

**LAPORAN PENELITIAN KOMPETITIF
TAHUN ANGGARAN 2017**

JUDUL PENELITIAN

**OPTIMALISASI DIMENSI *IMAGE* UNTUK MENINGKATKAN
AKURASI *NAÏVE BAYES CLASSIFIER* DENGAN MENGGUNAKAN
INTERPOLASI**

Nomor DIPA	:	DIPA BLU: DIPA-025.04.2.423812/2016
Tanggal	:	7 Desember 2017
Satker	:	(423812) UIN Maulana Malik Ibrahim Malang
Kode Kegiatan	:	(2132) Peningkatan Akses, Mutu, Kesejahteraan dan Subsidi Pendidikan Tinggi Islam
Kode Sub Kegiatan	:	(008) Penelitian Bermutu
Kegiatan	:	(004) Dukungan Operasional Penyelenggaraan Pendidikan

OLEH

Irwan Budi Santoso, S.Si., M.Kom (197701032011011004)

Supriyono, S.Kom., M.Kom (19841010 20160801 1 078)



**KEMENTERIAN AGAMA
LEMBAGA PENELITIAN DAN PENGABDIAN KEPADA MASYARAKAT
UNIVERSITAS ISLAM NEGERI MAULANA MALIK IBRAHIM MALANG
2017**

HALAMAN PENGESAHAN

Laporan Penelitian ini disahkan oleh Lembaga Penelitian dan Pengabdian kepada Masyarakat
Universitas Islam Negeri Maulana Malik Ibrahim Malang
Pada tanggal 17 Juli 2017

Peneliti

Ketua : Nama : Irwan Budi Santoso, S.Si.,M.Kom.....
NIP : 1977 0103 2011 011004.....
Tanda Tangan

Anggota I : Nama : Supriyono, S.Kom., M.Kom
NIDT : 19841010 20160801 1 078.....
Tanda Tangan

Anggota II : Nama.....
NIP.....
Tanda Tangan

Ketua LP2M
UIN Maulana Malik Ibrahim Malang

Dr. Hj. Mufidah Ch., M.Ag.
NIP. 196009101989032001

PERNYATAAN ORISINALITAS PENELITIAN

Kami yang bertanda tangan di bawah ini:

Nama : Irwan Budi Santoso,S.Si., M.Kom
NIP : 19770103 2011 011004
Pangkat/Gol.Ruang : Lektor/III-d
Fakultas/Jurusan : Sains dan Teknologi (Saintek)/ Teknik Informatika
Jabatan dalam Penelitian : Ketua Peneliti

Menyatakan dengan sebenar-benarnya bahwa dalam penelitian ini tidak terdapat unsur-unsur penjiplakan karya penelitian atau karya ilmiah yang pernah dilakukan atau dibuat oleh orang lain, kecuali yang secara tertulis disebutkan dalam naskah ini dan disebutkan dalam sumber kutipan dan daftar pustaka. Apabila dikemudian hari ternyata dalam penelitian ini terbukti terdapat unsur-unsur penjiplakan dan pelanggaran etika akademik, maka kami bersedia mengembalikan dana penelitian yang telah kami terima dan diproses sesuai dengan peraturan perundang-undangan yang berlaku.

Malang, 17 Juli 2017

Ketua Peneliti

Irwan Budi Santoso,S.Si., M.Kom
NIP. 19770103 2011 011004

PERNYATAN TIDAK SEDANG TUGAS BELAJAR

Yang bertanda tangan di bawah ini, Saya:

Nama : Irwan Budi Santoso, S.Si., M.Kom
NIP : 197701032011011004
Pangkat/Gol. : Lektor/III-d
Tempat; Tgl. Lahir : Jombang;3 Januari 1977
Judul Penelitian : Optimalisasi Dimensi Image untuk
Meningkatkan Akurasi Naïve Bayes Classifier
dengan Menggunakan Interpolasi

dengan ini menyatakan bahwa:

1. Saya TIDAK SEDANG TUGAS BELAJAR
2. Apabila dikemudian hari terbukti bahwa saya sedang tugas belajar, maka secara langsung saya menyatakan mengundurkan diri dan mengembalikan dana yang telah saya terima dari Program Penelitian Kompetitif tahun 2017.

Demikian surat pernyataan ini, Saya buat sebagaimana mestinya.

Malang, 17 Juli 2017
Yang membuat pernyataan,

Irwan Budi Santoso, S.Si.,M.Kom
NIP. 197701032011011004

OPTIMALISASI DIMENSI *IMAGE* UNTUK MENINGKATKAN AKURASI *NAÏVE BAYES CLASSIFIER* DENGAN MENGGUNAKAN INTERPOLASI

Irwan Budi Santoso, Supriyono

Jurusan Teknik Informatika, Fakultas Sains dan Teknologi
Universitas Islam Negeri (UIN) Maulana Malik Ibrahim Malang
e-mail: irwan@ti.uin-malang.ac.id, priyono@ti.uin-malang.ac.id

ABSTRAK

Salah satu faktor yang dapat meningkatkan akurasi *naïve bayes classifier* (NBC) dalam mengklasifikasikan objek *image* adalah ketepatan dalam ekstraksi fitur *image* dan ketepatan dalam membangun struktur model NBC. Pada penelitian ini, dikaji secara lebih mendalam bagaimana optimalisasi metode interpolasi khususnya metode *non-adaptive* (*nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*) sebagai dasar dalam ekstraksi fitur *image*. Ekstraksi fitur berdasarkan metode interpolasi dilakukan dengan melakukan optimalisasi dimensi *image* (*image downscaling*) untuk mendapatkan fitur *image* yang optimal bagi NBC. Untuk mengetahui sejauhmana kemampuan metode yang diusulkan, dilakukan eksperimen dengan menggunakan data *image benchmark* yaitu *image texture* yang diambil dari *CVonline database*. Hasil eksperimen menunjukkan bahwa ekstraksi fitur berdasarkan optimalisasi dimensi *image* dengan interpolasi *nearest neighbor* menghasilkan tingkat akurasi paling baik daripada interpolasi *bilinear*, *bicubic* dan *lanczos*. Untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama, sedangkan hasil terburuk diberikan oleh interpolasi *bilinear*.

Kata kunci: metode interpolasi, ekstraksi fitur, *naïve bayes classifier*, dimensi *image*

ABSTRAC

One of the factors that can improve the accuracy of naïve bayes classifier (NBC) in classifying image objects is the precision in image feature extraction and precision in constructing NBC model structures. In this research, we studied in more depth how the optimization of interpolation method, especially the non-adaptive (nearest neighbor, bilinear, bicubic and lanczos) method as the basis of image feature extraction. Feature extraction based on interpolation method is done by optimizing image dimension (image downscaling) to get optimal image feature for NBC. To know the extent of the performance of the proposed method, conducted experiments using image of benchmark ie image texture from CVonline database. The experimental results show that feature extraction based on the optimization of image dimension with nearest neighbor interpolation the best accuracy level than bilinear, bicubic and lanczos interpolation. For interpolation bicubic and lanczos give relatively the same result, whereas the worst result is given by bilinear interpolation.

Keywords: interpolation method, feature extraction, naïve bayes classifier, image dimension

BAB I

PENDAHULUAN

1.1 Latar Belakang

Sebuah objek dalam bentuk *image* (citra digital) dinyatakan dalam bentuk fungsi $f(x,y)$ dengan x dan y adalah koordinat *image* dan f adalah amplitudo pada koordinat (x,y) . Amplitudo tersebut adalah nilai intensitas yang memiliki nilai diskrit mulai dari 0 hingga 255 sebagai hasil akuisisi kamera ataupun *scanner* yang telah dikuantisasi dalam nilai tersebut (Gonzalez, 2009). Untuk keperluan klasifikasi atau pengenalan terhadap objek dalam bentuk *image*, dibutuhkan sejumlah sampel *image* objek untuk setiap kelasnya dalam proses *training* (pembelajaran). Keberhasilan metode klasifikasi dalam proses klasifikasi atau pengenalan *image* objek ditunjukkan dengan tingkat akurasi yang tinggi. Akurasi yang tinggi dari metode klasifikasi tersebut sangat tergantung dari beberapa faktor diantaranya akurasi sampel *image* objek yang diambil, preproses *image* objek, ekstraksi fitur *image* objek dan kehandalan metode klasifikasi yang digunakan. Untuk melakukan klasifikasi objek dalam bentuk *image*, preproses yang biasa dilakukan diantaranya *image scaling*, perbaikan *image* dari *noise* dengan menggunakan metode filter, sedangkan untuk ekstraksi fitur biasanya digunakan *fourier transform*, *wavelet*, *principal component analysis* (Nixon dan Aguado, 2008).

Berkenaan dengan *image scaling*, seringkali *image scaling* dilakukan untuk keperluan menjadikan dimensi atau ukuran *image* objek *training* ataupun *testing* menjadi sama sebelum dilakukan ekstraksi fiturnya. Belum banyak penelitian yang fokus pada bagaimana melakukan optimalisasi *image scaling*, dan kebanyakan penelitian terkait hal tersebut hanya fokus pada bagaimana melakukan *image scaling* yang baik ataupun efisien dengan menggunakan beberapa metode interpolasi diantaranya dilakukan oleh Prajapati, Parker, Kenyon dan Troxel [1983], Acharyaa dan Tsai [2007], Parkkinen, Haukijärvi dan Nenonen [2009], Naik and Mehta [2012], Olivier dan Hanqiang, [2012], Bhatt dan Pandit [2013], Jeon [2013], Parsania dan Virparia [2014] dan Safinaz [2014]. Dalam proses klasifikasi *image*, besarnya dimensi atau ukuran *image* menjadi persoalan tersendiri dalam keberhasilan klasifikasi ataupun proses komputasi. Fakta menunjukkan jarang sekali penelitian menggunakan metode interpolasi untuk tujuan mereduksi dimensi atau ukuran *image* serta menggunakan nilai hasil interpolasi sebagai nilai ekstraksi fitur *image* objek.

Adapun terkait metode klasifikasi, seringkali kita mendapatkan beberapa penelitian yang memfokuskan pada perbaikan metode, diantaranya dengan melakukan perubahan struktur model pengenalan ataupun perbaikan dalam estimasi bobot atau parameter. Dan diantara

metode klasifikasi berbasis probabilitas yang relatif simpel dan banyak digunakan adalah *naïve bayes classifier* (NBC). Banyak penelitian berkenaan dengan metode *naïve bayes* dengan fokus pada seperti yang telah disebutkan yaitu perbaikan metode dengan melakukan perubahan struktur model pengenalan, ataupun perbaikan dalam estimasi bobot atau parameter, diantaranya dilakukan oleh Langley dan Sage [1994], Kwoh dan Gilles [1996], Domingos dan Pazzani [1997], Noren dan Orre [2005], Ekdahl dan Koski [2006], Hall [2007], dan Wong [2009]. Secara prinsip *naïve bayes classifier* adalah metode klasifikasi berbasis probabilitas dengan mengasumsikan diantara atribut atau fitur objek bersifat independen (Maron and Kuhn, 1960; Minsky, 1961; Pablo, 2014). Adanya asumsi independen inilah yang membuat metode ini simpel untuk diimplementasikan serta masih menjadi topik yang hangat, khususnya terkait dengan bagaimana meningkatkan peformansi dalam klasifikasi.

Dengan melihat perkembangan dan celah baik metode interpolasi dan *naïve bayes classifier*, peneliti ingin melakukan penelitian bagaimana melakukan optimalisasi metode interpolasi untuk meningkatkan akurasi dalam mengklasifikasikan objek dalam bentuk *image*.

1.2 Rumusan Masalah

Berdasarkan uraian yang telah dijelaskan pada bab latar belakang, maka dapat dirumuskan beberapa permasalahan dalam penelitian ini sebagai berikut:

1. Bagaimana membangun langkah-langkah dan aplikasi optimalisasi metode interpolasi untuk meningkatkan akurasi *naïve bayes classifier* dalam mengklasifikasikan objek dalam bentuk *image*.
2. Sejauh mana tingkat akurasi metode *naïve bayes classifier* dalam mengenali objek dalam bentuk *image* berdasarkan hasil optimalisasi metode interpolasi.

1.3 Batasan Masalah

Untuk memfokuskan penelitian yang akan dilakukan, terdapat beberapa batasan masalah atau ruang lingkup penelitian sebagai berikut:

1. Metode interpolasi yang digunakan dalam penelitian ini adalah *non-adaptive* meliputi: *nearest neighbor*, *bilinier*, *bicubic*, *lanczos*.
2. Data *image* yang digunakan adalah data *benchmark* internasional yaitu data *image textur* yang diambil dari *CVonline:Image Databases* dan data *benchmark* lokal yaitu data *image* penelitian grup dosen-mahasiswa, laboratorium Komputer Vision Teknik Informatika UIN Maulana Malik Ibrahim Malang.

1.4 Tujuan Khusus Penelitian

Adapun beberapa tujuan khusus yang ingin dicapai dalam penelitian tentang optimalisasi dimensi *image* untuk meningkatkan akurasi *naïve bayes* dengan menggunakan interpolasi adalah sebagai berikut:

1. Membangun langkah-langkah dan aplikasi optimalisasi metode interpolasi untuk meningkatkan akurasi *naïve bayes classifier* dalam mengklasifikasikan objek dalam bentuk *image*. Dengan dibangunnya langkah-langkah dan aplikasi optimalisasi metode interpolasi dan *naïve bayes classifier* tersebut, akan memudahkan pengguna dalam menemukan dimensi objek *image* yang optimal untuk metode *naïve bayes classifier* dalam aplikasi riil, untuk mengenali atau mengklasifikasikan *image*.
2. Mengembangkan metode interpolasi untuk mereduksi dimensi *image*, mendapatkan dimensi *image* yang optimal serta mendapatkan hasil ekstraksi fitur *image* yang optimal berdasarkan nilai interpolasi, sehingga memberikan tingkat akurasi yang tinggi terhadap *naïve bayes classifier*. Penggunaan metode interpolasi sebagai salah satu solusi untuk mengatasi dimensi *image* yang besar dengan mereduksi (*downscaling*) *image* berdasarkan nilai *pixel*-nya serta menjadikan nilai interpolasi sebagai nilai hasil ekstraksi fitur sedemikian hingga memberikan tingkat akurasi tinggi bagi *naïve bayes classifier*.

1.5 Urgensi Penelitian

Urgensi dari penelitian tentang optimalisasi dimensi *image* untuk meningkatkan akurasi *naïve bayes* dengan menggunakan interpolasi adalah sebagai berikut:

1. Bagi Masyarakat Akademik
 - Mempermudah masyarakat akademik khususnya pada bidang yang terkait, dalam mempraktekkan metode interpolasi dan *naïve bayes classifier* untuk aplikasi riil khususnya dalam membuat aplikasi deteksi atau pengenalan atau klasifikasi objek dalam bentuk *image*.
 - Memberi kesempatan bagi masyarakat akademik bidang terkait, untuk ikut mengembangkan metode interpolasi dalam memecahkan persoalan klasifikasi.
2. Bagi Universitas dan Pengembangan Disiplin Ilmu
 - Penelitian ini merupakan salah satu bentuk upaya untuk mengintegrasikan ilmu sains dan teknologi dengan islam. Karena dengan mengembangkan metode dalam sains dan teknologi khususnya metode interpolasi dan *naïve bayes* berbasis *image*

akan mempermudah umat manusia untuk mengamalkan ilmu tersebut, sebagaimana yang diperintahkan oleh Allah SWT.

3. Bagi Peneliti

- Sebagai sarana untuk meningkatkan dan mengembangkan fokus keilmuan sesuai dengan *roadmap* penelitian di jurusan atau laboratorium, dimana hasil penelitian dapat digunakan sebagai bahan penelitian lanjutan dalam rangka mengembangkan *pattern recognition*. Salah satu penelitian yang terkait *pattern recognition* adalah metode dalam pengenalan atau klasifikasi objek, dan salah satu metode yang banyak digunakan dalam melakukan pengenalan terhadap objek dalam bentuk *image* adalah *naïve bayes classifier* (NBC). Peneliti ingin mengembangkan metode tersebut dengan tujuan ingin meningkatkan akurasi dengan cara melakukan optimalisasi terhadap dimensi *image training* atau *testing* dengan metode interpolasi.
- Hasil dari penelitian ini, diupayakan sedemikian hingga bisa mendapatkan pengakuan dari masyarakat, sehingga manfaatnya bisa dirasakan langsung bagi peneliti, universitas, dan masyarakat akademik pada umumnya.

1.6 Target Luaran dan Kontribusi Penelitian

Berkaitan tujuan dan urgensi penelitian maka yang menjadi target luaran penelitian dan kontribusi dalam ilmu pengetahuan adalah sebagai berikut:

1. Hasil dari penelitian ini, dapat dijadikan bahan bagi peneliti untuk dipublikasikan di jurnal nasional maupun internasional.
2. Hasil penelitian ini dapat dijadikan sebagai rujukan atau referensi bagi para peneliti lain yang ingin mengembangkan penelitian yang terkait dengan kasus yang sama yaitu dalam kaitannya peningkatan performan metode klasifikasi berbasis *image*.

BAB II

STUDI PUSTAKA DAN ROADMAP

2.1 Penelitian yang telah dilakukan

Belum banyak penelitian yang fokus pada bagaimana melakukan optimalisasi *image scaling* untuk meningkatkan performansi metode klasifikasi, kebanyakan penelitian terkait *image scaling* hanya fokus bagaimana melakukan *image scaling* yang baik ataupun efisien dengan menggunakan beberapa metode interpolasi diantaranya dilakukan oleh Prajapati, Parker, Kenyon dan Troxel [1983], Acharyaa dan Tsai [2007], Parkkinen, Haukijärvi dan Nenonen [2009], Prajapati, Naik and Mehta [2012], Olivier dan Hanqiang, [2012], Bhatt dan Pandit [2013], Jeon [2013], Parsania dan Virparia [2014] dan Safinaz [2014].

Prajapati, Parker, Kenyon dan Troxel [1983] dalam penelitian terkait resampling *image*, untuk menjaga kualitas *image* menggunakan fungsi interpolasi dalam resampling. Untuk mendapatkan hasil terbaik dilakukan ekeperimen dengan menggunakan 5 metode interpolasi dan membandingkan hasilnya. Lima metode yang digunakan adalah *nearest neighbor*, *linear*, *cubic B-spline*, *high-resolution cubic spline* dengan $\alpha=-1$ dan *high-resolution cubic spline* dengan $\alpha=-0.5$. Hasil eksperimen menunjukkan *B-spline*, *high-resolution cubic spline* dengan $\alpha=-1$ dan *high-resolution cubic spline* dengan $\alpha=-0.5$ lebih baik daripada *nearest neighbor*, linier. Sedangkan yang memberikan hasil terbaik adalah *high-resolution cubic spline* dengan $\alpha=-0.5$ akan tetapi waktu komputasinya lebih besar dari yang lain.

Acharyaa dan Tsai [2007] dalam penelitiannya melakukan review progres terhadap dua metode interpolasi yaitu *adaptive* dan *non-adaptive* (*bilinier*, *bicubic*, *triangle*, *bell*, *hermite*, *michell*, *lanczos*) serta mengusulkan metode baru yaitu *descret wavelet transform* (DWT). Secara umum metode baru yang diusulkan memberikan hasil kualitas *image* yang sepadan (*impact*) dengan komputasi yang dibutuhkan.

Parkkinen, Haukijärvi dan Nenonen [2009] melakukan penelitian terkait *image scaling* baik *downscaling* ataupun *upscaling* berbasis *mobile display*. Metode yang digunakan untuk melakukan *image scaling* adalah metode interpolasi *nearest neighbor*, *bilinear*, *bicubic* serta metode yang diusulkan. *Downscaling* terhadap *image* dilakukan dengan rata-rata terboboti (*weighted average*) area *pixel* tertentu, demikian juga dengan proses *upscaling* yang didasarkan pada metode *bilinear* yang didesain dengan menghindari *repetitive calculations*. Berdasarkan *weighted average* area *pixel*, mengajukan beberapa metode dengan perlakuan a. minimum jumlah operasi perpixel untuk *downscaling* 2x2, b. maximum jumlah operasi perpixel untuk *downscaling* 2x2 dan c. jumlah operasi perpixel untuk *upscaling* 2x2. Hasil

eksperimen menunjukkan bahwa metode yang diusulkan secara signifikan memberikan perbaikan terhadap performan *image scaling*.

Prajapati, Naik and Mehta [2012] melakukan penelitian dengan kasus hampir sama dengan penelitian sebelum, menggunakan interpolasi untuk mentransfer *image* dengan resolusi tertentu ke resolusi lain dengan harapan tidak mengurangi kualitas *image* yang dihasilkan. Dalam penelitiannya, dilakukan implementasi terhadap semua metode interpolasi yang diteliti (*nearest neighbor, bilinear, bicubic, edge guided, DWT based, dan threshold based*) dan membandingkan hasilnya. Hasil eksperimen menunjukkan *edge guided* memberikan kualitas *image* hasil transfer terbaik akan tetapi lebih kompleks algoritmanya sehingga waktu komputasinya paling besar.

Olivier dan Hanqiang, [2012] dalam penelitiannya mengajukan metode *nearest neighbor value* (MNV) untuk *image* dengan *high resolution*. Secara konsep metode MNV tersebut, digunakan untuk mengestimasi *missing pixel value*. Hasil uji coba menunjukkan bahwa metode yang diusulkan (MNV) mempunyai performan yang tinggi untuk *image* dengan *high resolution* dibandingkan dengan metode interpolasi konvensional seperti *nearest neighbor, bilinear, bicubic*.

Hal yang sama juga dilakukan oleh Bhatt dan Pandit [2013], mengajukan *texture synthesis* yaitu metode untuk *cleaning image* dengan menggunakan *patches* atau *pixels* sedemikian hingga menjadikan *image* dengan resolusi tinggi dan lebih baik dari *image* aslinya. Dalam penelitian tersebut ditunjukkan analisis perbandingan beberapa interpolasi yang berbeda dan metode *texture synthesis*. Hasil eksperimen menunjukkan metode *adaptive* secara umum lebih baik daripada metode *non-adaptive*.

Jeon [2013] dalam penelitiannya untuk memperbesar *image* (*zooming image*) mengusulkan metode yang terdiri dari empat langkah pertama *input image* asli, kedua *downscaling* dengan *image zooming*, ketiga proses *artifact removal* dengan *low pass filtering* dan langkah yang keempat *unsharp masking*. Hasil simulasi menunjukkan metode yang diajukan tersebut berhasil mengeluarkan bloking *artifact*.

Parsania dan Virparia [2014] melakukan review terhadap beberapa teknik atau metode untuk tujuan *image scaling*. Metode interpolasi yang diamati dan dilakukan review serta pembahasan adalah metode *non-adaptive* dan metode *adaptive*. Untuk metode *non-adaptive* meliputi *nearest neighbor, bilinear, bicubic, bicubic B-spline, lanczos, sinc* sedangkan untuk metode *adaptive* meliputi *context aware image resizing, segmentation-based approach, seam carving* dan *warping-based approach*. Dalam studinya, teknik *adaptive* lebih baik daripada

teknik *non-adaptive* akan tetapi waktu komputasinya lebih besar daripada metode *non-adaptive*.

Penelitian yang sama juga dilakukan oleh Safinaz [2014] yaitu menggunakan metode interpolasi *non-adaptive* untuk *upscaling* dan *downscaling image*. Dalam eksperimennya safinaz menggunakan beberapa langkah yaitu input *image* asli dan *image* dengan *factor scaling*. Langkah kedua membentuk *image intermediate* dengan menggunakan filter didasarkan resampling *lanczos* kernel dari *image* yang diinput. Dan langkah terakhir melakukan *scaling image intermediate* dengan menggunakan interpolasi linier. *Image* hasil dari proses tersebut selanjutnya dilakukan *enhancement* dengan *high boost filter*. Hasil tersebut kemudian dibandingkan dengan metode *bilinear*, *B-spline* dan *lanczos*.

Tabel 2.1 Penelitian metode interpolasi dan *naïve bayes classifier*

Penelitian	Metode Interpolasi	Objek Penelitian/ Case study	Fokus Penelitian terhadap <i>Naïve Bayes Classifier</i>		
			Variabel /fitur	Struktur model	Estimasi Parameter /distribution probabilitas
J.A.Parker, R.V.Kenyon and D.E.Troxel.(1983), “ Comparison of Interpolating Methods for Image Resampling , IEEE Transaction on Medical Imaging, Vol.M1-2,No.1	<i>neighbor, linear, cubic B-spline, high-resolution cubic spline</i> dengan $\alpha=-1$ dan <i>high-resolution cubic spline</i> dengan $\alpha=-0.5$	Khusus <i>image</i>	-	-	-
T.Acharyaa and P. Tsai.(2007),” Computational Foundations of Image Interpolation Algorithms ACM Ubiquity Vol. 8.	<i>bilinier, bicubic, triangle, bell, hermite, michell, lanczos</i> serta mengusulkan metode baru yaitu <i>descret wavelet transform (DWT)</i> .	Khusus <i>image</i>	-	-	-
J.Parkkinen, M.Haukijärvi and P.Nenonen.(2009),” A Fast Method for Scaling Color Image , 17th European Signal Processing Conference (EUSIPCO 2009) Glasgow, Scotland.	<i>nearest neighbor, bilinear, bi-cubic</i> serta metode yang diusulkan <i>weighted average area pixel</i> tertentu berbasis <i>linear</i> dan <i>bilinear</i> .	Khusus <i>image</i>	-	-	-
A. Prajapati, S.Naik and S.Mehta. (2012), “ Evaluation of Different Image Interpolation Algorithms , International Journal of Computer Applications (0975 – 8887) Volume 58– No.12 .	<i>nearest neighbor, bilinear, bicubic, edge guided, DWT based, dan threshold based</i>	Khusus <i>image</i>	-	-	-
R. Olivier and C. Hanqiang.(2012),” Nearest Neighbor Value Interpolation , (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 3, No. 4.	<i>nearest neighbor, bilinear bicubic</i> dan metode yang diusulkan <i>nearest neighbor value (MNV)</i>	Khusus <i>image</i>	-	-	-
P. Bhatt,S. Patel and R. Pandit.(2013), “ Comparative Analysis of Interpolation and Texture Synthesis Method for Enhancing Image , International Journal of Innovative Research in Science, Engineering and Technology, Vol. 2, Issue 1.	<i>nearest neighbor, bilinear, bicubic, edge guided, DWT based, dan threshold based</i> dengan <i>texture synthesis</i> sebagai <i>cleaning image</i>	Khusus <i>image</i>	-	-	-
G. Jeon. (2013), “ Window Size Zooming for Lower Resolution Contents ,	<i>low pass filtering</i>	Khusus <i>image</i>	-	-	-

International Journal of Software Engineering and Its Applications, Vol.7, No.5 (2013), pp.325-336. Available: http://dx.doi.org/10.14257/ijseia.2013.7.5.28					
P.Parsania and P. V.Virparia.(2014),” A Review: Image Interpolation Techniques for Image Scaling International Journal of Innovative Research in Computer and Communication , (An ISO 3297: 2007 Certified Organization) Vol. 2, Issue 12, Engineering	Review: <i>non-adaptive: nearest neighbor, bilinear, bicubic, bicubic B-spline, lanczos, sinc. adaptive : context aware image resizing, segmentation-based approach, seam carving dan warping-based approach.</i>	Khusus image	-	-	-
Safinaz.S. (2014),” An Efficient Algorithm for Image Scaling with High Boost Filtering , International Journal of Scientific and Research Publications, Volume 4, Issue 5, ISSN 2250-3153	<i>bilinear, B-spline, lanczos, High Boost Filtering</i>	Khusus image	-	-	-
P. Langley and S. Sage.(1994). Induction of selective Bayesian classifiers . In Proceeding of the 10 th Conference on Uncertainty in Artificial Intelligence(UAI-1994).Morgan Kaufmann, 399-406	-	Umum	-	Remove variabel yang tidak relevan (redundan)	-
C.K.Kwoh and D.Gilles.(1996). Using hidden nodes in Bayesian network . Artificial Intelligence 88(1996), 1-38	-	Umum	-	Hidden variabel dengan kondisional probabilitas	
G.N.Noren and R.Orre.(2005). Case based imprecision estimates for Bayes classifiers with the Bayesian bootstrap . Machine Learning 58,1(2005),79-94		Umum	-	-	<i>Bayesian bootstrap</i>
M.Hall.(2007). A decision tree-based attribute weighting filter for naïve Bayes . Knowledge-Based Systems 20,2(2007),120-126.		Umum	-	Pemberian bobot	-
T.T.Wong.(2009). Alternative prior assumptions for improving the performance of naïve Bayesian classifiers . Data Mining and Knowledge Discovery 18,2(2009),183-213		Umum	-	-	<i>prior distribution : gneralized Dirichlet dan Liouville distribution</i>
Usulan Penelitian	<i>nearest neighbor, bilinier, bicubic, lanczos</i>	Khusus image	Hasil optimalisasi dengan metode interpolasi	-	<i>Asumsi distribusi: Normal Distribution</i>

Berkenaan dengan metode klasifikasi, seringkali kita mendapatkan beberapa penelitian yang memfokuskan pada perbaikan metode diantaranya dengan melakukan perubahan struktur model pengenalan ataupun perbaikan dalam estimasi bobot atau parameter. Dan diantara metode klasifikasi berbasis probabilitas yang relatif simpel dan banyak digunakan adalah *naïve bayes classifier*. Banyak penelitian berkenaan dengan metode *naïve bayes* dengan fokus perbaikan metode dengan melakukan perubahan struktur model pengenalan ataupun perbaikan dalam estimasi bobot atau parameter, diantaranya dilakukan oleh Langley dan Sage [1994], Kwoh dan Gilles [1996], Domingos dan Pazzani [1997], Noren dan Orre [2005], Ekdahl dan Koski [2006], Hall [2007], dan Wong [2009].

Langley dan Sage tahun [1994] melakukan penelitian terhadap struktur *naïve bayes classifier* dengan mengeluarkan variabel yang tidak relevan atau redundan yang kemudian disebut sebagai

selective naïve Bayes. Kenapa variabel yang tidak relevan (redundan) dikeluarkan karena masuknya variabel yang tidak relevan dalam kelas atau struktur *naïve bayes* dapat memperburuk performan metode tersebut.

Kwoh dan Gilles [1996] dalam penelitiannya menganalisis bahwa adanya asumsi independen pada *naïve bayes* dapat diindikasikan adanya *hidden* atau *latent* variabel. Variabel *hidden* pada *naïve bayes* dapat dimodelkan sebagai *child* dari kelas variabel dan *parent* dari semua variabel predictor, sehingga ini merupakan solusi sederhana dari persoalan yang ada. Kondisional probabilitas adalah salah satu cara untuk membentuk *hidden* variabel yang ditentukan menggunakan metode *gradient descent*.

Penelitian lain dilakukan oleh Domingos dan Pazzani [1997] yang membuktikan bahwa *naïve bayes* optimal untuk pembelajaran *conjunction* dan *disjunction* literal. Demikian halnya dengan Ekdahl dan Koski [2006] menyatakan batas degradasi dari probabilitas akan memberikan koreksi dalam klasifikasi ketika *naïve bayes* digunakan untuk mendekati *bayes classifier*.

Kasus berbeda dilakukan oleh Noren dan Orre [2005] meneliti terkait estimasi probabilitas dengan menggunakan *Bayesian bootstrap*. Hasil penelitian menunjukkan bahwa hasil dalam pengambilan sampel data $N' \leq N$ adalah kasus yang berbeda dari D dengan *Dirichlet distribution*. Sedangkan Wong [2009] melakukan upaya meningkatkan performan *naïve bayes* dengan mengasumsikan *prior distribution* seperti *generalized Dirichlet* dan *Lioville distribution*.

Hall [2007] dalam penelitiannya melakukan *adjusting* terhadap *naïve bayes* dalam klasifikasi dengan memberikan bobot dalam menentukan nilai probabilitas sehingga memberikan tingkat performan yang baik. Pemberian bobot dalam menentukan nilai probabilitas sama halnya dengan pemberian bobot pada struktur *tree* yang telah dibangun sehingga akan berpengaruh terhadap tingkat performan dalam klasifikasi.

Dari penelitian-penelitian yang telah dilakukan baik terkait metode interpolasi dan *naïve bayes classifier* serta dengan melihat perkembangan dan celah baik metode interpolasi dan *naïve bayes classifier*, peneliti ingin melakukan penelitian bagaimana melakukan optimalisasi terhadap beberapa metode interpolasi untuk meningkatkan akurasi *naïve bayes* dalam mengklasifikasikan objek dalam bentuk *image*.

2.2 Dasar Teori

2.2.1 Definisi Citra Digital

Sebuah citra digital dinyatakan dalam bentuk fungsi $f(x,y)$, dengan x dan y adalah koordinat citra dan f adalah amplitudo pada koordinat (x,y) yang disebut sebagai intensitas (Gonzalez, 2009). Nilai intensitas bersifat diskrit mulai dari 0 hingga 255 dan merupakan hasil tangkapan oleh kamera ataupun *scanner* yang telah dikuantisasi dalam nilai tersebut. Hasil tangkapan objek oleh kamera ataupun *scanner* yang telah dikuantisasi nilai

intensitasnya, inilah yang disebut dengan citra digital dan digambarkan seperti pada persamaan 2.1

$$f(x,y) = \begin{pmatrix} f(1,1) & f(1,2) & \dots & f(1,n) \\ f(2,1) & f(2,2) & \dots & f(2,n) \\ \dots & \dots & \dots & \dots \\ f(m,1) & f(m,2) & \dots & f(m,n) \end{pmatrix} \quad (2.1)$$

2.2.2 Metode Interpolasi Non-Adaptive

Metode interpolasi *non-adaptive* yang digunakan dalam penelitian ini meliputi *nearest neighbor*, *bilinear*, *bicubic*, dan *lanczos* dengan masing-masing penjelesanya sebagai berikut:

1. *Nearest Neighbor Interpolation*

Nearest neighbor adalah metode interpolasi paling sederhana dengan waktu komputasi relatif paling kecil dibandingkan dengan metode interpoasi yang lain. Prinsip dari metode tersebut adalah dengan memilih nilai *pixel* terdekat yang ada disekitarnya. Nilai *pixel* yang baru dibuat sama dengan *pixel* yang berdekatan sebagaimana digunakan untuk memperbesar *image*. Karena prinsip yang sederhana tersebut sehingga hasil dari metode tersebut kurang begitu baik digunakan untuk memperbesar ataupun memperkecil *image*. Kernel interpolasi *nearest neighbor* dirumuskan pada persamaan 2.2 (pamarthy dkk, 2014)

$$u(x) = \begin{cases} 0 & |x| > 0.5 \\ 1 & |x| < 0.5 \end{cases} \quad (2.2)$$

dengan x adalah jarak antara poin dengan grid poin yang diinterpolasi.

2. *Bilinear Interpolation*

Metode *bilinear Interpolation* mempunyai prinsip mengambil rata-rata tertimbang dari 4 pixel disekitar poin yang akan dinterpolasi untuk menghitung nilai akhir interpolasi. *Image* yang dihasilkan dari metode ini lebih halus dari *image* aslinya. Jika diketahui jarak *pixel* adalah sama, maka nilai interpolasi hanya diperoleh dari jumlah *pixel* tersebut dibagi empat. Teknik ini dilakukan dengan melakukan interpolasi di kedua arah, horisontal dan vertikal. Teknik ini memberikan hasil yang lebih baik daripada *nearest neighbor* dengan waktu komputasi lebih kecil dibandingkan dengan

interpolasi *bicubic*. Adapun kernel untuk interpolasi *bilinear* dirumuskan pada persamaan 2.3 (Prajapati, naik dan metha, 2012)

$$u(x) = \begin{cases} 0 & |x| > 1 \\ 1 - |x||x| & |x| < 1 \end{cases} \quad (2.3)$$

dengan x adalah jarak antara poin dengan grid poin yang diinterpolasi.

3. *Bicubic Interpolation*

Metode *bicubic Interpolation* secara prinsip dilakukan dengan mempertimbangkan 4×4 *pixel* terdekat dari poin yang diinterpolasi sehingga totalnya ada sebanyak 16 piksel disekitarnya. Karena prinsip inilah maka pada berbagai jarak dari *pixel* yang tidak diketahui (poin yang diinterpolasi), *pixel* lebih dekat diberi bobot yang lebih tinggi. *Bicubic* menghasilkan image yang lebih tajam daripada dua metode sebelumnya, dan sepadan dengan waktu komputasinya. Adapun kernel interpolasi *bicubic* dirumuskan seperti pada persamaan 2.4 (Prajapati, naik dan metha, 2012)

$$u(x) = \begin{cases} 3/2|x|^3 - \frac{5}{2}|x|^2 + 1 & 0 \leq |x| < 1 \\ -1/2|x|^3 + \frac{5}{2}|x|^2 - 4|x| + 2 & 1 \leq |x| < 2 \\ 0 & 2 < |x| \end{cases} \quad (2.4)$$

dengan x adalah jarak antara poin dengan grid poin yang diinterpolasi.

4. *Lanczos Interpolation*

Interpolasi *lanczos* berupa fungsi interpolasi yang digunakan untuk mempermudah interpolasi antar sampel citra digital. Pada masing-masing sampel dari citra yang diberikan untuk ditranslasikan dan pemindahan menggunakan skala *lanczos kernel*, yang merupakan fungsi *sinc*. Jumlah kernel ditranslasikan dan diperkecil kemudian dievaluasi pada *pixel* yang diinginkan. Adapun fungsi interpolasi *lanczos* order n dirumuskan seperti pada persamaan 2.5 dan 2.6

$$L(x, n) = \begin{cases} \text{sinc}(x) \cdot \text{sinc}\left(\frac{x}{n}\right) & \text{untuk } |x| \leq n \\ 0 & \text{lainnya} \end{cases} \quad (2.5)$$

$$\text{sinc}(x) = \begin{cases} 1 & \text{untuk } x = 0 \\ \sin(\pi x) / (\pi x) & \text{lainnya} \end{cases} \quad (2.6)$$

dengan x adalah jarak antara poin dengan grid poin yang diinterpolasi.

2.2.3 Naïve Bayes Classifier (NBC)

Naïve bayes classifier (NBC) adalah metode klasifikasi berbasis probabilitas dengan mengasumsikan diantara atribut atau fitur objek bersifat independen (Pablo, 2014). *Naïve bayes* saat ini masih menjadi topik yang hangat, khususnya terkait dengan perbaikan metode tersebut untuk meningkatkan peformansi dalam klasifikasi. Dalam banyak aplikasi seringkali, diasumsikan fungsi peluang (*probability density function*) setiap atribut atau fiturnya berdistribusi *normal* (*gaussian*) (Webb and Cospey, 2011) sehingga asumsi tersebut sangat berpengaruh dalam pembentukan NBC. Bila diketahui fitur objek, $X = \{x_1, \dots, x_d\}$ dan setiap fitur berdistribusi *normal* (*gaussian*) maka peluang fitur atau atribut dengan syarat diketahui kelas ke- j (C_j) adalah

$$P(X | C_j) = \prod_{k=1}^d P(X_k | C_j) = \prod_{k=1}^d N(x_k; \hat{\mu}_{jk}, \hat{\sigma}_{jk}) \quad (2.7)$$

dengan $\hat{\mu}_{jk}$ dan $\hat{\sigma}_{jk}$ adalah hasil estimasi parameter distribusi (*normal*) μ dan σ untuk fitur ke- k dan kelas k- j . Dengan menggunakan kaidah peluang bersyarat didapatkan persamaan sebagai berikut

$$P(C_j, X) = P(C_j)P(X | C_j) = P(C_j) \prod_{k=1}^d N(x_k; \hat{\mu}_{jk}, \hat{\sigma}_{jk}) \quad (2.8)$$

Berdasarkan persamaan 2.8, maka untuk menentukan hasil klasifikasi berdasarkan atribut atau fitur objek yang diinputkan, berdasarkan nilai peluang terbesar dari $P(C_j | X)$

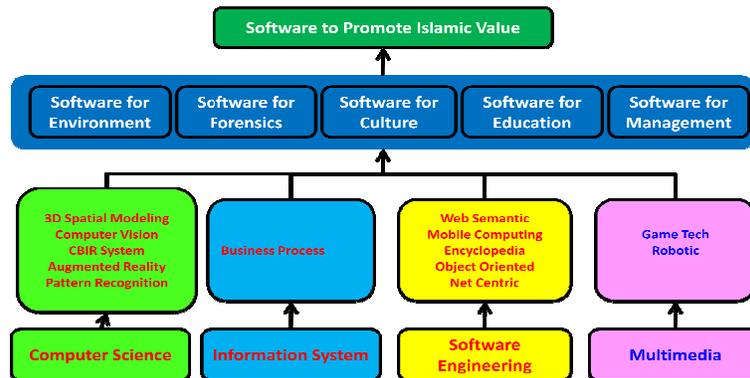
$$\hat{c} = \arg \max_{c_j} P(C_j) \prod_{k=1}^d N(x_k; \hat{\mu}_{jk}, \hat{\sigma}_{jk}) \quad (2.9)$$

Dengan \hat{c} adalah hasil klasifikasi atau deteksi.

2.3 RoadMap Penelitian

RoadMap Penelitian yang dilakukan selama ini mengacu pada *roadmap* jurusan Teknik Informatika (lihat Gambar 2.1.) dengan bidang keilmuan Ilmu Komputer dengan spesifikasi penelitian terkait *Pattern Recognition* untuk menghasilkan Aplikasi atau *software* untuk membantu mengaplikasikan nilai islam seperti membangun aplikasi mendeteksi makanan yang baik (*thoyyib*). Dalam perjalanannya peneliti telah memulai beberapa penelitian awal dan dipublikasikan baik secara local atau nasional. Dalam penelitian bidang *Pattern Recognition* (Pengenalan Pola) untuk multi objek ringan dalam bentuk *image* (citra). Pengembangan diawali dengan membandingkan dua metode estimator distribusi fitur objek yaitu RLME (*Regularized Laten Maximum Entropy*) dan ML (*Maximum Likelihood*) dalam membangun model *Tree-Augmented Network* (TAN) untuk kasus data sintesis. Tujuan dari pengembangan ini adalah untuk menentukan estimator dan model TAN terbaik khususnya untuk objek dengan distribusi fitur normal (MATICS, September 2011). Pengembangan metode terus dilakukan terhadap dua estimator tersebut, untuk fitur objek berdistribusi *Uniform* (kasus data sintesis). Tujuan dari pengembangan ini adalah untuk mengetahui sensitifitas dua estimator dalam membangun model TAN dalam mengenali objek (SciETec, Februari 2012). Pengembangan terhadap metode dalam membangun model TAN selanjutnya adalah untuk mendapatkan model pengenalan terbaik dengan TAN dan ML berdasarkan ukuran fitur objek (MATICS, Maret 2012). Untuk penelitian terkait hal ini, tetap berlanjut diantaranya meneliti salah komponen terpenting dalam membangun model TAN yaitu terkait penentuan hubungan antara dua fitur objek dengan Mutual Information (MATICS, 2013). Dalam penelitian bidang *Pattern Recognition* untuk objek (*image*) *handwriting* (tulisan tangan), dilakukan dalam rangka mengimplementasikan metode ML dan model TAN. Dalam membangun model Pengenalan Karakter Tulisan Tangan Terbaik selain pertimbangan metode juga mempertimbangkan ukuran fitur objek (*image*) karakter tulisan tangan (MATICS, September 2012). Penelitian terkait dengan mendapatkan model pengenalan terbaik terus dilanjutkan untuk meningkatkan lagi akurasi pengenalannya, yang tidak hanya melibatkan sebuah model TAN dan beberapa *threshol*d (multi model TAN) dan ternyata berhasil meningkatkan akurasi sistem sampai 100% Seminar Nasional Green Technology 3, 10 November 2012). Upaya mendapatkan model terbaik ataupun memperdalam classifier tersebut diantaranya dengan ikut seminar internasional “The 4th International Conference Green Technology, Faculty of Science And Technology, Maulana Malik Ibrahim State Islamic University” pada tahun 2013 dengan judul “Comparison of Pearson Correlation And Conditional Mutual Information To Construct Model of Tree-Augmented Network

(TAN)(Case study character handwriting recognition)”. Melalui penelitian kompetitif disen LP2M UIN Malang pada tahun 2014 melakukan penelitian yang berjudul “Deteksi Boraks pada Bakso Berbasis Image dengan Menggunakan *Tree-Augmented Bayesian Network* (TAN)” serta melalui penelitian penguatan program studi juga melakukan penelitian dengan judul “Deteksi Objek Nyata (Pada Lingkup: Visualisasi dan Deteksi Objek Nyata pada Lingkungan Hidup”.



Gambar 2.1 *Roadmap* Penelitian Jurusan Teknik Informatika UIN Malang

Begitu juga pada tahun 2015, peneliti melalui LP2M melakukan penelitian dengan judul “Deteksi dan Segmentasi Ruang Terbuka Hijau Kota Malang Berbasis Citra Google Earth dengan Menggunakan *Tree-Augmented Naïve Bayesian Network* dan *K-Means*

Berdasarkan *roadmap* penelitian tersebut maka rencana kedepan berdasarkan penelitian yang dilaksanakan ataupun diajukan adalah sebagai berikut:

1. Pengembangan keilmuan

Pengembangan metode terkait dengan *pattern recognition* (Pengenalan Pola) khususnya berkaitan dengan proses membangun model dan estimator modelnya akan dilanjutkan untuk beberapa tahun kedepan mengingat peningkatan akurasi pengenalan menjadi hal penting serta adanya distribusi fitur objek yang berbeda-beda. Pengembangan kedepan tidak hanya pada metode saja tetapi penggunaan objek yang berbeda.

2. Implementasi hasil penelitian

Hasil-hasil penelitian terhadap pengembangan metode yang berkaitan dengan *pattern recognition* (Pengenalan Pola), untuk rencana ke depan diusahakan bisa diimplementasikan dalam bentuk teknologi yang lebih praktis sehingga bisa dimanfaatkan oleh masyarakat baik dari kalangan akademis, umum ataupun praktisi. Supaya bisa dimanfaatkan masyarakat tentu implementasi metode tersebut akan dikemas dalam suatu perangkat lunak yang *user friendly*.

BAB III

METODE PENELITIAN

3.1. Metoda yang Diusulkan

Penelitian yang diusulkan penulis pada prinsipnya ada 4 proses yaitu preproses *image*, optimalisasi *image downscaling* dengan metode interpolasi, membangun struktur model *naïve bayes classifier* (NBC) berdasarkan fitur hasil interpolasi, estimasi parameter model NBC dan klasifikasi *image*. Sedangkan untuk menguji tingkat performansi metode yang diusulkan, akan dilakukan pengujian klasifikasi *image* berdasarkan data *benchmark* yang telah disediakan oleh *CVonline image database* dan data hasil penelitian laboratorium Komputer Vision Teknik Informatika Universitas Islam Negeri (UIN) Malang.

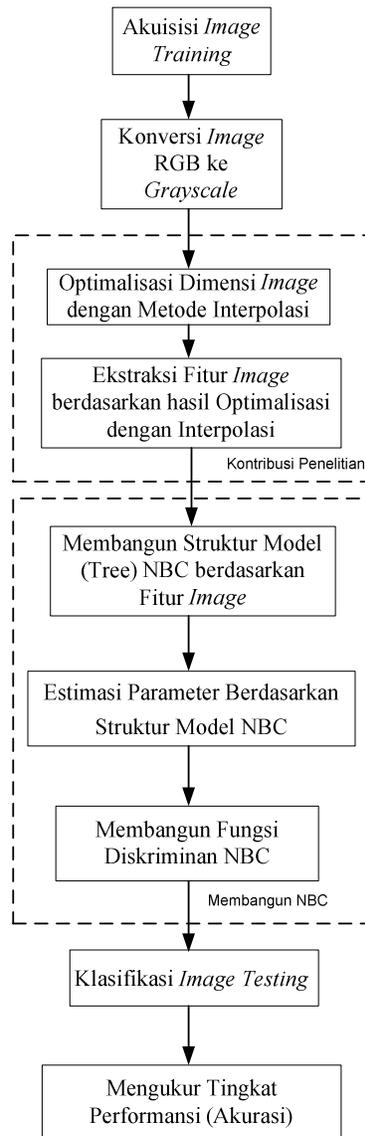
3.2. Tahapan Penelitian

Secara rinci tahapan dari penelitian ini digambarkan pada Gambar 3.1 yaitu konversi *image* ke *grayscale*, optimalisasi dimensi *image* dengan metode interpolasi, ekstraksi fitur *image* berdasarkan hasil optimalisasi dengan interpolasi, membangun struktur model (*Tree*) NBC, estimasi parameter berdasarkan struktur model NBC, klasifikasi *image testing* dan mengukur tingkat performansi metode. Kontribusi utama pada penelitian ini terletak pada tahap optimalisasi dimensi *image* dan ekstraksi fitur *image* berdasarkan hasil optimalisasi dengan interpolasi. Tahapan tersebut menjadi kontribusi utama karena hasil dari tahapan tersebut akan mempengaruhi struktur model NBC, hasil estimasi parameter NBC serta secara otomatis akan mempengaruhi kemampuan klasifikasi terhadap *image* (tingkat performansi metode NBC). Untuk penjelasan masing-masing tahapan secara detail termuat pada sub-bab berikutnya.

3.2.1 Akuisisi *Image Training*

Proses akuisisi *image training* dilakukan untuk mengambil data *image training* perkelas dan mengambil nilai *pixel* setiap *image training* serta menjadikan dalam bentuk matrik seperti pada persamaan 2.1. Untuk keperluan pada penelitian ini, akuisisi *image training* meliputi *image tekstur* yang disediakan oleh Lazebnik, Schmid, and Ponce [2003] pada *CVonline image database* sebagai data *benchmark* internasional (25 kelas dengan masing-masing kelas sebanyak 40 *sampel texture*) serta data hasil penelitian laboratorium Komputer Vision Teknik Informatika UIN Malang seperti hasil penelitian Santoso [2014, 2015], Purwanto [2016] dan

Hadini [2016] (*image* bakso boraks dan non-boraks, *image* objek RTH, dan *image* mata ikan bandeng berformalin dan tidak berformalin).



Gambar 3.1 Tahapan Penelitian

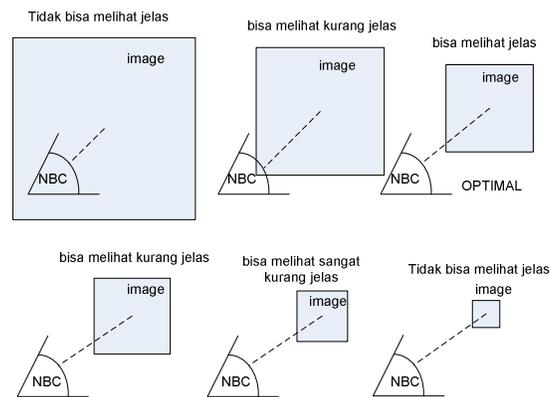
3.2.2 Konversi *Image* RGB ke *Grayscale*

Konversi image RGB ke *grayscale* dilakukan untuk mempermudah dalam melakukan optimalisasi dengan metode interpolasi. Untuk merubah ke bentuk *grayscale*, terlebih dahulu *image* RGB harus dibaca nilai intensitas *pixel*-nya dan disimpan ke dalam suatu variabel tertentu. Preproses pada proses *training* data dilakukan pada seluruh sampel *training* secara serentak, sedang pada proses *testing* dilakukan pada satu *image* objek yang akan dideteksi.

Perbedaan tersebut terjadi karena pada proses *training* tidak hanya melibatkan satu objek tetapi banyak objek dengan setiap kelas objeknya terdiri dari beberapa sampel objek.

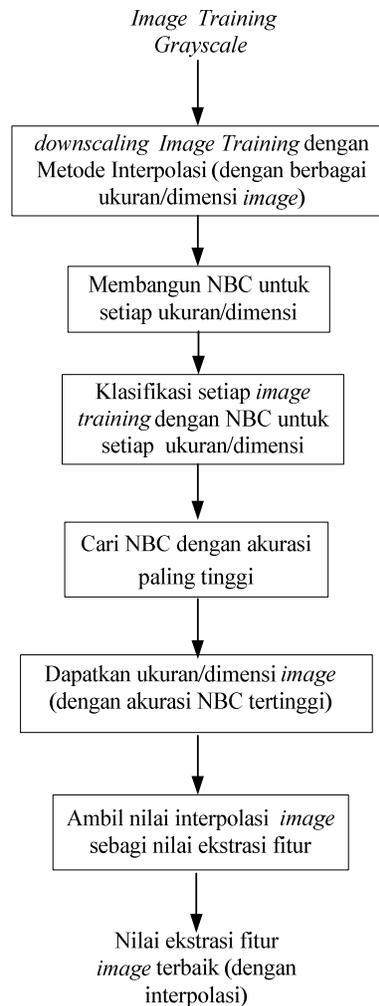
3.2.3 Optimalisasi Dimensi *Image* dengan Metode *Interpolasi*

Optimalisasi dimensi *image* (*training*) dengan metode interpolasi pada dasarnya adalah melakukan *downscaling* terhadap semua *image* yang digunakan dalam *training*. Alasan kenapa dimensi atau ukuran *image* perlu dioptimalkan, karena untuk menemukan jarak pandang yang tepat bagi metode klasifikasi dalam hal ini adalah *naïve bayes*, sehingga dapat membedakan *image* setiap kelasnya dengan ketepatan atau akurasi yang paling tinggi. Sebagai gambaran pemahaman terkait perlunya optimalisasi dimensi *image* tersebut bisa dilihat pada Gambar 3.2.



Gambar 3.2 Gambaran optimalisasi dimensi *image* terhadap NBC dengan metode interpolasi

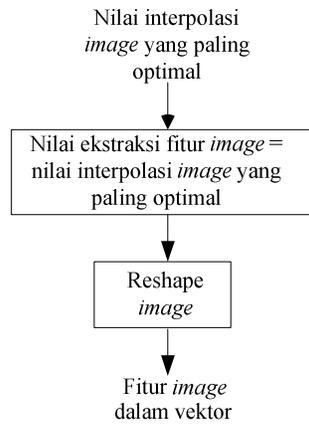
Adapun langkah-langkah untuk mendapatkan dimensi *image training* yang optimal dengan menggunakan metode interpolasi adalah pertama, melakukan *downscaling image training* dengan berbagai ukuran yang memungkinkan. Langkah kedua, membangun NBC untuk setiap ukuran dimensi yang ditentukan. Ketiga, melakukan klasifikasi setiap *image training* untuk setiap ukuran atau dimensi yang telah ditentukan. Keempat, mencari NBC yang memberikan akurasi tertinggi serta dimensi paling kecil. Kelima, simpan atau dapatkan ukuran atau dimensi *image* dengan akurasi NBC tertinggi dan yang keenam mengambil atau menggunakan nilai interpolasi *image* berdasarkan langkah kelima sebagai nilai ekstraksi fitur *image* yang optimal. Untuk selanjutnya gambaran terkait langkah-langkah optimalisasi dimensi *image* dengan metode interpolasi bisa dilihat pada Gambar 3.3



Gambar 3.3 Optimalisasi dimensi *image training* dengan metode interpolasi

3.2.4 Ekstraksi Fitur *Image* berdasarkan hasil Optimalisasi dengan Interpolasi

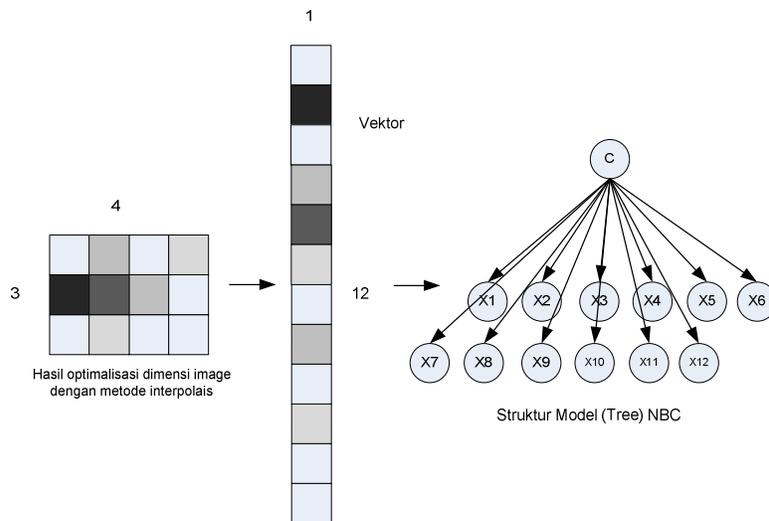
Hasil yang paling optimal dimensi *image* dengan metode interpolasi selanjutnya akan mewakili fitur utama dari *image training* atau dengan kata lain nilai ekstraksi fitur (ciri) *image* sama dengan nilai interpolasi *image* pada dimensi *image* yang paling optimal. Ekstraksi fitur tersebut berupa suatu nilai dalam bentuk vektor yang mewakili dari ciri objek *image* yang bersangkutan (lihat Gambar 3.4). Dimensi atau ukuran *image* objek yang dirubah tersebut, sedemikian hingga akan mempengaruhi struktur model NBC yang akan dibangun, estimasi parameter dan klasifikasi yang dihasilkan.



Gambar 3.4 Ekstraksi fitur image berdasarkan nilai Interpolasi optimal

3.2.5 Membangun Struktur Model (Tree) NBC

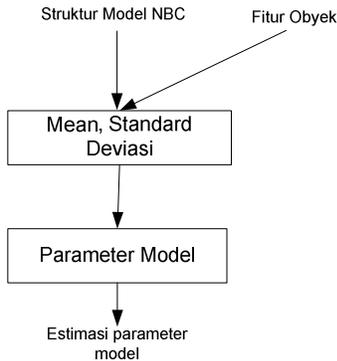
Untuk membangun struktur model atau tree dari NBC harus diketahui terlebih dahulu yang menjadi atribut (variabel) atau fitur *image* yang akan menjadi node dalam *tree* serta jumlahnya. Selanjutnya menentukan *node* yang menjadi *parent* dan *node* yang menjadi *child* yang dihubungkan dengan *edge*. Untuk kasus dalam penelitian ini, yang akan menjadi *node* dalam *tree* adalah fitur hasil ekstraksi fitur *image* pada tahap sebelumnya dengan jumlah *node* sebanyak jumlah fitur hasil dari optimalisasi dimensi *image* dengan metode interpolasi. Gambar 3.5 menunjukkan jumlah *node* dalam *tree* ditentukan dari dimensi *image* yang paling optimal dari hasil optimalisasi interpolasi.



Gambar 3.5 Membangun struktur model NBC dari hasil optimalisasi dengan Interpolasi

3.2.6 Estimasi Parameter Berdasarkan Struktur Model NBC

Proses estimasi parameter model NBC, dilakukan setelah struktur modelnya telah dibangun dan distribusi fitur *image* objek diketahui. Asumsi yang digunakan dalam melakukan estimasi parameter adalah bahwa setiap fitur objek mempunyai distribusi normal (*gaussian*).



Gambar 3.6 Estimasi parameter model NBC

Bila diasumsikan distribusi fitur image adalah Normal, maka parameter-parameter distribusi fitur image adalah *mean*, *standard deviasi* yang dapat diperoleh dengan metode *maximum likelihood* (Santoso, 2014, 2015).

3.2.7 Membangun Fungsi Diskriminan NBC

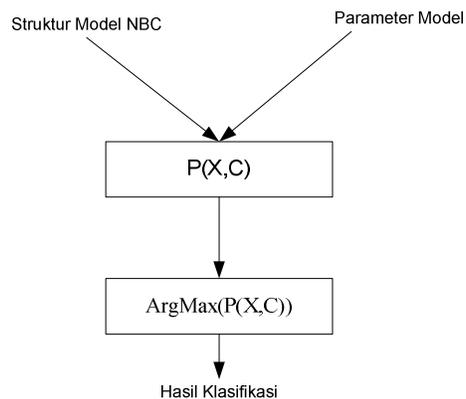
Fungsi diskriminan NBC digunakan untuk proses klasifikasi *image*, dapat dilakukan setelah struktur model NBC terbentuk, parameter-parameter modelnya telah diestimasi. Selanjutnya dengan mengambil nilai fitur *image testing*, dilakukan perhitungan nilai peluang untuk setiap kelas ($P(X,C)$) dengan menggunakan persamaan 2.8. Untuk mempermudah proses komputasi, selanjutnya ditentukan fungsi diskriminan untuk setiap NBC dengan melakukan logaritma terhadap persamaan tersebut, yang hasilnya sebagai berikut:

$$g_j(x) = \log(P(C_j)) - \sum_{l=1}^d \log(\hat{\sigma}_{jl}) - \frac{1}{2} \sum_{l=1}^d \frac{(x_l - \hat{\mu}_{jl})^2}{\hat{\sigma}_{jl}^2} \quad (3.1)$$

dengan C_j adalah kelas ke- j , $\hat{\mu}_{jl}$ adalah estimasi parameter rata-rata kelas ke- j dan fitur ke- l , $\hat{\sigma}_{jl}$ adalah nilai standar deviasi kelas ke- j fitur ke- l , dan x_l adalah data testing fitur ke- l .

3.2.8 Klasifikasi *Image Testing*

Proses klasifikasi *image*, dapat dilakukan setelah struktur model NBC terbentuk, parameter-parameter modelnya telah diestimasi. Selanjutnya dengan mengambil nilai fitur *image testing*, dilakukan perhitungan nilai peluang untuk setiap kelas ($P(X,C)$) yang diwakili dengan menggunakan fungsi diskrimian seperti pada persamaan 3.1. Selanjutnya setelah nilai peluang setiap kelas dihitung, kemudian dicari nilai peluang atau diskrimian yang paling besar (lihat persamaan 2.9, persamaan 3.1 dan Gambar 3.7), untuk ditentukan hasil klasifikasi *image*-nya.



Gambar 3.7 Proses klasifikasi dengan NBC

3.2.9 Mengukur Tingkat Performansi

Untuk mengukur tingkat performansi dari suatu metode yang diusulkan salah satunya adalah dengan mengukur sejauhmana tingkat akurasi terhadap metode lain atau metode tanpa perlakuan (tanpa optimalisasi). Dalam menentukan tingkat akurasi dalam klasifikasi (*correct classification*) *image*, sebaiknya terlebih dahulu dibuat matrik *confusion* sehingga mempermudah dalam menghitung tingkat akurasi. Untuk kasus dalam penelitian ini, akan dibandingkan tingkat akurasi hasil klasifikasi NBC dengan menggunakan optimalisasi beberapa metode interpolasi, dengan tanpa menggunakan optimalisasi. Begitu juga akan dibandingkan hasil akurasi klasifikasi NBC diantara beberapa metode interpolasi yang diujicobakan.

3.3 Pengujian Optimalisasi Metode Interpolasi dengan Data *benchmark*

Untuk mengetahui sejauhmana tingkat performasi metode yang diusulkan, akan dilakukan pengujian metode tersebut dengan data *benchmark CVonline image database* dan data hasil penelitian laboratorium Komputer Vision Teknik Informatika UIN Malang.

3.3.1 Data *image CVonline image database*

Data *image* yang akan digunakan sebagai data *benchmark* adalah data *image tekstur* yang diambil dari sumber *CVonline image database* oleh Lazebnik, Schmid, dan Ponce [2003]. Data *image tekstur* tersebut terdiri dari 25 jenis *image tekstur* yang berbeda dengan masing-masing *tekstur* terdiri dari 40 sampel (lihat Gambar 3.8).



T01_bark1	File folder	8/26/2003 5:55 ...
T02_bark2	File folder	8/26/2003 5:55 ...
T03_bark3	File folder	8/26/2003 5:56 ...
T04_wood1	File folder	8/26/2003 5:56 ...
T05_wood2	File folder	8/31/2003 4:41 ...
T06_wood3	File folder	8/26/2003 5:57 ...
T07_water	File folder	8/26/2003 5:57 ...
T08_granite	File folder	8/26/2003 5:58 ...
T09_marble	File folder	8/26/2003 5:58 ...
T10_floor1	File folder	8/26/2003 5:58 ...
T11_floor2	File folder	8/26/2003 5:58 ...
T12_pebbles	File folder	8/26/2003 5:59 ...
T13_wall	File folder	8/26/2003 5:59 ...
T14_brick1	File folder	8/26/2003 6:01 ...
T15_brick2	File folder	8/26/2003 6:02 ...
T16_glass1	File folder	8/26/2003 6:02 ...
T17_glass2	File folder	8/26/2003 6:02 ...
T18_carpet1	File folder	8/26/2003 6:03 ...
T19_carpet2	File folder	8/26/2003 6:03 ...
T20_upholstery	File folder	8/26/2003 6:04 ...
T21_wallpaper	File folder	8/26/2003 6:04 ...
T22_fur	File folder	8/26/2003 6:04 ...
T23_knit	File folder	8/26/2003 6:05 ...
T24_corduroy	File folder	8/26/2003 6:05 ...
T25_plaid	File folder	8/26/2003 6:06 ...

Gambar 3.8 *Database texture CVonline image database*
(S.Lazebnik, C.Schmid, and J.Ponce. 2003)

Dari data tersebut akan diujicoba dengan membangun NBC yang melibatkan masing 5 kelas dan seluruh kelas (T01-T25) dengan perlakuan seperti pada tabel 3.1 dan yang lainnya. Pada masing-masing ujicoba atau eksperimen akan dibangun NBC dengan optimalisasi dengan metode interpolasi (*nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*) dan tanpa optimalisasi. Dari masing-masing ujicoba tersebut selanjutnya dihitung akurasi dan untuk ujicoba 1 yang melibatkan T01 –T05 dapat dilihat pada Tabel 3.1, untuk ujicoba 2 yang melibatkan T06-T10 dapat dilihat pada Tabel 3.2, ujicoba 3 yang melibatkan T11-T15 dapat dilihat pada Tabel 3.3, ujicoba 4 yang melibatkan T15-T20 dapat dilihat pada Tabel 3.4, ujicoba 5 yang melibatkan T21-T25 dapat dilihat pada Tabel 3.5 dan ujicoba 6 yang melibatkan T01-T25 dapat dilihat pada Tabel 3.6.

Tabel 3.1 Akurasi NBC hasil training untuk data *image* T01-T05

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinear</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.2 Akurasi NBC hasil training untuk data *image* T06-T10

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinear</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.3 Akurasi NBC hasil training untuk data *image* T11-T15

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinear</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.4 Akurasi NBC hasil training untuk data *image* T15-T20

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.5 Akurasi NBC hasil training untuk data *image* T21-T25

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.6 Akurasi NBC hasil training untuk data *image* T01-T25

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

3.3.2 Data hasil penelitian laboratorium Komputer Vision Teknik Informatika UIN Malang

Data *image* yang akan digunakan sebagai data *benchmark* kedua adalah data *image* hasil penelitian laboratorium Komputer Vision Teknik Informatika UIN Malang oleh Santoso [2014, 2015], Purwanto [2016] dan Hadini [2016] . Data *image* tersebut meliputi *image* bakso boraks dan tidak mengandung boraks, *image* mata ikan bandeng yang berformalin dan tidak berformalin serta data *image* objek ruang terbuka hijau (RTH) kota malang yang memuat 6 jenis objek RTH.

Tabel 3.7 Akurasi NBC hasil training untuk data *image* bakso boraks dan non- baraks

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.8 Akurasi NBC hasil training untuk data *image* mata ikan bandeng berformalin dan tidak berformalin

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Tabel 3.9 Akurasi NBC hasil training untuk data *image* objek ruang terbuka hijau kota malang

Ukuran/dimensi Image	Tanpa Interpolasi	Metode Interpolasi			
		<i>nearest neighbor</i>	<i>bilinier</i>	<i>bicubic</i>	<i>lanczos</i>
Image asli		-	-	-	-
Downscaling					
	-				
	-				

Dari data tersebut akan diujicoba dengan membangun NBC yang melibatkan jenis image dengan perlakuan seperti pada tabel 3.7 sampai Tabel 3.9. Sama seperti pada data image tekstur, pada masing-masing jenis image akan dilakukan ujicoba atau eksperimen dengan membangun NBC yang dioptimalisasi dengan metode interpolasi (*nearest neighbor, bilinear, bicubic dan lanczos*) dan tanpa optimalisasi. Dari masing-masing ujicoba tersebut selanjutnya dihitung akurasinya .

BAB IV

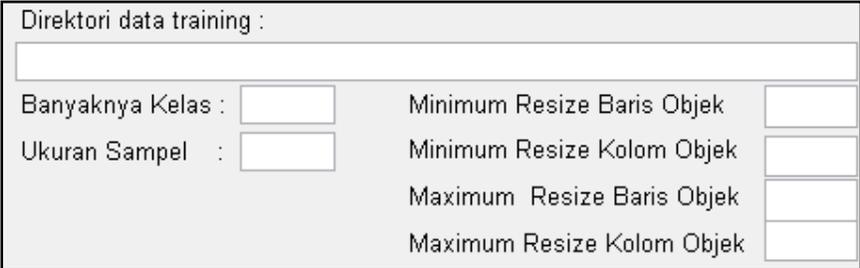
HASIL PENELITIAN DAN PEMBAHASAN

4.1 Implementasi Desain Sistem Aplikasi

Implementasi desain sistem optimalisasi dimensi *image* dengan menggunakan metode interpolasi dilakukan dengan menggunakan MATLAB. Implementasi terhadap desain sistem pada bab sebelumnya secara garis besar dibagi menjadi beberapa bagian yaitu akuisisi *image training*, konversi *image* RGB ke *grayscale*, optimalisasi dimensi dan ekstraksi fitur *image* dengan metode interpolasi, membangun *naïve bayes classifier* (NBC), klasifikasi *image* (data *image benchmark*) dan mengukur tingkat akurasi.

4.1.1 Akuisisi *Image Training*

Akuisisi *image training* dilakukan dengan membuka direktori data *training* yaitu direktori yang memuat *image training* dengan nama tertentu. Aplikasi akuisisi *image training* dapat dilihat pada Gambar 4.1.



Direktori data training :	
<input style="width: 100%;" type="text"/>	
Banyaknya Kelas :	<input style="width: 50px;" type="text"/>
Ukuran Sampel :	<input style="width: 50px;" type="text"/>
Minimum Resize Baris Objek	<input style="width: 50px;" type="text"/>
Minimum Resize Kolom Objek	<input style="width: 50px;" type="text"/>
Maximum Resize Baris Objek	<input style="width: 50px;" type="text"/>
Maximum Resize Kolom Objek	<input style="width: 50px;" type="text"/>

Gambar 4.1. Aplikasi *image training*

Dalam akuisisi *image training* harus terlebih dahulu harus diinputkan banyaknya kelas *image training* dan ukuran sampel *image* yang digunakan. File *image training* yang digunakan dalam aplikasi ini menggunakan ekstension *.JPG. Sedangkan untuk mempermudah dalam pembacaan *image training* nama file *image* dibuat pola khusus dengan memberi nama angka 1,2,3,... sampai *image* terakhir. Akuisisi *image* tersebut tidak hanya digunakan membuka file *image* saja, akan tetapi sampai pada proses pembacaan pixel *image* berdasarkan banyaknya baris dan kolom (*size/dimensi*) *image* yang diinginkan. Untuk melengkapi dan memudahkan pembahasan dalam memahami aplikasi ini selengkapnya dapat dilihat codingnya pada Gambar 4.2.

```

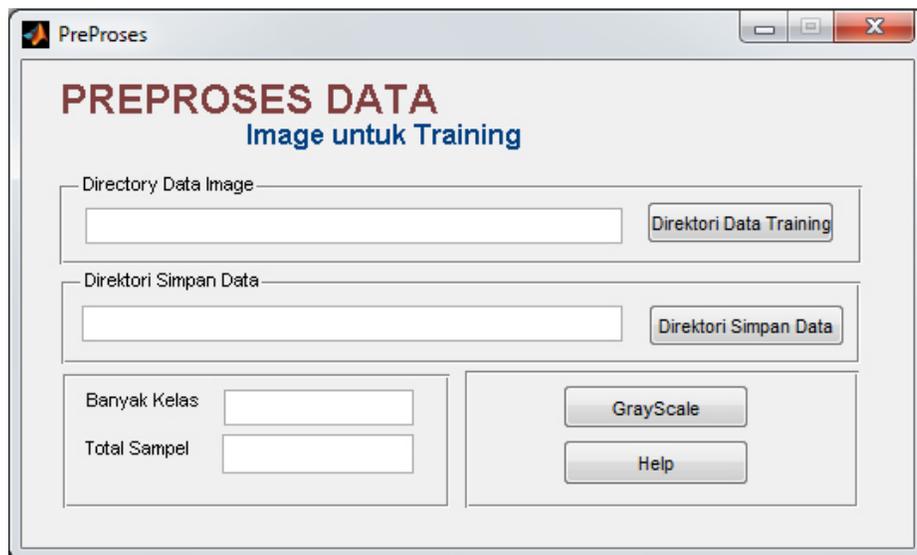
for sampel=1:USampel
    Objek=strcat(DirectoryDataTraining,'\',int2str(sampel),'.jpg');
    ObjekProses=imread(Objek);
    ObjekProses=imresize(ObjekProses,[baris,kolom],'nearest');
    Data_y(sampel,1:baris*kolom)=reshape(ObjekProses,1,baris*kolom);
end
Data_y=double(Data_y);

```

Gambar 4.2 code akuisi *image training*

4.1.2 Konversi *Image RGB ke Grayscale*

Konversi *image* RGB ke *grayscale* bisa disebut masuk dalam tahapan preproses. Sebelum dilakukan proses training atau proses yang lainnya terlebih dahulu *image training* RGB dirubah ke *image grayscale*. Aplikasi preproses tersebut selengkapnya dapat dilihat pada 4.3. Aplikasi preproses tersebut dilengkapi dengan menu menyimpan file *image grayscale* pada direktori tertentu. Proses merubah *image* RGB tidak dilakukan satu persatu melainkan dilakukan secara serentak dengan menginputkan jumlah sampel *image training* pada direktori *training* dan menyimpannya secara serentak pada direktori tertentu.



Gambar 4.3 Aplikasi preproses *image* untuk *training*
(Santoso, 2014)

Sedangkan *code* proses untuk merubah *image training* RGB ke *grayscale* selengkapnya dapat dilihat pada potongan *code* Gambar 4.4 (Santoso, 2014).

```

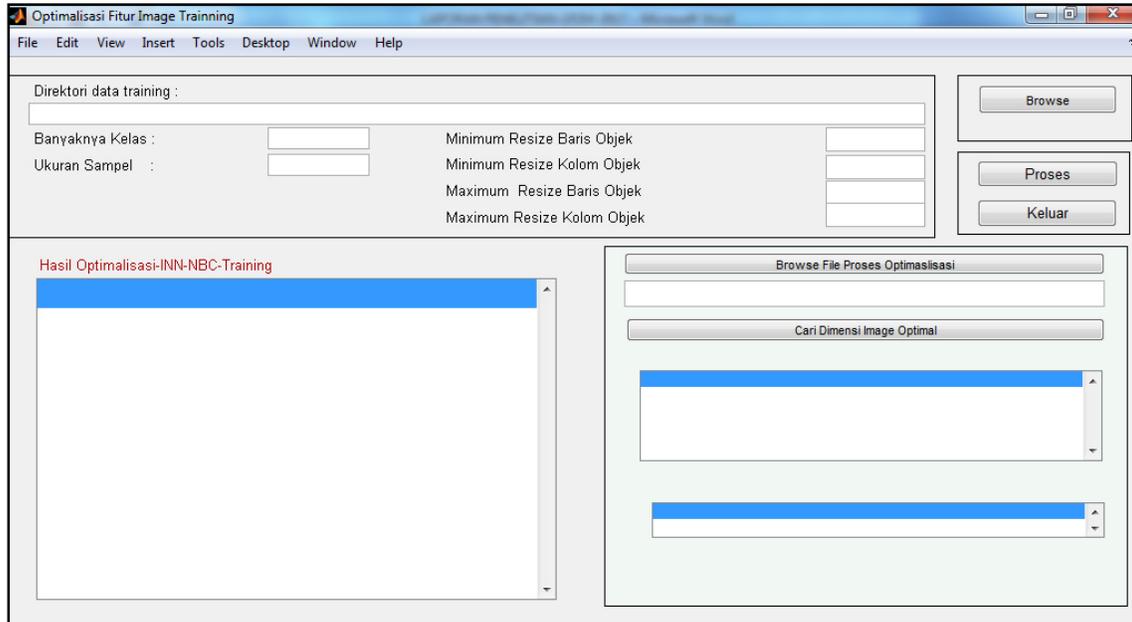
% --- Executes on button press in GrayScaleImage.
function GrayScaleImage_Callback(hObject, eventdata, handles)
DirektoriOpen=strcat(get(handles.DirektoriDataAkuisisi,'String'),'\\');
DirektoriSimpan=strcat(get(handles.DirektoriDataSimpan,'String'),'\\');
Sampel=str2num(get(handles.TotalSampel,'String'));
for i=1:Sampel
    fileOpen=strcat(DirektoriOpen,int2str(i),'.JPG');
    BacaImage=imread(fileOpen);
    ImageGray=rgb2gray(BacaImage);
    namafile=strcat(int2str(i),'.JPG');
    NamaFiledanDirektori=strcat(DirektoriSimpan,namafile);
    imwrite(ImageGray,NamaFiledanDirektori);
    pk=(i/Sampel)*100
end

```

Gambar 4.4. Implementasi proses konversi *image* RGB ke *grayscale*

4.1.3 Optimalisasi Dimensi *Image* dengan Metode Interpolasi

Optimalisasi dimensi *image* (*training*) digunakan untuk mendapatkan dimensi atau size *image* training sedemikian hingga diperoleh akurasi terbaik dalam klasifikasi *image* dengan NBC. Untuk membangun aplikasi optimalisasi dimensi *image* dengan metode interpolasi, mengacu pada langkah-langkah pada bab sebelumnya yaitu pada Gambar 3.3. Adapun langkah-langkah untuk mendapatkan dimensi *image training* yang optimal dengan menggunakan metode interpolasi seperti yang telah disebutkan pada bab sebelumnya adalah pertama, melakukan *downscaling image training* dengan berbagai ukuran yang memungkinkan. Kedua, membangun NBC untuk setiap ukuran dimensi yang ditentukan. Ketiga, melakukan klasifikasi setiap *image training* untuk setiap ukuran atau dimensi yang telah ditentukan. Keempat, mencari NBC yang memberikan akurasi tertinggi serta dimensi paling kecil. Kelima, simpan atau dapatkan ukuran atau dimensi *image* dengan akurasi NBC tertinggi dan yang keenam mengambil atau menggunakan nilai interpolasi *image* berdasarkan langkah kelima sebagai nilai ekstraksi fitur *image* yang optimal. Untuk selanjutnya hasil implementasi dari tahapan tersebut bisa dilihat pada Gambar 4.5. Di dalam aplikasi optimalisasi dimensi tersebut, terdapat menu untuk menginputkan nilai minimum dan maksimum *resize image* baik baris ataupun kolom. Input tersebut selanjutnya dijadikan sebagai dasar untuk melakukan trial (kombinasi) dimensi *image* sedemikian hingga didapatkan nilai akurasi NBC paling tinggi (lihat menu dimensi *image* optimal pada aplikasi). Adapun peranan metode interpolasi dalam aplikasi ini adalah untuk melakukan *resize image training*.



Gambar 4.5. Tampilan aplikasi optimalisasi dimensi *image training* dengan interpolasi

Hasil dimensi *image* yang paling optimal dengan metode interpolasi selanjutnya akan mewakili fitur utama dari *image training* atau sebagai nilai ekstraksi fitur (ciri) *image*. Ekstraksi fitur tersebut berupa suatu nilai dalam bentuk vektor yang mewakili dari ciri objek *image* yang bersangkutan. Selanjutnya untuk potongan code optimalisasi dimensi *image* dengan metode interpolasi dapat dilihat pada Gambar 4.6.

```

for baris=minBaris:maxBaris
    for kolom=minKolom:maxKolom
        for sampel=1:USampel
            Objek=strcat (DirectoryDataTraining, '\', int2str (sampel), '.jpg');
            ObjekProses=imread (Objek);
            ObjekProses=imresize (ObjekProses, [baris, kolom], 'nearest');
            Data_y (sampel, 1:baris*kolom)=reshape (ObjekProses, 1, baris*kolom);
        end
        Data_y=double (Data_y);
        [Klasifikasi, CM, ProsentaseErrorKlas_NBC, Mean_G, Sigma2_G]=TrainingNBC (Data_y, Data_c);
        indek=indek+1;
        Akurasi=100-ProsentaseErrorKlas_NBC;
    end
end

hasilOptimasiNBC=[dimensiResizeBaris dimensiResizeKolom AkurasiKlasifikasiSistem];

HasilOptimalisasi=strcat ('HasilOptimalisasi\HasilOptimalisasi.mat');
save (HasilOptimalisasi, 'hasilOptimalisasiNBC');
set (handles.HasilOptimalisasiNBC, 'String', num2str (hasilOptimasiNBC));

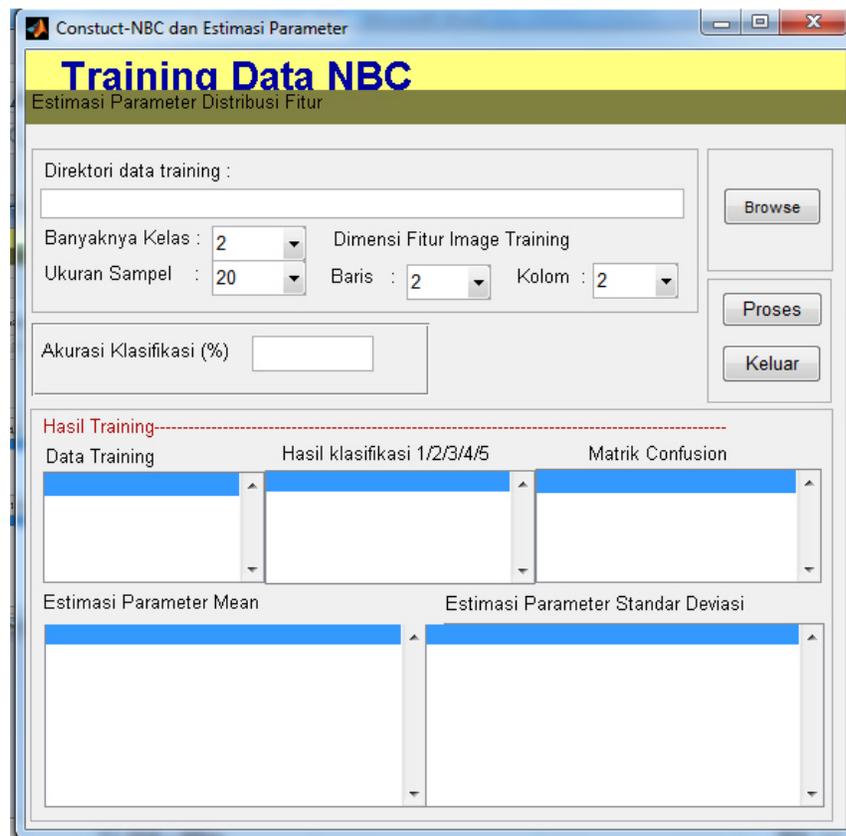
load (HasilOptimalisasi);
[dBaris dKolom Akurasi Kterpilih terpilih]=DimensiImageOptimal (hasilOptimasiNBC);

```

Gambar 4.6 Code optimalisasi dimensi *image* dengan metode interpolasi

4.1.4 Membangun NBC

Dimensi atau ukuran *image* objek hasil optimalisasi akan mempengaruhi struktur model NBC yang akan dibangun, estimasi parameter dan klasifikasi yang dihasilkan dan semua itu tercakup dalam aplikasi training data NBC. Aplikasi *training* data NBC digunakan untuk estimasi parameter model NBC, juga memuat ekstraksi fitur *image training* (lihat Gambar 4.7). Input dari aplikasi tersebut adalah sejumlah data *image grayscale training* dalam bentuk file dengan ekstension .JPG. Input lainnya selain *image training* adalah dimensi fitur *image training* yang diperoleh dari hasil optimalisasi dimensi *image* dengan metode interpolasi.



Gambar 4.7 Tampilan aplikasi *training* data NBC (sumber: Santoso, 2016)

Hasil dari *training* NBC ini meliputi estimasi parameter distribusi fitur *image* (asumsi distribusi fitur adalah normal (*gaussian*)) yaitu nilai estimasi parameter *mean* dan standar deviasi. Hasil lain selain nilai estimasi parameter adalah hasil ekstraksi fitur *image*, klasifikasi *image training*, matrik *confusion*, dan akurasi klasifikasi (lihat Gambar 4.7).

Adapun potongan *code* dari *training* data NBC selengkapnya dapat dilihat pada Gambar 4.8 dan Gambar 4.9.

```

DirectoryDataTraining=get(handles.EditDirectoryDataTraining,'String');

BanyakKelas=handles.BKelas;
UkuranSampel=handles.USampel;
baris=handles.DBaris
kolom=handles.DKolom

for sampel=1:UkuranSampel
    Objek=strcat(DirectoryDataTraining,'\ ',int2str(sampel),'.jpg');
    ObjekProses=imread(Objek);
    ObjekProses=imresize(ObjekProses,[baris,kolom]);
    Data_y(sampel,1:baris*kolom)=reshape(ObjekProses,1,baris*kolom);
end

```

Gambar 4.8. Potongan *code* ekstraksi fitur *image* (sumber:Santoso, 2016)

```

[Klasifikasi,CM,ProsentaseErrorKlas_NBC,Mean_G,Sigma2_G]=TrainingNBC(Data_y,Data_c)
set(handles.LBKlasifikasi,'String',num2str(Klasifikasi));
set(handles.LBCM,'String',num2str(CM));
set(handles.EError,'String',num2str(100-ProsentaseErrorKlas_NBC));
set(handles.LBPmeanPaxi,'String',num2str(Mean_G));
set(handles.LBPcovPaxi,'String',num2str(Sigma2_G));

```

Gambar 4.9. Potongan *code* *training* NBC(sumber:Santoso, 2016)

4.1.5 Estimasi Parameter NBC

Estimasi parameter untuk NBC pada dasarnya adalah estimasi parameter distribusi fitur *image* hasil dari optimalisasi dengan menggunakan metode interpolasi. Bila diasumsikan setiap fitur *image* mengikuti distribusi normal maka parameter yang diestimasi adalah *mean* dan standar deviasi (*varians*). Gambar 4.10 adalah *code* fungsi untuk melakukan estimasi parameter distribusi fitur *image* dengan asumsi berdistribusi normal.

```

function [ParameterMean,ParameterSigma2]=EstimasiParameterG(DataKelas,BanyakKelas);

for kelas=1:BanyakKelas
    temp=cov(DataKelas(:, :, kelas));
    ParameterCova(:, :, kelas)=temp;
    ParameterMean(kelas, :)=mean(DataKelas(:, :, kelas));
end
[a,d]=size(ParameterCova(:, :, 1));
for kelas=1:BanyakKelas
    for i=1:d
        ParameterSigma2(kelas,i)=ParameterCova(i,i,kelas);
    end
end

```

Gambar 4.10 *Code* estimasi parameter

Input dalam fungsi tersebut adalah `DataKelas` dan `BanyakKelas`, sedangkan output fungsi tersebut adalah `ParameterMean` dan `ParameterSigma2`. `DataKelas` merupakan data *image training* dalam bentuk nilai hasil interpolasi yang sudah dikumpulkan pada setiap kelasnya, sedangkan `BanyakKelas` merupakan banyak kelas/label *image training*. Output `ParameterMean` merupakan hasil estimasi parameter mean dan `ParameterSigma2` adalah hasil dari estimasi parameter varians.

4.1.6 Membangun Fungsi Diskriminan NBC

Fungsi diskriminan NBC pada dasarnya fungsi untuk mengatasi persoalan komputasi terhadap nilai variabel yang sangat kecil atau mendekati nol disamping untuk mempermudah klasifikasi *image*. Dengan merujuk pada persamaan 3.1, selanjutnya dapat dibuat implementasi fungsi tersebut dengan code seperti pada Gambar 4.11.

```
for j=1:C
    pw=nj(j)/ntot;
    SlogSigma=0;
    x_mu2divSigma2=0;
    for i=1:d
        x_mu=x(1,i)-mu(j,i);
        SlogSigma=SlogSigma+log(sqrt(sigma2(j,i)));
        x_mu2divSigma2=x_mu2divSigma2+ (x_mu^2)/sigma2(j,i);
    end
    gjx(j)=log(pw)-SlogSigma-0.5*x_mu2divSigma2;
end
```

Gambar 4.11 Code fungsi diskriminan NBC

`gix` pada *code* tersebut menunjukkan fungsi diskriminan untuk setiap kelas/label yang selanjutnya digunakan sebagai dasar klasifikasi *image*. Dengan mendapatkan nilai `gix` yang paling besar ($\text{argmax}(gix)$), kita dapat menentukan bahwa *image* tersebut di kategorikan pada kelas/labels dengan `gix` yang bersesuaian.

4.1.7 Mengukur Tingkat Performansi

Mengukur tingkat performansi dari metode yang diusulkan salah satunya dapat dilakukan dengan mengukur sejauhmana tingkat akurasi metode tersebut terhadap metode lain. Dalam menentukan tingkat akurasi dalam klasifikasi (*correct classification*) *image*, sebaiknya

terlebih dahulu dibuat matrik *confusion* sehingga mempermudah dalam menghitung tingkat akurasi. Code untuk menentukan matrik *confusion* selanjutnya dapat dilihat pada Gambar 4.12. Hasil dari proses tersebut, matrik *confusion* yang dihasilkan diberi nama CM, sedangkan untuk menentukan tingkat akurasi dilakukan dengan menggunakan nilai $\text{ProsentaseErrorKlas_NBC} = 100 - \text{ProsentaseErrorKlas_NBC}$, lihat Gambar 4.12 dan Gambar 4.6

```
[CM, CH, P]=crosstab(Data_c(:), klasifikasi_NBC(:));
CM
save('HasilTraining\CM.mat', 'CM');

ErrorKlas_NBC=0;
for i=1:N
    Hasil=[i Data_c(i) klasifikasi_NBC(i)];
    if Data_c(i)~=klasifikasi_NBC(i)
        ErrorKlas_NBC=ErrorKlas_NBC+1;
    end
end

ProsentaseErrorKlas_NBC=(ErrorKlas_NBC)*100/N
```

Gambar 4.12 Code menentukan matrik *confusion* dan *error* dalam klasifikasi *image*

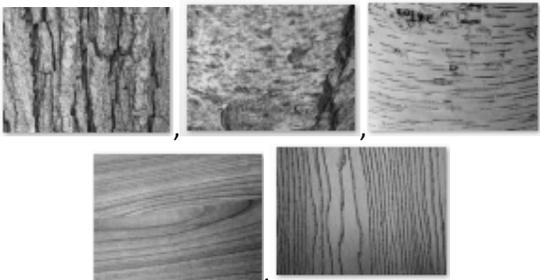
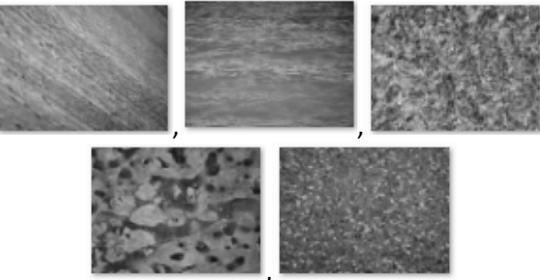
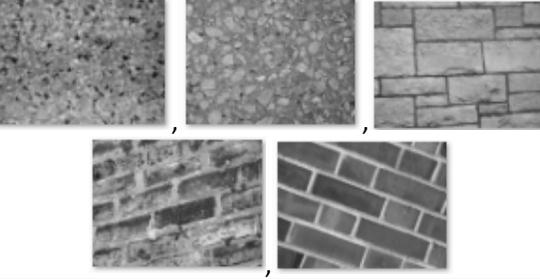
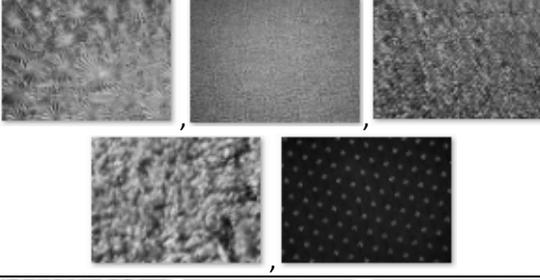
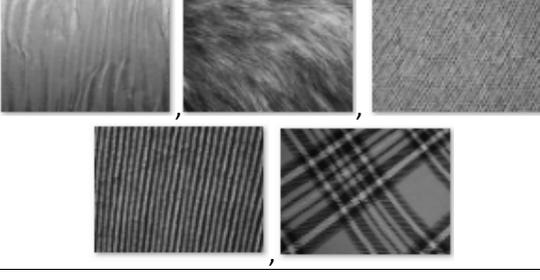
4.2 Skenario Uji Coba dengan Data Benchmark

Skenario uji coba dilakukan untuk mengetahui sejauhmana tingkat performansi metode yang diusulkan. Pengujian metode tersebut dilakukan dengan menggunakan data *benchmark CVonline image database* dan data hasil penelitian laboratorium Komputer Vision Teknik Informatika UIN Malang. Adapun skenario uji coba merujuk pada bab sebelumnya (lihat BAB III).

4.2.1 Image Texture : CVOnline Image Database

Data *image texture* yang digunakan untuk menguji tingkat performansi metode yang diusulkan seperti pada Tabel 4.1. Dari data tersebut akan diujicoba dengan membangun NBC yang melibatkan masing 5 kelas dan seluruh kelas (T01-T25) dengan perlakuan seperti pada tabel 4.1 dan yang lainnya. Pada masing-masing ujicoba atau eksperimen akan dibangun NBC dengan optimalisasi dengan metode interpolasi (*nearest neighbor, bilinear, bicubic dan lanczos*).

Table 4.1 Data *image texture* untuk uji coba optimalisasi metode interpolasi terhadap *naïve bayes classifier*(NBC)

image texture	Labels/class	sample	Example of image texture
T01-T05	5 (bark1, bark2, bark3, wood1, wood2)	200	
T06-T10	5 (wood3, water, granite, marble, floor1)	200	
T11-T15	5 (floor2, pebbles, wall, brick1, brick2)	200	
T16-T20	5 (glass1, glass2, carpet1, carpet2, uphostery)	200	
T21-T25	5 (wallpaper, fur, knit, cordury, plaid)	200	

T01-T25	25 (wood3, water, granite, marble, floor1, wood3, water, granite, marble, floor1, floor2, pebbles, wall, brick1, brick2, glass1, glass2, carpet1, carpet2, upholstery, wallpaper, fur, knit, cordury, plaid)	1000	
---------	---	------	---

Skenario uji coba data *benchmark* pada penelitian ini meliputi: **pertama**, dengan menggunakan *image* T01-T05 kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **kedua**, dengan menggunakan *image* T06-T10 kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **ketiga**, dengan menggunakan *image* T11-T15 kemudian dilakukan optimalisasi dimensi *image training*

menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **kempat**, dengan menggunakan *image* T16-T20 kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **kelima**, dengan menggunakan *image* T21-T25 kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, dan **keenam**, dengan menggunakan *image* T01-T25 kemudian dilakukan optimalisasi dimensi *image training* dengan menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos* dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi (lihat Tabel 4.2).

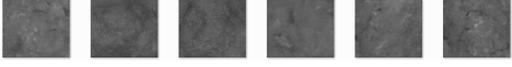
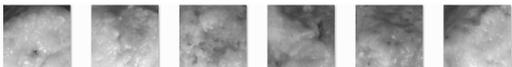
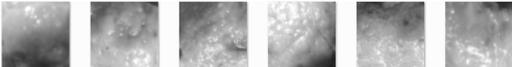
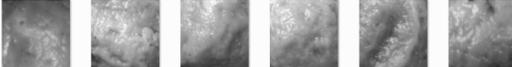
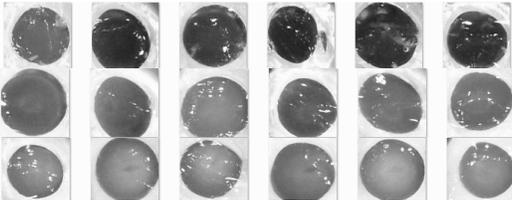
Table 4.2 Uji coba optimalisasi metode interpolasi terhadap *naïve bayes classifier*(NBC)

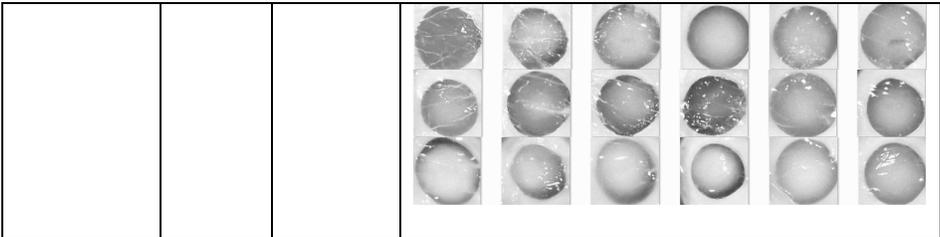
image texture	Size of feature based interpolation value (optimal)				Accuracy of NBC			
	Nearest Neighbor	Bilinear	Bicubic	Lanczos	Nearest Neighbor	Bilinear	Bicubic	Lanczos
T01-T05								
T06-T10								
T11-T15								
T16-T20								
T21-T25								
T01-T25								

4.2.2 Image Hasil Eksperimen Laboratorium Computer Vision Teknik Informatika UIN Malang

Data *image* hasil eksperimen laboratorium Computer Vision Teknik Informatika UIN Malang yang digunakan untuk menguji tingkat performansi metode yang disulkan seperti pada Tabel 4.3. Dari data tersebut akan diujicoba dengan membangun NBC yang melibatkan masing beberapa kelas dan seluruh kelas dengan perlakuan seperti pada tabel 4.3 dan yang lainnya. Pada masing-masing ujicoba atau eksperimen akan dibangun NBC dengan optimalisasi dengan metode interpolasi (*nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*).

Table 4.3 Data *image* laboratorium *Computer Vision* untuk uji coba optimalisasi metode interpolasi terhadap *naïve bayes classifier*(NBC)

image	Label/ kelas	Sampel	Example of image texture
Bakso (meatball) dengan alat			
1234	4	60	1.  2.  3.  4. 
1=bakso non-boraks, 2=bakso boraks 1%, 3=bakso boraks 3%, 4=bakso boraks 5%			
Bakso (meatball) tanpa alat			
12345	5	150	1.  2.  3.  4.  5. 
1=bakso non-boraks, 2=bakso boraks 0.5%, 3=bakso boraks 1%, 4=bakso boraks 3%, 5=bakso boraks 5%			
Mata ikan bandeng tanpa formalin dan dengan formalin			
12	2	180	1.  2.



1=ikan bebas formalin, 2=ikan mengandung formalin

Ruang Terbuka Hijau (RTH) dan non-RTH Kota Malang

12	2	140
		<p>1.</p> <p>2.</p>

1=rth(jalur hijau, sempadan sungai, makam, hutan kota), 2=non-rth(rumah,gedung/kantor,jalan,lapangan)

Skenario uji coba data *benchmark* pada penelitian ini meliputi: **pertama**, dengan menggunakan *image* Bakso (meatball) dengan alat kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **kedua**, dengan menggunakan *image* Bakso (meatball) tanpa alat kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, **ketiga**, dengan menggunakan *image* Mata ikan bandeng tanpa formalin dan dengan formalin kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi, dan **kempat**, dengan menggunakan *image* Ruang Terbuka Hijau (RTH) dan non-RTH Kota Malang kemudian dilakukan optimalisasi dimensi *image training* menggunakan interpolasi *nearest neighbor*, *bilinear*, *bicubic* dan *lanczos*, dan selanjutnya menentukan nilai akurasi NBC untuk masing-masing metode interpolasi (lihat Tabel 4.4).

Table 4.4 Uji coba optimalisasi metode interpolasi terhadap *naïve bayes classifier*(NBC)

image	Size of feature based interpolation value (optimal)				Accuracy of NBC			
	Nearest Neighbor	Bilinear	Bicubic	Lanczos	Nearest Neighbor	Bilinear	Bicubic	Lanczos
Bakso (meatball) dengan alat								
1234								
1=bakso non-boraks, 2=bakso boraks 1%, 3=bakso boraks 3%, 4=bakso boraks5%								
Bakso (meatball) tanpa alat								
12345								
1=bakso non-boraks, 2=bakso boraks 0.5%, 3=bakso boraks 1%, 4=bakso boraks3%,5=bakso boraks5%								
Mata ikan bandeng tanpa formalin dan dengan formalin								
12								
1=ikan bebas formalin, 2=ikan mengandung formalin								
Ruang Terbuka Hijau (RTH) dan non-RTH Kota Malang								
12								
1=rth(jalur hijau, sempadan sungai, makam, hutan kota), 2=non-rth(rumah,gedung/kantor,jalan,lapangan)								

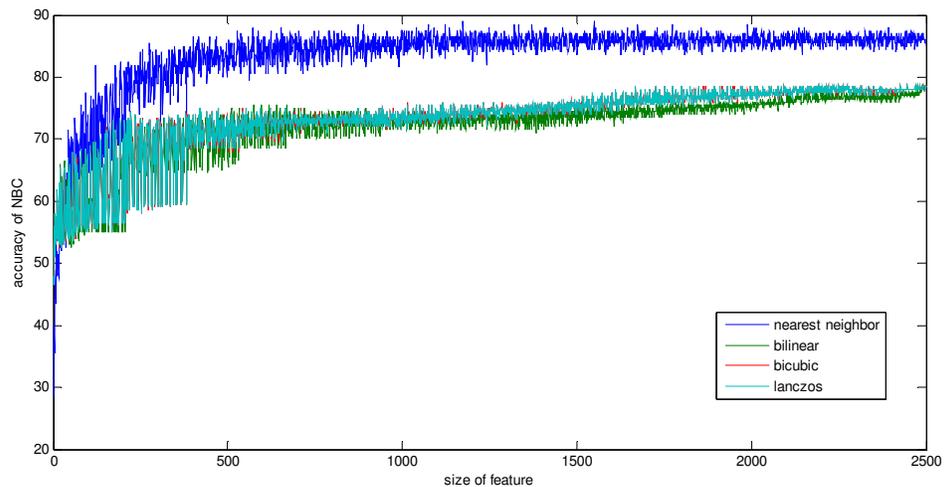
4.3 Uji Coba Sistem

Secara garis besar ujicoba sistem meliputi dua bagian yaitu pertama, optimalisasi dimensi *image* dengan metode interpolasi dan kedua, menentukan akurasi NBC dalam mengklasifikasikan *image benchmark*. Untuk mendapatkan dimensi (*size*) *image training*

yang optimal, dilakukan proses optimalisasi dengan melakukan iterasi berbagai variasi dimensi *image*. Untuk eksperimen dalam penelitian ini dibatasi maksimum dimensi baris *image* adalah 50 dan dimensi kolom adalah 50 (50x50), sehingga banyaknya iterasi dalam optimalisasi adalah 2500 sesuai dengan banyaknya kombinasi dimensi *image*. Proses iterasi tersebut dilakukan untuk mendapatkan dimensi *image* (*size of feature*) yang optimal. Adapun kriteria yang digunakan untuk mendapatkan dimensi *image* yang optimal adalah akurasi klasifikasi tertinggi sebagai prioritas pertama, baru kemudian dan *size of image* yang paling kecil. Secara detail hasil dan pembahasan ujicoba ini, dijelaskan sebagai berikut:

1. *Image Texture : CVOnline Image Database*

Untuk skenario pertama dengan menggunakan image texture T01-T05, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.13. Dari Gambar 4.13, nampak pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.

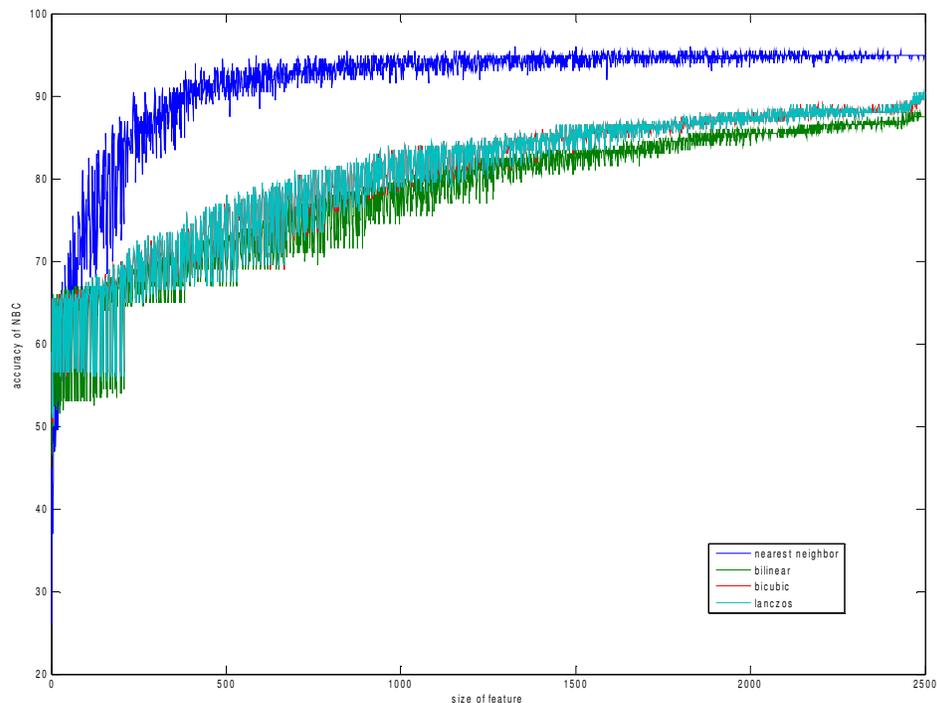


Gambar 4.13 Optimalisasi dimensi image T01-T05 dengan metode interpolasi

Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 14x32 (448) dengan akurasi NBC 89%, *bilinear* pada dimensi 47x49 (2303) akurasi 78.5%,

bicubic pada dimensi 41x50 (2050) akurasi 79% serta *lanczos* pada dimensi 41x50 (2050) akurasi 79.%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

Untuk skenario berikutnya dengan menggunakan image texture T06-T10, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.14. Dari Gambar 4.14, nampak juga pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.



Gambar 4.14 Optimalisasi dimensi image T06-T10 dengan metode interpolasi

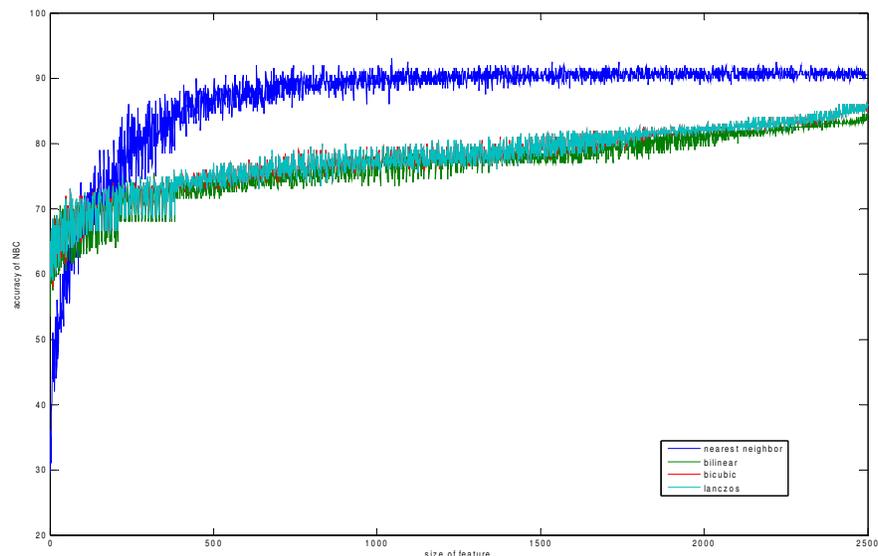
Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 20x27(540) dengan akurasi NBC 96%, *bilinear* pada dimensi 40x50(2000) akurasi 88%, *bicubic* pada dimensi 46x48(2208) akurasi 90.5% serta *lanczos* pada dimensi 45x48(2160) akurasi 90.5%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

Table 4.5 Hasil uji coba optimalisasi dimensi *image texture* dengan metode interpolasi terhadap akurasi *naïve bayes classifier*(NBC)

image texture	Size of feature based interpolation value (optimal)				Accuracy of NBC(%)			
	Nearest Neighbor	Bilinear	Bicubic	Lanczos	Nearest Neighbor	Bilinear	Bicubic	Lanczos
T01-T05	14x32(448)	47x49(2303)	41x50(2050)	41x50(2050)	89.0000	78.5000	79.0000	79.0000
T06-T10	20x27(540)	40x50(2000)	46x48(2208)	45x48(2160)	96.0000	88.0000	90.5000	90.5000
T11-T15	47x8(376)	46x50(2300)	40x48(2208)	40x48(2208)	93.0000	84.5000	86.0000	86.0000
T16-T20	47x42(1974)	4x5(20)	3x3(9)	22x25(550)	100.0000	91.0000	91.0000	91.0000
T21-T25	4x35(140)	27x36 (972)	24x19(456)	23x20(460)	94.0000	89.0000	89.0000	89.5000
T01-T25	34x36(1224)	49x50(2450)	46x50(2300)	49x50(2450)	81.6000	67.2000	68.8000	68.9000

*)maximum size of image in the experiment is 50x50

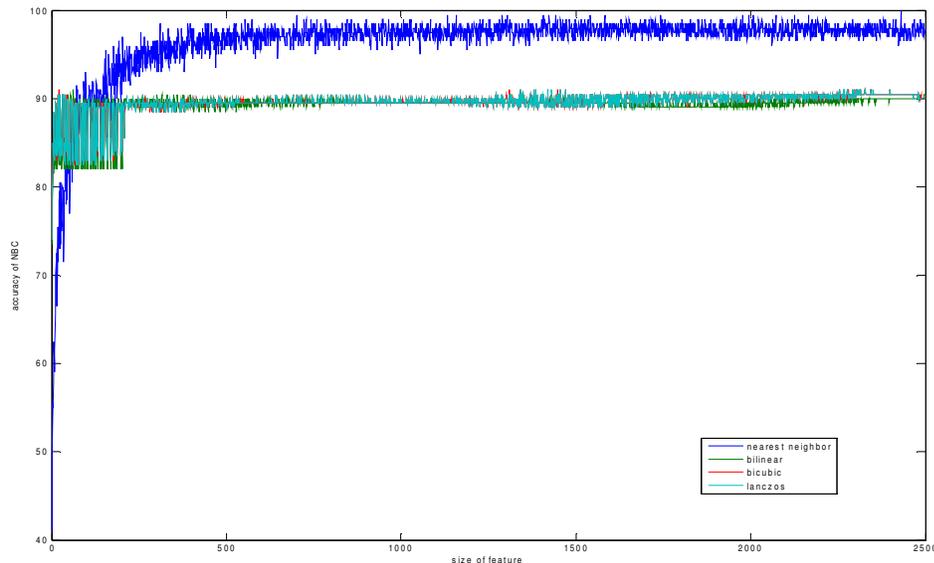
Untuk skenario berikutnya dengan menggunakan image texture T11-T15, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.15. Dari Gambar 4.15, nampak juga pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.



Gambar 4.15 Optimalisasi dimensi image T11-T15 dengan metode interpolasi

Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 47x8(376) dengan akurasi NBC 93%, *bilinear* pada dimensi 46x50(2300) akurasi 84.5%, *bicubic* pada dimensi 40x48(2208) akurasi 86% serta *lanczos* pada dimensi 40x48(2208) akurasi 86%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

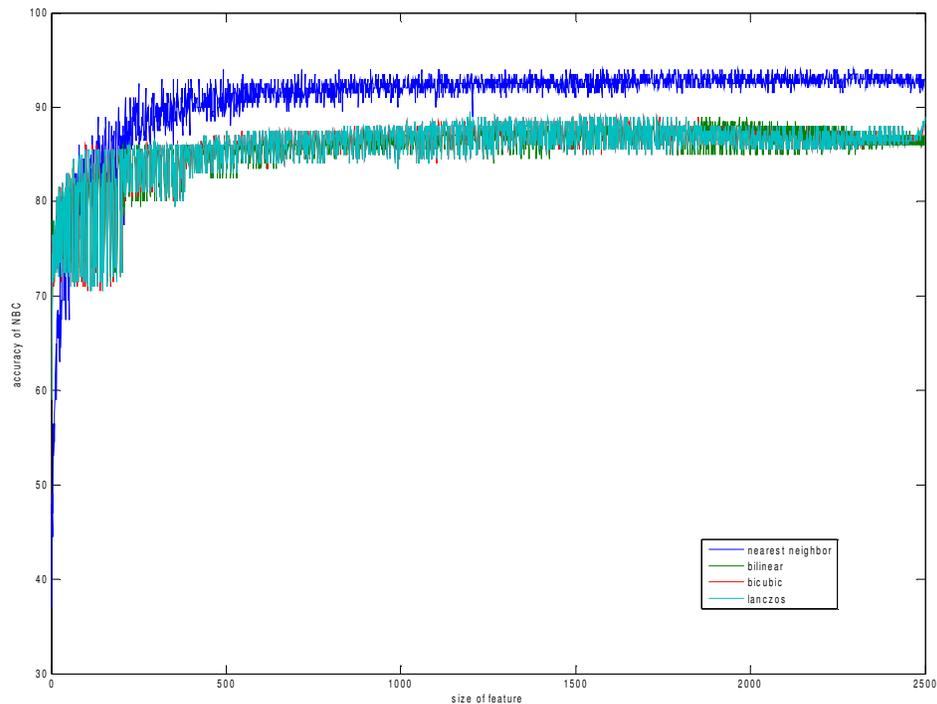
Untuk skenario berikutnya dengan menggunakan image texture T16-T20, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.16. Dari Gambar 4.16, nampak juga pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.



Gambar 4.16 Optimalisasi dimensi image T16-T20 dengan metode interpolasi

Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 47x42(1974) dengan akurasi NBC 100%, *bilinear* pada dimensi 4x5(20) akurasi 91%, *bicubic* pada dimensi 3x3(9) akurasi 91% serta *lanczos* pada dimensi 22x25(550) akurasi 91%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

Untuk skenario berikutnya dengan menggunakan image texture T21-T25, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.17. Dari Gambar 4.17, nampak juga pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.

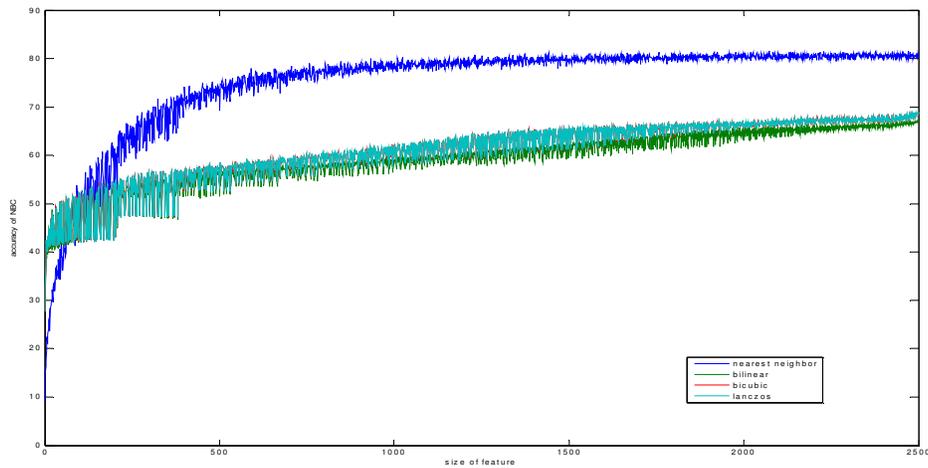


Gambar 4.17 Optimalisasi dimensi *image* T21-T25 dengan metode interpolasi

Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 4x35(140) dengan akurasi NBC 94%, *bilinear* pada dimensi 27x36 (972) akurasi 89%, *bicubic* pada dimensi 24x19(456) akurasi 89% serta *lanczos* pada dimensi 23x20(460) akurasi 89.5%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

Untuk skenario berikutnya dengan menggunakan image texture T01-T25, proses iterasi dalam optimalisasi untuk mendapatkan dimensi *image* yang optimal dapat dilihat pada Gambar 4.18. Dari Gambar 4.18, nampak juga pada dimensi *image* yang paling

kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi, pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Sedangkan untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama dan hasil terburuk diberikan oleh interpolasi *bilinear*.



Gambar 4.18 Optimalisasi dimensi *image* T01-T25 dengan metode interpolasi

Hasil optimalisasi didapatkan bahwa *nearest neighbor* optimal pada dimensi 34x36(1224) dengan akurasi NBC 81.6%, *bilinear* pada dimensi 49x50(2450) akurasi 67.2 %, *bicubic* pada dimensi 46x50(2300) akurasi 68.8% serta *lanczos* pada dimensi 49X50(2450) akurasi 68.9%. Untuk hasil selengkapnya bisa dilihat pada Tabel 4.5.

Sebagai catatan untuk scenario dengan menggunakan *image* original tidak dapat dilaksanakan, karena dimensi *image texture* yang besar yaitu 640x480 sehingga tidak dapat diproses oleh *hardware* yang digunakan untuk ujicoba (out of memory).

2. Image Hasil Eksperimen Laboratorium Computer Vision Teknik Informatika UIN Malang

Untuk data *benchmark image* laboratorium *Computer Vision*, skenario uji yang bisa dilaksanakan hanya pada skenario pertama saja mengingat waktu keterbatasan waktu dan hardware dalam eksperimen. Hasil uji coba untuk skenario pertama dengan data *image* bakso dengan alat menunjukkan optimalisasi dengan interpolasi *nearest neighbor* didapatkan dimensi optimal 44x5(220) dengan akurasi 93.33%. Untuk data image bakso

tanpa alat didapatkan dimensi optimal 13x7(91) dengan akurasi 64.667%, data image mata ikan bandeng berformalin atau tidak berformalin didapatkan dimensi optima 7x11(77) dengan akurasi 97.22% dan yang terakhir untuk data RTH dan non-RTH didapatkan dimensi optimal 2x5 dengan akurasi 70.7143%. Hasil ujicoba untuk skenario pertama dapat selengkapnya dilihat pada Tabel 4.6.

Table 4.6 Hasil uji coba optimalisasi dimensi *image* laboratorium *Computer Vision* dengan metode interpolasi terhadap akurasi *naïve bayes classifier*(NBC)

image	Size of feature based interpolation value (optimal)	Accuracy of NBC(%)
	Nearest Neighbor	Nearest Neighbor
Bakso (meatball) dengan alat		
1234	44x5	93.3333
1=bakso non-boraks, 2=bakso boraks 1%, 3=bakso boraks 3%, 4=bakso boraks5%		
Bakso (meatball) tanpa alat		
12345	13x7	64.6667
1=bakso non-boraks, 2=bakso boraks 0.5%, 3=bakso boraks 1%, 4=bakso boraks3%,5=bakso boraks5%		
Mata ikan bandeng tanpa formalin dan dengan formalin		
12	7x11	97.2222
1=ikan bebas formalin, 2=ikan mengandung formalin		
Ruang Terbuka Hijau (RTH) dan non-RTH Kota Malang		
12	2x5	70.7143
1=rth(jalur hijau, sempadan sungai, makam, hutan kota), 2=non-rth(rumah,gedung/kantor, jalan,lapangan)		

BAB V

PENUTUP

5.1 Kesimpulan

Dari hasil dan pembahasan pada bab sebelumnya, dapat dihasilkan beberapa kesimpulan sebagai berikut:

1. Langkah-Langkah untuk mendapatkan dimensi *image training* yang optimal dengan menggunakan metode interpolasi adalah pertama, melakukan *downscaling image training* dengan berbagai ukuran yang memungkinkan. Langkah kedua, membangun NBC untuk setiap ukuran dimensi yang ditentukan. Ketiga, melakukan klasifikasi setiap *image training* untuk setiap ukuran atau dimensi yang telah ditentukan. Keempat, mencari NBC yang memberikan akurasi tertinggi serta dimensi paling kecil. Kelima, simpan atau dapatkan ukuran atau dimensi *image* dengan akurasi NBC tertinggi dan yang keenam mengambil atau menggunakan nilai interpolasi *image* berdasarkan langkah kelima sebagai nilai ekstraksi fitur *image* yang optimal.
2. Hasil ujicoba menunjukkan pada dimensi *image* yang paling kecil metode interpolasi *nearest neighbor* menghasilkan tingkat akurasi NBC paling kecil dibanding interpolasi yang lain, akan tetapi pada dimensi *image* berikutnya nampak sekali interpolasi *nearest neighbor* stabil dengan tingkat akurasi paling baik banding *bilinear*, *bicubic* dan *lanczos*. Untuk interpolasi *bicubic* dan *lanczos* memberikan hasil relatif sama, sedangkan hasil terburuk diberikan oleh interpolasi *bilinear*. Hasil optimalisasi untuk T01-T05 didapatkan bahwa *nearest neighbor* optimal pada dimensi 14x32 (448) dengan akurasi NBC 89%, *bilinear* pada dimensi 47x49 (2303) akurasi 78.5%, *bicubic* pada dimensi 41x50 (2050) akurasi 79% serta *lanczos* pada dimensi 41x50 (2050) akurasi 79%. Untuk T06-T10, didapatkan *nearest neighbor* optimal pada dimensi 20x27(540) dengan akurasi NBC 96%, *bilinear* pada dimensi 40x50(2000) akurasi 88%, *bicubic* pada dimensi 46x48(2208) akurasi 90.5% serta *lanczos* pada dimensi 45x48(2160) akurasi 90.5%. Untuk T11-T15, *nearest neighbor* optimal pada dimensi 47x8(376) dengan akurasi NBC 93%, *bilinear* pada dimensi 46x50(2300) akurasi 84.5%, *bicubic* pada dimensi 40x48(2208) akurasi 86% serta *lanczos* pada dimensi 40x48(2208) akurasi 86%. Untuk T16-T20 *nearest neighbor* optimal pada dimensi 47x42(1974) dengan akurasi NBC 100%, *bilinear* pada dimensi 4x5(20) akurasi 91%, *bicubic* pada dimensi 3x3(9) akurasi 91% serta *lanczos* pada dimensi 22x25(550) akurasi 91%. Untuk T21-T25 *nearest neighbor* optimal pada dimensi 4x35(140) dengan akurasi NBC

94%, *bilinear* pada dimensi 27x36 (972) akurasi 89%, *bicubic* pada dimensi 24x19(456) akurasi 89% serta *lanzcos* pada dimensi 23x20(460) akurasi 89.5% dan untuk T01-T25 *nearest neighbor* optimal pada dimensi 34x36(1224) dengan akurasi NBC 81.6%, *bilinear* pada dimensi 49x50(2450) akurasi 67.2 %, *bicubic* pada dimensi 46x50(2300) akurasi 68.8% serta *lanzcos* pada dimensi 49X50(2450) akurasi 68.9%.

5.2 Saran

Dari hasil dan pembahasan optimalisasi dimensi image dengan metode interpolasi untuk meningkatkan akurasi NBC, didapatkan beberapa saran untuk penelitian berikutnya:

1. Perlu dikembangkan optimalisasi metode interpolasi tidak hanya pada metode *non-adaptive* tetapi juga pada metode interpolasi *adaptive* serta dengan metode klasifikasi yang lain.
2. Perlu adanya penanganan khusus terkait proses komputasi *image* dengan dimensi besar yang terkendala kondisi hardware saat ini.

DAFTAR PUSTAKA

- T.Acharyaa and P. Tsai.(2007),”Computational Foundations of Image Interpolation Algorithms,” ACM Ubiquity Vol. 8.
- P. Bhatt,S. Patel and R. Pandit.(2013), “Comparative Analysis of Interpolation and Texture Synthesis Method for Enhancing Image,” International Journal of Innovative Research in Science, Engineering and Technology, Vol. 2, Issue 1.
- D. Domingos and M.Pazzani.(1997), “On the optimality of the simple Bayesian classifier under zero-one loss,” Machine Learning 29(1997), 103-130.
- M.Ekdahl and T.Koski, (2006), “Bound for the loss in probability of correct classification under model based approximation,” Journal of Machine Learning Research 7(2006),2449-2480.
- Gonzalez, R. C., Woods, R. E. & Eddins, S. L. (2009). “Digital image processing using MATLAB,” Gatesmark Publishing Tennessee.
- M.Hall.(2007), “A decision tree-based attribute weighting filter for naïve Bayes,” Knowledge-Based Systems 20,2(2007),120-126.
- D.J. Hand and K.Yu.(2001). “Idiot’s Bayes-not so stupid after all?,” International Statistical Review 69,3(2001), 385-398.
- F.M.Hadini.(2016), “Sistem Pendeteksi Ikan Bandeng (Chanos chanos) Berformalin Berbasis Android Berdasarkan Image Mata Menggunakan Metode Naïve Bayes Classifier,” Skripsi Jurusan Teknik Informatika. Tidak dipublikasi.
- G. Jeon. (2013), “Window Size Zooming for Lower Resolution Contents, International Journal of Software Engineering and Its Applications,” Vol.7, No.5 (2013), pp.325-336. Available: <http://dx.doi.org/10.14257/ijseia.2013.7.5.28>
- C.K.Kwoh and D.Gilles.(1996), “Using hidden nodes in Bayesian network,” Artificial Intelligence 88(1996), 1-38
- P. Langley and S. Sage.(1994), “Induction of selective Bayesian classifiers,” In Proceeding of the 10th Conference on Uncertainty in Artificial Intelligence(UAI-1994).Morgan Kaufmann, 399-406.
- S.Lazebnik, C.Schmid, and J.Ponce. (2003), “The texture database,” *CVonline image database*
- M. Maron and J.Kuhn.(1960), “On relevance, propabilistic indexing, and information retrieval,” Journal of Association for Computing Machinery 7(1960),216-244.
- M. Minsky. (1961), “Steps toward artificial intelligence,” Transaction on Institue of Radio Engineers (1961), 8-30.

- M.Muja and D.G.Lowe.(2014),”Scalable Nearest Neighbor Algorithms for High Dimensional Data,” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 36, No. 11.
- M. Nixon and A.Aguado.(2008), “Feature Extraction and Image Processing.” Second Edition. Elsevier ltd.
- G.N.Noren and R.Orre.(2005), “Case based imprecision estimates for Bayes classifiers with the Bayesian bootstrap,” Machine Learning 58,1(2005),79-94
- R. Olivier and C. Hanqiang.(2012),”Nearest Neighbor Value Interpolation,” (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 3, No. 4.
- Pablo B. et al. (2014), “Speeding up incremental wrapper feature subset selection with Naïve Bayes classifier, Knowledge-Based Systems,” Elsevier 55. 140–147.
- C.Pamarthy, V.Vishnupriya, K.Anjali, P. Jayasree and R.Prindhvi. (2014), “A Novel Methods for Satellite Image Contrast Enhancement Using Interpolation,” International Journal of VLSI and Embedded Systems, Vol 5. Pp. 934-938.
- J.A.Parker, R.V.Kenyon and D.E.Troxel.(1983), “Comparison of Interpolating Methods for Image Resampling,” IEEE Transaction on Medical Imaging, Vol.M1-2,No.1
- J.Parkkinen, M.Haukijärvi and P.Nenonen.(2009),”A Fast Method for Scaling Color Image,” 17th European Signal Processing Conference (EUSIPCO 2009) Glasgow, Scotland.
- P.Parsania and P. V.Virparia.(2014),” A Review: Image Interpolation Techniques for Image Scaling International Journal of Innovative Research in Computer and Communication,” (An ISO 3297: 2007 Certified Organization) Vol. 2, Issue 12, Engineering
- S.D.Purwanto.(2016), “Rancang Bangun Sistem Identifikasi Kandungan Boraks pada Citra Bakso Daging Sapi Berbasis Android Menggunakan Algoritma Naïve Bayes Classifier,” Skripsi Jurusan Teknik Informatika. Tidak dipublikasi
- A. Prajapati, S.Naik and S.Mehta. (2012), “Evaluation of Different Image Interpolation Algorithms,” International Journal of Computer Applications (0975 – 8887) Volume 58– No.12 .
- Safinaz.S. (2014),”An Efficient Algorithm for Image Scaling with High Boost Filtering, International Journal of Scientific and Research Publications,” Volume 4, Issue 5, ISSN 2250-3153
- I.B.Santoso.(2014), “Deteksi Boraks pada Bakso Berbasis Image dengan Menggunakan Tree-Augmented Bayesian Network (TAN),” Penelitian Kompetitif Dosen LP2M UIN Malang.
- I.B.Santoso.(2015), “Deteksi dan Segmentasi Ruang Terbuka Hijau Kota Malang Berbasis Citra Google Earth dengan Menggunakan Tree-Augmented Naïve Bayesian Network dan K-Means,” Penelitian Kompetitif Dosen LP2M UIN Malang.
- A.R.Webb and K.D. Cospey. (2011),” Statistical Pattern Recognition,” Third Edition. John Wiley & Sons, Ltd

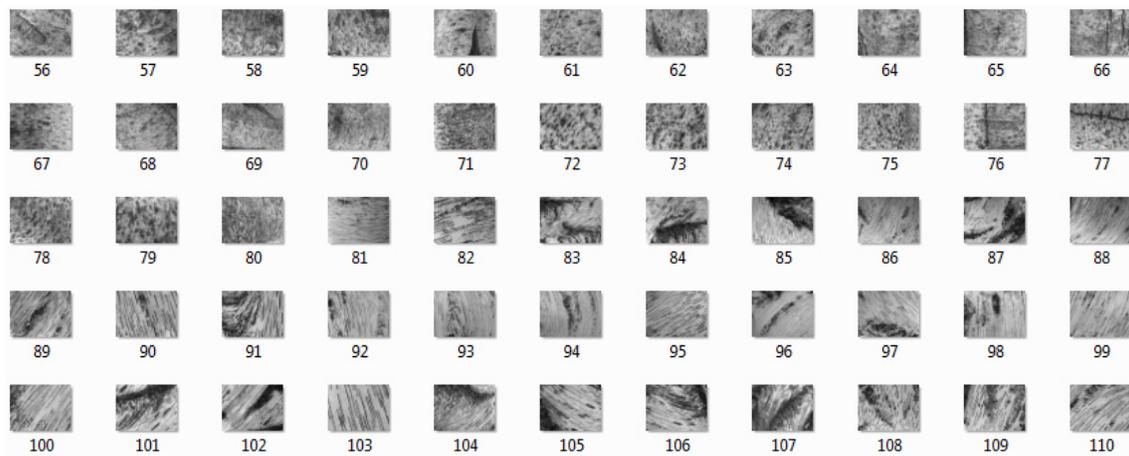
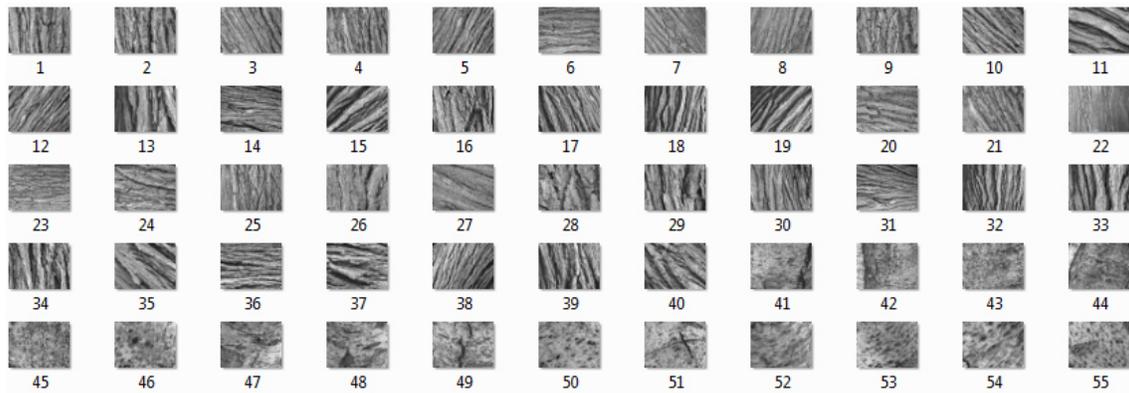
T.T.Wong.(2009), "Alternative prior assumptions for improving the performance of naïve Bayesian classifiers." Data Mining and Knowledge Discovery 18,2(2009), 183-213

LAMPIRAN

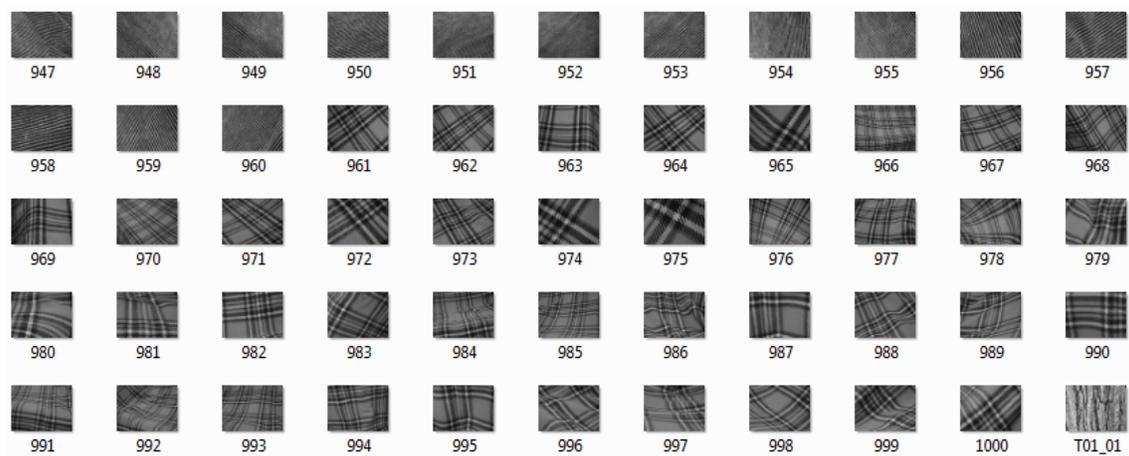
1. Data benchmark

Image Texture CVonline database

T01-T25



.....



2. Iterasi Optimalisasi Dimensi Image dengan Metode Interpolasi

Interpolasi Nearest Neighbor

T01-T05

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT01-05(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
  14  32  89
  41  17  89
-----dimensi yang optimal-----
terpilih =
  14  32  89
```

T06-T10

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT06-10(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
  20  27  96
  22  30  96
  23  41  96
-----dimensi yang optimal-----
terpilih =
  20  27  96
```

T11-T15

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT11-15(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
  47   8  93
-----dimensi yang optimal-----
terpilih =
  47   8  93
```

T16-T20

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT16-20(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
  47  42  100
-----dimensi yang optimal-----
terpilih =
  47  42  100
```

T21-T25

User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICоба\HasilOptimalisasiT21-25(1X50,1X50).mat

-----nilai akurasi tertinggi-----

----baris----kolom----akurasi----

Kterpilih =

4	35	94
8	28	94
10	27	94
10	31	94
10	41	94
12	32	94
12	34	94
18	40	94
18	44	94
18	49	94
18	50	94
19	41	94
21	34	94
21	36	94
21	41	94
21	49	94
22	33	94
22	36	94
23	39	94
23	45	94
24	34	94
24	39	94
27	21	94
28	28	94
28	36	94
29	18	94
30	24	94
30	33	94
30	36	94
30	39	94
30	41	94
30	50	94
31	41	94
32	20	94
32	24	94
32	34	94
32	50	94
33	41	94
34	39	94
34	46	94
35	27	94
35	34	94
35	36	94
35	43	94
38	17	94
38	28	94
38	29	94
38	36	94
38	38	94
39	29	94
39	30	94
39	31	94
39	34	94
39	43	94
41	17	94
41	22	94

```
41 33 94
41 41 94
44 19 94
44 22 94
44 34 94
44 39 94
45 33 94
46 34 94
46 41 94
47 34 94
47 36 94
47 39 94
48 31 94
49 12 94
50 26 94
-----dimensi yang optimal-----
terpilih =
 4 35 94
```

T01-T25

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT01-
25(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
 34.0000 36.0000 81.6000
 48.0000 45.0000 81.6000
-----dimensi yang optimal-----
terpilih =
 34.0000 36.0000 81.6000
```

T01-T02

```
User selected E:\IRWAN\PENELITIAN\LP2M\2017\HASIL_UJICOBA\HasilOptimalisasiT01-
02(1X50,1X50).mat
-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
 9 17 95
 22 10 95
 24 10 95
-----dimensi yang optimal-----
terpilih =
 9 17 95
```

T01-T03

```
-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
 8.0000 21.0000 93.3333
-----dimensi yang optimal-----

terpilih =
 8.0000 21.0000 93.3333
```

T01-T04

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
8.0000 21.0000 93.7500
13.0000 15.0000 93.7500
26.0000 8.0000 93.7500
-----dimensi yang optimal-----
terpilih =
8.0000 21.0000 93.7500

T01-T05

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
14 32 89
41 17 89
-----dimensi yang optimal-----
terpilih =
14 32 89

T01-T06

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
41.0000 17.0000 87.9167
-----dimensi yang optimal-----
terpilih =
41.0000 17.0000 87.9167

T01-T07

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
17.0000 47.0000 88.5714
30.0000 19.0000 88.5714
41.0000 17.0000 88.5714
-----dimensi yang optimal-----
terpilih =
30.0000 19.0000 88.5714

T01-T08

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
30.0000 19.0000 89.0625
46.0000 21.0000 89.0625
-----dimensi yang optimal-----
terpilih =
30.0000 19.0000 89.0625

T01-T09

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----
Kterpilih =
41.0000 17.0000 86.6667
-----dimensi yang optimal-----

terpilih =
41.0000 17.0000 86.6667

T01-T10

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
30.0000 19.0000 86.5000
-----dimensi yang optimal-----
terpilih =
30.0000 19.0000 86.5000

T01-T11

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
30 19 85
47 19 85
-----dimensi yang optimal-----
terpilih =
30 19 85

T01-T12

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
26.0000 27.0000 85.4167
30.0000 19.0000 85.4167
47.0000 19.0000 85.4167
-----dimensi yang optimal-----
terpilih =
30.0000 19.0000 85.4167

T01-T13

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
26.0000 27.0000 86.1538
-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 86.1538

T01-T14

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
26.0000 27.0000 86.7857
-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 86.7857

T01-T15

-----nilai akurasi tertinggi-----

----baris---kolom---akurasi---
Kterpilih =
26.0000 27.0000 83.1667
-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 83.1667

T01-T16*

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi---
Kterpilih =
35.0000 37.0000 82.6563
38.0000 35.0000 82.6563
-----dimensi yang optimal-----
terpilih =
35.0000 37.0000 82.6563

T01-T17

-----nilai akurasi tertinggi-----
---baris---kolom---akurasi---
Kterpilih =
26.0000 35.0000 82.6471
38.0000 35.0000 82.6471
-----dimensi yang optimal-----
terpilih =
26.0000 35.0000 82.6471

T01-T18

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi---
Kterpilih =

26.0000 27.0000 81.9444
26.0000 35.0000 81.9444
38.0000 35.0000 81.9444

-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 81.9444

T01-T19

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi---
Kterpilih =
26.0000 27.0000 81.9737
-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 81.9737

T01-T20

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi---
Kterpilih =
26.0000 27.0000 82.8750
-----dimensi yang optimal-----
terpilih =
26.0000 27.0000 82.8750

T01-T21

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi---

Kterpilih =
26.0000 46.0000 82.0238
-----dimensi yang optimal-----
terpilih =
26.0000 46.0000 82.0238

T01-T22
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
29.0000 45.0000 81.5909
34.0000 36.0000 81.5909
-----dimensi yang optimal-----
terpilih =
34.0000 36.0000 81.5909

T01-T23
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
34.0000 36.0000 80.3261
-----dimensi yang optimal-----
terpilih =
34.0000 36.0000 80.3261

T01-T24
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----
Kterpilih =
34.0000 36.0000 81.1458
-----dimensi yang optimal-----
terpilih =
34.0000 36.0000 81.1458

Interpolasi bilinear

T01-T05
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

47.0000 49.0000 78.5000
47.0000 50.0000 78.5000
48.0000 49.0000 78.5000
48.0000 50.0000 78.5000
49.0000 49.0000 78.5000
49.0000 50.0000 78.5000
50.0000 49.0000 78.5000
50.0000 50.0000 78.5000

-----dimensi yang optimal-----
terpilih =

47.0000 49.0000 78.5000

T06-T10

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

40	50	88
41	50	88
42	50	88
43	50	88
44	47	88
44	48	88
45	47	88
46	47	88
46	48	88
47	47	88
48	44	88
48	45	88
50	45	88
50	46	88

-----dimensi yang optimal-----

terpilih =

40	50	88
----	----	----

T11-T15

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

46.0000	50.0000	84.5000
47.0000	50.0000	84.5000
48.0000	50.0000	84.5000
49.0000	50.0000	84.5000
50.0000	50.0000	84.5000

-----dimensi yang optimal-----

terpilih =

46.0000	50.0000	84.5000
---------	---------	---------

T16-T20

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

4	5	91
---	---	----

-----dimensi yang optimal-----

terpilih =

T21-T25

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----

Kterpilih =

26 38 89
27 36 89
27 37 89
27 38 89
28 39 89
28 40 89

-----dimensi yang optimal-----

terpilih =

27 36 89

T01-T25

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----

Kterpilih =

49.0000 50.0000 67.2000

-----dimensi yang optimal-----

terpilih =

49.0000 50.0000 67.2000

Interpolasi bicubic

T01-T05

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----

Kterpilih =

41 50 79

-----dimensi yang optimal-----

terpilih =

41 50 79

T06-T10

-----nilai akurasi tertinggi-----
----baris---kolom---akurasi----

Kterpilih =

46.0000 48.0000 90.5000
47.0000 48.0000 90.5000
50.0000 48.0000 90.5000
50.0000 50.0000 90.5000

-----dimensi yang optimal-----

terpilih =

46.0000 48.0000 90.5000

T11-T15

-----nilai akurasi tertinggi-----

----baris----kolom----akurasi----

Kterpilih =

40 48 86
40 49 86
40 50 86
41 48 86
41 49 86
41 50 86
42 48 86
42 49 86
42 50 86
43 48 86
43 49 86
43 50 86
44 49 86
44 50 86
45 50 86
46 50 86
47 50 86
48 50 86
49 50 86
50 50 86

-----dimensi yang optimal-----

terpilih =

40 48 86

T16-T20

-----nilai akurasi tertinggi-----

----baris----kolom----akurasi----

Kterpilih =

3 3 91
22 24 91
22 25 91
22 29 91
23 27 91
24 24 91
24 25 91
25 25 91
33 46 91
34 46 91
35 44 91
38 41 91

38 42 91
38 43 91
38 44 91
39 41 91
40 41 91
42 38 91
43 38 91
44 38 91
45 38 91
46 35 91
49 33 91
49 35 91
49 38 91

-----dimensi yang optimal-----

terpilih =

3 3 91
T21-T25

-----nilai akurasi tertinggi-----

----baris----kolom----akurasi----

Kterpilih =

19 25 89
20 24 89
20 34 89
21 24 89
21 33 89
21 34 89
21 35 89
22 22 89
22 23 89
22 24 89
22 32 89
22 33 89
22 34 89
22 35 89
23 21 89
23 22 89
23 23 89
23 24 89
23 29 89
23 30 89
23 31 89
23 32 89
23 33 89
23 34 89
23 35 89
23 36 89
24 19 89
24 22 89
24 23 89
24 24 89
24 28 89
24 29 89
24 30 89
24 31 89
24 32 89
24 33 89

24 34 89
24 35 89
24 36 89
24 37 89
25 26 89
25 27 89
25 28 89
25 29 89
25 30 89
25 31 89
25 32 89
25 33 89
25 34 89
25 35 89
25 36 89
25 37 89
26 25 89
26 33 89
26 34 89
26 37 89

-----dimensi yang optimal-----

terpilih =

24 19 89
T01-T25

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

46.0000 50.0000 68.8000
47.0000 50.0000 68.8000
49.0000 50.0000 68.8000
50.0000 50.0000 68.8000

-----dimensi yang optimal-----

terpilih =

46.0000 50.0000 68.8000

Interpolasi lanczos

T01-T05

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

41 50 79

-----dimensi yang optimal-----

terpilih =

41 50 79
T06-T10

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

45.0000	48.0000	90.5000
46.0000	48.0000	90.5000
46.0000	50.0000	90.5000
47.0000	48.0000	90.5000
47.0000	49.0000	90.5000
49.0000	48.0000	90.5000
49.0000	49.0000	90.5000
50.0000	48.0000	90.5000
50.0000	49.0000	90.5000
50.0000	50.0000	90.5000

-----dimensi yang optimal-----

terpilih =

45.0000	48.0000	90.5000
---------	---------	---------

T11-T15
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

39	50	86
40	48	86
40	49	86
40	50	86
41	48	86
41	49	86
41	50	86
42	48	86
42	49	86
42	50	86
43	48	86
43	49	86
43	50	86
44	49	86
44	50	86
45	50	86
46	50	86
47	50	86
48	50	86
49	50	86
50	50	86

-----dimensi yang optimal-----

terpilih =

40	48	86
----	----	----

T16-T20
-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

21	29	91
22	25	91
22	29	91

24 24 91
24 25 91
25 23 91
25 25 91
33 46 91
35 44 91
36 43 91
37 44 91
38 41 91
38 42 91
38 43 91
38 44 91
39 40 91
39 41 91
40 41 91
42 38 91
42 41 91
43 38 91
44 38 91
45 38 91
49 33 91
49 38 91

-----dimensi yang optimal-----

terpilih =

22 25 91
T21-T25

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

23.0000 20.0000 89.5000

-----dimensi yang optimal-----

terpilih =

23.0000 20.0000 89.5000
T01-T25

-----nilai akurasi tertinggi-----
----baris----kolom----akurasi----

Kterpilih =

49.0000 50.0000 68.9000
50.0000 50.0000 68.9000

-----dimensi yang optimal-----

terpilih =

49.0000 50.0000 68.9000

Biodata Peneliti

Irwan Budi Santoso, M.Kom (Ketua Peneliti)

NIP : 19770103 201101 1 004
Pangkat / jabatan : Lektor/ III - d
Jenis kelamin : Laki-laki
Tmp & tgl lahir : Jombang, 3 Januari 1977
Alamat : Jl. Tirto Taruna III/11, Landungsari, Malang
No Telp / HP : 085732207551
Email : irwan.budi331177@gmail.com
Riwayat pendidikan : S1 Statistika Komputasi ITS (2000)
S2 Teknik Informatika ITS (2007)

Pengalaman penelitian/jurnal/prosiding:

- Perbandingan Struktur Model Tree-Augmented Network (TAN) dengan Estimator Regularized Laten Maximum Entropy (RLME) dan Maximum Likelihood (ML) Untuk Mengenali Objek dengan Fitur Berdistribusi Uniform (Studi Kasus Data Sintesis), Prosiding Seminar Nasional Science, Engineering and Technology (SciETec), Halaman TIF05-1 – TIF05-5, 23-24 Februari 2012, Universitas Brawijaya Malang.
- Model Pengenalan Terbaik Dengan Tree-Augmented Network (TAN) dan Estimator Maximum Likelihood (ML) Berdasarkan Fitur Objek, Jurnal MATICS (jurnal Ilmu Komputer dan Teknologi Informasi UIN Malang), Vol.4. no.5, hal 197-203, Maret 2012.
- Peningkatan Akurasi Sistem Pengenalan Karakter Tulisan Tangan dengan Multi Model Tree-Augmented Network (TAN), Prosiding Seminar Nasional Green Technology UIN Malang 3, Halaman 47, 10 November 2012.
- Comparison of Pearson Correlation And Conditional Mutual Information To Construct Model of Tree-Augmented Network (TAN)(Case study character handwriting recognition), The 4th International Conference Green Technology, Faculty of Science And Technology, Maulana Malik Ibrahim State Islamic University, Malang, 2013
- Deteksi Boraks pada Bakso Berbasis Image dengan Menggunakan Tree-Augmented Bayesian Network (TAN), Penelitian Kompetitif Dosen LP2M UIN Malang, 2014
- Deteksi Objek Nyata (Pada Lingkup: Visualisasi dan Deteksi Objek Nyata pada Lingkungan Hidup), Penelitian Penguatan Program Studi Fakultas Saintek UIN Malang, 2014.
- Deteksi dan Segmentasi Ruang Terbuka Hijau Kota Malang Berbasis Citra Google Earth dengan Menggunakan Tree-Augmented Naïve Bayesian Network dan K-Means, Penelitian Kompetitif Dosen LP2M UIN Malang, 2015
- Deteksi Non-RTH (Ruang Terbuka Hijau) Kota Malang Berbasis Citra Google Earth Dengan Menggunakan Naïve Bayes Classifier, Penelitian Penguatan Program Studi Fakultas Saintek UIN Malang, 2015.

Supriyono, MKom (Anggota Peneliti)

NIDT : 19841010 20160801 1 078
Pangkat / jabatan : Asisten Ahli/ III - B
Jenis kelamin : Laki-laki
Tmp & tgl lahir : Pati, 10 Oktober 1984
Alamat : Jl. Tirtosari Perum Graha Tirta Asri C2 RT.01/RW.09 Desa
Landungsari, Dau, Kab. Malang
No Telp / HP : 081333289554
Email : priyono.mipa@gmail.com
Riwayat pendidikan : S1 Ilmu Komputer UB Tahun Lulus 2009
S2 Teknik Informatika ITS Tahun Lulus 2012

Pengalaman penelitian/Jurnal/Proceeding:

- Pemilihan Kontrol TI Berdasarkan Pendekatan Risiko Dan Expected Monetary Values, ITS Master Thesis, 2010.
- Rancang Bangun Sistem Informasi Penjualan dengan Menerapkan Metode Akuntansi Persediaan Rata-rata, Jurnal MATICS Vol 7, No 2. 2015.
- Penerapan Parallel Computing Untuk Mempercepat Komputasi Pada Aplikasi Transliterasi Aksara Jawa, Konferensi Nasional Informatika (KNIF) 2015
- Sistem Tanya Jawab Menggunakan Web Services, Jurnal MATICS Vol 6, No 2. 2014
- Analisis Pengaruh Perangkat Lunak Accurate Pada Siklus Penjualan, Jurnal MATICS Vol 1, No 1 2014
- Integrasi Web Services Dengan Menggabungkan Perancangan Berorientasi Objek dan SOA Untuk Membangun Sistem e-Learning, Jurnal MATICS Vol 7, No 1 2015
- Kerangka Kerja Pemilihan Kontrol Ti Menggunakan Pendekatan Risiko Dan Expected Monetary Values, JUTI Vol 10, No 1, Januari 2012
- Pengembangan dan Software Testing Aplikasi Tebak Huruf Jawa, Seminar Nasional Teknologi Informatika dan Aplikasinya 2016