



Analysis of the Effect of the Optimization Method and the Regulating Parameters in the Deep Network to Improve the Classification Accuracy of Finger Movements based on Electromyogram Signal

Saheb Jameyan, Masoud¹ / Ahmadi Pajouh, Mohammad Ali^{2*} / Moradi, Mohammad Hassan³

¹ - Ph.D. Student, Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

² - Assistant Professor, Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

³ - Professor, Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

ARTICLE INFO

DOI: 10.22041/ijbme.2024.2022213.1884

Received: 5 February 2024

Revised: 21/5/2024 – 26/6/2024

Accepted: 1 July 2024

KEY WORDS

Surface Electromyogram
Convolution Neural Network
Deep Neural Network
Classification
Optimizer
Regulator

ABSTRACT

Hand and finger movements are crucial for daily activities, and their impairment due to illness or accidents can have a significant impact. In the rehabilitation and treatment of finger injuries, it is vital to classify finger movements and assess their condition accurately. One approach to establishing a connection between the surface electromyogram (EMG) signal and finger movement classes is through the application of deep learning techniques. Deep learning has made remarkable advancements across various domains in recent years, and leveraging its knowledge can be beneficial in this context. In this study, the focus is on classifying and identifying eight different finger movements using deep convolutional neural networks. The researchers utilized EMG signals obtained from the Ninapro database for their analysis. The results indicate that the classification accuracy for certain movements reaches as high as 98.9%. Certain regulators and optimizers have a significant impact on the classification accuracy. By carefully selecting regulators, such as the random removal layer and L2, it is possible to improve the accuracy of the classification.

***Corresponding Author**


Address: Bioelectric Group, Biomedical Engineering Department, Amirkabir University of Technology, Tehran, Iran

Postal Code: 15875-4413

E-Mail: pajouh@aut.ac.ir

Tel: +98-21-64545570





تحلیل تاثیر روش بهینه‌سازی و پارامترهای تنظیم کننده‌ی شبکه‌ی عمیق جهت بهبود صحت کلاس‌بندی حرکات انگشتان دست مبتنی بر سیگنال الکترومایوگرام

صاحب‌جمعیان، مسعود^۱ / احمدی‌پژوه، محمدعلی^{۲*} / مرادی، محمدحسن^۳

^۱ - دانشجوی دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۲ - استادیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

^۳ - استاد، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2024.2022213.1884

پذیرش: ۱۱ تیر ۱۴۰۳

بازنگری: ۱۴۰۳/۳/۱ - ۱۴۰۳/۴/۶

ثبت در سامانه: ۱۶ بهمن ۱۴۰۲

چکیده

واژه‌های کلیدی

حرکات دست و انگشتان در زندگی روزمره نقش مهمی دارد. ممکن است در اثر بیماری و سوانح به این اندام آسیب وارد شود. در توان‌بخشی انگشتان دست و درمان آسیب‌های وارده به آن‌ها، طبقه‌بندی حرکات انگشتان دست و شناسایی وضعیت آن‌ها بسیار حائز اهمیت است. یکی از روش‌ها برای ایجاد نگاشت بین سیگنال الکترومایوگرام سطحی و کلاس‌های حرکتی انگشتان دست، به کارگیری دانش یادگیری عمیق است. این علم در سال‌های اخیر باعث پیش‌رفت‌های چشم‌گیری در بسیاری از زمینه‌ها شده است. در این مطالعه به طبقه‌بندی و شناسایی ۸ حرکت انگشتان دست بر اساس شبکه‌های عصبی عمیق کانولوشنال پرداخته شده است. داده‌های مورد نیاز این پژوهش که سیگنال‌های الکترومایوگرام سطحی بوده مربوط به پایگاه داده‌ی نیناپرو است. نتایج نشان می‌دهد که دقت طبقه‌بندی در برخی از حرکات به ۹۸/۹ درصد رسیده است. برخی از تنظیم‌کننده‌ها و بهینه‌کننده‌ها می‌توانند بر دقت طبقه‌بندی بسیار موثر باشند. با انتخاب صحیح تنظیم‌کننده‌ها از قبیل لایه‌ی حذف تصادفی و L2 دقت طبقه‌بندی قابل افزایش است.

الکترومایوگرام سطحی

شبکه‌ی عصبی کانولوشن

شبکه‌ی عصبی عمیق

طبقه‌بندی

بهینه‌کننده

تنظیم‌کننده

*نویسنده‌ی مسئول

نشانی: گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

تلفن: +۹۸-۲۱-۶۴۵۴۵۵۷۰

پست الکترونیکی: pajouh@aut.ac.ir

کد پستی: ۱۵۸۷۵-۴۴۱۳



۱- مقدمه

انگشتان دست و حرکت آن‌ها نقش به‌سزایی را در زندگی ایفا می‌کنند. در صورتی که به انگشتان آسیبی وارد شود انسان با مسائل زیادی مواجه خواهد شد. آسیب‌ها ممکن است به شکل فیزیکی یا عصبی باشد. معمولاً به منظور از بین بردن آثار ناشی از بیماری‌ها به دوره‌های توان‌بخشی نیاز است. جهت درمان و پیگیری روند توان‌بخشی انگشتان، شناسایی وضعیت دست حائز اهمیت است. هر حرکت انگشت نتیجه‌ی تعامل بین سیستم کنترل مرکزی و اندام‌های مربوطه است. برای حرکت هر انگشت دستورات عصبی در بخش غشای مغز صادر شده و از طریق نخاع و سیستم عصبی فرعی به عضلات مربوطه ارسال می‌شود. سیگنال الکترومایوگرام سیگنالی کنترلی بوده که بخش کنترل مرکزی آن را صادر نموده که باعث انقباض در عضله شده و در نهایت انگشت حرکت خاصی را انجام می‌دهد. سنسورهای مختلفی برای تعیین کینماتیک انگشتان دست وجود دارد. یکی از بهترین سنسورها الکترودهای الکترومایوگرام سطحی است که اطلاعات مفیدی در ارتباط با منشا هر حرکت دارد [۱].

یکی از زمینه‌های مرتبط با حرکات دست، طبقه‌بندی و شناسایی وضعیت‌های دست است. این کار ممکن است به روش‌های مختلفی صورت پذیرد. یکی از روش‌های طبقه‌بندی به کارگیری روش‌های یادگیری ماشین است. استخراج ویژگی و طبقه‌بندی‌های مبتنی بر یادگیری ماشین در اوایل به شکل گسترده مورد استفاده قرار گرفته است. استخراج ویژگی‌ها می‌تواند در سه حوزه‌ی زمان، فرکانس و زمان-فرکانس صورت پذیرد. در این شیوه الگوریتم‌های فراوانی از قبیل ماشین بردار هم‌زمان^۱، تحلیل متمایز خطی^۲، k همسایگی نزدیک^۳، مدل فضای حالت، خودرگرسیون غیرخطی^۴ و غیره وجود دارد.

آرتیگا و هم‌کارانش به منظور شناسایی ۶ حرکت گرفتن، ویژگی‌های زمان و فرکانس را از سیگنال‌های الکترومایوگرام استخراج نموده‌اند. بر اساس بررسی آن‌ها طبقه‌بند KNN وزن‌دار شده نسبت به سایر الگوریتم‌های یادگیری ماشین برتری دارد [۲]. فجارو و هم‌کارانش برای شناسایی وضعیت‌های دست، ترکیب ویژگی‌های سیگنال را پیشنهاد کرده‌اند. آن‌ها ابتدا به صورت دستی در حوزه‌ی زمان ویژگی‌هایی از سیگنال الکترومایوگرام را با ویژگی‌های عمیق استخراج شده توسط شبکه‌ی کانولوشن ترکیب کرده و سپس از شبکه‌ی عصبی برای طبقه‌بندی حرکات استفاده نموده‌اند [۳]. میفتن و هم‌کارانش بر اساس یک مدل اسپکتروگرام

لگاریتمی ویژگی‌های سیگنال الکترومایوگرام را استخراج کرده و با یک طبقه‌بند k-means حرکات دست را شناسایی نموده‌اند. در این تحقیق طبقه‌بندی ۶ حرکت گرفتن، انجام شده است [۴]. نارایان ویژگی‌های حوزه‌ی فرکانس و زمان-فرکانس را برای ۶ حرکت متفاوت دست استخراج نموده و سپس طبقه‌بند KNN را برای شناسایی حرکات به کار گرفته است [۵]. سوباسی و هم‌کارش بر اساس تبدیل موجک قابل تنظیم، ویژگی‌هایی را برای شناسایی ۶ حرکت استخراج نموده و سپس از طبقه‌بندی برای شناسایی حرکات استفاده کرده‌اند [۶]. ساین و هم‌کارانش با استفاده از تبدیل ویولت گسسته ویژگی‌هایی را از سیگنال الکترومایوگرام سطحی تعدادی از حرکات دست استخراج نموده‌اند. بر اساس نتایج مطالعه‌ی آن‌ها الگوریتم SVM نسبت به شبکه‌های عصبی برای طبقه‌بندی حرکات مذکور برتری دارد [۷]. او و هم‌کارش تبدیل موجک مقیاس متوسط را به سیگنال‌های الکترومایوگرام مربوط به ۶ حرکت گرفتن اعمال کرده و از شبکه‌ی کانولوشن برای طبقه‌بندی این حرکات استفاده نموده‌اند [۸]. ون و هم‌کارانش برای شناسایی ۱۷ حرکت دست ابتدا به شناسایی ویژگی در سیگنال الکترومایوگرام پرداخته و بر اساس یک مدل مارکو پنهان، حرکات دست را طبقه‌بندی کرده‌اند [۹]. کارنام و هم‌کارانش به منظور طبقه‌بندی حرکات دست از ویژگی‌های انرژی سیگنال‌های الکترومایوگرام استفاده نموده‌اند. تحقیق آن‌ها بر اساس الگوریتم‌های یادگیری ماشین KNN و SVM برای طبقه‌بندی حرکات دست صورت پذیرفته است [۱۰]. کی و هم‌کارانش از الگوریتم تحلیل مولفه‌ی اصلی و شبکه‌ی عصبی GRNN برای ایجاد یک سیستم شناسایی ۹ حرکت ایستای دست استفاده کرده‌اند. آن‌ها ابتدا با تحلیل مولفه‌ی اصلی، اطلاعات تکراری سیگنال‌ها را حذف نموده‌اند. ایشان معتقد هستند که این عمل باعث می‌شود که شناسایی حرکات به صورت زمان واقعی صورت پذیرد [۱۱]. بیگین و هم‌کارانش برای شناسایی ۶ حرکت گرفتن، یک روش انتخاب ویژگی دستی ارائه نموده، به استخراج ویژگی‌های آماری پرداخته و آن‌ها را ادغام کرده‌اند. آن‌ها برای طبقه‌بندی از الگوریتم‌های SVM و KNN استفاده نموده‌اند [۱۲]. لی و هم‌کارانش برای طبقه‌بندی ۱۰ حرکت انگشت و دست، ۱۶ ویژگی حوزه‌ی زمان را از سیگنال الکترومایوگرام استخراج کرده و با استفاده از شبکه‌های عصبی به طبقه‌بندی این حرکات پرداخته‌اند [۱۳]. در این روش‌ها به دلیل این که ابتدا ویژگی‌هایی از سیگنال

^۱ K-Nearest Neighbor (KNN)^۲ Nonlinear Autoregressive^۳ Support Vector Machine (SVM)^۴ Linear Discriminate Analysis (LDA)



دارای پارامترهای بیش‌تری بوده و نیاز به زمان مصرف بالاتر و هزینه‌ی بیش‌تری دارد. چن و هم‌کارانش با به‌کارگیری تبدیل ویولت و شبکه‌ی عصبی کانولوشن برخی حرکات دست را شناسایی نموده‌اند. آن‌ها در مطالعه‌ی خود یک شبکه‌ی کانولوشن فشرده که تعداد پارامترهای کم‌تری دارد را ارائه کرده‌اند [۲۴]. کیم و هم‌کارانش ابتدا با استفاده از تحلیل مولفه‌ی اصلی، فاکتورسازی ماتریس غیرمنفی ابعاد تصاویر سیگنال‌های الکترومایوگرام را کاهش داده و سپس با کمک شبکه‌ی کانولوشن وضعیت انگشت دست را بررسی نموده‌اند. آن‌ها در مطالعه‌ی خود ۸ جهت انگشت اشاره را شناسایی کرده‌اند [۲۵]. از شبکه‌ی عصبی بازگشتی نیز برای تخمین موقعیت اندام‌ها استفاده شده است. ناسری و هم‌کارانش با کمک شبکه‌ی عصبی بازگشتی به طبقه‌بندی ۶ حرکت دست پرداخته‌اند. آن‌ها برای پیاده‌سازی شبکه‌ی بازگشتی از واحدهای بازگشتی درجه‌دار استفاده نموده‌اند [۲۶]. سیمو و هم‌کارانش ابتدا ویژگی‌هایی از سیگنال sEMG را استخراج نموده و سپس با استفاده از شبکه‌های بازگشتی عمیق به شناسایی ۸ حرکت دست پرداخته‌اند. آن‌ها در مطالعه‌ی خود طبقه‌بندی برخط حرکات دست را انجام داده‌اند [۲۷]. در این تحقیق به پیش‌بینی و تعیین وضعیت حرکات انگشتان دست در ۸ وضعیت مختلف پرداخته شده است. برای این منظور یک شبکه‌ی کانولوشن طراحی شده است.

در مقایسه با تحقیقات پیشین روی شناسایی الگوهای دست که با شبکه‌های عصبی عمیق صورت گرفته، نوآوری‌های این پژوهش در ادامه بیان شده است. برخی از تحقیقات با تعداد زیادی الکتروود صورت پذیرفته اما در این مطالعه تنها از ۱۰ الکتروود استفاده شده و دقت‌های بالایی به دست آمده است. در بسیاری از تحقیقات ابتدا به استخراج ویژگی از سیگنال الکترومایوگرام پرداخته شده و سپس طبقه‌بندی حرکات انجام شده است. این کار پیچیده و زمان‌بر است و باعث افزایش هزینه‌های محاسباتی می‌شود. در این مطالعه طبقه‌بندی حرکات با استفاده از سیگنال خام صورت گرفته است. با وجود این که استفاده از الگوریتم‌های یادگیری ماشین می‌تواند به دقت‌های خوبی در طبقه‌بندی حرکات منجر شود اما به کارگیری این الگوریتم‌ها ممکن است منجر به از دست دادن اطلاعات مفید سیگنال گردد. در طراحی شبکه‌ی کانولوشن، نوع الگوریتم بهینه‌سازی که بر دقت طبقه‌بندی موثر است بر حسب سری داده‌ی مورد استفاده تغییر می‌کند. در این تحقیق با بررسی بهینه‌سازها در ارتباط با سری داده‌ی نیناپرو عمل کرد بهینه‌ساز مطلوب‌تر شناسایی شده است. در این پژوهش میزان

استخراج گردیده و سپس برای طبقه‌بندی از الگوریتم یادگیری ماشین استفاده می‌شود علاوه بر پیچیده بودن و زمان‌بر بودن فرایند ممکن است اطلاعات مفید سیگنال از دست برود [۱۴]. به کارگیری دانش یادگیری عمیق در علوم مختلف نتایج با ارزشی داشته است. این دانش برای شناسایی و تعیین وضعیت اندام‌های حرکتی انسان نیز قابل استفاده است. تحقیقاتی در زمینه‌ی شناسایی حرکات اندام‌ها و دست با استفاده از شبکه‌های عصبی عمیق کانولوشن، بازگشتی و ترکیب هر دو آن‌ها صورت پذیرفته است. آتزی و هم‌کارانش با ساخت تصاویر الکترومایوگرام سطحی و اعمال آن‌ها به یک شبکه‌ی کانولوشن، وضعیت‌های دست را شناسایی کرده‌اند. آن‌ها با ارائه‌ی یک معماری ساده به بررسی تاثیر پیش‌پردازش، افزودگی داده و معماری لایه‌ها روی دقت طبقه‌بندی حرکات پرداخته‌اند [۱۵]. جنگ و هم‌کارانش به شناسایی وضعیت‌های دست با استفاده از شبکه‌های کانولوشن پرداخته‌اند. آن‌ها مفهوم تصاویر الکترومایوگرام مکانی در نمونه‌برداری با الکترودهای سطحی با چگالی بالا را ارائه نموده‌اند [۱۶]. دو و هم‌کارانش طبقه‌بندی حرکات انگشتان دست را با استفاده از ۱۲۸ الکتروود انجام داده‌اند. آن‌ها در مطالعه‌ی خود یک چهارچوب تطبیق دامنه‌ی مبتنی بر یادگیری عمیق را ارائه کرده‌اند [۱۷]. دینگ و هم‌کارانش از شبکه‌ی عصبی کانولوشن با ابعاد فیلترهای بزرگ جهت شناسایی حرکات دست استفاده نموده‌اند. آن‌ها برای افزایش دقت، دو شبکه‌ی کانولوشن را با یک‌دیگر موازی کرده‌اند [۱۸]. شن و هم‌کارانش حرکات دست را با استفاده از شبکه‌ی عصبی کانولوشن شناسایی نموده‌اند. آن‌ها در مطالعه‌ی خود دو طبقه‌بند را به صورت متوالی به کار گرفته‌اند [۱۹]. کان و هم‌کارانش با کمک یک شبکه‌ی کانولوشن با اوزان سبک به شناسایی حرکات دست پرداخته‌اند. آن‌ها نوعی بهینه‌سازی را در پیاده‌سازی خود به کار گرفته‌اند [۲۰]. آسیف و هم‌کارانش ۱۱ حرکت مچ دست و انگشتان دست را با یک شبکه‌ی کانولوشن شناسایی کرده‌اند. آن‌ها به بررسی اثر تغییرات برخی از پارامترهای شبکه روی میزان کارایی شبکه پرداخته‌اند [۲۱]. کی و هم‌کارانش حرکت ترکیبی دست را با استفاده از یک شبکه‌ی عصبی کانولوشن سه‌بعدی شناسایی کرده‌اند [۲۲]. چن و هم‌کارانش در بررسی خود به شناسایی حرکات انگشتان دست با یک شبکه‌ی کانولوشن سه‌بعدی پرداخته‌اند. آن‌ها اعلام کرده‌اند که چون حرکات انتخابی دارای دینامیک هستند و کانولوشن سه‌بعدی ویژگی‌های زمانی و مکانی سیگنال را در نظر می‌گیرد شناسایی بهتری از حرکات انجام می‌شود [۲۳]. شبکه‌ی کانولوشن سه‌بعدی در مقایسه با شبکه‌ی دوبعدی

ترای‌سپ‌براجی در جمع‌آوری سیگنال‌های الکترومایوگرام سطحی نقش دارند. هر شخص حرکات مختلف را ۶ بار انجام داده است [۳۰]. حرکات انتخاب شده از مجموعه‌ی حرکات سری داده در شکل (۲) نشان داده شده است. داده‌برداری نیز با نرخ ۲ کیلوهرتز صورت پذیرفته است. مشخصات افراد شرکت کننده در این سری داده مطابق با جدول (۱) است.



شکل (۲) - حرکات انتخابی انگشتان دست، حرکت ۱: خم کردن تمام انگشتان به جز شست، حرکت ۲: باز کردن انگشت اشاره و انگشت وسط و خم کردن سایر انگشتان، حرکت ۳: خم کردن انگشت حلقه و انگشت کوچک و باز کردن سایر انگشتان، حرکت ۴: شست در جهت مخالف با انگشت کوچک، حرکت ۵: دور کردن انگشتان از هم (دست باز)، حرکت ۶: خم کردن تمام انگشتان (دست بسته)، حرکت ۷: باز کردن انگشت اشاره و خم کردن سایر انگشتان، حرکت ۸: نزدیک کردن انگشتان به سمت یکدیگر

جدول (۱) - مشخصات افراد شرکت کننده در داده‌برداری سری

داده‌ی DB2 نیناپرو

نوع/مقدار	پارامتر
۲۸/۸۰±۳/۹۶ سال	سن
۴۰ نفر سالم	تعداد افراد
۱۱ زن، ۲۹ مرد	جنسیت
۱/۲، ۳/۳	نسبت داده‌های آموزش و آزمایش
۵ / ۳۵	راست‌دست/چپ‌دست

چندین مرحله پردازش سیگنال قبل از در دسترس قرار دادن داده‌ها برای عموم انجام شده است. این مراحل شامل همگام‌سازی، برچسب گذاری مجدد و فیلتر کردن بوده است.

۲-۱-۱- همگام‌سازی

از گام‌های زمانی با وضوح بالا برای همگام‌سازی رشته‌های داده استفاده شده است. تمام سیگنال‌ها با بالاترین فرکانس نمونه‌برداری (۲ کیلوهرتز) با استفاده از درون‌یابی خطی یا درون‌یابی نزدیک‌ترین همسایه فرانونه‌برداری شده است.


تاثیر دو فرآیند حذف و تنظیم لبه (L2) که در تعیین دقت شبکه موثر هستند بررسی گردیده و مقدار بهینه‌ی آن‌ها انتخاب شده است. در تمام تحقیقات انجام شده‌ی پیشین بدون در نظر گرفتن فیزیولوژی مساله تنها با به کارگیری شبکه‌ی عمیق به طبقه‌بندی حرکات پرداخته شده است. در تحقیق حاضر دلیل این که طبقه‌بندی بعضی از حرکات با دقت بالاتری صورت گرفته با دلایل فیزیولوژیکی توضیح داده شده است.

در ادامه ابتدا مواد و روش به کار گرفته شده شامل شبکه‌های کانولوشن، روش بهینه‌سازی، ابرپارامترهای موثر در این شبکه‌ها، روش ارزیابی و شبکه‌ی پیاده‌سازی شده و خصوصیات آن ارائه شده است. در بخش سوم یافته‌های حاصل از پیاده‌سازی بیان گردیده و به بحث در مورد این یافته‌ها پرداخته شده است. نتیجه‌گیری نیز در بخش چهارم بیان شده است.

۲- مواد و روش‌ها

۲-۱- پایگاه داده

در این پژوهش از بانک داده‌ی نیناپرو سری دوم، که به صورت رایگان در دسترس عموم قرار دارد استفاده شده است [۲۸]. این پایگاه داده شامل داده‌های سیگنال الکترومایوگرام سطحی مربوط به ۴۰ نفر است که ۴۹ حرکت متفاوت را انجام داده‌اند. فعالیت عضلات توسط ۱۲ الکتروود جمع‌آوری شده و موقعیت الکتروودها روی دست در شکل (۱) نشان داده شده است.



شکل (۱) - موقعیت الکتروودها شامل ۸ الکتروود قرمز که به طور یکنواخت روی انتهای ساعد قرار گرفته و ۲ الکتروود آبی که روی عضلات بازکننده و خم‌کننده‌ی ظاهری واقع شده است [۲۹]

تعداد ۸ الکتروود به طور یکنواخت با استفاده از نوار پلاستیکی در یک فاصله‌ی ثابت از مفصل رادیوهمرال در زیر آرنج قرار گرفته است. تعداد ۲ الکتروود نیز روی عضلات خم‌کننده‌ی سطحی و بازکننده‌ی سطحی قرار دارد. تعداد ۲ الکتروود دیگر نیز در ناحیه‌ی بالایی ساعد روی عضلات بای‌سپ‌براجی و



۲-۱-۲- برچسب‌گذاری مجدد

استفاده شده است. ابعاد فیلترهای مورد استفاده برای لایه‌ی ادغام 2×2 یا 3×3 است. معمولاً در لایه‌ی ادغام عمل ماکسیمم‌گیری و یا میانگین‌گیری انجام می‌شود. در مسائل طبقه‌بندی با چندین کلاس، تابع فعالیت لایه‌ی آخر معمولاً بیشینه‌ی هموار^۲ در نظر گرفته می‌شود [۳۴].

حرکات انجام شده توسط افراد ممکن است به دلیل زمان واکنش انسان و شرایط آزمایشی، کاملاً با محرک‌های ارائه شده توسط نرم‌افزار مورد استفاده در این مقاله مطابقت نداشته باشد. نتیجه‌ی برچسب‌های حرکتی اشتباه تصحیح شده است.

۳-۱-۲- فیلتر کردن

بهینه‌سازها با تنظیم وزن‌ها و بایاس‌های شبکه‌ی عصبی، نرخ یادگیری خطای بین مقادیر پیش‌بینی شده و واقعی را کاهش داده و تابع هزینه را به حداقل می‌رسانند [۳۵]. هم‌چنین بهینه‌سازها می‌توانند به جلوگیری از برازش بیش از حد کمک کنند. دو مورد از رایج‌ترین این بهینه‌سازها گرادیان تصادف کاهشی و آدام هستند.

الکترودها در برابر تداخل خطوط برق محافظت نمی‌شوند. بنابراین قبل از همگام‌سازی، سیگنال‌های الکترومایوگرام سطحی از تداخل خط برق ۵۰ هرتز و هارمونیک با استفاده از فیلتر همپل^۱ پاک‌سازی شده است [۲۹]. داده‌ها برای هر شخص به دو بخش داده‌ی آموزش و تست تقسیم شده است. هر حرکت ۶ بار تکرار شده و مدت زمان هر حرکت ۵ ثانیه است. دوسوم از حرکات برای آموزش و یک‌سوم برای تست انتخاب شده است. حرکاتی که برای آموزش استفاده شده به عنوان حرکات تست به کار گرفته نشده است.

۲-۳-۱- گرادیان تصادف کاهشی

یکی از بزرگ‌ترین چالش‌های این بهینه‌ساز در مواجهه با سری داده‌های بزرگ، هزینه‌ی محاسباتی گرادیان‌ها است [۳۶]. در این موارد گرادیان کاهشی تصادفی به جای استفاده از تمام سری داده برای هر تکرار^۳ تنها بسته‌هایی از سری داده را به طور تصادفی انتخاب کرده که باعث می‌شود با یک زیرسری داده‌ی کوچک‌تر پردازش صورت پذیرد [۳۷].

۲-۲- ساختار شبکه‌ی کانولوشنال

بهینه‌ساز آدام یک نسخه‌ی توسعه یافته از الگوریتم گرادیان نزولی تصادفی محبوب است که از آن برای به‌روزرسانی وزن یک شبکه‌ی عصبی استفاده می‌شود. با تجزیه و تحلیل گرادیان‌ها، آدام می‌تواند نرخ یادگیری را برای هر پارامتر به صورت بلادرنگ تنظیم کند که منجر به همگرایی سریع‌تر و عمل‌کرد بهتر می‌شود [۳۸].

ساختار اصلی معماری کانولوشن به کار گرفته شده در این طراحی، ساختار معماری کانولوشن بوده که نخستین بار توسط لی‌کان (ابداع‌کننده‌ی شبکه‌ی کانولوشن) مورد استفاده قرار گرفته است [۳۱]. لی‌کان این شبکه را برای طبقه‌بندی دست‌نوشته انتخاب کرده است. البته اصلاحاتی در این معماری به منظور بهینه کردن عمل‌کرد آن صورت گرفته است. داده‌ی ورودی به صورت یک تصویر به شبکه اعمال شده که ابعاد این تصویر بر اساس طول پنجره‌ی زمانی و تعداد الکترودها انتخاب شده است. بر اساس تحقیقاتی که در این زمینه انجام شده، طول پنجره با اندازه‌ی ۱۵۰ میلی‌ثانیه بهینه است [۳۲]. فیلتر لایه‌ی اول کانولوشن سطری انتخاب شده که تعداد ستون آن برابر با تعداد الکترودهای انتخابی است. در شبکه‌ی کانولوشن چون ابعاد نقشه‌ی ویژگی با افزایش عمق کاهش می‌یابد تعداد فیلترها هر چه به ورودی نزدیک‌تر باشد کم‌تر و هر چه به خروجی نزدیک‌تر باشد بیش‌تر انتخاب شده است [۳۳]. ابعاد فیلتر بر اساس سری داده تنظیم می‌شود. برای داده‌های الکترومایوگرام سطحی در مطالعات انجام شده ابعاد فیلترهای لایه‌های کانولوشن معمولاً 3×3 و 5×5 بوده است. از واحد خطی یک‌سو شده به عنوان تابع فعالیت غیرخطی در لایه‌های کانولوشن و از لایه‌ی ادغام برای کاهش ابعاد نقشه‌ی ویژگی

۲-۴- تنظیم‌کننده‌های شبکه‌ی کانولوشنال

منظم‌سازی یک گام مهم در یادگیری شبکه‌های عصبی است. منظم‌سازی با کاهش احتمال برازش بیش از حد داده‌های آموزشی به تعمیم مدل کمک می‌کند. انواع مختلفی از تکنیک‌های منظم‌سازی وجود دارد. دو فراپارامتری که در منظم‌سازی و در نتیجه در دقت طبقه‌بندی شبکه، زمان رسیدن به همگرایی شبکه و حداکثر دقت نقش دارند مقدار لایه‌ی حذف تصادفی و پارامتر تنظیم لایه‌ی $L2$ ^۴ هستند.

^۱ Iteration

^۲ Ridge

^۳ Hampel

^۴ Soft Max

کلاس واقعی را نشان داده در حالی که هر ستون نمونه‌های یک کلاس پیش‌بینی شده را نشان می‌دهد (یا برعکس). این ماتریس در حالت‌های دو و چندکلاس می‌تواند بررسی شود. ماتریس خطا در حالت دوتایی به صورت زیر است.

مقادیر پیش‌بینی			
مثبت	منفی		
TP	FN	مثبت	هدف
FP	TN	منفی	

بر اساس اطلاعات فوق صحت مطابق با رابطه‌ی (۲) است.


$$\text{صحت} = \frac{TP + TN}{TP + TN + FP + FN} \times 100 \quad (2)$$

۲-۶- مشخصات شبکه‌ی طراحی شده

طراحی شبکه‌ی کانولوشنال پیاده‌سازی شده در شکل (۴) نشان داده شده است. معماری شبکه‌ی کانولوشنال توصیف شده در این پژوهش از ۱ لایه‌ی ورودی، ۵ لایه‌ی کانولوشن پنجهان و ۱ لایه‌ی خروجی تشکیل شده است. به منظور طبقه‌بندی حرکات بر اساس الکترومایوگرام معمولاً لایه‌ی اول به صورت برداری سطری انتخاب شده که تعداد ستون‌های آن برابر با تعداد الکترودها است. در این تحقیق از سری داده‌ی DB2 استفاده شده که در آن سیگنال الکترومایوگرام توسط ۱۲ الکترودها جمع‌آوری گردیده اما ۲ الکترودها در محلی واقع شده که اطلاعات آن الکترودها در حرکات انتخابی تأثیری ندارد بنابراین از ۱۰ الکترودها استفاده شده است. دو لایه‌ی پنجهان اول دارای ۳۲ فیلتر به ترتیب با اندازه‌های ۱×۱۰ و ۳×۳ هستند. لایه‌های پنجهان سوم و چهارم هر کدام ۶۴ فیلتر دارند. فیلتر لایه‌ی کانولوشن سوم ۵×۵ و لایه‌ی پنجم ۱×۱ است. لذا فیلتر لایه‌ی چهارم ۵×۱ انتخاب شده است تا این کاهش ابعاد هموارتر صورت پذیرد. لایه‌ی پنجم دارای ۸ فیلتر با ابعاد ۱×۱ بوده و به دنبال آن لایه‌ی بیشینه‌ی هموار لحاظ شده است. فیلتر لایه‌ی آخر نیز به صورت برداری ستونی بوده که تعداد سطرهای آن برابر تعداد کلاس‌های حرکات انتخاب شده یعنی ۸ است. لایه‌گذاری صفر قبل از کانولوشن‌ها در لایه‌های پنجهان اعمال شده است. بعد از کانولوشن‌ها واحد خطی اصلاح شده اعمال شده است. علاوه بر این یک لایه‌ی حذفی برای صفر نمودن تصادفی خروجی واحد پنجهان وجود داشته که برای جلوگیری از برازش بیش از حد خروجی کاربرد دارد. یک لایه‌ی زیر

۲-۴-۱- مقدار لایه‌ی حذف تصادفی

این ساز و کار یکی از بهترین شیوه‌های تنظیم در شبکه‌های عصبی عمیق بوده که به کارگیری آن منجر به نتایج مطلوبی می‌شود. لایه‌ی حذف تصادفی بخشی از واحدهای ورودی را در طول هر به‌روزرسانی یادگیری غیرفعال می‌نماید. با به کارگیری این لایه در طراحی شبکه، در طول انتشار رو به جلو، نورون‌های خاصی در شبکه به همراه اتصالات مرتبط با آن‌ها بر اساس یک احتمال خاص، حذف شده یا موقتاً نادیده گرفته می‌شوند [۳۹]. نحوه‌ی عمل کرد این لایه در شکل (۳) نشان داده شده است.



شکل (۳) - الف) شبکه بدون اعمال لایه‌ی حذف تصادفی، ب) شبکه با اعمال لایه‌ی حذف تصادفی [۴۰]

۲-۴-۲- پارامتر تنظیم لایه‌ی L2

این منظم‌سازی مجموع مربعات اوزان را به تابع زیان اضافه می‌کند. در نتیجه تأثیر ویژگی‌های هم‌بسته به طور مساوی در بین ضرایب توزیع شده و تأثیر وزن‌های بزرگ کم می‌شود. همچنین از تسلط هر یک از ویژگی‌ها بر پیش‌بینی مدل جلوگیری شده و پیچیدگی مدل کاهش می‌یابد. این عمل در رابطه‌ی (۱) بیان شده است [۴۱].

$$\text{Cost function} = \text{Loss} + \frac{\lambda}{2m} * \sum \|w\|^2 \quad (1)$$

در این رابطه λ ابرپارامتر تنظیم است که مقدار آن برای ایجاد نتایج بهتر بهینه می‌شود.

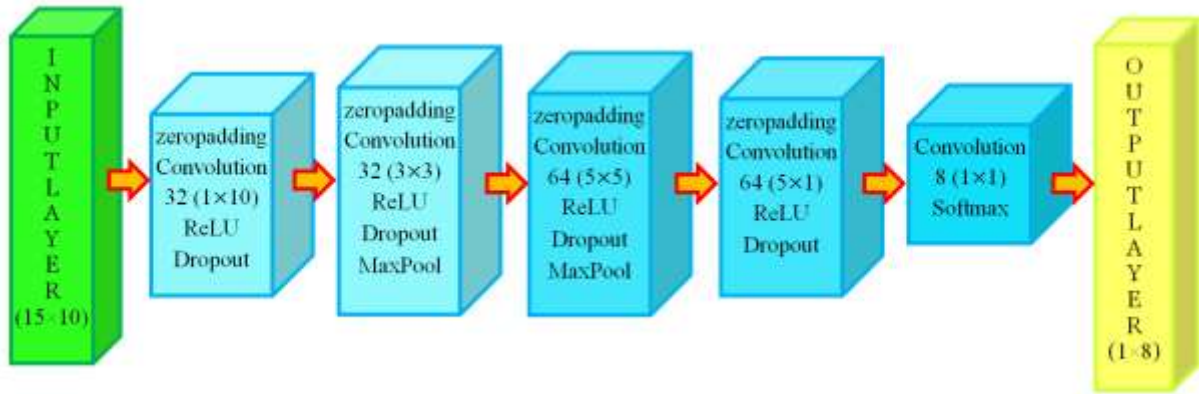
۲-۵- معیار ارزیابی

۲-۵-۱- ماتریس خطا

ماتریس خطا ابزار مهمی برای ارزیابی عمل کرد الگوریتم‌های طبقه‌بندی در یادگیری ماشین است که عمل کرد یک الگوریتم طبقه‌بندی را تجسم و خلاصه می‌کند. این ماتریس یک مقایسه‌ی جامع بین دقت مقادیر واقعی و پیش‌بینی شده را ممکن می‌سازد. این ماتریس دارای ابعاد $N \times N$ بوده که N تعداد کلاس‌ها یا خروجی‌ها است. هر ردیف از ماتریس نمونه‌های یک

کاهش نمونه‌های ویژگی‌های خروجی و به دست آوردن مهم‌ترین ویژگی‌ها می‌باشد.

نمونه‌برداری عمل ادغام ماکسیمم را در یک پنجره‌ی 3×3 بعد از حذف لایه‌های دوم و سوم انجام می‌دهد. این ادغام برای



شکل (۴) - معماری شبکه‌ی کانولوشن طراحی شده، لایه‌ی ورودی مطابق با زمان پنجره در تعداد الکترودهای استفاده شده است، در لایه‌ی کانولوشن اول $32 \times 10 \times 1$ فیلتر وجود دارد، واحد خطی یک‌سو شده و لایه‌ی حذف تصادفی بعد از آن قرار دارد، در لایه‌ی دوم از $32 \times 3 \times 3$ فیلتر استفاده شده است، واحدهای خطی یک‌سو شده، لایه‌ی حذف تصادفی و لایه‌ی ادغام ماکسیمم نیز در ادامه‌ی آن واقع شده است، در لایه‌ی سوم $64 \times 5 \times 5$ فیلتر یک‌سو شده، لایه‌ی حذف تصادفی و لایه‌ی ادغام ماکسیمم وجود دارد، برای لایه‌ی چهارم $64 \times 1 \times 5$ فیلتر واحد خطی یک‌سو شده و لایه‌ی حذف تصادفی در نظر گرفته شده است، لایه‌ی پنجم کانولوشن $8 \times 1 \times 1$ فیلتر با ابعاد 1×1 و لایه‌ی بیشینه‌ی هموار را در بر دارد، در لایه‌های کانولوشن اول تا چهارم لایه‌گذاری صفر قبل از عمل کانولوشن انجام شده است، لایه‌ی خروجی نیز برداری سطری است و تعداد حالت‌های دست را در بر دارد

قرار گرفته است. ویژگی‌های شبکه‌ی عصبی عمیق طراحی شده در جدول (۲) ارائه شده است.

شناسایی وضعیت دست بر اساس سیگنال الکترومایوگرام سطحی به عنوان یک مساله‌ی طبقه‌بندی تصویر با استفاده از شبکه‌ی کانولوشن تلقی می‌شود. تصویر sEMG ورودی دارای ابعاد $H \times W \times 1$ است. به طور کلی در تحقیقات انجام شده برای طبقه‌بندی حرکات دست بر اساس شبکه‌ی کانولوشن سه روش برای ایجاد تصویر به کار گرفته شده است. روش اول شامل سیگنال‌های الکترومایوگرام مربوط به یک آرایه‌ی دوبعدی است. در این حالت عرض و ارتفاع آرایه با ابعاد تصویر مطابقت دارد [۱۵]. در روش دوم قطعاتی از سیگنال‌های الکترومایوگرام با استفاده از پنجره‌های زمانی انتخاب می‌شود. در این حالت عرض تصویر با تعداد الکترودها و ارتفاع آن با طول پنجره مطابقت دارد [۱۶]. در روش سوم اسپکتروگرام یا تبدیل ویولت قطعاتی از سیگنال الکترومایوگرام سطحی انتخاب می‌شود [۴۲]. در این تحقیق به منظور اعمال ورودی به شبکه از شیوه‌ی دوم استفاده شده است. ابتدا داده‌ها به شکل یک تصویر در آمده و سپس تصویر حاصل به شبکه اعمال شده است. طول پنجره برابر با 150 میلی‌ثانیه بوده که یک طول پنجره‌ی بهینه است. طول پنجره در بازه‌ی 100 تا 300 میلی‌ثانیه انتخاب شده است. عرض پنجره برابر با تعداد الکترودها بوده که در این‌جا از 10 الکترودها برای طبقه‌بندی استفاده شده است. در طراحی این شبکه دو بهینه‌ساز آدام و گرادیان نزولی تصادفی مورد بررسی

جدول (۲) - ویژگی‌های شبکه‌ی عصبی عمیق طراحی شده

پارامتر	نوع/مقدار
تعداد فیلترها	۸، ۶۴، ۶۴، ۳۲، ۳۲
تعداد لایه‌ها	۷
ابعاد فیلترها	1×1 ، 5×5 ، 3×3 ، 1×10
نسبت داده‌های آموزش و آزمایش	۱/۲، ۳/۳
بهینه‌ساز	آدام، گرادیان کاهش تصادفی
لایه‌ی حذف تصادفی	✓
رگولاریزاسیون L2	✓

۳- یافته‌ها و بحث

۳-۱- ارزیابی شبکه‌ی طراحی شده

ماتریس خطای مربوط به طبقه‌بندی 8 حرکت بررسی شده در این پژوهش در شکل (۵) نشان داده شده است. دقت برخی از حرکات بالاتر و برخی پایین‌تر است به طوری که دقت طبقه‌بندی 8 کلاس حرکتی در بازه‌ی 85 تا $98/9$ قرار دارد. این اختلاف در دقت طبقه‌بندی از نقطه‌نظر فیزیولوژی قابل بررسی است. عضلات ساعد دست بر اساس میزان نزدیکی به

باز کردن انگشتان توسط عضلات بازکننده‌ی ظاهری دیجیتالوروم و بازکننده‌ی عمقی دیجیتالوروم انجام می‌شود. عمل خم کردن انگشت شست بر عهده‌ی عضله‌ی خم‌کننده‌ی پلیسیس لانگوس و عمل باز کردن آن بر عهده‌ی عضله‌ی بازکننده‌ی پلیسیس لانگوس است [۴۳].

پوست دست به دو دسته‌ی عمقی و ظاهری تقسیم‌بندی می‌شوند. علاوه بر این تقسیم‌بندی برخی عضلات دست عمل خم کردن انگشتان دست و برخی باز کردن آن‌ها را به عهده دارند. عمل خم کردن انگشتان دست به جز انگشت شست توسط عضلات خم‌کننده‌ی دیجیتالوروم و دیجیتی مینیمی و عمل

Confusion Matrix

1	94			1					98.9%	1.1%
2		86		3		3		2	91.5%	8.5%
3		1	91	2					96.8%	3.2%
4	3	2		85		2	2		90.4%	9.6%
5					89		1	3	95.7%	4.3%
6		3			2	86		3	91.5%	8.5%
7	2		2			2	86	3	90.5%	9.5%
8	2		3		5		3	77	85.6%	14.4%
	93.1%	93.5%	94.8%	93.4%	92.7%	92.5%	93.5%	87.5%		
	6.9%	6.5%	5.2%	6.6%	7.3%	7.5%	6.5%	12.5%		
	1	2	3	4	5	6	7	8		
	Predicted class									

شکل (۵) - ماتریس خطای شبکه‌ی کانولوشن طراحی شده

جدول (۳) - صحت طبقه‌بندی برای ۱۰ نفر از سری داده

شخص	صحت (%)
۱	۹۲/۳۴
۲	۹۲/۴۶
۳	۹۴/۷۱
۴	۸۹/۴۶
۵	۹۳/۱۱
۶	۹۴/۲۸
۷	۹۰/۱۸
۸	۸۸/۶۵
۹	۸۹/۳۳
۱۰	۹۳/۷۶

۳-۲- مقایسه‌ی تاثیر دو بهینه‌ساز

بر خلاف الگوریتم گرادین کاهشی تصادفی که تنها یک نرخ یادگیری را در سراسر یادگیری حفظ می‌کند، آدام به طور دینامیکی نرخ‌های یادگیری را بر اساس گرادین‌های گذشته و ممن‌های مرتبه‌ی دوم محاسبه می‌نماید. این تنظیم وفقی نرخ‌های یادگیری به غلبه بر بعضی از محدودیت‌های گرادین

با توجه به شکل (۱) موقعیت قرار گرفتن الکترودها به گونه‌ای است که این الکترودها روی عضلات موثر در حرکات انگشتان غیر از انگشت شست واقع شده‌اند و سیگنال الکترومایوگرام دریافتی اطلاعات کافی را دارد اما الکترودها روی عضلات موثر در حرکت انگشت شست واقع نیستند و سیگنال الکترومایوگرامی که توسط الکترودها در ارتباط با این عضلات جمع‌آوری شده دارای غنای کافی نبوده و بنابراین دقت شناسایی طبقه‌بندی انگشت شست را تحت تاثیر قرار داده است. کلاس دارای کم‌ترین دقت، کلاس شماره‌ی ۸ با دقت ۸۵ درصد است. این حرکت مربوط به نزدیک شدن انگشتان است که توسط عضلات بین استخوانی کف دست صورت می‌گیرد. از آن‌جا که تمام الکترودها در قسمت پروگزیمال مساعد قرار دارند بنابراین قادر به تشخیص موثر حرکت نزدیک شدن انگشتان نیستند. در مورد حرکت دورشدگی انگشتان نسبت به نزدیک شدن آن‌ها چون عضلات موثر در حرکت دورشدگی به الکترودها نزدیک‌تر هستند طبقه‌بندی این حرکت با دقت بالاتری صورت گرفته است. با محاسبه‌ی ماتریس خطا روی ۱۰ نفر از سری داده، نتایج جدول (۳) به دست آمده است.



جدول (۶) - تاثیر پارامتر تنظیم L2 بر میزان دقت طبقه‌بندی

پارامتر L2	صحت
۰/۵	۰/۸۷
۰/۰۵	۰/۸۸
۰/۰۰۵	۰/۸۹
۰/۰۰۰۵	۰/۹۳

با افزایش مقدار پارامتر L2 میزان دقت این شبکه کاهش یافته است. البته با کاهش این مقدار، دوره‌های بیش‌تر و در نتیجه زمان بیش‌تری برای رسیدن به دقت بالا و همگرایی بالاتر نیاز است. برای جلوگیری از برازش بیش از حد شبکه، لایه‌ی حذف تصادفی و پارامتر تنظیم L2 در معماری شبکه لحاظ شده است. از آن‌جا که اختلاف بین نتایج تابع زیان در آموزش و تست کم بوده شبکه دچار بیش برازش نشده است. تابع زیان برای ۱۰ نفر برای داده‌های آموزش و تست در جدول (۷) ارائه شده است. تابع زیان، میانگین مربعات خطا است.

جدول (۷) - تاثیر پارامتر تنظیم L2 بر میزان دقت طبقه‌بندی

شخص	تابع زیان-آموزش	تابع زیان-تست
۱	۱/۶۵	۲/۲
۲	۱/۷۲	۲/۱۸
۳	۱/۳۴	۱/۸
۴	۱/۷۲	۲/۳۵
۵	۱/۶	۲/۱۵
۶	۱/۳۶	۱/۹
۷	۱/۷۴	۲/۳۸
۸	۱/۸۷	۲/۴
۹	۱/۷۷	۲/۳
۱۰	۱/۵۹	۲/۰۵

کارهای زیادی در ارتباط با طبقه‌بندی حرکات دست و شناسایی حالت دست صورت گرفته است. در روش‌های یادگیری ماشین [۲-۱۳] ابتدا به استخراج ویژگی پرداخته شده و سپس عمل طبقه‌بندی با یک الگوریتم یادگیری ماشین صورت گرفته که این شیوه پیچیده، زمان‌بر و پرهزینه است. در ارتباط با به کارگیری یادگیری عمیق برای طبقه‌بندی حرکات دست، در برخی تحقیقات عمل داده‌برداری با تعداد زیادی الکتروود صورت گرفته است [۱۶، ۱۷]. هر چند این عمل در شناسایی واحدهای حرکتی مفید بوده و به اطلاعات مفیدی مربوط به منشا حرکت منجر شده است اما در ارتباط با طبقه‌بندی حرکات نیازی به وجود تعداد زیادی الکتروود نیست. در تحقیقات مذکور به ترتیب حداکثر دقت‌های ۸۹/۹ و ۸۵/۶ درصد به دست آمده است. مطالعاتی نیز برای افزایش دقت با

کاهش تصادفی از قبیل نیاز به تنظیم دستی نرخ یادگیری و همگرایی کندتر کمک می‌کند. آدام توانایی تخمین و تطبیق ممنتهای مرتبه‌ی اول و دوم را دارد. بهینه‌ساز آدام یک ساز و کار برای همگرایی سریع‌تر در طول یادگیری دارد. با این حال انتخاب بهینه‌ی بهینه‌ساز ممکن است به مجموعه‌ی داده‌های خاص و مشکلی که حل می‌شود بستگی داشته باشد. در سری داده‌ی مورد بررسی، بهینه‌ساز گرادیان تصادفی بعد از ۱۱۰ دور به دقت ۰/۸۷ رسیده در حالی که با به کارگیری بهینه‌ساز آدام تنها پس از ۳۰ دور دقت ۰/۹۵ حاصل شده است. این نتایج در جدول (۴) بیان شده است.

جدول (۴) - مقایسه‌ی تاثیر دو بهینه‌ساز بر دقت طبقه‌بندی

تعداد دور	صحت	بهینه‌ساز
۳۰	۰/۹۳	Adam
۱۱۰	۰/۸۷	SGD

۳-۳- تاثیر لایه‌ی حذف تصادفی بر عمل‌کرد شبکه
میزان دقت طبقه‌بندی شبکه‌ی طراحی شده به ازای مقادیر مختلف برای به کارگیری لایه‌ی حذف تصادفی در بازه‌ی ۰ تا ۰/۸ در جدول (۵) ارائه گردیده است.

جدول (۵) - تاثیر لایه‌ی حذف تصادفی بر دقت طبقه‌بندی

تعداد دور	صحت	پارامتر Drop Out
۶۰	۰/۹۵۱	۰
۶۸	۰/۹۶۲	۰/۲
۵۰	۰/۹۴۴	۰/۳
۴۰	۰/۹۳۲	۰/۴
۳۰	۰/۹۱	۰/۵
۲۵	۰/۸۷۹	۰/۶
۲۰	۰/۷۸۸	۰/۷
۱۶	۰/۶۳۵	۰/۸

مشاهده می‌شود که با افزایش مقدار لایه‌ی حذف تصادفی دقت شبکه کاهش یافته است. البته با کاهش مقدار حذف لایه‌ی تصادفی تعداد دورها و زمان لازم برای رسیدن به همگرایی و دقت بالا افزایش یافته است.

۳-۴- تنظیم کننده‌ی لایه‌ی L2

در این پژوهش شبکه‌ی پیشنهاد شده با مقادیر مختلفی از پارامتر L2 در بازه‌ی بین ۰/۰۰۰۵ تا ۰/۵ مورد ارزیابی قرار گرفته و نتایج آن در جدول (۶) ارائه شده است.

کاملاً موثر است. با افزایش این مقدار دقت طبقه‌بندی کاهش می‌یابد. البته به هر میزان که این پارامتر کاهش یابد تعداد دوره‌های لازم برای رسیدن به حداکثر دقت افزایش می‌یابد. پارامتر تنظیم لبه‌ی L2 نیز در میزان دقت موثر است به طوری که با افزایش مقدار آن دقت طبقه‌بندی کاهش می‌یابد.

۵- مراجع

- [1] R. Merletti, D. Farina, "Surface electro myography: Physiology, engineering and applications", 1st ed., New Jersey, John Wiley & Sons, 2016, pp. 440-443.
- [2] M.V. Arteaga, J.C. Castiblanco, I. F. Mondragon, J. D. Colorado, C.A. Rojas, "EMG-driven hand model based on the classification of individual finger movements", *Biomedical Signal Processing and Control*, volume 58, no. 101834, 2020. <https://doi.org/10.1016/j.bspc.2019.101834>.
- [3] J. M. Fajardo, O. Gomez, F. Prieto, "EMG hand gesture classification using handcrafted and deep features", *Biomedical Signal Processing and Control*, volume 63, no. 102210, 2021. <https://doi.org/10.1016/j.bspc.2020.102210>.
- [4] F.S. Miften, M. Diykh, S. Abdulla, S. Siuly, J.H. Green, R.C. Deo, "A new framework for classification of multi-category hand grasps using EMG signals", *Artificial Intelligence in Medicine*, vol. 112, 102005, 2021. <https://doi.org/10.1016/j.artmed.2020.102005>.
- [5] Y., Narayan. "SEMG signal classification using KNN classifier with FD and TFD features". *Materials Today: Proceedings*, vol. 37, no. 2, pp. 3219-3225, 2021. <https://doi.org/10.1016/j.matpr.2020.09.089>.
- [6] A., Subasi, S.M., Qaisar. "Surface EMG signal classification using TQWT, Bagging and Boosting for hand movement recognition." *J Ambient Intell Human Comput*, vol. 13, pp. 3539-3554, 2022. <https://doi.org/10.1007/s12652-020-01980-6>.
- [7] R.M., Singh, V., Ahlawat, S., Chatterji, A., Kumar. "Comparative analysis of SVM and ANN classifier based on surface EMG signals for elbow movement classification". *Journal of Interdisciplinary Mathematics*, vol. 23, no. 1, pp. 153-161, 2020. <https://doi.org/10.1080/09720502.2020.1721709>.
- [8] D.C., Oh, Y.U., Jo. "Classification of hand gestures based on multi-channel EMG by scale average wavelet transform and convolutional neural network". *Int. J. Control. Autom. Syst.*, 19, 1443-1450, 2021. <https://doi.org/10.1007/s12555-019-0802-1>.
- [9] R. Wen, Q. Wang, Z. Li, "Human hand movement recognition using infinite hidden Markov model based sEMG classification", *Biomedical Signal Processing and Control*, vol. 68, no. 102592, 2021, <https://doi.org/10.1016/j.bspc.2021.102592>.

استفاده از دو شبکه‌ی کانولوشن موازی [۱۸] و یا سری [۱۹] صورت گرفته است. در این دو پژوهش نیز به ترتیب حداکثر دقت‌های ۸۳/۷۹ و ۸۱/۰۱ حاصل شده است اما موازی یا سری نمودن شبکه‌های کانولوشن باعث پیچیده‌تر شدن طراحی گردیده و زمان و هزینه‌ی مصرفی را افزایش می‌دهد. در تعدادی از پژوهش‌های پیشین ابتدا ویژگی‌هایی از سیگنال الکترومایوگرام استخراج گردیده و سپس عمل طبقه‌بندی با شبکه‌ی کانولوشن صورت گرفته و در بعضی حالات حداکثر دقت ۸۶/۳۴ به دست آمده است [۲۵]. استخراج ویژگی در این موارد ممکن است باعث از دست رفتن اطلاعات مفید سیگنال شود. در برخی از مطالعات عمل طبقه‌بندی حرکات دست با شبکه‌های بازگشتی انجام شده و دقت‌های ۸۹ و ۹۱ درصد حاصل شده [۲۶، ۲۷] در حالی که طبقه‌بندی‌ها در حالت استاتیک انجام شده و نیازی برای به کارگیری شبکه‌های بازگشتی برای در نظر گرفتن دینامیک سیستم وجود ندارد و تنها انجام عمل طبقه‌بندی با شبکه‌های کانولوشن میسر است. در این مقاله با استفاده از سیگنال الکترومایوگرام سطحی خام مربوط به ۱۰ الکتروود به طبقه‌بندی ۸ حرکت پایه‌ای پرداخته شده است. علاوه بر این با انتخاب صحیح و دقیق بهینه‌کننده‌ها و تنظیم‌کننده‌ها در برخی از حرکات دقت ۹۸/۹ درصد برای طبقه‌بندی حاصل شده است. همچنین در این تحقیق نتایج حاصل از پژوهش از نقطه‌نظر فیزیولوژی نیز بررسی شده است.

۴- نتیجه‌گیری

در این تحقیق به طبقه‌بندی ۸ حرکت دست بر اساس شبکه‌های عصبی عمیق کانولوشنال با استفاده از سیگنال‌های الکترومایوگرام سطحی پرداخته شده است. برای این منظور از قسمت دوم سری داده‌ی نیناپرو استفاده گردیده است. ساختار این شبکه به طور کامل توصیف شده است. طبقه‌بندی برخی از کلاس‌های حرکتی با دقت بالاتری صورت گرفته که دلیل آن محل قرارگیری الکتروودها روی عضلات موثر در حرکات مختلف است. الگوریتم‌های بهینه‌سازی و برخی فرآیندها در میزان دقت شبکه‌ی طراحی شده نقش دارند که این مساله مورد بررسی قرار گرفته است. برای داده‌های الکترومایوگرام سطحی به کارگیری بهینه‌ساز آدام نسبت به بهینه‌ساز گرادیان نزولی تصادفی منجر به دقت بالاتر و همگرایی سریع‌تر شبکه‌ی عصبی عمیق شده است. در طراحی شبکه‌های مبتنی بر یادگیری عمیق حتی بعد از طراحی یک معماری خوب به منظور بهبود عمل کرد لازم است تغییرات برخی فرآیندها مورد بررسی قرار گیرد. مقدار پارامتر لایه‌ی حذف تصادفی در عمل کرد شبکه

- [21] AR. Asif, A. Waris, SO. Gilani, M. Jamil, H. Ashraf, M. Shafique, IK. Niazi, Performance Evaluation of Convolutional Neural Network for Hand Gesture Recognition Using EMG. *Sensors*. 2020; 20, 6, pp. 1642. <https://doi.org/10.3390/s20061642>.
- [22] S., Qi, X., W., Chen, J., Liu, J., Zhang, J., Wang, sEMG-based recognition of composite motion with convolutional neural network, *Sensors and Actuators A: Physical*, Volume 311, 2020, 112046, ISSN 0924-4247, <https://doi.org/10.1016/j.sna.2020.112046>.
- [23] X. Chen, Y. Li, R. Hu, X. Zhang and X. Chen, "Hand Gesture Recognition based on Surface Electromyography using Convolutional Neural Network with Transfer Learning Method," in *IEEE Journal of Biomedical and Health Informatics*, vol. 25, no. 4, pp. 1292-1304, April 2021, <https://doi.org/10.1109/JBHI.2020.3009383>.
- [24] L. Chen, J. Fu, Y. Wu, H. Li, B. Zheng. Hand Gesture Recognition Using Compact CNN via Surface Electromyography Signals. *Sensors*. 2020; 20,3, pp.672.<https://doi.org/10.3390/s20030672>.
- [25] Y., Kim, S., Stapornchaisit, M., Miyakoshi, N., Yoshimura, Y., Koike. "The Effect of ICA and Non-negative Matrix Factorization Analysis for EMG Signals Recorded From Multi-Channel EMG Sensors". *Front. Neurosci.* 14:600804. 2020. <https://doi.org/10.3389/fnins.2020.600804>.
- [26] N. Nasri, S. Orts-Escolano, F. Gomez-Donoso, M. Cazorla, "Inferring static hand poses from a low-cost non-intrusive sEMG sensor," *Sensors*, vol. 19, no. 2, pp. 371, Jan. 2019, <https://doi.org/10.3390/s19020371>.
- [27] M., Simão, P., Neto, O., Gibaru, "EMG-based online classification of gestures with recurrent neural networks", *Pattern Recognition Letters*, vol. 128, 2019, pp. 45-51, <https://doi.org/10.1016/j.patrec.2019.07.021>.
- [28] <http://ninaweb.hevs.ch/>
- [29] N.J. Jarque-Bou, M. Atzori, H. Müller, "A large calibrated database of hand movements and grasps kinematics," *Sci. Data*, vol. 7, no. 12, Jan. 2020, <https://doi.org/10.1038/s41597-019-0349-2>.
- [30] M. Atzori, A. Gijssberts, C. Castellini, B. Caputo, A.G.M. Hager, S. Elsig, Electromyography data for non-invasive naturally-controlled robotic hand prostheses, *Scientific Data*, 2014, 1, 1.<https://doi.org/10.1038/sdata.2014.53>.
- [31] Y., LeCun, L.D., Jackel, L., Bottou, A., Brunot, C., Cortes, J.S., Denker. "Comparison of learning algorithms for hand written digit recognition." In *international conference on artificial neural networks (Paris)*, 53–60, 1995.
- [32] K., Englehart, B., Hudgins, P.A., Parker, M. Stevenson. Classification of the myoelectric signal using time-frequency based representations. *Med. Eng. Phys.* Vol.21, pp.
- [10] N.K., Karnam, A. C., Turlapaty, S. R., Dubey, B., Gokaraju, "Classification of sEMG signals of hand gestures based on energy features", *Biomedical Signal Processing and Control*, vol. 70, 2021, 102948, <https://doi.org/10.1016/j.bspc.2021.102948>.
- [11] J., Qi, G., Jiang, G., Li. "Surface EMG hand gesture recognition system based on PCA and GRNN". *Neural Comput & Applic* 32, pp. 6343–6351, 2020. <https://doi.org/10.1007/s00521-019-04142-8>.
- [12] M., Baygin, P.D., Barua, S., Dogan, T., Tuncer, S. Key, U.R., Acharya, K.H., Cheong. "A Hand-Modeled Feature Extraction-Based Learning Network to Detect Grasps Using sEMG Signal". *Sensors*, vol.22, pp. 2007, 2022. <https://doi.org/10.3390/s22052007>.
- [13] K.H., Lee, J.Y., Min, S., Byun. "Electromyogram Based Classification of Hand and Finger Gestures Using Artificial Neural Networks. *Sensors*", vol. 22, no 1, pp. 225, 2021. <https://doi.org/10.3390/s22010225>.
- [14] X. Ma, Y. Liu, "Continuous estimation of knee joint angle based on surface electromyography using a Long Short-Term Memory neural network and time-advanced feature," *Sensors*, vol. 20, no. 17, Sept. 2020, <https://doi.org/10.3390/s20174966>.
- [15] M. Atzori, M. Cognolato, H. Müller, "Deep learning with convolutional neural networks applied to electromyography data: A resource for the classification of movements for prosthetic hands," *Front. Neurobot.* Vol. 10, Sept. 2016, <https://doi.org/10.3389/fnbot.2016.00009>.
- [16] W. Geng, Y. Du, W. Jin, W. Wei, Y. Hu, J. Li, Gesture recognition by instantaneous surface EMG images, *Sci. Rep.*, vol. 6, no. 1, 2016. <https://doi.org/10.1038/srep36571>.
- [17] Y. Du, W. Jin, W. Wei, Y. Hu, W. Geng. Surface EMG-Based Inter-Session Gesture Recognition Enhanced by Deep Domain Adaptation. *Sensors*. 2017; 17, 3, pp: 458. <https://doi.org/10.3390/s17030458>.
- [18] Z., Ding, C., Yang, Z., Tian, C., Yi, Y., Fu, F., Jiang, "sEMG-Based Gesture Recognition with Convolution Neural Networks". *Sustainability* 2018, 10, 1865. <https://doi.org/10.3390/su10061865>.
- [19] S., Shen, K., Gu, X.-R., Chen, M., Yang, R.-C., Wang, "Movements Classification of Multi-Channel sEMG Based on CNN and Stacking Ensemble Learning," in *IEEE Access*, vol. 7, pp. 137489-137500, 2019, <https://doi.org/10.1109/ACCESS.2019.2941977>.
- [20] X., Kan, D., Yang, L., Cao, H., Shu, Y., Li, W., Yao, X., Zhang, "A Novel PSO-Based Optimized Lightweight Convolution Neural Network for Movements Recognizing from Multichannel Surface Electromyogram", *Complexity*, vol. 2020, Article ID 6642463, 15 pages, 2020. <https://doi.org/10.1155/2020/6642463>.



- [39] B., Jabir N., Falih. "Dropout, a basic and effective regularization method for a deep learning model: A case study. Indonesian Journal of Electrical Engineering and Computer Science". 2021 Nov; vol.24, no. 2, pp. 1009-16.
- [40] M. Balasubramanian, K. Ramyadevi, R. Geetha, Deep transfer learning based real time face mask detection system with computer vision. *Multimed Tools Appl*, 2023. <https://doi.org/10.1007/s11042-023-16192-1>.
- [41] S. Shiliang, C. Zehui, Han Z, Z. Jing. A survey of optimization methods from a machine learning perspective, Supported by NSFC Project 61370175 and Shanghai Sailing Program 17YF1404600, 2019.
- [42] X. Zhai, B., Jelfs, R. Chan, C. Tin. "Self-recalibrating surface EMG pattern recognition for neuroprosthesis control based on Convolutional Neural Network," *Frontiers in Neuroscience*, 2017, 11, 379. <https://doi.org/10.3389/fnins.2017.00379>.
- [43] B. Hirt, H. Seyhan, M. Wagner, R. Zumhasch, "Hand and Wrist Anatomy and Biomechanics, A Comprehensive Guide," 3rd ed., Germany, Thieme, 2017, pp. 75-80.
- 431-438, 1999. [https://doi.org/10.1016/s1350-4533\(99\)00066-1](https://doi.org/10.1016/s1350-4533(99)00066-1).
- [33] Géron, Aurélien. *Hands-on machine Learning with scikit-learn, keras, and TensorFlow*. Sebastopol, CA: O'Reilly Media. (2019).
- [34] L. Alzubaidi, J. Zhang, A.J. Humaidi. Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *J Big Data* 8:53, 2021.
- [35] L. Agnes, F. Sagayaraj A survey of optimization techniques for deep learning networks, *Int J Res Eng Appl Manag (IJREAM)* 5:2, 2019.
- [36] S. Ruder, SM. Park, KB. Sim, KB (2017), An overview of gradient descent optimization algorithms, arXiv: 1609.04747v2.
- [37] AC. Wilson, R. Roelofs, M. Stern, N. Srebro, B. Recht. The marginal value of adaptive gradient methods in machine learning, in *Advances in Neural Information Processing Systems*. 2017.
- [38] M. Reyad, A. Sarhan, M. Arafah. "A modified Adam algorithm for deep neural network optimization". *Neural Comput & Applic* 35, 17095-17112, 2023. <https://doi.org/10.1007/s00521-023-08568-z>.