

La synthèse vocale

OBJECTIF: GÉNÉRER NUMÉRIQUEMENT UNE VOIX HUMAINE À PARTIR DE
D'UN TEXTE



Sommaire

2

I- Etude de la voix humaine

- 1) Origine et caractérisation de la voix humaine
- 2) Paramètres pertinents à étudier
- 3) Etude phonétique : décomposition du signal

II- Synthèse

- 1) D'une voyelle
- 2) D'une consonne

III-Concaténation

- 1) Concaténation de phonèmes
- 2) Algorithme d'identification des phonèmes à concaténer

IV-Conclusion

I. Etude de la voix humaine

1)- Origine et caractérisation de la voix humaine

➤ Voix

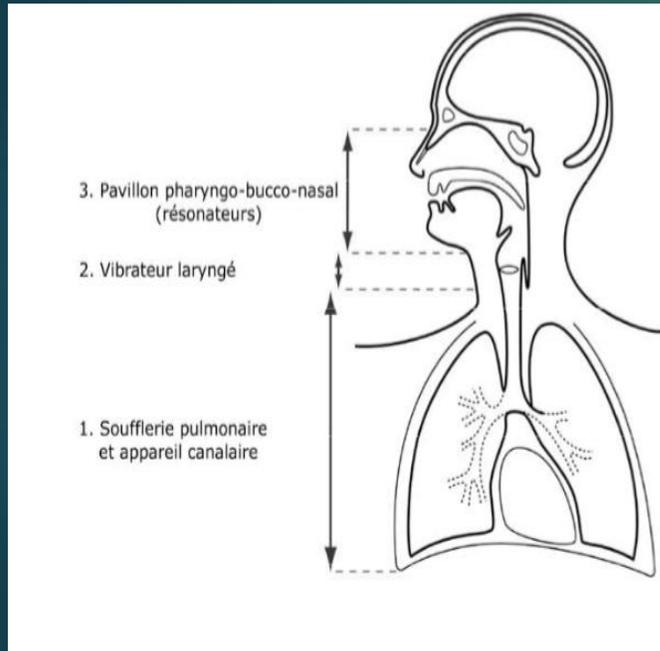
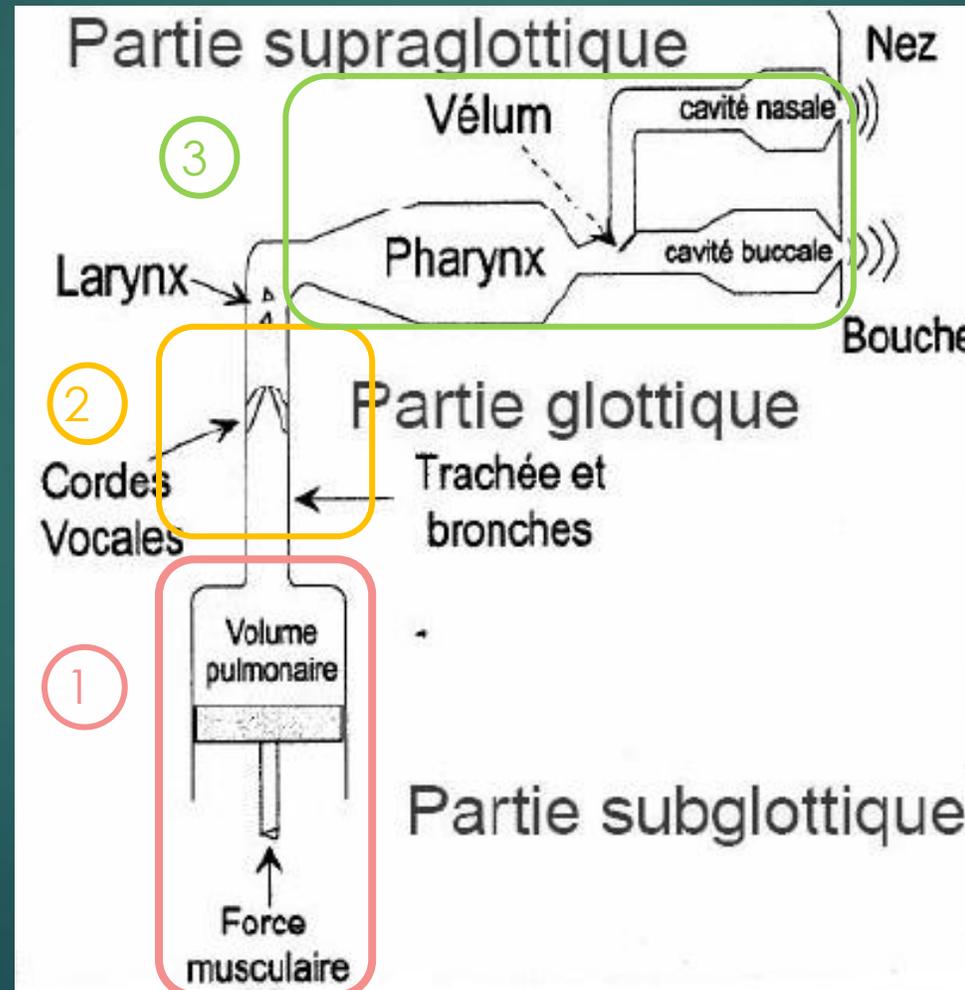


Schéma de l'appareil phonatoire

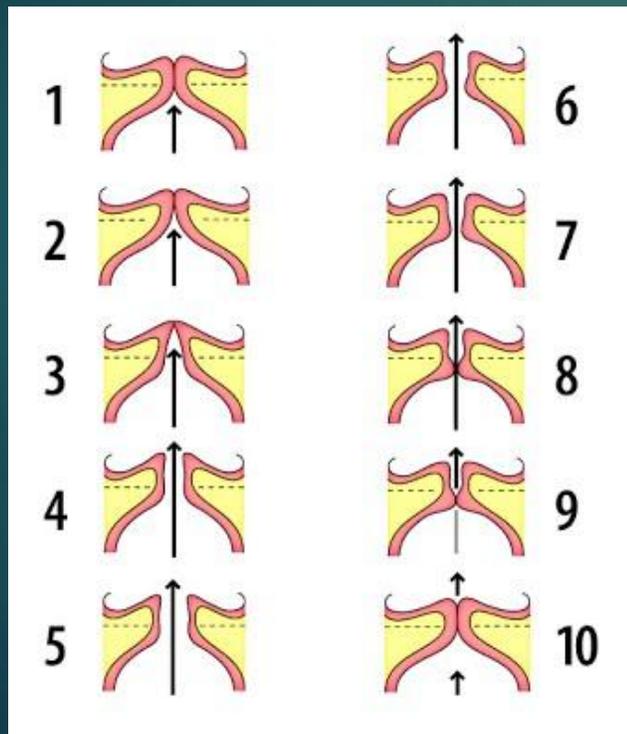
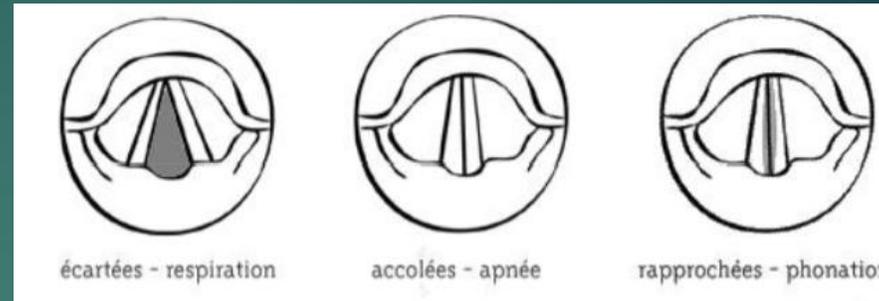


Mécanisme de production de la parole :

- ▶ Contraction du diaphragme (1)
- ▶ Libération d'air dans la trachée
- ▶ Passage de l'air au niveau:
 - des cordes vocales (2)
 - des résonateurs (3)

Les cordes vocales

- ▶ 3 positions fondamentales
- ▶ Rôle de valve régulant le débit d'air
- ▶ Mouvement cyclique

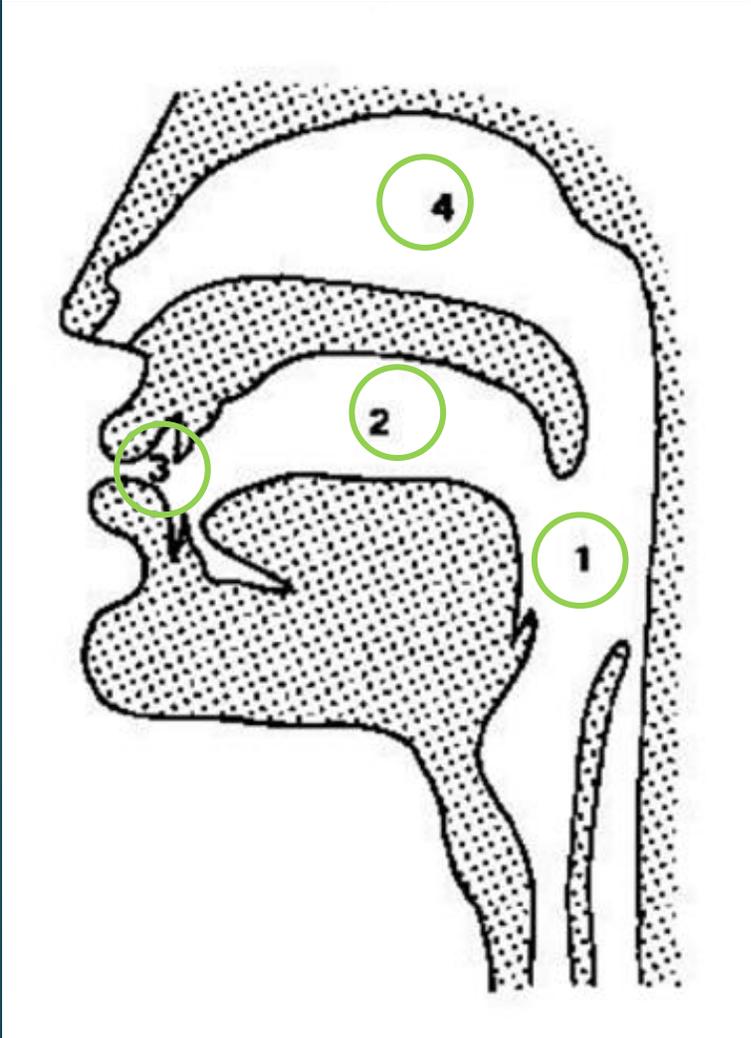


(2) écoulement turbulent

(4) et (5) écoulement parfait stationnaire incompressible et homogène

(6) Effet Venturi

Les résonateurs



Les principaux :

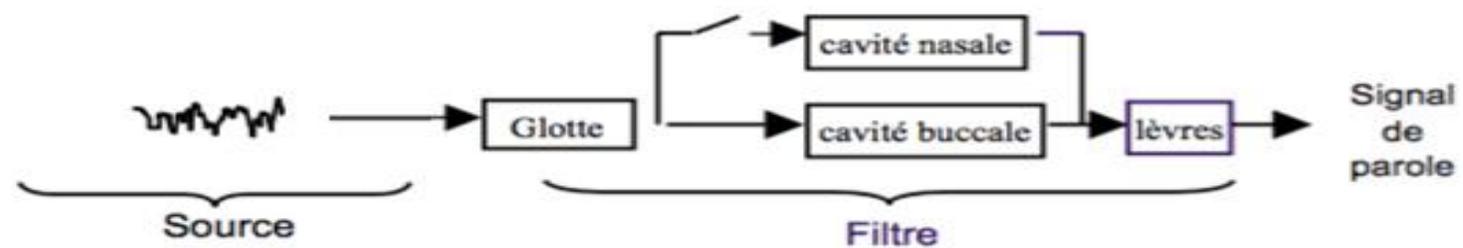
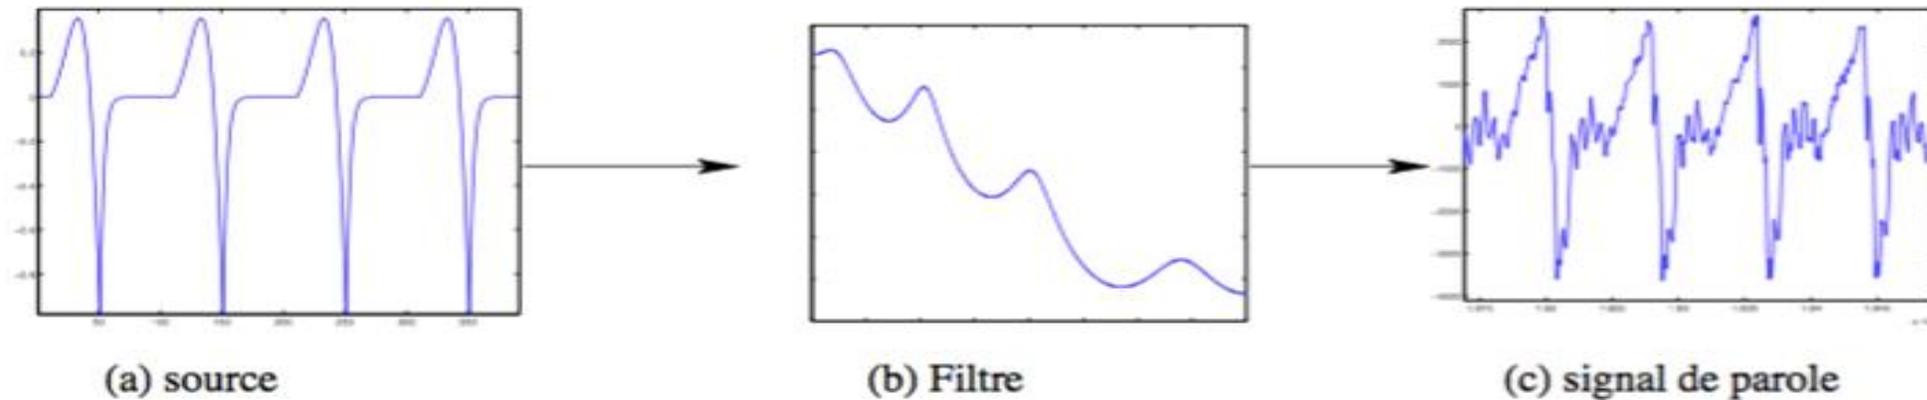
- ▶ Le pharynx (1)
- ▶ La cavité buccale (2)
- ▶ La cavité labiale (3)
- ▶ Les fosses nasales (4)

▶ Fréquence de résonance propre

▶ Condition de résonance: $f = f_{\text{résonateur}}$

f = formant

Modélisation source-filtre de l'appareil phonatoire



Production de la parole : le modèle source-filtre.

2)-Paramètres pertinents à étudier

La prosodie :

- Durée
- Intensité (niveau sonore)

I_{dB} en dB

I intensité sonore en $W.m^{-2}$

$I_0 = 10^{-12} W.m^{-2}$

$$I_{dB} = 10 \log \left(\frac{I}{I_0} \right)$$

- Hauteur

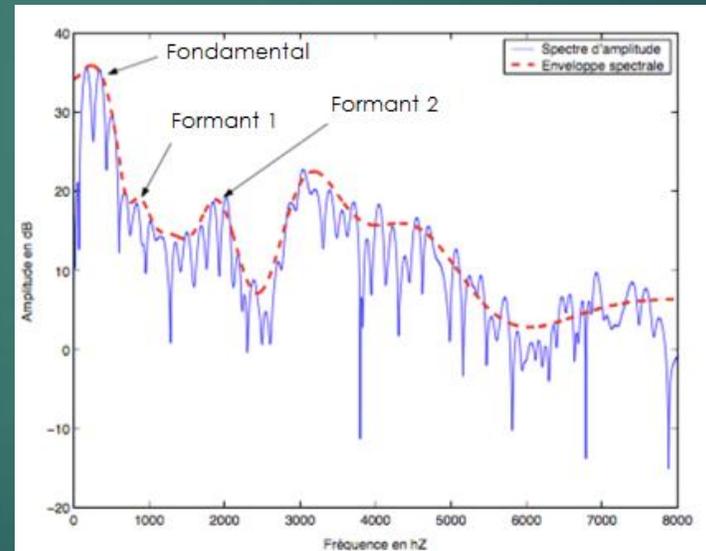
→ Pitch (fondamental)

→ Formants

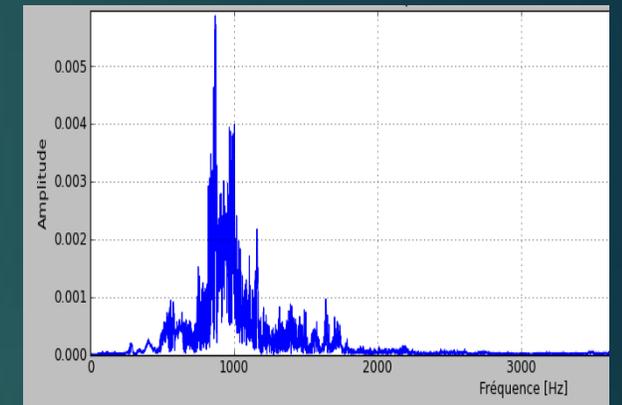
F1 : ouverture de la bouche

F2 : position de la langue

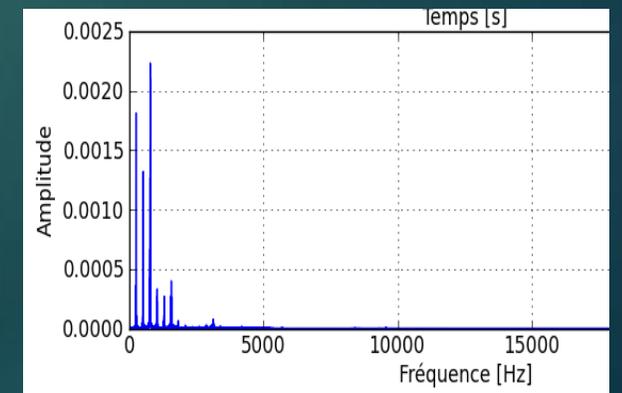
F3 : configuration des lèvres



Google



Humain

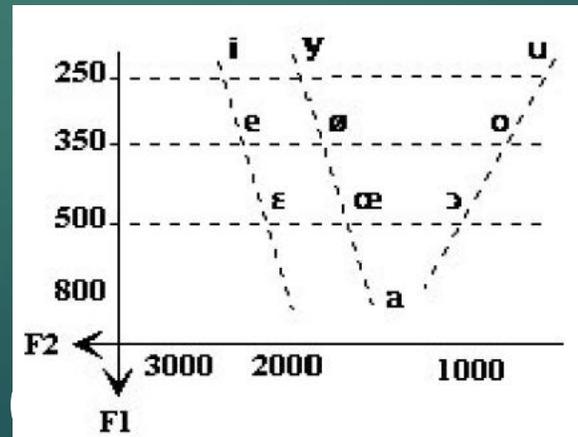
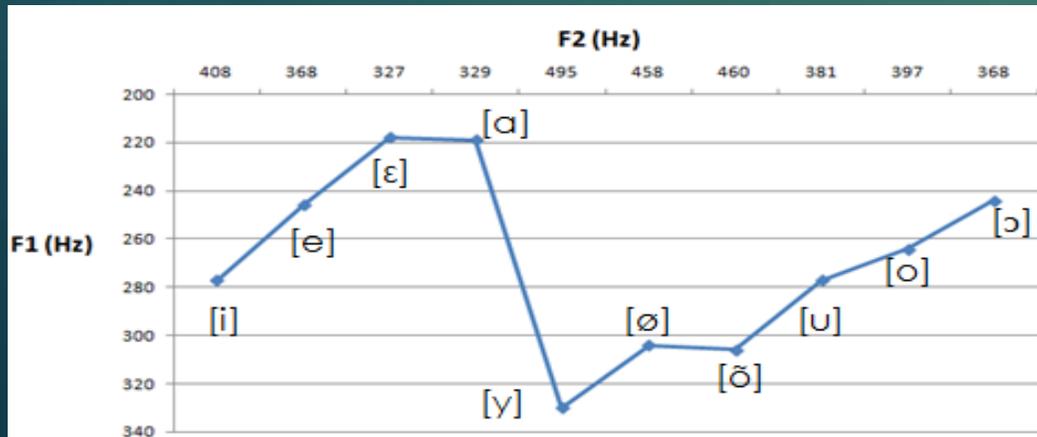


Phonème	Orateur	Fondamental	Amplitude 0	Formant 1	Amplitude 1	Formant 2	Amplitude 2	Formant 3	Amplitude 3
[a]	Lisa	262	0.00221	524	0.0015	784	0.0027	1046	0.00038
[a]	Sarah	241	0.00473	476	0.0003	722	0.0016	983	0.00022
[a]	Nicolas	109	0.004	219	0.007	329	0.002	437	0.003
[a]	Stéphane	179	0.0046	266	0.0041	449	0.0026	539	0.0049
[ʀ]	Lisa	244	0.017	493	0.013	742	0.0018	986	0.001
[ʀ]	Sarah	210	0.009	425	0.0015	673	0.0004	861	0.00015
[ʀ]	Nicolas	167	0.01	337	0.013	525	0.0045	658	0.0029
[ʀ]	Stéphane	97	0.0034	189	0.01	280	0.0035	409	0.0015
[ä]	Lisa	254	0.0022	508	0.0015	763	0.00050	1016	0.00056
[ä]	Sarah	249	0.0062	499	0.00038	748	0.001	998	0.00017
[ä]	Nicolas	122	0.032	245	0.0208	369	0.0097	491.9	0.019
[ä]	Stéphane	101	0.0045	202	0.01	303	0.0029	409	0.003
[e]	Lisa	231	0.00225	463	0.0025	697	0.0002	927	0.000039
[e]	Sarah	245	0.0047	499	0.0045	742	0.0034	1001	0.00011
[e]	Nicolas	122	0.021	246	0.0198	368	0.021	489	0.0026
[e]	Stéphane	113	0.004	228	0.009	336	0.0076	449	0.0034
[ɔ]	Lisa	279	0.00338	558	0.0022	837	0.0036	1115	0.0005
[ɔ]	Sarah	257	0.0036	510	0.0024	691	0.00169	1468	0.0006
[ɔ]	Nicolas	121.5	0.020	244	0.0226	368	0.0012	491	0.052
[ɔ]	Stéphane	87	0.00239	177	0.003	267	0.00239	539	0.00088

Individu	Âge
Lisa	19 ans
Sarah	20 ans
Nicolas	20 ans
Stéphane	50 ans

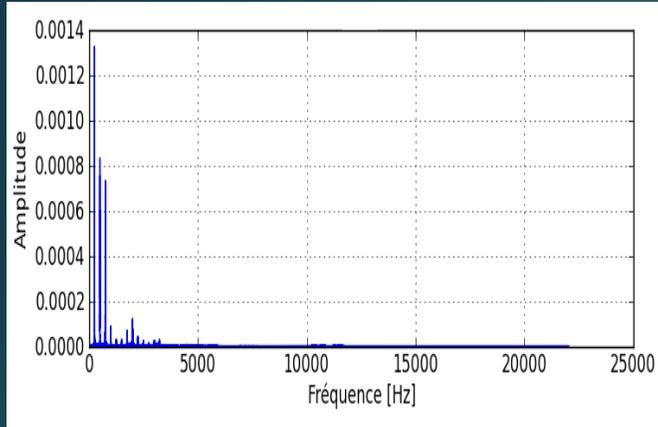
132 échantillons

Extrait du tableau contenant les valeurs mesurées sur les spectres

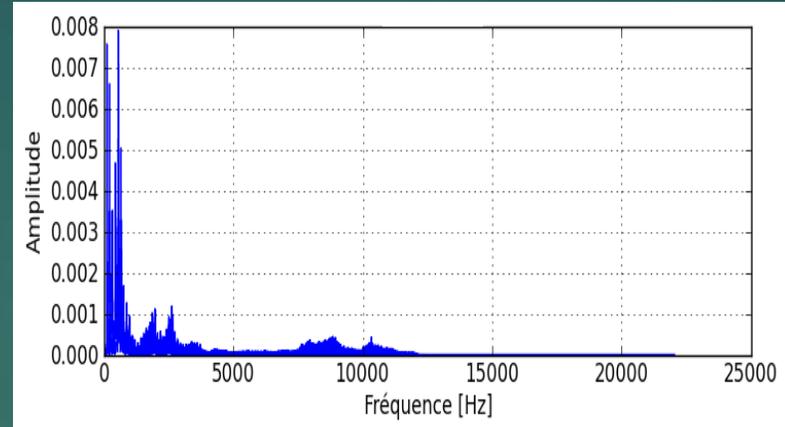


➤ Plus d'harmoniques chez l'homme

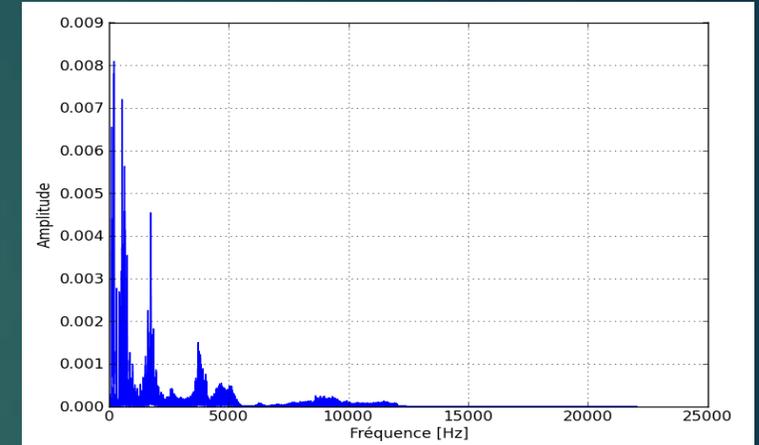
Phonème [ɛ] (merci)



Lisa



Nicolas



Stéphane

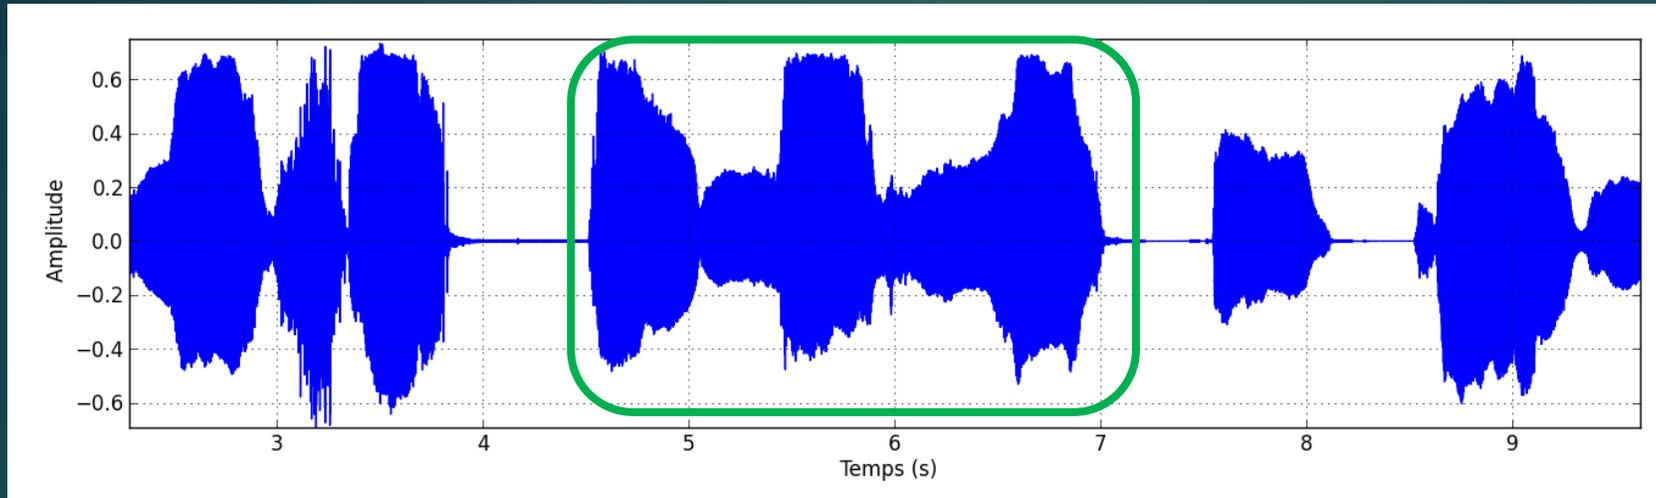
▶ Fondamental et formants féminins plus haut

Accroissement de l'écart

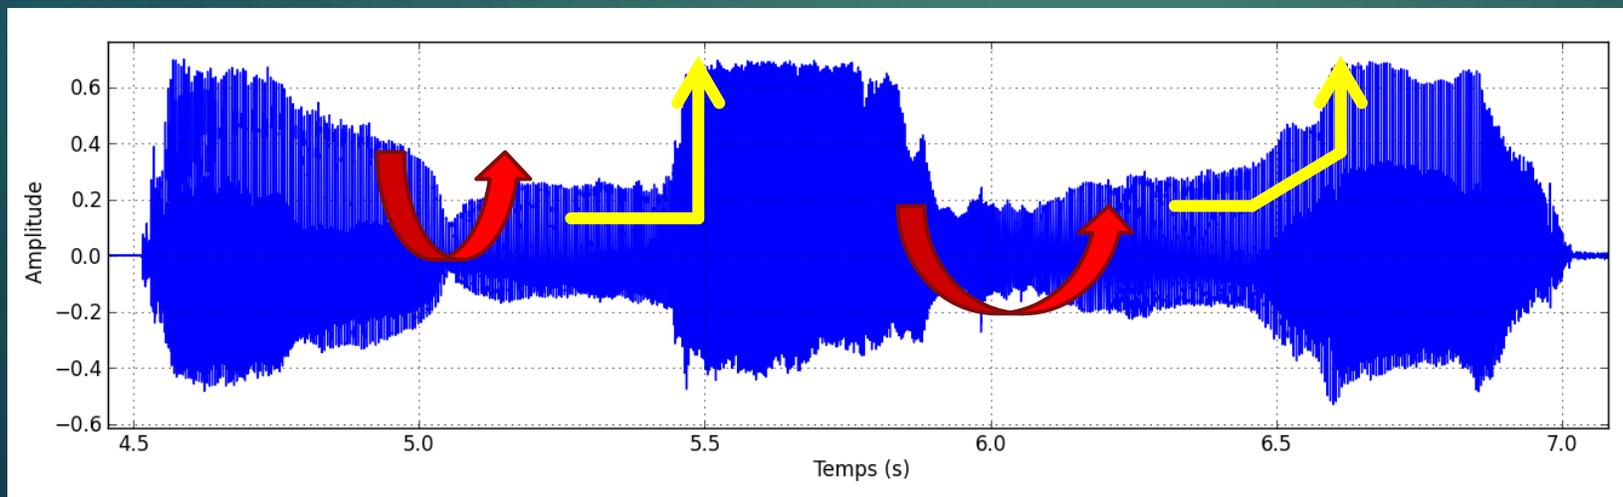
[ɛ]	Lisa	244	0.017	493	0.013	742	0.0018	986	0.001
[ɛ]	Sarah	210	0.009	425	0.0015	673	0.0004	861	0.00015
[ɛ]	Nicolas	167	0.01	337	0.013	525	0.0045	658	0.0029
[ɛ]	Stéphane	97	0.0034	189	0.01	280	0.0035	409	0.0015

« Le chat et l'agneau ont tous les deux quatre pattes »

12



« et l' a gn eau »



➤ Transitions

Transition voyelle-consonne

Transiition consonne-voyelle

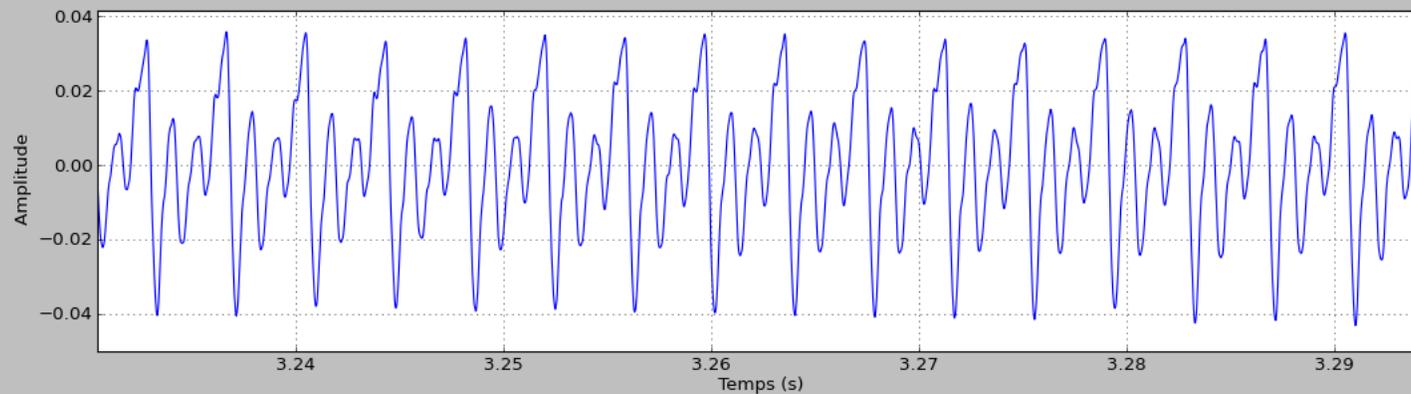
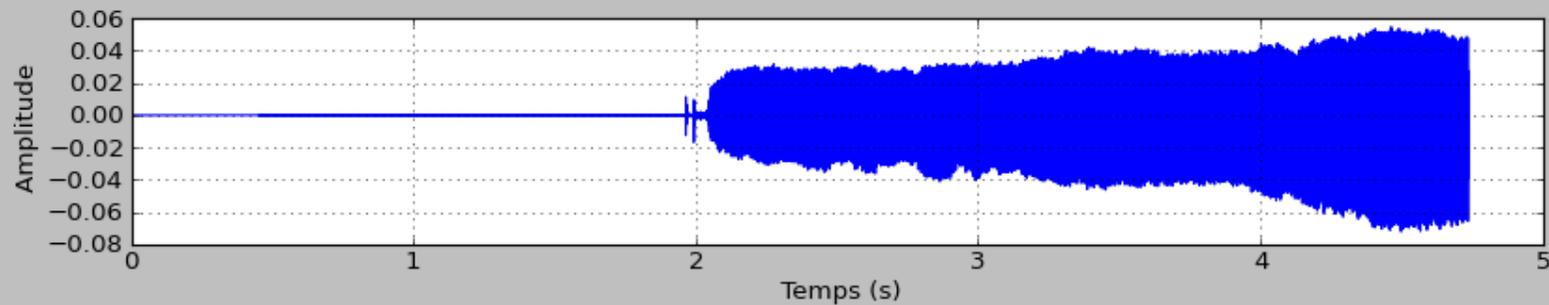
II. Synthèse

1)-Synthèse d'une voyelle

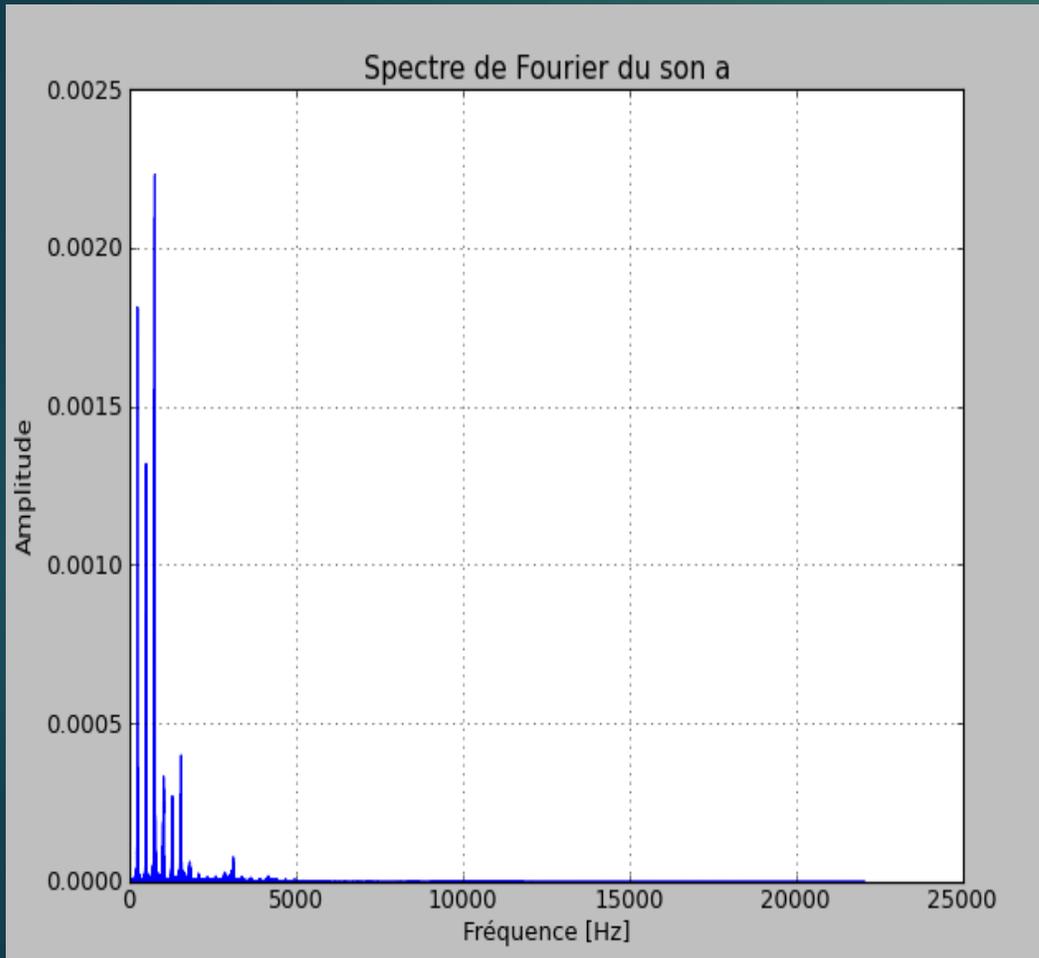
14

➤ Principe de Fourier :

Tout signal périodique peut se décomposer en somme de signaux sinusoïdaux



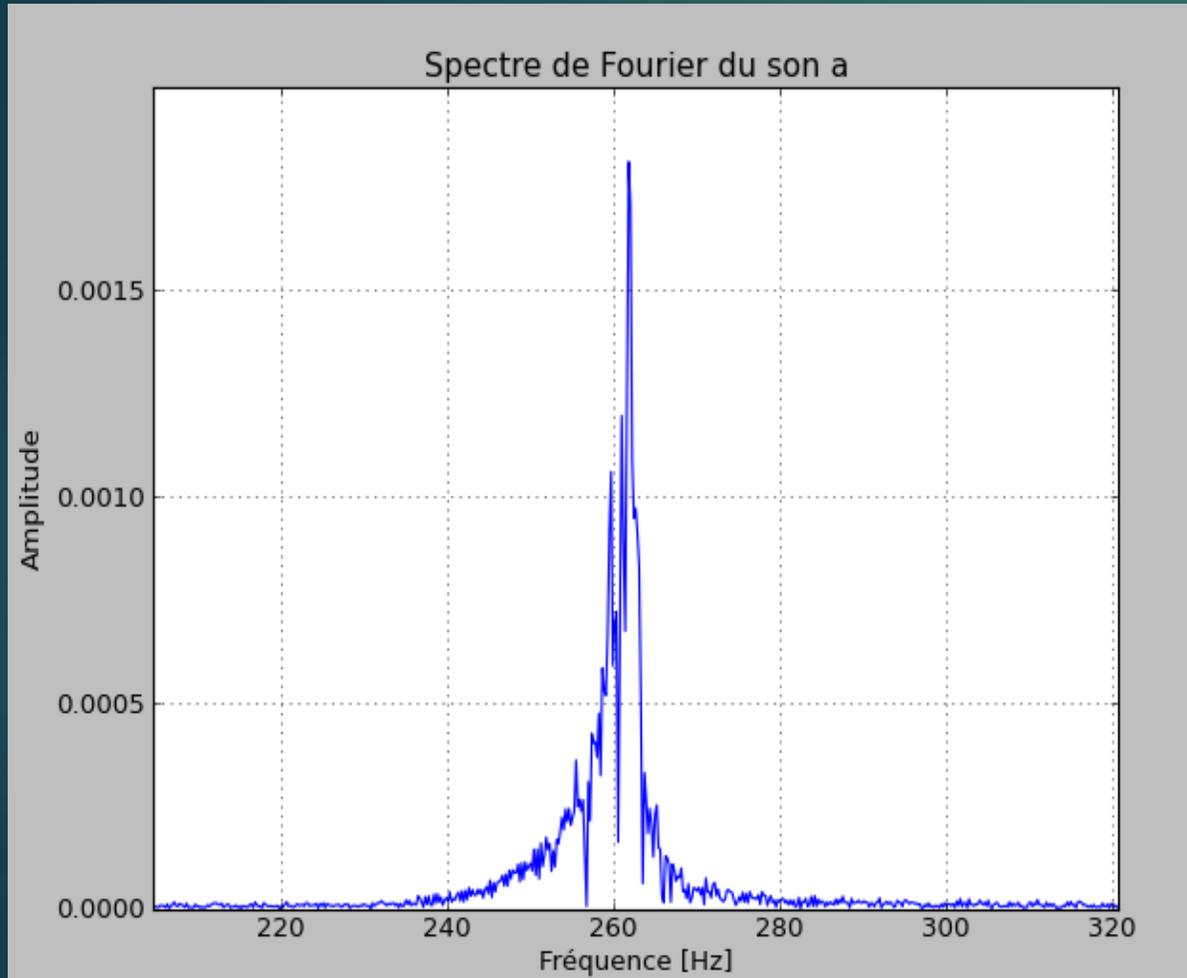
Synthèse additive



- ▶ Amplitudes égales
→ Absence d'humanité
- ▶ Amplitudes avec rapport de proportionnalité
→ Différence notable
- ▶ Amplitudes précises
→ Diffère du cas précédent
- ▶ Influence de la phase
→ Inaudible

Après un zoom...

16



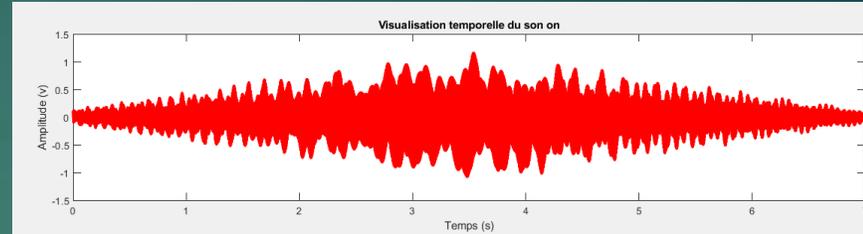
- ▶ Pas une mais plusieurs fréquences autour d'un pic
- ▶ Fréquence principale + quelques fréquences alentours
→ phénomène de battement
- ▶ Plages de fréquences
→ amélioration la plus importante
- ▶ Plages d'amplitudes (ascendantes puis descendantes)
→ Résultat proche du son réel

Difficultés rencontrées:

- ▶ Lecture simultanée des listes
 - montée vers l'aigu
 - variation du niveau sonore
 - Plages plus étroites

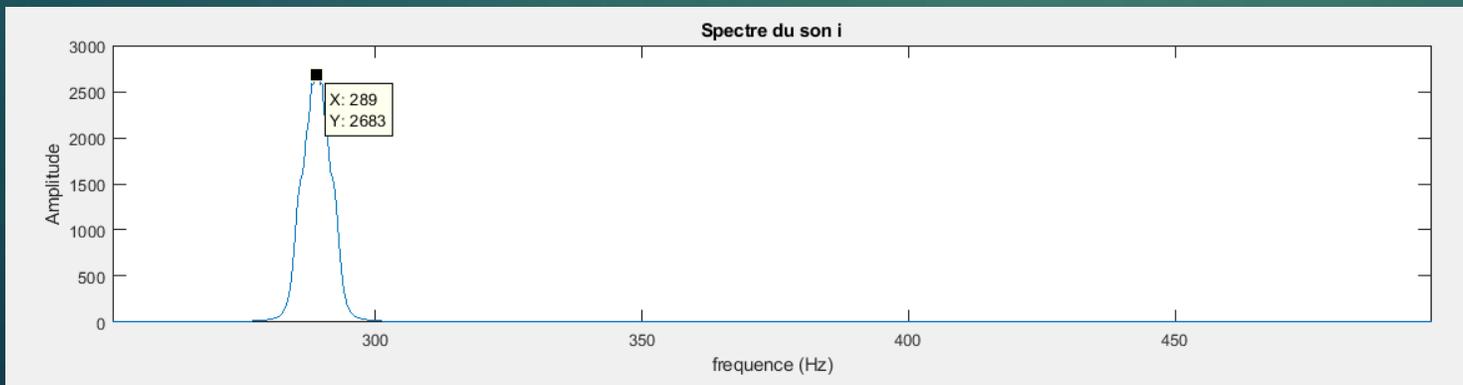
listes de même longueur

```
y0 = A0.*sin(2.*pi.*F00.*t);
```



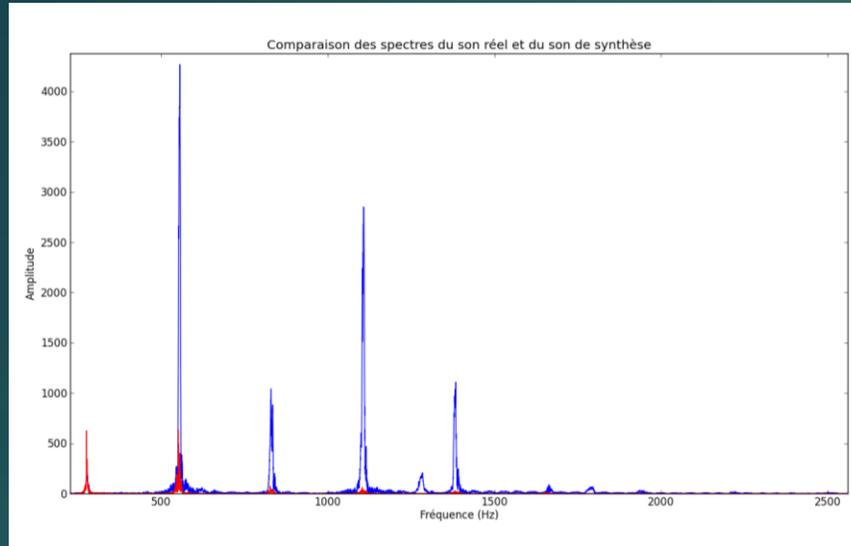
- ▶ Plages de fréquences élargies par Matlab

```
F00=284:(5/132300):289;
```

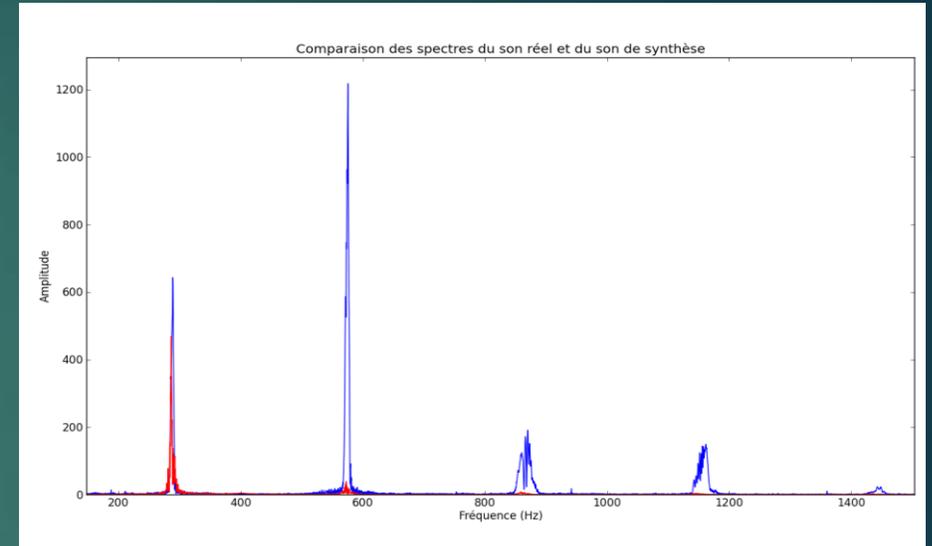


Résultats obtenus

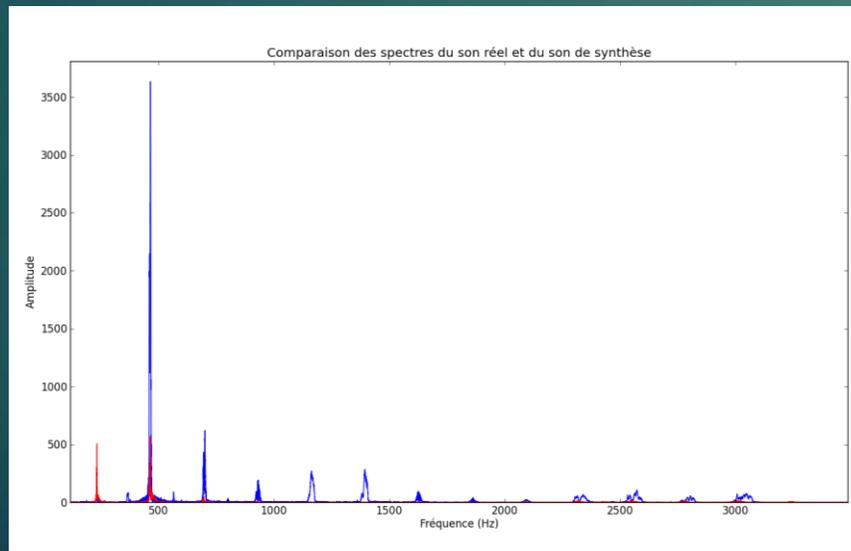
[o]



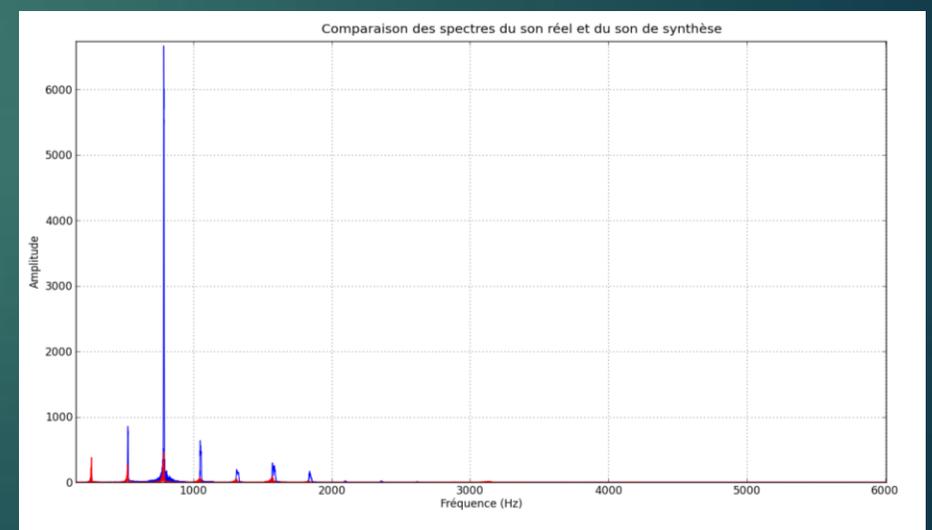
[i]

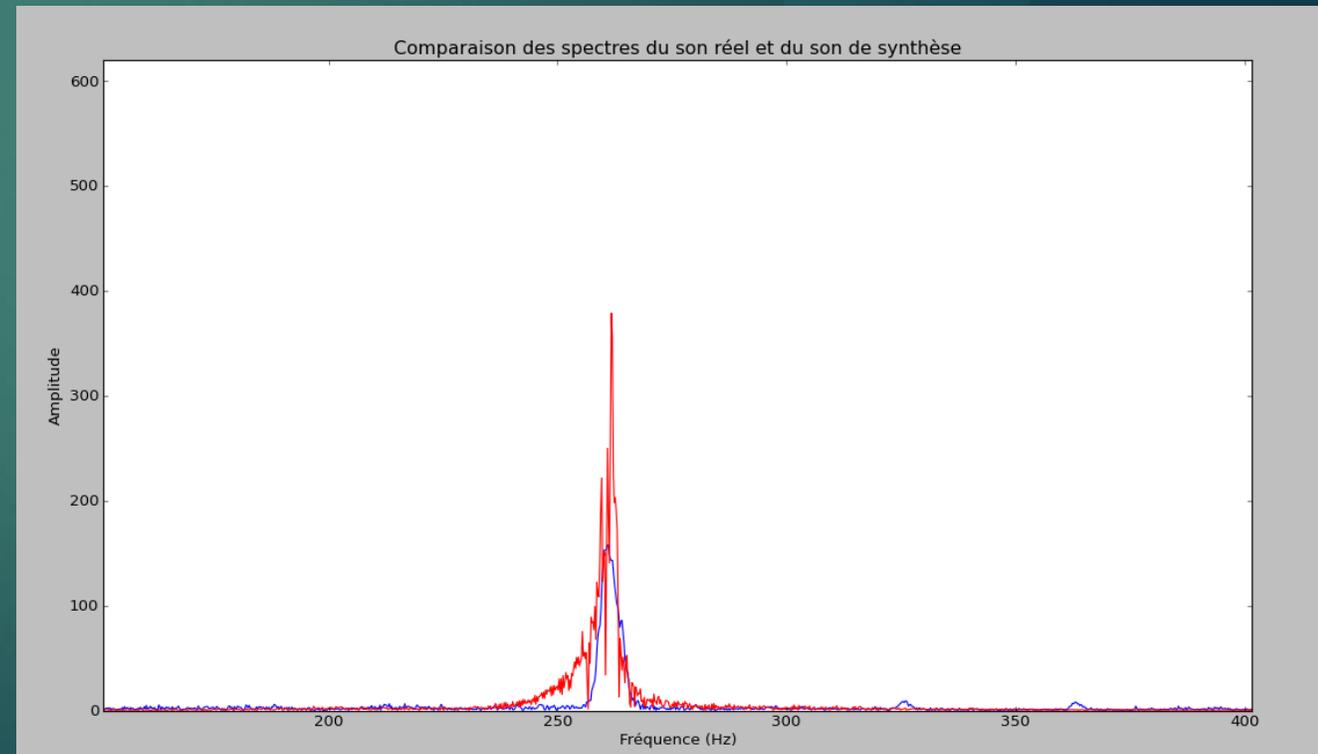
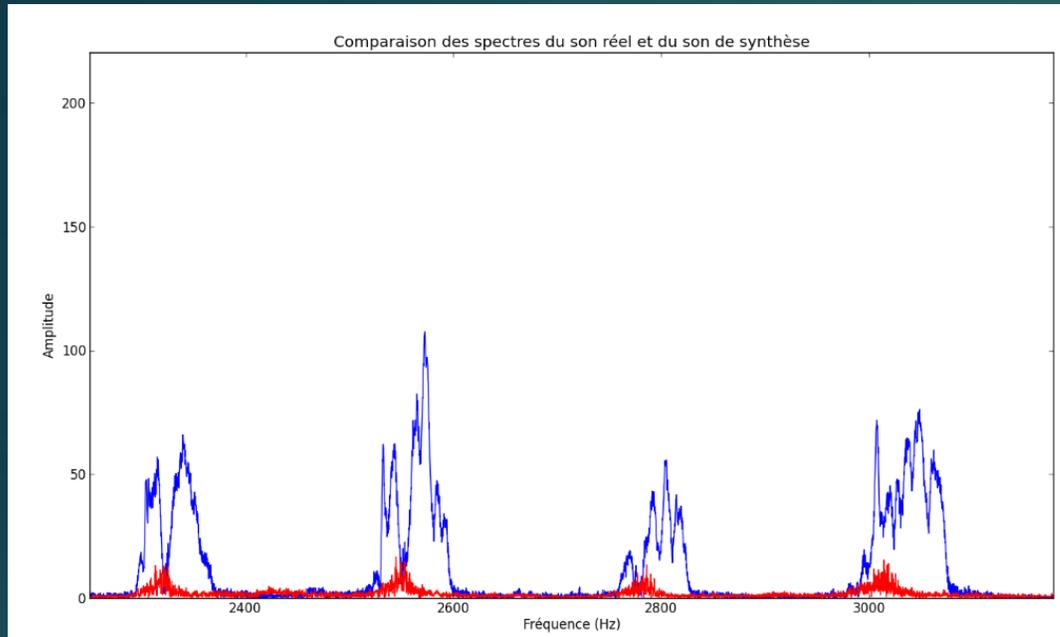


[e]



[a]

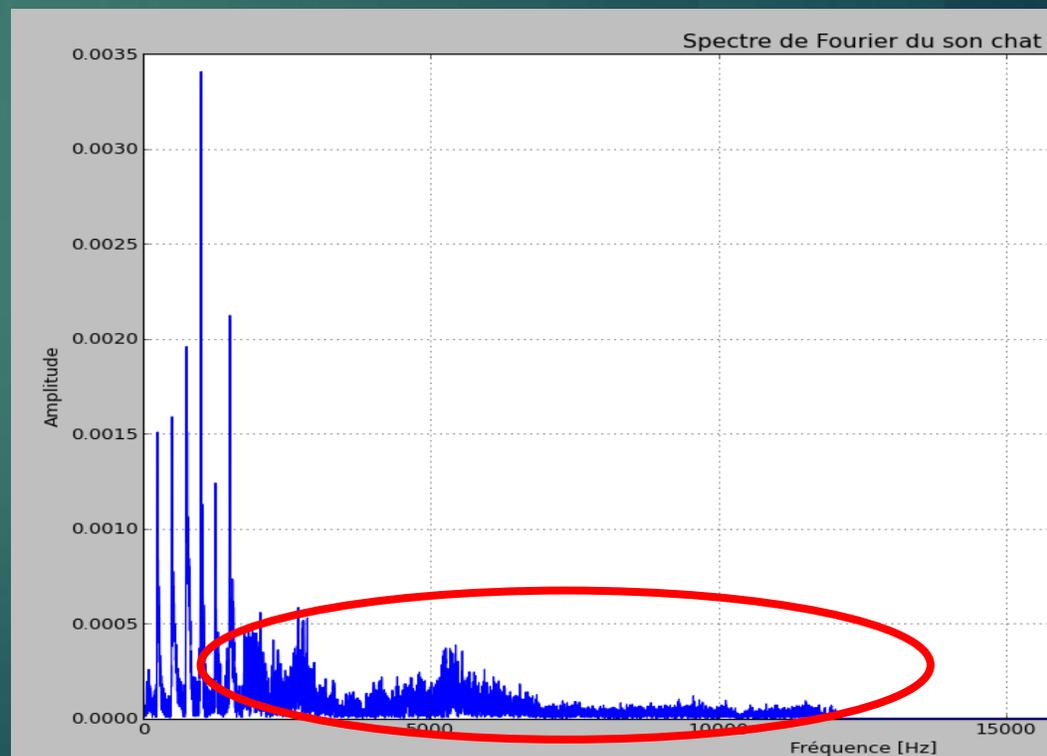
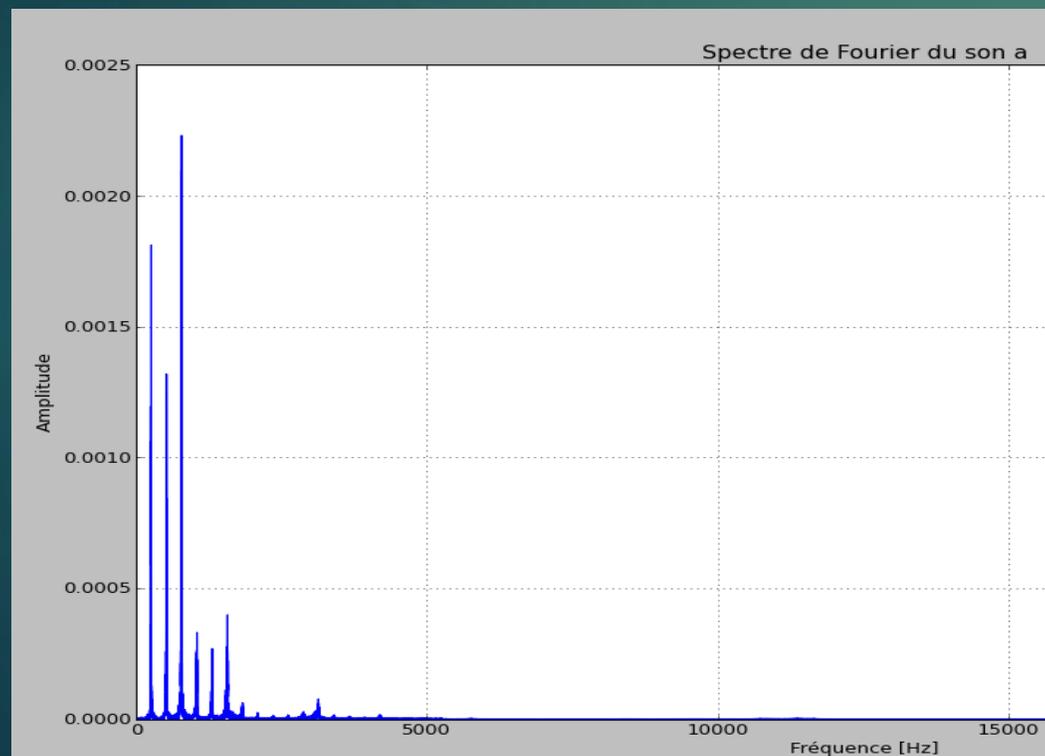




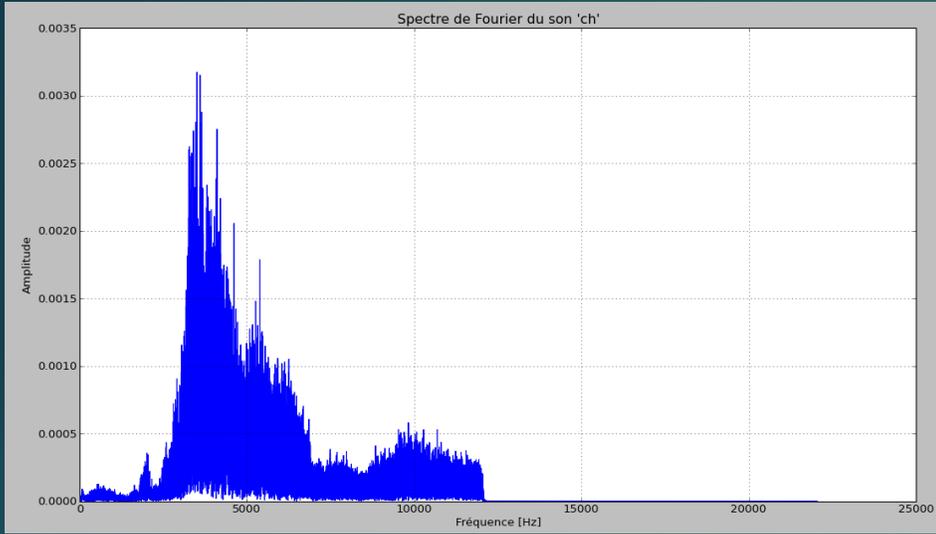
2)- Synthèse d'une consonne

20

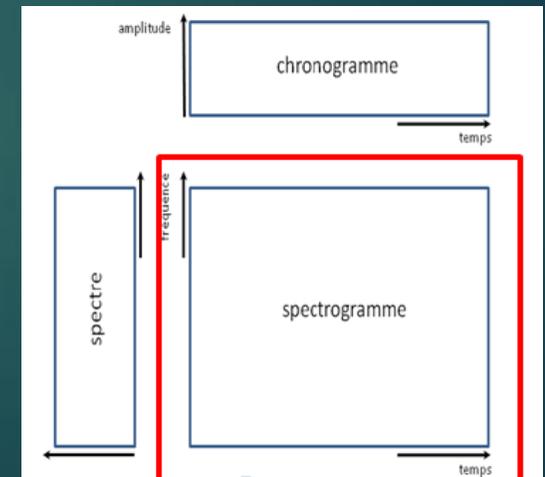
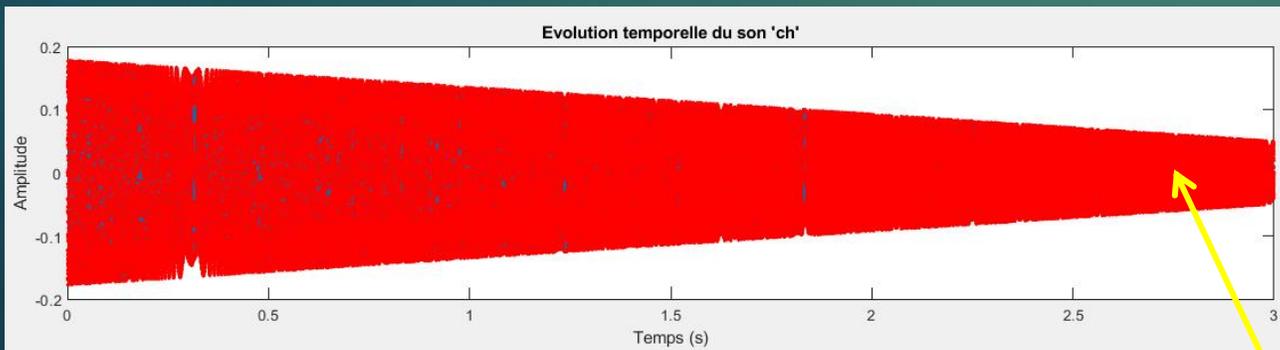
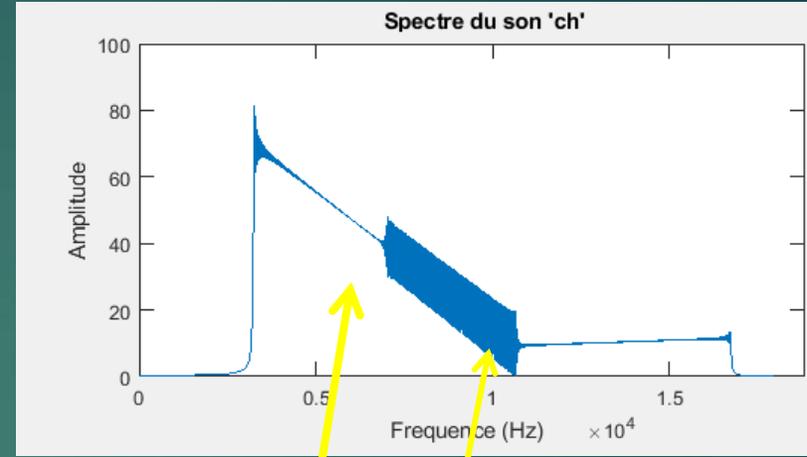
Spéctre	Fondamental (Hz)	Formant 1 (Hz)	Formant 2 (Hz)	Formant 3 (Hz)	Formant 4 (Hz)	Formant 5 (Hz)
a	262	524	784	1046	1308	1570
chat	255	505	756	1009	1259	1511



Spectre désiré (réellement prononcé)



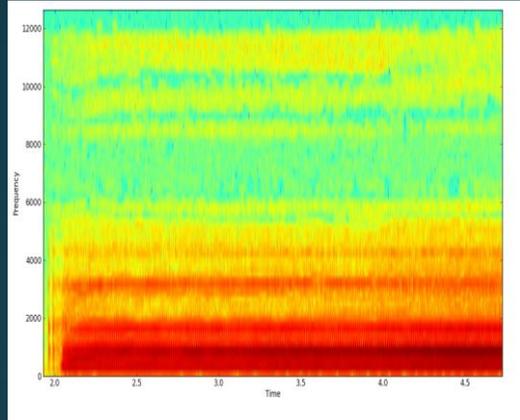
Spectre obtenu (son synthétisé)



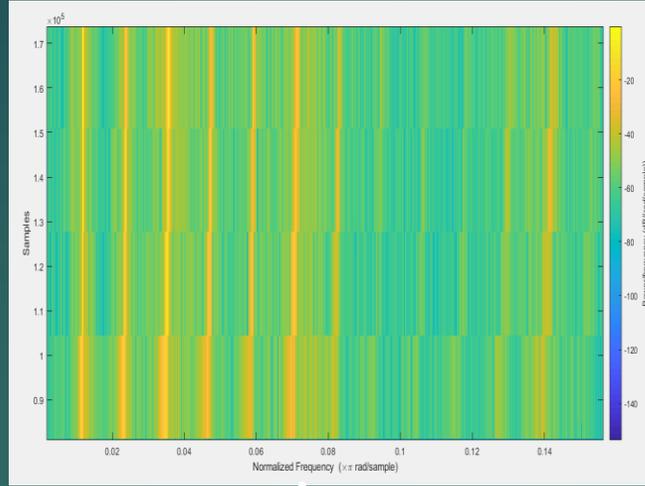
Difficultés

Alternative

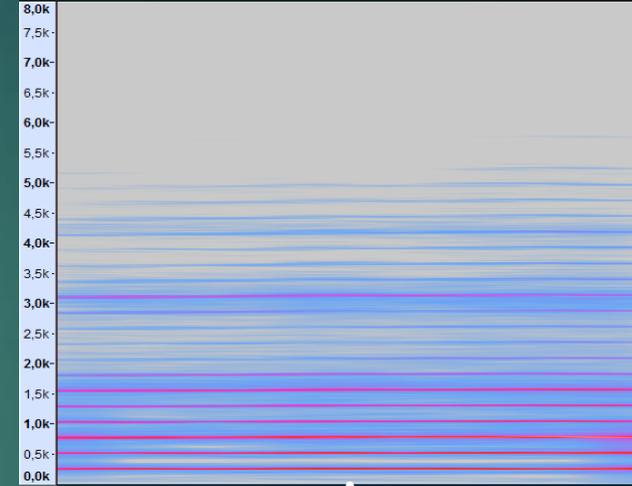
Spectrogramme Python



Spectrogramme Matlab

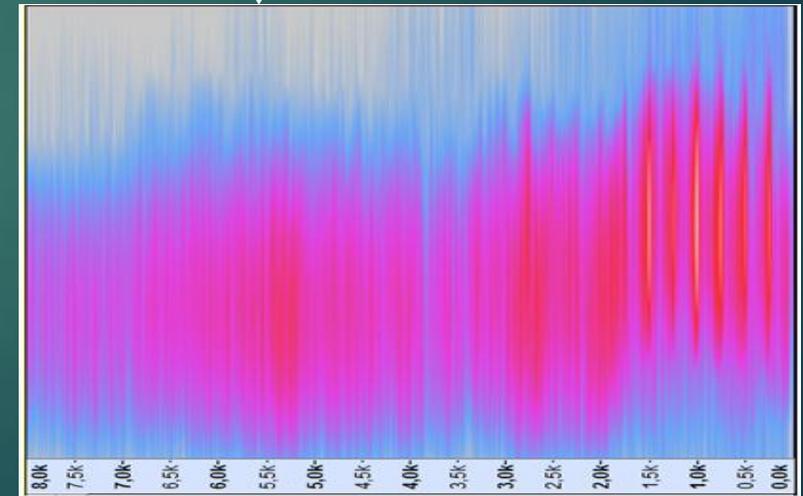
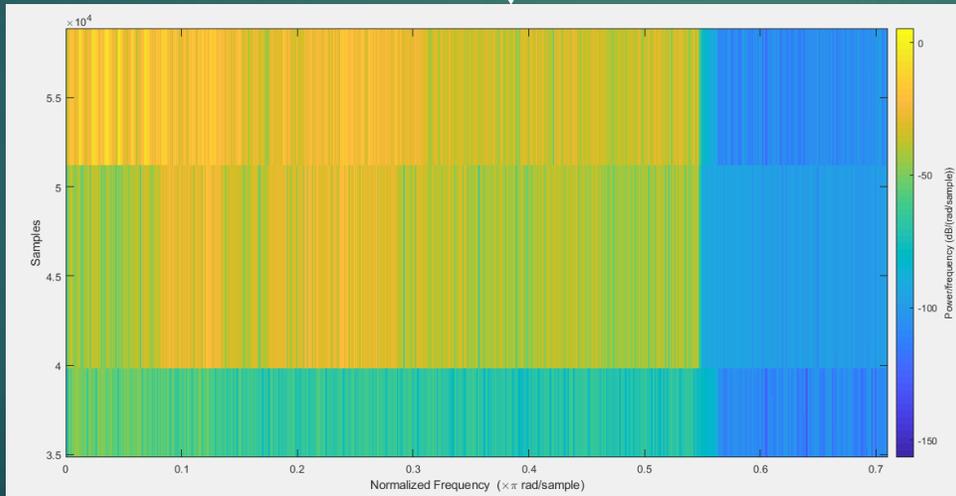


Spectrogramme Audacity



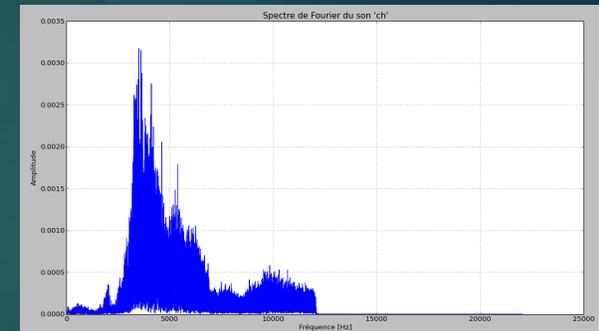
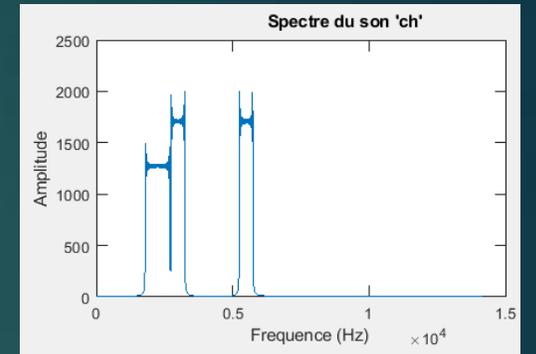
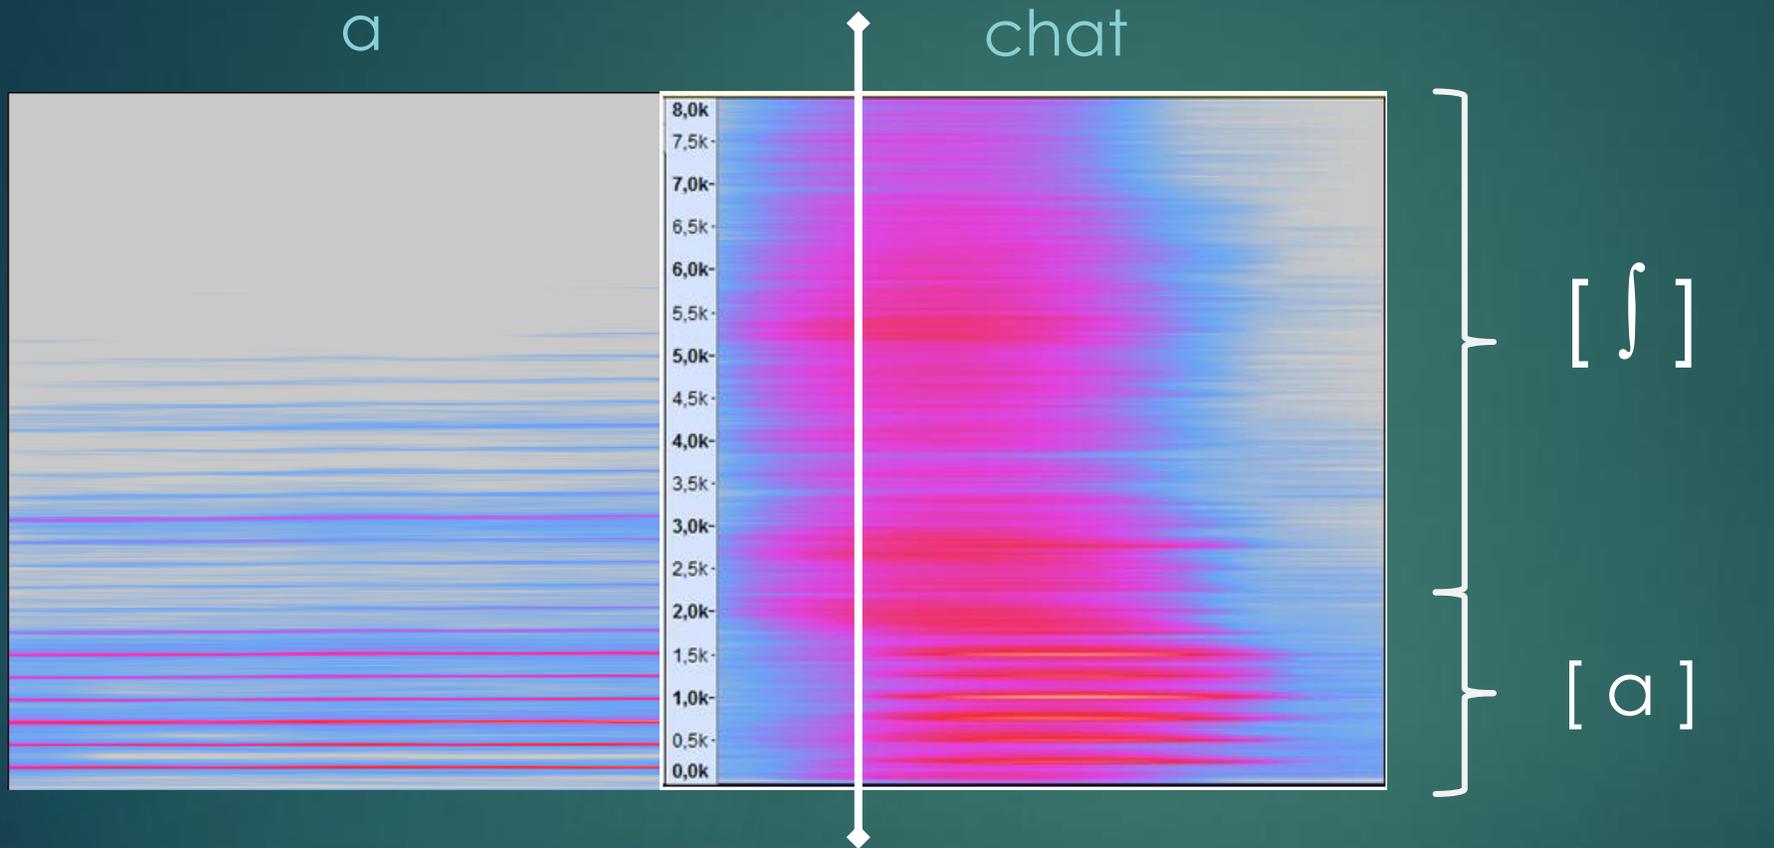
Phonème [a]

Phonème [ʃ]
Chat



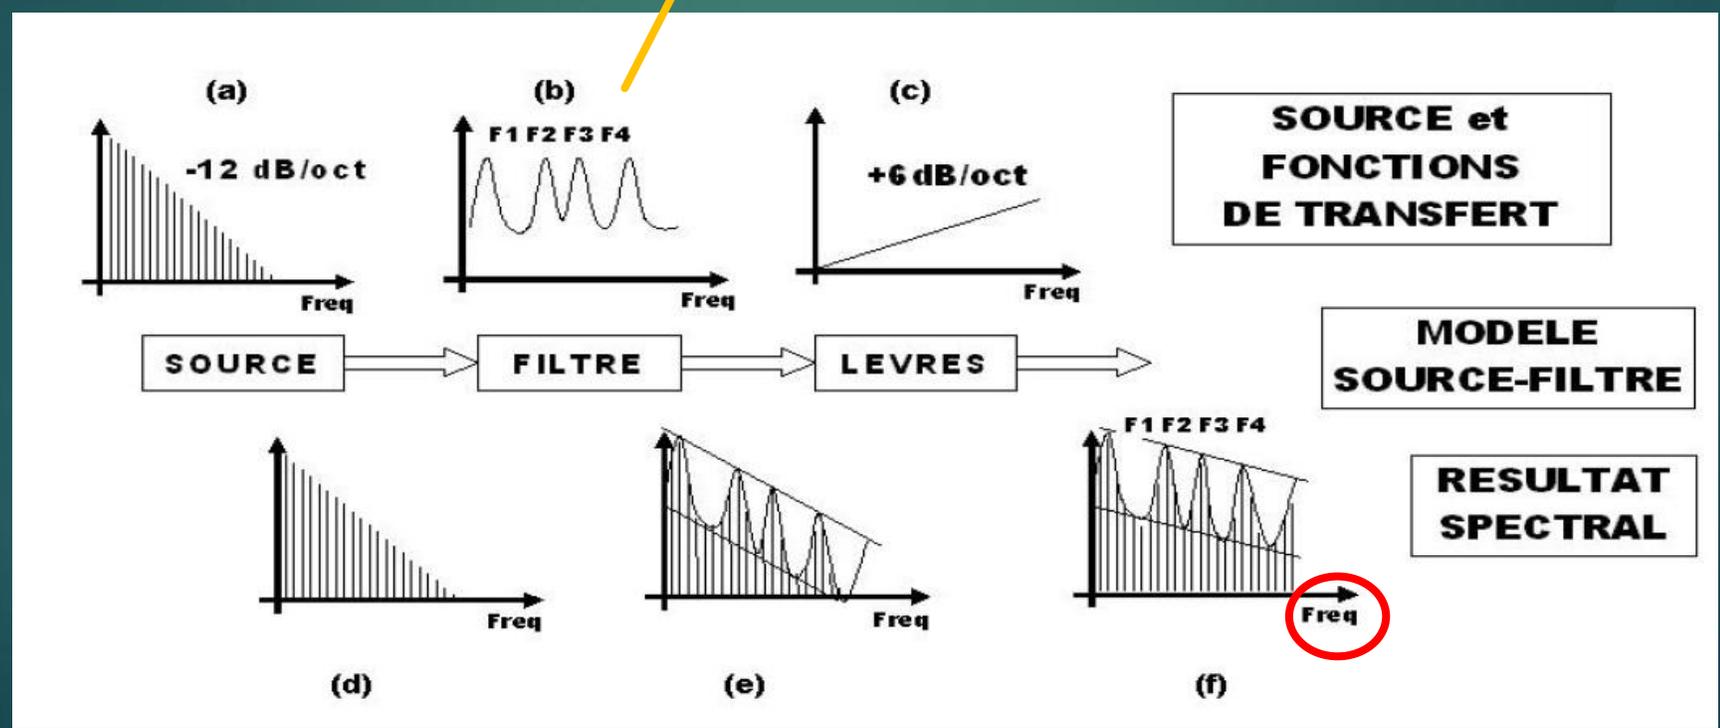
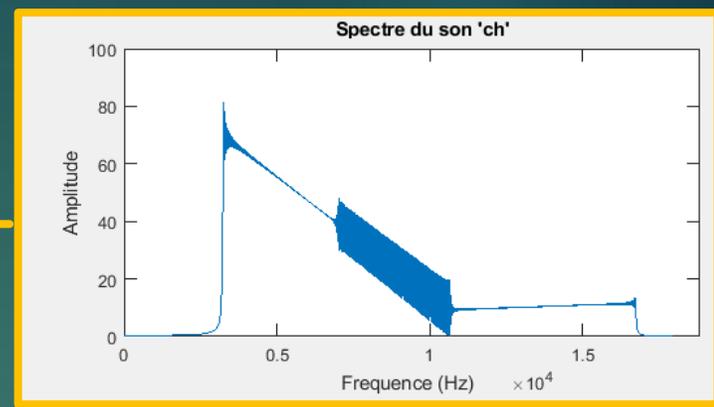
Méthode d'identification des fréquences associées aux consonnes

23

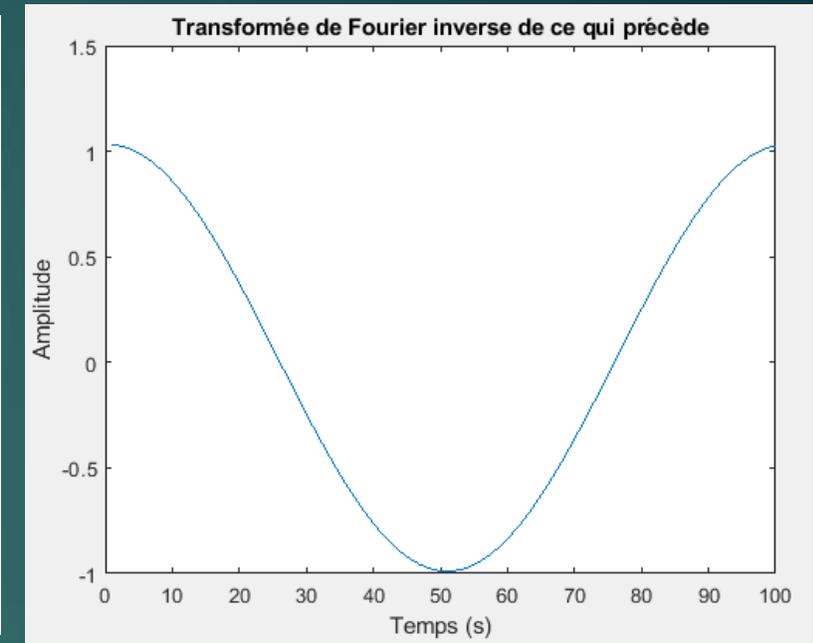
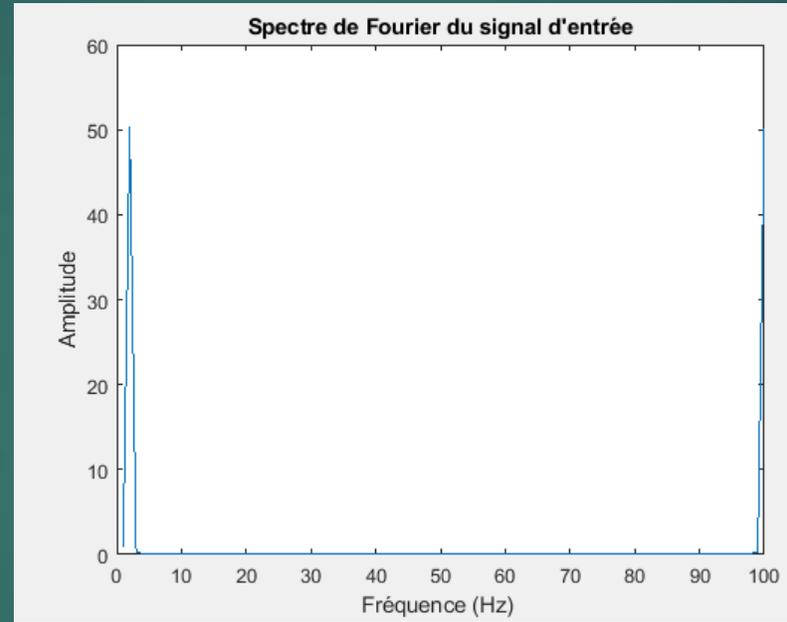
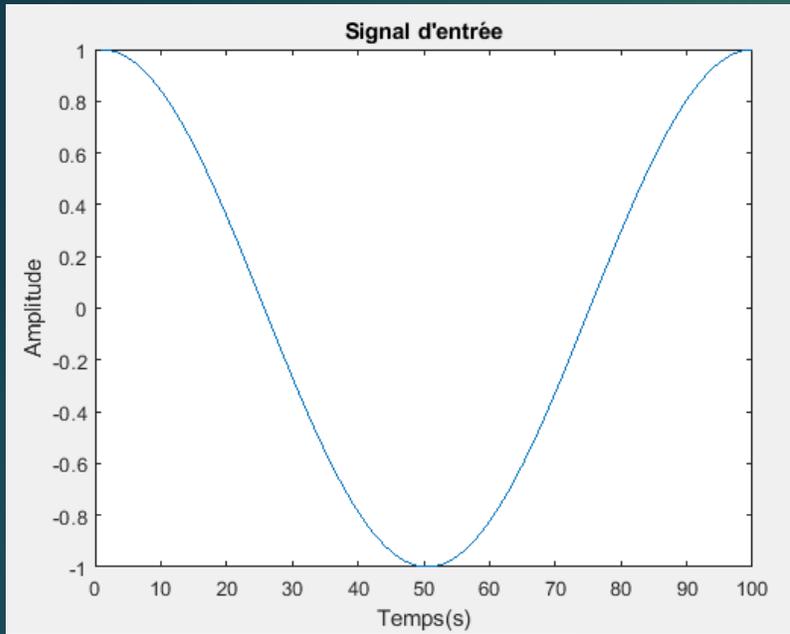


→ Synthèse additive incompatible avec les consonnes

La méthode soustractive



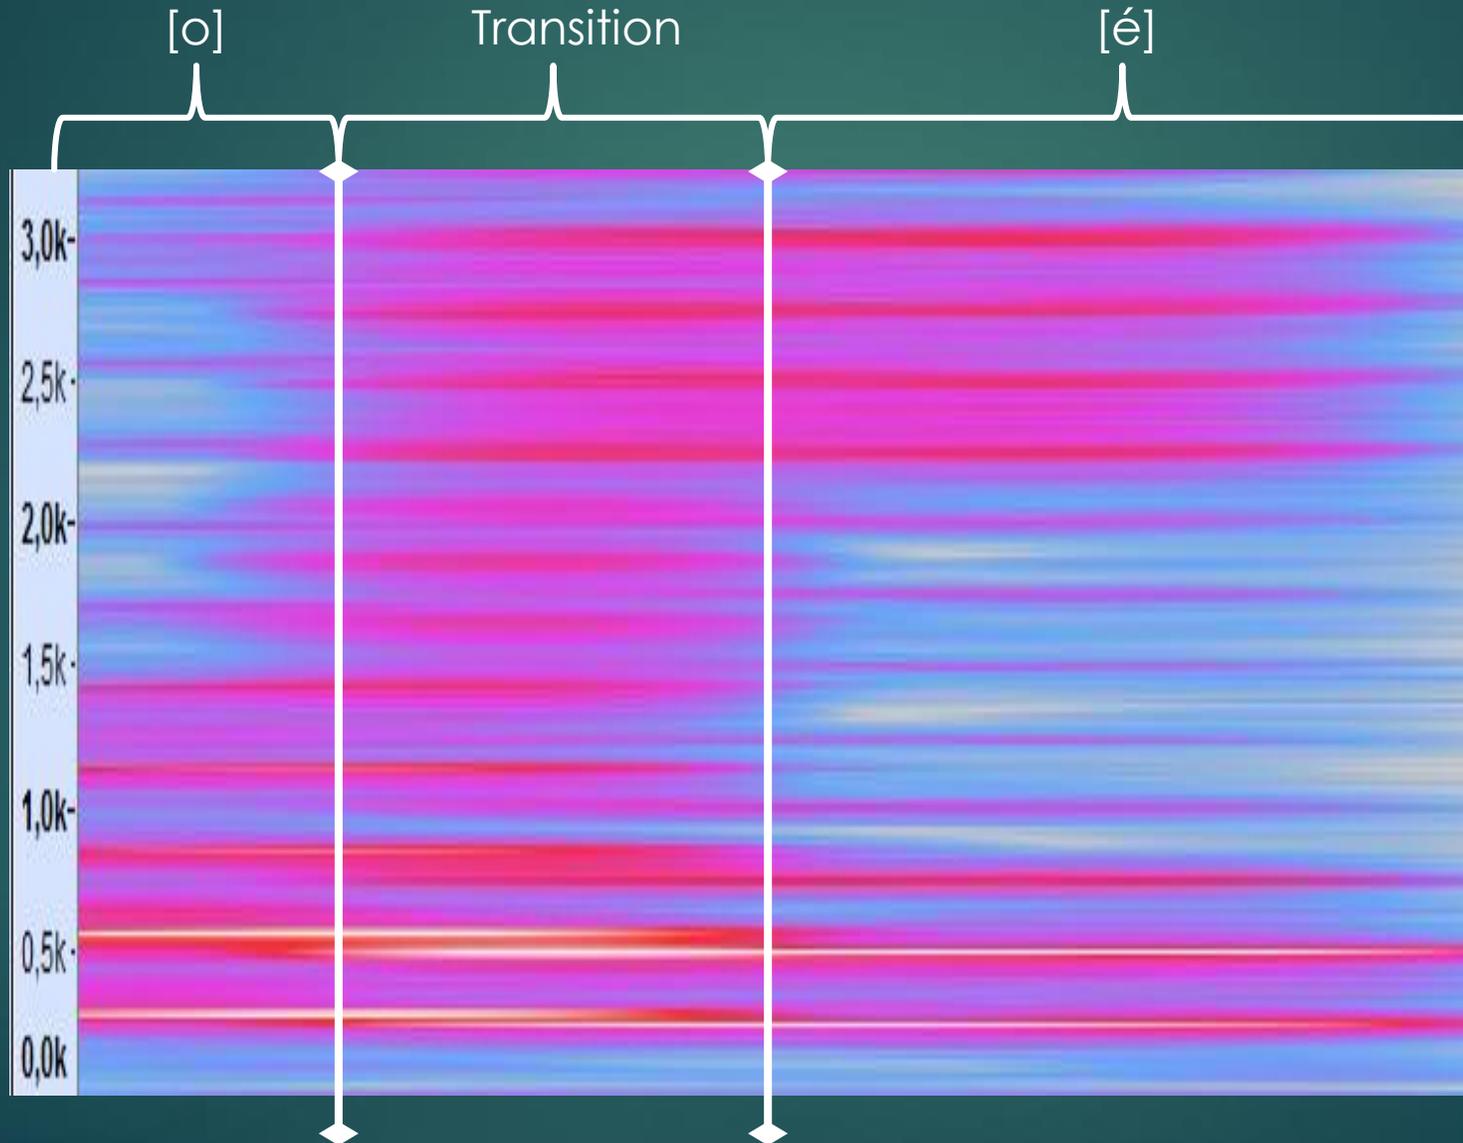
➤ Passage fréquentiel → temporel : ifft



III. Concaténation

1)-Concaténation de phonèmes

27



Concaténation de deux voyelles


- Fréquences communes
- Fréquences disparues
- Fréquences apparues

Résultats obtenus

28



Sans transition



Avec transition

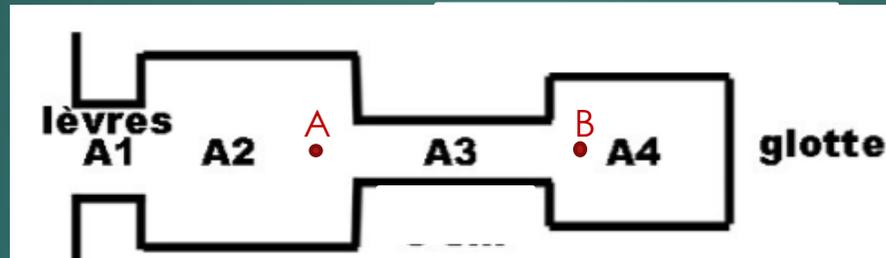
IV. Conclusion



Explications physiques: Effet VENTURI

Hypothèse: l'écoulement de l'air dans le conduit vocal est considéré comme parfait, stationnaire, homogène, et incompressible.

Modélisation du conduit vocal:



Avec:- la section des lèvres (A1)

- la cavité frontale (A2)
- l'articulation linguale (A3)
- la cavité arrière (A4)

En considérant par exemple la partie de A4 vers A2 on a:

En appliquant la relation de Bernoulli sur une ligne de courant allant de A vers B:

$$P_A + \mu g z_A + \frac{1}{2} \mu v_A^2 = P_B + \mu g z_B + \frac{1}{2} \mu v_B^2$$

Or A et B étant à la même altitude on obtient:

$$P_B = P_A + \frac{1}{2} \mu (v_A^2 - v_B^2)$$

Comme $S_B < S_A$ alors $v_B > v_A$, par conséquent $P_B < P_A$. Il y a diminution de la pression.

Interprétation physique:

L'air provenant de la trachée tente de sortir et accélère. Sa vitesse augmente et la pression au niveau des cordes vocales diminue, ce qui permet leur ouverture. Puis elles se referment et la situation se répète.

Etapes majeures du code

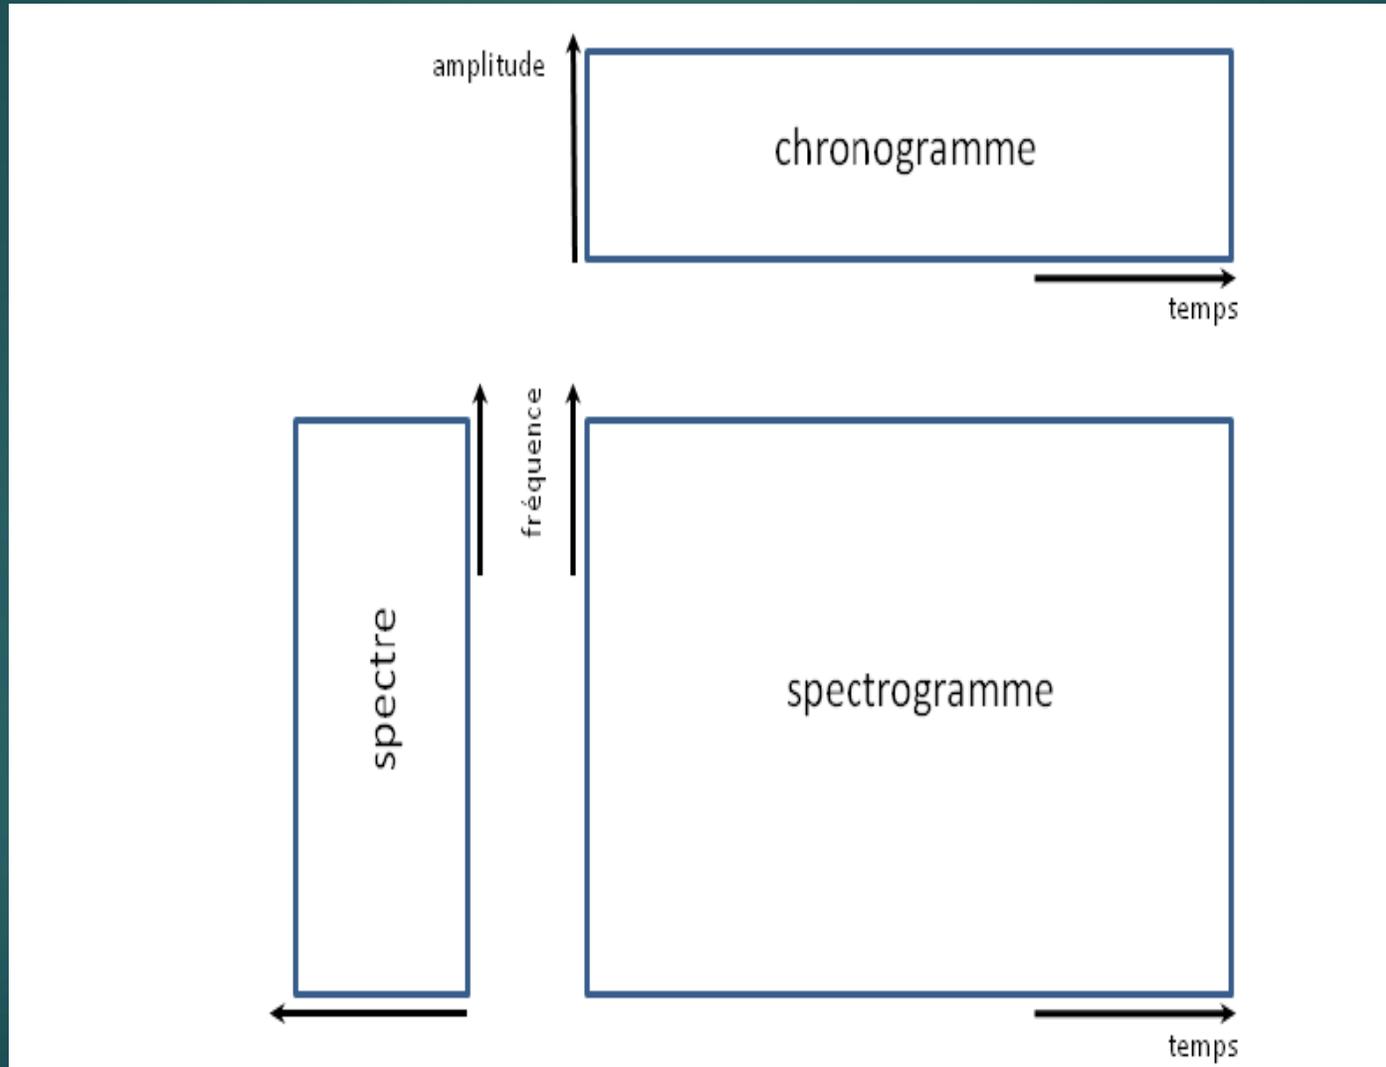
```
Fs= 44100;  
tmax=7;  
Nbdt=floor( (tmax*132301)/3);  
T= 0:1/Fs:tmax;  
t=[0 T];
```

```
F00=254: (2/ (Nbdt-1)) :256;
```

```
A0_m=0.000337: ((0.00378-0.000337)/mt) :0.00378;  
A0_d=0.00378: ((0.000333-0.00378)/mt):0.000333;  
A0=[A0_m,A0_d];
```

```
y0 = A0.*sin(2.*pi.*F00.*t);
```

Les différentes représentations possibles des paramètres d'un signal:



Le théorème de Shannon :

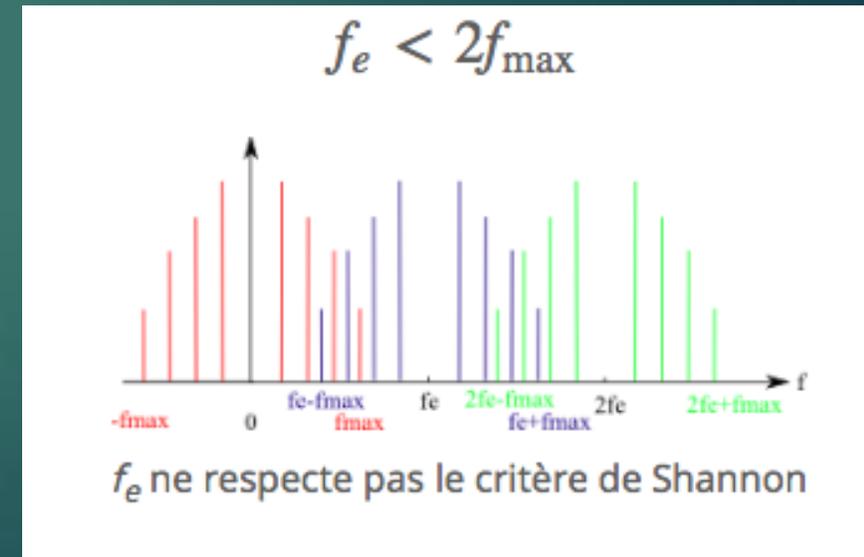
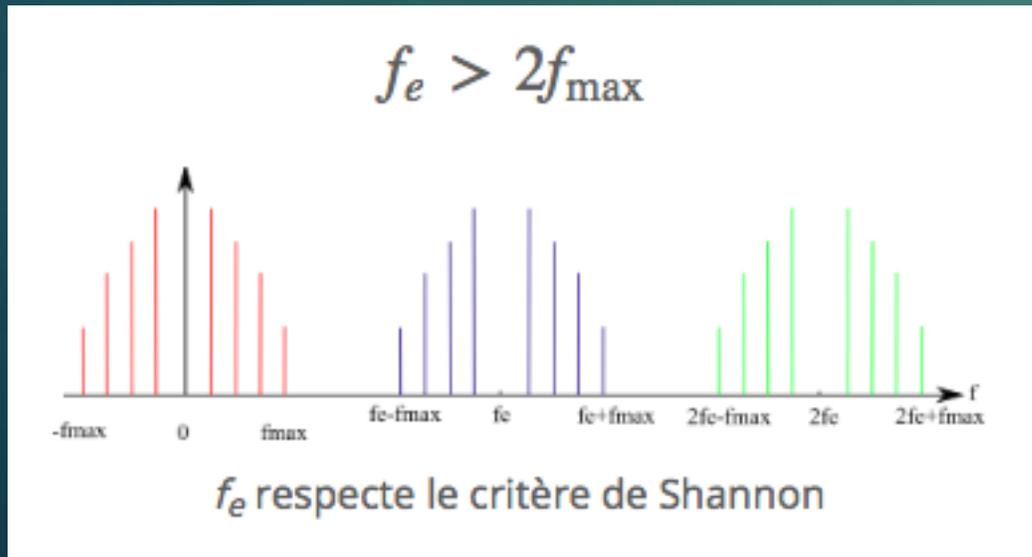
Permet de connaître la fréquence d'échantillonnage à choisir pour un signal donné :

Pour reconstruire un signal de sortie de manière fidèle au signal d'entrée, il faut choisir une fréquence d'échantillonnage au moins deux fois supérieure à la fréquence maximale contenue dans le signal d'entrée.

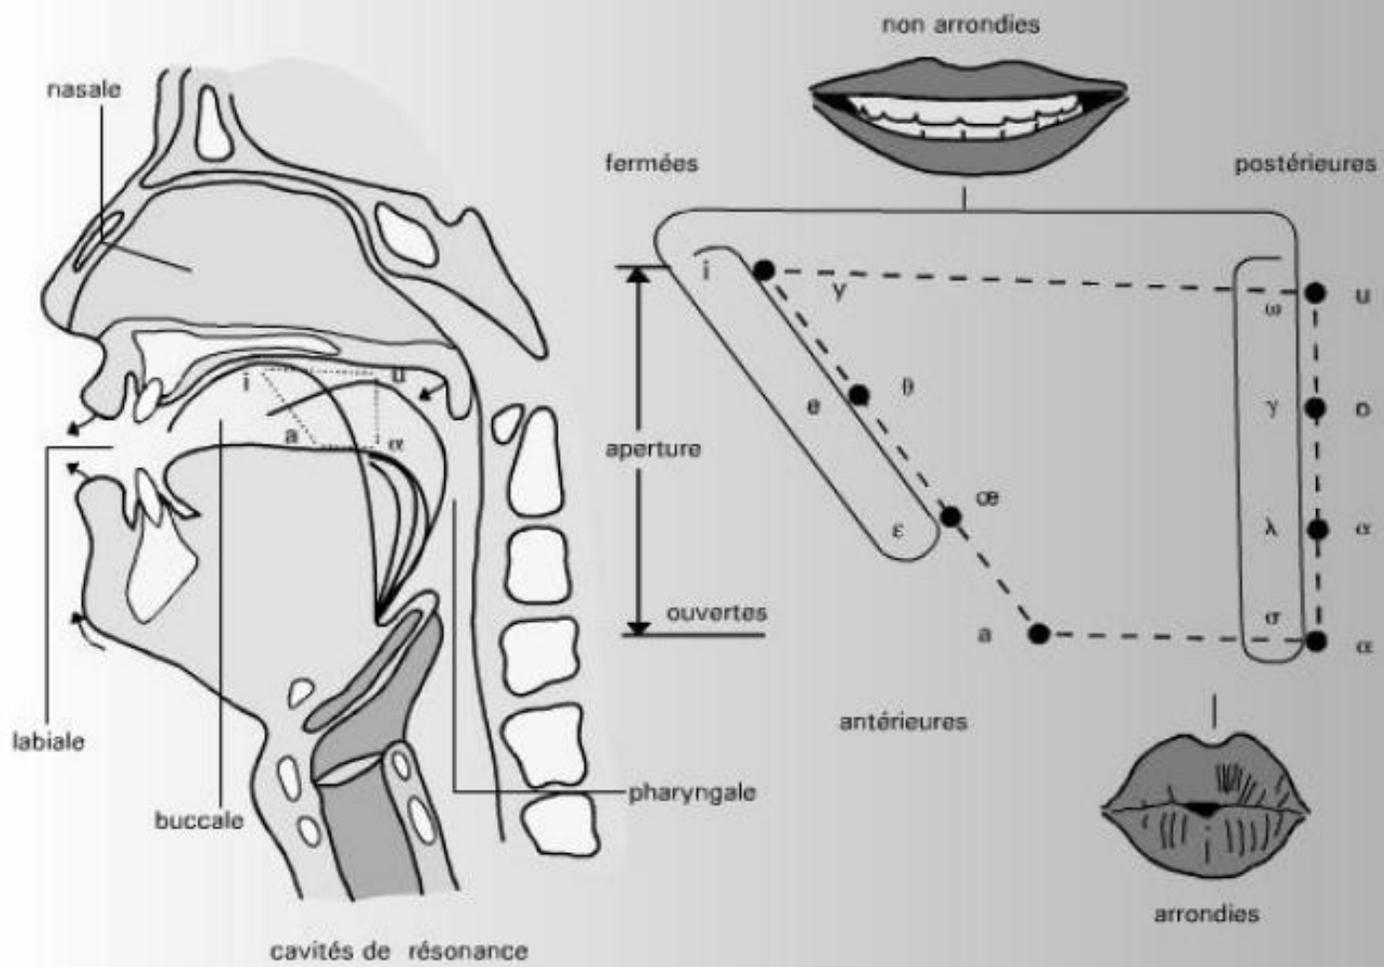
$$f_e > 2f_{\max}$$

Si cette règle n'est pas respectée, des fréquences parasites qui n'appartiennent pas au signal de départ apparaissent.

→ repliement du spectre



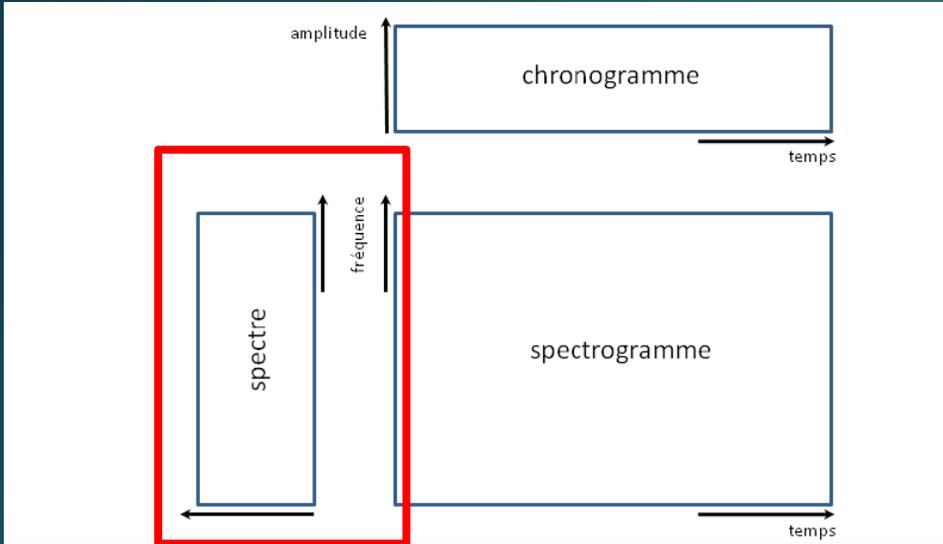
Trapèze vocalique des voyelles



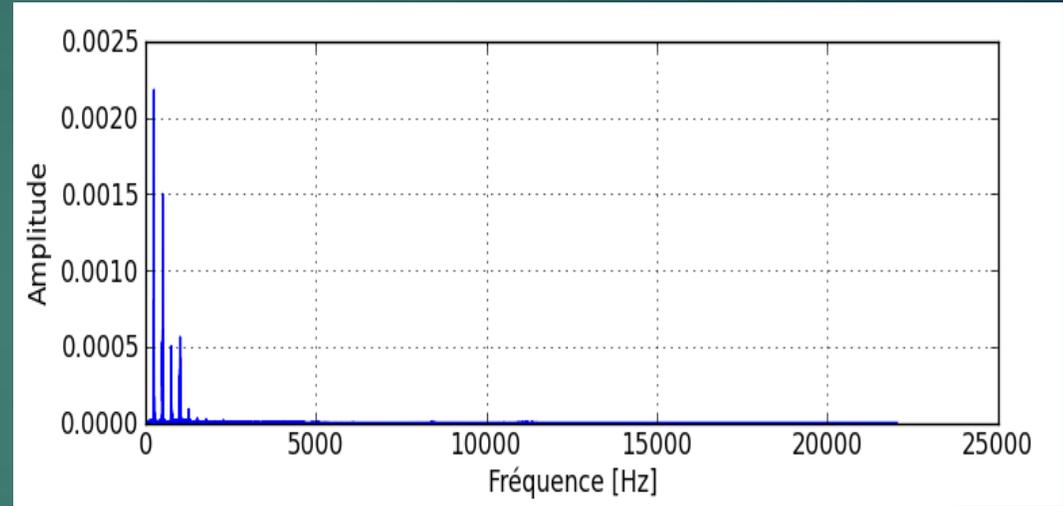
degré d'aperture	point d'articulation		
	antérieures	centrales	postérieures
1. fermées	i	y	ɨ u
2. mi-fermées	e	ø	o
3. mi-ouvertes	ɛ	œ	ɔ
4. ouvertes	λ	α	σ α

Spectres de Fourier

➤ Représentation de l'amplitude d'un son en fonction des fréquences qu'il contient



➤ Spectre de Fourier du son an (réalisé par un programme python)



➤ Principe de Fourier : Tout signal périodique se décompose en somme de signaux sinusoïdaux

➤ FFT: $S(jf) = \int_{-\infty}^{+\infty} s(t) \cdot e^{-j \cdot 2 \cdot \pi \cdot f \cdot t} dt$

- Principe de Fourier:

Tout signal périodique peut se décomposer en somme de signaux sinusoïdaux.

- ▶ Utilisation de la transformé de Fourier discrète:

La méthode consiste à échantillonner un signal $u(t)$ à valeurs réelles

en N échantillons u_n , avec : $\begin{cases} f_e = 2f_{max} \\ N = \frac{f_e}{\Delta f} \end{cases}$ avec Δf : résolution fréquentielle en Hz

La transformée de Fourier discrète est alors donnée par:

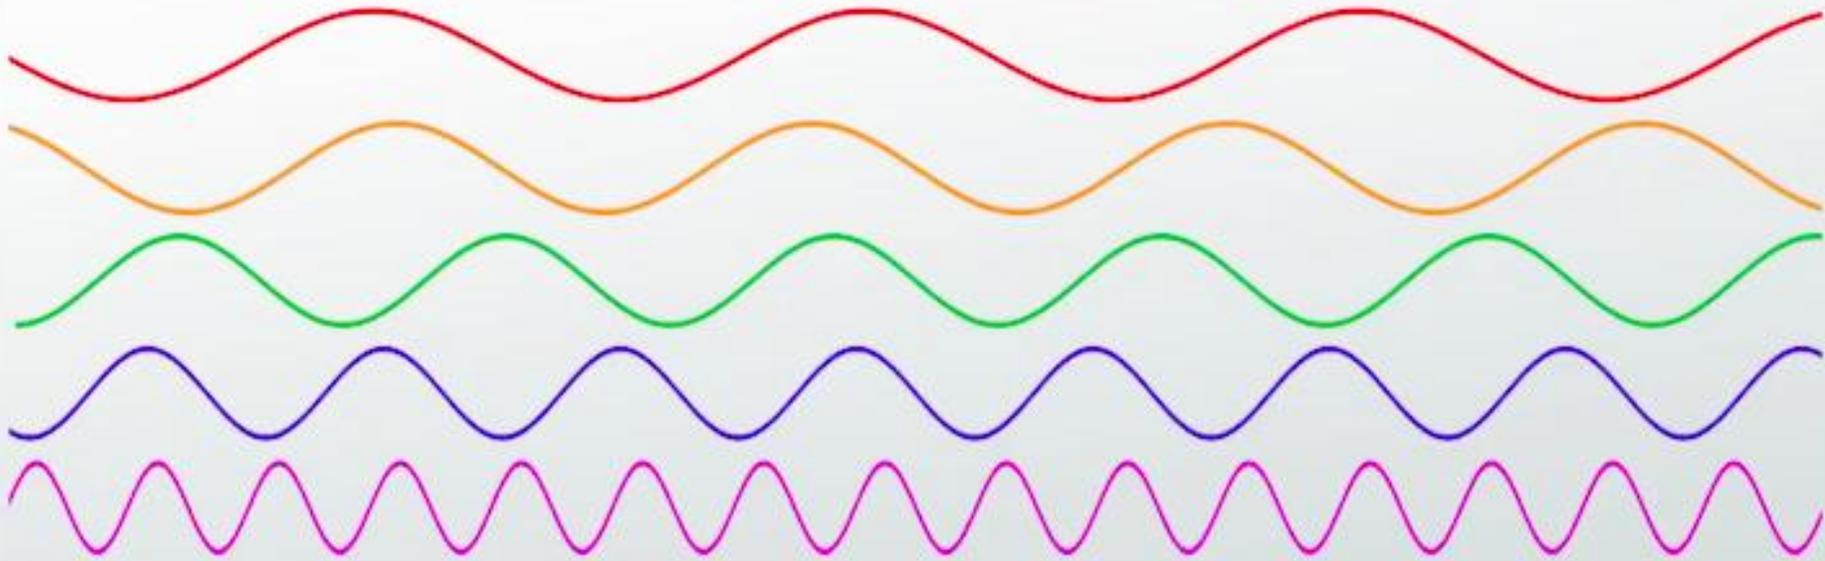
$$TU(k) = \frac{1}{N} \sum_{n=0}^{N-1} u_n e^{\frac{-2i\pi kn}{N}}$$

Dans la pratique, on implémente la transformée de Fourier rapide (FFT, pour Fast Fourier Transform).

Pertinence de la transformée Fourier: permet de réaliser une analyse temps-fréquence avec une résolution suffisante pour le signal vocal.

FREQUENCY

low pitch



high pitch