

BAB II

TINJAUAN PUSTAKA

Indonesia memiliki beragam Aksara yang merupakan peninggalan budaya dimasa lalu, salah satunya adalah Aksara Jawa. Aksara Jawa dianggap sebagai *abugidas*, yaitu cara penulisan karakter dengan menggabungkan konsonan dan vokal menjadi satu suku kata dalam satu unit (Tanaya dan Adriani, 2016). Aksara Jawa memiliki beberapa tanda baca seperti koma, titik, titik dua, dan karakter lain untuk menandai akhir dari kalimat.

Penelitian mengenai pengenalan Aksara-Aksara asli Indonesia tersebut telah banyak dilakukan, diantaranya yaitu penelitian oleh Nugraha & Purnomo(2012) mengenai pengenalan tulisan tangan Aksara Jawa *Nglegeno* atau *Nglegena*. Penelitian ini dilakukan untuk mengetahui berapa jumlah transisi fitur yang paling optimal untuk memberikan hasil pengenalan yang baik dengan menggunakan metode klasifikasi *Multi-class SVM*. Hasil penelitian menunjukkan bahwa dengan menggunakan vektor ciri transisi dengan 4 transisi fitur memberikan tingkan pengenalan diatas 90%. Aksara *Nglegena* merupakan Aksara dasar yang masih belum diberi *sandhangan* (Himamunanto dan Setyowati, 2018).

Penelitian lain yang dilakukan yaitu oleh Budhi & Adipranata (2015) mengenai pengenalan tulisan tangan Aksara Jawa menggunakan beberapa metode *Artificial Neural Network* (ANN) yaitu *Bidirectional Assiciative Memory Network*, *Counterpropagation Network*, *Evolutionary Network*, *Backpropagation Network*, dan *Backpropagation Network* yang dikombinasikan dengan *Chi2*. Hasil penelitian tersebut menunjukkan bahwa kombinasi antara *Backpropagation*

Network dengan *Chi2* memberikan hasil pengenalan yang lebih baik dibandingkan metode yang lainnya dengan tingkat akurasi sebesar 98% untuk data latih dan 73% untuk data uji.

Dalam Kamus Besar Bahasa Indonesia (Pusat Bahasa Departemen Pendidikan Nasional, 2007), transliterasi berarti “penyalinan dengan penggantian huruf abjad satu ke abjad yang lain”. Transliterasi adalah proses menerjemahkan secara fonetik suatu kata dari bahasa sumber ke dalam kata yang sama dalam bahasa target yang mewakili pengucapan bahasa sumber (Dasgupta, Sinha dan Basu, 2015). Transliterasi hanya mengubah teks dari satu skrip ke skrip lainnya. Tidak harus mewakili pengucapan asli, melainkan berfokus pada merepresentasikan karakter dengan seakurat dan sejelas mungkin (Prabhakar dan Pal, 2018).

Contoh transliterasi yaitu transliterasi dari Aksara Jawa ke huruf Latin, Aksara Arab ke huruf Latin, atau sebaliknya. Saat ini telah dikembangkan beberapa penelitian mengenai transliterasi dari huruf Latin ke Aksara Jawa. Salah satunya yaitu transliterasi huruf Latin ke Aksara Jawa dengan metode FSA (Atina, Palgunadi dan Widiarto, 2012).

Widiarti et al. (2017) melakukan penelitian mengenai transliterasi citra naskah Jawa kedalam huruf Latin. Pada penelitian ini metode *Template Matching* diterapkan pada proses memberi label pada tulisan menurut kelasnya. Hasil pengujian sistem transliterasi citra naskah pada 291 gambar naskah Jawa menghasilkan tingkat kepercayaan 95%, menunjukkan bahwa interval kepercayaan rata-rata persentase kebenaran transliterasi adalah 73,51% hingga 85,69%. Selanjutnya Widiarti et al. (2018) mengusulkan model untuk transliterasi

naskah Aksara Jawa. Dalam penelitian tersebut terdapat tiga langkah utama untuk transliterasi citra naskah Aksara Jawa, yaitu segmentasi naskah, mentransliterasikan huruf atau angka, kemudian mengelompokkan suku kata. Hasil dari penelitian tersebut menunjukkan bahwa pendekatan struktural dapat diterapkan pada ekstraksi fitur naskah Jawa, dengan syarat bahwa citra aksara Jawa yang akan diproses telah dibuat seragam dalam karakteristik fisik: yaitu sama dalam ukuran, ketebalan dan kemiringan.

Pengenalan pola citra digital dapat dibagi kedalam 3 tahap, yaitu *preprocessing*, ekstraksi fitur dan klasifikasi. Ekstraksi fitur dan klasifikasi merupakan dua tahap yang sangat penting dalam pengenalan pola citra digital. Ekstraksi fitur akan mempengaruhi kinerja sistem dalam pengklasifikasian objek, khususnya pengenalan karakter. Fitur yang diekstrak harus bisa mengklasifikasikan karakter dengan cara yang unik. Clemente et al. (2015) dalam penelitiannya mengenai pengenalan target otomatis dari platform radar aperture sintetis menggunakan *Pseudo Zernike Moments* (PZM) untuk mengekstrak fitur. Algoritma yang diusulkan mengeksploitasi PZM yang berasal dari citra *multi-channel SAR* sebagai fitur yang digunakan untuk mengidentifikasi target yang berbeda. Algoritma memungkinkan penggabungan dari hasil klasifikasi masing-masing dari beberapa pengamatan dari sudut pandang yang berbeda. Properti translasi dan kemandirian rotasi PZM membuat algoritma menjadi kuat sehubungan dengan orientasi target relatif di bidang gambar dan gambar yang tidak terdaftar di antara platform yang berbeda.

Kanan dan Salkhordeh (2016) dalam penelitiannya yang berjudul *Rotation Invariant multi-frame Image Super Resolution Reconstruction using Pseudo Zernike Moments* mengusulkan metode baru dengan memanfaatkan besaran *Pseudo Zernike Moments* (PZM) sebagai fitur rotasi invarian untuk merepresentasikan piksel dalam perhitungan berat. Dengan mempertimbangkan ketahanan PZM terhadap *noise* dan kemampuan deskripsi yang lebih tinggi untuk urutan yang sama dibandingkan dengan ZM dan fakta bahwa fase PZM memberikan informasi penting untuk rekonstruksi gambar, mereka mengusulkan deskriptor PZM berbasis fase baru untuk *Super Resolution* (SR) dengan membuat koefisien fase invarian terhadap rotasi. Hasil eksperimen pada beberapa rangkaian gambar menunjukkan bahwa algoritma yang diusulkan melebihi teknik SR populer lainnya dari sudut pandang PSNR (*peak signal-to-noise ratio*), SSIM (*Structural Similarity Index Measuring*) dan kualitas gambar visual.

Penelitian mengenai *framework* baru bagi sistem *computer-aided diagnosis* (CAD) untuk klasifikasi jaringan payudara jinak / ganas oleh Singh & Urooj (2016) menggunakan properti *Generalized pseudo-Zernike Moments* (GPZM) dan *pseudo-Zernike Moments* (PZM) sebagai deskriptor tekstur dari wilayah yang dicurigai dalam mammogram. Kombinasi metode klasifikasi yang diusulkan dan PZM memberikan AUC sebesar 0,9202 (95% CI, 0,7451-0,9710) dengan *std. error* sebesar 0,00529, sensitivitas sebesar 0,8237, dan spesifisitas sebesar 0,8528.

Selain ekstraksi fitur, tahap selanjutnya yang sangat penting yaitu tahap klasifikasi. Beragam metode klasifikasi telah digunakan dalam penelitian pengenalan karakter optik, salah satunya adalah metode *Support Vector Machine*

(SVM). SVM merupakan metode klasifikasi statistik yang umumnya digunakan untuk permasalahan klasifikasi dua kelas (biner), namun saat ini telah mengalami perkembangan sehingga dapat menyelesaikan permasalahan *multi-class* (Zareapoor et al., 2017).

Jan, Vu dan Koo (2018) menggunakan algoritma SVM dengan pendekatan *one-against-all* dalam *framework* penginderaan spektrum dengan hipotesis *multi-class* yang diusulkan untuk memaksimalkan pencapaian melalui jaringan radio kognitif. Algoritma SVM digunakan mengklasifikasikan sinyal input ke dalam kelas yang telah ditetapkan.

Amara et al. (2015) melakukan perbandingan terhadap lima metode SVM untuk masalah pengenalan karakter Arab, tiga metode berdasarkan pada pengklasifikasi biner, sedangkan dua metode menganggap semua kelas sekaligus. Algoritma tersebut dibandingkan berdasarkan parameter waktu pelatihan, waktu pengujian dan akurasi. Percobaan yang dilakukan dengan menggunakan *Arabic Printed Text Image Database-Multi-Font* (APTID / MF) menunjukkan bahwa metode "*one-against-one*" merupakan yang terkuat, cepat dan menghasilkan tingkat skor yang sangat baik pada waktu yang wajar.

Elleuch et al. (2016) mengusulkan sebuah model baru yang berfokus pada penggabungan dua pengklasifikasi, yaitu *Convolutional Neural Network* (CNN) dan *Support Vector Machine* (SVM) untuk pengenalan tulisan tangan Arab *off-line* dimana teknik *drop-out* diterapkan. Sistem yang diusulkan mengubah *classifier* yang dapat dilatih dari CNN oleh *classifier* SVM. Sebuah jaringan *convolutional* digunakan untuk mengekstrak informasi fitur, dan fungsi SVM

sebagai pengenalan. Dari penelitian ini ditemukan bahwa model ini secara otomatis mengekstrak fitur dari gambar mentah dan kemudian melakukan klasifikasi. Hasil simulasi membuktikan bahwa desain baru berbasis SVM dari arsitektur pengklasifikasi CNN dengan hasil *drop-out* secara signifikan lebih efisien daripada model SVM berbasis CNN tanpa *drop-out* dan pengklasifikasi CNN yang standar.

