

PEMANFAATAN K-NEAREST NEIGHBOR (KNN) PADA PENGENALAN WAJAH DENGAN PRAPROSES TRANSFORMASI WAVELET

Sufiatul Maryana, Lita Karlitasari, Arie Qur'ania

Email : anna_nemo1413@yahoo.com

1) Program Studi Manajemen Informatika Fakultas MIPA – UNPAK

ABSTRAK

Pengenalan wajah merupakan salah satu bidang penelitian dengan banyak aplikasi yang menerapkannya hal itu dikarenakan wajah manusia mampu merepresentasikan sesuatu yang kompleks sehingga dalam melakukan pemodelan komputasi yang ideal sangatlah sulit, karena setiap metode memiliki kelebihan dan kekurangan. Kemampuan untuk dapat mengidentifikasi wajah sangat diperlukan dalam berbagai bidang seperti kepolisian, hukum, forensik, imigrasi dan sebagai identitas wajah dalam memasuki daerah terlarang. Hal ini menyebabkan pengembangan system pengenalan wajah tetap menjadi riset yang penting. Tujuan dari penelitian ini adalah *k-nearest neighbor* KNN pada pengenalan wajah dengan praproses transformasi wavelet. Data yang digunakan berupa gambar atau citra yang diperoleh dari beberapa objek. Pada percobaan ini terdapat 80 citra dari 10 objek. Sebanyak 64 citra digunakan sebagai database pelatihan dan 16 digunakan untuk uji pengenalan pola. Metode yang digunakan adalah transformasi wavelet untuk ekstraksi fitur dan KNN untuk identifikasi. Hasil pemilihan k terbaik adalah 5 dengan jumlah citra pada setiap kelas dalam kelompok pengujian sebanyak 8 buah.

Kata Kunci : KNN, Wavelet, Citra Wajah

PENDAHULUAN

Manusia mempunyai kemampuan mengenali objek dengan cepat berdasarkan cirri-ciri yang pernah dilihat sebelumnya. Kemampuan untuk dapat mengidentifikasi wajah sangat diperlukan dalam berbagai bidang seperti kepolisian, hukum, forensik, imigrasi dan sebagai identitas wajah dalam memasuki daerah terlarang. Hal ini menyebabkan pengembangan system pengenalan wajah tetap menjadi riset yang penting.

Pengenalan wajah merupakan salah satu bidang penelitian dengan banyak aplikasi yang menerapkannya hal itu dikarenakan wajah manusia mampu merepresentasikan sesuatu yang kompleks sehingga dalam melakukan pemodelan komputasi yang ideal sangatlah sulit, karena setiap metode memiliki kelebihan dan kekurangan. Teknik pengenalan wajah dapat diklasifikasikan secara luas ke dalam dua kelompok, yaitu aplikasi dengan masukan gambar yang diam dan gambar bergerak atau dinamis. Pada gambar diam,

gambar yang diambil hanya gambar wajah tampak depan dengan berbagai macam ekspresi wajah, misalnya: senyum, tertawa, melotot, berkacamata, dan lain-lain.

Tahapan-tahapan penting yang dilakukan dalam proses pengenalan wajah antara lain pra proses pengolahan data dan pengambilan keputusan. Berbagai metode telah dikembangkan untuk tahapan ini, salah satunya adalah pengambilan keputusan menggunakan algoritma *k-Nearest Neighbor* dengan praproses transformasi *wavelet*.

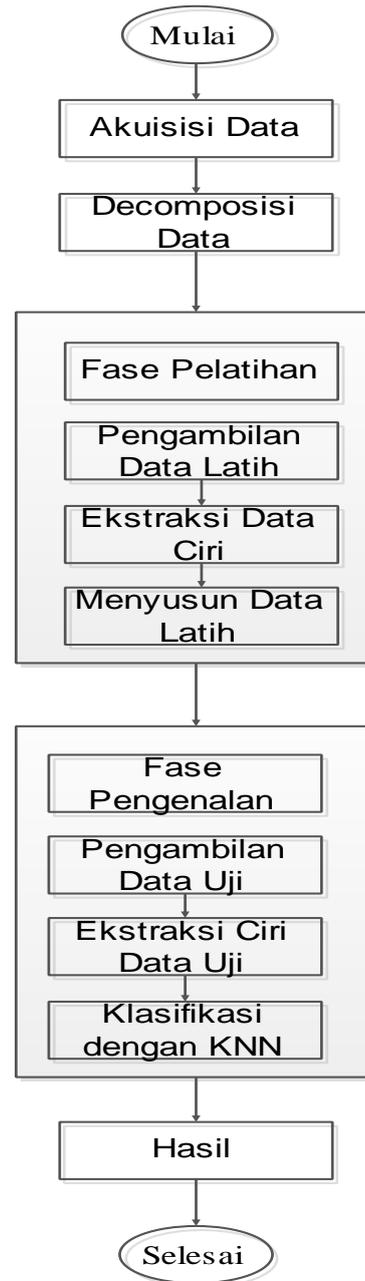
Tujuan yang hendak dicapai dalam pembuatan tulisan ini adalah mempelajari, memahami dan mengimplementasikan pengenalan wajah menggunakan KNN dengan praproses transformasi *wavelet*.

METODE PENELITIAN

Data dan Alat

Data yang digunakan berupa gambar atau citra yang diperoleh dari beberapa objek. Pada percobaan ini terdapat 80 citra dari 10 objek. Sebanyak 64 citra digunakan sebagai database pelatihan dan 16 digunakan untuk uji pengenalan pola. Sedangkan alat yang digunakan pada penelitian ini adalah *software* Matlab versi 7.7.0.471 (R2008) dan Microsoft Excel 2010.

Tahapan penelitian yang dilaksanakan disajikan pada Gambar 1



Gambar 1 Tahapan Penelitian

Langkah-langkah

Langkah-langkah pada percobaan ini adalah sebagai berikut:

1. Akuisisi Data
Merupakan pengambilan pada suatu objek melalui sensor sehingga menjadi suatu citra.
2. Dekomposisi Data
Proses ini akan menghasilkan ekstrasi ciri-ciri yang berguna pada proses pengenalan dan mereduksi ukuran citra
3. Fasa Pelatihan
Menyusun database untuk klasifikasi data latih
 - a) Pengambilan data latih
 - b) Ekstrasi Data ciri
 - c) Menyusun data latih
4. Fase Pengenalan
Proses untuk mengenali sebuah data uji untuk disimpulkan masuk ke salah satu kelas dalam data latih.
 - a) Pengambilan Data Uji
 - b) Praproses Data Uji/Ekstraksi Ciri
 - c) Pengambilan Keputusan kelsifikasi dengan KNN

HASIL DAN PEMBAHASAN

Penelitian yang dilakukan menggunakan data berupa citra. Citra adalah gambar dua dimensi yang dihasilkan dari gambar analog dua dimensi yang kontinu menjadi gambar diskrit melalui proses *sampling*. Citra digital dapat didefinisikan sebagai fungsi dua variabel, $f(x,y)$, dimana x dan y adalah koordinat spasial sedangkan nilai $f(x,y)$ adalah intensitas citra pada koordinat tersebut, hal tersebut diilustrasikan pada gambar di

bawah ini. Teknologi dasar untuk menciptakan dan menampilkan warna pada citra digital berdasarkan pada penelitian bahwa sebuah warna merupakan kombinasi dari tiga warna dasar, yaitu merah, hijau, dan biru (*Red, Green, Blue- RGB*).

Wavelet adalah fungsi yang dihasilkan dari satu fungsi tunggal (fungsi dasar) yang disebut prototipe atau mother wavelet oleh dilations (scalings) dan translasi (shift) dalam waktu (frekuensi) domain. Jika mother wavelet dinotasikan dengan $\varphi(t)$, wavelet lainnya $\varphi_{a, b}(t)$ dapat direpresentasikan sebagai (Acharya et al, 2005)

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \tag{1}$$

Dimana a dan b adalah dua bilangan real. Variabel a dan b merepresentasikan parameter dilatasi dan translasi dalam sumbu waktu. Dari Persamaan. 1, jelas bahwa mother wavelet dapat direpresentasikan sebagai

$$\psi(t) = \psi_{1,0}(t). \tag{2}$$

Untuk setiap $a \neq 1$ dan $b = 0$, dapat diperoleh persamaan sebagai berikut

$$\psi_{a,0}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t}{a}\right). \tag{3}$$

Seperti ditunjukkan pada Persamaan. 3 $\varphi_{a,0}(t)$ merupakan skala waktu (oleh a) dan skala amplitudo (oleh $\sqrt{|a|}$) dan versi fungsi mother wavelet $\varphi(t)$ pada persamaan 2. Parameter a menyebabkan kontradiksi menyebabkan dari $\varphi(t)$ pada persamaan 2 pada sumbu waktu ketika $a < 1$ dan ekspansi atau peregangan jika $a > 1$. Itu sebabnya parameter yang disebut dilatasi (scaling) parameter.

Transformasi wavelet (WT) dari fungsi sinyal $f(t)$ secara matematika dirumuskan sebagai berikut :

$$W(a, b) = \int_{-\infty}^{+\infty} \psi_{a,b}(t) f(t) dt.$$

Inverse transform untuk merekonstruksi $f(t)$ $W(a,b)$ secara matematis direpresentasikan oleh

$$f(t) = \frac{1}{C} \int_{a=-\infty}^{+\infty} \int_{b=-\infty}^{+\infty} \frac{1}{|a|^2} W(a,b) \psi_{a,b}(t) da db$$

Dimana

$$C = \int_{-\infty}^{+\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega$$

$\Psi(\omega)$ adalah transformasi fourier dari mother wavelet $\Psi(t)$.

Jika a dan b merupakan dua variable kontinu (bukan diskrit) dan $f(t)$ merupakan fungsi kontinu, $W(a,b)$ disebut continuous wavelet transform (CWT). CWT memetakan fungsi satu dimensi $f(t)$ pada fungsi $W(a,b)$ dari dua variable kontinu bilangan nyata a (dilatasi) dan b (translasi).

Transformasi wavelet menggunakan dua komponen penting dalam

melakukan transformasi yakni fungsi skala (*scaling function*) dan fungsi wavelet (*wavelet function*). Fungsi skala (*scaling function*) disebut juga sebagai *Lowpass Filter*, sedangkan fungsi wavelet (*wavelet function*) disebut juga sebagai *Highpass Filter*. Kedua fungsi ini digunakan pada saat transformasi wavelet dan inverse transformasi wavelet.

1. Fungsi wavelet (*highpass filter*)

Fungsi ini mengambil citra dengan gradiasi intensitas yang tinggi dan perbedaan intensitas yang rendah akan dikurangi atau dibuang.

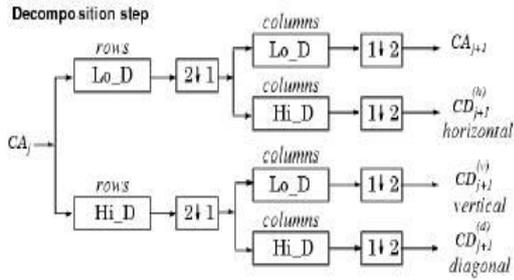
2. Fungsi skala (*lowpass filter*)

Fungsi ini mengambil citra dengan gradiasi intensitas yang halus dan perbedaan intensitas yang tinggi akan dikurangi atau dibuang. Kedua komponen diatas dapat disebut sebagai *mother wavelet* yang harus memenuhi kondisi :

$$\int_{-\infty}^{\infty} \psi(x) dx = 0$$

Transformasi Wavelet Diskrit

Transformasi wavelet diskrit merupakan dekomposisi citra pada frekuensi *subband* citra dimana komponennya dihasilkan dengan cara penurunan level dekomposisi. Implementasi transformasi wavelet diskrit dapat dilakukan dengan cara melewatkan sinyal frekuensi tinggi atau *highpass filter* dan frekuensi rendah atau *lowpass filter*.

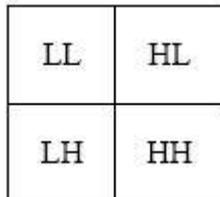


Gambar 2 Gambar langkah dekomposisi

2×1 merupakan downsample kolom
 1×2 merupakan downsample baris

Suatu citra di proses transformasi wavelet diskrit dua dimensi dengan level dekomposisi satu, akan menghasilkan empat buah *subband*, yaitu :

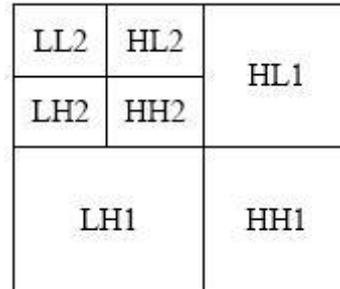
1. Koefisien Aproksimasi (CA_{j+1}) atau disebut juga *subband* LL
2. Koefisien Detil Horisontal ($CD^{(h)}_{j+1}$) atau disebut juga *subband* HL
3. Koefisien Detil Vertikal ($CD^{(v)}_{j+1}$) atau disebut juga *subband* LH
4. Koefisien Detil Diagonal ($CD^{(d)}_{j+1}$) atau disebut juga *subband* HH



Gambar 3 Gambar level dekomposisi 1

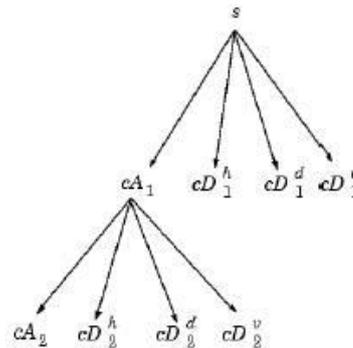
Level Dekomposisi 1 *Subband* hasil dari dekomposisi dapat didekomposisi lagi karena level dekomposisi wavelet bernilai dari 1 sampai n (transformasi wavelet multilevel). Jika dilakukan dekomposisi lagi, maka *subband* LL yang akan didekomposisi karena *subband* LL berisi

sebagian besar dari informasi citra. Jika dilakukan dekomposisi dengan level dekomposisi dua maka *subband* LL akan menghasilkan empat buah *subband* baru, yaitu *subband* LL2 (Koefisien Aproksimasi 2), HL2 (Koefisien Detil Horisontal 2), LH2 (Koefisien Detil Vertikal 2), dan HH2 (Koefisien Detil Diagonal 2). Dan begitu juga seterusnya jika dilakukan dekomposisi lagi.



Gambar 4 Gambar level dekomposisi 2

Dengan Level Dekomposisi 2 Dapat juga dilihat seperti gambar *wavelet tree* dibawah ini



Gambar 5 Gambar level dekomposisi 2 dalam tree

KNN

Penelitian ini menggunakan klasifikasi KNN. *K-nearest neighbor classification* (KNN) merupakan suatu

algoritma pembelajaran berbasis contoh yang telah terbukti sangat efektif untuk berbagai domain masalah (Cover & Hart, 1968). Tujuan dari *k-nearest neighbor classification* adalah untuk menemukan *k-nearest neighbor classification* untuk contoh yang diberikan, kemudian memberikan label kelas untuk contoh yang diberikan sesuai dengan kelas mayoritas *k-nearest neighbor classification*. Algoritma ini mengilustrasikan bahwa seluruh contoh sesuai dengan titik-titik pada ruang n-dimensi. Unsur kunci dari skema ini ialah ketersediaan ukuran kesamaan yang bisa mengidentifikasi data terdekat (tetangga). Tetangga terdekat dari sebuah contoh didefinisikan dalam hal fungsi jarak seperti jarak Euclidean standar. Lebih tepatnya, misalkan x digambarkan dengan fitur vektor $\langle a_1(x), a_2(x), \dots, a_r(x) \rangle$, dimana $a_i(x)$ merupakan nilai ke i atribut x .

Kemudian jarak antara dua x_i dan x_j didefinisikan sebagai $dist(x_i, x_j)$, dimana:

$$dist(x_i, x_j) = \sqrt{\sum_{q=1}^r (a_q(x_i) - a_q(x_j))^2}$$

Data untuk Percobaan

Data citra wajah yang digunakan dalam percobaan ini berasal dari citra 8 obyek/orang, dengan 10 citra wajah yang tersedia untuk setiap subyek jadi jumlah seluruh objek pada percobaan ini adalah 80 orang. Citra wajah dalam database ini selengkapnya ditunjukkan pada Gambar 3. Gambar-gambar wajah pada penelitian ini bervariasi dalam ekspresi wajah dan iluminasi dengan masing-masing obyek atau citra memiliki ukuran 92 x 112 pixel.



Gambar 3 Citra wajah yang digunakan

Fase Pelatihan

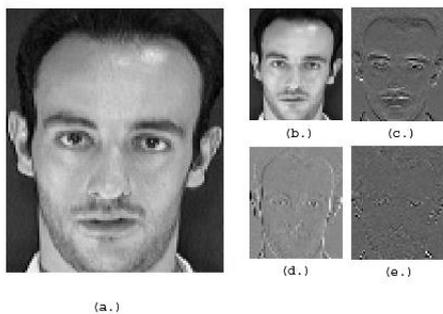
Sistem pengealan pola dimulai dengan fase pelatihan, yaitu menyusun data latih untuk proses pengenalan wajah. Dalam percobaan ini, dari masing objek/kelompok wajah, diambil sebanyak 8 sampel untuk proses pelatihan. Setiap gambar dibaca dengan program Matlab, menghasilkan matrik data sebanyak 64 buah dengan dimensi 112 X 92. Data tersebut diklasifikasikan dengan kelas sesuai asal objeknya. Data tersebut disimpan sebagai DataLatihLevel0.

Masing-masing citra kemudian didekomposisi dengan transformasi wavelet 2 dimensi tipe Haar. Pada kode program, proses ini dilakukan dengan perintah :

```
I=imread(filename);
[cA1,cH1,cV1,cD1] =
dwt2(I, 'Haar');
```

Proses ini akan menghasilkan Data Aproksimasi cA1, data koefisien horizontal cH1, koefisien vertical cV1 dan koefisien diagonal cD1. Data aproksimasi merupakan data yang menyimpan cirri/fitur paling banyak. Proses ini akan menghasilkan data latih level 1, berisi 64 buah matrik data dari citra sebelumnya dengan dimensi 56 x 46 pixel.

Visualisasi hasil dekomposisi level 1 adalah sebagai berikut :



Gambar 3. Hasil dekomposisi level 1.

- a. Gambar awal sebelum dekomposisi
- b. Gambar aproksimasi
- c. Gambar dari koefisien horizontal
- d. Gambar dari koefisien vertical
- e. Gambar dari koefisien diagonal

Pada percobaan ini akan digunakan data dekomposisi sampai level 4. Pada dekomposisi level 2, data yang didekomposisi adalah data aproksimasi dari dekomposisi level 1, pada dekomposisi level 3 dan 4, data yang digunakan adalah data aproksimasi dari level 2 dan level 4. Pada program Matlab, proses tersebut dilakukan dengan perintah :

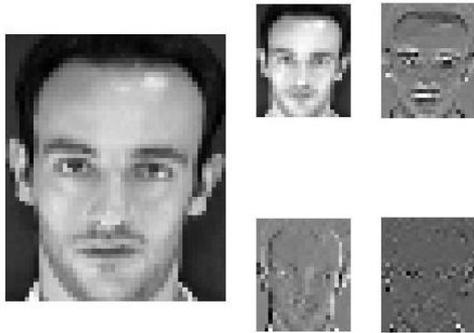
```
[cA2,cH2,cV2,cD2] =
dwt2(cA1, 'Haar');
[cA3,cH3,cV3,cD3] =
dwt2(cA2, 'Haar');
[cA4,cH4,cV4,cD4] =
dwt2(cA3, 'Haar');
```

Data hasil dekomposisi ini kemudian disimpan menjadi DataLatihLevel1, DataLatihLevel2, DataLatihLevel3, DataLatihLevel4.

Proses dekomposisi akan mengekstrasi fitur-fitur yang dominan dan sekaligus mereduksi ukuran citra, hal ini akan mempercepat proses komputasi dalam proses pengenalan.

Pada dekomposisi level 2, diperoleh matrik data dengan dimensi : 28 x 23
 Pada dekomposisi level 3, diperoleh matrik data dengan dimensi : 14 x 12
 Pada dekomposisi level 4, diperoleh matrik data dengan dimensi : 7 x 6

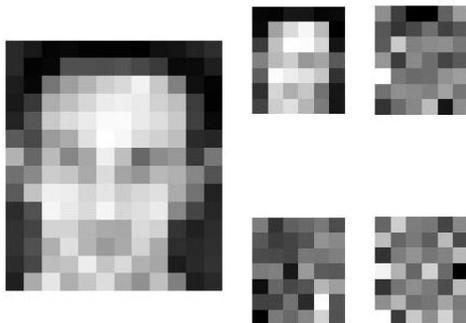
Visualisasi hasil dekomposisi level 3 s/d 4 adalah sebagai berikut :



Gambar. 4 Hasil dekomposisi level 2



Gambar 5. Hasil dekomposisi level 3



Gambar.6. Hasil dekomposisi level 4

Fase Pengenalan

Proses pengenalan adalah proses untuk menguji sebuah citra wajah, untuk dikenali berdasarkan data latih, dan disimpulkan masuk ke salah satu kelas dari

data latih. Dalam percobaan ini ini, keputusan hasil pengenalan wajah diambil dengan algoritma *k-Nearest Neighbor*.

Terhadap sebuah citra uji, dilakukan praproses dekomposisi menggunakan transformasi wavelet. Terhadap hasil praproses ini dilakukan proses identifikasi kedekatan antara data tersebut dengan seluruh data pada data latih, dilakukan pada level dekomposisi yang sama. Kedekatan data uji dengan data latih diukur berdasarkan Jarak Euclid antara matrik data uji dengan matrik data latih. Berdasarkan data jarak tersebut, diambil *k* buah objek terdekat. Keputusan diambil berdasarkan kelas terbanyak yang muncul pada *k* objek tersebut.

Dalah satu contoh proses pengenalan citra uji ke 4 pada dekomposisi level 1 dengan $k = 5$ adalah sebagai berikut :

Tabel 1. Proses pengenalan citra uji pada dekomposisi

Citra yang diuji	Dekomposisi Level 1			Kesimpulan
	5 buah citra terdekat			
Nomor	Nomor	Jarak	Kls	
4	8	4.246,55	1	2
	13	4.347,85	2	
	4	4.364,59	1	
	10	4.713,51	2	
	16	4.773,46	2	

Data uji ke-4, mempunyai tetangga terdekat berturut-turut dengan data latih ke 8, 13, 4, 10 dan 16, yang berasal dari kelas 1, 2, 1, 2 dan 2. Berdasarkan hasil ini, maka disimpulkan Data uji ke 4 dikenali sebagai gambar kelas 2.

Hasil Percobaan

Pada percobaan ini, proses pengenalan wajah dilakukan terhadap 16 buah citra dari kelas-kelas yang sudah

diketahui sebelumnya, oleh karena itu dapat diketahui kebenaran hasil pengenalan wajahbya benar atau tidak. Hasil pengenalan. Proses pengenalan wajah dikatakan dapat mengenali dengan benar apabila kesimpulan yang diambil menunjuk tepat ke satu kelas saja yang sesuai dengan kelas awal data uji, dan hasil proses pengenalan dikatakan tidak benar apabila kesimpulan yang diambil menunjuk ke kelas yang tidak sesuai dengan kelas awal data uji, atau menunjuk ke lebih dari satu kelas.

Tabel 6 Keberhasilan Pengenalan wajah terhadap 16 citra

K	Level Dekomposisi				
	0	1	2	3	4
3	15	15	15	15	16
4	15	15	15	15	16
5	15	16	15	16	16
6	14	15	15	14	13
7	16	15	15	14	13

Tabel 7 Prosentase Keberhasilan Pengenalan wajah terhadap 16 citra

k	Level Dekomposisi				
	0	1	2	3	4
3	93,75%	93,75%	93,75%	93,75%	100,00%
4	93,75%	93,75%	93,75%	93,75%	100,00%
5	93,75%	100,00%	93,75%	100,00%	100,00%
6	87,50%	93,75%	93,75%	87,50%	81,25%
7	100,00%	93,75%	93,75%	87,50%	81,25%

Berdasarkan hasil percobaan, dapat dilihat bahwa, dalam proses pengenalan wajah dengan algoritma k-Nearest Neighbor, dengan jumlah citra pada setiap kelas latih sebanyak 8 buah, pemilihan k terbaik adalah 5.

Proses dekomposisi akan mereduksi ukuran citra, semakin tinggi level

Percobaan pengenalan wajah dengan k-Nearest Neighbor ini dilakukan pada data awal (dekomposisi level 0) dan dekomposisi level 1 s/d 4 dan k = 3 s/d 7. Tabel hasil percobaan ini selengkapnya dapat dilihat pada lampiran.

Ringkasan kebenaran penarikan kesimpulan dari percobaan pengenalan wajah dari 16 citra uji pada k = 3 / 7 dan level dekomposisi 1 s/d 4 adalah sebagai berikut :

dekomposisinya, ukuran citra juga menjadi lebih kecil, sehingga ciri-ciri atau fitur yang dapat disimpan juga lebih sedikit. Apabila digunakan dalam algoritma k-nearest neighbor, maka jumlah k berpengaruh terhadap hasil kesimpulan yang diambil. Apabila ukuran citra kecil, jumlah ciri yang disimpan juga sedikit, bila nilai k yang diambil terlalu besar, maka peluang data yang diambil masuk di kelas lain menjadi lebih besar.

Pada citra dengan dimensi 92 x 112, proses hasil terbaik keberhasilan pengenalan wajah diperoleh dari dekomposisi level 1 (satu kali) dan level 2 (dua kali). Untuk nilai k = 6 dan 7, pada dekomposisi level 4, jumlah data yang tidak dapat dikenali dengan benar menjadi lebih banyak.

SIMPULAN

Berdasarkan hasil percobaan, dapat disimpulkan bahwa, dalam proses pengenalan wajah dengan algoritma k-Nearest Neighbor, dengan jumlah citra pada setiap kelas dalam kelompok pengujian sebanyak 8 buah, pemilihan k terbaik adalah 5.

Pemilihan nilai k dalam algoritma *k-Nearest Neighbor* perlu mempertimbangkan ukuran/dimensi data. Apabila dimensi data terlalu kecil, maka ciri/ciri yang dimuat juga kecil. Variasi jarak dalam table jarak antara data uji dengan data latih menjadi lebih kecil sehingga peluang suatu data uji dikenali masuk ke kelas lain menjadi lebih besar.

DAFTAR PUSTAKA

Acharya, tinku, Ray, A.K. 2005. *Image Processing Principles and Applications*

Aniati Murni Arymurthy & Suryana Setiawan (1992), "Pengantar Pengolahan Citra", PT. Elexmedia Komputindo.

Cover, T., & Hart, P. (1968). *Nearest neighbor pattern classification*. In *IEEE Transaction of Information Theory*, Vol. 13, pp. 21-27, January, 1968.

J. B. MacQueen (1967): "Some Methods for classification and Analysis of Multivariate Observations, *Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability*", Berkeley, University of California Press, 1:281-297

Stollnitz, E. J., DeRose, T. D., and Salesin, D. H. (1995a). Wavelets for computer graphics: A primer, part 1. *IEEE Computer Graphics and Applications*, **15**(3), 76-83.