

تشخیص صرع به کمک ارزیابی های کیفی و کمی آشوب گون سیگنال های مغزی

سید عابد حسینی

مربی گروه مهندسی برق، واحد شهرود، دانشگاه آزاد اسلامی

محمد رضا اکبرزاده توونچی

استاد گروه های مهندسی برق و کامپیوتر، دانشگاه فردوسی مشهد

محمد باقر نقیبی سیستانی

استادیار گروه مهندسی برق، دانشگاه فردوسی مشهد

*نشانی تماس: دانشکده مهندسی برق و کامپیوتر، واحد شهرود، دانشگاه آزاد اسلامی، شهرود، ایران

E-mail: Hosseyni@iau-shahrood.ac.ir

هدف: صرع یکی از بیماری های سیستم اعصاب مرکزی است که فرد مبتلا را در طول یک دوره زمانی چهار تشنیج های ناگهانی می کند. روش: یکی از مسائل مهم در آموزش سیستم شناخت، تهیه داده های مطلوب است که در ادامه به کمک تحلیل کیفی آشوب گون و نظر افراد خبره بر چسب زنی صحیح آن بررسی و سپس ویژگی های آشوب گون نظیر بُعد فرکتال، بزرگ ترین نمای لیاپانوف و نمای هرست استخراج می شود. برای تفکیک دسته های مختلف از یکدیگر، این ویژگی ها به دسته بندی کننده بیزین داده می شوند.

یافته ها: نتایج نشان می دهد که سیگنال مغزی EEG دارای رفتاری آشوب گون است و در حالت حمله کمینه ای بُعد بازسازی و به دنبال آن پیچیدگی کاهش می یابد. همچنین نتایج حاکی از آن است که دو دسته ای طبیعی و پیش حمله ای با متوسط صحت ۹۹/۲ درصد و دو دسته ای طبیعی و حمله ای با متوسط صحت ۹۹/۷ درصد و دو دسته ای پیش حمله ای و حمله ای با متوسط صحت ۹۷/۱ درصد از یکدیگر تفکیک شده اند. نتیجه گیری: به نظر می رسد تحلیل آشوب گون یکی از روش های مفید در بازیابی رفتار مغز در تشخیص حالت های صرعی باشد.

کلیدواژه ها: سیگنال مغزی، آشوب، صرع، بر چسب زنی، دسته بندی کننده.

Epilepsy Recognition using Chaotic Qualitative and Quantitative Evaluation of EEG Signals

Introduction: Epilepsy is a disease of the central nervous system presenting by sudden convulsive attacks over a period of time. **Method:** A key issue in recognition systems is optimal data acquisition as well as accurate labeling based on chaotic qualitative analyses and confirmatory annotations using expert eyes. To this end, chaotic features such as Petrosian fractal dimension, largest Lyapunov exponent and Hurst exponent were used in this investigation. Such features were submitted to the Bayesian classifier in order to have different categories separated. **Results:** Our findings confirmed a chaotic behavior in EEG with minimum embedding dimension reduced in ictal state. Similarly, the complexity of the ictal state was reduced. In addition, our results indicated an average classification accuracy of 99.2% for normal vs. pre-ictal states; the average classification accuracy is 99.7% for the normal vs. ictal states and the average classification accuracy is 97.1% for the pre-ictal vs. ictal states. **Conclusion:** Chaotic analysis appears to serve as a useful method in representation and recognition of the brain activities in epileptic states.

Keywords: *Electroencephalogram, Chaos, Epilepsy, Labelling, Classification.*

S. Abed Hosseini*

Instructor, Department of Electrical Engineering, Shahrood Branch, Islamic Azad University

Mohammad Reza Akbarzadeh Totonchi

Professor, Department of Electrical and Computer Engineering, Ferdowsi University of Mashhad

Mohammad Bagher Naghibi-Sistani
Assistant professor, Department of Electrical Engineering, Ferdowsi University of Mashhad

Corresponding Author:

Email: Hosseyni@iau-shahrood.ac.ir

مقدمه

طیف‌های مرتبه بالا (۱۱، ۱۲) و تحلیل آشوب‌گون (۱۳-۱۷) استفاده شده است. از میان تحقیقات مرتبط می‌توان به موارد زیر اشاره کرد: گاتمن (۱۸) برای تشخیص انواع تشنج یک سیستم محاسباتی ارائه داد. مورو و همکارانش (۱۹) بر اساس سیگنال‌های مغزی ثبت شده به روش تهاجمی، یک سیستم تشخیص تشنج پیشنهاد دادند. کانثال و همکارانش (۲۰) اهمیت استفاده از انواع مختلف آنتروپی را در تشخیص صرع بررسی کردند. سوباسی و همکارش (۲۱) با استفاده از شبکه‌های عصبی مصنوعی و رگرسیون لاجستیک^{۱۸} دو گروه طبیعی و صرعی را تفکیک کردند. در تحقیقی دیگر، سوباسی (۲۲) با استخراج ویژگی به وسیله‌ی تبدیل موجک و استفاده از یک سیستم عصبی فازی تطبیقی^{۱۹}، به آشکارسازی صرع پرداخت. چوا و همکارانش (۱۱) با استفاده از تحلیل طیف‌های مرتبه بالا و آزمون آماری تحلیل پراش^{۲۰} سه دسته‌ی طبیعی، پیش‌حمله‌ای و حمله‌ای را از هم تفکیک کردند. ویسی و همکارانش (۲۲) برای تشخیص صرع در سیگنال‌های مغزی نویزی و کوتاه‌مدت، یک معیار سنجش پیچیدگی ارایه دادند. آنها مشاهده کردند که هنگام وقوع حمله‌ی صرعی، پیچیدگی سیگنال‌های مغزی کاهش می‌یابد. کومار و همکارانش (۲۳) با کاربرد تحلیل‌های مختلف آنتروپی و کمک گرفتن از دسته‌بندی کننده‌هایی نظری شبکه‌های عصبی مصنوعی شعاعی پایه و *إِلْمَن*^{۲۱} به آشکارسازی صرع پرداختند. نتایج این تحقیق، رسیدن به صحت ۹۹/۷۵ درصد برای تفکیک حالت طبیعی از تشنج و صحت ۹۵/۴ درصد برای تفکیک حالت طبیعی از حمله‌ای بود. عادلی (۲۴) و همچنین گوش‌داستیدار و همکارانش (۲۵) با کمک تحلیل‌های آشوب، موجک و شبکه‌های عصبی مصنوعی از روی سیگنال‌های مغزی دو حالت طبیعی و صرعی را دسته‌بندی کردند. لنتر و همکارانش (۲۶، ۲۷) نشان دادند که با شروع حمله‌ی صرعی بُعد همبستگی سیگنال EEG عمیقی کم و به عبارتی سیستم دینامیکی مغز منظم‌تر

صرع یکی از بیماری‌های دستگاه اعصاب مرکزی است که حدود ۱ درصد در جهان را درگیر کرده است (۱). بیمار در حالت حمله‌ی صرع، در طول یک دوره‌ی زمانی، دچار تشنج‌های مکرر می‌شود. تشنج عبارت است از یک حمله ناگهانی در فعالیت الکتریکی مغز که می‌تواند باعث کاهش هوشیاری، حرکات مکرر، انقباضات عضلانی و گاهی اختلالات حسی شود. در بیماری صرع، حملات تشنج بدون عامل محرک دو بار یا بیشتر تکرار می‌شوند (۲). اتحادیه‌ی بین‌المللی مقابله با صرع در سال ۱۹۸۱، حملات صرعی را به دو گروه موضعی (کانونی) و منتشر تقسیم کرده است. حملات منتشر تمام قشر مغز را در برگرفته و معمولاً با از دست دادن هوشیاری و گاهی با حرکات غیررادی همراه است. حملات موضعی در محل ویژه‌ای مثلاً قطعه‌ی گیجگاهی رخ می‌دهند و معمولاً با از دست دادن هوشیاری همراه نیستند. این حمله‌ها به چند نوع اصلی غیابی^۱، غیابی^۲، میوکلونیک^۳، کلونیک^۴، تونیک^۵-کلونیک^۶ و آتونیک^۷ و حملات موضعی به چند نوع اصلی ساده^۸، مرکب^۹ و عمومی شدن ثانویه^{۱۰} تقسیم می‌شوند. در صرع سه حالت طبیعی، پیش‌حمله‌ای و حمله‌ای مورد توجه است. برای تشخیص صرع می‌توان از روش‌ها و سیگنال‌های زیستی متعدد استفاده کرد. یکی از سیگنال‌هایی که در تشخیص صرع بسیار اهمیت دارد، سیگنال مغزی (EEG)^{۱۱} است. در نوار مغزی بیشتر بیماران صرعی، الگوهای غیرطبیعی گذراشی مشاهده می‌شود که از روی آن می‌توان به وجود بیماری صرع و در برخی موارد حتاً به نوع آن پی برد. تاکنون برای تحلیل سیگنال‌های مغزی، ابزارها و روش‌های گوناگونی نظری خطی، غیرخطی و آشوب‌گون^{۱۲} به کار رفته است. امروزه آشوب یک روش جدید مطالعه و ایده‌های خوبی برای حل بسیاری از مسائل ارائه کرده است. از میان ابزارهای موجود برای تحلیل آشوب، می‌توان به بُعد همبستگی^{۱۳}، ساختار فضایی فاز، نمای لیپاپانوف^{۱۴}، آنتروپی^{۱۵}، نمای هرست^{۱۶} و بُعد فرکتال^{۱۷} اشاره کرد. کوتاه‌اینکه، درباره‌ی ماهیت آشوب‌گون سیگنال‌های مغزی می‌شود گفت، سیگنال‌های مغزی به طور طبیعی خواص آشوبی دارند. آنها در حملات صرعی حالت منظم از خود نشان می‌دهند و در پایان حملات مجدداً به وضعیت آشوب بازمی‌گردند. پیچیدگی سیگنال‌ها با آغاز حملات صرعی کاهش و با پایان حملات افزایش می‌یابد (۳).

برای ارزیابی صرع، از ویژگی‌های زیادی شامل حوزه‌ی زمان و فرکانس (۶-۴)، تبدیل موجک^{۱۸} (۷-۹)، تبدیل فوریه (۱۰)،

- | | |
|-------------------------------------|---------------------------|
| 1. Absence | 12. Correlation Dimension |
| 2. Atypical absence | 13. Lyapunov Exponent |
| 3. Myoclonic | 14. Entropy |
| 4. Clonic | 15. Hurst |
| 5. Tonic | 16. Fractal |
| 6. Atonic | 17. Wavelet Transform |
| 7. Simple | 18. Logistic Regression |
| 8. Complex | 19. Adaptive Neuro |
| 9. Secondarily generalized Seizures | Fuzzy Inference System |
| 10. Electroencephalogram (ANOVA) | 20. Analysis of variance |
| 11. Chaotic | 21. Elman |

تجزیه و تحلیل داده

در این بخش، شرح روش تجزیه و تحلیل داده آمده است. ممکن است برای بخش آموزش سیستم شناخت، تمام سیگنال‌های ثبت شده مناسب نباشند، بنابراین برای دست‌یابی به برچسب صحیح سیگنال‌های مغزی، از تحلیل کیفی و کمی آشوب‌گون سیگنال‌های مغزی و کمک افراد خبره استفاده شد. بدین‌منظور پس از پیش‌پردازش سیگنال‌ها، داده‌هایی که نویز و آرتیفیکت^۱ فراوانی داشتند، از جریان آموزش سیستم شناخت حذف و داده‌هایی که با موفقیت از بخش قبل عبور کرده بودند، برای محاسبه‌ی ویژگی‌های کیفی آشوب‌گون وارد بخش بعدی شدند. در این مرحله، داده‌هایی که از نظر تحلیل کیفی آشوب‌گون وضعیت قابل قبولی داشتند، اجازه‌ی عبور پیدا می‌کردند؛ در غیراین صورت دوباره از آموزش سیستم شناخت کنار گذاشته می‌شدند. در آموزش سیستم شناخت، داده‌هایی نقش دارند که مراحل قبلی را با موفقیت تمام کرده‌اند. سپس ویژگی‌هایی کمی این داده‌ها استخراج و برای تصمیم‌گیری به دست‌بندی کننده تحويل داده می‌شد.

۱- تحلیل کیفی

شواهد نشان می‌دهد که سیگنال EEG رفتاری آشوب‌گون دارد (۳۰)، بنابراین رویکرد این تحقیق دیدگاه آشوب‌گون است. با مشاهده‌ی سری زمانی حاصل از یک فرآیند، تشخیص وجود آشوب تقریباً ناممکن است، بنابراین سعی می‌شود برای تعیین الگوهای مشخص کننده و علامت‌هایی از وجود آشوب و یا رفتارهای خاص در مدل‌ها و اطلاعات تجربی ابزارهایی فراهم شود. این روش‌ها می‌توانند به پنج گروه برسی طیف فرکانسی، ساختار فضایی فاز، حساسیت به شرایط اولیه، قابلیت کنترل سری‌های زمانی و ابعاد دینامیک‌ها تقسیم شوند. در ادامه هر یک از این روش‌ها به طور خلاصه توضیح داده می‌شود.

طیف فرکانسی: یکی از ابزارهای تشخیص رفتارهای آشوب‌گون از رفتارهای متناوب، تحلیل در حوزه‌ی فرکانس است. در سیگنال‌های متناوب، انرژی بر فرکانس‌های خاصی متتمرکز است، در صورتی که در رفتارهای آشوبی طیف فرکانسی در فرکانس‌های مختلف مقدار غیرصرف دارد و دارای باند گسترده است. طیف فرکانسی حاصل از یک سری

می‌شود. آنها با استفاده از این پدیده توانستند حملات صرعی را تا ۲۵ دقیقه قبل از شروع با حداکثر صحت ۶۷ درصد پیش‌بینی کنند؛ اما اشکال مطالعه‌ی آنها در نظر گرفتن بازه‌های کوتاه ۳۰ تا ۵۰ دقیقه‌ای برای پردازش است؛ بنابراین نتایج به بازه‌های طولانی تر تعیین‌پذیر نیست (۲۸). حسینی و همکارانش (۱۲) با استفاده از تحلیل طیف‌های مرتبه‌بالا و ماشین بردار پشتیبان به تفکیک سه دسته‌ی طبیعی، پیش‌حمله‌ای و حمله‌ای پرداختند. نتایج این تحقیق، به صحت ۹۷/۲ درصد برای تفکیک حالت طبیعی از حمله‌ای منجر شد.

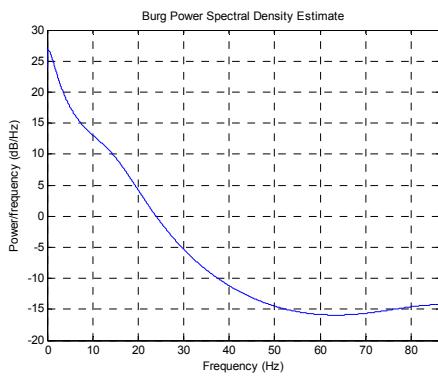
هدف این تحقیق، استفاده از ابزارهای آشوب‌گون، نظیر بزرگ‌ترین نمای لیپانوف، بُعد فرکتال و نمای هرست برای تشخیص بهینه‌ی حالات صرعی است. بدین‌منظور با استخراج ویژگی‌های کیفی و کمی، سیگنال‌های مغزی را برچسب مناسب زده و سپس به کمک ابزار تصمیم‌گیر بیزین تشخیص انجام شد.

در ادامه‌ی این مقاله، در بخش دوم داده معرفی شد؛ در بخش سوم روش تجزیه و تحلیل با دو رویکرد کیفی و کمی توضیح داده شد؛ در بخش چهارم گزارش نتایج تحقیق و در نهایت در بخش پنجم بحث و نتیجه‌گیری ارائه شده است.

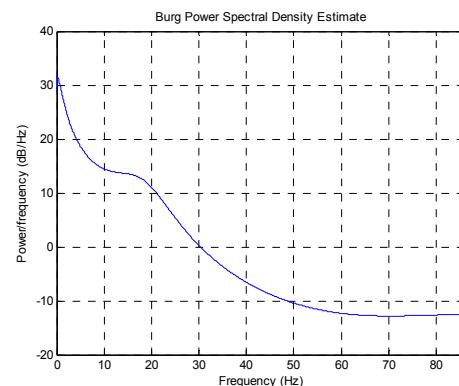
داده‌ی تحقیق

در این مقاله، از سیگنال‌های EEG ثبت شده به وسیله‌ی آندرزز جاک و همکارانش از سایت دانشگاه بُن استفاده شده (۲۹) که شامل پنج گروه A، B، C، D و E است. سیگنال‌ها با دستگاه ۱۲۸ کاناله با استاندارد ۱۰-۲۰ به دست آمداند. هر مجموعه شامل ۱۰۰ قطعه سیگنال مغزی به طول ۲۳/۶ ثانیه (۴۰۹۶ نمونه) است. داده‌ها که با فرکانس ۱۷۳/۶ هرتز و مبدل ۱۲ بیتی آسالوگ به دیجیتال نمونه‌برداری شده‌اند، به گروه سنی شش تا ۴۳ سال (متوسط ۲۸ سال) تعلق دارند. مجموعه‌های A و B به وسیله‌ی الکترودهای سطحی از حالت بیداری پنج داوطلب سالم ثبت شده‌اند. چشمان داوطلب در دو مجموعه‌ی A و B به ترتیب باز و بسته بوده است. مجموعه‌های C، D و E به وسیله‌ی الکترودهای عمقی ثبت شده‌اند. دو مجموعه‌ی C و D در زمان غیرتشنج و مجموعه‌ی E در خلال تشنج ثبت شده است. بر روی داده‌ها یک فیلتر ناج^۲ با فرکانس توقف ۵۰ هرتز و یک فیلتر میان‌گذر باترورث^۳ درجه‌ی چهار با گستره‌ی فرکانسی ۰/۵۳ تا ۰/۴۵ هرتز اعمال شده است.

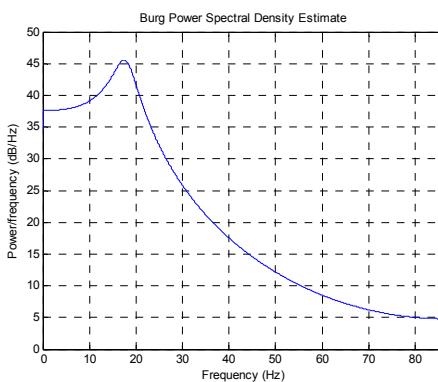
1. Notch
2. Butterworth
3. Artifact



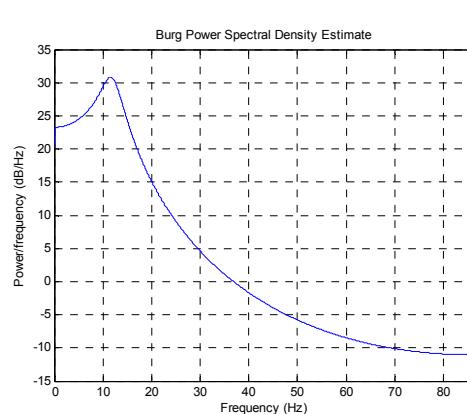
شکل ۴- طیف فرکانسی بخشی از داده‌ی D



شکل ۱- طیف فرکانسی بخشی از داده‌ی A



شکل ۵- طیف فرکانسی بخشی از داده‌ی E



شکل ۲- طیف فرکانسی بخشی از داده‌ی B

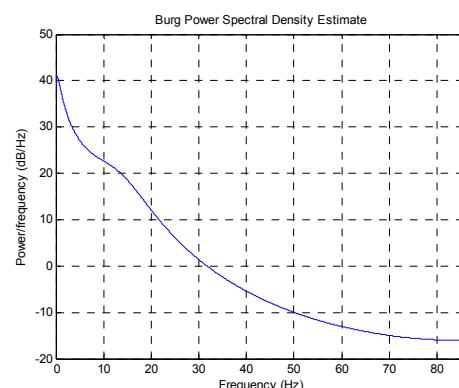
کند؛ به طوری که هر نقطه بیانگر رفتار سیستم در زمان مشخص باشد. بازسازی^۲ به معنای روند بازسازی بردارهای حالت یک سیستم دینامیکی از روی سری زمانی، یکی از متغیرهای زمانی آن سیستم است. این فرآیند با توجه به دو عامل بُعد بازسازی فضای حالت (m) و تأخیر زمانی (τ) طی می‌شود. فرض کنید $[x(1)x(2)\dots x(N)]$ یک $x = [x(1)x(2)\dots x(N)]$ سیگنال یک بُعدی با طول N باشد، بردارهای تأخیر زمانی فضای فاز به صورت رابطه‌ی ۱ شکل می‌گیرند.

(1)

$$X(i) = [x(i + \tau), x(i + 2\tau), \dots, x(i + (m-1)\tau)], \\ i = 1, 2, \dots, N - (m-1)\tau$$

$(m-1)\tau$ بردار حالت از روی عوامل معلوم m و τ قابل بازسازی است. تاکنون برای تخمین بُعد بازسازی و تأخیر زمانی بهینه، الگوریتم‌های زیادی پیشنهاد شده است. در قضایای ریاضی قیدی برای تعیین τ وجود ندارد. البته در این قضایای داده‌ها بدون نویز در نظر گرفته شده‌اند، بنابراین با توجه به نویزی بودن سیگنال‌های مغزی، انتخاب τ مناسب

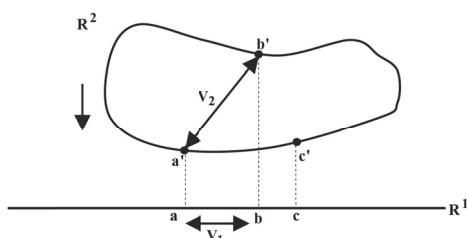
-
1. Burg
 2. Embedding



شکل ۳- طیف فرکانسی بخشی از داده‌ی C

زمانی تصادفی و سری زمانی مربوط به سیستم‌های دینامیکی حقیقی آمیخته با نویز نیز دارای باند گسترده است که تشخیص این موارد صرفاً از روی طیف فرکانسی ممکن نیست. طیف فرکانسی به روش بورگ^۱ برای بخشی از داده‌های A تا E، به ترتیب در شکل‌های ۱ تا ۵ آمده است.

فضای حالت: بررسی فضای حالت و یا فضای فاز، ابزاری قدرتمند برای مطالعه‌ی سیستم‌های دینامیکی است. یک سیستم دینامیکی می‌تواند با نمودار فضای حالت، تمامی متغیرهای مؤثر بر شرایط سیستم را در هر لحظه توصیف



شکل ۶ - نمایش جاذب یک سیستم دینامیکی در فضای R^1 به همراه تصویرش در فضای R^2

بر حسب τ به عنوان مقدار تأخیر بهینه در نظر گرفته می‌شود.

روش شمارش نزدیک‌ترین همسایه‌ی کاذب: کنل برای تعیین بعد بازسازی سری‌های زمانی آشوب‌گون، روش شمارش نزدیک‌ترین همسایه‌ی کاذب را پیشنهاد کرد (۳۹، ۳۸، ۳۶). مفهوم همسایه‌های کاذب در شکل ۶ توصیف شده است (۴۰) که با توجه به آن می‌توان گفت که در فضای R^1 نزدیک‌ترین همسایه به a با فاصله‌ی V_1 است. سپس با افزایش بعد (فضای R^2) فاصله‌ی b' از a' برابر V_2 می‌شود. با توجه به اینکه $V_1 \gg V_2$ است، دیگر b' همسایه‌ی a' محسوب نمی‌شود، بنابراین b همسایه‌ی a شده است؛ نه به دلیل دینامیک حاصل بر جاذب سیستم، بلکه به علت تصویرسازی در فضای دارای بعد ناکافی، بنابراین b نه همسایه‌ی واقعی a ، بلکه همسایه‌ی کاذب a است. در این صورت برای یک نقطه، همسایه‌ای واقعی محسوب می‌شود که با افزایش بعد فاصله‌ی بین آنها تفاوت چشم‌گیری نیافته باشد.

با توجه به شرط لیپ‌شیتز^۱ درباره‌ی معادلات دینامیکی، مسیرهای حالت سیستم یکدیگر را قطع نمی‌کنند. در این روش بررسی می‌شود که در مسیرهای حالت، که از تصویر کردن کاذب در فضایی با بعد پایین ناشی شده است، انقطع کاذب چه زمانی متوقف می‌شود؟ فرض کنید که کمترین بعد بازسازی برای سری زمانی m_0 باشد؛ یعنی در یک فضای تأخیر یافته‌ی m_0 بعدی، بستر جذب بازسازی شده‌ی یک تصویر یک به یک از بستر جذب واقعی در فضای فاز اصلی است؛ به خصوص که در این بعد خواص توپولوژیک حفظ شده‌اند، بنابراین همسایه‌ی یک نقطه در فضای اصلی به

در تحلیل‌ها ضروری است و انتخاب دلخواه برای استخراج دینامیک داده‌ها مناسب نیست. اگر τ در مقایسه با مقیاس‌های زمانی مربوط به ذات سیستم بسیار کوچک استخاب شود، مؤلفه‌های متوالی در بردار تأخیر به شدت به هم نزدیک و وابسته شده و لذا تمام بردارهای تأخیر در فضای بازسازی m بُعدی در حوالی محور قطری فضا متمرکز می‌شوند. اما؛ گر τ بسیار بزرگ انتخاب شود، مؤلفه‌های متفاوت کاملاً قاهمبسته می‌شوند. در این حالت با وجود ساده بودن جاذب واقعی سیستم ساده، ممکن است جاذب بازسازی شده بسیار پیچیده شود.

برای محاسبه‌ی τ بهینه،تابع خودهمبستگی و اطلاعات مشترک^۲ مفیدند (۳۱، ۳۲). τ در روش اول محلی در نظر گرفته می‌شود که در آن اولین مقدار تابع خودهمبستگی به صفر و یا کمتر از یک مقدار کوچک برسد و در روش دوم زمان رخ دادن اولین کمینه در تابع میانگین اطلاعات متقابل. براساس نظریه‌ی بازسازی ویتنی^۳، یک فضای خم شده‌ی d بُعدی می‌تواند بدون هیچ‌گونه تقاطعی^۴ به یک فضای $2d + 1$ بُعدی نگاشت یابد (۳۳). این نظریه توسط نظریه‌ی تأخیر بازسازی تاکنز توسعه یافت (۳۴). تاکنز همچنین نشان داد که برای بازسازی کامل فضای فاز حداقل $2d + 1$ تأخیر زمانی لازم است (۱). از طرف دیگر، روش کائو^۵ می‌تواند بعد بهینه برای بازسازی فضای حالت سیستم‌های دینامیکی را با استفاده از یکی از متغیرهای حالت محاسبه کند (۳۷). در این مقاله، برای انتخاب تأخیر زمانی از روش اطلاعات متقابل و برای انتخاب بعد بازسازی از روش شمارش نزدیک‌ترین همسایه‌ی کاذب^۶ استفاده شده است.

روش اطلاعات متقابل: روش اطلاعات متقابل را فراسر^۶ و سوئینی^۷ در سال ۱۹۸۶ برای محاسبه‌ی تأخیر زمانی پیشنهاد کردند. امتیاز این روش نسبت به روش خودهمبستگی، در نظر گرفتن همبستگی‌های غیرخطی در سری زمانی است. اطلاعات متقابل برای مقادیر مختلف τ به کمک رابطه‌ی ۲ محاسبه می‌شود.

$$M(\tau) = - \sum_{i,j} p_{ij}(\tau) \ln \frac{p_{ij}(\tau)}{p_i p_j} \quad (2)$$

در رابطه‌ی ۲، p_i احتمال یافتن یک مقدار سری زمانی در نامین فاصله؛ (τ) احتمال مشترکی است که یک مشاهده در فاصله‌ی τ ام و مشاهده‌ی بعدی با تأخیر τ در زامین فاصله اتفاق بیفتد. در نهایت اولین کمینه‌ی تابع M

- | | |
|-----------------------|----------------------------|
| 1. Mutual Information | 5. False nearest neighbors |
| 2. Whitney | 6. Fraser |
| 3. Self-intersection | 7. Swinney |
| 4. Cao | 8. Linschitz |

جدول ۱- مقدار تأخیر بهینه و کمینه بُعد بازسازی برای پنج داده

داده	مقدار تأخیر بهینه (τ)	کمینه بُعد بازسازی (m)
A	۵	۱۰
B	۶	۹
C	۱۱	۷
D	۱۲	۸
E	۱۰	۶

می‌مانند. این خاصیت را "حساسیت به شرایط اولیه" نامیده‌اند.

قابلیت کنترل آشوب: در مدیریت سیستم‌های غیرخطی، مسئله‌ای کنترل آشوب اهمیت خاصی دارد. سیستم‌های آشوبی به‌علت ساختار مشخص غیرخطی کنترل‌پذیرند، در حالی که فرآیندهای تصادفی چنین قابلیتی ندارند؛ زیرا هیچ ساختار مشخصی برای آنها وجود ندارد.

ابعاد دینامیک‌ها: دینامیک‌های آشوبی جاذب‌های پیچیده‌ای ایجاد می‌کنند که کل فضا را پوشش نمی‌دهند و فقط محدود به قسمتی از آن هستند. برای محاسبه‌ی بُعد آشوب و دینامیک‌های پنهان، روش‌های مختلفی پیشنهاد شده است که از میان آنها می‌توان به دو بعد همبستگی و فرکتال و نماهای لیپانوف و هرست اشاره کرد.

همسايه‌ای در فضای فاز تأخیریافته نگاشته می‌شود. به دلیل فرض هموار بودن دینامیک‌ها، همسایه‌های نقاط نیز به همسایه‌هایی نگاشته می‌شوند که شکل و قطر همسایه‌گی براساس نماهای لیپانوف تغییر می‌کند. فرض کنید که بستر جذب در بُعدی کوچک‌تر از بُعد واقعی محاط شود، بر اثر این تصویر کردن، ساختار توپولوژیکی به خوبی حفظ نشده و نقاط به همسایه‌هایی از دیگر نقاط، که در واقع در بُعد بالاتر همسایه نبودند، نگاشته می‌شوند. این نقاط را همسایه‌های کاذب نامیده‌اند. به صورت نظری می‌توان گفت، برای هر نقطه‌ی x_i در سری زمانی، نزدیک‌ترین همسایه x_j در فضای m بُعدی یافت می‌شود. سپس فاصله‌ی این دو نقطه در این فضا محاسبه و $E(i)$ به کمک رابطه‌ی 3 برای تمام مقادیر i محاسبه می‌شود.

$$E(i) = \frac{\|x_{i+1} - x_{j+1}\|}{\|x_i - x_j\|} \quad (3)$$

اگر (i) از یک آستانه‌ی مشخص تجاوز کند، این نقطه برچسب همسایه‌ی کاذب می‌خورد. برای تعیین بُعد بازسازی کافی است کسر نقاطی که در آنها $E(i) > E(j)$ است، صفر و یا خیلی کوچک شود؛ به عبارت دیگر نمودار $E(j)/E(i)$ تقریباً به اشباع برسد.

در این مقاله، با استفاده ازتابع fnn نوشته‌ی دیوید چلیدز^۱ (۲۰۰۹) در نرم‌افزار Matlab، کمینه بُعد بازسازی محاسبه شده است. مقدار تأخیر بهینه و بُعد بازسازی کمینه برای پنج داده A در جدول ۱ آمده است.

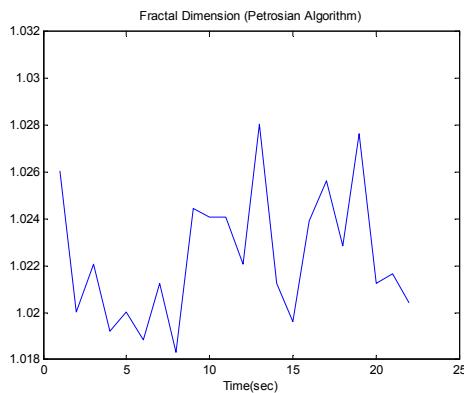
حساسیت به شرایط اولیه: در سیستم‌های آشوبی، بعد از گذشت زمان‌های طولانی، کوچک‌ترین تغییر در مقدار اولیه، به رفتاری کاملاً متفاوت منجر می‌شود. اگر دو جواب مختلف یک معادله‌ی مشخص، صرفاً با توجه به یک تفاوت جزئی در مقدار اولیه (در ناحیه‌ی آشوب) در نظر گرفته شوند، آن دو جواب با گذشت زمان نسبت به هم واگرا می‌شوند؛ اگرچه هر دو در ناحیه‌ی محدودی از فضایی حالت باقی

۲- تحلیل کمی استخراج ویژگی‌های آشوب‌گون

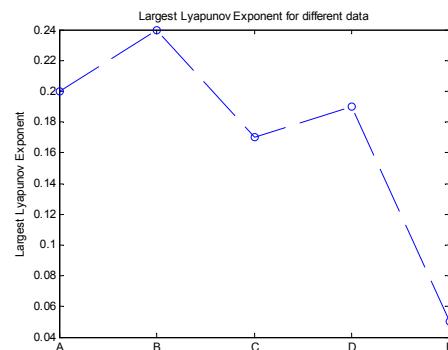
در این تحقیق، برای تشخیص و کمی‌سازی وجود آشوب در سری‌های زمانی از روش‌های مختلفی نظریه بزرگ‌ترین نمای لیپانوف، بُعد فرکتال و نمای هrst استفاده شده است.

نمای لیپانوف: استفاده از نماهای تغییرناپذیر در مطالعه‌ی پایداری سیستم‌های دینامیکی را سونیا کوالسکایا مطرح کرد. بعدها این نظریه را الکساندر میخایلویچ لیپانوف توسعه داد. نمای لیپانوف، میزان واگرایی مسیرهای حالت را اندازه‌گیری می‌کند و از آن می‌توان به عنوان معیاری برای اندازه‌گیری آشوب و وجود آن در یک پدیده بهره جُست (۴۲). برای محاسبه‌ی بزرگ‌ترین نمای لیپانوف روش‌های مختلفی نظری روشن‌های مبتنی بر ژاکوبین و مستقیم وجود دارد. در این تحقیق برای محاسبه‌ی نمای لیپانوف، از روش مستقیم ولف استفاده شد (۴۲). بزرگ‌ترین نمای لیپانوف برای بخشی از داده‌ای مختلف A در شکل ۷ آمده است.

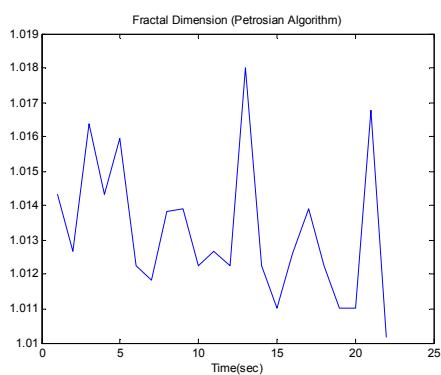
1. David Chelidze



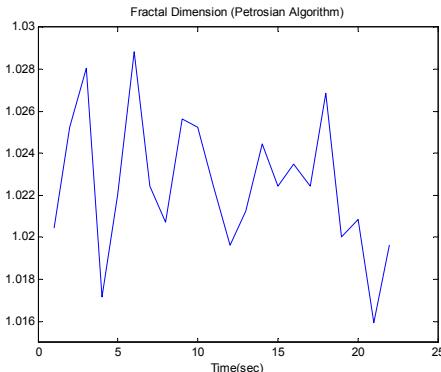
شکل ۸- نمودار تغییرات بُعد فرکتال به روش پتروشن برای بخشی از داده‌ی A



شکل ۷- محاسبه‌ی بزرگ‌ترین نمای لیاپانوف برای بخشی از داده‌های مختلف TA



شکل ۹- نمودار تغییرات بُعد فرکتال به روش پتروشن برای بخشی از داده‌ی B



شکل ۱۰- نمودار تغییرات بُعد فرکتال به روش پتروشن برای بخشی از داده‌ی C

زیر است: یک سری زمانی $X = X_1, X_2, \dots, X_n$ را در نظر بگیرید و سپس داده‌ها را به شکل رابطه‌ی ۵ بهنجار کنید.

$$Z_r = X_r - X_m, \quad r = 1, 2, \dots, n \quad (5)$$

فرکتال: این بُعدها نشان‌دهنده‌ی خواص هندسی بستر جذب هستند. برای محاسبه‌ی بُعد فرکتال در حوزه‌ی زمان و فضای فاز، دو روش عمده وجود دارد. در حوزه‌ی زمان، بُعد فرکتال مستقیماً در حوزه‌ی زمان و یا حوزه‌ی شکل موج اصلی (حوزه‌ای که در آن شکل موج و سیگنال اصلی یک شکل هندسی در نظر گرفته می‌شوند) تخمین زده می‌شود. در حوزه‌ی فضای فاز، تخمین بُعد فرکتال جاذب در فضای حالت انجام می‌شود. در محاسبه‌ی بُعد فرکتال در حوزه‌ی زمان، بین تغییرات پیچیدگی و تغییرات سیگنال در طول زمان یک ارتباط مستقیم وجود دارد، بنابراین برای آشکارسازی هرگونه رفتار غیرطبیعی در این سیگنال‌ها این روش ابزار محاسباتی سریعی خواهد بود. برای محاسبه‌ی بُعد فرکتال در حوزه‌ی زمان الگوریتم‌های مختلفی نظیر الگوریتم پتروشن، کتز و هایوچی وجود دارند که از آن میان روش پتروشن برای محاسبه‌ی بُعد فرکتال بسیار ساده و سریع است(۴۳، ۴۴). در این روش بُعد از رابطه‌ی ۴ بدست می‌آید:

$$(4) D = \frac{\log_{10} n}{\log_{10} n + \log_{10} \left(\frac{n}{n + 0.4 * N_\Delta} \right)}$$

در رابطه‌ی ۴، n طول سیگنال و N_Δ تعداد تغییر علامت مشتق سیگنال است و به دلیل گستگی، تفاضل متواالی آن است. تغییرات بُعد فرکتال به روش پتروشن برای بخشی از داده‌ی A تا E به ترتیب در شکل‌های ۸ تا ۱۲ نمایش داده شده است.

نمای هرسست: آزمون نمای هرسست بر مبنای مطالعات ادین هرسست (۴۵)، برای مطالعه‌ی پدیده‌های طبیعی مانند تشخیص جریان آب در سد روی رود نیل، انجام شد. نمای هرسست یک مقدار کمی برای خواص فرکتالی و سنجشی از تغییرات سیگنال است. روش اجرای آزمون هرسست به شرح

بدیهی است که چون میانگین Y صفر است، بیشترین مقدار Y_r همیشه بزرگ‌تر و یا مساوی صفر و کمترین مقدار آن همیشه کوچک‌تر و یا مساوی صفر خواهد بود. بنابراین $R(n)$ همیشه غیرمنفی خواهد بود. هرست با استفاده از قاعده‌ی نصف در آمار رابطه‌ی ۹ را تعریف کرد:

$$\frac{R(n)}{S(n)} = a \cdot n^H, \text{ as } n \rightarrow \infty \quad (9)$$

در رابطه‌ی ۹، انحراف معیار سری زمانی، a عدد ثابت، n تعداد مشاهدات و H نمای هرست است. $S(n)$ را می‌توان با استفاده از رابطه‌ی ۱۰ محاسبه کرد:

$$S(n) = \sqrt{\frac{1}{n} \sum_{i=1}^n (X_i - X_m)^2} \quad (10)$$

رابطه‌ی ۹ را می‌توان به صورت رابطه‌ی ۱۱ نیز نوشت:

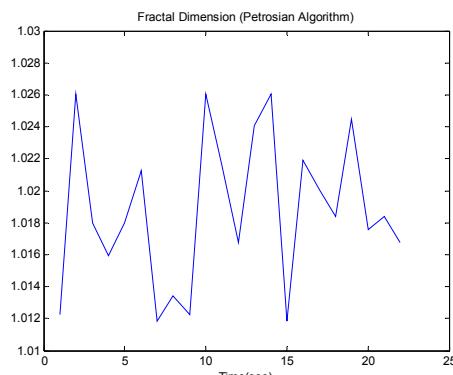
$$\log\left(\frac{R(n)}{S(n)}\right) = \log a + H \log(n) \quad (11)$$

نمای هرست عددی بین صفر تا یک و نشان‌دهنده‌ی خودهمانندی^۱ است. بر پایه‌ی نتایج هرست، نمای هرست 0.5 دال بر ناهمبستگی در سری زمانی؛ هرست بین 0.0 و 0.5 دال بر همبستگی مثبت در سری زمانی دوامدار^۲ با حافظه‌ی طولانی مدت و در نهایت نمای هرست بین صفر و 0.5 حاکی از همبستگی منفی در سری زمانی بی‌دوام^۳ است. منحنی لگاریتم-لگاریتم برای بخشی از داده‌های A تا E به ترتیب در شکل‌های ۱۳ تا ۱۷ نمایش داده است. نمای هرست شبی خطی است که بر این منحنی‌ها برآش می‌شود.

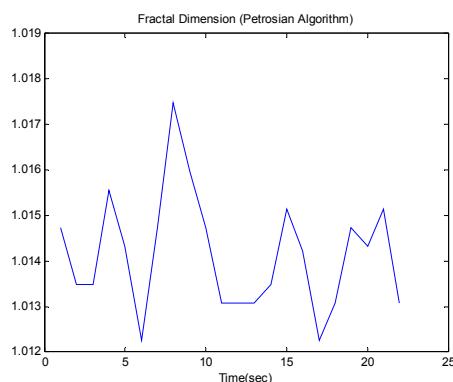
هنجارت‌سازی ویژگی‌ها

در دسته‌بندی، معمولاً ویژگی‌های مختلف، که از نظر گستردگی دامنه با یکدیگر تفاوت دارند، استخراج می‌شوند. در این تحقیق، برای عملکرد بهینه‌ی سیستم شناخت، ویژگی‌ها در بازه‌ی $1\text{--}12$ به وسیله‌ی رابطه‌ی ۱۲ هنجارت‌سازی شدند.

1. Self-similarity (or Self-affine)
2. Persistent
3. Antipersistent



شکل ۱۱- نمودار تغییرات بعد فرکتال به روشن پتروشن برای بخشی از داده‌ی D



شکل ۱۲- نمودار تغییرات بعد فرکتال به روشن پتروشن برای بخشی از داده‌ی E

در رابطه‌ی ۵، مقدار میانگین سری است که با رابطه‌ی ۶ محاسبه می‌شود.

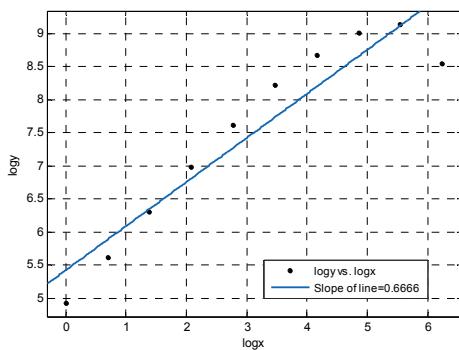
$$X_m = \frac{1}{n} \sum_{i=1}^n X_i \quad (6)$$

در مرحله‌ی بعد، سری زمانی جدیدی به صورت رابطه‌ی ۷ محاسبه می‌شود.

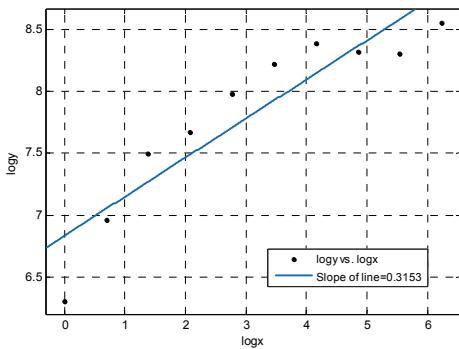
$$Y_r = Z_1 + Z_r, \quad r = 2, \dots, n \quad (7)$$

از آنجاکه میانگین Z صفر است، آخرین مقدار (Y_n) همیشه صفر خواهد بود. دامنه‌ی تعديل شده $(R(n))$ به وسیله‌ی رابطه‌ی ۸ محاسبه می‌شود.

$$R(n) = \max(Y_1, \dots, Y_n) - \min(Y_1, \dots, Y_n) \quad (8)$$



شکل ۱۶- نمودار نمای هرست مربوط به بخشی از داده‌ی D



شکل ۱۷- نمودار نمای هرست مربوط به بخشی از داده‌ی E

دسته‌بندی می‌کند. در این قانون یک الگوی نامشخص جدید به دسته‌ای که با احتمال بیشتری به آن تعلق دارد، دسته‌بندی می‌شود. فرض کنید، بردار ویژگی و یا بردار مشاهده‌ی x در اختیار بوده و هدف انتساب به یکی از دسته‌های $\omega_1, \omega_2, \dots, \omega_c$ باشد، بنابراین دیدگاه آمار و احتمال به دنبال معیاری برای دسته‌بندی x به محتمل‌ترین دسته است. برای سادگی فرض می‌شود دو دسته‌ی وجود دارد ($c = 2$) و احتمال‌های پیشین ($P(\omega_1)$ و $P(\omega_2)$) معلوم‌اند. اگر N تعداد کل داده‌ی آموزش و N_1 و N_2 به ترتیب داده‌های متعلق به دسته‌های ω_1 و ω_2 باشند، آن‌گاه بر اساس رابطه‌ی ۱۳ عمل می‌شود.

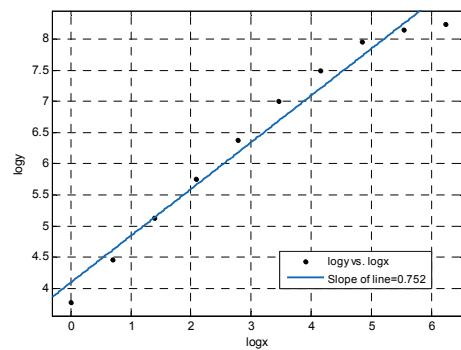
$$P(\omega_1) = \frac{N_1}{N} \quad (13)$$

$$P(\omega_2) = \frac{N_2}{N}$$

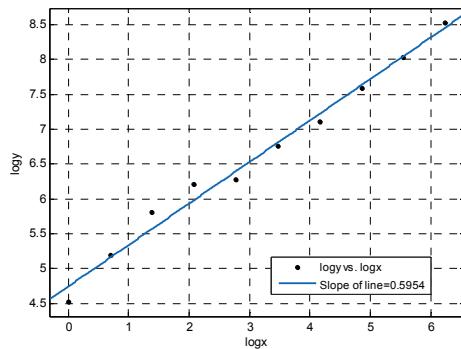
طبق قاعده‌ی بیز(۴۶)، محاسبه‌ی مستقیم احتمال پسین ممکن نیست، بنابراین براساس احتمالات پیشین وتابع درست‌نمایی، طبق رابطه‌ی ۱۴ عمل می‌شود.

$$P(\omega_i | x) = \frac{P(x | \omega_i) P(\omega_i)}{P(x)}, \quad i = 1, 2 \quad (14)$$

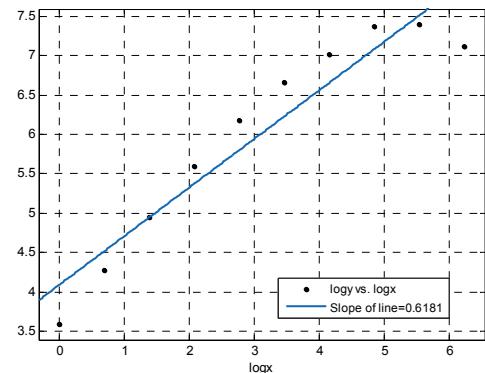
در رابطه‌ی ۱۴ $P(x | \omega_i)$ تابع چگالی احتمال دسته‌ی ω_i ؛



شکل ۱۳- نمودار نمای هرست مربوط به بخشی از داده‌ی A



شکل ۱۴- نمودار نمای هرست مربوط به بخشی از داده‌ی B



شکل ۱۵- نمودار نمای هرست مربوط به بخشی از داده‌ی C

$$Y_{norm} = \frac{-2Y_s' + Y_{s\max}' + Y_{s\min}'}{Y_{s\min}' - Y_{s\max}'} \quad (12)$$

در رابطه‌ی ۱۲، Y_s' مقدار دامنه‌ی بردار ویژگی، $Y_{s\max}'$ مقدار دامنه‌ی بیشینه‌ی بردار ویژگی، $Y_{s\min}'$ مقدار دامنه‌ی کمینه‌ی بردار ویژگی و Y_{norm} مقدار دامنه‌ی نسبی است که در محدوده‌ی ۰-۱ قرار می‌گیرد.

دسته‌بندی کننده‌ی بیزین

دسته‌بندی کننده‌ی بیزین، براساس قانون بیز و با فرض یک تابع چگالی احتمال مشخص برای داده‌های هر دسته، آنها را

جدول ۲- مقادیر صحت دسته‌بندی کننده برای سه آزمایش

مختلف		نوع آزمایش	صحت دسته‌بندی کننده (به درصد)
۹۹/۲	طبیعی- پیش‌حمله‌ای	۹۹/۷	طبیعی- حمله‌ای
۹۹/۱	پیش‌حمله‌ای- حمله‌ای		

نحوه محاسبه‌ی هر یک از این پارامترها در رابطه‌ی ۲۵ آمده است.

$$Sensitivity = \frac{T_P}{T_P + F_N}$$

$$Specificity = \frac{T_N}{T_N + F_P} \quad (25)$$

$$Accuracy = \frac{T_P + T_N}{T_P + T_N + F_P + F_N}$$

در رابطه‌ی ۲۵، توضیح T_P, T_N, F_P و F_N برای تمایز بین دو گروه صرعنی و طبیعی به این شرح است. T_P داده‌های صرعنی است که صرع آنها درست تأیید شده است؛ F_P داده‌های طبیعی است که به اشتباه صرعنی تشخیص داده شده‌اند؛ T_N داده‌های طبیعی است که به درستی طبیعی تشخیص داده شده‌اند و F_N داده‌های صرعنی است که به اشتباه طبیعی تشخیص داده شده‌اند. جدول ۳ گزارش مقادیر محاسبه شده‌ی حساسیت، میزان عدم اشتراک و صحت سه آزمایش را نشان می‌دهد.

تاکنون پژوهشگران برای تشخیص صرع، روش‌های گوناگونی پیشنهاد کرده‌اند. جدول ۴ مقایسه‌ی نتایج این روش را با دیگر روش‌های پیشنهادی نشان می‌دهد.

بحث و نتیجه‌گیری

صرع یکی از بیماری‌های دستگاه اعصاب مرکزی است که برای تشخیص آن، در این تحقیق، از سیگنال مغزی استفاده شده است. شواهد نشان می‌دهد که سیگنال مغزی ماهیّت آشوب‌گون دارد، بنابراین در این تحقیق نگرش صحیح به سیگنال مغزی اهمیّت دارد. این تحقیق با دو دیدگاه کیفی و کمی اجرا شد. برای برچسب صحیح سیگنال مغزی، دیدگاه کیفی و کمک افراد خبره به کار رفت. از میان مشخصه‌های تحلیل کیفی می‌توان به طیف فرکانسی، ساختار فضای فاز و ابعاد دینامیک‌ها (تحلیل شهودی نمای لیاپانوف، بُعد فرکتال و نمای هرست) اشاره کرد. در صورت هم‌سو بودن تحلیل شهودی و شواهد کیفی و نظر فرد خبره، از داده برای بخش آموزش تحلیل کمی استفاده می‌شد؛ در غیراین صورت داده

($P(\omega_i)$) احتمال وقوع دسته‌ی ω_i (احتمال پیشین دسته‌ی ω_i)؛ ($P(x)$) احتمال وقوع بردار x و ($P(\omega_i|x)$) احتمال مشاهده‌ی بردار x است. وقتی مشخص است که بردار x به دسته‌ی ω_i تعلق دارد، به اصطلاح گفته می‌شود تابع درستنمایی دسته‌ی ω_i نسبت به x اکنون برای انتخاب محتمل‌ترین دسته کافی است، احتمالات رابطه‌ی ۱۵ با یکدیگر مقایسه شوند.

$$\text{If } P(\omega_1 | x) > P(\omega_2 | x) \Rightarrow x \in \omega_1 \quad (15)$$

$$\text{If } P(\omega_1 | x) < P(\omega_2 | x) \Rightarrow x \in \omega_2$$

$$\text{If } P(\omega_1 | x) = P(\omega_2 | x) \Rightarrow \text{arbitrary}$$

همان‌طور که رابطه‌ی ۱۵ نشان می‌دهد، در حالت تساوی x می‌تواند به هر کدام از دو دسته نسبت داده شود. با توجه به فرمول قاعده‌ی بیز، تصمیم‌گیری معادل با حل نامساوی ۱۶ است.

$$\text{If } P(x | \omega_1)P(\omega_1) > P(x | \omega_2)P(\omega_2) \Rightarrow x \in \omega_1 \quad (16)$$

$$\text{If } P(x | \omega_1)P(\omega_1) < P(x | \omega_2)P(\omega_2) \Rightarrow x \in \omega_2$$

در این حالت اگر $P(\omega_2) = P(\omega_1)$ باشد، کافی است توابع چگالی احتمال $P(x | \omega_1)$ و $P(x | \omega_2)$ با یکدیگر مقایسه شوند. حال می‌توان رابطه‌ی ۱۶ را به رابطه‌ی ۱۷ تبدیل کرد.

$$l(x) = \frac{P(x | \omega_1)}{P(x | \omega_2)}$$

$$l(x) > \frac{P(\omega_2)}{P(\omega_1)} \Rightarrow x \in \omega_1 \quad (17)$$

$$l(x) < \frac{P(\omega_2)}{P(\omega_1)} \Rightarrow x \in \omega_2$$

که در آن $l(x)$ را نسبت درستنمایی گویند. در عمل راحت‌تر است که بر اساس رابطه‌ی ۱۸ با منفی لگاریتم کار شود.

$$-\ln(l(x)) = -\ln P(x | \omega_1) + \ln P(x | \omega_2) \quad (18)$$

گوسی بودن توابع توزیع در رابطه‌ی ۱۸، نتیجه را به یک تابع تفکیک خطی می‌رساند.

یافته‌ها

برای رسیدن به اهداف تحقیق، سه آزمایش مختلف شامل تفکیک داده‌ی طبیعی از پیش‌حمله‌ای، طبیعی از حمله‌ای و پیش‌حمله‌ای از حمله‌ای طراحی شد. جدول ۲ گزارش مقادیر صحت دسته‌بندی کننده برای سه آزمایش را نشان می‌دهد. عملکرد آزمون با محاسبه‌ی پارامترهای آماری مانند حساسیت، میزان عدم اشتراک و صحت ارزیابی می‌شود.

جدول ۳- مقادیر محاسبه شده‌ی حساسیت، ویژگی و صحت سه آزمایش مختلف

نوع آزمایش	صحت(به درصد)	میزان عدم اشتراک(به درصد)	حساسیت(به درصد)
طبیعی-پیش‌حمله‌ای	۹۹/۲	۹۹/۵	۹۸/۹
طبیعی-حمله‌ای	۹۹/۷	۹۹/۴	۱۰۰
پیش‌حمله‌ای-حمله‌ای	۹۷/۱	۹۵/۲	۹۹

جدول ۴- مقایسه‌ی نتایج این تحقیق با نتایج سایر تحقیقات

مرجع	روش	نوع دسته‌بندی	صحت(به درصد)
(۱۴)	آنتروپی و سیستم عصبی فازی تطبیقی	A, E	۹۰
(۷)	تبديل موجک و سیستم عصبی فازی تطبیقی	A, E	۹۴
(۱۵)	آنتروپی و شبکه عصبی مصنوعی المان	A,E	۱۰۰
(۴۷)	تحلیل زمان - فرکانس و شبکه عصبی مصنوعی	A, E	۱۰۰
(۴۸)	شبکه عصبی مصنوعی	A, E	~۱۰۰
(۴۹)	تبديل موجک و شبکه عصبی مصنوعی	A, E	۹۹/۶
(۵۰)	تبديل موجک و آنتروپی	(A, C, D), E	۹۶/۶۵
(۴۹)	تبديل موجک و شبکه عصبی مصنوعی	(A, C, D), E	۹۷/۷۵
(۴۷)	تحلیل زمان - فرکانس و شبکه عصبی مصنوعی	(A, B, C, D), E	۹۷/۷۳
(۴۹)	تبديل موجک و شبکه عصبی مصنوعی	(A, B, C, D), E	۷۷,۷۷
(۸)	تبديل موجک و ماشین بردار پشتیبان	(A, B), E	۹۴/۸۶
(۵۱)	نمای هrstت، نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(A, B), (C, D)	۹۷/۴
(۵۱)	نمای هrstت، نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(A, B), E	۹۶/۹
(۵۱)	نمای هrstت، نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(C, D), E	۹۶/۵
(۵۲)	نمای هrstت، بعد همبستگی، بعد فرکتال، بزرگترین نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(A, B), (C, D)	۹۸/۶
(۵۲)	نمای هrstت، بعد همبستگی، بعد فرکتال، بزرگترین نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(A, B), E	۹۸/۱
(۵۲)	نمای هrstت، بعد همبستگی، بعد فرکتال، بزرگترین نمای لیاپانوف و سیستم عصبی فازی تطبیقی	(C, D), E	۹۷/۲
آزمایش ۱	نمای هrstت، بعد فرکتال، بزرگترین نمای لیاپانوف و دسته‌بندی کننده‌ی بیزین	(A, B), (C, D)	۹۹/۲
آزمایش ۲	نمای هrstت، بعد فرکتال، بزرگترین نمای لیاپانوف و دسته‌بندی کننده‌ی بیزین	(A, B), E	۹۹/۷
آزمایش ۳	نمای هrstت، بعد فرکتال، بزرگترین نمای لیاپانوف و دسته‌بندی کننده‌ی بیزین	(C, D), E	۹۷/۱

صحت ۹۷/۱ درصد به ترتیب از یکدیگر تفکیک شده‌اند. نتایج این روش تحقیق توانسته است نسبت به (۳۴، ۳۵) و همچنین نسبت به بقیه‌ی تحقیقات، با در نظر گرفتن نوع تقسیم‌بندی داده، بهبود خوبی در نتایج حاصل کند که این می‌تواند مفید بودن روش تحلیل آشوب‌گون در بازیابی رفتار مغز در حالات صرعی را نشان دهد.

تشکر و قدردانی

این تحقیق حاصل طرح پژوهشی است که با حمایت‌های مادی و معنوی دانشگاه آزاد اسلامی واحد شاهroud اجرا شد. بدین وسیله از زحمات دکتر سید مهران همام، متخصص مغز و اعصاب، قدردانی و از داور ارزشمند نیز تشکر می‌شود.

دریافت: ۹۲/۷/۲؛ پذیرش: ۹۳/۵/۱۵

برای بخش آموزش به کار نمی‌رفت. همان‌طور که از تحلیل‌ها مشاهده می‌شود، نمای لیاپانوف مثبت، بُعد فرکتال و نمای هrstت شاهدی بر وجود آشوب در پدیده است. این موارد به افزایش نظم در سیستم دینامیکی مغز بر می‌گردد. به عبارت دیگر، تعداد معادلات دینامیکی لازم برای توصیف سیستم دینامیکی مغز در هنگام صرع کاهش می‌یابد. در این مقاله از روش اطلاعات متقابل برای انتخاب تأخیر زمانی و همچنین از روش شمارش نزدیکترین همسایه کاذب برای انتخاب بُعد بازسازی استفاده شد. برای استخراج ویژگی، مشخصه‌هایی نظیر بُعد فرکتال، بزرگترین نمای لیاپانوف و نمای هrstت استخراج و سپس این ویژگی‌ها به دسته‌بندی-کننده‌ی بیزین داده شد تا دسته‌های مختلف از یکدیگر تفکیک شوند. نتایج نشان می‌دهند که دو دسته‌ی طبیعی و پیش‌حمله‌ای با متوسط صحت ۹۹/۲ درصد و همچنین دو دسته‌ی طبیعی و حمله‌ای با متوسط صحت ۹۹/۷ درصد و همچنین دو دسته‌ی پیش‌حمله‌ای و حمله‌ای با متوسط

منابع

1. Litt B, Echauz J. Prediction of epileptic seizures. *Lancet Neurology* 2002;1(1):22-30.
2. Engel J, Pedley TA. *Introduction: what is epilepsy?* In J. Engel, T.A. Pedley (Eds.) *Epilepsy: A comprehensive textbook*. Lippincott-Raven, Philadelphia 1997: 2.
3. daSilva F, Blanes W, Kalitzin S, Parra J, Suffczynski P, Velis D. Dynamical diseases of brain systems: different routes to epileptic seizures. *IEEE Transaction on Biomedical Engineering* 2003;50(5):540-48.
4. Nigam VP, Graupe D, A neural-network-based detection of epilepsy. *Neurological Research*, 2004;26(1):55-60.
5. Srinivasan V, Eswaran C, Sriraam N. Artificial neural network based epileptic detection using time-domain and frequency-domain features. *Journal of Medical Systems* 2005;29(6):647-60.
6. Kerr WT, Anderson A, Lau EP, Cho AY, Xia H, Bramen J, et al. Automated diagnosis of epilepsy using EEG power spectrum. *Epilepsia* 2012;53(11):189-92.
7. Subasi A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction. *Journal of Computers in Biology and Medicine* 2007;37(2):227-44.
8. Liu Y, Zhou W, Yuan Q, Chen S. Automatic seizure detection using wavelet transform and SVM in long-term intracranial EEG. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 2012;20(6):749-55.
9. Guler I, Ubeyli ED. Application of adaptive neuro-fuzzy inference system for detection of electrocardiographic changes in patients with partial epilepsy using feature extraction. *Journal of Expert Systems with Applications* 2004;27:323-30.
10. Ktonas PY. Automated spike and sharp wave (SSW) detection. In A.S. Gevins, A. Remond (Eds.), *Methods of analysis of brain electrical and magnetic signals*, Amsterdam: Elsevier 1987: 211-41.
11. Chua KC, Chandran V, Acharya R, Lim CM. Higher order spectral (HOS) analysis of epileptic EEG signals. *29th Annual International Conference of the IEEE EMBS*, Lyon, France; 2007.
12. Hosseini SA, Akbarzadeh-T MR, Naghibi-Sistani MB. Automatic epilepsy recognition with using higher order spectra analysis of EEG signals. *11th Iranian Conference on Intelligent Systems*, Kharazmi University, Tehran; 2013.
13. Pravin-Kumar S, Sriraam N, Benakop PG, Jinaga BC. Entropies based detection of epileptic seizures with artificial neural network classifiers. *Journal of Expert systems with application* 2010;37(4):3284-291, 2010.
14. Kannathal N, Lim CM, Acharya UR, Sadasivan PK. Entropies for detection of epilepsy in EEG. *Journal of Computer Methods and Programs in Biomedicine* 2005; 80(3):187-94.
15. Srinivasan V, Eswaran C, Sriraam N. Approximate entropy-based epileptic EEG detection using artificial neural networks. *IEEE Transactions on Information Technology in Biomedicine* 2007;11(3):288-95.
16. Tito M, Cabrerizo M, Ayala M, Barreto A, Miller I, Jayakar P, et al. Classification of electroencephalographic seizure recordings into ictal and interictal files using correlation sum. *Computers in Biology and Medicine* 2009;39(7):604-14.
17. Lerner DE. Monitoring changing dynamics with correlation integrals: Case study of an epileptic seizure. *Physica D* 1996;97(4):563-76.
18. Gotman J. Automatic recognition of epileptic seizures in the EEG. *Electroencephalography and Clinical Neurophysiology* 1982;54(5):530-40.
19. Murro AM, King DW, Smith JR, Gallagher BB, Flanigin HF, Meador K. Computerized seizure detection of complex partial seizures. *Electroencephalogr Clin Neurophysiol* 1991;79(4):330-33.
20. Subasi A, Ercelebi E. Classification of EEG signals using neural network and logistic regression. *Computer Methods and Programs in Biomedicine* 2005;78(2):87-99.
21. Subasi A. Application of adaptive neuro-fuzzy inference system for epileptic seizure detection using wavelet feature extraction. *Journal of Computers in Biology and Medicine* 2007;37:227-44.
22. Veysi I, Karimpour A, Pariz N, Shakeri MT. A novel method for detection of epilepsy in short and noisy EEG signals using ordinal pattern analysis. *Iranian Journal of Medical Physics* 2010;7(1):79-92.
23. Kumar SP, Sriraam N, Benakop PG, Jinaga BC. Entropies based detection of Epileptic seizures with artificial neural network classifiers. *Journal of Expert System with Applications* 2010; 37(4):3284-91.
24. Adeli H. Chaos-wavelet-neural network models for automated EEG-based diagnosis of the neurological disorders. *17th International Conference on Systems, Signals and Image Processing* 2010:45-8.
25. Ghosh-Dastidar S, Adeli H, Dadmeher N. Mixed-band wavelet-chaos-neural network

- methodology for epilepsy and epileptic seizure detection. *IEEE Transaction on Biomedical Engineering* 2007;54(9):827-33.
26. Lehnertz K, Elger CE. Can epileptic seizures be predicted? Evidence from nonlinear time series analysis of brain electrical activity. *Physical Review Letter* 1998;80:5019-22.
 27. Lehnertz K, Andrzejak RG, Arnhold J, Kreuz T, Mormann F, Rieke C, et al. Nonlinear EEG analysis in epilepsy: its possible use for interictal focus localization, seizure anticipation, and prevention. *Journal of Clinical Neurophysiology* 2001;18(3):209-22.
 28. Jerger KK, Weinstein SL, Sauer T, Schiff SJ. Multivariate linear discrimination of seizures. *Clinical Neurophysiology* 2005;116:545-51.
 29. Andrzejak R G, Lehnertz K, Mormann F, Rieke C, David P, Elger CE. Indications of nonlinear deterministic and finite dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state. *Physical Review E* 2001; 64, Available form: <http://epileptologie-bonn.de>
 30. Korn H, Faure P. Is there Chaos in the brain? II. Experimental evidence and related models, C.R. Biologies 2003;326,840-87.
 31. Fraser AM, Swinney HL. Independent coordinates for strange attractors from mutual information. *Physical Review A* 1986; 33(2): 1134-40.
 32. Ng WW, Panu US, Lennox WC. Chaos based analytical techniques for daily extreme hydrological observations. *Journal of Hydrology* 2007;342(1-2):17- 41.
 33. Sprott JC. *Chaos and time-series analysis*. Oxford University Press, 2003.
 34. Takens F. *Detecting strange attractors in turbulence*. Dynamical Systems and Turbulence. Berlin, Germany: Springer-Verlag 1981:366- 81.
 35. Akay M. *Nonlinear biomedical signal processing, dynamic analysis and modeling*. IEEE Press on Biomedical Engineering, 2001;2.
 36. Hegger R, Kantz H, Schreiber T. Practical implementation of nonlinear time series methods: The TISEAN Package. *Chaos* 1999;9(2):413-35.
 37. Ramdani S, Casties JF, Bouchara F, Mottet D. *Influence of noise on the averaged false neighbors method for analyzing time series*. Elsevier Science; 2006.
 38. Radojicic I, Manic D, Vulic D. On the presence of deterministic chaos in HRV signals. *IEEE Transaction on computers in cardiology* 2001;28,465-8.
 39. Kennel M, Brown R, Abarbanel H. Determining embedding dimension for phase-space reconstruction using a geometrical construction. *Physical Review A* 1992;45(6), 3403-11.
 40. Pari-Zangeneh M, Ataei M, Moallem P. Phase space reconstruction of chaotic time series using an intelligent method. *Journal of Intelligent Procedures in Electrical Technology (Electronics and power)* 2009;1(2):3-10. [Persian].
 41. Available form: <http://personal.egr.uri.edu/chelidz/courses/mce567/matlab/fnns.m>
 42. Wolf A, Swift J, Swinney H, Vastano J. Determining lyapunov exponents from a time series. *Physica D* 1985;16:285-317.
 43. Petrosian A. Kolmogorov complexity of finite sequences and recognition of different preictal EEG patterns. *8th IEEE Symposium on Computer-Based Medical Systems* 1995:212-17.
 44. Esteller R, Vachtsevanos G, Echauz J, Litt B. A comparison of waveform fractal dimension algorithms. *IEEE Transactions on Circuits and Systems—I: Fundamental Theory and Applications* 2001;48(2):177-83.
 45. Hurst HE. Long-term storage of reservoirs: an experimental study. *Transactions of the American society of civil engineers* 1951; 116:770-99.
 46. Bishop CM. *Pattern recognition and machine learning* (Information science and statistics). New York: Springer, Heidelberg; 2006.
 47. Tzallas A, Tsipouras M, Fotiadis D. Automatic seizure detection based on time-frequency analysis and artificial neural networks. *Computational Intelligence and Neuroscience* 2007;7(3):1-13.
 48. Tezel G, Ozbay Y. A new approach for epileptic seizure detection using adaptive neural network. *Journal of Expert systems with application* 2009;36(1):172-80.
 49. Guo L, Rivero D, Dorado J, Rabunal JR, Pazos A. Automatic epileptic seizure detection in EEGs based on line length feature and artificial neural networks. *Journal of Neuroscience Methods* 2010;191(1):101-9.
 50. Ocak H. Automatic detection of epileptic seizures in EEG using discrete wavelet transform and approximate entropy. *Journal of Expert Systems with Applications* 2009; 36(2):2027-36.
 51. Hosseini SA, Akbarzadeh-T MR, Naghibi-Sistani MB. Qualitative and quantitative evaluation of EEG signals in epileptic seizure recognition. *Journal of Intelligent Systems and Applications* 2013;5(6):41-6.
 52. Hosseini SA, Akbarzadeh-T MR, Naghibi-Sistani MB. Methodology for epilepsy and epileptic seizure recognition using chaos analysis of brain signals. In K. Kolomvatsos, C. Anagnostopoulos, S. Hadjiefthymiades (Eds.), *Intelligent Technologies and Techniques for Pervasive Computing*, IGI Global; 2013.