

## *A New Approach for Investigating the Complexity of Short Term EEG Signal Based on Neural Network*

Alireza Khorrami moghaddam

Assistant Professor, Department of Radiology, Faculty of Allied Health, Mazandaran University of Medical Sciences, Sari, Iran

(Received December 8, 2020 Accepted July 14, 2021)

### **Abstract**

**Background and purpose:** The nonlinear quality of electroencephalography (EEG), like other irregular signals, can be quantified. Some of these values, such as Lyapunov's representative, study the signal path divergence and some quantifiers need to reconstruct the signal path but some do not. However, all of these quantifiers require a long signal to quantify the signal complexity.

**Materials and methods:** In this study, we present a new approach to investigate the complexity of turbulent signals in short term and use this method to investigate the complexity of EEG. This method is based on signal modeling and we compared this model with the real signal. The importance of this method is its ability to estimate the complexity of short-term signals, especially in signals whose dynamics change rapidly.

**Results:** To quantify the appropriateness of the proposed method, this method was calculated on an EEG signal and also the values of Lyapunov view were calculated by Wolf and Rosenstein and the correlation of the value obtained from the proposed method and two Lyapunov views were calculated. This value was 90% compared to Wolf method and 83% compared to Rosenstein method.

**Conclusion:** The method used in current study, can estimate the complexity of signals in short periods. This quantifier feature is of great help for tracking rapid changes and tracking the time sequence of this change. This quantifier can also be used to detect other disturbed signals.

**Keywords:** chaos, quantifier, neural network, electroencephalography

**J Mazandaran Univ Med Sci 2021; 31 (199): 89-97 (Persian).**

\* **Corresponding Author:** Alireza khorrami moghaddam - Faculty of Allied Health, Mazandaran University of Medical Sciences, Sari, Iran (E-mail: ar.khorrami@gmail.com)

# رویکرد جدید برای بررسی پیچیدگی سیگنال کوتاه مدت EEG بر اساس شبکه عصبی

علیرضا خرمی مقدم

## چکیده

**سابقه و هدف:** کیفیت غیرخطی بودن EEG مانند سایر سیگنال‌های بی‌نظم را می‌توان با مقداری کمی نمود. بعضی از این مقادیر مانند نمای لیاپانوف (Lyapunov) در بررسی واگرایی مسیر سیگنال و برخی از این کمی‌کننده‌ها نیاز به بازسازی مسیر سیگنال دارند و برخی دیگر ندارند. اما همه این کمی‌کننده‌ها برای تعیین کمیت پیچیدگی سیگنال به سیگنال‌های طولانی نیاز دارند.

**مواد و روش‌ها:** در این مطالعه ما یک رویکرد جدید برای بررسی پیچیدگی سیگنال آشفته در کوتاه مدت و استفاده از این روش برای بررسی پیچیدگی EEG ارائه خواهیم نمود. این روش، مبتنی بر مدل‌سازی سیگنال و مقایسه این مدل با سیگنال واقعی است. اهمیت این روش توانایی آن در تخمین پیچیدگی سیگنال کوتاه مدت به ویژه در سیگنال‌هایی است که بویایی آن‌ها به سرعت تغییر می‌کند.

**یافته‌ها:** برای بررسی کمی میزان مناسب بودن روش ارائه شده، این روش بر روی یک سیگنال EEG محاسبه شد و همچنین مقادیر نمای لیاپانوف با دو روش Wolf و Rosenstein محاسبه شد و میزان همبستگی مقدار به دست آمده از روش ارائه شده و دو نمای لیاپانوف محاسبه گردید که مشابهت این مقدار با مقایسه با روش Wolf برابر با 90 درصد و با مقایسه با روش Rosenstein برابر با 83 درصد بود.

**استنتاج:** روش ارائه شده می‌تواند پیچیدگی سیگنال‌ها را در دوره‌های کوتاه مدت تخمین بزند. این ویژگی کمی‌کننده که برای سیگنال‌های کوتاه مدت کاربرد دارد این ویژگی را برای بررسی تغییرات سریع و بررسی زمانی این تغییر قابل استفاده می‌کند. این کمی‌ساز همچنین می‌تواند در بررسی سیگنال‌های آشوب‌گون دیگر نیز مورد استفاده قرار گیرد.

**واژه‌های کلیدی:** آشوب، کمی‌ساز، شبکه عصبی، EEG

## مقدمه

تئوری آشوب، هرج و مرج شامل برخی از بی‌نظمی در آرایه شناخته شده است که یک سری. زمانی نامنظم به ظاهر تصادفی می‌تواند در میزان آشوب‌گونگی تعیین کننده

نظر بررسی متون، آشوب (Chaos) به معنای شلوغی یا بی‌نظمی است. در مباحث فلسفه، این به معنای شرایطی است که در رفتارهای تصادفی نشان داده می‌شود. در

E-mail: ar.khorrami@gmail.com

**مؤلف مسئول:** علیرضا خرمی مقدم - ساری: دانشگاه علوم پزشکی مازندران، دانشکده پیراپزشکی

استادیار، گروه رادیولوژی، دانشکده پیراپزشکی، دانشگاه علوم پزشکی مازندران، ساری، ایران

تاریخ دریافت: 1399/9/18 تاریخ ارجاع جهت اصلاحات: 1399/9/18 تاریخ تصویب: 1400/4/23

باشد (1) پدیده‌های بی‌نظم اغلب در اقتصاد، هواشناسی، فرآیندهای شیمیایی، زیست‌شناسی، هیدرودینامیک و بسیاری از علوم دیگر ظاهر می‌شوند (2). تعریف اساسی این پدیده بهم ریختگی در یک سیستم دینامیکی قطعی است که شیوه قابل پیش‌بینی را در مدت زمان کوتاه نشان می‌دهد اما در طولانی مدت شیوه آن قابل پیش‌بینی نیست. ظاهراً سیستم‌های آشوب‌گون، رفتارهای نویزی از خود نشان می‌دهند، اما در واقع براساس قوانین قطعی رفتار می‌کنند. این سیستم‌ها با حساسیت نسبت به شرایط اولیه معرفی می‌شوند. این بدان معناست که با داشتن دو شرط اولیه در مرحله اول، بعد از چند مرحله واگرایی ایجاد می‌شود. از آن‌جاکه سری‌های زمانی بی‌نظم نویز به نظر می‌آیند، روش‌های خطی برای پردازش آن‌ها مناسب نیستند. با توجه به ویژگی‌های غیرخطی سری‌های زمانی آشوب‌گون، برای مدل‌سازی این سیستم‌ها، ما مجبوریم از مدل‌های غیرخطی استفاده کنیم. بسیاری از محققان از شبکه‌های عصبی به عنوان مدل سری‌های زمانی بی‌نظم استفاده می‌کنند (3-7).

تعداد زیادی روش‌های کمی‌سازی برای بررسی پیچیدگی سیگنال آشفته وجود دارد، اما همه آن‌ها برای قابلیت استفاده به سیگنال طولانی مدت نیاز دارند. مهم‌ترین پدیده در سیستم‌های آشوب‌گون، انحراف دو مسیر مشابه در فضای فاز با گذشت زمان است. در این مطالعه روشی برای تعیین کمیت این واگرایی در کوتاه مدت معرفی خواهیم کرد. این روش براساس مدل‌سازی غیرخطی سیگنال آشوب‌گون و مقایسه سیگنال مدل شده با سیگنال اصلی است. همان‌طور که در بالا معرفی کردیم سیستم‌های آشوب‌گون نسبت به شرایط اولیه بسیار حساس هستند، بنابراین تفاوت کمی بین اولین نمونه از سیگنال مدل شده و سیگنال اصلی در زمان انجام افزایش می‌یابد. این افزایش با استفاده از توان لیاپانوف (Lyapunov) یا ضریب Floquet اندازه‌گیری می‌شود. در سال 2003 V. Golovko روشی مبتنی بر شبکه عصبی را برای تخمین نمای لیاپانوف معرفی می‌کند (8). در مطالعه وی تراژکتوری سیگنال

مدلسازی شده است.

در برخی موارد، پویایی سیستم به سرعت تغییر می‌کند. در این موارد اگر از کمی‌سازهای مرسوم برای برآورد پیچیدگی استفاده کنیم ممکن است نوع این مفهوم را از دست بدهیم. به منظور تجزیه و تحلیل رشد مغز انسان، دانشمندان از روش‌های مختلف تصویربرداری از مغز استفاده می‌کنند. یکی از تکنیک‌های معمول برای اندازه‌گیری فعالیت مغز، EEG است، این سیگنال کاربردهای مختلفی مانند تجزیه و تحلیل فعالیت‌های مغز در حالت‌های مختلف است (9,10). روش ما این ردیابی را امکان‌پذیر می‌کند. از این رو سیگنال EEG رفتارهای آشفته (11-14) را نشان می‌دهد و پویایی آن به سرعت تغییر می‌کند. روش‌های مختلفی برای محاسبه میزان پیچیدگی سیگنال‌های آشوب‌گون مانند EEG ارائه شده‌اند که شامل محاسبه نمای لیاپانوف می‌باشند (15,16). از آن‌جاکه پیچیدگی مغز نشان‌دهنده توانایی مغز در انطباق با شرایط متغیر است و محیط به صورت مداوم در حال تغییر و ارائه ورودی‌های مختلفی به مغز است، تظاهرات سیگنال مغز می‌تواند به صورت مداوم تغییر نماید (17). بنابراین برای ردیابی این تغییر، ما باید پیچیدگی را در دوره‌های کوتاه مدت برآورد کنیم. در این مطالعه تصمیم گرفته شد از روش جدیدی برای بررسی این تغییرات سریع استفاده کنیم. این روش، براساس پیش‌بینی کوتاه مدت سری‌های زمانی آشوب‌گون می‌باشد که در مطالعات گذشته به آن اشاره شده است و نشان داده شده که می‌توان سری‌های زمانی آشوب‌گون را به صورت کوتاه مدت پیش‌بینی نمود (18). در ادامه ما برخی از کمی‌سازهای سنتی سیگنال‌های آشوب‌گون را معرفی خواهیم کرد سپس روش خود را معرفی می‌کنیم و در آخر برای تخمین پیچیدگی این سیگنال از این روش برای سیگنال EEG استفاده خواهیم کرد.

## مواد و روش‌ها

برای تعریف رویکرد مورد نظر، به‌طور خلاصه

روش Rosenstein

Rosenstein و همکاران (1993) الگوریتم دیگری برای محاسبه بزرگترین نمای Lyapunov در سری زمانی کوتاه و نویزی ایجاد کرد (16). مانند قبل، اولین قدم ساختن بازسازی فاز است. سپس نزدیکترین همسایه برای هر بردار تعبیه شده، پیدا می‌شود. پس از این، سیستم مدتی ثابت تکامل یافته و بزرگترین نمای Lyapunov می‌تواند به عنوان میانگین میزان جدایی همسایگان تخمین زده شود. با فرض این که جدایی توسط بزرگترین نمای Lyapunov ( $\lambda$ ) تعیین شود، در هر زمان  $t$  فاصله برابر خواهد بود:

$$d(t) \sim Ce^{\lambda t} \quad \text{معادله شماره 2:}$$

که در آن  $C$  فاصله اولیه است. با استفاده از لگاریتم طبیعی از هر دو طرف به دست می‌آوریم:

$$\ln d(t) = \ln C + \lambda t \quad \text{معادله شماره 3:}$$

این مجموعه‌ای از خطوط موازی را برای ابعاد مختلف جاسازی فراهم می‌کند و بزرگترین نمای Lyapunov را می‌توان به عنوان میانگین شیب، با میانگین تمام بردارهای تعبیه شده، محاسبه کرد. نماهای Lyapunov نسبت به انتخاب تأخیر زمانی، بعد تعبیه شده و به‌ویژه زمان تکامل بسیار حساس هستند. اگر زمان تکامل خیلی کوتاه باشد، بردارهای همسایه برای دستیابی به اطلاعات مربوطه به اندازه کافی تکامل نمی‌یابند. اگر زمان تکامل خیلی زیاد باشد، بردارها به مسیرهای دیگر می‌روند بنابراین نتایج غیرقابل اطمینان می‌دهند.

روش ارائه شده برای محاسبه پیچیدگی سیگنال

در پیش‌بینی سری زمانی آشوب‌گون، اولین گام به‌دست آوردن مدلی از سیستم با استفاده از آخرین نمونه‌ها و پس از آن با استفاده از چند نمونه آخر می‌توان  $n$  نمونه بعدی را پیش‌بینی کرد. هنگامی که سری زمانی مشاهده شده خطی باشد، مدل‌های خطی قادر به

روش‌های مرسوم تخمین پیچیدگی را مرور می‌کنیم سپس روش خود را برای تخمین پیچیدگی سیگنال آشوب‌گون توضیح می‌دهیم. یک مقدار کمی‌ساز از پیچیدگی سیگنال‌های آشوب‌گون که با واگرایی مسیرهای اطراف تعیین می‌شود، نمای لیاپانف است. روش‌های زیادی برای تخمین نمای لیاپانف وجود دارد. از آن‌جا که روش ما مبتنی بر واگرایی مسیرهای مجاور است، در این بخش چند روش معمول برای محاسبه نمای لیاپانف معرفی خواهد شد. سپس روش خود را معرفی می‌کنیم و در آخرین مرحله از این روش برای تخمین پیچیدگی سیگنال EEG استفاده خواهیم کرد.

روش Wolf

Wolf و همکاران (1985) الگوریتمی را برای محاسبه بزرگترین نمای لیاپانف (Lyapunov) پیشنهاد کردند (15). ابتدا بازسازی فاز انجام می‌شود و نزدیکترین همسایه به دنبال یکی از اولین بردارها جاسازی می‌شود. هنگام جستجوی همسایه باید محدودیتی ایجاد شود: باید به اندازه کافی در زمان فاصله ایجاد شود تا بردارهای پی در پی همان مسیر از نزدیکترین همسایگان محاسبه نشود. بدون در نظر گرفتن این اصلاح، نمای Lyapunov به دلیل همبستگی زمانی همسایگان می‌تواند جعلی باشد. هنگامی که همسایه و فاصله اولیه ( $L$ ) تعیین می‌شود، سیستم مقداری زمان ثابت (زمان تکامل) تکامل یافته و فاصله جدید ( $L_0$ ) محاسبه می‌شود. این تکامل با محاسبه فواصل متوالی تکرار می‌شود، تا زمانی که فاصله از یک آستانه خاص بیش‌تر شود. سپس بردار جدید (بردار جایگزین) با نزدیکترین جهت مشابه همسایه اول جستجو می‌شود. سرانجام، نماهای Lyapunov را می‌توان با استفاده از معادله زیر تخمین زد:

$$\lambda = \frac{1}{t_k - t_0} \sum_{i=1}^k \ln \frac{L(t_i)}{L(t_{i-1})} \quad \text{معادله شماره 1:}$$


که در آن  $k$  تعداد مراحل زمانی است.

عملکرد آن را محاسبه می‌کنیم. در مرحله آخر پس از آموزش و اعتبارسنجی مدل، مدل باید مقادیر بعدی را تخمین بزند. بردار اول برابر با  $I_1 = [x(1), x(2), \dots, x(\tau)]$  است. با استفاده از این بردار ورودی  $x_p(1)$  تولید می‌شود که با  $x(\tau + 1)$  مطابقت دارد. حال برای به دست آوردن  $x_p(2)$  باید از این بردار ورودی که در معادله شماره 4 نشان داده شده استفاده کنیم.

$$I_2 = [x(2), x(3), \dots, x(\tau), x_p(1)]$$

معادله شماره 4:

بنابراین بعد از مرحله  $\tau$  تمام عناصر بردار ورودی با نمونه‌های پیش‌بینی شده جایگزین می‌شوند (5). نمودار نمادین این روش در تصویر شماره 1 نشان داده شده است.



تصویر شماره 1: دیاگرام شماتیک پیش‌بینی سری زمانی با استفاده از شبکه عصبی

پس از به دست آوردن نمونه  $\tau$  از خروجی مدل، ما اختلاف بین این نمونه‌های سری زمانی مدل شده و نمونه‌های متناظر را در سری‌های زمانی واقعی محاسبه می‌کنیم که این اختلاف همان‌طور که در معادله شماره 2 نشان داده شده است، در حال رشد نمایی است. اکنون طبق معادله شماره 2 می‌توان پیچیدگی را با معادله زیر تخمین زد:

$$com = \frac{1}{k-1} \ln \frac{d_k}{d_1}$$


معادله شماره 5:

جایی که  $d_k$  تفاوت بین نمونه  $k$  ام سری‌های زمانی مدل شده و نمونه متناظر آن در سری‌های زمانی واقعی است.

پیش‌بینی بلند مدت هستند. اما مدل خطی برای پیش‌بینی سیگنال‌های آشوب‌گون کافی نیست. در این موارد می‌توان از تئوری تقریب غیرخطی برای پیش‌بینی استفاده کرد. اما مشکل اساسی این پیش‌بینی‌ها حساسیت سیستم‌های آشوب‌گون به شرایط اولیه آن‌ها است که به دلیل آشوب‌گونگی سیگنال ایجاد می‌شود، بنابراین پس از برخی نمونه‌ها، سری‌های زمانی تولید شده توسط مدل با سری‌های زمانی واقعی منطبق نیستند. بنابراین پیش‌بینی طولانی مدت مجموعه‌های زمانی آشفته به دلیل تقویت خطاها در هر مرحله پیش‌بینی، بسیار دشوار است. Farmer و Sidorowichl برای اولین بار پیش‌بینی سری زمانی آشفته را معرفی کردند (18)، آن‌ها از تقریب اسمی چند خطی محلی بر اساس  $K$  نزدیک‌ترین همسایه پس از تعویق زمان تعبیه سیگنال در فضای حالت استفاده کردند. سایر مطالعات مانند توابع بالاتر چند جمله‌ای (19)، توابع پایه شعاعی یا Radial Basis Function (RBF) (20, 21) و شبکه‌های عصبی (22-25) موفقیت محدودی در دستیابی به پیش‌بینی طولانی مدت سیگنال‌های بی‌نظم دارند. اما همه این روش‌ها با مشکل تقویت خطاها روبرو هستند. ما از این تقویت خطاها بین سری‌های زمانی واقعی و سری‌های زمانی تولید شده با استفاده از مدل برای به دست آوردن یک مقدار جدید پیچیدگی استفاده کرده‌ایم.

برای برآورد پیچیدگی سیگنال توسط روش جدید، ما سه مرحله انجام دادیم. در مرحله اول از یک شبکه عصبی با عملکرد شعاعی برای دستیابی به مدل مناسب از سری زمانی واقعی خود استفاده کردیم. برای رسیدن به این هدف ما از نمونه‌های  $\tau$  به عنوان ورودی استفاده می‌کنیم و نمونه بعدی را به عنوان خروجی مورد نظر در نظر می‌گیریم. برای آموزش این شبکه عصبی، از همه نمونه‌ها استفاده کردیم. در این مطالعه از یک شبکه عصبی با یک لایه پنهان و 5 نرون در لایه پنهان استفاده شده است که دارای 7 ورودی می‌باشد. روش آموزش این شبکه عصبی نیز به صورت Backpropagation بوده است. در مرحله دوم ما این مدل را اعتبارسنجی کرده و

ثبت شده‌اند. همان‌طور که در بالا شرح داده شده است، برای مدلسازی کوتاه مدت سیگنال‌های EEG از یک شبکه عصبی RBF استفاده شده است. آموزش این شبکه عصبی به صورتی بوده است که حداقل یکی از شروط خروج آموزش برآورده شوند. شروط خروج از آموزش شامل صفر شدن خطای آموزش، ثابت شدن خطای ارزیابی، افزایش خطای آزمون می‌باشد. پس از خروج از آموزش یک بار سیگنال با ورودی آموزش مورد آزمون قرار می‌گیرد و خطای شبکه عصبی محاسبه می‌گردد. نمونه‌ای از این خطا در مقدار اولین خطا در تصویر شماره 2 به نمایش گذاشته شده است. اگر اکنون اختلاف بین سیگنال تخمینی و سیگنال واقعی را محاسبه کنیم، می‌توانیم ببینیم که این اختلاف به عنوان عملکرد نمایی در حال رشد است. نمودار شماره 1 نمونه‌ای از این رشد را نشان می‌دهد. با استفاده از معادله شماره 5 و این اختلاف رو به رشد می‌توان پیچیدگی سیگنال را تخمین زد.



نمودار شماره 1: رشد نمایی تفاوت بین سیگنال اصلی و سیگنال تخمین زده شده

همان‌طور که در بالا توضیح دادیم، ما سیگنال را با استفاده از شرایط اولیه پنج بار تخمین می‌زنیم و پیچیدگی این پنج نمونه را تخمین می‌زنیم، بنابراین برای هر پنج نمونه یک مقدار پیچیدگی داریم. نمودار شماره 2 سری زمانی این مقادیر را برای یک سیگنال EEG نشان می‌دهد.

همان‌طور که در بالا توضیح دادیم، اولین قدم در این روش ایجاد حالت مناسب برای تخمین سیگنال است. برای دستیابی به یک مدل مناسب ما از یک شبکه عصبی RBF با یک لایه مخفی استفاده می‌کنیم. این مدل در سیگنال واقعی متناسب است. مرحله دوم شبیه‌سازی این مدل است. برای این مرحله یک شرط اولیه برای مدل تعریف کردیم که این شرط اولیه شامل سه مشت نمونه سیگنال واقعی است. با استفاده از این شرط اولیه، نمونه بعدی را تخمین می‌زنیم. در مرحله بعدی ما این نمونه تخمینی را به ورودی برمی‌گردانیم و با استفاده از این نمونه بعدی را تخمین می‌زنیم. ما می‌توانیم چندین بار این روش را برای تخمین نمونه‌های شوخی نمونه‌ها با استفاده از سه نمونه سیگنال واقعی انجام دهیم. ما این روش را پنج بار انجام می‌دهیم. لازم به ذکر است که روش ارائه شده در این مطالعه، اختصاصاً برای تخمین میزان پیچیدگی سیگنال در کوتاه‌مدت است، در صورتی که روش‌های ذکر شده در بالا با هدف محاسبه پیچیدگی سیگنال‌ها با تعداد نمونه‌های زیاد و طولانی مدت ارائه شده‌اند. تفاوت اصلی روش ارائه شده در این مطالعه و دیگر روش‌های موجود در واژه‌های تخمین و محاسبه می‌باشد. البته در مطالعات اخیر ذکر شد که روش‌های فوق با کمی اغماض قابلیت استفاده برای تخمین پیچیدگی سیگنال‌های کوتاه مدت را نیز دارند (14)، به همین جهت در این مطالعه روش ارائه شده با روش‌های محاسبه پیچیدگی مقایسه شده‌اند.


## یافته‌ها

در مطالعه حاضر برای تأیید رویکرد جدید، از سیگنال EEG استفاده کردیم. برای تخمین سیگنال EEG و دریافت نتایج به دست آمده، از سیگنال‌های ثبت شده از 16 نفر در حالت استراحت استفاده شده است که هر کدام از این داده‌ها طبق پروتکل 20-10 ثبت شده‌اند و دارای 19 سری زمانی از داده‌های EEG مرتبط با الکترودهای مکانی مختلف هستند. این داده‌ها توسط یک دستگاه EEG با فرکانس نمونه‌برداری 256 هر تنز

با توجه به دو نمودار شماره 3 و 4 دیده می‌شود که یک همبستگی به میزان 90 درصد بین پیچیدگی محاسبه شده و نمای لیاپانف Wolf و همچنین همبستگی برابر با 83 درصد با نمای لیاپانف روش Rosenstein وجود دارد که نشان‌دهنده قابلیت اطمینان این روش می‌باشد.


## بحث

در این مطالعه یک مقدار جدید از پیچیدگی سیگنال‌های بی‌نظم معرفی کردیم. تعداد کمی پیچیدگی وجود دارد اما همه این کمی‌کننده‌ها فقط برای سیگنال‌های بلندمدت قابل استفاده و قابل اعتماد هستند. وقتی دینامیکی سیگنال به سرعت تغییر کند، این محدودیت این کمی‌کننده‌ها مشهود خواهد بود. در این حالت اگر از این کمی‌کننده‌ها استفاده کنیم، می‌توان میانگین این پویا را تخمین زد. اما کمی‌کننده جدید ما می‌تواند پیچیدگی سیگنال‌ها را در دوره‌های کوتاه مدت تخمین بزند. مطالعات کمی در مورد محاسبه پیچیدگی‌های غیر خطی سیگنال EEG در کوتاه مدت ارائه شده‌اند. در مطالعه‌ای که در سال 2017 انجام پذیرفت الگوریتم جدیدی برای تشخیص اجزای سیگنال EEG از توزیع فرکانس زمان ارائه شد که با اصلاح نحوه محاسبه آنتروپی Renyi انجام پذیرفت (26). در صورتی که در مطالعه حاضر به تخمین میزان پیچیدگی سیگنال EEG و تغییرات آن در طول زمان با استفاده از مشخصات غیرخطی و مشخصاً معادل نمای لیاپانف پرداخته شده است. این ویژگی این کمی‌کننده، این ویژگی را برای بررسی تغییرات سریع و دنباله زمانی پیگیری این تغییر قابل استفاده می‌کند. این کمی‌ساز همچنین می‌تواند در بررسی سیگنال‌های آشسته دیگر نیز مورد استفاده قرار گیرد. اما محدودیت این روش به مدل بستگی دارد. اگر مدل مناسب و قابل اعتماد نباشد، نمی‌توانیم مراحل دیگر را برای تخمین پیچیدگی سیگنال انجام دهیم. بنابراین در ابتدا باید نسبت به تناسب مدل خود اطمینان داشته باشیم. روش‌های محاسبه میزان پیچیدگی در سیگنال‌های آشوب‌گون کاربردهای وسیعی، مخصوصاً




نمودار شماره 2: سری زمانی پیچیدگی تخمین زده شده

برای مقایسه‌ای دقیق‌تر، سری زمانی تخمین زده شده را با نمای لیاپانف به روش Wolf و Rosenstein مقایسه نمودیم و مقدار R-value آن را محاسبه نمودیم که به ترتیب در نمودار شماره 3 و 4 نمایش داده شده است.



نمودار شماره 3: نمودار رگرسیون بین سری زمانی نمای لیاپانف با روش Wolf و پیچیدگی تخمین زده شده



نمودار شماره 4: نمودار رگرسیون بین سری زمانی نمای لیاپانف با روش Rosenstein و پیچیدگی تخمین زده شده

در مطالعه دیگری که در سال 2018 انجام پذیرفت از تخمین میزان آنتروپی در EEG های کوتاه مدت برای پیش بینی زمان رخداد تشنج های صرع استفاده شد (28). در مطالعات پیش رو می توان از روش ارائه شده در این مطالعه برای تخمین میزان پیچیدگی سیگنال ها با تظاهرات آشوب گون و مشخصا سیگنال EEG استفاده نمود.

در تحلیل سیگنال های حیاتی و مشخصا سیگنال EEG دارند. به عنوان نمونه در مطالعه ای که در سال 2018 انجام پذیرفت، میزان پیچیدگی سیگنال EEG به صورت فاصله های زمانی کوتاه مدت برای تعیین اثر ترس، هیجان، انزجار و طنز تخمین زده شد که این تخمین ها براساس محاسبه بعد فراکتال انجام پذیرفت (27). همچنین

## References

1. Fujimoto Y, Iokibe T. Evaluation of deterministic property of time series by the method of surrogate data and the trajectory parallel measure method. *IEICE Trans Fundamentals* 2000; 83(2): 343-349
2. Han M, Guo W, Fan M. Multivariate chaotic time series prediction based on radial basis function neural network. In: Wang J, Yi Z, Zurada JM, Lu BL, Yin H, (eds.) *Advances in Neural Networks Lecture Notes in Computer Science*, Berlin: Springer; 2006. p. 741-746.
3. Omidvar AE, Hashemi R, Lucas C, Badie K. Dynamic modeling of chaotic systems using neural networks. 14<sup>th</sup> Annual International Conference of the IEEE Engineering in Medicine and Biology Society; 1992 29 Oct-1 Nov; Paris, France: IEEE; 1992.
4. Myers C, Singer A, Shin F, Church E. Modeling chaotic systems with hidden Markov models. *IEEE International Conference on Acoustics, Speech, and Signal Processing*; 1992; 4: 565-568.
5. Porto M, Amato P. A fuzzy approach for modeling chaotic dynamics with assigned properties. *Ninth IEEE International Conference on Fuzzy Systems FUZZ-IEEE 2000 (Cat No 00CH37063)*; 2000 May 7-10; San Antonio, TX, USA: IEEE; 2000.
6. Xu X, Ren W. A hybrid model based on a two-layer decomposition approach and an optimized neural network for chaotic time series prediction. *Symmetry* 2019; 11(5): 610.
7. Ong P, Zainuin Z. Optimizing wavelet neural networks using modified cuckoo search for multi-step ahead chaotic time series prediction. *Appl Soft Comput* 2019; 80: 374-386.
8. Golovko V. Estimation of the Lyapunov spectrum from one-dimensional observations using neural networks. *Proceedings of the 2<sup>th</sup> IEEE International Workshop on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications*; 2003 Sep 8-10; Lviv, Ukraine: IEEE; 2003.
9. Namazi H, Jafari S. Estimating of brain development in newborns by fractal analysis of sleep Electroencephalographic (EEG) signal. *Fractals* 2019; 27(3): 1950021.
10. Allahverdy A, Jafari AH. Non-auditory effect of noise pollution and its risk on human brain activity in different audio frequency using electroencephalogram complexity. *Iran J Public Health* 2016; 45(10): 1332-1339.
11. Sarbadhikari S, Chakrabarty K. Chaos in the brain: a short review alluding to epilepsy, depression, exercise and lateralization. *Med Eng Phys* 2001; 23(7): 447-457.
12. Kunhimangalam R, Joseph PK, Sujith O. Nonlinear analysis of EEG signals: Surrogate data analysis. *IRBM* 2008; 29(4): 239-244.
13. Allahverdy A, Moghadam AK, Mohammadi



- MR, Nasrabadi AM. Detecting ADHD Children using the Attention Continuity as Nonlinear Feature of EEG. *Frontiers in Biomedical Technologies* 2016; 3(1-2): 28-33.
14. Allahverdy A, Nasrabadi AM, Mohammadi MR, editors. Detecting ADHD children using symbolic dynamic of nonlinear features of EEG. *Proceedings of the 19<sup>th</sup> Iranian Conference on Electrical Engineering*; 2011 May 17-19; Tehran, Iran: IEEE; 2011.
  15. Wolf A, Swift JB, Swinney HL, Vastano JA. Determining Lyapunov exponents from a time series. *Physica D: Nonlinear Phenomena* 1985; 16(3): 285-317.
  16. Rosenstein MT, Collins JJ, De Luca CJ. A practical method for calculating largest Lyapunov exponents from small data sets. *Physica D: Nonlinear Phenomena* 1993; 65(1-2): 117-134.
  17. Cao Z, Prasad M, Lin C-T, editors. Estimation of SSVEP-based EEG complexity using inherent fuzzy entropy. *IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*; 2017 July 9-12; Naples, Italy :IEEE; 2017
  18. Farmer JD, Sidorowich JJ. Exploiting chaos to predict the future and reduce noise. In: Lee YC, (ed). *Evolution, learning and cognition*. Singapore: World Scientific; 1989. p. 277-330.
  19. Casdagli M. Nonlinear prediction of chaotic time series. *Physica D: Nonlinear Phenomena* 1989; 35(3): 335-356.
  20. Li Yl, Liu Bf, Wu G, Liu Z-q, Ding Jf, Abubakar S. Intelligent prediction on air intake flow of spark ignition engine by a chaos radial basis function neural network. *J Cent South Univ T* 2020; 27(9): 2687-2695.
  21. Lapedes A, Farber R. Nonlinear signal processing using neural networks: Prediction and system modelling. Washington DC, Los Alamos National Laboratory 1987.
  22. Weigend A, Huberman BA, Rumelhart DE. Predicting sunspots and exchange rates with connectionist networks. In: Casdagli M, Eubank S, (eds). *Nonlinear Modeling and Forecasting*. Redwood City: Addison Wesley; 1992. p. 395-432.
  23. Albano A, Passamante A, Hediger T, Farrell ME. Using neural nets to look for chaos. *Physica D: Nonlinear Phenomena* 1992; 58(1-4): 1-9.
  24. Principe JC, Rathie A, Kuo J-M. Prediction of chaotic time series with neural networks and the issue of dynamic modeling. *Int J Bifurc Chaos* 1992; 2(04): 989-996.
  25. Lerga J, Saulig N, Mozetič V. Algorithm based on the short-term Rényi entropy and IF estimation for noisy EEG signals analysis. *Comput Biol Med* 2017; 80: 1-13.
  26. Ruiz-Padial E, Ibáñez-Molina AJ. Fractal dimension of EEG signals and heart dynamics in discrete emotional states. *Biol Psychol* 2018; 137: 42-48.