種の音声データベースとのデータ互換性

心理学実験においては、その実験刺激の選定にあたって細心の注意を払い、十分な吟味の上でその採用を決定する。例えば、視覚刺激などにあたっては、様々な図形について、その複雑性などの評定により規準データが作成されたものがある(Vanderplas & Garvin, 1959)。そして、そのような規準に基づいて刺激を統制したり、困難度の調節を行ったりする。また、言語材料などを使用する場合などでも、日常での出現頻度や親和感を基にしたり、さらに無意味語においても、その連想価を測定したものを刺激選定の参考にしている(林, 1972; 国立国語研究所, 1962)。

したがって、実験刺激に音声を使用するような場合も、視覚刺激や言語材料の扱いと同様に、音声そのものの素性に対して、音響的な特性をはじめとする多面的な側面について標準化されたデータや、経験的な蓄積のあるデータの使用が必要とされる場面が想定される。この

ような条件が特に求められる場合には、音声認識や音声合成、情報通信の分野で既に構築されてきた音声データベースの利用ができれば、音声刺激に関する様々な統制が比較的容易になると考えられる。

しかし、これまでに様々な研究機関で作成してきた各種の音声データベースは、それぞれの仕様も動作環境も異なる。ここでは、各種の代表的な音声データベースについて、その仕様やメディアなどについてまとめておく(表1)。

各々のデータベースは、研究目的の用途に限り、他の研究機関での購入や使用が可能である。もちろん、それらは、それぞれの作成した機関の用途や目的に応じた構成になっているため、その選択や使用にあたっては、利用者側の十分な知識と理解の上での検討が必要である。

音声データベースの利用にあたっての、現時点での課題は、これまで本装置を利用して作成してきた音声刺激などについて、その音響的特性を当該の音声データベースの音声試料と比較するような場合に、A/D変換時のサンプリング周波数や量子化bit数の違いが、その直接的な比較を困難にしている点である。もちろん、該当する条件に沿ったA/D変換を改めてやり直せば、比較が可能ではあるが、以前の音声刺激で得られた心理学実験の結果の蓄積については再現性の保証がなくなってしまう。また、既存の音声刺激のデータに、アップ・サンプリングやダウン・サンプリングといった、計算機上でソフト・ウェア的な処理を施した上での比較も可能ではあるが、計算量が膨大であり、現状のパーソナル・コンピュータ単体での性能ではやや荷が重いため実用的ではない。さらに実験結果の再現性の問題もそのまま残ってしまう。

表1 各種の音声データベースの仕様

ATR音声・言語 データベース	電 研 究 用 音 声 データ ベース	日本音響学会 研究用連続音声 データベース	重点領域研究に よる音声 データベース	東北大一松下 单語音声 データベース
サンプリング周波数	20 kHz	原則として20kHz (従来10, 12, 15 kHzで利用) (16kHzへの移行 を検討)	16 kHz	16 kHz 24 kHz(実用で は6, 8, 12kHz で使用)
量子化bit数	16 bit	12 bit	収録機関で非統一	16 bit 12 bit
ロー・パス・フィルタ 遮断周波数	8 kHz	—	収録機関で非統一	— 9 kHz
メ デ ィ ア	—	—	—	DAT/PCM版 CD-ROM版 CD-ROM

匂坂・浦谷(1992), 田中・速水(1992), 小林・板橋・速水・竹沢(1992), 板橋(1992), 及び, 牧野・二矢田・真船・城戸(1992)より作表([—]部は不明)

したがって、本装置を用いた音声刺激の作成の上でも、音声集録の段階から、利用する音声データベースと対照できる条件で作成しておく配慮が必要となろう。本装置を利用した音声刺激作成では、当初はコンピュータの記憶容量の制限や、実験時の音声データの読み出し時間の節約などもあって、サンプリング周波数を10kHzで実施していた。しかし、1992年以降は、音質の向上、各種のデータベースとの対照、さらに音声分析用のソフト・ウェアでの利用の便宜を図るために、サンプリング周波数を16kHzに移行して音声刺激を作成している。今後、ATR音声・言語データベースや、電総研の研究用音声データベースなどの利用が想定される場合には、サンプリング周波数20kHzへの移行を検討する必要があるかも知れない。今後も、様々な音声データベースの趨勢を見守りながら、検討をすすめていく課題であろう。

3. 各種の民生用音響機器の利用

ここでは、コスト・パフォーマンスが高く、多用途に使用できる民生用の一般的な音響機器において、音声を扱う心理学実験にも使用できる機器の利用を検討する。

現在のところ、音声刺激用の原音声を録音するにあたっては、DATを用い、サンプリング周波数48kHz、量子化16bitのliner PCMのスタンダード・モードでの録音が望ましいと思われる。そして、その録音音声をDATのデジタル入出力を利用して、デジタル信号のまま、DAT・インターフェース・ボード（岩通アイセル：IS-3690）などを介し、適切な条件でダウン・サンプリングしてパーソナル・コンピュータに直接取り込むのが、現時点は最善であろう。

一方、カセット・テープでの録音は非常に手軽に行えるのだが、現在では残念ながら周波数特性やS/N比、クロストークなどの観点から、原音声の録音には必ずしも十分であるとは言い難い。

さて、最近、光磁気ディスクを用いたミニ・ディスク(MD)や、従来のカセット・テープと同様の形状でデジタル録音を可能にしたデジタル・コンパクト・カセット(DCC)といった、現在の主流であるコンパクト・ディスク(CD)やDATの次の世代のメディアを目指した新しいデジタル録音機器が相次いで発表された。

しかし、これらのメディアでは、前田(1993)や藤本(1993)が述べているように、音声や音楽をデジタル化した場合の膨大なデータを、人間の聴覚特性などを利用し、データを圧縮して記録している。基本原理としては、主に聴覚心理におけるマスキング効果と、等ラウドネス特性を利用し、量子化雑音が人間に認知されにくくように、音声の帯域ごとの量子化bit数を適応的に削減

して符号化を行っている。そして、その成果として、データの圧縮率を1/4～1/5へと高め、少量の記憶容量しか持たないメディアにおいて、音楽鑑賞などの実用に耐える高音質を実現したものである。

しかし、このような人間の聴覚特性を利用した音声データの圧縮は、その評価自体に人間による官能検査を必要とする。すなわち、その方式に対しての出来不出来の評価そのものが、心理学的測定の対象となっているのである。したがって、このような機器の利用については、実施しようとする心理学的な実験の内容とよく照らし合わせて、その使用の適否を判断する必要があろう。例えば、音声の品質を問わない実験の教示などの音声提示のために用いる場合ならば、カセット・テープなどの利用と比べて遙かに望ましい。しかし、音声の特性そのものが実験条件になるような音声言語認知や、ヘッドホン提示などによって音質の影響がより顕著に現れる可能性のあるダイコティック・リスニング課題などに用いるのは、必ずしも好ましくはないと考えられる。さらに、音声情報処理技術を利用して、録音された音声を加工して実験刺激を作成するような場合には、データ圧縮における非線形な歪みが、刺激の処理過程に芳しくない影響を与える可能性もある。

したがって現時点では、原音声の録音にあたってはDATの利用が好ましい。そして、録音された音声をDAT・インターフェース・ボードを介して、ハード・ウェア的にダウン・サンプリングを行い、目的のサンプリング周波数での音声データに変換する。その上で、パーソナル・コンピュータに取り込んで、所与の仕様で管理するのが望ましいと考えられる。

なお、その他のオーディオ・アンプやスピーカー、マイクやヘッドホンなどについては、業務用、民生用の区分を問わず、音響特性ができる限りフラットなものを選択するのが妥当といえよう。

4. パーソナル・コンピュータのマルチ・メディア化

近年、パーソナル・コンピュータの世界では、グラフィカル・ユーザー・インターフェイス(GUI)の進展にみられるように、従来の抽象的な文字列操作によるコンピュータ操作の方法から、図形的な手がかりを重視した直感的理理解が容易な操作への指向を強めている。このような時流に沿って、コンピュータの操作や利用については、人間に親しみやすいインターフェイスの設計に重点がおかれてきている。そして、従来の文字や図形に加え、人間の視聴覚を重視した、音声や優れた画像によるインターフェイスが実現されつつある。もちろん、これ

までにも機種によっては、当初から音声の入出力を前提に設計されたものもあったが、最近、さらに多くのコンピュータでも音声の取り扱いができるようになり、形式も標準化されつつある。

このようなパーソナル・コンピュータのマルチ・メディア化の傾向は、従来よりも一層容易にコンピュータで音声を扱えるようになる点でも、大いに進展が期待できる。そこで現時点において、音声を扱う心理学的実験を行うために配慮すべきだと思われる点をハード・ウェアとソフト・ウェアのそれぞれの観点から検討しておく。

まず、ハード・ウェア上の留意点としては、まず現時点でのマルチ・メディア用の音声ボードは、職場でのビジネス・ユースを前提に設計されており、音声分析用のボードとは用途が異なっている。具体的な問題点として指摘できるのは、アンチ・エイリアシング・フィルタ用のロー・パス・フィルタには、やや低減率の低いものが用いられていることが多い、また、サンプリング周波数に追従して遮断周波数が変化するものは、残念ながら少ない。従って、音声データ・ベースの音声試料などの、低サンプリング周波数での音声の取り扱いにおいては、エイリアシング・ノイズへの対処が別途必要になる。また、ステレオ出力の中には、クロストークの大きいものもあり、厳密なダイコティック・リスニング課題には、必ずしも理想的なものばかりではないことが指摘できよう。

次に、ソフト・ウェアについては、前述の民生用音響機器のMDやDCCのところでも指摘したように、コンピュータにおいても、音声データの圧縮が留意すべき事柄となる。まず、膨大なデータ量になってしまう音声を少しでも圧縮し、限られた記憶容量を有効に利用し、コンピュータを効率的に活用するのは極めて大切なことである。そのため、音声データの形式についても、データ圧縮のためにADPCM方式などを利用した非線形の圧縮が行われていたり、LPC方式を応用した圧縮方式の実用化をめざして標準化が進められたりしている。このような方式は、それ自体が音声情報処理技術の成果である。しかし、その成果はそのものが、心理学的な官能検査の評価対象であり、限定された用途において、実用で許容される枠内での最善の品質をめざしたものなのである。したがって、音声を用いる心理学の実験においては、実験の条件に沿った品質のものであるかを、実験者が把握した上での利用が一層肝要となる。

以上、現時点でのパーソナル・コンピュータのマルチ・メディア化を巡る音声の取り扱い上で、配慮すべき点を検討した。今後、マルチ・メディア化の動向も、高機能化とともに、高品質化が進んでいくと思われる。そう

すれば、高品質な音声の扱いも容易になり、より柔軟なデザインでの心理学実験を工夫していく上でのプラット・フォームになることが期待できよう。

5. 音声情報処理技術の利用

心理学実験において、実験刺激として音声を用いる場合、実験条件に応じて音声を加工することが必要になる場合がある。例えば、外国人日本語学習者における日本語の長音や促音の聞き取りの問題を取り扱うような場合には、長音の作成のために母音部の持続時間の伸長や圧縮、促音作成のための無音部の挿入、また発話速度の制御のためにも、音声の時間軸上での伸長と圧縮を行える技術が望まれる。また、ダイコティック・リスニング課題では、左右のチャンネルから同時提示される音声刺激として、[apa] と [aba] のように、母音・子音・母音からなる刺激で、母音部は共通で、子音部のみ変更した音声を使用するような場合もある。このような刺激として、実際の発話を利用するような場合は、発話者には子音部のタイミングが揃うように、同じ速度で発音してもらうのであるが、現実的にはどうしても微妙にタイミングが異なってしまう。そして、その音声を左右から同時に提示すると、子音部分が必ずしも同時にならず、そのままで刺激としては不適切となる。そこで、刺激作成の段階で、はじめの母音部の持続時間を操作して、子音部の開始点を揃えるような作業が必要になる。

このような用途を満たす音声情報処理技術に、森田・板倉(1986)の考案による、音声データの時間軸上で制御のためのポインター移動量制御による重複加算法(Pointer Interval Control OverLap and Add; PICOLA) がある。

ところで、いわゆる音声情報処理技術としては、LPC分析合成やPARCOR分析合成などが有名であるが、これらと比較してPICOLAは、情報通信の観点からの情報圧縮符号化の側面については劣るが、音声データの波形を直接操作するので音質の面や計算量の少なさの点で優れており、聴覚実験の用途に合致している。また塚本・東倉(1990)も、乳幼児の泣き声についての研究で、その音質を生かしてPICOLAを制御に用いている。さらに、本装置では、この方式をもとに、音声の指定区間のみに処理を行えるように設計仕様を変更したPICOLA plusを作成し、音声処理に利用している。

このPICOLAでの音声データの処理方法は、基本的には自己相関法などで抽出できる音声波形の周期性を利用した波形の挿入や削除である。しかし、それは必ずしも単純な波形の繰り返しや削除ではない。まず処理にあたっては、対象を隣り合う2周期分の波形に限定する。

そして圧縮の場合には、まずその2つの波形の特徴を生かして重ね合わせた1周期分の波形を作り出し、もとの2つの波形の代わりに挿入する処理を行う。また伸長の場合は2周期分の音声波形から、さらに1周期分の音声波形を余分に作り、2つの波形の間に挿入する処理を実施する。さらにそのような処理の後に、次に処理すべきデータ位置を示すポインターの移動量を制御することによって、任意の圧縮と伸長を実現するのである。このような技術を利用すれば、従来のどうしても不自然な印象が残ってしまう合成音でなく、自然な音声をそのまま生かした実験状況を実現でき、Liberman (1982) などが苦慮してきたような、実験に先立った合成音声になれるための手続きも省くことができる。

PICOLAについて、森田・板倉(1986)をもとに、さらに説明する。音声の時間軸での圧縮・伸長技術として最も単純な方法としては録音テープの再生スピードを調整することであるが、この方法では容易に推測できるように、音声信号の周波数成分も変化してしまい、ピッチの変化、話者性の欠落、さらには音韻の明瞭性までも、わずかな圧縮・伸長により損なってしまう。それに對し、この技術は録音音声のピッチ情報や個人性情報を失うことなく、時間長だけを圧縮・伸長する技術であるため、音声情報検索の能率化、外国语教育の補助、聴覚障害者の聞き取りの補助、音声情報圧縮等、さまざまな応用が考えられる。

さらに、具体的なPICOLAの原理を述べる。処理にあたって、まず音声のpitchを抽出するために、入力波形に対して、分析用ポインター(▼で示す)と分析フレームを設定する(図2)。分析フレームの長さは、予想される最大pitch周期とほぼ同等にする。この分析フレームに対して自己相関関数を計算し、その最大値をとる時間遅れをTpとし、周期性の強い波形A、Bを決定する(図3)。

次に、入力信号の時間長に対する出力信号の時間長の比を、伸長・圧縮率と呼びRで示す($R = \text{出力信号の時間長} / \text{入力信号の時間長}$)。この定義によれば、圧縮の場合は $R < 1$ 、伸長の場合は $R > 1$ となる。

まず、圧縮の場合について説明する。まず音声波形Aに対しては1から0へ、Bに対しては0から1へ直線的に向かう重みをつけて加え合わせ、長さTpの音声波形Cを作る。これらの重みは、Cの前後の接続点での連続性を保つために設けるものである。次にポインターを、C上で $Lc = R Tp / (1 - R)$ だけ移動する(図3、▽で示す)。以降、それを次のポインターとみなして同様の操作を行なう。以上の操作で、長さ $Lc + Tp = Tp / (1 - R)$ の入力音声波形から、長さLcの出力音

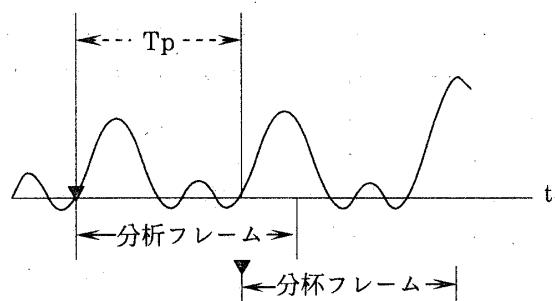


図2 自己相関関数を利用した入力音声のピッチ周期の抽出

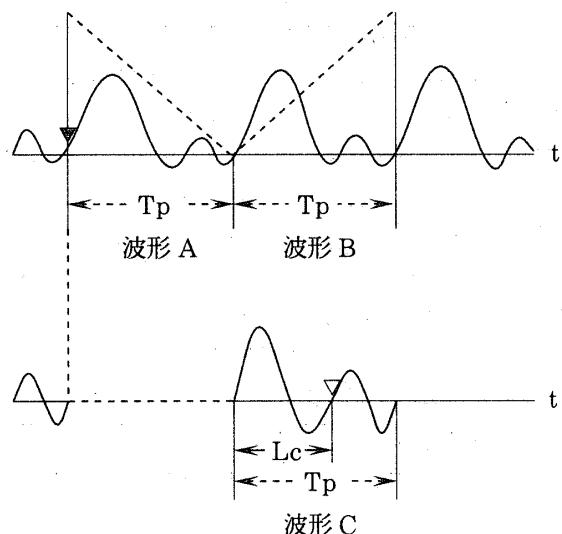


図3 PICOLAによる音声の時間軸上の圧縮

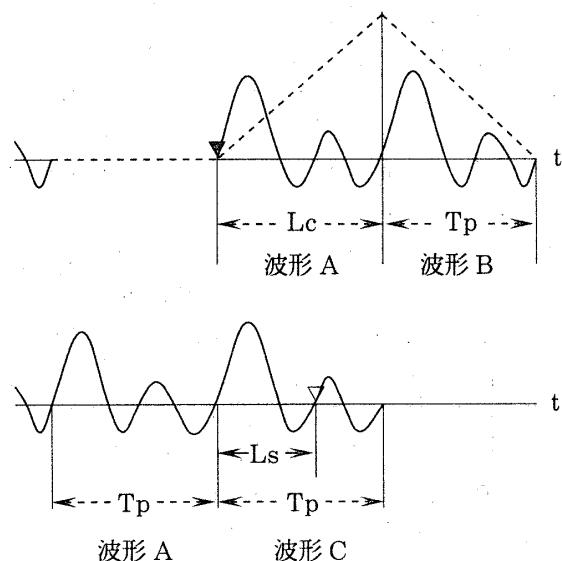


図4 PICOLAによる音声の時間軸上の伸長

声波形が作られており、圧縮・伸長率Rの満足されていることがわかる。この圧縮では、 $R > 0.5$ では、一度も重ね合わせの行われない波形が一部に生じ、また $R < 0.5$ では2回以上の重ね合わせが行われている波形が存在することになる。

次に、伸長の場合について説明する。図4において、現在のポインターは▼で表示されている。先述の音声波形A, Bについて、まずAをそのまま出力する。次にAに対しては0から1へ、Bに対しては1から0へ直線的に向かう重みをつけて加え合わせ、長さTpの音声波形Cを作る。これらの重みも圧縮の場合と同様に、Cの前後の接続点での連続性を保つために設けるものである。そして最後にポインターをC上で $L_s = T_p / (R - 1)$ だけ離れた位置に移動する(図4、▽で示す)。以降、それを次のポインターをみなして同様の操作を行なう。以上の操作では、長さ L_s の入力音声波形から、長さ $L_s + T_p = R T_p / (R - 1)$ の出力音声波形が作られており、圧縮・伸張率Rの満足されていることがわかる。伸長では、 $R < 1.5$ では、一度も重ね合わせの行われない波形が一部に生じ、また $R > 1.5$ では2回以上の重ね合わせが行われている波形が存在することになる。

なお、実際の処理では、ポインターの移動量は整数の値をとるので、正確な伸縮を行なうには、処理ごとの誤差を打ち消すような修正も行なう。

このような処理がなされた音声の評価としては、原音声と、圧縮・伸長の処理により再びもとの時間長に戻した音声について、LPCスペクトル歪を計算されているが、アルゴリズムの性質上、聴覚では聞き取れない時間のずれが生じ、正確な評価ができない。そこでこの影響を取り除くために、新たな歪尺度としてDPマッチングを用いたLPCスペクトル歪が提案されている。この尺度により、従来、有効とされてきたTDHS法は、圧縮の程度が小さくなると一度減少した歪みが再び増大するのに対し、PICOLAでは、時間長を70%に圧縮した場合にLPCスペクトル歪が1dBとなり、圧縮の程度が小さくなるに従って、単調に歪が減少することが示されている。さらに、ピッチ抽出法の検討、複数回の圧縮・伸長、二段階の圧縮・伸長、他の波形符号化法との接続による情報圧縮についても検討した結果、音質も良好で計算量としても実時間処理が充分可能なものであることが示されている。

本装置では、以上のようなPICOLAの特徴を生かし、さらに入力音声における指定区間のみの伸長・圧縮をできるように設計仕様を変更したPICOLA plusを作成している。このPICOLA plusにおいては、指定区間をms以下の音声データの1サンプル単位で、指定し、

伸縮比も細かく指定するようになっている。しかし、前述のPICOLAの処理方法からわかるように、実際の処理を行う時間の最小単位としては、1ステップ分の伸長・圧縮の処理を行う時間以下の単位での制御はできない。したがって、指定区間の伸縮処理の終了は、計算で予測される伸縮時間を基準にして、PICOLAの処理を繰り返していく、処理される音声の時間が、基準時間の前後の最も近くなる時点での処理を打ち切っている。ここで現れる誤差は、音声そのもののpitch周期、分析フレーム長、自己相関関数を求める時の時間遅れ下限値、伸縮比の相互の関連により発生する。したがって、PICOLA plusを用いて1msごとに変化するような刺激連続体を作成することは現実的ではなく、実際に音声刺激を作成した後で、目的の操作が達成されているかどうかを確認することが重要である。

以上、本装置で主に用いられている音声情報処理技術について説明した。

6. 今後の発展

本装置のメリットは、心理学実験において音声を扱う上で、音声操作のための専用機器ではなく、パーソナル・コンピュータを用いた点である。すなわち、今後現れてくるであろう新規の優れたハード・ウェアを増設するような場合でも、これまでの蓄積を生かしたままに機能拡張をすることができる。また、ソフト・ウェアの進展により、現時点の本装置ではまだ使われていない優れた音声情報処理技術の利用も可能である。例えば、DSPを利用することにより、PARCOR分析合成をパーソナル・コンピュータ上で実用的な処理速度で実現した今川・桐谷(1989)の開発による『音声録聞見』の利用などにも対応できよう。

今後、コンピュータや音声情報処理技術の発展に応じて、音声を取り扱うための実験装置の整備も継続していくなければならない。そして、このような装置を活用することにより、従来の視覚優位であった心理学の研究に加え、音声知覚に代表される聴覚からの入力を中心とする人間の認知などの心理事象を、一層明らかにしていく心理学の研究が、今後、精力的に進められていくことを切望している。

引用文献

- 阿部純一(編) 1988 パーソナル・コンピュータによる心理学実験入門プログラミング ブレーン出版
藤本健文 1993 ディジタル・コンパクト・カセット

音声を扱うためのパーソナル・コンピュータを用いた心理学実験装置

- (DCC) の開発に携わって、日本音響学会誌, 49, 284-292.
- 深田昭三 1992 パーソナルコンピュータにおける音声発生ルーチンの作成 平成4年度文部省科学研究費重点領域研究(2) 研究課題番号04207202 「日本語音声教育の社会言語学的言語工学的研究」 E8班研究成果刊行書
- 古井貞熙 1985 デジタル テクノロジー シリーズ⑥ デジタル音声処理 東海大学出版会
- 林 貞子 1976 ノンセンスシラブル新規準表 東海大学出版会
- 今川 博・桐谷 滋 1989 DSP を用いたピッチ・フォルマント実時間抽出とその発話訓練への応用 電子情報通信学会技術報告 SP89-36, 17-24.
- 板橋秀一 1992 文部省「重点領域研究」による音声データベース 日本音響学会誌, 48, 894-898.
- 河合優年・吉崎一人・伊藤晋彦 1989 マイクロコンピュータを用いた汎用音声記録・再生装置 心理学研究, 60, 113-121.
- 小林哲則・板橋秀一・速水 悟・竹沢寿幸 1992 日本音響学会研究用連続音声データベース 日本音響学会誌, 48, 888-893.
- 国立国語研究所 1962 国立国語研究所報告21 現代雑誌九十種の用語用字 第一分冊 総記及び語意表
- 国立国語研究所
- Lieberman, A. M. 1982 On finding that speech is special. *American Psychologist*, 37, 148-167.
- 前田保旭 1993 ミニディスクシステム 日本音響学会誌, 49, 277-283.
- 牧野正三・二矢田勝行・真船裕雄・城戸健一 1992 東北大-松下単語音声データベース 日本音響学会誌, 48, 899-905.
- 森田直孝・板倉文忠 1986 自己相関法による音声の時間軸での伸縮方式とその評価 電子通信学会技術報告 信学技報, 86(25), 9-16.
- 中谷和夫(監修) 1975 パーソナル・コンピュータによる心理学実験入門 ブレーン出版
- 匂坂芳典・浦谷則好 1992 ATR 音声・言語データベース 日本音響学会誌, 48, 878-882.
- 田中和世・速水 悟 1992 電総研の研究用音声データベース 日本音響学会誌, 48, 883-887.
- 塚本妙子・東倉洋一 泣き声の時間構造とカテゴリー判断の関係 日本心理学会第54回大会発表論文集, 522.
- Vanderplas, J. M. & Garvin, E. A. 1959 The Association Value of Random Shapes. *Journal of Experimental Psychology*, 57, 147-154.

(1993年8月25日 受稿)

ABSTRACT

A psychological equipment experiment for controlling speech-sound stimuli using a personal computer : for the studies of spoken language cognition, music perception, dichotic listening tests, and cross modality tasks

Teruhisa UCHIDA

These days, personal computers are used frequently in psychological experiments. In Japan, the major personal computers have no sound recording devices, so, thus we have seen few cases using computers in which speech-sound stimuli is controlled. As for the studies of spoken language cognition, it is believed that computers should be used for processing sound data. The purpose of this study is to make contribution in the fields of auditory and cognitive psychology. At first, a multi-purpose equipment used in auditory and cognitive experiments at Nagoya University was introduced and inspected points to be careful in the cases of managing speech-sound stimuli were studied. In addition, the compatibility of data with various speech-sound database was examined, the use of various general audio-visual apparatus was considered from various viewpoints, and the problems and possibilities of using personal computers installed with multimedia expansion introduced. Then the PICOLA plus was introduced. This is a sound processing technique (time compression and expansion of speech sound) used in this type of equipment. In the end, views about using this equipment from now were examined.