

Neural Network Modeling of Electrically Stimulated Muscle under Non-Isometric Conditions

A. Erfanian-Omidvar

Department of Biomedical Engineering, Faculty of Electrical Engineering, Iran University of Science and Technology

Received 5 April 2004; received in revised form 23 May 2005; accepted 25 May 2005

Abstract

This paper is concerned with developing a force-generating model of electrically stimulated muscle under non-isometric condition. Hill-based muscle models have been the most popular structure. This type of muscle model was constructed as a combination of different independent blocks (i.e., activation dynamics, force-length and force-velocity relations, and series elastic element). The model assumes that the force-length and the force-velocity relations are uncoupled from the activation dynamics. However, some studies suggest that the shapes of the active force-length and the active force-velocity curves change with the level of the activation. Moreover, the “active state” block of the Hill-type model has no physical interpretation. To overcome the limitation of the Hill-type model, we used the multilayer perceptron (MLP) with back-propagation learning algorithm and Radial Basis Function (RBF) network with stochastic gradient learning rule for muscle modeling, where the stimulation signal, muscle length, velocity of length perturbation, and past measured or predicted force constitute the input of the neural model, and the predicted force is the output. Two modes of network operation are of interest: a time-varying network which allows updating the parameters of network to continue after convergence, and a time-invariant neural network with parameters fixed after convergence. The results show that time-varying and time-invariant neural networks would be able to track the muscle force with accuracy up to 99.5% and 95%, respectively. In addition, the results show that the accuracy of muscle force prediction depends on the structure of neural network. The prediction accuracy of RBF network after 1000 training epochs is higher than that of MLP network after 5000 training epochs.

Keywords: Neural network; Functional electrical stimulation; Muscle modeling; Neuromuscular systems

* Corresponding author

Address: Faculty of Electrical Engineering, Iran University of Science and Technology, Narmak, Tehran, I.R.Iran

Tel: +98 21 73913553

Fax: +98 21 77454055

E-mail: erfanian@iust.ac.ir

مدل شبکه عصبی از عضله تحریک شده در شرایط غیرایزومتریک

عباس عرفانیان امیدوار*

دانشگاه علم و صنعت ایران، دانشکده مهندسی برق، گروه مهندسی پزشکی، آزمایشگاه کنترل سیستم‌های عصبی - عضلانی

تاریخ ثبت اولیه: ۱۳۸۳/۱/۱۷، تاریخ دریافت نسخه اصلاح شده: ۱۳۸۴/۳/۲، تاریخ پذیرش قطعی: ۱۳۸۴/۳/۴

چکیده

مدل جدیدی از عضله تحریک شده در شرایط غیرایزومتریک ارائه شده است. مدل‌های ارائه شده کنونی مبتنی بر ساختار مدل هیل هستند. در این ساختار، رفتار عضله به بخش‌های مستقل از یکدیگر تجزیه شده و فرض می‌شود که این بخش‌ها ارتباطی با یکدیگر ندارند، در صورتی که این تجزیه و عدم وابستگی بخش‌ها به یکدیگر، واقعیت فیزیکی ندارد. به منظور رفع محدودیت‌های مدل‌های ساختار هیل، در این تحقیق از شبکه‌های عصبی دینامیک به عنوان ابزاری جهت مدل‌سازی عضله در شرایط غیرایزومتریک استفاده شده است. برای این منظور، دو نوع شبکه عصبی به کار گرفته شد: شبکه پرسپترون با الگوریتم یادگیری پس‌انتشار خطا و شبکه عصبی مبتنی بر توابع پایه شعاعی با الگوریتم یادگیری گرادیان تصادفی. نتایج این تحقیق نشان می‌دهد مدل‌های عصبی قادر به پیش‌بینی دقیق‌تری از میزان نیروی انقباض عضلانی در شرایط غیرایزومتریک نسبت به مدل‌های پایه هیل هستند. از آنجایی که عضله دارای رفتار متغیر با زمان است دو ساختار متفاوت؛ شبکه عصبی متغیر با زمان و نامتغیر با زمان برای مدل‌سازی عضله در نظر گرفته شده است. نتایج نشان می‌دهد مدل‌های عصبی متغیر با زمان، با دقت ۹۹/۵٪ و مدل‌های نامتغیر با زمان، با دقت ۹۵٪ قادر به پیش‌بینی نیروی انقباض عضله تحریک شده در شرایط غیرایزومتریک هستند. علاوه بر این، نتایج این تحقیق نشان می‌دهد دقت پیش‌بینی شبکه عصبی به ساختار شبکه بستگی دارد. با وجود ساده بودن ساختار شبکه عصبی مبتنی بر توابع شعاعی نسبت به ساختار شبکه عصبی پس‌انتشار خطا، دقت پیش‌بینی با شبکه عصبی مبتنی بر توابع شعاعی با ۱۰۰۰ دوره یادگیری بیشتر از شبکه عصبی پس‌انتشار خطا با ۵۰۰۰ دوره یادگیری است.

واژه‌های کلیدی: عضله؛ مدل‌سازی؛ شبکه‌های عصبی؛ تحریک الکتریکی کارکردی؛ سیستم‌های عصبی - عضلانی

*عهده‌دار مکاتبات

نشانی: نارمک، تهران، دانشگاه علم و صنعت ایران، دانشکده مهندسی برق، گروه مهندسی پزشکی

تلفن: ۰۲۱-۷۳۹۱۳۵۵۳، دورنگار: ۰۲۱-۷۷۴۵۴۰۵۵، پیام‌نگار: erfanian@iust.ac.ir

۱- مقدمه

امروزه تحریک الکتریکی کارکردی^۱، به عنوان یک روش بالقوه مؤثر جهت ایجاد حرکت در اندام فلج افراد دچار ضایعه نخاعی مطرح است. در این روش، عضلات فلج درگیر یک حرکت خاص به وسیله سیگنال الکتریکی مناسب از طریق الکترودهای سطحی و یا زیرجلدی منقبض می‌شوند. این سیگنال‌ها در حقیقت نقش دستورات موتوری را در سیستم حسی- حرکتی انسان ایفا می‌کنند. با اعمال الگوهای الکتریکی مناسب به عضلات درگیر یک حرکت، می‌توان حرکت مورد نظر را در عضو فلج پدید آورد. به منظور ایجاد یک حرکت مطلوب در اعضای فلج، باید عضلات درگیر حرکت به میزان مناسب منقبض شده تا نیروی انقباضی لازم ایجاد شده و متعاقب آن گشتاور لازم در مفاصل تولید شود. برای بوجود آمدن یک انقباض مشخص در عضله لازم است سیگنال‌های الکتریکی مناسبی به عضلات فلج درگیر حرکت اعمال شود. در این راستا، شناسایی رابطه ورودی- خروجی عضله و به عبارت کلی‌تر، مدل‌سازی عضله امری لازم است. تاکنون مدل‌های متنوعی از عضله تحریک شده در سطوح مختلف ماکروسکوپی و میکروسکوپی ارائه شده است [۱]، اگر چه، این مدل‌ها به فهم رفتار عضله کمک کرده‌اند، اما توانایی بازنمایی تمام جنبه‌های رفتاری عضله را ندارند و قادر به پیش‌بینی دقیق نیروی انقباض عضله نیستند. به طور کلی، مدل‌های عضله را می‌توان به دو دسته ایزومتریک و غیرایزومتریک تقسیم‌بندی کرد. مدل‌های ایزومتریک رفتار عضله را در یک طول ثابت توصیف می‌کنند [۲-۷]، ولیکن در انقباض غیرایزومتریک، طول عضله ثابت نیست. از آنجایی که میزان نیروی انقباضی عضله وابسته به طول عضله و سرعت انقباض است، مدل‌های ایزومتریک (طول ثابت) قادر به پیش‌بینی نیرو در حالت انقباض غیرایزومتریک^۲ نیستند.

در مرجع ۸، یک مدل پیش‌بینی‌کننده از عضله تحریک شده در شرایط غیرایزومتریک ارائه شده است. ورودی این مدل‌ها را علاوه بر سیگنال تحریک، طول عضله و سرعت تغییر طول نیز تشکیل می‌دهد. این مدل بر اساس مدل پایه هیل^۳

بنا شده است [۹]. در ساختار مدل هیل فرض می‌شود که نیروی عضلانی از جمع دو قسمت فعال^۴ و غیرفعال^۵ حاصل می‌گردد. نیروی فعال خود از سه قسمت مجزا تشکیل یافته است: الف- دینامیک فعال، ب- رابطه طول- نیرو، و ج- رابطه سرعت- نیرو. در ساختار مدل هیل فرض می‌شود دینامیک فعال، نیرویی ایجاد می‌کند که به طول عضله و سرعت انقباض بستگی ندارد. در این مدل‌ها، نیروی دینامیک فعال به وسیله رابطه نیرو- طول و نیرو- سرعت مدوله می‌شود. ورودی دینامیک فعال را تحریک عصبی و یا الکتریکی تشکیل می‌دهد. در این مدل فرض شده است شکل رابطه نیرو- طول و نیرو- سرعت، مستقل از یکدیگر و برای تمام سطوح فعالیت عضله یکی است، اما باید توجه داشت شکل رابطه نیرو- طول و نیرو- سرعت برای واحدهای حرکتی مختلف، متفاوت است [۱۰، ۱۱]. علاوه بر این، در این مدل دینامیک فعال مستقل از میزان شدت فعالیت عضله در نظر گرفته شده است. این فرض، تغییر دینامیک عضله در اثر به‌کارگیری واحدهای حرکتی مختلف در سطوح متفاوت تحریک را در نظر نمی‌گیرد [۱۲]. به منظور رفع محدودیت‌های ساختار مدل هیل، مدل غیرایزومتریک دیگری از عضله تحریک شده در مراجع ۱۳ و ۱۴ ارائه شده است. در این مدل، نیروی عضلانی برابر با حاصلضرب دو فاکتور مجزا در نظر گرفته شده است: ۱- دینامیک فعالیت عضله که بیان‌کننده رفتار دینامیک عضله و رابطه نیرو با سرعت انقباض است؛ ۲- رابطه نیرو با طول عضله. در این مدل، رابطه نیرو- طول با یک خط و رابطه سرعت- نیرو با دو خط با ضریب‌زاویه‌های مختلف برای سرعت‌های مثبت و منفی بیان شده است. لازم به ذکر است شکل روابط سرعت- نیرو در این مدل ثابت است، اما در تحقیقات دیگری نشان داده شده است که نمی‌توان برای رابطه نیرو- سرعت یک شکل ثابت تعریف کرد [۱۵]. رابطه نیرو- سرعت به میزان زیادی وابسته به سابقه سرعت است. این شکل، هم‌چنین با فرکانس تحریک تغییر می‌کند.

به منظور رفع محدودیت‌های مدل‌های ساختار هیل، در این تحقیق از شبکه‌های عصبی دینامیک به عنوان ابزاری جهت

¹Functional Electrical Stimulation (FES)

⁴Active

²Nonisometric

⁵Passive

³Hill

مرجع ۱۸ نشان داده شده است که می‌توان از یک شبکه چندلایه پرسپترون با تعداد زیاد نرون در لایه پنهان و با توابع فعالیت دلخواه squashing، به عنوان یک تقریب‌زننده فراگیر استفاده کرد. همچنین نشان داده شده است شبکه‌های عصبی مبتنی بر توابع پایه شعاعی، قابلیت تقریب فراگیر دارند [۱۹]. به طور کلی، توابع پایه شعاعی یک روش درون‌یابی فراگیر با خواص خوب محلی است و قابلیت درون‌یابی صاف را برای داده‌های پراکنده دارد.

قابلیت تقریب فراگیر شبکه‌های عصبی، یکی از انگیزه‌های استفاده از این مدل‌ها در شناسایی سیستم‌های غیرخطی و پویا به شمار می‌رود. یکی از خصوصیات مهم سیستم‌های بیولوژیک، رفتار غیرخطی و پویای آنها است. عضله دارای رفتار متغیر با زمان، غیرخطی و پویا است. در هنگام مدل‌سازی عضله، چشم‌پوشی از خاصیت غیرخطی عضله و استفاده از ساختارهای خطی، کیفیت مدل را کاهش می‌دهد، لذا برای مدل‌سازی عضله نیاز به مدل‌های غیرخطی و پویا است. یکی از روش‌های کلی برای توصیف سیستم‌های غیرخطی پویا استفاده از شبکه‌های عصبی به صورت رابطه ۱ است:

$$y(t) = f[y(t-1), y(t-1), \dots, y(t-m), \dots, u(t-1), u(t-2), \dots, u(t-n)] \quad (1)$$

در این رابطه، $y(t)$ ، خروجی و $u(t)$ ورودی در لحظه t است. پویایی به وسیله اعمال خروجی‌های لحظات گذشته به ورودی شبکه در نظر گرفته شده است. از آنجایی که رفتار عضله در هنگام انقباض غیرایزومتریک، علاوه بر میزان تحریک، بستگی به طول عضله، سرعت انقباض و وضعیت گذشته عضله دارد باید از ساختارهای مدل چندورودی استفاده کرد:

$$y(t) = f[y(t-1), y(t-1), \dots, y(t-m), s(t-1), s(t-1), \dots, s(t-n), l(t-1), l(t-2), \dots, l(t-p), v(t-1), v(t-2), \dots, v(t-q)] \quad (2)$$

در این رابطه، y ، نیروی تولید شده در لحظه t ، s ، میزان تحریک، l ، طول عضله و v سرعت انقباض است. ورودی


مدل‌سازی عضله در حالت غیرایزومتریک استفاده می‌شود. شبکه عصبی دارای ساختار غیرخطی است و یک نگاشت غیرخطی بین ورودی و خروجی برقرار می‌کند؛ رفتار عضله را به طور کلی در نظر می‌گیرد و هیچ‌گونه تجزیه‌ای در رفتار آن انجام نمی‌دهد، در حالی که، ساختار مدل هیل رفتار عضله را تجزیه کرده و هیچ ارتباطی بین اجزای آن در نظر نمی‌گیرد. علاوه بر این، در ساختار مدل هیل لازم است با توجه به دانش موجود در مورد رفتار عضله، پیش‌فرض‌هایی درباره ساختار هر یک از اجزاء در نظر گرفته شود. این پیش‌فرض‌ها و تجزیه‌ها، کارایی مدل را محدود می‌کند. با مد نظر قرار دادن قابلیت یادگیری شبکه‌های عصبی انتظار می‌رود مدل‌های عصبی قادر به بازنمایی تغییرات دینامیک عضله نسبت به شدت تحریک، بازنمایی رابطه بین نیروی عضله و سرعت انقباض و تغییرات این رابطه نسبت به شدت تحریک و نیز بازنمایی رابطه بین نیروی عضله و طول آن و تغییرات نسبت به شدت فعالیت عضله باشد.

تاکنون از شبکه‌های عصبی برای پیش‌بینی میزان انقباض عضلانی و مدل‌سازی استفاده شده است [۱۶، ۱۷]. در مرجع ۱۶، از شبکه عصبی پیش‌سو برای مدل‌سازی فرآیند فعال‌سازی عضله^۶ در حالت انقباض ایزومتریک ارادی استفاده شده است. سیگنال الکترومایوگرام به عنوان ورودی مدل در نظر گرفته شده است. سپس خروجی شبکه جهت پیش‌بینی گشتاور مفصل به یک مدل مبتنی بر مدل هیل اعمال شده است. در مرجع ۱۷، شبکه‌های عصبی با ورودی سیگنال الکترومایوگرام برانگیخته برای پیش‌بینی نیروی انقباض عضله تحریک شده در حالت ایزومتریک در فرد فلج به کار گرفته شده است. در این تحقیق، از شبکه‌های عصبی جهت پیش‌بینی نیروی عضله تحریک شده در حالت غیرایزومتریک استفاده شده است.

۲- ساختار مدل‌های عصبی عضله

گزارشات زیادی مبنی بر تقریب توابع به وسیله شبکه‌های عصبی وجود دارد. اثبات شده است که می‌توان هر نگاشت پیوسته را به وسیله شبکه‌های عصبی چندلایه تقریب زد. در

⁶ Muscle Activation



مدل را سیگنال تحریک، طول عضله، سرعت انقباض و حالت‌های گذشته عضله تشکیل می‌دهد. برای شناسایی مدل، لازم است تابع f مشخص و پارامترهای m ، n ، p و q تعیین شوند. در این تحقیق، پارامترهای m ، n ، p و q درجه مدل اطلاق می‌شود و برای تعیین مقادیر آن، از معیار خطای پیش‌بینی استفاده شده است. درجه مدلی که به ازای آن خطای پیش‌بینی کمینه شده باشد به عنوان درجه مدل انتخاب می‌شود.

در این تحقیق از دو شبکه عصبی برای مدل‌سازی عضله، شبکه چندلایه پرسپترون با قاعده یادگیری پس‌انتشار خطا و شبکه عصبی مبتنی بر توابع پایه شعاعی و با روش یادگیری الگوریتم گرادیان تصادفی استفاده شده است [۱۹].

۲-۳- شبکه عصبی مبتنی بر توابع شعاعی با روش

یادگیری الگوریتم گرادیان تصادفی

ساختار شبکه‌های عصبی مبتنی بر توابع شعاعی^۷ ساده بوده و فقط دارای یک لایه میانی مخفی است. در شکل ۱، نمونه ساختار یک شبکه RBF نشان داده شده است. لایه میانی از تعدادی گره‌های کرنل با توابع فعالیت کرنل تشکیل شده است. خروجی شبکه، مجموع خطی توابع کرنل وزن‌دار است.

$$y(x) = \sum_{i=1}^M w_i \cdot k_i(x(n)) = \sum_{i=1}^M w_i \cdot g_i \left(\frac{\|x(n) - c_i\|}{s_i} \right) \quad (3)$$

در این رابطه، $x(n)$ بردار ورودی در لحظه n ؛ M تعداد نرون‌های لایه پنهان؛ w_i وزن گره i -ام به گره خروجی و k تابع کرنل است. معمولاً از تابع گوسین به عنوان تابع کرنل استفاده می‌شود. پارامتر c_i و s_i ، به ترتیب مرکز و عرض گره i -ام است. تاکنون الگوریتم‌های یادگیری متنوعی برای شبکه RBF پیشنهاد شده است. در این تحقیق، از الگوریتم یادگیری گرادیان تصادفی استفاده شده است [۱۹]. شرح روابط الگوریتم در ضمیمه الف آورده شده است.

۳- آزمایش‌های حیوانی

آزمایش‌ها بر روی عضله نعلی^۸ گربه انجام شده است [۱۳]. عضله با استفاده از پالس‌های دوفاز به وسیله الکتروودکاف دوقطبی که بر روی عصب سیاتیک قرار داده شده، تحریک

۲-۱- ساختارهای عصبی متغیر با زمان و نامتغیر با زمان


از آنجایی که عضله دارای رفتار متغیر با زمان است در این تحقیق، از ساختارهای عصبی متغیر با زمان استفاده شده و کارایی آن با ساختار نامتغیر با زمان در پیش‌بینی نیروی انقباض عضلانی مقایسه شده است. در ساختارهای متغیر با زمان، ضرایب شبکه، متغیر با زمان است. به عبارتی، فرآیند یادگیری نیز بعد از همگرایی ادامه دارد. انتظار می‌رود این نوع ساختارها بهتر بتوانند رفتار متغیر با زمان فرآیندهای غیرایستا را دنبال کنند، اما باید فرآیند یادگیری به اندازه کافی سریع باشد. در ساختارهای عصبی نامتغیر با زمان، ضرایب شبکه بعد از همگرایی ثابت نگه داشته می‌شود. به عبارت دیگر، فرآیند یادگیری بعد از همگرایی متوقف می‌شود.

۲-۲- شبکه عصبی چندلایه پرسپترون


ساختار شبکه عصبی پرسپترون مورد استفاده در این تحقیق، دارای دو لایه مخفی و یک نرون در لایه خروجی است و از الگوریتم یادگیری پس‌انتشار خطا برای آموزش شبکه استفاده شده است [۱۹]. شبکه‌های مختلفی با تعداد نرون‌های متفاوت در لایه پنهان و تعداد گره‌های مختلف ورودی آموزش و آزمایش شده است.

^۷ Radial Basis Function (RBF) Network


^۸ Soleus



الف




ب



ج

شکل ۳- نمونه‌ای از الگوی تصادفی سیگنال تحریک، تغییرات طول عضله و نیروی اندازه‌گیری شده برای گستره تغییرات ۶ میلی‌متر (الف)، ۳ میلی‌متر (ب) و ۱/۵ میلی‌متر (ج) در نقطه کار ۲۰ میلی‌متر

است، بنابراین، ورودی‌های مورد استفاده در شناسایی عضله، تصادفی هستند.




شکل ۲- نحوه انجام آزمایش

گردیده است. تمام شاخه‌های عصب سیاتیک به جز شاخه عصب عضله نعلی قطع شده است. سیگنال تحریک الکتریکی شامل مجموعه‌ای از پالس‌ها با دامنه ثابت و عرض متغیر است. در این آزمایش، برای کنترل میزان انقباض عضله از عرض پالس سیگنال تحریک استفاده شده است. از آنجایی که ورودی‌های برانگیزنده برای اطمینان از همگرایی الگوریتم‌های شناسایی مورد نیاز است، عضله با الگوهای تصادفی تحریک گردیده است. برای این منظور، عرض پالس تحریک به طور تصادفی با توزیع یکنواخت بین دو مقدار سوئیچ کرده است. همچنین تغییرات طول عضله تصادفی با توزیع یکنواخت، حول یک مقدار متوسط بوده است.

یک سر عضله از تاندون قطع شده و از طریق یک نیروسنج به موتور پله‌ای وصل شده است. همزمان با اعمال سیگنال تحریک تصادفی به عضله، طول عضله نیز با استفاده از موتور پله‌ای به طور تصادفی در حول یک طول مشخص تغییر داده شده است. آزمایشات در دو طول مختلف عضله؛ ۸ و ۲۰ میلی‌متر به عنوان دو نقطه کار متفاوت انجام شده است. سعی گردیده با توجه به طول عضله گربه، دو نقطه کار کاملاً متفاوت و دور از هم انتخاب شود. سپس در هر نقطه کار، طول عضله به طور تصادفی تغییر داده شده است (شکل ۲). گستره تغییرات طول عضله ۱/۵ میلی‌متر، ۳ میلی‌متر و ۶ میلی‌متر بوده است.

در شکل ۳، نمونه‌ای از الگوهای سیگنال تحریک، تغییرات طول عضله و نیروی اندازه‌گیری شده نشان داده شده است. شکل ۴، تغییرات طول عضله و نیروی اندازه‌گیری شده (نیروی غیرفعال) را هنگامی که سیگنال تحریک اعمال نشده است نشان می‌دهد. در شکل ۵، تابع خودهمبستگی سیگنال تحریک، طول عضله و نیروی اندازه‌گیری آورده شده است. مشاهده می‌شود تابع همبستگی تقریباً شبیه یک تابع ضربه




شکل ۵- نمونه‌ای از تابع خودهمبستگی سیگنال تحریک (شکل بالا)، تابع خودهمبستگی تغییرات طول عضله با گستره تغییرات ۶ میلی‌متر (شکل وسط) و تابع خودهمبستگی نیروی اندازه‌گیری شده (شکل پایین)

$$NPE = \frac{\sum_t |y(t) - \hat{y}(t)|}{\sum_t y(t)} \quad (4)$$


در رابطه ۴، $y(t)$ ، نیروی اندازه‌گیری شده و $\hat{y}(t)$ ، نیروی پیش‌بینی شده است. برای شناسایی مدل لازم است که مقادیر پارامترهای p و q (رابطه ۲) مشخص شود. برای این منظور، مدل‌های مختلفی به ازای مقادیر متفاوت p و q شناسایی شده‌اند. درجه مدلی که به ازای آن خطای پیش‌بینی کمتر باشد، به عنوان درجه مناسب انتخاب شده است. سرعت، با استفاده از تغییرات طول عضله محاسبه، و به مدل اعمال شده است.

۱-۵- نتایج مدل‌سازی با شبکه‌های عصبی پس‌انتشارخفا


شبکه پرسپترون مورد استفاده دارای دو لایه مخفی، هر یک دارای ۲۰ نرون است و یک نرون در خروجی در نظر گرفته شده است. ورودی شبکه را سیگنال تحریک، طول، سرعت و گذشته‌های خروجی مدل (نیرو) تشکیل می‌دهد. در این راستا، مقادیر p و q (رابطه ۱) باید مشخص شود. علاوه بر این، همان‌طور که در بخش آزمایش گفته شد آزمایش‌ها در دو طول مختلف عضله؛ ۲۰ mm و ۸ mm، به عنوان دو نقطه کار متفاوت انجام شده است. سپس در هر



الف



ب



ج

شکل ۴- نمونه‌ای از تغییرات طول عضله و نیروی اندازه‌گیری شده برای گستره تغییرات ۶ میلی‌متر (الف)، ۳ میلی‌متر (ب) و ۱/۵ میلی‌متر (ج) در نقطه کار ۲۰ میلی‌متر هنگامی که سیگنال تحریک صفر است.

۵- مدل‌سازی عضله در شرایط غیرایزومتریک با

شبکه‌های عصبی

در این بخش به نتیجه مدل‌سازی عضله در شرایط غیرایزومتریک با استفاده از شبکه‌های عصبی متغیر با زمان و نامتغیر با زمان پرداخته می‌شود. به منظور ارزیابی عملکرد شبکه، از معیار "خطای پیش‌بینی"^۹ استفاده شده است:

^۹Normalized Prediction Error (NPE)

الف- خطای پیش‌بینی برای درجه (۱،۱،۱) و (۲،۲،۲) نسبت به درجه‌های دیگر کمتر است.

ب- خطای پیش‌بینی شبکه عصبی متغیر با زمان، کمتر از خطای پیش‌بینی شبکه عصبی نامتغیر با زمان است.

ج- هنگامی که از شبکه عصبی آموزش داده شده با داده‌های با گستره تغییرات ۱/۵ mm، برای پیش‌بینی نیرو با گستره ۳ و ۶ میلی‌متر استفاده شده است خطا، به میزان قابل‌توجهی افزایش می‌یابد.

د- نتایج این بررسی در جدول‌های ۱ تا ۴ نشان می‌دهد که دقت پیش‌بینی شبکه عصبی آموزش داده شده با داده‌های با گستره ۶ mm بسیار بیشتر از شبکه عصبی آموزش داده شده با داده‌های با گستره ۱/۵ mm است.

۵-۱-۲- نقطه کار ۸ میلی‌متر

در این بخش، شبکه عصبی با داده‌های با گستره تغییرات ۶ mm در نقطه کار ۸ mm آموزش داده شده و از آن، برای پیش‌بینی نیروی انقباض عضلانی در نقطه کار ۲۰ mm استفاده شده است. در جدول ۵، نتایج این پیش‌بینی آورده شده است. چنانچه این نتایج (جدول ۵) با نتایج حاصل از پیش‌بینی شبکه عصبی آموزش داده شده در نقطه کار ۲۰ mm (جدول ۱ و ۲) مقایسه شود، ملاحظه می‌گردد که تفاوت، کمتر از ۱٪ است. بر عکس، چنانچه از شبکه آموزش داده شده با داده‌های با گستره تغییرات ۶ mm در نقطه کار ۲۰ mm، برای پیش‌بینی نیروی انقباض عضلانی در نقطه کار ۸ mm استفاده شود، ملاحظه می‌شود که دقت پیش‌بینی تغییر چندانی نکرده و اختلاف کمتر از ۴/۰٪ است.

این نتایج نشان می‌دهد شبکه آموزش داده شده در یک نقطه کار قادر به پیش‌بینی رفتار عضله در نقاط دیگر کار است اگر چه، رفتار عضله در نقاط مختلف کار (طول عضله) کاملاً متفاوت است.

۵-۲- نتایج مدل‌سازی با شبکه عصبی مبتنی بر توابع

شعاعی

در جدول ۶، میزان خطای پیش‌بینی نیروی انقباض عضلانی را با استفاده از شبکه عصبی مبتنی بر توابع شعاعی متغیر

نقطه کار، طول عضله به طور تصادفی با گستره تغییرات مختلف تغییر داده شده است. در ادامه، نتایج پیش‌بینی برای دو نقطه کار متفاوت بیان می‌شود.

۵-۱-۱- نقطه کار ۲۰ میلی‌متر

در جدول ۱، مقدار خطای همگرایی برای مقادیر مختلف $(q \text{ و } p \text{ n sm})$ با استفاده از شبکه عصبی متغیر با زمان آورده شده است. ملاحظه می‌شود مقدار خطای پیش‌بینی برای درجه (۱،۱،۱) و (۲،۲،۲) کمینه شده است. شبکه با داده‌های به دست آمده با بیشترین گستره تغییرات طول عضله (۶ mm)، آموزش داده شده و با تمام داده‌ها، آزمایش شده است. نتایج نشان می‌دهد شبکه عصبی متغیر با زمان، قادر به پیش‌بینی نیروی انقباض عضلانی با دقت حدود ۹۶٪ است. نکته قابل توجه اینکه چنانچه میزان تغییرات طول عضله به ۳ و یا ۱/۵ میلی‌متر کاهش یابد، خطای پیش‌بینی نیز کاهش می‌یابد. در جدول ۲، میزان خطای پیش‌بینی با استفاده از شبکه عصبی متغیر با زمان به ازای مقادیر مختلف $(q \text{ و } p \text{ n sm})$ آورده شده است. ملاحظه می‌شود خطای پیش‌بینی برای درجه (۱،۱،۱) و (۲،۲،۲) نسبت به درجه‌های دیگر کمتر شده است. در این حالت نیز شبکه با استفاده از داده‌های حاصل از گستره تغییرات ۶ mm آموزش داده شده و با تمام داده‌ها، آزمایش شده است.

ملاحظه می‌شود میزان خطای پیش‌بینی برای داده‌های آزمایش بیشتر از داده‌های آموزش است. در این حالت ملاحظه می‌گردد به طور کلی، خطای پیش‌بینی با استفاده از شبکه عصبی متغیر با زمان، کمتر از شبکه عصبی نامتغیر با زمان است. علاوه بر این، نتایج نشان می‌دهد که در شبکه عصبی نامتغیر با زمان، هنگامی که گستره تغییرات طول ۳ و یا ۱/۵ میلی‌متر است خطای پیش‌بینی، اندکی افزایش یافته است.

در جداول ۳ و ۴، به ترتیب خطای پیش‌بینی نیروی انقباض عضلانی با استفاده از شبکه عصبی متغیر با زمان و نامتغیر با زمان آورده شده است. در این حالت، شبکه‌ها با استفاده از داده‌های حاصل از گستره تغییرات ۱/۵ mm آموزش داده شده و با تمام داده‌ها، آزمایش شده است. ملاحظه می‌شود:

جدول ۱- متوسط خطای پیش‌بینی با استفاده از شبکه عصبی پس‌انتشار خطا (متغیر با زمان) پس از ۵۰۰۰ دوره یادگیری (آموزش با داده‌های گستره ۶ در طول عضله ۲۰ میلی‌متر و آزمایش با تمام داده‌ها در همین نقطه کار انجام شده است.)

(m,n,p,q)	(۱,۱,۱,۱)	(۰,۱,۱,۱)	(۱,۲,۲,۱)	(۱,۲,۲,۲)	(۲,۲,۲,۲)	(۳,۳,۳,۳)	(۱,۱,۱,۰)
LP: ۶	۰/۰۴۶	۰/۰۹۴	۰/۰۴۶	۰/۰۴۲	۰/۰۳۸	۰/۰۳۸	۰/۱۱۰
LP: ۳	۰/۰۴۸	۰/۰۷۴	۰/۰۴۶	۰/۰۴۸	۰/۰۴۳	۰/۰۵۳	۰/۰۸۹
LP: ۱/۵	۰/۰۲۹	۰/۰۴۹	۰/۰۳۹	۰/۰۴۳	۰/۰۳۵	۰/۰۵۰	۰/۰۴۸
متوسط	۰/۰۳۸	۰/۰۷۲	۰/۰۴۳	۰/۰۴۴	۰/۰۳۹	۰/۰۴۷	۰/۰۸۲

جدول ۲- متوسط خطای پیش‌بینی با استفاده از شبکه عصبی پس‌انتشار خطا (نامتغیر با زمان) پس از ۵۰۰۰ دوره یادگیری (آموزش با داده‌های گستره ۶ در طول عضله ۲۰ میلی‌متر و آزمایش با تمام داده‌ها در همین نقطه کار انجام شده است.)

(m,n,p,q)	(۱,۱,۱,۱)	(۰,۱,۱,۱)	(۱,۲,۲,۱)	(۱,۲,۲,۲)	(۲,۲,۲,۲)	(۳,۳,۳,۳)	(۱,۱,۱,۰)
LP: ۶	۰/۰۴۶	۰/۱۳۱	۰/۰۴۰	۰/۰۴۰	۰/۰۳۲	۰/۰۳۱	۰/۰۷۳
LP: ۳	۰/۰۴۴	۰/۱۶۶	۰/۰۵۱	۰/۰۵۸	۰/۰۵۴	۰/۱۱۰	۰/۰۶۸
LP: ۱/۵	۰/۰۳۸	۰/۲۲۰	۰/۰۵۳	۰/۰۵۹	۰/۰۶۷	۰/۱۳۴	۰/۰۴۹
متوسط	۰/۰۴۳	۰/۱۷۲	۰/۰۴۸	۰/۰۵۲	۰/۰۵۱	۰/۰۹۲	۰/۰۶۳

جدول ۳- متوسط خطای پیش‌بینی با استفاده از شبکه عصبی پس‌انتشار خطا (متغیر با زمان) پس از ۵۰۰۰ دوره یادگیری (آموزش با داده‌های گستره ۱/۵ در طول عضله ۲۰ میلی‌متر و آزمایش با تمام داده‌ها در همین نقطه کار انجام شده است.)

(m,n,p,q)	(۱,۱,۱,۱)	(۰,۱,۱,۱)	(۱,۲,۲,۱)	(۱,۲,۲,۲)	(۲,۲,۲,۲)	(۳,۳,۳,۳)	(۱,۱,۱,۰)
LP: ۱/۵	۰/۰۲۳	۰/۰۴۳	۰/۰۲۲	۰/۰۲۲	۰/۰۲۱	۰/۰۲۷	۰/۰۴۲
LP: ۳	۰/۰۵۰	۰/۱۱۷	۰/۰۴۴	۰/۰۵۸	۰/۰۵۳	۰/۰۸۵	۰/۰۹۰
LP: ۶	۰/۱۴۱	۰/۱۹۸	۰/۱۱۱	۰/۱۹۲	۰/۱۷۰	۰/۲۲۲	۰/۱۲۹
متوسط	۰/۰۷۱	۰/۱۱۹	۰/۰۵۹	۰/۰۹۱	۰/۰۸۱	۰/۱۱۱	۰/۰۸۷

جدول ۴- متوسط خطای پیش‌بینی با استفاده از شبکه عصبی پس‌انتشار خطا (نامتغیر با زمان) پس از ۵۰۰۰ دوره یادگیری (آموزش با داده‌های گستره ۱/۵ در طول عضله ۲۰ میلی‌متر و آزمایش با تمام داده‌ها در همین نقطه کار انجام شده است.)

(m,n,p,q)	(۱,۱,۱,۱)	(۰,۱,۱,۱)	(۱,۲,۲,۱)	(۱,۲,۲,۲)	(۲,۲,۲,۲)	(۳,۳,۳,۳)	(۱,۱,۱,۰)
LP: ۱/۵	۰/۰۲۴	۰/۰۸۶	۰/۰۲۲	۰/۰۲۴	۰/۰۱۸	۰/۰۲۲	۰/۰۴۱
LP: ۳	۰/۰۷۷	۰/۲۳۰	۰/۰۵۳	۰/۱۳۹	۰/۰۸۶	۰/۱۸۳	۰/۰۸۰
LP: ۶	۰/۴۰۴	۰/۶۱۵	۰/۱۷۵	۰/۶۲۶	۰/۴۳۷	۰/۷۴۳	۰/۲۸۰
متوسط	۰/۱۶۸	۰/۳۱۰	۰/۰۸۳	۰/۲۶۳	۰/۱۸۰	۰/۳۱۶	۰/۱۳۴

جدول ۵- متوسط خطای پیش‌بینی با استفاده از شبکه عصبی پس‌انتشار خطا (متغیر و نامتغیر با زمان) پس از ۵۰۰۰ دوره یادگیری

درجه مدل	آموزش با داده‌های با گستره تغییرات ۶ mm در نقطه کار ۲۰ mm، آزمایش با داده‌های نقطه کار ۸ mm				آموزش با داده‌های با گستره تغییرات ۶ mm در نقطه کار ۸ mm، آزمایش با داده‌های نقطه کار ۲۰ mm			
	متوسط	۱/۵	۳	۶	متوسط	۱/۵	۳	۶
(۱،۱،۱)	۰/۰۵۴	۰/۰۳۸	۰/۰۵۲	۰/۰۷۳	۰/۰۵۳	۰/۰۵۰	۰/۰۴۳	۰/۰۶۵
نامتغیر با زمان	۰/۰۴۱	۰/۰۳۰	۰/۰۳۹	۰/۰۵۵	۰/۰۳۷	۰/۰۲۷	۰/۰۳۴	۰/۰۴۹

جدول ۶- متوسط خطای پیش‌بینی با استفاده از شبکه‌های عصبی مبتنی بر توابع شعاعی پس از ۱۰۰۰ دوره یادگیری

(آموزش با داده‌های گستره ۶ در طول نامی عضله ۲۰ و آزمایش با تمام داده‌ها در گستره‌های مختلف در طول نامی ۲۰ و ۸ انجام شده است.)


نقطه کار	۲۰ mm				۸ mm			
	متوسط	۱/۵	۳	۶	متوسط	۱/۵	۳	۶
گستره تغییرات طول عضله	۰/۰۴۹	۰/۰۳۵	۰/۰۳۶	۰/۰۷۶	۰/۰۴۹	۰/۰۳۰	۰/۰۴۲	۰/۰۷۴
متغیر با زمان	۰/۰۵۶۷	۰/۰۵۸۹	۰/۰۴۴۹	۰/۰۶۶۲	۰/۰۴۶۷	۰/۰۴۳۱	۰/۰۴۵۳	۰/۰۵۱۸

۶- نتیجه‌گیری

ساختار مدل هیل از معروف‌ترین ساختارهای مدل عضله به شمار می‌رود. در ساختار مدل هیل فرض می‌شود که نیروی عضلانی از جمع دو قسمت فعال و غیرفعال حاصل می‌گردد. نیروی فعال خود از سه قسمت مجزا تشکیل یافته است: الف- دینامیک فعال، ب- رابطه طول- نیرو و ج- رابطه سرعت- نیرو. در ساختار مدل هیل فرض می‌شود دینامیک فعال نیرویی ایجاد می‌کند که به طول عضله و سرعت انقباض بستگی ندارد. در این ساختار، نیروی دینامیک فعال به وسیله رابطه نیرو- طول و نیرو- سرعت مدوله می‌شود. ورودی دینامیک فعال را تحریک عصبی و یا سیگنال الکتریکی تشکیل می‌دهد. در این مدل فرض شده است شکل رابطه نیرو- طول و نیرو- سرعت مستقل از یکدیگر و برای تمام سطوح فعالیت عضله یکی است. اما باید توجه داشت که شکل رابطه نیرو- طول و نیرو- سرعت برای واحدهای حرکتی مختلف، متفاوت است. علاوه بر این، در این مدل دینامیک فعال مستقل از میزان شدت فعالیت عضله در نظر گرفته شده است. این فرض، تغییر دینامیک عضله را در اثر به‌کارگیری واحدهای حرکتی مختلف در سطوح

و نامتغیر با زمان آورده شده است. در این حالت، شبکه با استفاده از داده‌های به دست آمده در آزمون با بیشترین گستره تغییرات طول عضله (۶ میلی‌متر) در نقطه کار ۲۰ mm، آموزش، و با تمام داده‌ها در دو نقطه کار آزمایش شده است. نکته قابل توجه اینکه، با کاهش گستره تغییرات طول عضله، خطای پیش‌بینی نیز کاهش یافته است. نتیجه بسیار قابل توجه اینکه، شبکه عصبی متغیر با زمان با دقت حدود ۹۹/۵٪ و شبکه عصبی نامتغیر با زمان، با دقت حدود ۹۵٪ توانسته میزان نیروی انقباض عضلانی را در حالت غیرایزومتریک پیش‌بینی کند. لازم به ذکر است شبکه عصبی مبتنی بر توابع شعاعی دارای ۲۵ نرون در لایه مخفی و تعداد دور یادگیری، ۱۰۰۰ بوده است.

در شکل ۶، پیش‌بینی نیروی انقباض عضلانی با استفاده از شبکه عصبی مبتنی بر توابع شعاعی نامتغیر با زمان نشان داده شده است. شبکه با استفاده از داده‌های به دست آمده در آزمون با بیشترین گستره تغییرات طول عضله (۶ میلی‌متر) در نقطه کار ۲۰ mm، آموزش و با تمام داده‌ها در دو نقطه کار آزمایش شده است. مشاهده می‌شود شبکه قادر به دنبال کردن رفتار عضله با دقت بسیار عالی است.



شکل ۶- نیروی انقباض اندازه‌گیری شده (خط توپر) و پیش‌بینی شده (نقطه‌چین) در نقطه کار ۸ mm با استفاده از شبکه عصبی مبتنی بر توابع شعاعی نامتغیر با زمان، هنگامی که گستره تغییر تصادفی طول عضله ۶ میلی‌متر (شکل بالا)، ۳ میلی‌متر (شکل وسط) و ۱/۵ میلی‌متر (شکل پایین) است. شبکه با استفاده از داده‌های به دست آمده در آزمون با بیشترین گستره تغییرات طول عضله (۶ میلی‌متر) در نقطه کار ۲۰ mm آموزش داده شده است.

متفاوت تحریک در نظر نمی‌گیرد. (تطبیقی)، به طور متوسط برابر با ۰/۵٪ و در حالت نامتغیر با زمان (ثابت)، برابر با حدود ۵٪ است. هم‌چنین نتایج این تحقیق (جدول ۶) نشان می‌دهد که با آموزش شبکه در حول یک نقطه کار با تغییرات ماکزیمم طول عضله، می‌توان رفتار عضله را در نقاط دیگر کار نیز پیش‌بینی کرد. این از نتایج بسیار حائز اهمیت این تحقیق است.

علاوه بر این، نتایج این تحقیق نشان می‌دهد که دقت پیش‌بینی شبکه عصبی به ساختار شبکه بستگی دارد. با وجود ساده بودن ساختار شبکه عصبی مبتنی بر توابع شعاعی نسبت به ساختار شبکه عصبی پس‌انتشار خطا، دقت پیش‌بینی با شبکه عصبی مبتنی بر توابع شعاعی با ۱۰۰۰ دوره یادگیری بسیار دقیق‌تر از شبکه عصبی پس‌انتشار خطا با ۵۰۰۰ دوره یادگیری است.

سپاسگزاری

آزمایش‌های این تحقیق در بخش مهندسی پزشکی دانشگاه کیس وسترن آمریکا انجام شده است و لازم می‌دانم از همکاری پروفسور Patrick E. Crago تشکر نمایم.

به منظور رفع محدودیت‌های ساختار مدل هیل، در این تحقیق از شبکه‌های عصبی برای مدل‌سازی عضله استفاده شده است. با توجه به توانایی یادگیری شبکه‌های عصبی انتظار می‌رود که شبکه قابلیت فراگیری رابطه نیرو با طول عضله، نیرو با سرعت انقباض، و ارتباط این روابط با میزان سیگنال تحریک را داشته باشد. با مقایسه نتایج این تحقیق با نتایج گزارش شده در مرجع ۱۳، ملاحظه می‌شود شبکه‌های عصبی، پیش‌بینی بسیار دقیق‌تری را نسبت به مدل هیل داشته است.

در مرجع ۱۳، میزان خطای پیش‌بینی برای هنگامی که تطبیق پارامترهای مدل هیل را داشته است بین ۵ تا ۲۰٪، به ازای نقاط مختلف کار و گستره‌های متفاوت طول عضله گزارش شده است. قابل توجه اینکه، در هنگامی که پارامترهای مدل هیل ثابت نگه داشته شده‌اند خطای پیش‌بینی به ۴۰٪ رسیده است، در حالی که، میزان خطای پیش‌بینی با شبکه‌های عصبی مبتنی بر توابع شعاعی در حالت متغیر با زمان

ضمیمه الف

در الگوریتم گرادیان تصادفی؛ تمام پارامترهای شبکه، مراکز، ضرایب و عرض توابع کرنل تحت فرآیند یادگیری با معلم قرار دارند. یک روش معمول یادگیری با معلم، الگوریتم شیب گرادیان تصادفی است که در روابط زیر ارائه شده است:

$$y(n) = \sum_{i=1}^M w_i(n) \cdot k(x(n); c_i(n); S_i^2(n)) \quad (\text{الف-۱})$$

$$e(n) = d(n) - y(n) \quad (\text{الف-۲})$$

$$w_i(n+1) = w_i(n) + m \cdot e(n) \times k(x(n); c_i(n); S_i^2(n)) \quad (\text{الف-۳})$$

$$c_i(n+1) = c_i(n) + 2m \cdot e(n) \cdot w_i(n) \times k(x(n); c_i(n); S_i^2(n)) \frac{x(n) - c_i(n)}{S_i^2(n)} \quad (\text{الف-۴})$$

$$S_i^2(n+1) = S_i^2(n) + m \cdot e(n) \cdot w_i(n) \times k(x(n); c_i(n); S_i^2(n)) \cdot \frac{\|x(n) - c_i(n)\|^2}{S_i^2(n)} \quad (\text{الف-۵})$$

$$k(x(n); c_i(n); S_i^2(n)) = \exp\left(-\frac{1}{S_i^2(n)} \|x(n) - c_i(n)\|^2\right) \quad (\text{الف-۶})$$

در روابط فوق، $y(n)$ ، خروجی شبکه؛ $d(n)$ سیگنال مطلوب؛ m ضریب یادگیری؛ $x(n)$ بردار ورودی و c_i و S_i به ترتیب مرکز و عرض گره i -ام است.

مراجع

- [6] Bobet J, Stein RB, Oguztoreli MN; A linear time-varying model of force generation in skeletal muscle; *Trans Biomed Eng* 1997; 40: 1000-1006.
- [7] Hunt KJ, Munih M, Donaldson NN, Barr FMD; Investigation of the Hammerstein hypothesis in the modeling of electrically stimulated muscle; *Trans Biomed Eng* 1998; 45(8): 998-1009.
- [8] Durfee WK, Palmer KI; Estimation of force-activation, force-length, and force-velocity properties in isolated electrically stimulated muscle; *IEEE Trans Biomed Eng* 1994; 41: 205-216.
- [9] Winters JM, Woo SLY (Eds); *Multiple Muscle Systems: Biomechanics and Movement Organization*; New York, Springer-Verlag; 1990.
- [10] Joyce GC, Pack PMH, Westbury D; The mechanical properties of cat soleus muscle during controlled lengthening and shortening movements; *J Physiol* 1969; 204: 461-474.
- [11] Heckman C, Weytjens J, Loeb G; Effect of velocity and mechanical history on the force of motor units in the cat medial gastrocnemius muscle; *J Neurophysiol* 1992; 68: 1503-1515.
- [12] Petrofsky J, Phillips C; Determinations of the contractile characteristics of the motor units in skeletal muscle through twitch characteristics; *Med Biol Eng Comput* 1979; 17: 525-533.
- [13] Shue G, Crago PC, Chizeck HJ; Muscle-joint model incorporating activation dynamics, torque-angle and torque-velocity properties; *IEEE Trans Biomed Eng* 1995; 42: 212-223.
- [14] Shue G, Crago PE; Muscle-tendon model with length history-dependent activation-velocity coupling; *Annals of Biomed Eng* 1998; 26: 369-380.
- [15] Joyce GC, Rack PMH; Isotonic lengthening and shortening movement in cat soleus muscle; *J Physiol* 1969; 204: 461-491.
- [16] Wang L, Buchanan S; Prediction of joint moments using a neural network model of muscle activations from EMG signals; *IEEE Trans Neural Systems and Rehab Eng* 2002; 10: 30-37.
- [17] Erfanian A, Rajabi P; Prediction of electrically stimulated muscle force under isometric conditions using self-constructing neural network; *IUST international Journal of Eng and Science* 2004; 15: 121-141.
- [18] Scarsell F, Tsoi AC; Universal approximation using feedforward neural networks: A survey of some existing methods, and some new results; *Neural Networks* 1998; 11: 15-37.
- [19] Haykin S; *Neural Networks*; New Jersey, Prentice-Hall Inc; 1999.

عباس عرفانیان امیدوار، مدرک لیسانس را در

رشته مهندسی کامپیوتر از دانشگاه شیراز در سال

۱۳۶۴، مدرک فوق لیسانس را در مهندسی برق از

دانشگاه صنعتی شریف در سال ۱۳۶۸، و مدرک

دکترای تخصصی در مهندسی پزشکی را از

دانشگاه تربیت مدرس تهران، در سال ۱۳۷۴ اخذ

کرده است. وی در دوره دکتری خود، به عنوان دانشجوی نمونه دانشگاه

تربیت مدرس برگزیده شد. از سال ۱۳۶۵ الی ۱۳۶۸ به عنوان مهندس

الکترونیک در مرکز تحقیقات مخابرات ایران مشغول به کار بوده و در



مدل‌سازی سیستم‌های بیولوژیک، مهندسی عصبی، سیستم‌های کنترل عصبی-عضلانی، نظریه آشوب و فرکتال و کاربرد آن در حل مسائل پزشکی و معماری می‌باشد. یکی از مهمترین زمینه‌های تحقیقاتی وی FNS است. از سال ۱۳۷۱ تاکنون، وی مسئول چندین پروژه تحقیقاتی در زمینه FNS بوده است. از نتایج این پروژه‌ها، گسترش سیستم‌های FNS قابل حمل، برای اولین بار در ایران بوده است. یکی دیگر از زمینه‌های تحقیقاتی دکتر عرفانیان، گسترش سیستم‌های ارتباطی انسان با کامپیوتر بر مبنای سیگنال مغزی (EEG-based BCI) و یا سیگنال‌های چشمی است. دکتر عرفانیان عضو جامعه بین‌المللی FES (IFESS) است.

زمینه طراحی و ساخت آزمایشگاه‌های میان‌مداری فعالیت داشته است. از سال ۱۳۶۸ الی ۱۳۷۰، به عنوان مربی آموزشی در دانشکده کامپیوتر دانشگاه علم و صنعت ایران مشغول به کار بوده است. در سال ۱۳۷۲ به عنوان محقق میهمان در دانشگاه کیس وسترن آمریکا و مرکز پزشکی VA شهر کلیولند آمریکا، تحقیقاتی در زمینه FES داشته است. وی از سال ۱۳۷۴ به بعد، عضو هیأت علمی گروه مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران است و از سال ۱۳۷۹، تاکنون مدیریت گروه مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران را به عهده دارد. ایشان در حال حاضر دانشیار مهندسی پزشکی است. زمینه‌های تحقیقاتی وی شامل شبکه‌های عصبی، پردازش سیگنال‌های بیولوژیک،