

# DEEP LEARNING

Teori, Algoritma, dan Aplikasi

Tim Penulis:

Norbertus Tri Suswanto Saptadi

Hedie Kristiawan

Agung Yuliyanto Nugroho

Nina Rahayu

Suwarniyati

Bayu Waseso

Indo Intan

Khairunnas

Martono

Pramana Yoga Saputra

Sutriawan

Soekarman

Kodrat Mahatma

Imam Yunianto

Oleh Soleh

Muh. Nurtanzis Sutoyo

Bambang Siswoyo

Aliyah

Editor: Nur Azizah

# ***DEEP LEARNING***

Teori, Algoritma, dan Aplikasi

**Norbertus Tri Suswanto Saptadi**

**Hedie Kristiawan**

**Agung Yuliyanto Nugroho**

**Nina Rahayu**

**Suwarniyati**

**Bayu Waseso**

**Indo Intan**

**Khairunnas**

**Martono**

**Pramana Yoga Saputra**

**Sutriawan**

**Soekarman**

**Kodrat Mahatma**

**Imam Yunianto**

**Oleh Soleh**

**Muh. Nurtanzis Sutoyo**

**Bambang Siswoyo**

**Aliyah**

# ***DEEP LEARNING***

Teori, Algoritma, dan Aplikasi

**Tim Penulis:**

Norbertus Tri Suswanto Saptadi  
Hedie Kristiawan  
Agung Yuliyanto Nugroho  
Nina Rahayu  
Suwarmiyati  
Bayu Waseso  
Indo Intan  
Khairunnas  
Martono  
Pramana Yoga Saputra  
Sutriawan  
Soekarman  
Kodrat Mahatma  
Imam Yunianto  
Oleh Soleh  
Muh. Nurtanzis Sutoyo  
Bambang Siswoyo  
Aliyah

**Editor** : Dr. Nur Azizah, S.Kom., M.Akt., M.Kom.  
**Tata Letak** : Asep Nugraha, S.Hum.  
**Desain Cover** : Septimike Yourintan Mutiara, S.Gz.  
**Ukuran** : UNESCO 15,5 x 23 cm  
**Halaman** : ix, 277  
**ISBN** : 978-634-7021-26-7  
**Terbit Pada** : Maret 2025  
**Anggota IKAPI** : No. 073/BANTEN/2023

**Hak Cipta 2025 @ Sada Kurnia Pustaka dan Penulis**

*Hak cipta dilindungi undang-undang dilarang memperbanyak karya tulis ini dalam bentuk dan dengan cara apapun tanpa izin tertulis dari penerbit dan penulis.*

**PENERBIT PT SADA KURNIA PUSTAKA**

Jl. Warung Selikur Km.6 Sukajaya – Careng, Kab. Serang-Banten  
Email : [sadapenerbit@gmail.com](mailto:sadapenerbit@gmail.com)  
Website : [sadapenerbit.com](http://sadapenerbit.com) & [repository.sadapenerbit.com](http://repository.sadapenerbit.com)  
Telpon/WA : +62 838 1281 8431

# KATA PENGANTAR

Puji syukur kehadirat Tuhan Yang Maha Esa oleh karena kasih, karunia, penyertaan, kesempatan, keselamatan, dan rahmat berlimpah yang telah diberikan melalui kekuatan, semangat, keteguhan, kebijakan dan kesehatan sehingga seluruh rangkaian penulisan buku yang berjudul “**Deep Learning Teori Algoritma dan Aplikasi**” telah selesai sesuai dengan harapan, waktu dan kesempatan yang boleh diterima. Pembelajaran mendalam (*deep Learning*) merupakan cabang dari pembelajaran mesin (*machine learning*) yang berfokus pada penggunaan jaringan saraf tiruan (*artificial neural networks*) dengan lapisan yang mendalam (*deep layers*) untuk memproses, menganalisis, dan memahami data yang kompleks.

*Deep learning* memiliki kemampuan luar biasa untuk terus menangani data yang tidak terstruktur, seperti gambar, suara, dan teks, dengan performa yang dapat melampaui metode pembelajaran tradisional. Keunggulan utama *deep learning* terletak pada kemampuannya untuk melakukan *feature extraction* secara otomatis, yang berarti model dapat secara mandiri menemukan pola penting dari data mentah tanpa memerlukan intervensi manusia yang signifikan.

Buku ini terdiri dari delapan belas bab, yaitu: bab pertama tentang Konsep Dasar *Deep Learning*, bab dua tentang Sejarah dan Evolusi *Neural Networks*, bab tiga tentang Dasar-dasar Matematika *Deep Learning*, bab empat tentang Struktur Jaringan Syaraf Tiruan, bab lima tentang Algoritma *Backpropagation* dan Optimasi, bab enam tentang Arsitektur *Deep Neural Networks (DNN)*, bab tujuh tentang Jaringan Konvolusi, bab delapan tentang Jaringan *Long Short-Term Memory (LSTM)* dan *Gated Recurrent Units (GRU)*, bab sembilan tentang Jaringan Generatif, bab sepuluh tentang Jaringan Transformer dan Pemrosesan Bahasa Alami (*NLP*), bab sebelas tentang Pemrosesan Gambar dengan *Deep Learning*, bab dua belas tentang Pemrosesan *Audio* dan *Video* dengan *Deep Learning*, bab tiga belas tentang Teknik Regularisasi dalam *Deep Learning*, bab empat belas tentang *Deep*

*Reinforcement*, bab lima belas tentang Pelatihan Model *Deep Learning* pada Data Skala Besar, bab enam belas tentang Aplikasi *Deep Learning* dalam Bidang Medis, bab tujuh belas tentang Aplikasi *Deep Learning* dalam Bidang Finansial, bab delapan belas tentang *Deep Learning* untuk Keamanan Siber.

Penulis sangat merasa berbahagia dan bergembira dengan penerbitan buku ini yang tentu sangat berharap banyak dapat membantu, berkontribusi dan memberikan inspirasi bagi para pembaca serta pemerhati pendidikan. Buku ini sangat perlu untuk dibaca, menjadi referensi dan dilaksanakan sebagai sarana untuk membangun komunikasi, meningkatkan wawasan, menambah pengetahuan, dan juga semangat dalam meningkatkan eksistensi. Buku ini sangat berguna dan relevan sebagai pemahaman dasar mengenai *Deep Learning Teori Algoritma dan Aplikasi* bagi pemangku kepentingan seperti penyelenggara pendidikan, tenaga pendidik, peserta didik, pemerhati pendidikan, praktisi, profesional, dan masyarakat secara umum. Tak ada gading yang tak retak sehingga penulis berharap mendapatkan masukan, saran, dan sumbangan pemikiran untuk peningkatan dan kesempurnaan dalam penulisan buku ini.

Tim Penulis

# DAFTAR ISI


<b>KATA PENGANTAR</b> .....	<b>iii</b>
<b>DAFTAR ISI</b> .....	<b>v</b>
<b>BAB 1 KONSEP DASAR DEEP LEARNING</b> .....	<b>1</b>
Pengertian .....	2
Struktur dan Komponen Utama Jaringan Saraf.....	4
<i>Forward Propagation</i> dan <i>Backpropagation</i> .....	6
Fungsi Aktivasi dalam <i>Deep Learning</i> .....	8
Arsitektur Jaringan <i>Deep Learning</i> .....	9
Data Dalam <i>Deep Learning</i> .....	10
Algoritma Optimasi.....	11
<i>Overfitting</i> dan Generalisasi.....	12
Aplikasi <i>Deep Learning</i> .....	13
Masa Depan <i>Deep Learning</i> .....	14
Daftar Pustaka.....	17
Profil Penulis.....	20
<b>BAB 2 SEJARAH DAN EVOLUSI NEURAL NETWORKS</b> .....	<b>21</b>
Pendahuluan .....	22
Sejarah Perkembangan <i>Neural Network</i> .....	23
Masa Depan <i>Neural Network</i> .....	28
Daftar Pustaka.....	30
Profil Penulis.....	31
<b>BAB 3 DASAR-DASAR MATEMATIKA DEEP LEARNING</b> .....	<b>32</b>
Pendahuluan .....	33
Aljabar Linear .....	34
Statistik dan Probabilitas.....	38
Aplikasi dan Studi Kasus .....	40
Daftar Pustaka.....	43
Profil Penulis.....	44
<b>BAB 4 STRUKTUR JARINGAN SARAF TIRUAN (ARTIFICIAL NEURAL NETWORKS)</b> .....	<b>45</b>
Pendahuluan .....	46
Komponen Utama Jaringan Saraf Tiruan .....	46
Arsitektur JST .....	50

Proses Pelatihan .....	54
Kesimpulan .....	55
Daftar Pustaka .....	56
Profil Penulis .....	58
<b>BAB 5 ALGORITMA BACKPROPAGATION &amp; OPTIMASI .....</b>	<b>59</b>
Konsep Dasar <i>Backpropagation</i> .....	60
Mekanisme Kerja <i>Backpropagation</i> .....	60
Langkah-langkah <i>Backpropagation</i> .....	61
Metode Optimasi Lanjutan .....	62
Teknik Optimasi dalam <i>Backpropagation</i> .....	63
Teknik Optimasi Lanjutan .....	65
Studi Kasus Implementasi <i>Backpropagation</i> dan Optimasi .....	67
Kesimpulan .....	69
Daftar Pustaka .....	71
Profil Penulis .....	73
<b>BAB 6 ARSITEKTUR DEEP NEURAL NETWORKS .....</b>	<b>74</b>
Definisi <i>Deep Neural Networks</i> (DNN).....	75
Perkembangan dan Pentingnya <i>DNN</i> Dalam Bidang <i>Deep Learning</i> .....	75
Komponen Dasar <i>DNN</i> .....	76
Tipe-tipe Arsitektur <i>DNN</i> .....	78
Optimisasi dan Regularisasi Dalam <i>DNN</i> .....	80
Evaluasi dan Validasi Arsitektur <i>DNN</i> .....	82
Studi Kasus Implementasi Arsitektur <i>DNN</i> .....	84
Kesimpulan dan Tren Masa Depan Arsitektur <i>DNN</i> .....	86
Daftar Pustaka .....	89
Profil Penulis .....	92
<b>BAB 7 JARINGAN SARAF KONVOLUSI.....</b>	<b>93</b>
Pengantar.....	94
Jaringan Saraf ( <i>Neural Network</i> ) .....	94
Jaringan Saraf Konvolusi ( <i>Convolutional Neural Network</i> ).....	99
Beberapa Arsitektur Jaringan Saraf Konvolusi Terkini.....	110
Daftar Pustaka .....	113
Profil Penulis .....	116
<b>BAB 8 JARINGAN LONG SHORT-TERM MEMORY (LSTM) DAN GATED RECURRENT UNITS (GRU) .....</b>	<b>117</b>

Pendahuluan .....	118
Pemrosesan <i>Data Sequence</i> RNN vs LSTM vs GRU .....	119
Struktur <i>LSTM</i> .....	122
<i>Gated Recurrent Unit</i> (GRU).....	123
Daftar Pustaka.....	125
Profil Penulis.....	126
<b>BAB 9 JARINGAN GENERATIF .....</b>	<b>127</b>
Pendahuluan .....	128
<i>Variants</i> Jaringan Adversarial Generatif (GAN) .....	128
Penutup .....	137
Daftar Pustaka.....	138
Profil Penulis.....	139
<b>BAB 10 JARINGAN <i>TRANSFORMER</i> DAN PEMROSESAN BAHASA ALAMI (NLP).....</b>	<b>140</b>
Evolusi Arsitektur Transformer Dalam Pemrosesan Bahasa Alami: Dampak dan Implementasi.....	141
Arsitektur dan Mekanisme <i>Transformer</i> .....	142
Komponen Utama Transformer.....	143
Arsitektur <i>Transformer</i> .....	143
Aplikasi <i>Transformer</i> Dalam <i>NLP</i> .....	146
Contoh Proses <i>Transformer</i> .....	147
Visualisasi Alur Data.....	149
Daftar Pustaka.....	151
Profil Penulis.....	152
<b>BAB 11 PEMROSESAN GAMBAR DENGAN <i>DEEP LEARNING</i> .....</b>	<b>153</b>
Pendahuluan .....	154
Pemrosesan Gambar Dengan <i>Convolutional Neural Network</i> .....	155
<i>Training</i> Model Dengan <i>Epoch</i> dan <i>Batch Size</i> .....	165
<i>Matrix</i> Evaluasi Model Dalam <i>Deep Learning</i> .....	168
Kesimpulan.....	170
Daftar Pustaka.....	171
Profil Penulis.....	173
<b>BAB 12 PEMROSESAN AUDIO DAN VIDEO DENGAN <i>DEEP LEARNING</i> .....</b>	<b>174</b>
Pemrosesan Audio dengan <i>Deep Learning</i> .....	175
Pemrosesan Video Dengan <i>Deep Learning</i> .....	175

Teknologi yang Digunakan Dalam Pemrosesan Audio dan Video.....	176
Langkah-langkah dalam Menerapkan <i>Deep Learning</i> pada Audio.....	177
Penanganan Data Dalam Domain Audio.....	178
Langkah-langkah Dalam Menerapkan <i>Deep Learning</i> pada Video.....	180
Daftar Pustaka.....	183
Profil Penulis.....	184
<b>BAB 13 TEKNIK REGULARISASI DALAM <i>DEEP LEARNING</i>.....</b>	<b>185</b>
Konsep Regularisasi.....	186
Regularisasi Berbasis Norma.....	188
<i>Dropout</i> .....	190
<i>Batch Normalization</i> .....	191
<i>Early Stopping</i> .....	192
<i>Data Augmentation</i> .....	193
<i>Label Smoothing</i> .....	194
Analisis Perbandingan Teknik Regularisasi.....	195
Rekomendasi Teknik Regularisasi.....	196
Daftar Pustaka.....	198
Profil Penulis.....	199
<b>BAB 14 <i>DEEP REINFORCEMENT- LEARNING</i>.....</b>	<b>200</b>
Sejarah <i>Reinforcement Learning</i> .....	201
<i>Reinforcement Learning</i> .....	202
Algoritma <i>Reinforcement Learning</i> .....	203
<i>Deep Reinforcement Learning</i> .....	205
<i>Policy Gradient</i> .....	207
Proses <i>Learning</i> .....	208
<i>Acting</i> .....	209
Daftar Pustaka.....	211
Profil Penulis.....	212
<b>BAB 15 PELATIHAN MODEL <i>DEEP LEARNING</i> PADA DATA SKALA BESAR.....</b>	<b>213</b>
Ukuran <i>Dataset</i> .....	214
Bagaimana <i>Deep Learning</i> Menangani <i>Dataset</i> Besar.....	217
Bagaimana Melatih Model <i>Deep Learning</i> .....	219

Bagaimana Melatih Model <i>Deep Learning</i> dengan <i>Dataset</i> Skala Besar .....	224
Faktor yang Memengaruhi Pelatihan Model.....	228
Ikhtisar Pelatihan Model <i>Deep Learning</i> .....	229
Daftar Pustaka.....	231
Profil Penulis.....	233
<b>BAB 16 APLIKASI DEEP LEARNING DALAM BIDANG MEDIS .....</b>	<b>234</b>
Pendahuluan .....	235
Alur Kerja <i>Deep Learning</i> Dalam Analisis Data Medis.....	237
Dataset dan Sumber Data Medis.....	238
Aplikasi <i>Deep Learning</i> di Bidang Medis.....	242
Tantangan dan Solusi.....	244
Kesimpulan.....	246
Daftar Pustaka.....	248
Profil Penulis.....	249
<b>BAB 17 APLIKASI DEEP LEARNING DALAM BIDANG FINANSIAL .....</b>	<b>250</b>
Pendahuluan .....	251
Pengenalan <i>Machine Learning</i> dan <i>Deep Learning</i> .....	251
Penerapan <i>Machine Learning</i> .....	256
Penerapan Bidang Keuangan.....	257
<i>Deep Learning</i> Untuk Prediksi Kebangkrutan.....	258
Penerapan <i>Python</i> Pada Klasifikasi Kebangkrutan.....	261
Daftar Pustaka.....	264
Profil Penulis.....	266
<b>BAB 18 DEEP LEARNING UNTUK KEAMANAN SIBER .....</b>	<b>267</b>
<i>Deep Learning</i> Keamanan Siber .....	268
Tantangan Penggunaan <i>Deep Learning</i> Dalam Keamanan Siber.....	269
Tantangan Dalam Keamanan Siber Tradisional .....	271
Kerangka Kerja Keamanan Siber.....	272
Daftar Pustaka.....	275
Profil Penulis.....	277



# **BAB 1**

## **KONSEP DASAR *DEEP***

### ***LEARNING***

---


**Dr. Ir. Norbertus Tri Suswanto Saptadi, S.Kom., M.T., M.M., IPM.**  
Universitas Atma Jaya Makassar



## Pengertian

Pembelajaran mendalam (*deep Learning*) merupakan cabang dari pembelajaran mesin (*machine learning*) yang berfokus pada penggunaan jaringan saraf tiruan (*artificial neural networks*) dengan lapisan yang mendalam (*deep layers*) untuk memproses, menganalisis, dan memahami data yang kompleks (Huang, Chai and Cho, 2020). Model ini dirancang untuk meniru cara kerja otak manusia dalam mengenali pola, menganalisis hubungan, dan melakukan pengambilan keputusan berdasarkan data.

*Deep learning* memiliki kemampuan luar biasa untuk menangani data yang tidak terstruktur, seperti gambar, suara, dan teks, dengan performa yang dapat melampaui metode pembelajaran tradisional (Muhammadiyah Mataram *et al.*, 2024). Perkembangan teknologi komputasi, ketersediaan *big data*, dan algoritma yang efisien telah menjadikan *deep learning* sebagai teknologi utama dalam revolusi kecerdasan buatan (*artificial intelligence*).



**Gambar 1.1: *Deep Learning, Machine Learning, Artificial Intelligence***

Sumber:

<https://jesit.springeropen.com/articles/10.1186/s43067-023-00108-y>.

ekspresi wajah pengguna, dan membaca konteks teks secara bersamaan untuk memberikan tanggapan yang lebih relevan dan personal. Hal ini mengarah pada aplikasi yang lebih interaktif, seperti di bidang pendidikan, hiburan, atau layanan pelanggan.

Masa depan *deep learning* akan semakin diperkaya dengan kemajuan dalam pembelajaran yang lebih mirip dengan manusia, seperti *unsupervised learning*, *self-supervised learning*, dan *few-shot learning*. Teknik ini memungkinkan model untuk belajar dari jumlah data berlabel yang lebih sedikit atau bahkan tanpa label sama sekali, membuka jalan bagi penerapan *deep learning* di domain yang sebelumnya sulit dijangkau karena keterbatasan data.

Melalui kemampuan ini, *deep learning* diproyeksikan akan terus memainkan peran utama dalam inovasi teknologi, termasuk kecerdasan buatan umum (AGI), eksplorasi ruang angkasa, dan pengelolaan tantangan global seperti perubahan iklim dan kesehatan masyarakat. Selain peningkatan teknis, *deep learning* diprediksi akan semakin banyak diterapkan untuk menyelesaikan masalah global. Misalnya, dalam pengelolaan perubahan iklim, model *deep learning* dapat digunakan untuk memprediksi pola cuaca ekstrem atau mengoptimalkan distribusi energi terbarukan.

Di bidang kesehatan, *deep learning* diharapkan dapat mempercepat penelitian obat dan meningkatkan diagnosis berbasis data, terutama di berbagai negara berkembang yang memiliki keterbatasan tenaga medis. Inovasi ini menunjukkan bagaimana teknologi *deep learning* dapat memberikan dampak yang luas dan signifikan untuk keberlanjutan dan kesejahteraan global. Masa depan *deep learning* juga menghadirkan tantangan yang perlu diatasi, seperti masalah transparansi dan etika. Dengan meningkatnya kompleksitas model, muncul kebutuhan untuk mengembangkan metode interpretasi dan penjelasan keputusan model (*explainable AI*).

Selain itu, penggunaan teknologi ini perlu diimbangi dengan pengelolaan dampak sosialnya, termasuk isu privasi data, bias algoritma (kecenderungan sistem AI untuk menghasilkan keputusan atau prediksi yang tidak adil atau merugikan kelompok tertentu), dan pengaruhnya pada pekerjaan manusia.

Dengan mengatasi tantangan ini, *deep learning* dapat berkembang menjadi teknologi yang tidak hanya cerdas, tetapi juga bertanggung jawab secara sosial dan etis, sehingga memberikan manfaat yang merata bagi semua lapisan masyarakat.

\*\*\*\*\*

## Daftar Pustaka

- Agus Khumaidi *et al.* (2024). Prediksi Konsumsi Daya Listrik Pada Panel Listrik Menggunakan Metode Neural Network, *Jurnal Elektronika dan Otomasi Industri*, 11(2), pp. 350–362.
- Alom, M.Z. *et al.* (2018). The History Began from AlexNet: A Comprehensive Survey on Deep Learning Approaches. Available at: <http://arxiv.org/abs/1803.01164>.
- Alzubaidi, L. *et al.* (2021). *Review of Deep Learning: Concepts, CNN Architectures, Challenges, Applications, Future Directions*, *Journal of Big Data*. Springer International Publishing.
- Andini, D. (2023). Jaringan Syaraf Tiruan Untuk Klasifikasi Penyakit Demam Menggunakan Algoritma Backpropagation, *Bulletin of Artificial Intelligence*, 2(1), pp. 86–99.
- Arora, Anmol and Arora, Ananya. (2022). Generative Adversarial Networks and Synthetic Patient Data: Current Challenges and Future Perspectives, *Future Healthcare Journal*, 9(2), pp. 190–193.
- Bimanjaya, A., Handayani, H.H. and Rachmadi, R.F. (2024). Penggunaan Deep Learning dan Post-Processing Algoritma Douglas-Peucker untuk Ekstraksi Jaringan Jalan pada Area Urban dari Orthophoto, *Geoid*, 19(2), pp. 371–385.
- Firmansyach, W.A., Hayati, U. and Arie Wijaya, Y. (2023). Analisa Terjadinya Overfitting dan Underfitting pada Algoritma Naive Bayes dan Decision Tree dengan Teknik Cross Validation, *JATI (Jurnal Mhs Teknik Informatika)*, 7(1), pp. 262–269.
- Firmanto, B., Aziz, S. and Sesoca, J. (2024). Tinjauan Perkembangan Kecerdasan Buatan Berbasis Arsitektur Transformer, 10(1), pp. 33–38.
- Garcia-Perez, A. *et al.* (2023). Analysing Edge Computing Devices For The Deployment of Embedded AI, *Sensors*, 23(23), pp. 1–21.
- Huang, J., Chai, J. and Cho, S. (2020). Deep Learning In Finance and Banking, *Frontiers of Business Research in China*, 14(1).
- Khalifa, M. and Albadawy, M. (2024). AI in Diagnostic Imaging: Revolutionising Accuracy and Efficiency, *Computer Methods and Programs in Biomedicine Update*, 5(March), p. 100146. Available at: <https://doi.org/10.1016/j.cmpbup.2024.100146>.

- Khan, W. *et al.* (2023). Exploring the Frontiers of Deep Learning and Natural Language Processing: A comprehensive Overview of Key Challenges and Emerging Trends, *Natural Language Processing Journal*, 4(January), p. 100026. Available at: <https://doi.org/10.1016/j.nlp.2023.100026>.
- Kurniawan, K., Ceasaro, B. and Sucipto, S. (2024). Perbandingan Fungsi Aktivasi Untuk Meningkatkan Kinerja Model LSTM dalam Prediksi Ketinggian Air Sungai, *Jurnal Edukasi dan Penelitian Informatika (JEPIN)*, 10(1), p. 134.
- Mehedi Shamrat, F.M.J. *et al.* (2024). An Advanced Deep Neural Network for Fundus Image Analysis and Enhancing Diabetic Retinopathy Detection, *Healthcare Analytics*, 5(December 2023), p. 100303. Available at: <https://doi.org/10.1016/j.health.2024.100303>.
- Miranda, N.D., Novamizanti, L. and Rizal, S. (2020). Classification of Fingerprint Pattern using Convolutional, *Jurnal Teknik Informatika (Jutif)*, 1(2), pp. 61–68.
- Moolayil, J. (2019). *Learn Keras for Deep Neural Networks, Learn Keras for Deep Neural Networks*. Available at: <https://doi.org/10.1007/978-1-4842-4240-7>.
- Moshawrab, M. *et al.* (2023). Reviewing Multimodal Machine Learning and Its Use in Cardiovascular Diseases Detection, *Electronics (Switzerland)*, 12(7), pp. 1–30.
- Muhammadiyah Mataram, U. *et al.* (2024). Penerapan Deep Learning Dalam Menganalisis Sentimen di Media Sosial, 4, pp. 328–339.
- Mulyani, S., Bekti, R.D. and Pratiwi, N. (2024). Perbandingan Fungsi Aktivasi Linear, ReLU, SIGMOID, dan TANSIG pada ELM untuk Peramalan Harga Saham, *Jurnal Statistika Industri dan Komputasi*, 9(1), pp. 67–74.
- Nana, N. *et al.* (2022). Optimasi Klasifikasi Buah Anggur Menggunakan Data Augmentasi dan Convolutional Neural Network, *Smart Comp: Jurnalnya Orang Pintar Komputer*, 11(2), pp. 148–161.
- Nurtiwi, N., Ruliana, R. and Rais, Z. (2022). Convolutional Neural Network (CNN) Method for Classification of Images by Age, *JINAV: Journal of Information and Visualization*, 3(2), pp. 126–130. Available at: <https://doi.org/10.35877/454ri.jinav1481>.

- Ramadhani Putra, E., Widi Nurcahyo, G. and Ilmu Komputer, F. (2024). Penerapan Jaringan Syaraf Tiruan Dengan Algoritma Backpropagation Untuk Memprediksi Kunjungan Poliklinik (Studi Kasus Di Rumah Sakit Otak Dr. Drs. M. Hatta Bukittinggi), *KESATRIA: Jurnal Penerapan Sistem Informasi (Komputer & Manajemen)*, 5(2), pp. 448–457.
- Rayed, M.E. *et al.* (2024). Deep Learning for Medical Image Segmentation: State-of-the-art Advancements and Challenges, *Informatics in Medicine Unlocked*, 47(April), p. 101504.
- Schwabe, D. *et al.* (2024). The METRIC-Framework for Assessing Data Quality for Trustworthy AI in Medicine: A Systematic Review, *npj Digital Medicine*, 7(1). Available at: <https://doi.org/10.1038/s41746-024-01196-4>.
- Setiawan, D., Karuniawati, E.A.D. and Janty, S.I. (2023). Peran Chat GPT (Generative Pre-Training Transformer) dalam Implementasi Ditinjau dari Dataset, *INNOVATIVE: Journal of Social Science Research*, 3(3), pp. 9527–9539.
- Silaparasetty, N. (2020). *Machine Learning vs. Deep Learning, Machine Learning Concepts with Python and the Jupyter Notebook Environment*, pp. 57–65. Available at: [https://doi.org/10.1007/978-1-4842-5967-2\\_4](https://doi.org/10.1007/978-1-4842-5967-2_4).
- Suahati, A.F., Nurrahman, A.A. and Rukmana, O. (2022). Predicting Number of New Student Using Artificial Neural Network-Backpropagation, *Jurnal Media Teknik dan Sistem Industri*, 6(1), p. 21.
- Sulaeman, A.S., Sujada, A. and Kharisma, I.L. (2024). Penerapan Algoritma Cerdas Bidirectional Encoder Representations From Transformers dalam Menganalisis Opini Publik Terhadap Produk yang Mengalami Boikot, *INOVTEK Polbeng - Seri Informatika*, 9(1), pp. 460–473.
- Suprapti, T. *et al.* (2023). Implementasi Model Algoritma Generative Adversarial Network (Gan) pada Sistem Presensi Berbasis Deteksi Wajah (SIDEWA), *Tematik*, 9(2), pp. 231–236.
- Syahputri, C.N. and Hasibuan, M.S. (2024). Optimasi Klasifikasi Decision Tree dengan Teknik Pruning untuk Mengurangi Overfitting, *Jurnal Sistem Informasi*, 11(2), pp. 87–96.

## PROFIL PENULIS



### **Dr. Ir. Norbertus Tri Suswanto Saptadi, S.Kom., M.T., M.M., IPM.**

Lahir di Cirebon, Jawa Barat, tanggal 7 Juni 1975. Memiliki Jabatan Fungsional Lektor Kepala, Pembina Tingkat I (IV/b). Berpendidikan Sarjana Komputer (S.Kom.) di Universitas Teknologi *Digital* Indonesia (UTDI) tahun 1998, Magister Manajemen (M.M.) di Universitas Hasanuddin (UNHAS) tahun 2004,

Magister Teknologi Informasi (M.T.) di Universitas Gadjah Mada (UGM) tahun 2007, Insinyur (Ir.) di Pendidikan Profesi Insinyur UNHAS tahun 2020, Insinyur Profesional Madya (IPM.) di Persatuan Insinyur Indonesia (PII) tahun 2021, Doktor (Dr.) di Fakultas Teknik UNHAS tahun 2023, dan Program Pendidikan Reguler Angkatan (PPRA) LX Lemhannas RI tahun 2020. Menjadi tenaga pengajar (Dosen) pada Program Studi Teknik Informatika Fakultas Teknologi Informasi Universitas Atma Jaya Makassar (UAJM).

Peraih Poster terbaik DPRM Dikti tahun 2016. Dosen berprestasi IKDKI tahun 2020, 2021, dan 2024. Pernah menjabat Kepala UPT Komputer, Kepala BAPSI, Wakil Dekan FT, Dekan FT dan FTI, Wakil Rektor III, Ketua Penjaminan Mutu. Tim PAK Dosen dan Asesor BKD UAJM. *Reviewer International Conference* dan Jurnal SINTA. Pemenang Hibah Kemdikbud Penelitian Dosen Pemula, Bersaing, Fundamental, dan Strategi Nasional. Penulis artikel media massa Tribun Timur, Koinonia, Bisnis Sulawesi, Sesawi.net, Mirifica.net, HidupKatolikCom, OMKNet, KatolikanaTV, Jalan Hidup Katolik, dll. Penulis Buku di Kanisius, Sada Kurnia Pustaka, Aksara Sastra Media, *Future Science*, *HEI Publishing*, Mifandi Mandiri *Digital*, Rey Media Grafika, Widina Salemba, Andi, dan Cendikia Mulia Mandiri. Aktifis organisasi IKA Lemhannas RI LX, IARMI, DPP ISKA, BAPOMI Sulsel, LP3KD Sulsel, IKDKI SulSelTraBar, Komkep KAMS, Komsos KAMS, PUKAT KAMS, TPP KAMS, FMKI KAMS, UPS KAMS, Pengurus Kebun Sawit Laimbo, FDI, PII Makassar, INAPR, Dewan Keuangan Paroki dan Program Ayo Sekolah Mariso, Animator Laudato Si', dll.

Email Penulis: ntsaptadi@gmail.com.



# **BAB 2**

## **SEJARAH DAN EVOLUSI**

### ***NEURAL NETWORKS***

---

**Hedie Kristiawan, S.Kom., M.M.**  
Universitas Santo Borromeus



Kebangkitan di tahun 1980-an ketiak David Rumelhart, Geoffrey Hinton dan Ronald Williams memperkenalkan *Algoritma backpropagation* yang mendasar, sehingga membuka jalan bagi pengembangan pembelajaran saat ini. Banyak terobosan penting pada tahun 2006 *Deep Belief Netowrks* yang dikembangkan oleh Geoffery *Neural Networks*, lalu diperkenalkan oleh Yann LeCun *Convolutional Neural Networks*.

Penelitian dari ilmuwan lainnya mengubah bidang ini menjadi teknologi yang mampu menangani tugas-tugas rumit seperti pengenalan gambar, pemrosesan bahasa alami dan pembelajaran yang mendalam. Perkembangan *neural networks* mencerminkan kerjasama antara pemahaman tentang *neurobiology*, inovasi Algoritma dan kemajuan dalam komputasi, yang membangun dasar bagi revolusi *AI* yang dapat kita lihat sekarang (LeCun et al., 1998).

Perkembangan ini tidak hanya merubah cara kita memandang komputasi, tetapi memberikan wawasan baru dalam memahami kecerdasan buatan dan potensinya di masa depan. Pemahaman neurobiologis, inovasi algoritma, dan kemajuan komputasi bekerja sama untuk menciptakan evolusi *neural networks*, yang membentuk landasan bagi revolusi *AI* saat ini. Perkembangan ini tidak hanya mengubah paradigma komputasi, tetapi juga membuka mata kita pada potensi masa depan kecerdasan buatan.

## Sejarah Perkembangan *Neural Network*

### 1. Sejarah Awal (1940-1960)

Penting bagi perkembangan *neural network* dan komputasi *neural*, model McCulloch Pitts (1943) dikembangkan oleh Warren McCulloch dan Walters Pitts. Neuron didefinisikan oleh McCulloch dan Pitts sebagai unit logika biner sederhana yang memiliki kemampuan untuk melakukan operasi logika dasar seperti *AND*, *OR*, dan *NOT*.

Model McCulloch-Pitts, meskipun sederhana, memberikan dasar bagi perkembangan *neural networks* modern. Model ini menunjukkan bagaimana jaringan neuron sederhana dapat menjalankan operasi logika kompleks, membuka jalan bagi penelitian lanjut dalam bidang komputasi *neural* (McCulloch & Pitts, 1943).

Karakteristik utama Model McCulloch-Pitts sebagai berikut: (a) *input* biner (0 atau 1), (b) ambang batas tetap, (c) *Output* biner, (d) operasi sinkron (semua neuron diperbarui secara bersamaan), (e) bobot sinaptik tetap (tidak dapat diubah melalui pembelajaran). (Hopfield, 1982).

## 2. Era Stagnasi (1970-1980)

Pada tahun 1970-an hingga 1980-an terjadi periode stagnasi dalam pengembangan *neural networks* yang sering disebut sebagai "Winter AI". Dalam buku yang ditulis oleh Marvin Minsky dan Seymour Papert yang berjudul "*Perceptrons*" (1969) mereka memberikan kritik yang tajam yang mengungkapkan keterbatasan fundamental dari perangkat lapis tunggal.

Perangkat ini tidak dapat memecahkan masalah XOR dan masalah non-linier lainnya. Karena kritik ini, minat dan dana yang dihabiskan untuk penelitian *neural networks* berkurang (Minsky & Papert, 1995). Paul Werbos adalah seorang peneliti lain yang berkontribusi pada era ini.

Memperkenalkan konsep *backpropagation* dalam disertasinya pada tahun 1974, tetapi tidak mendapatkan perhatian yang besar hingga tahun 1980-an. Selain itu, James Anderson dan Edward Rosenfeld (1975) membuat model jaringan syaraf yang lebih kompleks, tetapi tidak dapat mengatasi keterbatasan yang diidentifikasi oleh Minsky dan Seymour.

Meskipun mengalami masa stagnasi, pada periode ini penting dalam sejarah *neural networks* karena menunjukkan masalah yang harus diatasi untuk maju. Peneliti mencari solusi baru untuk masalah dan keterbatasan yang ditemukan selama periode ini. Pada tahun 1980-an pengenalan algoritma *backpropagation* dan model-model yang lebih canggih membawa kembali *neural networks* (WERBOS, 1974).

## 3. Renaissance Neural Network (1980-2000)

Periode yang penting dalam perkembangan *neural network*. Selama periode ini banyak kemajuan besar dicapai setelah periode stagnasi, dan beberapa model dan algoritma baru diperkenalkan,

Selain itu dibutuhkan juga kemampuan komputasi yang lebih tinggi. Masalah lainnya adalah interpretabilitas model, *neural network* sering dianggap sebagai *blackbox* yang sulit untuk dipahami. Isu keamanan dan privasi data juga sangat penting, terutama dalam penggunaan yang melibatkan informasi sensitif. Arah pengembangan untuk *neural network* meliputi peningkatan pada efisiensi dan efektivitas model, serta pengembangan metode baru untuk mengatasi masalah yang ada.

Salah satu arah yang menjanjikan adalah menciptakan model-model yang lebih kecil dan efisien, seperti yang dapat dijalankan pada perangkat dengan sumber daya terbatas. Selain itu penelitian juga sedang berusaha untuk meningkatkan interpretabilitas model, sehingga hasil yang diperoleh dapat lebih mudah dipahami dan dijelaskan. Pertimbangan mengenai etika dan efek sosial dari pemakaian *neural network* juga perlu diperhatikan.

Pemanfaatan teknologi ini bisa menghasilkan hasil positif, seperti peningkatan efisiensi dan produktivitas, serta memberikan solusi untuk berbagai persoalan rumit. Namun ada juga kemungkinan munculnya efek negatif, seperti penggantian pekerjaan manusia oleh mesin, serta adanya resiko adanya bias dan diskriminasi dalam model yang diterapkan.

Oleh karena itu, sangat penting untuk mengembangkan dan menggunakan *neural network* dengan memperhatikan unsur etika dan dampak sosial dan memastikan bahwa teknologi ini dimanfaatkan untuk kebaikan bersama (Doshi-Velez & Kim, 2017).

\*\*\*\*\*

## Daftar Pustaka

- Doshi-Velez, F., & Kim, B. (2017). *Towards A Rigorous Science of Interpretable Machine Learning*. *ML*, 1–13. <http://arxiv.org/abs/1702.08608>.
- Fontanini, T., Ferrari, C., Lisanti, G., Bertozzi, M., & Prati, A. (2023). Semantic Image Synthesis via Class-Adaptive Cross-Attention. *IEEE Access*, 13(January), 10326–10339. <https://doi.org/10.1109/ACCESS.2025.3529216>.
- Hebb, D. O. (2002). *The Organization Of Behavior: A Neuropsychological Theory*. Psychology Press. <https://doi.org/https://doi.org/10.4324/9781410612403>.
- Hopfield, J. J. (1982). Neural Networks And Physical Systems With Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the United States of America*, 79(8), 2554–2558. <https://doi.org/10.1073/pnas.79.8.2554>.
- Ian Goodfellow, Yoshua Bengio, A. C. (2017). *Deep Learning*. MIT Press, 521(7553), 785. <https://doi.org/10.1016/B978-0-12-391420-0.09987-X>.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-Based Learning Applied To Document Recognition. *Proceedings Of The IEEE*, 86(11), 2278–2323. <https://doi.org/10.1109/5.726791>.
- McCulloch, W. S., & Pitts, W. (1943). A Logical Calculus Of The Ideas Immanent In Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>.
- Minsky, M. L., & Papert, S. A. (1995). Introduction to Computational Geometry. *Graphics Gems V*, 33. <https://doi.org/10.1016/b978-0-12-543457-7.50013-9>.
- Pampalk, E. (n.d.). *Aligned Self-Organizing Maps*.
- WERBOS, P. (1974). Beyond Regression: New Tools For Prediction And Analysis In The Behavioral Sciences. *PhD Thesis, Committee on Applied Mathematics, Harvard University, Cambridge, MA*. <https://cir.nii.ac.jp/crid/1571135649638605440.bib?lang=en>.


## PROFIL PENULIS



### **Hedio Kristiawan, S.Kom., M.M.**

Ketertarikan penulis terhadap ilmu manajemen dan sistem informasi dan komputer dimulai pada tahun 2000 silam. Hal tersebut membuat penulis memilih untuk masuk ke Perguruan Tinggi Sekolah Tinggi Ilmu Komputer (STMIK) LIKMI Bandung dengan memilih Manajemen Sistem Informasi (Manj.Informasi) dan berhasil menyelesaikan studi pada tahun 2005. Penulis kemudian melanjutkan studi S2 pada tahun 2015 di prodi Manajemen Program Pasca Sarjana Universitas Pasundan Bandung dengan bidang minat Sistem Informasi Bisnis. Penulis memiliki kepakaran dibidang Manajemen dan Sistem Teknologi Informasi. Serta untuk mewujudkan karir sebagai dosen profesional, dan juga sebagai praktisi, penulis pun aktif sebagai peneliti di bidang kepakarannya tersebut dan penulis juga aktif menulis buku dengan harapan dapat memberikan kontribusi positif bagi bangsa dan negara yang sangat tercinta ini.

Email Penulis: [hedio.kristiawan161@gmail.com](mailto:hedio.kristiawan161@gmail.com).



**BAB 3**  
**DASAR-DASAR**  
**MATEMATIKA *DEEP***  
***LEARNING***

---

**Agung Yuliyanto Nugroho, M.Kom., M.Par.**  
Universitas Cendekia Mitra Indonesia



- b. Analisis ini memastikan bahwa model *deep learning* dapat diterapkan pada skala besar dengan sumber daya komputasi terbatas.

Matematika bertindak sebagai bahasa universal yang mendeskripsikan bagaimana data diolah, dipelajari, dan digunakan untuk membuat keputusan dalam model *deep learning*. Tanpa pemahaman dasar matematika, sulit untuk memahami mekanisme seperti *backpropagation*, optimasi, dan regularisasi, yang menjadi inti dari pembelajaran mendalam.

## Aljabar Linear

Aljabar linear adalah cabang matematika yang fokus pada studi vektor, matriks, dan transformasi linier. Dalam *deep learning*, aljabar linear menjadi dasar untuk memahami bagaimana data diolah, diproses, dan dimanipulasi di dalam model *neural network*.

### 1. Vektor dan Matriks

- a. Vektor: Representasi data dalam bentuk satu dimensi. Contohnya, *input data* atau bobot dalam *neural network* sering direpresentasikan sebagai vektor.

$$\mathbf{v} = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{bmatrix}$$

Contoh: Setiap piksel gambar dapat direpresentasikan sebagai elemen vektor.

Matriks: Bentuk dua dimensi yang sering digunakan untuk merepresentasikan kumpulan data atau parameter.

$$\mathbf{M} = \begin{bmatrix} m_{11} & m_{12} \\ m_{21} & m_{22} \end{bmatrix}$$

Contoh: Bobot lapisan *fully connected* direpresentasikan sebagai matriks.

- b. *Fault Prediction*: statistik dan probabilitas digunakan untuk menganalisis data sensor dan memprediksi kegagalan mesin. Studi kasus: kartu kredit *fraud detection*: model *deep learning* dengan statistik pada distribusi transaksi normal dan probabilitas untuk mendeteksi anomali.

### 7. *Recommender Systems*

Aplikasi: sistem rekomendasi: probabilitas digunakan untuk memprediksi preferensi pengguna berdasarkan statistik data historis.

Contoh: *Netflix*, *Spotify*, dan *Amazon* menggunakan probabilitas untuk memberikan rekomendasi yang personal.

Studi kasus: *Netflix Prize*: model probabilistik dan statistik digunakan untuk meningkatkan akurasi prediksi film yang akan disukai pengguna.

### 8. *Reinforcement Learning*

Aplikasi:

- a. *Game AI*: probabilitas digunakan untuk memprediksi kemungkinan hasil dari tindakan tertentu dalam lingkungan permainan.
- b. Robotika: probabilitas digunakan untuk memperkirakan posisi dan tindakan terbaik dalam lingkungan yang dinamis. Studi kasus: *AlphaGo*: probabilitas membantu memilih langkah terbaik dengan evaluasi hasil jangka panjang dalam permainan *Go*.

\*\*\*\*\*

## Daftar Pustaka

- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.
- Chollet, F. (2018). *Deep Learning With Python*. Manning Publications.
- Chollet, F. (2017). *On the Measure of Intelligence*. arXiv preprint arXiv:1911.01547.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). *Deep Learning*. *Nature*, 521(7553), 436–444.
- Kingma, D. P., & Welling, M. (2013). *Auto-Encoding Variational Bayes*. arXiv preprint arXiv:1312.6114.
- Zhang, C., Bengio, S., Hardt, M., Recht, B., & Vinyals, O. (2021). Understanding Deep Learning (still) Requires Rethinking Generalization. *Communications Of The ACM*, 64(3), 107–115.


## PROFIL PENULIS



### **Agung Yuliyanto Nugroho, M.Kom., M.Par.**

Ketertarikan penulis terhadap ilmu komputer dimulai pada tahun 2015 silam. Hal tersebut membuat penulis melanjutkan pendidikan ke Perguruan Tinggi dan berhasil menyelesaikan studi S1 di prodi Teknik Informatika Universitas Teknologi Yogyakarta pada tahun 2018. Dua tahun kemudian, penulis menyelesaikan studi S2 di prodi Teknik Informatika Program Pasca Sarjana Universitas Amikom Yogyakarta dan juga prodi Magister Pariwisata di Sekolah Tinggi Pariwisata Ambarrukmo Yogyakarta. Atas dedikasi dan kerja keras dalam membuat suatu karya, Republik Indonesia Kementerian Hukum Dan Hak Asasi Manusia sudah mencatat ada kurang lebih 100 karya yang sudah tercatat di surat pencatatan ciptaan sebagai salah satu kontribusi dalam melindungi hak kekayaan intelektual.

Email Penulis: [agungboiler11@gmail.com](mailto:agungboiler11@gmail.com).



**BAB 4**  
**STRUKTUR JARINGAN**  
**SARAF TIRUAN**  
***(ARTIFICIAL NEURAL***  
***NETWORKS)***

---

**Nina Rahayu, S.Kom., M.M., M.T.I.**  
Universitas Raharja



diimplementasikan, tetapi mempunyai kekurangan dengan tidak dapat mempelajari pola non-linier dalam data. b) fungsi aktivasi non-linear, fungsi aktivasi non-linear memperkenalkan *non-linieritas* yang dapat memungkinkan jaringan belajar pola kompleks.

Fungsi aktivasi *ReLU* dan variannya (*Leaky ReLU*, *Parameter ReLU*) merupakan fungsi aktivasi yang paling sering atau umum digunakan di jaringan modern karena mempunyai kecepatan dan memiliki efisiensi, sedangkan *sigmoid* dan *tanh* lebih jarang digunakan di jaringan modern dikarenakan rentan terhadap masalah *vanishing gradient*. Pada *softmax* tetap menjadi pilihan utama untuk lapisan *output* pada tugas klasifikasi multi-kelas.

Fungsi aktivasi yaitu komponen kunci pada JST yang dapat mempengaruhi performa jaringan secara signifikan. Pemilihan fungsi aktivasi yang tepat bergantung pada jenis tugas, data, dan kebutuhan model. Dengan memahami klasifikasi karakteristik fungsi aktivasi dapat merancang jaringan saraf yang lebih efisien dan akurat.

## Arsitektur JST

Arsitektur JST mengacu pada cara *neuron-neuron* buatan diorganisasi dalam lapisan-lapisan serta bagaimana informasi mengalir di dalam jaringan. Berdasarkan struktur dan mekanisme kerja, terdapat beberapa jenis arsitektur utama dalam JST.

Komponen utama Jaringan Saraf Tiruan (JST) merupakan suatu element-element dasar atau inti yang membentuk struktur dan fungsi dari suatu jaringan.

### 1. Perceptron Tunggal (*Single-layer Perceptron*)

*Perceptron* tunggal adalah jaringan saraf sederhana yang terdiri dari satu lapisan *neuron* yang langsung menghubungkan *input* ke *output*. *Single-layer perceptron* adalah JST pertama yang paling sederhana dan dasar yang pertama kali memperkenalkan yaitu Frank Rosenblatt Pada tahun 1958 (Anderson, 1995).

*Perceptron* tunggal merupakan model yang terdiri dari satu lapisan *neuron* yang langsung menghubungkan *input* ke *output*

- b. *Load dataset MNIST.*
- c. Definisi Model JST.
- d. Kompilasi model.
- e. Pelatihan JST (*Training*).
- f. Evaluasi model.
- g. Prediksi dan visualisasi.

## **Kesimpulan**

Struktur *JST* terdiri dari neuron, lapisan, bobot, bias dan fungsi aktivasi. Dengan memahami komponen dan arsitektur *JST* dapat membangun model yang efisien untuk menyelesaikan berbagai masalah yang ada. Pemilihan arsitektur *JST* dan parameter yang tepat merupakan kunci keberhasilan dalam penerapan *JST*.

\*\*\*\*\*

## Daftar Pustaka

- Aggarwal, C. C. (2018). *Artificial Neural Network and Deep Learning*. Springer.
- Anderson, J. A. (1995). *An Introduction to Neural Networks*. The MIT Press.
- Bahdanau, D., Cho, K., & Bengio, Y. (2015). Neural Machine Translation by Jointly Learning to Align and Translate. *Published as a conference paper at ICLR 2015*. doi: <https://doi.org/10.48550/arXiv.1409.0473>.
- Bose, N. K., & Liang, P. (1996). *Neural Network Fundamentals With Graphs, Algorithms, and Applications*. McGraw-Hill.
- Cho, K., van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*. 1724–1734. doi: <https://doi.org/10.48550/arXiv.14061078>.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale*. Published as a conference paper at ICLR 2021. doi: <https://doi.org/10.48550/arXiv.2010.11929>.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 27. doi: <https://doi.org/10.48550/arXiv.1406.2661>.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. The MIT Press.
- Gurney, K. (1999). *Computer and Symbols Versus Nets and Neurons*. Academic Press.
- Heaton, J. (2017). Ian Goodfellow, Yoshua Bengio, and Aaron Courville Deep Learning. *MIT Press*. Volume 19, 305-307. doi: <https://doi.org/10.1007/s10710-017-9314-z>.
- Hertz, J., Krogh, A., & Palmer, R. G. (1991). *Introduction To The Theory Of Neural Computation*. Addison-Wesley Pub. Co.

- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*. 9(8), 1735-1780. doi: <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer Feedforward Networks are Universal Approximators. *Neural Networks*. Volume 2, Issue 5, 359-366. doi: [https://doi.org/10.1016/0893-6080\(89\)90020-8](https://doi.org/10.1016/0893-6080(89)90020-8).
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based Learning Applied to Document Recognition. *IEEE Proceeding*. Volume 86, Issue 11, 2278-2324.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*. 521, 436-444. doi: <https://doi.org/10.1038/nature14539>.
- Reed, R. D., & Marks, R. J. (1999). Neural Smithing: Supervised Learning in Feedforward Artificial Neural Networks. *The MIT Press*. doi: <https://doi.org/10.7551/mitpress/4937.001.0001>.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning Representations by Back-Propagation Error. *Nature*. 323, 533-536.
- Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. *Neural Network*. Volume 61, 85-117.

## PROFIL PENULIS



### **Nina Rahayu, S. Kom., M.M., M.T.I.**

Penulis adalah seorang akademisi dan peneliti di bidang Teknologi Informasi dengan pengalaman lebih dari satu dekade. Saat ini, Penulis berperan sebagai dosen di Universitas Raharja sejak tahun 2016. Dengan latar belakang pendidikan di bidang Manajemen dan Teknologi Informasi, Penulis juga aktif dalam pengajaran, penelitian, dan pengembangan sistem berbasis teknologi. Selain mengajar dan meneliti, Penulis juga memiliki pengalaman dalam implementasi sistem teknologi di industri, seperti keterlibatannya dalam proyek pada bagian ITM di PT. Telkomsigma. Komitmennya terhadap dunia akademik dibuktikan dengan kelanjutan studinya pada program doctoral di Universitas Kristen Satya Wacana, di mana ia terus mengembangkan penelitian di bidang ilmu komputer. Sebagai seorang peneliti, penulis telah menulis berbagai artikel ilmiah dan berpartisipasi dalam hibah penelitian, termasuk proyek-proyek seperti prediksi biaya kuliah menggunakan kecerdasan buatan, sistem peringatan dini kebakaran berbasis sensor fusion, dan pengembangan sistem keamanan data berbasis *blockchain* untuk *e-voting*. Dengan dedikasi yang tinggi dalam dunia pendidikan dan teknologi, Penulis terus berkontribusi dalam inovasi sistem informasi dan kecerdasan buatan, serta berperan dalam mencetak generasi muda yang siap menghadapi tantangan *digital*.

Email Penulis: [ninarahayu.niez@gmail.com](mailto:ninarahayu.niez@gmail.com).



# **BAB 5**


## **ALGORITMA**

### ***BACKPROPAGATION &***

### **OPTIMASI**

---

**Suwarniyati, S.T., M.T.**  
Politeknik Muhammadiyah Makassar



## Langkah-langkah *Backpropagation*

### 1. *Forward Propagation*

Proses *backpropagation* dimulai dari lapisan *input*, melewati lapisan tersembunyi, hingga mencapai lapisan *output*. Setiap neuron dalam jaringan melakukan operasi sebagai berikut:

$$Z = W \cdot X + b$$

di mana:

- $X$  adalah *input*,
- $W$  adalah bobot,
- $b$  adalah bias,
- $f(Z)$  adalah fungsi aktivasi (*ReLU*, *Sigmoid*, atau *Softmax*).

### 2. Menghitung *Error (Loss Function)*

Setelah prediksi dihasilkan, langkah selanjutnya adalah menghitung *error* atau selisih antara hasil prediksi dan target menggunakan fungsi *loss*. Beberapa fungsi *loss* yang umum digunakan:

- Mean Squared Error (MSE)* (untuk regresi):

$$L = \frac{1}{n} \sum (Y_{true} - Y_{pred})^2$$

- Cross-Entropy Loss* (untuk klasifikasi):

$$L = - \sum Y_{true} \log(Y_{pred})$$

*Error* ini digunakan untuk mengetahui seberapa jauh model dari hasil yang diharapkan.

### 3. *Backward Propagation (Menyebarkan Error ke Belakang)*

Proses *backward propagation* dimulai dengan menghitung kembali nilai *error* menggunakan aturan rantai (*chain rule*) dalam kalkulus, kita menghitung turunan dari *error* terhadap bobot pada setiap lapisan dalam jaringan.

- Menghitung Gradien di Lapisan *Output*

$$\frac{\partial L}{\partial W} = \frac{\partial L}{\partial A} \cdot \frac{\partial A}{\partial Z} \cdot \frac{\partial Z}{\partial W}$$

- Menyebarkan Gradien ke Lapisan Sebelumnya

## Langkah 7: Visualisasi Kinerja Model

Kita bisa melihat bagaimana model memprediksi gambar secara langsung.

```
# Menampilkan contoh prediksi
predictions = model.predict(X_test)
# Plot gambar pertama dalam dataset uji
plt.imshow(X_test[0], cmap=plt.cm.binary)
plt.title(f"Prediksi: {np.argmax(predictions[0])}")
plt.show()
```

Model akan menampilkan angka yang diprediksi oleh jaringan. Perbandingan Teknik Optimasi

Untuk membandingkan performa berbagai teknik optimasi, kita bisa mencoba mengubah *optimizer* dan melihat dampaknya.

### Ekspirimen 1: Menggunakan *Stochastic Gradient Descent (SGD)*

```
model.compile(optimizer='sgd',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
history_sgd = model.fit(X_train, y_train, epochs=10, validation_data=(X_test,
y_test))
```

*SGD* biasanya lebih lambat dan memiliki konvergensi yang tidak stabil dibanding Adam.

### Ekspirimen 2: Menggunakan *RMSprop*

```
model.compile(optimizer='rmsprop',
              loss='sparse_categorical_crossentropy',
              metrics=['accuracy'])
history_rmsprop = model.fit(X_train, y_train, epochs=10, validation_data=(X_test,
y_test))
```

*RMSprop* sering bekerja lebih baik daripada *SGD*, tetapi *Adam* tetap lebih unggul.

## Kesimpulan

Dalam bab ini, telah dibahas secara mendalam tentang *Backpropagation* dan berbagai teknik optimasi yang berperan penting dalam pelatihan jaringan saraf. Beberapa poin utama yang dapat disimpulkan:

1. *Backpropagation* adalah algoritma inti dalam pelatihan jaringan saraf yang bekerja dengan menyebarkan *error* ke belakang untuk

menyesuaikan bobot dan bias, sehingga model dapat belajar dari data dengan lebih efektif.

2. Teknik optimasi sangat penting dalam meningkatkan kecepatan, stabilitas, dan akurasi pembelajaran. Optimasi bertujuan untuk mempercepat proses konvergensi dan mencegah masalah seperti *vanishing gradient*.
3. Beberapa metode optimasi yang umum digunakan meliputi:
  - a. *Stochastic Gradient Descent (SGD)* yang lebih cepat daripada *GD* tetapi cenderung tidak stabil.
  - b. *Momentum* yang mengurangi osilasi dan mempercepat konvergensi.
  - c. *RMSprop* yang menyesuaikan *learning rate* berdasarkan rata-rata gradien kuadrat untuk stabilitas lebih baik.
  - d. *Adam*, kombinasi *Momentum* dan *RMSprop*, yang menjadi salah satu *optimizer* terbaik untuk *Deep Learning* karena cepat dan stabil.
4. Studi kasus menggunakan *dataset MNIST* menunjukkan bahwa pemilihan teknik optimasi yang tepat dapat berdampak besar pada akurasi dan efisiensi model.

Dengan pemahaman yang lebih baik tentang *Backpropagation* dan teknik optimasi, pengembangan jaringan saraf yang lebih efisien dan akurat dapat dicapai, memungkinkan penerapan *deep learning* dalam berbagai bidang seperti pengenalan gambar, pemrosesan bahasa alami, dan sistem rekomendasi.

\*\*\*\*\*

## Daftar Pustaka

- A. Agustyawan, T. G. Laksana, and U. Athiyah. (2022). Combination of Backpropagation Neural Network and Particle Swarm Optimization for Water Production Prediction in Municipal Waterworks. *Scientific Journal of Informatics*, Vol. 9, No. 1, pp. 84–94, May 2022, doi: 10.15294/SJI.V9I1.29849.
- Adam Optimizer Tutorial. (2025). *Intuition and Implementation in Python | DataCamp*. Accessed: Feb. 17, 2025. [Online]. Available: [https://www.datacamp.com/tutorial/adam-optimizer-tutorial?utm\\_source=chatgpt.com](https://www.datacamp.com/tutorial/adam-optimizer-tutorial?utm_source=chatgpt.com).
- F. Mignacco and P. Urbani. (2020). The Effective Noise of Stochastic Gradient Descent. *Journal of Statistical Mechanics: Theory and Experiment*, Vol. 2022, No. 8, Dec. 2021, doi: 10.1088/1742-5468/ac841d.
- J. Resti, R. Ramadana, A. Perdana Windarto, and D. Suhendro. (2024). Comparative Analysis of Gradient Descent Learning Algorithms in Artificial Neural Networks for Forecasting Indonesian Rice Prices, *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, Vol. 8, No. 4, pp. 466–478, Aug. 2024, doi: 10.29207/RESTI.V8I4.5822.
- J. Waldo. (2022). *A Comparative Study Of Back Propagation And Its Alternatives On Multilayer Perceptrons*, May 2022, Accessed: Feb. 17, [Online]. Available: <https://arxiv.org/abs/2206.06098v1>.
- M. Chakraborty and A. Ghosh. (2012). Hybrid Optimized Back propagation Learning Algorithm For Multi-layer Perceptron. *Int J Comput Appl*, Vol. 60, No. 13, pp. 1–5, Dec. 2012, doi: 10.5120/9749-3332.
- Moh. Dasuki. (2021). *Optimasi Nilai Bobot Algoritma Backpropagation Neural Network Dengan Algoritma Genetika, JUSTINDO (Jurnal Sistem dan Teknologi Informasi Indonesia)*. Vol. 6, No. 1, pp. 38–44, Jun. 2021, doi: 10.32528/JUSTINDO.V6I1.5280.
- Putrama Alkhairi and A. P. Windarto. (2023). Classification Analysis of Back Propagation-Optimized CNN Performance in Image Processing. *Journal of Systems Engineering and Information Technology (JOSEIT)*, Vol. 2, No. 1, Mar. 2023, doi: 10.29207/JOSEIT.V2I1.5015.

Y. Lei and Y. Ying, (2020). *Fine-Grained Analysis of Stability and Generalization for Stochastic Gradient Descent*.

Y.-F. PU and J. Wang. (2025). *Fractional-order Backpropagation Neural Networks: Modified Fractional-order Steepest Descent Method for Family of Backpropagation Neural Networks*, Accessed: Feb. 17, 2025. [Online]. Available: <https://arxiv.org/abs/1906.09524v2>.

## PROFIL PENULIS



### **Suwarmiyati, S.T., M.T.**

Penulis mendalami dunia alat kesehatan sejak tahun 1997 silam. Hal tersebut membuat penulis memilih untuk masuk ke Akademi Teknik Elektromedik Muhammadiyah Makassar dan lulus pada tahun 2000. Tahun 2011 penulis kemudian melanjutkan pendidikan S1 jurusan teknik elektro pada Universitas Muhammadiyah dan lulus tahun 2013. Setahun kemudian, penulis melanjutkan studi S2 jurusan teknik elektro pada Program Pasca Sarjana Universitas Hasanuddin Makassar dan berhasil lulus pada tahun 2016.

Email Penulis: [suwarmiyati.imb@gmail.com](mailto:suwarmiyati.imb@gmail.com).



**BAB 6**  
**ARSITEKTUR *DEEP***  
***NEURAL NETWORKS***

---

**Bayu Waseso, S.Kom., M.Kom.**  
Universitas Mercu Buana



## Definisi *Deep Neural Networks* (DNN)

*Deep Neural Networks* (DNN) merupakan sebuah arsitektur kecerdasan buatan yang terdiri dari sejumlah besar lapisan pemrosesan (*hidden layers*) yang dirancang untuk meniru cara otak manusia memproses data dan informasi. DNN merupakan salah satu bentuk dari *Artificial Neural Networks* (ANN), namun dengan arsitektur yang lebih kompleks dan mendalam (*deep*), yang memungkinkan pengenalan pola dan abstraksi tingkat tinggi.

Goodfellow dalam buku *Deep Learning* mendefinisikan DNN sebagai jaringan saraf buatan yang memiliki banyak lapisan tersembunyi, memungkinkan pembelajaran fitur yang lebih kompleks dibandingkan jaringan dengan lapisan yang lebih dangkal (Goodfellow, 2016).

Ian et al. (2020) menyebutkan bahwa DNN adalah arsitektur pembelajaran mendalam yang dirancang untuk menangkap representasi data dalam berbagai tingkatan abstraksi, dari fitur rendah hingga fitur tingkat tinggi (Heaton, 2018). Jangam menggarisbawahi bahwa DNN adalah inti dari revolusi *deep learning*, memungkinkan mesin untuk memahami data tanpa kebutuhan fitur yang dirancang secara manual (Jangam et al., 2023).

## Perkembangan dan Pentingnya DNN Dalam Bidang *Deep Learning*

Dalam dekade terakhir, DNN telah menjadi inti dari revolusi kecerdasan buatan dan pembelajaran mesin. Kemajuan ini didorong oleh berbagai faktor, termasuk peningkatan daya komputasi, ketersediaan data besar (*big data*), dan algoritma yang lebih efisien.

### 1. Sejarah Singkat Perkembangan DNN:

- a. 1950–1980-an: Konsep jaringan saraf buatan pertama kali diperkenalkan, tetapi keterbatasan komputasi dan algoritma membuat perkembangannya lambat.
- b. 1990-an: Algoritma *backpropagation* menjadi terobosan penting untuk melatih jaringan saraf.
- c. 2006: Geoffrey Hinton memperkenalkan konsep *deep belief networks*, yang membuka jalan untuk perkembangan DNN.

- c. *K-Fold Cross-Validation*:
  - 1) Menggunakan *subset* berbeda dari *dataset* untuk pelatihan dan validasi dalam iterasi.
  - 2) Kelebihan: mengurangi *overfitting* dengan evaluasi menyeluruh.
  - 3) Kekurangan: menambah *overhead* komputasi.
- d. Tantangan Evaluasi dan Validasi
  - 1) *Overfitting*: Kinerja model terlalu baik pada data pelatihan tetapi buruk pada data baru.
  - 2) Solusi: menggunakan regularisasi dan validasi silang.
- e. Data Tidak Representatif:
  - 1) *Dataset* validasi atau pengujian tidak mencerminkan kondisi data nyata.
  - 2) Solusi: menggunakan data beragam dari *domain* yang relevan.
- f. Skalabilitas:
  - 1) Evaluasi pada *dataset* besar memerlukan waktu dan sumber daya komputasi.
  - 2) Solusi: *Sampling data* yang cermat.

## Studi Kasus Implementasi Arsitektur *DNN*

Studi kasus memberikan wawasan nyata tentang bagaimana arsitektur *Deep Neural Networks (DNN)* diterapkan untuk memecahkan masalah dunia nyata. Bagian ini membahas beberapa kasus implementasi arsitektur *DNN* yang signifikan di berbagai domain. Berikut beberapa studi kasus implementasi *DNN*:

### 1. Pengenalan Gambar dengan *Convolutional Neural Networks (CNN)* (Narayan & Muthalagu, 2021).

Klasifikasi gambar menggunakan *dataset ImageNet*.

Implementasi:

- a. Menggunakan arsitektur seperti *AlexNet*, *VGG*, atau *ResNet* untuk mengenali objek dalam gambar.
- b. Teknik seperti augmentasi data dan transfer learning sering digunakan untuk meningkatkan akurasi. Hasil: CNN secara konsisten mencapai akurasi tinggi dalam tugas-tugas pengenalan gambar. Aplikasi: Deteksi objek, sistem pengawasan, dan pencarian berbasis gambar.

## Daftar Pustaka

- Afkham, B., Chung, J., & Chung, M. (2021). Learning Regularization Parameters of Inverse Problems Via Deep Neural Networks. *Inverse Problems*, 37. <https://doi.org/10.1088/1361-6420/ac245d>.
- Arsalan, M. (2024). Transformers in Natural Language Processing: A Comprehensive Review. *International Journal for Research in Applied Science and Engineering Technology*. <https://doi.org/10.22214/ijraset.2024.62863>.
- Chen, C., Peng, H., Liu, X., Ding, H., & Shi, C. R. (2018). Exploring the Programmability for Deep Learning Processors: from Architecture to Tensorization. *2018 55th ACM/ESDA/IEEE Design Automation Conference (DAC)*, 1-6. <https://doi.org/10.1145/3195970.3196049>.
- Deldjoo, Y., He, Z., McAuley, J., Korikov, A., Sanner, S., Ramisa, A., Vidal, R., Sathiamoorthy, M., Kasrizadeh, A., Milano, S., & Ricci, F. (2024). Recommendation with Generative Models. *ArXiv*, *abs/2409.15173*. <https://doi.org/10.48550/arXiv.2409.15173>.
- Finsveen, L., & Fisveen, L. (2018). *Time-series predictions with Recurrent Neural Networks*. <https://consensus.app/papers/timeseries-predictions-with-recurrent-neural-networks-finsveen-fisveen/6f09da26a21a536a829b25ff2d37f15e/>.
- Galván, E., & Mooney, P. (2020). Neuroevolution in Deep Neural Networks: Current Trends and Future Challenges. *IEEE Transactions on Artificial Intelligence*, 2, 476-493. <https://doi.org/10.1109/TAI.2021.3067574>.
- Goodfellow, I. (2016). *Deep learning*. In: MIT Press.
- Guo, X., Zhang, H., Yang, H., Xu, L., & Ye, Z. (2018). A Single Attention-Based Combination of CNN and RNN for Relation Classification. *IEEE Access*, 7, 12467-12475. [https://doi.org/10.1007/978-3-030-04212-7\\_21](https://doi.org/10.1007/978-3-030-04212-7_21).
- Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, And Aaron Courville: Deep Learning: The Mit Press, 2016, 800 pp, isbn: 0262035618. *Genetic Programming and Evolvable Machines*, 19(1), 305-307.

- Huang, L., Liu, X., Qin, J., Zhu, F., Liu, L., & Shao, L. (2020). Projection Based Weight Normalization: Efficient Method For Optimization On Oblique Manifold In DNNs. *Pattern Recognit.*, 105, 107317. <https://doi.org/10.1016/j.patcog.2020.107317>.
- Jangam, S., Kate, M., Patil, S., Pitale, T., Kawase, P. N., & Sharma, P. D. (2023). AI in Deep Learning: Advancements, Challenges, and Future Prospects. *International Journal For Multidisciplinary Research*. <https://doi.org/10.36948/ijfmr.2023.v05i06.8901>.
- K, R., Dhananjaya, G., Ds, L., Krishnamurthy, P. L., & Pawar, A. S. (2022). Recommendation System Using Deep Learning. *2022 IEEE 7th International Conference on Recent Advances and Innovations in Engineering (ICRAIE)*, 7, 99-103. <https://doi.org/10.1109/ICRAIE56454.2022.10054275>.
- Klingner, M., & Fingscheidt, T. (2021). Online Performance Prediction of Perception DNNs by Multi-Task Learning With Depth Estimation. *IEEE Transactions on Intelligent Transportation Systems*, 22, 4670-4683. <https://doi.org/10.1109/TITS.2021.3054437>.
- La Malfa, E., Malfa, G., Nicosia, G., & Latora, V. (2024). Deep Neural Networks via Complex Network Theory: a Perspective. 4361-4369. <https://doi.org/10.48550/arXiv.2404.11172>.
- Lumumba, V., Kiprotich, D., Mpaine, M., Makena, N., & Kavita, M. (2024). Comparative Analysis of Cross-Validation Techniques: LOOCV, K-folds Cross-Validation, and Repeated K-folds Cross-Validation in Machine Learning Models. *American Journal of Theoretical and Applied Statistics*. <https://doi.org/10.11648/j.ajtas.20241305.13>.
- Luo, L. (2021). Architectures of Neuronal Circuits. *Science*, 373. <https://doi.org/10.1126/science.abg7285>.
- Mao, W., Wang, M., Xie, X., Wu, X., & Wang, Z. (2024). Hardware Accelerator Design for Sparse DNN Inference and Training: A Tutorial. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 71, 1708-1714. <https://doi.org/10.1109/TCSII.2023.3344681>.
- Narayan, A., & Muthalagu, R. (2021). Image Character Recognition Using Convolutional Neural Networks. *2021 Seventh International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, 1-5. <https://doi.org/10.1109/ICBSII51839.2021.9445136>.

- Singh, G., Rani, L., Sarangi, P., Sharma, K., Sahoo, A., & Malhotra, R. (2023). CNN-RNN Based Hybrid Deep Learning Model for Predicting Fluctuations in the Stock Market. *2023 5th International Conference on Advances in Computing, Communication Control and Networking (ICAC3N)*, 417-422. <https://doi.org/10.1109/ICAC3N60023.2023.10541397>.
- Suhermi, N. S., Suhartono & Prastyo, Dedy & Dana, I. (2018). Pemilihan Arsitektur Terbaik pada Model Deep Learning Melalui Pendekatan Desain Eksperimen untuk Peramalan Deret Waktu Nonlinier. *STATISTIKA Journal of Theoretical Statistics and Its Applications*, 18(2), 153-159. <https://doi.org/10.29313/jstat.v18i2.4545>.
- Wang, H., & S, S. (2021). Overview of Configuring Adaptive Activation Functions for Deep Neural Networks - A Comparative Study. *March 2021*. <https://doi.org/10.36548/jucct.2021.1.002>.
- Xu, Q., Chen, J., Tang, J., Kang, Q., & Zhou, M. (2023). Performing Effective Generative Learning from a Single Image Only. *2023 32nd Wireless and Optical Communications Conference (WOCC)*, 1-5. <https://doi.org/10.1109/WOCC58016.2023.10139746>.
- Yang, Q., Wen, W., Wang, Z., & Li, H. (2019). Joint Regularization on Activations and Weights for Efficient Neural Network Pruning. *2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA)*, 790-797. <https://doi.org/10.1109/ICMLA.2019.00139>.
- Yang, Y., Yu, J., Yang, Z., Wang, G., Yu, H., & Cheng, Q. (2022). A Trustable Data-Driven Framework for Composite System Reliability Evaluation. *IEEE Systems Journal*, 16, 6697-6707. <https://doi.org/10.1109/JSYST.2021.3131822>.

## PROFIL PENULIS




### **Bayu Waseso, S.Kom, M.Kom.**

Penulis merupakan lulusan sarjana Teknik Informatika dari Universitas Bina Nusantara, Jakarta. Magister Komputer dari STMIK Eresha, Jakarta, jurusan Teknik Informatika dan sedang melanjutkan pendidikan doctoral pada *Asia eUniversity* Kuala Lumpur Malaysia. Selain sebagai dosen di Universitas Mercu Buana Jakarta pada Fakultas Ilmu Komputer, jurusan Sistem Informasi, penulis juga aktif terlibat bekerja sebagai Konsultan pada berbagai proyek TI sejak tahun 2010.

Pengalaman terlibat dalam berbagai proyek TI tersebut memberikan banyak manfaat untuk bisa berbagi pengetahuan dan pengalaman saat di kelas maupun sebagai bahan penelitian ataupun saat melakukan pengabdian masyarakat, sebagai bagian dari Tri Dharma Pendidikan. Bidang spesialisasi yang penulis tekuni antara lain *Project Management, IT Governance, dan Software Engineering*. Penulis juga aktif berorganisasi pada *Project Management Institute (PMI) Indonesia Chapter*.

Selain itu penulis seringkali memberikan pelatihan profesional untuk pelatihan sertifikasi *ITIL 4 Foundation, COBIT 2019 Foundation, serta PRINCE2 Foundation*. Penulis menyadari teknologi selalu berkembang setiap saat oleh sebab itu penulis senantiasa untuk selalu belajar dan membagi pengetahuan serta pengalamannya baik saat di kelas ataupun melalui media buku ini, semoga pengetahuan yang sedikit bisa memberikan manfaat bagi pembaca. Semua ini hanya karena Allah SWT semata yang telah memberikan karuniaNya.

Email Penulis: [bayu.waseso@mercubuana.ac.id](mailto:bayu.waseso@mercubuana.ac.id), [bwaseso@gmail.com](mailto:bwaseso@gmail.com).



# **BAB 7**

# **JARINGAN SARAF**

# **KONVOLUSI**

---

**Indo Intan, S.T., M.T.**  
Universitas Dipa Makassar



## Pengantar

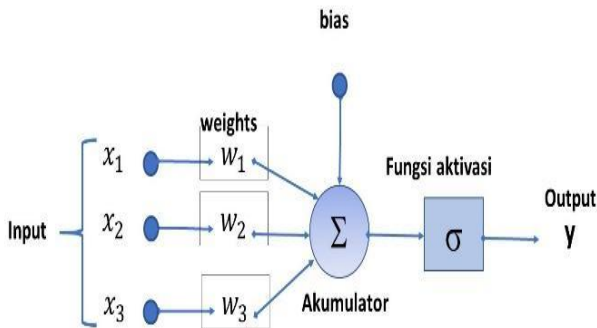
Pembelajaran mendalam (*deep learning*) merupakan metode yang dilakukan untuk mengatasi kekurangan dari pembelajaran mesin tradisional.

Seiring pesatnya peranan dunia *digital* dan *virtual* sehingga memberikan jangkauan data yang semakin luas dan fleksibilitas perkembangan interkoneksi data antar pengguna, *server*, *cloud computing*, dan sejumlah layanan *digital* lainnya. Tentu saja hal ini akan menampung kapasitas data yang tersiklusasi secara *real-time* maupun *non real-time* secara terus menerus seiring dengan berlangsungnya aktivitas hidup manusia.

Kapasitas data dalam jangkauan *big data* sudah mencapai batas saturasi dari metode pembelajaran mesin tradisional sehingga *deep learning* tampil sebagai teknologi terdepan dalam penerapannya sekarang ini. Salah satu metode yang digunakan pada *deep learning* yaitu Jaringan Saraf Konvolusi (*Convolutional Neural Network*). Berikut kita akan mengulas hal yang berkaitan dengan pembahasan ini.

## Jaringan Saraf (*Neural Network*)

Jaringan saraf merupakan nama yang sama dengan jaringan saraf tiruan. Jaringan saraf memiliki struktur yang sangat sederhana yang merupakan cikal bakal jaringan saraf konvolusi (Gambar 7.1). Jaringan sederhana ini dikenal dengan *perceptron* yang ditemukan oleh Frank Rosenblatt (Teuwen & Moriaikov, 2019).




**Gambar 7.1: Perceptron**

Sumber: Diolah Penulis.

### 3. Lapisan Pooling (Pooling Layer)

Teknik yang berfungsi untuk mengurangi ukuran *feature map* dengan mempertahankan informasi penting, sehingga mampu mengurangi jumlah parameter dan kerumitan komputasi serta andal terhadap pergeseran distorsi gambar (Valizadeh & Wolff, 2022). Teknik pooling terdiri atas tiga:


- a. *Max Pooling*, mengambil bobot fitur tertinggi pada area tertentu untuk mempertahankan bobot fitur yang paling menonjol (Raiaan et al., 2024).



**Gambar 7.11: Proses Max Pooling**

Sumber: Diolah Penulis.

- b. *Average Pooling*, menghitung rata-rata bobot dalam area tertentu (Raiaan et al., 2024).



**Gambar 7.12: Proses Average Pooling**

Sumber: Diolah Penulis.

### 4. Lapisan Perataan (Flattening Layer)

Proses mengubah *feature map* berdimensi 2D atau 3D menjadi *vector* 1D sehingga semua fitur terkoneksi dengan *neuron* untuk mereduksi dimensi (Gurov et al., 2022)(Valizadeh & Wolff, 2022). Misalnya kita memiliki *output* lapisan konvolusi  $(7,7,64) = (7 \times 7 \times 64) = 3,136$  *neuron*.

```

from tensorflow.keras import layers
def create_cnn_classifier(input_shape=(32, 32, 3),
num_classes=10):
    model = keras.Sequential([
        layers.Conv2D(32, (3, 3), activation='relu',
padding='same', input_shape=input_shape),
        layers.MaxPooling2D((2, 2)),
        layers.Conv2D(64, (3, 3), activation='relu',
padding='same'),
        layers.MaxPooling2D((2, 2)),
        layers.Conv2D(128, (3, 3), activation='relu',
padding='same'),
        layers.MaxPooling2D((2, 2)),
        layers.Flatten(),
        layers.Dense(128, activation='relu'),
        layers.Dropout(0.5), # Prevent overfitting
        layers.Dense(num_classes, activation='softmax') #
Output layer
    ])
    # Compile the model
    model.compile(optimizer='adam',
        loss='sparse_categorical_crossentropy',
        metrics=['accuracy'])

    return model

```

**# Pemodelan dan Proses Training**

```

# Example dataset: CIFAR-10
(x_train, y_train), (x_test, y_test) =
keras.datasets.cifar10.load_data()
x_train, x_test = x_train / 255.0, x_test / 255.0 #
Normalize pixel values
# Create the CNN model
cnn_model = create_cnn_classifier(input_shape=(32, 32, 3),
num_classes=10)
# Train the model
cnn_model.fit(x_train, y_train, epochs=10,
validation_data=(x_test, y_test), batch_size=32)
# Evaluate the model
test_loss, test_acc = cnn_model.evaluate(x_test, y_test)
print(f"Test Accuracy: {test_acc:.4f}")

```

\*\*\*\*\*

## Daftar Pustaka

- Cong, S., & Zhou, Y. (2023). A Review of Convolutional Neural Network Architectures And Their Optimizations. *Artificial Intelligence Review*, 56(3), 1905–1969. <https://doi.org/10.1007/s10462-022-10213-5>.
- Cong, S., & Zhou, Y. (2023). A Review of Convolutional Neural Network Architectures And Their Optimizations. *Artificial Intelligence Review*, 56(3), 1905–1969. <https://doi.org/10.1007/s10462-022-10213-5>.
- Gurov, A., Evmenova, E., & Chunaev, P. (2022). Supervised Community Detection In Multiplex Networks Based On Layers Convex Flattening And Modularity Optimization. *Procedia Computer Science*, 212(C), 181–190. <https://doi.org/10.1016/j.procs.2022.11.002>.
- Gurov, A., Evmenova, E., & Chunaev, P. (2022). Supervised Community Detection In Multiplex Networks Based on Layers Convex Flattening And Modularity Optimization. *Procedia Computer Science*, 212(C), 181–190. <https://doi.org/10.1016/j.procs.2022.11.002>.
- Habibi Aghdam, H., Jahani Heravi, E., & AG, S. I. P. (2018). *Guide to Convolutional Neural Networks A Practical Application to Traffic-Sign Detection and Classification*.
- Habibi Aghdam, H., Jahani Heravi, E., & AG, S. I. P. (2018). *Guide to Convolutional Neural Networks A Practical Application to Traffic-Sign Detection and Classification*.
- Haruna, Y., Qin, S., Adama Chukkol, A. H., Yusuf, A. A., Bello, I., & Lawan, A. (2025). Exploring The Synergies of Hybrid Convolutional Neural Network And Vision Transformer Architectures For Computer Vision: A Survey. *Engineering Applications of Artificial Intelligence*, 144, 110057. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.110057>
- Haruna, Y., Qin, S., Adama Chukkol, A. H., Yusuf, A. A., Bello, I., & Lawan, A. (2025). Exploring The Synergies Of Hybrid Convolutional Neural Network And Vision Transformer Architectures For Computer Vision: A survey. *Engineering Applications of Artificial Intelligence*, 144, 110057. <https://doi.org/https://doi.org/10.1016/j.engappai.2025.110057>

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity Mappings In Deep Residual Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9908 LNCS, 630–645. [https://doi.org/10.1007/978-3-319-46493-0\\_38](https://doi.org/10.1007/978-3-319-46493-0_38).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Identity Mappings In Deep Residual Networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9908 LNCS, 630–645. [https://doi.org/10.1007/978-3-319-46493-0\\_38](https://doi.org/10.1007/978-3-319-46493-0_38).
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *Proceedings-30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017-January, 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>.
- Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely Connected Convolutional Networks. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, 2017-January, 2261–2269. <https://doi.org/10.1109/CVPR.2017.243>.
- Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2022-June*, 11966–11976. <https://doi.org/10.1109/CVPR52688.2022.01167>.
- Liu, Z., Mao, H., Wu, C. Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). A ConvNet for the 2020s. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2022-June*, 11966–11976. <https://doi.org/10.1109/CVPR52688.2022.01167>.
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Mamun, A. Al, Rahman, M. A., Shatabda, S., & Mukta, M. S. H. (2024). A Systematic Review Of Hyperparameter Optimization Techniques In Convolutional Neural Networks. *Decision Analytics Journal*, 11(September 2023), 100470. <https://doi.org/10.1016/j.dajour.2024.100470>.
- Raiaan, M. A. K., Sakib, S., Fahad, N. M., Mamun, A. Al, Rahman, M. A., Shatabda, S., & Mukta, M. S. H. (2024). A Systematic Review of Hyperparameter Optimization Techniques in Convolutional Neural Networks. *Decision Analytics Journal*, 11(September 2023), 100470. <https://doi.org/10.1016/j.dajour.2024.100470>.

- Teuwen, J., & Moriakov, N. (2019). Convolutional Neural Networks. In *Handbook of Medical Image Computing and Computer Assisted Intervention*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-816176-0.00025-9>.
- Teuwen, J., & Moriakov, N. (2019). Convolutional Neural Networks. In *Handbook of Medical Image Computing and Computer Assisted Intervention*. Elsevier Inc. <https://doi.org/10.1016/B978-0-12-816176-0.00025-9>.
- Valizadeh, M., & Wolff, S. J. (2022). Convolutional Neural Network Applications In Additive Manufacturing: A Review. *Advances in Industrial and Manufacturing Engineering*, 4(October 2021), 100072. <https://doi.org/10.1016/j.aime.2022.100072>.
- Valizadeh, M., & Wolff, S. J. (2022). Convolutional Neural Network Applications In Additive Manufacturing: A Review. *Advances in Industrial and Manufacturing Engineering*, 4(October 2021), 100072. <https://doi.org/10.1016/j.aime.2022.100072>.

## PROFIL PENULIS




### **Indo Intan, S.T., M.T.**

Penulis menyelesaikan S1 di Prodi Teknik Telekomunikasi Jurusan Teknik Elektro tahun 2002 silam di Universitas Hasanuddin. Selanjutnya pada jenjang S2 penulis berhasil mempertahankan tesis di bidang Kecerdasan Buatan khususnya *Image Processing* dan Pengenalan Pola. Terdaftar sebagai dosen di Universitas Dipa Makassar sejak tahun 2005 pada Prodi Teknik Informatika. Selain mengajar, penulis aktif melakukan kegiatan penelitian maupun pengabdian masyarakat. Selama beberapa kali memperoleh dana hibah pada penelitian dosen pemula, penelitian fundamental reguler, dan pengabdian masyarakat. Bidang kajian penulis adalah *machine learning*, *deep learning*, dan *medical data analysis*. Melalui penerapan *machine learning* berbasis pengolahan citra pada *biometric* menghasilkan karya paten sederhana dan sejumlah artikel ilmiah.

Selama beberapa tahun ini kajian riset berfokus pada analisis citra medis yang bermitra dengan rumah sakit demi menghadirkan inovasi yang bisa mengeksplorasi potensi antara dunia kedokteran dengan dunia informatika. *From zero to hero*, kalimat ini yang masih membutuhkan pembuktian untuk sebuah pencapaian yang optimal. Penulis terus belajar, meriset, dan menulis agar bisa memberikan kontribusi bermanfaat bagi mahasiswa dan masyarakat. Penulis telah merilis beberapa buku sesuai bidang kajian tersebut. Semoga buku ini bisa membuka wawasan kita bersama, bahwa eksplorasi ilmu melalui buku akan melahirkan “energi baru” untuk menjadi bekal mengajar, meriset, dan memberikan kontribusi di tengah masyarakat sebagai jariah pahala.

Email Penulis: [indo.intan@undipa.ac.id](mailto:indo.intan@undipa.ac.id).



**BAB 8**  
***JARINGAN LONG SHORT-  
TERM MEMORY (LSTM)  
DAN GATED RECURRENT  
UNITS (GRU)***

---

**Mgr inz. Khairunnas, S.Kom.**  
Universitas Muhammadiyah Bima



*intelligence (AI)* semakin populer. *AI* memiliki dampak besar pada berbagai aspek, termasuk industri, ekonomi, politik, dan masyarakat.

Teknologi ini menyediakan alat yang canggih untuk data analysis, *pattern recognition*, dan *prediction*, yang sangat bermanfaat dalam *predictive maintenance* dan sistem produksi (Mateus, Mendes, Farinha, Assis, & Cardoso, 2021).

## **Pemrosesan *Data Sequence RNN vs LSTM vs GRU***

Penting untuk menekankan bahwa *Recurrent Neural Networks (RNN)* dirancang untuk menganalisis data temporal atau sekuensial. Jaringan ini menggunakan data tambahan dalam urutan untuk meningkatkan akurasi prediksi.

Cara kerjanya adalah dengan mengambil input dan menggunakan kembali aktivasi dari *node* sebelumnya atau berikutnya dalam urutan untuk mempengaruhi *output* (Academy, 2023).


### **1. *Recurrent Neural Networks (RNN)***

Dirancang untuk mengolah data sekuensial, seperti *time-series*, yang dapat berbentuk teks, audio, atau video. Namun, *RNN* memiliki kendala *short-term memory*, yang terjadi akibat *vanishing gradient problem* (kendala dalam pelatihan jaringan saraf dalam yang terjadi saat gradien). Semakin banyak langkah yang diproses dalam jaringan, semakin besar kemungkinan nilai gradien menyusut secara eksponensial dibandingkan dengan arsitektur jaringan saraf lainnya (Pedamallu, 2020).

### **2. *Long Short-Term Memory (LSTM)***

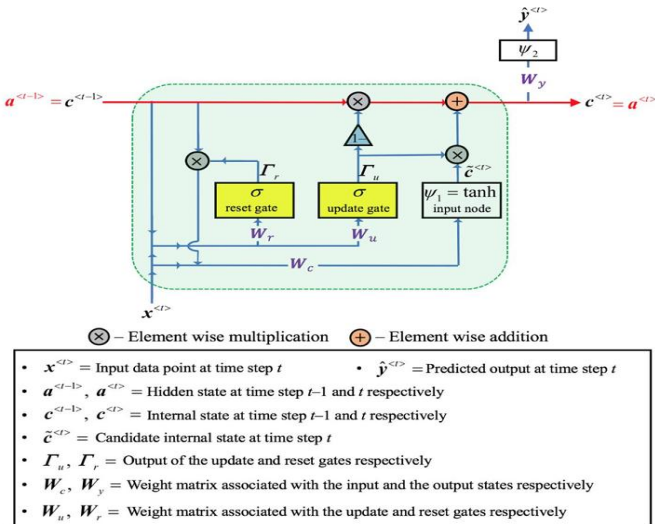
Adalah jenis jaringan saraf tiruan dalam *Artificial Intelligence* dan deep learning yang memiliki koneksi umpan balik, berbeda dengan jaringan feedforward biasa. *LSTM* merupakan bagian dari *Recurrent Neural Networks (RNN)* yang mampu menangani data sekuensial seperti suara dan video, bukan hanya data tunggal seperti gambar.

*LSTM* dirancang untuk mengatasi *vanishing gradient problem* pada *RNN* dengan mempertahankan informasi dalam jangka panjang. Arsitektur *LSTM* memiliki *cell state* yang menyimpan informasi penting, serta tiga gerbang utama: *input gate*, *output gate*, dan *forget gate*, yang mengatur aliran informasi masuk dan keluar.



Gambar 8.3: Arsitektur GRU

Sumber: Carnegie & Chairani, 2023.



Gambar 8.4: Unit Cell GRU

Sumber: Zargar.

$$\tilde{c}^{<t>} = \tanh(W_c [x^{<t>}; \Gamma_r * c^{<t-1>}] + b_c)$$

$$\Gamma_u = \sigma(W_u [x^{<t>}; c^{<t-1>}] + b_u)$$

$$\Gamma_r = \sigma(W_r [x^{<t>}; c^{<t-1>}] + b_r)$$

$$c^{<t>} = (\Gamma_u * \tilde{c}^{<t>}) + (1 - \Gamma_u) * c^{<t-1>}$$

$$\hat{y}^{<t>} = \psi_2(W_y c^{<t>} + b_y)$$

## Daftar Pustaka

- Academy, T. I. (2023, July). *What is The Main Difference Between RNN and LSTM- (RNN vs LSTM)*. Retrieved from The IoT Academy: <https://www.theiotacademy.co/blog/what-is-the-main-difference-between-rnn-and-lstm/>.
- Carnegie, M. D., & Chairani. (2023). Perbandingan Long Short Term Memory (LSTM) dan Gated Recurrent Unit (GRU) Untuk Memprediksi Curah Hujan. *Jurnal Media Informatika Budidarma*.
- Chen, C., Liu, Y., Wang, S. W., Sun, X., Di Cairano-Gilfedder, C., Titmus, S., & A. Syntetor, A. (2020). Predictive Maintenance Using Cox Proportional Hazard Deep Learning. *Advanced Engineering Informatics*.
- Mateus, B. C., Mendes, M., Farinha, J. T., Assis, R., & Cardoso, A. M. (2021). Comparing LSTM and GRU Models to Predict the Condition of a Pulp Paper Press. *MDPI Energies*.
- Pedamallu, H. (2020, November). *RNN vs GRU vs LSTM*. Retrieved from <https://medium.com/analytics-vidhya/rnn-vs-gru-vs-lstm-863b0b7b1573>: <https://medium.com/analytics-vidhya/rnn-vs-gru-vs-lstm-863b0b7b1573>.
- Sherwin, D. J. (1999). Age-based opportunity maintenance. *Journal of Quality in Maintenance Engineering*.
- Zargar, S. A. (n.d.). *Introduction to Sequence Learning Models: RNN, LSTM, GRU*. Retrieved from Researchgate: [https://www.researchgate.net/profile/Sakib-Zargar-2/publication/350950396\\_Introduction\\_to\\_Sequence\\_Learning\\_Models\\_RNN\\_LSTM\\_GRU/links/607b41c0907dcf667ba83ade/Introduction-to-Sequence-Learning-Models-RNN-LSTM-GRU.pdf](https://www.researchgate.net/profile/Sakib-Zargar-2/publication/350950396_Introduction_to_Sequence_Learning_Models_RNN_LSTM_GRU/links/607b41c0907dcf667ba83ade/Introduction-to-Sequence-Learning-Models-RNN-LSTM-GRU.pdf).

## PROFIL PENULIS



### **Mgr inz. Khairunnas, S.Kom.**

Penulis saat ini menjabat sebagai dosen ilmu komputer di Universitas Muhammadiyah, sebuah peran yang diemban sejak belum lama ini. Meski belum memiliki pengalaman luas dalam menulis buku, penulis memiliki ketertarikan mendalam untuk terus belajar dan memperluas wawasan akademik. Penulis menyelesaikan pendidikan sarjana di Universitas Mataram dalam jurusan Teknik Informatika, kemudian melanjutkan studi pascasarjana di *Vistula University*, Polandia dengan beasiswa dari Pemerintah Provinsi NTB, dengan spesialisasi dan fokus pada *Applied Data Science*. Pengetahuan yang diperoleh selama periode studi kini diaplikasikan dalam pembelajaran dan pembimbingan mahasiswa. Penulis juga terus mendalami bidang *data science* dan teknologi terbaru, yang relevan dengan spesialisasi akademis. Melalui pengembangan karir ini, penulis bertujuan untuk memperkaya pengalaman menulis dan berkontribusi lebih aktif dalam komunitas ilmiah, terutama dalam upaya peningkatan mutu pendidikan dan penelitian.

Email Penulis: [kkhairunnas.khairunnas@gmail.com](mailto:kkhairunnas.khairunnas@gmail.com).




# **BAB 9**

# **JARINGAN GENERATIF**

---

**Martono, S.Pd.Kim., M.Tl.**  
Universitas Raharja





**Gambar 10.1: Jaringan Adversarial Generatif Asli (GAN)**

Sumber: *Generative Adversarial Learning: Architectures and Applications* (Razavi-Far, 2022).

Ide di balik persaingan pembelajaran GAN adalah bahwa G mencoba “menipu” D dengan menghasilkan sampel yang mengikuti distribusi data sampel nyata, sementara D mencoba membedakannya sampel palsu yang dihasilkan oleh G dan sampel asli. Untuk tujuan ini, G memodelkan pemetaan berfungsi dari distribusi kebisingan sebelumnya menjadi  $G(z)$ .

Proses persaingan dilakukan melalui permainan min-max antara G dan D. Hasilnya, generator mengembangkan sampel agar D tidak bisa membeda-bedakan dan tertipu. GAN menggunakan *multi-layer perceptron* sebagai generator dan diskriminator, hal ini lebih cocok untuk kumpulan data kecil.

**2. Deep Convolutional Generative Adversarial Network (DCGAN)**

*Deep Convolutional Generative Adversarial Network (DCGAN)* atau Jaringan Generatif Konvolusional Dalam merupakan model generatif yang menggunakan lapisan konvolusi. Pada DCGAN ada *neural network* bernama *generator* dan *discriminator* yang membentuk hubungan *-zero-sum game*. Jaringan Adversarial Generatif Konvolusional Dalam (DCGAN) dapat dipertimbangkan sebagai dukungan dasar untuk penelitian GAN.

Mirip dengan GAN, DCGAN punya diskriminator D maupun generator G dengan fungsi tujuan yang sama, dimana hilangnya setiap jaringan dihitung selama proses perlawanan untuk memperbarui bobot generator dan pembeda. Tampilan skema DCGAN ditampilkan pada gambar berikut:

Pada contoh gambar di atas, *StyleGAN* menggunakan arsitektur *baseline progressive* GAN yang berarti ukuran gambar yang dihasilkan meningkat secara bertahap dari resolusi yang sangat rendah ( $4 \times 4$ ) ke resolusi tinggi ( $1024 \times 1024$ ).

Hal ini dilakukan dengan menambahkan blok baru ke kedua model untuk mendukung resolusi yang lebih besar setelah menyesuaikan model pada resolusi yang lebih kecil agar lebih stabil. Sebagian besar model transfer gaya sebelumnya menggunakan *input* acak untuk membuat kode laten awal dari generator, yaitu input level  $4 \times 4$ .

Namun, penulis *style-GAN* menyimpulkan bahwa fitur pembangkitan gambar dikontrol oleh  $w$  dan AdaIN. Oleh karena itu, mereka mengganti *input* awal dengan matriks konstan  $4 \times 4 \times 512$ . Hal ini juga berkontribusi pada peningkatan kinerja jaringan.


**12. Bidirectional Generative Adversarial Network (BiGAN)**

*Bidirectional Generative Adversarial Network (BiGAN)* tidak hanya memetakan sampel laten ke data yang dihasilkan, tetapi juga memiliki pemetaan terbalik dari data ke representasi laten.

Tujuannya adalah membuat jenis GAN dapat mempelajari representasi yang kaya untuk aplikasi seperti pembelajaran tanpa pengawasan. *BiDirectional GAN* atau *BiGAN* merupakan varian dari GAN menambahkan *encoder* model GAN asli.

Dengan *encoder* tambahan, *BiGAN* mampu mempelajari pemetaan terbalik dari data nyata ke ruang laten untuk lebih mendukung *generator* yang menghasilkan kumpulan data sintetik yang lebih kaya secara semantik.

*Encoder* memainkan peran penting untuk model *BiGAN* menyediakan representasi laten pembelajaran dari data nyata.



**Gambar 10.8: Struktur *BiGAN***

Sumber: <https://doi.org/10.3390/computers11060085>.

Perhatikan bahwa ( $z$  dan  $E(x)$ ) dan ( $G(z)$  dan  $x$ ) memiliki dimensi yang sama. Pasangan gabungan [ $G(z)$ ,  $z$ ] dan [ $x$ ,  $E(x)$ ] adalah dua sumber masukan dari diskriminator  $D$ . *Generator*  $G$  dan *encoder*  $E$  dioptimalkan dengan kerugian yang dihasilkan oleh diskriminator  $D$ .

### 13. *Bayesian Generative Adversarial Network (BGAN)*

Baru-baru ini, terdapat cukup banyak upaya untuk mengatasi masalah keruntuhan mode, untuk menstabilkan pelatihan GAN. diusulkan berbagai pendekatan untuk meningkatkan pelatihan dan menghindari keruntuhan mode.

Ada juga banyak penelitian yang bertujuan untuk meningkatkan fungsi kerugian, misalnya, menggunakan kerugian *Wasserstein*. Metode ini mirip dengan mengatur jaringan untuk menstabilkan optimasi.

*Bayesian GAN* menggunakan pendekatan berbeda yang memodelkan distribusi generator bersama dan diskriminator dengan memasukkan posterior persamaan bersyarat. Jaringan Bayesian merupakan model grafis probabilistik yang dapat merepresentasikan ketergantungan kompleks antara variabel. Jaringan ini sering digunakan dalam aplikasi seperti diagnosis dan prediksi.

## Penutup

GAN merupakan model generatif yang dipergunakan untuk membuat data baru. Model ini cukup populer karena dapat digunakan untuk menghasilkan sampel gambar sintesis, yang dapat berguna untuk tugas-tugas seperti pengenalan gambar atau deteksi objek.

Salah satu tantangan utama dalam melatih jaringan adversarial generatif adalah membuat jaringan tersebut konvergen dan menghasilkan hasil yang baik. GAN sering kali tidak stabil dan sulit dilatih.

Banyak faktor yang dapat menyebabkan hal ini, seperti inisialisasi jaringan, jenis data yang digunakan untuk pelatihan, dan cara jaringan dikonfigurasi. Selain itu, GAN sering kali memerlukan sejumlah besar data untuk pelatihan yang efektif. Hal ini dapat menjadi tantangan saat bekerja dengan kumpulan data yang terbatas.

## Daftar Pustaka

- Arjovsky, M., Chintala, S., Bottou, L. (2017). Wasserstein Generative Adversarial Networks, *ICML*. Vol 70, Sydney, Australia.
- Dumouli, V., Arulkumaran, K., Sengupta, B., Bharath, A. (2017). Generative Adversarial Networks: An Overview. *Submitted To IEEE-SPM*.
- <https://developers.arcgis.com/python/latest/guide/how-cyclegan-works/>.
- <https://www.geeksforgeeks.org/stylegan-style-generative-adversarial-networks/>.
- Karas, T., Alia, T., Liane, S., Lehtine, J. (2018). Progressive Growing Of Gans For Improved Quality, Stability And Variation, *Published at ICLR*.
- Razavi-Far, R., Garcia, A. R., Palade, Vasile & Schmidhuber, J. (2022). *Generative Adversarial Learning: Architectures and Applications*. Switzerland: Springer Nature Switzerland AG, Cham.
- Xu, W., Jang-Jaccard, J., Liu, T., Sabrina, F., Kwak, J. (2022). Improved Bidirectional GAN-Based Approach for Network Intrusion Detection Using One-Class Classifier. *Computers*, 11, 85.

## PROFIL PENULIS




### **Martono, S.Pd.Kim., M.TI.**

Ketertarikan penulis pada bidang komputer awalnya hanya karena hobi dan iseng-iseng. Sambil menyelesaikan Pendidikan Kimia jenjang Diploma 3 di IKIP Jakarta pada saat itu penulis juga mengikuti pelatihan elektronika komputer. Belajar tentang jaringan komputer dimulai dari era *Novell Netware* dan *Microsoft NT 4.0* pada saat jaringan LAN yang masih populer menggunakan *Cable Coaxial* hingga kini era jaringan menggunakan *Wifi* dan *Fiber Optics*, hal tersebut lebih karena tuntutan pekerjaan.

Pendidikan D3 diselesaikan di IKIP Jakarta dan S1 diselesaikan di Universitas Terbuka pada tahun 2006 masih pada Jurusan yang sama yakni Pendidikan Kimia. Penulis kemudian melanjutkan Pendidikan S2 di STMIK Raharja (sekarang sudah jadi Universitas Raharja) pada program studi Teknik Informatika dan selesai pada tahun 2017. Awalnya penulis bekerja di Perusahaan yang merupakan vendor di bidang Teknologi Informasi yang melayani berbagai organisasi pendidikan dan perusahaan.

Kemudian penulis berlanjut bergabung dengan perusahaan Teknologi Informasi yang memberikan pelatihan-pelatihan kepada sekolah-sekolah dan juga mengembangkan *Software-software* Pendidikan dan Pelatihan Robotika. Dari sini penulis akhirnya banyak melakukan eksplorasi *software*, Mikrokontroler dan Robotika serta terlibat baik secara langsung maupun tidak langsung dalam pengembangan *software*. Beberapa tulisan ringan ditulis dalam bentuk blog dan sering menggunakan nickname *martonokita*. Adapun tulisan ilmiahnya telah diterbitkan dalam beberapa buku dan dalam beberapa Jurnal Ilmiah. Selain memberikan pelatihan, penulis juga mengajar di SMKN 4 Depok dan Universitas Raharja.

Email Penulis: [martono@raharja.info](mailto:martono@raharja.info).



**BAB 10**  
**JARINGAN**  
***TRANSFORMER* DAN**  
**PEMROSESAN BAHASA**  
**ALAMI (NLP)**

---

**Pramana Yoga Saputra, S.Kom., M.MT.**  
Politeknik Negeri Malang



secara luas dalam sistem penerjemahan mesin, memungkinkan peningkatan kualitas hasil terjemahan dengan memahami konteks mendalam (Patwardhan et al., 2023; Vaswani et al., 2017).

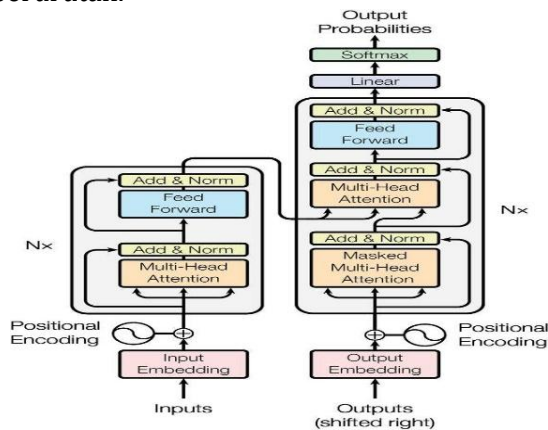
Selain itu, *Transformer* juga diadopsi dalam tugas klasifikasi teks, sistem *question-answering*, serta pembangkitan teks otomatis yang semakin mendekati kemampuan manusia menghasilkan bahasa alami (Patwardhan et al., 2023; Devlin et al., 2019).

Popularitas arsitektur ini semakin meningkat dengan munculnya berbagai varian dan optimalisasi yang bertujuan untuk meningkatkan efisiensi serta akurasi model, seperti BERT (*Bidirectional Encoder Representations from Transformer*), GPT (*Generative Pre-trained Transformer*), dan T5 (*Text-to-Text Transfer Transformer*).

### Arsitektur dan Mekanisme *Transformer*

*Transformer* adalah arsitektur model *deep learning* yang dirancang khusus untuk menangani data sekuensial, seperti teks, dengan menggunakan mekanisme *self-attention* (Vaswani et al., 2017), seperti yang ditunjukkan pada gambar 10.1 Arsitektur ini pertama kali diperkenalkan dalam konteks pemrosesan bahasa alami (*Natural Language Processing* atau *NLP*) dan telah menjadi fondasi bagi banyak model modern seperti *BERT*, *GPT*, dan T5.

*Transformer* memungkinkan pemrosesan paralel yang efisien, mengatasi keterbatasan model sebelumnya yang bergantung pada pemrosesan berurutan.



**Gambar 10.1: Arsitektur *Transformer***

Sumber: Vaswani et al., 2017.

- b. Proses:
  - 1) Setiap kata menghitung *attention score* dengan semua kata lain.
  - 2) Kata "nice" mungkin memiliki skor tinggi dengan "weather" (subjek) dan "very" (penekanan).
- c. Contoh *Output*: representasi baru untuk "nice" setelah *self-attention*:  
[nice] → [0.7, -0.2, 1.4, ...] (terbobot dari kombinasi "weather", "very", "today").

### 3. Tahap *Feed-Forward Network (Encoder)*

- a. *Input*: representasi dari *self-attention*.
- b. Proses:
  - 1) Transformasi non-linear melalui jaringan saraf (misal: 2 lapisan dengan aktivasi ReLU).
  - 2) Menangkap pola kompleks seperti hubungan subjek-predikat.
- c. Contoh *Output*:  
[nice] → [1.1, 0.4, -0.5, ...] (representasi yang lebih kaya).

### 4. Tahap *Masked Self-Attention di Decoder*

- a. *Input*: *token output* sebelumnya (misal: "Cuaca hari ini" dalam bahasa Indonesia).
- b. Proses:
  - 1) *Masking* mencegah dekoder melihat kata masa depan (misal: "sangat" saat memproses "hari ini").
  - 2) "hari ini" fokus pada "Cuaca".
- c. Contoh *Output*:  
[hari ini] → [0.6, -0.1, 0.9, ...] (terbobot dari "Cuaca").

### 5. Tahap *Cross-Attention (Decoder ke Encoder)*

- a. *Input*:
  - 1) *Query* dari *decoder* ("hari ini").
  - 2) *Key/Value* dari *encoder* ("The weather is very nice today").
- b. Proses:  
"hari ini" mencari kata relevan di *encoder*, seperti "today" dan "weather".

- c. Contoh *Output*:  
 [hari ini] → [0.7, 0.3, -0.4, ...] (terbobot dari "today" dan "weather" di *encoder*).

## 6. Tahap *Feed-Forward Network (Decoder)*

- a. *Input*: Representasi dari *cross-attention*.
- b. Proses:  
 Transformasi non-linear untuk menyiapkan prediksi kata berikutnya.
- c. Contoh *Output*:  
 [hari ini] → [1.2, -0.8, 0.5, ...] (siap untuk memprediksi "sangat").

## 7. *Output Layer dan Softmax*

- a. *Input*: Representasi akhir dari decoder.
- b. Proses:
  - 1) Vektor diubah ke dimensi kosakata (misal: 50.000 token).
  - 2) *Softmax* menghitung probabilitas kata berikutnya.
- c. Contoh *Output*:  
 Prediksi setelah "Cuaca hari ini":
  - "sangat" → 65%
  - "lumayan" → 10%
  - "cukup" → 5%
  - ... (dst).

## Visualisasi Alur Data

*Input*: The → weather → is → very → nice → today

*Embedding + Positional Encoding* → *Encoder Self-Attention* → *Encoder FFN* → (diulang N lapis)

*Decoder Input*: [Start] → Cuaca → hari → ini

*Decoder Masked Attention* → *Cross-Attention* (ke *Encoder*) → *Decoder FFN* → Prediksi "sangat"

*Output*: Cuaca hari ini sangat → ... → [End].

Analisis Contoh:

**1. Encoder**

Kata "*weather*" di *encoder* memiliki bobot *attention* tinggi ke "*nice*" dan "*today*", membantu memahami deskripsi dan waktu.

**2. Decoder**

a. Saat menghasilkan "*sangat*", *decoder* menggunakan *cross-attention* ke "*very*" di *encoder*.

b. *Masked self-attention* memastikan "*sangat*" tidak melihat kata "*bagus*" selama pelatihan.

Dengan mekanisme ini, *transformer* mampu menghasilkan terjemahan yang kontekstual dan akurat, seperti "*Cuaca hari ini sangat bagus*".

\*\*\*\*\*

## Daftar Pustaka

- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., ... & Amodei, D. (2020). *Language Models Are Few-Shot Learners*. arXiv. <https://arxiv.org/abs/2005.14165>.
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). *BERT: Pre-training of Deep Bidirectional Transformer For Language Understanding*. arXiv. <https://arxiv.org/abs/1810.04805>.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., ... & Houlsby, N. (2021). *An image is worth 16x16 words: Transformer For Image Recognition At Scale*. arXiv. <https://arxiv.org/abs/2010.11929>.
- <https://doi.org/10.48550/arXiv.2005.14187>.
- Islam, S., Elmekki, H., Elsebai, A., Bentahar, J., Drawel, N., Rjoub, G., & Pedrycz, W. (2023). *A Comprehensive Survey On Applications Of Transformer For Deep Learning Tasks*. arXiv. <https://arxiv.org/abs/2301.00001>.
- Lu, D., Xie, Q., Wei, M., Xu, L., & Li, J. (2022). *Transformer in 3D point clouds: A survey*. arXiv. <https://arxiv.org/abs/2201.00001>.
- Patwardhan, N., Marrone, S., & Sansone, C. (2023). *Transformer In The Real World: A Survey On NLP Applications*. MDPI. <https://doi.org/10.3390/info14040242>.
- Raffel, C., Shazeer, N., Roberts, K., Lee, K., Narang, S., Matena, M., ... & Liu, P. J. (2020). *Exploring The Limits Of Transfer Learning With A Unified Text-To-Text Transformer*. arXiv. <https://arxiv.org/abs/1910.10683>.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., & Polosukhin, I. (2017). *Attention is all you need*. arXiv. <https://arxiv.org/abs/1706.03762>.
- Wang, H., Wu, Z., Liu, Z., Cai, H., Zhu, L., Gan, C., & Han, S. (2020). *HAT: Hardware-Aware Transformer For Efficient Natural Language Processing*. ACL Anthology.
- Yuan, K., Guo, S., Liu, Z., Zhou, A., Yu, F., & Wu, W. (2021). *Incorporating convolution designs into visual transformer*. IEEE Xplore. <https://doi.org/10.1109/ICCV48922.2021.00062>.


## PROFIL PENULIS



### **Pramana Yoga Saputra, S.Kom., M.MT.**

Pramana Yoga Saputra, S.Kom, M.MT., adalah seorang dosen dan peneliti yang berpengalaman dalam bidang teknologi informasi dan multimedia di Politeknik Negeri Malang. Berbekal latar belakang akademik yang kuat di bidang Teknik Informatika (S.Kom., Institut Teknologi Sepuluh Nopember Surabaya) dan Magister Manajemen Teknologi Informasi, Pramana telah mendedikasikan kariernya untuk mengkaji keterkaitan antara teknologi, multimedia, dan pendidikan. Fokus pengajarannya mencakup mata kuliah Dasar Pemrograman, Desain Antar Muka, Statistika Komputasi, dan Manajemen Proyek, di mana ia telah berhasil membimbing lebih dari 40 lulusan. Sebagai peneliti yang berdedikasi, Pramana telah terlibat dalam berbagai proyek inovatif yang didanai oleh pemerintah Indonesia, termasuk pengembangan sistem analisis sentimen, gamifikasi dalam pendidikan pemrograman, serta sistem cerdas untuk prediksi kesiapan operasional. Kontribusinya dalam bidang multimedia terlihat jelas, khususnya dalam desain dan implementasi media pembelajaran untuk pemrograman, selain juga menulis sejumlah artikel ilmiah di bidang pembelajaran mesin, analisis data, dan pengembangan perangkat lunak.

Email Penulis: [pramana.yoga@polinema.ac.id](mailto:pramana.yoga@polinema.ac.id).



# **BAB 11**

# **PEMROSESAN GAMBAR**

# **DENGAN *DEEP***

# ***LEARNING***

---

**Sutriawan, S.Kom., M.Kom.**  
Universitas Muhammadiyah Bima



*Deep learning* telah membawa perubahan besar dalam berbagai bidang yang mengandalkan pemrosesan gambar, termasuk:

1. **Deteksi dan Klasifikasi Objek:** digunakan dalam pengenalan wajah, deteksi plat nomor kendaraan, dan klasifikasi objek dalam gambar.
2. **Segmentasi Gambar:** berguna dalam analisis medis untuk mendeteksi tumor atau dalam pengolahan citra satelit.
3. **Peningkatan Resolusi Gambar:** model seperti *Super-Resolution GAN (SRGAN)* dapat meningkatkan kualitas gambar dengan memperjelas detail yang hilang.
4. **Pemulihan dan Rekonstruksi Gambar:** digunakan untuk memperbaiki gambar yang buram atau rusak, misalnya dalam restorasi film lama.
5. **Pemahaman Kontekstual Gambar:** teknologi seperti *CLIP* dari *OpenAI* dapat memahami hubungan antara teks dan gambar, memungkinkan aplikasi seperti pencarian berbasis visual.

Bab ini bertujuan untuk memberikan gambaran awal tentang peran *deep learning* dalam pemrosesan gambar. Selanjutnya, kita akan mendalami prinsip dasar pemrosesan gambar, arsitektur *deep learning* yang populer, teknik *training* dan optimasi model, serta implementasi nyata dalam berbagai domain aplikasi.

Dengan memahami dasar ini, diharapkan pembaca dapat memiliki wawasan yang kuat dalam mengembangkan solusi berbasis *deep learning* untuk pemrosesan gambar di berbagai bidang.

**Pemrosesan Gambar Dengan *Convolutional Neural Network***  
*Convolutional Neural Networks (CNN)* adalah salah satu arsitektur *deep learning* yang paling populer dalam pemrosesan gambar (Taye, 2023).

*CNN* bekerja dengan mengekstrak fitur dari gambar menggunakan operasi konvolusi, yang memungkinkan model mengenali pola seperti tepi, tekstur, dan bentuk pada berbagai tingkat abstraksi (Leke and Marwala, 2019; Medioni and Dickinson, 2022).

### 1. **Arsitektur *Convolutional Neural Network***

*Convolutional Neural Network (CNN)* terdiri dari beberapa komponen utama yang seperti yang terlihat pada arsitektur pada gambar 11.1.

### c. Sigmoid

Adalah fungsi aktivasi yang mengubah input menjadi nilai antara 0 dan 1 dengan rumus :

$$\hat{y} = \frac{1}{1 + e^{-(wx+b)}}$$

Fungsi ini banyak digunakan dalam lapisan output untuk klasifikasi biner, karena dapat merepresentasikan probabilitas. Namun, sigmoid memiliki kelemahan yaitu vanishing gradient, yang membuat jaringan sulit untuk belajar pada lapisan yang lebih dalam.

## Training Model Dengan Epoch dan Batch Size

Dalam *deep learning*, proses *training model* memerlukan pengaturan *epoch* dan *batch size*, yang berperan penting dalam konvergensi, performa, dan efisiensi komputasi.

### 1. Epoch

*Epoch* adalah jumlah siklus penuh ketika model melewati seluruh *dataset* untuk melakukan pembaruan bobot berdasarkan *error* yang dihitung dalam setiap iterasi.

Jika 1 *epoch* berarti model telah melihat seluruh *dataset* sekali, maka 10 *epoch* berarti model telah melihat *dataset* sebanyak 10 kali, memungkinkan model untuk memperbaiki bobotnya di setiap iterasi.

Meningkatkan jumlah *epoch* dapat membantu model belajar lebih baik, tetapi terlalu banyak *epoch* bisa menyebabkan *overfitting*, di mana model tidak hanya belajar pola dalam data tetapi juga mulai menghafal *noise* atau detail yang tidak relevan (Sutriawan *et al.*, 2023).

Dalam *training deep learning*, jumlah *epoch* yang optimal sangat bergantung pada *dataset* dan kompleksitas model. Jika *epoch* terlalu sedikit, model mungkin mengalami *underfitting*, di mana ia gagal menangkap pola yang cukup dari data. Sebaliknya, jika *epoch* terlalu banyak, model bisa kehilangan kemampuan untuk melakukan generalisasi, yang menyebabkan performa tinggi pada *data training* tetapi buruk pada data baru.

## Kesimpulan

Pemrosesan gambar dengan *deep learning* telah membawa revolusi dalam berbagai bidang, mulai dari pengenalan wajah, deteksi objek, segmentasi gambar, hingga analisis medis. Dengan memanfaatkan arsitektur seperti *Convolutional Neural Networks (CNN)*, model dapat secara otomatis mengekstraksi fitur dari gambar, menggantikan pendekatan tradisional berbasis ekstraksi fitur manual.

Dalam *training* model *deep learning* untuk pemrosesan gambar, *epoch* dan *batch size* memainkan peran penting dalam konvergensi dan generalisasi model. *Epoch* menentukan berapa kali seluruh *dataset* diproses, sementara *batch size* mengatur jumlah sampel yang diproses dalam satu iterasi pembaruan bobot.

Evaluasi model dilakukan dengan berbagai metrik untuk memastikan model dapat mengenali pola dengan akurat dan dapat diterapkan pada data baru. Untuk klasifikasi gambar, metrik seperti *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* digunakan untuk mengukur performa model.

Pemrosesan gambar dengan *deep learning* juga terus berkembang dengan hadirnya teknik *transfer learning*, augmentasi data, dan arsitektur jaringan yang lebih canggih seperti *ResNet*, *EfficientNet*, dan *Vision Transformers (ViT)*. Dengan melakukan eksperimen dan *tuning hyperparameter* yang tepat, dapat menghasilkan performa yang optimal, akurat, dan dapat diandalkan dalam berbagai aplikasi pemrosesan gambar.

\*\*\*\*\*

## Daftar Pustaka

- C. Musab, *et al.* (2017). an Overview of Popular Deep Learning Methods, *European Journal of Technic*, 7(2), pp. 165–176. Available at: <https://doi.org/10.23884/ejt.2017.7.2.11>.
- D. Shetty, *et al.* (2020). Diving Deep into Deep Learning: History, Evolution, Types and Applications, *International Journal of Innovative Technology and Exploring Engineering*, 9(3), pp. 2835–2846. Available at: <https://doi.org/10.35940/ijitee.a4865.019320>.
- Derry, A., Krzywinski, M. and Altman, N. (2023). *Convolutional Neural Networks, Nature Methods*. Available at: <https://doi.org/10.1038/s41592-023-01973-1>.
- Heydarian, M., Doyle, T.E. and Samavi, R. (2022). MLCM: Multi-Label Confusion Matrix, *IEEE Access*, 10, pp. 19083–19095. Available at: <https://doi.org/10.1109/ACCESS.2022.3151048>.
- Karanam, S.R., Srinivas, Y. and Krishna, M.V. (2020). WITHDRAWN: Study on Image Processing Using Deep Learning Techniques, *Materials Today: Proceedings* [Preprint]. Available at: <https://doi.org/10.1016/j.matpr.2020.09.536>.
- Krichen, M. (2023). Convolutional Neural Networks: A Survey, *Computers*, 12(8), pp. 1–41. Available at: <https://doi.org/10.3390/computers12080151>.
- Lateef, A.A.A., Al-Janabi, S.T.F. and Al-Khateeb, B. (2019). Survey on Intrusion Detection Systems Based On Deep Learning, *Periodicals of Engineering and Natural Sciences*, 7(3), pp. 1074–1095. Available at: <https://doi.org/10.21533/pen.v7i3.635>.
- Leke, C.A. and Marwala, T. (2019). Introduction to Deep Learning, *Studies in Big Data*, 48, pp. 21–40. Available at: [https://doi.org/10.1007/978-3-030-01180-2\\_2](https://doi.org/10.1007/978-3-030-01180-2_2).
- Litjens, G. *et al.* (2017). A Survey On Deep Learning In Medical Image Analysis, *Medical Image Analysis*, 42(1995), pp. 60–88. Available at: <https://doi.org/10.1016/j.media.2017.07.005>.
- Medioni, G. and Dickinson, S. (2022). *Synthesis Lectures on Computer Vision Editors*.
- Meena, B., Rao, K.V. and Chittineni, S. (2020). A Survey On Deep Learning Methods And Tools In Image Processing, *International Journal of Scientific and Technology Research*, 9(2), pp. 1057–1062.

- Sakib, S. *et al.* (2018). An Overview of Convolutional Neural Network: Its Architecture and Applications, *Preprints 2018* [Preprint], (February). Available at: <https://doi.org/10.20944/preprints201811.0546.v1>.
- Sutriawan, S. *et al.* (2023). Deep Learning Jaringan Saraf Tiruan Untuk Pemecahan Masalah Deteksi Penyakit Daun Apel, *Jurnal Teknologi Informasi dan Komunikasi (TIKOMSiN)*, 11(1), p. 35. Available at: <https://doi.org/10.30646/tikomsin.v11i1.729>.
- Taobao (2024). *Detailed Explanation of Generative AI Principles and Technology (Part 1) - Neural Networks and Deep Learning*, Taobao Alibaba. Available at: <https://blog.csdn.net/Taobaojishu/article/details/138102502>.
- Taye, M.M. (2023). Theoretical Understanding of Convolutional Neural Network: Concepts, Architectures, Applications, Future Directions, *Computation*, 11(3). Available at: <https://doi.org/10.3390/computation11030052>.
- Visa, S. *et al.* (2011). Confusion Matrix-Based Feature Selection, *CEUR Workshop Proceedings*, 710, pp. 120–127.
- Wang, Y. *et al.* (2020). Improvement of Mnist Image Recognition Based on CNN, *IOP Conference Series: Earth and Environmental Science*, 428(1). Available at: <https://doi.org/10.1088/1755-1315/428/1/012097>.

## PROFIL PENULIS




### **Sutriawan, S.Kom., M.Kom.**

Sutriawan adalah seorang peneliti dan dosen di bidang ilmu komputer. Ia memperoleh gelar sarjana di bidang Teknik Informatika dari Universitas Ahmad Dahlan di Yogyakarta, Indonesia, pada tahun 2018, dan kemudian menyelesaikan gelar magister di bidang Teknik Informatika dari Universitas Dian Nuswantoro, Indonesia.

Saat ini Sutriawan merupakan kandidat doktor di Universitas Dian Nuswantoro dan bekerja sebagai dosen di Program Studi Ilmu Komputer Universitas Muhammadiyah Bima. Minat penelitiannya meliputi kecerdasan buatan (*AI*), penambangan teks, penambangan data, dan pemrosesan bahasa alami (*NLP*), di mana ia bekerja untuk memajukan bidang-bidang ini melalui penelitian teoritis dan aplikasi praktis.


Email Penulis: [Sutriawan@umbima.com](mailto:Sutriawan@umbima.com).



**BAB 12**  
**PEMROSESAN AUDIO**  
**DAN VIDEO DENGAN**  
***DEEP LEARNING***

---

**Soekarman, S.T., M.T.**  
Politeknik Muhammadiyah Makassar



## **Pemrosesan Audio dengan *Deep Learning***

Pemrosesan audio dan video menggunakan pembelajaran mendalam adalah salah satu bidang kecerdasan buatan (*AI*) yang paling cepat berkembang. Pembelajaran mendalam digunakan untuk menganalisis, mengenali, dan memanipulasi data audio dan video dengan sangat efektif. Berikut beberapa aspek penting pemrosesan audio dan video dengan pembelajaran mendalam:

### **1. Pemrosesan Ucapan**

Pembelajaran mendalam banyak digunakan dalam aplikasi pengenalan ucapan, seperti asisten *virtual* (misalnya, Siri atau Asisten *Google*), transkripsi otomatis, dan teks ke suara. Model seperti *RNN* (*Recurrent Neural Networks*), *LSTM* (*Long Short-Term Memory*) dan *CNN* (*Convolutional Neural Networks*) digunakan untuk mengenali pola dalam data audio.

### **2. Pengenalan Ucapan**

Pembelajaran mendalam dapat digunakan untuk mengubah ucapan menjadi teks. Model seperti *DeepSpeech Mozilla* atau sistem yang menggunakan jaringan saraf konvolusional dan *recurrent* mampu melakukan pengenalan suara dengan akurasi yang tinggi.

### **3. Pemrosesan Audio Untuk Musik**

Pembelajaran mendalam juga digunakan dalam analisis musik, seperti klasifikasi *genre*, pemisahan instrumen, atau bahkan pembuatan musik dengan model seperti *WaveNet* atau *GAN* (*Generative Adversarial Networks*).

### **4. Peningkatan Suara**

Dalam aplikasi lain, pembelajaran mendalam digunakan untuk meningkatkan kualitas suara, misalnya untuk mengurangi kebisingan atau meningkatkan kualitas rekaman suara berkualitas buruk.

## **Pemrosesan Video Dengan *Deep Learning***

### **1. Pengenalan Objek**

Pembelajaran mendalam, khususnya dengan model *CNN* atau *YOLO* (*You Only Look Once*), digunakan untuk mengenali objek dalam video. Model ini mampu mendeteksi berbagai objek dalam gambar video secara *real-time*.

menggunakan algoritma seperti *Stochastic Gradient Descent (SGD)* atau *Adam* untuk meminimalkan kesalahan. Penyesuaian: teknik ini membantu menghindari *overfitting*. Misalnya, lapisan putus sekolah sering digunakan untuk mengurangi kemungkinan suatu model terlalu bergantung pada fitur tertentu.

#### 4. Langkah 4: Mengevaluasi Model

Evaluasi dilakukan untuk mengukur kinerja model pada data yang belum pernah terlihat sebelumnya. Beberapa ukuran penilaian yang umum digunakan adalah:

- a. Akurasi: mengukur persentase prediksi yang benar.
- b. Presisi dan Ingatan: Cocok untuk deteksi objek, presisi menunjukkan berapa banyak prediksi yang benar, sedangkan ingatan menunjukkan berapa banyak objek yang dikenali dengan benar.
- c. Skor F1: kombinasi presisi dan ingatan yang memberikan pandangan yang lebih seimbang tentang kinerja model.

#### 5. Langkah 5: *Fine-Tuning* dan *Deployment*

Setelah model dilatih dengan benar, penyempurnaan dilakukan untuk mengoptimalkan kinerja. Jika hasilnya memuaskan, model dapat diimplementasikan dalam lingkungan produksi atau aplikasi tertentu.

\*\*\*\*\*

## Daftar Pustaka

- Ardiansyah, A., Rainarli, E. (2017). Implementasi Q-Learning and Backpropagation pada Agen yang Memainkan Permainan Flappy Bird. *JNTETI* Vol. 6 No. 1, February 2017, ISSN 2301-4156.
- Bellemare, M. G., Naddaf, Y., Veness, J., Dan Bowling, M. (2013). The Arcade Learning Environment: An Evaluation Platform For General Agents. *Journal of Artificial Intelligence Research*, 47, 253-279.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Huang, X., & Chan, C. (2019). *Deep Learning for Speech Recognition*. Springer.
- Rajkumar, N., Jaganathan., P. (2013). A New RBF Kernel Based Learning Method Applied to Multiclass Dermatology Diseases Classification. *Proceedings of 2013 IEEE Conference on Information and Communication Technologies (ICT 2013)*.
- Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *arXiv:1409.1556*.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. A., Kaiser, Ł., & Polosukhin, I. (2017). *Attention is All You Need*. *Advances in Neural Information Processing Systems*.30.

## PROFIL PENULIS



### **Soekarman, S.T., M.T.**

Ketertarikan penulis terhadap Ilmu Elektro dan Elektronika dimulai pada tahun 2011 silam. Hal tersebut membuat penulis memilih untuk masuk ke Sekolah Menengah Kejuruan di SMK Negeri 2 Kota Makassar dengan memilih Jurusan Elektronika audio video dan berhasil lulus pada tahun 2006. Penulis kemudian melanjutkan pendidikan ke Perguruan Tinggi dan berhasil menyelesaikan studi DIII Elektromedis di prodi Teknologi Elektromedis, Akademi Teknik Elektromedik Muhammadiyah Makassar, dan lulus pada tahun 2010. Dua tahun kemudian, penulis Konversi menyelesaikan studi S1 dengan mengambil jurusan Teknik Elektro lalu lanjut ke Program Pasca Sarjana di Universitas Hasanuddin, dan berhasil menyelesaikan S2 Teknik Elektro pada tahun 2020. Penulis memiliki rumpun ilmu terapan, dengan cabang ilmu teknologi rekayasa elektromedis. Untuk mendukung tugas sebagai dosen profesional, maka penulis aktif untuk menulis sesuai kompetensi yang telah dicapai dengan harapan dapat mewujudkan cita-cita bangsa dan negara Republik Indonesia.

Email Penulis: [soekarman@poltekkesmu.ac.id](mailto:soekarman@poltekkesmu.ac.id).



**BAB 13**  
**TEKNIK REGULARISASI**  
**DALAM *DEEP LEARNING***

---

**Kodrat Mahatma S.T., M.Kom.**  
Universitas Teknologi Digital



- saat diberikan gambar baru dengan latar belakang berbeda. Teknik seperti augmentasi data dapat membantu mengurangi *overfitting*.
- b. *Overfitting* Dalam Pemrosesan Bahasa Alami (NLP): dalam tugas klasifikasi teks (misalnya, analisis sentimen), model yang *overfitting* mungkin terlalu kuat mengasosiasikan kata tertentu dengan suatu kategori. Teknik seperti label *smoothing* dan *dropout* dapat membantu mencegah *overfitting* ini.
  - c. *Overfitting* Dalam Model Regresi: model *deep learning* yang dilatih untuk memprediksi harga rumah dapat mengingat data spesifik alih-alih mengenali hubungan sebenarnya antara fitur (misalnya, luas rumah, jumlah kamar tidur). Ini menghasilkan model yang tidak stabil dan tidak dapat digeneralisasi dengan baik. Regularisasi L2 (*Ridge Regression*) sering digunakan untuk menghaluskan nilai bobot dan menghindari sensitivitas yang berlebihan terhadap fitur tertentu.
  - d. *Overfitting* Dalam Peramalan Deret Waktu: misalkan jaringan saraf berulang (RNN) dilatih pada dataset kecil harga saham. Model mungkin mulai memprediksi harga masa depan hanya berdasarkan pola historis tanpa memperhitungkan variasi dunia nyata. Teknik seperti *dropout*, *weight decay*, dan augmentasi data dapat membantu meningkatkan generalisasi.

## Regularisasi Berbasis Norma

Regularisasi berbasis norma, khususnya L1 (*Lasso*) dan L2 (*Ridge*), merupakan salah satu teknik yang paling umum digunakan untuk mengontrol kompleksitas jaringan saraf dengan memberikan penalti pada bobot yang terlalu besar.

Teknik regularisasi berbasis norma membatasi bobot model dengan menambahkan istilah penalti ke dalam fungsi *loss*. Metode ini membantu mengurangi *overfitting* dengan memastikan bahwa parameter yang dipelajari tetap kecil dan menghindari fluktuasi ekstrem yang dapat menghambat generalisasi model.

### 1. Regularisasi L1 (*Lasso*)

Regularisasi L1 menambahkan nilai absolut dari koefisien bobot ke dalam fungsi *loss*:

$$R(w) = \sum |w_i|$$

Sehingga, fungsi *loss* baru dengan regularisasi L1 menjadi:

$$L = L_{\text{original}} + \lambda \sum |w_i|$$

dimana  $\lambda$  menentukan seberapa besar model akan memberikan penalti pada bobot yang besar.

Penggunaan Regularisasi L1, untuk (a) Seleksi fitur pada dataset berdimensi tinggi; (b) Pelatihan model yang lebih ringkas (misalnya, jaringan saraf terkompresi); (c) Mengurangi kompleksitas model dalam klasifikasi teks.

## 2. Regularisasi L2 (*Ridge*)

Regularisasi L2, juga dikenal sebagai *Ridge Regression*, menambahkan kuadrat dari nilai bobot ke dalam fungsi *loss*:

$$R(w) = \sum w_i^2$$

Sehingga, fungsi *loss* baru dengan regularisasi L2 menjadi:

$$L = L_{\text{original}} + \lambda \sum w_i^2$$

dimana  $\lambda$  mengontrol seberapa besar regularisasi diterapkan.

Penggunaan Regularisasi L2, untuk (a) mencegah *overfitting* dalam model *deep learning*; (b) Regularisasi untuk jaringan saraf dalam seperti *CNN* dan *RNN*; dan (c) Digunakan dalam regresi logistik dan regresi linier dalam statistik.

## 3. Regularisasi *Elastic Net* (Gabungan L1 + L2)

Dalam beberapa kasus, regularisasi L1 atau L2 saja tidak cukup optimal. *Elastic Net* menggabungkan keduanya:

$$R(w) = \alpha \sum |w_i| + (1 - \alpha) \sum w_i^2$$

di mana  $\alpha$  mengontrol keseimbangan antara sparsitas L1 dan kelancaran L2.

Penggunaan Regularisasi *Elastic Net*, untuk (a) Seleksi fitur pada dataset berdimensi tinggi dengan menjaga stabilitas bobot; (b) Genomika, pemrosesan teks, dan dataset dengan fitur yang berkorelasi.

Teknik Regularisasi	BK*	Kasus Penggunaan Terbaik	Efektivitas dalam Mencegah <i>Overfitting</i> **
<i>Dropout</i>	S	Jaringan dalam, <i>CNN, NLP</i>	K: Mencegah ko-adaptasi neuron, meningkatkan generalisasi
<i>Batch Normalization</i>	S	Jaringan dalam, <i>CNN, Transformers</i>	S: Menstabilkan pelatihan, mempercepat konvergensi
<i>Early Stopping</i>	R	Optimasi pelatihan umum	S: Menghentikan pelatihan sebelum <i>overfitting</i> terjadi
<i>Data Augmentation</i>	S	Pemrosesan gambar, <i>NLP</i> , tugas visi	K: Menambah variasi dataset, meningkatkan generalisasi
<i>Label Smoothing</i>	R	Tugas klasifikasi, model probabilistik	S: Mencegah prediksi terlalu percaya diri, meningkatkan ketahanan
<i>Stochastic Depth</i>	S	Jaringan residual dalam ( <i>ResNets</i> )	S: Mendorong jalur redundan, menstabilkan pelatihan

\* **Biaya Komputasi:** (R)endah, (S)edang, (T)inggi

\*\***Efektivitas dalam Mencegah *Overfitting*** (S)edang, (K)uat, (S)angat (K)uat

Sumber: Diolah Penulis.

Tabel 13.1 membandingkan beberapa teknik regularisasi berdasarkan tiga faktor utama (a) Biaya komputasi: seberapa besar tambahan perhitungan yang diperlukan oleh teknik tersebut; (b) Kasus penggunaan terbaik: Jenis tugas di mana teknik ini paling efektif; dan (c) Efektivitas dalam mencegah *overfitting*: seberapa baik teknik ini membantu mengurangi *overfitting*.

## Rekomendasi Teknik Regularisasi

Pemilihan teknik regularisasi bergantung pada beberapa faktor, termasuk arsitektur model, ukuran *dataset*, keterbatasan komputasi, dan kebutuhan tugas. Berikut aspek pertimbangan lain.

### 1. Biaya/*Cost* Komputasi vs. Efektivitas

- a. Metode dengan biaya rendah seperti *L1/L2 Regularization* dan *Early Stopping* mudah diterapkan dan efektif untuk sebagian besar tugas.
- b. Metode dengan biaya sedang seperti *Dropout*, *Batch Normalization*, dan *Data Augmentation* membutuhkan lebih

banyak komputasi tetapi dapat meningkatkan performa model secara signifikan.

- c. Metode dengan biaya tinggi seperti *Adversarial Training* memerlukan sumber daya komputasi yang besar tetapi menawarkan ketahanan yang sangat baik terhadap serangan adversarial.

## 2. Kombinasi Teknik Regularisasi

Tidak ada satu teknik regularisasi yang sempurna. Pendekatan terbaik adalah mengkombinasikan beberapa teknik untuk mendapatkan kinerja optimal. Kombinasi yang umum Digunakan:

- a. *Dropout + Batch Normalization*: menyeimbangkan regularisasi dan stabilitas pelatihan.
- b. *L2 Regularization + Early Stopping*: mengurangi overfitting sambil mengoptimalkan waktu pelatihan.
- c. *Data Augmentation + Cutout/Mixup*: meningkatkan keragaman dataset sekaligus memaksa ketahanan model.
- d. *Adversarial Training + Stochastic Depth*: memperkuat ketahanan dalam model *deep learning*.

Regularisasi adalah salah satu aspek utama dalam *deep learning*. Seiring bertambahnya kompleksitas model, para peneliti akan terus mengembangkan teknik regularisasi baru yang menyeimbangkan efisiensi pelatihan, ketahanan, dan generalisasi, sehingga teknik regularisasi akan terus berkembang.

\*\*\*\*\*

## Daftar Pustaka

- Bishop, C. M. (2006). *Pattern Recognition And Machine Learning*. Springer.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2012). *Improving Neural Networks By Preventing Co-Adaptation Of Feature Detectors*. arXiv preprint arXiv:1207.0580.
- IBM. (n.d.). *Regularization*. IBM Think. <https://www.ibm.com/think/topics/regularization>.
- Ioffe, S., & Szegedy, C. (2015). Batch Normalization: Accelerating Deep Network Training By Reducing Internal Covariate Shift. *Proceedings Of The 32nd International Conference on Machine Learning (ICML)*, 448-456.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification With Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems (NeurIPS)*, 25, 1097-1105.
- Ng, A. Y. (2004). Feature Selection, L1 Vs. L2 Regularization, And Rotational Invariance. *Proceedings of the 21st International Conference on Machine Learning (ICML)*, 78.
- Sid321axn. (n.d.). *Regularization techniques in deep learning*. Kaggle. <https://www.kaggle.com/code/sid321axn/regularization-techniques-in-deep-learning>.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016). Rethinking The Inception Architecture For Computer Vision. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818-2826.
- Zhang, H., Cisse, M., Dauphin, Y. N., & Lopez-Paz, D. (2018). Mixup: Beyond Empirical Risk Minimization. *International Conference on Learning Representations (ICLR)*.
- Zoph, B., & Le, Q. V. (2017). *Neural Architecture Search With Reinforcement Learning*. arXiv preprint arXiv:1611.01578.


## PROFIL PENULIS



### **Kodrat Mahatma, S.T., M.Kom.**

Penulis saat ini bergabung sebagai dosen ilmu komputer di Universitas Teknologi *Digital*. Penulis adalah alumni Program Magister Teknik Informasi, Fakultas Ilmu Komputer Universitas Indonesia. Berpengalaman sebagai praktisi dan konsultan *IT* dengan berbagai peran, baik untuk sektor publik maupun sektor swasta. Dalam lima belas tahun terakhir aktif dalam bidang Sistem Informasi dan Komunikasi untuk Pembangunan, *ICT4D (Information and Communications Technologies for Development)*, membantu berbagai program pemerintah mengelola data dalam bidang kemiskinan, pertanian, bantuan sosial dan rujukan layanan, disabilitas, kebencanaan, dan kesehatan, khususnya terkait *stunting*. Sebagai pengajar dan periset, penulis meminati dan mendalami bidang pemantauan dan evaluasi, metodologi *Agile* dan *Scrum*, manajemen data, *sains data*, dan pembelajaran mesin. Pengalaman mengajar di berbagai pelatihan dan perguruan tinggi dalam bidang *ERP*, Sistem Informasi SDM, Sistem Informasi Akuntansi, Manajemen Data, Manajemen Proyek, *Agile/Scrum*, *CMMI*, dan *sains data*.

Email Penulis: [kodrat.mahatma@gmail.com](mailto:kodrat.mahatma@gmail.com).




# **BAB 14**

## ***DEEP REINFORCEMENT- LEARNING***

---

**Imam Yuniarto, S.Kom., M.M., M.Kom.**  
Institut Bisnis Muhammadiyah Bekasi



## Sejarah *Reinforcement Learning*

Sejarah pembelajaran penguatan (*reinforcement learning*) memiliki dua jalur utama yang masing-masing panjang dan kaya, yang awalnya berkembang secara terpisah sebelum bersatu dalam bidang modern pembelajaran penguatan. Jalur pertama berkaitan dengan pembelajaran melalui coba-coba, yang dimulai dari psikologi pembelajaran hewan.

Jalur ini melalui beberapa karya awal dalam kecerdasan buatan dan mengarah pada kebangkitan pembelajaran penguatan pada awal 1980-an. Jalur kedua berkaitan dengan masalah pengendalian optimal (*optimal control*) dan penyelesaiannya menggunakan fungsi nilai dan pemrograman dinamis. Sebagian besar, jalur ini tidak melibatkan pembelajaran.

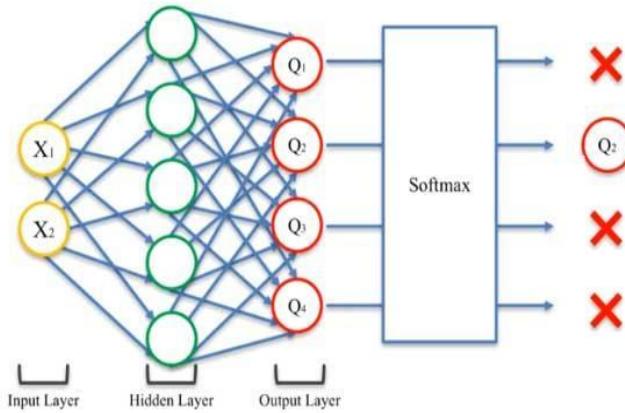
Meskipun kedua jalur ini sebagian besar berkembang secara independen, ada pengecualian yang melibatkan jalur ketiga, yang lebih samar, berkaitan dengan metode perbedaan temporal (*temporal-difference*) seperti yang digunakan dalam contoh *tic-tac-toe* di bab ini. Ketiga jalur ini bersatu pada akhir 1980-an untuk membentuk bidang modern pembelajaran penguatan sebagaimana disajikan dalam buku ini.

Jalur yang berfokus pada pembelajaran coba-coba adalah yang paling akrab bagi kita dan yang paling banyak dibahas dalam sejarah singkat ini. Namun, sebelum membahasnya, kita akan membahas secara singkat jalur pengendalian optimal.

Istilah "pengendalian optimal" mulai digunakan pada akhir 1950-an untuk menggambarkan masalah merancang pengendali guna meminimalkan ukuran perilaku sistem dinamis dari waktu ke waktu. Salah satu pendekatan untuk masalah ini dikembangkan pada pertengahan 1950-an oleh Richard Bellman dan lainnya, yang memperluas teori abad ke-19 dari Hamilton dan Jacobi. Pendekatan ini menggunakan konsep keadaan sistem dinamis dan fungsi nilai, atau "fungsi pengembalian optimal," untuk mendefinisikan persamaan fungsional, yang sekarang sering disebut persamaan Bellman.

Kelas metode untuk menyelesaikan masalah pengendalian optimal dengan memecahkan persamaan ini dikenal sebagai pemrograman dinamis (Bellman, 1957a). Bellman (1957b) juga

range 0-1, jadi ada kemungkinan *action* yang diambil walaupun probabilitasnya kecil.



**Gambar 14.5: Acting**  
Sumber: SkillPlus, 2025.

Perhatian, jumlah parameter input dan *output* yang digunakan di atas adalah contoh, menyesuaikan dengan *environment* yang sederhana. Jumlah *parameter input* menyesuaikan dengan *environment*. *Experience replay: experience replay* bermanfaat agar *neural network* dapat mengambil *action* berdasarkan *experience* yang pernah dilakukan.

Penggunaan *experience replay*, selain mempercepat proses *learning*, dapat mencegah bias (hal ini bisa terjadi jika pada kondisi *state* cenderung monoton). *Experience replay* akan memiliki *table data* dari terpisah yang berisi *state, action, state+1, reward*. Data ini akan digunakan secara acak oleh *agent* untuk menentukan *action* berikutnya.

\*\*\*\*\*

## Daftar Pustaka

- Adnan, Risman. (2022). *Introduction to Reinforcement Learning*.
- Ammar, Haitham Bou, Eric Eaton, Eaton Cis, Upenn Edu, Paul Ruvolo, Olin College, Paul Ruvolo, Olin Edu, Matthew E. Taylor, Taylorm Eecs, and W. S. U. Edu. n.d. *Online Multi-Task Learning for Policy Gradient Methods*.
- SkillPlus. (2025). *Teori: Pengenalan Deep Q-Learning*. Retrieved (<https://skillplus.web.id/teori-pengenalan-deep-q-learning/>).
- Sutton, Richard S. .., and Andrew G. .. Barto. (2020). *Reinforcement Learning: An Introduction*. The MIT Press.
- Suyanto, Kurniawan Nur Ramadhani, and Satria Mandala. (2019). *Deep Learning: Modernisasi Machine Learning Untuk Big Data*. Vol. 1. 1st ed. Bandung: Informatika.


## PROFIL PENULIS



### **Imam Yuniyanto, S.Kom., M.M., M.Kom.**

Ketertarikan penulis dengan Dunia IT dimulai dari penulis yang baru pertama kali bekerja di PT. Showa Indonesia Manufacturing sebagai *Staff Industrial Relation*. Penulis yang waktu itu masih baru tamat dari STM Negeri 5 Budi Utomo-Jakarta Pusat mengurungkan niat melanjutkan kuliah di Jurusan Teknik Sipil dan beralih ke Jurusan S1 Manajemen Informatika. Selesai menamatkan Sarjana Komputer di STMIK Jayakarta, penulis sempat melanjutkan kuliah di Magister Manajemen Universitas Muhammadiyah Prof. DR. HAMKA dan Magister Ilmu Komputer di Universitas Budi Luhur-Jakarta. Penulis memiliki kepakaran di bidang Algoritma dan *Artificial Intelligence*. Saat ini Penulis sedang menjalani Studi S3 Ilmu Komputer dengan Konsentrasi *Computational Intelligence* dan *Optimization (CIO)* di IPB University. Disertasinya menggunakan Algoritma *Reinforcement Learning* dalam memecahkan masalah dalam Operasi Penangkapan Ikan. Selain menjadi Mahasiswa dan Dosen Teknik Informatika di Institut Bisnis Muhammadiyah Bekasi, Penulis juga aktif sebagai Ketua Asosiasi Penulis dan Peneliti Indonesia (APPEPINDO) DKI Jakarta, Aktivis Komunitas Muda Telematika Indonesia (KOMTI) dan *Chief of Editor* di Jurnal KOMTI serta *Reviewer* di berbagai Jurnal terakreditasi Sinta.

Email Penulis: [imamyuniyanto@gmail.com](mailto:imamyuniyanto@gmail.com).



**BAB 15**  
**PELATIHAN MODEL**  
***DEEP LEARNING* PADA**  
**DATA SKALA BESAR**

---


Oleh Soleh, S.Kom., M.MSI.  
Universitas Raharja



4.100.000 teks yang didasarkan pada wilayah yang menunjukkan peningkatan dalam kecepatan dan akurasi.

### Bagaimana *Deep Learning* Menangani *Dataset* Besar

*Deep Learning* diisi dengan *dataset* yang besar berisi berbagai contoh, yang darinya model mempelajari fitur-fitur yang harus dicari dan menghasilkan *output* dengan vektor probabilitas yang tersedia. Model tersebut "belajar" untuk dirinya sendiri sebagaimana kita mempelajari angka-angka numerik saat masih anak-anak (Ida, 2018).



**Gambar 15.1: Matlab Tutorial Dalam Pengenalan *Deep Learning***

Sumber: Diolah Penulis.

Bila melihat kebelakang terlebih dahulu terkait dengan Metode multi-layer perceptron dan backpropagation dirancang secara teoritis pada tahun 1980-an, tetapi karena kurangnya jumlah data yang besar dan kemampuan pemrosesan yang tinggi, inspirasi tersebut memudar. Sejak munculnya big data dan *GPU Nvidia* yang sangat canggih, potensi pembelajaran mendalam sedang dicoba dan diuji seperti yang belum pernah terjadi sebelumnya.

Sekarang banyak perdebatan telah terjadi tentang seberapa besar *dataset* yang dibutuhkan. Meskipun beberapa orang mengklaim bahwa *dataset* yang lebih kecil namun beragam akan berhasil, semakin banyak parameter yang diinginkan agar dipelajari model atau semakin kompleks masalah yang dihadapi, semakin banyak pula data yang diperlukan untuk pelatihan. (Ida, 2018)

Berikut beberapa cara algoritma *deep learning* untuk dapat melakukan pelatihan dengan *dataset* yang besar (Mathwork, 2024):

7. **Pengoptimal:** algoritma pengoptimalan yang berbeda, seperti *Adam*, *SGD*, atau *RMSprop*, dapat mempengaruhi kecepatan dan efisiensi pelatihan model.
8. **Ukuran *Batch*:** jumlah sampel yang diproses dalam setiap iterasi pelatihan (*batch*) dapat mempengaruhi proses pelatihan dan konvergensi.

### **Ikhtisar Pelatihan Model *Deep Learning***

Proses pelatihan model *deep learning* sangat penting dalam memungkinkan mesin untuk belajar dan membuat keputusan seperti otak manusia. Melalui pengumpulan data dan praproses yang tepat, akan memastikan kemampuan model untuk menggeneralisasi dan bekerja dengan baik pada data baru.

Teknik pengoptimalan seperti pengoptimal tertentu (yang sudah dilakukan pengujian dan validasi) memainkan peran penting dalam menyempurnakan parameter model untuk akurasi yang lebih baik dan konvergensi yang lebih cepat.

Masa depan *deep learning* sangat menjanjikan. Dengan penelitian dan kemajuan yang berkelanjutan, dapat mengharapkan terobosan yang lebih signifikan di berbagai bidang seperti pengenalan gambar, pemrosesan bahasa alami, dan diagnosis medis. Seiring dengan terus berkembangnya daya komputasi dan ketersediaan data, model pembelajaran mendalam akan menjadi lebih canggih dan membuka jalan bagi aplikasi baru serta membantu memecahkan masalah kompleks dengan cara yang tidak dapat dibayangkan sebelumnya.

Pelatihan model *deep learning* pada *dataset* besar merupakan proses *multifaset* yang memanfaatkan kombinasi teknik canggih dan teknologi canggih untuk menangani kompleksitas dan volume data. Metode yang digunakan meliputi pelatihan *batch*, paralelisme data dan jalur, algoritma pengoptimalan canggih, teknik regularisasi, kecepatan pembelajaran adaptif, penambahan data, penyyetelan hiperparameter otomatis, kerangka kerja yang dapat diskalakan, checkpointing, penghentian awal, dan pembelajaran transfer.

Masing-masing metode ini memainkan peran penting dalam memastikan pelatihan yang efisien, efektif, dan dapat diskalakan, yang

pada akhirnya mengarah pada model yang dapat digeneralisasi dengan baik ke data baru dan berkinerja kuat dalam aplikasi dunia nyata. Dengan merencanakan dan menerapkan metode ini secara cermat, praktisi dapat memanfaatkan potensi penuh pembelajaran mendalam untuk menangani tugas-tugas yang menantang di berbagai domain.

\*\*\*\*\*

## Daftar Pustaka

- Agniva Maiti, Ue Kiao. (2025). *Training Process Of Deep Learning Models, OpenGenius IQ: Lear Algorithms, DL, System Design*.
- Alec Radford, Karthik Narasimhan, Tim Salimans, Ilya Sutskever, et al. (2018). *Improving language Understanding By Generative Pre-Training*.
- Damanpreet Kaur Vohra. (2024). *What You Need to Know About Large AI Model Training, Hyperstack.cloud*.
- Geek. (2024). *Impact of Dataset Size on Deep Learning Model, Sanchhaya Education Private Limited*.
- Ibomoie Domor Mienye, Theo G. Swart.
- Ida Jessie Sagina. (2018). *Why Go Large With Data For Deep Learning? Towards Data Science*.
- Jared Kaplan, Sam McCandlish, Tom Henighan, Tom B Brown, Benjamin Chess, Rewon Child, Scott Gray, Alec Radford, Jeffrey Wu, and Dario Amodei. (2020). *Scaling Laws For Neural Language Models. arXiv preprint arXiv:2001.08361*.
- Jason Brownlee. (2020). *Impact of Dataset Size on Deep Learning Model Skill And Performance Estimates, Deep Learning Performance, Machine Learning Mastery is part of Guiding Tech Media*.
- Kavindu Rathansiri. (2025). *What Impact Does Dataset Size Have On Your Machine Learning Predictions?, Data Science and AI Community Consultant*.
- Lilian Weng, Greg Brockman. (2022). *Techniques For Training Large Neural Networks, OpenAI*.
- Mathwork. (2024). *Deep Learning With Big Data, Deep Learning Trust Center*.
- Mostafa Dehghani, Josip Djolonga, Basil Mustafa, Piotr Padlewski, Jonathan Heek, Justin Gilmer, Andreas Steiner, Mathilde Caron, Robert Geirhos, Ibrahim Alabdulmohsin, et al. (2023). *Scaling Vision Transformers To 22 Billion Parameters. arXiv preprint arXiv:2302.05442*,
- Shaden Smith, Mostofa Patwary, Brandon Norick, Patrick LeGresley, Samyam Rajbhandari, Jared Casper, Zhun Liu, Shrimai Prabhunoye, George Zerveas, Vijay Korthikanti, et al. (2022). *Using*

*Deepspeed And Megatron To Train Megatron-Turing Nlg 530b, A Large-Scale Generative Language Model.* arXiv preprint arXiv:2201.11990.

Tom Brown, Benjamin Mann, Nick Ryder, Melanie Subbiah, Jared D Kaplan, Prafulla Dhariwal, Arvind Neelakantan, Pranav Shyam, Girish Sastry, Amanda Askell, et al. (2020). *Language Models Are Few-Shot Learners. Advances In Neural Information Processing Systems*, 33:1877–1901.

Tony Wan. (2024). *AI Supercluster: Advanced Parallelism And Memory Optimization, Supercluster.*

Wael Rahhal. (2025). *What Impact Does Dataset Size Have On Your Machine Learning Predictions?*, Data Science and AI Community Consultant.

## PROFIL PENULIS



### Oleh Soleh, S.Kom., M.MSI.

Ketertarikan penulis terhadap ilmu komputer dimulai pada tahun 1996 silam. Hal tersebut membuat penulis memilih untuk masuk ke Universitas Gunadarma dengan memilih Jurusan Manajemen Informatika (MI) pada Fakultas Ilmu Komputer dan berhasil menyelesaikan program studi S1 dengan kelulusan pada tahun 2000. Penulis kemudian melanjutkan pendidikan ke jenjang master yang masih di kampus yang sama pada tahun 2004 berhasil menyelesaikan studi S2 di prodi Ilmu Komputer dengan Jurusan Manajemen Informasi Bisnis. Mulai tahun 2022 sampai saat ini sedang menempuh pendidikan doktoral di Universitas Kristen Satya Wacana Salatiga melalui prodi Ilmu Komputer dengan konsentrasi *Deep Learning & Computer Vision*. Penulis memiliki kepakaran di bidang *Business Intelligence, Data Mining, Manajemen Informasi* serta *Deep Learning*. Dan untuk mewujudkan karir sebagai dosen profesional, penulis pun aktif sebagai peneliti di bidang kepakarannya tersebut. Beberapa penelitian yang telah dilakukan didanai oleh internal perguruan tinggi.


Email Penulis: [oleh.soleh@raharja.info](mailto:oleh.soleh@raharja.info).



**BAB 16**  
***APLIKASI DEEP***  
***LEARNING* DALAM**  
**BIDANG MEDIS**

---

**Ir. Muh. Nurtanzis Sutoyo, S.Kom., M.Cs., IPP.**  
Universitas Sembilanbelas November Kolaka



(*Health Insurance Portability and Accountability Act*) di Amerika Serikat atau aturan perlindungan data lainnya di berbagai negara. Pengumpulan, penyimpanan, dan pemrosesan data medis memerlukan kepatuhan ketat terhadap regulasi tersebut untuk mencegah penyalahgunaan data.

*Dataset* yang tidak mencerminkan keragaman populasi pasien dapat menyebabkan hasil model yang kurang akurat atau bahkan diskriminatif, sehingga membatasi kegunaan model di dunia nyata (Arora *et al.*, 2023). Meskipun demikian, kesulitan tersebut juga mendorong penciptaan solusi kreatif yang membuka peluang baru. *Federated learning* adalah metode belajar yang menjanjikan di mana model dilatih secara terdistribusi tanpa perlu memindahkan data awal, menjaga privasi pasien.

Mengatasi bias data juga memerlukan pengembangan model global yang dapat disesuaikan dengan kebutuhan lokal. Selain itu, kerja sama lintas disiplin antara dokter, insinyur data, dan peneliti hukum sangat penting untuk integrasi teknologi ini dengan sistem kesehatan. Dalam bidang medis, adopsi *deep learning* dapat dipercepat, memberikan manfaat nyata bagi pasien di seluruh dunia. Ini dapat dicapai melalui pemanfaatan teknologi dan kerja sama yang tepat.

### **Alur Kerja *Deep Learning* Dalam Analisis Data Medis**

*Deep Learning (DL)* adalah cabang dari pembelajaran mesin yang memanfaatkan jaringan saraf tiruan berlapis (*multi-layer neural networks*) untuk memproses data yang kompleks. Prinsip kerja DL berfokus pada proses hierarkis, di mana data diproses melalui beberapa lapisan, dengan setiap lapisan bertanggung jawab untuk mengekstraksi fitur-fitur yang lebih abstrak.

Lapisan awal menangkap fitur sederhana, seperti tepi atau pola dalam citra, sementara lapisan berikutnya menyusun informasi ini menjadi representasi yang lebih kompleks, seperti bentuk atau struktur spesifik (Tegar Prabowo and Hadikurniawati, 2023). Jaringan *DL* terdiri dari tiga jenis lapisan utama: lapisan *input*, lapisan tersembunyi (*hidden layers*), dan lapisan *output*. Lapisan tersembunyi dapat terdiri dari puluhan hingga ratusan lapisan tergantung pada kompleksitas data dan tugas yang ingin diselesaikan.

- c. Mengatasi Keterbatasan Infrastruktur
  - 1) Adopsi teknologi *cloud computing* dapat mengurangi kebutuhan akan infrastruktur lokal yang mahal.
  - 2) Kerjasama lintas institusi untuk berbagi sumber daya komputasi dan data juga dapat membantu mengatasi keterbatasan ini.
- d. Kolaborasi Lintas Disiplin
  - 1) Melibatkan dokter, ilmuwan data, ahli hukum, dan insinyur teknologi dalam proses pengembangan *Deep Learning* dapat memastikan pendekatan yang holistik.
  - 2) Investasi dalam pelatihan tenaga kesehatan dan pengembangan keterampilan teknis mereka akan mendukung adopsi teknologi secara lebih luas.

## Kesimpulan

Kesimpulan dari penerapan *deep learning* dalam bidang medis menunjukkan potensi yang luar biasa untuk mengubah cara data medis dilihat dan digunakan dalam pengambilan keputusan klinis. Teknologi ini mempercepat diagnosis, efisiensi operasional, dan pengembangan solusi perawatan yang dipersonalisasi.

*Deep learning* telah memungkinkan deteksi penyakit dini, prediksi hasil pengobatan, dan otomatisasi berbagai proses medis karena kemampuan untuk memproses data kompleks seperti gambar medis, sinyal fisiologis, dan rekam medis elektronik. Namun, penerapan *deep learning* di bidang medis menghadapi beberapa masalah. Ini termasuk masalah dengan privasi data pasien, bias dalam data pelatihan, dan keterbatasan infrastruktur komputasi.

Untuk mengatasi masalah ini, solusi yang inovatif dan bekerja sama diperlukan, seperti pembelajaran federasi untuk melindungi privasi data, pengumpulan dataset yang lebih representatif, dan pemanfaatan *cloud computing* untuk mengatasi keterbatasan sumber daya teknologi. Untuk memastikan bahwa teknologi ini dapat dimasukkan secara efektif ke dalam sistem layanan kesehatan, tenaga medis, peneliti, dan insinyur teknologi harus bekerja sama dengan baik di antara mereka dari berbagai disiplin ilmu.

*Deep learning* memiliki potensi besar untuk meningkatkan kualitas layanan kesehatan di seluruh dunia melalui pengembangan teknologi yang berkelanjutan dan pendekatan moral. Teknologi ini dapat sangat membantu pasien, tenaga kesehatan, dan sistem layanan kesehatan secara keseluruhan dengan memastikan bahwa masalah utama dapat diatasi melalui inovasi dan kebijakan yang tepat. Masa depan kesehatan yang didukung *AI* semakin dekat, menjanjikan peningkatan kualitas hidup manusia.

\*\*\*\*\*

## Daftar Pustaka

- Aggarwal, R. *et al.* (2021). Diagnostic Accuracy Of Deep Learning In Medical Imaging: A Systematic Review And Meta-Analysis, *npj Digital Medicine*, 4(1), pp. 1–23. doi: 10.1038/s41746-021-00438-z.
- Arora, A. *et al.* (2023). The Value Of Standards For Health Datasets In Artificial Intelligence-Based Applications, *Nature Medicine*, 29(11), pp. 2929–2938. doi: 10.1038/s41591-023-02608-w.
- Dankwa-Mullan, I. and Weeraratne, D. (2022). Artificial Intelligence and Machine Learning Technologies in Cancer Care: Addressing Disparities, Bias, and Data Diversity, *Cancer Discovery*, 12(6), pp. 1423–1427. doi: 10.1158/2159-8290.CD-22-0373.
- Echle, A. *et al.* (2021). Deep learning in cancer pathology: a new generation of clinical biomarkers, *British Journal of Cancer*, 124(4), pp. 686–696. doi: 10.1038/s41416-020-01122-x.
- Guardiola, J. and Donna, R. (2021). The Patient Data Protection from the Using of Big Data During the COVID-19 Pandemic in Indonesia, *Proceedings of the 1st International Conference on Law and Human Rights 2020 (ICLHR 2020)*, 549(1), pp. 453–461. doi: 10.2991/assehr.k.210506.059.
- Krishnan, G. *et al.* (2023). Artificial intelligence in clinical medicine: catalyzing a sustainable global healthcare paradigm', *Frontiers in Artificial Intelligence*, 6, pp. 1–14. doi: 10.3389/frai.2023.1227091.
- Putra, H. and Ulfa, N. (2020). Jurnal Nasional Teknologi dan Sistem Informasi Penerapan Prediksi Produksi Padi Menggunakan Artificial Neural Network Algoritma Backpropagation, *Nasional Teknologi dan Sistem Informasi*, 06(02), pp. 100–107.
- Tegar Prabowo, S. and Hadikurniawati, W. (2023). Deteksi Dan Pengenalan Jenis Beras Menggunakan Metode Convolutional Neural Network, *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(1), pp. 163–167. doi: 10.36040/jati.v7i1.6150.
- Van Teijlingen, A. *et al.* (2020). Artificial Intelligence and Health in Nepal, *Nepal Journal of Epidemiology*, 10(3), pp. 915–918. doi: 10.3126/nje.v10i3.31649.

## PROFIL PENULIS



**Ir. Muh. Nurtanzis Sutoyo, S.Kom., M.Cs., IPP.**

Lahir di Jember Jawa Timur 1984, adalah seorang profesional dan akademisi di bidang teknologi informasi. Menyelesaikan pendidikan dasar di SD Negeri 3 Wolulu (1990-1996), kemudian melanjutkan ke MTs Baitul Arqam Polinggona (1996-1999) dan Madrasah Aliyah Negeri Kolaka (1999-2002). Gelar sarjana Sistem Komputer diraihinya dari STIMIK Bina Bangsa Kendari (2002-2008), sedangkan gelar magister Ilmu Komputer diperoleh dari Universitas Gadjah Mada Yogyakarta (2013-2015). Pada 2021-2022, ia menyelesaikan Program Profesi Insinyur di Universitas Hasanuddin Makassar.

Email Penulis: [mns.usn21@gmail.com](mailto:mns.usn21@gmail.com).



**BAB 17**  
***APLIKASI DEEP***  
***LEARNING DALAM***  
**BIDANG FINANSIAL**

---

**Bambang Siswoyo, S.T., M.Si., M.Kom., Ph.D.**  
Universitas Komputer Indonesia



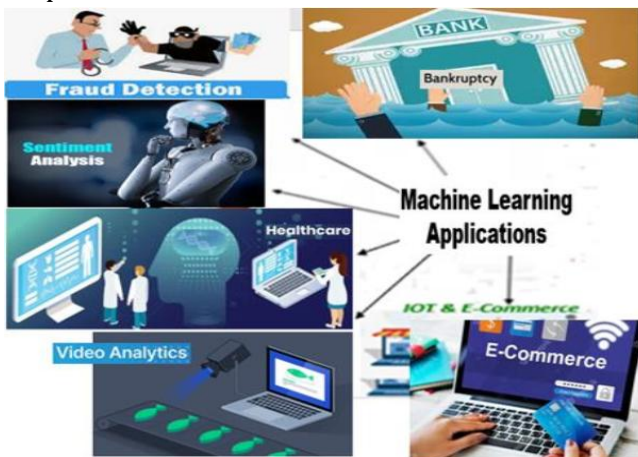
### 3. Perbandingan *Machine Learning* dan *Deep Learning*

**Tabel 17.1: *Machine Learning* dan *Deep Learning***

Aspek	<i>Machine Learning</i>	<i>Deep Learning</i>
Ketertgantungan pada Fitur	Memerlukan kstraksi fitur manual	Memerlukan ekstraksi fitur manual
Kebutuhan Data	Bisa bekerja dengan dataset kecil	Bisa bekerja dengan dataset kecil
Kompleksitas Model	Algoritma lebih sederhana	Algoritma lebih omplek dengan banyak parameter
Waktu Pelatihan	Lebih cepat	Lebih lama, terutama tanpa GPU
Aplikasi	Analisis bisnis, klasifikasi sederhana	<i>Computer vision, NLP, autonomous systems</i>

Sumber: Diolah Penulis.

Berbagai aplikasi dari *Machine Learning* dalam kehidupan nyata ditunjukkan pada Gambar 17.1:



**Gambar 17.1: *Machine Learning***

Sumber: Bambang Siswoyo, 2023.

## 2. *Preprocessing Data*

- a. Pembersihan Data: tangani data yang hilang (*missing values*), *data outlier*, data yang tidak relevan, nois data, data tidak seimbang, data tidak normal, transformasi data.
- b. Normalisasi atau Standardisasi: skala fitur numerik agar nilai data seimbang (contohnya menggunakan *min-max scaling* atau *z-score*).
- c. *Feature Selection*: pilih fitur-fitur penting yang memiliki pengaruh signifikan terhadap prediksi kebangkrutan.
- d. Pemisahan Data: pisahkan data menjadi set pelatihan, validasi, dan pengujian (misalnya 70%:15%:15%).

## 3. *Pembangunan Model Deep Learning*

- a. Pilih jenis model jaringan saraf tiruan (*ANN*, *LSTM*, atau *CNN* tergantung kebutuhan):
  - 1) *ANN (Artificial Neural Network)*: untuk data tabular umum.
  - 2) *LSTM (Long Short-Term Memory)*: jika data memiliki komponen waktu, misalnya data keuangan bulanan.
- b. Tentukan arsitektur model:
  - 1) *Input Layer*: jumlah neuron sesuai dengan jumlah fitur input.
  - 2) *Hidden Layers*: tambahkan satu atau lebih lapisan tersembunyi dengan jumlah neuron yang sesuai.
  - 3) *Output Layer*: gunakan satu neuron dengan fungsi aktivasi sigmoid (untuk klasifikasi biner).
- c. Tentukan fungsi aktivasi (*ReLU* di *hidden layer*, *sigmoid* atau *softmax* di *output layer*).

## 4. *Pelatihan Model*

- a. Tentukan parameter pelatihan:
  - 1) *Learning Rate*.
  - 2) *Batch size*.
  - 3) Jumlah *epoch*.
- b. Gunakan algoritma optimasi (misalnya *Adam*, *SGD*) untuk memperbarui bobot.
- c. Lakukan propagasi maju (*forward propagation*) dan propagasi balik (*backpropagation*) selama pelatihan untuk meminimalkan *error*.

## 5. Evaluasi Model

- a. Uji model pada data validasi dan pengujian untuk mengukur performa.
- b. Gunakan metrik evaluasi:
  - 1) Akurasi: persentase prediksi benar.
  - 2) *Precision, Recall, F1-Score*: untuk mengevaluasi model dalam kasus data tidak seimbang (kebangkrutan jarang terjadi).
  - 3) *AUC-ROC Curve*: untuk mengukur kemampuan model dalam membedakan antara kelas positif dan negatif.

## 6. Optimasi Model

- a. Lakukan *tuning* pada *hyperparameter* (jumlah neuron, jumlah *hidden layer*, *learning rate*, dll.).
- b. Gunakan teknik seperti *Dropout* atau *Batch Normalization* untuk mencegah *overfitting*.
- c. Jika diperlukan, gunakan *cross-validation* untuk memastikan generalisasi model.

## 7. Deployment

- a. Setelah model memiliki performa yang memadai, simpan model untuk digunakan dalam lingkungan produksi.
- b. Integrasikan model dengan aplikasi atau sistem yang dapat digunakan oleh bank untuk memprediksi kebangkrutan secara *real-time*.

## 8. Monitoring dan Maintenance

- a. Pantau performa model setelah di-*deploy* untuk memastikan model tetap relevan.
- b. Lakukan *retraining* secara berkala jika terdapat data baru untuk meningkatkan akurasi prediksi.

\*\*\*\*\*

## Daftar Pustaka

- Altman, E. I., et al. (2017). Financial Distress Prediction In An International Context: A Review And Empirical Analysis of Altman's Z-score model. *Journal of International Financial Management & Accounting*, 28(2), 131171. <https://doi.org/10.1111/jifm.12053>.
- Bambang Siswoyo, at.al (2023) Optimization of Multi-Layer Perceptron in Ensemble Using Random Search for Bankruptcy Prediction. *Journal of Computer Science 2023*, 19 (2): 251.260. DOI: 10.3844/jcssp.2023.251.260.
- Barboza, F., et al. (2017). Machine Learning Models And Bankruptcy Prediction. *Expert Systems With Applications*, 83, 405-417. <https://doi.org/10.1016/j.eswa.2017.04.006>.
- Faris, H., et al.(2020). Improving Financial Bankruptcy Prediction In A Highly Imbalanced Class Distribution Using Oversampling And Ensemble Learning: A Case From The Spanish Market. *Progress in Artificial Intelligence*, 9(1), 31-53. <https://doi.org/10.007/s13748-019-00197-9>.
- Jian Huang et al (2020). Deep Learning In Finance And Banking: A Iterature Review And Classification, *Huang et al. Frontiers of Business Research in China (2020)* 14:13 <https://doi.org/10.1186/s11782-020-00082-6>.
- Pisula, T. et al. (2020). An Ensemble Classifier-Based Scoring Model For Predicting Bankruptcy Of Polish Companies In The Podkarpackie Voivodeship. *Journal of Risk and Financial Management*, 13(2), 37. <https://doi.org/10.3390/jrfm13020037>.
- Safi, S. A. D., et al. (2021). CostSensitive Metaheuristic Optimization-Based Neural Network with Ensemble Learning for Financial Distress Prediction. *Applied Sciences*, 12(14), 6918. <https://doi.org/10.3390/app12146918>.
- Siswoyo, B., et al.. (2022). Ensemble Machine Learning Algorithm Optimization of Bankruptcy Prediction of Bank. *Int J Artif Intell*, 11(2), 679-686. <https://doi.org/10.11591/ijai.v11.i2.pp679-686>.
- Siswoyo, B., et al. (2020) Machine Learning Approach As An Alternative Tool To Build A Bankruptcy Prediction Model In Banking Industry. *In IOP Conference Series: Materials Science and*

*Engineering* (Vol.830, No. 2, pp: 022083). IOP Publishing.  
<https://doi.org/10.1088/1757-899X/830/2/022083>.

Zhen, Yang, et al (2020). An Introductory Review of Deep Learning for Prediction Models With Big Data. *Frontiers in Artificial Intelligence* 3, 2020, [www.frontiersin.org/articles/10.3389/frai.2020.00004/full](http://www.frontiersin.org/articles/10.3389/frai.2020.00004/full).

## PROFIL PENULIS



### **Bambang Siswoyo, S.T., M.Si., M.Kom., Ph.D.**

Ketertarikan penulis terhadap ilmu komputer dimulai pada tahun 1989 silam. Hal tersebut membuat penulis memilih untuk melanjutkan pendidikan ke Perguruan Tinggi dan berhasil menyelesaikan studi S1 di prodi Teknik Informatika Sekolah Tinggi Sains dan Teknologi Indonesia. Kemudian, penulis menyelesaikan studi S2 di prodi Ilmu Ekonomi Program Pasca Sarjana Universitas Padjadjaran dan S3 di Fakultas Teknologi Informasi Universitas Teknik Melaka Malaysia. Penulis memiliki kepakaran di bidang *Machine Learning* dan *Data Science*. Dan untuk mewujudkan karir sebagai dosen profesional, penulis pun aktif sebagai peneliti di bidang kepakarannya tersebut. Beberapa penelitian yang telah dilakukan didanai oleh internal perguruan tinggi sudah dipublikasikan di jurnal internasional *Scopus* dan jurnal Nasional Sinta. Selain peneliti, penulis juga aktif menulis buku dengan harapan dapat memberikan kontribusi positif bagi bangsa dan negara yang sangat tercinta ini. Atas dedikasi dan kerja keras dalam menulis buku.

Email Penulis: [Bambang.siswoyo@email.unikom.ac.id](mailto:Bambang.siswoyo@email.unikom.ac.id).



**BAB 18**  
***DEEP LEARNING* UNTUK**  
**KEAMANAN SIBER**

---

**Aliyah, S.Kom., M.T.I.**  
Universitas Cendekia Abditama



## **Deep Learning Keamanan Siber**

*Deep learning* merupakan bagian dari metode *machine learning* yang berbasis jaringan saraf tiruan. Metode ini digunakan untuk menangani kumpulan data besar dengan menggunakan algoritma *backpropagation* untuk menunjukkan bagaimana mesin harus mengubah parameter internal yang digunakan untuk menghitung representasi di setiap lapisan dari representasi di lapisan sebelumnya (LeCun, Bengio, & Hinton, 2015).

*Deep learning* digunakan sebagai pendekatan pembelajaran mesin untuk memecahkan deteksi objek, klasifikasi gambar dan segmentasi *semantic* (Attia, Hossny, Nahavandi, & Yazdabadi, 2017). Sebagai pengguna sudah tidak asing dengan *malware*, *phishing*, *ransomware*, dan berbagai serangan *digital* lainnya.

Berita baiknya, Teknologi mutakhir seperti *deep learning* hadir sebagai benteng pertahanan di era *digital* ini. Ancaman siber terus berkembang dan semakin canggih. Para pelaku kejahatan siber menggunakan berbagai metode baru untuk menyerang sistem dan mencuri data.

Hal ini membuat keamanan siber menjadi semakin penting bagi individu, organisasi, dan pemerintah. Salah satu teknologi yang menjanjikan untuk meningkatkan keamanan siber adalah *deep learning*.

*Deep learning* adalah subbidang dari kecerdasan buatan (*AI*) yang memungkinkan komputer untuk belajar dari data dalam jumlah besar dan mengenali pola yang kompleks. Teknologi *deep learning* dapat digunakan untuk berbagai aplikasi keamanan siber, antara lain:

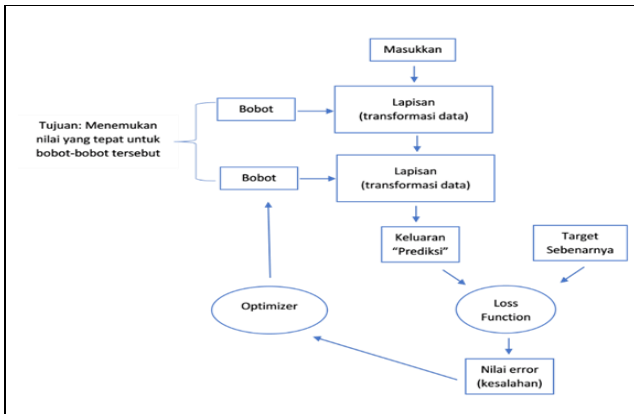
### **1. Deteksi *Malware***

Deteksi *malware* dapat dianalisis oleh *file* dan kode untuk mengidentifikasi *malware*. Hal ini dilakukan dengan melatih model *deep learning* pada kumpulan data *malware* yang diketahui dan kemudian menggunakan model tersebut untuk mengidentifikasi *file* baru yang mungkin berbahaya.

### **2. Deteksi Anomali**

*Deep learning* dapat memantau aktivitas jaringan dan sistem untuk mendeteksi aktivitas yang tidak biasa. Hal ini dapat membantu mengidentifikasi serangan siber yang sedang berlangsung atau potensi serangan di masa depan.

Cara mendasar dalam *deep learning* adalah menggunakan nilai *error* (kesalahan) sebagai sinyal umpan balik untuk menyesuaikan nilai bobot, ke arah yang akan menurunkan *error* (Gambar 18.3). Penyesuaian ini adalah tugas pengoptimal (*optimizer*), dengan menerapkan apa yang disebut algoritma *Backpropagation*: algoritma sentral dalam *deep learning*. setelah menjelaskan secara lebih rinci cara kerja *backpropagation*.



**Gambar 18.3: Loss Function Digunakan Sebagai Sinyal Umpan Balik Untuk Menyesuaikan Bobot**

Sumber: Diolah Penulis.

Pertama, bobot jaringan diberi nilai tidak beraturan, sehingga jaringan hanya menerima serangkaian transformasi nilai tidak teratur, jika keluarannya jauh dari yang seharusnya, dan nilai *error* nya sangat tinggi. Tetapi dengan setiap contoh proses jaringan, bobot disesuaikan sedikit ke arah yang benar, dan nilai *error* menurun.

Ini adalah pengulangan pelatihan (*looping*) yang diulangi dalam jumlah yang cukup banyak (biasanya puluhan iterasi lebih dari ribuan contoh), menghasilkan nilai bobot yang meminimalkan *loss function*. Jaringan dengan nilai *error* yang minimal adalah jaringan yang keluarannya sedekat mungkin dengan target dimana jaringan terlatih.

\*\*\*\*\*

## Daftar Pustaka

- Afshar, A., Massoumi, F., Afshar, A., & Mariño, M. A. (2015). State of The Art Review Of Ant Colony Optimization Applications In Water Resource Management. *Water Resources Management*, 29(11), 3891–3904.
- Akhouayri, E.-S., Agliz, D., Zonta, D., Atmani, A., & others. (2015). A Fuzzy Expert System For Automatic Seismic Signal Classification. *Expert Systems with Applications*, 42(3), 1013–1027.
- AlJadda, K., Korayem, M., Ortiz, C., Grainger, T., Miller, J. A., Rasheed, K. M., ... others. (2018). Mining Massive Hierarchical Data Using A Scalable Probabilistic Graphical Model. *Information Sciences*, 425, 62–75.
- Amato, F., López, A., Peña-Méndez, E. M., Vanhara, P., Hampl, A., & Havel, J. (2013). *Artificial Neural Networks In Medical Diagnosis*. Elsevier.
- Arp, D., Spreitzenbarth, M., Malte, H., Gascon, H., & Rieck, K. (2013). DREBIN: Effective and Explainable Detection of Android Malware in Your Pocket Daniel. *Choice Reviews Online*, 45(02), 45-0765-45-0765. <https://doi.org/10.5860/choice.45-0765>.
- Arsene, O., Dumitrache, I., & Miha, I. (2015). Expert System For Medicine Diagnosis Using Software Agents. *Expert Systems with Applications*, 42(4), 1825–1834.
- Patterson, J., & Gibson, A. (2017). Deep Learning: A Practitioner's Approach. In *O'Reilly* (1th ed.). O'Reilly Media, Inc.
- Putra, W. S. E. (2016). Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101. *Jurnal Teknik ITS*, 5(1).
- Quang, D., & Xie, X. (2016). DanQ: A Hybrid Convolutional And Recurrent Deep Neural Network For Quantifying The Function Of DNA Sequences. *Nucleic Acids Research*, 44(11), e107--e107.
- Recent Advances In Convolutional Neural Network Acceleration. *Neurocomputing*, 323, 37–51.
- Richardson, F., Reynolds, D., & Dehak, N. (2015). Deep Neural Network Approaches To Speaker And Language Recognition. *IEEE Signal Processing Letters*, 22(10), 1671–1675.

- Stewart, D. & Simmons, M. (2010). *The Business Playground: Where Creativity and Commerce Collide*. Berkeley, AS: New Riders Pres
- Walley, R. J., Smith, C. L., Gale, J. D., & Woodward, P. (2015). Advantages Of A Wholly Bayesian Approach To Assessing Efficacy In Early Drug Development: A Case Study. *Pharmaceutical Statistics*, 14(3), 205–215.
- Zen, H., & Sak, H. (2015). Unidirectional Long Short-Term Memory Recurrent Neural Network With Recurrent Output Layer For Low-Latency Speech Synthesis. *Acoustics, Speech and Signal Processing (ICASSP), 2015 IEEE International Conference On*, 4470–4474.
- Zhang, Q., Zhang, M., Chen, T., Sun, Z., Ma, Y., & Yu, B. (2019).
- Zhang, Z. (2018). Artificial Neural Network. In *Multivariate Time Series Analysis In Climate And Environmental Research* (pp. 1–35). Springer.
- Zhao, Z., & Kumar, A. (2017). Accurate Periocular Recognition Under Less Constrained Environment Using Semantics-Assisted Convolutional Neural Network. *IEEE Transactions on Information Forensics and Security*, 12(5), 1017–1030.

## PROFIL PENULIS



### **Aliyah, S.Kom., MTI.**

Ketertarikan penulis terhadap ilmu komputer dimulai pada tahun 2000 silam. Hal tersebut membuat penulis memilih untuk masuk ke Sekolah Menengah Kejuruan di SMK Pelita Utama Kabupaten Lampung selatan dengan memilih Jurusan Sekretaris dan berhasil lulus pada tahun 2003. Penulis kemudian melanjutkan pendidikan ke Perguruan Tinggi dan berhasil menyelesaikan studi S1 di prodi Sistem Informasi STMIK Insan Pembangunan dan berhasil lulus pada tahun 2018. Dua tahun kemudian, penulis menyelesaikan studi S2 di prodi Teknik Informatika Program Pasca Sarjana Universitas Raharja. Penulis memiliki kepakaran di bidang Bahasa Pemrograman dan *Data Science*. Dan untuk mewujudkan karir sebagai dosen profesional, penulis pun aktif sebagai peneliti di bidang kepakarannya tersebut. Beberapa penelitian yang telah dilakukan didanai oleh internal perguruan tinggi dan juga Kemenristek DIKTI. Selain peneliti, penulis juga aktif menulis buku dengan harapan dapat memberikan kontribusi positif bagi bangsa dan negara yang sangat tercinta ini. Atas dedikasi dan kerja keras dalam menulis buku, Perpustakaan Nasional RI memberikan penghargaan sebagai salah satu Pemenang Buku Terbaik Tahun 2018.

Email Penulis: [aliyah@uca.ac.id](mailto:aliyah@uca.ac.id).

# DEEP LEARNING

## Teori, Algoritma, dan Aplikasi

Buku *Deep Learning: Teori, Algoritma dan Aplikasi* adalah buku yang dirancang untuk memberikan pemahaman komprehensif tentang berbagai topik utama dalam *Deep Learning*. Buku ini menyajikan ulasan mendalam mengenai perkembangan Teori, Algoritma dan Aplikasi. Buku ini berisi berbagai topik menarik yang disajikan dalam bab, sebagai berikut:

1. Konsep Dasar *Deep Learning*,
2. Sejarah dan Evolusi *Neural Networks*,
3. Dasar-dasar Matematika *Deep Learning*,
4. Struktur Jaringan Syaraf Tiruan,
5. Algoritma *Backpropagation* dan Optimasi,
6. Arsitektur *Deep Neural Networks (DNN)*,
7. Jaringan Konvolusi,
8. Jaringan *Long Short-Term Memory (LSTM)* & *Gated Recurrent Units (GRU)*,
9. Jaringan Generatif,
10. Jaringan Transformer dan Pemrosesan Bahasa Alami (*NLP*),
11. Pemrosesan Gambar dengan *Deep Learning*,
12. Pemrosesan *Audio* dan *Video* dengan *Deep Learning*,
13. Teknik Regularisasi dalam *Deep Learning*,
14. *Deep Reinforcement*,
15. Pelatihan Model *Deep Learning* pada Data Skala Besar,
16. Aplikasi *Deep Learning* dalam Bidang Medis,
17. Aplikasi *Deep Learning* dalam Bidang Finansial,
18. *Deep Learning* untuk Keamanan Siber.

Buku ini ditulis dengan gaya bahasa yang mudah dipahami, disertai studi kasus nyata dan ilustrasi menarik untuk membantu pembaca memahami konsep yang kompleks. Sasaran pembaca meliputi mahasiswa, dosen, praktisi TI, serta siapa pun yang ingin memperdalam wawasan tentang dinamika *deep learning*. Melalui pembahasan yang mendalam namun praktis, *Deep Learning: Teori, Algoritma dan Aplikasi* tidak hanya menjadi sumber referensi, tetapi juga dapat menjadi panduan strategis bagi masyarakat yang ingin beradaptasi dan berkembang *deep learning* di era *digital*.