

## استخراج ویژگی‌ها با استفاده از اطلاعات متقابل جهت طبقه‌بندی سیگنال‌های مغزی در سیستم‌های ارتباطی مغز با کامپیوتر

فرید اویسی ارنگه      عباس عرفانیان امیدوار

دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران

### چکیده

از عوامل مهم در دقت و کارایی طبقه‌بندی کننده‌ها، کاهش ابعاد فضای ویژگی است. کاهش هزینه محاسباتی و دقت طبقه‌بندی، دو دلیل عمده کاهش بعد فضای ویژگی است. به طور کلی دو روش برای کاهش ابعاد فضای ویژگی وجود دارد: انتخاب ویژگی و استخراج ویژگی. در روش انتخاب ویژگی‌ها، ویژگی‌هایی که در طبقه‌بندی مفید هستند، از یک مجموعه کامل ویژگی انتخاب می‌شوند. در روش استخراج ویژگی، ویژگی‌های جدیدی با استفاده از ویژگی‌های اولیه تولید می‌شود. در این تحقیق از یک الگوریتم استخراج ویژگی با استفاده از اطلاعات متقابل برای طبقه‌بندی سیگنال‌های مغزی در سیستم‌های ارتباطی مغز با کامپیوتر مورد استفاده قرار گرفته است. هدف در این سیستم، تشخیص تصور بستن پنجه دست و حالت استراحت ذهنی با استفاده از سیگنال‌های مغزی است. برای این منظور، آزمایشات مختلفی بر روی چهار فرد سالم در روزهای مختلف انجام شده است. نتایج نشان می‌دهد که عملکرد طبقه‌بندی کننده با استفاده از ویژگی‌های استخراج شده به وسیله اطلاعات متقابل نسبت به عملکرد طبقه‌بندی کننده با مجموعه کامل ویژگی بهبود قابل توجهی داشته است. علاوه بر این، عملکرد استخراج ویژگی مبتنی بر اطلاعات متقابل با روش استخراج ویژگی آنالیز مولفه‌های اصلی در طبقه‌بندی سیگنال‌های مغزی مقایسه شده، نتایج، برتری کامل استخراج ویژگی مبتنی بر اطلاعات متقابل را نسبت به روش آنالیز مولفه‌های اصلی نشان می‌دهد.

**کلمات کلیدی:** استخراج ویژگی، اطلاعات متقابل، طبقه‌بندی، ارتباط مغز با کامپیوتر، سیگنال‌های مغزی.

### ۱- مقدمه

پتانسیل‌های آهسته مغزی [۴]، مولفه‌های نوسانی EEG [۵]، [۶]، [۷]، و انواع مختلف پتانسیل‌های برانگیخته شامل پتانسیل آمادگی [۸]، پتانسیل برانگیخته بینایی [۹]، و P300 [۱۰] در سیستم‌های مختلف BCI بکار گرفته شده است. استخراج ویژگی برای طبقه‌بندی سیگنال‌های مغزی ناشی از فعالیت‌های ذهنی، نقش مهمی را در کارایی سیستم‌های BCI ایفا می‌کند. ویژگی‌های بی‌ربط یا اضافی، باعث پیچیدگی فرآیند طبقه‌بندی و وجود خطا در فرآیند پیش‌بینی می‌شود. حتی زمانی که ویژگی‌های ارائه شده دارای اطلاعات کافی درباره کلاس خروجی باشند، ممکن است به علت بزرگی ابعاد فضای ویژگی، خروجی به درستی پیش‌بینی نشود. هم چنین بعضی از آزمایشات نشان داده است که با اضافه کردن یک ویژگی بی‌ربط عملکرد سیستم‌های طبقه‌بندی کننده بدتر می‌شود [۱۱].

در سال‌های اخیر کوشش‌های زیادی جهت استفاده از سیگنال‌های مغزی به عنوان یک کانال جدید ارتباطی بین انسان و کامپیوتر تحت عنوان ارتباط مغز با کامپیوتر<sup>۱</sup> انجام گرفته و مقالات فراوانی در این رابطه انتشار یافته است [۱]، [۳]. بسیاری از این کوشش‌ها در جهت افزایش کارایی سیستم‌های BCI انجام گرفته است. کارایی چنین سیستم‌هایی به چند عامل مهم بستگی دارد. این عوامل شامل نوع سیگنال مغزی است که به عنوان ورودی به سیستم BCI استفاده می‌شود، روش‌های پردازش سیگنال جهت استخراج و یا انتخاب ویژگی، روش طبقه‌بندی ویژگی‌ها، فعالیت ذهنی، و آموزش شخص است. انواع مختلف سیگنال‌های مغزی جهت تشخیص فعالیت ذهنی بکار گرفته شده است. تاکنون از

بهینه تمیز دهنده است. این روش، بیشتر از  $N_c - 1$  قادر به استخراج ویژگی نیست، در حالیکه  $N_c$  تعداد کلاس‌ها است.

اخیراً روش تحلیل مولفه‌های مستقل<sup>۸</sup> [۱۹]، که برای جداسازی کور منابع اندیشه شده است، به علت کاربرد گسترده آن، بسیار مورد توجه قرار گرفته است. ICA یک روش آماری است که داده‌های تصادفی مشاهده شده را به مولفه‌هایی تبدیل می‌کند که تا حد امکان از هم مستقل باشند. بل و سچونسکی [۱۹] یک الگوریتم یادگیری بدون معلم برای تحلیل مولفه‌های مستقل ارائه کرده است. این الگوریتم بر اساس بیشینه کردن آنترپپی در یک شبکه عصبی پیشرو تک لایه است. خروجی‌های ICA یک مجموعه از بردارهای مستقل است که ترکیب خطی از داده‌های مشاهده شده می‌باشد. این روش در جداسازی کور منابع و حذف انواع آرتیفک بطور گسترده استفاده شده است. اما ICA معمول برانزده استخراج ویژگی برای مسائل طبقه‌بندی نیست. زیرا که آن یک روش یادگیری بدون معلم است و اطلاعات کلاس‌ها را در تخمین ماتریس ترکیب بکار نمی‌برد.

محققین سعی کرده‌اند با استفاده از تحلیل مولفه‌های مستقل روش‌هایی برای استخراج ویژگی ارائه دهند که ویژگی‌ها علاوه بر اینکه از یکدیگر مستقل باشند، دارای حداکثر اطلاعات درباره کلاس باشند. در این راستا، در مرجع [۱۱] روشی برای استخراج ویژگی بر مبنای تحلیل مولفه‌های مستقل ارائه شده است. در این روش، متغیرهای ورودی با یک تبدیل خطی به دو دسته ویژگی تبدیل می‌شوند. یک دسته دارای حداکثر اطلاعات در مورد کلاس خروجی و دسته دیگر تا حد امکان نسبت به کلاس مستقل هستند.

این روش محدود به دو کلاس است. از این روش برای استخراج ویژگی از سیگنال‌های مغزی در حین تصور حرکت دست در سیستم‌های ارتباطی مغز با کامپیوتر استفاده شده است [۲۰]. هدف اصلی در استخراج ویژگی، تولید ویژگی‌هایی است که حداقل اطلاعات متقابل را بین هم داشته باشند و در عین حال حداکثر اطلاعات متقابل با کلاس خروجی. به این منظور در مرجع [۲۱]، ابتدا با استفاده از روش ICA ویژگی‌های مستقل ایجاد شده، سپس ویژگی‌های با حداکثر اطلاعات متقابل با کلاس خروجی انتخاب شده است. اما باید توجه داشت که کمینه کردن اطلاعات مشترک بین ویژگی‌ها با استفاده از ICA بطور کامل انجام نمی‌شود [۲۲].

روش‌هایی که از آمارگان درجه دوم استفاده می‌کنند، رابطه خطی بین متغیرهای تصادفی را مقایسه می‌کنند، در حالیکه روش‌های مبتنی بر نظریه اطلاعات رابطه غیرخطی بین متغیرهای تصادفی را در نظر می‌گیرند، به عنوان مثال بین یک بردار ویژگی و کلاس. یک شاخص برای روش‌های مبتنی بر نظریه اطلاعات، استفاده از اطلاعات متقابل است. اطلاعات متقابل یک روش غیرپارامتریک برای اندازه‌گیری میزان وابستگی بین دو متغیر تصادفی است. چنانچه دو متغیر تصادفی مستقل باشند، مقدار اطلاعات متقابل صفر خواهد بود. هدف از استخراج ویژگی با استفاده از اطلاعات متقابل، تولید ویژگی‌هایی است که بطور مشترک دارای حداکثر وابستگی را به کلاس خروجی داشته باشند. علی‌الرغم مزیت‌های اطلاعات متقابل، تخمین اطلاعات متقابل با بعد بالا بطور دقیق غیر ممکن است.

تخمین اطلاعات متقابل بین دو متغیر از طریق هیستوگرام قابل انجام است. اما به علت پراکندگی توزیع داده‌ها در فضای با بعد بالا، تخمین زنده‌های مبتنی بر هیستوگرام قابل اعتماد نیستند [۲۳]. به منظور رفع این مشکل، از تخمین آنترپپی معرفی شده توسط رینی همراه با تخمین پنجره پارزن برای تخمین اطلاعات متقابل استفاده شده است [۱۲]، [۲۴].

ما در این مقاله از این روش تخمین اطلاعات متقابل به منظور استخراج ویژگی از سیگنال‌های مغزی برای سیستم‌های ارتباطی مغز با کامپیوتر استفاده کرده‌ایم. اطلاعات متقابل بین کلاس‌های خروجی و ویژگی‌های استخراج شده به

به طور کلی دو روش برای کاهش بعد فضای ویژگی وجود دارد. روش اول که انتخاب ویژگی<sup>۲</sup> نامیده می‌شود، از میان بردار کامل ویژگی‌ها، تعدادی که در طبقه‌بندی کلاس‌ها مفید هستند انتخاب می‌شوند. در روش دوم که استخراج ویژگی<sup>۳</sup> نامیده می‌شود ویژگی‌های جدیدی با استفاده از مجموعه ویژگی‌های اصلی ساخته می‌شوند. روش‌های کاهش بعد را می‌توان از جنبه‌ای دیگر به دو دسته فیلتر و پوشه‌ای<sup>۴</sup> تقسیم کرد. در روش‌های فیلتر، انتخاب یا استخراج ویژگی با ارزیابی یک شاخص انجام می‌شود [۱۲]. اما در روش‌های پوشه‌ای [۱۳]، کاهش بعد ویژگی با طبقه‌بندی کننده ترکیب می‌شود. در این روش ویژگی‌هایی انتخاب یا استخراج می‌شوند که خطای طبقه‌بندی کننده را حداقل سازند. روش‌های پوشه‌ای دو مشکل عمده دارند. اول اینکه این روش‌ها دارای بار محاسباتی زیادی هستند. دوم اینکه ویژگی‌های بدست آمده تنها برای طبقه‌بندی کننده خاص استفاده شده دارای حداقل خطا است [۱۴].

از روش‌های انتخاب و استخراج ویژگی در سیستم‌های ارتباطی مغز با کامپیوتر استفاده است. در مرجع [۱۵]، مولفه‌های فرکانسی به عنوان بردار ویژگی برای طبقه‌بندی سیگنال‌های مغزی در هنگام تصور حرکت دست راست و چپ استفاده شده است. در این کار از الگوریتم DSLVQ<sup>۵</sup> برای تعیین میزان وابستگی هر مولفه فرکانسی نسبت به کلاس استفاده شده است، سپس مولفه‌ای که بیشترین وابستگی را به کلاس داشته باشد، بطور دستی انتخاب شده است. نشان داده شده است که به طور کلی دقت طبقه‌بندی با ویژگی‌های انتخاب شده، بهتر از دقت طبقه‌بندی با تمام ویژگی‌ها است.

در مرجع [۸]، با استفاده از نظریه اطلاعات، جهت انتخاب ویژگی از یک بانک ویژگی شامل ۱۰۰۰ ویژگی استفاده شده است. اما این الگوریتم نتیجه قابل قبولی نداده است. از روش‌های پوشه‌ای نیز برای انتخاب ویژگی در سیستم‌های ارتباطی مغز با کامپیوتر استفاده شده است [۱۶]، [۸].

روش پوشه‌ای استفاده شده در این مقالات شامل SVM به عنوان طبقه‌بندی کننده و الگوریتم ژنتیک جهت جستجوی زیرمجموعه ویژگی، است. در مرجع [۱۶]، از متوسط توان در باندهای فرکانسی دلتا (۴-۲)، تتا (۸-۴)، آلفا در فرکانس‌های پایین (۱۲-۱۰)، آلفا در فرکانس‌های بالا (۱۲-۱۰)، بتا (۳۵-۱۲)، گاما (۵۰-۳۵) هرترز مربوط به ۳۰ کانال مغزی به عنوان مجموعه کامل ویژگی استفاده شده است. سپس با استفاده از الگوریتم ژنتیک تعدادی ویژگی انتخاب شده است.

هدف ما در این مقاله، استخراج ویژگی‌های مناسب از سیگنال‌های الکتروانسفالوگرام با استفاده از اطلاعات متقابل برای سیستم‌های ارتباطی مغز با کامپیوتر است. فعالیت ذهنی در نظر گرفته شامل حالت تصور بستن دست و حالت استراحت است. هدف، تشخیص این دو حالت ذهنی با استفاده از سیگنال‌های مغزی است.

## ۲- استخراج ویژگی

کاهش بعد فضای متغیرهای ورودی، یک مرحله مهم در فرآیند شناسایی و طبقه‌بندی الگوها است. یکی از روش‌های معمول کاهش بعد فضای داده‌ها و استخراج ویژگی، روش تحلیل مولفه‌های اصلی<sup>۶</sup> [۱۷] است. این روش به دنبال یک بازنمایی از داده‌ها بر حسب کوچکترین متوسط مربعات خطا بین داده‌های بازنمایی شده و اصلی است. لذا، PCA کاری به استخراج ویژگی‌های بهینه به منظور طبقه‌بندی ندارد. به عبارتی، این روش به منظور استخراج ویژگی و کاهش بعد، تنها به داده‌های ورودی توجه می‌کند و کلاس داده‌ها را در نظر نمی‌گیرد.

از روش‌های معمول و رایج استخراج ویژگی، تحلیل خطی تفکیک کننده<sup>۷</sup> [۱۸] است. این روش یک تبدیل خطی است که برای حالت‌های خاصی به طور

#### ۴- استخراج ویژگی بر مبنای اطلاعات متقابل

فرض کنید مجموعه ای از داده‌های آموزشی  $\{x_i, c_i\}$  به عنوان نمونه‌هایی از یک متغیر تصادفی پیوسته  $X(x_i \in R^D)$ ، و برچسب کلاس‌ها به عنوان نمونه‌های یک متغیر تصادفی گسسته  $C(c_i \in \{1, 2, \dots, N_c\}, i \in \{1, 2, \dots, N\})$  در اختیار باشد. هدف از استخراج ویژگی، پیدا کردن یک تبدیل  $g$ ، به طوری که  $f_i = g(w, x_i)$ ،  $f_i \in R^d$ ،  $d < D$ ، تبدیل شده  $F$  و برچسب کلاس‌ها  $C$ ،  $I(F, C)$  بیشینه شود. به منظور تحقق این، لازم است که  $I(F, C)$  به صورت تابعی از مجموعه داده‌ها و شکل قابل مشتق پذیر تخمین زده شود. سپس از این می‌توان با مشتق گرفتن از  $I(F, C)$  نسبت به پارامترهای تبدیل و استفاده از الگوریتم کمترین شیب<sup>۱۱</sup>، قاعده یادگیری استخراج ویژگی را بدست آورد:

$$w_{t+1} = w_t + \eta \frac{\partial I}{\partial w} = w_t + \eta \sum_{i=1}^N \frac{\partial I}{\partial f_i} \frac{\partial f_i}{\partial w} \quad (5)$$

این روال استخراج ویژگی در شکل ۱ نشان داده شده است.

#### ۴-۱- تخمین اطلاعات متقابل

برای محاسبه اطلاعات متقابل احتیاج به تخمین تابع چگالی احتمال<sup>۱۱</sup> وجود دارد. در بسیاری از مقالات از روش هیستوگرام برای تخمین تابع چگالی احتمال استفاده می‌شود که در آن عمل انتگرال برای سادگی به عمل جمع تبدیل شده است، اما دقت اکثر تخمین زنده‌های هیستوگرام به علت کمبود داده و پراکندگی توزیع داده در بعد بالا، ضعیف است. بنابراین تخمین زنده‌های هیستوگرام تنها در داده‌های با بعد پایین استفاده می‌شوند [۲۶]. در این مقاله برای محاسبه اطلاعات متقابل از تخمین انتروپی معرفی شده توسط رینی استفاده شده است [۱۲]. با جایگزینی انتروپی رینی در رابطه (۳)، تخمین اطلاعات متقابل به صورت ذیل حاصل می‌شود:

$$I(F; C) \cong H_2(C) - H_2(C|F) \quad (6)$$

در این رابطه،  $H_2(X)$  انتروپی Quadratic رینی است:

$$H_2(X) = -\log \frac{1}{N} \sum_{n=1}^N G(x(n) - x(n-1), 2\sigma^2) \quad (7)$$

همچنین می‌توان با استفاده از رابطه (۱۲) رابطه (۱۵) را بیان کرد.

$$H(X|C) = -\sum_{j=1}^{N_c} \left( \frac{N_j}{N_T} \log \frac{1}{N_j} \sum_{n=1}^{N_j} G(x_j(n) - x_j(n-1), 2\sigma^2) \right) \quad (8)$$

در این روابط،  $N_j$  تعداد الگوهای آموزشی مربوط به کلاس  $j$ ،  $N_T$  تعداد الگوهای آموزشی و  $N_c$  تعداد کلاس‌ها است. با قرار دادن رابطه (۶) و (۷) در رابطه (۵) برای  $I(X, C)$  رابطه زیر برحسب متغیر  $X$  حاصل می‌شود.

عنوان یک شاخص جهت گسترش قانون یادگیری برای استخراج کننده ویژگی بکار گرفته شده است. استخراج کننده ویژگی می‌تواند یک تبدیل خطی باشد که خروجی آن ویژگی‌های جدید باشند. قبل از ارائه روش استخراج ویژگی، در بخش بعد، مفاهیم پایه نظریه اطلاعات بطور مختصر بیان می‌شود.

#### ۳- مفاهیم پایه در نظریه اطلاعات

در فرآیند طبقه‌بندی، ویژگی‌هایی که اطلاعاتی در مورد کلاس داشته باشند می‌توانند به تفکیک کلاس‌ها کمک کنند، اما ویژگی‌هایی که اطلاعاتی در مورد کلاس ندارند، تنها سبب افزایش بعد فضای ویژگی شده و باعث کاهش کارایی طبقه‌بندی کننده می‌شود. برای اندازه‌گیری اطلاعات موجود در یک ویژگی مربوط به یک کلاس نیاز به ابزار جدیدی است. نظریه اطلاعات شانون<sup>۱۲</sup>، یک روش برای اندازه‌گیری اطلاعات متغیرهای تصادفی با استفاده از انتروپی و اطلاعات متقابل ارائه می‌کند [۲۵]. روش‌هایی که از آمارگان درجه دوم استفاده می‌کنند، رابطه خطی بین متغیرهای تصادفی را مقایسه می‌کنند، در حالیکه روش‌های مبتنی بر نظریه اطلاعات رابطه غیرخطی بین متغیرهای تصادفی را در نظر می‌گیرند، به عنوان مثال بین یک بردار ویژگی و کلاس.

چنانچه احتمال کلاس‌های مختلف  $p(c); c = 1, \dots, N_c$  باشد، میزان عدم قطعیت کلاس خروجی با انتروپی اندازه‌گیری می‌شود:

$$H(C) = -\sum_{c=1}^{N_c} p(c) \log p(c) \quad (1)$$

عدم قطعیت  $C$  با معلوم بودن بردار ویژگی  $f$  با استفاده از انتروپی شرطی به صورت ذیل اندازه‌گیری می‌شود.

$$H(C|F) = -\int p(f) \left( \sum_{c \in C} p(c|f) \log(p(c|f)) \right) df \quad (2)$$

در حالیکه  $p(c|f)$  احتمال شرطی متغیر  $C$  با فرض معلوم بودن  $f$  است. بطور کلی انتروپی شرطی کمتر و یا مساوی انتروپی اولیه است، هنگامی برابر است که دو متغیر  $C$  و  $f$  مستقل باشد. میزانی که عدم قطعیت کلاس کاهش می‌یابد، اطلاعات متقابل نامیده می‌شود و برابر است با

$$I(F; C) = H(C) - H(C|F) \quad (3)$$

اطلاعات متقابل را می‌توان بعد از اعمال مقادیر  $p(c, f) = p(c|f)p(f)$  و

$$p(c) = \int p(c, f) df$$

$$I(F; C) = \sum_{c \in C} \int p(c, f) \log \frac{p(c, f)}{p(c)p(f)} df \quad (4)$$

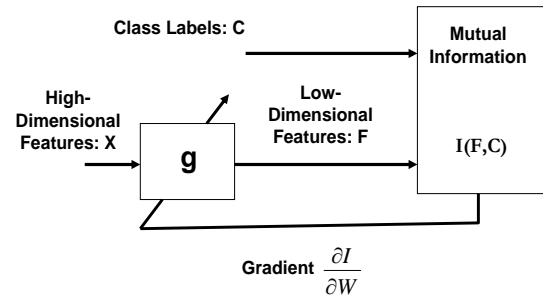
اگر اطلاعات متقابل بین دو متغیر بزرگ باشد، نشان دهنده وابسته بودن آن دو متغیر به یکدیگر خواهد بود. اطلاعات متقابل فقط در صورت مستقل بودن دو متغیر تصادفی صفر خواهد بود.

در این تحقیق، قدر مطلق دامنه (MAV)، واریانس، توان در هر یک از فرکانس‌های ۹-۲۸ Hz، ضرایب مدل AR از مرتبه ۵، تعداد عبور از صفر و تعداد اکسترمم‌های محلی به عنوان ویژگی برای طبقه‌بندی سیگنال‌های مغزی در حین تصور حرکت در نظر گرفته شده است. بعد از محاسبه ویژگی‌ها، ویژگی‌های مناسب با استفاده از روش ارائه شده استخراج شده و سپس از آنها برای آموزش و آزمون طبقه‌بندی کننده استفاده شده است. در این مقاله از طبقه بندی کننده معروف LDA قطری نرم افزار MATLAB [۲۹] برای طبقه‌بندی استفاده شده است. در هر روز آزمایشی، برای هر یک از دو حالت آرامش و تصور حرکت ۱۰۰ الگو و در مجموع ۲۰۰ الگو وجود دارد. هر ویژگی برای ۲۰۰ آزمون نرمالیزه شده است. الگوهای مربوط به حالت باز کردن و بستن پنجه دست در یک کلاس و الگوهای مربوط به حالت آرامش در کلاس دیگر قرار داده شده است. هر بار ۵۰ الگو بطور تصادفی از بین الگوهای آرامش و ۵۰ الگو بطور تصادفی از میان الگوهای اتفاق انتخاب می‌شود.

این الگوها برای آموزش به طبقه‌بندی کننده داده می‌شود و از سایر الگوها برای ارزیابی کارایی طبقه‌بندی کننده استفاده می‌شود. این عمل ۱۰ بار انجام می‌شود و نتایج آن میانگین‌گیری می‌شود. این کار بر روی ۷ کانال به صورتی انجام می‌شود که ترتیب الگوها برای آموزش و آزمون طبقه‌بندی کننده‌های ۷ کانال در هر بار یکسان باشد. سپس بر روی نتایج کانال‌ها رای‌گیری صورت گرفته است. رای‌گیری به این صورت انجام می‌شود که خروجی طبقه‌بندی کننده‌ها با هم جمع می‌شود، اگر جواب نهایی مثبت باشد به معنای تصور حرکت و اگر منفی باشد به معنای وقوع آرامش است. در آموزش طبقه‌بندی کننده مقدار +۱ برای حالت بستن و یا باز کردن دست و -۱ برای حالت آرامش در نظر گرفته شده است (شکل ۲).

$$I(X, C) = -\log \frac{1}{N_T} \sum_{n=1}^{N_T} G(x(n) - x(n-1), 2\sigma^2) + \sum_{j=1}^{N_C} \left( \frac{N_j}{N_T} \log \frac{1}{N_j} \sum_{n=1}^{N_j} G(x_j(n) - x_j(n-1), 2\sigma^2) \right) \quad (9)$$


با استفاده از قانون یادگیری تصادفی کمترین شیب (۵) و اطلاعات متقابل بر حسب آنتروپی رینی، می‌توان تابع تبدیل بین متغیرهای ورودی و ویژگی‌های جدید را تخمین زد. این الگوریتم بطور اختصار MRMI-SIG<sup>17</sup> [۲۴] نامیده شده است.



شکل ۱- استخراج ویژگی با استفاده از اطلاعات متقابل

## ۵- روال آزمایش

برای ارزیابی روش، از داده‌های اخذ شده در آزمایشگاه پردازش سیگنال‌های بیولوژیک گروه مهندسی پزشکی دانشگاه علم و صنعت ایران استفاده شده است [۲۷]. برای اخذ سیگنال‌های مغزی آزمایشات مختلفی بر روی انسان انجام شده است. شخص بر روی صندلی در مقابل صفحه نمایش کامپیوتر می‌نشیند و با ظاهر شدن یک نشانه بر روی صفحه نمایش کامپیوتر، شخص تصور حرکت را انجام می‌دهد. با توجه به نشانه، شخص تصور حرکت بستن و یا باز کردن پنجه دست را انجام می‌شود. چنانچه نشانه‌ای بر روی صفحه کامپیوتر ظاهر نشود، شخص عمل خاصی را انجام نمی‌دهد. سیگنال‌های EEG با نصب الکترودهای از جنس Ag/AgCl در موقعیت‌های Fp1, T5, Cz, Pz, Fz, F4, F3, F4, F3 مطابق استاندارد ۱۰-۲۰ از سر افراد سالم ثبت شده است. همه کانال‌ها نسبت به الکترود مرجعی در گوش راست با فرکانس نمونه‌برداری ۲۵۶ هرتز ثبت شده‌اند. مدت زمان هر آزمون برابر با پنج ثانیه بوده و برای هر حالت ۵۰ آزمون انجام شده است. لازم به ذکر است که آزمایشات در حالت چشم باز انجام شده است. سیگنال‌های اخذ شده از یک فیلتر پایین گذر ۴۵ هرتز عبور کرده‌اند و متوسط داده‌های هر آزمون از تمام داده‌های آن کم شده است. از یک الکترود که بر روی پیشانی سمت چپ قرار داده شده، برای اخذ سیگنال‌های چشمی استفاده شده است. یکی از مشکلات مهم تحلیل سیگنال‌های EEG، وجود آرتیفکت پلک زدن است. در این تحقیق از روش تحلیل مولفه‌های مستقل و با استفاده از الگوریتم Infomax آرتیفکت پلک زدن حذف شده است [۲۸]. لازم به ذکر است که از هر فرد در ۴ روز متفاوت آزمایش به عمل آمده است.



شکل ۲- مراحل طبقه‌بندی تصور حرکت پنجه دست

در این تحقیق، همچنین برای استخراج ویژگی از روش PCA استفاده شده است و کارائی آن با روش پیشنهادی استخراج ویژگی و استفاده از مجموعه کامل ویژگی مقایسه شده است. در شکل ۳ متوسط طبقه‌بندی تصور حرکت پنجه دست ناشی از ۴ روز آزمایش برای ۴ فرد (AA, ME, MA, AE) نشان داده شده است. در این شکل‌ها، درصد طبقه‌بندی به ازاء انتخاب ۳، ۵، ۱۰ و ۲۰ ویژگی با استفاده از الگوریتم MRMI-SIG و PCA آورده شده است.

درصد طبقه‌بندی به ازاء ۲۹ ویژگی (مجموعه کامل ویژگی‌ها)، بدون استفاده از الگوریتم استخراج ویژگی نوشته شده است. همانطور که از شکل ۳ مشخص است، برای فرد AA با استفاده از الگوریتم MRMI-SIG به ازاء ۳ ویژگی بهترین دقت طبقه‌بندی، ۷۱/۲۵٪ بدست آمده است که حدود ۱۱٪ نسبت به نتیجه طبقه‌بندی با استفاده از مجموعه تمام ویژگی‌ها بهبود یافته است. اما این بهبودی به ازاء ۱۰ و ۲۰ ویژگی استخراج شده با استفاده از الگوریتم MRMI-SIG حدود ۳/۵ درصد است. این در حالی است که نتایج الگوریتم PCA همواره کمتر از نتایج طبقه‌بندی با استفاده از مجموعه کامل ویژگی‌ها است. در مورد فرد AE نیز متوسط نتیجه طبقه‌بندی با استفاده از ۳ ویژگی استخراج شده توسط الگوریتم

## ۶- طبقه‌بندی سیگنال‌های مغزی در هنگام تصور

برای طبقه‌بندی سیگنال‌های مغزی در سه حالت آرامش، باز و بستن پنجه دست، ویژگی‌های مربوط به داده‌های هر آزمون و برای هر کانال مغزی محاسبه شده است.


MRMI-SIG حدود ۵ درصد نسبت به نتیجه طبقه‌بندی با استفاده از تمام ویژگی‌ها بهتر است.

این در حالی است که دقت طبقه‌بندی با استفاده از همین الگوریتم به ازاء ۱۰ و ۲۰ ویژگی حدود ۲ درصد نسبت به استفاده از تمام ویژگی‌ها کمتر شده است. در مورد این فرد بهترین نتیجه حاصل از PCA ۳ درصد کمتر از دقت طبقه‌بندی با استفاده از مجموعه کامل ویژگی‌ها بوده است. در فرد ME نیز دقت طبقه‌بندی حدود ۳ درصد با استفاده از ۳ ویژگی استخراج شده توسط الگوریتم MRMI-SIG نسبت به استفاده از تمام ویژگی‌ها افزایش و حدود ۱ درصد به ازاء ۱۰ و ۲۰ ویژگی کاهش یافته است. اما توسط الگوریتم PCA، بهترین نتیجه با ۲۰ ویژگی بدست آمده که ۲ درصد از نتیجه بدست آمده با مجموعه کامل ویژگی‌ها کمتر بوده است. در مورد فرد MA دقت طبقه‌بندی با استفاده از ۵ ویژگی حدود ۳/۵ افزایش یافته است.


در شکل ۴ متوسط نتایج طبقه‌بندی برای ۴ نفر با استفاده از ۳، ۵، ۱۰ و ۲۰ ویژگی استخراج شده با استفاده از الگوریتم MRMI-SIG و PCA و تمام ویژگی‌ها (۲۹ ویژگی) آورده شده است. همانطور که ملاحظه می‌شود، بهترین نتیجه با استفاده از ۳ ویژگی با استفاده از الگوریتم MRMI-SIG حاصل شده است. در این حالت دقت طبقه‌بندی حدود ۵/۵ درصد نسبت به حالت مجموعه کامل ویژگی‌ها افزایش نشان می‌دهد. در مورد الگوریتم PCA حداکثر دقت طبقه‌بندی با استفاده از ۲۰ ویژگی رخ داده است. دقت در این حالت حدود ۱ درصد نسبت به حالت استفاده از تمام ویژگی‌ها کمتر است.

در شکل ۵، دقت طبقه‌بندی به ازاء ۳، ۵، ۱۰ و ۲۰ ویژگی استخراج شده با استفاده از الگوریتم MRMI-SIG و PCA و همچنین دقت طبقه‌بندی با مجموعه کامل ویژگی‌ها برای روزهای مختلف فرد AA نشان داده شده است. ملاحظه می‌شود در روز اول این فرد، حدود ۹ درصد و در روز دوم حدود ۱۴ درصد، دقت طبقه‌بندی با استفاده از الگوریتم MRMI-SIG و انتخاب سه ویژگی نسبت به تمام ویژگی‌ها بیشتر است. این افزایش برای روز سوم حدود ۱۵ درصد و برای روز چهارم حدود ۱۱ درصد است. اما با الگوریتم PCA برای تمام روزها بجز روز سوم، دقت طبقه‌بندی کمتر از دقت طبقه‌بندی با استفاده از تمام ویژگی‌ها بوده است.


در روز سوم با استفاده از ۵ ویژگی استخراج شده توسط PCA حدود ۱ درصد نسبت به حالت تمام ویژگی‌ها بهبود مشاهده می‌شود. میانگین دقت طبقه‌بندی برای افراد مختلف و بازای تعداد ویژگی‌های مختلف با استفاده از الگوریتم PCA و تمام ویژگی‌ها (۲۹ ویژگی) در جدول ۱ آورده شده است. نتایج نشان می‌دهد که دقت طبقه‌بندی با استفاده از الگوریتم MRMI-SIG، بیشتر از دقت طبقه‌بندی با استفاده از الگوریتم PCA و استفاده از مجموعه تمام ویژگی‌ها بوده است. به طور متوسط، بهترین نتیجه طبقه‌بندی با استفاده از الگوریتم MRMI-SIG با سه ویژگی و حدود ۷۴٪ حاصل شده، در حالیکه با استفاده از الگوریتم PCA، بهترین نتیجه با ۲۰ ویژگی و حدود ۶۷٪ بدست آمده است. میانگین دقت طبقه‌بندی با تمام ویژگی‌ها حدود ۶۸٪ است.




(الف)




(ب)



(ج)



(د)



شکل ۴- متوسط طبقه‌بندی تصور حرکت پنجه دست برای تمام افراد

شکل ۳- متوسط طبقه‌بندی تصور حرکت پنجه دست برای فرد الف) AA (ب) AE (ج) ME (د) MA

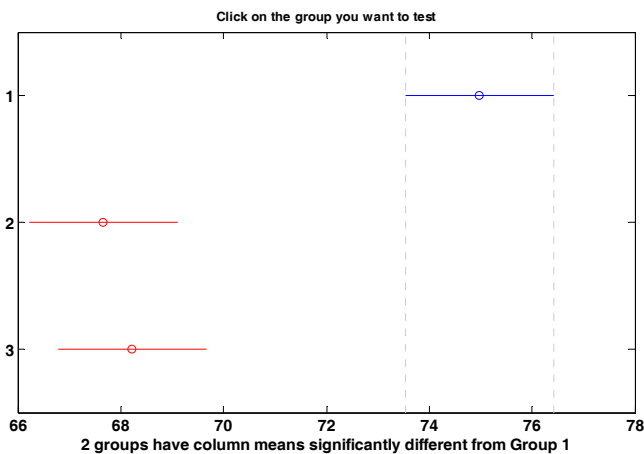
## ۷- نتیجه‌گیری

یکی از مهمترین پیش‌پردازش‌ها به منظور بهبود عملکرد سیستم‌های طبقه‌بندی، کاهش بعد فضای ویژگی است. کاهش بعد فضای ویژگی باعث کاهش پیچیدگی فرآیند طبقه‌بندی و در نتیجه کاهش وقوع خطا می‌شود. یکی از روش‌هایی که برای کاهش بعد فضای ویژگی معرفی شده است، استخراج ویژگی نامیده می‌شود. در این روش‌ها ویژگی‌های جدیدی با استفاده از مجموعه ویژگی‌های اصلی ساخته می‌شود. تاکنون روش‌های زیادی برای استخراج ویژگی‌های مناسب معرفی شده است. یکی از روش‌های استخراج ویژگی استفاده از تحلیل مولفه‌های اصلی است.


اشکال اصلی این روش این است که برای استخراج ویژگی، تنها به داده‌های ورودی توجه می‌کند و کلاس خروجی سیستم طبقه‌بندی کننده را مورد ملاحظه قرار نمی‌دهد. یکی دیگر از روش‌هایی که به طور گسترده به منظور استخراج ویژگی به کار رفته، روش تحلیل مولفه‌های مستقل است. در این روش سعی می‌شود، ویژگی‌هایی استخراج شود که تا حد امکان از هم مستقل باشند. اما در این روش نیز مشکل عدم توجه به کلاس خروجی وجود دارد. اخیراً استخراج ویژگی با استفاده از نظریه اطلاعات مورد توجه زیاد قرار گرفته است. در این روش‌ها سعی می‌شود ویژگی‌هایی استخراج شوند که دارای حداکثر اطلاعات را در مورد کلاس خروجی داشته باشند.

در این مقاله، از یک روش استخراج ویژگی مبتنی بر اطلاعات متقابل برای طبقه‌بندی سیگنال‌های مغزی در حین تصور حرکت برای سیستم‌های ارتباطی مغز با کامپیوتر مورد استفاده قرار گرفته شد و کارایی آن با روش استخراج ویژگی PCA و همچنین با مجموعه کامل ویژگی‌ها مقایسه گردید. نتایج نشان می‌دهد که استخراج ویژگی‌های با استفاده از اطلاعات متقابل باعث افزایش دقت طبقه‌بندی شده است.


در شکل ۶ نتیجه مقایسه دقت طبقه‌بندی سیگنال‌های مغزی با استفاده از دو روش استخراج ویژگی، MRMI-SIG، PCA و با استفاده از مجموعه کامل ویژگی با استفاده از آنالیز پراش<sup>۱۳</sup> نشان داده شده است. نتایج نشان می‌دهد که روش استخراج ویژگی MRMI-SIG بطور قابل ملاحظه‌ای باعث بهبود طبقه‌بندی کننده شده است ( $p=5 \times 10^{-8}$ ).




شکل ۶- نتیجه آزمون آماری بین نتایج طبقه‌بندی با استفاده از تمام ویژگی‌ها و ویژگی‌های استخراج شده با استفاده از الگوریتم MRMI-SIG و PCA




(الف)



(ب)



(ج)



(د)

شکل ۵- طبقه‌بندی تصور حرکت پنجه دست برای فرد AA (الف) روز اول (ب) روز دوم (ج) روز سوم (د) روز چهارم

جدول ۱- دقت طبقه‌بندی با تعداد ویژگی استخراج شده مختلف با استفاده از الگوریتم MRMI-SIG و PCA برای افراد مختلف

تعداد ویژگی	۳ ویژگی		۵ ویژگی		۱۰ ویژگی		۲۰ ویژگی		۲۹ ویژگی
	MRMI-SIG	PCA	MRMI-SIG	PCA	MRMI-SIG	PCA	MRMI-SIG	PCA	Full Set
فرد AA	۷۱/۲۵	۵۹/۱	۶۹/۹	۵۹/۳۵	۶۳/۷۵	۵۹/۱۵	۶۳/۴	۵۸/۹	۶۰/۲۵
فرد AE	۷۸/۳۵	۶۹/۵۵	۷۴/۶	۷۰/۰۵	۷۱/۹۵	۷۰/۲۵	۷۱/۶۵	۷۰/۰۵	۷۳/۲۵
فرد ME	۷۸/۲	۶۶/۲	۷۷/۲	۶۹/۸	۷۴/۴	۷۱/۱	۷۴/۵	۷۳/۷	۷۵/۱۵
فرد MA	۶۷/۷	۶۰/۰۵	۶۷/۸	۶۱/۹۵	۶۵/۱۵	۶۳/۶	۶۵/۴	۶۵/۵	۶۴/۲۵
میانگین	۷۳/۸۷	۶۳/۷۲	۷۲/۳۷	۶۵/۲۸	۶۸/۸۱	۶۶/۰۲	۶۸/۷۳	۶۷/۰۳	۶۸/۲۲

## مراجع

[11] N. Kwak, and C.-H. Choi, "Feature extraction based on ICA for binary classification problems," *IEEE Trans. Knowledge and Data Eng.*, Vol. 15, No. 6, pp. 1374,1388, 2003.

[12] K. Torkkola, "Feature Extraction by non-parametric Mutual Information Maximization," *Journal of Machine Learning Research*, Vol. 3, pp. 1415–1438, 2003.

[13] R. Kohavi, and G. John, "Wrapper for Feature Subset Selection," *Artificial Intelligence*, Vol. 97, Nos. 1-2, pp. 273-324, 1997.

[14] H. Peng, F. Long, and C. Ding, "Feature selection based on mutual information: criteria of max-dependency, max-relevance, and min-redundancy," *IEEE Trans. Pattern Analysis*, Vol. 27, No. 8, pp. 1226-1238, 2005.

[15] M. Pregenzer, and G. Pfurtscheller, "Frequency Component Selection for an EEG-Based Brain to Computer Interface," *IEEE Trans. Rehab. Eng.*, Vol. 7, No. 4, pp. 413-419, 1999.

[16] D. Peterson, J. Knight, M. Kirby, C. Anderson, and M. Thaut, "Feature Selection and Blind Source Separation in an EEG-Based Brain-Computer Interface," *EURASIP Journal on Applied Signal Processing*, pp. 3128-3140, 2005.

[17] H. Li, T. Jiang, and K. Zhang, "Efficient and Robust Feature Extraction by Maximum Margin Criterion," *IEEE Trans. Neural Networks*, Vol. 17, No. 1, pp. 157–1165, 2006.

[18] R. O. Duda, P. E. Hart, and D. Stork, *Pattern Classification*, Wiley, 2000.

[19] A. Hyvarinen, J. Karhunen, and E. Oja, *Independent Component Analysis*, John Wiley & Sons, 2001.

[20] A. Erfanian, and A. Erfani, "EEG-based brain-computer interface for hand grasp control: feature extraction by using ICA," *Proc. 9th Annual Conf. Int'l. Functional Electrical Stimulation Society*, 2004.

[21] T. Trappenberg, J. Ouyang, and A. Back "Input Variable Selection: Mutual Information and Linear Mixing Measures," *IEEE Trans. Knowledge and Data Eng.*, Vol. 15, No. 1, pp. 37-46, 2006.

[1] E. Haselsteiner, and G. Pfurtscheller, "Using time-dependent neural networks for EEG classification," *IEEE Trans. Rehab. Eng.*, Vol. 8, No. 4, pp. 457-463, 2000.

[2] B. Mahmoudi, and A. Erfanian, "Single-channel EEG-based prosthetic hand grasp control for amputee subjects," *Proc. 24<sup>th</sup> Annual Int'l Conf. IEEE Engineering in Medicine and Biology Society*, pp. 2406 – 2407, 2002.

[3] C. Guger, H. Ramoser, and G. Pfurtscheller, "Realtime EEG analysis with subject-specific spatial patterns for a brain-computer interface (BCI)," *IEEE Trans. Biomed. Eng.* Vol. 8, No. 4, pp. 447-456, 2000.

[4] T. Hinterberger, S. Schmidt, N. Neumann, J. Mellinger, B. Blankertz, G. Curio, and N. Birbaumer, "Brain – computer communication and slow cortical potentials," *IEEE Trans. Biomed Eng.*, Vol. 51, pp. 1011-1018, 2004.

[5] S. G. Mason, and G. E. Birch, "A brain-controlled switch for asynchronous control applications," *IEEE Trans. Biomed Eng.*, Vol. 47, pp. 1297-1307, 2000.

[6] G. Pfurtscheller, C. Neuper, A. Schlogl, and K. Lugger, "Motor imagery and direct brain-computer communication," *Proc. the IEEE*, Vol. 89, pp. 1123-1134, 2001.

[7] J. R. Wolpaw, D. J. McFarland, and T. M. Vaughan, "Brain-computer interface research at the Wadsworth Center," *IEEE Trans Rehab Eng.*, Vol. 8, pp. 222–226, 2000.

[8] E. Yom-Tov, and G. F. Inbar, "Feature selection for the classification of movements from single movement-related potentials," *IEEE Trans. Rehab. Eng.*, Vol. 10, No. 3, pp. 170-177, 2002.

[9] G. Pfurtscheller, C. Neuper, A. Schlogl, and K. Lugger, "Separability of EEG signals recorded during right and left motor imagery using adaptive autoregressive parameters," *IEEE Trans. Rehab. Eng.*, Vol. 6, No. 3, pp. 316-325, 1998.

[10] H. Serby H, E. Yom-Tov, and G. F. Inbar, "An improved P300-based brain-computer interface," *IEEE Trans. Neural Syst. Rehabil. Eng.*, Vol. 13, pp. 89–98, 2005.

دانشگاه کیس وسترن آمریکا و مرکز پزشکی VA در شهر کلیولند ایالت اوهایو آمریکا گذرانده است. وی از سال ۱۳۷۴ به بعد، عضو هیأت علمی گروه مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران بوده و از سال ۱۳۷۹ تا ۱۳۸۷ مدیریت گروه مهندسی پزشکی دانشکده برق دانشگاه علم و صنعت ایران را به عهده داشته است. در حال حاضر دانشیار مهندسی پزشکی این دانشگاه است. زمینه‌های تحقیقاتی وی شامل شبکه‌های عصبی، پردازش سیگنال‌های بیولوژیک، مدل‌سازی سیستم‌های بیولوژیک، مهندسی عصبی، سیستم‌های کنترلی عصبی-عضلانی، نظریه آشوب و فرکتال و کاربرد آن در حل مسائل پزشکی می‌باشد. یکی از مهمترین زمینه‌های تحقیقاتی وی کنترل سیستم‌های عصبی-عضلانی است. از سال ۱۳۶۹ تا کنون، وی مسؤل چندین پروژه تحقیقاتی در زمینه کنترل سیستم‌های عصبی-عضلانی بوده است. از نتایج این پروژه ها، گسترش پروتزهای عصبی حرکتی قابل حمل، برای اولین بار در ایران بوده است. با استفاده از این سیستم‌های الکترونیکی بیماران ضایعه نخاعی قادر به ایستادن و گام برداشتن می‌باشند.

عرفانیان، تا کنون دارای بیش از ۱۲۰ مقاله چاپ شده در داخل و خارج از کشور است و در سال ۱۳۷۷ و ۱۳۸۵ به عنوان پژوهشگر نمونه دانشگاه انتخاب شده است. در حال حاضر، وی دروس کارشناسی ارشد و دکترا شامل شبکه‌های عصبی، پردازش سیگنال‌های بیولوژیک، مدل‌سازی سیستم‌های بیولوژیک، سیستم‌های کنترل عصبی-عضلانی، تکنولوژی توانبخشی و پردازش سیگنال‌های دیجیتال پیشرفته را برای دانشجویان فوق لیسانس و دکترا ارائه می‌کند. عرفانیان عضو جامعه بین‌المللی (International Functional Electrical Stimulation Society) FES و IEEE است.

آدرس پست‌الکترونیکی ایشان عبارت است از:

erfanian@iust.ac.ir

#### اطلاعات بررسی مقاله:

تاریخ ارسال: ۸۶/۰۵/۲۲

تاریخ اصلاح: ۸۹/۰۱/۲۲

تاریخ قبول شدن: ۸۹/۰۴/۰۱

نویسنده مرتبط: دکتر عباس عرفانیان امیدوار، دانشکده مهندسی برق، دانشگاه علم و صنعت ایران، تهران، ایران.

[22] A. Hyvarinen, P. O. Hoyer, and M. Inki, "Topographic Independent Component Analysis," *Neural computation*, pp. 1527-1558, 2001.

[23] D. Huang, and T. Chow, "Effective feature selection scheme using mutual information," *Neurocomputing*, pp. 325-343, 2005.

[24] K. Hild, D. Erdogmus, K. Torkkola, and J. Pirincipe, "Feature Extraction Using Information-Theoretic Learning," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol. 28, No. 9, pp. 1385-1392, 2006.

[25] N. Kwak, and C.-H. Choi, "Input feature selection for classification problems," *IEEE Trans. Neural Netw.*, Vol. 13, No. 1, pp. 143-159, 2002.

[26] D. Huang, and T. Chow, "Effective feature selection scheme using mutual information," *Neurocomputing*, pp. 325-343, 2005.

[27] B. Mahmoudi, and A. Erfanian, "Electro-encephalogram based brain-computer interface: improved performance by mental practice and concentration skills," *Med. & Biol. Eng & Compu*, Vol. 44, pp. 959-969, 2006.

[28] H. Ghandeharion, and A. Erfanian, "A fully Automatic method for ocular artifact suppression from EEG Data using wavelet transform and independent component analysis," *Proc. 28<sup>th</sup> Annual Int'l. Conf. IEEE Engineering in Medicine and Biology Society*, pp. 5265-5268, 2006.

[29] W. J. Krzanowski, *Principles of multivariate analysis: a user's perspective*, Oxford University Press, Oxford, 2000.



**فرید اویسی ارنکه** در سال ۱۳۶۱ در شهر تهران متولد گردید. ایشان مدارک کارشناسی و کارشناسی ارشد خود را در سال‌های ۱۳۸۳ و ۱۳۸۶ به ترتیب از دانشگاه آزاد اسلامی و دانشگاه علم و صنعت ایران دریافت کرد. زمینه کارهای تحقیقاتی او تاکنون پردازش سیگنال‌های مغزی، پردازش سیگنال‌های صوتی و روش‌های بازشناخت الگو بوده است. آدرس پست‌الکترونیکی ایشان عبارت است از:

faridoveisi@gmail.com



**عباس عرفانیان امیدوار** مدرک لیسانس خود را در سال ۱۳۶۴ در رشته مهندسی کامپیوتر از دانشگاه شیراز، مدرک فوق لیسانس را در سال ۱۳۶۸ در مهندسی برق و الکترونیک از دانشگاه صنعتی شریف تهران و مدرک دکترای تخصصی

خود را در مهندسی پزشکی در سال ۱۳۷۴ از دانشگاه تربیت مدرس تهران، ایران اخذ کرد. وی در دوره دکترای 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 بکار بوده و در 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 بکار بوده است. او در سال ۱۳۷۲، یک دوره تحقیقاتی در زمینه کنترل سیستم‌های عصبی-عضلانی و رفع مشکلات حرکتی در افراد دچار ضایعه نخاعی با استفاده از فناوری عصبی در

<sup>1</sup> Brain-Computer Interface (BCI)

<sup>2</sup> Feature Selection

<sup>3</sup> Feature Extraction

<sup>4</sup> Wrapper

<sup>5</sup> Distinctive Sensitive Learning Vector Quantization

<sup>6</sup> Principle Component Analysis

<sup>7</sup> Linear Discriminant Analysis

<sup>8</sup> Independent Component Analysis

<sup>9</sup> Shannon

<sup>10</sup> Gradient ascent

<sup>11</sup> Probability Density Function

<sup>12</sup> Minimum Renyi's Mutual Information-Stochastic Information Gradient

<sup>13</sup> ANOVA