

Black box modeling of Paralyzed Arm for FES-based Reaching Movement Control in SCIPatients

R. Shafaei¹, M.R. HashemiGolpayegani^{2*}

¹M.Sc, Bioelectric Group, Faculty of Biomedical Engineering, Amirkabir University of Technology

r_shafaei@aut.ac.ir

²Professor, Bioelectric Group, Faculty of Biomedical Engineering, Amirkabir University of Technology,

hashemi_g@morva.net

Abstract

One of main the issues in achieving to a successful FES control is using an as much as possible accurate model of the under electrical stimulation system so that it can adequately indicate the system behavior. Classical computational models that are commonly used for this purpose have a reductionism nature; so they cannot consider the interaction existed in biological systems. Considering these restrictions, recently behavioral black box models are mostly used. These models focus on input/output dynamic, which is certainly the necessary modeling information for control design; thus the system is dealt with as a whole, which has hidden the interactions between components inside. Such a model has not been presented for elbow angle movement so far. Therefore in this study, we have been to present and verify a black box model of elbow joint movement in the transverse plane, for reaching movement control in people with C5/C6 SCI using dynamic neural networks, including time-delayed feedforward and recurrent networks. Extreme flexibility of time-delayed feedforward architectures was obtained in a 2 layer structure including 5 hidden neurons and using 1.25s of history of input with performance indexes of 89.89% & 4.85% for cross correlation coefficient and normalized mean square error respectively. The best recurrent network with NARX architecture and equal history of input & output was also occurred in a 2 layer structure having 12 neurons in the hidden layer and using 0.1s of history, with performance indexes of 89.89% & 4.85% for cross correlation coefficient and normalized mean square error respectively. Comparison between best results of training using feedforward and recurrent networks, clearly illustrates both qualitative and quantitative excellency of the latter one in identification of the under-study system.

Keywords: Functional Electrical Stimulation, paralyzed arm musculoskeletal system, reaching movement, black box models, neural networks.

* Corresponding author

Address: Mohammad Reza Hashemi Golpayegani, Bioelectric Group, Faculty of Biomedical Engineering, Tehran, Iran

Tel: +98 21 64542370

Fax: +98 21 66468186

E-mail: hashemi_g@morva.net

مدل جعبه سیاه دست فلج برای کاربرد کنترل حرکت ریش به کمک FES در افراد با آسیب نخاعی

^۱ راحله شفاei، ^۲ سید محمد رضا هاشمی گلپایگانی

^۱ کارشناس ارشد گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر

r_shafaei@aut.ac.ir

^۲ استاد تمام گروه بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر

hashemi_g@morva.net

چکیده

یکی از مسائل کلیدی در نایل شدن به کنترل موفق FES، استفاده از یک مدل مناسب و صحیح از سیستم تحت تحریک الکتریکی است که به میزان کافی بیان‌کننده رفتار آن سیستم باشد. مدل‌های محاسباتی کلاسیک که به‌طور متعارف برای این منظور استفاده می‌شوند، ماهیتی جزءنگر دارند؛ بنابراین نمی‌توانند اندرکنش موجود در سیستم بیولوژیک را لحاظ کنند. با توجه به این محدودیت‌ها، اخیراً مدل‌های رفتاری که جعبه سیاه هستند اغلب استفاده می‌شوند. این مدل‌ها روی دینامیک ورودی/خروجی، که همانا اطلاعات مورد نیاز مدل‌سازی برای طراحی کنترل است تمرکز دارند؛ بدین ترتیب به سیستم به عنوان یک کل، که تعاملات بین اجزا را در خود نهفته دارد، پرداخته می‌شود. تاکنون چنین مدلی برای حرکت مفصل آرنج ارائه نشده است. از این رو در این پژوهش، با استفاده از شبکه‌های عصبی دینامیک، شامل شبکه‌های جلوسو با تاخیر زمانی و بازگشتی، به ارائه و اعتبارسنجی یک مدل جعبه سیاه از حرکت مفصل آرنج در صفحه افق، برای کاربردهای کنترل حرکت رساندن دست، در افرادی با ضایعه نخاعی C5/C6 پرداخته شده است. نهایت انعطاف‌پذیری معماری جلوسو با تاخیر زمانی، در یک ساختار دو لایه با ۵ نورون پنهان و استفاده از ۱/۲۵ ثانیه از سوابق ورودی، با شاخص عملکرد ضریب همبستگی متقابل ۸۹/۸۶٪ و نرمالیزه شده‌ی میانگین مربعات خطای ۴/۸۵٪ رخ داد و به عنوان مدل برگزیده‌ی این معماری معرفی گردید. بهترین شبکه‌ی بازگشتی با معماری NARX و تعداد سوابق ورودی و خروجی برابر نیز، در ساختاری دو لایه با ۱۲ نورون در لایه‌ی پنهان و استفاده از ۰/۱ ثانیه از سوابق، با شاخص عملکرد همبستگی متقابل ۹۲/۵۰٪ و نرمالیزه شده‌ی میانگین مربعات خطای ۴/۰۶٪ رخ داد و به عنوان مدل برگزیده‌ی این معماری معرفی گردید. مقایسه‌ی بهترین نتایج آموزش با استفاده از شبکه جلوسو از هر دو جنبه کمی و کیفی به شکل آشکاری بیان‌کننده برتری شبکه‌های بازگشتی در شناسایی سیستم مورد مطالعه است.

کلیدواژگان: تحریک الکتریکی عملکردی، سیستم عضلانی-اسکلتی دست فلج، حرکت ریش، مدل‌های جعبه سیاه، شبکه عصبی.

عهده‌دار مکاتبات

نشانی: تهران، خیابان حافظ، دانشگاه صنعتی امیرکبیر، دانشکده مهندسی پزشکی، گروه بیوالکتریک

تلفن: ۰۲۱۶۵۴۲۳۷۰، دورنگار: ۰۲۱۶۶۴۶۸۱۸۶، پیام نگار: hashemi_g@morva.net

۱- مقدمه

تحریک الکتریکی عملکردی^۱ (FES) موثرترین روش برای جبران نسبی عوارض نقص حرکتی ناشی از ضایعه در سیستم اعصاب مرکزی است. افرادی که دچار ضایعه‌ی نخاعی در سطوح مهره‌های پنجم و ششم گردنی (C5/C6) شده‌اند در حرکت "رساندن"^۲ با مشکل مواجه هستند. کنترل مفصل شانه در این افراد به صورت تقریباً ارادی انجام می‌شود، اما در حرکت مفصل آرنج با مشکل مواجه هستند. اگر با استفاده از تحریک الکتریکی عملکردی، امکان حرکت آرنج فراهم گردد توانایی‌ها و استقلال فرد از پرستار برای انجام حرکت‌های ضروری روزمره به میزان قابل توجهی افزایش خواهد یافت. ضایعه در سیستم اعصاب مرکزی اغلب با از دست رفتن توانایی‌های حرکتی همراه است. تحریک الکتریکی عملکردی راهکاری است که می‌تواند امکان بازگرداندن بخشی از توانایی‌های حرکتی از دست رفته را فراهم نماید.

تا به امروز روش‌های مختلفی برای کنترل حرکات اندام فوقانی و تحتانی با FES مورد مطالعه و آزمایش قرار گرفته‌اند. این روش‌ها عموماً بر پایه‌ی مدل هستند و مستقیماً از روابط تحلیلی ریاضی که در مدل‌سازی استفاده می‌شوند، برای طراحی کنترلگر استفاده می‌کنند. به سبب پیچیدگی سیستم‌های عضلانی-اسکلتی هیچ‌یک از این مدل‌ها با واقعیت موجود زنده مطابقت ندارند و همواره با خطاهایی نسبت به واقعیت مواجه هستند. بنابراین کنترلگرهایی که بر پایه‌ی آنها عمل می‌کنند نیز عملکرد مناسبی نخواهند داشت [۱].

توسعه‌ی یک مدل از سیستم عضلانی-اسکلتی انسانی تحت مطالعه که بتواند ارتباط دینامیک بین پالس تحریک و حرکت مفصل را بیان کند، طراحی و آزمون کنترلگرهای کارآمد و به‌ویژه استراتژی‌های سیستم‌های کنترل حلقه بسته برای FES را امکان‌پذیر می‌سازد. بنابراین این امکان فراهم می‌گردد که از طراحی و تنظیم کردن کنترلگر به روش سعی و خطا در زمان آزمایش، که برای بیمار بسیار خسته‌کننده و خطرناک است، اجتناب گردد یا میزان آن به حداقل برسد [۲].

مدل‌های موجود از پاسخ عضله اسکلتی به تحریک الکتریکی به دو دسته‌ی عمده تقسیم می‌شوند. اولین دسته، مدل‌های ریاضی فیزیولوژیکی یا مدل‌های بیومکانیکی کلاسیک هستند که تلاش دارند ساختار فیزیولوژیک عضله را، بر پایه‌ی توصیفی مستقیم از ویژگی‌های بیومکانیکی، زیستی و فیزیولوژیکی سیستم مورد نظر، جزء به جزء (میکروسکوپی یا ماکروسکوپی) مدل کنند. در این رویکرد، عضله به بخش‌های مستقل (فعال‌سازی ماهیچه، مشخصه‌ی طول-نیرو و سرعت-نیرو) از یکدیگر تجزیه شده و فرض می‌شود که این بخش‌ها ارتباطی به یکدیگر ندارند و مشخصه‌ی طول-نیرو و سرعت-نیرو برای تمام سطوح فعالیت عضله یکسان است؛ در صورتی که این تجزیه و عدم وابستگی بخش‌ها به یکدیگر واقعیت فیزیکی ندارد و نیز شکل روابط برای واحدهای حرکتی مختلف متفاوت است [۳]. مدل‌های فیزیولوژیکی به نظر دقیق، پیچیده، و مختص یک فرد بخصوص هستند. همچنین، مقدار برخی از پارامترهای آناتومیک و فیزیولوژیکی این مدل‌ها سخت بدست می‌آیند [۴]؛ با اتخاذ این رویکرد، مدل‌های بدست آمده با تعداد زیادی پارامتر نظیر جرم، لختی و ضریب میرایی توصیف و متمایز می‌شوند. مسئله‌ی اصلی این است که چه مقداری برای این پارامترها، که به مقدار زیادی غیرقطعی هستند (اگر کاملاً ناشناخته نباشند)، باید تعیین شود؛ ضمن اینکه جلسات آزمایش اختصاصی برای تخمین آنها لازم است برگزار گردد. مدل راینر^۳ پیشرفته‌ترین مدل ارائه شده در این حوزه تا به امروز است [۵]. به منظور رفع این محدودیت‌ها، اخیراً رویکردهای دسته‌ی دوم که مدل‌های تجربی و جعبه سیاه هستند اغلب استفاده می‌شوند. این مدل‌ها تنها از داده‌های ورودی/خروجی بدست می‌آیند و با استفاده از روش‌های محاسبات نرم سعی در ارائه‌ی مدلی رفتاری از سیستم دارند [۶]. به عبارت دیگر این مدل‌ها روی دینامیک ورودی/خروجی، که همانا اطلاعات مورد نیاز مدل‌سازی برای طراحی کنترل است تمرکز دارند [۷]؛

بدین ترتیب به سیستم به عنوان یک کل، که تعاملات بین اجزا را در خود نهفته دارد، پرداخته می‌شود. در این رویکرد ورودی، مشخصات پالس تحریک و خروجی، زاویه، گشتاور

¹ Functional Electrical Stimulation² Reaching Movement³ Riener

زاویه‌ی میج در فضای شبیه‌سازی و فضای آزمایشگاهی پرداخته‌اند. در این پژوهش، مدل سیستم میج با استفاده از یک شبکه عصبی که قابلیت تقلید از پاسخ میج سوژه به تحریک الکتریکی را دارد پیاده شده است. عرفانیان [۳] از شبکه‌های عصبی دینامیک به عنوان ابزاری جهت مدل‌سازی عضله در شرایط غیرایزومتریک استفاده کرده است.

اساساً پژوهش‌های انجام شده در زمینه‌ی مدل‌سازی جعبه سیاه در حوزه‌ی FES، نسبت به رویکردهای دسته‌ی اول، به مراتب کمتر صورت گرفته است؛ در مقایسه‌ی پژوهش‌های انجام شده در زمینه‌ی مدل‌سازی جعبه سیاه نیز، ارائه‌ی مدل رفتاری از اندام تحتانی بیشتر از اندام فوقانی، مورد مطالعه قرار گرفته‌اند. ضمن آنکه به جز یک مورد [۱۳]، تمام مدل‌ها تک تحریکه (تحریک یک عضله) بوده‌اند. تاکنون چنین مدلی برای حرکت اندام فوقانی و به‌ویژه مفصل آرنج که ارائه نشده است. از این رو ارائه‌ی چنین مدلی می‌تواند در کاربردهای کنترل حرکت رساندن دست به کمک FES تاثیر بسزایی داشته باشد. در این پژوهش مطلوب، ارائه‌ی مدل جعبه سیاه از حرکت مفصل آرنج (شرایط غیرایزومتریک عضله) در صفحه‌ی عرضی، با استفاده از شبکه‌های عصبی است. به‌منظور حرکت مفصل آرنج در صفحه، عضلات مخالف بازو (دوسربازویی و سه‌سربازویی) به‌وسیله‌ی پالس‌های جریان، تحت تحریک الکتریکی قرار می‌گیرند، در حالیکه مفصل شانه بی‌حرکت نگه داشته می‌شود. سیستم تحریک الکتریکی موجب انقباض ماهیچه و در نتیجه تولید نیرو در آن می‌شود. این نیرو به اجزای اسکلت اعمال شده و موجب ایجاد گشتاور در مفصل و نهایتاً حرکت اندام می‌گردد.

۲- روش کار

در این مطالعه پس از فراهم کردن یک مجموعه‌ی آزمایشگاهی مناسب و کارآمد، برخی آزمایش‌ها تحریک اولیه به‌منظور بررسی ویژگی‌های کیفی و شهودی سیستم انجام گرفته است. برپایه‌ی این مشاهدات در ادامه، با اعمال سیگنال‌های تحریکی که غنای کافی برای تحریک سیستم و آشکار ساختن مشخصه‌های آن را داشته باشند خروجی مفصل

مفصل یا نیروی عضله می‌تواند باشد. اگرچه این مدل‌ها سعی بر ارائه‌ی ارتباط دینامیک ورودی/خروجی عضله‌ی واقعی دارند، ساختار آنها لزوماً فیزیولوژی عضله را بازتاب نمی‌کند و پارامترهای آن معنی فیزیکی ندارند. انتخاب مدل‌های رفتاری جعبه سیاه عمدتاً به سبب این واقعیت صورت می‌گیرد که در اهداف طراحی کنترل، توجه روی دقت مدل متمرکز است تا روی شفافیت آن. مهمترین مشکل این رویکرد مدل‌سازی، مشکل بودن ثبت داده‌های ورودی خروجی به منظور آموزش است [۴، ۸].

مدل‌سازی با رویکرد هوش محاسباتی، در جایی که شگردهای مرسوم قبلی در نایل شدن به نتایج رضایت‌بخش ناکام مانده‌اند، در حال تبدیل شدن به چاره‌ای مناسب رشد و ترقی است. دلیل این امر آن است که با این ابزار، به موضوعاتی نظیر عدم قطعیت یا تغییرات ناشناخته در پارامترها و ساختار سیستم به شکل کارآمدتری پرداخته می‌شود [۹-۱۱]. ویژگی‌های شبکه‌های عصبی مصنوعی نظیر توانمندی در مدل‌سازی تعاملات غیرخطی پیچیده بدون نیاز به داشتن روابط تحلیلی، یادگیری از نمونه‌ها با استفاده از داده‌های ورودی/خروجی و قابلیت تعمیم به ورودی‌هایی که در مجموعه‌ی آموزش نبوده‌اند، آن را برای کاربردهای مدل‌سازی و کنترل سیستم‌های دینامیکی غیرخطی مناسب گردانیده است. مدل‌های دسته‌ی اول قطعی‌گرا هستند در حالیکه سیستم عضلانی-اسکلتی در فضای عدم قطعیت رفتار می‌کند. اگرچه الگوریتم‌های هوش محاسباتی مفهوم دینامیک پویا را در خود ندارند اما از آنجا که این قابلیت را دارند که از چندین راه به یک هدف منتهی شوند، می‌توانند معادلی برای رفتار آشوب‌گونه‌ی انسان باشند. [۳].

در این حوزه چنگ^۴ و همکاران [۱۲]، پرویدی^۵ [۸] و دناایی^۶ و همکاران [۹] در بخشی از کار خود به تحریک گروه عضلات چهارسران پرداخته و از روی حرکت نتیجه‌ی مفصل زانو به ارائه‌ی یک مدل جعبه سیاه از دینامیک غیرخطی زانو در پاسخ به FES با استفاده از شبکه‌های عصبی پرداخته‌اند. کورسواوا^۷ و همکاران [۱۳] به مطالعه‌ی طرح کنترل یادگیری پس‌خور برای کنترلگر FES و به‌طور خاص، کنترل

^۴ Chang^۵ Previdi^۶ Denaii^۷ Kurosawa


آرنج ثبت شده است.

۲-۱- تجهیزات آزمایشگاهی

در راستای انجام آزمایش‌های اعمال تحریک الکتریکی و ثبت نتایج مورد استفاده در مدل‌سازی، نیاز به ابزارهایی است که تسهیلات لازم را فراهم آورند. بلوک دیاگرام تجهیزات آزمایشگاهی فراهم شده برای این مطالعه در شکل ۱ نشان داده شده است.

برای تحریک الکتریکی عملکردی، دستگاهی مطابق ملزومات این مجموعه‌ی آزمایشگاهی ساخته شده است که ARFESS04 نامیده می‌شود. این دستگاه قابلیت ایجاد سیگنال تحریک جریانی تک‌فاز و دوفاز (به‌صورت انفجاری یا پالسی)، با دامنه‌ی بین ۰ تا ۵۰ میلی‌آمپر و با رزولوشن ۰/۲ میلی‌آمپر، پهنای پالس با پارامترهای زمانی قابل تنظیم و رزولوشن ۱ میکرو ثانیه در یک تا هشت کانال تحریک مجزا را دارد. از ویژگی‌های این دستگاه، علاوه بر قابل برنامه‌ریزی و سفارشی‌سازی از طریق درگاه USB کامپیوتر که آن را برای کاربردهای پژوهشی کارآمد می‌سازد می‌توان به سبک، کوچک و قابل حمل بودن آن اشاره نمود، ضمن اینکه به‌سبب استفاده از باتری در بخش تغذیه، از برق شهر ایزوله بوده و ایمنی بیمار را تضمین می‌کند.

برای ثبت زاویه مفصل آرنج از زاویه‌سنج الکتریکی تجاری مدل SG110 ساخت شرکت بایومتریکس استفاده شده است. این حسگر سبک (۱۷ گرم) و انعطاف‌پذیر، با استفاده از چسب‌های دوطرفه، از یک طرف مفصل به طرف دیگر آن چسبانده می‌شود به‌طوری‌که ممانعتی در حرکت آن ایجاد نمی‌کند؛ با تغییر زاویه بین دو بلوک انتهایی این حسگر، ولتاژی متناسب با زاویه فراهم می‌گردد [۱۴]. دامنه‌ی ولتاژ خروجی حسگر کوچک است و برای ثبت و نمایش نیاز به تقویت دارد. به‌منظور آماده‌سازی این سیگنال، دستگاه آماده-سازی سیگنالی استفاده شده است که GSC01 نامیده می‌شود. این دستگاه یک مدار تقویت‌کننده‌ی ابزاری است که امکان تنظیم دقیق بهره و آفست برای آن فراهم شده است.



شکل ۱- بلوک دیاگرام تجهیزات آزمایشگاهی فراهم شده برای این مطالعه.

ARFESS04 دارای ۸ ورودی آنالوگ در محدوده‌ی صفر تا ۵ ولت و رزولوشن ۵ میلی‌ولت است؛ خروجی‌های آنالوگ حسگر زاویه، پس از آماده‌سازی، نمونه‌برداری و دیجیتال می‌گردد تا با ارسال به کامپیوتر، به‌صورت بی‌درنگ نمایش یافته و ثبت گردد.

اگرچه هدف از انجام تحقیقات FES، کمک به بازتوانی افراد معلول است اما در این پژوهش به‌دلیل ممکن نشدن استفاده از سوژه‌ی بیمار واجد شرایط، به ناچار از یک فرد سالم برای انجام آزمایش‌ها استفاده شده است. در کل، اندام شُل^۱ شده (در حال استراحت) در فرد سالم و یک عضو فلج، به تحریک الکتریکی پاسخ مشابه می‌دهند. به همین دلیل از سوژه خواسته شده عضلات دست خود را شُل کند و تا حد امکان توجه خود را از حرکت ارادی دست منحرف کند تا حرکت اندام در نتیجه‌ی تحریک الکتریکی باشد. با این حال تفاوت‌های عمده‌ای بین اندام طبیعی و فلج وجود دارد (مثلاً وجود اسپاسم در اندام فلج)؛ از این رو نتایج ارائه شده در این مطالعه منسوب به اندام فاقد اسپاسم^۲ است [۱۲، ۱۳].

برای انتخاب سوژه، آزمایش‌ها مقدماتی و ساده‌ای با هدف بررسی آمادگی فیبرهای عضلانی در پاسخ‌دهی به تحریک، روی افراد مختلف، از جمله قشر ورزشکار، عمومی



شکل ۲- وضعیت قرارگیری فرد و دست وی حین انجام آزمایش‌ها. نحوه‌ی نصب الکترودهای بازو و زاویه‌سنج روی دست. دستگاه تحریک الکتریکی در سمت چپ شکل بالا دیده می‌شود.

۲-۲- آزمایش‌های تحریک الکتریکی

به‌منظور ارائه‌ی یک مدل جعبه سیاه از هر سیستم، نیاز به مجموعه دادگانی است که غنای کافی برای آشکارسازی ویژگی‌های آن سیستم را داشته باشد. در پژوهش حاضر هدف، ارائه‌ی چنین مدلی از حرکت دست فلج و به‌صورت دقیق‌تر، موقعیت مفصل آرنج حین حرکت در صفحه‌ی افق است. در یک فرد سالم، حرکت مفصل آرنج وابسته به تعامل دو عضله‌ی متقابل بازو، یعنی عضلات دوسربازویی و سه‌سربازویی است. انقباض عضله‌ی سه‌سربازویی موجب خم شدن آرنج و انقباض عضله‌ی سه‌سربازویی موجب باز شدن آن می‌شود. اما افراد معلول مخاطب این مطالعه، با ضایعه‌ی نخاعی در مهره‌های گردنی C۵/C۶، در حرکت ارادی آرنج دچار مشکل هستند. در مطالعه‌ی حاضر، تحریک هر دو عضله مد نظر قرار گرفته است؛ چنانچه فرد معلول بنا به مشکل حرکتی خود تنها نیاز به تحریک یکی از عضلات بازویی خود داشته باشد، با صفر قرار دادن تحریک عضله‌ی دیگر در ورودی مدل می‌توان به مقصود نایل شد.

سالم و بیمار انجام گرفت و در نهایت تمامی آزمایش‌ها بر روی یکی از دانشجویان پسر، بازیکن حرفه‌ای پینگ‌پنگ با ۴ سال سابقه، ۲۱ ساله، با مشخصات ظاهری ۱۷۹ سانتی‌متر قد و وزنی معادل ۶۳ کیلوگرم انجام گرفت.

از سوژه خواسته می‌شود روی صندلی راست بنشیند. به‌کمک فریم مکانوترایی و متعلقات آن، دست در صفحه‌ی افق به حالت تعلیق در می‌آید، به نحوی که مفصل شانه در ۴۵ درجه ثابت نگه داشته می‌شود، زاویه‌ی آرنج در حالت استراحت ۶۰ درجه است اما می‌تواند آزادانه حرکت کند. زاویه‌ی صفر آرنج در وضعیتی که ساعد و بازو هم‌راستا هستند، یعنی اکستنشن^{۱۰} کامل آرنج، قرارداد شده است و هر چه به سمت فلکشن^{۱۱} پیش می‌رویم زاویه رو به افزایش دارد. بدین ترتیب علاوه بر ملزم کردن دست به حرکت در صفحه‌ی افق، وزن دست خنثی شده و از بروز اصطکاک سطحی حین حرکت جلوگیری به عمل می‌آید. ضمن اینکه دست می‌تواند هر دو عمل فلکشن و اکستنشن را با شروع از حالت استراحت انجام دهد.


هر یک از عضلات بازو توسط یک جفت الکترود تحریک سیلیکون‌رابر (۶۰×۴۰mm^۲) با بالشتک‌های خیس شده، تحریک می‌شوند. برای هر عضله، الکترود فعال روی نقطه‌ی حرکتی عضله و الکترود بی‌اثر در نقطه‌ای دورتر^{۱۲} روی تاندون قرار داده می‌شود. الکترودها توسط کش‌هایی که دور بازو انداخته می‌شوند ثابت می‌گردند. سپس لازم است زاویه‌سنج به شکل صحیحی روی دست نصب شود تا زاویه‌ی مفصل آرنج را به درستی اندازه‌گیری کند. در شکل ۳ وضعیت قرارگیری فرد و دست وی حین انجام آزمایش‌ها، همچنین نحوه‌ی نصب ادوات آزمایش روی بازو و مفصل از نمای جلو و پشت دست به تصویر کشیده شده است.

^{۱۰} Extension

^{۱۱} Flexion

^{۱۲} Distal

فاز را خواهیم داشت. در شکل ۳ نمونه‌ای از سیگنال تصادفی زمانی مورد استفاده در آموزش شبکه عصبی برای دو عضله بازو مشخص شده است.



شکل ۳- نمونه‌ای از سیگنال تصادفی زمانی مورد استفاده در آموزش و آزمون شبکه عصبی. مقادیر دامنه و مدت زمان هر دامنه با الگوهای تصادفی ساخته شده‌اند.

سیگنال تصادفی که با استفاده از لاجستیک $3/7$ ، اعشار π ، اعشار e یا عدد طلایی درست شده باشد، یک تصادفی قانونمند و تکاملی است؛ تصادفی معمولی غایتش یک چیز منظم نیست ولی غایت نمونه‌هایی که گفته شد یک بستر جذب مشخص است. با این توضیح، الگوهای تحریک تصادفی مورد استفاده در این پژوهش بر دو دسته قرار گرفته‌اند: سیگنال‌های "تصادفی قانونمند" که با استفاده از ارقام اعشار π و e ساخته شده است و سیگنال‌های "تصادفی معمولی" که توسط نرم‌افزار و با توزیع آماری یکنواخت تولید شده‌اند. از آنجا که برای دامنه‌ی جریان به اعداد بین ۰ تا ۳۳ برحسب میلی‌آمپر نیاز بود، رقم‌های اعشار π را دو رقم دو رقم جدا کرده (۰۰ الی ۹۹ را خواهیم داشت) و با تقسیم آنها بر ۳، گستره‌ی مطلوب به‌دست آمد. بدین ترتیب از اطلاعات کیفی اعشار π استفاده شده است. برای مدت زمان نیز با استفاده از جداسازی دو رقمی اعشار e و ضرب آن در نرخ

پیش از انجام آزمایش‌های اصلی و ثبت داده‌های مورد استفاده در مدل‌سازی، الگوهای آزمایشی متنوعی شامل الگوهای پله یا پالس، دندان‌اره‌ای، مثلثی و دوزنقه‌ای به عضلات سوژه اعمال شد و زاویه‌ی مفصل آرنج وی به‌عنوان پاسخ ثبت گردید. فرکانس و پهنای پالس سیگنال پایه‌ی تحریک به ترتیب در مقادیر ۲۰ هرتز و ۵۰۰ میکروثانیه ثابت بوده‌اند درحالی‌که دامنه‌ی جریان تحریک با مدولاسیون همراه بوده است. نرخ نمونه‌برداری از زاویه نیز همواره برابر فرکانس تحریک بوده است. هدف از طرح و انجام این آزمایش‌ها، بررسی، مشاهده و تخمین برخی ویژگی‌های سیستم عضلانی- اسکلتی دست هنگام خم و باز شدن مفصل آرنج، نظیر تأثیر بروز تعاملات دو عضله‌ی درگیر در پاسخ نهایی و حدود گستره‌ی تغییرات دامنه‌ی جریان لازم برای وقوع فلکشن و اکستنشن کامل بوده است. تحریک بیش از حد عضلات تنها به تولید نیروی مضاعف در عضله می‌انجامد که به‌دلیل محدودیت‌های حرکتی مفصل موجب ایجاد حرکات پر تنش و خستگی عضله می‌شود.

داده‌های مورد استفاده برای آموزش و آزمون شبکه عصبی، الگوهای تحریک تصادفی بوده است؛ از مزایای این الگو این است که سوژه‌ی آزمایش نمی‌تواند الگو را تجسم کند و یاد بگیرد. همچنین سیگنال تصادفی از غنای بالایی برخوردار است زیرا می‌تواند ویژگی‌های سیستم را به‌خوبی آشکار کند (حالت‌های پنهان آن را تحریک نماید) و تحریک را به‌سمت سینرژتیک بودن برد یا به‌عبارتی می‌توان توسط آن سینرژتی را مدل کرد. سینرژتی یعنی مقدار تحریک مناسب در زمان‌های مناسب برای دو تا ماهیچه به‌صورتیکه اینها هم‌افزایی داشته باشند. آنچه در سینرژتی اثر دارد دوره‌ی کمون و مدت زمان است. با این نوع تصادفی کردن، مدت زمان تصادفی می‌شود و دوره‌ی کمون نیز گرچه دست ما نیست، اما به‌سمت سینرژتیک بودن پیش می‌رود. در یک حرکت واقعی، دامنه و فاز هر دو به‌صورت تصادفی، اما قانونمند تغییر می‌کنند. کمیت باید تصادفی باشد تا عضلات مستقل از هم عمل کنند و فاز باید تغییر کند تا اینها سینرژتیک عمل نمایند. در نتیجه‌ی این الگوی تحریک، گستره‌ی بزرگی از تغییرات دامنه و اختلاف

شبکه‌های TDNN در دو دسته‌ی کلی متمرکز و توزیع‌شده طبقه‌بندی می‌شوند. ساده‌ترین و سرراست‌ترین شبکه‌ی دینامیک که متشکل از یک شبکه‌ی جلوسو با یک خط تأخیر در ورودی است، شبکه عصبی با تأخیر زمانی متمرکز^{۱۳} (FTDNN) نامیده می‌شود. یکی از ویژگی‌های جالب توجه FTDNN این است که برای محاسبه‌ی گرادینان شبکه به پس‌انتشار دینامیک نیاز ندارد زیرا خط تأخیر تنها در ورودی شبکه ظاهر می‌شود و حاوی هیچ حلقه‌ی پسخوری نیست. به‌همین دلیل این شبکه از سایر شبکه‌های دینامیک سریع‌تر آموزش می‌بیند [۱۷].

FTDNN، حافظه‌ی خط تأخیر را تنها در ورودی لایه‌ی اول شبکه‌ی جلوسوی استاتیک دارا است. اما این قابلیت وجود دارد که توسط شبکه عصبی با تأخیر زمانی توزیع‌شده^{۱۴} (DTDNN)، خطوط تأخیر در تمام شبکه و بین لایه‌های میانی توزیع شود. بدین ترتیب ورودی به هر لایه، سوابقی از خروجی لایه‌ی قبل می‌باشد. این ساختار اولین بار در [۱۸] برای بازشناسی واج در گفتار معرفی شد. آموزش شبکه‌ی DTDNN نسبت به شبکه‌ی FTDNN کندتر انجام می‌گیرد زیرا DTDNN از پس‌انتشار دینامیک استفاده می‌کند [۱۷].

یکی از روش‌های مناسب برای وارد کردن پویایی در مدل‌های ارائه شده، استفاده از خروجی‌های لحظات گذشته در ورودی مدل است. معادله‌ای به‌صورت

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

که در آن $y(t)$ ، خروجی و $u(t)$ ، ورودی در لحظه‌ی t است، ساختار NARX نامیده می‌شود. این ساختار توسط یک شبکه عصبی جلوسو که دارای اتصالات پسخور از خروجی شبکه است، با هدف تقریب تابع f ، قابل پیاده‌سازی می‌باشد. کاربردهای بسیاری برای شبکه‌های NARX وجود دارد. از این مدل به‌طور متداول برای مدل‌سازی سری‌های زمانی استفاده می‌شود، به عنوان پیش‌بینی کننده برای پیش‌بینی مقادیر بعدی سیگنال ورودی استفاده شود و همچنین برای فیلتر کردن غیرخطی که در آن خروجی هدف نسخه‌ی خالی از

نمونه‌برداری، گستره‌ی ۰ تا ۲ ثانیه پوشش داده شد. این روند برای هر دو عضله به‌طور مشابه انجام گرفته است.

۲-۳- معماری شبکه‌های عصبی مورد استفاده در مدل‌سازی

قابلیت‌های فراگیر تقریب‌زنی شبکه‌های پرسپترون^{۱۳} چند لایه، از آن انتخاب خوبی برای مدل‌سازی سیستم‌های غیرخطی و پیاده‌سازی کنترل‌گرهای غیرخطی همه منظوره ساخته است [۹، ۱۲].

شبکه‌های عصبی در دو دسته‌ی کلی استاتیک و دینامیک طبقه‌بندی می‌شوند. شبکه‌های استاتیک جلوسو هیچ عنصر پسخوری ندارند و دارای تأخیر نیز نیستند؛ خروجی مستقیماً از ورودی و از طریق وزن‌های جلوسو محاسبه می‌شوند. در شبکه‌های دینامیک، خروجی نه تنها به ورودی کنونی به شبکه بلکه به ورودی‌ها و خروجی‌های حال و گذشته یا حالت‌های شبکه وابسته است [۱۵]. ساختار استاندارد شبکه‌ی جلوسو تنها می‌تواند تبدیل‌های بی‌حافظه را بازتولید کند و ذاتاً برای مدل‌سازی سیستم‌های دینامیک رضایت‌بخش نیست. در حالیکه شبکه‌های دینامیک دارای حافظه هستند و می‌توانند برای یادگیری الگوهای متغیر با زمان و ترتیبی آموزش داده شوند [۱۶]. به‌جهت آنکه سیستم عضلانی- اسکلتی ذاتاً دینامیک و دارای حافظه است ساختار شبکه عصبی مورد استفاده در این مطالعه باید مدل‌های دینامیک را عرضه کند [۱۳].

شبکه‌های دینامیک خود به دو دسته تقسیم می‌شوند؛ آنهایی که تنها اتصالات جلوسو دارند و دینامیک توسط عناصر تأخیر در آنها وارد می‌شود و آنهایی که اتصالات پسخور یا بازگشتی دارند [۱۷]. در این مطالعه ابتدا شبکه‌های دینامیک از نوع اول پرداخته می‌شوند و در ادامه نوع خاصی از شبکه‌های دینامیک بازگشتی با ساختار NARX که در آن تأخیر ورودی و خروجی مساوی لحاظ شده است، به‌منظور شناسایی سیستم عضلانی- اسکلتی دست فلج در صفحه‌ی افق، آموزش داده شده‌اند.

^{۱۳} Perceptron^{۱۴} Focused Time Delay Neural Network^{۱۵} Distributed Time Delay Neural Network

$$CCC = \frac{\sum_{i=1}^N y(i)\hat{y}(i)}{\sqrt{\sum_{i=1}^N y^2(i)} \sqrt{\sum_{i=1}^N \hat{y}^2(i)}} \quad (۱)$$

$$NMSE = \frac{\frac{1}{N} \sum_{i=1}^N (y(i) - \hat{y}(i))^2}{\frac{1}{N} \sum_{i=1}^N y^2(i)} \quad (۲)$$

در این روابط N تعداد نمونه‌ها، $\mathcal{Y}$ زاویه واقعی و $\hat{\mathcal{Y}}$ زاویه تخمین زده شده توسط شبکه است.

به منظور حذف اثرات مقداردهی اولیه تصادفی، برای هر ساختار، روند تخمین ۱۵ بار تکرار شده، سپس میانگین مقدار شاخص عملکرد برای هر ساختار، پس از حذف موارد نامناسب و ناهمگون، محاسبه گشته و به عنوان معیار مقایسه بین ساختارهای مختلف استفاده شده است؛ مدلی که بهترین شاخص عملکرد را دارد به عنوان بهترین گزینه برگزیده می‌شود [۸].

۳- نتایج

شبکه‌های تحت سرپرستی FTDNN، DTDNN و NARX با استفاده از رشته‌های تصادفی ذکر شده در ۲-۲، هر یک به مدت ۶۰ ثانیه به عنوان ورودی، و زاویه‌ی ثبت شده‌ی مفصل آرنج به عنوان خروجی مطلوب آموزش داده شده‌اند. شبکه عصبی آموزش دیده سپس با استفاده از رشته‌های تصادفی دیگری فراخوانی شده و بدین وسیله اعتبارسنجی می‌شود. بدین منظور ۱۶ جفت ورودی/خروجی تصادفی متمایز (۸۰٪ کل دادگان)، از هر دسته ۸ عدد، مجموعه‌ی دادگان آموزش را تشکیل داده‌اند و ۲ سیگنال تصادفی معمولی و ۲ سیگنال تصادفی قانونمند، جمعا ۴ سیگنال تصادفی متمایز (۲۰٪ کل دادگان)، که در مجموعه‌ی دادگان آموزش نبوده‌اند، برای اعتبارسنجی مدل استفاده شده است. معیار CCC برای هر یک از ۴ سیگنال آزمون محاسبه شده و در جدول نتایج در ادامه آمده است. با کنار هم قرار دادن سیگنال‌های آزمون و محاسبه‌ی CCC روی این مجموعه، یک معیار کلی برای ارزیابی یادگیری شبکه به دست آمد که در جدول نتایج با شناسه‌ی CCCT مشخص شده است.

نویز سیگنال ورودی است. استفاده از شبکه‌ی NARX در کاربرد مهم دیگری نیز نشان داده شده است و آن مدل‌سازی سیستم‌های دینامیک غیرخطی است.

۲-۴- شیوه‌ی آموزش و ارزیابی مدل‌های شبکه

عصبی

در این پژوهش مدل‌های تک لایه پنهان مورد مطالعه قرار گرفته‌اند. شبکه دارای ۲ نورون ورودی، Hn نورون در لایه‌ی پنهان و یک نورون خروجی است. ورودی شبکه $(u(t))$ ، شامل دو عنصر دامنه‌ی جریان تحریک اعمال شده به عضلات دوسربازویی $(bi(t))$ و سه‌سربازویی $(tri(t))$ است:

$$u(t) = \begin{bmatrix} bi(t) \\ tri(t) \end{bmatrix}$$

غیرخطی نورون‌های لایه‌ی پنهان استفاده شده است. نورون خروجی، با تابع فعال‌سازی خطی، زاویه را تخمین می‌زند.

آموزش به صورت خارج خط ^{۱۶} انجام گرفته است. در آغاز فرآیند آموزش، برای مقداردهی اولیه‌ی وزن‌های اتصال عصبی، روش نگوین-ویدرو ^{۱۷} [۱۹] استفاده شده است. سپس الگوریتم لوئبرگ-مارکواردت ^{۱۸} (LM)، که یک روش پس‌انتشار خطای پر سرعت از درجه‌ی دو برای کاهش گرادیان است [۲۰]، برای تغییر این وزن‌ها به منظور کمینه کردن خطای بین خروجی مطلوب و خروجی شبکه بکار گرفته شده است. تابع عملکرد برای آموزش شبکه، میانگین مربعات خطای نرمالیزه (MSNE) بوده است. در تمامی آموزش‌های شبکه شرط توقف یادگیری، پیش‌فرض نرم‌افزار MATLAB، یعنی آغاز به فرایادگیری در شبکه بوده است [۱۷] که در هر بار آموزش، این رخداد در شماره‌ی تکرار متفاوتی (حداکثر ۱۰۰) اتفاق می‌افتاد. ضریب یادگیری مطابق پیش فرض نرم‌افزار و برابر ۰/۰۱ بوده است.

شاخص عملکرد برای ارزیابی میزان یادگیری شبکه، ضریب همبستگی متقابل ^{۱۹} (CCC) [۲۱] و نرمالیزه شده‌ی میانگین مربعات خطا ^{۲۰} (NMSE) بوده است:


^{۱۶} offline

^{۱۷} Nguyen-Widrow

^{۱۸} Levenberg-Marquardt

^{۱۹} Cross Correlation Coefficient

^{۲۰} Normalized Mean Square Error




شکل ۴: نتیجه‌ی ارزیابی تمامی مدل‌های FTDNN با تغییر نورون‌های پنهان و سوابق ورودی بر اساس مقایسه‌ی دو معیار CCCt (ترسیمه‌ی بالا) و NMSEt (ترسیمه‌ی پایین). محور افقی تعداد نورون‌های لایه پنهان در هر ساختار را نشان می‌دهد. ساختار به ازای $d=25$ و $Hn=5$ با $CCCt = 89/86\%$ و $NMSEt = 4/85\%$ بهترین مدل از این دست را نتیجه داده است.

روند گفته شده با $d=5$ و تغییر Hn از ۳ تا ۷ و $Hn=10$ آغاز و با افزایش سوابق ورودی (d) با گام ۵ ادامه پیدا کرده است. در $d=5$ و $d=10$ ، بهترین عملکرد به ازای ۵ نورون پنهان حاصل شده و افزایش دینامیک ورودی بهبود قابل توجهی را به دست داده است؛ میزان این بهبود در ترسیمه‌های مربوط به این دو حالت در شکل ۴ مشهود است. با مد نظر قرار دادن دو نتیجه‌ی ذکر شده در بالا، افزایش سوابق ورودی برای $Hn=5$ ، ادامه یافته و تاثیر آن مورد مطالعه قرار گرفت. نتایج بیان می‌دارد که ظرفیت شبکه برای شناسایی سیستم، با وارد کردن اطلاعات سوابق ورودی تا سقف ۲۵ نمونه، یا به عبارتی ۱/۲۵ ثانیه، افزایش می‌یابد و پس از آن با تغییر نامحسوس مواجه هستیم. از آنجا که به ازای $d=30$ دیگر بهبودی در عملکرد مشاهده نمی‌شود؛ به نظر می‌رسد بیشتر کردن بار اطلاعاتی شبکه، تنها آن را پیچیده‌تر می‌کند بدون آنکه سودی در پی داشته باشد. برای یافتن دینامیک ورودی بهین بین $d=25$ و $d=30$ ، نیز روی $Hn=5$ آزموده شد؛ نتیجه موید برتری $d=25$ بوده است. بالاترین ضریب همبستگی به ازای $d=25$ و $Hn=5$ حاصل شده است. بدین ترتیب


۳-۱- مدل‌سازی با استفاده از ساختار FTDNN

با استناد به ساختار FTDNN، تعداد نورون‌های لایه پنهان (Hn) و بردار دینامیک ورودی (d) پارامترهایی از شبکه هستند که لازم است به منظور یافتن مدل بهینه طراحی شوند. ترم‌های تأخیر بر حسب نمونه بیان شده است؛ با توجه به نرخ نمونه‌برداری، فاصله‌ی هر نمونه داده با نمونه‌ی دیگر ۰/۰۵ ثانیه است. برای مثال $d=5$ یعنی سوابق سیگنال تا ۰/۲۵ ثانیه پیش از زمان حال.

با ثابت نگه داشتن d و افزایش گام به گام Hn ، شبکه با ساختار به دست آمده آموزش داده شده و عملکرد آن مورد ارزیابی قرار گرفته است. افزایش Hn تا جایی که پس از آن، بهبود قابل توجهی در عملکرد شبکه مشاهده نشود ادامه پیدا کرده است. در گام بعدی دینامیک ورودی افزایش یافته و در گستره‌ی تعداد نورون‌های مرحله‌ی قبل، عمل آموزش و ارزیابی تکرار شده است. بدین ترتیب، تاثیر افزایش نورون‌های لایه پنهان و سوابق ورودی بر عملکرد مدل، به طور هم‌زمان مورد مطالعه قرار گرفته و از مقایسه‌ی نتایج، بهترین طراحی ممکن در ظرفیت این مجموعه از شبکه‌ها به دست می‌آید. نتایج ترسیمه‌ی تمام این بررسی‌ها، شامل مقایسه‌ی دو معیار CCC و NMSE، در نمودارهای شکل ۴ نمایش داده شده است.



ساختارهای FTDNN به‌دست داده است با ۵ نورون



شکل ۵- خروجی مطلوب و خروجی بهترین شبکه FTDNN به ازای ۴ سیگنال آزمون.

DTDNN

در این بخش با استفاده از بهترین ساختار به‌دست آمده از شبکه‌ی FTDNN و اضافه کردن یک خط تاخیر بین خروجی لایه‌ی پنهان و ورودی لایه‌ی خروجی، مدل‌های DTDNN حاصل شده و تحت آموزش قرار گرفته‌اند. پارامترهای دخیل در ساختار این دسته از شبکه‌ها، تعداد نورون‌های لایه‌ی پنهان (H_n)، بردار تاخیر ورودی (d^1) و بردار تاخیر لایه‌ی میانی

ساده‌ترین شبکه‌ای که در عین حال بهترین مدل را بین در لایه‌ی پنهان و استفاده از اطلاعات ۱/۲۵ ثانیه از سوابق ورودی حاصل شده است. با یادآوری این نکته که مدت زمان اعمال هر مقدار از دامنه‌ی جریان در تحریکات تصادفی اعمال شده، بین ۰/۱ تا ۲ ثانیه است و شبکه تنها از اطلاعات ورودی برای شناسایی استفاده می‌کند، نیاز به در اختیار داشتن اطلاعات ۱/۲۵ ثانیه پیش‌تر از ورودی کنونی منطقی می‌نماید و دور از انتظار نیست.

جدول ۱ میزان یادگیری شبکه‌ی برگزیده را برای هر یک از چهار سیگنال آزمون و شکل ۵ بهترین شناسایی صورت گرفته توسط این مدل را، از بین ۱۵ بار یادگیری برای این سیگنال‌ها نشان می‌دهد.

جدول ۱- میزان یادگیری شبکه FTDNN با ساختار $H_n=5$ و $d=25$ برای هر یک از چهار سیگنال آزمون.

	NMSE(%)	CCC(%)
سیگنال آزمون ۱	/ ± /	/ ± /
سیگنال آزمون ۲	/ ± /	/ ± /
سیگنال آزمون ۳	/ ± /	/ ± /
سیگنال آزمون ۴	/ ± /	/ ± /
سیگنال آزمون کل	/ ± /	/ ± /

خروجی سیستم واقعی با خط چین و رنگ تیره و خروجی تخمین زده شده با خط توپر و رنگ روشن مشخص شده‌اند؛ مقدار ضریب همبستگی و نرمالیزه شده‌ی میانگین مربعات خطای این دو خروجی روی هر ترسیمه نوشته شده است.

چنانچه بخواهیم عملکرد مدل را به‌صورت کیفی قضاوت کنیم، این شکل‌ها نشان می‌دهند که مدل، رفتار دینامیکی سیستم را در حد خوبی توانسته شناسایی کند؛ یعنی انتقال از فلکشن به اکستنشن و برعکس و افزایش و کاهش هر کدام از این وضعیت‌ها را به‌خوبی تشخیص می‌دهد. اما نکته‌ای که وجود دارد اختلاف در مقادیر استاتیک است. برای مثال هنگامی که زاویه تغییرات کوچکی دارد، مدل همان تغییر را در مقیاس بزرگتری بازتولید می‌کند.

با توجه به برابر در نظر گرفتن ترم‌های تاخیر ورودی/خروجی، رابطه‌ی NARX به صورت:

$$y(t) = f(y(t-1), \dots, y(t-d), u(t), u(t-1), \dots, u(t-d))$$

در می‌آید در نتیجه تعداد نوروهای لایه‌ی پنهان (Hn) و بردار دینامیک (d) پارامترهایی از شبکه هستند که لازم است به منظور یافتن مدل بهینه طراحی شوند.


در گام اول، آموزش تنها با استفاده از سوابق ورودی و خروجی به تعداد برابر، بدون احتساب ورودی زمان حال، انجام گرفته است. در این مرحله تعداد نوروهای لایه‌ی پنهان با استاندارد به بهترین ساختار به دست آمده از آموزش شبکه عصبی جلوسو، برابر ۵ انتخاب شده است. به ازای تغییرات d از ۱ تا ۱۰ و نیز d=۱۵ شبکه‌های حاصل آموزش داده شدند. به ازای d=۲، CCCT میانگین، تعداد دفعات یادگیری قابل قبول و بهترین پاسخ، با اقتدار کامل نسبت به سایر حالت‌ها برتری دارد. همچنین سوابق بیشتر از ۵ واحد، بهبودی در نتایج نداده و حتی عملکرد شبکه را با افت مواجه می‌کند. از این رو در ادامه‌ی بررسی‌ها تنها سوابق ۱ تا ۵ واحد مورد مطالعه قرار گرفته است. در گام بعدی، ورودی زمان حال یعنی u(t) به ورودی شبکه افزوده شد و بدین ترتیب خروجی شبکه در هر زمان، علاوه بر سوابق ورودی و خروجی، از ورودی حال نیز تاثیر می‌پذیرد. نتایج به ازای d=۴،۳،۲ برتری غالبی نسبت به دو وضعیت دیگر دارند؛ همچنین در یک مقایسه‌ی اجمالی روی دو ساختار این نتیجه حاصل می‌شود که وارد کردن اطلاعات ورودی زمان حال در عملکرد شبکه بهبود ایجاد کرده است. از این رو از این مرحله به بعد، آموزش شبکه با وارد کردن ورودی زمان حال انجام گرفته است ضمن آنکه به سبب برتری تاخیر ۲ الی ۴ واحد، از بررسی تاخیر ۱ واحد چشم‌پوشی شده و بررسی تاخیر ۵ واحد نیز احتیاطاً ادامه می‌یابد.

با وارد کردن سوابق اطلاعات خروجی به ورودی شبکه عصبی، با افزایش حجم اطلاعات رو به رو هستیم و این احتمال می‌رود که افزایش تعداد نوروهای لایه‌ی پنهان بتواند ظرفیت شبکه را در استفاده از این اطلاعات بالاتر برد. از این


است. Hn و d¹ را به ترتیب برابر با Hn و d بهترین ساختار مدل FTDNN یعنی به ترتیب ۵ و ۲۵ ثابت در نظر می‌گیریم. با انتخاب بردار d² به شکل‌ها و اندازه‌های مختلف، ساختارهای متفاوتی پدید می‌آید؛ در این قسمت از پژوهش دو حالت برای d² در نظر گرفته شده است. حالت اول این است که لایه‌ی خروجی تنها از سوابق خروجی لایه‌ی پنهان استفاده کند؛ حالت دوم این است که لایه‌ی خروجی علاوه بر سوابق، از مقدار کنونی خروجی لایه‌ی پنهان نیز استفاده کند. شبکه در حالت اول به ازای تغییرات d² از ۱ تا ۵ آموزش داده شد. با مقایسه‌ی ضرایب همبستگی مشاهده گردید که شبکه‌ی DTDNN بهبودی در عملکرد شبکه ایجاد نکرده است. با هدف بررسی این نکته که شاید به ازای تاخیرهای بیشتر، بهبود مورد انتظار تحقق پذیرد، ساختارهای به ازای d²=۱۰ و d²=۱۵ آموزش داده شده و ارزیابی شدند؛ تمامی تغییرات بسیار جزئی بوده و حکایت از تکمیل ظرفیت شبکه‌ی جلوسو در امر یادگیری سیستم حاضر می‌کند. شبکه در حالت دوم، به ازای تغییرات d² مشابه حالت اول، آموزش داده شد. در این حالت نیز تغییر قابل توجهی در عملکرد نسبت به شبکه‌ی FTDNN مشاهده نمی‌شود؛ تنها اندکی بهبود به ازای d²=۱۵ جلب توجه می‌کند و گمان آن می‌رود که با افزایش d² مدل رو به بهبود باشد. با هدف بررسی صحت این گمان، شبکه به ازای d²=۲۰ آموزش داده شده و ارزیابی شد. افت مجدد CCCT این گمان را ناکام گذاشت.

NARX

یکی از راه‌های افزایش انعطاف‌پذیری شبکه عصبی، استفاده از ساختارهای بازگشتی است. آموزش دادن این شبکه‌های مشکل‌تر از شبکه‌های جلوسو است؛ زیرا علاوه بر تاثیر مقداردهی تصادفی وزن‌های اولیه بر یادگیری، احتمال به دام افتادن شبکه‌های بازگشتی در کمینه‌ی محلی بیشتر از شبکه‌های جلوسو است، از این رو پیشنهاد می‌شود برای دستیابی به نتیجه‌ی بهینه، شبکه چندین بار آموزش داده شود [۲۲].



شکل ۷- تعداد دفعات یادگیری قابل قبول برای تمامی ساختارهای بازگشتی بررسی شده.



شکل ۸- ضریب همبستگی بهترین پاسخ هر یک از ساختارهای بازگشتی بررسی شده.

جدول ۲- میزان یادگیری شبکه NARX با ساختار $Hn=12$ و $d=2$ برای هر یک از چهار سیگنال آزمون.

NMSE(%)	CCC(%)	
/ ± /	/ ± /	سیگنال آزمون ۱
/ ± /	/ ± /	سیگنال آزمون ۲
/ ± /	/ ± /	سیگنال آزمون ۳
/ ± /	/ ± /	سیگنال آزمون ۴
/ ± /	/ ± /	سیگنال آزمون کل


مقایسه کمی و کیفی نتایج شبکه‌های دینامیک بازگشتی و شبکه‌های دینامیک جلوسو حکایت از بررسی مسلم شبکه‌های بازگشتی دارد. مقایسه کمی، بهبود حدود ۳٪ و ۸٪ را به ترتیب در CCCt و NMSE نشان می‌دهد اما همان‌طور که از شکل‌ها مشخص است، کیفیت، بهبود قابل توجهی داشته است؛ پاسخ‌های شبکه‌ی بازگشتی بسیار هموارتر و اختلاف مقادیر استاتیک خروجی زاویه بسیار کمتر است.

رو در ادامه، تاثیر افزایش نورون‌های لایه پنهان مورد مطالعه قرار گرفته است.

شکل‌های ۶، ۷ و ۸ نتایج این افزایش را برای $Hn=15, 12, 10, 8$ آشکار می‌سازد. در یک بررسی کلی روی این نمودارها این‌طور دیده می‌شود که با افزایش تعداد نورون‌های پنهان تا ۱۲ نورون، هر سه مشخصه مورد مطالعه، خصوصا به ازای d برابر با ۲، ۳ و ۴، رو به افزایش دارند و در نتیجه عملکرد شبکه بهبود یافته است. با افزایش Hn به ۱۵ نورون، این مشخصه‌ها کاهش یافته و عملکرد شبکه افت می‌کند.

ساختارها به ازای $Hn=12$ و $d=4, 3, 2$ عملکردی نزدیک به هم دارند که با بررسی دقیق‌تر هر سه مشخصه CCCt میانگین، تعداد دفعات یادگیری قابل قبول و اولویت داشتن تعداد تاخیرهای هر چه کمتر ممکن، ساده‌ترین شبکه‌ای که در عین حال بهترین مدل را بین ساختارهای NARX به دست دهد با ۱۲ نورون در لایه پنهان و استفاده از اطلاعات ۲ واحد (۱/۰ ثانیه) از سوابق ورودی و خروجی، با احتساب ورودی زمان حال، حاصل شده است.

جدول ۲ میزان یادگیری شبکه‌ی برگزیده را برای هر یک از چهار سیگنال آزمون و شکل ۹، بهترین شناسایی صورت گرفته توسط این مدل را، از بین ۱۵ بار یادگیری برای این سیگنال‌ها نشان می‌دهد. خروجی سیستم واقعی با خط چین و رنگ تیره و خروجی تخمین زده شده با خط توپر و رنگ روشن مشخص شده‌اند؛ مقدار ضریب همبستگی بین دو این دو خروجی در بالای هر ترسیمه نوشته شده است.



شکل ۶- میانگین ضریب همبستگی متقابل برای تمامی ساختارهای بازگشتی بررسی شده.





به بلوغ و کمال خود رسیده‌اند برای کاربرد وسیع عملی نیستند. در نتیجه این تفکر به وجود آمد که شاید بتوان ایده‌های کنترل را از سیستم بیولوژیکی قرض گرفت. اگرچه مکانیسم حرکت بیولوژیکی انسان هنوز دور از این است که به طور کامل فهمیده شود ولی نتایج ابتدایی این ادراکات به پیدایش الگوریتم‌های هوش محاسباتی انجامیده است. این الگوریتم‌ها پتانسیلی برای روش‌های مدل‌سازی و کنترل FES فراهم کرده است.

رویکردهای متعارف در زمینه‌ی مدل‌سازی سیستم به میزان زیادی تکیه به ابزارهای ریاضی دارد؛ تاکید این روش‌ها بر توصیف دقیق مقادیر فیزیکی مورد بحث است. در مقابل، مدل‌سازی با رویکرد شبکه عصبی و هوش محاسباتی، در جایی که شگردهای مرسوم قبلی در نایل شدن به نتایج رضایت‌بخش ناکام مانده‌اند، در حال تبدیل شدن به چاره‌ای مناسب رشد و ترقی است. دلیل این امر آن است که با این ابزار، به موضوعاتی نظیر عدم قطعیت یا تغییرات ناشناخته در پارامترها و ساختار سیستم به شکل کارآمدتری پرداخته می‌شود؛ ضمن آنکه خود سازمانده و خود تعمیر بودن از ویژگی‌های این روش‌ها است.

کاربران این پژوهش افرادی هستند که از ناحیه‌ی مهره‌های C۵/C۶ دچار آسیب شده‌اند؛ این افراد در باز کردن ارادی آرنج دچار مشکل هستند در حالیکه حرکت خم کردن آرنج را بدون مشکل انجام می‌دهند. بنابراین در این پژوهش به ارائه‌ی مدل جعبه سیاه از حرکت مفصل آرنج (شرایط غیرایزومتریک عضله) در صفحه‌ی عرضی، با استفاده از شبکه‌های عصبی دینامیک پرداخته شده است. ورودی به مدل، دامنه‌ی جریان تحریک عضلات دوسربازویی و سه‌سربازویی و خروجی آن تخمین زاویه‌ی مفصل آرنج است. هدف از ارائه‌ی این مدل، استفاده از آن برای کاربردهای کنترلی FES در حرکت رساندن دست، در امور ساده‌ی حرکت در صفحه‌ی افق بوده است.

در هنگام مدل‌سازی این سیستم، چشم‌پوشی از خاصیت غیرخطی عضله و استفاده از ساختارهای خطی، کیفیت مدل را کاهش می‌دهد، لذا برای مدل‌سازی عضله نیاز به مدل‌های

کاهش بسیار زیاد در سوابق مورد نیاز ورودی برای یادگیری شبکه‌های بازگشتی، نسبت به این پارامتر در یادگیری شبکه‌های جلوسو، تاثیر اطلاعات خروجی را نمایان می‌کند.



شکل ۹- خروجی مطلوب و خروجی بهترین شبکه NARX به ازای ۴ سیگنال آزمون.

۴- جمع‌بندی و نتیجه‌گیری

از آنجا که در دنیای امروز هیچ ماشین مصنوعی که بتوان آن را با سیستم حرکتی انسان طبیعی مقایسه کرد وجود ندارد، هیچ‌یک از روش‌های مدل‌سازی و کنترل مصنوعی که نزدیک

جنبه‌ی کمی و کیفی به شکل آشکاری بیان کننده‌ی انعطاف‌پذیری بیشتر شبکه‌های بازگشتی در شناسایی سیستم مورد مطالعه است.

در انتها لازم به تذکر است که عوامل فردی بسیار دیگری علاوه بر ورودی تحریک الکتریکی روی پاسخ سیستم موثر است. به منظور ثابت نگه داشتن این عوامل، در این پژوهش تنها از یک سوژه استفاده شده است؛ اما برای آنکه مدل قادر باشد این ویژگی‌های درون فردی را یاد بگیرد و در نتیجه برای افراد مختلف قابل استفاده باشد، لازم است که با دادگان افراد متفاوت آموزش ببیند.

سپاسگزاری

با سپاس بی‌پایان از استاد بزرگوارم، جناب آقای دکتر علی مالکی، که صمیمانه و بی‌دریغ در تمامی آزمایش‌های تحریک الکتریکی حضور فعال به هم رسانیده و بنده را از راهنمایی و یاری خود بهره‌مند نمودند.

با تشکر فراوان از جناب آقای مصطفی ربانی که به عنوان سوژه‌ی آزمایش‌های تحریک الکتریکی نهایت همکاری صمیمانه را با ما مبذول داشتند.

مراجع

- [1] Zhang D, Zhu K, "Modeling biological Motor Control for Human Locomotion with Functional Electrical Stimulation", Biol. Cybern, Vol.13, No. 3, 2007.
- [2] Riener R, Fuhr T, Patient-Driven Control of FES-Supported Standing up: A Simulation Study, IEEE Transaction on Rehabilitation Engineering. Vol. 6, NO. 2, June 1998.
- [4] Lynch C L, Popovic M R, "Functional Electrical Stimulation", IEEE Magazine, Control Systems, Vol. 28, 2008.
- [5] Riener R, Quintern J, Schmidt G, Biomechanical Model of the Human Knee Evaluated by Neuromuscular Stimulation, Journal of Biomechanics, Vol. 29, No. 9, pp. 1157-1167, 1996.
- [6] Park H, Durand D M, "Motion Control of Musculoskeletal Systems with Redundancy", Biol. Cybern, Vol.99, 2008.
- [7] Previdi F, Carpanzano E, "Design of a Gain Scheduling Controller for Knee-Joint Angle

غیرخطی و پویا است. شبکه عصبی دارای ساختار غیرخطی است و یک نگاشت غیرخطی بین ورودی و خروجی برقرار می‌کند. رفتار عضله را به‌طور کلی در نظر می‌گیرد و هیچ‌گونه تجزیه‌ای در رفتار آن انجام نمی‌دهد؛ به جهت آنکه سیستم عضلانی- اسکلتی ذاتا دینامیک و دارای حافظه است ساختار شبکه عصبی مورد استفاده در این مطالعه مدل‌های دینامیک را عرضه کرده است. به‌کمک یک نگاشت مناسب که دینامیک در آن به‌وسیله‌ی وارد کردن عناصر تاخیر و اعمال خروجی‌های لحظاتی گذشته به ورودی شبکه لحاظ شده است، مدل رفتاری ارائه گشته و به اعتبارسنجی مدل پرداخته شد.

نهایت انعطاف‌پذیری معماری FTDNN در یک ساختار دو لایه با ۵ نورون پنهان و استفاده از ۱/۲۵ ثانیه از سوابق ورودی، با شاخص عملکرد $CCct=89/86\%$ و $NMSE=4/85\%$ رخ داد و به‌عنوان مدل برگزیده‌ی این معماری معرفی گردید. نتیجه آنکه برای شناسایی سیستم مورد بحث، اگر شبکه‌ی جلوسو ظرفیت معینی در شناسایی سیستم مورد نظر داشته باشد، نهایت این ظرفیت در ساختار برگزیده به‌دست می‌آید و اضافه کردن تعداد لایه‌ها، نورون‌ها و دینامیک شبکه اگر جواب بدتری ندهد بهبودی هم در پاسخ ایجاد نخواهد کرد.

شبکه‌های DTDNN با پارامترهای طراحی شده در شبکه‌ی برتر ساختار FTDNN و اضافه نمودن یک خط تاخیر در لایه‌ی میانی و مقدار دهی به آن مورد بررسی قرار گرفتند اما به‌دلیل قرار نگرفتن در میدان دینامیک پویا بهبودی در نتیجه حاصل نشد. بدین ترتیب ساختارهای DTDNN ای که در این قسمت از پژوهش بررسی شدند، در امر بهبود مدل با موفقیت روبه‌رو نبودند.

بهترین شبکه‌ی بازگشتی با معماری NARX و تعداد سوابق ورودی و خروجی برابر نیز، در ساختاری دو لایه با ۱۲ نورون در لایه‌ی پنهان و استفاده از ۰/۱ ثانیه از سوابق، با شاخص عملکرد $CCct=92/50\%$ و $NMSE=4/06\%$ رخ داد و به‌عنوان مدل برگزیده‌ی این معماری معرفی گردید. مقایسه‌ی بهترین نتایج آموزش با استفاده از شبکه جلوسو از هر دو

- Vol.11, No. 3, 2003.
- ftp.emgsrus.com/manuals/biometrics_goniometer_u_g.pdf
- [15] Hagan M T, Demuth H B, Beale M, Neural Network Design, Boston: PWS Publishing Company, 1996.
 - [16] Medsker L R, Jain L C, Recurrent neural networks: design and applications, Boca Raton, FL: CRC Press, 2000.
 - [17] Hagan M T, Demuth H B, Beale M, "Neural Network Toolbox™ 6 User's Guide", MathWorks, 2008, Retrieved 22 Jan. 2011 from: www.mathworks/help/pdf_doc/nnet/nnet.pdf
 - [18] Waibel A, Hanazawa T, Hilton G, Shikano K, Lang K J, "Phoneme Recognition Using Time-Delay Neural Networks", IEEE Tran. on Acoustics, Speech, and Signal Processing, Vol. 37, 1989.
 - [19] Nguyen D, Widrow B, "Improving the Learning Speed of 2-Layer Neural Networks by Choosing Initial Values of the Adaptive Weights", Proc. Int. Joint Conf. on Neural Networks, Vol. 3, 1990.
 - [20] Hagan M T, Menhaj M, "Training Feed-Forward Networks with the Marquardt Algorithm," IEEE Tran. on Neural Networks, Vol. 5, No. 6, 1999.
 - [21] Dosen S, Popovic D, "Functional Electrical Stimulation for Walking: Rule Based Controller using Accelerometers", Annual IEEE Student Paper Conf, AISPC, Art. No. 4460550, 2008.
 - [22] De Jesús O, Horn J M, Hagan M T, "Analysis of Recurrent Network Training and Suggestions for Improvements", Proc. Int. Joint Conf. on Neural Networks, Washington, DC, 2001
 - Control by Using Functional Electrical Stimulation", IEEE Trans. Control Syst. Technol.
 - [8] Previdi F, "Identification of Black Box Nonlinear Models for Lower Limb Movement Control Using Functional Electrical Stimulation", Control Engineering Practice, Vol. 10, No.1, 2002.
 - [9] Denaii M A, Palis F, Zeghib A, "Modeling and Control of Non-linear Systems Using Soft Computing Techniques", Applied Soft Computing, Vol. 7, 2007.
 - [10] Cheng K W E, Cao L, Rad A B, Sutanto D, Chow D H K, Tong K Y, "Adaptive Neural Network Control of FES in Arm Movements and its Application Based on Resonant Converter", Proc. Int. Conf. IEEE on Industrial Technology, Vol. 2, 2002.
 - [11] Haiming Qi, Dustin J T, Dominique M D, "Neurofuzzy Adaptive Controlling of Selective Stimulation for FES: A Case Study", IEEE Tran. on Rehabil. Eng, Vol. 7, No. 2, June 1999.
 - [12] Chang G C, Lub J J, Liao G D, Lai J S, Cheng C K, Kuo B L, Kuo T S, "A Neuro-Control System for the Knee Joint Position Control with Quadriceps Stimulation", IEEE Trans. on Rehabil. Eng, Vol.5, No. 1, 1997.
 - [13] Kurosawa K, Futami R, Watanabe T, Hoshimiya N, "Joint Angle Control by FES Using a Feedback Error Learning Controller", IEEE Trans. Neural Syst. Rehabil. Eng, Vol.13, No. 3, 2005.
 - [14] Biometrics Ltd, "Goniometer and Torsiometer Operating Manual", 2002, Retrieved 22 Jan. 2011 from: <ftp://>