

The classification of selected facial expressions using single-channel electromyographic signals through artificial neural networks and decision trees

Niloofar Shojaeian^{1*}, Babak Rezaee Afshar²

¹ Department of Biomedical Engineering Group, Bioelectronics, Islamic Azad University, Central Tehran Branch, Tehran, Iran
niloofar.shojaeian@iau.ir

² Orthotics and Prosthetics, Faculty of Rehabilitation Sciences, Iran University of Medical Sciences, Tehran, Iran
babak.rezaee@srbiau.ac.ir

Abstract: This study examines various facial expressions using single-channel electromyography with minimal computational complexity for real-time applications. The electromyography data of facial muscles is derived from the electrical potential generated by different facial expressions, which can have varying values for each expression. In this study, electromyography data were recorded from the facial muscles of six female participants with a mean age of 25 ± 5 years. After applying a fourth-order Butterworth filter, the data were divided into 10-second windows, and 12 features were extracted in both time and frequency domains. To reduce computational load, Principal Component Analysis (PCA) was utilized for feature reduction, while classification of the data was performed using artificial neural networks and decision trees. After applying the filters and extracting features, the data were classified using multilayer perceptron classifiers with an accuracy of 73.57%, decision trees with an accuracy of 95.16%, MPL-PCA with an accuracy of 65.20%, and DT-PCA with an accuracy of 96.33%. Challenges in this study include the small number of participants and the single-channel nature of the data. Future studies could combine facial muscle data.

Keywords: Facial expressions, electromyography, artificial neural network, decision tree, principal component analysis

JCDSA, Vol. 3, No. 1, Spring 2025
 Received: 2025-01-22

Online ISSN: 2981-1295
 Accepted: 2025-05-06

Journal Homepage: <https://sanad.iau.ir/en/Journal/jcdsa>
 Published: 2025-06-21

CITATION

Shojaeian, N., Rezaee Afshar, B., "The classification of selected facial expressions using single-channel electromyographic signals through artificial neural networks and decision trees", Journal of Circuits, Data and Systems Analysis (JCDSA), Vol. 3, No. 1, pp. 44-53, 2025.
 DOI: 00.00000/0000

COPYRIGHTS



©2025 by the authors. Published by the Islamic Azad University Shiraz Branch. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0)

<https://creativecommons.org/licenses/by/4.0>

* Corresponding author

Extended Abstract

1- Introduction

Electromyography (EMG) is a medical technique that records and analyzes the electrical activity of muscles. This method uses electrodes to capture the electrical signals generated by the muscles. According to recent articles, the main applications of electromyography include analyzing emotions from facial muscles in identifying and differentiating various emotions such as happiness, sadness, anger, etc. [1], as well as clinical diagnosis in identifying movement disorders and other medical conditions, such as swallowing difficulties in stroke patients [2], and controlling prosthetic devices in human-machine interfaces (HMI) [3], as well as biometric research on physiological states like muscle fatigue [1].

Facial muscles play a vital role in conveying emotional states. Facial expressions are a source of information that help in understanding an individual's emotional condition; thus, recognizing facial expressions is essential for effective communication and social interactions. Moreover, facial emotional disorders can be an early indicator of various medical conditions. For instance, stroke patients may experience swallowing difficulties as an early sign that can be detected through changes in facial expressions. This highlights the importance of facial expression recognition in clinical diagnosis and monitoring health conditions.

In this study, we will examine the relationship between electromyography and facial expressions and the differentiation of states through machine learning methods. It seems that machine learning methods, combined with signal processing algorithms, can effectively differentiate data related to single-channel electromyography.

2- Methodology

In this study, four female participants with an average age of 25 ± 2 years and a body mass index of 23.2 ± 2 kg/m² were present. All participants were healthy adults with no history of neuromuscular disease. These individuals participated voluntarily and with full awareness of the study's implementation process. To obtain facial data, it is necessary to place two electrodes connected to the input terminals (orange and red) at a maximum distance of 4 centimeters on the cheeks and a reference electrode (green) on the forehead bone or behind the ear. In this case, the electromyographic signal related to the face will be easily identifiable through the signal amplitude. Additionally, the seniam electrode placement method was used differentially. Data for each class of facial movements was recorded over a period of 10 seconds. Each individual repeated each movement 15 times in each class. Six classes of different facial movements (natural expression, yawning, laughing, studying, and chewing gum) were performed by each individual as shown in

Figure (2), and the corresponding data was recorded as per the sample in Figure (3). After this step, 12 features in the time and frequency domains that had the most variance among the selected features were extracted for data analysis from the windows. Initially, 24 features were chosen as effective features based on preliminary studies, which were ultimately narrowed down to 12 selected features after the feature extraction and variance analysis of the data. After the feature extraction phase and considering the numerous features extracted from the data, there is a need to reduce the computational burden. In the data classification stage, the use of machine learning methods is essential. For this purpose, the artificial neural network (ANN) is a computational model inspired by the structure of the human brain that is capable of learning and solving complex problems.

3- Results and discussion

The display of the data by two selected features in the time and frequency domain, namely RMS and MDF features, shows a good condition as indicated in Figure X. Based on this figure, which is for the third sample data, it has been determined that MDF is scattered between 90 to 155 units and RMS between 0.75 to 9, indicating that the densities reflect the validity of performance during the data acquisition period. According to the results obtained after extracting 12 features from the time and frequency domains, various classifiers with different accuracies, precision, features, and sensitivities were applied, including a multilayer perceptron with an accuracy of 73.57%, a decision tree with an accuracy of 95.16%, an MLP-PCA combination with an accuracy of 65.20%, and a DT-PCA combination with an accuracy of 96.33% for the purpose of detecting different states based on facial muscles; therefore, the highest classification accuracy was achieved when the decision tree was combined with principal component analysis. The results indicate that the classifications have various levels of accuracy, precision, and sensitivity. Ultimately, we concluded that the decision tree has higher accuracy and precision compared to the other classifiers.

4- Conclusion

Considering the results obtained, EMG has been a powerful tool, applicable in various fields, and has provided extensive capabilities to researchers and specialists. According to this study, EMG is used for emotion analysis and recognition tasks, and the decision tree performs very effectively in this process, providing results with a high percentage of accuracy. Combining it with principal component analysis improves performance. One of the limitations of this study is the use of single-channel signals. In other words, in this research, the human body is assumed to be symmetrical, disregarding the differences in individuals' physical characteristics.





طبقه بندی حالات منتخب صورت از طریق سیگنال الکترومایوگرافی

تک کاناله به وسیله شبکه عصبی مصنوعی و درخت تصمیم

نیلوفر شجاعیان^{۱*}، بابک رضایی افشار^۲

۱- گروه مهندسی پزشکی بیوالکتریک، دانشگاه آزاد اسلامی واحد تهران مرکزی، تهران، ایران (niloofar.shojacian@iau.ir)

۲- گروه ارتز و پروتز، دانشکده توان بخشی، دانشگاه علوم پزشکی ایران، تهران، ایران (babak.rezace@srbiau.ac.ir)

چکیده: این مطالعه، به بررسی حالات مختلف صورت از طریق الکترومایوگرافی تک کاناله با حداقل پیچیدگی محاسباتی به منظور استفاده در کاربردهای واقعی به صورت بلادرنگ می پردازد. داده های الکترومایوگرافی عضلات صورت نشأت گرفته از پتانسیل الکتریکی اجرای حالات مختلف صورت است که به ازای حالات مختلف می تواند مقادیر متفاوتی را داشته باشد. در این مطالعه، داده های الکترومایوگرافی از حالات های مختلف عضلات صورت ۶ نفر از شرکت کنندگان زن با میانگین سنی 25 ± 5 سال ثبت گردید و پس از اعمال فیلتر باترورت مرتبه چهار، داده ها در پنجره های ۱۰ ثانیه ای تقسیم بندی شد و سپس ۱۲ ویژگی در حوزه زمان و فرکانس از آن استخراج گردید. برای کاهش حجم محاسباتی از روش کاهش ویژگی *PCA* و برای طبقه بندی داده ها از شبکه عصبی مصنوعی و درخت تصمیم استفاده شد. پس از اعمال فیلترها و استخراج ویژگی، داده ها توسط طبقه بندی های پرسپترون چندلایه با صحت ۷۳.۵۷ درصدی، درخت تصمیم با صحت ۹۵.۱۶ درصدی، *MPL-PCA* با صحت ۶۵.۲۰ درصدی و *DT-PCA* با صحت ۹۶.۳۳ درصدی مورد طبقه بندی قرار گرفتند. از چالش های این مطالعه می توان به تعداد کم افراد شرکت کننده و تک کاناله بودن اشاره کرد. همچنین در مطالعات آینده می توان داده های عضلات صورت را به صورت ترکیبی استفاده کرد.

واژه های کلیدی: حالات صورت، الکترومایوگرافی، شبکه عصبی مصنوعی، درخت تصمیم، تحلیل مؤلفه های اساسی

DOI: 00.00000/0000

نوع مقاله: پژوهشی

تاریخ چاپ مقاله: ۱۴۰۴/۰۳/۳۱

تاریخ پذیرش مقاله: ۱۴۰۴/۰۲/۱۶

تاریخ ارسال مقاله: ۱۴۰۳/۱۱/۰۳

۱- مقدمه

است. همچنین اختلالات عاطفی صورت می توانند نشانگر اولیه انواع شرایط پزشکی باشند. به عنوان مثال، بیماران سکتة مغزی ممکن است مشکلات بلع را به عنوان یک علامت اولیه تجربه کنند که از طریق تغییرات در حالات صورت قابل تشخیص است. این امر اهمیت تشخیص حالات صورت را در تشخیص بالینی و پایش شرایط سلامتی نشان می دهد [۱]. پردازش دقیق اطلاعات عاطفی از طریق تحلیل فعالیت عضلات صورت می تواند به عنوان ابزاری برای بازخورد در زمان واقعی در سیستم های هوش مصنوعی و فناوری های نوین، از جمله رابط های انسان و ماشین به کار رود [۴]. در برخی مطالعات از سیگنال های اخذ شده از سنسورها برای بررسی حالات صورت بهره برده اند. به طور مثال در مطالعه ژانگ و همکاران از یک سیستم پوشیدنی مبتنی بر حسگر ToF و یادگیری عمیق بهره برداری شده که قادر به تشخیص هفت حالت چهره اصلی بوده است. این سیستم به گونه ای طراحی شده است که در دستگاه های کم مصرف و با استفاده از یک MCU (STM32F476) قابل اجرا باشد [۵]. در مطالعه اسیف حسین و همکاران از روشی نوآورانه

الکترومایوگرافی^۲ (EMG) یک تکنیک پزشکی است که به ثبت و تحلیل فعالیت الکتریکی عضلات می پردازد. این روش با استفاده از الکترودها، سیگنال های الکتریکی تولید شده توسط عضلات را ضبط می کند. مطابق مقالات اخیر کاربردهای اصلی الکترومایوگرافی، تحلیل احساسات از عضلات صورت در شناسایی و تفکیک انواع احساسات نظیر شادی، غم، عصبانیت و غیره [۱]، همچنین تشخیص بالینی در شناسایی اختلالات حرکتی و دیگر شرایط پزشکی، مانند مشکلات بلع در بیماران سکتة مغزی [۲] و نیز کنترل دستگاه های پروتزی در رابط های انسان و ماشین (HMI)^۳ [۳] و تحقیقات بیومتریک در مورد وضعیت های فیزیولوژیکی مانند خستگی عضلانی ارائه دهند [۱]. عضلات صورت نقش حیاتی در انتقال حالات عاطفی دارند. حالات صورت منبعی از اطلاعات هستند که به درک وضعیت عاطفی یک فرد کمک می کنند؛ بنابراین، تشخیص حالات صورت برای برقراری ارتباط مؤثر و تعاملات اجتماعی ضروری

* نویسنده مسئول

² Electromyography³ Human-machine interfaces

عصبی - عضلانی نداشتند. این افراد به صورت داوطلبانه و با آگاهی کامل از روند اجرای مطالعه در آن شرکت کردند. فرایند انجام مطالعه مطابق با شکل (۱) پیاده سازی شد. همچنین در این پژوهش، برای جمع آوری داده ها از دستگاه الکترومایوگرافی تک کاناله مدل *sEMG* شرکت ساب تل استفاده شد. این دستگاه دارای امپدانس ورودی ۲ گیگا اهم و نسبت رد مد مشترک (*CMRR*)^۳ برابر با ۱۲۰ دسی بل است. این مازول به منظور دریافت و تقویت سیگنال های حیاتی، بهویژه الکتروکاردیوگرام، به کار گرفته شد. مازول مذکور با بهره ۸۸۰ و فرکانس بالاگذر ۴۰۰ هرتز و فیلتر پایین گذر ۲۰ هرتز با ولتاژ ۵ ولت جریان مستقیم تغذیه می شود. قبل از انجام الکتروگذاری، لازم است از دستیابی امپدانس پوست به سطح قابل قبول اطمینان حاصل شود. پروسه آماده سازی پوست باید به گونه ای انجام شود که با استفاده از پد الکلی یا پنبه ای مرطوب، سطح پوست به آرامی سابیده شود تا مقاومت پوست به حداقل برسد. هرچند ممکن است بخشی از پوست در اثر سابیدن قرمز شود، اما نباید آسیبی جدی به آن وارد گردد. با انجام صحیح آماده سازی پوست، الکترودها ارتباط بهتری با بدن خواهند داشت. الکترودهای مورد استفاده به صورت چسبی و از جنس نقره یا نقره کلرید ساخته شده اند.

برای دریافت داده های مربوط به صورت، لازم است دو الکترو متصل به پایه های ورودی (نارنجی و قرمز) با فاصله حداکثر ۴ سانتی متر بر روی گونه ها قرار گیرند و یک الکترو مرجع (سبز رنگ) روی استخوان پیشانی یا پشت گوش قرار گیرد. در این حالت، سیگنال الکترومایوگرافی مرتبط با صورت به آسانی از طریق دامنه سیگنال قابل شناسایی خواهد بود. همچنین از روش الکتروگذاری *seniam* به صورت تفاضلی استفاده گردید. علاوه بر آن در زمان ثبت سیگنال، باید در وضعیت کاملاً آرام و ریلکس باشید؛ زیرا فعالیت های عضلانی می تواند به عنوان نویز بر روی سیگنال مغزی تأثیر بگذارد. لازم است به این نکته توجه شود که الکترودها باید به میزان کافی ژل داشته باشند. این ژل برای ایجاد اتصال صحیح ضروری است و موجب تسهیل رسانایی جریان می شود. در صورتی که مقدار ژل به اندازه کافی نباشد، می توان با خیس کردن پوست با آب، این کمبود را جبران کرد. قابل توجه است که ابزار باید از هرگونه سیستم متصل به برق شهری فاصله داشته باشد تا با نویز ۵۰ یا ۶۰ هرتز برق شهر مواجه نشود. در این پژوهش به جهت کاهش نویز مربوط به برق شهر، تا حد ممکن فضا ایزوله گردید. در شکل (۲) نحوه قرارگیری الکترودهای *EMG* نشان داده شده است. برای مشاهده و ذخیره سیگنال *EMG* بر روی نمایشگر رایانه، از برد آردوینو مدل *UNO* و نرم افزار *Serial Oscilloscope* به عنوان رابط سخت افزاری و نرم افزاری استفاده می کنیم. در این سیستم، آردوینو به عنوان مبدل آنالوگ به دیجیتال عمل می کند و داده های آنالوگ با دامنه بین ۰ تا ۵ ولت را به داده های دیجیتال باینری تبدیل می نماید. برد آردوینو *UNO* دارای رزولوشن ۱۰ بیت و ۱۰۲۴ سطح مجزا است. همچنین، نرخ نمونه برداری برای دریافت سیگنال *EMG* بر روی ۲۰۰۰ هرتز تنظیم شده است، زیرا فرکانس مورد نظر ما بین ۲۰ تا ۴۵۰ هرتز قرار دارد.

برای تشخیص حالات صورت استفاده کرده است که ترکیبی از الکترومایوگرافی صورت (*fEMG*)^۱، آنالیز کورتوگرام و شبکه های عصبی کانولوشنی (*CNN*)^۲ است. در واقع این مقاله از یک روش قوی استفاده می کند که *fEMG* و تکنیک های یادگیری عمیق، بهویژه *CNN* ها، را برای تشخیص مؤثر حالات صورت ادغام می کند. این رویکرد چندوجهی از طریق پروتکل های آزمایش دقیق تأیید شده و دقت بالایی در طبقه بندی حالات احساسی نشان می دهد [6]. علاوه بر روش های سیگنالی، روش های مبتنی بر تصویر نیز در مقالات اخیر بیشتر استفاده شده است [۷-۹]. مثلاً مقاله فرنک و همکاران از الگوریتم های پیشرفته برای دقت در شناسایی حالات عاطفی استفاده کرده است [۱۰].

بطور کلی مطالعات پیشین از روش های نوآورانه ای برای تشخیص حالات صورت استفاده کرده اند اما هر کدام محدودیت های قابل توجهی دارند که ممکن است کارایی و قابلیت استفاده از آنها را دچار مشکلاتی کند. چالش های مطالعات شامل کیفیت سنسور، حساسیت به محیط، وابستگی به فناوری های خاص، مشکلات حریم خصوصی، عدم تفکیک جنسیت، عدم مقایسه با سایر مطالعات و نیاز به آزمایش گسترده در دنیای واقعی است. علاوه بر این، موضوعاتی مانند عدم تعادل در مجموعه داده ها و نیاز به محاسبات سنگین می تواند توسعه سیستم های قوی را با مشکل مواجه کند [1, 4, 5, 11-20]. دلیل انتخاب حرکات (خنده، جویدن آدامس، خواندن کتاب، حالت نرمال و حالت خمیازه) این است که در مطالعات پیشین بر روی این حالت ها مطالعه صورت گرفته است [۲۱-۲۴]. نوآوری های قابل توجهی در این پژوهش بر روی انتخاب حرکات انجام شده است؛ به گونه ای که اکثر حرکات مورد تفکیک در این مطالعه بیانگر حالات روحی فردی در حال رانندگی است که نتایج این پژوهش را می تواند به سمت موضوع آنالیز خستگی و خواب آلودگی از طریق بررسی همین حالات چهره بکشاند. علاوه بر این ترکیب و مقایسه روش های طبقه بندی در این مطالعه می تواند به بهبود قدرت تفکیک داده ها بینجامد. لازم به ذکر است مطالعات قبلی برای اخذ داده ها از چندین کانال الکترومایوگرافی استفاده کرده بودند که مشکلات مربوط به الکتروگذاری و همچنین مشکلات مداخله در رفتار نرمال فرد را به همراه داشت که اخذ تک کاناله این مشکلات را به حداقل می رساند.

در این مطالعه، به بررسی موضوع ارتباط بین الکترومایوگرافی و حالات صورت و تفکیک حالات از طریق روش های یادگیری ماشین خواهیم پرداخت. به نظر می رسد روش های یادگیری ماشین در ترکیب با الگوریتم های پردازش سیگنال می توانند تفکیک داده های مربوط به الکترومایوگرافی تک کاناله را به خوبی انجام دهند.

۲- مواد و روش ها

در این پژوهش، چهار نفر از شرکت کنندگان زن با میانگین سنی 25 ± 5 سال و شاخص توده بدنی 22 ± 23 کیلوگرم بر مترمربع حضور داشتند. تمامی شرکت کنندگان، افراد بالغ و سالم بودند و هیچ گونه سابقه بیماری

³ common mode rejection ratio

¹ Facial Electromyography

² convolutional neural network



داده‌های هر کلاس از حرکات صورت، طی مدت ۱۰ ثانیه ثبت شد. هر فرد در هر کلاس، هر حرکت را ۱۵ بار تکرار کرد. شش کلاس حرکات مختلف صورت (حالت طبیعی، خمیازه، خنده، مطالعه، و جویدن آدامس) مطابق شکل (۲)، توسط هر فرد اجرا و داده‌های مربوطه مطابق نمونه شکل (۳) ثبت شد. تجزیه و تحلیل داده‌ها با استفاده از نرم‌افزار *MATLAB* نسخه 2018a انجام شد. پس از وارد کردن داده‌ها به نرم‌افزار و اصلاح خط مبنا، یک فیلتر میان‌گذر باترورت مرتبه ۴ بر روی داده‌ها اعمال شد تا داده‌های خارج از محدوده فرکانسی مورد نظر تضعیف شوند. با افزایش مرتبه فیلتر، پاسخ فرکانسی آن به پاسخ ایده‌آل (دیوار آجری) نزدیک‌تر می‌شود. پس از آزمایش چندین مرتبه، بهینه‌ترین مرتبه برای فیلتر انتخاب گردید. برای تجزیه و تحلیل داده‌ها، از تکنیک پنجره‌گذاری با همپوشانی صفر درصد استفاده شد. این تکنیک به تقسیم داده‌ها درون پنجره‌های ۱۰ ثانیه‌ای به مدت ۱۰ ثانیه با همپوشانی صفر در میان کمک نمود. پس از انجام این کار، ۱۲ ویژگی در حوزه‌های زمان و فرکانس که از میان ویژگی‌های منتخب دارای بیشترین واریانس بودند به‌منظور تجزیه و تحلیل داده‌ها از پنجره‌ها استخراج شد. ۲۴ ویژگی در ابتدا بر اساس مطالعات اولیه به‌عنوان ویژگی‌های مؤثر انتخاب شد که نهایتاً پس از استخراج ویژگی‌ها و بررسی واریانس داده‌ها، ۱۲ ویژگی منتخب در ادامه مورد بررسی قرار می‌گیرد.

میانگین، یک مفهوم آماری است که به‌عنوان یک نوع "معدل" برای مجموعه‌ای از داده‌ها و اعداد تعریف می‌شود که در (۱) آمده است.

$$Mean = \frac{1}{n} \sum_{i=1}^n x_i \quad (1)$$

که در این رابطه X_i نمایانگر مقدار هر یک از نقاط در داده و N نشانگر تعداد نمونه‌های پنجره است. میانه، یکی از ویژگی‌های آماری متداول حوزه زمان است که در (۲) آمده است.

$$\begin{cases} x_{\frac{n+1}{2}}, & \text{if } n \text{ is odd} \\ x_{\frac{n}{2}} + x_{(\frac{n}{2}+1)}, & \text{if } n \text{ is even} \end{cases} \quad (2)$$


که در این رابطه X لیست مرتب شده مقادیر در مجموعه داده‌ها و n تعداد مقادیر در مجموعه داده‌ها است. واریانس، یک معیار آماری است که در واقع میزان پراکندگی یا تنوع داده‌ها نسبت به میانگین می‌پردازد. به عبارت دیگر، واریانس فاصله داده‌ها از میانگین آنها را نشان می‌دهد و از طریق (۳) بیان می‌شود.

$$\begin{cases} x_{(n+1)/2}, & \text{if } n \text{ is odd} \\ x_{\frac{n}{2}} + x_{(\frac{n}{2}+1)}, & \text{if } n \text{ is even} \end{cases} \quad (3)$$


جزر میانگین مربعات (RMS)^۱، یک معیار آماری است که جهت اندازه‌گیری اندازه یا شدت یک مجموعه از مقادیر استفاده می‌شود. رابطه آن به صورت (۴) بیان می‌شود.

$$RMS = \sqrt{\frac{\sum_{i=1}^N x_i^2}{N}} \quad (4)$$


که در آن، RMS ریشه میانگین مربع، n تعداد مربعات و X_i هر مقدار است.



شکل (۱): چارت مراحل پردازش سیگنال در این مطالعه



شکل (۲): نحوه قرار گرفتن الکتروود EMG



شکل (۳): نمونه داده‌های هر کلاس

¹ Root Mean Squared




تجزیه و تحلیل کرد. این متغیرهای جدید معمولاً به عنوان مؤلفه های اصلی شناخته می شوند که بر اساس شدت همبستگی با داده ها ترتیب داده می شوند. با این حال، باید به این نکته توجه کرد که تحلیل مؤلفه های اصلی تنها یک روش کاهش ابعاد است و قادر به حل مشکلات ناشی از عدم تعادل داده ها یا شرایط خاص دیگر نمی باشد [۲۵].

در مرحله طبقه بندی داده ها استفاده از روش های یادگیری ماشین ضروری است. به همین منظور شبکه عصبی مصنوعی 2 (ANN) یک مدل محاسباتی الهام گرفته از ساختار مغز انسان است که قادر به یادگیری و حل مسائل پیچیده است. این شبکه ها از نودها (نورون ها) تشکیل شده که به یکدیگر متصل هستند و می توانند سیگنال ها را پردازش کنند. اجزای اصلی آن شامل ورودی ها یعنی داده های ورودی که به شبکه وارد می شوند، لایه های پنهان یعنی لایه هایی که بین لایه ورودی و خروجی قرار دارند و مسئول پردازش اطلاعات و استخراج الگوها هستند، خروجی ها که نمایانگر خروجی نهایی شبکه است که پیش بینی یا تصمیم گیری را نشان می دهد، وزن ها و بایاس ها که شامل ارتباط بین نورون ها و بایاس ها است [۲۶].

علاوه بر روش های با نظارت یادگیری ماشین همانند شبکه عصبی مصنوعی الگوریتم های دیگری نیز امروزه مورد توجه است. از این میان درخت تصمیم (DT)^۳، یک مدل پیش بینی آماری است که به وسیله آن می توان به کمک یک درخت تصمیم گیری کرد. این درخت بر اساس ویژگی های ورودی داده ها و روابط بین آن ها، به یک تصمیم نهایی برسد. درخت تقسیم یک روش تفکیکی است که در آن، داده ها را بر اساس ویژگی های آن ها به شاخه های مختلف تقسیم می کند. این شاخه ها هر کدام را می توان به شاخه های کوچک تر و کوچک تر تقسیم کرد تا در نهایت به یک نتیجه یا کلاس پیش بینی برسد. فازهای اصلی درخت تقسیم به ۴ مرحله تقسیم می شوند. مرحله اول شامل انتخاب ویژگی است که در این مرحله ویژگی های داده مشخص می شوند، سپس در مرحله بعد از روش های تفکیکی برای تقسیم کردن داده ها استفاده می کنیم، در مرحله ۳ پیش بینی برای هر داده بر اساس تقسیم هایی که صورت گرفته است، انجام می شود، سپس در مرحله آخر پارامترهای درخت تصمیم گیری انتخاب می شوند. همچنین ۷۰ درصد از داده های جمع آوری شده برای آموزش و ۳۰ درصد باقیمانده برای آزمایش مدل طبقه بندی مورد استفاده قرار گرفت. به منظور بررسی طبقه بندی از مؤلفه صحت مطابق با (۱۲) استفاده می شود.

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (11)$$

در این رابطه TP نشانگر مثبت صادق، TN نشانگر منفی صادق، FP نشانگر مثبت کاذب، FN نشانگر منفی کاذب است.



شکل (۴): ساختار شبکه عصبی مصنوعی

تعداد عبور از صفر، به تعداد دفعاتی گفته می شود که یک سیگنال (معمولاً یک سیگنال متغیر یا زمانی) از مقدار صفر عبور کرده باشد که در (۵) آمده است.

$$\sum_{i=1}^{n-1} [sgn(x_i \times x_{i+1}) \cap |x_i - x_{i+1}|] \geq \text{threshold} \quad (5)$$

$$\text{sgn}(x) = \begin{cases} 1, & \text{if } x \geq th \\ 0, & \text{otherwise} \end{cases}$$

$iEMG$ یا همان الکترومایوگرافی خام، مجموع داده های سیگنال الکترومایوگرافی در یک پنجره است که نشانگر تقارن داده ها است و از طریق (۶) محاسبه می شود.

$$iEMG = \sum_{i=1}^N X_i \quad (6)$$

مرتبه v ، به وابستگی عملکرد یک الگوریتم یا تابع به پارامتر ورودی اشاره دارد و به صورت (۷) تعریف می شود.

$$Vorder = \left(\frac{1}{N} \sum_{i=1}^N X_i^v \right)^{\frac{1}{v}} \quad (7)$$

میانگین فرکانسی، به میانگین فرکانس های موجود در یک سیگنال یا تابع زمانی اشاره دارد و در (۸) آمده است.

$$\sum_{j=1}^m f_j P_j / \sum_{j=1}^m P_j \quad (8)$$

که در این رابطه مقادیر P از طریق محاسبه تبدیل فوریه سریع برای هر طیف فرکانسی به دست می آید. میانه فرکانسی، بیان می کند که در چه نقطه ای از توزیع فرکانس، ۵۰ درصد از انرژی یا قدرت سیگنال تحت پوشش قرار گرفته است و به صورت (۹) تعریف می شود.

$$\sum_{j=1}^{MDF} P_j = \sum_{j=MDF}^M P_j = \frac{1}{2} \sum_{j=1}^M P_j \quad (9)$$

پیک فرکانسی، فرکانسی است که ماکسیمم توان در آن به نمایش درمی آید که در (۱۰) آورده شده است.

$$PKF = \max(P_j) \quad j = 1 \dots \quad (10)$$

میانگین قدرت، فرکانس متوسط یک طیف به صورت مجموع حاصل ضرب شدت طیف (به دسی بل) و فرکانس تقسیم بر مجموع کل شدت طیف گرام محاسبه می شود.

$$f_{mean} = \frac{\sum_{i=0}^n I_i \cdot f_i}{\sum_{i=0}^n I_i} \quad (11)$$

قدرت مجموع، مجموع حاصل ضرب شدت طیف و فرکانس که پس از استخراج از طریق تبدیل فوریه سریع به دست می آید.


پس از مرحله استخراج ویژگی و باتوجه به تعدد ویژگی های مستخرج از داده ها نیاز به کاهش بار محاسباتی احساس می شود. تحلیل مؤلفه های اصلی (PCA)^۱ یک روش آماری است که به منظور تبدیل مجموعه ای از متغیرها به متغیرهای جدید طراحی شده است. این متغیرهای جدید، به صورت کامل یا جزئی، از ترکیب متغیرهای اولیه تشکیل می شوند. هدف اصلی این روش، کاهش بعد داده ها و همچنین کاهش تعداد متغیرهای ورودی است که به نوبه خود می تواند پیچیدگی مدل های آماری را کاهش دهد. در تحلیل مؤلفه های اصلی می توان متغیرهای اولیه را به صورت خطی به عنوان ترکیب خطی از متغیرهای جدید

³ Decision Tree

¹ Principal Component Analysis

² Artificial Neural Networks





شکل (۵): نمودار ویژگی‌ها بر اساس دو ویژگی منتخب در حوزه فرکانس یعنی RMS و MDF

جدول (۱): مقادیر حاصل از طبقه‌بندی توسط MLP DT با استفاده و بدون استفاده از تحلیل مؤلفه‌های اصلی

تعداد نفرات	MLP	DT	MLP-PCA	DT-PCA
نفر اول	۴۲.۸۶٪	۹۸٪	۴۲.۸۶٪	۹۸٪
نفر دوم	۸۵٪	۱۰۰٪	۷۱.۴۳٪	۱۰۰٪
نفر سوم	۷۱.۴۳٪	۹۲٪	۲۸.۵۷٪	۹۸٪
نفر چهارم	۸۵.۷۱٪	۹۲٪	۷۱.۴۳٪	۹۴٪
نفر پنجم	۸۶٪	۹۵٪	۵۵.۲۸٪	۹۵٪
نفر ششم	۷۰.۴۲٪	۹۴٪	۶۵.۲۳٪	۹۳٪
میانگین	۷۳.۵۷٪	۹۵.۱۶٪	۶۵.۲۰٪	۹۶.۳۳٪

باتوجه به آنچه در مراحل قبلی انجام شد، داده‌ها امکان تفکیک یافته و میزان تفکیک داده‌ها به صورت مقادیر آماری از طریق مؤلفه سنجشی صحت اندازه‌گیری خواهد شد. همچنین بررسی مقدار صحت تفکیک نمایه مناسبی برای کارآمدی روش‌های پردازشی خواهد بود.

۳- نتایج

نتایج اصلی این پژوهش شامل داده‌های جمع‌آوری شده از سیگنال‌های الکترومایوگرافی (EMG) چهار فرد است که در حین انجام شش کلاس منتخب حرکات صورت مورد بررسی و آزمایش قرار گرفته‌اند. در این مطالعه، ۱۲ ویژگی از داده‌ها استخراج شد که شامل ۷ ویژگی در حوزه زمان و ۵ ویژگی در حوزه فرکانس بود. در مجموع ۳۰۰ داده مختلف از افراد جمع‌آوری شد. داده‌های هر کلاس از حرکات صورت، در مدت ۱۰ ثانیه ثبت گردید. هر حرکت توسط هر فرد ۱۵ بار تکرار گردید. همچنین پنج کلاس از حرکات مختلف صورت شامل (حالت طبیعی، خمیازه، خنده، مطالعه، و جویدن آدامس) ثبت گردید.

نمایش داده‌ها توسط دو ویژگی منتخب در حوزه زمان و فرکانس یعنی ویژگی‌های RMS و MDF وضعیت خوبی را مطابق شکل X نشان می‌دهد. بر اساس این شکل که برای داده‌های نمونه سوم است، مشخص گردیده MDF در کلاس‌های مختلف بین ۹۰ تا ۱۵۵ واحد و RMS بین ۰/۷۵ تا ۹ پراکنده شده است که تراکم‌ها را در بخشی از نمودار مذکور نشان‌دهنده صحت عملکرد در زمان داده‌گیری است. اجرای روش‌های طبقه‌بندی توسط ۲ طبقه‌بند پرسپترون چندلایه MLP و درخت تصمیم انجام شد. حالاتی که از تحلیل مؤلفه‌های اصلی برای کاهش ویژگی استفاده شده یا استفاده از تحلیل مؤلفه‌های اصلی نادیده گرفته شده است که در جدول (۱) آمده است. طبق نتایج به‌دست‌آمده پس از استخراج ۱۲ ویژگی از حوزه زمان و فرکانس، طبقه‌بندهای مختلف با دقت، صحت، ویژگی‌ها و حساسیت‌های مختلف شامل پرسپترون چندلایه با صحت ۷۳.۵۷ درصدی، درخت تصمیم با صحت ۹۵.۱۶ درصدی، ترکیب MLP-PCA با صحت ۶۵.۲۰ درصدی و DT-PCA با صحت ۹۶.۳۳ درصدی باهدف تشخیص حالات مختلف از روی عضلات صورت اعمال شدند؛ بنابراین بالاترین صحت تفکیک برای طبقه‌بندی در زمانی که درخت تصمیم با تحلیل مؤلفه‌های اصلی ترکیب شده بود به دست آمد. نتایج طبقه‌بندی توسط ماتریس تصمیم نیز به جهت بهره‌برداری در راستای بهبود عملکرد شبکه برای تمامی کلاس‌ها و افراد اجرا گردید که نمونه‌ای از آن مطابق شکل (۶) است. نتیجه‌های نشان‌داده‌شده حاکی از آن است که طبقه‌بندی‌ها دارای دقت، صحت و حساسیت‌های مختلفی بوده‌اند. نهایتاً به این نتیجه رسیدیم که درخت تصمیم از نتایج، صحت و دقت بالاتری نسبت به دیگر طبقه‌بندها برخوردار است.




۵- جمع بندی

باتوجه به نتایج حاصل شده، *EMG* به عنوان ابزاری قدرتمند، در حوزه های گوناگونی کاربرد داشته و امکانات گسترده ای را در اختیار محققان و متخصصان قرار داده است. این کاربردها می تواند در حوزه های مختلف از جمله هوش مصنوعی، تحلیل حالات احساسی افراد، بررسی فرایندهای شناختی، تشخیص اختلالات روان شناختی، تشخیص فلج عضلات صورت، پایش پیشرفت درمان و طراحی ربات های اجتماعی باشد. ترکیب طبقه بندی های پرسپترون چند لایه و تحلیل مؤلفه های اصلی به عنوان یک رویکرد موثر در یادگیری ماشین به منظور بهبود دقت پایش بینی و کاهش ابعاد داده ها شناسایی می شود. طبق تحقیقاتی که در سال های اخیر انجام شده است، استفاده از تحلیل مؤلفه های اصلی به عنوان پایش پردازش، قبل از طبقه بندی با *MLP* باعث افزایش دقت نسبت به مدل تحلیل مؤلفه های اصلی می شود. نهایتاً ترکیب این دو مدل با یکدیگر علاوه بر اینکه دقت را افزایش می دهد، به افزایش توانایی تفسیر نتایج هم کمک می کند. همچنین طبق مطالعه ارکلی و همکاران، ترکیب این دو طبقه بند با یکدیگر دقت و کارایی را به طرز قابل توجهی بالا برد و در مطالعه ما نیز با ترکیب این دو با یکدیگر، مقادیر بالا رفته است [۲۷]. ضمن اینکه در مطالعه وورگاس و همکاران نیز مشخص گردیده استفاده از تحلیل مؤلفه های اصلی در کنار *MLP* موجب بهبود صحت طبقه بندی می شود [28]. که این نتیجه در مطالعه اخیر نیز حاصل گردیده است هرچند در مطالعه اخیر علاوه بر این موضوع مشخص گردید تحلیل مؤلفه های اصلی در کنار درخت تصمیم نیز باعث افزایش صحت طبقه بندی می شود.

طبق این مطالعه، *EMG* برای کارهای تحلیل و تشخیص احساسات مورد استفاده قرار می گیرد و درخت تصمیم در این روند بسیار قوی عمل کرده و نتیجه را با درصد دقت بالایی می دهد و ترکیب آن با تحلیل مؤلفه های اصلی، باعث بهبود عملکرد می شود. از محدودیت های این مطالعه، می توان به تک کاناله بودن سیگنال ها اشاره کرد. به عبارت دیگر، در این تحقیق، بدن انسان به صورت متقارن فرض شده و از تفاوت های موجود در ویژگی های بدنی افراد صرف نظر شده است. این تصمیم ممکن است تأثیراتی بر دقت و تعمیم پذیری نتایج به دست آمده داشته باشد. در واقع، با نادیده گرفتن تفاوت های فردی، ممکن است برخی از جنبه های مهم و قابل توجه در تحلیل داده ها تحت تأثیر قرار گیرد؛ بنابراین، این نکته باید در تفسیر یافته ها و کاربردهای عملی مطالعه در نظر گرفته شود. همچنین از مزیت های آن این است که ساده تر هست و الکتروگذاری و تعداد داده کمتری مورد استفاده قرار گرفت. به عنوان مثال در مقاله ساتو و همکاران ۶ کانال استفاده کردید که موجب بالا بردن دقت نهایی گردید [۲۹].

مطابق جدول (۲)، در مطالعات گذشته تعداد کانال های استفاده شده نسبت به مطالعه حاضر بیشتر بوده و نتیجه حاصل با تعداد کانال کمتری بوده است. کانال های کمتر مداخلات کمتری در دیتاگیری ایجاد می کند. همچنین تعداد کلاس های مطالعات [۳۱] - [۳۲] از مطالعه فعلی کمتر بوده و در مطالعاتی هم که تعداد کلاس ها بالاتر بوده، درصد صحت



شکل (۶): طبقه بندی توسط ماتریس تصمیم

جدول (۲): مقایسه نتایج به دست آمده از مطالعات پیشین

مرجع	تعداد کانال	روش تفکیک	تعداد کلاس	درصد صحت
[۲۹]	۱۴	الگوریتم های طبقه بندی KNN, SVM	۱۱	۸۳.۹٪
[۳۰]	۱۶	الگوریتم های طبقه بندی SVM و ICA	۵	۷۱.۱۳٪
[۳۱]	۱	شبکه عصبی RMS, VAR, IEMG	۴	۴۱.۲٪
[۳۲]	۱۰	تحلیل فریم با استفاده از نرم افزار Affectiva	۳	۶۷.۵۳٪

۴- بحث

در این مطالعه، دوازده شاخص متمایز از داده های گردآوری شده در دو بازه زمانی و فرکانسی استخراج گردید. هر یک از این شاخص ها قابلیت تفکیک پذیری منحصربه فردی را به نمایش می گذاشتند و دربردارنده اطلاعات و تغییراتی ارزشمند برای تفکیک داده ها بودند. بر این اساس، هر شاخصی که از درصد بالاتری برخوردار بود، بهتر از دیگر داده ها بود. همچنین، حسگرهای به کاررفته در این مطالعه، اطلاعات بسیاری را از فعالیت های عضله در اختیار ما قرار دادند. طبق مطالعه صورت گرفته، پس از دریافت و ثبت سیگنال های *EMG*، مشاهده گردید که دامنه این سیگنال ها، بر حسب نوع حرکت، نوسانات و تغییرات قابل توجهی را از خود بروز می دهد. این تغییرات، به گونه ای معنادار و قابل تأمل، حرکات مختلف و متنوع (از جمله خنده، جویدن آدامس، مطالعه و کتاب خوانی، حالت عادی و نرمال، و خمیازه کشیدن) را از یکدیگر متمایز می سازد و هر یک را با امضایی منحصربه فرد و هویتی مستقل مشخص می نماید. این تفاوت های مشهود و محسوس، حاکی از آن است که سیگنال *EMG*، ابزاری کارآمد و توانا برای تفکیک الگوهای حرکتی گوناگون به شمار می آید. همچنین مشخص گردید تحلیل مؤلفه های اصلی می تواند بهبود قابل توجهی در نتایج طبقه بندی ما ایجاد نماید. این بهبود در ترکیب با درخت تصمیم نتایج بالاتری از صحت را با میانگین حدود ۹۶.۳۳ درصد ایجاد کرد.

- [۱۰] S. Casaccia, E. J. Sirevaag, M. G. Frank, J. A. O'Sullivan, L. Scalise, and J. W. Rohrbaugh, "Facial muscle activity: High-sensitivity noncontact measurement using laser Doppler vibrometry," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-10, 2021. <https://doi.org/10.1109/TIM.2021.3060564>
- [۱۱] Q. Zhu, G. Lu, and J. Yan, "Valence-arousal model based emotion recognition using EEG, peripheral physiological signals and facial expression," in *Proceedings of the 4th International Conference on Machine Learning and Soft Computing*, 2020, pp. 81-85. <https://doi.org/10.1145/3380688.3380694>
- [۱۲] A. Kelati, J. Plosila, and H. Tenhunen, "Machine learning for semg facial feature characterization," in *2019 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, ۲۰۱۹, pp. 169-174. <https://doi.org/10.23919/SPA.2019.8936818>
- [۱۳] S. S. Blom, H. Aarts, and G. R. Semin, "Lateralization of facial emotion processing and facial mimicry," *Laterality*, vol. 25, pp. 259-274, 2020. <https://doi.org/10.1080/1357650X.2019.1657127>
- [۱] V. Kehri and R. Awale, "A facial EMG data analysis for emotion classification based on spectral kurtogram and CNN," *International Journal of digital signals and smart systems*, vol. 4, pp. 50-63, 2020. <https://doi.org/10.1504/IJDSS.2020.106072>
- [۲] K.-H. S. Chen and R. Chen, "Principles of electrophysiological assessments for movement disorders," *Journal of movement disorders*, vol. 13, p. 27, 2020. <https://doi.org/10.14802/jmd.19064>
- [۳] C. L. Kok, C. K. Ho, F. K. Tan, and Y. Y. Koh, "Machine learning-based feature extraction and classification of emg signals for intuitive prosthetic control," *Applied Sciences*, vol. 14, p. 5784, 2024. <https://doi.org/10.3390/app14135784>
- [۴] M. Gjoreski, I. Kiprijanovska, S. Stankoski, I. Mavridou, M. J. Broulidakis, H. Gjoreski, et al., "Facial EMG sensing for monitoring affect using a wearable device," *Scientific reports*, vol. 12, p. 16876, 2022.
- [۵] J. Zhang, X. Xie, G. Peng, L. Liu, H. Yang, R. Guo, et al., "A Real-Time and Privacy-Preserving Facial Expression Recognition System Using an AI-Powered Microcontroller," *Electronics*, vol. 13, p. 2791, 2024. <https://doi.org/10.3390/electronics13142791>
- [۶] S. A. Hussain and A. S. A. Al Balushi, "A real time face emotion classification and recognition using deep learning model," in *Journal of physics: Conference series*, 2020, p. 012087. 10.1088/1742-6596/1432/1/012087
- [۷] E. S. Agung, A. P. Rifai, and T. Wijayanto, "Image-based facial emotion recognition using convolutional neural network on emognition dataset," *Scientific reports*, vol. 14, p. 14429, 2024.
- [۸] J. Wei, G. Hu, X. Yang, A. T. Luu, and Y. Dong, "Learning facial expression and body gesture visual information for video emotion recognition," *Expert Systems with Applications*, vol. 237, p. 121419, 2024. <https://doi.org/10.1016/j.eswa.2023.121419>
- [۹] J. Basavaiah, A. A. Anthony, N. K. HN, and C. M. Patil, "Facial Emotion Recognition: A Review on State-of-the-art Techniques," in *2024 4th International Conference on Data Engineering and Communication Systems (ICDECS)*, 2024, pp. 1-6.

تفکیک کمتر بوده بنابراین با استفاده از روش‌های پردازشی ترکیبی با تعداد کانال کمتر و تعداد کلاس‌های بیشتر، درصد صحت بالاتری حاصل گردید. در مطالعات آینده می‌توان ترکیبی از داده‌های عضلات صورت را استفاده کرد، همچنین می‌توان تعداد حرکات انتخابی صورت را بیشتر کرد و حرکات بیشتری از صورت را مورد بررسی قرارداد. ضمن اینکه با استفاده از هم‌زمان‌سازی سنسورها، تأثیر مؤلفه‌های مغزی روی عضلات صورت را بررسی کنیم. این رویکرد نه تنها به درک عمیق‌تری از ارتباطات میان مغز و حرکات صورت کمک می‌کند، بلکه می‌تواند زمینه‌ساز پیشرفت‌های قابل‌توجهی در زمینه‌های مختلفی مانند روان‌شناسی، عصب‌شناسی و حتی هنرهای زیبا گردد.

مراجع

- [۱] V. Kehri and R. Awale, "A facial EMG data analysis for emotion classification based on spectral kurtogram and CNN," *International Journal of digital signals and smart systems*, vol. 4, pp. 50-63, 2020. <https://doi.org/10.1504/IJDSS.2020.106072>
- [۲] K.-H. S. Chen and R. Chen, "Principles of electrophysiological assessments for movement disorders," *Journal of movement disorders*, vol. 13, p. 27, 2020. <https://doi.org/10.14802/jmd.19064>
- [۳] C. L. Kok, C. K. Ho, F. K. Tan, and Y. Y. Koh, "Machine learning-based feature extraction and classification of emg signals for intuitive prosthetic control," *Applied Sciences*, vol. 14, p. 5784, 2024. <https://doi.org/10.3390/app14135784>
- [۴] M. Gjoreski, I. Kiprijanovska, S. Stankoski, I. Mavridou, M. J. Broulidakis, H. Gjoreski, et al., "Facial EMG sensing for monitoring affect using a wearable device," *Scientific reports*, vol. 12, p. 16876, 2022.
- [۵] J. Zhang, X. Xie, G. Peng, L. Liu, H. Yang, R. Guo, et al., "A Real-Time and Privacy-Preserving Facial Expression Recognition System Using an AI-Powered Microcontroller," *Electronics*, vol. 13, p. 2791, 2024. <https://doi.org/10.3390/electronics13142791>
- [۶] S. A. Hussain and A. S. A. Al Balushi, "A real time face emotion classification and recognition using deep learning model," in *Journal of physics: Conference series*, 2020, p. 012087. 10.1088/1742-6596/1432/1/012087
- [۷] E. S. Agung, A. P. Rifai, and T. Wijayanto, "Image-based facial emotion recognition using convolutional neural network on emognition dataset," *Scientific reports*, vol. 14, p. 14429, 2024.
- [۸] J. Wei, G. Hu, X. Yang, A. T. Luu, and Y. Dong, "Learning facial expression and body gesture visual information for video emotion recognition," *Expert Systems with Applications*, vol. 237, p. 121419, 2024. <https://doi.org/10.1016/j.eswa.2023.121419>
- [۹] J. Basavaiah, A. A. Anthony, N. K. HN, and C. M. Patil, "Facial Emotion Recognition: A Review on State-of-the-art Techniques," in *2024 4th International Conference on Data Engineering and Communication Systems (ICDECS)*, 2024, pp. 1-6.



- [۲۱] G. Lombardi, M. Gerbella, M. Marchi, A. Sciutti, G. Rizzolatti, and G. Di Cesare, "Investigating form and content of emotional and non-emotional laughing," *Cerebral Cortex*, vol. 33, pp. 4164-4172, 2023. <https://doi.org/10.1093/cercor/bhac334>
- [۲۲] L. Franz, C. de Filippis, A. Daloiso, E. Biancoli, F. P. Iannaccone, D. Cazzador, et al., "Facial surface electromyography: A systematic review on the state of the art and current perspectives," *American Journal of Otolaryngology*, vol. 45, p. 104041, 2024. <https://doi.org/10.1016/j.amjoto.2023.104041>
- [۲۳] A. van Boxtel, "Electromyographic (EMG) responses of facial muscles during language processing," in *Language Electrified: Principles, Methods, and Future Perspectives of Investigation*, ed: Springer, 2023, pp. 367-385.
- [۲۴] C. J. Doelman and J. A. Rijken, "Yawning and airway physiology: a scoping review and novel hypothesis," *Sleep and Breathing*, vol. 26, pp. 1561-1572, 2022.
- [۲۵] B. Merzoug, M. Ouslim, L. Mostefai, and M. Benouis, "Evaluation of dimensionality reduction using PCA on EMG-based signal pattern classification," *Engineering Proceedings*, vol. 14, p. 23, 2022. <https://doi.org/10.3390/engproc2022014023>
- [۲۶] T. S. Murotzhonovich, "Introduction to Artificial Neural Networks," *Web of Synergy: International Interdisciplinary Research Journal*, vol. 2, pp. 198-202, 2023. 10.4018/979-8-3693-7250-0.ch016
- [۲۷] A. K. Ali and E. Erçelebi, "Automatic modulation classification using different neural network and PCA combinations," *Expert Systems with Applications*, vol. 178, p. 114.۲۰۲۱, ۹۳۱, 2021. <https://doi.org/10.1016/j.eswa.2021.114931>
- [۲۸] F. Vargas, D. Lettnin, M. C. F. de Castro, and M. Macarthy, "Electrocardiogram pattern recognition by means of MLP network and PCA: A case study on equal amount of input signal types," in *VII Brazilian Symposium on Neural Networks*, 2002. SBRN 2002. Proceedings., 2002, pp. 200-205. <https://doi.org/10.1109/SBRN.2002.1181474>
- [۲۹] L. Shao, "Facial movements recognition using multichannel EMG signals," in *2019 IEEE Fourth International Conference on Data Science in Cyberspace (DSC)*, 2019, pp. 561-566.
- [۳۰] J. Zhang, S. Huang, J. Li, Y. Wang, Z. Dong, and S.-J. Wang, "A Perifacial EMG Acquisition System for Facial-Muscle-Movement Recognition," *Sensors*, vol. 23, p. 8758, 2023.
- [۳۱] S. A. Mithavkar and M. S. Shah, "Recognition of emotion through facial expressions using EMG signal," in *2۰۱۹ international conference on nascent technologies in engineering (ICNTE)*, 2019, pp. 1-6.
- [۳۲] L. Kulke, D. Feyerabend, and A. Schacht, "A comparison of the Affectiva iMotions Facial Expression Analysis Software with EMG for identifying facial expressions of emotion," *Frontiers in psychology*, vol. 11, p. 329, 2020.
- [۹] J. Basavaiah, A. A. Anthony, N. K. HN, and C. M. Patil, "Facial Emotion Recognition: A Review on State-of-the-art Techniques," in *2024 4th International Conference on Data Engineering and Communication Systems (ICDECS)*, 2024, pp. 1-6.
- [۱۰] S. Casaccia, E. J. Sirevaag, M. G. Frank, J. A. O'Sullivan, L. Scalise, and J. W. Rohrbaugh, "Facial muscle activity: High-sensitivity noncontact measurement using laser Doppler vibrometry," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, pp. 1-10, 2021. <https://doi.org/10.1109/TIM.2021.3060564>
- [۱۱] Q. Zhu, G. Lu, and J. Yan, "Valence-arousal model based emotion recognition using EEG, peripheral physiological signals and facial expression," in *Proceedings of the 4th International Conference on Machine Learning and Soft Computing*, 2020, pp. 81-85. <https://doi.org/10.1145/3380688.3380694>
- [۱۲] A. Kelati, J. Plosila, and H. Tenhunen, "Machine learning for semg facial feature characterization," in *2019 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, ۲۰۱۹, pp. 169-174. <https://doi.org/10.23919/SPA.2019.8936818>
- [۱۳] S. S. Blom, H. Aarts, and G. R. Semin, "Lateralization of facial emotion processing and facial mimicry," *Laterality*, vol. 25, pp. 259-274, 2020. <https://doi.org/10.1080/1357650X.2019.1657127>
- [۱۴] M. N. Kyranides, M. Petridou, H. A. Gokani, S. Hill, and K. A. Fanti, "Reading and reacting to faces, the effect of facial mimicry in improving facial emotion recognition in individuals with antisocial behavior and psychopathic traits," *Current Psychology*, vol. 42, pp. 14306-14319, 2023.
- [۱۵] A. González-Rodríguez, Á. García-Pérez, M. Godoy-Giménez, P. Sayans-Jiménez, F. Cañadas, and A. F. Estévez, "The role of the differential outcomes procedure and schizotypy in the recognition of dynamic facial expressions of emotions," *Scientific Reports*, vol. 14, p. 2322, 2024.
- [۱۶] L. O. LUNDQVIST, "Facial EMG reactions to facial expressions: A case of facial emotional contagion?," *Scandinavian journal of psychology*, vol. 36, pp. 130-141, 1995. <https://doi.org/10.1111/j.1467-9450.1995.tb00974.x>
- [۱۷] B. 't Hart, M. E. Struiksma, A. van Boxtel, and J. J. Van Berkum, "Emotion in stories: Facial EMG evidence for both mental simulation and moral evaluation," *Frontiers in psychology*, vol. 9, p. 613, 2018. <https://doi.org/10.3389/fpsyg.2018.00613>
- [۱۸] J. J. van Berkum, M. Struiksma, and B. t Hart, "Using facial EMG to track emotion during language comprehension: past, present, and future," in *Language Electrified*, ed: Springer, 2023, pp. 687-729.
- [۱۹] J. Chen, T. Ro, and Z. Zhu, "Emotion recognition with audio, video, EEG, and EMG: a dataset and baseline approaches," *IEEE Access*, vol. 10, pp. 13229-13242, 2022.
- [۲۰] C.-T. Hsu and W. Sato, "Electromyographic validation of spontaneous facial mimicry detection using automated facial action coding," *Sensors*, vol. 23, p. 9076, 2023.

