

Evaluation of nonlinear models based on kernel functions for force decoding using Local Field Potential signals

M. Fatemi¹ and M. R. Daliri^{2*}

¹Ph.D Student, Biomedical Engineering Department, School of Electrical Engineering, Iran University of Science and Technology (IUST), Tehran, Iran

²Professor, Biomedical Engineering Department, School of Electrical Engineering, Iran University of Science and Technology (IUST), Tehran, Iran

Receipt in the Online Submission System: 26/5/2019, Received in Revised Form: 2/11/2019, Accepted: 3/11/2019

Abstract

Controlling of neuroprostheses to restore grasping ability in patients with paralyzed or amputated upper limbs is one of the important applications of BCI systems. The ability to get objects is necessary for daily works so, for a reliable function of the neuroprostheses, it is necessary for the user to control the amount of force needed for grasping. For this reason, increasing the accuracy of continuous force decoding is an important issue for the convenient function of these BCI systems. In most studies in the field of force decoding, linear models such as wiener filter, Kalman filter, PLS, etc. are used to decode force. So far, the effect of using nonlinear models is not investigated on force decoding. The goal of this study is to investigate the effect of using nonlinear regression models based on kernel functions on the accuracy of force decoding in Vistar rats using local field potential signals. To do this, we choose ridge regression, PCR and PLS methods and use the Gaussian kernel function to construct a generalized nonlinear model for the force decoding. Evaluating kernel ridge, kernel PCR and kernel PLS methods shows that considering nonlinear relations between brain signal's features improves decoding accuracy. The mean coefficient of determination (R^2) improves 12.7% in kernel ridge toward ridge regression, 25.5% in kernel PCR toward PCR and 19.1% in kernel PLS toward PLS method. The best decoding accuracy has been achieved by the kernel ridge regression method and the mean correlation coefficient between the estimated and measured force is 0.72 and R^2 is 0.62.

Key words: *Brain Computer Interface (BCI), Local Field Potential, Continuous Force Decoding, Nonlinear Regression.*

*Corresponding author

Address: Biomedical Engineering Department, School of Electrical Engineering, Iran University of Science and Technology (IUST), P.O.Box: 1684613114, Tehran, Iran

Tel: +98-21-732225738

Fax: +98-21-732225777

E-mail: daliri@iust.ac.ir



ارزیابی مدل‌های غیرخطی مبتنی بر توابع کرنل برای رمزگشایی نیرو با استفاده از سیگنال‌های پتانسیل میدانی محلی مریم فاطمی^۱، محمدرضا دلیری^{۲*}

^۱ دانشجوی دکتری مهندسی پزشکی، گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران
^۲ استاد، گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

تاریخ ثبت در سامانه: ۱۳۹۸/۳/۵، بازنگری: ۱۳۹۸/۸/۱۱، پذیرش قطعی: ۱۳۹۸/۸/۱۲

چکیده

کنترل پروتز عصبی به منظور بازیابی عملکرد دست افراد مبتلا به فلج در اندام‌های فوقانی، یکی از کاربردهای مهم سیستم‌های *BCI* می‌باشد. توانایی گرفتن اجسام، از ابتدایی‌ترین نیازها برای انجام کارهای روزانه است و برای عملکرد صحیح پروتز عصبی بدین منظور، لازم است کاربر بتواند مقدار نیروی لازم برای گرفتن اجسام را کنترل کند. به همین دلیل افزایش دقت رمزگشایی پیوسته نیرو، موضوعی مهم برای عملکرد صحیح این نوع سیستم‌های *BCI* می‌باشد. در اغلب پژوهش‌های صورت گرفته در زمینه رمزگشایی نیرو، از مدل‌های خطی مانند فیلتر وینر، فیلتر کالمن و *PLS* استفاده شده و تاکنون تاثیر استفاده از مدل‌های غیرخطی بر دقت رمزگشایی نیرو مورد بررسی قرار نگرفته است. هدف این پژوهش، بررسی تاثیر استفاده از مدل‌های رگرسیون غیرخطی مبتنی بر توابع کرنل بر دقت رمزگشایی نیروی دست موش صحرائی با استفاده از سیگنال‌های پتانسیل میدانی محلی می‌باشد. بدین منظور، روش‌های رگرسیون ستیغی، *PCR* و *PLS* را در نظر گرفته و با استفاده از تابع کرنل گوسی، تعمیم‌یافته غیرخطی آنها را برای تخمین پیوسته نیرو به کار گرفته‌ایم. ارزیابی و مقایسه روش‌های رگرسیون ستیغی کرنلی، *PCR* کرنلی و *PLS* کرنلی نشان می‌دهد که در نظر گرفتن ارتباطات غیرخطی بین ویژگی‌های سیگنال مغزی، دقت رمزگشایی نیرو را نسبت به مدل‌های خطی بهبود می‌بخشد. درصد بهبود میانگین ضریب R^2 ، ۱۲٫۷٪ برای روش رگرسیون ستیغی کرنلی نسبت به روش ستیغی، ۲۵٫۵٪ برای روش *PCR* کرنلی نسبت به *PCR* و ۱۹٫۱٪ برای روش *PLS* کرنلی نسبت به *PLS* بوده است. بهترین دقت رمزگشایی نیرو نیز به ازای روش رگرسیون ستیغی کرنلی و با میانگین ضریب همبستگی ۷۲٪ و مقدار R^2 برابر ۰٫۶۲ بدست آمده است.

کلیدواژه‌ها: واسط مغز-کامپیوتر (*BCI*)، پتانسیل میدانی محلی، رمزگشایی پیوسته نیرو، رگرسیون غیرخطی

*نویسنده مسئول

نشانی: گروه مهندسی پزشکی، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران. کد پستی: ۱۶۸۴۶۱۳۱۱۴

تلفن: +۹۸(۲۱)۷۳۲۲۲۵۷۳۸

دورنگار: +۹۸(۲۱)۷۳۲۲۲۵۷۷۷

پست الکترونیکی: daliri@iust.ac.ir

۱- مقدمه

در دهه‌های اخیر، تلاش‌های بسیاری برای بهبود کیفیت زندگی افراد دچار ناتوانایی‌های حرکتی انجام شده و به همین منظور، پژوهش‌های فراوانی در حوزه سیستم‌های BCI^۱ حرکتی انجام شده است. یک سیستم BCI، فعالیت‌های مغزی کاربر را ثبت و آنالیز کرده و آن را به خروجی مصنوعی تبدیل می‌کنند که برای جایگزینی، بازبایی، افزایش، تکمیل یا بهبود خروجی طبیعی مغز استفاده می‌شود [۱]. معماری یک سیستم BCI بدین صورت است که پس از ثبت سیگنال مغزی، ویژگی مناسب با توجه به کاربردی که مد نظر داریم استخراج شده و سپس ترجمه می‌شود تا دستورات کنترلی مورد نظر از روی آن تولید شود [۱].

یکی از مهم‌ترین کاربردهای سیستم‌های BCI، کنترل مستقیم پروتز عصبی به منظور بازیابی عملکردهای دست افراد مبتلا به فلج در اندام‌های فوقانی می‌باشد. توانایی گرفتن اجسام^۲، یکی از ابتدایی‌ترین نیازها برای انجام کارهای روزانه می‌باشد اما تاکنون چگونگی کنترل عصبی این حرکت به طور کامل شناخته نشده است. از طرف دیگر، بیشتر مطالعات انجام شده در حوزه سیستم‌های BCI حرکتی، بر استخراج و رمزگشایی اطلاعات کینماتیکی حرکت متمرکز بوده‌اند در حالیکه برای بازیابی عملکرد گرفتن، به ترکیب اطلاعات کینماتیکی و کینماتیکی نیاز می‌باشد [۲]. برای عملکرد صحیح پروتز عصبی به منظور گرفتن اجسام، لازم است که کاربر بتواند مقدار نیروی لازم را کنترل کند. به همین دلیل، مطالعاتی در زمینه رمزگشایی مقدار نیروی لازم برای گرفتن اجسام و همچنین نحوه فعالیت ماهیچه‌های دست هنگام عمل گرفتن، انجام شده است. این مطالعات نشان می‌دهند که از روی سیگنال‌های اسپایک قشر حرکتی، می‌توان علاوه بر جهت و سرعت حرکت، مقدار نیروی وارد شده را نیز تخمین زده و همچنین نوع گرفتن را مشخص نمود [۳-۸]. همچنین برخی پژوهش‌ها نشان می‌دهند که با استفاده از سیگنال‌های پتانسیل میدانی محلی^۳ نیز می‌توان برخی پارامترهای حرکت گرفتن مانند جهت حرکت، نوع گرفتن، مقدار نیرو و فعالیت EMG ماهیچه‌ها را رمزگشایی نمود [۹-۱۹]. اخیراً مطالعاتی انجام شده که نشان می‌دهد سیگنال‌های ECoG^۴

ناحیه حرکتی نیز حاوی اطلاعات مفیدی برای تخمین پارامترهای کینماتیکی حرکت مانند نیروی وارد شده و فعالیت ماهیچه‌ها می‌باشد [۲۰-۲۱].

یک سیستم BCI به یک الگوریتم رمزگشایی نیاز دارد که داده‌های نوروبی را به پارامترهای حرکتی مانند مکان، سرعت و نیرو ترجمه کند. برای مدل کردن رابطه بین سیگنال‌های مغزی و پارامترهای حرکتی، می‌توان از انواع روش‌های رگرسیون استفاده نمود. در اغلب مطالعات صورت گرفته در زمینه رمزگشایی پارامترهای کینماتیکی و کینماتیکی حرکت، از مدل‌های رگرسیون خطی مانند فیلتر وینر، فیلتر کالمن و PLS^۵ استفاده شده است.

مدل‌های خطی به علت سادگی، تعمیم‌پذیری و مقاوم بودن نسبت به پدیده بیش‌برازش^۶، بیشتر از مدل‌های غیرخطی کاربرد دارند. با این وجود، این روش‌ها نمی‌توانند ارتباط‌های پیچیده‌تر بین ویژگی‌های سیگنال مغزی را مدل کنند. در نظر گرفتن اثرات غیرخطی می‌تواند به ارائه مدل دقیق‌تری منجر شود که دقت رمزگشایی را بهبود بخشد. بدین منظور در تعدادی از مطالعات انجام شده، تاثیر استفاده از برخی روش‌های رگرسیون غیرخطی نیز بر دقت رمزگشایی مورد بررسی قرار گرفته است. به طور مثال آقای وسبرگ^۷ و همکاران در سال ۲۰۰۰، در پژوهش خود توانستند با استفاده از سیگنال‌های اسپایک مغزی میمون به صورت آنلاین، حرکت یک بازوی مصنوعی را کنترل کنند. در این مطالعه برای رگرسیون از روش خطی فیلتر وینر و روش غیرخطی شبکه عصبی مصنوعی^۸ استفاده شد و نتایج دو روش با یکدیگر مقایسه گردید که تفاوت معناداری با یکدیگر نداشت [۲۲]. همچنین آقای فلینت^۹ و همکاران در سال ۲۰۱۲ به رمزگشایی جهت و سرعت دست میمون توسط روش ترکیبی غیرخطی وینر-همرشتاین پرداختند [۲۳].

در سال ۲۰۱۴ در مطالعه‌ای که توسط آقای کیم^{۱۰} و همکاران صورت گرفت، از روش خطی رگرسیون ستیغی^{۱۱} و تعمیم‌یافته کرنلی آن برای رمزگشایی جهت و سرعت حرکت دست انسان

^۵ Partial least square

^۶ Overfitting

^۷ Wessberg

^۸ Artificial neural network

^۹ Flint

^{۱۰} Kim

^{۱۱} Ridge regression

^۱ Brain computer interface

^۲ Grasping

^۳ Local field potential

^۴ Electrocorticography

شده است. در قسمت آزمایش، داده‌های مورد استفاده در این پژوهش توصیف و سپس پارادایم رمزگشایی بیان شده است. در قسمت نتایج نیز، مقایسه‌ای بین دقت رمزگشایی و پیچیدگی محاسباتی الگوریتم‌های مختلف بیان شده در قسمت روش‌ها انجام شده و تاثیر استفاده از مدل غیرخطی برای رمزگشایی نیرو مورد بررسی قرار گرفته است.

۲- مواد و روش‌ها

۲-۱- الگوریتم رگرسیون ستیغی

روش رگرسیون ستیغی یکی از ساده‌ترین روش‌های رگرسیون خطی مبتنی بر الگوریتم حداقل مربعات خطای جریمه شده^{۲۰} می‌باشد. اگر فرض کنیم $\mathbf{X} \in \mathbb{R}^{L \times M_1}$ ماتریس ورودی و $\mathbf{Y} \in \mathbb{R}^{L \times M_2}$ ماتریس خروجی باشند، روش ستیغی به دنبال ماتریس ضرایب $\boldsymbol{\beta} \in \mathbb{R}^{M_1 \times M_2}$ به صورتی است که تابع هزینه زیر حداقل شود:

$$\begin{aligned} \text{Minimize } \sum_{i=1}^N (\mathbf{y}_i - \sum_{j=1}^{M_1} \mathbf{x}_{ij} \boldsymbol{\beta}_j)^2 \quad (1) \\ \text{subject to } \sum_{j=1}^{M_1} \boldsymbol{\beta}_j^2 \leq c \end{aligned}$$

مساله فوق یک مساله بهینه‌سازی مشروط است که با محدود کردن نرم دوم ضرایب تخمین با عدد ثابت c ، دقت رمزگشایی را بهبود می‌بخشد. این مساله بهینه‌سازی را می‌توان بدین صورت نیز بیان کرد:

$$\text{Minimize } \sum_{i=1}^N (\mathbf{y}_i - \sum_{j=1}^{M_1} \mathbf{x}_{ij} \boldsymbol{\beta}_j)^2 + \lambda \sum_{j=1}^{M_1} \boldsymbol{\beta}_j^2 \quad (2)$$

که در رابطه فوق، λ پارامتر تنظیم^{۲۱} می‌باشد. در این صورت راه حل مساله ستیغی بدین صورت بدست می‌آید:

$$\boldsymbol{\beta}_{\text{ridge}} = (\mathbf{X}^T \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^T \mathbf{Y} \quad (3)$$

که $\mathbf{I} \in \mathbb{R}^{M_1 \times M_1}$ ماتریس همانی^{۲۲} می‌باشد.

۲-۲- الگوریتم PCR

یکی از راه‌های افزایش دقت تخمین، کاهش رتبه^{۲۳} تخمین می‌باشد. استفاده از تخمین با رتبه کمتر ورودی و خروجی، از پدیده بیش‌برازش جلوگیری کرده و دقت رمزگشایی را بهبود می‌بخشد. در الگوریتم PCR، با استفاده از روش تجزیه مولفه‌های اساسی^{۲۴}، ماتریس ورودی‌ها به فضایی تصویر می‌شود که در آن

در سه بعد با استفاده از سیگنال‌های EEG مغزی او استفاده شد. نتایج این پژوهش نشان داد که استفاده از روش رگرسیون ستیغی کرنلی^{۱۲} باعث بهبود مقاومت مدل در حضور نویز و آرتیفکت و افزایش دقت رمزگشایی می‌شود [۲۴].

همچنین آقای هان^{۱۳} و همکاران در سال ۲۰۱۴ در پژوهشی که برای کنترل حرکات مچ دست توسط سیگنال EMG انجام دادند، از روش رگرسیون خطی و روش‌های غیرخطی شبکه عصبی پرسپترون چندلایه^{۱۴} و روش رگرسیون ستیغی کرنلی برای رمزگشایی استفاده نمودند. نتایج پژوهش نشان داد که روش رگرسیون ستیغی کرنلی بهتر از دیگر روش‌ها عمل می‌کند [۲۵]. در یکی از تازه‌ترین پژوهش‌هایی که در این موضوع انجام شده، برای پیش‌بینی نیروی دست انسان با استفاده از سیگنال‌های پتانسیل میدانی محلی عمیق^{۱۵} (ناحیه SNT^{۱۶}) از مدل‌های خطی فیلتر وینر، فیلتر کالمن و مدل‌های غیرخطی فیلتر وینر سری^{۱۷} و شبکه عصبی پویا^{۱۸} استفاده شده است. نتایج این تحقیق نشان می‌دهد که مدل غیرخطی فیلتر وینر سری، بهترین دقت رمزگشایی را دارد [۲۶].

همانطور که ذکر شد، استفاده از مدل‌های رگرسیون غیرخطی در کاربردهای BCI محدود بوده و در اغلب مطالعات صورت گرفته در این زمینه، از مدل‌های خطی مانند فیلتر وینر، فیلتر کالمن و PLS استفاده شده است. در این پژوهش، برای بررسی عملکرد مدل‌های رگرسیون غیرخطی به منظور رمزگشایی نیرو، چند الگوریتم خطی ساده رگرسیون ستیغی، PCR و PLS انتخاب شده و تعمیم‌یافته غیرخطی آنها با کرنل گوسی به منظور تخمین نیروی دست موش صحرایی مورد استفاده قرار گرفته و دقت و پیچیدگی این روش‌ها با یکدیگر مقایسه شده است.

بخش‌های پیش‌رو بدین صورت سامان یافته است: ابتدا در قسمت روش‌ها، الگوریتم‌های رگرسیون ستیغی، PCR^{۱۹} و PLS به طور مختصر بیان شده و سپس تعمیم‌یافته کرنلی آنها ذکر

^{۱۲} Kernel ridge regression

^{۱۳} Hahne

^{۱۴} Multilayer perceptron

^{۱۵} Deep brain local field potential

^{۱۶} Subthalamic Nucleus

^{۱۷} Wiener cascade model

^{۱۸} Dynamic neural network

^{۱۹} Principle component regression

^{۲۰} Penalized least square errors

^{۲۱} Regularization parameter

^{۲۲} Identity matrix

^{۲۳} Rank

^{۲۴} Principle component analysis

که E و F ، باقیمانده ها می باشند. برای بدست آوردن i امین متغیر پنهان t و u که بیشترین کواریانس را داشته باشند، به دنبال جهت های w و q هستیم که با تصویر کردن X و Y بر روی آنها، کواریانس ورودی و خروجی در این جهت ها ماکزیمم باشد. $(t=Xw, u=Yq)$

$$\text{Maximize } (t^T u) \Rightarrow \text{Maximize } (w^T X^T Y q) \quad (6)$$

$$\text{where } w \in \mathbb{R}^{M_1 \times 1}, q \in \mathbb{R}^{M_2 \times 1}$$

برای حل مساله فوق، الگوریتم NIPALS^{۲۷} ارائه شده است. در مرحله اول الگوریتم فرض می شود که q ثابت است، پس برای ماکزیمم شدن عبارت فوق کافی است که $w = X^T Y q$ یا $w = X^T u$ باشد. در مرحله دوم فرض می شود که w ثابت است، پس برای ماکزیمم شدن عبارت فوق کافی است که $q = Y^T t$ یا $q = Y^T X w$ باشد. در یک فرآیند تکراری، دو مرحله فوق تکرار شده و در هر مرحله مقادیر $t = Xw, u = Yq$ نیز آپدیت می شوند تا مقادیر همگرا شوند.

در روش PLS فرض می شود که متغیرهای پنهان t و u با یکدیگر رابطه خطی دارند یعنی $u = td$. پس می توان با استفاده از الگوریتم حداقل مربعات، مقدار $d = t^T u / t^T t$ را محاسبه کرد. سپس متغیر $p = X^T t$ تعریف شده و در مرحله انقباض^{۲۸}، اثر تخمین رتبه یک X و Y از X و Y کم می شود یعنی:

$$Y = Y - dtq^T, X = X - tp^T \quad (7)$$

برای پیدا کردن a مولفه، لازم است که a بار مراحل فوق تکرار شود [۲۳]. پس از طی این مراحل و تخمین ماتریس های Q و T و U و P ، رابطه بین ورودی و خروجی بدین صورت بدست می آید:

$$Y = XW(P^T W)^{-1} Q^T + F \quad (8)$$

و ماتریس ضرایب رگرسیون $\beta \in \mathbb{R}^{M_1 \times M_2}$ برابر است با:

$$\beta_{PLS} = W(P^T W)^{-1} Q^T \quad (9)$$

۲-۴- الگوریتم های غیرخطی مبتنی بر توابع کرنل

استفاده از توابع کرنل، یکی از ساده ترین روش های ساخت یک مدل غیرخطی است. الگوریتم های کرنلی یک تعمیم ساده از رگرسیون خطی بوده و بدین صورت است که ابتدا به وسیله یک تابع کرنل غیرخطی، متغیرها به فضایی با ابعاد بالاتر تصویر شده و سپس از الگوریتم رگرسیون خطی در این فضا استفاده می شود. در این پژوهش با استفاده از تابع کرنل گوسی، الگوریتم-

که واریانس تصویر ماکزیمم بوده و مولفه های تصویر نسبت به هم ناهمبسته باشند. با استفاده از PCA می توان مولفه های اساسی ماتریس ورودی را استخراج نمود و با انتخاب تعداد مناسبی از آنها که درصد خوبی از واریانس سیگنال را پوشش دهد، یک تخمین با رتبه کمتر از رگرورها فراهم نمود و سپس با استفاده از الگوریتم حداقل مربعات، خروجی را تخمین زد. اگر فرض کنیم بردار $U \in \mathbb{R}^{L \times k}$ شامل k مولفه اساسی اول ورودی ها باشد، ماتریس ضرایب رگرسیون $\beta \in \mathbb{R}^{k \times M_2}$ در الگوریتم PCR بدین صورت تخمین زده می شود:

$$\beta_{PCR} = (U^T U)^{-1} U^T Y \quad (4)$$

این الگوریتم نسبت به الگوریتم حداقل مربعات نسبت به پدیده بیش برآزش مقاوم تر می باشد [۲۷].

۲-۳- الگوریتم PLS

الگوریتم PLS، یکی از روش های خطی و بسیار پر کاربرد برای پیش بینی متغیرهای وابسته با استفاده از ماتریس ویژگی ها می باشد. روش کار، استخراج مجموعه ای از فاکتورهای متعامد از ورودی و خروجی است که به آنها متغیرهای پنهان^{۲۵} می گویند. با استفاده از این متغیرهای پنهان، یک تخمین با رتبه کمتر از ورودی و خروجی محاسبه شده و مدل رمزگشایی بر اساس آنها ساخته می شود. در روش PLS نیز مشابه PCR، داده های ورودی به فضای مناسب تری تصویر می شوند اما تفاوت این دو روش، در انتخاب جهتی است که داده ها روی آن تصویر می شوند. روش PCR، به دنبال جهتی است که ورودی ماکزیمم واریانس را داشته باشد در حالی که در PLS، جهتی انتخاب می شود که کواریانس ورودی و خروجی در فضای تصویر ماکزیمم باشد. این موضوع، مزیت PLS نسبت به PCR است زیرا ماکزیمم شدن کواریانس، بدین معناست که از روی ماتریس ویژگی ها، مولفه هایی ساخته می شود که برای توصیف متغیر وابسته مناسب باشند و بهترین قدرت پیش بینی را داشته باشند.

در روش PLS ماتریس های X, Y به متغیرهای پنهان U, T و متغیرهای بار^{۲۶} Q, P بدین صورت تجزیه می شوند:

(5)

$$\begin{aligned} X &= TP^T + E \quad \text{where } T = [t_1, t_2, \dots, t_R] \in \mathbb{R}^{L \times R}, \\ & \quad P = [P_1, P_2, \dots, P_R] \in \mathbb{R}^{M_1 \times R} \\ Y &= UQ^T + F \quad \text{where } U = [u_1, u_2, \dots, u_R] \in \mathbb{R}^{L \times R}, \\ & \quad Q = [q_1, q_2, \dots, q_R] \in \mathbb{R}^{M_2 \times R} \end{aligned}$$

^{۲۷} Nonlinear iterative partial least squares

^{۲۸} Deflation

^{۲۵} Latent variable

^{۲۶} Loading variable

$$\beta(\mathbf{x})_k = (\mathbf{v}^k \cdot \Phi(\mathbf{x})) = \sum_{i=1}^n \alpha_i^k \mathbf{K}(x_i, \mathbf{x})$$

اگر ماتریس $\beta = \Phi * \mathbf{V}$ ماتریس مولفه‌های اساسی فوق باشد، ماتریس ضرایب رگرسیون $\hat{\mathbf{W}}$ برای روش PCR کرنلی بدین صورت محاسبه می‌شود:

(۱۷)

$$\hat{\mathbf{W}} = (\beta^T \beta)^{-1} \beta^T \mathbf{Y} = \Lambda^{-1} \beta^T \mathbf{Y}$$

که در رابطه فوق، Λ ماتریس قطری مقادیر ویژه می‌باشد. با حذف تعدادی از مولفه‌های اساسی غیرخطی که متناظر مقادیر ویژه کوچکتر هستند، می‌توان واریانس تخمین را کاهش داد و از بیش‌برازش جلوگیری نمود [۲۷].

آخرین الگوریتم مبتنی بر توابع کرنل مورد بحث در این پژوهش، روش PLS کرنلی می‌باشد. مشابه قبل، در این روش نیز ماتریس ویژگی‌های \mathbf{X} توسط تابع غیرخطی Φ به فضای ویژگی جدید تصویر می‌شود و مساله یافتن مدل خطی PLS مانند قسمت قبل بین \mathbf{Y} و $\Phi(\mathbf{X})$ می‌باشد:

(۱۸)

$$\text{Maximize}(\mathbf{t}^T \mathbf{u}) \Rightarrow \text{Maximize}(\mathbf{w}^T \Phi(\mathbf{X})^T \mathbf{Y} \mathbf{q})$$

حل این مساله مشابه PLS خطی است و تنها کافی است که همه جا در روابط قبلی به جای \mathbf{X} ، $\Phi(\mathbf{X})$ جایگذاری شود [۲۹-۲۸].

لازم به ذکر است که در این پژوهش، در هر سه روش کرنلی از تابع گوسی استفاده شده و مقدار عرض بهینه آن با روش اعتبار سنجی متقابل^{۳۱} بدست آمده است.

۳- آزمایش

۳-۱- توصیف داده‌ها

در این مقاله، از داده‌های پژوهش آقای خراسانی و همکاران که در آزمایشگاه علوم اعصاب دانشگاه علم و صنعت ایران ثبت گردیده استفاده شده و هدف، رمزگشایی نیروی دست موش صحرائی با استفاده از سیگنال‌های پتانسیل میدانی محلی ثبت شده از قشر حرکتی حیوان می‌باشد [۳۰]. تعداد ۳ عدد موش صحرائی ویستار^{۳۲} نر، آموزش دیده‌اند که تکلیف^{۳۳} فشردن^{۳۴} را انجام دهند. موش‌ها درون یک محفظه قرار می‌گیرند که در آن

های خطی رگرسیون ستینی، PCR و PLS را غیرخطی کرده و از آنها برای تخمین نیرو استفاده کرده‌ایم. در روش ستینی کرنلی، ابتدا با استفاده از تابع گوسی، متغیرها از فضای \mathbf{X} به فضای غیرخطی $\Phi(\mathbf{X})$ برده می‌شوند و سپس جریمه ستینی مشابه رابطه ۳ در این فضا اعمال می‌شود:

$$\beta_{\text{kernel ridge}} = (\Phi(\mathbf{X})^T \Phi(\mathbf{X}) + \lambda \mathbf{I})^{-1} \Phi(\mathbf{X})^T \mathbf{Y} \quad (10)$$

در روش PCR کرنلی، برای در نظر گرفتن اثرات غیرخطی از تابع کرنل برای استخراج مولفه‌های اساسی غیرخطی^{۲۹} استفاده می‌شود. بدین صورت که ابتدا ویژگی‌ها توسط تابع کرنل به فضای با ابعاد بالاتر برده شده و سپس مولفه‌های اساسی در این فضا محاسبه می‌شوند [۲۷]. برای بدست آوردن مولفه‌های اساسی غیرخطی، مانند PCA ابتدا لازم است که ماتریس کوارینانس $\hat{\mathbf{C}}$ در فضای تبدیل یافته $\Phi(\mathbf{X})$ محاسبه شود:

(۱۱)

$$\hat{\mathbf{C}} = \frac{1}{n} \sum_{i=1}^n \Phi(x_i) \Phi(x_i)^T$$

که در رابطه فوق، n تعداد نمونه‌ها می‌باشد. سپس تجزیه مقدار ویژه^{۳۰} با بردارهای ویژه \mathbf{V} و ثابت حقیقی λ بدین صورت انجام می‌شود:

(۱۲)

$$\lambda \mathbf{V} = \hat{\mathbf{C}} \mathbf{V}$$

با تعریف ماتریس کرنل $\mathbf{K} \in \mathbb{R}^{n \times n}$ به صورت زیر داریم:

(۱۳)

$$\mathbf{K}_{ij} = (\Phi(x_i) \cdot \Phi(x_j)) := \mathbf{K}(x_i, x_j)$$

با توجه به رابطه فوق، می‌توان تجزیه به بردارهای ویژه را بدین صورت بازنویسی کرد:

(۱۴)

$$n \lambda \alpha = \mathbf{K} \alpha$$

که در آن بردار α به گونه‌ای تعریف می‌شود که رابطه زیر را با بردار ویژه \mathbf{V} داشته باشد:

(۱۵)

$$\mathbf{V} = \sum_{i=1}^n \alpha_i \Phi(x_i)$$

بدین صورت تصویر $\Phi(\mathbf{X})$ بر روی k امین مولفه اساسی غیرخطی \mathbf{V}^k بدین صورت محاسبه می‌شود:

(۱۶)

^{۳۱} Cross-validation

^{۳۲} Vistar rat

^{۳۳} Task

^{۳۴} Push

^{۲۹} Nonlinear principle components

^{۳۰} Eigenvalue decomposition

(۱۹)

$$y'_{ch}(t) = y_{ch}(t) - \frac{1}{M} \sum_{i=1}^{M=16} y_i(t)$$

در رابطه فوق، $y_{ch}(t)$ نشان دهنده سیگنال اولیه LFP در هر کانال در لحظه t ، M تعداد کانالها و $y'_{ch}(t)$ نشان دهنده سیگنال LFP فیلتر شده توسط روش CAR می باشد.

۳-۳- استخراج ویژگیها

برای رمزگشایی پیوسته نیرو، از تغییرات توان سیگنال مغزی در باندهای مختلف فرکانسی که با تغییرات نیرو رخ می دهد استفاده می شود. در این پژوهش برای محاسبه ویژگیهای توان باند، سیگنال LFP در ۶ زیرباند فرکانسی (۴-۱ هرتز) δ و (۸-۴ هرتز) θ و (۱۲-۸ هرتز) α و (۳۰-۱۲ هرتز) β و (۱۲۰-۳۰ هرتز) γ low و (۲۰۰-۱۲۰ هرتز) γ high فیلتر شده و پوش سیگنال برای هر باند محاسبه می شود. یعنی ابتدا سیگنال یکسو شده و سپس با استفاده از فیلتر Savitzky-Golay با درجه ۳ و عرض 3^8 ۱۰۰ میلی ثانیه، نرم 3^9 شده و پوش سیگنال محاسبه می شود. بدین صورت برای هر نمونه زمانی، ۹۶ ویژگی (۱۶ کانال * ۶ زیرباند فرکانسی) استخراج شده و سپس با استفاده از روش z-score نرمال می شود. با توجه به اینکه مقدار نیرو در لحظه t به سیگنال مغزی در لحظات قبل از t وابسته است، برای رمزگشایی نیرو در لحظه t ، ۱۰ نمونه قبلی آن نیز در نظر گرفته شده است. در نتیجه برای پیش بینی نیرو در هر لحظه از زمان، از ۹۶۰ ویژگی (۱۶ کانال * ۶ زیرباند فرکانسی * ۱۰ تاخیر زمانی 4^0) استفاده شده و ابعاد ماتریس ویژگیها برابر $960 * L$ می باشد که L تعداد نمونههای زمانی است.

۳-۴- معیارهای ارزیابی دقت رمزگشایی

ضریب همبستگی f^1 بین نیروی واقعی ثبت شده f و نیروی تخمین زده شده f^1 به عنوان معیار عملکرد هر یک از روشهای رگرسیون به صورت زیر محاسبه می شود:

(۲۰)



$$CC = \frac{\sum_{i=1}^n (f_i - \text{mean}(f_i)) * (f_i^1 - \text{mean}(f_i^1))}{\sqrt{\sum_{i=1}^n (f_i - \text{mean}(f_i))^2} * \sqrt{\sum_{i=1}^n (f_i^1 - \text{mean}(f_i^1))^2}}$$

یک حسگر^{۳۵} نیرو متصل به یک کلید کار گذاشته شده است و یاد می گیرند که با فشردن کلید، می توانند مقداری آب به عنوان پاداش دریافت کنند. پس از اینکه موش فرآیند آزمایش را یاد گرفت، آماده ورود به مرحله بعد است که ثبت سیگنال مغزی از ناحیه forelimb در بخش حرکتی کورکتس حیوان می باشد. برای ثبت سیگنال مغزی، از آرایه میکرو وایر^{۳۶} (Microprobes Inc., Gaithersburg, USA) استفاده شده است. پس از گذشت دو هفته از جراحی، موش برای انجام تکلیف، درون محفظه طراحی شده قرار گرفته و سیگنالهای مغزی و نیروی دست او به طور همزمان ثبت می شود. نرخ نمونه برداری سیگنال مغزی ۱۰ کیلوهرتز و نرخ نمونه برداری نیرو ۳۰ هرتز بوده و از همگام سازی TTL^{۳۶} برای سنکرون کردن دادهها استفاده شده است. همچنین برای استخراج مولفه های LFP، سیگنال مغزی خام از فیلتر میان گذر (۳۰۰-۳۰۰۰ هرتز) گذرانده شده تا مولفه های فرکانس بالای آن (اسپایک) حذف گردد [۳۰]. برای رمزگشایی نیروی دست موش اول تا سوم به ترتیب از ۷۴، ۷۹ و ۸۰ ترايال استفاده شده که زمان هر ترايال ۳ ثانیه می باشد [۳۰].

۳-۲- پیش پردازش دادهها

در مرحله پیش پردازش لازم است که تغییراتی بر روی سیگنال مغزی و نیروی ثبت شده اعمال گردد. بدین منظور برای حذف dc و همچنین نویزهای فرکانس بالا از سیگنال مغزی، از فیلتر میان گذر باترورث درجه ۴ (۵۰۰-۰/۱ هرتز) استفاده شده است. همچنین با توجه به توان ناچیز سیگنال نیرو در فرکانس های بالاتر از ۱۰ هرتز، سیگنال نیروی ثبت شده، ابتدا با فیلتر پایین گذر باترورث درجه ۴ با فرکانس قطع ۵ هرتز فیلتر شده و سپس نرخ نمونه برداری به ۱۰ هرتز کاهش یافته است. هدف پژوهش، پیش بینی مقدار نیروی دست موش از روی سیگنال های LFP می باشد، بنابراین بهتر است که ابتدا سیگنال های LFP حذف نویز شوند. برای این کار از روش مرجع میانگین مشترک^{۳۷} استفاده شده است. میانگین سیگنال LFP در همه کانالها را می توان به عنوان تخمینی از نویز در نظر گرفت و با کم کردن این میانگین از همه کانالها، اثر نویز را خنثی نمود.

^{۳۸} Width^{۳۹} Smooth^{۴۰} Time lag^{۴۱} Correlation coefficient^{۳۵} Sensor^{۳۶} TTL-synchronization^{۳۷} Common average reference (CAR)



می‌دهد. با توجه به نتایج، مشاهده می‌شود که استفاده از روش رمزگشایی غیرخطی موجب شکل (۱) - میانگین و خطای استاندارد ضرایب همبستگی و R^2 بین نیروی تخمین زده شده و اندازه گیری شده با استفاده از روش رگرسیون ستیغی و ستیغی کرنلی

بهبود دقت شده است. درصد بهبود جواب برای میانگین ضریب همبستگی ۴٫۳٪ و برای میانگین R^2 به میزان ۱۲٫۷٪ می‌باشد. برای بررسی بیشتر، از آزمون آماری غیرپارامتری ویلکاکسون برای نتایج CC و R^2 نیز استفاده شده است. نتایج آزمون نشان می‌دهد که عملکرد روش رگرسیون ستیغی کرنلی، تفاوت معناداری نسبت به ستیغی داشته است ($p\text{-value} < 10^{-2}$).

شکل ۲ ضرایب همبستگی و R^2 برای روش PCR و PCR کرنلی را نشان می‌دهد. با توجه به نتایج، مشاهده می‌شود که در این روش نیز، استفاده از تابع کرنل موجب بهبود دقت رمزگشایی شده است. درصد بهبود جواب برای میانگین ضریب کورولیشن ۵٫۹٪ و برای میانگین R^2 به میزان ۲۵٫۵٪ می‌باشد. نتایج آزمون ویلکاکسون نیز نشان می‌دهد که عملکرد روش PCR کرنلی تفاوت معناداری نسبت به PCR داشته است ($p\text{-value} < 10^{-4}$).

شکل ۳ ضرایب همبستگی و R^2 برای روش PLS و PLS کرنلی را نشان می‌دهد. با توجه به نتایج، مشاهده می‌شود که در این روش نیز، استفاده از تابع کرنل موجب بهبود دقت رمزگشایی شده است. درصد بهبود جواب برای میانگین ضریب کورولیشن ۴٫۴٪ و برای میانگین R^2 به میزان ۱۹٫۱٪ می‌باشد. نتایج آزمون ویلکاکسون نیز نشان می‌دهد که عملکرد روش PLS کرنلی تفاوت معناداری نسبت به PLS داشته است ($p\text{-value} < 10^{-2}$).

برای مقایسه روش‌های کرنلی با یکدیگر، نتایج رمزگشایی در

که در رابطه فوق، صورت کسر همان کواریانس متقابل بین نیروی واقعی و نیروی تخمین زده شده و مخرج کسر نیز، جذر واریانس هر کدام از نیروها می‌باشد. مقدار CC در واقع نشان‌دهنده میزان شباهت شکلی سیگنال واقعی و تخمین زده شده می‌باشد.

معیار دیگر برای ارزیابی دقت رمزگشایی، R^2 می‌باشد که نشان می‌دهد چه میزان از تغییرات نیروی واقعی ثبت شده توسط نیروی تخمین زده شده قابل توصیف است. (۲۱)

$$R^2 = 1 - \frac{\sqrt{\sum_{i=1}^n (f_i - \hat{f}_i)^2}}{\sqrt{\sum_{i=1}^n (f_i - \text{mean}(f))^2}}$$

R^2 عددی بین ۰ و ۱ است که هر چقدر مقدار آن به ۱ نزدیکتر باشد، نشان دهنده کمتر بودن خطای تخمین می‌باشد.

در این پژوهش برای ارزیابی دقت رمزگشایی از دو معیار فوق استفاده شده است. همچنین داده‌های موجود ۱۰ بار به صورت تصادفی مخلوط^{۴۳} شده و در هر بار تکرار از روش اعتبارسنجی متقابل ۱۰ لایه نیز^{۴۴} استفاده شده است.


۴- نتایج

در این بخش، نتایج رمزگشایی نیروی دست موش صحرائی با توجه به سیگنال‌های LFP مغزی او با استفاده از مدل‌های خطی رگرسیون ستیغی، PCR و PLS و تعمیم‌یافته کرنلی آنها ارائه شده است. شکل ۱ ضرایب همبستگی و ضرایب R^2 برای روش ستیغی و ستیغی کرنلی برای سه موش صحرائی را نشان-

^{۴۱} Coefficient of determination

^{۴۳} Shuffle

^{۴۴} 10-fold cross validation



Kernel ridge	0.62 ± 0.008	0.72 ± 0.006
Kernel PCR	0.59 ± 0.013	0.71 ± 0.006
Kernel PLS	0.56 ± 0.007	0.70 ± 0.006

۵- بحث و نتیجه‌گیری

در این پژوهش، اثر استفاده از سه روش رگرسیون غیرخطی مبتنی بر توابع کرنل برای رمزگشایی نیروی دست موش صحرائی بررسی شده و مقایسه‌ای بین روش‌های خطی و غیرخطی انجام گرفت. نتایج بدست آمده نشان می‌دهد که در همه روش‌ها، غیرخطی سازی مدل با استفاده از تابع کرنل گوسی موجب افزایش دقت رمزگشایی شده است و در بین روش‌های کرنلی نیز، رگرسیون ستیغی کرنلی دقت بهتری دارد. همانطور که در بخش مقدمه ذکر شد، مدل‌های خطی به علت سادگی و مقاوم بودن نسبت به بیش‌برازش، در کاربردهای BCI بیشتر مورد استفاده قرار می‌گیرند. مزیت استفاده از مدل غیرخطی به جای خطی، در نظر گرفتن برخی روابط غیرخطی بین ویژگی‌هاست که می‌تواند باعث افزایش دقت رمزگشایی گردد. اما مشکل این روش‌ها، علاوه بر افزایش پیچیدگی محاسباتی این است که می‌تواند موجب بیش‌برازش شوند. برای حل این مشکل می‌توان از روش‌های جریمه و تنک‌سازی^{۴۵} جواب استفاده نمود و مدل غیرخطی را ارائه کرد که خاصیت تعمیم‌پذیری بهتری نیز داشته باشد که این امر می‌تواند موضوعی برای پژوهش‌های پیش‌رو باشد.

شکل (۳) - میانگین و خطای استاندارد ضرایب همبستگی و R^2 بین نیروی تخمین زده شده و اندازه گیری شده با استفاده

جدول ۱ ارائه شده است. بهترین دقت رمزگشایی با استفاده از روش ستیغی کرنلی (میانگین ضریب همبستگی 0.72 و R^2 برابر 0.62) بدست آمده است. نتایج آزمون ویلکاکسون نشان می‌دهد که تفاوت مقادیر بدست آمده معنادار می‌باشد ($p < 10^{-4}$).

برای مقایسه مدل‌های خطی و غیرخطی از نظر زمان محاسبات، مدت زمان پیش‌بینی نیرو با استفاده از 100 ثانیه سیگنال LFP توسط هر مدل رگرسیون را محاسبه کرده و میانگین این عدد در 100 بار تکرار را با یکدیگر مقایسه کرده‌ایم. زمان بدست آمده برای روش ستیغی برابر 6.53 ثانیه، برای روش ستیغی کرنلی برابر 12.81 ثانیه، برای روش PCR برابر 6.16 ثانیه، برای روش PLS برابر 9.22 ثانیه، برای روش PLS برابر 5.18 ثانیه و برای روش PLS کرنلی برابر 9.15 ثانیه بوده است. با توجه به نتایج مشاهده می‌شود که مدل‌های غیرخطی نسبت به مدل‌های خطی زمان محاسباتی بیشتری دارند و در بین روش‌های

غیرخطی نیز، روش ستیغی کرنلی بیشترین پیچیدگی شکل (۲) - میانگین و خطای استاندارد ضرایب همبستگی و R^2 بین نیروی تخمین زده شده و اندازه گیری شده با استفاده از

روش PCR و PCR کرنلی

محاسباتی را دارد.


شکل ۴ نمونه‌ای از نیروی تخمین زده شده با بهترین روش تخمین ارائه شده یعنی ستیغی کرنلی به ازای بیشترین مقدار R^2 را نمایش می‌دهد. مشاهده می‌شود که نیروی تخمین زده شده با دقت مناسبی تغییرات نیروی واقعی را دنبال می‌کند.

جدول (۱) - میانگین و خطای استاندارد نتایج رمزگشایی نیرو

با روش های کرنلی

	R^2	CC

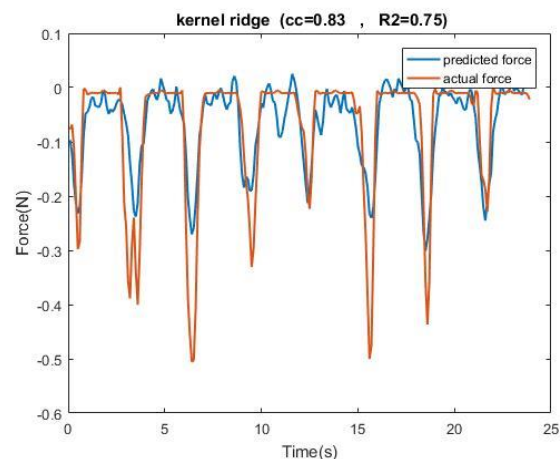
^{۴۵} Sparse



از روش PLS و کرنلی

from hybrid signals in motor and premotor cortices: spikes, multiunit activity, and local field potentials,” *Journal of Neurophysiology*, vol. 107, pp. 1337–1355, 2012.

- [6] M. Saleh, K. Takahashi, N.G. Hatsopoulos, “Encoding of coordinated reach and grasp trajectories in primary motor cortex,” *Journal of Neuroscience*, vol.32, pp. 1220–1232, 2012.
- [7] C.E. Vargas-Irwin, G. Shakhnarovich, P. Yadollahpour, J.M. Mislow, M.J. Black, J.P. Donoghue, “Decoding complete reach and grasp actions from local primary motor cortex populations,” *Journal of Neuroscience*, vol.30, pp. 9659–9669, 2010.
- [8] M. Mollazadeh, V. Aggarwal, A.G. Davidson, A.J. Law, N.V. Thakor, M.H. Schieber, “Spatiotemporal variation of multiple neurophysiological signals in the primary motor cortex during dexterous reach-to-grasp movements,” *Journal of Neuroscience*, vol. 31, pp. 15531–15543, 2011
- [9] R.D. Flint, E.W. Lindberg, L.R. Jordan, L.E. Miller, M.W. Slutzky, “Accurate decoding of reaching movements from field potentials in the absence of spikes,” *Journal of Neural Engineering*, vol 9, 2012.
- [10] R.D. Flint, C. Ethier, E.R. Oby, L.E. Miller, M.W. Slutzky, “Local field potentials allow accurate decoding of muscle activity,” *Journal of Neurophysiology*, vol. 108, pp. 18–24 2012.
- [11] C. Mehring, J. Rickert, E. Vaadia, S. Cardoso de Oliveira, A. Aertsen, S. Rotter, “Inference of hand movements from local field potentials in monkey motor cortex,” *Nature Neuroscience*, vol. 6, pp. 1253–1254, 2003.
- [12] D.A. Markowitz, Y.T. Wong, C.M. Gray, B. Pesaran, “Optimizing the decoding of movement goals from local field potentials in macaque cortex,” *Journal of Neuroscience*, vol. 31, pp. 18412–18422, 2011.
- [13] A.K. Bansal, C.E. Vargas-Irwin, W. Truccolo, J.P. Donoghue, “Relationships among low-frequency local field potentials, spiking activity,



شکل (۴) - نمونه ای از نیروی اندازه گیری شده و تخمین زده شده با استفاده از روش رگرسیون ستیغی کرنلی.

۵- مراجع

- [1] J. Wolpaw, E.W. Wolpaw, “Brain-computer interfaces: principles and practice,” OUP; USA: 2012.
- [2] R. D. Flint, P.T Wang, Z. A. Wright. “Extracting kinetic information from human motor cortical signals” *Neuroimage*, vol. 101, pp. 695-703, 2014.
- [3] J.M. Carmena, M.A. Lebedev, R.E. Crist, J.E. O’Doherty, D.M. Santucci, D.F. Dimitrov, P.G. Patil, C.S. Henriquez, M.A. Nicolelis, “Learning to control a brain-machine interface for reaching and grasping by primates,” *PLoS Biology*, vol. 1, pp. 1–16,2003.
- [4] R. Gupta , J. Ashe, “Offline Decoding of End-Point Forces Using Neural Ensembles: Application to a Brain-Machine Interface,” *IEEE Transaction on Neural System and Rehabilitation Engineering* , vol. 17, no. 3 ,2009
- [5] A.K. Bansal, W. Truccolo, C.E. Vargas-Irwin, J.P. Donoghue, “Decoding 3D reach and grasp

- Transactions on Neural Systems and Rehabilitation Engineering, Vol 23, num. 5, 2014.
- [25] J. M. H. F. Bießmann, N. Jiang, H. Rehbaum, D. Farina, F. C. Meinecke, K. R. Müller, L. C. Parra, "Linear and Nonlinear Regression Techniques for Simultaneous and Proportional Myoelectric Control", IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 23, num. 2, 2014.
- [26] S. A. Shah, .Tan, G. Tinkhauser, P. Brown, "Towards Real-Time, Continuous Decoding of Gripping Force From Deep Brain Local Field Potentials", IEEE Transactions on Neural Systems and Rehabilitation Engineering, Vol. 26, issue 7, 2018.
- [27] B. Scholkopf, A. Smola, K. R. Müller. 'Nonlinear Component Analysis as a Kernel Eigenvalue Problem'. Neural Computation, vol 10, num 5, pp 1299-1319, 1998.
- [28] R. Rosipal and L. J. Trejo. 'Kernel Partial Least Squares Regression in Reproducing Kernel Hilbert Space'. Journal of Machine Learning Research, pp 97-123. 2001.
- [29] B. V. Srinivasan, Y. C. Luo, D. G. Romero. 'A Symmetric Kernel Partial Least Squares Framework for Speaker RECoGnition', IEEE Transactions on Audio, Speech, and Language Processing, vol 21, num 7, pp 1415-1423, 2013.
- [30] A. Khorasani, N. Heydari Beni, V. Shalchyan, M. R. Daliri. "Continuous Force Decoding from Local Field Potentials of the Primary Motor Cortex in Freely Moving Rat". Scientific Reports, 2016.
- and three-dimensional reach and grasp kinematics in primary motor and ventral premotor cortices," Journal of Neurophysiology, vol. 105, pp. 1603–1619, 2011.
- [14] J. Rickert, S. C. Oliveira, E. Vaadia, A. Aertsen, S. Rotter, C. Mehring, "Encoding of movement direction in different frequency ranges of motor cortical local field potentials," Journal of Neuroscience, vol. 25, pp. 8815–8824, 2005.
- [15] C. Mehring, M. P. Nawrot, S. C. de Oliveira, E. Vaadia, A. Schulze-Bonhage, A. Aertsen, T. Ball, "Comparing information about arm movement direction in single channels of local and epicortical field potentials from monkey and human motor cortex," Physiology Paris, vol. 98, pp. 498–506, 2004.
- [16] J. Zhuang, W. Truccolo, C. Vargas-Irwin, J. P. Donoghue, "Decoding 3-D reach and grasp kinematics from high frequency local field potentials in primate primary motor cortex," IEEE Transaction on Biomedical Engineering, vol. 57, pp. 1774–1784, 2010.
- [17] T. Milecovic, W. Truccolo, "Local field potentials in primate motor cortex encode grasp kinetic parameters," Neuroimage, vol. 114, pp. 338-355, 2015.
- [18] A. Khorasani, N. Heydari Beni, V. Shalchyan, M. R. Daliri, "Continuous Force Decoding from Local Field Potentials of the Primary Motor Cortex in Freely Moving Rat," Scientific Reports, 2016.
- [19] S. A. Shah, H. Tan, P. Brown. "Continuous Force Decoding from Deep Brain Local Field Potentials for Brain Computer Interfacing," International IEEE EMBS Conference in Neural Engineering, pp. 371–374, 2017.
- [20] R. D. Flint, P. T. Wang, Z. A. Wright, "Extracting kinetic information from human motor cortical signals," Neuroimage, vol. 101, pp. 695-703, 2014.
- [21] Ch. Chen, D. Shin. "Decoding grasp force profile from electrocorticography signals in non-human primate sensorimotor cortex," Neuroscience Research, vol. 83, 1-7, 2014.
- [22] J. Wessberg, C. R. Stambaugh, J. D. Kralik, P. D. Beck, M. Laubach, J. K. Chapin, et al., "Real-time prediction of hand trajectory by ensembles of cortical neurons in primates," Nature, vol. 408, pp. 361-365, 2000.
- [23] R. D. Flint, E. W. Lindberg, L. R. Jordan, L. E. Miller, M. W. Slutzky, "Accurate decoding of reaching movements from field potentials in the absence of spikes," Journal of neural engineering, vol 9, 2012.
- [24] J. H. Kim, F. Bießmann, S. W. Lee, "Decoding Three-Dimensional Trajectory of Executed and Imagined Arm Movements from Electroencephalogram Signals", IEEE