

**MAKALAH**  
**PENGOLAHAN SINYAL MULTIMEDIA**  
“ Eigenvector Analysis, Principal Component Analysis  
and Independent Component Analysis ”



**OLEH:**  
**PUTU NOPA GUNAWAN D411 10 009**

**Jurusan Teknik Elektro**  
**Fakultas Teknik**  
**Universitas Hasanuddin**  
**2013**

## DAFTAR ISI

Daftar Isi .....	ii
A. Pengertian .....	1
B. Eigenvector dan eigenvalues .....	1
C. PCA (Principle Component Analisis ) atau Analisis Komponen Utama .....	5
D. Analisis Komponen Independen atau Independent Component Analysis (ICA) .....	8
Ringkasan .....	13
Daftar Pustaka .....	14

## A. Pengertian

Eigen berasal dari kata Jerman yang berarti sendiri, khas, karakteristik atau individu. Untuk memahami vektor eigen kita perlu memahami fungsi operasional dasar dari sebuah matriks. Secara umum, matriks linier mengubah arah dan besaran vektor. *Eigenanalysis* berguna dalam aplikasi seperti diagonalisasi dari korelasi matriks, pemrosesan sinyal radar, ekstraksi fitur, pengenalan pola, coding sinyal, estimasi kebisingan, dan pemisahan biomedis campuran atau sinyal komunikasi.

Sebuah aplikasi utama *eigenanalysis* dalam analisis komponen utama (*principal component analysis* atau PCA). PCA secara luas digunakan untuk ekstraksi fitur dan pengurangan dimensi dengan membuang fitur yang memiliki varians tidak signifikan atau sangat rendah signal-to-noise rasionya. PCA memungkinkan transformasi dan representasi dari sinyal dalam hal koefisien dari satu set vektor eigen ortonormal, sehingga komponen utama (yaitu komponen yang paling signifikan) yang memiliki nilai eigen terbesar dan paling signifikan.

Komponen analisis independen (*Independent component analysis* atau ICA) merupakan perluasan dari PCA untuk sinyal yang memiliki statistik orde tinggi. ICA biasanya melibatkan penentuan satu parameter yang diagonal orde kedua (kovarians) dan orde keempat (kurtosis) dari sinyal. ICA sering digunakan sebagai add-on untuk PCA untuk pengolahan non-Gaussian sinyal seperti suara, gambar dan sinyal biomedis. ICA sangat berguna untuk pemisahan sinyal campuran dalam multi-sumber multi-sensor sistem medis dan *multi-input multi-output* (MIMO) sistem komunikasi.

## B. Eigenvector dan eigenvalues

Sebuah matriks bujur sangkar dengan orde  $n \times n$  misalkan  $A$ , dan sebuah vektor kolom  $X$ . Vektor  $X$  adalah vektor dalam ruang Euklidian  $R$  yang dihubungkan dengan sebuah persamaan:

$$AX = \lambda X \quad (1)$$

Dimana  $\lambda$  adalah suatu skalar dan  $X$  adalah vektor yang tidak nol. Skalar  $\lambda$  dinamakan nilai Eigen (*eigenvalue*) dari matriks  $A$ . Nilai eigen adalah nilai karakteristik dari suatu matriks bujur sangkar. Vektor  $X$  dalam persamaan (1) adalah suatu vektor yang tidak nol yang memenuhi persamaan (1) untuk nilai eigen yang sesuai dan disebut dengan vektor eigen. Jadi vektor  $X$  mempunyai nilai tertentu untuk nilai eigen tertentu.

### Diagonalisasi

Sebuah matriks bujursangkar  $A$  dikatakan dapat didiagonalisasi jika terdapat sebuah matriks  $P$  yang dapat dibalik sedemikian rupa sehingga menjadi sebuah matriks diagonal,  $P$  dikatakan mendiagonalisasi  $A$ .

### Diagonalisasi Ortogonal

Jika  $A$  adalah sebuah matriks simetriks, maka:

- (a) Nilai eigen matriks  $A$  semuanya adalah bilangan real.
- (b) Vektor eigen yang berasal dari ruang eigen yang berbeda saling ortogonal.

### Perhitungan eigenvalues

Kita tinjau perkalian matriks  $A$  dan  $X$  dalam persamaan (1) apabila kedua sisi dalam persamaan tersebut dikalikan dengan matriks identitas didapatkan:

$$IAX = I\lambda X \quad (2)$$

$$AX = IX\lambda \quad (3)$$

$$[\lambda I - A]X = 0 \quad (4)$$

Persamaan (4) terpenuhi jika dan hanya jika:

$$\det [\lambda I - A] \quad (5)$$

Dengan menyelesaikan persamaan (5) dapat ditentukan nilai eigen ( $\lambda$ ) dari sebuah matriks bujur sangkar  $A$  tersebut.

## Perhitungan eigenvector

Kita tinjau kembali persamaan  $AX = \lambda X$  dimana A adalah matriks bujur sangkar dan X adalah vector bukan nol yang memenuhi persamaan tersebut.

Kita tinjau sebuah matriks bujur sangkar orde 2 x 2 berikut:

$$A = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \quad (6)$$

Persamaan  $AX = \lambda X$  dapat di tuliskan:

$$\begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \lambda \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (7)$$

Persamaan di atas dikalikan dengan identitas didapatkan

$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = \begin{bmatrix} \lambda & 0 \\ 0 & \lambda \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (8)$$

$$\begin{bmatrix} a_{11} - \lambda & a_{12} \\ a_{21} & a_{22} - \lambda \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} = 0$$

Persamaan di atas dalam bentuk persamaan linier dituliskan:

$$(a_{11} - \lambda)x_1 + a_{12}x_2 = 0 \quad (9)$$

$$a_{21}x_1 + (a_{22} - \lambda)x_2 = 0$$

Contoh 1:

Jika diberikan matriks:

$$A = \begin{bmatrix} 2 & 1 \\ 0 & 3 \end{bmatrix}$$

maka polynomial karakteristiknya dapat dicari sebagai berikut:

$$\det \begin{bmatrix} 2 - \lambda & -1 \\ 0 & 3 - \lambda \end{bmatrix} = \lambda^2 - 5\lambda + 6 = 0$$

ini adalah persamaan kuadrat dengan akar-akarnya adalah  $\lambda = 2$  dan  $\lambda = 3$ .

Adapun eigenvector yang didapat ada dua buah. Eigenvector pertama dicari dengan mensubstitusikan  $\lambda = 3$  ke dalam persamaan. Misalnya  $Y_0$  adalah eigenvector yang berasosiasi dengan eigenvalue  $\lambda = 3$ . Set  $Y_0$  dengan nilai:

$$Y_0 = \begin{bmatrix} X_0 \\ Y_0 \end{bmatrix}$$

Kemudian substitusikan  $Y_0$  dengan  $v$  pada persamaan:

$$(A - \lambda I)v = 0$$

sehingga diperoleh:

$$(2 - 3)X_0 + (-Y_0) = 0$$

$$0 + (3 - 3)Y_0 = 0$$

dapat disederhanakan menjadi:

$$-X_0 - Y_0 = 0 \text{ atau } Y_0 = -X_0$$

sehingga eigenvector untuk eigenvalue  $\lambda = 3$  adalah:

$$Y_0 = \begin{bmatrix} X_0 \\ Y_0 \end{bmatrix} = \begin{bmatrix} X_0 \\ -X_0 \end{bmatrix} = X_0 \begin{bmatrix} 1 \\ -1 \end{bmatrix}$$

Hubungan antara eigenvalue dan eigenvector dari suatu matriks digambarkan oleh persamaan:

$$C \times v_i = \lambda_i \times v_i$$

dimana  $v$  adalah eigenvector dari matriks  $M$  dan  $\lambda$  adalah eigenvalue. Terdapat  $n$  buah *eigenvector* dan *eigenvalue* dalam sebuah  $n \times n$  matriks.

### C. PCA (*Principle Component Analysis*) atau Analisis Komponen Utama

Analisis komponen utama (PCA) adalah metode analisis data yang populer digunakan untuk tujuan sebagai pengurangan dimensi kompresi sinyal, fitur ekstraksi, dan pemisahan noise.

Prosedur PCA pada dasarnya adalah bertujuan untuk menyederhanakan variabel yang diamati dengan cara menyusutkan (mereduksi) dimensinya. Hal ini dilakukan dengan cara menghilangkan korelasi diantara variabel bebas melalui transformasi variabel bebas asal ke variabel baru yang tidak berkorelasi sama sekali atau yang biasa disebut dengan *principal component*. Setelah beberapa komponen hasil PCA yang bebas multikolinearitas diperoleh, maka komponen-komponen tersebut menjadi variabel bebas baru yang akan diregresikan atau dianalisa pengaruhnya terhadap variabel tak bebas (Y) dengan menggunakan analisis regresi. Proses ini akan menghasilkan beberapa *eigenvector* yang merupakan kombinasi seluruh variasi fitur yang terdapat dalam seluruh data. Jika objek yang digunakan berupa gambar wajah, *eigenvector* tersebut sering disebut *eigenfaces*.

Keuntungan penggunaan *Principal Component Analysis* (PCA) dibandingkan metode lain :

1. Dapat menghilangkan korelasi secara bersih (korelasi = 0) sehingga masalah multikolinearitas dapat benar-benar teratasi secara bersih.
2. Dapat digunakan untuk segala kondisi data / penelitian
3. Dapat dipergunakan tanpa mengurangi jumlah variabel asal
4. Walaupun metode Regresi dengan PCA ini memiliki tingkat kesulitan yang tinggi akan tetapi kesimpulan yang diberikan lebih akurat dibandingkan dengan penggunaan metode lain.

## Perhitungan PCA

Asumsikan kita memiliki sampel  $L$  dari proses vektor  $N$ -dimensi  $\mathbf{x}(0)$ ,  $\mathbf{x}(1)$ ,  $\dots$ ,  $\mathbf{x}(L-1)$ . Vektor ini mungkin *frame* suara atau sub-blok dari suatu gambar. Langkah pertama dalam analisis PCA adalah untuk mendapatkan perkiraan rata-rata dari vektor sinyal seperti

$$\mu = \frac{1}{L} \sum_{m=0}^{L-1} \mathbf{x}(m) \quad (10)$$

Perkirakan matriks kovarians dari vektor sinyal kemudian diperoleh sebagai

$$C_{xx} = \frac{1}{L} \sum_{m=0}^{L-1} (\mathbf{x}(m) - \mu) (\mathbf{x}(m) - \mu)^T \quad (11)$$

Langkah berikutnya adalah menghitung *eigenvector* dan *eigenvalue* dari matriks *covariance* tersebut. Dari *eigenvector* dan *eigenvalue* yang dihasilkan, dipilih  $K$  *eigenvector* yang memiliki *eigenvalue* terbesar.

Hitung matriks  $V$  dari vector eigen yang mendiagonalisasi matriks  $C$ :

$$V^{-1}CV = D \quad (12)$$

Dimana  $D$  adalah matriks diagonal dari *eigenvalues* di  $C$ . Langkah ini biasanya akan melibatkan penggunaan algoritma berbasis komputer untuk komputasi vector eigen dan nilai eigen.

Matrix  $D$  akan mengambil bentuk  $M \times M$  matriks diagonal, di mana

$$D[p, q] = \lambda_m \quad \text{for } p = q = m \quad (13)$$

adalah  $m$  th eigen dari matriks kovariansi  $C$ , dan

$$D[p, q] = 0 \quad \text{for } p \neq q. \quad (14)$$

Matrix  $V$ , juga dimensi  $M \times M$ , berisi  $M$  vektor kolom, masing-masing panjangnya  $M$ , yang mewakili  $M$  vektor eigen dari matriks kovariansi  $C$ .

## Analisis Gambar dengan PCA

Analisis PCA dapat digunakan untuk menguraikan gambar ke dalam satu set komponen utama gambar ortogonal juga dikenal sebagai *eigenfaces*. *Eigenfaces* dapat digunakan untuk coding gambar, denoising gambar, atau sebagai fitur untuk klasifikasi citra.

Untuk mendapatkan sebuah eigenfaces  $[E_{ij}]$  untuk gambar yang diberikan  $A$  dengan ukuran  $r_0 \times c_0$  pixels, gambar pertama dibagi menjadi sub-gambar  $L$  (sub-blok)  $A_k$  dengan ukuran  $r \times c$  (biasanya  $8 \times 8$  atau  $16 \times 16$ ).

Mean dari sub-gambar diperoleh sebagai

$$A_{mean} = \frac{1}{L} \sum_{k=0}^{L-1} A_k \quad (15)$$

Mean gambar kemudian dihapus dari setiap sub-gambar sebagai

$$\bar{A}_k = A_k - A_{mean} \quad (16)$$

Sebuah  $r \times r$  matriks kovarians untuk baris dari sub-gambar diperoleh

$$C_r = \frac{1}{L} \sum_{k=0}^{L-1} \bar{A}_k \bar{A}_k^T \quad (17)$$

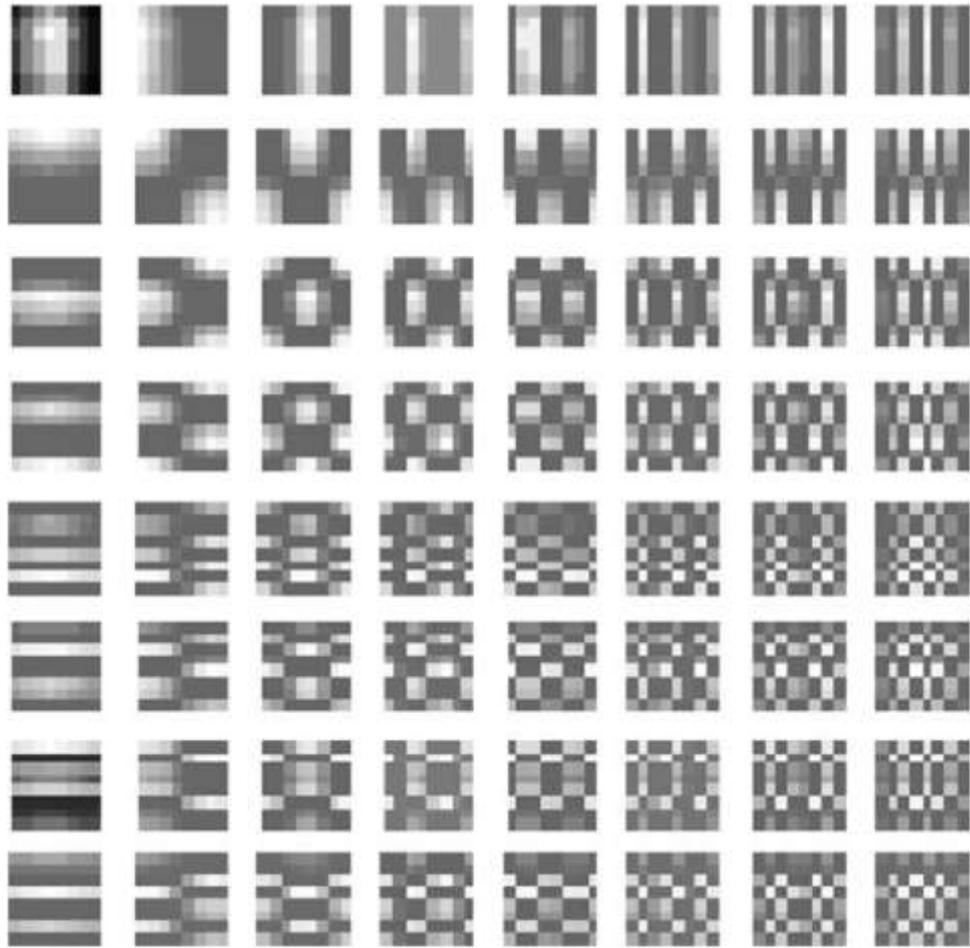
Demikian pula, sebuah  $c \times c$  matriks kovarians untuk kolom dari sub-gambar diperoleh

$$C_c = \frac{1}{L} \sum_{k=0}^{L-1} \bar{A}_k^T \bar{A}_k \quad (18)$$

Baris dan kolom matriks kovarians kemudian mengalami eigenanalysis untuk menghasilkan vektor eigen  $r$  baris  $[r_i ; 1 \leq i \leq r]$  dan kolom vektor eigen  $[c_j ; 1 \leq j \leq c]$ .

Sebuah  $r \times c$  eigenfaces  $E_{ij}$  didefinisikan sebagai produk dari setiap baris eigenvector dengan setiap kolom eigenvektor sebagai

$$E_{ij} = r_i c_j^T \quad 1 \leq i \leq r, 1 \leq j \leq c \quad (19)$$



Gambar 1. Menunjukkan contoh *eigenfaces* untuk gambar . 64 *eigenfaces* ukuran 8 x 8 dalam urutan nilai eigen terkait

#### **D. Analisis Komponen Independen atau *Independent Component Analysis (ICA)***

*Independent Component Analysis (ICA)* adalah sebuah teknik pemrosesan sinyal untuk menemukan faktor–faktor atau komponen tersembunyi yang membentuk sekumpulan variabel acak (hasil dari pengukuran, sinyal atau secara umum data). ICA mendefinisikan sebuah model untuk mengamati data multivariabel atau multidimensi, yang biasanya berupa sampel data yang besar. Dalam model tersebut, variabel data dianggap sebagai gabungan linier dari beberapa variabel tersembunyi yang tidak diketahui dan sistem pencampuran yang tidak diketahui

pula. Tujuan dari ICA adalah untuk melakukan alih ragam linier yang menyebabkan variabel yang dihasilkan sedapat mungkin saling secara statistik independen.

Salah satu penggunaan metode ICA adalah untuk memisahkan sinyal-sinyal tercampur yang berasal dari beberapa sumber yang saling bebas statistik satu sama lain dan distribusi sumber tersebut bersifat non Gaussian.

### **Model dasar**

ICA menggunakan persamaan sederhana yaitu sebagai berikut:

$$X=AS \tag{20}$$

Dimana  $S$  merupakan kumpulan  $m$  Sinyal source, matrik  $A$  merepresentasikan mekanisme penggabungan sinyal-sinyal source dan  $X$  merepresentasikan sinyal mixture hasil penggabungan tersebut. Contoh sederhana dari rumus diatas terdapat dalam cocktail problem dimana terdapat 2 orang yang berhitung dengan bahasa masing-masing. Dua buah microphone merekam suara kedua orang tersebut dan menghasilkan suara campuran. Jadi terdapat dua buah suara campuran dari kedua orang tersebut.

Ide utama dari ICA adalah menemukan source asli  $S$  dengan asumsi bahwa source asli tersebut saling independent satu sama lain secara statistik. Artinya joint probabilistic densityfunction komponen-komponenya (pdf) adalah product dari densitas seluruh sinyal asli.

$$P(s)=\prod p(s_i) \tag{21}$$

Di mana  $p(s_i)$  adalah pdf dari sinyal asli dan  $P(s)$  adalah joint density function. Dengan sebuah vektor  $V$ , tujuan dari ICA adalah menemukan matrik  $U$  sedemikian sehingga  $V=UX$ , Dimana  $V$  adalah estimasi dari source sinyal  $S$ . Dari persamaan diatas diketahui bahawa matrik  $U$  adalah estimasi dari invers matrik  $A$ .

ICA melakukan beberapa asumsi terhadap data yang akan diolah, asumsi tersebut adalah

1. Data bersifat Non-Gaussian hal ini dilakukan karena data ICA tidak dapat mengkalkulasi data gaussian. Misalkan suatu data gaussian  $x_1$  dan

$x_2$ , yang saling tidak berkorelasi (uncorrelated), maka akan didapatkan joint density sebagai berikut :

$$p(x_1, x_2) = \frac{1}{2\pi} \exp\left(-\frac{x_1^2 + x_2^2}{2}\right) \quad (22)$$

2. *Data Statistically Independent*. Walaupun data yang diolah tidak bersifat statistically independent namun data tersebut akan diolah dengan mengasumsikan bahwa data tersebut statistically independent. Asumsi tidak dilakukan dengan menganggap bahwa data statistically independent secara keseluruhan, namun asumsi dilakukan dengan menganggap bahwa data statistically independent setiap selang waktu observasi  $t$ .
3. *Square Mixing Matrix*. Mixing Matrix  $A$  adalah hasil primer dari algoritma ICA, sedangkan Independent Component merupakan hasil sekunder yang didapatkan melalui fungsi invers. Mixing matrix diasumsikan mempunyai bentuk square perseg untuk memudahkan kalkulasi algoritma ICA.
4. Data tercampur secara linier. Untuk memudahkan kalkulasi, data diasumsikan merupakan hasil perkalian antara matriks sinyal asli dengan matriks pencampur.

### **Ambiguitas ICA**

Dalam Algoritma ICA terdapat beberapa ambiguitas yang muncul, yaitu :

1. Variansi dan Energi tidak dapat ditentukan  
Setiap sinyal memiliki suatu nilai variansi tertentu yang menyatakan tingkat energi sinyal tersebut, begitu juga dengan sinyal asli pembentuk mixed signal. ICA memungkinkan proses pemisahan sejumlah komponen bebas dari suatu sinyal tercampur, namun ICA tidak dapat menentukan nilai variansi sinyal asli. Hal ini disebabkan karena pada saat perekaman data akan terdapat faktor bebas scalar yang

menyebabkan pelemahan atau penguatan sinyal hasil rekaman, sehingga nilai variansi sinyal asli tidak dapat ditentukan melalui proses ICA.

2. Urutan Independent Component tidak dapat

Ditentukan Komponen bebas yang dihasilkan melalui kalkulasi ICA dapat berubah-ubah urutannya, hal ini jelasketika proses simulasi ICA dilakukan.

### Algoritma

Estimasi model data ICA biasanya menggunakan fungsi *objective* misal mutual information atau negentropy kemudian dilakukan optimalisasi. Pada paper ini, estimasi model data ICA menggunakan algoritma JADE yang dikembangkan oleh Cardoso. Algoritma JADE mendasarkan atas diagonalisasi matrik cummulant bersama. Algoritma JADE adalah sebagai berikut:

1. Inisialisasi

Dilakukan proses whitening  $W$  dan temukan  $Z=WX$  Definisikan matrik covariance  $R_x=E(X X^T)$  dimana  $E$  adalah Fungsi Ekspektasi.  $D$  adalah matrik diagonal dari eigenvalue,  $H$  adalah matrik eigen vector.  $W=HD^{-1/2}H^T$

2. Estimasi himpunan  $\{Q_z\}$  dari matrik cummulant

Jika terdapat vector  $z$  berukuran  $n \times 1$  dan matrik  $M$  berukuran  $n \times n$ , matrik cummulant adalah

$$Q_z(M) = E \{ (z^T M z) z z^T \} - R_z \text{tr} (M R_z) - R_z M_z - R_z M^T R_z \quad (23)$$

Dimana  $\text{tr}$  menyatakan trace dari matrik

3. Optimisasi orthogonal contrast

Menemukan matrik rotasi  $U$  dimana matrik cummulant sediadagonal mungkin.

4. Pemisahan

Estimasi  $A$  sebagai  $V=UW^{-1}$  dan sinyal asli sebagai  $V=U^{-1}X$ . Jika estimasi sinyal asli menggunakan ICA telah menghasilkan estimasi sinyal maka dilakukan identifikasi sinyal asli apakah merupakan sinyal

noise, artefak atau memang sinyal sesungguhnya yang diinginkan. Rekonstruksi sinyal campuran dilakukan dengan mengeset seluruh row yang merepresentasikan sinyal gangguan noise atau artefak dengan 0.

$$X' = UV' \quad (24)$$

Dengan  $V'$

$$\begin{bmatrix} V_{11} & V_{12} & V_{1N} \\ 0 & 0 & 0 \\ V_{31} & V_{32} & V_N \end{bmatrix} \quad (25)$$

Misalkan row kedua adalah noise atau artefak dan matrik  $V_{ij}(i,j=1,..N)$  adalah elemen dari matrik  $V$  dan  $N$  merepresentasikan jumlah sinyal.

### ICA Kawasan Frekuensi

Pada pengamatan di lingkungan yang sebenarnya, selain merekam sinyal yang datang secara langsung, sensor (mikrofon) juga akan merekam versi sinyal sumber yang mengalami penundaan (delay) dan pelemahan (attenuation) akibat adanya pemantulan. Hal ini menyebabkan sinyal-sinyal yang diamati tidak dapat dianggap hanya sebagai kombinasi linear dari sinyal sumber (seperti model pada persamaan 4) dan harus dimodelkan sebagai proses konvolusi seperti berikut:

$$x_i(t) = \sum_{j=1}^m \sum_k a_{ikj} s_j(t - k) \quad (26)$$

dengan  $j$  merupakan jumlah sumber,  $i$  merupakan jumlah sinyal campuran, dan  $k$  merupakan indeks konvolusi.

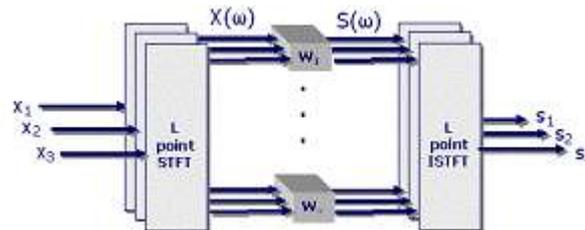
Selanjutnya model konvolusi di atas akan diubah menjadi model ICA kawasan frekuensi sebagai berikut:

$$X(f) = A(f)S(f) \quad (27)$$

dengan  $X(f)$  merupakan vektor sinyal yang diamati,  $S(f)$  merupakan sinyal sumber, dan  $A(f)$  merupakan matriks pencampuran yang bernilai kompleks.

Untuk mengubah proses pencampuran secara konvolusi menjadi model dalam kawasan frekuensi, digunakan alihragam Fourier waktu pendek (STFT) pada

sinyal campuran  $x(t)$  dan selanjutnya proses ICA akan dilakukan untuk setiap binfrekuensi (frequency bin). Dengan demikian, pada kawasan frekuensi seluruh proses ICA untuk sinyal terkonvolusi diubah menjadi proses ICA untuk menentukan matriks pemisah  $W(f)$  pada setiap binfrekuensi tiap sumber.



Gambar 2. Model pemisahan ICA kawasan frekuensi

## Ringkasan

Pemahaman yang mendalam dan pemanfaatan teori sistem linear itu sangat penting dalam penelitian dan penerapan pemrosesan sinyal digital. Sebuah konsep sentral dalam teori sistem linear adalah konsep analisis eigen. Analisis Eigen menyediakan alat untuk dekomposisi sinyal dalam sebuah fungsi dasar ortogonal. Eigen analisis vektor dapat digunakan untuk pemrosesan sinyal. Eigen vektor analisis juga digunakan dalam analisis komponen utama (PCA) untuk menentukan komponen dasar yang paling signifikan ortogonal dari proses sinyal. Independen analisis komponen dapat dilihat sebagai perpanjangan eigen analisis atau PCA, namun, ada substansial perbedaan. Tidak seperti PCA, ICA dapat digunakan untuk memproses sinyal yang non-Gaussian. Satu aplikasi penting dari ICA masih dalam pemisahan sumber (BSS), aplikasi lain pada prinsipnya ekstraksi fitur untuk sinyal non-Gaussian (seperti ekstraksi citra eigen) sebagai efisien alternatif untuk PCA.

## Daftar Pustaka

- John Wiley & Sons, 2007, Multimedia Signal Processing: Theory and Applications in Speech, Music and Communications, Saeed V. Vaseghi : Ltd;
- [http://resources.unpad.ac.id/unpad-content/uploads/publikasi\\_dosen/PCA%20\(PRCPL%20COMP%20ANLS\).pdf](http://resources.unpad.ac.id/unpad-content/uploads/publikasi_dosen/PCA%20(PRCPL%20COMP%20ANLS).pdf) (Akses tanggal 14 April 2013)
- <http://aristriwiatno.blog.undip.ac.id/files/2012/09/Linear-Algebra.pdf> (Akses tanggal 14 April 2013)
- <http://id.scribd.com/doc/133407385/Mencari-Eigenvalue-Dan-Eigenvector> (Akses tanggal 14 April 2013)
- [http://faculty.petra.ac.id/halim/index\\_files/Stat2/PCA.pdf](http://faculty.petra.ac.id/halim/index_files/Stat2/PCA.pdf) (Akses tanggal 19 April 2013)

## HASIL DISKUSI

### Sesi Pertanyaan:

#### 1. Andika Kumoro Seto

Apa perbedaan dari Eigenvector dan Eigenvalue dan mana yang paling bagus diantara keduanya?

Jawab :

Oleh Putu Nopa Gunawan

Eigenvector dan eigenvalue bukan merupakan perbandingan penggunaan sehingga tidak ada yang bagus dan tidak ada yang tidak bagus. Tapi Eigenvector dan Eigenvalues merupakan 2 hal yang berbeda, dimana Eigenvector atau vektor eigen merupakan nilai vektor dari suatu matrix bujur sangkar yang mana dalam rumus itu disimbolkan dengan X sedangkan untuk eigenvalue atau nilai eigen adalah besaran skalar yang dalam rumus disimbolkan dengan lamda ( $\lambda$ ) . Jadi berdasarkan rumus  $AX = \lambda X$  dapat disimpulkan bahwa untuk mencari eigenvector maka kita terlebih dahulu mencari nilai eigennya atau eigenvalue seperti pada contoh yang saya berikan.

## **2. Aniszhah Mulyawati**

Apa perbedaan Matrix biasa dengan matrix eigen? Dan dimana aplikasi dari matrix eigen itu?

Jawab:

Oleh Putu Nopa Gunawan

Matrix eigen dan matrix biasa tidak memiliki perbedaan yang signifikan, tapi untuk mencari atau mengetahui proses eigenvector analysis dan proses perhitungan Principal Component Analysis dan Independent Component analysis maka kita harus mengetahui prinsip dasar dari operasional suatu matrix. dan itulah tujuannya kita mempelajari cara mencari nilai eigen dan vektor eigen sehingga kita kesulitan dalam menggunakan metode analisis PCA atau Principal Component analysis.

Principal Component Analysis banyak digunakan dalam proses menganalisis tingkat noise, pada sistem komunikasi , pada pengolahan sinyal multimedia seperti video, graphic, gambar dan suara.