

jsinbis-klasifikasi alat musik.doc

WORD COUNT

2925

TIME SUBMITTED

16-JUN-2019 10:18PM

PAPER ID

47922896



Klasifikasi Citra Alat Musik Tradisional dengan Metode *k-Nearest Neighbor, Random Forest*, dan *Support Vector Machine*

Herry Sujaini^{a,*}

^a Program Studi Informatika, Universitas Tanjungpura

Naskah Diterima : 11 Maret 2015; Diterima Publikasi : 13 April 2015

DOI : 10.21456/vol7iss1pp

Abstract

1

In the last decade, non-parametric methods (machine learning based algorithms) are increasingly being used from various applications based on digital image processing. This study aims to compare three non-parametric methods, namely the *k-Nearest Neighbor* (kNN), *Random Forest* (RF), and *Support Vector Machine* (SVM) methods for image classification of traditional musical instruments in Indonesia that are popular among the public, namely: angklung, djembe, gamelan, gong, gordang, kendang, kolintang, rebana, sasando, and serunai. From the results of the experimental classifications using the kNN, RF and SVM methods, the kNN method has the best accuracy. The average precision values of the three methods are 92.1% for kNN, 85.4% for SVM, and 69.4% for RF.

1

Keywords: Classification; musical instrument; *k-Nearest Neighbor*; *Random Forest*; *Support Vector Machine*

Abstrak

Dalam dekade terakhir, metode non-parametrik (algoritma berbasis pembelajaran mesin) semakin banyak dipergunakan dari berbagai aplikasi berbasis pengolahan citra digital. Penelitian ini bertujuan untuk membandingkan tiga metode non-parametrik yaitu Metode *k-Nearest Neighbor* (kNN), *Random Forest* (RF), dan *Support Vector Machine* (SVM) terhadap klasifikasi citra alat musik tradisional di Indonesia yang populer di kalangan masyarakat yaitu : angklung, djembe, gamelan, gong, gordang, kendang, kolintang, rebana, sasando, dan serunai. Dari hasil eksperimen pengklasifikasian dengan metode kNN, RF dan SVM, metode kNN memiliki akurasi yang paling baik. Rata-rata nilai *precision* ketiga metode tersebut berturut-turut adalah 92,1% untuk kNN, 85,4% untuk SVM, dan 69,4% untuk RF.

1

Keywords: Klasifikasi; alat musik; *k-Nearest Neighbor*; *Random Forest*; *Support Vector Machine*

1. Pendahuluan

Proses mengklasifikasikan piksel ke dalam set terbatas dari kelas individu berdasarkan nilai datanya dikenal sebagai klasifikasi citra. Piksel ditetapkan ke kelas tertentu jika memenuhi seperangkat aturan tertentu agar sesuai dengan kelas tersebut. Kelas-kelas tersebut dapat diketahui atau tidak diketahui. Jika pengguna dapat memisahkan kelas-kelas berdasarkan data latih, maka kelas-kelas tersebut diketahui atau tidak diketahui. Secara umum, teknik klasifikasi citra dapat dikategorikan sebagai *parametric* dan *non-parametric*, atau *supervised* dan *unsupervised*, atau *hard classifiers* dan *soft classifiers*. Tergantung pada apakah ada pengetahuan sebelumnya tentang kelas, teknik dibagi menjadi dua kelompok, teknik klasifikasi *supervised* dan *unsupervised*.

Teknik klasifikasi *supervised* membutuhkan data pelatihan yang ditetapkan untuk mengajarkan pengklasifikasi menentukan batas keputusan. Hal ini mengacu pada contoh informasi yang diperlukan dalam sebuah citra, yang dikenal sebagai *training sites* yang kemudian digunakan untuk memperluas deskripsi statistik dari informasi untuk setiap kelas, yang dikenal sebagai *Signature Analysis*. Langkah terakhir adalah mengklasifikasikan citra adalah dengan mencari refleksi untuk setiap piksel dan mengevaluasi kemiripan dengan *signatures* (Beaula et al, 2016).

Data yang diberikan selama analisis *signature*, juga dikenal sebagai fase pelatihan. Data tersebut disimpan dalam file yang disebut file data pelatihan. Fase klasifikasi menggunakan informasi ini untuk mengklasifikasikan citra input (Kalra et al, 2013). Keuntungan dari teknik semacam ini adalah bahwa

*) Penulis korespondensi: hs@untan.ac.id

kesalahan dapat dengan mudah diidentifikasi dan dipecahkan. Satu-satunya kelemahan adalah waktu yang dibutuhkan cukup lama untuk tahap pelatihan (Kurian dan Karunakaran, 2012).

Hu et al. (1994) menyatakan bahwa *unsupervised learning* mengeksplorasi struktur yang mendasari data dan secara otomatis mempartisi mereka berdasarkan data tersebut. Hal ini menghasilkan satu set sentroid yang mewakili prototipe kelas untuk digunakan pada klasifikasi lebih lanjut. Yang dan Chen (2010) membagi *unsupervised*, yang juga dikenal sebagai metode *clustering*, menjadi dua kelompok, yaitu *Hierarchical clustering* dan *Partitioning clustering*. *Hierarchical clustering* mengelompokkan data dengan urutan partisi, sedangkan *Partitioning clustering* membagi data menjadi jumlah *cluster* yang ditentukan sebelumnya. Menurut Haixia Bi et al.. (2017), algoritma dimulai dengan inisialisasi yang dilakukan dengan mengeksekusi aturan segmentasi awal. Selanjutnya, klasifikasi dilakukan dengan menggunakan strategi yang berbeda. Hasil dari teknik ini dapat dijelaskan secara fisik, tetapi akurasi sangat tergantung pada desain algoritma. Teknik ini cepat dan sepenuhnya otomatis.

Teknik klasifikasi citra *parametric* dan *non-parametric* berada di bawah *supervised learning*. Penggolongan parametrik menggunakan kemungkinan aljabar untuk alokasi ke setiap kelas. Beberapa pengklasifikasi parametrik adalah *Bayesian Classifier*, *Naïve Bayes classifier* dan *decision tree*. Parameter yang diperlukan diambil dari data pelatihan. Parameter seperti *mean* dan *co-variance* digunakan dalam pengklasifikasi ini. Klasifikasi non-parametrik digunakan ketika tidak ada fungsi kerapatan yang tersedia. Ini mendekati fungsi kepadatan probabilitas untuk penggunaan lebih lanjut. Beberapa pengklasifikasi non-parametrik adalah *K-Nearest Neighbor*, *Logical Regression* dan *Multilayer Perceptron* (Sonawane dan Dhawale, 2016).

Dalam dekade terakhir, metode non-parametrik (algoritma berbasis pembelajaran mesin) telah mendapatkan banyak perhatian dari aplikasi berbasis pengolahan citra digital. Dalam rentang waktu ini, penggunaan algoritma klasifikasi SVM dan RF meningkat secara signifikan. Artikel yang menggunakan MLC dan ANN telah berfluktuasi sepanjang tahun, tetapi umumnya tetap stabil. Dalam beberapa tahun terakhir (2014, 2015, dan 2017), ada beberapa studi yang menggunakan kNN. SVM dan RF tidak sensitif terhadap *noise* atau *overtraining*, yang menunjukkan kemampuannya dalam berurusan dengan data yang tidak seimbang (Breiman, 2001). Oleh karena itu, di antara metode non-parametrik, SVM dan RF menjadi semakin populer dalam studi klasifikasi citra digital (Adam et al. 2014).

Beberapa studi telah dilaksanakan untuk menemukan algoritma klasifikasi terbaik untuk studi

penggunaan lahan dengan membandingkan kinerja di antara pengklasifikasi ini atau dengan algoritma klasifikasi lainnya. Namun, kesimpulan mereka sangat berbeda. Misalnya, dalam studi oleh Adam et al. (2014) dan Ghosh dan Joshi (2014). SVM dan RF menunjukkan hasil klasifikasi yang serupa. Khatami et al. (2016) menemukan bahwa SVM, kNN, dan RF umumnya mengungguli pengklasifikasi *supervised* tradisional lainnya. Pouteau et al. (2011) membandingkan 6 algoritma pembelajaran mesin (SVM, Naive Bayes, C4.5, RF, Boosted Regression Tree, dan kNN) dengan 6 set data satelit dari berbagai sensor menyatakan bahwa kNN berkinerja lebih baik untuk klasifikasi Landsat-7 ETM +. Heydari dan Mountrakis (2018) mempelajari efek dari pemilihan kelas, ukuran sampel referensi, distribusi kelas referensi, dan genetika heterogenitas menggunakan lima algoritma klasifikasi (Naïve Bayesian, kNN, SVM, Tree ensemble, dan ANN). Mereka menyimpulkan bahwa SVM dan kNN adalah metode klasifikasi terbaik untuk klasifikasi citra Landsat.

Indonesia dikenal dengan negara yang sangat kaya budayanya, termasuk alat musik tradisional yang sangat beragam dan memiliki ciri khas daerah di nusantara. Alat-alat musik tradisional tersebut memiliki bentuk yang khas, tapi tidak jarang pula ditemukan bentuk-bentuk yang mirip diantara alat-alat musik tersebut. Penelitian ini bertujuan untuk membandingkan Metode *k-Nearest Neighbor* (kNN), *Random Forest* (RF), dan *Support Vector Machine* (SVM) terhadap klasifikasi citra alat musik tradisional di Indonesia.

2. Kerangka Teori

24

2.1. Support Vector Machine

Support Vector Machine, juga dikenal sebagai SVM adalah classifier non-parametrik. SVM adalah pengklasifikasi biner dan memisahkan kelas menggunakan batas linear. Klasifikasi ini mengasumsikan bahwa tidak ada informasi sebelumnya tentang cara mengklasifikasikan data. Ini mengoptimalkan penggunaan data pelatihan, yang merupakan keuntungan terbesar dari pengklasifikasi ini daripada pengklasifikasi lain seperti *Maximum Likelihood Classifier* (Niknejad et al. 2014). Kekuatan sebenarnya dari SVM terletak pada ilustrasi kernel karena memfasilitasi pemetaan non-linear ruang input ke ruang fitur (Beaula et al, 2016). Oleh karena itu, pilihan fungsi kernel adalah langkah paling signifikan dalam Support Vector Machine. Beberapa fungsi kernel yang umum digunakan adalah: *Kernel Linear*, *Kernel Polinomial*, dan *Kernel Gaussian*.

Ketika SVM mengoptimalkan penggunaan data pelatihan, ini meningkatkan kecepatan klasifikasi hingga tingkat yang lebih tinggi. Ini juga

meminimalkan kesalahan klasifikasi yang akan terjadi karena asumsi sebelumnya pada data *unsupervised* (Niknejad et al. 2014). Keuntungan utama SVM adalah: memiliki kapasitas generalisasi yang sangat baik, tidak menghadapi masalah overfitting, dan dapat memanfaatkan transformasi non-linear. Kerugian dari pengklasifikasi ini adalah: struktur algoritma yang kompleks dan parameter optimal tidak dapat didefinisikan dengan mudah.

2.2. K-Nearest Neighbor

Pendekatan *K-Nearest Neighbor* (kNN) adalah non-parametrik yang telah digunakan pada awal tahun 1970 dalam aplikasi statistik. Teori dasar di balik kNN adalah bahwa dalam dataset kalibrasi, data sekelompok k hingga sampel uji-ke-rata-rata berikutnya (misalnya G, berbasis resistensi). Dari contoh-contoh, label dikenal sebagai penghitungan rata-rata variabel respon (yaitu, kelas atribut tetangga terdekat) [54,55]. Akibatnya, untuk klasifikasi ini, k memainkan peran penting dalam kinerja kNN, yaitu, itu adalah parameter tuning kunci dari kNN. Parameter ditentukan menggunakan prosedur bootstrap (Akbulut et al, 2017) dan (Wei et al, 2017)

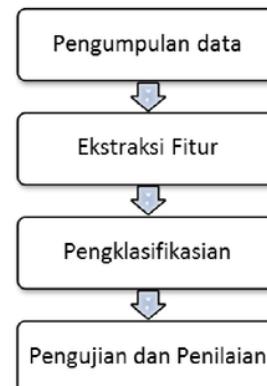
2.3. Random Forest

Breiman (2001) memperkenalkan gagasan mengantongi yang merupakan kependekan dari "bootstrap aggregating". Idenya adalah untuk menggunakan beberapa versi alat prediksi atau klasifikasi untuk membuat keputusan akhir dengan mengambil suara pluralitas di antara para prediktor. Dalam mengantongi, telah terbukti bahwa ketika jumlah prediktor meningkat, akurasi juga meningkat hingga titik tertentu di mana ia turun. Menemukan jumlah prediktor yang optimal untuk menghasilkan akan menghasilkan akurasi tertinggi. Efektivitas pengklasifikasi pohon keputusan untuk klasifikasi tutupan lahan. Mereka mampu meningkatkan akurasi klasifikasi data penginderaan jauh dengan mengantongi menggunakan beberapa pohon keputusan. *Random Forest* ditanam menggunakan kolaborasi prinsip pengemasan dan ID3. Setiap pohon di hutan ditanam dengan cara berikut. Diberikan set pelatihan, subset acak diambil sampelnya (dengan penggantian) dan digunakan untuk membangun pohon yang menyerupai ide ID3. Namun, setiap kasus dalam sampel bootstrap ini tidak digunakan untuk menumbuhkan pohon. Sekitar sepertiga dari bootstrap ditinggalkan dan dianggap sebagai data out-of-bag (OOB). Juga, tidak setiap fitur digunakan untuk membangun pohon. Pilihan fitur acak dievaluasi di setiap node. Data OOB digunakan untuk mendapatkan tingkat kesalahan klasifikasi karena pohon ditambahkan ke forest dan untuk mengukur variabel input (fitur) penting. Setelah forest selesai, sebuah kasus dapat

diklasifikasi dengan mengambil suara terbanyak di antara semua pohon di forest yang menyerupai ide agregat bootstrap (Kulkarni dan Lowe, 2016).

3. Metode

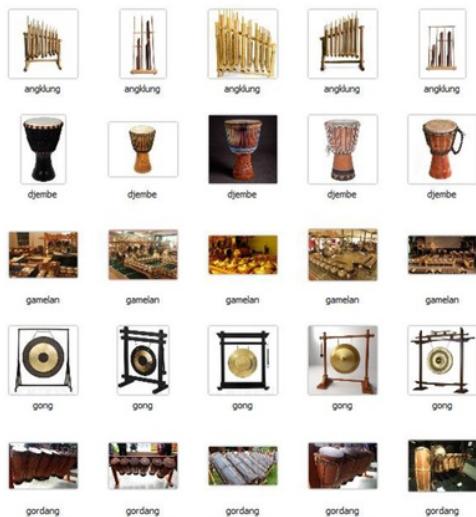
Langkah-langkah penelitian yang dilakukan dapat dilihat pada Gambar 1. Tahap pertama dilakukan pengumpulan data yang berupa file gambar, data-data tersebut kemudian diekstrak fitur-fiturnya. Hasil ekstraksi fitur kemudian dijadikan input secara bergantian untuk tiga pengklasifikasi, yaitu kNN, RF dan SVM. Masing-masing hasil klasifikasi kemudian diuji dan dinilai sehingga bisa disimpulkan pengklasifikasi mana yang paling optimal untuk klasifikasi alat musik tradisional pada penelitian ini.



Gambar 1. Proses penelitian

3.1. Data Latih

Data latih (sampel pelatihan dan pengujian) dikumpulkan berdasarkan interpretasi manual dari data citra berbagai alat musik tradisional yang tersedia di internet. Data sampel pelatihan pada penelitian ini dibatasi dengan 10 jenis alat musik tradisional dari berbagai daerah di Indonesia yang populer di kalangan masyarakat yaitu : angklung, djembe, gamelan, gong, gordang, kendang, kolintang, rebana, sasando, dan serunai. Masing-masing jenis alat musik diwakili dengan 5 buah citra yang sebagian sampelnya dapat dilihat pada Gambar 2.



Gambar 2. Sampel gambar data latih

Sebagai gambaran data yang digunakan pada penelitian ini, ukuran rata-rata file gambar yang digunakan adalah 7,7 Kbyte dengan file terkecil 3,2 Kbyte dan terbesar 15,8 Kbyte. Sedangkan ukuran piksel rata-rata file gambar yang dijadikan data pada penelitian ini adalah 50.433 piksel dengan ukuran terkecil 50.220 piksel dan terbesar 50.625 piksel.

3.2. Ekstraksi Fitur

Pada proses ekstraksi fitur atau ciri, setiap citra yang sudah disiapkan dihitung vektor fiturnya dengan model deep learning SQUEEZENET (Iandola et al. 2017). Proses ini tergabung dalam proses image embedding yang selain menghasilkan fitur, output proses ini menghasilkan data-data kategori, nama gambar, ukuran gambar, dan ukuran file masing-masing gambar. Contoh hasil embedding seperti terlihat pada Tabel 1.

Tabel 1. Contoh hasil embedding

Kategori	Nama image	Ukuran (byte)	Width (pixel)	Height (pixel)
angklung	angklung1	5568	225	225
angklung	angklung2	5417	183	275
angklung	angklung3	12213	225	225
angklung	angklung4	6428	225	225
angklung	angklung5	6295	183	275
djembe	djembe1	5936	180	281
djembe	djembe2	4522	252	200
djembe	djembe3	7509	225	225
djembe	djembe4	6930	225	225

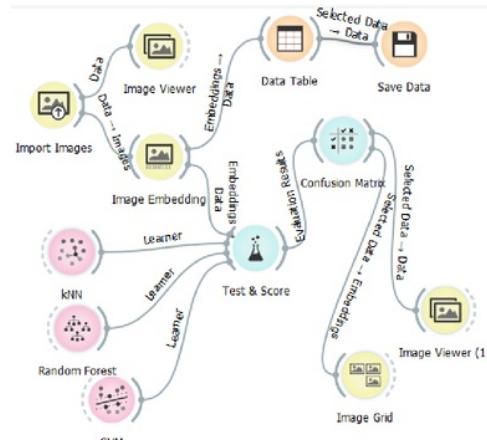
djembe	djembe5	6056	225	225
sasando	sasando5	3737	225	225
serunai	serunai1	4099	259	194
serunai	serunai2	3670	225	225
serunai	serunai3	3750	300	168
serunai	serunai4	5652	330	153
serunai	serunai5	3232	183	276

Metode pengklasifikasian yang digunakan pada penelitian ini adalah Metode *Random Forest*, *k-Nearest Neighbor*, dan *Support Vector Machine*.

4. Hasil dan Pembahasan

Penelitian ini menggunakan tools “Orange” (Demsar et al. 2013) yang merupakan sebuah tools open source untuk pengolahan data mining, lingkungan visualisasi, analitik, dan skrip. Widget harus digunakan sebagai blok-blok untuk membuat alir kerja dengan di lingkungan Orange. Widget dapat dikategorikan sebagai data, visualisasi, klasifikasi, regresi, evaluasi, dan lain-lain. Widget data dimungkinkan untuk manipulasi data text atau gambar.

Work flow klasifikasi alat musik tradisional dengan 23 bandingkan pengklasifikasi kNN, RF dan SVM dapat dilihat pada gambar 3.



Gambar 3. Work flow klasifikasi alat musik tradisional

Pada eksperimen dengan menggunakan kNN, digunakan nilai number of neighbors = 5, metric yang digunakan adalah Euclidean dan Weight = Uniform. Pada eksperimen dengan menggunakan RV, digunakan number of trees = 10 dan growth control menggunakan setting tidak mensplit subsets yang kurang dari 5. Sedangkan pada eksperimen

dengan menggunakan SVM, digunakan nilai cost = 1, regression loss epsilon = 0,1, kernel RBF, toleransi numerik = 0,001 dan batas iterasi = 100.

Teknik sampling yang digunakan adalah *5-fold cross validation* dan *random sampling* dengan 75% 22 latih. Hasil masing-masing teknik sampling dapat dilihat pada Tabel 2 dan 3.

Tabel 2. Hasil eksperimen 5-fold cross validation

Metode	AUC	CA	F1	Precision	Recall
kNN	0,984	0,960	0,960	0,960	0,960
SVM	0,896	0,900	0,895	0,897	0,900
RV	0,926	0,680	0,677	0,745	0,680

Tabel 3. Hasil eksperimen random sampling

Metode	AUC	CA	F1	Precision	Recall
kNN	0,985	0,877	0,877	0,882	0,877
SVM	0,857	0,785	0,792	0,810	0,785
RV	0,916	0,631	0,633	0,643	0,631

Dari Tabel 2 dan 3 terlihat bahwa metode kNN memiliki presisi yang terbaik dengan rata-rata precision 92,1%, diikuti oleh metode SVM dengan precision 85,4% dan RF dengan precision 69,4%. Jika dianalisis dari data citranya, hal ini lebih disebabkan karena cukup banyaknya noise pada sample yang diambil dari gambar-gambar di internet. Sedangkan SVM dan RF tidak sensitif terhadap noise, yang menunjukkan kemampuannya dalam berurusan dengan data yang tidak seimbang.

Citra yang tidak terprediksi dengan baik dari 21 sil Proportion of predicted masing-masing metode dapat dilihat pada gambar 4, 5 dan 6.

Predicted

	angklung	djembe	gamelan	gong	gordang	kendang	kolinang	rebana	sasando	seruna
Actual										
angklung	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
djembe	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gamelan	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gong	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gordang	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	20.0 %	0.0 %	0.0 %	0.0 %	0.0 %
kendang	0.0 %	0.0 %	0.0 %	0.0 %	20.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %
kolinang	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %
rebana	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %
sasando	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %
seruna	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %

Gambar 4. Proporsi prediksi metode kNN

	Predicted									
	angklung	djembe	gamelan	gong	gordang	kendang	kolinang	rebana	sasando	seruna
angklung	100.0 %	14.3 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
djembe	0.0 %	57.1 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	16.7 %	0.0 %	0.0 %
gamelan	0.0 %	0.0 %	75.0 %	0.0 %	0.0 %	12.5 %	0.0 %	0.0 %	16.7 %	0.0 %
gong	0.0 %	0.0 %	0.0 %	80.0 %	0.0 %	0.0 %	0.0 %	0.0 %	16.7 %	0.0 %
gordang	0.0 %	14.3 %	25.0 %	20.0 %	50.0 %	12.5 %	0.0 %	0.0 %	0.0 %	0.0 %
kendang	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	50.0 %	0.0 %	0.0 %	16.7 %	0.0 %
kolinang	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	16.7 %	0.0 %
rebana	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	12.5 %	0.0 %	50.0 %	16.7 %	0.0 %
sasando	0.0 %	14.3 %	0.0 %	0.0 %	50.0 %	0.0 %	0.0 %	16.7 %	33.3 %	0.0 %
seruna	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	12.5 %	0.0 %	0.0 %	0.0 %	100.0 %

Gambar 6. Proporsi prediksi metode RF

Hasil terbaik yang diperoleh dari metode kNN memperlihatkan bahwa terdapat dua citra yang belum dapat diprediksi dengan benar yaitu gambar gondang5 yang terprediksi sebagai alat musik kendang (Gambar 7) dan gambar kendang3 terprediksi sebagai alat musik gondang (Gambar 8). Kesalahan prediksi pada metode kNN ini memang terlihat wajar mengingat kedua alat musik kendang dan gondang merupakan jenis alat musik pukul yang memang memiliki bentuk yang mirip.



Gambar 7. Hasil prediksi klasifikasi kendang dengan metode kNN



gordang2 gordang3 kendang3



gordang1 gordang4

Gambar 7. Hasil prediksi klasifikasi gondang dengan metode kNN

Gambar 5. Proporsi prediksi metode SVM

	Predicted									
	angklung	djembe	gamelan	gong	gordang	kendang	kolinang	rebana	sasando	seruna
angklung	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
djembe	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gamelan	0.0 %	0.0 %	80.0 %	0.0 %	25.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gong	0.0 %	0.0 %	0.0 %	83.3 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
gordang	0.0 %	0.0 %	20.0 %	16.7 %	50.0 %	0.0 %	16.7 %	0.0 %	0.0 %	0.0 %
kendang	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %
kolinang	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	83.3 %	0.0 %	0.0 %	0.0 %	0.0 %
rebana	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %	0.0 %
sasando	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %	0.0 %	0.0 %
seruna	0.0 %	0.0 %	0.0 %	0.0 %	25.0 %	0.0 %	0.0 %	0.0 %	0.0 %	100.0 %

Gambar 5. Proporsi prediksi metode SVM

5. Kesimpulan

Dari hasil eksperimen pengklasifikasian terhadap 10 jenis citra alat musik tradisional Indonesia dengan metode kNN, RF dan SVM, metode kNN memiliki akurasi yang lebih baik dari kedua metode lainnya. Rata-rata nilai *precision* ketiga metode tersebut berturut-turut adalah 92,1% untuk kNN, 85,4% untuk SVM, dan 69,4% untuk RF. Pada metode terbaik yaitu kNN, citra yang tidak dapat diprediksi dengan baik hanya dua citra yang jenis alat musiknya sama dan memiliki citra yang mirip, yaitu sebuah citra kendang yang terprediksi sebagai gondang dan sebuah citra gondang yang terprediksi sebagai kendang.

Daftar Pustaka

5

Adam, E., Mutanga, O., Odindi, J., Abdel-Rahman, E.M., 2014. Land-use/cover classification in a heterogeneous coastal landscape using Rapid Eye imagery: Evaluating the performance of random forest and support vector machines classifiers. *Int. J. Remote Sens.* 35, 3440–3458.

Akbulut, Y., Sengur, A., Guo, Y., Smarandache, F., 2017. NS-k-NN: Neutrosophic Set-Based k-
11 Nearest Neighbors classifier. *Symmetry* 9, 179.

Beaula, A.R., Marikkannu, P., Sungheetha, A., Sahana, C., 2016. Comparative study of distinctive image classification techniques. *2016 10th International Conference on Intelligent Systems and Control (ISCO)*.

Bi, H., Sun, J., Xu, Z., 2017. Unsupervised PolSAR Image Classification Using Discriminative Clustering”, *IEEE Transactions on Geoscience and Remote Sensing*, 55(5).

Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 3 5–32.

Demsar, J., Curk, T., Erjavec, A., Gorup, C., Hocevar, T., Milutinovic, M., Mozina, M., Polajnar, M., Toplak, M., Staric, A., Stajdohar, M., Umek, L., Zagar, L., Zbontar, J., Zitnik, M., Zupan, B., 2013. Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research* 9 14(Aug), 2349–2353.

Ghosh, A., Joshi, P.K., 2014. A comparison of selected classification algorithms for mapping bamboo patches in lower Gangetic plains using very high resolution World View 2 imagery. *Int. J. Appl. Earth Obs. Geoinf.* 26, 298–311.

Heydari, S.S., Mountakis, G., 2018. Effect of classifier selection, reference sample size, reference class distribution and scene heterogeneity in per-pixel classification accuracy using 26 Landsat sites. *Remote Sens. Environ.* 204, 648–658.

Hu, Y., Ashenayi, K., Veltri, R., O'Dowd, G., Miller, G., Hurst, R., Bonner, R., 1994. A Comparison of Neural Network and Fuzzy c-Means Methods in

Bladder Cancer Cell Classification, *IEEE World Congress on Computational Intelligence*.

Iandola, F.N., Moskewicz, M.W., Ashraf, K., Han, S., Dally, W.J., Keutzer, K., 2017. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <1MB model size. *CoRR*, abs/1602.07360. 12

Kalra, K., Goswami, A.K., Gupta, R., 2013. A Comparative Study of Supervised Image Classification Algorithms for Satellite Images. *International Journal of Electrical, Electronics and Data Communication* 1(10).

Khatami, R., Mountakis, G., Stehman, S.V., 2016. A meta-analysis of remote sensing research on supervised pixel-based land cover image classification processes: General guidelines for practitioners and future research. *Remote Sens. Environ.* 177, 89–100. 18

Kulkarni, A.D., Lowe, B.C., 2016. International Journal on Recent and Innovation Trends in Computing and Communication 4(3), 58-63.

Kurian, J., Karunakaran, V., 2012. A Survey on Image Classification Methods, *International Journal of Advanced Research in Electronics and Communication Engineering (IJARECE)* 1(4).

Nikjad, M., Zadeh, V.M., Heydari, M., 2014. Comparing different classifications of satellite imagery in forest mapping, *International Research Journal of Applied and Basic Sciences*.

Pouteau, R., Collin, A., Stolla, B.A., 2011. Comparison of Machine Learning Algorithms for Classification of Tropical Ecosystems Observed by Multiple Sensors at Multiple Scales, *International Geoscience and Remote Sensing Symposium (IGARSS)*, Vancouver, BC, Canada.

Sonawane, M.S., Dhawale, C.A., 2016. Evaluation and Analysis of few Parametric and Nonparametric Classification Methods. *2016 Second International Conference on Computational Intelligence & Communication Technology*

Wei, C., Huang, J., Mansaray, L.R., Li, Z., Liu, W., Han, J., 2017. Estimation and mapping of winter oil seed rape LAI from high spatial resolution satellite data based on a hybrid method. *Remote Sens.* 9, 488.

Yang, Y., Chen, K., 2010. Unsupervised Learning via Iteratively Constructed Clustering Ensemble, *The 2010 International Joint Conference on Neural Networks (IJCNN)*.

jsinbis-klasifikasi alat musik.doc

ORIGINALITY REPORT

24%

SIMILARITY INDEX

PRIMARY SOURCES

- | | | |
|----|--|----------------|
| 1 | www.mdpi.com
Internet | 139 words — 4% |
| 2 | ejournal.undip.ac.id
Internet | 104 words — 3% |
| 3 | www.matec-conferences.org
Internet | 48 words — 2% |
| 4 | www.ijritcc.org
Internet | 40 words — 1% |
| 5 | X. M. Zhang, G. J. He, Z. M. Zhang, Y. Peng, T. F. Long. "Spectral-spatial multi-feature classification of remote sensing big data based on a random forest classifier for land cover mapping", Cluster Computing, 2017
<small>Crossref</small> | 39 words — 1% |
| 6 | www.aboutgis.com
Internet | 37 words — 1% |
| 7 | www.tritonia.fi
Internet | 35 words — 1% |
| 8 | www.int-arch-photogramm-remote-sens-spatial-inf-sci.net
Internet | 34 words — 1% |
| 9 | www.spiedigitallibrary.org
Internet | 34 words — 1% |
| 10 | scitepress.org
Internet | 32 words — 1% |

-
- 11 Utkarsh Shrivastav, Sanjay Kumar Singh. "chapter 9 Digital Image Classification Techniques", IGI Global, 2019
Crossref 27 words — 1%
- 12 Pankaj Pal, Siddhartha Bhattacharyya. "chapter 7 True Color Image Segmentation by MUSIG Activation Function Using Self-Supervised QMLSONN Architecture With Context-Sensitive Thresholding", IGI Global, 2018
Crossref 23 words — 1%
- 13 www.ijesrt.com Internet 22 words — 1%
- 14 "Fuzzy Multi-criteria Decision-Making Using Neutrosophic Sets", Springer Science and Business Media LLC, 2019
Crossref 20 words — 1%
- 15 www.cs.manchester.ac.uk Internet 19 words — 1%
- 16 Soumya K. Patil, M M Shreyas. "A Comparative Study of Question Bank Classification based on Revised Bloom's Taxonomy using SVM and K-NN", 2017 2nd International Conference On Emerging Computation and Information Technologies (ICECIT), 2017
Crossref 18 words — 1%
- 17 www.tandfonline.com Internet 16 words — 1%
- 18 docplayer.net Internet 13 words — < 1%
- 19 www.acscinf.org Internet 13 words — < 1%
- 20 tel.archives-ouvertes.fr Internet 11 words — < 1%

21	fahmiii69.blogspot.com Internet	10 words — < 1%
22	vdocuments.site Internet	10 words — < 1%
23	ppta.stikom.edu Internet	9 words — < 1%
24	etheses.whiterose.ac.uk Internet	9 words — < 1%

EXCLUDE QUOTES OFF
EXCLUDE BIBLIOGRAPHY OFF

EXCLUDE MATCHES OFF