

# Klasifikasi Emosi Berdasarkan Sinyal EEG Menggunakan *Deep Neural Network* dengan *Stacked Denoising AutoEncoder*

## *EEG Signal Classification using Deep Neural Network with Stacked Denoising AutoEncoder*

Dieka Nugraha Karyana<sup>1</sup>, Untari Novia Wisesty<sup>2</sup>, Jondri<sup>3</sup>

<sup>1,2,3</sup>Prodi S1 Teknik Informatika, Fakultas Informatika, Universitas Telkom

<sup>1</sup>[diekanugraha@gmail.com](mailto:diekanugraha@gmail.com), <sup>2</sup>[untarinw@telkomuniversity.ac.id](mailto:untarinw@telkomuniversity.ac.id), <sup>3</sup>[jondri@telkomuniversity.ac.id](mailto:jondri@telkomuniversity.ac.id)

---

### Abstrak

Pengenalan emosi merupakan kunci untuk membangun sebuah human computer interaction yang alami, yaitu komputer yang memiliki kecerdasan emosional dalam memberikan tanggapan. Emosi dapat dikenali salah satunya melalui EEG (electrocephalogram). Deep Learning berfokus pada menemukan representasi fitur bertingkat yang dimana pada tingkatan fitur yang lebih tinggi merepresentasikan lebih banyak aspek abstrak dari data. Dengan menggunakan deep learning, data EEG dapat ditemukan representasi bertingkatnya dan dijadikan sebagai input kepada classifier agar dapat dilakukan Klasifikasi. Pada tugas akhir ini emosi diklasifikasi dengan menggunakan metode deep learning dengan Stacked Denoising AutoEncoder sebagai pembangun dari Deep Neural Network. Hasil pengujian terbaik untuk 4 kelas didapatkan nilai f1 score sebesar 0.3578 menggunakan data PCA. Sedangkan untuk klasifikasi 2 kelas didapatkan nilai f1 score sebesar 0.5656 untuk klasifikasi valence dan 0.5891 untuk klasifikasi arousal. Proses klasifikasi menggunakan data per orang menghasilkan performansi dengan rerata f1 score sebesar 0.5488. Penambahan jumlah hidden layer dan peningkatan nilai corruption level menyebabkan efek yang bervariasi terhadap performansi DNN.

**Kata kunci :** EEG, DNN, *autoencoder*, klasifikasi

---

### Abstract

Emotion identification is key to build a natural human-computer interaction, that is a computer that has an emotional intelligence in its response. Emotion could be identified by EEG (electrocephalogram). Deep learning focused in finding hierarchical feature representation which in higher level represents more abstract aspect of data. By using deep learning, hierarchical feature of EEG data could be obtained and used as input for classifier. In this final task, emotion classified using deep learning by using stacked denoising autoencoder as builder for deep neural network. Best f1 score obtained for 4 class classification is 0.3578, 2 class classification best f1 score is 0.5656 for valence classification and 0.5891 for valence classification. Per person classification yields average f1 score of 0.5488. Increase in number of hidden layer and corruption level value yields varying effect in performance.

**Keywords :** EEG, DNN, *autoencoder*, classification

---

## 1. Pendahuluan

Emosi merujuk pada suatu perasaan dan pikiran yang khas, suatu keadaan biologis dan psikologis dan serangkaian kecenderungan untuk bertindak. Emosi pada dasarnya adalah dorongan untuk bertindak. Biasanya emosi merupakan reaksi terhadap rangsangan dari luar dan dalam diri individu. Emosi dapat digunakan pada *human-computer interaction* (HCI) sebagai informasi untuk menentukan aksi yang akan dilakukan sehingga akan dihasilkan suatu tanggapan yang dapat menanggapi keadaan emosi pengguna dan menciptakan komputer yang memiliki kecerdasan emosional. Hal ini dapat dilakukan dengan mengenali isyarat-isyarat emosi yang terjadi ketika berlangsungnya HCI dan menggabungkannya dengan tanggapan komputer [1].

Emosi dapat dikenali dari berbagai sumber, diantaranya adalah raut wajah, intonasi suara dan aktifitas neuron pada otak manusia melalui EEG. EEG (*electroencephalogram*) adalah rekaman pengukuran potensial listrik akibat dari aktifitas neuron pada otak [2]. Rekaman EEG dapat digunakan untuk mengenali emosi untuk orang yang sulit raut wajah maupun intonasi suaranya seperti orang yang terkena stroke. Rekaman EEG sudah sering digunakan untuk pengenalan emosi [2] [3] dengan berbagai metode ekstraksi ciri seperti *Power Spectral Density* (PSD), *Common Spatial Pattern* (CSP) [4], *Fast Fourier Transform* (FFT) [5], *Wavelet Transform* (WT) [3] dan *deep learning* [2].

Performansi dari banyak algoritma *machine learning* sangat bergantung kepada representasi atau fitur yang digunakan. Oleh karena itu pada implementasi dari algoritma *machine learning*, ekstraksi ciri atau fitur dibuat sedemikian rupa sehingga dihasilkan sebuah fitur yang secara efektif dapat mendukung algoritma yang digunakan [6]. *Deep learning* adalah salah satu metode pada *machine learning* yang dapat digunakan untuk melakukan klasifikasi data EEG. Kelebihan dari metode *deep learning* adalah dapat melakukan *hierarchical feature learning* dari data yang digunakan, sehingga dapat menciptakan representasi bertingkat [7]. Dimana representasi tersebut


semakin abstrak dari tingkatan sebelumnya sehingga diharapkan menghasilkan representasi yang baik. Salah satu dari kriteria representasi yang baik adalah berguna sebagai *input* untuk *classifier* [8]. Pada Tugas Akhir ini dibangun sebuah *Deep Neural Network* (DNN) dengan *Stacked Denoising AutoEncoder* (SDAE) sebagai pembangun DNN untuk membangun representasi bertingkat dari data EEG dan menggunakannya untuk klasifikasi.

2. Tinjauan Pustaka

A. Denoising AutoEncoder

Untuk membentuk representasi yang baik, ternyata kriteria bahwa representasi harus mempertahankan informasi input saja tidak cukup. Jika AE dimana memiliki dimensi yang sama dengan , maka AE bisa saja mencapai tingkat rekosntruksi yang sempurna dengan hanya mempelajari pemetaan identitas atau belajar untuk menyalin input menjadi representasi . Tanpa adanya kriteria tambahan, maka representasi yang lebih berguna tidak dapat ditemukan. Oleh karena itu definisi dari representasi yang baik diubah, menjadi representasi yang baik adalah representasi *robust* yang didapatkan dari *input* yang dirusak yang berguna untuk mendapatkan *input* utuh yang sebenarnya.

Pendekatan ini melahirkan *Denoising AutoEncoder* (DAE). DAE dilatih untuk merekonstruksi *input* yang utuh hasil dari perbaikan *input* yang dirusak. Perbedaan antara DAE dengan AE adalah pemetaan *input* pada DAE diterapkan kepada *input* yang sudah dirusak [9].




Gambar 1: Denoising AutoEncoder

Arsitektur dari DAE (gambar 1) dengan *input* yang dirusak melalui sehingga menjadi *input* rusak . *Encoder* memetakan ke dan *decoder* memetakan ke . *Reconstruction error* ( , ) digunakan untuk membandingkan dengan . Proses perusakan terhadap dapat dilakukan dengan beberapa cara, yaitu:

- Menambahkan *isotropic gaussian noise*
- *Masking noise*, yaitu dengan mengubah nilai elemen *input* menjadi 0 berdasarkan pecahan secara acak.
- *Salt-and-pepper noise*, yaitu dengan mengubah nilai elemen *input* menjadi nilai maksimum atau minimum secara acak berdasarkan pecahan secara acak.

B. Stacked Denoising AutoEncoder

DAE dapat digunakan untuk membentuk *deep neural network* dengan menggunakan pendekatan *greedy layerwise training* yang sama dengan *AutoEncoder* biasa [10].



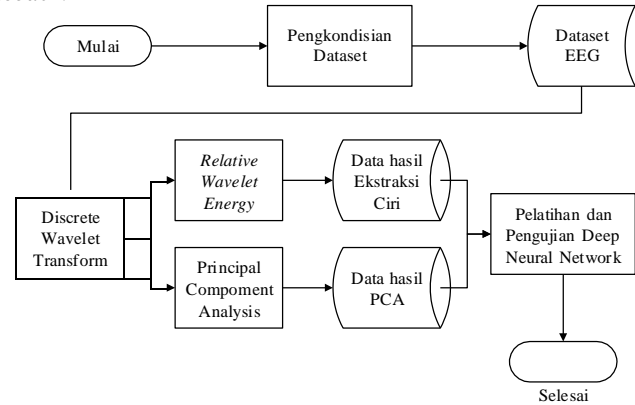
Gambar 2: Greedy Layerwise Training

*Deep neural network* dibangun dengan cara menumpukkan dan melakukan pelatihan satu per satu untuk setiap *layer*. Seperti pada (gambar 2) diatas, setelah *layer* pertama selesai di latih, maka *layer* tersebut akan menjadi *layer input* untuk melakukan pelatihan *layer* selanjutnya. Proses pelatihan yang digunakan adalah proses pelatihan yang sama dengan DAE. Setelah semua *layer* selesai dilatih, maka dapat ditambahkan *output layer* berupa

classifier di ujung tumpukkan *hidden layer* dan dilakukan *fine tuning* yaitu proses minimasi *error* dengan melakukan pembaharuan bobot dengan menggunakan *gradient descent* [9].

### 3. Perancangan Sistem

Berikut ini adalah flowchart dari sistem klasifikasi sinyal EEG menggunakan *Deep Neural Network* dengan *Stacked Denoising AutoEncoder*:



Gambar 3: Flowchart Diagram Rancangan Sistem

#### A. Pengkondisian Dataset

Pengkondisian dataset bertujuan untuk mempersiapkan dan mempermudah penggunaan dataset untuk proses-proses berikutnya. berikut ini ulasan untuk setiap langkah pada proses pengkondisian dataset:

##### 1. Pemisahan Rekaman EEG

Dataset DEAP terdiri atas 32 file yang masing-masing file berisikan 40 percobaan rekaman EEG. Masing-masing rekaman berisikan dua *array*, yaitu: *array data* yang berisi data rekaman EEG dan *array labels* yang berisi nilai *valence*, *arousal*, *dominance* dan *liking*. Data pada *array data* terdiri atas 32 *channel* data EEG dan 8 *channel* rekaman psikologis lainnya. Karena hanya data EEG yang akan digunakan untuk klasifikasi, maka dilakukan pemisahan.

##### 2. Pelabelan

Setelah data rekaman EEG dipisahkan, maka kemudian data tersebut diberi label. Proses pelabelan menggunakan nilai *valence* dan *arousal* yang berada pada *array labels*. Nilai *valence* dan *arousal* berkisar antara 1 dan 9. Proses pelabelan dilakukan dengan ketentuan dengan ketentuan:

Untuk 4 Kelas:

- $Valence < 5$  dan  $Arousal < 5$  dilabeli *low arousal/low valence* (LALV)
- $Valence < 5$  dan  $Arousal \geq 5$  dilabeli *low arousal/high valence* (LAHV)
- $Valence \geq 5$  dan  $Arousal < 5$  dilabeli *high arousal/low valence* (HALV)
- $Valence \geq 5$  dan  $Arousal \geq 5$  dilabeli *high arousal/high valence* (LALV)

Untuk 2 Kelas:

- $Valence < 5$  atau  $Arousal < 5$  dilabeli *Low*
- $Valence \geq 5$  atau  $Arousal \geq 5$  dilabeli *High*

##### 3. Penyimpanan Dataset EEG

Setelah data rekaman EEG dilabeli, kemudian masing-masing rekaman EEG disimpan ke dalam satu *file* sehingga total terdapat 1280 *file*.

#### B. Discrete Wavelet Transform (DWT)

DWT digunakan untuk mentransformasi data EEG. Fungsi *Wavelet* yang digunakan adalah “db4” dan level dekomposisi yang digunakan adalah 5 level. Proses multi-level discrete wavelet transform dilakukan untuk setiap channel data EEG, sehingga dihasilkan 6 koefisien, 1 approximation coefficient (cA) dan 5 detail coefficient (cD) seperti berikut: cA5, cD5, cD4, cD3, cD2 dan cD1 untuk setiap channel. yang kemudian dijadikan satu *array* berukuran 32 yang masing-masing. Proses ini diulang sampai semua data EEG selesai ditransformasi sehingga terdapat 1280 *file* yang kemudian disimpan sebagai data DWT.

#### C. Relative Wavelet Energy

Pada proses ekstraksi ciri dilakukan penghitungan *relative wavelet energy* pada setiap level dan *channel*. Proses ekstraksi ciri dimulai dengan melakukan pengambilan 5 *detail coefficient* (cD5, cD4, cD3, cD2 dan cD1) dari setiap channel. Kemudian dilakukan penghitungan *relative wavelet energy* untuk semua *detail coefficient*

tersebut sehingga menghasilkan vektor dengan ukuran 160 *relative wavelet energy*. Proses ini dilakukan untuk seluruh file rekaman EEG sehingga terdapat 1280 *file* yang disimpan sebagai data *relative wavelet energy*.

**D. Principal Component Analysis (PCA)**

Pada proses ini dilakukan *principal component analysis* untuk data hasil dari DWT. Data yang digunakan pada proses ini adalah *detail coefficient* level ke 4 (cD4). Jumlah *principal component* yang diambil adalah 500 buah.

**E. Pelatihan dan Pengujian Deep Neural Network**

Proses pelatihan dan pengujian *deep neural network* dilakukan dengan menggunakan *k-fold cross validation*. Performansi dari *deep neural network* didapatkan dengan cara menghitung rerata performansi dari setiap *fold*. Proses pelatihan dan pengujian *deep neural network* terdiri atas tahapan-tahapan berikut:

1. Scaling

Scaling dilakukan untuk mengubah rentang data menjadi antara -1 dan 1. Scaling dilakukan dengan menggunakan rumus:

$$= \frac{x - \min(x)}{\max(x) - \min(x)} \tag{1}$$

Dimana merupakan hasil dari scaling, adalah nilai asli data, sedangkan merupakan nilai tertinggi data tersebut dan merupakan nilai terendah data tersebut. Proses scaling dilakukan terlebih dahulu terhadap *train set*. Kemudian dilakukan terhadap *validation set* dengan menggunakan parameter dan dari proses scaling terhadap *train set*.

2. Pre Training

Pada tahap ini dilakukan pembangunan DNN dengan menggunakan prosedur *greedy layerwise unsupervised training* yaitu melakukan pelatihan terhadap representasi data menggunakan SDAE dengan Proses perusakan *masking noise* satu per satu layer secara bertahap. Proses pelatihan dilakukan menggunakan *stochastic gradient descent* dengan optimasi Adam.

3. Fine Tuning

Pada tahap ini, *hidden layer* pada DNN yang sudah selesai dibangun disambungkan dengan *softmax layer* dan dilakukan pelatihan menggunakan algoritma *backpropagation* dengan *stochastic gradient descent* dengan optimasi Adam untuk memperbaharui bobot-bobot pada semua layer dari DNN untuk meminimalisasi *error*. Tahap ini mirip dengan fase training jaringan syaraf tiruan pada umumnya.

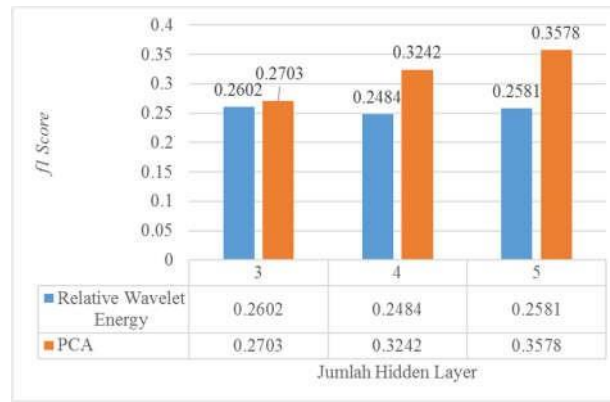
4. Klasifikasi

Setelah DNN selesai dilakukan *fine tuning*, maka DNN kemudian digunakan untuk klasifikasi ke dalam 4 kelas: *low arousal/low valence* (LALV), *low arousal/high valence* (LAHV), *high arousal/low valence* (HALV) dan *high arousal/high valence* (HAHV) dan 2 kelas: *low* dan *high* untuk pengujian klasifikasi kelas *valence* atau *arousal*. Proses klasifikasi dimulai dengan melakukan forward pass pada DNN yang sudah selesai dilatih dengan data uji sebagai masukkanya. Kemudian data uji tersebut akan ditentukan kelasnya dengan memilih nilai index dari neuron pada hidden layer yang memiliki nilai *output* terbesar. Proses ini dilakukan untuk semua data uji. Setelah semua data uji selesai di tentukan kelasnya, dilakukan pembuatan *confusion matrix* dengan membandingkan kelas yang dihasilkan oleh DNN dengan kelas data yang sebenarnya (*label*). Setelah *confusion matrix* selesai dibuat kemudian dihitung *f1 score* untuk *confusion matrix* tersebut

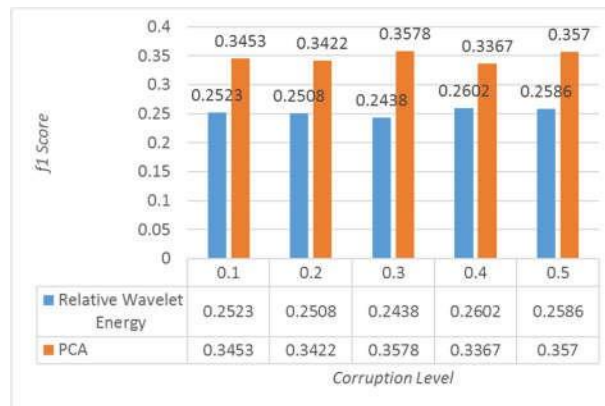
**4. Pengujian dan Hasil**

**5.1. Hasil dan Analisis Pengujian Skenario 1**

Skenario pengujian dilakukan untuk mencari performansi DNN terhadap data hasil dari proses DWT dan ekstraksi ciri. Skenario ini diuji menggunakan *8 fold cross validation*. Hasil dari pengujian ini dapat dilihat pada Gambar 4 dan Gambar 5.



Gambar 4: Grafik Performansi Terbaik Terhadap Jumlah Hidden Layer Skenario 1

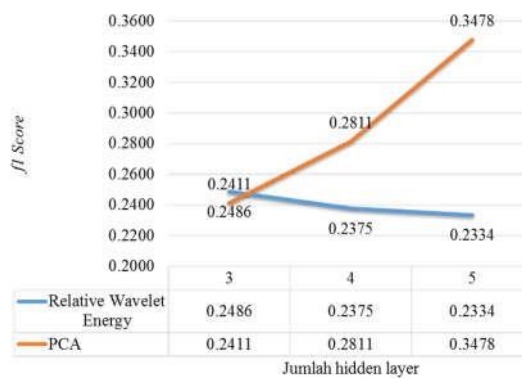


Gambar 5: Grafik Performansi Terbaik Terhadap Corruption Level Skenario 1

Dari hasil diatas didapatkan bahwa DNN mempunyai performansi terbaik pada data hasil dari proses PCA, yaitu 0.3578 pada data PCA dibandingkan dengan 0.2602 pada data hasil *relative wavelet energy*. Hal ini disebabkan oleh DNN yang menggunakan data PCA berhasil dilatih representasi bertingkat yang lebih baik dari DNN yang menggunakan data hasil *relative wavelet energy*.

**5.2. Hasil dan Analisis Pengujian Skenario 2**

Skenario pengujian 2 dilakukan untuk mencari pengaruh jumlah *hidden layer* terhadap performansi DNN. Pengaruh dari jumlah *hidden layer* dapat dilihat pada Gambar 6.



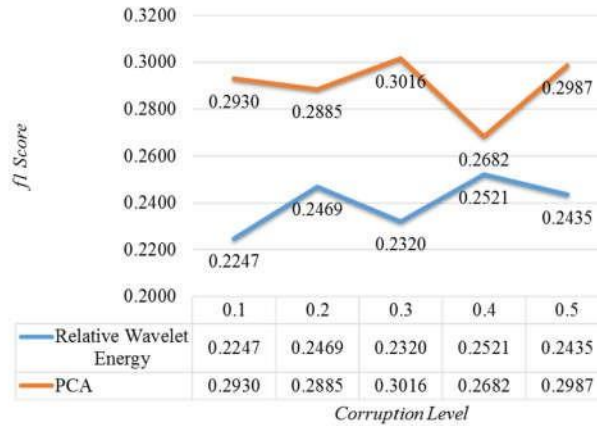
Gambar 6: Grafik Hasil Pengujian Skenario 2

Dari Gambar 6 dapat dilihat bahwa jumlah *hidden layer* mempunyai pengaruh yang berbeda terhadap masing-masing data. Untuk data hasil PCA penambahan jumlah *hidden layer* meningkatkan performansi dari DNN. Hal ini disebabkan oleh auto encoder menghasilkan fitur yang lebih baik setiap jumlah *hidden layer* ditambah sehingga lebih mudah untuk diklasifikasikan yang berdampak pada meningkatnya performansi. Sedangkan untuk data hasil *relative wavelet energy*, penambahan jumlah *hidden layer* menurunkan performansi.

Hal ini disebabkan oleh auto encoder tidak dapat menghasilkan fitur yang baik pada saat proses *pre-training* karena disebabkan oleh berbagai macam faktor, seperti kurangnya epoch pada saat pre-training.

**5.3. Hasil dan Analisis Pengujian Skenario 3**

Skenario pengujian 3 dilakukan untuk mencari pengaruh *corruption level* ( ) terhadap performansi DNN. Pengaruh dari *corruption level* dapat dilihat pada Gambar 7.

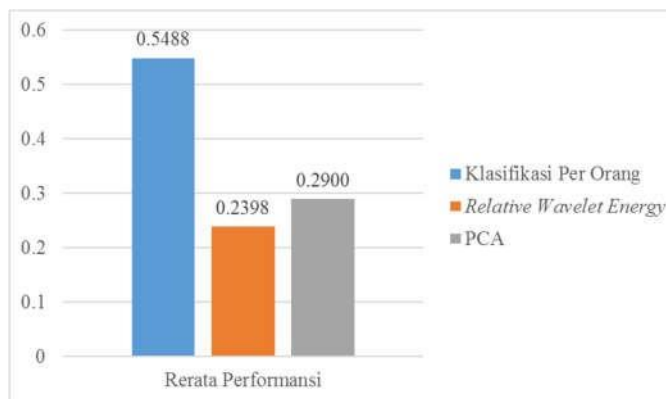


Gambar 7: Grafik Hasil Pengujian Skenario 3

Dari Gambar 7 dapat dilihat bahwa *corruption level* menyebabkan efek yang bervariasi pada performansi DNN. Peningkatan nilai *corruption level* berpengaruh terhadap performansi, tetapi tidak secara linier. Hal ini disebabkan oleh banyaknya *output* dari *neuron* pada *neural network* yang dipaksa bernilai 0 semakin tinggi seiring dengan naiknya nilai *corruption level* pada tahap pre-training. Berkurangnya *neuron* menyebabkan hilangnya informasi yang diperlukan DNN untuk dapat mengklasifikasikan kelas dengan benar sehingga berpengaruh terhadap bobot awal yang dihasilkan.

**5.4. Hasil dan Analisis Pengujian Skenario 4**

Skenario pengujian dilakukan untuk menguji performansi DNN terhadap klasifikasi per orang menggunakan data hasil dari proses *relative wavelet energy* dan membandingkannya terhadap hasil dari klasifikasi menggunakan seluruh data (skenario 1). Skenario ini diuji menggunakan *4-fold cross validation* karena data untuk setiap orang yang hanya berjumlah 40 data. Hasil dari pengujian ini dapat dilihat pada Gambar 8.

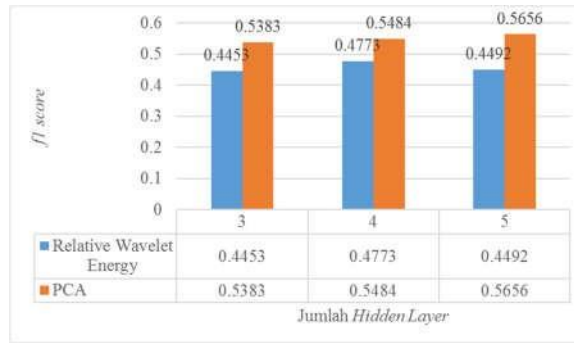


Gambar 8: Grafik Hasil Pengujian Skenario 4

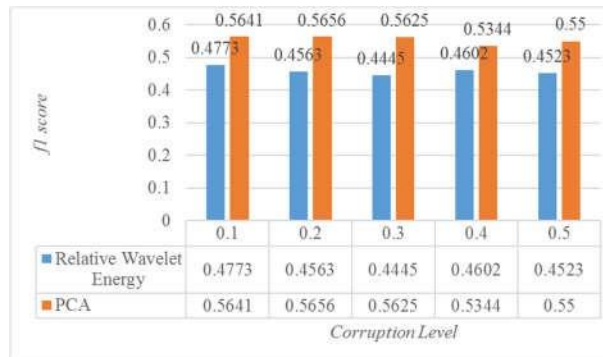
Dapat dilihat dari Gambar 8 bahwa performansi dari klasifikasi per orang lebih baik dibandingkan dengan klasifikasi menggunakan keseluruhan data uji. Rerata untuk data hasil *relative wavelet energy* dan PCA didapatkan dari skenario 1. Rerata performansi dari hasil klasifikasi per orang adalah 0.5488. Rerata tersebut lebih besar jika dibandingkan dengan rerata performansi dari hasil klasifikasi data *relative wavelet energy* dan PCA yang menggunakan semua data uji pada proses *fine tuning*. Hal ini disebabkan karena data EEG memiliki pola yang unik untuk setiap orang, sehingga lebih mudah diklasifikasikan oleh DNN.

5.5. Hasil dan Analisis Pengujian Skenario 5

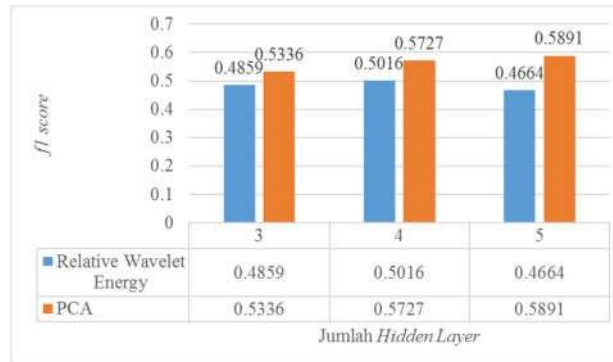
Skenario pengujian dilakukan bertujuan untuk menguji performansi DNN terhadap klasifikasi emosi berdasarkan 2 kelas, *low* dan *high* untuk masing-masing *valence* dan *arousal*. Hasil dari pengujian skenario 5 dapat dilihat pada Gambar 9, Gambar 10, Gambar 11, dan Gambar 12.




Gambar 9: Grafik performansi terbaik terhadap jumlah hidden layer untuk kelas valence



Gambar 10: Grafik performansi terbaik terhadap corruption level untuk kelas valence



Gambar 11: Grafik preformansi terbaik terhadap jumlah hidden layer untuk kelas arousal



Gambar 12: Grafik performansi terbaik terhadap corruption level untuk kelas arousal

Dari dapat dilihat dari Gambar 9, Gambar 10, Gambar 11, dan Gambar 12 bahwa performansi DNN dalam mengklasifikasikan 2 kelas (*valence* atau *arousal* saja) lebih baik jika dibandingkan dengan performansi klasifikasi 4 kelas (LALV, LAHV, HALV dan HAHV). Diperoleh performansi terbaik bernilai 0.5656 untuk klasifikasi *valence* dan 0.5891 untuk klasifikasi *arousal*. Kedua performansi terbaik tersebut dihasilkan dari data hasil proses PCA. Hal ini disebabkan oleh data EEG lebih mudah untuk diklasifikasikan menjadi 2 kelas.

## 5. Kesimpulan

Berdasarkan hasil pengujian dan analisis yang telah dilakukan, maka dapat ditarik kesimpulan sebagai berikut:

1. Klasifikasi gelombang EEG menggunakan Deep Neural Network dengan Stacked Denoising AutoEncoder telah diimplementasikan dengan hasil klasifikasi terbaik sebesar 0.3578 untuk klasifikasi 4 kelas, sebesar 0.5656 untuk klasifikasi *valence* dan 0.5891 untuk klasifikasi *arousal* pada klasifikasi 2 kelas.
2. Data hasil *principal component analysis* (PCA) menghasilkan performansi yang lebih baik dibandingkan dengan data hasil dari proses *relative wavelet energy*. Dengan hasil sebesar 0.3578 untuk data hasil PCA dengan selisih 0.0976 terhadap data hasil *relative wavelet energy*.
3. Penambahan jumlah *hidden layer* pada DNN menyebabkan peningkatan performansi.
4. Peningkatan nilai *corruption level* berpengaruh secara tidak linier terhadap performansi.
5. Klasifikasi menggunakan data per orang menghasilkan performansi lebih baik dari klasifikasi yang menggunakan semua data uji yaitu dengan rerata *f1 score* sebesar 0.5488.
6. Performansi DNN untuk klasifikasi 2 kelas (*low* atau *high* untuk *valence* atau *arousal* saja) lebih baik dibandingkan dengan klasifikasi 4 kelas (LALV, LAHV, HALV, dan HAHV).

## Daftar Pustaka

- [1] S. Koelstra, C. Mühl, M. Soleymani, J. S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, and I. Patras, "DEAP: A database for emotion analysis; Using physiological signals," *IEEE Trans. Affect. Comput.*, vol. 3, no. 1, pp. 18–31, 2012.
- [2] S. Jirayacharoensak, S. Pan-Ngum, and P. Israsena, "EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation.," *ScientificWorldJournal.*, vol. 2014, p. 627892, 2014.
- [3] M. Murugappan, "Classification of human emotion from EEG using discrete wavelet transform," *J. Biomed. Sci. Eng.*, vol. 03, no. 04, pp. 390–396, 2010.
- [4] S. Koelstra, A. Yazdani, M. Soleymani, and M. Christian, "Single Trial Classification of EEG and Peripheral Physiological Signals for Recognition of Emotions Induced by Music Videos," *Brain informatics*, pp. 89–100, 2010.
- [5] D. Nie, X. W. Wang, L. C. Shi, and B. L. Lu, "EEG-based emotion recognition during watching movies," *2011 5th Int. IEEE/EMBS Conf. Neural Eng. NER 2011*, no. October, pp. 667–670, 2011.
- [6] Y. Bengio, "Deep Learning of Representations: Looking Forward," 2013.
- [7] A. SUBASI, "EEG signal classification using wavelet feature extraction and a mixture of expert model," *Expert Syst. Appl.*, vol. 32, no. 4, pp. 1084–1093, 2007.
- [8] Y. Bengio, "Deep Learning of Representations for Unsupervised and Transfer Learning," *JMLR Work. Conf. Proc. 7*, vol. 7, pp. 1–20, 2011.
- [9] P. Vincent, H. Larochelle, I. Lajoie, Y. Bengio, and P.-A. Manzagol, "Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion," *J. Mach. Learn. Res.*, vol. 11, pp. 3371–3408, 2010.
- [10] Y. Bengio, P. Lamblin, D. Popovici, and H. Larochelle, "Greedy Layer-Wise Training of Deep Networks," *Adv. Neural Inf. Process. Syst. 19*, no. 1, pp. 153–160, 2007.