

DEEP LEARNING : REVIEW DAN IMPLEMENTASI

Aditya Cahyadi, Artiko Fajar, Benaya Sastro, Gamma Fitriani, Hanif Adhilaga

Universitas Negeri Malang, Jl. Semarang No.5, Sumber Sari, Kota Malang, Jawa Timur 65145

*Corresponding author, email: aditya.cahyadiputra@gmail.com

doi: 10.17977/um068.v4.i8.2024.5

Kata kunci

Big data
Analisa big data
Algoritma big data
Business intelligent
Deep learning

Abstrak

The abstract should be written in both English and Indonesian in one paragraph consists of maximum 250 words. The abstract should explain the purpose, method, and the result of the research concisely. An abstract should stand alone, means that no citation in the abstract. The abstract should be written in both English and Indonesian in one paragraph consists of maximum 250 words. The abstract should explain the purpose, method, and the result of the research concisely. An abstract should stand alone, means that no citation in the abstract. The abstract should be written in both English and Indonesian in one paragraph consists of maximum 250 words. The abstract should explain the purpose, method, and the result of the research concisely. An abstract should stand alone, means that no citation in the abstract. The abstract should be written in both English and Indonesian in one paragraph consists of maximum 250 words. The abstract should explain the purpose, method, and the result of the research concisely. An abstract should stand alone, means that no citation in the abstract.

1. Pendahuluan

Deep Learning telah menjadi salah satu topik hangat dalam hal machine learning karena kapabilitasnya yang signifikan dalam memodelkan berbagai data kompleks seperti citra dan suara. Contohnya pada perusahaan besar di dunia seperti google, facebook, dan apple sedang berlomba-lomba untuk membuat sistem berbasis deep learning. Mereka juga rela mengeluarkan jutaan dolar untuk meneliti deep learning. Beberapa metode yang ada pada Deep Learning yaitu Convolutional Neural Network (CNN), Restricted Boltzmann Machines (RBMs), dan Autoencoder (Xue & Ray, 2017) (Particke et al., 2017).

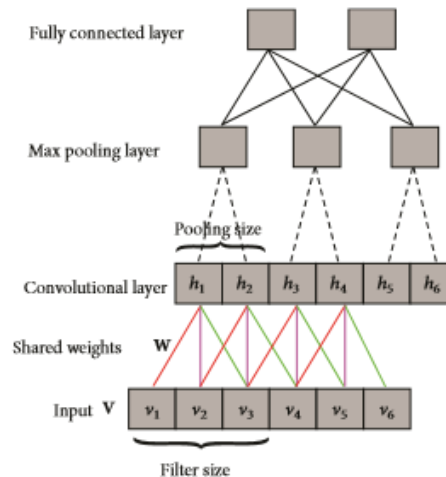
Convolutional Neural Network (CNN) pertama kali dikembangkan dengan nama Neocognitron oleh Kunihiko Fukushima, seorang peneliti dari NHK Broadcasting Science Research Laboratories, Kinuta, Setagaya, Tokyo, Jepang (Min et al., 2014). Kemudian konsep tersebut di kembangkan lagi oleh Yann LeCun, seorang peneliti dari AT&T Bell Laboratories di Holmdel, New Jersey, USA (Sharma et al., 2017). Pada tahun 2012, Alex Krizhevsky dengan penerapan CNN miliknya berhasil menjuarai kompetisi ImageNet Large Scale Visual Recognition Challenge 2012 (Muhammad & Novia Wisesty, 2017). Momen tersebut menjadi bukti bahwa metode CNN baik diterapkan dalam image processing seperti klasifikasi gambar, deteksi objek, dan lain-lain (Ersti & Wisesty, 2016).

Restricted Boltzmann Machines (RBMs) adalah salah satu metode yang ada pada deep learning. RBMs di kembangkan oleh Hinton et al pada tahun 1986 (Cao & Fan, 2014). RBM adalah varian dari mesin Boltzman, dengan batasan bahwa unit yang terlihat dan unit tersembunyi harus membentuk grafik bipartit (Ahmad, 2017). Pembatasan ini digunakan untuk mengefisienkan algoritma latihan, terutama algoritma divergensi berbasis gradien (Pyakillya et al., 2017).

Salah satu penemuan penting dalam Deep Learning sejak sekitar tahun 2000 adalah Deep Belief Network untuk melakukan pretraining pada arsitektur jaringan (Zulfa & Winarko, 2017). Pendekatan ini didasari dari pengamatan bahwa melakukan inisialisasi secara acak memberikan hasil yang kurang baik (Tang, 2013). Oleh sebab itu dilakukan pretraining dengan algoritma unsupervised learning dihasilkan inisialisasi nilai awal yang baik (Abdillah et al., 2016). Contoh algoritma unsupervised learning adalah Deep Belief Network, yang didasarkan pada Autoencoders (Glorot et al., 2011).

2. Metode

Pada bab ini dibahas tentang apa saja metode-metode yang ada pada penerapan Deep Learning. CNN sendiri adalah singkatan dari Convolutional Neural Network yang merupakan metode dari Deep Learning (Syulistyo et al., 2016). CNN pada umumnya diterapkan pada data image yang berfungsi untuk mendeteksi dan mengenali objek pada sebuah image (K. Nguyen et al., 2017) (Rere et al., 2015). CNN terdiri dari 3 lapisan kombinasi, yaitu lapisan konvolusi, lapisan pooling lapisan terhubung penuh. Arsitektur jaringan pada CNN tersebut ditunjukkan pada gambar 1 dibawah ini.



Gambar 1 Arsitektur jaringan CNN

2.1. Convolution Layer (Lapisan Konvolusi)

Konvolusi dapat diartikan sebagai pengaplikasian fungsi output dengan fungsi yang lain secara berulang. Tujuan dalam pengaplikasian fungsi konvolusion adalah untuk mengekstraksi fitur dari citra input (Socher & Huval, 2012). Dalam CNN proses konvolusi dapat ditulis menggunakan persamaan sebagai berikut:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) K(i - m, j - n)$$

Pada persamaan diatas, i adalah masukan dari gambar, sedangkan K adalah filter yang digunakan di proses konvolusi (Z. Y. Wu & Rahman, 2017). M adalah baris keberapa dalam gambar dan n adalah kolom keberapa dari gambar (Heinsfeld et al., 2018).

2.2. Pooling Layer (Lapisan Polling)

Pada proses pooling atau adalah proses untuk mengurangi data dalam citra (Hao et al., 2018). Tujuan dalam pengaplikasian lapisan pooling adalah meningkatkan invariasi posisi dari fitur Prosesnya hampir sama seperti proses konvolusi yaitu memfilter gambar masukan yang telah diproses di lapisan konvolusi (Shi et al., 2017). Begitu pula pada akhir jaringan syaraf yang telah terhubung penuh (Erdmann et al., 2018).


2.3. Fully Connected Layer (Lapisan Terhubung Penuh)

Pada proses layer ini tujuannya adalah untuk melakukan transformasi pada hasil pooling layer agar dapat diklasifikasikan kedalam bentuk linier (Kvam & Kongsro, 2017). Layer ini adalah proses yang terakhir dalam arsitektur metode CNN (Rere et al., 2015).

RBM adalah singkatan dari Restricted Boltzmann Machine yang merupakan salah satu dari metode Deep Learning (Mohsen et al., 2017). RBM sendiri merupakan varian Mesin Boltzmann yang berguna untuk menyingkat algoritma agar lebih efisien, terutama algoritma divergensi kontras berdasarkan gradien (Chen et al., 2018). Pada metode RBM ini mempunyai 3 model, yaitu Deep Belief Network (DBN), Deep Boltzmann Machine (DBM), Deep Energy Models (DEM).

Perbedaan dari 3 model tersebut adalah DBN mempunyai koneksi tidak langsung pada lapisan yang paling atas lalu membentuk RBM dan koneksi yang terarah ke lapisan bawahnya(Gibson et al., 2018). Lalu bila DBM mempunyai koneksi yang tidak langsung antara semua lapisan jaringan(Isin & Ozdalili, 2017). DEM mempunyai unit tersembunyi deterministik untuk lapisan bawah dan unit tersembunyi untuk lapisan atas(X. Wang et al., 2017).

Autoencoders adalah salah satu metode inti dari deep learning yang dipublikasikan pada tahun 2000an pada deep belief network penerapan deep learning belief network, pada awal inisiasi pembuatan metode autoencoders berdasarkan pengamatan bahwa disaat data yang diinisialisasi tidak terurut akan memberikan hasil yang kurang maksimal untuk memetakan prediksi(Loukas et al., 2017)(Yuan et al., 2016). Untuk meminimalisir hasil prediksi yang kurang maksimal pada saat inisialisasi data, maka dilakukan unsupervised learning dengan pendekatan autoencoders tersebut. Metode autoencoders berfungsi untuk memperbaiki data yang cacat atau rusak agar data yang diperoleh tetap bisa memberikan informasi yang kita perlukan, yang berarti autoencoders mengolah dengan memprediksi bagian yang rusak, dan autoencoders menggunakan beberapa denoising untuk meningkatkan akurasi dalam mengolah data sehingga diperoleh hasil pengkodean yang efisien(J. Liu et al., 2018).



Gambar 2. Autoencoder

3. Hasil Dan Pembahasan

Dewasa ini penerapan deep learning banyak diaplikasikan di kehidupan sehari-hari(Schuermans & Zinkevich, 2016)(Smith, 2017)(Kang & Choo, 2016). berbagai bidang mulai melakukan penerapan deep learning(van der Burgh et al., 2017). penggunaan deep learning ini kedepannya bisa mengurangi ketergantungan akan tenaga ahli dalam pengambilan keputusan(Araque et al., 2017). beberapa metode deep learning telah dijelaskan pada bab sebelumnya. Misalnya metode Convolutional Neural Network(CNN), Restricted Boltzmann Machine (RBM), Autoencoder(Yoo et al., 2018)(Sun et al., 2014)(Guimaraes et al., 2017). selanjutnya dalam paper ini akan dijelaskan tentang implementasi dari metode diatas.

Klasifikasi citra merupakan bagian dari jaringan syaraf konvolusi(Collobert & Weston, 2009)(Sun et al., 2014)(W. Liu et al., 2017). Pengklasifikasian citra ini bertujuan untuk mengklasifikasikan citra dalam pada deep learning metode Convolution Neural Network (CNN)(Wan et al., 2014)(Chothitham et al., 2014)(George & Huerta, 2017). Proses pengklasifikasian citra tersebut mengurangi 8.06% tingkat kesalahan data yang sedang di olah(Lenz et al., 2015)(Yu et al., 2014)(Denil et al., 2013). Pengimplementasian kalsifikasi citra antara lain terdapat pada bidang kesehatan untuk menghasilkan data hasil klasifikasi aritmia jantung dalam bentuk gelombang elektrodigram (EKG) yang diproses menjadi jaringan gambar sederhana untuk dikelompokkan berdasarkan nilai elektrodigram dan kondisi jantung pasien(Z. Wu et al., 2014)(Ouyang & Wang, 2013). Selain menghasilkan data, klasifikasi citra juga dapat dilatih untuk mempelajari dataset berupa gambar dengan tujuan klasifikasi citra dapat membandingkan data uji gambar dengan dataset yang sebelumnya telah dipelajari oleh algoritma klasifikasi citra untuk menghasilkan pengkategorian atau pengelompokan jenis data uji gambar tersebut(Guo et al., 2016). Selain pada bidang kesehatan, klasifikasi citra juga di implementasikan pada bida disaster, yaitu memproses gambar dari CCTV umum untuk mengklasifikasikan kondisi tersebut termasuk apakah.dalam(Stevenson et al., 1990)(Bengio et al., 2012).

Deteksi objek pada jaringan syaraf konvolusi berfungsi untuk m1enangkap suatu kondisi pada suatu objek untuk diterjemahkan dan serta diproses untuk dikelompokkan atau diinisialisasi oleh

klafisikasi citra(Costilla-Reyes et al., 2017)(Yan et al., 2018). Deteksi objek ini diimplementasikan beberapa bidang kesehatan, antara lain mendeteksi kondisi scan otak untuk diolah menjadi data gambar dan diproses oleh klasifikasi citra(Ouyang et al., 2014)(Le et al., 2011).

Image Retrival bertujuan untuk menemukan gambar sejenis, identik, mirip, atau mendekati ciri-ciri dari data gambar yang diolah(W. X. Liu et al., 2017)(Mehmood et al., 2017)(Ravi, Wong, Deligianni, et al., 2017). Image retrieval ini diimplementasikan pada mesin pencari data diri penduduk(Yang et al., 2017)(G. Wang et al., 2018). Dengan memasukkan gambar sketsa atau gambar diri seseorang, mesin akan mencari data diri data gambar tersebut meskipun penduduk tersebut telah mengalami perubahan dengan catatan tidak terlalu signifikan(Akhtar & Mian, 2018).

Semantic Segmentation ini berfokus pada pencarian objek gambar melalui pendekatan nilai piksel, lokasi piksel, dan urutan piksel(B.-F. Wu & Lin, 2018)(Elmisery et al., 2018)(H. Liu et al., 2017). Dengan bermodalkan hal tersebut, akan dilakukan prediksi dari data gambar yang diuji tanpa mengestraksi citra mentahnya(Zhao et al., 2017)(N. D. Nguyen et al., 2017). Semantic segmentation diimplementasikan pada face recognition untuk mendeteksi ekspresi wajah(Maimo et al., 2018)(Conneau et al., 2016).

Penggunaan RBM sangat luas, ini karena metode ini memiliki kerumitan sendiri(Z. Wang, 2015). dengan kerumitannya metode ini memungkinkan proses pelatihan lebih efisien(Ravi, Wong, Lo, et al., 2017)(Dimitrovski et al., 2015)(Pei et al., 2017). salahsatunya yang digunakan adalah pada deteksi malware pada android. dalam mendeteksi sebuah malware diperlukan pelukisan karakter(Bar et al., 2015)(Melucci, 2016). malware memiliki berbagai nama dan jenis, tetapi dengan menggunakan metode ini pendeteksian akan lebih mudah(Sundsøy et al., 2016)(Huval et al., 2015)(Z. Liu et al., 2015). ini karena tingkat efisiensi pada saat pelatihan yang tinggi maka dapat meningkatkan akurasi dari pendeteksian malware ini(Ahmed et al., 2015).

Selain pada pendeteksian malware metode ini dapat juga digunakan pada bidang kesehatan(Carrio et al., 2017)(Y. Wang, 2016)(Holden et al., 2016). menyangkut masalah kesehatan yang begitu kompleks metode ini juga sangat cocok(Ozbolat, 2017)(W. Wang et al., 2016). misalnya pada suatu wilayah, dengan data demografinya dapat diprediksi penyakit yang mungkin diderita oleh penduduknya(Zhu et al., 2013)(Lustberg et al., 2017). ini sangat berguna bagi puskesmas atau rumahsakit yang berada di sekitar daerah tersebut(Sallab et al., 2015)(Hanif Tnn-94-Gradient.Pdf, n.d.)(Putra, 2016). bagi pelayan kesehatan yang mampu mendapat informasi ini dapat mempersiapkan obat dan peralatan medis secara dini(Erickson et al., 2018)(Maymin, 2017)(Vieira et al., 2017)(Chotitham et al., 2014). dengan pencegahan dini ini dapat pula menekan angka kematian akibat penyakit di daerah tersebut.Juga deep learning telah membantu meningkatkan teraf kesehatan masyarakat. Deep learning telah berkontribusi banyak dalam pengolahan data.

4. KESIMPULAN

Kesimpulan yang dapat diambil dalam pembuatan review ini adalah terdapat metode-metode Deep Learning, yaitu metode CNN, metode RBM, dan metode Autoencoders. Metode - metode tersebut dapat diimplementasikan di berbagai bidang. Contohnya adalah pengelompokan aritmia jantung pada pasien penderita kelainan jantung, klasifikasi citra dari cctv umum untuk menentukan ada atau tidaknya tanda bahaya, pengolahan citra gambar untuk menemukan data yang sejenis, dan masih banyak contoh-contoh lainnya. Harapan untuk kedepannya adalah agar metode metode deep learning dapat terus dikembangkan dan menjadi alternatif penyelesaian penyelesaian masalah yang ada pada kehidupan kita.

Daftar Rujukan

- Abdillah, M., ... J. N., & 2016, undefined. (2016). Using Deep Learning To Predict Customer Churn In A Mobile Telecommunication Network.Telkomuniversity.Ac.Id, 3(2), 3882-3888.
- Ahmad, A. (2017). Mengenal Artificial Intelligence , Machine Learning , Neural Network , dan Deep Learning. June.
- Ahmed, E., Jones, M., & Marks, T. K. (2015). An improved deep learning architecture for person re-identification. 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 3908-3916. <https://doi.org/10.1109/CVPR.2015.7299016>
- Akhtar, N., & Mian, A. (2018). Threat of Adversarial Attacks on Deep Learning in Computer Vision: A Survey. 4(c). <https://doi.org/10.1109/ACCESS.2018.2807385>

- Araque, O., Corcuera-Platas, I., Sánchez-Rada, J. F., & Iglesias, C. A. (2017). Enhancing deep learning sentiment analysis with ensemble techniques in social applications. *Expert Systems with Applications*, 77, 236–246. <https://doi.org/10.1016/j.eswa.2017.02.002>
- Bar, Y., Diamant, I., Wolf, L., Lieberman, S., Konen, E., & Greenspan, H. (2015). Chest pathology detection using deep learning with non-medical training. *Proceedings - International Symposium on Biomedical Imaging*, 2015–July, 294–297. <https://doi.org/10.1109/ISBI.2015.7163871>
- Bengio, Y., Courville, A., & Vincent, P. (2012). Representation Learning: A Review and New Perspectives. 1–30. <https://doi.org/10.1145/1756006.1756025>
- Cao, L., & Fan, J. (2014). Deep Learning in Computer Vision and NLP. 1–14.
- Carrio, A., Sampedro, C., Rodriguez-Ramos, A., & Campoy, P. (2017). A review of deep learning methods and applications for unmanned aerial vehicles. *Journal of Sensors*, 2017. <https://doi.org/10.1155/2017/3296874>
- Chen, H., Engkvist, O., Wang, Y., Olivecrona, M., & Blaschke, T. (2018). The rise of deep learning in drug discovery. *Drug Discovery Today*, 00(00), 1–10. <https://doi.org/10.1016/j.drudis.2018.01.039>
- Chotitham, S., Wongwanich, S., & Wiratchai, N. (2014). Deep Learning and its Effects on Achievement. *Procedia - Social and Behavioral Sciences*, 116(1), 3313–3316. <https://doi.org/10.1016/j.sbspro.2014.01.754>
- Collobert, R., & Weston, J. (2009). Deep Learning for Natural Language Processing. Slides, 1–113. <https://doi.org/10.1.1.678.8129>
- Conneau, A., Schwenk, H., Barrault, L., & Lecun, Y. (2016). Very Deep Convolutional Networks for Text Classification. *Künstliche Intelligenz*, 26(4), 357–363. <https://doi.org/10.1007/s13218-012-0198-z>
- Costilla-Reyes, O., Scully, P., & Ozanyan, K. B. (2017). Deep Neural Networks for Learning Spatio-Temporal Features from Tomography Sensors. *IEEE Transactions on Industrial Electronics*, 65(1), 1–1. <https://doi.org/10.1109/TIE.2017.2716907>
- Denil, M., Shakibi, B., Dinh, L., Ranzato, M., & de Freitas, N. (2013). Predicting Parameters in Deep Learning. 1–9.
- Dimitrovski, I., Kocev, D., Kitanovski, I., Loskovska, S., & Džeroski, S. (2015). Improved medical image modality classification using a combination of visual and textual features. *Computerized Medical Imaging and Graphics*, 39, 14–26. <https://doi.org/10.1016/j.compmedimag.2014.06.005>
- Elmisery, A. M., Sertovic, M., & Gupta, B. B. (2018). Cognitive Privacy Middleware for Deep Learning Mashup in Environmental IoT. *IEEE Access*, 6(0518798), 8029–8041. <https://doi.org/10.1109/ACCESS.2017.2787422>
- Erdmann, M., Glombitza, J., & Walz, D. (2018). A deep learning-based reconstruction of cosmic ray-induced air showers. *Astroparticle Physics*, 97, 46–53. <https://doi.org/10.1016/j.astropartphys.2017.10.006>
- Erickson, B. J., Korfiatis, P., Kline, T. L., Akkus, Z., Philbrick, K., & Weston, A. D. (2018). Deep Learning in Radiology: Does One Size Fit All? *Journal of the American College of Radiology*, 1–6. <https://doi.org/10.1016/j.jacr.2017.12.027>
- Ersti, R., & Wisesty, U. N. (2016). Klasifikasi Sinyal EEG Menggunakan Deep Neural Network EEG Signal Classification using Deep Neural Network. 3(3), 5213–5220.
- George, D., & Huerta, E. A. (2017). Deep Learning for Real-time Gravitational Wave Detection and Parameter Estimation: Results with Advanced LIGO Data. *Physics Letters B*, 778, 64–70. <https://doi.org/10.1016/j.physletb.2017.12.053>
- Gibson, E., Li, W., Sudre, C., Fidon, L., Shakir, D. I., Wang, G., Eaton-Rosen, Z., Gray, R., Doel, T., Hu, Y., Whyntie, T., Nachev, P., Modat, M., Barratt, D. C., Ourselin, S., Cardoso, M. J., & Vercauteren, T. (2018). NiftyNet: a deep-learning platform for medical imaging. *Computer Methods and Programs in Biomedicine*, 158, 113–122. <https://doi.org/10.1016/j.cmpb.2018.01.025>
- Glorot, X., Bordes, A., & Bengio, Y. (2011). Domain Adaptation for Large-Scale Sentiment Classification: A Deep Learning Approach. *Proceedings of the 28th International Conference on Machine Learning*, 1, 513–520.
- Guimaraes, R. G., Rosa, R. L., De Gaetano, D., Rodriguez, D. Z., & Bressan, G. (2017). Age Groups Classification in Social Network Using Deep Learning. *IEEE Access*, 5, 10805–10816. <https://doi.org/10.1109/ACCESS.2017.2706674>
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48. <https://doi.org/10.1016/j.neucom.2015.09.116>
- Hanif tnn-94-gradient.pdf. (n.d.).
- Hao, Y., Khoo, H. M., von Ellenrieder, N., Zazubovits, N., & Gotman, J. (2018). DeepIED: An epileptic discharge detector for EEG-fMRI based on deep learning. *NeuroImage: Clinical*, 17(June 2017), 962–975. <https://doi.org/10.1016/j.nicl.2017.12.005>
- Heinsfeld, A. S., Franco, A. R., Craddock, R. C., Buchweitz, A., & Meneguzzi, F. (2018). Identification of autism spectrum disorder using deep learning and the ABIDE dataset. *NeuroImage: Clinical*, 17(June 2017), 16–23. <https://doi.org/10.1016/j.nicl.2017.08.017>
- Holden, D., Saito, J., & Komura, T. (2016). A deep learning framework for character motion synthesis and editing. *ACM Transactions on Graphics*, 35(4), 1–11. <https://doi.org/10.1145/2897824.2925975>
- Huval, B., Wang, T., Tandon, S., Kiske, J., Song, W., Pazhayampallil, J., Andriluka, M., Rajpurkar, P., Migimatsu, T., Cheng-Yue, R., Mujica, F., Coates, A., & Ng, A. Y. (2015). An Empirical Evaluation of Deep Learning on Highway Driving. 1–7.

- Insin, A., & Ozdalili, S. (2017). Cardiac arrhythmia detection using deep learning. *Procedia Computer Science*, 120, 268–275. <https://doi.org/10.1016/j.procs.2017.11.238>
- Kang, B., & Choo, H. (2016). A deep-learning-based emergency alert system. *ICT Express*, 2(2), 67–70. <https://doi.org/10.1016/j.icte.2016.05.001>
- Kvam, J., & Kongsro, J. (2017). In vivo prediction of intramuscular fat using ultrasound and deep learning. *Computers and Electronics in Agriculture*, 142(September), 521–523. <https://doi.org/10.1016/j.compag.2017.11.020>
- Le, Q. V., Coates, A., Prochnow, B., & Ng, A. Y. (2011). On Optimization Methods for Deep Learning. *Proceedings of The 28th International Conference on Machine Learning (ICML)*, 265–272. <https://doi.org/10.1.1.220.8705>
- Lenz, I., Lee, H., & Saxena, A. (2015). Deep learning for detecting robotic grasps. *International Journal of Robotics Research*, 34(4–5), 705–724. <https://doi.org/10.1177/0278364914549607>
- Liu, H., Taniguchi, T., Tanaka, Y., Takenaka, K., & Bando, T. (2017). Visualization of Driving Behavior Based on Hidden Feature Extraction by Using Deep Learning. *IEEE Transactions on Intelligent Transportation Systems*, 18(9), 2477–2489. <https://doi.org/10.1109/TITS.2017.2649541>
- Liu, J., Pan, Y., Li, M., Chen, Z., Tang, L., Lu, C., & Wang, J. (2018). Applications of deep learning to MRI images: A survey. *Big Data Mining and Analytics*, 1(1), 1–18. <https://doi.org/10.26599/BDMA.2018.9020001>
- Liu, W. X., Zhang, J., Liang, Z. W., Peng, L. X., & Cai, J. (2017). Content Popularity Prediction and Caching for ICN: A Deep Learning Approach with SDN. *IEEE Access*, 5, 5075–5089. <https://doi.org/10.1109/ACCESS.2017.2781716>
- Liu, W., Zhang, M., Luo, Z., & Cai, Y. (2017). An Ensemble Deep Learning Method for Vehicle Type Classification on Visual Traffic Surveillance Sensors. *IEEE Access*, 5, 24417–24425. <https://doi.org/10.1109/ACCESS.2017.2766203>
- Liu, Z., Luo, P., Wang, X., & Tang, X. (2015). Deep learning face attributes in the wild. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 3730–3738. <https://doi.org/10.1109/ICCV.2015.425>
- Loukas, G., Vuong, T., Heartfield, R., Sakellari, G., Yoon, Y., & Gan, D. (2017). Cloud-based cyber-physical intrusion detection for vehicles using Deep Learning. *IEEE Access*, PP(99), 1. <https://doi.org/10.1109/ACCESS.2017.2782159>
- Lustberg, T., van Soest, J., Gooding, M., Peressutti, D., Aljabar, P., van der Stoep, J., van Elmpt, W., & Dekker, A. (2017). Clinical evaluation of atlas and deep learning based automatic contouring for lung cancer. *Radiotherapy and Oncology*. <https://doi.org/10.1016/j.radonc.2017.11.012>
- Maimo, L. F., Gomez, A. L. P., Clemente, F. J. G., Perez, M. G., & Perez, G. M. (2018). A Self-Adaptive Deep Learning-Based System for Anomaly Detection in 5G Networks. *IEEE Access*, 3536(c), 1–12. <https://doi.org/10.1109/ACCESS.2018.2803446>
- Maymin, P. Z. (2017). Wage against the machine: A generalized deep-learning market test of dataset value. *International Journal of Forecasting*. <https://doi.org/10.1016/j.ijforecast.2017.09.008>
- Mehmood, R. M., Du, R., & Lee, H. Y. O. J. (2017). SPECIAL SECTION ON ADVANCES OF MULTISENSORY SERVICES AND Optimal Feature Selection and Deep Learning Ensembles Method for Emotion Recognition From Human Brain EEG Sensors. 5, 14797–14806.
- Melucci, M. (2016). Relevance Feedback Algorithms Inspired by Quantum Detection. *IEEE Transactions on Knowledge and Data Engineering*, 28(4), 1022–1034. <https://doi.org/10.1109/TKDE.2015.2507132>
- Min, W., Ha, E. Y., Rowe, J., Mott, B., & Lester, J. (2014). Deep Learning-Based Goal Recognition in Open-Ended Digital Games. *Proceedings of the 10th AAAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, 37–43.
- Mohsen, H., El-Dahshan, E.-S. A., El-Horbaty, E.-S. M., & Salem, A.-B. M. (2017). Classification using Deep Learning Neural Networks for Brain Tumors. *Future Computing and Informatics Journal*. <https://doi.org/10.1016/j.fcij.2017.12.001>
- Muhammad, I., & Novia Wisesty, U. (2017). Klasifikasi Sinyal Ecg Menggunakan Deep Learning Dengan Stacked Denoising Autoencoders Ecg Signal Classification Using Deep Learning With Stacked Denoising Autoencoders. 4(3), 4719–4724.
- Nguyen, K., Fookes, C., Ross, A., & Sridharan, S. (2017). Iris Recognition with Off-the-Shelf CNN Features: A Deep Learning Perspective. *IEEE Access*, 1–9. <https://doi.org/10.1109/ACCESS.2017.2784352>
- Nguyen, N. D., Nguyen, T., & Nahavandi, S. (2017). System Design Perspective for Human-Level Agents Using Deep Reinforcement Learning: A Survey. *IEEE Access*, PP(99), 1. <https://doi.org/10.1109/ACCESS.2017.2777827>
- Ouyang, W., Chu, X., & Wang, X. (2014). Multi-source Deep Learning for Human Pose Estimation. *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2337–2344. <https://doi.org/10.1109/CVPR.2014.299>
- Ouyang, W., & Wang, X. (2013). Joint deep learning for pedestrian detection. *Proceedings of the IEEE International Conference on Computer Vision*, 2056–2063. <https://doi.org/10.1109/ICCV.2013.257>
- Ozolat, I. T. (2017). Introduction. *3D Bioprinting*, 18(1), 1–12. <https://doi.org/10.1016/B978-0-12-803010-3.00001-9>
- Particke, F., Kolbenshlag, R., Hiller, M., Patiño-Studencki, L., & Thielecke, J. (2017). Deep Learning for Real-Time Capable Object Detection and Localization on Mobile Platforms. *IOP Conference Series: Materials Science and Engineering*, 261, 012005. <https://doi.org/10.1088/1757-899X/261/1/012005>
- Pei, K., Cao, Y., Yang, J., & Jana, S. (2017). DeepXplore: Automated Whitebox Testing of Deep Learning Systems. <https://doi.org/10.1145/3132747.3132785>
- Putra, I. W. S. E. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101. *Jurnal Teknik ITS*, 5(1), 65–69.

- Pyakillya, B., Kazachenko, N., & Mikhailovsky, N. (2017). Deep Learning for ECG Classification. *Journal of Physics: Conference Series*, 913(1). <https://doi.org/10.1088/1742-6596/913/1/012004>
- Ravi, D., Wong, C., Deligianni, F., Berthelot, M., Andreu-Perez, J., Lo, B., & Yang, G. Z. (2017). Deep Learning for Health Informatics. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 4–21. <https://doi.org/10.1109/JBHI.2016.2636665>
- Ravi, D., Wong, C., Lo, B., & Yang, G.-Z. (2017). A Deep Learning Approach to on-Node Sensor Data Analytics for Mobile or Wearable Devices. *IEEE Journal of Biomedical and Health Informatics*, 21(1), 56–64. <https://doi.org/10.1109/JBHI.2016.2633287>
- Rere, L. M. R., Fanany, M. I., & Arymurthy, A. M. (2015). Simulated Annealing Algorithm for Deep Learning. *Procedia Computer Science*, 72, 137–144. <https://doi.org/10.1016/j.procs.2015.12.114>
- Sallab, A. A. Al, Baly, R., & Hajj, H. (2015). Deep Learning Models for Sentiment Analysis in Arabic. *ANLP Workshop ...*, November, 9–17. <https://doi.org/10.13140/RG.2.1.4537.4167>
- Schuurmans, D., & Zinkevich, M. (2016). Deep Learning Games. *Nips*, 1–9.
- Sharma, M., Anuradha, J., Manne, H. K., & Kashyap, G. S. C. (2017). Facial detection using deep learning. *IOP Conference Series: Materials Science and Engineering*, 263, 042092. <https://doi.org/10.1088/1757-899X/263/4/042092>
- Shi, H., Xu, M., Ma, Q., Zhang, C., Li, R., & Li, F. (2017). A Whole System Assessment of Novel Deep Learning Approach on Short-Term Load Forecasting. *Energy Procedia*, 142, 2791–2796. <https://doi.org/10.1016/j.egypro.2017.12.423>
- Smith, L. N. (2017). Best Practices for Applying Deep Learning to Novel Applications. *ArXiv*, 1–10.
- Socher, R., & Huval, B. (2012). Convolutional-recursive deep learning for 3D object classification. *Advances in Neural ...*, i, 1–9.
- Stevenson, M., Winter, R., & Widrow, B. (1990). Sensitivity of Feedforward Neural Networks to Weight Errors. *IEEE Transactions on Neural Networks*, 1(1), 71–80. <https://doi.org/10.1109/72.80206>
- Sun, Y., Wang, X., & Tang, X. (2014). Deep learning face representation from predicting 10,000 classes. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1891–1898. <https://doi.org/10.1109/CVPR.2014.244>
- Sundsøy, P. R., Bjelland, J., Iqbal, A. M., & Jahani, E. (2016). Deep Learning Applied to Mobile Phone Data for Individual Income Classification. *Icaita*, 96–99.
- Syulistyo, A. R., Jati Purnomo, D. M., Rachmadi, M. F., & Wibowo, A. (2016). Particle Swarm Optimization (Pso) for Training Optimization on Convolutional Neural Network (Cnn). *Jurnal Ilmu Komputer Dan Informasi*, 9(1), 52. <https://doi.org/10.21609/jiki.v9i1.366>
- Tang, Y. (2013). Deep Learning using Linear Support Vector Machines. *Deeplearning.Net*.
- van der Burgh, H. K., Schmidt, R., Westeneng, H. J., de Reus, M. A., van den Berg, L. H., & van den Heuvel, M. P. (2017). Deep learning predictions of survival based on MRI in amyotrophic lateral sclerosis. *NeuroImage: Clinical*, 13, 361–369. <https://doi.org/10.1016/j.nicl.2016.10.008>
- Vieira, S., Pinaya, W. H. L., & Mechelli, A. (2017). Using deep learning to investigate the neuroimaging correlates of psychiatric and neurological disorders: Methods and applications. *Neuroscience and Biobehavioral Reviews*, 74, 58–75. <https://doi.org/10.1016/j.neubiorev.2017.01.002>
- Wan, J., Wang, D., Hoi, S. C. H., & Wu, P. (2014). Deep Learning for Content-Based Image Retrieval: A Comprehensive Study. *Proceedings of the ACM International Conference on Multimedia (MM)*, 157–166.
- Wang, G., Li, W., Zuluaga, M. A., Pratt, R., Patel, P. A., Aertsen, M., Doel, T., David, A. L., Deprest, J., Ourselin, S., & Vercauteren, T. (2018). Interactive Medical Image Segmentation using Deep Learning with Image-specific Fine-tuning. *IEEE Transactions on Medical Imaging*, 1–12. <https://doi.org/10.1109/TMI.2018.2791721>
- Wang, W., Zhang, M., Chen, G., Jagadish, H. V., Ooi, B. C., & Tan, K.-L. (2016). Database Meets Deep Learning. *ACM SIGMOD Record*, 45(2), 17–22. <https://doi.org/10.1145/3003665.3003669>
- Wang, X., Gao, L., & Mao, S. (2017). BiLoc: Bi-Modal Deep Learning for Indoor Localization with Commodity 5GHz WiFi. *IEEE Access*, 5, 4209–4220. <https://doi.org/10.1109/ACCESS.2017.2688362>
- Wang, Y. (2016). Application of Deep Learning to Biomedical Informatics. *International Journal of Applied Science - Research and Review*, 03(05), 3–5. <https://doi.org/10.21767/2349-7238.100048>
- Wang, Z. (2015). *The Applications of Deep Learning on Traffic Identification*. Black Hat USA.
- Wu, B.-F., & Lin, C.-H. (2018). Adaptive Feature Mapping for Customizing Deep Learning Based Facial Expression Recognition Model. *IEEE Access*, XX(c), 1–1. <https://doi.org/10.1109/ACCESS.2018.2805861>
- Wu, Z., Jiang, Y.-G., Wang, J., Pu, J., & Xue, X. (2014). Exploring Inter-feature and Inter-class Relationships with Deep Neural Networks for Video Classification. *Proceedings of the ACM International Conference on Multimedia - MM '14*, 167–176. <https://doi.org/10.1145/2647868.2654931>
- Wu, Z. Y., & Rahman, A. (2017). Optimized Deep Learning Framework for Water Distribution Data-Driven Modeling. *Procedia Engineering*, 186, 261–268. <https://doi.org/10.1016/j.proeng.2017.03.240>
- Xue, Y., & Ray, N. (2017). Cell Detection with Deep Convolutional Neural Network and Compressed Sensing. 1–29.

- Yan, H., Wan, J., Zhang, C., Tang, S., Hua, Q., & Wang, Z. (2018). Industrial Big Data Analytics for Prediction of Remaining Useful Life Based on Deep Learning. *IEEE Access*, 3536(c), 1-1. <https://doi.org/10.1109/ACCESS.2018.2809681>
- Yang, P.-C., Sasaki, K., Suzuki, K., Kase, K., Sugano, S., & Ogata, T. (2017). Repeatable Folding Task by Humanoid Robot Worker Using Deep Learning. *IEEE Robotics and Automation Letters*, 2(2), 397-403. <https://doi.org/10.1109/LRA.2016.2633383>
- Yoo, Y., Tang, L. Y. W., Brosch, T., Li, D. K. B., Kolind, S., Vavasour, I., Rauscher, A., MacKay, A. L., Traboulsee, A., & Tam, R. C. (2018). Deep learning of joint myelin and T1w MRI features in normal-appearing brain tissue to distinguish between multiple sclerosis patients and healthy controls. *NeuroImage: Clinical*, 17(October 2017), 169-178. <https://doi.org/10.1016/j.nicl.2017.10.015>
- Yu, L., Hermann, K. M., Blunsom, P., & Pulman, S. (2014). Deep Learning for Answer Sentence Selection. 1-9.
- Yuan, Z., Lu, Y., & Xue, Y. (2016). Droiddetector: Android malware characterization and detection using deep learning. *Tsinghua Science and Technology*, 21(1), 114-123. <https://doi.org/10.1109/TST.2016.7399288>
- Zhao, L., Sun, Q., & Zhang, Z. (2017). Single Image Super-Resolution Based on Deep Learning Features and Dictionary Model. *IEEE Access*, 5(Cccv), 17126-17135. <https://doi.org/10.1109/ACCESS.2017.2736058>
- Zhu, Z., Luo, P., Wang, X., & Tang, X. (2013). Deep learning identity-preserving face space. *Proceedings of the IEEE International Conference on Computer Vision*, 113-120. <https://doi.org/10.1109/ICCV.2013.21>
- Zulfa, I., & Winarko, E. (2017). Sentimen Analisis Tweet Berbahasa Indonesia Dengan Deep Belief Network. *IJCCS (Indonesian Journal of Computing and Cybernetics Systems)*, 11(2), 187. <https://doi.org/10.22146/ijccs.24716>