

استفاده از ترکیب الگوریتم ژنتیک و شبکه‌های

عصبی مصنوعی برای پیش‌بینی نیروی گازگرفتن از روی سیگنال الکترومایوگرام

نازنین گوهریان^۱، سحر مقیمی^{۲*} و هادی کلانی^۳

^۱ و ^۲ دانشگاه فردوسی مشهد، گروه مهندسی برق، مشهد، ایران

^۳ دانشگاه فردوسی مشهد، گروه مهندسی مکانیک، مشهد، ایران



چکیده

امروزه بررسی ارتباط بین سیگنال‌های نیرو و فعالیت الکتریکی عضله‌ها بسیار حائز اهمیت بوده و در مسائل مهمی مانند تحلیل حرکت، علوم ارتوپدی، توانبخشی، طراحی ارگونومیک و تعامل انسان-ماشین و کاربردهای پزشکی مانند کنترل پروتزهای مصنوعی کاربرد فراوانی دارد. از مزیت‌های استفاده از الکترودهای سطحی، ارزان تر و قابل حمل بودن آن‌ها در مقایسه با حسگرهای نیرو است که به‌طور معمول گران هستند و ساختار حجیمی دارند. از آنجایی که اندازه‌گیری نیروی گازگرفتن بسیار سخت و پیچیده است، در این مقاله می‌خواهیم توانایی شبکه‌های عصبی چند لایه پرسپترون (MLPANN) و توابع با پایه شعاعی (RBFANN) را در پیش‌بینی نیروی گازگرفتن توسط دندان پیشین از روی سیگنال‌های الکترومایوگرام صورت بررسی کنیم. بدین منظور سیگنال الکترومایوگرام عضلات گیجگاهی و ماضغه و نیروی گازگرفتن به ترتیب به عنوان ورودی و خروجی شبکه‌های عصبی در نظر گرفته شده‌اند. برای پیدا کردن بهترین ساختار شبکه و تأخیر زمانی مناسب سیگنال‌های الکترومایوگرام، از الگوریتم ژنتیک (GA) استفاده شده است. نتایج نشان می‌دهند که سیگنال الکترومایوگرام عضلات یادشده شامل اطلاعات مفیدی از نیروی گازگرفتن هستند. روش‌های MLPANN و RBFANN دینامیک مورد نظر را با دقت مناسبی شناسایی می‌کنند. درصد میانگین مربع خطا در مرحله آموزش و آزمون به ترتیب ۲/۳٪ و ۱۹/۴٪ برای MLPANN و ۸/۳٪ و ۲۲/۷٪ برای RBFANN است. همچنین روش تحلیل واریانس نشان می‌دهد که تفاوت معناداری بین نتایج حاصله از MLPANN و RBFANN وجود ندارد.

واژگان کلیدی: سیگنال‌های الکترومایوگرام، نیروی گازگرفتن، شبکه عصبی چند لایه پرسپترون، تابع پایه شعاعی، الگوریتم ژنتیک.

Application of an ANN-GA Method for Predicting the Biting Force Using Electromyogram Signals

Nazanin Goharian¹, Sahar Moghimi^{2*} and Hadi Kalani³

^{1,2}Electrical Engineering Department, Ferdowsi University of Mashhad, Mashhad, Iran

³Mechanical Engineering Department, Ferdowsi University of Mashhad, Mashhad, Iran

Abstract

Human mastication is a common rhythmic behavior and a complex biomechanical process which is hard to reproduce. Today, investigating the relation between electrical activity of muscles and force signals is of high importance in many applications including gait analysis, orthopedics, rehabilitation, ergonomic design, haptic technology, tele presence surgery and human-machine interaction. Surface electrodes have many advantages over force sensors which are often expensive and of massive structure, two of which are less expensive and portable. Since the biting force is too difficult to be measured, in this paper, we aim to investigate the ability of a Multi-Layer Perceptron artificial neural network (MLPANN) and Radial Basis Function artificial neural network (RBFANN) to predict the biting force of incisor teeth based on surface

electromyography (EMG) signals. RBFANN and MLPANN are two of the most widely used neural network architecture. These two methods are both known as universal approximates for nonlinear input-output mapping. To do this, biting force and EMG signals from the masticatory muscles were recorded and used as output and input of neural networks, respectively. Genetic algorithm was applied to find the best structure for ANNs and the appropriate total time-delay of EMGs. Results show that the EMG signals recorded from aforementioned muscles contain useful information about the biting force. Furthermore, they indicate that MLPANN and RBFANN can detect the dynamics of the system with good precision. The mean percentage error in the training and validation phase is %2.3 and %19.4 for MLPANN and %8.3 and %22.7 for RBFANN, sequentially. Also the variance analysis technique shows that there is no significant difference between results achieved through MLPANN and RBFANN. The provided analysis will aid researchers in characterizing and investigating the mastication process, through the specification of SEMG signal patterns and the observation of the resulting biting force. Such models can provide clinical insight into the development of more effective rehabilitation therapies, and can aid in assessing the effects of an intervention. This methodology can be applied to any tele-operated robot or orthotic device (exoskeleton), either for rehabilitation or extension of human ability.

Key words: Electromyogram (EMG) signal, biting force, multi-Layer perceptron artificial neural networks (MLP), Radial basis function (RBF), Genetic algorithm.

اندازه‌گیری‌های بین افراد (به علت تفاوت‌ها در هندسه آرواره، شکل دندان و حساسیت نسبت به درد) با توجه به بافت غذا (رفتار مکانیکی، سختی و چسبندگی) تغییر می‌کنند. بنابراین با توجه به اهمیت بسیار بالای جویدن و پیچیدگی این فرایند، نیاز به توسعه روش‌های جدید برای ارزیابی ظرفیت افراد و بهبود عمل جویدن آن‌ها است [18]، [33]، [36]، [39]، [44].

الکترومایوگرافی (EMG)^۱ مطالعه عملکرد عضله از طریق تحلیل سیگنال‌های الکتریکی تولیدشده حین انقباضات عضلانی است. اندازه‌گیری سیگنال الکتریکی همراه با تحریک عضله است که می‌تواند شامل انقباضات ارادی و غیر ارادی شود. می‌توان ادعا کرد که یکی از بهترین راه‌ها برای جمع‌آوری اطلاعات در زمینه نحوه جویدن، ثبت سیگنال‌های الکترومایوگرام عضله‌های درگیر در فرآیند جویدن است [4]، [5]، [7]، [14] و [27]. بیش از بیست عضله در فرآیند جویدن درگیر هستند، که از بین این بیست عضله، دو عضله ماضغه^۲ و گیجگاهی^۳ سمت چپ و راست صورت تنها عضلاتی هستند که اندازه‌گیری عملکرد آنها با استفاده از الکترودهای سطحی ممکن است. از این سیگنال برای تشخیص نوع بافت غذا از نظر خواص مکانیکی نیز استفاده شده است [7]. از طرفی دیگر سیگنال الکترومایوگرام شامل اطلاعات فراوانی درباره نوع حرکت و نیروی تولیدشده توسط عضله و عضو مورد نظر است. بسیاری از پژوهش‌گران از این سیگنال برای تشخیص بیماری در عضو استفاده می‌کنند. به کمک این بررسی می‌توان بیماری‌های مورد نظر را با

۱- مقدمه

عمل جویدن فرآیند پیچیده‌ای است که با قرارگرفتن غذا در داخل دهان شروع شده و به کمک بزاق دهان غذا را برای بلعیدن آماده می‌سازد [3] و [13]. جویدن غذا به مقدار پارامترهای جابه‌جایی، تعداد تکرار، سرعت و نیروی واردشده به غذا بستگی دارد [40]. دندان‌ها برای عمل جویدن طراحی شده است. دندان‌های قدامی (جلویی) دارای عمل قطع‌کننده و دندان‌های خلفی (عقبی یا آسیا) دارای عمل خردکننده یا آسیا هستند. در صورتی که عضلات فک با یکدیگر عمل کنند، می‌توانند دندان‌های قدامی را با نیروی ۲۵ و دندان‌های خلفی را با نیروی ۹۰ کیلوگرم بر روی یکدیگر فشار دهند [8] و [12]. در سال‌های اخیر پژوهش‌گران، به دلیل اهمیت این فرآیند علاقه‌مند به مدل‌سازی عملکرد دستگاه جوینده انسان شده‌اند و در این راستا ابزارها و روبات‌هایی به منظور توانبخشی، برای شبیه‌سازی عمل جویدن طراحی و ساخته شده است. از جمله مطالعاتی که انجام شده با هدف ارزیابی تغییرات خواص مواد غذایی در حین فرآیند جویدن بوده است [11]، [13]، [19]، [20]، [45].

برای داشتن تحلیلی جامع و کامل از مشخصات جویدن، بایستی اندازه‌گیری عمل جویدن به صورت پیوسته در زمان انجام گیرد. این اندازه‌گیری‌ها شامل فرکانس و زمان جویدن، مسیر جابه‌جایی آرواره، توزیع نیرو و محاسبه تغییر نیروهای اعمالی برشی و فشاری بر روی غذا با توجه به ابعاد و ساختار غذا هستند. همان‌طور که انتظار داریم این

¹ Electromyography

² Masseter

³ Temporalis

میزان دقت دلخواه تخمین بزنند. این کار با استفاده از تعداد کافی بخش‌های خطی و غیرخطی که به‌صورت آبخاری^۶ قرار می‌گیرند، انجام می‌شود. علاوه‌براین نیازی نیست که ورودی سامانه، گوسی یا دارای ویژگی‌های خودهمبستگی خاصی باشد [21]. هاشمی و همکارانش از روش PCI به‌عنوان یک ابزار تخمین دینامیک برای نگاشت الکترومایوگرام سطحی ثبت‌شده از عضلات قسمت بالایی بازو به نیروی ایجادشده در مچ دست استفاده کرده‌اند [10]. مزیت‌های استفاده از روش‌های متعامد^۸ این است که در ورودی نیازی به وجود ویژگی‌های خود همبستگی خاصی نیست. همچنین استفاده از داده‌های ثبت‌شده با مدت محدود باعث ایجاد خطا نخواهد شد؛ اما، ایجاد توابع متعامد زمان‌بر بوده و نیاز به حافظه قابل توجهی دارد. روش جستجوی متعامد سریع (FOS) پیشنهاد داده‌شده توسط کورنبرگ^۹ به‌طور مؤثری از این مشکل جلوگیری کرده است. کورنبرگ تنها با به‌کارگیری بعضی از میانگین‌های زمانی برای محاسبه کاهش ایجادشده در کمینه مربعات خطا^{۱۰} مربوط به هر کدام از توابع پایه نامزد مشکل اخیر را حل کرده است [22]. روش FOS در بین تمام توابع پایه نامزد جستجو را انجام می‌دهد و توابع پایه‌ای را که مهم‌ترین نقش را در تخمین دارند، انتخاب می‌کند. در این روش، انتخاب توابع پایه غیرخطی تأثیر مهمی بر روی پدیده-ی افزونگی تطبیق دارد. هشتروودی‌زاد و همکارانش از روش FOS که یک روش حوزه زمان برای شناسایی سریع سامانه‌های غیرخطی است، برای تخمین نیروی ایجادشده در مچ دست توسط سیگنال‌های الکترومایوگرام ثبت‌شده در بازو استفاده کردند [29].

اندازه‌گیری نیروی گازگرفتن بسیار سخت و پیچیده است و نیاز تماس مستقیم دهان و دندان با حس‌گر خارجی است. هدف اصلی این مقاله پیش‌بینی نیروی گازگرفتن توسط دندان‌های پیشین با استفاده از سیگنال‌های الکترومایوگرام سطحی عضلات صورت است. بدین منظور ابتدا در مورد نحوه انتخاب داوطلب‌ها و ویژگی‌های آنها، مجموعه آزمایشگاهی اخذ داده و گام‌های مربوط به پروتکل ثبت بحث می‌کنیم. همچنین پیش‌پردازش‌های مورد نیاز را که بایستی بر روی سیگنال‌های الکترومایوگرام اعمال شوند، بیان می‌کنیم؛ سپس با استفاده از مدل‌های شبکه‌های عصبی

سرعت بیشتر و با هزینه کمتر تشخیص داد. از این رو پژوهش‌گران متعددی برای تشخیص بیماری‌های مرتبط به دهان از جمله اختلال مفاصل گیجگاهی-فکی، بر روی تفاوت سیگنال الکترومایوگرام افراد سالم و بیمار متمرکز شده‌اند [1]، [28] و [36].

سیگنال الکترومایوگرام حاوی اطلاعاتی جهت پیش‌بینی نیروی عضلات است و به‌طور گسترده‌ای در کاربردهای کلینیکی مورد استفاده قرار می‌گیرد. ارتباط بین فعالیت الکتریکی عضلات و نیروی عضله مربوطه از موضوعات بسیار مهمی است که در خیلی از زمینه‌ها از جمله توانبخشی، کاربرد دارد.

روش‌هایی بر پایه مدل‌های پارامتریک و غیرپارامتریک برای تخمین نیروی عضلات از روی این سیگنال‌ها پیشنهاد شده است [10]، [21]، [22]، [23]، [32]، [34]، [41]، [42]. تمامی این روش‌ها توسط سیگنال مربوطه با دقت‌های متفاوت می‌توانند نیروی عضلات را تخمین بزنند. امروزه مطالعات زیادی در زمینه استفاده از سیگنال‌های الکترومایوگرام جهت تخمین نیروی عضلات انجام می‌شود. بنابراین شناسایی دینامیک بین سیگنال الکترومایوگرام و نیرو با استفاده از روش‌های شناسایی سامانه‌ها موضوعی است که پرداختن به آن ضروری است. از جمله روش‌های به‌کار رفته جهت شناسایی دینامیک الکترومایوگرام-نیرو، می‌توان به مدل‌های شبکه عصبی [16]، [23]، [32]، [41]، [46] شناسایی آبخاری موازی^۱ [9]، [10] و [21] و جستجوی متعامد سریع^۲ [17] و [22] اشاره کرد. سولبرگ و هرزوغ^۳ از سیگنال‌های الکترومایوگرام برای پیش‌بینی میزان نیروی ایجادشده در تاندون^۴ استفاده کرده‌اند [34]. وانگ و بوکانان^۵ با استفاده از یک روش هیبرید که ترکیبی از روش‌های مبتنی بر فیزیک سامانه و روش‌های مبتنی بر ورودی-خروجی است، گشتاور مفصل را به‌کمک سیگنال الکترومایوگرام به‌دست آورده‌اند [41]. لو^۶ و همکارانش دینامیک بین سیگنال الکترومایوگرام ثبت‌شده و گشتاور ایجادشده در مفاصل را شناسایی کرده‌اند [24]. روش دیگری که برای مدل‌سازی سامانه عصبی-عضلانی مورد استفاده قرار گرفته است، روش PCI است. این روش می‌تواند هر سامانه تغییرناپذیر با زمان، علی، با حافظه محدود و غیرخطی را با

⁶ Luh

⁷ Cascade

⁸ Orthogonal

⁹ Korenberg

¹⁰ Mean Square Error

¹ Parallel Cascade Identification (PCI)

² Fast Orthogonal Search (FOS)

³ Savelberg & Herzog


⁴ Tendon

⁵ Wang and Buchanan


روند را هشت بار تکرار کند. در انتها داوطلبین ده ثانیه استراحت می‌کنند (شکل ۱ ج). قبل از شروع تست، داوطلبین در تعدادی آزمایش تمرینی نحوه اعمال نیرو به حس‌گر در سطح مورد نظر را فرا گرفته‌اند. فرکانس نمونه‌برداری توسط دستگاه ثبت EMG و نیرو 1000 هرتز است و با توجه به پروتکل ثبت، سیگنال‌های الکترومایوگرام و نیرو به صورت هم‌زمان ثبت شده است.



(الف)



(ب)



(ج)

(شکل ۱-۱): الف. نحوه قرار گرفتن الکتروود بر روی صورت داوطلب، ب. حس‌گر اندازه‌گیری نیروی گاز گرفتن، ج. شماتیک اعمال نیرو

(Figure-10): (a) Marker position and SEMG electrodes on the subject's face. (b) Biting force sensor and (c) Schematic of the experimental protocol.

برای مدل‌سازی، ابتدا سیگنال‌های الکترومایوگرام و نیرو به منظور حذف نوفه‌های فرکانس بالا و پایین پیش‌پردازش شدند. سیگنال‌های الکترومایوگرام ثبت شده از

چندلایه پرسپترون (MLPANN) و توابع با پایه شعاعی (RBFANN) که ساختار آن‌ها و همین‌طور تأخیر ورودی اعمال شده در آن‌ها با استفاده از الگوریتم ژنتیک بهینه شده است، به تخمین نیروی گازگرفتن می‌پردازیم.

۲- مواد و روش‌ها

۲-۱- پروتکل و شرایط انجام آزمایش

به منظور اخذ داده از شش داوطلب زن با بازه سنی 22 ± 4 سال استفاده شده است. شرایط انجام ثبت و قوانین اخذ داده قبل از شروع فرآیند ثبت برای داوطلب‌ها شرح داده شده است و کلیه داوطلب‌ها رضایت کتبی خود را برای شرکت در ثبت‌ها اعلام کرده‌اند. در این پژوهش از الکترودهای سطحی برای ثبت میزان فعالیت الکتریکی چهار عضله همزمان استفاده شده است. این چهار عضلات عبارتند از عضلات گیجگاهی و ماضغه سمت چپ و راست صورت. برای ثبت فعالیت الکتریکی عضلات از دستگاه ثبت EMG با ۱۶ کانال، استفاده شده است. الکترودها بر روی نقطه میانی عضله‌های ذکر شده متصل شده‌اند تا بتوان بهترین ثبت سیگنال را داشت. الکترودها بایستی در مکانی قرار گیرند که بتوان یک سیگنال الکترومایوگرام پایدار با دامنه مناسب ثبت کرد. عوامل تأثیرگذار در ثبت مطلوب این سیگنال عبارتند از: حضور واحدهای حرکتی و/یا تاندون عضلات در محل الکترودها و همچنین حضور عضلات فعال دیگر در نزدیکی الکترودهای ثبت که می‌توانند باعث ایجاد تداخل در سیگنال ثبت شده، شوند. مکان قرار گرفتن الکترودهای الکترومایوگرام برای دو عضله گیجگاهی و ماضغه در شکل ۱ الف نشان داده شده است. برای ثبت و اندازه‌گیری نیروی گازگرفتن ابزاری طراحی شده که متشکل از سه حس‌گر FSR است که توانایی ثبت نیرو تا ۱۰۰ نیوتن را دارد (شکل ۱ ب). این ابزار طوری طراحی شده است که بتوان نیروی گازگرفتن طبیعی را اندازه‌گیری کرد. از آنجایی که بیماری‌های دهان، یکی از خطرناک‌ترین بیماری‌ها است، لذا از چوب‌های استریلیزه شده و قابل تعویض برای قرار گرفتن در دهان افراد استفاده شده است؛ لذا هیچ‌گونه تماسی بین دهان افراد و دستگاه وجود ندارد. حس‌گرهای FSR توسط نیروسنج تنظیم شده‌اند. این حس‌گر داخل دهان داوطلب قرار می‌گیرد و از داوطلب خواسته می‌شود که در سطح ۱۵ نیوتن به مدت پنج ثانیه نیرو را وارد کند؛ سپس به آرامی فشار را از روی حس‌گر برداشته و بعد از پنج ثانیه نیرو را دوباره اعمال کند و این

فیلتر میان‌گذر باترورث^۱ مرتبه ۳ (۴۰۰-۱۵ هرتز) عبور داده شده است؛ سپس توسط فیلتر متحرک گوسی نرم شده و در نهایت سیگنال حاصل نسبت به واریانس نرمال شده است. برای پیش‌پردازش سیگنال نیرو از فیلتر متحرک گوسی صدنقطه‌ای استفاده شده است. با توجه به اعمال نیرو به دندان پیشین و تقارن موجود، در این مطالعه تنها سیگنال‌های الکترومایوگرام طرف راست صورت داوطلبان به‌منظور پیش‌بینی نیروی گازگرفتن مورد مطالعه قرار گرفته‌اند.

۲-۲-۲- مدل‌سازی رابطه EMG و نیروی گازگرفتن

در این مطالعه دو مدل MLPANN و RBFANN مورد مطالعه قرار گرفته‌اند. این دو شبکه را می‌توان به‌عنوان تقریب‌گرهای عمومی^۲ برای نگاشت غیرخطی بین ورودی و خروجی در نظر گرفت که در بخش آینده نحوه تعیین و بهینه‌سازی پارامترهای دو مدل توضیح داده شده است [31].

۲-۳- بهینه‌سازی پارامترهای مدل

توانایی پیش‌گویی شبکه‌های عصبی به ساختارشان، تابع فعال‌سازی، تعداد لایه‌ها و تعداد نرون‌های لایه پنهان (برای MLPANN) و تعداد گره، شعاع گره (برای RBFANN) وابستگی کامل دارد. تخمین این پارامترها به‌طور عمومی با آزمون و خطا انجام می‌شود که وقت‌گیر بوده و دارای خطا است؛ لذا روش‌های بهینه‌سازی مانند الگوریتم ژنتیک (GA) در جهت غلبه بر این مشکل ذاتی شبکه‌های عصبی مورد استفاده قرار می‌گیرند. مفاهیم اصلی الگوریتم ژنتیک عملگرهای سه‌گانه انتخاب^۳، آمیزش^۴ و جهش^۵ است. در این مطالعه برای شبکه MLP، تعداد نرون در لایه پنهانی و زمان تأخیر لازم برای هر سیگنال الکترومایوگرام توسط الگوریتم ژنتیک تعیین می‌شوند. همچنین الگوریتم ژنتیک در شبکه RBF، تعداد گره، شعاع هم‌گرایی گره‌ها و زمان تأخیر لازم برای هر سیگنال الکترومایوگرام را مشخص می‌کند. برای MLPANN، تعداد نرون و زمان تأخیر برای هر سیگنال الکترومایوگرام به‌ترتیب بین 5 تا 40 و 0 تا 1000 ms (با فاصله 200 ms) در نظر گرفته شده‌اند. همچنین برای

RBFANN، تعداد گره در لایه پنهانی، شعاع هم‌گرایی گره و زمان تأخیر برای هر سیگنال الکترومایوگرام به‌ترتیب بین 5 تا 40، 10 تا 0 و 1000 ms (با فاصله 200 ms) در نظر گرفته شده‌اند. برای پیدا کردن بهترین شبکه، تابع برازندگی با توجه به خطای پیش‌بینی شبکه به‌صورت زیر تعریف می‌شود.

$$F = \alpha \|y - \hat{y}\| + \max(y - \hat{y}) + \beta \text{std}(y - \hat{y}) \quad (1)$$

که در آن y و \hat{y} به‌ترتیب بردار خروجی اندازه‌گیری شده و پیش‌بینی شده هستند. پارامترهای α و β برای میزان کردن ترم‌های معادله (۱) است و به‌صورت تجربی تعیین شدند. شکل (۲) الگوریتم یادگیری پیشنهاد شده را نشان می‌دهد. پارامترهای بهینه MLPANN و RBFANN و تأخیرهای سیگنال‌های الکترومایوگرام ثبت شده برای هر داوطلب به صورت جداگانه تعیین شدند.

۲-۴- ارزیابی مدل

یکی از نکات حائز اهمیت در فرآیند شناسایی مدل‌های مختلف، بحث آزمودن مدل شناسایی شده است. سه معیار بحرانی برای ارزیابی مدل شبکه تعلیم‌یافته در نظر گرفته شد. این معیارها شامل درصد میانگین نسبی مربع خطا^۶ (%RMSE)، درصد همبستگی متقابل^۷ (%CC) و میانگین خطای مطلق^۸ (AAE) هستند. این معیارها را می‌توان به‌صورت زیر تعریف کرد.

$$\%RMSE = 100 * \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i)^2} \quad (2)$$

$$\%CC = 100 * \frac{\sum_i (y_i * \hat{y}_i)}{\sqrt{\sum_i (y_i)^2} \sqrt{\sum_i (\hat{y}_i)^2}} \quad (3)$$

$$AAE = \frac{\sum_i |y_i - \hat{y}_i|}{n} \quad (4)$$

که در آن‌ها n تعداد داده می‌باشد. معیار %CC شباهت بین y و \hat{y} را بررسی می‌کند. هرچه این پارامتر به مقدار 100 نزدیک‌تر باشد، شباهت بالایی بین سیگنال‌ها وجود دارد.

۳- نتایج و بحث

همان‌طور که در قبلس اشاره شده نزدیک به بیست عضله برای حرکت‌های مختلف آرواره به‌کار گرفته می‌شوند [39]؛ اما تنها چهار عضله ماضغه سمت چپ و راست و گیجگاهی چپ و

⁵ Mutation

⁶ relative mean square error

⁷ cross-correlation

⁸ average absolute error

¹ Bu

² Universal approximator

³ Selection

⁴ Crossover

راست قابل اندازه‌گیری با الکترودهای سطحی هستند. با فرض متقارن بودن عضله‌های چپ و راست صورت در فرآیند گازگرفتن، تنها سیگنال‌های دریافتی از عضله‌های گیجگاهی و ماضغه راست به‌عنوان ورودی استفاده شده است.

شکل (۳)، سیگنال الکترومایوگرام ثبت‌شده از عضله‌های سمت راست صورت و نیروی گازگرفتن داوطلب نخست را نشان می‌دهد. در هر نمونه‌برداری از داوطلب خواسته شده که در زمان‌های معین بر روی حس‌گر قرار گرفته شده است بین دندان‌های پیشین، نیرو اعمال کند.

شکل (۴-الف) تغییرات $RMSE\%$ بر اساس تغییر شعاع و تعداد گره در RBFANN را نشان می‌دهد. همان‌طور که در این شکل نشان داده شده است، تغییر این دو پارامتر بر روی $RMSE\%$ در مرحله آموزش و آزمون تأثیرگذار است. افزایش شعاع تا مقدار معینی، باعث کاهش مقدار $RMSE$ در مرحله آموزش و آزمون می‌شود؛ اما بعد از این مقدار معین تأثیر محسوسی بر روی $RMSE\%$ ندارد. همچنین تعداد گره در لایه پنهان نیز نقش مهمی در ساختار RBFANN دارد. با افزایش تعداد گره، شبکه پیچیده و زمان آموزش افزایش می‌یابد. همان‌طور که در شکل (۴-ب) تا (۴-د) مشاهده می‌شود با تعداد معینی گره مقدار $RMSE\%$ و AAE کاهش و مقدار $CC\%$ در هر دو مرحله آموزش و آزمون افزایش می‌یابد؛ اما بعد از این مقدار معین، مقادیر $RMSE\%$ ، AAE و $CC\%$ در مرحله آموزش تغییر محسوسی نمی‌کنند. در صورتی که در مرحله آزمون مقدار $RMSE\%$ و AAE افزایش و مقدار $CC\%$ کاهش می‌یابد. به عبارت دیگر شبکه دچار آموزش بیش از حد شده است؛ لذا پیدا کردن بهینه پارامترهای شبکه برای هر فرد امری ضروری به نظر می‌رسد. در این مقاله از الگوریتم ژنتیک برای پیدا کردن بهترین ساختار مدل استفاده شده است. نتایج مربوط به مدل‌های شناسایی شده برای داوطلب دوم در شکل (۵) نمایش داده شده است. نشان داده شده است که عملکرد MLPANN از RBFANN بهتر است. به عبارت دیگر اگر چه RBFANN توانسته است، تغییرات نیروی اندازه‌گیری‌شده را دنبال کند، اما نتوانسته به خوبی مدل MLPANN دامنه این تغییرات را شناسایی و تخمین بزند.

در ادامه نتایج کمی مربوط به مدل‌های شناسایی شده برای کلیه داوطلب‌ها در جدول (۱) بیان شده است. در این جدول، مقادیر $RMSE\%$ ، $CC\%$ و AAE برای تخمین‌های انجام‌شده مربوط به کلیه داوطلبان در دو مرحله آموزش و آزمون ارائه شده است. همان‌طور که در جدول (۱) نشان داده

شده است، هر دو شبکه با دقت‌های قابل قبولی دینامیک نیروی گازگرفتن را پیش‌بینی کرده‌اند. همان‌طور که در جدول (۱) نیز دیده می‌شود، مدل MLPANN شناسایی شده برای داوطلب دوم دقت بسیار مناسبی دارد.

با توجه به جدول (۱)، مدل MLPANN برای تمام داوطلب‌ها بهتر از RBFANN عمل کرده است؛ اما برای پاسخ‌دادن به این سؤال که آیا تفاوت معناداری بین دو شبکه RBF و MLP بر روی داوطلبان وجود دارد، روش تحلیل آماری T-test به کار گرفته شد. تحلیل آماری موردنظر نشان می‌دهد که تفاوت معناداری بین دو مدل در مرحله آزمون وجود ندارد ($p > 0.05$).

همان‌گونه که در مقالات مختلف نیز اشاره شده است مدل شناسایی‌شده برای یک فرد ممکن است برای افراد دیگر معتبر نباشد [۲۶]. دلیل این موضوع نیز وجود تفاوت‌ها بین افراد از قبیل مکان قرارگرفتن الکترودهای الکترومایوگرام نسبت به واحدهای حرکتی و ویژگی‌های شخصی مانند نوع فیبرهای عضلانی، حجم عضله، طول عضله، تفاوت در استراتژی راه‌اندازی واحدهای حرکتی، میزان چربی موجود در زیر پوست و مشخصات مکانیکی مفاصل است. جدول (۲) مقدار سه معیار بحرانی مدل شناسایی‌شده برای داوطلب دوم را برای افراد دیگر خلاصه کرده است. این جدول نشان می‌دهد که مدل شناسایی‌شده برای داوطلب دوم توانسته است دینامیک مورد نظر برای داوطلبین دیگر را با خطای قابل قبولی شناسایی کند؛ بنابراین می‌توان گفت که مدل شناسایی‌شده برای داوطلب دوم جامعیت خوبی دارد و از آن می‌توان برای پیش‌بینی نیروی گازگرفته‌شده توسط افراد دیگر استفاده کرد.

به‌طور کلی نیروی اعمال‌شده بر روی دندان با توجه به سن، جنس و نوع غذا (ویژگی‌های غذا مانند چسبندگی و سختی) تغییر می‌کند. همچنین نیروی اعمال‌شده توسط یک دندان با نیروی اعمال‌شده توسط تمام دندان‌ها تفاوت چشم‌گیری می‌کند [۲]، [۶]، [۱۲]، [۴۳]. اما از آنجایی که هدف اصلی این مقاله پیدا کردن رابطه بین نیروی گازگرفتن و سیگنال‌های الکترومایوگرام عضله‌های صورت است، از داوطلبین خواسته شده است که نیرویی معادل پانزده نیوتن را توسط دندان پیشین بر روی حس‌گر اعمال کنند.

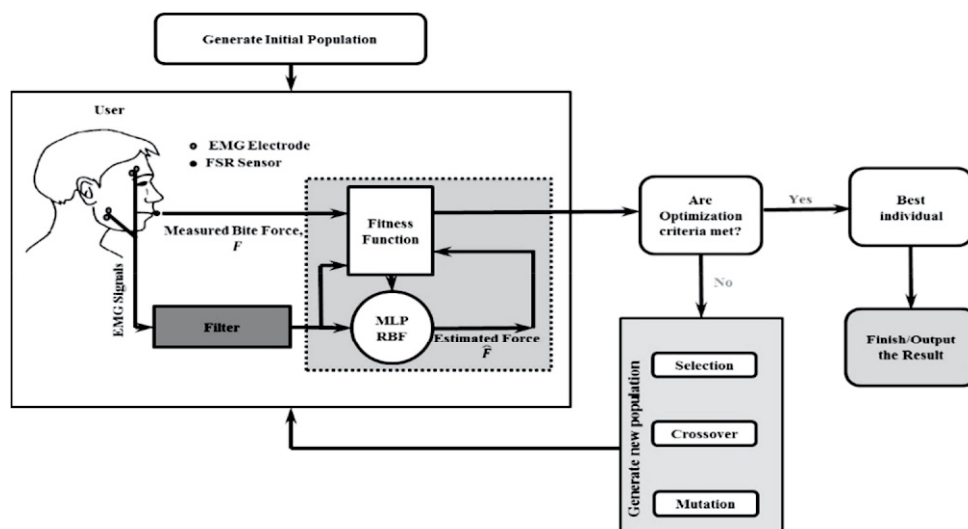
پژوهش‌گران زیادی برای پیدا کردن دینامیک بین نیرو و حرکت عضو و سیگنال EMG، از مدل‌های MLPANN و RBFANN استفاده کرده‌اند [۱۹] و [۳۵]. مبصر و هشترودی‌زاد از دو مدل MLPANN و RBFANN

نیز روبات‌هایی برای شبیه‌سازی عمل جویدن و انجام آزمایش‌های مکانیکی بر روی مواد غذایی مختلف، طراحی و ساخته شده‌اند. پیداکردن ارتباط بین فعالیت الکتریکی عضلات و حرکات بدن از موضوعات بسیار مهمی است که در بسیاری از زمینه‌ها از جمله توان‌بخشی، کاربرد فراوانی دارد. هدف اصلی این مقاله پیداکردن ارتباط بین نیروی گازگرفته‌شده توسط دندان پیشین و سیگنال‌های الکترومایوگرام عضله‌های ماضغه و گیجگاهی بود. از آنجایی که ثبت نیروی گازگرفتن بسیار سخت‌تر (تماس مستقیم با دهان) از ثبت سیگنال‌های الکترومایوگرام است، بنابراین پیداکردن ارتباط بین این دو سیگنال امری ضروری و مفید است. این مدل ما را قادر خواهد ساخت که تنها با داشتن سیگنال‌های الکترومایوگرام، نیروی گازگرفتن توسط دندان‌ها را پیش‌بینی کرده، بدون آنکه از حسگر نیرو استفاده کنیم. بدین منظور دو مدل MLPANN و RBFANN برای یافتن این رابطه مورد استفاده قرار گرفته‌اند. نتایج نشان می‌دهند که سیگنال الکترومایوگرام دریافتی از این عضله‌ها دارای اطلاعات کافی برای تخمین نیرو است و هر دو شبکه با دقت‌های قابل قبولی، نیروی گازگرفتن را پیش‌بینی می‌کنند. در این مطالعه برای پیداکردن ساختار شبکه بهینه برای هر داوطلب، GA استفاده شده است. به‌علاوه تحلیل واریانس انجام‌شده بر روی تخمین‌های هر دو مدل، حاکی از آن است که تفاوت معناداری در خروجی این دو شبکه وجود ندارد.

برای تخمین نیروی عضله دست استفاده کردند. آن‌ها نتایج حاصل از این دو شبکه را با یکدیگر مقایسه کردند و نشان دادند که عملکرد مدل RBFANN در بار سبک بهتر از مدل MLPANN است؛ در صورتی که در شرایط ایزوتونیک^۱ MLPANN دارای تخمین‌های بهتری است. به‌علاوه آن‌ها نشان دادند که با در نظر گرفتن شتاب آرنج به‌عنوان ورودی، عملکرد شبکه‌ها بهتر می‌شوند. همچنین آن‌ها تأثیر تعداد گره در مدل RBFANN و تعداد نرون در لایه‌های پنهانی مدل MLPANN در مرحله آموزش و آزمون را بررسی کردند. آن‌ها نشان دادند که افزایش این پارامترها همواره باعث بهبود عملکرد دو شبکه نمی‌شود، بلکه ممکن است، باعث پدیده یادگیری بیش از حد شود. این موضوع نیز در این مقاله مورد ارزیابی قرار گرفته است و برای رفع مشکل و پیداکردن پارامترهای بهینه، GA استفاده شد. زمان اجرای برنامه و یافتن پارامترهای بهینه با استفاده از الگوریتم ژنتیک، چهار الی پنج ساعت به‌طول انجامید.

۴- جمع‌بندی

مدل‌سازی بیومکانیکی عملکرد دستگاه جونده انسان یکی از موضوعات مورد علاقه پژوهش‌گران در سال‌های اخیر بوده که با اهداف مختلفی صورت گرفته است. ارزیابی تغییرات خواص و ساختار مکانیکی مواد غذایی در حین عمل جویدن، یکی از این اهداف بوده است. بدین منظور، نحوه حرکت فک و نیروهای وارد بر دندان و استخوان مورد مطالعه قرار گرفته و



(شکل-۲): شماتیک ترکیب شبکه عصبی و الگوریتم ژنتیک

(Figure-2): Block diagram of the proposed technique for combining neural network and genetic algorithm

^۱ Isotonic condition

(جدول-۱): میزان %RMSE، %CC و AAE مربوط به تخمین‌های زده شده برای کلیه داوطلبین در هر دو مدل MLPANN و RBFANN در دو فاز آموزش و آزمون



(Table-1): The %RMSE, %CC and AAE of the training and validation results for all subjects for both MLPANN and RBFANN

آزمون			آموزش			روش	داوطلب‌ها
AAE	CC (%)	RMSE (%)	AAE	CC (%)	RMSE (%)		
0.46	85.1	28.4	0.13	97	5.9	MLPANN	داوطلب اول
0.43	87.6	23.4	0.26	87.14	24.02	RBFANN	
0.11	98.7	2.53	0.05	99.7	0.59	MLPANN	داوطلب دوم
0.43	87.95	25.6	0.09	99.20	1.57	RBFANN	
0.23	95.4	9.1	0.08	99.2	1.58	MLPANN	داوطلب سوم
0.32	84.7	17.2	0.12	98.1	3.7	RBFANN	
0.24	93.5	18.2	0.07	99.2	1.5	MLPANN	داوطلب چهارم
0.35	90.2	25.7	0.22	95.3	9.07	RBFANN	
0.31	85.7	26.6	0.07	99.1	1.73	MLPANN	داوطلب پنجم
0.38	89.7	19.48	0.07	99.3	1.2	RBFANN	
0.343	82.82	31.93	0.1	98.7	2.52	MLPANN	داوطلب ششم
0.38	86.9	25.3	0.2	94.5	10.6	RBFANN	

(جدول-۲): نتایج مربوط به آزمون بین فردی مدل MLPANN شناسایی شده برای داوطلب دوم

(Table-2): The result of %RMSE, % CC and AAE values of MLPANN of second subject to other subjects

میانگین			داوطلب ششم			داوطلب پنجم			داوطلب چهارم			داوطلب سوم			داوطلب دوم			داوطلب اول			
CC %	AAE	RMSE %	CC %	AAE	RMSE %	CC %	AAE	RMSE %	CC %	AAE	RMSE %	CC %	AAE	RMSE %	CC %	AAE	RMSE %	CC %	AAE	RMSE %	معیار بحرانی
0.25	93.2	13.65	93.03	0.23	13.46	92.7	0.27	13.92	91.06	0.25	17.6	94.95	0.21	11.82	98.76	0.21	2.53	88.7	0.44	22.57	داوطلب دوم




(شکل-۳): سیگنال‌های ثبت شده از داوطلب نخست: (الف)


سیگنال الکترومایوگرام عضله ماضغه سمت راست (ب)

سیگنال الکترومایوگرام عضله گیجگاهی سمت راست (د)

سیگنال نیروی ثبت شده از دندان پیشین

(Figure-3): SEMG signal of first subject (a) the right Masseter muscle, (b) the right Temporalis muscle and (c) biting force






(شکل-۵): مقایسه عملکرد MLPANN و RBFANN

(Figure-5): Comparison between RBFANN and MLPANN


5-References

۵-مراجع


- [1] M. A. Al-Saleh, S. Armijo-Olivo, C. Flores-Mir, N. M. Thie, "Electromyography in diagnosing temporomandibular," J. Am. Dent. Assoc., vol. 143, no. 4, pp. 351-362, 2012.
- [2] D. J. Anderson, "Measurements of stress in mastication," J. Dent. Res., vol. 35, no. 5, pp. 175-189, 1956.
- [3] M.C. Bourne, Relationship between rheology and food texture, Engineering and food for the 21st century, CRC Press, LLC. 2002.
- [4] W. E. Brown, "Method to investigate differences in chewing behaviour in humans," J. Texture. Stud, vol. 25, no. 1, pp. 1-16, 1994.
- [5] W. E. Brown, K. R. Langley, L. Mioche, S. Marie, S. Gerault, D. Braxton, "Individuality of understanding and assessment of sensory attributes of foods, in particular, tenderness of meat," Food Qual. Prefer., vol. 7, pp. 205-216, 1996.
- [6] C. H. Gibbs, P. E. Mahan, H. C. Lundeen, K. Brehnan, E. K. Walsh, S. L. Sinkewicz, S. B. Ginsberg, "Occlusal forces during chewing - influences of biting strength and food consistency," J. Prosthet. Dent., vol. 46, no. 5, pp. 561-567, 1981.
- [7] R. Gonzalez, I. Montoya, J. Carcel, "Review: the use of electromyography on food texture assessment," Food Sci. Technol. Int., vol. 7, no. 6, pp. 461-471, 2001.
- [8] A. Hannam, Jaw muscle structure and function, In: McNeill, C. (ed.) Science and Practice of Occlusion, Quintessence Publishing Co, pp. 41-49, 1991.
- [9] J. Hashemi, E. Morin, P. Mousavi, K. Hashtrudi-zaad, "Enhanced Dynamic EMG- Force




(الف)



(ب)



(ج)



(د)

(شکل-۴): (الف) تأثیر تعداد گره و شعاع هم‌گرایی بر روی RMSE در دو مرحله آموزش و آزمون. (ب) تأثیر تعداد گره بر روی AAE (ج) RMSE و (د) CC در دو مرحله آموزش و آزمون
(Figure-4): (a) effect of number of nodes and spread on RMSE in training and validating phases, Effect of number of nodes on (b) AAE and (c) CC in training and validating phases

- [20] K. Kohyama, E. Hatakeama, T. Sasaki, T. Azuma, K. Karita, "Effect of sample thickness on bite force studied with a multiple-point sheet sensor," *J. Oral Rehabil.*, vol. 31, no. 4, 327-334, 2004.
- [21] M. J. Korenberg, "Parallel cascade identification and kernel estimation for nonlinear systems," *Ann. Biomed. Eng.*, vol. 19, no. 4, pp. 429-455, 1991.
- [22] M. J. Korenberg, "Fast orthogonal algorithms for nonlinear system identification and time-series analysis," *Advanced methods of physiological system modeling*, vol. 2, pp. 165-177, 1989.
- [23] M. M. Liu, W. Herzog, H. C. M. Savelberg, "Dynamic muscle force predictions from EMG: an artificial neural network approach," *J. Electromyography Kinesiol.*, vol. 9, no. 6, pp. 391-400, 1999.
- [24] J. J. Luh, G. C. Chang, C.K. Cheng, J.S. Lai, S. Kuo, "Isokinetic elbow joint torques estimation from surface EMG and joint kinematic data: using an artificial neural network model," *J. Electromyography Kinesiol.*, vol. 9, no. 3, pp. 173-183, 1999.
- [25] B. Lawrence, G. Buckner, G. Mirka, "An adaptive system identification model of the biomechanical response of the human trunk during sudden loading," *J. Biomed. Eng.*, vol. 128, no. 2, pp. 235-241, 2006.
- [26] L. Ljung, "System identification," *Signal Analysis and Prediction*, pp. 163-173, 1999.
- [27] B. May, S. Saha, "A three-dimensional mathematical model of temporomandibular joint loading," *Clin. Biomech.*, vol. 16, no. 6, pp. 489-495, 2001.
- [28] A. Monaco, F. Sgolastra, I. Ciarrocchi, R. Cattaneo, "Effects of transcutaneous electrical nervous stimulation on electromyographic and kinesiographic activity of patients with temporomandibular disorders: a placebo-controlled study," *J. Electromyography Kinesiol.*, vol. 22, no. 3, pp. 463-468, 2012.
- [29] F. Mobasser, J.M. Eklund, K. Hashtrudi-Zaad, "Estimation of Elbow Induced Wrist Force With EMG Signals Using Fast Orthogonal Search" *IEEE T. Bio-Med. Eng.*, vol. 54, no. 4, pp. 683 - 693, 2007.
- [30] I. Milovanovic, "Radial basis function networks for improved gait analysis". In *Proc of Symp on Neural Networks Applications in Electrical Engineering*, 2008.
- [31] F. Mobasser, K. Hashtrudi-Zaad, "A Comparative Approach to Hand Force Estimation Through Calibration and PCI Modeling" *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 23, no. 1, pp. 41-50, 2014.
- [10] J. Hashemi, E. Morin, P. Mousavi, K. Mountjoy, K. Hashtrudi-Zaad, "EMG-force modeling using parallel cascade identification" *J. Electromyography Kinesiol.*, vol. 22, no. 3, pp. 469-477, 2012.
- [11] K. Harada, M. Watanabe, K. Ohkura, S. Enomoto, "Measure of bite force and occlusal contact area before and after bilateral sagittal split ramun osteotomy of the mandible using a new pressure-sensitive device: A preliminary report". *J. Oral Maxillofac. Surg.*, vol. 58, no. 4, pp. 370-373, 2000.
- [12] E. Helkimo, B. Ingervall, "Bite force and functional state of the masticatory system in young men" *Swed. Dent. J.*, vol. 2, no. 5, pp. 167-175, 1978.
- [13] M. R. Heath, J. F. Prinz, "Oral processing of foods and the sensory evaluation of texture. Food texture: measurement and perception", Aspen Publishers Inc., Gaithersburg, 1999.
- [14] Y. Ioannides, J. Seers, M. Defenez, C. Raithatha, M. S. Howarth, A. Smith, E. K. Kemsleys, "Electromyography of the masticatory muscles can detect variation in the mechanical and sensory properties of apples," *Food Qual. Prefer.*, vol. 20, no. 3, pp. 203-215, 2009.
- [15] F. R. Jack, J. R. Piggott, A. Paterson, "Relationships between electromyography, sensory and instrumental measures of cheddar cheese texture" *Int. J. Food Sci. Tech.*, vol. 58, no. 6, pp. 1313-1317, 1993.
- [16] H. Kalani, S. Moghimi, A. Akbarzadeh, "SEMG-based prediction of masticatory kinematics in rhythmic clenching movements" *Biomed. Signal Process. Control*, vol. 20, pp. 24-34, 2015.
- [17] H. Kalani, A. Akbarzadeh, S. Moghimi, "Prediction of clenching jaw movements based on EMG signals using fast orthogonal search" *23rd Iranian Conference on Electrical Engineering (ICEE)*, 2015, pp. 17-22.
- [18] E. K. Kemsley, M. Defernez, J. C. Sprunt, A. Smith, "Electromyographic responses to prescribed mastication," *J. Electromyography Kinesiol.*, vol. 13, pp. 197-207, 2003.
- [19] K. Kohyama, F. Hayakawa, Z. Gao, S. Ishihara, T. Funami, K. Nishinari, "Nature eating behavior of two types of hydrocolloid gels as measured by electromyography: Quantitative analysis of mouthful size effects," *Food Hydrocolloids*, vol. 52, pp. 243-252, 2016.

- [43] G. D. Wood, J. E. Williams, "Gnathodynamometer: measuring opening and closing forces," *Dent. Update*, vol. 8, no. 4, pp. 239–250, 1981.
- [44] W. Xu, J. E. Bronlund, *Mastication robots: biological inspiration to implementation*, Springer-Verlag Berlin Heidelberg Press, 290, 2010.
- [45] H. Yu, Y. Sun, F. Bai, H. Ren, "A Preliminary Study of Force Estimation Based on surface EMG: Towards Neuromechanically Guided Soft Oral Rehabilitation Robot," *IEEE Int. Conf. Rehabil. Robot*, pp. 991–996, 2015.
- [46] A. Zalzal, N. Chaiyaratana, "Myo-electric signal classification using evolutionary hybrid RBF-MLP networks," *Evol. Comput.*, pp. 691–698, 2000.
- Estimation using Artificial Neural Networks," *Bioinform. Biol. Insights*, vol. 4, pp. 1–15, 2012.
- [32] F. Mobasser, K. Hashtrudi-Zaad, "Rowing stroke force estimation with EMG signals using artificial neural networks," *IEEE Conference on Control Applications*, pp. 825–830, 2005.
- [33] J. S. Pap, W. L. Xu, J. Bronlund, "A robotic human masticatory system –kinematics simulations", *International Journal of Intelligent Systems Technology Applications*, vol. 1, pp. 3–17, 2005.
- [34] H. C. M. Savelberg, W. Herzog, "Prediction of dynamic tendon forces from electromyographic signals, An artificial neural network approach," *J. Neurosci. Methods*, vol. 78, pp. 65–74, 1997.
- [35] F. Sepulveda, D. Wells, C. Vaughan, "A neural network representation of electromyography and joint dynamics in human gait," *J. Biomech.*, vol. 26, no. 2, pp. 101–109, 1993.
- [36] C. Sforza, S. Montagna, R. Rosati, M. De Menezes, "Immediate effect of an elastomeric oral appliance on the neuromuscular coordination of masticatory muscles: a pilot study in healthy subjects," *J. Oral Rehabil.*, vol. 37, no. 11, pp. 840–847, 2010.
- [37] A. Shimada, Y. Yamabe, T. Torisu, L. Baad, H. Murata, P. Svensson, "Measurement of dynamic bite force during mastication," *J. Oral Rehabil.*, vol. 39, no. 5, pp. 349–356, 2012.
- [38] H. J. Smit, E. K. Kemsley, H. S. Tapp, J. K. Henry, "Does prolonged chewing reduce food intake?, Fletcherism revisited," *Appetite*, vol. 57, no. 1, pp. 295–298, 2011.
- [39] J. D. Torrance, "kinematics, Motion control and force estimation of a chewing robot of 6rss parallel mechanism," *Ph. D thesis*, Massy University, Palmerston North, New Zealand, 2011.
- [40] J. Tsuruta, A. Mayanagi, H. Miura, S. Hasagawa, "An index for analysing the stability of lateral excursions," *J. Oral Rehabil.*, vol. 29, no. 3, pp. 274–281, 2002.
- [41] L. Wang, S. Buchanan, "Prediction of Joint Moments Using a Neural Network Model of Muscle Activations From EMG Signals," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 10, no. 1, pp. 30–37, 2002.
- [42] R. Wang, Y. Yang, X. Hu, "A hybrid AB-RBF classifier for surface electromyography classification," *Lect. Notes Comput. Sc.*, vol. 4561, pp. 727–735, 2007.



نازنین گوهریان در سال ۹۲ مدرک کارشناسی خود را در رشته مهندسی الکترونیک از دانشگاه سجاد مشهد دریافت کرد. او هم‌اکنون دانشجوی کارشناسی ارشد مهندسی پزشکی دانشگاه فردوسی مشهد است. زمینه پژوهشی ایشان پردازش سیگنال‌های الکترومایوگرام و مدل‌سازی دینامیکی سامانه عصبی-عضلانی است. نشانی رایانامه ایشان عبارت است از:

Goharian_n@yahoo.com



سحر مقیمی کارشناسی خود را در رشته مهندسی برق از دانشگاه تهران در سال ۱۳۸۲ و کارشناسی ارشد و دکترای خود را در رشته مهندسی پزشکی از دانشگاه تربیت مدرس به ترتیب در سال‌های ۱۳۸۵ و ۱۳۸۹ دریافت کرد. او از سال ۱۳۸۹ به عنوان عضو هیأت علمی در گروه مهندسی برق مشغول به کار شده است و هدایت آزمایشگاه پردازش سیگنال‌های مغزی را در آن دانشگاه بر عهده دارد. از زمینه‌های پژوهشی مورد علاقه ایشان علوم اعصاب شناختی، پردازش سیگنال‌های مغزی و مطالعه فرآیندهای مرتبط با پردازش احساسات در مغز انسان است. نشانی رایانامه ایشان عبارت است از:

s.moghimi@um.ac.ir



هادی کلانی در سال ۱۳۸۷ مدرک

کارشناسی خود را در رشته مهندسی

مکانیک از دانشگاه آزاد مشهد و مدرک

کارشناسی ارشد خود را در سال ۱۳۸۹

از دانشگاه فردوسی مشهد دریافت کرد.

ایشان فارق التحصیل دکترای مهندسی مکانیک دانشگاه

فردوسی مشهد است. زمینه پژوهشی ایشان در رباتیک

است.

نشانی رایانامه ایشان عبارت است از:

Hadi.kalani@yahoo.com