
Tema: Clasificare de sunete folosind filtre Gabor

Andrei Nicolicioiu

andrei.nicolicioiu@gmail.com

Publicat: 3 noiembrie 2020.

Update: **9 noiembrie**. Clarificare $o_e == o$.

Update: **15 noiembrie**.

Dacă nu ați trimis deja tema, vă rugăm să țineți cont de următoarele 2 aspecte.

1. Pentru a prezenta mai ușor tema vă rugăm să adăugați și un fișier `readme` de câteva rânduri în care să prezentați structura implementării (ex. ce face fiecare funcție) și câteva detalii de implementare. Pentru a nu rata ceva la corectare, vă rugăm să menționați în `readme` câte cerințe ați rezolvat și ce acuratețe ați obținut la cerințele 4 și 5.

2. Pentru o corectură mai rapidă, am schimbat antetul funcției `get_features`. Folosiți noua formă în scheletul de cod și nu o modificați.

Termen Limită: **16 noiembrie 2020**

1 CLASIFICARE

Clasificarea de sunete, adică prezicerea tipului unui sunet este foarte utilă în diferite domenii [1; 2]. În această temă vom implementa o metodă care va clasifica sunete din mai multe categorii ('Lătratul unui câine', 'Valuri', 'Ploaie' și altele), folosindu-ne de datele din subsetul ESC10 din datasetul [3]

2 TRASĂTURI

În orice metodă de clasificare avem nevoie de un set de trăsături (feature-uri) care caracterizează o entitate și fac posibilă distingerea între două entități diferite. De exemplu, pentru diferențierea imaginilor cu căpșuni de imagini cu banane, culoarea va fi o bună trăsătură. Pentru distingerea sunetelor este foarte important spectrul lor de frecvențe, așa că vom încerca să ne construim niște feature-uri care surprind bine spectrul sunetelor. De exemplu, în plânsul unui copil există frecvențe mai mari decât există în sunetul valurilor.

La curs am învățat să analizăm spectrul unui semnal cu ajutorul Transformatei Fourier. În cadrul acestei teme vom proiecta o serie de filtre în domeniul timpului care au un comportament dorit în domeniul frecvențelor.

2.1 FILTRUL GABOR

Filtrele Gabor sunt folosite de obicei pentru analiza semnalelor bidimensionale precum imaginile, însă noi le vom folosi în varianta unidimensională. Ele sunt folosite pentru a găsi regiuni locale dintr-un semnal care au anumite frecvențe.

Vom învăța mai multe despre filtrare în cursurile și laboratoarele următoare. O operație de filtrare liniară a unui semnal x este definită în felul următor:

$$y(n) = h(0)x(n) + h(1)x(n-1) + \dots + h(K)x(n-K)$$

$$y(n) = \sum_{k=0}^{K-1} h(k)x(n-k) \tag{1}$$

Aceasta mai poartă numele de convoluție:

$$y = h * x \quad (2)$$

Operația este definită de elementele filtrului h . În funcție de valorile lui h putem defini diferite tipuri de filtrări. Unul dintre cele mai populare filtre îl reprezintă filtrul Gaussian, definit în felul următor:

$$g(k) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(k-\mu)^2}{2\sigma^2}} \quad (3)$$

Acesta este definit de media μ și deviația standard σ care controlează locația respectiv lățimea filtrului.




Figure 1: Gaussian Filter.

Filtrul Gaussian este un filtru trece-jos, lasă să treacă frecvențele joase nealterate iar frecvențele înalte sunt amortizate. Ne dorim însă un filtru care să răspundă la anumite frecvențe.

Filtrul Gabor este construit să răspundă la semnale având frecvențe în jurul unei valori f_0 date. Deci este un tip de filtru trece-bandă. Este construit prin înmulțirea unui filtru Gaussian cu un semnal sinusoidal de o anumită frecvență f_0 .

$$b(n) = g(n) \cos(2\pi f_0 n) \quad (4)$$

Modulând filtrul gaussian folosind funcțiile \cos și \sin obținem 2 filtre ortogonale. Ne rezumăm în descriere la semnalul definit cu funcția \cos , celalalt fiind definit echivalent.




Figure 2: Filtru Gabor.

2.2 TRĂSĂTURI DIN FILTRE GABOR

Putem caracteriza un semnal după răspusul său la diferite filtre Gabor. Ne construim întâi un set de filtre (*filter bank*), definite printr-un set de frecvențe $\{f_0, f_1, \dots, f_M\}$. Obținem M semnale filtrate:

$$\begin{aligned}y_1 &= b_1 * x \\y_2 &= b_2 * x \\&\dots \\y_M &= b_M * x\end{aligned}\tag{5}$$

Semnalul de iesire y poate fi caracterizat în fiecare punct n de cele M activări ale filtrelor: $o(n) = [y_1(n), y_2(n), \dots, y_M(n)]$. La fiecare pas de timp n , iesirea va fi caracterizată de vectorul de trăsături (*features*) $o(n)$. Cel mai simplu mod de a caracteriza întreg semnalul de iesire, va fi să calculăm media peste timp a acestor trăsături, obținând un singur vector de dimensiune M pe care îl putem folosi pentru a putea analiza întreg semnalul.

3 ANTRENARE

Pentru fiecare sunet din baza de date, ar trebui să obținem în modul descris un vector de trăsături. Baza de date folosită de noi are 10 tipuri de sunete iar noi vom folosi o metodă de învățare automată (*machine learning*) pentru a le putea distinge.

În general se folosesc 2 subseturi distincte de date. Primul este setul de învățare (antrenare) pe care îl folosim ca să analizăm datele și să ne antrenăm un clasificator care să diferentieze cât mai bine datele. Pentru ca vrem ca un clasificator să generalizeze, adică să poată face predicții corecte despre fișiere audio pe care nu le-a văzut la antrenare, vom măsura performanța clasificatorului pe un alt subset din date, denumit setul de testare.

În scheletul temei veți folosi direct o metodă implementată în pachetele octave.

4 IMPLEMENTARE

În implementarea temei veți pleca de la un schelet de cod, pe care va trebui să îl urmați.

Install Instalați octave:

```
sudo apt-get install liboctave-dev
```

Instalați pachetul octave *nan* din octave command prompt. Aceasta ne oferă access la un clasificator de tip Linear discriminant analysis (LDA) implementat în funcția *train_sc*.

```
pkg install nan -forge
pkg load nan
```

5 CERINTE

1. Implementare filtru Gabor [3 puncte]. Implementați o funcție care crează un filtru Gabor de dimensiune, deviație standard și frecvență date. Creați 3 variante de filtre, modulând filtrul gaussian cu următoarele funcții sinusoidale: $\cos(x)$ și $\sin(x)$ și sinusoidală complexă $e^{ix} = \cos(x) + i \sin(x)$.

```
function [complex_h, cos_h, sin_h] = gabor_filter(size, sigma, freq)
```

2. Creați un set de filtre [1 punct]. Creați un set de $M = 12$ filtre Gabor folosind următorii parametri:

```

size = 1102

freq = [0.0027, 0.0089, 0.0173, 0.0284, 0.0433, 0.0632, 0.0898,
0.1254, 0.1730, 0.2365, 0.3215, 0.4350]

sigma = [187.2109 140.0663 104.7939, 78.4041, 58.6599, 43.8878,
32.8357, 24.5668, 18.3803, 13.7516, 10.2886, 7.6977]

```

Afișați filtrele de tip cos și sin cu primii parametrii.




Figure 3: Perechea de filtre Gabor de aceeași frecvență, definite cu funcțiile cos și sin. Cele doua filtre pot fi privite ca partea reală și partea imaginară a filtrului definit prin modularea unui Gaussian cu sinusoidalul complex.

3. Afișați spectrul filtrelor [1 punct]. Calculați folosind Transformata Fourier Discretă (implementată ca Fast Fourier Transform - *fft*) spectrul fiecărui filtru Gabor definit cu funcția cos și funcția sin. Afișați magnitudinea spectrului corespunzător frecvențelor pozitive, aflat în prima jumătate a răspunsului dat de funcția *fft*.

```

coefs = fft(cos_h);

```




Figure 4: Spectrul Setului de Filtre Gabor.

4. Convoluție [1 punct]. Putem folosi direct filtrele create pentru a procesa inputul precum este prezentat în Secțiunea 2.2. Vom folosi doar filtrele de tip cos pentru acest task. Asta presupune aplicarea unei convoluții dintre fiecare fisier de input și fiecare filtru din setul de filtre de tip cos. Putem folosi direct funcția *conv* din Octave.

Pentru fiecare fisier audio, grupând rezultatele celor M filtre, vom obține un rezultat de dimensiune (aproximativ) $N \times M$, unde N este numărul de esantioane ale fisierului audio. Pentru a obține un

descriptor al fisierului, vom calcula media și deviație standard pe cei N pași de timp. În final vom obține câte un vector de dimensiune $2M$ pentru fiecare fisier audio, pe care îi returna din funcția `get_features` din scheletul de cod.

5. Filtrare rapidă [4 puncte]. Operația de filtrare dată de convoluție este oarecum inefficientă pentru că are multe operații redundante. Pentru că sunetul este esantionat foarte des, rezultatul filtrării a unor esantioane apropiate este aproximativ același. Așa că vom aplica operația de filtrare definită de Ecuația 1 doar în anumite puncte. Această operație se mai numește și convoluție cu stride.

5.a Creare ferestre [1 punct]. Un fisier audio conține N esantioane, unde N este de ordinul 10^6 . Vom selecta un număr de $F \ll N$ ferestre, adică grupuri consecutive de esantioane, fiecare având K esantioane. Știind că fisierele audio sunt esantionate la frecvența f_s , creăm ferestrele astfel încât să corespundă la 25 ms cu 10 ms distanță între ele.

5.b Filtrare ferestre [3 punct]. Vom aplica Ecuația 1 pentru fiecare fereastră. Vom folosi filtre de tip cos cu aceeași dimensiune K cu a ferestrelor create. Prin această operație, din fiecare fereastră obținem un scalar. Putem observa că această operație se reduce la un produs scalar între fereastră și filtrul inversat. De asemenea putem observa că filtrul este simetric și inversarea este redundantă.

Aplicând această operație pentru toate elementele din dataset vom obține pentru fiecare fisier un tensor o_c de dimensiune $F \times M$.

Repetăm aceleași operații, dar cu seturile de filtre sin și sinusoid complex pentru a obține o_s și o_e .

Calculați $o = \sqrt{o_c^2 + o_s^2}$ și afișați media diferenței dintre aceasta și valoarea absolută $|o_e|$ [1 punct]. Ar trebui ca cele 2 să fie egale, arătând că filtrarea cu 2 filtre cos și sin e echivalentă cu filtrarea cu filtrul sinusoidal complex echivalent $o = |o_e|$. **Pentru că mereu vor exista probleme numerice, egalitatea se va verifica testând $|o - |o_e|| < \epsilon$, unde ϵ este un număr mic, de exemplu 10^{-10} .**

La fel ca la subpunctul precedent, pentru fiecare fisier audio, putem calcula media și deviația standard a reprezentării o de dimensiune $F \times M$ obținând un vector de dimensiune $2M$ folosit în funcția `get_features` din scheletul de cod.

Folosind metoda descrisă, putem obține un clasificator cu acuratețe de aproximativ 55 – 70%.

[Bonus] Încercați să obțineți o performanță cât mai bună prin varierea numărului de filtre folosite și a parametrilor filtrelor.

REFERENCES

- [1] Jens Schröder, Jorn Anemüller, and Stefan Goetze. Classification of human cough signals using spectro-temporal gabor filterbank features. In *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 6455–6459. IEEE, 2016.
- [2] Shawn Hershey, Sourish Chaudhuri, Daniel P. W. Ellis, Jort F. Gemmeke, Aren Jansen, Channing Moore, Manoj Plakal, Devin Platt, Rif A. Saurous, Bryan Seybold, Malcolm Slaney, Ron Weiss, and Kevin Wilson. Cnn architectures for large-scale audio classification. In *International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. 2017.
- [3] Karol J Piczak. Esc: Dataset for environmental sound classification. In *Proceedings of the 23rd ACM international conference on Multimedia*, pages 1015–1018, 2015.