



Rekonstruksi citra kendaraan menggunakan SRCNN untuk peningkatan akurasi pengenalan pelat nomor kendaraan

Vehicle images reconstruction using SRCNN for improving the recognition accuracy of vehicle license plate number

Windra Swastika^{*}, Ekky Rino Fajar Sakti, Mochamad Subianto

Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Ma Chung
Villa Puncak Tidar N01, Malang, Indonesia 65151

Cara sitasi: W. Swastika, E. R. F. Sakti, and M. Subianto, "Rekonstruksi citra kendaraan menggunakan SRCNN untuk peningkatan akurasi pengenalan pelat nomor kendaraan," *Jurnal Teknologi dan Sistem Komputer*, vol. 8, no. 4, pp. 289-296, 2020. doi: [10.14710/jtsiskom.2020.13726](https://doi.org/10.14710/jtsiskom.2020.13726), [Online].

Abstract - Low-resolution images can be reconstructed into high-resolution images using the Super-resolution Convolution Neural Network (SRCNN) algorithm. This study aims to improve the vehicle license plate number's recognition accuracy by generating a high-resolution vehicle image using the SRCNN. The recognition is carried out by two types of character recognition methods: Tesseract OCR and SPNet. The training data for SRCNN uses the DIV2K dataset consisting of 900 images, while the training data for character recognition uses the Chars74 dataset. The high-resolution images constructed using SRCNN can increase the average accuracy of vehicle license plate number recognition by 16.9 % using Tesseract and 13.8 % with SPNet.

Keywords – SPNet; SRCNN; super resolution; Tesseract OCR; image reconstruction; license plate recognition

Abstrak – Citra resolusi rendah dapat direkonstruksi menjadi citra resolusi tinggi dengan menggunakan algoritma Super-resolution Convolution Neural Network (SRCNN). Penelitian ini bertujuan untuk menjawab pertanyaan apakah citra resolusi tinggi yang dihasilkan melalui algoritme SRCNN dapat meningkatkan akurasi pengenalan pelat nomor kendaraan. Pengenalan pelat nomor kendaraan dilakukan dengan 2 jenis metode pengenalan karakter yaitu Tesseract OCR dan SPNet. Data latih untuk SRCNN menggunakan dataset DIV2K yang terdiri dari 900 citra, sedangkan data latih untuk pengenalan karakter menggunakan dataset Chars74. Hasil yang didapatkan adalah bahwa peningkatan resolusi citra menggunakan SRCNN dapat meningkatkan rata-rata akurasi pengenalan pelat nomor kendaraan peningkatan akurasi sebesar 16,9 % dengan Tesseract dan 13,8 % dengan SPNet.

Kata kunci – SPNet; SRCNN; super resolution; Tesseract OCR; rekonstruksi citra; pengenalan pelat nomor

I. PENDAHULUAN

Super resolution merupakan sebuah teknik yang bertujuan untuk merekonstruksi citra beresolusi rendah menjadi citra beresolusi lebih tinggi [1]. Secara umum, citra beresolusi tinggi memiliki kerapatan piksel lebih tinggi dibandingkan dengan citra dengan resolusi yang lebih rendah. Dengan kerapatan piksel yang lebih padat, maka citra beresolusi tinggi memiliki detail yang lebih baik daripada citra beresolusi rendah. Peran *super resolution* sangat diperlukan dalam kasus-kasus yang membutuhkan proses analisis citra, seperti diagnosis medis, pemeriksaan kondisi lahan oleh citra satelit, dan sistem pengawasan lalu lintas.

Ada setidaknya empat metode rekonstruksi citra resolusi tinggi menggunakan citra resolusi rendah, yaitu model prediksi dengan menggunakan interpolasi *bicubic* [2], metode *edge based* [3], metode *image statistical* [4], [5], dan metode *patched based* [6]-[10]. Dari keempat metode tersebut, metode *patched based* mendapatkan hasil yang lebih baik dibandingkan dengan ketiga metode lainnya. Metode *patched based* sendiri dibagi kembali ke dalam 2 bagian, yaitu internal [6], [7] dan eksternal [8]-[10].

Metode internal yang pertama kali diterapkan pada [6] menggunakan tingkat kesamaan dari citra beresolusi rendah dan tinggi untuk menghasilkan *super resolution*. Metode eksternal memerlukan proses pelatihan terlebih dahulu untuk mempelajari pola *patch* antara citra beresolusi rendah dan tinggi untuk menghasilkan citra dengan resolusi yang lebih tinggi. Dengan menggunakan proses pelatihan, metode eksternal mendapatkan hasil lebih baik dibandingkan dengan metode internal [11].

Salah satu algoritme yang dihasilkan dengan mengadopsi metode eksternal pada *patched based* adalah Super Resolution Convolutional Neural Network (SRCNN) [12]. Algoritme ini memanfaatkan Convolution Neural Network (CNN) untuk menghasilkan citra beresolusi tinggi dari citra beresolusi rendah. Proses ekstraksi citra dan rekonstruksi citra dilakukan secara menyeluruh oleh model CNN sehingga tidak diperlukan banyak *preprocessing* dan *post-processing*.

^{*}Penulis korespondensi (Windra Swastika)
Email: windraswastika@machung.ac.id

SRCNN mencatatkan waktu eksekusi yang lebih cepat dan kualitas rekonstruksi yang lebih baik dibandingkan dengan beberapa metode *patch based* ketika jumlah dataset untuk data latih ditingkatkan jumlahnya. Dengan menggunakan pengukuran *Peak Signal to Noise Ratio* (PSNR), rekonstruksi citra resolusi tinggi yang dihasilkan SRCNN mendapatkan performa sebesar 27,18 dB dibandingkan dengan *sparse-coding* dengan PSNR sebesar 26,54 dB [12].

Smith [13] menunjukkan contoh SRCNN yang diterapkan dalam meningkatkan akurasi deteksi kendaraan dari citra resolusi tinggi. Namun, SRCNN belum banyak digunakan untuk melakukan rekonstruksi citra pelat nomor khususnya untuk tujuan peningkatan akurasi pengenalan karakter. Tujuan dari penelitian ini adalah melakukan rekonstruksi citra pelat nomor kendaraan yang beresolusi rendah menggunakan SRCNN lalu mengenali karakter dari citra pelat nomor kendaraan yang telah memiliki resolusi tinggi. Sejauh yang penulis ketahui, studi pemanfaatan SRCNN dalam melakukan rekonstruksi citra resolusi tinggi untuk melihat peningkatan akurasi pengenalan pelat nomor kendaraan ini adalah yang pertama kali. Untuk proses pengenalan karakter pada pelat nomor menggunakan dua jenis metode pengenalan, yaitu Tesseract OCR [14] dan SPNet [15].

II. METODE PENELITIAN

A. Pengumpulan data

Secara keseluruhan, penelitian ini menggunakan tiga jenis dataset. *Dataset* pertama digunakan sebagai data latih bagi SRCNN menggunakan dataset DIV2K. Dataset ini berisi citra beresolusi tinggi yang bersumber dari data *open source* [16]. Dataset tersebut terdiri dari 900 citra, dengan salah satu dimensinya berukuran 2000 piksel. Namun karena keterbatasan perangkat keras, penelitian ini hanya menggunakan citra latih sebanyak 200 buah saja.

Dataset kedua digunakan sebagai data latih bagi arsitektur SPNet, yaitu dataset Chars74. Dataset yang secara khusus digunakan untuk Optical Character Recognition (OCR) dalam bahasa Inggris dan Kanada [17]. Secara spesifik, dataset yang diambil untuk data latih hanya dibatasi pada huruf besar dan angka seperti yang umum terdapat pada pelat nomor.

Dataset ketiga digunakan untuk data uji bagi proses pengenalan pelat nomor kendaraan. Dataset ini berisi sekumpulan citra kendaraan yang akan digunakan sebagai data uji untuk penentuan kesimpulan penelitian. Pengumpulan dataset dilakukan menggunakan kamera gawai cerdas Realme 2 Pro dengan resolusi 4608x3456 piksel. Namun karena keterbatasan spesifikasi perangkat keras dalam melakukan *super resolution*, maka dilakukan proses *downscaling* untuk menurunkan resolusi citra menjadi berukuran 1280x960 piksel. Proses pengambilan dataset untuk data uji dibagi ke dalam tiga bagian berdasarkan tingkat pencahayaannya, yaitu tingkat pencahayaan 50 lux, 200 lux, dan lebih



Gambar 1. Dataset untuk data uji dengan variasi tingkat pencahayaan

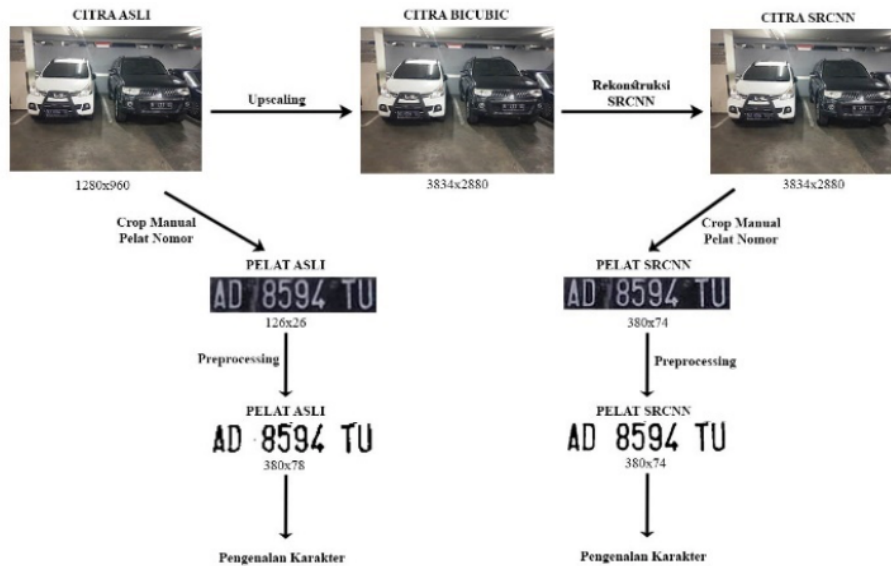
dari 2000 lux. **Gambar 1** menunjukkan contoh citra dalam dataset untuk data uji. Secara berturut-turut angka 1, 2, dan 3 menunjukkan tingkat pencahayaan 50 lux, 200 lux, dan lebih dari 2000 lux.

B. Proses pelatihan

Proses pelatihan dibagi ke dalam dua bagian, yaitu pelatihan SRCNN dan SPNet. Sebelum melakukan proses pelatihan SRCNN, setiap data latih pada dataset DIV2K harus diolah terlebih dahulu untuk mendapatkan citra dengan resolusi rendah dan tinggi. Citra dengan resolusi rendah diperoleh dengan cara melakukan *downscaling* terhadap setiap data latih sehingga dihasilkan sebuah citra baru yang berukuran lebih kecil. Proses *downscaling* dilakukan berdasarkan skala yang telah ditentukan sebelumnya. Misalnya, apabila skala yang digunakan adalah 2, maka citra baru akan memiliki ukuran setengah dari ukuran sebelumnya.

Proses *upscaling* selanjutnya dilakukan sesuai dengan skala yang telah ditentukan untuk mengembalikan ukuran citra baru tersebut ke ukuran aslinya. Dari proses tersebut, diperoleh citra baru dengan kerapatan piksel yang lebih rendah dibandingkan citra asli. Citra baru tersebut merupakan citra beresolusi rendah, sedangkan citra asli merupakan citra beresolusi tinggi. Selanjutnya, *preprocessing* dilakukan kembali untuk memecah citra beresolusi rendah dan tinggi ke dalam banyak citra berukuran lebih kecil yang disebut sebagai *patch*. *Patch* milik citra beresolusi rendah bertindak sebagai data masukan, sementara *patch* milik citra beresolusi tinggi bertindak sebagai data target bagi model SRCNN.

Proses pelatihan SRCNN dan SPNet menggunakan konfigurasi yang dinyatakan dalam **Tabel 1**. Fungsi optimasi yang digunakan adalah Adam dengan *learning rate* sebesar 0,001 dan *decay* sebesar 0,0001. Fungsi *loss* yang digunakan adalah *mean squared error* (MSE). Pelatihan SRCNN ini tidak menggunakan *padding* apapun sehingga ukuran resolusi *patch* yang dihasilkan oleh SRCNN berkurang menjadi 21x21 piksel.



Gambar 2. Alur pengenalan pelat nomor kendaraan

Pelatihan SPNet menggunakan fungsi optimasi *stochastic gradient descent* (SGD) dengan *learning rate* sebesar 0,01, *momentum* 0,9, dan *decay* sebesar 0,0005. Fungsi *loss* yang digunakan adalah *categorical crossentropy*.

C. Perancangan model

Tahap ini membahas langkah-langkah yang dilakukan dari proses rekonstruksi hingga pengenalan pelat nomor kendaraan, seperti yang ditunjukkan dalam Gambar 2. Tahapan pengenalan pelat nomor meliputi rekonstruksi citra, *cropping* area pelat nomor, prapengolahan citra, dan pengenalan karakter.

Citra yang direkonstruksi merupakan citra pelat nomor milik beberapa kendaraan, sekaligus yang terdapat dalam *dataset* pengujian. Citra hasil rekonstruksi bertindak sebagai citra beresolusi tinggi, sedangkan citra asli bertindak sebagai citra beresolusi rendah. Area pelat nomor di-*crop* secara manual dengan cara memilih area *bounding box* pada citra karakter yang ingin dikenali. Teknik prapengolahan citra yang dilakukan kepada citra pelat nomor kendaraan beresolusi rendah dan tinggi secara berurutan adalah *resizing*, *thresholding* dan *negative transformation*.

Pada tahap pengenalan karakter, Tesseract OCR tidak membutuhkan prapengolahan tambahan untuk mengenali karakter. Jadi, proses pengenalan karakter dalam citra dilakukan sepenuhnya oleh Tesseract OCR. Sementara itu, metode SPNet membutuhkan teknik prapengolahan tambahan dalam mengenali pelat nomor. Teknik prapengolahan yang digunakan tersebut adalah kontur. Penggunaan kontur ini bertujuan untuk melakukan ekstraksi setiap citra karakter dalam pelat nomor kendaraan.

Gambar 3 menunjukkan contoh hasil pencarian kontur pada pelat nomor. Setiap karakter dalam pelat nomor berhasil dideteksi dengan menggunakan kotak berwarna merah. Setiap piksel di dalam kotak tersebut

Tabel 1. Konfigurasi pelatihan SRCNN dan SPNet

Konfigurasi	SRCNN	SPNet
Ukuran <i>batch</i>	128	36
Jumlah <i>epoch</i>	10	100
Dimensi masukan	33x33 piksel	60x60x1 piksel
Dimensi keluaran	21x21 piksel	60x60 piksel
<i>Stride</i>	14	36



Gambar 3. Contoh Hasil Pencarian Kontur



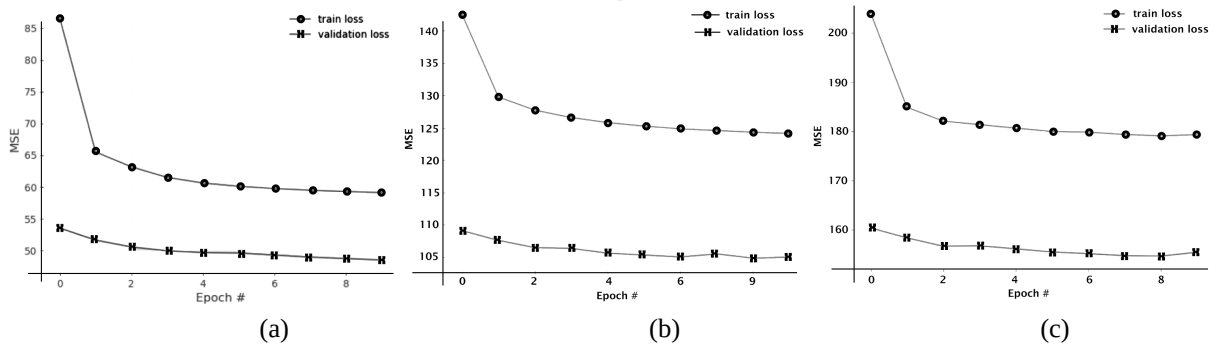
Gambar 4. Perbandingan sebelum dan sesudah *resizing* citra

diambil dan diterapkan *resizing* agar panjang dan lebar citra setiap karakter menjadi berukuran 60x60 piksel. Citra hasil *resizing* dimasukkan ke dalam model SPNet untuk dilakukan proses pengenalan karakter. Penerapan proses *resizing* ditunjukkan oleh Gambar 4.

D. Pengujian

Tahap pengujian dibagi ke dalam tiga bagian, yaitu pengujian terhadap hasil pelatihan SRCNN, pengujian terhadap hasil pelatihan SPNet, dan pengujian untuk menentukan kesimpulan penelitian.

Pengujian pelatihan SRCNN bertujuan untuk mengetahui performa SRCNN dalam melakukan



Gambar 5. MSE hasil pelatihan SRCNN setiap epoch: a) skala 2, b) skala 3 dan c) skala 4

rekonstruksi citra. Performa rekonstruksi ini dapat diketahui dengan cara mengukur kualitas citra hasil rekonstruksi SRCNN dengan menggunakan nilai MSE dan PSNR [18]. Nilai MSE dihitung dengan menggunakan Persamaan 1. Variabel I_1 merupakan citra asli, variabel I_2 merupakan citra hasil rekonstruksi SRCNN, dan variabel n merupakan jumlah piksel dalam citra I .

$$MSE = \frac{1}{n} \sum (I_1 - I_2)^2 \quad (1)$$

Nilai PSNR dihitung dengan menggunakan Persamaan 2. Variabel R merupakan nilai intensitas maksimum yang digunakan oleh citra. Jadi, dalam penelitian ini, nilai R yang digunakan adalah 255 karena nilai intensitas maksimum dari setiap piksel adalah 255. Variabel MSE merupakan nilai MSE yang telah dihitung menggunakan Persamaan 1.

$$PSNR = 10 \log_{10} \left(\frac{R^2}{MSE} \right) \quad (2)$$

Tahap pengujian terakhir adalah pengujian kesimpulan penelitian yang bertujuan untuk mengambil kesimpulan penelitian. Pada tahap ini dilakukan serangkaian uji coba untuk mencari peningkatan akurasi, mencari nilai skala terbaik, mencari tingkat pencahayaan terbaik, dan mengetahui metode pengenalan karakter terbaik antara Tesseract OCR dan SPNet.

Pengujian kesimpulan penelitian dilakukan dengan cara membandingkan hasil pengenalan pelat nomor kendaraan antara citra beresolusi rendah dan tinggi dengan nilai sebenarnya untuk mendapatkan nilai akurasi dari masing-masing citra. Proses perbandingan tersebut menggunakan metode *levensthein distance* yang banyak digunakan untuk menghitung kesamaan antara dua buah *string* [19].

Setelah jarak antara 2 *string* berhasil diperoleh, maka nilai *loss* dihitung dengan menggunakan Persamaan 3. Variabel *distance* menunjukkan jarak kedua *string* yang dihitung berdasarkan metode *levensthein distance*. Variabel tersebut dibagi dengan variabel *total karakter* yang menunjukkan jumlah karakter *string* sebenarnya. Spasi tidak dihitung sebagai



Gambar 6. Lima buah citra uji untuk pengujian SRCNN

sebuah karakter. Setelah mendapatkan *loss*, maka nilai akurasi dihitung berdasarkan Persamaan 4.

$$loss = \frac{distance}{total\ karakter} \times 100\% \quad (3)$$

$$akurasi = \frac{(total\ karakter - distance)}{total\ karakter} \times 100\% \quad (4)$$

III. HASIL DAN PEMBAHASAN

SRCNN dilatih sebanyak tiga kali sesuai dengan jumlah skala yang diuji, yaitu 2, 3, dan 4. Performa pelatihan SRCNN pada setiap skala ditunjukkan oleh Gambar 5. SRCNN memiliki performa pelatihan yang serupa pada setiap jenis skala. Penurunan *training loss* paling besar terjadi pada *epoch* pertama, dilanjutkan dengan penurunan *loss* yang konstan hingga *epoch* kesepuluh. Selain itu, *validation loss* juga turun secara konstan pada setiap *epoch* sehingga dapat disimpulkan bahwa pelatihan SRCNN ini tidak mengalami *overfitting*.

Untuk menguji performa model SRCNN dalam merekonstruksi citra, dilakukan proses *super resolution* kepada lima buah citra uji dengan resolusi sebesar 1280x960 piksel, seperti yang ditunjukkan pada Gambar 6. Proses *super resolution* tersebut dilakukan dengan menggunakan metode interpolasi *bicubic* dan SRCNN. Kualitas hasil rekonstruksi kedua jenis metode tersebut kemudian diukur dengan cara membandingkan setiap hasil rekonstruksi dengan citra

asli beresolusi tinggi. Pengukuran dilakukan dengan menggunakan metode MSE dan PSNR [18]. Kelima nilai MSE dan PSNR tersebut kemudian dihitung rata-ratanya sehingga didapatkan rata-rata kualitas rekonstruksi citra pada masing-masing skala.

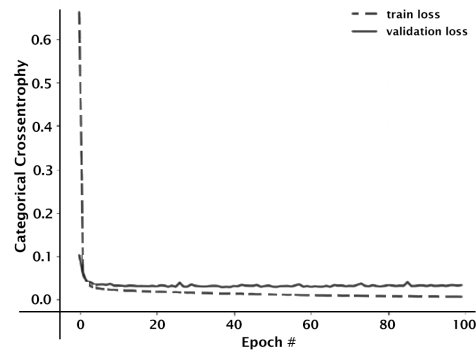
Rata-rata tersebut ditampilkan dalam Tabel 2. SRCNN memiliki performa yang lebih baik daripada metode interpolasi *bicubic* pada semua jenis skala. Hasil ini selaras dengan [20] yang menyatakan SRCNN memiliki performa lebih baik untuk skala 2, 3 dan 4 dibandingkan dengan *bicubic*. Selain itu, skala bernilai kecil memiliki kualitas rekonstruksi citra yang lebih baik daripada skala berukuran lebih besar. Hasil rekonstruksi terbaik terjadi pada SRCNN skala 2, sedangkan hasil rekonstruksi citra terburuk didapatkan oleh SRCNN skala 4.

Performa pelatihan SPNet pada setiap *epoch* dapat ditunjukkan melalui Gambar 7. Fungsi optimasi SGD berjalan dengan sangat baik. Nilai *loss* citra latih pada *epoch* pertama turun secara signifikan kemudian dilanjutkan dengan penurunan yang konstan dan stabil pada *epoch-epoch* selanjutnya. Grafik tersebut juga menunjukkan bahwa nilai *loss* pada citra validasi mengalami penurunan pada *epoch* pertama. Nilai *loss* tersebut kemudian cenderung konstan pada *epoch* kedua hingga keseratus. Kecepatan pelatihan dengan menggunakan fungsi optimasi SGD ini diperoleh karena SGD merupakan penyederhanaan dari perhitungan gradien dengan melakukan estimasi gradien berbasis sampel yang diambil secara acak [21].

Pengujian kesimpulan penelitian dilakukan dengan cara membandingkan nilai *loss* dan akurasi pengenalan karakter antara citra beresolusi rendah dan tinggi. Pengujian ini dibagi ke dalam tiga bagian berdasarkan nilai skala yang digunakan. Pada setiap skala tersebut dilakukan pembagian kembali sesuai dengan tingkat pencahayaan dalam *dataset* uji. Oleh sebab itu, terdapat sembilan buah hasil pengujian yang digunakan sebagai dasar bagi pengambilan kesimpulan penelitian. Setiap hasil pengujian tersebut disajikan dalam bentuk tabel yang berisi rata-rata nilai akurasi dan *loss* dari kedua jenis metode pengenalan karakter, yaitu Tesseract OCR dan SPNet.

Tabel 3 menunjukkan nilai akurasi setiap pengujian pada citra beresolusi rendah. TOCR menunjukkan Tesseract OCR. Rata-rata akurasi dihitung berdasarkan jenis skala yang digunakan. Rata-rata akurasi untuk Tesseract dengan skala 2, 3, dan 4 berturut-turut adalah 71,5 %, 73,1 % dan 71,9 %. SPNet dengan skala 2, 3, dan 4 menghasilkan akurasi berturut-turut adalah 58,7 %, 54,6 % dan 55,4 %. Rata-rata akurasi untuk pengenalan menggunakan Tesseract pada skala 2, 3 dan 4 adalah 72,2 %, sedangkan pengenalan menggunakan SPNet adalah 56,2 %. Tingkat pencahayaan 50 *lux* mendapatkan nilai akurasi yang paling tinggi untuk metode pengenalan Tesseract, yaitu sebesar 82,2 %.

Perbedaan nilai akurasi yang terlalu besar tidak terjadi untuk setiap jenis skala nampak. Selain itu, tidak ada pola khusus yang dapat diambil dari nilai akurasi yang diperoleh oleh masing-masing skala. Hal ini terjadi



Gambar 7. Kinerja pelatihan SPNet setiap epoch

Tabel 2. Rata-rata hasil pengujian SRCNN

Skala	Bicubic		SRCNN	
	MSE	PSNR	MSE	PSNR
2	23,29	34,55	17,25	35,82
3	22,85	34,63	17,58	35,74
4	22,84	34,63	18,67	35,49

Tabel 3. Akurasi pada citra beresolusi rendah (dalam %)

Skala	50 Lux		200 Lux		> 2000 Lux	
	TOCR	SPNet	TOCR	SPNet	TOCR	SPNet
2	81,3	70,4	68,1	50,9	65,2	54,9
3	84,7	67,6	67,2	46,4	67,5	49,7
4	80,7	63,8	64,7	45,7	70,3	56,6
Rerata	82,2	67,2	66,7	47,7	67,6	53,7

Tabel 4. Akurasi pada citra beresolusi tinggi (dalam %)

Skala	50 Lux		200 Lux		> 2000 Lux	
	TOCR	SPNet	TOCR	SPNet	TOCR	SPNet
2	89,4	78,6	85,1	63,2	82,0	66,2
3	94,3	80,4	89,9	63,4	86,1	68,4
4	93,9	74,9	92,6	64,3	88,8	70,4
Rerata	92,5	78,0	89,2	63,6	85,6	68,4

karena proses pengenalan karakter pada citra beresolusi rendah tidak dipengaruhi oleh variabel skala. Walaupun demikian, rata-rata nilai akurasi menunjukkan informasi penting tentang metode pengenalan karakter terbaik pada citra beresolusi rendah, yaitu Tesseract OCR dengan nilai rata-rata akurasi sebesar 72,2 %.

Untuk citra resolusi tinggi, tingkat akurasi berdasarkan skala dan pencahayaan dinyatakan pada Tabel 4. Rata-rata akurasinya dihitung berdasarkan jenis skala. Rata-rata akurasi untuk Tesseract dengan skala 2, 3, dan 4 berturut-turut adalah 85,5 %, 90,1 % dan 91,8 %, sedangkan SPNet berturut-turut 69,4 %, 70,7 %, dan 69,9 %. Dari data rata-rata tersebut, terlihat bahwa metode Tesseract OCR dan SPNet mendapatkan rata-rata nilai akurasi terendah pada skala 2. Skala terbaik yang diperoleh oleh metode Tesseract OCR terjadi pada skala 4 dengan rata-rata akurasi untuk semua jenis

pencahayaan sebesar 91,8 %. Pada metode SPNet, skala terbaik terjadi pada jenis skala 3, yaitu sebesar 70,7 %.

Sama halnya dengan akurasi pada citra beresolusi rendah, nilai akurasi tertinggi untuk citra resolusi tinggi diperoleh pada tingkat pencahayaan 50 lux, yaitu sebesar 92,5 % untuk metode Tesseract OCR dan 78,0 % untuk metode SPNet. Hal ini menunjukkan bahwa tingkat cahaya yang lebih terang (200 lux dan >2000 lux) mempengaruhi akurasi pengenalan teks. Pada pengenalan dengan menggunakan Tesseract OCR, semakin terang pencahayaan, maka akurasi yang diperoleh semakin berkurang.

Hasil tersebut di atas menunjukkan bahwa kedua jenis metode pengenalan karakter memiliki performa yang lebih baik pada citra beresolusi tinggi. Untuk mengetahui perubahan nilai akurasi antara citra beresolusi rendah dan tinggi, maka dilakukan proses penghitungan nilai peningkatan akurasi pada setiap pengujian.

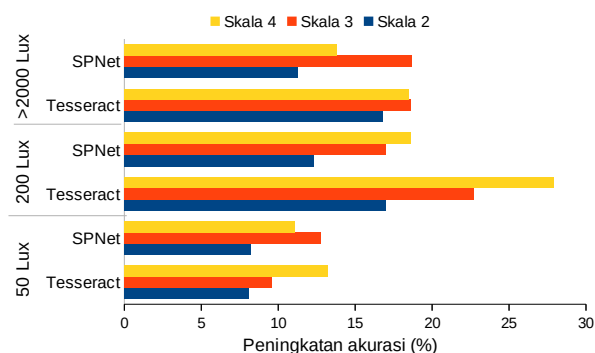
Tesseract secara keseluruhan menghasilkan akurasi yang lebih tinggi daripada arsitektur SPNet untuk citra beresolusi rendah maupun tinggi. Hal ini disebabkan karena SPNet mempunyai kelemahan, seperti halnya arsitektur CNN secara umum, yaitu proses ekstraksi fitur dilakukan pada layer konvolusi. Di sisi lain, proses ekstraksi fitur pada Tesseract terdiri dari beberapa proses, seperti *line finding*, *baseline fitting*, *fixed pitch detection*, dan *proportional word finding* serta dilanjutkan dengan menggunakan *adaptive classifier* untuk mengenali karakter [13], [14].

Peningkatan nilai akurasi pada setiap pengujian ditunjukkan oleh Gambar 8. Pada metode Tesseract OCR, skala 2 mendapatkan rata-rata peningkatan akurasi yang paling rendah, yaitu 13,9 %, sedangkan skala 4 mendapatkan peningkatan akurasi tertinggi yaitu: 19,0 %. Ini menunjukkan bahwa ekstraksi fitur yang dilakukan oleh Tesseract lebih berhasil mengenali karakter pada citra berukuran besar dibandingkan dengan citra yang berukuran kecil. Namun hal tersebut tidak berlaku pada SPNet. Pada metode SPNet, jenis skala yang mendapatkan peningkatan akurasi terendah adalah skala 2, yaitu 10,6 %, dan peningkatan akurasi tertinggi terjadi pada skala 3, yaitu 16,2 %.

Berdasarkan tingkat pencahayaan, diperoleh rata-rata peningkatan akurasi untuk metode Tesseract OCR dengan pencahayaan berturut-turut 50, 200 dan >2000 lux adalah 10,3 %, 22,5 % dan 18,0 %. Peningkatan akurasi metode pengenalan karakter menggunakan SPNet dengan pencahayaan berturut-turut 50, 200 dan >2000 lux adalah 10,7 %, 16,0 % dan 14,6 %.

IV. KESIMPULAN

Citra hasil rekonstruksi SRCNN dapat meningkatkan kualitas yang lebih baik daripada metode interpolasi *bicubic* pada semua jenis skala. Selain itu, teknik *super resolution* menggunakan SRCNN juga terbukti dapat meningkatkan akurasi pengenalan pelat nomor kendaraan sebesar 16,9 % untuk pengenalan menggunakan Tesseract OCR dan 13,8% untuk



Gambar 8. Peningkatan akurasi untuk masing-masing metode pengenalan, tingkat pencahayaan, dan skala

pengenalan menggunakan SPNet. Secara umum, metode pengenalan karakter terbaik adalah metode Tesseract OCR. Metode ini berhasil mengungguli SPNet dalam semua jenis pengujian baik pada rata-rata peningkatan akurasi, nilai akurasi pada citra beresolusi rendah, maupun nilai akurasi pada citra beresolusi tinggi.

DAFTAR PUSTAKA

- [1] L. Yue, S. Huanfeng, J. Li, Q. Yuan, H. Zhang, and L. Zhang, "Image super-resolution: the techniques, applications, and future," *Signal Processing*, vol. 128, pp. 389-408, 2016. doi: [10.1016/j.sigpro.2016.05.002](https://doi.org/10.1016/j.sigpro.2016.05.002)
- [2] J. W. Hwang and H. S. Lee, "Adaptive image interpolation based on local gradient features," *IEEE Signal Processing Letters*, vol. 11, no. 3, pp. 359-362, 2004. doi: [10.1109/LSP.2003.821718](https://doi.org/10.1109/LSP.2003.821718)
- [3] R. Fattal, "Image upsampling via imposed edge statistics," *ACM Transactions on Graphics*, vol. 26, no. 3, pp. 95-102, 2007. doi: [10.1145/1275808.1276496](https://doi.org/10.1145/1275808.1276496)
- [4] T. Peleg and M. Elad, "A statistical prediction model based on sparse representations for single image super-resolution," *IEEE Transactions on Image Processing*, vol. 23, no. 6, pp. 2569-2582, 2014. doi: [10.1109/TIP.2014.2305844](https://doi.org/10.1109/TIP.2014.2305844)
- [5] J. Huang and D. Mumford, "Statistics of natural images and models," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Fort Collins, USA, Jun. 1999, pp. 541-547. doi: [10.1109/CVPR.1999.786990](https://doi.org/10.1109/CVPR.1999.786990)
- [6] D. Glasner, S. Bagon, and M. Irani, "Super-resolution from a single image," in *12th International Conference on Computer Vision*, Kyoto, Japan, Oct. 2009, pp. 349-356. doi: [10.1109/ICCV.2009.5459271](https://doi.org/10.1109/ICCV.2009.5459271)
- [7] G. Freedman and R. Fattal, "Image and video upscaling from local self-examples," *ACM Transactions on Graphics (TOG)*, vol. 30, no. 2, pp. 1-11, 2011. doi: [10.1145/1944846.1944852](https://doi.org/10.1145/1944846.1944852)
- [8] M. Bevilacqua, A. Roumy, C. Guillemot, and M. L. Alberi-Morel, "Low-complexity single-image super-resolution based on nonnegative neighbor embedding," in *British Machine Vision*

- Conference, Surrey, UK, Sept. 2012, pp. 135.1-135.10. doi: [10.5244/C.26.135](https://doi.org/10.5244/C.26.135)
- [9] H. Chang, Y. Dit-Yan, and Y. Xiong, "Super-resolution through neighbor embedding," in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Washington, USA, Jul. 2004. doi: [10.1109/CVPR.2004.1315043](https://doi.org/10.1109/CVPR.2004.1315043)
- [10] S. Schulter, C. Leistner, and H. Bischof, "Fast and accurate image upscaling with super-resolution forests," in *IEEE Conference on Computer Vision and Pattern Recognition*, Boston, USA, Jun. 2015, pp. 3791-3799. doi: [10.1109/CVPR.2015.7299003](https://doi.org/10.1109/CVPR.2015.7299003)
- [11] C-Y. Yang, C. Ma, and M-H. Yang, "Single-image super-resolution: A benchmark," in *European Conference on Computer Vision*, Zurich, Switzerland, Sept. 2014, pp. 372-386. doi: [10.1007/978-3-319-10593-2_25](https://doi.org/10.1007/978-3-319-10593-2_25)
- [12] C. Dong, C. C. Loy, K. He, and X. Tang, "image super-resolution using deep convolutional networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 38, no. 2, pp. 295-307, 2015. doi: [10.1109/TPAMI.2015.2439281](https://doi.org/10.1109/TPAMI.2015.2439281)
- [13] R. Smith, "an overview of the tesseract ocr engine," in *Ninth International Conference on Document Analysis and Recognition*, Parana, Brazil, Sept. 2007, pp. 629-633. doi: [10.1109/ICDAR.2007.4376991](https://doi.org/10.1109/ICDAR.2007.4376991)
- [14] H. Ji, Z. Gao, T. Mei, and B. Ramesh, "Vehicle detection in remote sensing images leveraging on simultaneous super-resolution," *IEEE Geoscience and Remote Sensing Letters*, vol. 17, no. 4, pp. 676-680, 2019. doi: [10.1109/LGRS.2019.2930308](https://doi.org/10.1109/LGRS.2019.2930308)
- [15] D-G. Ko, S-H. Song, K-M. Kang, and S-W. Han, "Convolutional neural networks for character-level classification," *IEIE Transactions on Smart Processing & Computing*, vol. 6, no. 1, pp. 53-59, 2017. doi: [10.5573/IEIESPC.2017.6.1.053](https://doi.org/10.5573/IEIESPC.2017.6.1.053)
- [16] E. Agustsson and R. Timofte, "Ntire 2017 challenge on single image super-resolution: dataset and study," in *IEEE Conference on Computer Vision and Pattern Recognition Workshops*, Honolulu, USA, Jul. 2017, pp. 126-135. doi: [10.1109/CVPRW.2017.150](https://doi.org/10.1109/CVPRW.2017.150)
- [17] T. E. De Campos, B. R. Babu, and M. Varma, "Character recognition in natural images," in *Fourth International Conference on Computer Vision Theory and Applications*, Lisboa, Portugal, Feb. 2009, pp. 1-8.
- [18] A. Hore and D. Ziou, "Image quality metrics: PSNR vs. SSIM," in *International Conference on Pattern Recognition*, Istanbul, Turkey, Aug. 2010, pp. 2366-2369. doi: [10.1109/ICPR.2010.579](https://doi.org/10.1109/ICPR.2010.579)
- [19] K. Balhaf, M. A. Alsmirat, M. Al-Ayyoub, Y. Jararweh, and M. A. Shehab, "Accelerating Levenshtein and Damerau edit distance algorithms using GPU with unified memory," in *8th International Conference on Information and Communication Systems*, Irbid, Jordan, Apr. 2017, pp. 7-11. doi: [10.1109/IACS.2017.7921937](https://doi.org/10.1109/IACS.2017.7921937)
- [20] G. Lin et al., "Image super-resolution using a dilated convolutional neural network," *Neurocomputing*, vol. 275, pp. 1219-1230, 2018. doi: [10.1016/j.neucom.2017.09.062](https://doi.org/10.1016/j.neucom.2017.09.062)
- [21] L. Bottou, "Large-scale machine learning with stochastic gradient descent," in *19th International Conference on Computational Statistics*, Paris, France, Aug. 2010, pp. 177-186. doi: [10.1007/978-3-7908-2604-3_16](https://doi.org/10.1007/978-3-7908-2604-3_16)