

BAB VI

Kesimpulan dan Saran

6.1 Kesimpulan

Berdasarkan eksperimen, analisis data, dan klasifikasi yang telah dilakukan, maka kesimpulan yang dapat diambil dari penelitian ini adalah:

1. Telah berhasil mempersiapkan data Galvanic Skin Response dengan menggunakan metode penambangan data temporal. Data tersebut disiapkan dengan dikategorisasi, diagregasi, dinormalisasi dan dikonversi. Konversi tersebut menggunakan metode *sliding windows* dengan lag yang dimulai dari 5 hingga 41, hal tersebut dilakukan untuk mencari jumlah lag yang tepat. Lalu label diberikan setelah data dikonversi sesuai dengan kategori status emosinya.
2. Telah berhasil ditemukan algoritma yang tepat dalam melakukan klasifikasi pada data yang diolah menggunakan metode penambangan data temporal. Klasifikasi dilakukan dengan menggunakan algoritma *support vector machine*, *naive bayes* dan *k-nearest neighbors*. Pada *support vector machine* sendiri, *kernel* yang digunakan berjumlah 4, yaitu *linear*, *radial basis function*, *polynomial* dan *sigmoid*. Hasil klasifikasi terbaik didapatkan dengan menggunakan algoritma *support vector machine* dengan *kernel radial basis function* pada data dengan jumlah lag 40. Sedangkan algoritma *naive bayes* menunjukkan performa paling rendah. Hasil juga menunjukkan bahwa proses normalisasi dan penggunaan *kernel* yg berbeda juga berpengaruh terhadap hasil akhir klasifikasi.

6.2 Saran

Pada penelitian selanjutnya, peneliti dapat mencoba menggunakan metode yang lain dalam memproses data temporal. Peneliti juga dapat mencoba berbagai macam algoritma yang lain dalam membentuk model klasifikasi. Selain itu, peneliti juga dapat mencoba untuk sumber data temporal yang lainnya.

Pelajari permasalahan yang ingin diselesaikan dan dasar teori dengan baik terlebih dahulu. Ketika membentuk model klasifikasi jangan terlalu terpaku pada suatu algoritma saja, cobalah algoritma yang lainnya. Sesuatu yang rumit belum tentu lebih baik. Kalau bisa, hindari penggunaan resampling karena hal tersebut memanipulasi data sebenarnya.

Daftar Pustaka

- Hsu, C.-W., Chang, C.-C. & Lin, C.-J., 2016. A Practical Guide to Support Vector Classification.
- Patro, S. K. & Sahu, K. K., 2015. Normalization: A Preprocessing Stage. *arXiv*.
- Ansari-Asl, K., Chanel, G. & Pun, T., 2007. A CHANNEL SELECTION METHOD FOR EEG CLASSIFICATION IN EMOTION ASSESSMENT BASED ON SYNCHRONIZATION LIKELIHOOD. *European Signal Processing Conference (EUSIPCO)*.
- Antunes, C. M. & Oliveira, A. L., 2001. Temporal data mining: An overview. *KDD 2001 Workshop on Temporal Data Mining*.
- AYATA, D., YASLAN, Y. & KAMASAK, M., 2017. EMOTION RECOGNITION VIA GALVANIC SKIN RESPONSE: COMPARISON OF MACHINE LEARNING ALGORITHMS AND FEATURE EXTRACTION METHODS. *Istanbul University - Journal of Electrical and Electronics Engineering*, Volume 17, p. 3129.
- Berg, R. A. v. d. et al., 2006. Centering, scaling, and transformations: improving the biological information content of metabolomics data. *BMC Genomics*.
- Boswell, D., 2002. Introduction to Support Vector Machines.
- Boucsein, W., 2012. *Electrodermal Activity* 2nd. s.l.:Springer.
- Bramer, M., 2013. *Principles of Data Mining*. s.l.:Springer.
- Burges, C. J., 1998. A Tutorial on Support Vector Machines for Pattern Recognition. *Data Mining and Knowledge Discovery*, 2(2), pp. 121-167.
- Campbell, C. & Cristianini, N., 1998. Simple Learning Algorithms for Training Support Vector Machines. *CiteSeerXbeta*.
- Campbell, C. & Ying, Y., 2011. *Learning with Support Vector Machines*. s.l.:Morgan & Claypool Publishers.
- Cortes, C. & Vapnik, V., 1995. Support-Vector Networks. *Machine Learning - Kluwer Academic Publishers, Boston.*, pp. 273-297.
- Devroye, L., Györfi, L. & Lugosi, G., 2013. Automatic Nearest Neighbor Rules. In: *A probabilistic theory of pattern recognition*. s.l.:Springer, pp. 451-460.
- Dietterich, T. G., 2002. Machine Learning for Sequential Data: A Review. *Proceedings of the Joint IAPR International Workshop on Structural, Syntactic, and Statistical Pattern Recognition*, pp. 15-30.
- Famili, A., Shen, W.-M., Weber, R. & Simoudis, E., 1997. Data Preprocessing and Intelligent Data Analysis. *Intelligent Data Analysis*, 1(1), pp. 3-23.
- Fawcett, T., 2006. An introduction to ROC analysis. *Pattern Recognition Letters - Special issue: ROC analysis in pattern recognition*, 27(8), pp. 861-874 .
- García, S., Luengo, J. & Herrera, F., 2014. *Data Preprocessing in Data Mining*. s.l.:Springer.

- Gellman, M. D. & Turner, J. R., 2013. *Encyclopedia of Behavioral Medicine*. s.l.:Springer.
- Grimes, D. et al., 2008. Feasibility and Pragmatics of Classifying. *CHI 2008 Proceedings · Cognition, Perception, and Memory*.
- Guo, R. et al., 2013. Pervasive and Unobtrusive Emotion Sensing for Human Mental Health. *PervasiveHealth '13 Proceedings of the 7th International Conference on Pervasive Computing Technologies for Healthcare*, pp. 436-439.
- Han, J., Kamber, M. & Pei, J., 2011. *Data Mining: Concepts and Techniques 3rd*. San Francisco: Morgan Kaufmann Publishers Inc..
- Hastie, T., Tibshirani, R. & Friedman, J., 2001. *The Elements of Statistical Learning*. s.l.:Springer New York Inc.
- iMotions, 2016. *iMotions*. [Online] Available at: imotions.com [Accessed Mei 2017].
- JAPKOWICZ, N. & SHAH, M., 2011 . *Evaluating Learning Algorithms: A Classification Perspective*. New York: Cambridge University Press .
- Kabacoff, R. I., 2015. *R in action: data analysis and graphics with R*. 2nd ed. s.l.:Manning Publications Co..
- Kuhn, M. & Johnson, K., 2013. *Applied Predictive Modeling*. s.l.:Spinger.
- Kurniawan, H., Maslov, A. & Pechenizkiy, M., 2013. Stress detection from speech and Galvanic Skin Response signals. *Computer-Based Medical Systems (CBMS)*.
- Lijffijt, J., Papapetrou, P. & Puolamaki, K., 2012. Size Matters: Finding the Most Informative. *ECML PKDD'12 Proceedings of the 2012 European conference on Machine Learning and Knowledge Discovery in Databases*, Volume 2, pp. 451-466 .
- Liu, D. & Ulrich, M., 2013-2014. Listen to Your Heart: Stress Prediction Using Consumer Heart Rate Sensors. *CS229 Machine Learning Autumn* .
- Liu, M., Fan, D., Zhang, X. & Gong, X., 2016. Human Emotion Recognition Based On Galvanic Skin Response signal Feature Selection and SVM. *International Conference on Smart City and Systems Engineering*.
- Liu, Y., Sourina, O. & Nguyen, M. K., 2010. Real-time EEG-based Human Emotion Recognition and Visualization. *CW '10 Proceedings of the 2010 International Conference on Cyberworlds*, pp. 262-269.
- Li, X. & Marlin, B., 2015. Classification of Sparse and Irregularly Sampled Time Series with. *Proceeding UAI'15 Proceedings of the Thirty-First Conference on Uncertainty in Artificial Intelligence*, pp. 484-493.
- Lu, Y., Zheng, W.-L., Li, B. & Lu, B.-L., 2015. Combining Eye Movements and EEG to Enhance Emotion Recognition.

- Proceedings of the Twenty-Fourth International Joint Conference on Artificial Intelligence (IJCAI 2015).*
- MacKenzie, I. S., 2013. *Human-Computer Interaction: An Empirical Research Perspective*. 1st ed. San Francisco: Morgan Kaufmann Publishers Inc.
- Meyer, D., 2017. Support vector machines. The Interface to libsvm in package.. *CranR*.
- Mitsa, T., 2010. *Temporal Data Mining 1st*. s.l.:Chapman & Hall/CRC.
- Muller, K.-R. et al., 2001. An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, 12(2), pp. 181 - 201.
- Mundell, C., Vielma, J. P. & Zaman, T., 2016. Predicting Performance Under Stressful Conditions Using Galvanic Skin Response. *CoRR: computing research repository*.
- Pappa, G. L. & Freitas, A. A., 2006. Automatically Evolving Rule Induction Algorithms. *17th European Conference on Machine Learning ECML 2006*, p. 341.
- Picard, R. W., 1997. *Affective Computing*. MIT Press.
- Ringeval, F. et al., 2015. Prediction of Asynchronous Dimensional Emotion Ratings from Audiovisual and Physiological Data. *Pattern Recognition Letters*, Volume 66, pp. 22-30.
- Sokolova, M. & Lapalme, G., 2009. A systematic analysis of performance measures for classification tasks. *Information Processing and Management: an International Journal*, 45(4), pp. 427-437.
- Solovey, E. T. et al., 2014. Classifying Driver Workload Using Physiological and Driving Performance Data: Two Field Studies. *Proceeding CHI '14 Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*, pp. 4057-4066 .
- Stikic, M., Johnson, R. R., Tan, V. & Berka, C., 2014. EEG-based classification of positive and negative affective states. *Brain-Computer Interfaces*, 1(2), pp. 99-112.
- Villarejo, M. V., Zapirain, B. G. & Zorrilla, A. M., 2012 . A Stress Sensor Based on Galvanic Skin Response (GSR) Controlled by ZigBee. *Sensors (Basel, Switzerland)*.
- Wei, C.-Y., Dimitrova, N. & Chang, S.-F., 2004. Color-Mood Analysis of Films Based on Syntactic and Psychological Models. *In IEEE International Conference on Multimedia and Expo (ICME)*.
- Widodo, A., Budi, I. & Widjaja, B., 2016. Automatic lag selection in time series forecasting using multiple kernel learning. *International Journal of Machine Learning and Cybernetics*, 7(1), pp. 95-110.

Lampiran



Lampiran 1 - Kontrak Kerja Penelitian Tugas Akhir



KONTRAK KERJA PENELITIAN TUGAS AKHIR

Yang bertanda tangan di bawah ini,

Nama : **Ir. Djoko Budiyanto Setyohadi M.Eng. , PhD**
NPP/NIDN : **08.93.463 / 0513096501**

Selaku ketua tim Penelitian Kompetitif UAJY tahun anggaran 2017 dengan judul "PENGEMBANGAN DESAIN ANTAR MUKA MEDIA PEMBELAJARAN AUDIO-VISUAL DENGAN KANSEI ENGINEERING" sebagai **pemberi tugas**

dan

Nama : **Sebastian Bagya Gunawan**
No. Mahasiswa : **140707815**

Selaku mahasiswa sebagai **penerima tugas**,

sepakat untuk melakukan kontrak kerja yaitu sebagai anggota tim peneliti dengan penyusunan tugas akhir dengan ketentuan sebagai berikut:

1	Mahasiswa menandatangani kontrak kerja dan kesepakatan pemberian tugas pekerjaan terkait penelitian sebagai topik penyusunan tugas akhir.
2	Masa kerja mahasiswa selama 6 (enam) bulan setelah penandatanganan kontrak.
3	Mahasiswa terlibat aktif dalam pelaksanaan penelitian sesuai dengan topik tugas akhir yang telah disepakati dengan pemberi tugas.
4	Mahasiswa wajib memberikan laporan kemajuan tugas akhir maupun pelaksanaan penelitian minimal satu minggu sekali sesuai jadwal yang disepakati dengan pemberi tugas.
5	Mahasiswa berhak menerima subsidi biaya tugas akhir sebesar Rp 800.000 (delapan ratus ribu rupiah) dipotong pajak sesuai ketentuan yang berlaku dan sertifikat sebagai anggota tim peneliti dari Fakultas Teknologi Industri UAJY.
6	Hasil skripsi menjadi milik tim peneliti

Demikian isi kontrak kerja ini, semoga dapat dipergunakan sebagaimana mestinya, dan masing-masing pihak yang terlibat akan menunaikan kewajibannya hingga selesai.

Disetujui

Yogyakarta, 14 Agustus 2017

Pemberi Tugas,

Ir. Djoko Budiyanto Setyohadi M.Eng. , PhD



Sebastian Bagya Gunawan

Lampiran 2 - Model Skala PANAS (Positive and Negative
Affect Schedule)



PANAS merupakan metode pengukuran kecenderungan sebelum eksperimen. Pengukuran tersebut terdiri atas beberapa tahap, yaitu uji reliabilitas, uji homogenitas dan uji manipulasi.

Uji Reliabilitas

Reliabilitas yang digunakan dalam penelitian ini menggunakan metode *Cronbach's Alpha* yang merupakan reliabilitas berdasarkan konsistensi internal. Hasil estimasi reliabilitas dapat dilihat pada tabel dibawah ini.

Aitem	Korelasi aitem-total	Cronbach's Alpha jika aitem dihapus	Aitem	Korelasi aitem-total	Cronbach's Alpha jika aitem dihapus
anak	0.154	0.791	jari	0.171	0.790
baju	0.516	0.772	kapal	0.394	0.778
bambu	0.227	0.787	mata	0.273	0.785
bola	0.279	0.785	mobil	0.349	0.781
buku	0.273	0.785	nasi	0.258	0.785
bulan	0.362	0.780	obat	0.525	0.771
bumi	0.384	0.779	orang	0.153	0.791
burung	0.290	0.784	perahu	0.394	0.779
cahaya	0.501	0.772	pesawat	0.372	0.780
daging	0.516	0.772	rambut	0.109	0.794
emas	0.408	0.778	sekolah	0.278	0.785
ibu	0.230	0.787	tali	0.409	0.777
N		38			38
Cronbach's Alpha					0,789

Reliabilitas skala PANAS diestimasi pada skala afeksi positif dan negatif dalam kondisi baseline. Koefisien reliabilitas pada skala PANAS afeksi positif menunjukkan hasil 0,606. Sedangkan reliabilitas pada skala PANAS afeksi negatif menunjukkan koefisien sebesar 0,765. Hasil selengkapnya dapat dilihat pada tabel dibawah ini.

Skala Afeksi Positif			Skala Afeksi Negatif		
Aitem	Korelasi aitem-total	Cronbach's Alpha jika aitem dihapus	Aitem	Korelasi aitem-total	Cronbach's Alpha jika aitem dihapus
Tertarik	-0,155	0,663	Sedih	0,317	0,761
Tekun	0,402	0,548	Tertekan	0,410	0,749
Perhatian	0,164	0,608	Bersalah	0,540	0,729
Bergairah	0,339	0,565	Ngeri	0,354	0,755
Kuat	0,253	0,587	Bermusuhan	0,476	0,744

Antusias	0,510	0,533	Jengkel	0,433	0,745
Bangga	0,298	0,576	Malu	0,263	0,766
Waspada	0,134	0,620	Gugup	0,239	0,769
Terinspirasi	0,489	0,528	Gelisah	0,682	0,707
Aktif	0,422	0,548	Takut	0,617	0,721
N	38				38
Cronbach's Alpha	0,606				0,765

Uji Homogenitas

Uji homogenitas pada faktor *between-subject* dilakukan dengan menggunakan *Levene's Test for Equality of Variance*. Hasil uji homogenitas PANAS dapat dilihat pada tabel dibawah ini.


	Afeksi Positif		Afeksi Negatif		
	F (1,36)	p	F (1,36)	p	
<i>Baseline</i>	2,383	0,131	0,092	0,763	
Kondisi Netral	1,408	0,243	0,896	0,350	
Kondisi Positif	3,610	0,065	0,460	0,502	
Kondisi Negatif	0,015	0,904	0,992	0,343	
N					38

Hasil uji homogenitas GSR, bisa dilihat pada tabel dibawah ini.

	F (1,31)	p	
Kondisi Netral	4,973	0,033*	
Kondisi Positif	0,171	0,682	
Kondisi Negatif	6,008	0,020*	
N			33

Uji Manipulasi

Uji Manipulasi dilakukan dengan menjalankan *Repeated Measures ANOVA* pada skala PANAS. Manipulasi dikatakan berhasil apabila terdapat perbedaan skor PANAS kondisi perlakuan relatif terhadap *baseline*, serta perbedaan dalam tiap kondisi perlakuan. Data deskriptif dua sub-skala PANAS dapat dilihat pada tabel dibawah ini.



	Afeksi Positif				Afeksi Negatif			
	Mean	SD	Min	Max	Mean	SD	Min	Max
Baseline	3,566	0,4828	2,3	4,3	2,171	0,6182	1,2	4
Kondisi Netral	3,229	0,6049	1,5	4,4	2,021	0,748	1	4,1
Kondisi Positif	3,284	0,5659	1,8	4,2	1,992	0,7585	1	4,4
Kondisi Negatif	3,239	0,6262	1,4	4,2	2,339	0,7387	1,1	4,1

Kesimpulan

Peneliti menyimpulkan dari hasil skala PANAS bahwa pemberian induksi afeksi berhasil mengubah kondisi afeksi positif dari baseline walaupun belum efektif untuk membedakan dari kondisi perlakuan yang lainnya. Sementara itu, hasil pada sub-skala afeksi negatif menunjukkan bahwa kondisi perlakuan negatif berhasil menginduksi afeksi negatif relatif terhadap kondisi perlakuan yang lainnya. Terdapat kemungkinan kesalahan pengukuran yang disebabkan oleh skala PANAS sub-skala afeksi positif karena beberapa aitem memiliki interkorelasi antar-aitem yang relatif rendah.

Lampiran 3 - Pseudocode



```

Function PreprocessData(mainDataFrame, frequency, lag, data)
return dataframe
    Initialize positif to data.positif
    Initialize netral to data.netral
    Initialize negatif to data.negatif

    Initialize positifAgregasi as
        Aggregate(data.positif, frequency, formula = mean)
    Initialize netralAgregasi as
        Aggregate(data.netral, frequency, formula = mean)
    Initialize negatifAgregasi as
        Aggregate(data.negatif, frequency, formula = mean)

    Initialize positifNormalisasi as
        Normalize(positifAgregasi)
    Initialize netralNormalisasi as
        Normalize(netralAgregasi)
    Initialize negatifNormalisasi as
        Normalize(negatifAgregasi)

    Initialize positifSlidingWindows as
        generate SlidingWindows(positifNormalisasi, lag)
    Initialize netralSlidingWindows as
        generate SlidingWindows(netralNormalisasi, lag)
    Initialize negatifSlidingWindows as
        generate SlidingWindows(negatifNormalisasi, lag)

    add label "positif" to positifSlidingWindows
    add label "netral" to netralSlidingWindows
    add label "negatif" to negatifSlidingWindows

    add MergeDataFrame(positifSlidingWindows,
        netralSlidingWindows, negatifSlidingWindows)
        to mainDataFrame

```

```
        return mainDataFrame
    end Function
```

Main

```
Initialize mainDataFrame as empty dataframe
Initialize frequency to 103
Initialize lag to 0
Initialize trainSize to 70
Initialize testSize to 30
For i in 4:40
    Set lag to -(i)
    //Menggunakan data sebesar t-i. Misalkan i = -4
    maka akan terbentuk 5 kolom yang terdiri atas data
    t-4, t-3, t-2, t-1 dan t-0.

    Set mainDataFrame to
        PreprocessData(mainDataFrame, frequency,
            lag, readData(Responden-1.csv))
    Set mainDataFrame to
        PreprocessData(mainDataFrame, frequency,
            lag, readData(Responden-2.csv))
    Set mainDataFrame to
        PreprocessData(mainDataFrame, frequency,
            lag, readData(Responden-40.csv))
end For

Initialize modelData as generate
    SplitSample(mainDataFrame, trainSize, testSize)
    //akan terbentuk modelData.train dan
    modelData.test

Initialize modelTrained as generate
    Model(modelData.train, Algorithm = SVM)
```

```
Initialize testResult as generate
    Test(modelTrained, modelData.test)
Show testResult
Draw ROC(testResult)
end Main
```

