

EEG ile Kiři-Temelli Negatif Duygulanım Kestirimi Individual-based Estimation of Valence with EEG

Bora Cebeci
Elektrik-Elektronik Mühendisliđi
Kırkırelle Üniversitesi
Kırkırelle, Türkiye
bora.cebeci@klu.edu.tr

Aydın Akan
Elektrik-Elektronik Mühendisliđi
İzmir Ekonomi Üniversitesi
İzmir, Türkiye
akan.aydin@ieu.edu.tr

Tamer Demiralp ve Miray Erbey
Fizyoloji Anabilim Dalı
İstanbul Üniversitesi
İstanbul, Türkiye
demiralp@istanbul.edu.tr

Özetçe —Bu çalışmada, negatif değerkli duygusal durum kestiriminde kullanılacak birey bazlı özneliklerin tespiti ve farklı sınıflandırıcılar ile karşılaştırmalı sınıflandırılması yapılmıştır. Emosyonel uyarıcı olarak katılımcılara on film klipi gösterilmiş senkron olarak EEG kaydı alınmıştır. Duygusal değerkli parametresi, her video sonunda katılımcılar tarafından [-7 7] arasında skorlanmış, sınıf ayrımı en düşük ve en yüksek değerk almış video versisine göre yapılmıştır. Veri birey bazlı işlenerek, kişiye özel uzamsal filtreler Bağımsız Bileşen Analizi ile elde edilmiştir. Uzamsal filtrelenmiş verinin spektrogramı hesaplanarak, sınıflar arası farkın yüksek olduğu 3Hz'lik frekans bantları öznelik olarak çıkarılmıştır. İlinti-temelli Öznelik Altküme Seçimi yöntemi ile seçilen öznelikler arasında ağırlıklı olarak çıkan frekans bantları beta ve gama bantlarıdır. Seçilen özneliklerin başarı oranı beş sınıflandırıcı ile çapraz geçerkleme ile test edilmiş, örnek temelli k-en yakın komşuluk algoritması (k-NN) ile çok-katmanlı algılayıcı sınıflandırıcılarından yüksek başarımla elde edilmiştir. K-NN sınıflandırıcı ile ortalama %86±8 doğruluk başarımları, çok-katmanlı algılayıcı ile ortalama %83±9 başarımları sağlanmıştır.

Anahtar Kelimeler—duygu, negatif değerklik, film, EEG .

Abstract—In this study, it is determined individual-based features which are used to estimate emotional negative valence and compared the features effectiveness with different classifiers. Ten movie clips are shown to subjects as an emotional stimuli and EEG recording is recorded synchronously. Emotional valence value is scored in [-7 7] Likert scale by the subjects immediately after video ended. According to lowest and highest valence values, two classes are generated. The data is processed on an individual basis and personal spatial filters is obtained by Independent Component Analysis. After calculating the spectrogram of the spatial filtered data, features are extracted by subtracting amplitudes of 3Hz averaged frequency bands. The result of feature selection, it is observed that features from beta and gamma bands are much more effective. The success rate of the selected features was tested with five classifiers by cross validation, and high performance was obtained from multilayer perceptron classifiers and the instance-based k-nearest neighborhood algorithm (IBk-NN). The average accuracies of IBk-NN and multilayer classifier are achieved 86% ±8 and 83% ±9 , respectively.

Keywords—emotion, negative valence, film, EEG .

I. GİRİŞ

Literatürde en sık kullanılan emosyonel uyarıcı yöntemleri duygusal yüklü fotoğraf ve video göstermektir. Fotoğraf gösteriminde sıklıkla kullanılan ve bir standart haline gelmiş

Uluslararası Duygusal Resim Sistemi (ing. IAPS) uyarıcıları olarak kullanılır. Standart veri tabanı kullanmayan çalışmalarda ise uyarıcıların değerkli (ing. Valence) ve etkilenme (ing. Arouse) gibi duygu durum parametreleri katılımcılar tarafından puanlandırılır. Bu çalışmada da katılımcı puanlaması her bir video bitiminde yapılmıştır. Lenç ve ark. çalışması da duygudurum derecesini ölçmede bireysel niceliklendirmenin bilişsel, davranışsal ve psikolojik cevaplara göre daha etkin olduğu saptanmıştır [1]. Laboratuvar ortamında verimli emosyonel uyarıcı üretmek için film sahneleri kullanılması katılımcıda daha kolay fizyolojik değerişimleri tetikleyebilmektedir [2,3,4]. Fernandez-Aguilar ve ark. duygusal durum tetiklemede filmlerin ne kadar etkili olduğu üzerine bir meta-analiz çalışması yayınlamıştır. Pozitif, nötr ve negatif duygudurum uyarıcılarını içeren çalışmaları analize dahil etmişler. Analiz sonucunda film kliplerinin özellikle negatif duygudurum tetiklemede güçlü olduğu, pozitif duygudurum tetiklemede de etkili olduğu görülmüş [2]. Westermann ve ark. meta-analiz çalışmasında da film klipi gösteriminin duyguları tetiklemede daha etkin olduğu görülmüştür [3].

Bechara ve Damasio çalışmasında somatik işaretçi hipotezi olarak, karar verme ve kararın duygulardan etkilenmesini açıklayan nöro-anatomik bilişsel bir çerçeve önerilmektedir[5,6]. Bu hipoteze göre duyguları da içeren biyo-düzenleyici süreçlerin oluşturduğu işaretçi sinyaller karar verme sürecini etkilemektedir. Hipotez, bireyin hükümde bulunurken sadece sonucun şiddeti ve gerçekleşme olasılığı ile değerklendirme yapmadığını, bunun yanında öncelikli olarak sonucun duygusal mahiyetini de karar vermede değerklendirmeye kattığını önermektedir. Ventromedial prefrontal korteksteki lezyonlar, somatik veya duygusal sinyallerin normal işleyişini engellemekte fakat diğer bilişsel fonksiyonları pek etkilemez[7,8]. Ventromedial hasar karar verme sürecinde patolojik bozukluklara yol açmakta ve gündelik hayattaki kararların yeterliliğini ciddi derecede etkilemektedir. Somatik İşaretçi hipotezi iddiasının, karar vermede duygu, duygulanım ve duygudurumun temel rolü olduğunu gösteren diğer çalışmalarla da uyumlu gözükmektedir [9,10,11].

II. YÖNTEM

A. EEG Veri Kaydı ve Önışleme

EEG kaydı için 32 kanallı EEG kayıt sistemi kullanılmıştır (BrainAmp). Genişletilmiş 10-20 sistemine göre 25 kanaldan (Oz, O1, O2, Pz, P3, P4, P7, P8, Cz, C3, C4, T7, T8, Fz,

F3, F4, FC3, FC4, FT7, FT8,F7, F8, FP1, FP2) 1000Hz örnekleme ile veri toplanmıştır. Deneyde yaş ortalamaları 25 olan 10'u erkek 11'i kadın olmak üzere 21 gönüllü katılımcı yer almıştır. Katılımcıların nörolojik herhangi bir hastalığının bulunmamasına ve sinir sistemini etkileyen herhangi bir ilaç kullanılmalarına dikkat edilmiştir. Deney düzeneği Matlab-GUI kullanılarak tasarlanmıştır. Deney akışı, 3-4dak. uzunluklu on Türk filmi parçasının (video) rastgele gösterimi, her film sonrası ekrana gelen üç soruluk anket şeklindedir. Birinci soru, [-7 7] Likert ölçeğe emosyonel değerlik (ing. valence) puanlamasına yöneliktir; "İzlediğiniz bu sahne nasıl bir duygu içeriyordu?" İkinci soru, [1 7] Likert ölçeğe uyabilirlik (ing. arouse) puanlamasına yöneliktir; "izlediğiniz bu sahne sizi ne kadar etkiledi?" Üçüncü soru, [1 7] Likert ölçeğe beğenme (ing. like) puanlamasına yönelik "beğendiniz mi?" sorusudur.

Ham EEG verisinde gürültü temizleme BrainAmp-Analyzer yazılımı yardımıyla iki aşamada gerçekleştirilmiştir. İlk aşamada, yazılımdaki Bağımsız Bileşen Analizi (BBA ,ing. ICA) fonksiyonu kullanılarak göz kırpmaları temizlenmiştir. İkinci aşama, kalan düzensiz gürültülerin gözle işaretlenmesidir. Analiz sırasında bu bölgeler işleme alınmamıştır.

B. Bağımsız Bileşen Analizi

Bağımsız bileşen analizi (BBA), çok kanallı kaydedilmiş verinin kaynaklarına ayrıştırma yöntemlerinden biridir. Kör kaynak ayrıştırma (ing. Blind source separation) olarak adlandırılan metoda çok benzerdir. Burada "kaynak" kelimesi, orjinal sinyali, yani bağımsız bileşeni işaret eder. Çalışma prensibi, kokteyl parti problemi örneği üzerinden açıklanabilir [12]. İki kişi eşzamanlı olarak konuşuyor olsun ve farklı noktalara yerleştirilmiş iki mikrofon ile de konuşmalar kaydedilsin, elde edilen sinyaller sırasıyla $x_1(t)$ ve $x_2(t)$. Kaydedilmiş bu sinyaller, iki konuşmacıdan gelen konuşma sinyallerinin $s_1(t)$ ve $s_2(t)$ 'nin ağırlıklandırılmış toplamlarıdır. Lineer bir denklemle ifade edecek olursak;

$$x_1(t) = a_{11}s_1(t) + a_{12}s_2(t) \quad (1)$$

$$x_2(t) = a_{21}s_1(t) + a_{22}s_2(t) \quad (2)$$

burada, a_{ij} parametreleri konuşmacıların mikrofonlara olan uzaklıklarının yansıtan katsayılarıdır. Denklem (1) ve (2) üzerinden, $s_1(t), s_2(t)$ konuşma sinyallerinin çözümlenmesine "kokteyl parti problemi" olarak adlandırılır. Problemin çözümü, a_{ij} parametreleri bilindiği takdirde kolaylıkla hesaplanabilir. BBA, bu ve benzer problemleri çözmeye olanak sağlamaktadır. Örneğin, EEG verisi benzer niteliktedir, pek çok farklı kaynaktan doğan elektriksel potansiyellerin kafatası üzerinde yerleştirilmiş elektrotlar yardımıyla kaydedilmesiyle oluşur. Böylece bir kanaldaki veri, belli bir beyin aktivitesinin bileşenlerinin elektrotlardaki karışımından meydana gelmektedir.

Varsayalım ki, n bağımsız bileşenden oluşan n lineer karışım (ing.: mixture) x_1, \dots, x_n gözlenmiş olsun.

$$x_j(t) = a_{j1}s_1(t) + a_{j2}s_2(t) + \dots + a_{jn}s_n(t) \quad (3)$$

BBA'da Denklem-3'deki t zaman indeksini ortadan kaldırmak için, her bir karışım değişkeni x_j ve bağımsız bileşen s_k 'nin bir zaman sinyali değil de sıfır ortalamalı rastgele değişken olduğunu varsayalım. Yazımda kolaylık olması açısından matris notasyonunu kullanırsak, x karışım vektörünü, s bağımsız

bileşen vektörünü ve A katsayılar matrisini gösterebiliriz. Buna göre (3) yeniden yazılırsa,

$$x = As \quad (4)$$

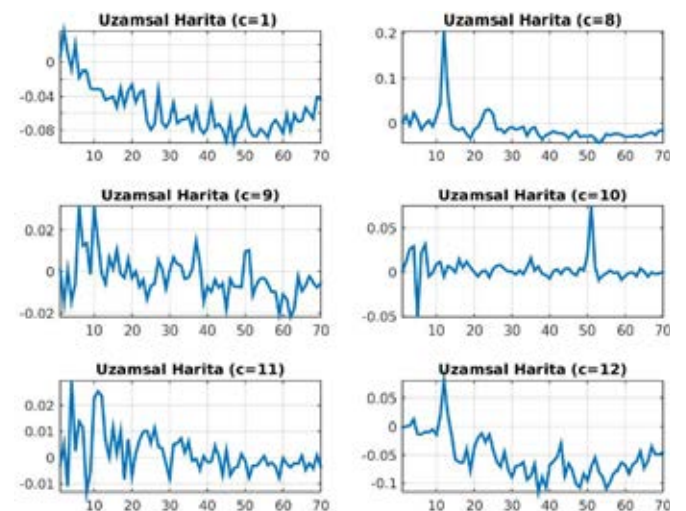
Denklem (4)'deki istatistiksel model, BBA modeli olarak tanımlanır. Bu model, s_i bileşenlerin karışımı ile gözlenmiş verinin nasıl üretildiğini açıklar. Bağımsız bileşenler, örtük bileşenler olduğu için doğrudan gözlenemedikleri için gizli bileşen olarak adlandırılır. Aynı zamanda karışım matrisi (ing. mixing matrix) bilinmeyen olarak kabul edilir. BBA için başlangıç noktası, basit bir kabul olan, s_i bileşenlerinin istatistiksel olarak bağımsız olduğu kabulüdür. Basitlik amacıyla, bilinmeyen karışım matrisini kare matris kabul edelim. A matrisinin kestiriminden sonra, tersini hesaplayıp W matrisi, bağımsız bileşenleri elde ederiz;

$$s = Wx \quad (5)$$

C. BBA ile EEG verisinden Uzamsal Filtre Çıkarımı

BBA denklemini (4) EEG analizi açısından okuyacak olursak, x kafa derisinden kaydedilen EEG sinyali, s beyinde senkron çalışarak baskın hale gelen EEG kaynaklarını ve A karışım matrisi de EEG kaynaklarındaki sinyalin elektrotlara dağılımı katsayı matrisini göstermektedir. Burada ulaşılmak istenen A karışım matrisinin hesaplanmasıdır. Matris çarpımından da görüleceği üzere, A karışım matrisinin her bir satırı, tek bir kanal verisi için her bir kaynak verisinin katsayısını içerir. Eğer A karışım matrisinin sütunlarını dikkate alırsak, her bir kaynağın kanallara olan katsayı dağılımını, başka bir deyişle, o kaynak için uzamsal filtreyi bulmuş oluruz. Filtreler uzamsal düzlemde olduğu için "harita" (ing. map) olarak tanımlanmıştır.

Verinin işleme adımları şu şekildedir. EEG video verileri 1Hz-70Hz arası filtrelenip birleştirilir ve her bir kanal için birleşik tek bir zaman sinyali oluşturulur, ardından gürültülü bölgeler temizlenir. Temizlenmiş veriye BBA analizi uygulanarak, karışım matrisi ve bağımsız bileşenler bulunur. Her bir kişi için karışım matrislerinden topografiler elde edilir.



Şekil 1: Negatif-Nötr Frekans Genlik Fark Grafiği [Hz x Genlik], uzamsal harita sonuçları. c: Harita numarası

D. Spektrogram ve Öznitelik Çıkarma

Güç spektrum hesabı sadece frekans düzlemindeki değişimi gösterdiğinden zamansal hassasiyeti ölçebilmek için uzamsal filtelenmiş verinin spektrogram değerleri hesaplanmıştır. Hesaplamalar her bir video için örtüşmesiz 4s'lik FFT dönüşümleri bulunarak yapılmıştır. Katılımcıların videolar için verdiği değerlik skorları üzerinden iki sınıf oluşturulmuştur. İstatistiksel anlamlılığı sağlamak amacıyla negatif, nötr ve pozitif değerlikli video segmentleri eşit adette seçilmiştir. Negatif değerlik verisi en düşük iki skorlu video, pozitif değerlik verisi en yüksek iki skorlu video ile, nötr veri seti de kişinin verdiği skorların ortalamasına en yakın iki skorlu video ile belirlenmiştir. Sınıf oluşturma iki şekilde yapılmıştır, birincisinde negatif değerliğe karşı nötr değerlik, ikincisinde negatif değerliğe karşı nötr ve pozitif değerlik olarak kümelendirilmiştir.

Her bir kümenin spektrogram verisi zaman boyutu üzerinde ortalama alınarak, o değerlik için frekans dağılımı hesaplanmıştır. Negatif ve nötr değerlikli ortalama frekans dağılımlarının farkı alınarak (Şekil 1), iki duygudurum arasındaki farklı ilintili frekans bölgeleri öznitelik değerlerini oluşturacak şekilde belirlenmiştir. Örneğin, Şekil 1'de Uzamsal Harita $c=8$ grafiğinde 11-14Hz bandında farkın yüksek olduğu görülmektedir. Fark bölgelerinin bulunması başlangıçta elle yapılmış daha sonra kod ile otomatik olarak yapılmıştır.

Öznitelik çıkarma adımları şu şekilde özetlenebilir. Katılımcının verdiği emosyonel değerlik skoruna göre negatif, nötr ve pozitif skorlu video verileri BBA ayrıştırma yöntemi ile elde edilen filtreler ile 25 ayrı veriye dönüştürülmekte ve spektrogramları hesaplanmaktadır. Negatif ve pozitif skorlu video spektrogram değerlerinin 1-70Hz arası frekans bandında tepe noktaları (yerel maksimum ve minimumlar) hesaplanmıştır. Bu tepe noktaları, belirlenen dört ana band aralığında (delta, alfa, beta, gama) nötr skorlu verinin spektrogram ortalamasından mutlak değer olarak 10 kat büyük ise bu tepe noktası merkezli 3Hz'lik frekans bölgesi öznitelik frekans değerleri olarak seçildi. Sonuç olarak, sınıflandırma için kullanılacak öznitelik verileri, frekans bölgelerinde negatif skorlu verinin frekans genliği nötr skorlu verinin frekans genliğinden 10 kat büyük/küçük olacak şekilde oluşturulmaktadır.

E. Öznitelik Seçimi

Farklı öznitelik azaltma metodları denenip, İliinti-temelli Öznitelik Altküme Seçimi (ing. Correlation-based Feature Subset Selection, CfsSubset) metodunda karar kılınmıştır. Çalışılan diğer metodlar sarmalayıcı algoritma (ing. Wrapper) ve sıra temelli (ing. rank) metodlar. CfsSubset bunlara göre hem daha hızlı hem daha başarılı sonuç vermektedir [13]. Sıra temelli metodlar, özniteliklerin etkinliği tek tek incelediği için farklı olasılıkta bir araya gelebilecek öznitelik kümelerini bulamamaktadır. Sarmalayıcı algoritması da altküme seçimleri yaparak çalışır, CfsSubset'e göre yavaş bir metottur.


İteratif aramada ise ileri doğru, geriye doğru ve iki yönlü aramalar çalıştırılmış, üretilen sonuçta aralarında pek fark gözlenmemiştir. Bununla birlikte çapraz geçiş (ing. cross-validation) uygulanarak eğitim ve test kümeleri ayrılarak öznitelikler seçilmiştir. Çapraz geçiş de farklı katlar için test edilmiştir, test kümesinde sınıf örneklerinin eşit dağılabilmesi için tam bölün katlar seçilmiştir. Nihai hesaplamalarda literatürde sıklıkla kullanılan geriye doğru arama kullanılmıştır.

III. SONUÇLAR

Çalışmanın amacı, negatif duygulanımı kestirebilecek öznitelik ve sınıflayıcıları belirlemektir. Sınıflayıcının maliyet hesabı bu amaç doğrultusunda ağırlıklandırılmıştır. Negatif duygulanım, katılımcıların video sonrası verdikleri değerlik skorlaması (ing. Valence:pleasant upleasant) üzerinden yapılmıştır. İki veri kümesinden, birincisinde negatif-nötr değerlikli verilerden bir küme seti, ikincisinde negatif-(nötr+pozitif) değerlikli verilerden bir küme seti oluşturulmuştur. İki kümenin sınıflandırılmasında da aynı sınıflayıcılar benzer başarı oranları yakalamıştır. Sonuç olarak, maliyet hesabı da gözetilerek eğitilmiş sınıflayıcılar arasında sınıflama başarısını en iyi veren metodlar, örnek temelli k-en yakın komşuluk algoritması (ing. Instance-based k-NN, IBk) ile çokkatmanlı algılayıcı (Multilayer Perceptron, ML) algoritması %80 üzerinde başarı göstermiştir. Öznitelik seçiminde ise Beta ve Gama bandı frekanslarının çalışılan katılımcılar arasında ayırıcı öznitelik olarak öne çıktığı görülmüştür.

A. Özel Puanlama Sonuçları

Katılımcıların on film klipi için [-7 7] aralığında verdiği emosyonel değerlik puanlamaları, Şekil 2'de gösterilmektedir. Grafikte negatif ve pozitif duygu tetiklemesi beklediğimiz filmler sıralı şekilde dizilmiştir. Katılımcılar arasında ortalamada negatif ve pozitif değerlikli filmler üzerinde bir uzlaşma görülmektedir. 9 numaralı film nötr değerlikli uyarın olarak kullanılmıştır. 10 numaralı film puanlamasında ise ortalamada bir uzlaşmaya varılmadığı görülmektedir.



Şekil 2: Katılımcıların On Film klipi için Emosyonel Değerlik Puanlamaları

| Katılımcı-04 | Katılımcı-11 | Katılımcı-14 |
|----------------|----------------|----------------|
| map:1,23-26Hz | map:1 34-41Hz | map:2 38-43Hz |
| map:5,43-47Hz | map:2 43-47Hz | map:3 40-45Hz |
| map:13,18-19Hz | map:3 18-27Hz | map:4 39-62Hz |
| map:18,58-59Hz | map:5 6-20Hz | map:5 22-25Hz |
| map:23,19-25Hz | map:5 32-39Hz | map:23 54-58Hz |
| | map:7 37-53Hz | map:5 47-60Hz |
| | map:9 34-36Hz | map:17 20-26Hz |
| | map:9 37-40Hz | map:22 12-37Hz |
| | map:17 22-26Hz | |
| | map:17 54-55Hz | |
| | map:18 11-24Hz | |
| | map:18 28-33Hz | |
| | map:18 34-41Hz | |
| | map:18 48-49Hz | |

Tablo I: Seçilen Öznitelikler, map: BBA ile hesaplanan uzamsal filtreler, harita

B. Öznitelik Seçim Sonuçları

Yöntem kısmında anlatılan adımlar izlenerek üç katılımcıdan elde edilen öznitelik adedi sırasıyla 42, 30 ve 56'dır. Bu üç katılımcının seçimi verilerinin farklı miktarlarda gürlüğü içerdiği üzerinden yapılmıştır. Böylece çalışmada önerilen sistem farklı örnek sayısında test edilmiştir. Öznitelik azaltma yöntemi olarak İnti-temelli Öznitelik Altküme Seçimi yöntemi kullanıldı ve elde edilen öznitelikler Tablo 1'de verilmektedir.

C. Negatif Değerlik Kestirim Sonuçları

Sınıflandırma karşılaştırmasında farklı öğrenme algoritmaları kullanan beş sınıflandırıcı seçilmiştir. Bunlar Destek Vektör Makine (DVM) algoritması, polinomal (ing. SVM Poly Kernel) ve radyal çekirdekli (ing. SVM RBF Kernel), örnek temelli k-en yakın komşuluk algoritması (ing. IBk-NN), çok katmanlı algılayıcı algoritması (ing. ML) ve J48 karar ağacı algoritmasıdır. 10 tekrarlı çapraz geçişleme sonucunda elde edilen standart sapmaları ile birlikte doğruluk oranları ve analiz anlamlılığını gösteren kappa değerleri Tablo II ve Tablo III'te verilmiştir. Seçilen özniteliklerle DVM sınıflandırıcılar anlamlı sonuç üretmediği, örnek temelli k-en yakın komşuluk ve çok katmanlı algılayıcı sınıflandırıcıların her iki küme seti için başarılı sonuç verdiği görülmektedir.

| | Katılımcı-04 | Katılımcı-11 | Katılımcı-14 |
|--------------------|-----------------|--------------|---------------|
| SVM | 50.00(±0.00) | 94.55(±5.55) | 59.70(±8.34) |
| Poly Kernel | $\kappa = 0.00$ | 0.89 | 0.19 |
| SVM | 50.00(±0.00) | 50.00(±0.00) | 50.00(±0.00) |
| RBF Kernel | $\kappa = 0.00$ | 0.00 | 0.00 |
| IBk-NN | 90.47(±10.19) | 96.43(±4.51) | 87.30(±9.62) |
| | $\kappa = 0.81$ | 0.93 | 0.75 |
| ML | 83.91(±12.61) | 86.17(±8.34) | 81.20(±10.76) |
| | $\kappa = 0.68$ | 0.72 | 0.62 |
| J48 | 50.00(±0.00) | 97.08(±3.91) | 83.30(±10.83) |
| | $\kappa = 0.00$ | 0.94 | 0.67 |

Tablo II: Negatif Değerliğe karşı Nötr Değerlik Sınıflandırıcı Karşılaştırma, Değerler: % Doğruluk (Standart Sapma), κ : Kappa Değeri

| | Katılımcı-04 | Katılımcı-11 | Katılımcı-14 |
|--------------------|-----------------|--------------|--------------|
| SVM | 66.67(±0.00) | 74.81(±5.17) | 66.67(±0.00) |
| Poly Kernel | $\kappa = 0.00$ | 0.30 | 0.19 |
| SVM | 66.67(±0.00) | 66.67(±0.00) | 66.67(±0.00) |
| RBF Kernel | $\kappa = 0.00$ | 0.00 | 0.00 |
| IBk-NN | 87.81(±8.79) | 87.75(±6.81) | 85.67(±8.96) |
| | $\kappa = 0.81$ | 0.72 | 0.66 |
| ML | 85.42(±8.85) | 80.22(±7.19) | 73.47(±9.28) |
| | $\kappa = 0.68$ | 0.49 | 0.28 |
| J48 | 88.65(±8.09) | 88.10(±6.79) | 84.20(±8.19) |
| | $\kappa = 0.00$ | 0.72 | 0.60 |

Tablo III: Negatif Değerliğe karşı Nötr-Pozitif Değerlik Sınıflandırıcı Karşılaştırma, Değerler: % Doğruluk (Standart Sapma), κ : Kappa Değeri

IV. TARTIŞMA

Çalışmada negatif duygulanım iki ayrı veri seti oluşturularak, negatif duygulanımın pozitif ve nötre göre ayırt edilebilirliği sınanmıştır. Negatife karşı nötr değerlikli veriden oluşan veri seti sınıflandırılması, negatife karşı nötr ve pozitif değerlikli birlikte işlenen veri seti sınıflandırmasına göre %3-5 oranında daha yüksek doğruluk oranında kestiriliyor. Fakat her iki veri seti de %83±9 üzerinde başarımlıdır.

Analizde kullanılan negatif-nötr skorlu veri frekans genlik oranı 10 kat büyük/küçük olarak belirlenmiş eşik sınırı ile sınıflandırma için yeterli öznitelik verisi oluşturulamaz ise bu değer düşürülerek sınıflandırma yapılabilir. Bu durumda genlik farkı azalacağından dolayı, sınıflayıcının negatif duyguyu kestirim başarı oranında düşme görülebilir.

TEŞEKKÜR

Çalışma verilerin kaydedildiği İstanbul Üniversitesi İstanbul Tıp Fakültesi Fizyoloji Anabilim Dalı EEG Laboratuvarı araştırmacılarına desteklerinden dolayı teşekkür ederiz.

KAYNAKÇA

- [1] H. C. Lench, S. A. Flores & S. W. Bench, "Discrete emotions predict changes in cognition, judgment, experience, behavior, and physiology: A meta-analysis of experimental emotion elicitation", *Psychological Bulletin*, 137(5), pp. 834-855, 2011.
- [2] L. Fernández-Aguilar, B. Navarro-Bravo, J. Ricarte, L. Ros, & J. M. Latorre, "How effective are films in inducing positive and negative emotional states? A meta-analysis", *PLoS one*, 14(11), e0225040, 2019.
- [3] R. Westermann, K. Spies, G. Stahl, F.W. Hesse, "Relative effectiveness and validity of mood induction procedures: A meta-analysis", *Eur J Soc Psychol*, 26, pp. 557-80, 1996.
- [4] A. Schaefer, F. Nils, X. Sanchez, P. Philippot, "Assessing the effectiveness of a large database of emotion-eliciting films: A new tool for emotion researchers", *Cognition and Emotion*, 24(7), pp. 1153-1172, 2010.
- [5] A. Bechara, H. Damasio, A.R. Damasio, "Emotion, decision making and the orbitofrontal cortex." *Cerebral cortex* 10.3, pp. 295-307, 2000.
- [6] A.R. Damasio, *Descartes' Error: Emotion, Reason, and the Human Brain*, Putnam Publishing, 1994.
- [7] A. Bechara, H. Damasio, A.R. Damasio, S.W. Anderson, "Insensitivity to future consequences following damage to human prefrontal cortex", *Cognition* 50, pp. 7-15, 1994.
- [8] A. Bechara, H. Damasio, A.R. Damasio, G.P. Lee, "Different contributions of the human amygdala and ventromedial prefrontal cortex to decision-making", *J Neurosci* 19, pp. 5473-5481, 1999.
- [9] N. Schwartz, G.L. Clore, "Mood, misattribution, and judgements of well-being: information and directive functions of affective states", *J Person Soc Psychol* 45, pp. 513-523, 1983.
- [10] R.B. Zajonc, "On the primacy of affect", *Am Psychol* 39, pp. 117-123, 1984.
- [11] J. LeDoux, *The emotional brain: the mysterious underpinnings of emotional life*, New York: Simon and Schuster, 1996.
- [12] A. Hyvärinen, E. Oja, "Independent component analysis: algorithms and applications", *Neural networks*, 13(4-5), pp. 411-430, 2000.
- [13] M.A. Hall, "Correlation-based feature selection of discrete and numeric class machine learning", (Working paper 00/08). Hamilton, New Zealand: University of Waikato, Department of Computer Science, 2000.