

# PELERAIAN SUPER IMEJ MENGGUNAKAN RANGKAIAN NEURAL KONVOLUSI PELERAIAN SUPER

JACYLN WANG LING

KOK VEN JYN

*Fakulti Teknologi & Sains Maklumat, Universiti Kebangsaan Malaysia*

## 1 PENGENALAN

Peleraian super(Super Resolution, SR) merupakan satu teknik pemprosesan visual yang menerima visual peleraian rendah sebagai input dan menghasilkan visual peleraian tinggi. Teknik ini sering digunakan dalam bidang-bidang yang memerlukan imej peleraian tinggi seperti bidang perubatan untuk menambahbaikkan kualiti imej perubatan, bidang mikroskopik untuk penglihatan sel hidup, dan bidang satelit untuk mempertingkatkan maklumat geografi atas peta. Pembatasan dan kos perkakasan yang tinggi semasa menghasilkan visual peleraian tinggi telah menyebabkan dalam penggunaan SR untuk meningkatkan peleraian visual dalam bidang-bidang tersebut.

Kini, terdapat pelbagai jenis kaedah telah dihasilkan dengan penggunaan algoritma yang berbeza untuk melaksanakan proses peleraian super dengan kelebihan dan kelemahan tersendiri. Kebanyakan kaedah ini adalah berdasarkan example-based, di mana kaedah sebegini menggunakan kesamaan sekitar pixel dalam satu imej untuk menghasilkan imej peleraian tinggi. Sesetengah kaedah tersebut pula, akan menggunakan kesamaan dalam dua imej yang menunjukkan objek yang sama bagi meningkatkan peleraian imej.

Kebelakangan ini, penggunaan kaedah rangkaian neural konvolusi(Convolutional Neural Network, CNN) semakin popular kerana dapat mencapai kecekapan dan kelajuan yang lebih tinggi berbanding dengan kaedah-kaedah lain. Penggunaan kaedah CNN dapat dilihat dalam kaedah rangkaian neural konvolusi peleraian super (Super Resolution Convolutional Neural Network, SRCNN) dimana kaedah ini merumuskan pengekstrakan dan perwakilan patch dan pemetaan bukan linear sebagai lapisan konvolusi untuk pemprosesan imej. Kaedah tersebut boleh dijadikan

lebih baik apabila dilatih dengan memperkenalkan lebih banyak lapisan ke dalam rangkaian berdasarkan kajian He et al.. Dalam projek ini, satu lapisan konvolusi akan ditambah dalam kaedah ini bagi menguji kecekapan dan ketepatannya dalam penghasilan imej peleraian tinggi.

## **2 PENYATAAN MASALAH**

Modal asal mengandungi satu lapisan konvolusi sahaja dalam operasi pemetaan bukan linear. Lapisan konvolusi dalam pemetaan bukan linear penting dalam pengekstrakan ciri. Rangkaian yang lebih mendalam dapat meningkatkan pengekstrakan ciri yang lebih kompleks di mana ia dapat membawa kepada hasil keluaran yang lebih baik. Oleh itu, kecekapan dan ketepatan sesebuah model pembelajaran dapat ditingkatkan melalui pengubahsuaian dalam bilangan lapisan konvolusi dalam operasi tersebut bagi meningkatkan pengestakan ciri yan kompleks.

## **3 OBJEKTIF KAJIAN**

Projek ini dijalankan untuk:-

- i. meningkatkan ketepatan dalam peleraian super melalui rangkaian neural yang mendalam
- ii. meningkatkan kualiti pemulihan imej dengan penalaan parameter

## **4 METOD KAJIAN**

Projek ini akan dilaksanakan berdasarkan amalan experimental dengan menggunakan teknik pembelajaran mesin. Amalan tersebut dipilih kerana projek ini melibatkan eksperimen dengan penalaan parameter model untuk melihat kesannya. Amalan tersebut melibatkan empat fasa iaitu fasa perancangan, fasa analisis, fasa reka bentuk dan fasa pengujian.

- i. Fasa Perancangan

Perancangan projek ini dilakukan dengan menetapkan bidang yang ingin dikajikan dan masalah yang sedia ada dalam bidang tersebut. Bagi projek ini, pemprosesan peleraian imej dipilih kerana

ia merupakan salah satu masalah sedia ada sejak dahulu. Walaupun banyak penyelidikan telah dilakukan bagi masalah ini dan banyak kaedah telah dihasilkan, ia masih mempunyai ruang untuk kemajuan bagi mencapai hasil yang tinggi.

ii. Fasa Analisis

Fasa ini melibatkan mengenalpasti dan membuat perbandingan kaedah yang sedia ada serta mengenal pasti kelemahan kaedah-kaedah yang sedia ada. Kaedah yang mempunyai ruang penambahbaikan yang tinggi dipilih sebagai tumpuan projek ini. Formulasi SRCNN dianalisiskan bagi pemahaman yang mendalam untuk mencari cara penambahbaikannya.

iii. Fasa Rekabentuk

Fasa ini melibatkan rekabentuk dalam struktur imej yang akan diproses sehingga ke imej yang telah diproseskan. Satu modal rangkaian yang lebih mendalam dibina berdasarkan rangka model asal. Pengetahuan dalam penyelidikan CNN juga digunakan bagi membina model tersebut untuk mengetahui kesannya terhadap menambahbaik kecekapan dan ketepatan.

iv. Fasa Pengujian

Fasa ini akan dijalankan untuk menguji kecekapan algoritma yang telah diubahsuaikan. Fasa ini dijalankan untuk memastikan proses penghasilan imej berfungsi dengan baik. Set latihan digunakan untuk melatih rangkaian manakala set ujian akan disediakan untuk menguji ketepatan hasil keluaran model tersebut.

5

## HASIL KAJIAN

Berikut merupakan butiran implementasi dalam model pembelajaran ini:

Lapisan Pertama:

9x9 saiz penapis untuk penyarian patch dan perwakilan

Bilangan penapis: 64

Lapisan Kedua:

5x5 saiz penapis untuk pemetaan tidak linear lapisan pertama

Bilangan penapis: 32

Lapisan Ketiga:

1x1 saiz penapis untuk pemetaan tidak linear lapisan kedua

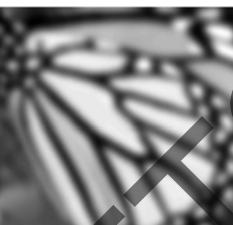
Bilangan penapis: 16

Lapisan Keempat:

1x1 saiz penapis untuk pembinaan semula

Bilangan penapis: 1

Sub-imej size 33x33 disediakan secara rawak dipotong daripada imej dataset latihan telah digunakan dalam fasa latihan. Semua sub-imej yang digunakan adalah dalam YCrCb saluran warna. Rectified Linear Unit(ReLU) digunakan dalam setiap lapisan konvolusi bagi memperbaikkan rangkaian neural dengan mempercepatkan latihan. Kadar pembelajaran yang digunakan adalah  $10^{-4}$  dalam kesemua lapisan.

Modal	Imej Ujian
SRCNN	   
Rangkaian Mendalam CNN	   

Rajah 5.1 Output SRCNN dan rangkaian mendalam

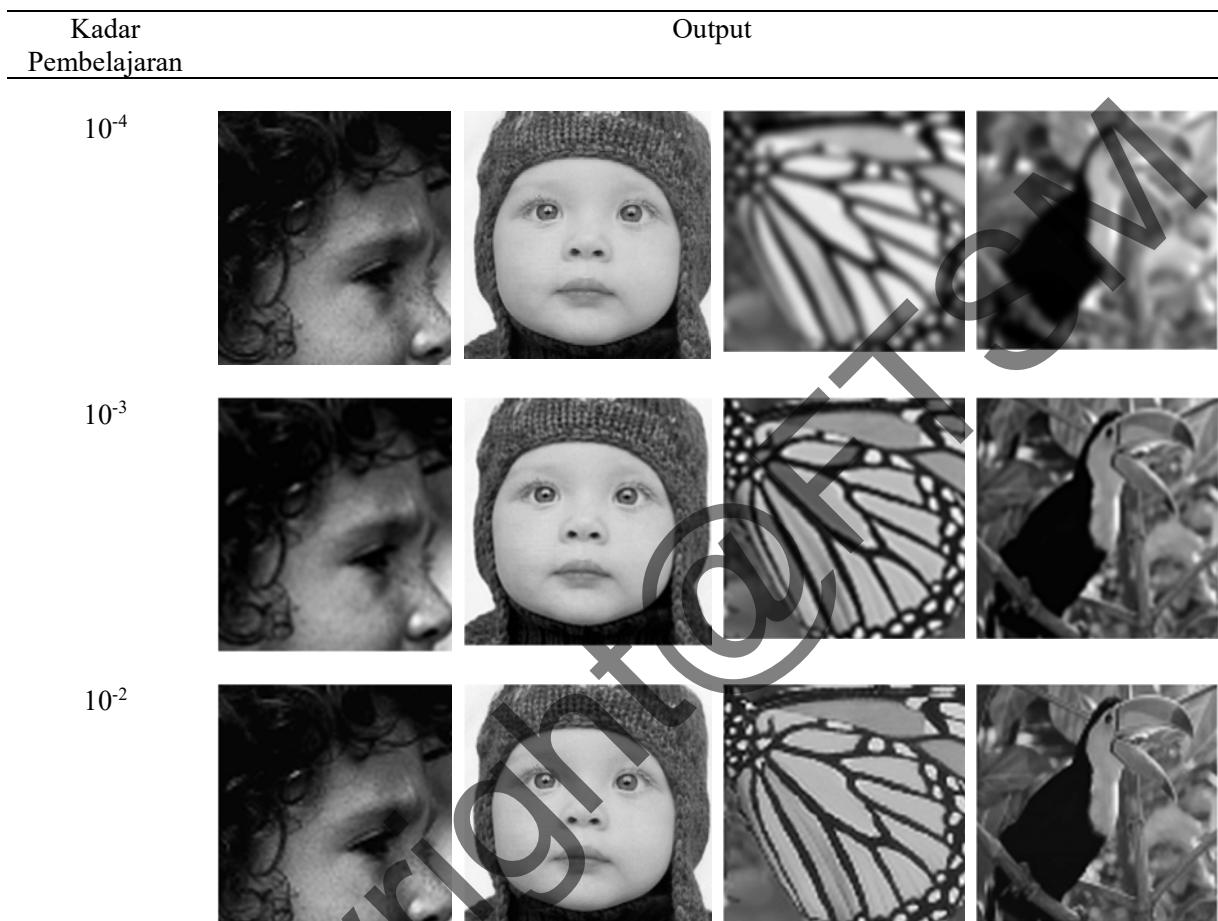


Jadual 5.1 Hasil Kajian PSNR antara SRCNN dan rangkaian mendalam CNN berdasarkan lapisan

Image	SRCNN	Rangkaian mendalam
	PSNR	PSNR
Head	<b>35.66</b>	23.59
Baby	<b>38.44</b>	18.16
Butterfly	<b>30.48</b>	12.56
Bird	<b>40.04</b>	17.66
Woman	<b>34.55</b>	16.54
Average	<b>35.83</b>	17.70

Hasil kajian daripada penambahan satu lapisan konvolusi menunjukkan PSNR yang lebih rendah berbanding dengan modal SRCNN. Hal ini demikian kerana apabila saiz imej ditingkatkan, bilangan pixel ditingkat juga dan secara langsung kerentanan imej terhadap gangguan ditingkat. Dalam kajian ini, output yang dihasilkan adalah lebih kecil berbanding dengan output SRCNN.

Hal ini menyebabkan bilangan pixel berkurang dan nilai isyarat yang ada dalam output akan berkurang. Secara langsung, menyebabkan PSNR menurun.



Rajah 5.2 Output Kadar Pembelajaran yang berbeza

Jadual 5.2 Hasil Kajian PSNR rangkaian mendalam berdasarkan kadar pembelajaran

Image	$10^{-4}$	$10^{-3}$	$10^{-2}$
	PSNR	PSNR	PSNR
Head	23.59	<b>29.60</b>	28.88
Baby	18.16	25.96	<b>26.14</b>
Butterfly	12.56	<b>17.55</b>	15.56
Bird	17.66	17.68	<b>18.73</b>
Woman	16.54	20.41	<b>20.63</b>
Average	17.70	<b>22.24</b>	21.99

Walaupun kadar pembelajaran  $10^{-3}$  hanya mencapai PSNR yang paling tinggi sebanyak 2 kali, ia masih menonjol dalam purata PSNR. Bagi kadar pembelajaran  $10^{-4}$ , kadar pembelajaran ini tidak menambahbaik dengan cepat dalam setiap lapisan konvolusi, menyebabkan hasilannya lebih teruk daripada yang lain. Di sini dapat lihat kadar pembelajaran yang paling sesuai untuk modal ini adalah  $10^{-3}$ .

## 6 KESIMPULAN

Model baru ini mempunyai kebatasannya. Antara batasan yang didapati ialah kuasa pengkomputeraan akan menjadi lebih tinggi jika lebih banyak lapisan konvolusi ditambahkan. Algoritma ini memerlukan kuasa pengkomputeraan yang tinggi jika ingin membuat rangkaian yang lebih besar seperti 30 lapisan konvolusi. Selain itu, model ini memerlukan banyak set latihan untuk pembelajaran untuk menghasilkan ketepatan yang lebih tinggi.

SRCNN tidak dinafikan mempunyai kebolehan untuk menghasilkan ketepatan dan kecekapan yang tinggi. Kaedah ini boleh diubahsuai dalam banyak aspek. Salah satu adalah penggabungan model ini dengan kaedah lain untuk mengkaji ketetapan dan kecekapannya. Selain itu, model ini boleh ditambahbaik dengan menambahkan set latihan.

## 7 RUJUKAN

- Deshpande, A. A Beginner's Guide To Understanding Convolutional Neural Networks.  
<https://adeshpande3.github.io/A-Beginner%27s-Guide-To-Understanding-Convolutional-Neural-Networks/> [20 Julai 2016]
- Dong, C., Loy, C.C., He, K. and Tang, X., 2014, September. Learning a deep convolutional network for image super-resolution. In European Conference on Computer Vision (pp. 184-199). Springer, Cham.
- He, K. and Sun, J., 2015, June. Convolutional neural networks at constrained time cost. In *Computer Vision and Pattern Recognition (CVPR), 2015 IEEE Conference on* (pp. 5353-5360). IEEE.
- Jordi Salvador. 2016. *Example-Based Super Resolution*.

Nielsen, M. Neural Networks and Deep Learning. <http://neuralnetworksanddeeplearning.com/> [2015]

Standford University. Convolutional Neural Network. <http://ufldl.stanford.edu/tutorial/supervised/ConvolutionalNeuralNetwork/>

Standford University. CS231n Convolutional Neural Networks for Visual Recognition. <http://cs231n.github.io/convolutional-networks/>

Standford University. Feature extraction using convolution [http://deeplearning.stanford.edu/wiki/index.php/Feature\\_extraction\\_using\\_convolution](http://deeplearning.stanford.edu/wiki/index.php/Feature_extraction_using_convolution)

Yang, J., Wright, J., Huang, T. S., & Ma, Y. (2010). Image super-resolution via sparse representation. *IEEE transactions on image processing*, 19(11), 2861-2873.