

Klasifikasi Sinyal EEG Menggunakan Deep Neural Network

EEG Signal Classification using Deep Neural Network

Renette Ersti, Untari Novia Wisesty, Jondri

Prodi S1 Teknik Informatika , Fakultas Teknik, Universitas Telkom
reersti@gmail.com, untarinw@telkomuniversity.ac.id, jondri@telkomuniversity.ac.id

Abstrak

Emosi adalah luapan perasaan seseorang yang dipengaruhi oleh suasana hati dan keadaan sekitarnya. Tidak semua orang dapat dengan mudah menyampaikan emosinya. Bagi orang yang kesusahan dalam menyampaikan emosi, orang tersebut tentu membutuhkan perantara. Salah satu caranya yaitu dengan membaca aktivitas sinyal otak atau biasa disebut dengan *electroencephalograph* (EEG). Pada Tugas Akhir ini, proses klasifikasi emosi terdiri dari tahap *preprocessing*, *training*, dan *testing*. *Preprocessing* dilakukan dengan menggunakan metode *Discrete Wavelet Transform*. Digunakan metode *Deep Neural Network* untuk mengolah sinyal EEG untuk diklasifikasi..

Metode *Deep Neural Network* menghasilkan performansi yang rendah. Data yang bagus dapat mengoptimalkan performansi sistem. Performansi terbaik diperoleh pada percobaan dengan *learning rate* sebesar 0.01 dan dengan parameter konstan *epoch* sebesar 100, *epoch2* sebesar 10, dan menggunakan fungsi aktivasi sigmoid bipolar yaitu *fscore* sebesar 0.2051.

Kata kunci : *emosi, electroencephalograph, Deep Neural Networks, Discrete Wavelet Transform.*

Abstract

Emotion is the outpouring of feeling in someone who is affected by the mood and the circumstances surrounding. In fact, because of it also can causes misunderstandings. There are people can't easily convey emotions. For people in distress in conveying emotion, the people would need an intermediary. One way is by reading brain activity signals or commonly called the electroencephalograph (EEG). In this final project, the emotion classification process comprising the step of preprocessing, training, and testing. Preprocessing performed using Discrete Wavelet Transform. Thereafter, the method used Deep Neural Network to process the EEG signals to be classified.

Deep Neural Network method produces low performance. Good data can optimize performance system. The best performance was obtained in experiments with learning rate of 0.01 and with a constant parameter epoch of 100, epoch2 at 10, and using sigmoid bipolar activation function with fscore 0.2051.

Keywords: *emotion, electroencephalograph, Deep Neural Network, Discrete Wavelet Transform.*

I. Pendahuluan

Emosi sangat berperan penting dalam komunikasi sehari-hari. Mungkin untuk sebagian besar orang, penyampaian emosi dengan benar itu sangat penting karena dengan penyampaian emosi yang berbeda akan menyebabkan persepsi yang berbeda bagi setiap orang. Bagi orang yang tidak bisa menyampaikan emosinya, seperti orang yang terkena stroke, membutuhkan perantara agar orang lain dapat mengerti apa yang sedang dirasakan. Salah satu cara yang dapat dilakukan yaitu dengan membaca sinyal biolistrik yang dikeluarkan oleh otak manusia. Algoritma *deep learning* digunakan untuk model abstraksi tingkat tinggi. Algoritma *deep learning* memiliki beberapa macam variasi arsitektur, salah satunya yaitu *deep neural networks* [8]. Pada penelitian sebelumnya, rekognisi emosi berdasarkan sinyal EEG dengan menggunakan *Deep Learning Network* dengan mengacu pada *valence* dan *arousal* mendapatkan akurasi sebesar 49.52% dan 46.03%, dan bila dikombinasikan dengan *principal component*

based covariate shift adaptation dapat meningkatkan akurasi sebesar 5.55% dan 6.53% [13]. Pada eksperimen lain dengan menggunakan KNN diperoleh akurasi sebesar 69.66%, DBN sebesar 86.91%, dan DBN-HMM sebesar 87.62% [20]

Pada tugas akhir ini, penulis membangun sistem yang dapat mengklasifikasi sinyal EEG. Digunakan *discrete wavelet transform* untuk pengolahan sinyal EEG sebelum masuk ke metode utama. Metode *discrete wavelet transform* berguna untuk mengolah sinyal EEG menjadi data EEG agar lebih mudah diproses dengan menggunakan algoritma *deep neural network*. Sementara algoritma *deep neural network* berguna untuk proses *training* dan *testing*.

II. Tinjauan Pustaka

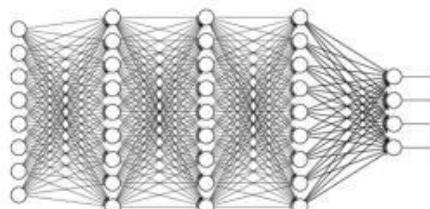
A. Discrete Wavelet Transform

Discrete Wavelet Transform (DWT) ini berfungsi untuk mengurangi redundansi saat transformasi wavelet kontinu dengan mengambil nilai diskrit dari parameter translasi dan dilatasi. DWT terdiri dari 2 tahap, yaitu :

1. *Forward Discrete Wavelet Transform* (FDWT) : tahap dekomposisi dari *wavelet transform*.
2. *Inverse Discrete Wavelet Transform* (IDWT) : tahap rekonstruksi yang merupakan kebalikan dari proses dekomposisi.

B. Deep Neural Network

Deep Neural Networks (DNNs) merupakan salah satu tipe dari *deep neural network*. DNN ini terdiri dari beberapa *hidden units* dengan koneksi antar *layer* tetapi tidak ada koneksi antar *units* pada setiap *layer*-nya. Metode ini memiliki arsitektur yang serupa dengan arsitektur pada *Artificial Neural Networks* (ANNs), hanya saja pada Tugas Akhir ini menerapkan skema *Deep Belief Networks* (DBNs), dengan *supervised training*. *Building block* pada arsitektur ini disebut dengan *Restricted Boltzmann Machines* (RBM) yang digunakan untuk merepresentasikan model [18]. Inti dari cara kerja DBN yaitu merekonstruksi input..



Gambar 1: Skema DNN

C. Restricted Boltzmann Machines

Restricted Boltzmann Machines merupakan salah satu tipe dari *Markov Random Field* (MRF) [2]. Arsitektur pada RBM ini hampir sama dengan arsitektur pada *Artificial Neural Networks* (ANNs), tetapi RBM hanya memiliki *hidden units* dan *visible units* [2].

Summing function:

$$\sum_{i=1}^n w_i x_i + b = v \quad (1)$$

di mana v merepresentasikan data input, w merepresentasikan bobot, dan b merepresentasikan bias.

Fungsi aktivasi sigmoid:

$$\sigma(x) = 1 / (1 + e^{-x}) \quad (2)$$

di mana x adalah hasil dari *summing function*.

Energy:

$$E(h) = -\sum_{i=1}^n w_i x_i - \sum_{i=1}^n b_i h_i - \sum_{i=1}^n \frac{1}{2} h_i^2 \quad (3)$$

dimana a dan b merepresentasikan bias, v merepresentasikan *visible units*, h merepresentasikan *hidden units*, dan w merepresentasikan bobot (*weight*).

Kemudian langkah berikutnya yaitu melakukan proses *fine-tuning* dengan menggunakan metode *backpropagation* dengan tahapannya hampir sama dengan *summing function*.

Update bobot:

$$\Delta w_{ij} = \eta (v_i h_j - \langle v_i h_j \rangle) \quad (4)$$

dimana η merepresentasikan *learning rate*.

Langkah lain pada RBM yang menjadi pembeda pada RBM yaitu perhitungan *probability*.

$$\Pr(h_j = 1 | \theta) = \frac{1}{1 + e^{-\sigma(\theta_j + \sum_i w_{ji} v_i)}} \quad (5)$$

$$\Pr(h_i = 1 | h) = \frac{1}{1 + e^{-\sigma(\theta_i + \sum_j w_{ij} h_j)}} \quad (6)$$

dimana h merepresentasikan *hidden units*, v merepresentasikan *visible units*, σ merepresentasikan fungsi sigmoid, a dan b merepresentasikan bias, dan w merepresentasikan bobot.

Learning dapat bekerja dengan baik dengan meminimalkan fungsi dengan “*Contrastive Divergence*”.

$$W = W + \eta (h_1 - \Pr(h_1 = 1 | \theta)) \quad (7)$$

di mana W merepresentasikan bobot, η merepresentasikan *learning rate*, h merepresentasikan *neuron hidden*, dan v merepresentasikan *visible layer*.

Update bias:

$$\theta_i = \theta_i + \eta (h_i - \Pr(h_i = 1 | \theta)) \quad (8)$$

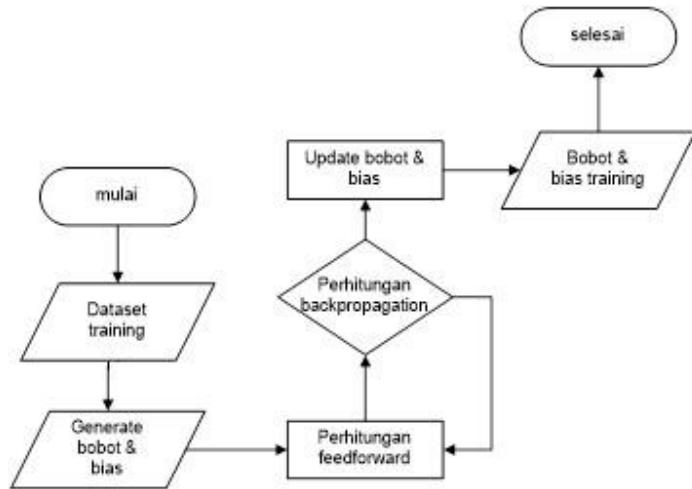
$$\theta_j = \theta_j + \eta (h_j - \Pr(h_j = 1 | \theta)) \quad (9)$$

di mana b dan a merepresentasikan bias, η merepresentasikan *learning rate*, h merepresentasikan *neuron hidden*, dan v merepresentasikan *visible layer*. b adalah bias untuk perhitungan *backpropagation* dan a adalah bias untuk perhitungan *feedforward*.

III. Desain Sistem

A. Training

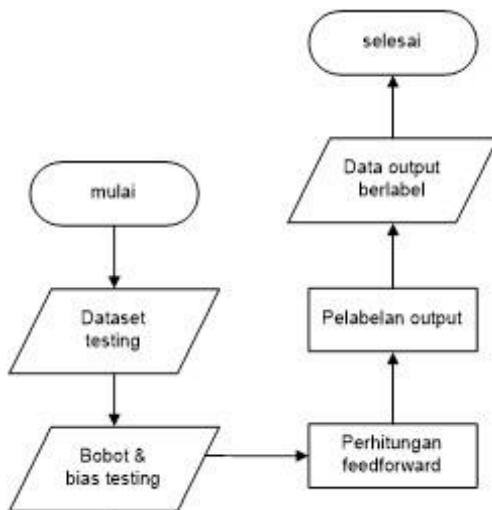
Pada tahap ini dilakukan perhitungan untuk *update* bobot dan bias yang akan digunakan untuk bobot dan bias pada tahap *testing*. Bobot dan bias awal di-generate secara *random* dengan rentang -1 hingga 1. Selanjutnya, dilakukan perhitungan *feedforward*. Fungsi aktivasi yang digunakan yaitu sigmoid agar nilai dapat *flexible* dari 0 hingga 1.



Gambar 2 Proses Training

B. Test

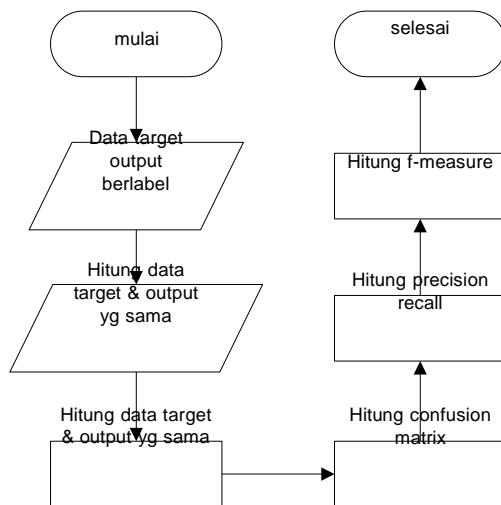
Alur *testing* tidak dilakukan perhitungan *backpropagation* dan hanya dilakukan satu kali perhitungan maju saja. Hasil dari perhitungan tersebut akan diberi label yang kemudian akan dibandingkan dengan data target.



Gambar 3 Proses Testing

C. Pencocokan dan pengukuran performansi

Pada tahap ini dilakukan pencocokan antara hasil dari *testing* yang telah diberi label dengan data target. Selanjutnya, dilakukan perhitungan performansi.



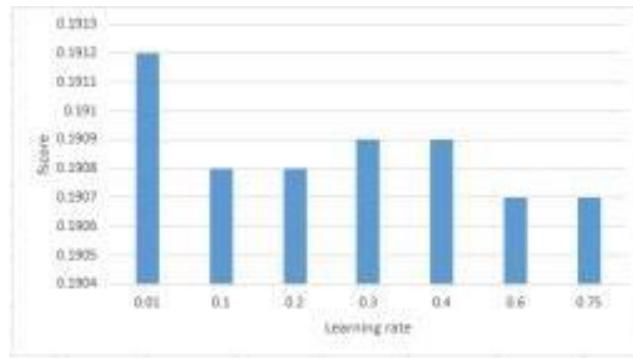
Gambar 4 Proses pencocokan dan pengukuran performansi

IV. Pengujian dan Analisis

Pada pengujian ini dilakukan pengujian apakah untuk mengetahui pengaruh parameter, fungsi aktivasi, dan data perorangan. Pada Tabel 2 merupakan tabel skenario pengujian dengan parameter uji dan parameter konstan.

Tabel 2 Skenario pengujian 1

Parameter Konstan	Parameter Uji
Epoch : 100	Learning rate : 0.01, 0.1, 0.2,
Epoch2 : 10	0.3, 0.4, 0.6, 0.75
Fungsi aktivasi : sigmoid	

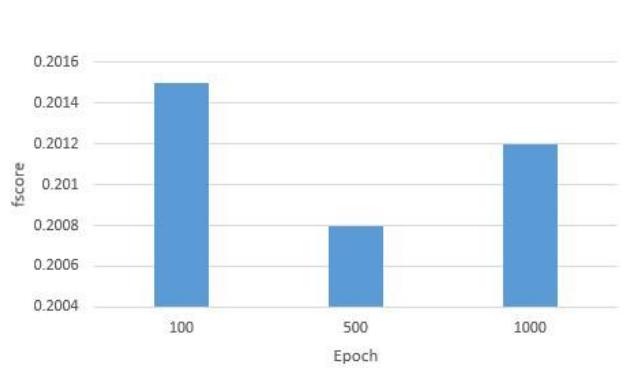


Gambar 5 Hasil Skenario 1

Semakin tinggi *learning rate* maka nilai performansi sistem semakin tinggi juga. Pada skenario 1, performansi terbaik diperoleh oleh *learning rate* 0.01 yaitu sebesar 0.1912. *Learning rate* 0.01 memperoleh nilai performansi yang terbesar karena semakin kecil *learning rate* maka akan semakin teliti suatu sistem.

Tabel 3 Skenario pengujian 2

Parameter Konstan	Parameter Uji
Learning rate : 0.01	Epoch : 100, 500, 1000
Fungsi aktivasi : sigmoid	
Epoch2 : 10	

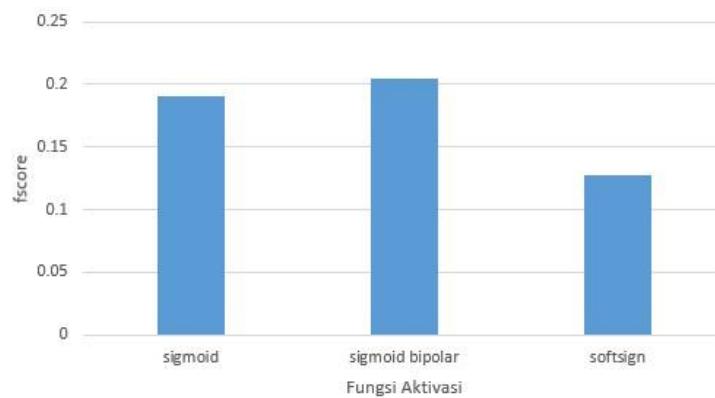


Gambar 6 Hasil Skenario 2

Performansi tertinggi diperoleh ketika *epoch* 100 yaitu sebesar 0.2452. Perubahan hasil performansi untuk *epoch* yang berbeda tidak begitu signifikan di mana perubahan yang terjadi di bawah 0.01. Hal tersebut terjadi karena data yang diolah sangat kecil dengan *range* nilai pada data yang tidak begitu jauh antar data satu dengan data lainnya sehingga hasil dari perhitungan yang dilakukan oleh sistem juga tidak begitu jauh perbedaannya.

Tabel 4 Skenario pengujian 3

Parameter Konstan	Parameter Uji
<i>Learning rate</i> : 0.01	Fungsi aktivasi : <i>sigmoid</i> ,
<i>Epoch</i> : 100	<i>sigmoid bipolar</i> , <i>softsign</i>
<i>Epoch2</i> : 10	

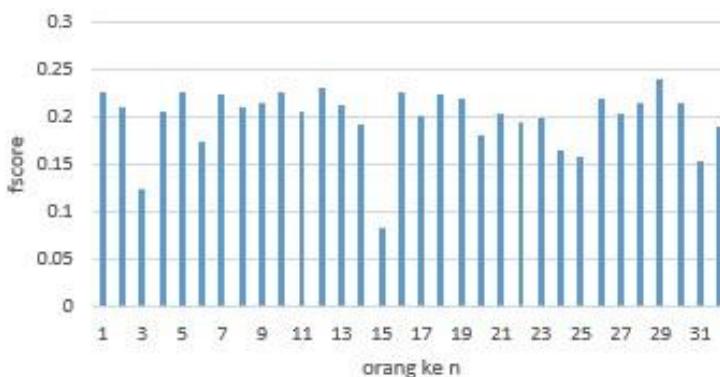


Gambar 7 Hasil Skenario 3

Performansi tertinggi diperoleh dengan menggunakan fungsi aktivasi *sigmoid bipolar* yaitu sebesar 0.1261. Hal tersebut terjadi karena fungsi aktivasi *sigmoid bipolar* ini memiliki rentang dari -1 hingga 1 yang menyebabkan nilai yang dihasilkan lebih bervariasi sehingga hasil dari fungsi aktivasi ini lebih besar dari fungsi aktivasi *sigmoid* biasa yang memiliki rentang dari 0 hingga 1 meskipun perbedaan hasil dari *sigmoid* biasa dan *sigmoid bipolar* tidak begitu jauh. Dari beberapa referensi yang telah dibaca, fungsi aktivasi *softsign* tidak diajukan untuk digunakan dalam perhitungan fungsi aktivasi pada *Deep Neural Network*.

Tabel 4 Skenario pengujian 3

Parameter Konstan	Parameter Uji
<i>Learning rate</i> : 0.01	
<i>Epoch</i> : 100	File s01.mat – s32.mat
<i>Epoch2</i> : 10	
Fungsi aktivasi : sigmoid	



Gambar 8 Hasil Skenario 4

Pada gambar di atas dapat dilihat bahwa performansi tertinggi diperoleh dari data s29.mat dengan *fscore* sebesar 0.2408. Pada hasil pengukuran F untuk tiap kelas seperti pada Tabel 4.9, nilai F untuk F pada kelas 2 dan 3 hampir selalu menghasilkan nilai yang sangat rendah. Hal itu disebabkan karena sistem sulit untuk membaca kelas 2 dan 3 ketika nilai seharusnya adalah kelas 2 atau kelas 3 sehingga hal tersebut berpengaruh pada rendahnya nilai *fscore* pada setiap individu. Selain itu, data yang tidak bagus juga berpengaruh pada perhitungan nilai *fscore*, karena data yang tidak bagus juga dapat mempersulit sistem untuk melakukan klasifikasi.

V. Kesimpulan

Berdasarkan pengujian yang telah dilakukan, dapat disimpulkan bahwa:

1. Performansi terbaik diperoleh saat *learning rate* sebesar 0.01 yaitu 0.1912, *epoch* sebesar 100 yaitu 0.2015, menggunakan fungsi aktivasi *sigmoid bipolar* yaitu 0.2051, dan untuk pengujian perorang didapatkan akurasi terbesar 0.2408.
2. Semakin kecil *learning rate*, maka akan semakin teliti suatu sistem, namun *learning rate* yang tidak terlalu besar dapat meminimalisir terhitungnya data dengan nilai yang mengalami penurunan sangat tajam. Jumlah *epoch* tidak begitu berpengaruh terhadap pengukuran performansi. Fungsi aktivasi yang berbeda juga dapat menyebabkan nilai performansi naik atau turun
3. Performansi pada sistem ini rendah karena dipengaruhi oleh faktor nilai data. Besarnya parameter dapat mempengaruhi nilai performansi dan data yang berbeda juga dapat mempengaruhi besarnya nilai performansi suatu sistem

Referensi

- [1] A. Subasi, "EEG signal classification using wavelet feature extraction and a mixture of expert model," Elsevier Ltd., pp. 1085-1087, 2007.
- [2] Abdel-rahman Mohamed, George Dahl, Geoffrey Hinton, "Deep Belief Networks for Phone Recognition," University of Toronto.
- [3] Arisoy Ebru, Sainath Tara N., Kingsbury Brian, Ramabhadran Bhuvana, "Deep Neural Network Language Models," Association for Computational Linguistics, pp. 20-21, 2012.
- [4] B. D. Oude, "EEG-based Emotion Recognition," p. 1, 2006.

- [5] C. P. Niemic, "Studies of emotion: A theoretical and empirical review of psychophysiological studies of emotion," *Journal of Undergraduate Research*, p. 2002, 1:15-18.
- [6] Ciresan Dan C., Giusti Alessandro, Gambardella Luca M., Schmidhuber Jurgen, "Deep Neural Networks Segment Neuronal Membranes in Electron Microscopy Image," p. 3.
- [7] Deng Li, Hinton Geoffrey, Kingsbury Brian, "New Types of Deep Neural Network Learning for Speech Recognition and Related Applications: an Overview," p. 2.
- [8] Djamal Esmeralda C., Tjokronegoro Harijono A., Soegijanto, "The Use of Wavelet Power Spectrum for Detection and Identification of Thinking-Induced EEG Signals," *Majalah IPTEK*, pp. 12-15, 2005.
- [9] Djamal Esmeralda C., Tjokronegoro Harijono A., "Identifikasi dan Klasifikasi Sinyal EEG terhadap Rangsangan Suara dengan Ekstraksi Wavelet dan Spektral Daya," *Institut Teknologi Bandung*.
- [10] Guey-Shya Chen, Min-Feng Lee, "Detecting Emotion Model in E-Learning System", 2012, International Conference on Machine Learning and Cybernetics, Xian, 15-17 July, 2012
- [11] H. Robert, "Emotion Recognition using Brain Activity," *CompSysTech '08 Proceedings of the 9th International Conference on Computer Systems and Technologies and Workshop for PhD Students in Computing*, vol. 6, pp. 1-2, 2008.
- [12] James A. Russel, "A Circumplex Model of Affect", University of British Columbia, Canada, *Journal of Personality and Social Psychology*, 1980, Vol. 39, No. 6, 1161-1178
- [13] Jirayucharoensak Suwicha, Pan-Ngum Setha, Israsena Pasin, "EEG-Based Emotion Recognition Using Deep Learning Network with Principal Component Based Covariate Shift Adaptation," *Hindawi Publishing Corporation The Scientific World Journal*, 2014
- [14] Liu Yisi, Sourina Olga, Nguyen Minh Khoa, "Real-time EEG-based Human Emotion Recognition and Visualiation," *Cyberworlds (CW), 2010 International Conference on*, pp. 262-263, 2010.
- [15] M. M. Shaker, "EEG Waves Classifier using Wavelet Transform and Fourier Transform," pp. 1-3.
- [16] M. Teplan, "Fundamentals of EEG Measurement", *MEASUREMENT SCIENCE REVIEW*, Vol. 2, Section 2, 2002
- [17] Murugappan Murugappan, Ramachandran Nagarajan, Saali Yaacob, "Classification of human emotion from EEG using discrete wavelet transform," *J. Biomedical Science and Engineering*, pp. 391-393, 2010.
- [18] Nicolas Le Roux, Yoshua Bengio, "Representational Power of Restricted Boltzmann Machines and Deep Belief Networks," *Neural Computation*, vol. 20, pp. 1631-1649, 2008.
- [19] Stehman, Stephen V. (1997). "Selecting and interpreting measures of thematic classification accuracy". *Remote Sensing of Environment*. **62** (1): 77–89.
- [20] Zheng Wei-Long, Zhu Jia-Yi, Peng Yong, Lu Bao-Liang, "EEG-Based Emotion Classification Using Deep Belief Networks".