

Pengenalan Karakter Hieroglif Mesir Kuno Menggunakan *Convolutional Neural Network*

Darmatasia

Program Studi Teknik Informatika, Fakultas Sains dan Teknologi, Universitas Islam Negeri Alauddin Makassar
 Jl. H. M. Yasin Limpo No.36 Kel. Romang Polong, Kec. Somba Opu, Kab. Gowa, Kode Pos, 92118

E-mail: darmatasia@uin-alauddin.ac.id

Abstrak – Penelitian ini mengimplementasikan *Convolutional Neural Network* (CNN) untuk mengenali Hieroglif Mesir kuno. CNN adalah salah satu arsitektur *deep learning* yang secara otomatis mempelajari fitur pada sebuah data secara hierarki. CNN secara efektif mengintegrasikan ekstraksi fitur dan pengklasifikasi ke dalam satu sistem. Penelitian ini menggunakan karakter hieroglif dari piramida Unas yang terdiri dari 170 jenis karakter, namun penelitian ini hanya menggunakan 11 jenis karakter yang memiliki jumlah sampel di atas 100 yaitu karakter D21, E34, G17, G43, I9, M17, N35, O50, S29, V31, dan X1. Hasil penelitian menunjukkan bahwa akurasi yang diperoleh mencapai 99%. Penelitian ini diharapkan dapat membantu arkeolog, peminat, turis, dan pengunjung museum untuk mengenali karakter atau tulisan hieroglif sebagai salah satu benda bersejarah yang hanya diketahui oleh beberapa orang saja.

Kata Kunci: pengenalan karakter, hieroglif Mesir kuno, *convolutional neural network*

Abstract – This research implements a *Convolutional Neural Network* (CNN) to recognize ancient Egyptian hieroglyphics. CNN is a deep learning architecture that automatically learns the features of data hierarchically. The CNN technique effectively integrates feature extraction and classifiers into one system. This study used hieroglyphic characters from the pyramid of Unas, which consisted of 170 kinds of characters, but this study only used 11 kinds of characters that had a sample size above 100, namely characters D21, E34, G17, G43, I9, M17, N35, O50, S29, V31, and X1. The results showed that the accuracy achieved was 99%. This research is expected to help archaeologists, enthusiasts, tourists, and museum visitors to recognize hieroglyphic characters as historical objects that only a few people know.

Keywords: character recognition, ancient Egyptian hieroglyphics, *convolutional neural network*

PENDAHULUAN

Hieroglif Mesir adalah salah satu sistem penulisan kuno di dunia yang merupakan naskah versi tertua, ditandai dengan tampilan gambarnya yang elegan. Hieroglif ini biasanya ditemukan dalam prasasti monumen dan konteks penguburan (Scoville, 2015). Penemuan arkeologi menunjukkan bahwa hieroglif Mesir mungkin merupakan bentuk tulisan tertua.

Salah satu hieroglif yang populer adalah hieroglif Maya. Peradaban Maya adalah salah satu zaman budaya paling signifikan di Mesoamerika pra-Columbus. Sebagian besar teks Maya disusun di atas monumen batu dan bejana tembikar sepanjang zaman klasik untuk melestarikan peristiwa sejarah (Hu et al., 2014). Selain hieroglif Maya, sebuah hieroglif dari piramida Unas diperkenalkan oleh Franken. Piramida ini dibangun pada dinasti kelima sebagai tempat pemakaman Firaun Unas dan terletak tepat di sebelah selatan kota Giza (Franken & van Gemert, 2013).

Saat ini di Mesir, bahasa Arab digunakan untuk berkomunikasi baik secara lisan maupun tulisan, sehingga menyebabkan pengetahuan kuno tentang

menulis dan membaca simbol-simbol seperti hieroglif menjadi terlupakan. Berdasarkan hal tersebut, untuk memahami makna hieroglif yang mengandung sejarah, budaya, agama, dan peradaban diperlukan ahli atau arkeolog.

Penggunaan *computer vision* dapat membantu para arkeolog dengan mengembangkan sistem yang dapat secara otomatis mengenali benda-benda bersejarah, misalnya hieroglif yang hanya diketahui oleh beberapa orang saja. Selain itu juga dapat membantu para peminat, turis, dan pengunjung museum (Franken & van Gemert, 2013).

Penelitian tentang hieroglif, khususnya hieroglif Maya telah banyak dikembangkan. Teknik BoVW digunakan untuk mengukur karakteristik lokal dan merepresentasikan keseluruhan bentuk menggunakan histogram, dan selanjutnya menggunakan *glyph co-occurrence* untuk melengkapi informasi visual dan membantu meningkatkan akurasi. HOOSC dan GF-HOG digunakan sebagai deskriptor bentuk lokal di dalam penelitian (Hu et al., 2014).

Perbaikan dalam deskriptor bentuk seperti HOOSC dirancang oleh Roman et al. dalam (Roman-Rangel et al., 2011). Kontur terbuka, kombinasi garis tebal dan tipis, variabilitas yang besar, dan berbagai detail internal dirancang untuk menangani kompleksitas visual hieroglif Maya. Penggabungan *Harris-Laplace* dan HOOSC mencapai hasil yang kompetitif untuk deteksi citra biner kompleks (hieroglif suku kata Maya) (Roman-Rangel et al., 2013)

Selain hieroglif Maya, Arrivault dan Richard memperkenalkan *Hierarchical-Fuzzy-Attributed Graph* (FHAG), yang memodelkan atribut dengan tata bahasa *fuzzy-tree*. Kemudian diintegrasikan ke dalam sistem pengenalan berdasarkan perbandingan model tunggal untuk hieroglif Mesir tulisan tangan (Arrivault et al., 2005).

Pengenalan hieroglif Mesir secara otomatis dengan mengambil gambar sebagai teks menggunakan dataset baru dari piramida Unas telah diperkenalkan di penelitian (Franken & van Gemert, 2013). Lima deskriptor citra, *Shape-Context* (SC), *Self Similarity* (SS), *Histogram of Oriented Gradients* (HOG), dan gabungan SC dan HOG disebut HOOSC, gabungan SS dan HOG disebut HOOSS digunakan dalam penelitian tersebut.

Secara umum, berdasarkan penelitian terkait pengenalan hieroglif, fitur gambar diekstraksi secara manual menggunakan deskriptor gambar kemudian diklasifikasi menggunakan *classifier* seperti *Support Vector Machine*, *Artificial Neural Network*, dan *classifier* lainnya. Beberapa penelitian telah dilakukan dengan menggunakan pendekatan pembelajaran mendalam (*deep learning*), yang secara otomatis mengekstrak fitur gambar. Salah satu arsitektur *deep learning* adalah *Convolutional Neural Network* (CNN).

CNN adalah teknik pengenalan yang populer dan efektif dalam pengenalan pola dan pemrosesan gambar. Karakteristiknya meliputi kemampuan beradaptasi dan parameter pelatihan yang lebih sedikit. CNN banyak digunakan dalam analisis suara dan identifikasi gambar (Liu et al., 2015). Performa CNN dapat dilihat pada penelitian (Ejaz & Islam, 2019), (Khandokar et al., 2021), dan (Ptucha et al., 2019).

Penelitian ini mengimplementasikan *Convolutional Neural Network* untuk mengenali hieroglif Mesir dari piramida Unas yang telah dibuat oleh peneliti sebelumnya (Franken & van Gemert, 2013). Metode *Convolutional Neural Network* (CNN) pertama kali diperkenalkan oleh Yann Lecun pada tahun 1998 (Lecun Yann and Y. Bengio, 1998). CNN banyak

digunakan untuk pengenalan karakter, objek, dan tulisan tangan karena dapat menghasilkan performa yang baik.

METODOLOGI PENELITIAN

Pengumpulan Data

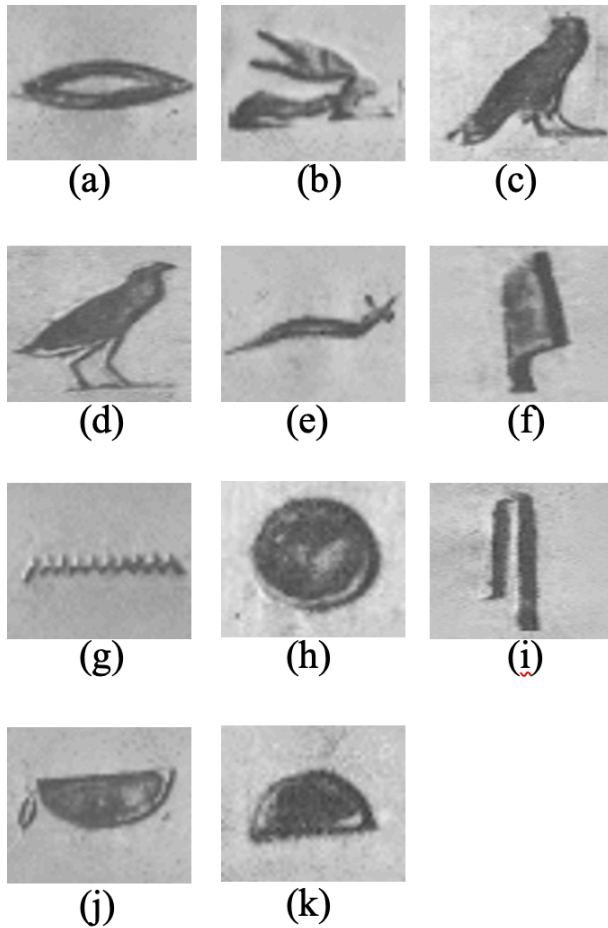
Data yang dihasilkan oleh Franken (Franken & van Gemert, 2013) digunakan dalam penelitian ini. Dataset terdiri dari dua set: gambar teks hieroglif dan korpus teks yang digunakan untuk membuat model bahasa. Peneliti secara manual membuat *bounding box* untuk mensegmentasi setiap karakter hieroglif yang selanjutnya diberi label masing-masing. Dataset terdiri dari 170 jenis karakter Hieroglif dengan total 3993 karakter. Namun dalam penelitian ini yang digunakan hanya jenis karakter Hieroglif yang memiliki sampel di atas 100 karakter atau lebih. Total karakter yang digunakan dalam penelitian ini untuk data pelatihan adalah 2136 yang terbagi ke dalam 11 jenis karakter, sedangkan untuk data pengujian adalah 255 karakter. Data pelatihan dan pengujian telah dipisahkan oleh peneliti sebelumnya. Distribusi data pada setiap jenis karakter yang digunakan dalam penelitian dapat dilihat pada Tabel 1.

Tabel 1 Distribusi Data pada Setiap Karakter/Kelas

Karakter/Kelas	Jumlah Data Training	Jumlah Data Testing
D21	165	18
E34	105	17
G17	175	19
G43	183	14
I9	124	22
M17	319	46
N35	403	45
O50	101	5
S29	238	27
V31	118	15
X1	205	27
Total	2136	255

Berdasarkan Tabel 1 terlihat bahwa sebaran data pada masing-masing karakter/kelas tidak seimbang. Karakter N35 memiliki jumlah sampel paling banyak, yaitu 403 karakter, sedangkan karakter O50 memiliki jumlah sampel paling sedikit yaitu 101 karakter.

Adapun contoh gambar pada setiap karakter dapat dilihat pada Gambar 1.



Gambar 1. Contoh Karakter Hieroglif (a). D21; (b). E34; (c) G17; (d). G43; (e) I9; (f). M17; (g). N35; (h). O50; (i). S29; (j). V31; (k). X1

Convolutional Neural Network

Yann Lecun dan Yoshua Bengio menemukan struktur jaringan unik yang dapat secara efisien mengurangi kompleksitas *Feedback Neural Network* yang selanjutnya mengusulkan *Convolution Neural Networks* (CNN), yang sebelumnya ditemukan oleh Hubel dan Wiesel (Lecun Yann and Y. Bengio, 1998).

Convolutional Neural Network (CNN) adalah salah satu jenis algoritma pembelajaran mendalam (*deep learning*) yang banyak digunakan untuk pengenalan gambar, pemrosesan bahasa alami, dan pengenalan suara.


Secara umum, CNN menggunakan tiga ide dasar: *local receptive field*, *shared weight*, dan *pooling*. *Input* dari setiap neuron terhubung ke *local receptive field* dari lapisan sebelumnya (lapisan tersembunyi), dan setiap koneksi memiliki bobot dan bias tunggal. *Mapping* dari lapisan *input* ke lapisan tersembunyi disebut *feature map*. Setiap *feature map* dapat mengekstraksi dan menghasilkan satu fitur yang berbeda dari data *input*.

Lapisan *convolutional* biasanya terdiri dari beberapa *feature map* dengan vektor bobot yang berbeda sehingga beberapa fitur dapat diekstraksi. *Convolutional Neural Networks* juga memiliki *pooling* atau *subsampling layer*. Lapisan *subsampling* biasanya digunakan setelah lapisan konvolusional. Lapisan *subsampling* menyederhanakan informasi dalam keluaran dari lapisan konvolusional (Michael Nielsen, 2015). Lapisan terakhir CNN dalam adalah *fully connected layer* yang memiliki arsitektur yang sama dengan *Multilayer Neural Network*. Namun, perlu dilakukan sedikit modifikasi pada prosedur *backpropagation* untuk lapisan *convolutional* dan *subsampling*.


CNN memiliki banyak arsitektur, pada penelitian ini menggunakan arsitektur MobileNet. MobileNet adalah salah satu arsitektur CNN yang dirancang untuk perangkat seluler. MobileNet memiliki jaringan efisien yang menggunakan konvolusi yang dapat dipisahkan secara mendalam.

MobileNet terdiri dari dua lapisan, yaitu *depthwise convolution* dan *pointwise convolution*. *Depthwise convolution* akan menerapkan filter tunggal pada setiap saluran input, sedangkan *pointwise convolution* akan membuat kombinasi linear dari *output layer depthwise* (Howard et al., 2017). Tujuan MobileNet adalah memperoleh akurasi tinggi dengan sumber daya pemrosesan seefisien mungkin. Untuk mencapai hal tersebut, arsitektur MobileNet memisahkan dimensi spasial dan saluran dari data *input* menggunakan konvolusi yang dapat dipisahkan secara mendalam, sejenis teknik konvolusional.


MobileNet juga mengusulkan *hyperparameter* global untuk mengurangi komputasi dan mengurangi dimensi gambar masukan. Dibandingkan dengan jaringan konvolusional konvensional, MobileNet memerlukan lebih sedikit parameter dan komputasi karena menggunakan konvolusi yang dapat dipisahkan secara mendalam. Hal ini memungkinkan model berjalan lebih cepat dan efektif dengan tetap mempertahankan akurasi tinggi.



Gambar 2. Lapisan Konvolusi Standar (Howard et al., 2017)



Gambar 3. Depthwise Convolution (Howard et al., 2017)



Gambar 4. Pointwise Convolution (Howard et al., 2017)

Type / Stride	Filter Shape	Input Size
Conv / s2	$3 \times 3 \times 3 \times 32$	$224 \times 224 \times 3$
Conv dw / s1	$3 \times 3 \times 32$ dw	$112 \times 112 \times 32$
Conv / s1	$1 \times 1 \times 32 \times 64$	$112 \times 112 \times 32$
Conv dw / s2	$3 \times 3 \times 64$ dw	$112 \times 112 \times 64$
Conv / s1	$1 \times 1 \times 64 \times 128$	$56 \times 56 \times 64$
Conv dw / s1	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 128$	$56 \times 56 \times 128$
Conv dw / s2	$3 \times 3 \times 128$ dw	$56 \times 56 \times 128$
Conv / s1	$1 \times 1 \times 128 \times 256$	$28 \times 28 \times 128$
Conv dw / s1	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 256$	$28 \times 28 \times 256$
Conv dw / s2	$3 \times 3 \times 256$ dw	$28 \times 28 \times 256$
Conv / s1	$1 \times 1 \times 256 \times 512$	$14 \times 14 \times 256$
5× Conv dw / s1	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 512$	$14 \times 14 \times 512$
Conv dw / s2	$3 \times 3 \times 512$ dw	$14 \times 14 \times 512$
Conv / s1	$1 \times 1 \times 512 \times 1024$	$7 \times 7 \times 512$
Conv dw / s2	$3 \times 3 \times 1024$ dw	$7 \times 7 \times 1024$
Conv / s1	$1 \times 1 \times 1024 \times 1024$	$7 \times 7 \times 1024$
Avg Pool / s1	Pool 7×7	$7 \times 7 \times 1024$
FC / s1	1024×1000	$1 \times 1 \times 1024$
Softmax / s1	Classifier	$1 \times 1 \times 1000$

Gambar 5. Arsitektur MobileNet

Evaluasi

Model yang telah dibangun dievaluasi menggunakan *confusion matrix*, akurasi, presisi, dan *recall*. Akurasi mengukur seberapa mirip prediksi dengan nilai sebenarnya. Ukuran akurasi adalah proporsi data yang diidentifikasi dengan benar untuk semua data pengujian.

$$Akurasi = \frac{\sum TP + \sum TN}{Jumlah\ Data} \quad (1)$$

$$Presisi = \frac{(TP)}{(TP)+(FP)} \quad (2)$$

$$Recall = \frac{(TP)}{(TP)+(FN)} \quad (3)$$

TP merupakan *True Positive*, FN merupakan *False Negative*, FP merupakan *False Positive*, dan TN merupakan *True Negative*. Suatu kondisi dikatakan TP atau TN Ketika suatu observasi dikenali dengan benar, sedangkan FP dan FN merupakan suatu observasi salah diidentifikasi.

Recall adalah rasio jumlah *record* relevan yang ditemukan dengan jumlah *record* yang ditemukan tidak relevan dan relevan, sedangkan presisi adalah rasio jumlah *record* relevan yang ditemukan dengan jumlah *record* yang ditemukan tidak relevan dan relevan. (Jizba, 2000).

HASIL DAN PEMBAHASAN

Pada penelitian ini proses pelatihan dilakukan dengan menggunakan library Keras dengan *backend* TensorFlow. Parameter yang digunakan: *learning rate*: 0,001, *epoch*: 25, *Batch Size* 32, dan *dropout* adalah 0,5 untuk mencegah *overfitting*. Tingkat akurasi yang dicapai adalah 99%.


Selain akurasi, nilai presisi dan *recall* pada masing-masing karakter/kelas juga dievaluasi, hasilnya dapat dilihat pada Tabel 2.

Tabel 2 Nilai Presisi dan *Recall* setiap Karakter Hieroglif

Karakter/ Kelas	Presisi	Recall
D21	100%	100%
E34	100%	100%
G17	95%	100%
G43	100%	100%
I9	100%	100%
M17	96%	98%
N35	100%	100%
O50	100%	100%
S29	100%	93%
V31	100%	100%
X1	100%	100%
Rata-rata	99%	99%


Rata-rata presisi dan *recall* yang diperoleh penelitian ini menggunakan CNN sebagai ekstraksi fitur dan *classifier* adalah 99%.

Confusion matrix pada penelitian ini dapat dilihat pada Gambar 6. Berdasarkan *confusion matrix*, terdapat 3 karakter Hieroglif yang salah dikenali yaitu karakter M17 salah dikenali sebagai karakter G17, dan 2 karakter S29 yang salah dikenali sebagai karakter M17.




Gambar 6. Confusion Matrix

Contoh karakter S29 (sebelah kiri) yang salah dikenali sebagai karakter M17 (sebelah kanan) dapat dilihat pada gambar 7. Dari Gambar 7, secara sepintas kedua karakter tersebut memiliki bentuk yang hampir sama tetapi merupakan karakter yang berbeda. Kualitas dari gambar juga mempengaruhi akurasi pengenalan.



Gambar 7. Karakter Hieroglif yang Salah Dikenali

Adapun grafik akurasi *training* dan validasi pada setiap *epoch* dapat dilihat pada Gambar 8.



Gambar 8. Grafik Akurasi *Training* dan Validasi pada Setiap *Epoch*

Hasil penelitian ini juga dibandingkan dengan penelitian sebelumnya yang dilakukan oleh Franken yang menggunakan kumpulan data yang sama dengan penelitian tersebut. Itu ditunjukkan pada Tabel 3.

Tabel 3 Perbandingan Akurasi dengan Penelitian Sebelumnya

Penulis	Metode	Dataset	Akurasi
Franken [4]	HOG	Pyr of Unas	83%
Darmatasia	CNN	Pyr of Unas	99%

Berdasarkan Tabel 3, metode yang diusulkan, yaitu menggunakan CNN sebagai ekstraksi fitur dan *classifier* untuk pengenalan hieroglif, memiliki akurasi yang lebih baik daripada penelitian sebelumnya yang dilakukan oleh Franken. mAP (*mean Average Precision*) juga dibandingkan dengan penelitian terkait lainnya yang ditunjukkan pada Tabel 4.

Tabel 4 Perbandingan mAP dengan Penelitian Sebelumnya

Penulis	Metode	Dataset	mAP
	GSC		0.236
	HOOSC-expl spat position	Maya Dataset	0.538
Roman [7]	GSC		0.813
	HOOSC-expl spat position	A-MPEG-7	0.867
Roman [8]	Harr Lapl-HOOSC	Maya Dataset	0.646
Darmatasia	CNN	Pyr of Unas	0.99

Tabel 4 menunjukkan bahwa metode yang diusulkan memiliki mAP terbaik. Selain itu, metode yang diimplementasikan dalam penelitian ini yaitu metode CNN juga dapat dievaluasi menggunakan dataset lain seperti hieroglif Maya atau dataset A-MPEG-7.

KESIMPULAN

Penelitian ini menggunakan *Convolutional Neural Network* (CNN) dengan arsitektur MobileNet untuk pengenalan karakter hieroglif Mesir.

Kelebihan dari metode CNN adalah fitur data dapat diekstraksi secara otomatis. Pada penelitian ini,

ekstraksi fitur dan *classifier* diintegrasikan ke dalam satu sistem pada CNN, sehingga membuat algoritma menjadi lebih efisien. Metode yang diusulkan memperoleh kinerja yang lebih baik dalam akurasi dan presisi daripada metode yang lain.

Namun pada penelitian ini data yang digunakan hanya sekitar setengah dari keseluruhan data dan hanya mengevaluasi tingkat pengenalan berdasarkan label data. Selanjutnya, metode yang diusulkan dapat diterapkan kembali dengan menggunakan semua data dan mengevaluasi tingkat pengenalan sesuai dengan kriteria Pascal VOC, model kata, dan n-gram. Selain itu, metode CNN juga perlu dievaluasi dengan menggunakan dataset lain seperti Maya hieroglif atau dataset A-MPEG-7.

maya hieroglyphs. *Proceedings of the 19th ACM International Conference on Multimedia*, 163–172. <https://doi.org/10.1145/2072298.2072321>
 Scoville, P. (2015). *Egyptian Hieroglyphs*. 02 July. http://www.ancient.eu/Egyptian_Hieroglyphs/

DAFTAR PUSTAKA

- Arrivault, D., Richard, N., & Bouyer, P. (2005). A fuzzy hierarchical attributed graph approach for handwritten egyptian hieroglyphs description and matching. *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR, 2005*, 898–902. <https://doi.org/10.1109/icdar.2005.11>
- Ejaz, M. S., & Islam, M. R. (2019). Masked face recognition using convolutional neural network. *2019 International Conference on Sustainable Technologies for Industry 4.0, STI, December 2019*. <https://doi.org/10.1109/STI47673.2019.9068044>
- Franken, M., & van Gemert, J. C. (2013). Automatic Egyptian hieroglyph recognition by retrieving images as texts. *Proceedings of the 21st ACM International Conference on Multimedia - MM '13*, 765–768. <https://doi.org/10.1145/2502081.2502199>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*. <https://doi.org/https://doi.org/10.48550/arXiv.1704.04861>
- Hu, R., Gayol, C. P., Krempel, G., Odobez, J.-M., & Gatica-Perez, D. (2014). Automatic Maya hieroglyph retrieval using shape and context information. *Proceedings of the ACM International Conference on Multimedia - MM '14*, 1037–1040. <https://doi.org/10.1145/2647868.2655044>
- Jizba, R. (2000). Measuring search effectiveness. *Creighton University Health Sciences Library and ...*. <http://scholar.google.com/scholar?hl=en&btnG=Search&q=intitle:Measuring+Search+Effectiveness#2>
- Khandokar, I., Hasan, M., Ernawan, F., Islam, S., & Kabir, M. N. (2021). Handwritten character recognition using convolutional neural network. *Journal of Physics: Conference Series*, 1918(4), 42152. <https://doi.org/10.1088/1742-6596/1918/4/042152>
- Lecun Yann and Y. Bengio. (1998). Convolutional Networks for Images, Speech, and Time-Series. *The Handbook of Brain Theory and Neural Network*, 255–258.
- Liu, T., Fang, S., Zhao, Y., Wang, P., & Zhang, J. (2015). Implementation of training convolutional neural networks. *ArXiv Preprint ArXiv:1506.01195*. <https://doi.org/https://doi.org/10.48550/arXiv.1506.01195>
- Michael Nielsen. (2015). *Deep Learning*. <http://neuralnetworksanddeeplearning.com/chap6.html>
- Ptucha, R., Such, F. P., Pillai, S., Brockler, F., Singh, V., & Hutkowski, P. (2019). Intelligent character recognition using fully convolutional neural networks. *Pattern Recognition*, 88, 604–613. <https://doi.org/https://doi.org/10.1016/j.patcog.2018.12.017>
- Roman-Rangel, E., Odobez, J.-M., & Gatica-Perez, D. (2013). *Evaluating Shape Descriptors for Detection of Maya Hieroglyphs BT - Pattern Recognition* (J. A. Carrasco-Ochoa, J. F. Martínez-Trinidad, J. S. Rodríguez, & G. S. di Baja (eds.); pp. 145–154). Springer Berlin Heidelberg. https://doi.org/https://doi.org/10.1007/978-3-642-38989-4_15
- Roman-Rangel, E., Pallan Gayol, C., Odobez, J.-M., & Gatica-Perez, D. (2011). Searching the past: an improved shape descriptor to retrieve