



Hibrid Çok Değişkenli Görgül Kip Ayrışımı ve Senkrosıkıştırma Dönüşümü Kullanılarak Duygu Durum Sezimi

Emotional State Sensing by Using Hybrid Multivariate Empirical Mode Decomposition and Synchrosqueezing Transform

Pınar ÖZEL¹ ve Aydın AKAN²

¹Elektrik-Elektronik Mühendisliği Bölümü

²Biyomedikal Mühendisliği Bölümü

¹Nevşehir Hacı Bektaş Veli Üniversitesi, Nevşehir, Türkiye

²İzmir Katip Çelebi Üniversitesi, İzmir, Türkiye

pinarozel@nevsehir.edu.tr, aydin.akan@ikc.edu.tr

Bülent YILMAZ³

³Elektrik-Elektronik Mühendisliği Bölümü

Abdullah Gül Üniversitesi

Kayseri, Türkiye

bulent.yilmaz@agu.edu.tr

Özetçe—Son yıllarda Hilbert tabanlı zaman frekans analizi kullanılarak yapılan duygu durum modelleme beyin bilgisayar arayüzü çalışmalarında önemli bir yer tutmaktadır. Öncelikle Hilbert dönüşümü tabanlı Görgül Kip Ayrışımının duygu durum modelleme çalışmalarında uygunluğu dikkat çekmiştir. Daha yeni çalışmalarda ise Görgül Kip Ayrışımı (GKA) sonrası elde edilen özgül kip fonksiyonlarına uygulanan zaman, frekans, zaman-frekans domenli özniteliklerle sınıflandırmalar gerçekleştirilmiştir. Bu çalışmada Çok Değişkenli GKA kullanılarak elde edilen özgül kip fonksiyonlarına Senkrosıkıştırma Dönüşümü uygulandıktan sonra elde edilen senkrosıkıştırma katsayılarına ait özniteliklerle sınıflandırmanın yapıldığı bir duygu durum analizi önerilmiştir. Böylelikle, DEAP veri tabanındaki EEG dataları üzerinde değerlik, aktivasyon ve baskınlık boyutları için düşük/yüksek sınıflandırmaları yapılmış ve sınıflandırma aşamasında 4 farklı sınıflandırıcı kullanılmıştır. Değerlik, aktivasyon ve baskınlık boyutlarında sırasıyla en iyi %76, %68 ve %68 sınıflandırma oranları elde edilmiştir.

Anahtar Kelimeler — Duygu Durum Analizi; EEG; Çok Değişkenli Görgül Kip Ayrışımı; Senkrosıkıştırma Dönüşümü

Abstract—In recent years, utilizing Hilbert-based time-frequency methods in emotional state sensing research attracted attention in the brain computer interfaces. Primarily, Hilbert Transform-based empirical mode decomposition (EMD) was found to be suitable for emotional state modeling studies. In more recent studies, models of emotional state recognition were proposed in which the classification was implemented by using the features obtained after applying the time, frequency, and time-frequency domain methods to intrinsic mode functions achieved by operating EMD. In this study, an analysis of emotional state recognition is proposed by using the features of the synchrosqueezing coefficients obtained in the classification

process after applying the Synchrosqueezing Transform to intrinsic mode functions achieved by using Multivariate EMD. As a result, EEG data available in the DEAP database were categorized as low and high for valence, activation, and dominance dimensions, and 4 different classifiers were utilized in the classification process. The most satisfying ratios of valence, activation and dominance were attained 76%, 68%, and 68% respectively.

Keywords — Emotional State Analysis; EEG; Multivariate Empirical Mode Decomposition; Synchrosqueezing Transform

I. GİRİŞ

Duygu durum analizi çalışmaları son yıllarda farklı metotlar ve duygu durum modelleri ile insan makina arası iletişimin kolaylaşmasına katkı sağlamaktadır. Duygu modellemede hibrid model kavramı da son yıllarda Hilbert tabanlı görgül kip ayrışımı (GKA) ve görgül dalgacık dönüşümü (GDD) gibi yöntemlerden elde edilen özgül kip fonksiyonları (ÖKF) sonrası osilasyonun taşıdığı bilgiden daha fazla faydalanmak için farklı bir yöntem daha önerilmesi ile elde edilir. İlk olarak, Petrantonakis ve arkadaşları [1] duyguya bağlı EEG özelliklerinin etkin bir şekilde çıkarılması için yeni bir filtreleme prosedürü olan hibrid adaptif filtreleme (HAF) yöntemini, EEG sinyallerinin GKA analizine dayalı temsiline genetik algoritma uygulayarak geliştirmiştir. Ek olarak, HAF filtreli sinyallerden öznitelik çıkarımı gerçekleştirilmesi için yüksek mertebeden geçişler (YMG, *İng. Higher Order Crossings*) analizi kullanılmıştır. Benzer şekilde Zhang ve arkadaşları [2] önerdikleri EEG tabanlı duygu durum analizi



modelinde, GKA sonrası elde edilen ÖKF'lere örnek entropi (*İng. Sample Entropy*) yöntemini uygulayarak duygu durum sınıflandırması üzerinde çalışmışlardır. Bhuiyan ve Das [3] EEG sinyaline GKA uyguladıktan sonra ayırık dalgacık dönüşümü (ADD) yöntemi kullanarak spektral entropi bazı öznelikleri duygu durum analizinde kullanmışlardır. Shannaz C. ve diğ. [4] mevcut duygusal ses sinyallerini doğrudan işlemek yerine, önce GKA yöntemini kullanarak ÖKF'leri çıkarıp, daha sonra baskın ÖKF'lere ADD uygulamıştır.

Bunların dışında, son yıllardaki GKA'nın çok değişkenli uzantısının önerilmesi ile hibrid model kullanımında çok değişkenli GKA (ÇDGKA) yöntemine doğru geçiş olmuştur. Mert ve Akan [5] ÇDGKA algoritmasından elde edilen ÖKF kümelerinin güç spektral yoğunluğu (GSY) entropi, Hjorth parametreleri, korelasyon ve sol ve sağ yarıküredeki asimetrik özellikleri hesaplayarak duygu durum tanıma doğruluğunu arttırmak için özellik vektörünü zenginleştirerek sınıflandırmayı gerçekleştirmiştir. Tonoyan ve arkadaşları [6] çok değişkenli, çoklu ölçekli entropi (*İng. multivariate multiscale entropy*) uzantılı ÇDGKA ile duygu durum analizi değerlendirmesi gerçekleştirmişlerdir. Bunlara ek olarak, [7] ve [8] çalışmalarında ÇDGKA sonrası elde edilen ÖKF'lere farklı yöntemler uygulayarak elde edilen özneliliklerle duygu durum analizi sınıflandırması gerçekleştirmişlerdir.

Hibrid GKA ve ÇDGKA yöntemlerinden farklı olarak, Huang ve arkadaşları [9] çalışmasından GDD yöntemini kullanarak sinyali ÖKF'lerine ayırıp, seçilen ÖKF'lerin otoregresif model katsayılarını hesaplamışlardır. Ayrıca, duygu durum analizi çalışmaları dışında ÖKF'den sonra kullanılacak optimum yöntem önerisi üzerine çalışmalar da devam etmektedir [10 - 15].

Gelişen teknoloji ve insan-makine etkileşiminin artışı ile etkili bir duygu durum analizi gerçekleştirebilmek ve bir duygunun türleri ile seviyelerini anlamak ve açıklamak gereksinimi ile ortamı uygun sayısal duygu modelleri ile donatmak gerekir. Duygu sınıflandırması ayırık model olarak Ekman ve Friesen [16] ve Parrot'un ağaç yapısı [17] tarafından önerilen mutluluk, üzüntü, korku, sevinç, öfke, kafa karışıklığı ve iğrenme gibi altı temel duygu olarak, bunun dışında boyutsal model olarak iki boyutlu ve üç boyutlu ele alınıp iki boyutlu modelde circumplex model [18], vektör modeli [19], PANA modeli [20], rSASM modeli, 12-PAC modeli [21], üç boyutlu model olarak Lövheims küpü [22], PAD modeli [23] ve hem ayırık hem boyutsal model olarak Plutchik modeli ve kum saati modeli [24] olarak incelenmektedir.

Duygu durum analizi sürecinde bir başka önemli boyut, sınıflandırıcının kullanıcı bağımlı verilerle eğitilip eğitilmediğidir. Kullanıcıya dayalı veriler olduğu durumda, her kullanıcı için yeni bir model oluşturulur ve test adımı bu kullanıcı verileriyle de yapılır. Genellikle, daha iyi sonuçlar elde edilir, ancak genelleme yapmanın dezavantajını göz önünde bulundurmak gerekir. Kullanıcıdan bağımsız bir modelde, birden çok kullanıcının verileri hem eğitim hem de test amaçlı kullanılmıştır. Bu, modelde yeni bir model oluşturmaya gerek

duyulmadığı yeni kullanıcılara daha kolay uygulanabilir olması avantajını sağlar [25].

Bazı çalışmalarda, yerinde duygu tanıma kavramı oldukça önemlidir, bu nedenle bu uygulamalarda çevrimiçi yöntemler kullanılmalıdır. Gerçek zamanlı uygulamada kullanılması için tercih edilecek yöntemin hızı, doğruluğu ve pratikliği de göz önünde bulundurulmalıdır. Fraktal dönüşüm ve dalgacık dönüşümü bunlardan ikisidir. Örneğin, Iacoviello ve arkadaşları, dalgacık dönüşümü kullanarak çevrim içi uygulamalarda EEG sinyalleri için etkili ve genel bir sınıflandırma yöntemi geliştirmiştir. Sourina ve arkadaşları müzik uyarımını takiben fraktal dönüşümü kullanarak beyin tepkilerini incelemişlerdir. Diğer tip duygu tanıma sistemleri çevrim dışı olarak bilinir. Çalışmaların %90'a yakını çevrim dışı çalışmadır [25] [26].

Duygu algılamadaki son gelişmeler, duygu durum veritabanlarını oluşturmak için çok sayıda araştırmacıyı teşvik ederek bu çalışmalarda kullanılacak veritabanı önerilerinin yolunu açmıştır. Duygu durum veritabanlarının içeriği genel olarak fizyolojik duygu verisi olanlardan bazıları DREAMER [27], SEED [28], EMOEEG [29], AMIGOS [30], ASCERTAIN [31], MIT [32], HUMAINE [33], MAHNOB-HCI [34] ve DEAP [35] ve eINTERFACE [36] veritabanlarıdır. Ayrıca, DEAP, DREAMER, EMOEEG, AMIGOS, ASCERTAIN veritabanları, "değerlik, uyarılma, baskınlık, beğenme, aşinalık", "değerlik, uyarılma, baskınlık", "değerlik, uyarılma", "değerlik, uyarılma" gibi katılımcının kendini raporlayan notları içerir. Ancak, genel olarak tercih söz konusu olduğunda DEAP veri tabanı, literatürde katılımcının öz değerlendirmesi açısından bir numaralandırma içermesinin yanı sıra farklı fizyolojik duygu verileri de içermesiyle yayımlandığı tarihten günümüze farklı yaklaşımların karşılaştırılmasında kullanılan standart bir veritabanı gereksinimini doldurmuştur.

Bu çalışmada, ilk basamak olarak, duygusal olarak uyarılmış EEG sinyallerinin, ÖKF kümesini elde etmek amacıyla ÇDGKA algoritması uygulanmıştır. Sonrasında, daha iyi bir zaman frekans çözünürlüğü elde etmek amacıyla seçilen ÖKF'lere SSD uygulanıp, senkro-sıkıştırma katsayıları öznelikleri çalışılmıştır. Farklı sınıflandırıcı performansları sonuçlar ve değerlendirme kısmında sunulmuştur. Bölüm II'de duygu durum analizi içeriği anlatılırken, Bölüm III'te uygulanan yöntemin aşamaları, öznelilik çıkarım ve sınıflandırma yöntemleri ele alınmıştır. Bölüm IV'te çalışmanın sonuçları ve değerlendirilmesine yer verilmiştir.

II. YÖNTEM

DEAP veritabanında [35] duygu oluşumunu sağlamak amacıyla 40 adet birer dakikalık duygusal videolar kullanılmıştır. Yaşları 19 ile 37 arasında değişen 32 kişi deney katılmış olup her deneyin sonunda, katılımcılar izledikleri her videodaki gerçek duygularıyla ilgili bir duygu durum derecelendirmesi sağlayan anket doldurmuştur. Doldurulan anket değerleri sonucu elde edilen uyarılma, değerlik ve baskınlık boyut değerleri duygu durum sınıflandırma sürecinde kullanılmıştır. Her boyutta, yüksek ve düşük seviyelerden



oluşan iki sınıf kabul edilmiştir. Bu veritabanında, her kanal için 8064 örneklemeyle toplam 1280 (32*40) deneme bulunmaktadır. Önerilen yöntemde, DEAP veritabanındaki ilk 5 kişiye izletilen ilk 5 video ile diğer çalışmalarımızda kullanılan aynı elektrot düzeni kullanılarak 26 girişlik elektrot düzeni ÇDGKA algoritmasına verilmiştir. Algoritma sonucu elde edilen ÖKF'lerden ana sinyal ile korelasyonu en yüksek ÖKF sinyali seçilip SSD algoritması uygulanmıştır. Sonrasında elde edilen senkrosıkıştırma katsayıları sınıflandırma sürecinde kullanılmıştır. Öznitelik çıkarma işleminde kullanılan ÇDGKA ve SSD yöntemleri aşağıdaki gibi özetlenmiştir.

A. Çok Değişkenli Görgül Kip Ayrışımı

Rehman ve Mandic 'in geliştirdiği ÇDGKA standart GKA'nın uzantısıdır [5] [37]. Standart GKA, aşağı ve yukarı zarfların ortalamasını kullanarak yerel ortalamayı hesaplama ilkesine dayanır. Ancak, n boyutlu bir sinyalin yerel ortalaması söz konusu olduğunda durum farklıdır, bu durumda yerel ortalama direk hesaplanamaz ve sinyalin değişken uzaylarda, farklı yönler boyunca yansıtılarak çok boyutlu zarfları üretilir. Daha sonra yerel ortalamayı elde etmek amacıyla bu yansıtımların ortalaması alınır.

B. Senkrosıkıştırma Dönüşümü

SSD, durağan olmayan sinyallerin kompakt bir zaman frekans temsili oluşturacak şekilde sürekli dalgacık dönüşümüne uygulanan bir işlem sonrası tekniğidir. SSD başlangıçta ses sinyali ayrışması amacı ile sunulmuştur ve GKA'ya bir alternatif olarak ortaya çıkmıştır. Sürekli dalgacık dönüşümü (SDD), dalgacıklar olarak bilinen zaman frekans filtrelerinin ilerlemesi ile, ilgilenilen salınım unsurlarını tanıyan bir projeksiyon tabanlı algoritma olmasına rağmen, SSD zaman içinde değişen bir davranışa sahip olan bir sinyali elementlerine ayrıştırmayı amaçlamaktadır. Buna göre sinyaller, bireysel zaman frekansı uyumlu bileşenlerin "(1)" hali ile genişletilmesi olarak hesaplanabilir:

$$s(t) = \sum_{k=1}^K A_k(t) \cos(Q_k(t)) + \eta(t) \quad (1)$$

Bir sinyalin sürekli dalgacık dönüşümü s(t) ise "(2)"de sunulur;

$$W_s(a, b) = \int a^{-1/2} \psi * \left(\frac{t-b}{a} \right) s(t) dt \quad (2)$$

Burada, ψ^* , ana dalgacıklarının karmaşık konjügesidir ve b, "a" ile ölçeklendirilen ana dalgacıklarına yapılan zaman kaymasıdır. SDD, s(t) sinyalinin, orijinal ana dalgacıkların biçimlerinin ve çözülen çok sayıda dalgacık ile çapraz korelasyonudur. $W_s(a, b)$ işaretleri, anlık frekansları çıkarmak için kullanılan bir kompakt zaman frekansı temsili sunan katsayılarıdır. Buradaki amaç, SDD'de oluşan bulanıklık etkisini azaltmaktır. Bu bulanıklık temelde "a" ölçeğinde mevcuttur, çünkü sabit zaman kayması "b" için eğer zaman eksenini boyunca bulanıklık göz ardı edilemezse, o zaman anlık frekans $w_s(a, b)$ SDD'nin türevi olarak hesaplanabilir. "w" (a, b) $\neq 0$ için "b" ile ilgili herhangi bir noktada $w_s(a, b)$ "(3)" de verilmiştir.

$$w_s(a, b) = \frac{-j}{2\pi W_s(a, b)} \frac{\partial W_s(a, b)}{\partial b} \quad (3)$$

Zaman frekans temsilindeki son basamak, bilgiyi zaman ölçeği alanından zaman frekans alanına göre tasarlamaktır. Her bir nokta (b, a), (b, $w_s(a, b)$) 'ye değiştirilir ve bu işlem, Senkrosıkıştırma olarak bilinir, çünkü a ve b ayrı değerlerdir ve ölçeklendirme adımı, $\Delta a_k = a_{(k-1)} - W_s(a, b)$ herhangi bir a_k için hesaplanabilir.

III. SONUÇLAR VE DEĞERLENDİRME

Çalışmamızda EEG sinyallerinden duygu durum analizi çalışmasında ÇDGKA ve SSD yöntemleri bir arada kullanılarak yeni bir model önerilmiştir. Sınıflandırma sonuçları çevrim dışı, kullanıcı bağımsız olmak üzere DEAP veritabanı kullanılarak değerlendirilmiştir. Tablo I'de elde edilen değerlere göre en iyi sınıflandırma sonuçları uyarılma düzleminde elde edilmiş olup, en iyi sınıflandırıcı sonuçları destek vektör makinesi ve en yakın komşu sınıflandırıcıda elde edilmiştir. Buna göre karar ağacı sınıflandırıcının değerlik ve baskınlık sınıflandırıcı sonuçları tatmin edici bulunmamıştır. Sınıflandırma sonuçları uyarılma boyutu için 75% civarı değişirken, baskınlık ve değerlik boyutlarında bu değer 65% dolaylarındadır. İlerleyen çalışmalarda SSD algoritmasından özgül kip türleri (ÖKT)'lere elde edilerek sınıflandırma sonucu değerlendirilecektir.

TABLO I. UYARILMA, DEĞERLİK, BASKINLIK PARAMETRELERİ İLE SINIFLANDIRMA ORANLARI

| Uyarılma, Değerlik, Baskınlık Parametreleri ile Sınıflandırma Oranları | Duygu Durum Etiketleri | | |
|--|------------------------|----------|-----------|
| | Uyarılma | Değerlik | Baskınlık |
| KARAR AĞACI | 72% | 36% | 44% |
| DESTEK VEKTÖR MAKİNESİ | 76% | 68% | 68% |
| EN YAKIN KOMŞU SINIFLANDIRICI | 76% | 60% | 68% |
| TOPLULUK SINIFLANDIRICI | 71% | 60% | 56% |

KAYNAKLAR

- [1] Petrantonakis, P.C, Hadjileontiadis, L.J., "Emotion Recognition from Brain Signals Using Hybrid Adaptive Filtering and Higher Order Crossings Analysis", *IEEE Transactions on Affective Computing*, cilt 1, no. 2, pp. 81-97, 2010.
- [2] Zhang, Y., Ji, X., Zhang, S., "An approach to EEG-based emotion recognition using combined feature extraction method.", *Neuroscience Letter*, cilt 633, pp. 152-157, 2016.
- [3] Bhuiyan, M.I.H., Das, A.B., "Discrimination and classification of focal and non focal EEG signals using entropy based features in the EMD-DWT", *Biomedical Signal Processing and Control*, cilt 29, pp. 11-21, 2016.
- [4] Shannaz, C., Sultana, S., Fattah, S.A., Rafi, R.H.M., Ahmed, I., Zhu, W.-P., Ahmad, M.O., "Emotion recognition based on EMD-Wavelet analysis of speech signals", *IEEE International Conference on Digital Signal Processing (DSP)*, London, 2015.



- [5] Mert,A., Akan,A., "Emotion recognition from EEG signals by using multivariate empirical mode decomposition",*Pattern Analysis and Applications*, pp. 1-9, 2016
- [6] Tonoyan, Y., Looney, D., Mandic, D. P., Hulle, M.M.V., "Discriminating Multiple Emotional States from EEG Using a Data-Adaptive, Multiscale Information-Theoretic Approach", *International Journal of Neural Systems*, cilt 26, no. 2, p. 1650005 (15 sayfa) 2016.
- [7] Xu, H., Plataniotis, K.N., "Application of Multivariate Empirical Mode Decomposition in EEG signals for Subject Independent Affective States Classification", *International Journal of Communications*, cilt 9, pp. 91-97, 2015.
- [8] Guitton, C., "Emotions Estimation from EEG Recordings", London: Imperial College of Science, Technology & Medicine Department of Electrical& Electronic Engineering, 2010.
- [9] Huang, D., Zhang, S., Zhang, Y., "EEG-based emotion recognition using empirical wavelet transform", *The 2017 4th International Conference on Systems and Informatics(ICSAI 2017)*, Hangzhou, China, 2017.
- [10] Yin, Y., Cao, J., Tanaka, T., "EEG energy analysis based on MEMD with ICA pre-processing", *Signal & Information Processing Association Annual Summit and Conference (APSIPA ASC)*, Asia-Pacific, 2012.
- [11] Chen, X., Xu, X., Liu, A., McKeown, M.J., Wang, Z.J. "The Use of Multivariate EMD and CCA for Denoising Muscle Artifacts From Few-Channel EEG Recordings", *IEEE Transactions on Instrumentation and Measurement*, cilt 67, no. 2, pp. 359-370, 2018.
- [12] Chen, Y.-F., Atal, K., Xie, S.-Q., Liu, Q., "A new multivariate empirical mode decomposition method for improving the performance of SSVEP-based brain-computer interface", *Volume 14, Number 4*, cilt 14, no. 4, 2017.
- [13] Huang, J.-R., Fan, S.-Z., Abbod, M.F., Jen, K.-K., Wu, J.-F., Shieh, J.,-S., "Application of Multivariate Empirical Mode Decomposition and Sample Entropy in EEG Signals via Artificial Neural Networks for Interpreting Depth of Anesthesia", *Entropy*, cilt 15, no. 9, pp. 3325-3339, 2013.
- [14] Azami, H., Smith, K., Escudero, J., "MEMD-enhanced multivariate fuzzy entropy for the evaluation of complexity in biomedical signals", *2016 IEEE 38th Annual International Conference of the Engineering in Medicine and Biology Society (EMBC)*, Engineering in Medicine and Biology Society (EMBC), 2016.
- [15] Khosropanah, P., Ramli, A.R., Lim, K.S., Lim, K.S., Ahmedov, A., "Fused multivariate empirical mode decomposition (MEMD) and inverse solution method for EEG source localization", *Biomedical Engineering / Biomedizinische Technik*, 2017.
- [16] Ekman, P., Friesen, W. V, O'Sullivan, M., Chan, A., Diacoyanni-Tarlatzis, I., Heider, K., Ricci-Bitti, P. E., "Universals and cultural differences in the judgments of facial expressions of emotion", *Journal of personality and social*, cilt 53, p. Journal of personality and social, 1987.
- [17] Parrott, W. G., "Emotions in Social Psychology: Essential Readings", Philadelphia, PA: Psychology Press, 2001.
- [18] Russell, J. A. "A circumplex Model of Affect", *Journal of Personal and Social Psychology*, cilt 39, pp. 1161-1178, 1980.
- [19] Bradley, M. M., Greenwald, M. K., Petry, M.C., Lang, P. J, "Remembering Pictures : Pressure & Arousal in Memory", *Journal of Experimental Psychology: Learning, Memory & Cognition*, cilt 2, no. 18, pp. 379-390, 1992.
- [20] Watson, D., Tellegan, A., "Towards a consensual structure of Mood", *Psychological Bulletin*, cilt 98, no. 2, pp. 219-235, 1985.
- [21] Othmana, M., Wahaba, A., Karima, I., Dzulkiplib, M. A., Alshaiklia, I. F. T., "EEG emotion recognition based on the dimensional models of emotions", *Procedia - Social and Behavioral Sciences*, cilt 97, pp. 30-37, 2013.
- [22] Lövheim, H., "A new three-dimensional model for emotions and monoamine neurotransmitters," *Medical Hypotheses*, cilt 78, pp. 341-348, 2012.
- [23] Mehrabian, A., Russell, J. A., "An approach to environmental psychology", *Cambridge, MA: MIT Press*, 1974.
- [24] Cambria, E., Livingstone, A., Hussain, A., "The Hourglass of Emotions" *Cognitive Behavioural Systems*, pp. 144-157, 2012.
- [25] Alarcao, S.M., Fonseca, M. J. "Emotions Recognition Using EEG Signals: A survey", *IEEE Transactions on Affective Computing*, cilt PP, no. 99, pp. 1-1, 2017.
- [26] Soroush, M. Z., Maghooli, K., Setarehdan, S. K., Nasrabadi, A. M., "A review on EEG Signals Based Emotion Recognition", *Int Clin Neurosci J*, cilt 4, no. 4, pp. 118-129, 2017.
- [27] Katsigiannis, S., Ramzan, N., "DREAMER: A Database for Emotion Recognition Through EEG and ECG Signals From Wireless Low-cost Off-the-Shelf Devices", *IEEE Journal of Biomedical Informatics*, cilt 22, no. 1, pp. 98-107, 2018.
- [28] Zheng, W.-L., Lu, B.-L., "Investigating Critical Frequency Bands and Channels for EEG-based Emotion Recognition with Deep Neural Networks", *IEEE Transactions on Autonomous Mental Development*, cilt 7, no. 3, pp. 162-175, 2015.
- [29] Conneau, A. -C., Hajlaoui, A., Chetouani, M., Essid, S., "EMOEEG: a New Multimodal Dataset for Dynamic EEG-based Emotion Recognition with Audiovisual Elicitation", *2017 25th European Signal Processing Conference (EUSIPCO)*, Kos island, Greece, 2017.
- [30] Miranda-Correa, J.A., Abadi, M.K., Sebe, N., Patras, I., "AMIGOS: A Dataset for Affect, Personality and Mood Research on Individuals and Groups," *IEEE Transactions on Affective Computing*, 2017.
- [31] Subramanian, R., Wache, J., Abadi, M., Vieriu, R., Winkler, S., Sebe, N., "Ascertain: Emotion and personality recognition using", *IEEE Trans. on Affective Computing*, cilt PP, no. 99, pp. 1-1, 2016.
- [32] Healey, J. A., Picard, R.W., "Detecting stress during real-world driving tasks using physiological sensors", *IEEE Transactions on Intelligent Transportation Systems*, cilt 6, no. 2, pp. 156 - 166, 2005.
- [33] Douglas-Cowie, E., Cowie, R., Sneddon, I., Cox, C., Lowry, O., McRorie, M., Martin, J.-C., Devillers, L., Abrilian, S., Batliner, A., Amir, N., Karpouzis, K., "The HUMAINE Database: Addressing the Collection and Annotation of Naturalistic and Induced Emotional Data", *Affective Computing and Intelligent Interaction, Second International Conference, ACII*, Lisbon, Portugal, 2007.
- [34] Soleymani, M., Lichtenauer, J., Pun, T., Pantic, M., "A Multimodal Database for Affect Recognition and Implicit Tagging", *IEEE Transactions on Affective Computing*, cilt 3, no. 1, pp. 42-55, 2012.
- [35] Koelstra, S., Mühl, C., Soleymani, M., Lee, J. S., Yazdani, A., Ebrahimi, T., Patras, I., "DEAP: A database for emotion analysis; using physiological signals" *IEEE transactions on affective computing*, cilt 3, pp. 18-31, 2012.
- [36] Savran, A., Ciftci, K., Chanel, G., Mota, J.C., Viet, L.H., Sankur, B., Akarun, L., Caplier, A., Rombaut, M., "Emotion Detection in the Loop from Brain Signals and Facial Images", *Proceedings of the eNTERFACE 2006 Workshop*, Dubrovnik (Croatia), 2006.
- [37] Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., Yen, N.-C., Tung, C.C., Liu, H.H., "The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis", *Proc.Royal Society .Lond.*, cilt 454, pp. 903-995, 1998.