平成28年度 日本大学文理学部オープンキャンパス 特別講義

音声認識の仕組みを知ろう

日本大学 文理学部 情報科学科 准教授

北原 鉄朗

kitahara@chs.nihon-u.ac.jp

http://www.kthrlab.jp/

Twitter: @tetsurokitahara

皆さんに実際に試していただけるように
操作方法などを詳しく説明していますが、
時間と施設の制約から、講義中に皆さんに
お試しいただく機会をつくることができません。
講義内で用いるソフトウェアは、私のWebサイト
（http://www.kthrlab.jp/）からダウンロードできる
ようにしてありますので、ぜひ帰宅後に
お試しください。

音の認識と合成

音の認識

音 → 文字など

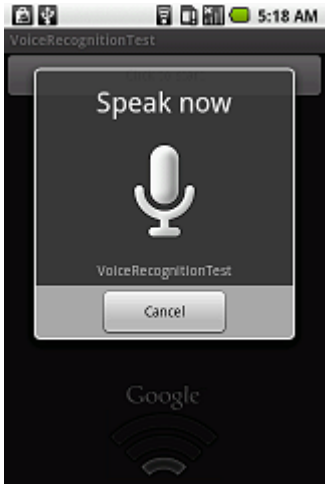

音声認識

声による
個人認証

音の合成

文字など → 音

音声案内
(カーナビなど)

歌声合成
(Vocaloidなど)

音声認識･音声合成の基本的な仕組みを知ろう

そもそも音って何?

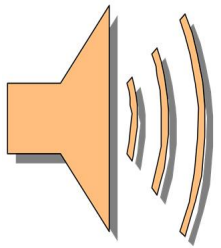

スピーカーが空気を押す → 押された空気が隣の空気を押す → これが連鎖的に繰り返される → 鼓膜が押され人間が音を知覚する

↳ 押した側は押した反動で戻ってくる

このような、ものが行ったり来たりする運動が、遥か遠くまで伝わる現象を波動(または波)という

スピーカーが空気をどのぐらい押すのかを波形として表す

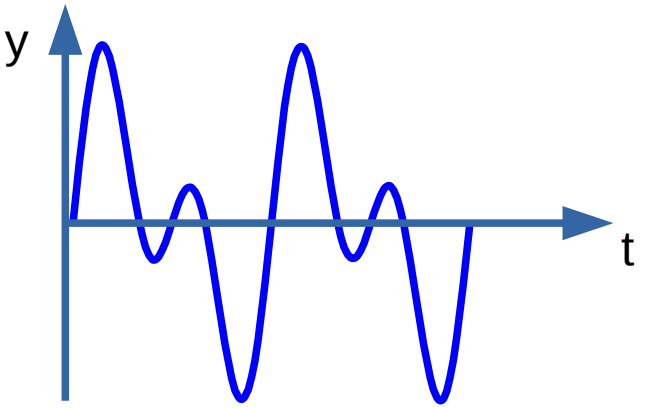

参考

- http://www.wakariyasui.sakura.ne.jp/2-2-0-0/2-2-1-1onnpa.html
- http://www.ne.jp/asahi/tokyo/nkgw/gakusyu/hadou/tate-yoko-wave/wave1.html

音の波形を数式で表してみましょう

$$y(t) = A \sin(2\pi f t)$$

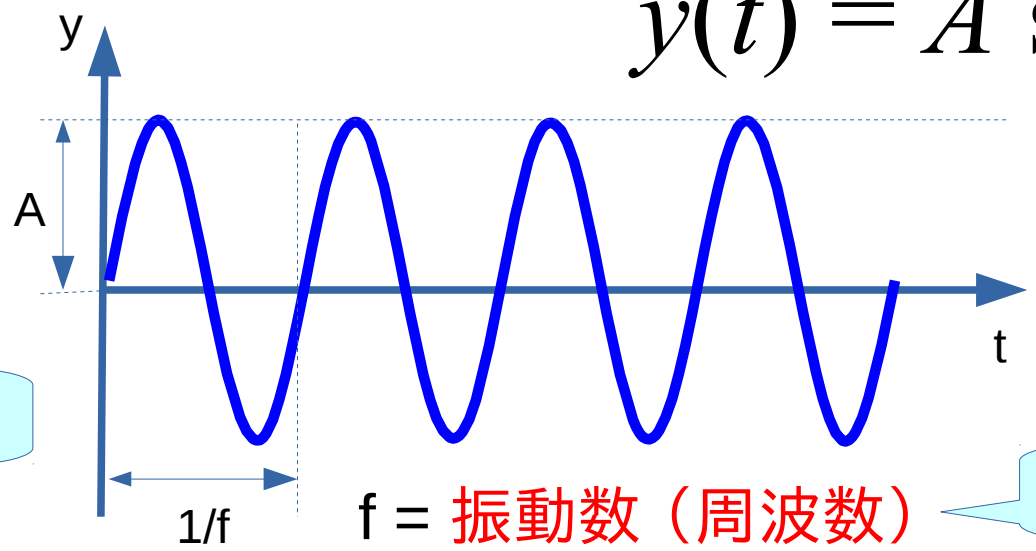

振幅
（振れの大きさ）

音の大きさ

f = 振動数（周波数）
（振れの速さ）

音の高さ

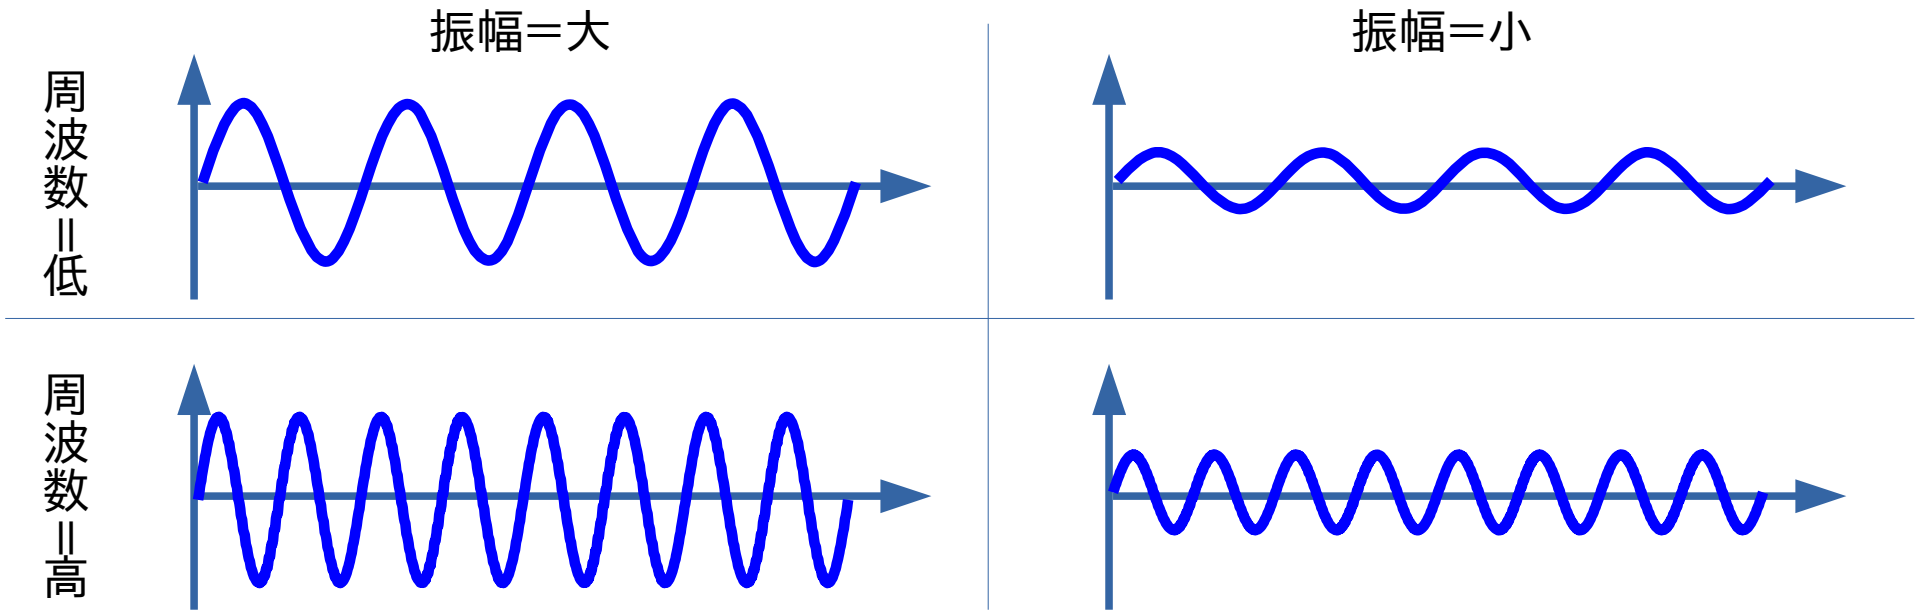

プログラミング用ソフトウェア「FreeMat」を起動してみよう

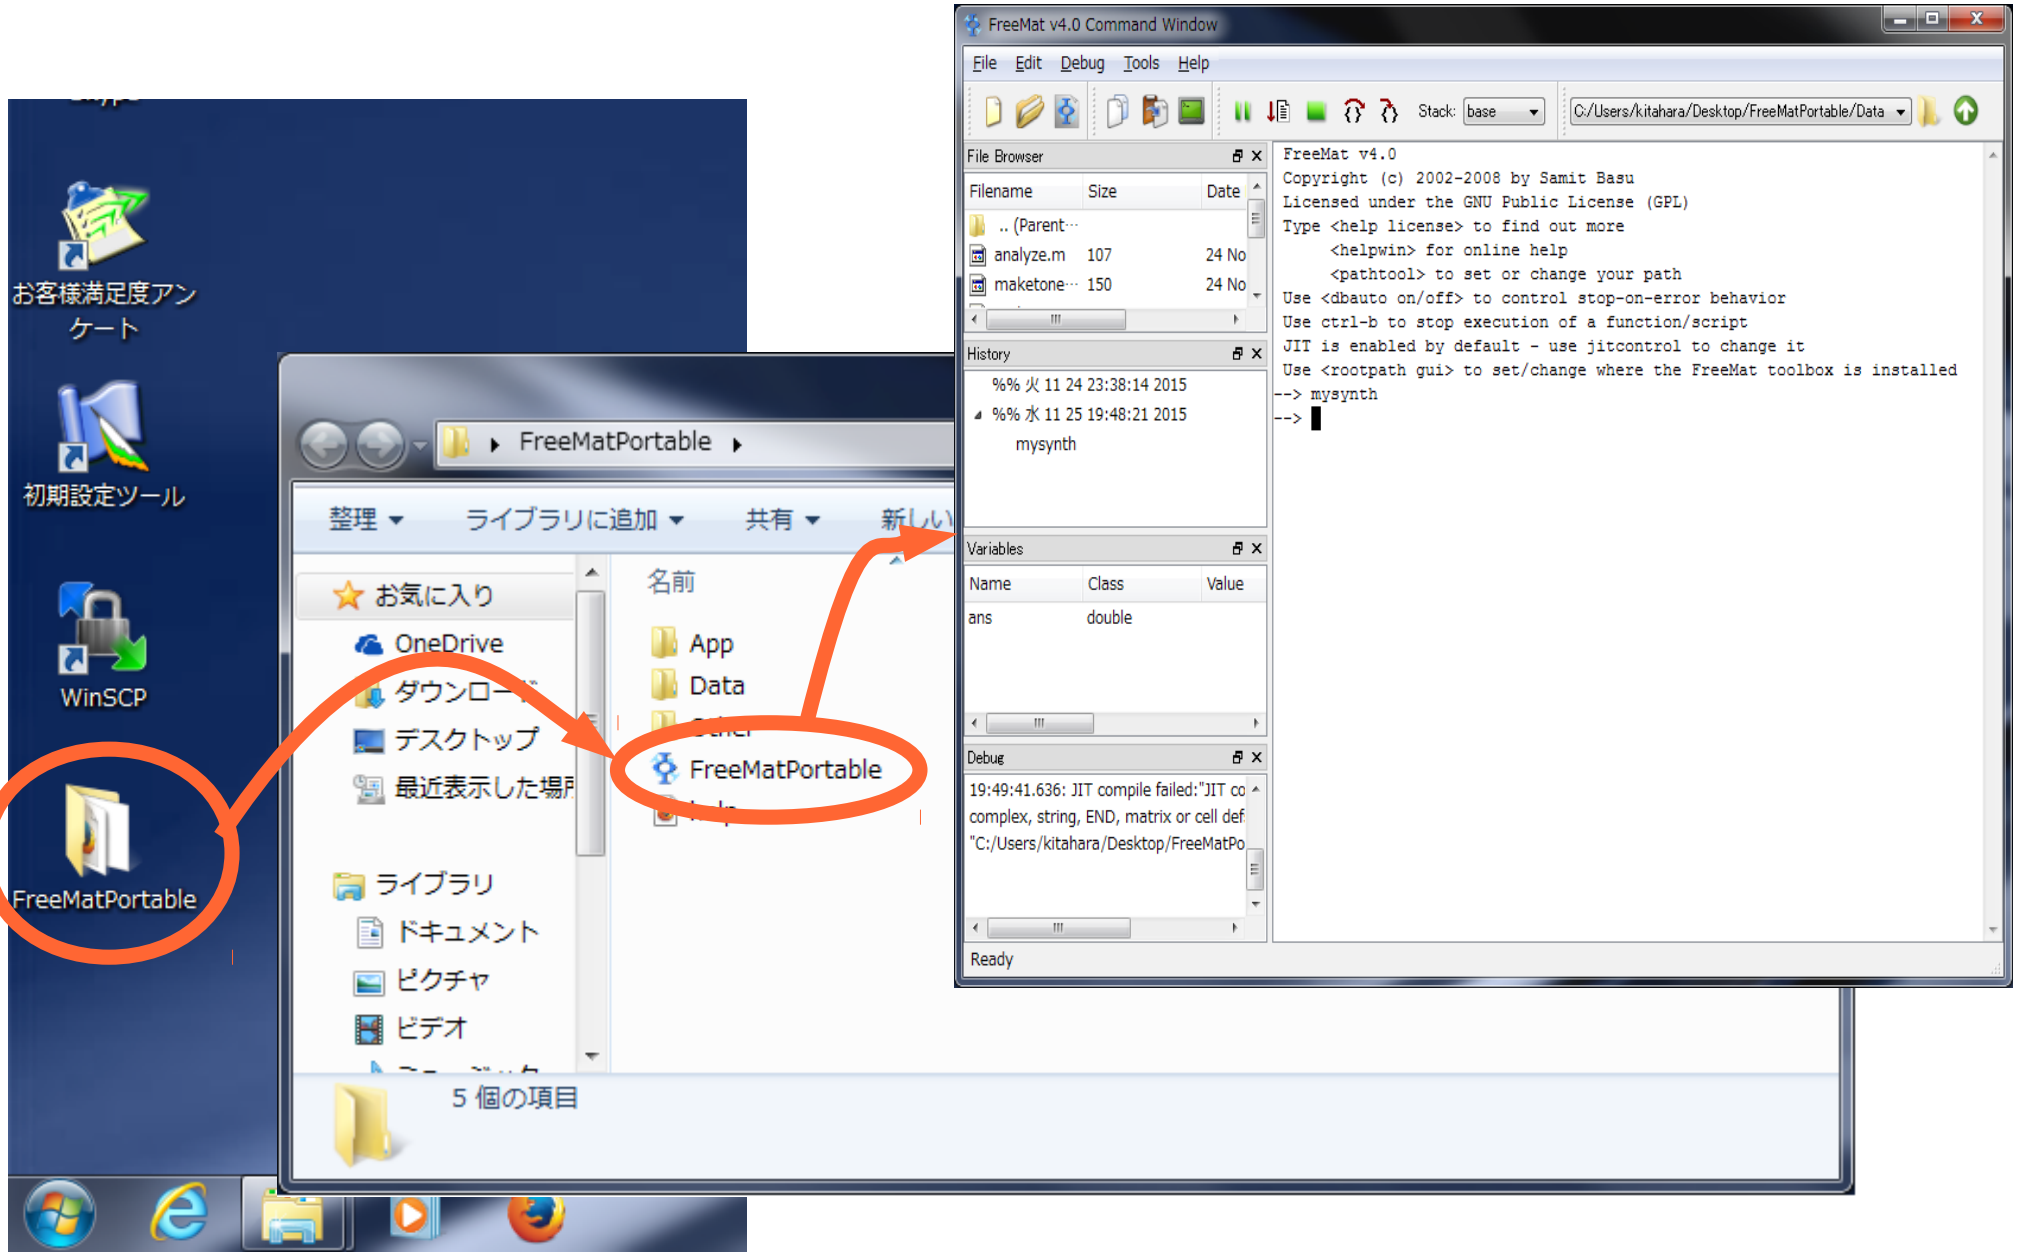

「音の波形を作るプログラム」を作ってみよう

計算機にして欲しいことを書き並べたものが「プログラム」。

先ほどの式 $y(t) = A\sin(2\pi f t)$ を使って音の波形を作るプログラムを作ってみましょう。 ←― 実際は作成済みで、読み込むだけ

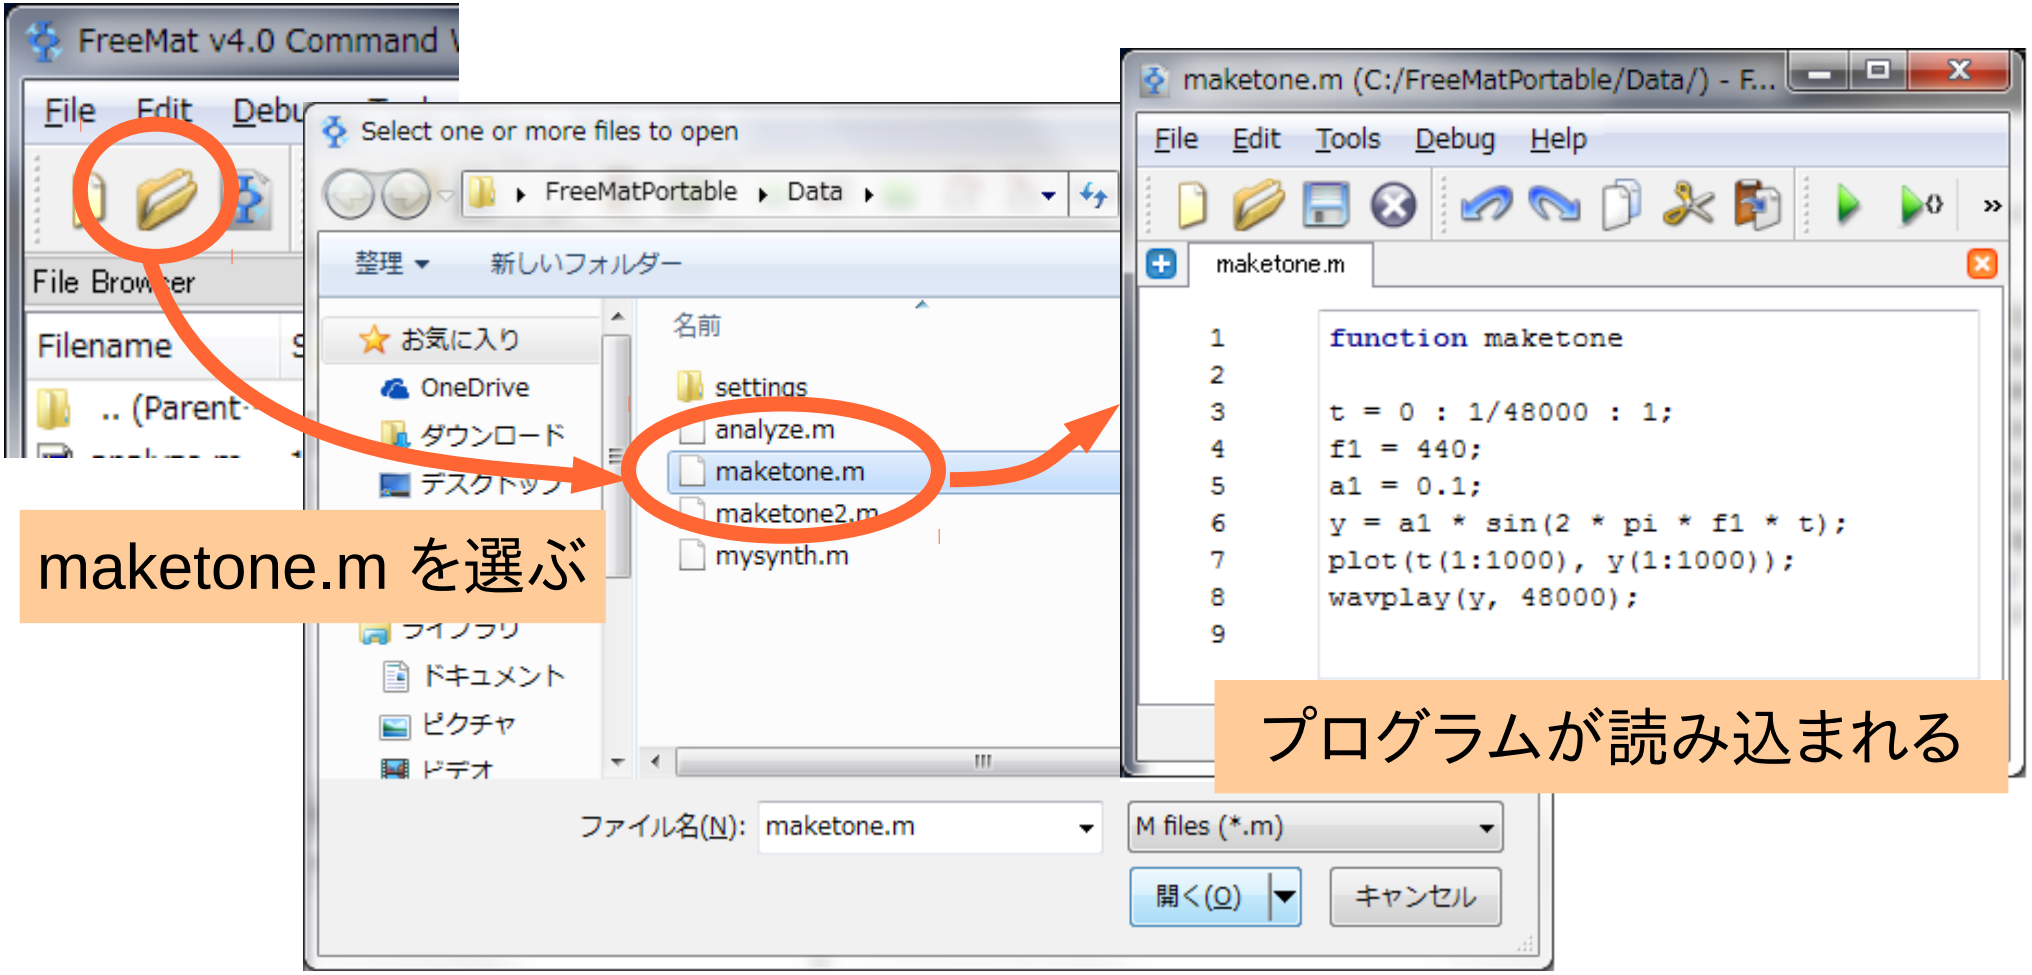

解説

```
function maketone
```

maketoneという名前のプログラムを作ります。

```
t = 0 : 1/48000 : 1;
```

tの値は、1/48000[秒]刻みで0[秒]から1[秒]までとします。

```
f = 440;
```

周波数は440[Hz]とします。

```
a = 0.1;
```

振幅は、音が割れるぎりぎりの振幅の0.1倍とします。

```
y = a * sin(2 * pi * f * t);
```

yの値を、$y(t) = A \sin(2\pi f t)$ で計算します。

```
plot(t(1:1000), y(1:1000));
```

$y(t) = A \sin(2\pi f t)$ のグラフを1～1000番めの点だけ描画します。

```
wavplay(y, 48000);
```

作った波形をスピーカーから鳴らします。

プログラムを実行してみよう

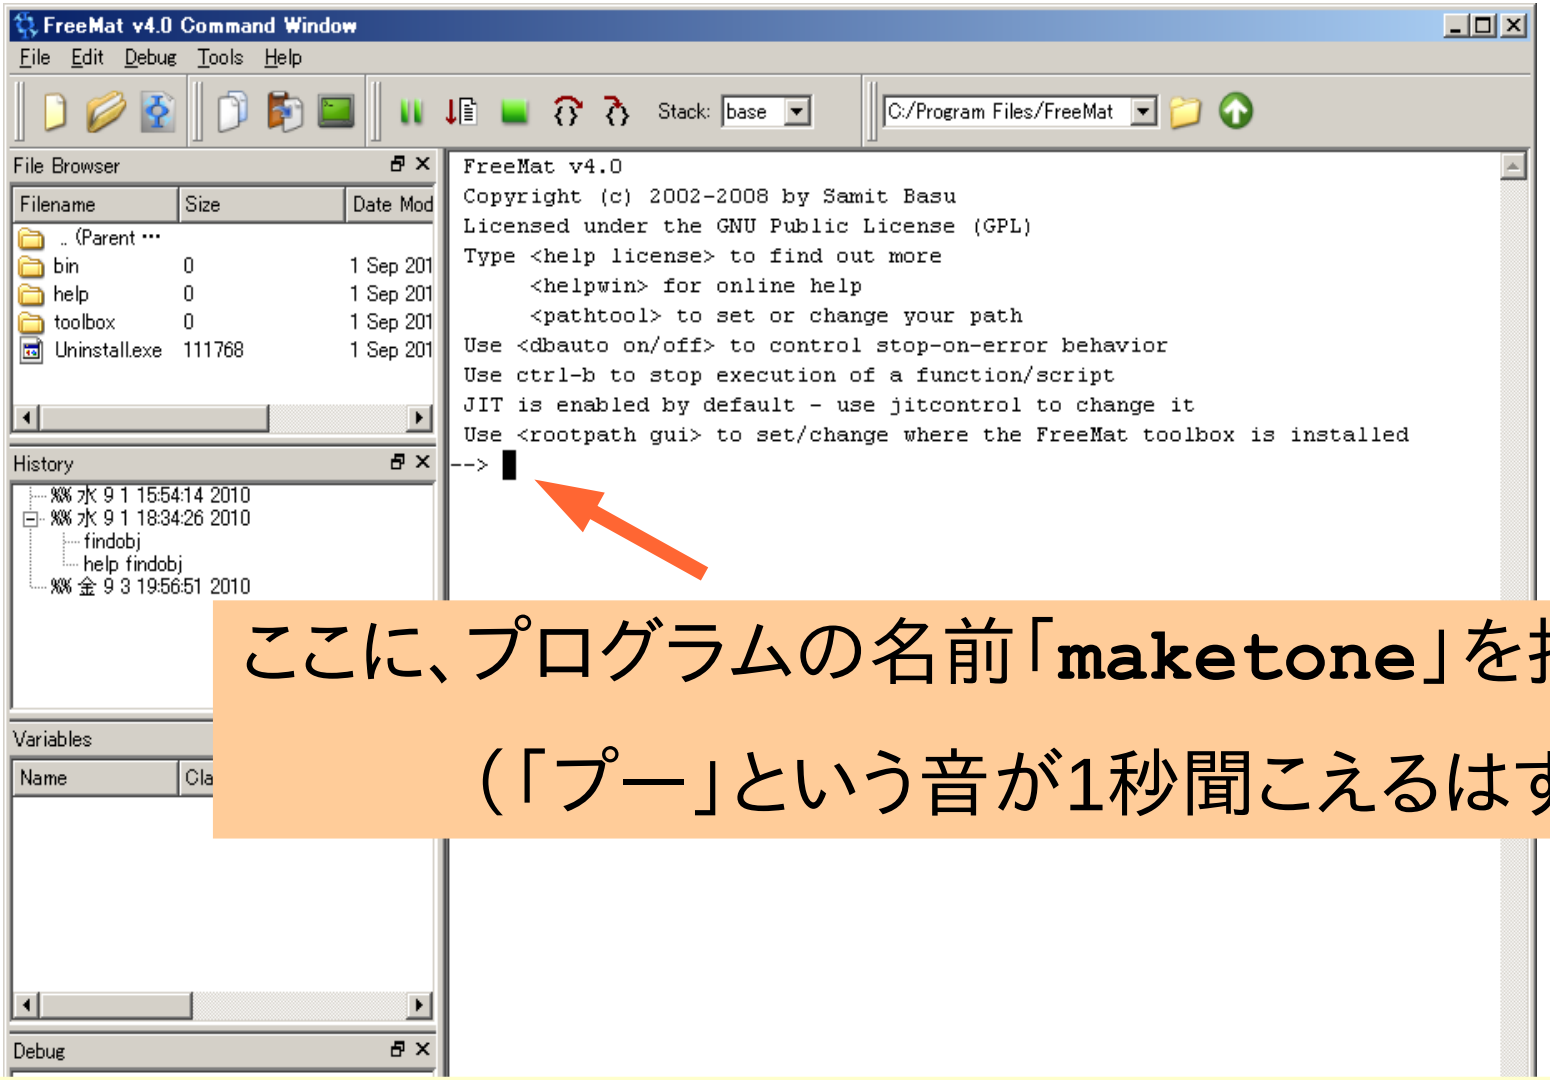

ここに、プログラムの名前「**maketone**」を打ち込む。

（「プー」という音が1秒聞こえるはず）

注意

何も聞こえないときは、ヘッドフォンの音量設定が0になっている可能性があります。確認しましょう。

2つの音を出してみよう

2つの音からなる和音を作ってみましょう。

プログラムを以下のように書き換えて実行してみましょう。

```
function maketone

t = 0 : 1/48000 : 1;
f1 = 440;
f2 = 660;
a1 = 0.1;
a2 = 0.1;
y = a1 * sin(2 * pi * f1 * t) + ...
    a2 * sin(2 * pi * f2 * t);
 plot(t(1:1000), y(1:1000));
 wavplay(y, 48000);
```

※下線部が変更点

周波数や振幅をいろいろ変えて、
きれいな和音やきたない和音を作ってみよう。

2つの音が1つになる!?

片方の周波数を440Hz、もう片方を880Hzにしてみましょう。

```
function maketone

t = 0 : 1/48000 : 1;
f1 = 440;
f2 = 880;
a1 = 0.1;
a2 = 0.1;
y = a1 * sin(2 * pi * f1 * t) + ...
    a2 * sin(2 * pi * f2 * t);
plot(t(1:1000), y(1:1000));
wavplay(y, 48000);
```

どうなりましたか?

f2がf1のちょうど2倍のときだけ、1つの音に聞こえるかも!?

f2を色々変えて、確かめてみましょう。

3つの音も1つになる!?

さきほどの音に、1320Hzの音も加えてみましょう。

```
function maketone

t = 0 : 1/48000 : 1;
f1 = 440;
f2 = 880;
f3 = 1320;
a1 = 0.1;
a2 = 0.1;
a3 = 0.1;
y = a1 * sin(2 * pi * f1 * t) + ...
    a2 * sin(2 * pi * f2 * t) + ...
    a3 * sin(2 * pi * f3 * t);
plot(t(1:1000), y(1:1000));
wavplay(y, 48000);
```

※下線部が変更点

どうなりましたか? こちらも1つの音に聞こえましたか?

音に関する大事な性質

ある正弦波に、周波数がその整数倍の正弦波を足し合わせると、1つの音に聞こえる場合があります。

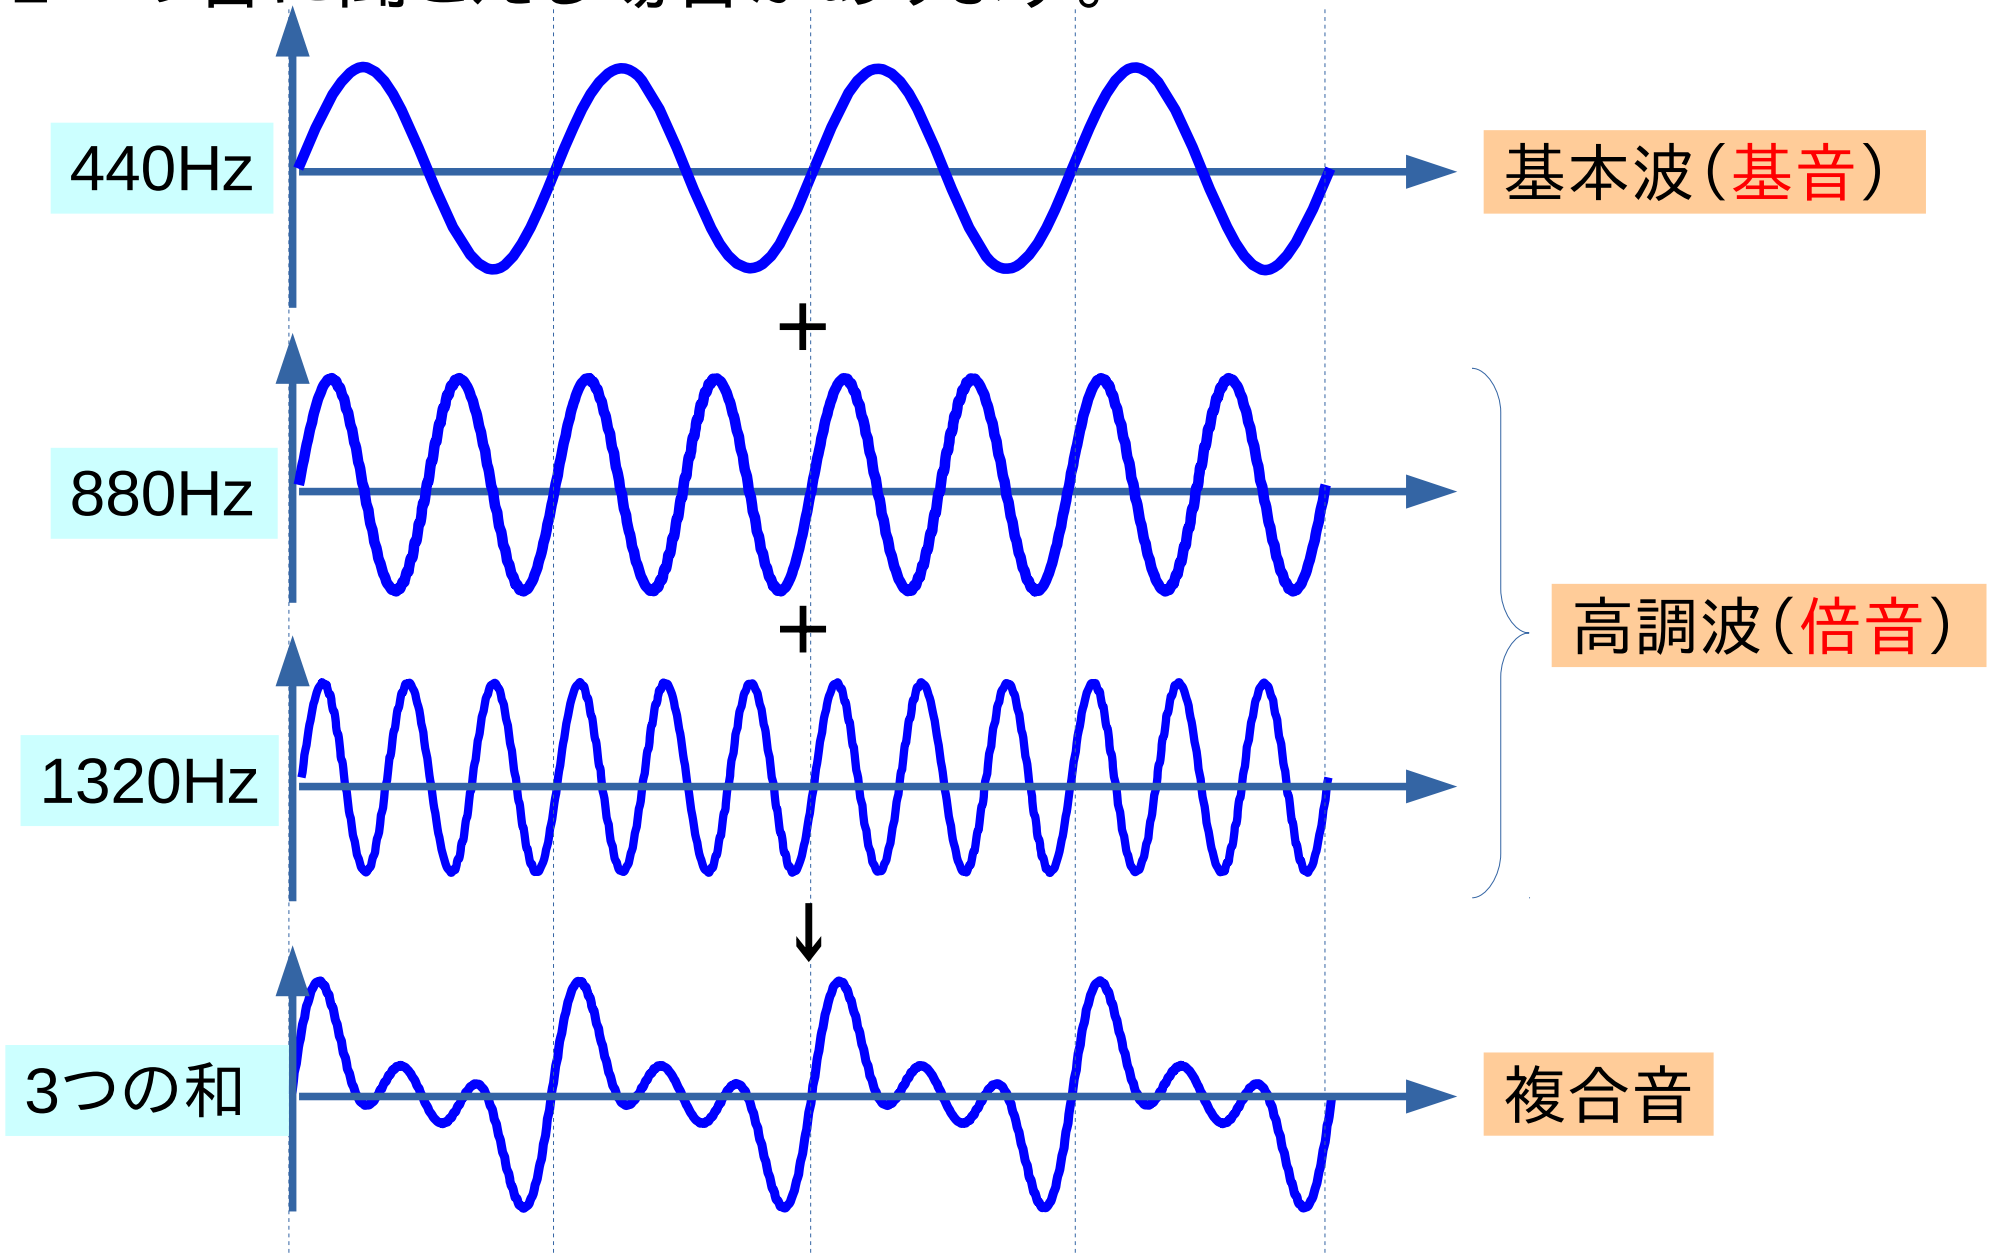

私が作ったプログラムでさらに試そう

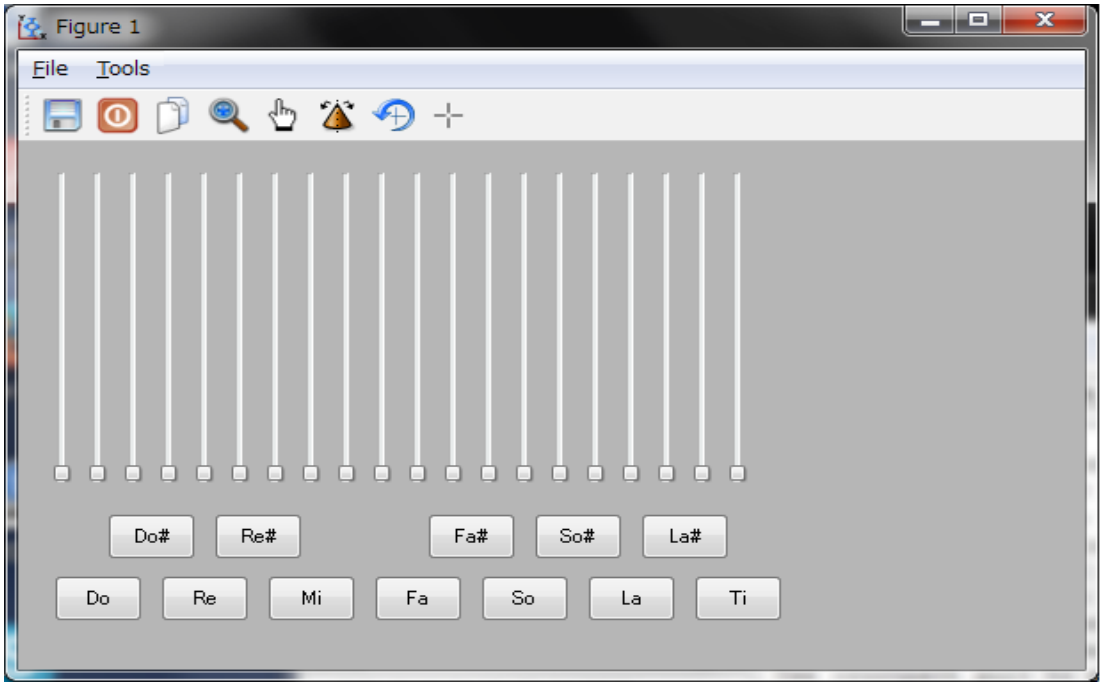

1) コマンドを打ち込む場所に「**mysynth**」と入力して起動

2) 基音から20次倍音までの振幅（大きさ）を指定（＝音色）

3) ボタンを押すと、その高さの音を合成

（内部でやってることは、先ほどのプログラムを一緒）

各倍音の振幅をいろいろ変えて試してみよう

音の合成から分析へ

周波数が整数倍の正弦波を足し合わせると、1つに聞こえる

1つ（に聞こえる）音も、周波数が整数倍の正弦波が
いくつも足し合わされてできている

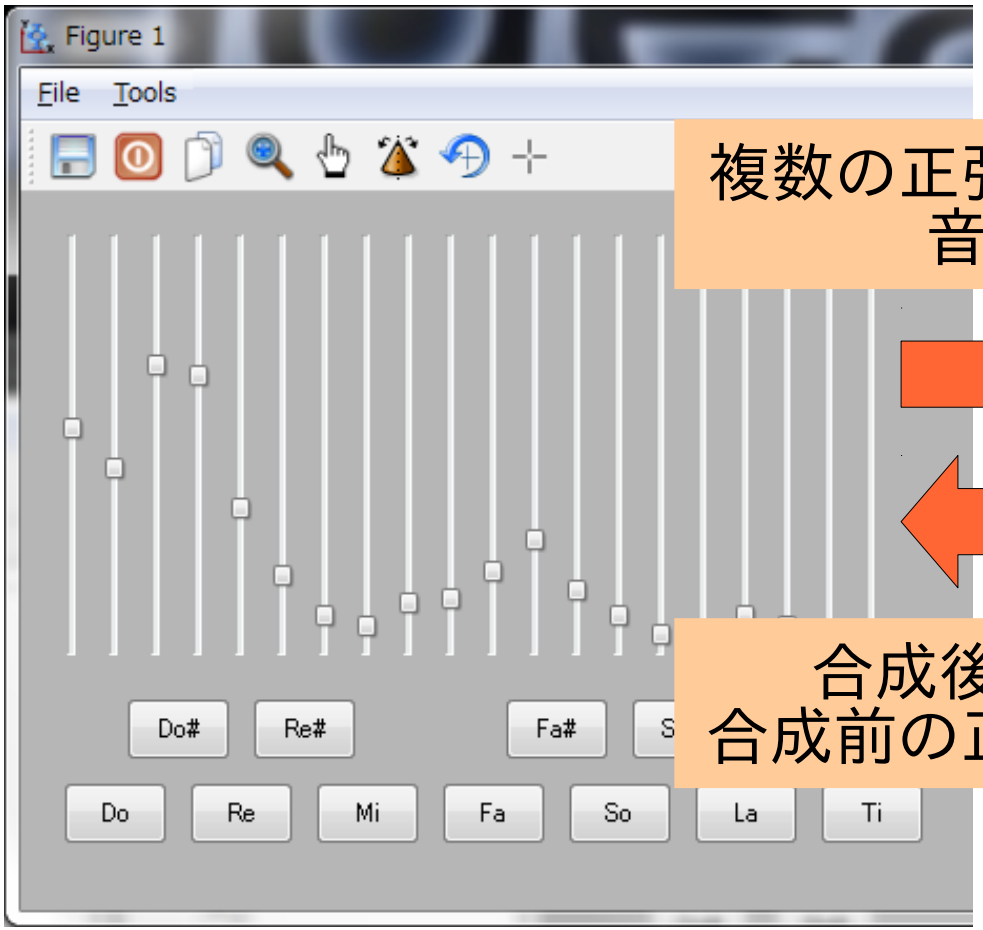

複数の正弦波を合成して
音を作る

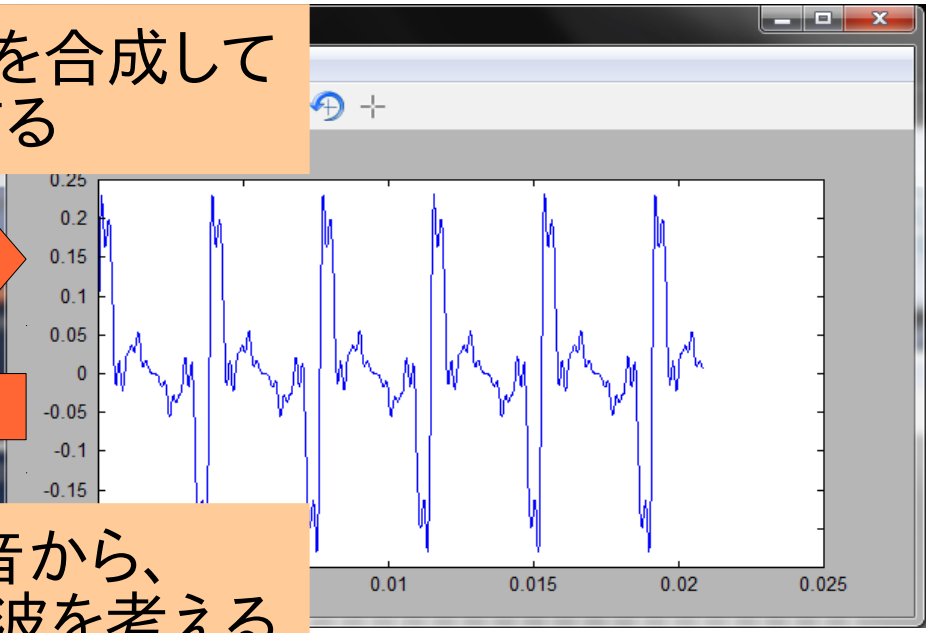

合成後の音から、
合成前の正弦波を考える

フーリエ変換

音を周波数ごとに分解する技術

$$F(\omega) = \frac{1}{2\pi}\int_{-\infty}^{\infty} f(t)e^{-i\omega t}dt$$

←理解しなくていいです

/a/

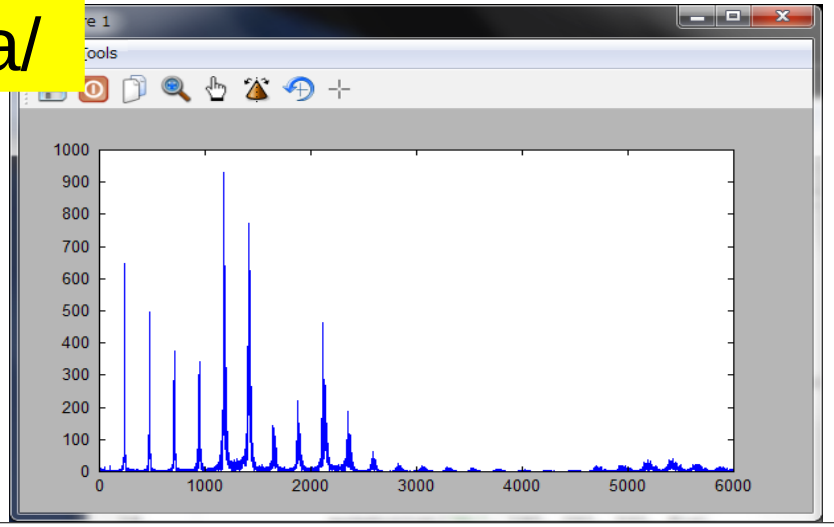

/i/

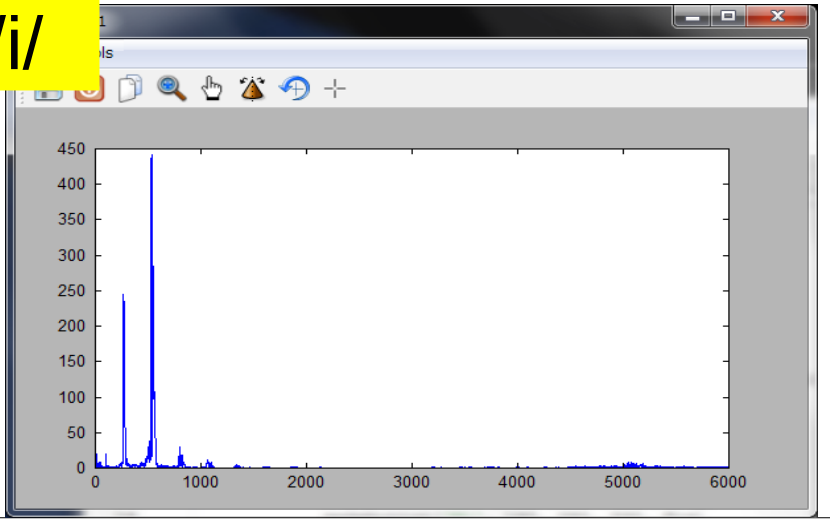

/u/

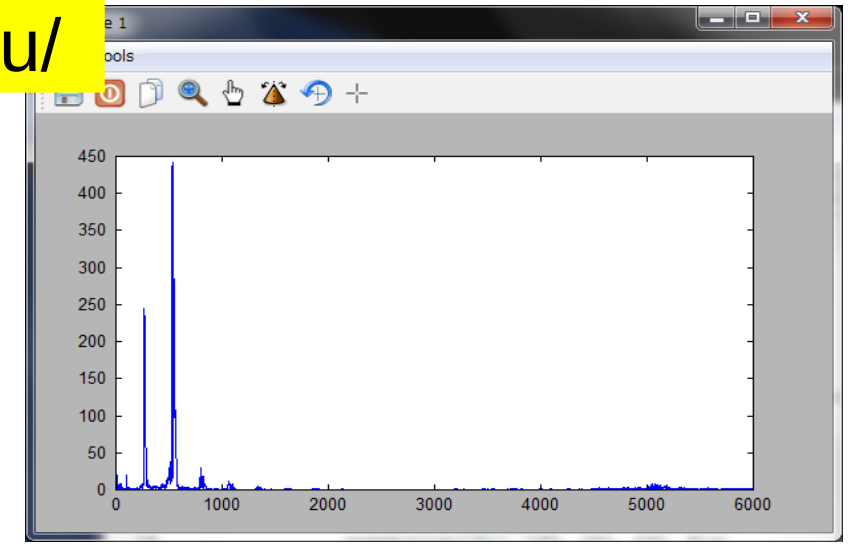

/e/

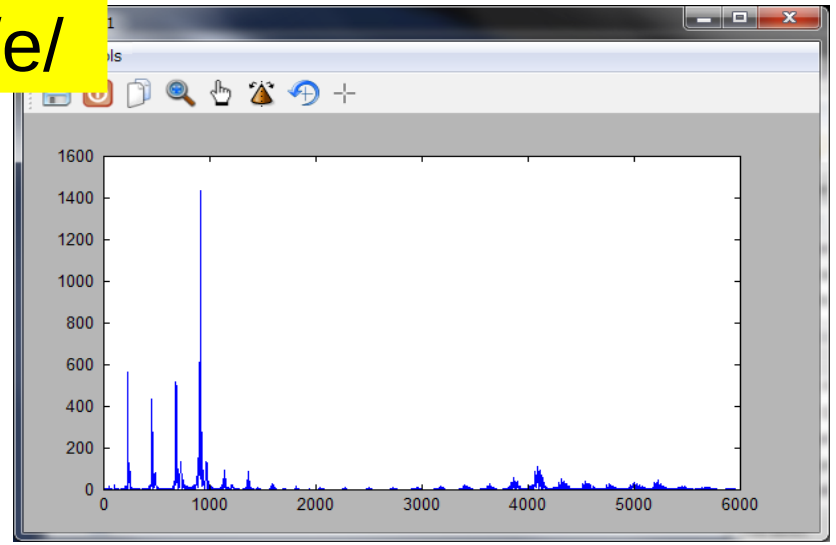

フーリエ変換を試そう

1.FreeMat のコマンドを打ち込む部分に

　`analyze` と入力してプログラムを実行させよう

2.すぐに録音状態になるので、2秒間「あー」と言おう

3.フーリエ変換の結果がグラフとして表示されます

```
function analyze

y = wavrecord(2 * 16000, 16000);
Y = fft(y);
A = abs(Y);
plot(A(1 : 6000));
```

←2秒間マイクから録音
←フーリエ変換を実行
←複素数なので絶対値
←結果をグラフ表示

フーリエ変換のポイント

- どの周波数の倍音が強いかは、「あ」には「あ」に、「い」には「い」に特有の傾向がある（フォルマントという）
- フォルマントを人工的に再現して音を合成すれば、そのフォルマントの母音の音に聞こえるようになる（音声合成の基本）
- マイクから入力された音のフォルマントが、あらかじめ集めておいた「あ」の音のフォルマントと近ければ、その音は「あ」に違いないと判断できる（音声認識の基本）

実際にはもっと高度な値を求めるけど

音声認識の基本

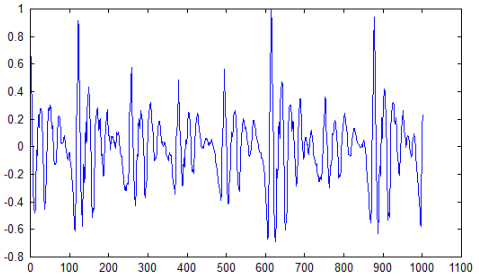

フーリエ変換

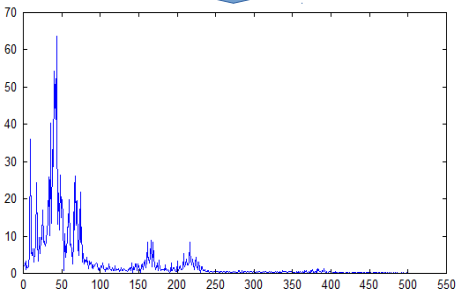

振幅が際立って

大きい周波数を探す

（実際はもっと複雑なことを行う）

/a/～/o/ の音声を

あらかじめ用意

左と同じことをする

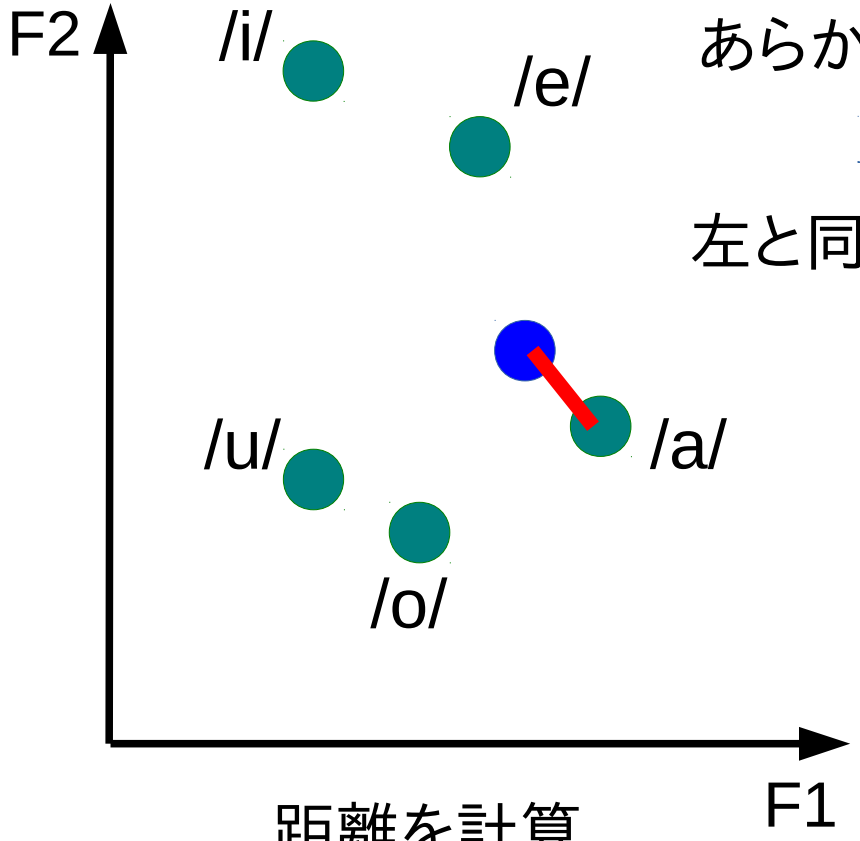

距離を計算

/a/ が最も距離が小さい

この人は /a/ と言ったに違いない

音声認識を試そう

1.FreeMatのコマンドを打ち込む部分に

　recognize と入力してプログラムを実行させよう

2.すぐに録音状態になるので、2秒間「あー」と言おう

3.「**ans = 1**」と出れば成功

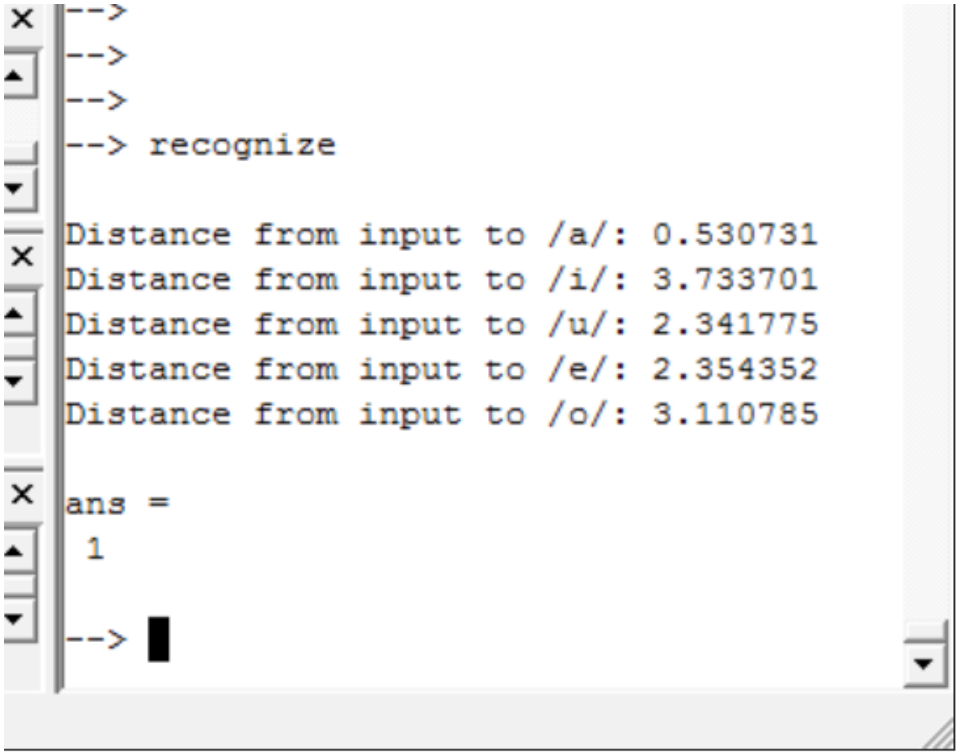

- 「いー」～「おー」も試そう
  （「2」～「5」が返ればOK）
- 比較用の音声は私の声なので、
  声質が違うとうまくいかないかも

まとめ

- sinの式を入れれば、計算機で音を作れる
- ある周波数の正弦波に、その整数倍の周波数の正弦波を合成すると、1つに聞こえる（場合がある）
- 混ぜる正弦波の振幅をどのぐらいにするかが、音の音色を決める
- 合成後の波形から、合成前の正弦波を知るには、「フーリエ変換」を使う
- これらが、音声認識／音声合成の基本となる