



## **Weight Synchronization in Feedforward Neural Networks and a Novel Method to Detect Synchrony Patterns**

**Banki-Koshki, Hossein<sup>1</sup> / Seyedsalehi, S. Ali<sup>2\*</sup>**

<sup>1</sup> - Ph.D. Student, Bioelectric Department, Biomedical Engineering Faculty, Amirkabir University of Technology, Tehran, Iran

<sup>2</sup> - Associate Professor, Bioelectric Department, Biomedical Engineering Faculty, Amirkabir University of Technology, Tehran, Iran

### **ARTICLE INFO**

DOI: 10.22041/ijbme.2023.2011702.1861

Received: 16 September 2023

Revised: 27 October 2023

Accepted: 2 November 2023

### **KEYWORDS**

*Neuronal Synchronization*  
*Weight Synchronization*  
*Synaptic Plasticity*  
*Artificial Neural Network*  
*Neuronal Map*  
*Cognition*  
*Modeling*  
*Chaos*

### **ABSTRACT**

Neuronal synchronization as a significant cognitive phenomenon of the human brain, has attracted the interest of neuroscience researchers in recent years. This phenomenon is generally investigated in discrete and continuous neuronal models or experimentally recorded signals of the brain. In this study, for the first time, we investigate the weight synchronization instead of neuronal synchrony, in the training step of the artificial feedforward neural networks. The findings of the study show that the generalized weight synchronization occurs both during the training mode and in the non-training mode. Furthermore, as the training is completed, the synchronization increases between the weights. In this study, a new method is introduced in order to detect synchrony patterns using signal derivative and hierarchical clustering. We have also presented a criterion to quantify weight synchronization in different layers of the neural network. Accordingly, the results demonstrate that the lower layers of the network have a significantly higher level of weight synchrony than the upper layers.

### **\*Corresponding Author**

**Address:** Bioelectric Department, Biomedical Engineering Faculty, Amirkabir University of Technology, Tehran, Iran

**Postal Code:** 15875-4413

**E-Mail:** ssalehi@aut.ac.ir

**Tel:** +98-21-64542388





## بررسی پدیده‌ی هم‌آوایی در وزن‌های شبکه‌های عصبی جلوسو و ارائه‌ی روشی جدید برای تشخیص الگوهای هم‌آوایی

بانکی کشکی، حسین<sup>۱</sup> / سیدصالحی، سیدعلی<sup>۲\*</sup>

<sup>۱</sup> - دانشجوی دکتری، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

<sup>۲</sup> - دانشیار، گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

### مشخصات مقاله

شناسه‌ی دیجیتال: 10.22041/ijbme.2023.2011702.1861

پذیرش: ۱۱ آبان ۱۴۰۲

بازنگری: ۵ آبان ۱۴۰۲

ثبت در سامانه: ۲۵ شهریور ۱۴۰۲

### چکیده

### واژه‌های کلیدی

هم‌آوایی نورونی به عنوان یکی از مهم‌ترین پدیده‌های شناختی مغز انسان در سال‌های اخیر مورد توجه پژوهش‌گران قرار گرفته است. پدیده‌ی هم‌آوایی اغلب در مدل‌های نورونی گسسته و پیوسته یا سیگنال‌های تجربی ثبت شده از مغز مورد بررسی قرار می‌گیرد اما در این پژوهش بر خلاف پژوهش‌های قبلی، پدیده‌ی هم‌آوایی برای نخستین بار در وزن‌های شبکه‌های عصبی مصنوعی در حال تعلیم مورد بررسی قرار گرفته است. یافته‌های پژوهش نشان داده که هم‌آوایی در وزن‌های این شبکه‌ها هم در حین یادگیری و هم در حالت بدون یادگیری اتفاق افتاده و از نوع هم‌آوایی عمومی است. هم‌چنین با افزایش میزان یادگیری در شبکه، میزان هم‌آوایی در وزن‌ها نیز افزایش یافته است. در این پژوهش هم‌چنین روشی جدید برای تشخیص الگوهای هم‌آوایی با استفاده از مشتق سیگنال و روش خوشه‌بندی سلسله‌مراتبی ارائه شده و یک شاخص نیز برای سنجش میزان هم‌آوایی وزن‌ها در لایه‌های مختلف شبکه‌ی عصبی معرفی شده است. بررسی این شاخص نشان داده است که وزن‌های لایه‌های نخستین شبکه در مقایسه با لایه‌های سطوح بالاتر به صورت معناداری هم‌آوایی بیشتری دارند.

هم‌آوایی نورونی

هم‌آوایی وزنی

انعطاف‌پذیری سیناپسی

شبکه‌ی عصبی مصنوعی

نگاشت نورونی

شناخت

مدل‌سازی

آشوب

### \*نویسنده‌ی مسئول

نشانی: گروه بیوالکتریک، دانشکده‌ی مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

تلفن: +۹۸-۲۱-۶۴۵۴۲۳۸۸

پست الکترونیک: ssalehi@aut.ac.ir

کد پستی: ۱۵۸۷۵-۴۴۱۳



## ۱- مقدمه

هم‌آوایی به فعالیت هماهنگ کمی و کیفی گروه‌های نورونی در نواحی مختلف مغز یا سیستم عصبی گفته می‌شود. در این پدیده نورون‌ها به صورت هم‌زمان یا همراه با تاخیر فاز، پالس الکتریکی تولید می‌کنند [۱-۳]. هم‌آوایی به عنوان یکی از پدیده‌های مهم در علوم شناختی در سال‌های اخیر مورد توجه قرار گرفته است که در فرایندهای مهم شناختی مغز مانند درک، توجه، حافظه و یادگیری نقش مهمی ایفا می‌کند. به عنوان مثال هنگام مشاهده‌ی یک تصویر یا شنیدن یک صدا، بخش‌های مختلف قشر بینایی و شنوایی در مغز فعالیت خود را با هدف پردازش ویژگی‌های تصویر مانند شکل، رنگ و مکان یا ویژگی‌های صدا مانند جهت، شدت و زیر و بمی صدا هم‌آوایی می‌کنند [۴-۸]. اختلال در هم‌آوایی نورون‌ها یا هم‌آوایی بیش از حد آن‌ها باعث اختلال در عملکردهای شناختی و بروز بیماری‌هایی مانند پارکینسون، صرع و تشنج، روان‌پریشی (اسکیزوفرنی) و زوال عقل (هانتینگتون) می‌شود. به عنوان مثال در بیماری پارکینسون افزایش بیش از حد هم‌آوایی در باند فرکانسی بتا (۱۳-۳۰ هرتز) در هسته‌های قاعده‌ای مغز<sup>۱</sup> باعث اختلال در سیستم حرکتی بدن می‌شود [۹].

هم‌آوایی نورونی بر اساس شاخص‌های مختلف از جمله مقیاس مکانی هم‌آوایی (موضعی یا پراکنده) [۱۰، ۱۱]، پهنای فرکانسی (دلتا، تتا، آلفا، بتا، گاما) [۱۲، ۱۳] و ساز و کار (تحریکی یا مهارتی) [۱۴] قابل تقسیم‌بندی به انواع مختلف است. از سوی دیگر این پدیده بر اساس فاز هم‌آوایی نورون‌ها به سه صورت هم‌فاز<sup>۲</sup>، فاز مخالف<sup>۳</sup> و فاز جابه‌جا شده<sup>۴</sup> ظاهر می‌شود [۱۵].

هم‌آوایی نورونی از طریق ثبت سیگنال‌های EEG و MEG و یا تصویربرداری fMRI از مغز قابل تشخیص و تحلیل است [۱۶]. با این وجود این پدیده از منظر مدل‌سازی اغلب در مدل‌های نورونی پیوسته (مبتنی بر معادلات دیفرانسیل) [۱۷، ۱۸] و مدل‌های نورونی گسسته (مبتنی بر دنباله‌های بازگشتی) [۶، ۱۹] بررسی می‌شود. این مدل‌ها به شبیه‌سازی جریان و ولتاژ یونی نورون‌ها در طول زمان پرداخته و امکان مدل‌سازی و تحلیل هم‌آوایی گروه‌های نورونی را فراهم می‌کنند.

شبکه‌های عصبی مصنوعی به عنوان یکی از روش‌های قدرتمند یادگیری ماشین، با الهام گرفتن از عمل کرد و ساختار مغز انسان طراحی شده و یادگیری از روی داده‌ها مهم‌ترین ویژگی این شبکه‌ها است. یک شبکه‌ی عصبی مصنوعی مجموعه‌ای متشکل از نورون‌های محاسباتی است که در لایه‌های سلسله‌مراتبی در

کنار یک‌دیگر قرار گرفته و با دریافت ورودی و پردازش آن در لایه‌های میانی، خروجی مطلوب را تولید می‌کنند. هر نورون محاسباتی، مدلی ریاضی از نورون زیستی است که اجزای اصلی آن را مدل می‌کند. در این مدل، دندریت نورون زیستی به صورت ورودی نورون محاسباتی، سیناپس‌ها به صورت وزن، جسم سلولی به صورت تابع انتقال و آکسون به صورت خروجی مدل‌سازی می‌شود. خروجی هر نورون محاسباتی به عنوان ورودی یک نورون دیگر محسوب می‌شود [۲۰].

برای استفاده از شبکه‌ی عصبی باید در گام نخست شبکه با استفاده از داده‌های تعلیم و الگوریتم یادگیری آموزش داده شده و سپس عمل کرد شبکه روی داده‌های تست ارزیابی شود. آموزش شبکه از طریق الگوریتم‌های تعلیم مانند پس‌انتشار خطا به عنوان معروف‌ترین الگوریتم یادگیری شبکه‌های عصبی انجام می‌شود. در این روش، وزن‌های شبکه با هدف کاهش خطای خروجی شبکه در هر دور از تعلیم اصلاح می‌شود [۲۱]. اعمال الگوریتم پس‌انتشار خطا روی وزن‌های شبکه باعث تبدیل شدن رابطه‌ی ریاضی وزن‌ها به صورت دنباله‌ی بازگشتی گسسته می‌شود. این دنباله‌ی بازگشتی در حین تعلیم به صورت یک سری زمانی گسسته قابل نمایش است. از آن‌جا که وزن‌های شبکه به هم وابسته بوده و روی یک‌دیگر اثر می‌گذارند، وقوع پدیده‌ی هم‌آوایی در سری زمانی وزن‌های شبکه‌ی عصبی مصنوعی قابل بررسی است. هدف اصلی این پژوهش در گام نخست بررسی وقوع پدیده‌ی هم‌آوایی در وزن‌های شبکه‌ی عصبی مصنوعی است. پژوهش‌هایی که تا کنون برای بررسی و مدل‌سازی پدیده‌ی هم‌آوایی در مغز انجام شده مبتنی بر مدل‌های نورونی پیوسته و گسسته بوده که صرفاً به شبیه‌سازی ولتاژ و جریان یونی یک نورون یا مجموعه‌های نورونی پرداخته و فاقد مهم‌ترین ویژگی مغز یعنی قابلیت یادگیری هستند که در این پژوهش به آن‌ها مدل‌های غیریادگیرنده گفته شده است. در این پژوهش حاضر برای نخستین بار پدیده‌ی هم‌آوایی در شبکه‌ی عصبی مصنوعی که یک مدل یادگیرنده بوده مورد بررسی قرار گرفته است. مطابق شکل (۱) هم‌آوایی در شبکه‌های عصبی مصنوعی هم در خروجی لایه‌ها و هم در وزن‌های شبکه (هدف پژوهش حاضر) قابل بررسی است.

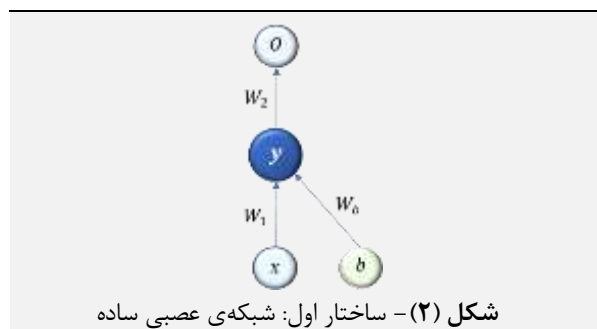
حال باید به این سوال پاسخ داد که چرا در این پژوهش پدیده‌ی هم‌آوایی به جای خروجی لایه‌های شبکه (خروجی نورون‌ها) در وزن‌های شبکه مورد بررسی قرار گرفته است و اساساً بررسی هم‌آوایی وزن‌ها چه دلالت زیستی می‌تواند داشته باشد. در پاسخ

<sup>۱</sup> Anti-Phase Synchronization<sup>۲</sup> Phase-Shifted Synchronization<sup>۳</sup> Basal Ganglia<sup>۴</sup> Phase Synchronization

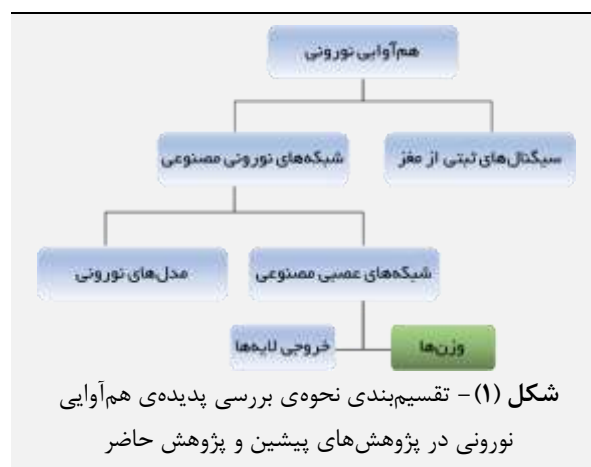
وزنی در شبکه‌های عصبی مصنوعی است. سری‌های زمانی حاصل از فرایند آموزش شبکه‌ی عصبی مصنوعی از نوع سری‌های غیرخطی بوده و بنابراین استفاده از روش‌های اندازه‌گیری خطی مانند همبستگی متقابل برای این سری‌های زمانی مناسب نیست. استفاده از روش‌های غیرخطی نظیر سنجش اطلاعات متقابل، با توجه به تعداد زیاد سری‌های زمانی در یک شبکه‌ی عصبی مصنوعی، بار محاسباتی بالایی ایجاد کرده و در ابعاد بالا عملاً پذیر نیست. علاوه بر روش‌های فوق از روش‌های مبتنی بر فاز شامل ارتباط فاز-فاز و فاز-دامنه در هر فرکانس یا بین فرکانس‌ها می‌توان برای بررسی هم‌آوایی نوروئی استفاده کرد که مختص بررسی هم‌آوایی نوروئی است. در این پژوهش به منظور اندازه‌گیری میزان هم‌آوایی سری‌های زمانی وزن‌های شبکه‌ی عصبی مصنوعی برای نخستین بار از مشتق سیگنال به جای خود سیگنال استفاده شده است تا از این طریق پیچیدگی‌های استفاده از سری زمانی غیرخطی هموار گردد. هم‌چنین به جای استفاده از روش‌های پیشین برای سنجش هم‌آوایی، روش جدیدی مبتنی بر یادگیری ماشین برای خوشه‌بندی سلسله‌مراتبی وزن‌های هم‌آوای ارائه شده است. در ادامه در بخش ۲ انواع شبکه‌های عصبی مورد استفاده و نحوه‌ی به دست آوردن نگاشت‌های وزنی متناظر با شبکه‌ها شرح داده شده و سپس روش سنجش هم‌آوایی در سری‌های زمانی توضیح داده شده است. در بخش ۳ نیز یافته‌های پژوهش در حین تعلیم و بدون تعلیم مورد بررسی قرار گرفته است.

## ۲- مواد و روش‌ها

به منظور بررسی پدیده هم‌آوایی وزن‌ها در شبکه‌ی عصبی مصنوعی از دو ساختار متفاوت استفاده شده است. ساختار اول که در شکل (۲) نشان داده شده یک شبکه‌ی عصبی ساده شامل ورودی، بایاس، نوروئ لایه‌ی پنهان و خروجی است و این امکان را فراهم می‌سازد تا بتوان سری زمانی وزن‌ها را در ساده‌ترین حالت ممکن و بدون اعمال وظایف یادگیری بر شبکه (بدون تعلیم) به دست آورد.



باید بیان کرد که در شبکه‌های عصبی مصنوعی، وزن‌های بین نوروئ‌های محاسباتی، مدل‌کننده‌ی سیناپس‌ها در نوروئ‌های زیستی هستند. اتصالات سیناپسی در شبکه‌ی عصبی زیستی در طول زمان پیوسته در حال تغییر<sup>۱</sup> بوده و این تغییرات نقشی اساسی در یادگیری و شکل‌گیری حافظه ایفا می‌کنند [۲۲-۲۴]. اگر چه با استفاده از روش‌های تصویربرداری مبتنی بر کلسیم<sup>۲</sup> تا حدی امکان بررسی دینامیک سیناپسی فراهم شده اما نحوه‌ی شکل‌گیری حافظه و یادگیری در سطح سیناپس‌ها کماکان به عنوان یکی از چالش‌های پژوهشی در دست بررسی است [۲۵]. از منظر مدل‌سازی می‌توان دینامیک سیناپسی را با تغییرات سری زمانی وزن‌های شبکه‌های عصبی مصنوعی متناظر دانست. نتایج حاصل از این مدل‌سازی می‌تواند منجر به طرح فرضیه‌های جدید شناختی درباره‌ی یادگیری در سطح سیناپسی باشد. در این پژوهش از طریق بررسی سری زمانی وزن‌ها در حین تعلیم شبکه‌ی عصبی جلوسو به این سوال که آیا پدیده هم‌آوایی در سطح سیناپس‌ها (وزن‌ها) نیز قابل وقوع می‌باشد پاسخ داده شده است. پاسخ مثبت به این سوال بدین معنا است که می‌توان در بررسی‌های بیولوژیکی نیز به دنبال ردپای وقوع هم‌آوایی در تغییرات سیناپسی در طول زمان بود.



برای کمی‌سازی و اندازه‌گیری هم‌آوایی شبکه‌های نوروئی روش‌های مختلفی وجود دارد که از آن جمله می‌توان به روش‌های خطی مانند همبستگی متقابل و هم‌دوسی، روش‌های غیرخطی مانند اطلاعات متقابل و روش‌های هم‌فازی مانند قفل‌شدگی فاز و شاخص تاخیر فاز [۲۶، ۲۷] اشاره کرد. برای اندازه‌گیری هم‌آوایی سری زمانی وزن‌های شبکه‌ی عصبی مصنوعی باید در ابتدا به ویژگی‌های این سری‌های زمانی توجه نموده و سپس روش مناسب را انتخاب کرد. بنابراین هدف دوم این پژوهش ارائه‌ی روشی جدید برای سنجش میزان هم‌آوایی

<sup>۲</sup> Calcium Imaging


<sup>۱</sup> Synaptic Plasticity (Synaptic Modification or Synaptic Dynamic)

بر اساس رابطه‌ی (۱) عبارت ریاضی هر وزن متشکل از دنباله‌ی بازگشتی وضعیت گذشته‌ی آن وزن و اثر سایر وزن‌ها است، بنابراین تعامل وزن‌ها (اثرگذاری و اثرپذیری روی یکدیگر) وقوع پدیده‌ی هم‌آوایی را محتمل می‌سازد.

ساختار دوم که در شکل (۳) نشان داده شده شامل یک شبکه‌ی عصبی پیچیده‌تر است. اعمال الگوریتم پس‌انتشار خطا روی وزن‌های این شبکه، یک نگاهت نه‌بعدی را به دست می‌دهد. این نگاهت از یک منظر می‌تواند صرفاً به صورت یک نگاهت ریاضی با پارامترهای مشخص و از منظر دیگر به صورت یک شبکه‌ی عصبی که توانایی یادگیری دارد مورد بررسی واقع شود. به عبارت دیگر در ساختار دوم در حین تعلیم شبکه با داده‌ها می‌توان سری زمانی وزن‌ها را به دست آورد و سپس با روش‌های سنجش هم‌آوایی میزان هم‌آوایی وزن‌ها را بررسی کرد.

در این پژوهش تابع خطای مجذور مربعات خطا (MSE) و تابع فعال‌سازی خطی  $f(x)=x$  برای شبکه‌ی عصبی فوق مورد استفاده قرار گرفته است. با اعمال الگوریتم پس‌انتشار خطا روی وزن‌های شبکه‌ی عصبی مصنوعی، دنباله‌ی بازگشتی وزن‌ها به صورت رابطه‌ی (۱) به دست آمده که یک نگاهت سه‌بعدی است. در این رابطه  $\eta$  ضریب یادگیری،  $x$  ورودی،  $d$  خروجی،  $b$  بایاس و  $w_i$  وزن‌های شبکه است.

$$\begin{aligned} W_{2(n+1)} &= W_{2(n)} + \eta \times (x \times W_{1(n)} + b \times W_{b(n)}) \\ &\times [d - W_{2(n)} \times (x \times W_{1(n)} + b \times W_{b(n)})] \\ W_{1(n+1)} &= W_{1(n)} + \eta \times x \times W_{2(n)} \\ &\times [d - W_{2(n)} \times (x \times W_{1(n)} + b \times W_{b(n)})] \\ W_{b(n+1)} &= W_{b(n)} + \eta \times b \times W_{2(n)} \\ &\times [d - W_{2(n)} \times (x \times W_{1(n)} + b \times W_{b(n)})] \end{aligned} \quad (1)$$



شکل (۳) - ساختار دوم: شبکه‌ی عصبی پیچیده به همراه نگاهت نورونی متناظر

$$\begin{aligned} V_{1(n+1)} &= V_{1(n)} + 0.5 \times \eta \times y_{1(n)} \times \delta_{z(n)} \\ V_{2(n+1)} &= V_{2(n)} + 0.5 \times \eta \times y_{2(n)} \times \delta_{z(n)} \\ V_{3(n+1)} &= V_{3(n)} + 0.5 \times \eta \times \delta_{z(n)} \\ W_{1(n+1)} &= W_{1(n)} + 0.25 \times \eta \times x_{1(n)} \times (1 - y_{1(n)}^2) \times \delta_{z(n)} \times V_{1(n)} \\ W_{2(n+1)} &= W_{2(n)} + 0.25 \times \eta \times x_{1(n)} \times (1 - y_{2(n)}^2) \times \delta_{z(n)} \times V_{2(n)} \\ W_{3(n+1)} &= W_{3(n)} + 0.25 \times \eta \times x_{2(n)} \times (1 - y_{1(n)}^2) \times \delta_{z(n)} \times V_{1(n)} \\ W_{4(n+1)} &= W_{4(n)} + 0.25 \times \eta \times x_{2(n)} \times (1 - y_{2(n)}^2) \times \delta_{z(n)} \times V_{2(n)} \\ W_{5(n+1)} &= W_{5(n)} + 0.25 \times \eta \times (1 - y_{1(n)}^2) \times \delta_{z(n)} \times V_{1(n)} \\ W_{6(n+1)} &= W_{6(n)} + 0.25 \times \eta \times (1 - y_{2(n)}^2) \times \delta_{z(n)} \times V_{1(n)} \\ y_{1(n)} &= f(x_{1(n)} \times W_{1(n)} + x_{2(n)} \times W_{3(n)} + W_{5(n)}) \\ y_{2(n)} &= f(x_{1(n)} \times W_{2(n)} + x_{2(n)} \times W_{4(n)} + W_{6(n)}) \\ z(n) &= f(y_{1(n)} \times V_{1(n)} + y_{2(n)} \times V_{2(n)} + V_{3(n)}) \\ \delta_{z(n)} &= (1 - z(n)^2) \times (d(n) - z(n)) \\ f(t) &= \text{tansig}(t) = \frac{2}{1 + e^{-2t}} - 1 \\ b_1 &= b_2 = 1 \end{aligned}$$

در گام بعدی از خوشه‌بندی سلسله‌مراتبی برای شناسایی دسته‌های هم‌آوا استفاده شده است [۲۹]. در این روش برای خوشه‌بندی وزن‌های شبکه‌ی عصبی ابتدا فاصله‌ی بردار سری زمانی وزن‌ها دوبه‌دو مقایسه شده و سپس سری‌های زمانی با بیش‌ترین شباهت (کم‌ترین فاصله) در نمودار درخت‌واره‌ی سلسله‌مراتبی به یکدیگر وصل شده است. پس از آن سری‌های زمانی مشابه در یک خوشه قرار گرفته و میانگین خوشه‌ها مجدداً به صورت دوبه‌دو با هم مقایسه شده و در نمودار درخت‌واره‌ی سلسله‌مراتبی به یکدیگر متصل شده است. این

پس از به دست آمدن سری زمانی وزن‌های شبکه، باید وزن‌های هم‌آوا شناسایی شود اما در شبکه‌های عصبی جلوسو این امر به آسانی میسر نیست زیرا در این شبکه‌ها هم‌آوایی به طور کامل<sup>۱</sup> اتفاق نمی‌افتد بلکه هم‌آوایی وزن‌ها از نوع هم‌آوایی عمومی<sup>۲</sup> [۲۸] است. بدین منظور در این پژوهش ابتدا بر اساس رابطه‌ی (۲) مشتق سری زمانی وزن‌ها محاسبه شده و سپس از الگوی علامت مشتق به عنوان سیگنال جدید استفاده شده است.

$$y = \text{sign}\left(\frac{dw}{dt}\right) \quad (2)$$

<sup>۱</sup> Generalized Synchronization

<sup>۲</sup> Complete Synchronization

بدین منظور نمودارهای بایفورکیشن مربوط به نگاشت رابطه‌ی (۱) به ازای تمام پارامترهای شبکه‌ی عصبی در شکل (۴) رسم شده است و بر این اساس شبکه با افزایش مقدار هر چهار پارامتر قابلیت بروز رفتارهای آشوبی را دارد.

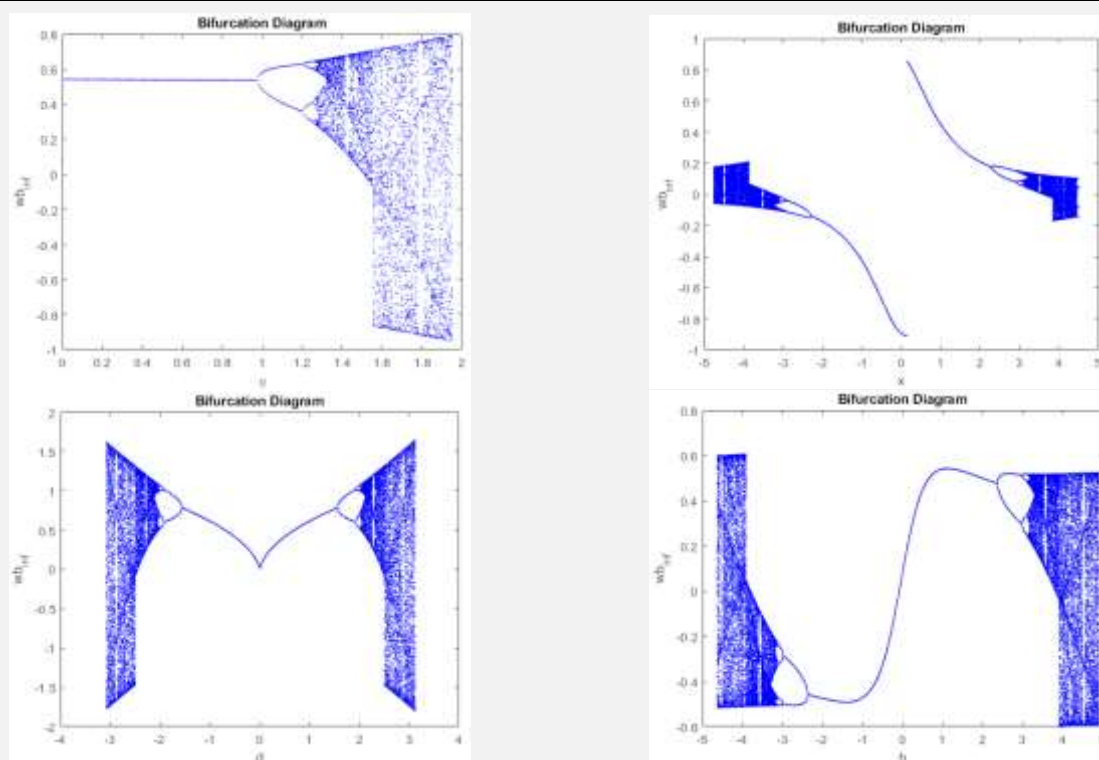
### ۳-۱- بخش اول: هم‌آوایی بدون یادگیری

نمودار سری زمانی وزن‌های رابطه‌ی (۱) در حالت آشوبی پارامتر  $b$  در شکل (۵) نشان داده شده است. بر این اساس وزن‌های  $W_2$  و  $W_b$  علی‌رغم این که در دو لایه‌ی متفاوت از شبکه‌ی عصبی قرار گرفته و عبارت ریاضی متفاوتی نیز دارند از نظر الگو و دامنه با یکدیگر هم‌آوا هستند. همچنین وزن  $W_1$  صرفاً از نظر الگو با دو وزن دیگر هم‌آوا است و دامنه‌ی نوسانی کوچک‌تری دارد. هم‌آوایی وزن‌های  $W_2$  و  $W_b$  نیز به صورت کامل نبوده و مطابق نمودار تراژکتوری شکل (۶) این نمودار به صورت کامل روی نیم‌ساز قرار نگرفته است.


کار تا زمانی ادامه پیدا کرده که تمام سری‌های زمانی در یک خوشه قرار گیرند. در نهایت بر اساس نمودار درخت‌واره‌ی سلسله‌مراتبی به دست آمده، امکان دسته‌بندی شبیه‌ترین سری‌های زمانی میسر شده است. پس از بررسی پدیده‌ی هم‌آوایی در دو شبکه‌ی عصبی که نگاشت‌های نورونی متناظر آن‌ها قابل استخراج بوده، در بخش بعدی از یک شبکه‌ی عصبی با ابعاد  $4 \times 32 \times 64 \times 728$  برای طبقه‌بندی داده‌های تصویر اعداد ۰ تا ۹ مجموعه‌ی داده‌ی MNIST استفاده شده و سری‌های زمانی حاصل از تعلیم شبکه مورد تحلیل قرار گرفته است.

### ۳- یافته‌ها و بحث

پدیده‌ی هم‌آوایی اغلب در حالت آشوب بررسی می‌شود هر چند در حالت نوسانی و نقطه‌ی ثابت نیز اتفاق می‌افتد. از این رو در شبکه‌ی عصبی مصنوعی نیز ابتدا باید وقوع آشوب در نگاشت وزن‌ها بررسی شده و سپس به موضوع هم‌آوایی پرداخته شود.




شکل (۴) - نمودارهای بایفورکیشن پارامترهای رابطه‌ی (۱)، با افزایش مقدار پارامتر رفتارهای آشوبی در سری زمانی وزن‌ها نمایان شده است

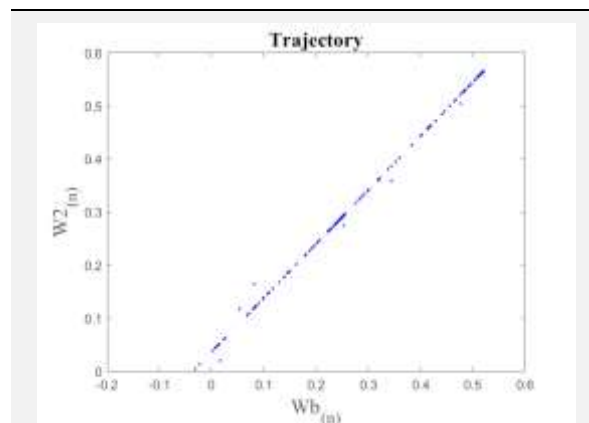


شکل (۵) - وقوع هم‌آوایی در وزن‌های ساختار اول، محور افقی تعداد دور تعلیم و محور عمودی مقدار وزن را نشان می‌دهد

هم‌چنین وزن  $V_3$  به صورت متضاد با دو وزن دیگر هم‌آوا است بدین معنا که هنگام صعودی بودن دو وزن دیگر، وزن  $V_1$  نزولی بوده و هنگام نزولی بودن دو وزن دیگر، این وزن صعودی می‌باشد. مشاهده می‌شود که وزن‌های لایه‌ی اول ( $W$ ) در حالت نقطه‌ی ثابت با یک‌دیگر هم‌آوا شده در حالی که وزن‌های لایه‌ی دوم ( $V$ ) در حالت آشوبی هم‌آوا شده‌اند.




شکل (۷) - الف) نمودار بایفورکیشن به ازای تغییرات پارامتر  $\eta$  مربوط به ساختار دوم، ب) بزرگ‌نمایی بخشی از نمودار بایفورکیشن




شکل (۶) - نمودار تراژکتوری وزن‌های  $W_b$  و  $W_2$  مربوط به رابطه‌ی (۱)، قرار نگرفتن نمودار تراژکتوری روی نیم‌ساز نشان می‌دهد که هم‌آوایی دو وزن به صورت کامل نیست

شبکه‌ی عصبی مصنوعی نمایش داده شده در شکل (۳) شبکه‌ای پیچیده‌تر با نگاشت متناظر نه‌بعدی است. نمودار بایفورکیشن این نگاشت به ازای تغییرات پارامتر  $\eta$  در شکل (۷) نشان داده شده که بر اساس آن رفتار آشوبی به ازای مقادیر بزرگ پارامتر  $\eta$  در یک محدوده‌ی مشخص قابل مشاهده است. در این محدوده‌ی آشوبی و بدون اعمال وظیفه‌ی یادگیری بر شبکه، رفتار وزن‌ها از نظر هم‌آوایی در شکل (۸) نشان داده شده است. بر این اساس وزن‌های  $V_1$  و  $V_2$  علی‌رغم هم‌آوایی، در محدوده‌ی متفاوتی حول یک عدد ثابت نوسان می‌کنند.



شکل (۸) - بررسی وقوع هم‌آوایی در وزن‌های ساختار دوم در حالت بدون یادگیری



گرفته تا این مورد که آیا ساختار شبکه (فارغ از اثرگذاری عوامل بیرونی) قابلیت بروز پدیده‌ی هم‌آوایی را دارد یا خیر مشخص شود. در این بخش وظیفه‌ی یادگیری نیز بر شبکه اعمال شده تا پدیده‌ی هم‌آوایی در حضور عوامل بیرونی (داده‌های ورودی شبکه در حین تعلیم) مورد بررسی قرار گیرد زیرا این وضعیت به وضعیت واقعی شبکه‌ی عصبی زیستی و مغز نزدیک‌تر است و اثر عوامل بیرونی در هم‌آوایی را نیز مشخص می‌کند.

اعمال وظیفه‌ی یادگیری بر شبکه‌ی عصبی در یک طبقه‌بندی دوکلاسه و رسم سری زمانی وزن‌ها در حین تعلیم در شکل (۹)


در مجموع بررسی شکل‌های (۵) و (۸) نشان می‌دهد که پدیده‌ی هم‌آوایی وزنی در حالت بدون یادگیری در ساختارهای ساده و پیچیده‌ی شبکه‌ی عصبی مصنوعی قابل وقوع بوده و وزن‌ها از نظر کمی (دامنه) و کیفی (الگو) به هم‌آوایی رسیده هر چند این هم‌آوایی به صورت کامل اتفاق نیفتاده است.

### ۳-۲- بخش دوم: هم‌آوایی در حین یادگیری

در بخش قبل پدیده‌ی هم‌آوایی در وزن‌های شبکه‌ی عصبی در حالت عدم اعمال وظیفه‌ی یادگیری بر شبکه مورد بررسی قرار

روند متفاوت صعودی و نزولی را در حین تعلیم طی می‌کنند. تفاوت دیگر به تقارن متضاد وزن‌های هم‌آوا باز می‌گردد. به عنوان مثال وزن‌های  $V_1$  و  $V_2$  علی‌رغم هم‌آوایی، از نظر تقارن کاملاً متضاد هستند.

نشان داده که وزن‌های شبکه الگوهای متفاوتی از هم‌آوایی را به نمایش گذاشته‌اند. این تفاوت در وهله‌ی اول به صعودی یا نزولی بودن وزن‌های هم‌آوا باز می‌گردد. به عنوان مثال وزن‌های  $V_1$  و  $V_3$  علی‌رغم این که از نظر الگو و دامنه هم‌آوا هستند اما دو




شکل (۹) - بررسی وقوع هم‌آوایی در ساختار دوم در حالت با یادگیری

وقوع هم‌آوایی را افزایش می‌دهد اما بررسی نمودار سری زمانی وزن‌های  $W_1$  تا  $W_6$  و  $V_1$  تا  $V_3$  در شکل (۱۰) نشان می‌دهد که وزن‌های لایه‌ی اول و دوم با یک‌دیگر هم‌آوا نیستند که دلیل آن به کوچک بودن ضرایب کوپلینگ وزن‌ها باز می‌گردد. ضرایب کوپلینگ بین وزن‌ها تابعی از پارامترهای  $\eta$  و  $x$  بوده که به صورت  $C(\eta, x)$  قابل بیان است و برای هر جفت وزن، تابع متفاوتی می‌باشد. هم‌چنین از آن‌جا که داده‌های ورودی  $x$  در هر دور از تعلیم تغییر می‌کند، ضرایب کوپلینگ بین دو وزن مشخص نیز در هر دور از تعلیم تغییر می‌یابد. به عبارت دیگر ضرایب کوپلینگ در شبکه‌ی عصبی مصنوعی وضعیتی دینامیک (غیر ثابت) دارند و تابعی از ضریب یادگیری و ورودی شبکه هستند که به صورت مستمر در حال تغییر می‌باشند.

بررسی سری زمانی وزن‌ها در حین تعلیم نشان می‌دهد که وزن‌ها در دوره‌های ابتدایی تعلیم با یک‌دیگر هم‌آوا نیستند اما پس از دوره‌ی گذار که می‌توان آن را دوره‌ی شکل‌گیری الگو در شبکه‌ی عصبی (مغز) نامید به هم‌آوایی رسیده‌اند. بنابراین می‌توان این فرضیه را مطرح نمود که یادگیری در مغز با هم‌آوا شدن وزن‌ها همراه است و به میزانی که یادگیری کامل شود (افزایش درصد صحت تعلیم یا کاهش خطای خروجی شبکه) هم‌آوایی وزن‌ها نیز افزایش می‌یابد.

مساله‌ی دیگری که باید به آن توجه شود هم‌آوایی وزن‌های لایه‌ی اول با وزن‌های لایه‌ی دوم است. اگر چه بر اساس نگاشت متناظر با ساختار دوم، عبارت ریاضی هر وزن به صورت تابعی از سایر وزن‌ها است و اثرگذاری وزن‌ها روی یک‌دیگر احتمال



شکل (۱۰) - نتیجه‌ی خوشه‌بندی روی سیگنال مشتق وزن‌های لایه‌ی سوم شبکه‌ی در حال یادگیری داده‌های MNIST

حین تعلیم اکتفا شود. شبکه‌ی فوق با ۱۰۰۰ نمونه‌ی داده‌ی تعلیم تا ۷۵۰ دور آموزش می‌بیند تا به درصد صحت ۹۱/۴٪ برسد. با به دست آمدن سری زمانی وزن‌های لایه‌های اول تا سوم (لایه‌ی اول ۴۶۵۹۲ وزن، لایه‌ی دوم ۲۰۴۸ وزن، لایه‌ی سوم ۱۲۸ وزن) و استخراج سیگنال علامت مشتق این سری‌های زمانی، خوشه‌بندی سلسله‌مراتبی روی سیگنال‌های به دست آمده اعمال شده است. نتیجه‌ی خوشه‌بندی برای وزن‌های لایه‌ی سوم این شبکه در شکل (۱۰) به صورت نمودار Heatmap نشان داده شده است. بر این اساس هیچ دو وزنی به صورت کامل با یک‌دیگر هم‌آوا نیستند اما دسته‌هایی که بیش‌ترین هم‌آوایی را داشته در یک گروه قرار گرفته‌اند. هر چند استفاده از روش خوشه‌بندی سلسله‌مراتبی برای هم‌آوایی‌های عمومی (نسبی) مناسب است و شبیه‌ترین خوشه‌ها را برای تحلیل در اختیار می‌گذارد اما این روش برای هم‌آوایی‌هایی که از نوع تقارن متضاد هستند مناسب نیست و باید برای تشخیص این نوع از هم‌آوایی از روش‌های دیگری استفاده شود.

بررسی خوشه‌های هم‌آوا در هر لایه از شبکه با مشاهده‌ی نمودار درخت‌واره‌ی سلسله‌مراتبی آن لایه امکان‌پذیر است اما برای مقایسه‌ی میزان هم‌آوایی در لایه‌های مختلف شبکه باید یک شاخص کمی ارائه شود. بدین منظور می‌توان با محاسبه‌ی مجموع فاصله‌ی دوجه‌دوی سیگنال علامت مشتق وزن‌ها در هر لایه و نرمال کردن مجموع فاصله‌ها با تعداد وزن‌های هر لایه، شاخصی برای سنجش میزان هم‌آوایی در هر لایه ارائه کرد. این شاخص  $S_k$  بوده که به صورت رابطه‌ی (۳) تعریف شده است. مقادیر کم‌تر این شاخص به معنای هم‌آوایی بیش‌تر وزن‌ها است. در این رابطه  $D_k$  مجموع فاصله‌ی دوجه‌دوی وزن‌ها در لایه‌ی  $k$  و  $L$  تعداد وزن‌های آن لایه است.

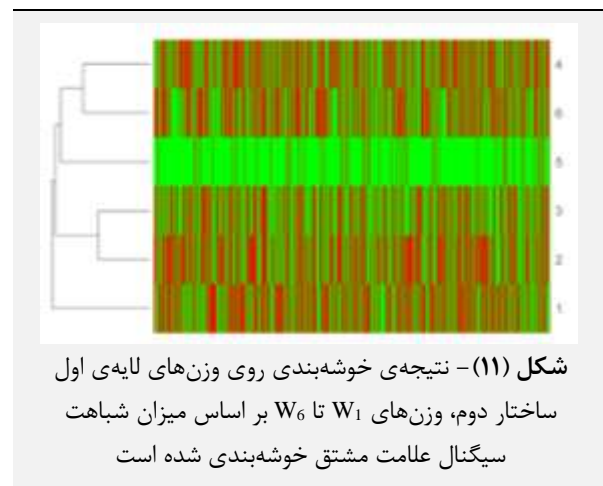
$$S_k = \frac{D_k}{L} \quad (3)$$

$$D_k = \sum_{i=1}^{L-1} \sum_{j=i+1}^L distance(Y_{ki}, Y_{kj})$$

مقدار شاخص  $S_k$  برای لایه‌های شبکه در جدول (۱) آورده شده است. مقدار شاخص هم‌آوایی برای لایه‌ی اول کمینه بوده بنابراین میزان هم‌آوایی وزن‌ها در لایه‌ی اول به صورت معناداری بیش‌تر از سایر لایه‌ها است. هم‌آوایی بیش‌تر وزن‌ها در لایه‌ی اول می‌تواند ناشی از مساله‌ی کاهش گرادیان [۳۰] در الگوریتم پس‌انتشار خطا باشد. کاهش گرادیان وزن‌ها در لایه‌های نخستین شبکه باعث می‌شود که تغییرات این وزن‌ها در طول تعلیم بسیار اندک یا صفر باشد بنابراین وزن‌هایی که بدون تغییر می‌مانند دارای مشتق صفر بوده که به عنوان دسته‌های هم‌آوا

وجود الگوهای متفاوت هم‌آوایی در حین یادگیری داده‌ها باعث دشوار شدن استفاده از سری زمانی وزن‌ها برای سنجش هم‌آوایی شده به طوری که حتی اعمال روش‌های نرمال‌سازی و حذف بایاس روی سری زمانی وزن‌ها نیز به نتیجه‌ی مطلوبی منجر نمی‌شود. به منظور رفع مشکلات ناشی از نزولی و صعودی بودن سری‌های زمانی (سیگنال)، به جای استفاده از خود سیگنال، از علامت مشتق سیگنال بر اساس رابطه‌ی (۲) استفاده شده که به صورت +۱ و -۱ قابل بیان است. بنابراین بالا و پایین رفتن هم‌زمان دو سیگنال فارغ از کمیت سیگنال و صرفاً از روی تشابه الگوی علامت مشتق قابل تشخیص است.

با استفاده از سیگنال‌های مربوط به علامت مشتق سری‌های زمانی، خوشه‌بندی سلسله‌مراتبی روی این سیگنال‌ها اعمال شده تا وزن‌های هم‌آوا شناسایی شود. نتیجه‌ی خوشه‌بندی برای وزن‌های لایه‌ی اول ساختار دوم در شکل (۱۱) نشان داده شده و بر این اساس سری‌های زمانی با بیش‌ترین شباهت به صورت دوجه‌دو به یک‌دیگر متصل شده است.



### ۳-۳- بخش سوم: شبکه‌ی بزرگ‌تر در حین یادگیری

در بخش‌های قبلی شبکه‌های عصبی مورد استفاده دارای ساختار کوچک و دادگان تعلیم محدود بوده و بنابراین استخراج نگاشت‌های ریاضی و تحلیل رفتار شبکه با استفاده از نگاشت‌ها در کنار سری‌های زمانی به دست آمده از مرحله‌ی تعلیم، میسر بوده است. در این بخش با استفاده از یک شبکه‌ی عصبی با ساختار بزرگ‌تر و ابعاد  $4 * 32 * 64 * 728$  به طبقه‌بندی داده‌های تصویر اعداد صفر تا ۹ مجموعه‌ی داده‌ی MNIST پرداخته شده است. در چنین شبکه‌های بزرگی به دست آوردن نگاشت ریاضی وزن‌ها به دلیل ابعاد بالای شبکه امکان‌پذیر نیست (نگاشتی با ابعاد ۴۸۷۶۸) بنابراین برای تحلیل رفتار شبکه از منظر هم‌آوایی وزنی، باید به سری زمانی وزن‌ها در

می‌کند. هم‌چنین در صورت اعمال اثر عوامل بیرونی از طریق داده‌های ورودی، پدیده هم‌آوایی در وزن‌ها در حالت یادگیری نیز اتفاق می‌افتد اما الگوهای هم‌آوایی در مقایسه با حالت بدون یادگیری پیچیده‌تر است. هم‌آوایی در هر دو حالت بدون یادگیری و با یادگیری از نوع هم‌آوایی عمومی (نسبی) است و وزن‌ها به صورت کامل با یک‌دیگر هم‌آوا نمی‌شوند. هم‌آوایی در حالت یادگیری پس از یک دوره‌ی گذار اتفاق می‌افتد که این دوره‌ی گذار را می‌توان دوره‌ی شکل‌گیری الگو در شبکه‌ی عصبی (مغز) نامید. بنابراین به میزانی که یادگیری افزایش یابد، هم‌آوایی وزن‌ها نیز افزایش می‌یابد.

بررسی‌های صورت گرفته در این پژوهش مشخص کرده که علی‌رغم هم‌آوایی وزن‌ها در یک لایه در حین یادگیری، بین وزن‌های لایه‌های مختلف در شبکه‌ی عصبی مصنوعی هم‌آوایی وجود ندارد که این پدیده ناشی از مقدار کوچک ضرایب کوپلینگ میان وزن‌های لایه‌های مختلف است. هم‌چنین ضرایب کوپلینگ بین وزن‌ها در شبکه‌های عصبی مصنوعی بر خلاف ضرایب کوپلینگ مدل‌های نورونی رایج، در طول تعلیم متغیر و تابع شرایط محیطی (داده‌های ورودی به شبکه) و پارامترهای شبکه (ضریب یادگیری) هستند.

به دلیل کامل نبودن هم‌آوایی و روند صعودی و نزولی سری‌های زمانی در طول تعلیم، در این پژوهش استفاده از علامت مشتق سیگنال به جای خود سیگنال و سپس استفاده از خوشه‌بندی سلسله‌مراتبی برای به دست آوردن دسته‌های هم‌آوا پیشنهاد شده است. هم‌چنین شاخصی برای سنجش میزان هم‌آوایی در لایه‌های مختلف شبکه‌ی عصبی بر اساس فاصله‌ی نرمال شده‌ی سری‌های زمانی هر لایه معرفی شده است. بررسی این شاخص نشان داده که میزان هم‌آوایی در لایه‌ی اول در مقایسه با سایر لایه‌ها به دلیل مساله‌ی کاهش گرادیان به صورت معناداری بیش‌تر است. هم‌چنین با افزایش سطح لایه‌ها میزان هم‌آوایی نیز به صورت سلسله‌مراتبی کاهش یافته است. در این پژوهش به منظور استخراج روابط ریاضی نگاشت وزن‌ها و هم‌چنین تعلیم شبکه از روش پس‌انتشار خطا استفاده شده و تمام تحلیل‌ها مبتنی بر این روش ارائه شده است. استفاده از سایر الگوریتم‌های تعلیم شبکه‌های عصبی نظیر روش گرادیان مزدوج یا روش لونیگ-مارکوارت، نگاشت‌های ریاضی و سری‌های زمانی متفاوتی را حاصل کرده و ممکن است نتایج تحلیل هم‌آوایی را تحت تاثیر قرار دهد که باید در پژوهش‌های دیگری مورد بررسی قرار گیرد. هم‌چنین در خوشه‌بندی سلسله‌مراتبی مورد استفاده در این پژوهش، شاخص ارائه شده برای سنجش میزان هم‌آوایی در لایه‌های مختلف شبکه،

شناسایی شده و باعث می‌شوند مقدار شاخص هم‌آوایی برای لایه‌ی اول به صورت معناداری کم‌تر باشد.

جدول (۱) - مقدار شاخص هم‌آوایی در لایه‌های مختلف

لایه‌ی ۱	لایه‌ی ۲	لایه‌ی ۳	
۱/۴۱	۶/۵۸	۶/۹۷	$S_k$

در بین لایه‌ی دوم و سوم نیز میزان هم‌آوایی در لایه‌ی دوم بیش‌تر از لایه‌ی سوم است. بنابراین می‌توان بیان کرد که میزان هم‌آوایی به صورت سلسله‌مراتبی در لایه‌های شبکه‌ی عصبی کاهش یافته و لایه‌های بالاتر که پردازش‌های پیچیده‌تری را نیز بر عهده دارند غیرهم‌آواتر هستند. از آن‌جا که شبکه‌های عصبی مصنوعی با الگو گرفتن از کارکرد شناختی یادگیری در مغز انسان توسعه داده شده‌اند، بر اساس یافته‌های این بخش می‌توان این فرضیه را مطرح کرد که در مغز انسان نیز لایه‌های بالاتر که پردازش‌های پیچیده‌تر را بر عهده داشته هم‌آوایی کم‌تری دارند هر چند این فرضیه هنوز اثبات نشده و تا کنون بررسی تجربی جامعی برای آن انجام نشده است.

#### ۴- نتیجه‌گیری

شبکه‌های عصبی مصنوعی توانایی مدل‌سازی انواع پدیده‌ها و کارکردهای شناختی از جمله هم‌آوایی را دارند و به دلیل دارا بودن قابلیت یادگیری به عنوان مهم‌ترین قابلیت مغز انسان، مدل‌سازی با آن‌ها تحلیل‌های واقع‌بینانه‌تری از پدیده‌های مرتبط با شبکه‌های عصبی زیستی را به دست می‌دهد. در این پژوهش به مدل‌سازی پدیده هم‌آوایی به عنوان یکی از مهم‌ترین پدیده‌های شناختی مغز با استفاده از وزن‌های شبکه‌های عصبی مصنوعی پرداخته شده است. پژوهش‌های مرتبط با پدیده هم‌آوایی در مغز اغلب هم‌آوایی نورونی را در مدل‌های نورونی گسسته و پیوسته مورد مطالعه قرار داده اما در این پژوهش برای نخستین بار هم‌آوایی وزن‌ها در طول تعلیم مورد بررسی قرار گرفته است. از آن‌جا که وزن‌ها در شبکه‌های عصبی مصنوعی مدل‌کننده سیناپس‌ها در شبکه‌های عصبی زیستی هستند، بررسی دینامیک وزن‌ها در طول تعلیم می‌تواند رهیافت‌های جدیدی را درباره‌ی پدیده‌ی زیستی مانند دینامیک سیناپسی و انعطاف‌پذیری سیناپسی در اختیار قرار دهد. یافته‌های این پژوهش نشان داده که پدیده هم‌آوایی در وزن‌های شبکه‌های عصبی مصنوعی در حالت بدون یادگیری قابل وقوع است بنابراین ساختار ذاتی شبکه بدون اثرگذاری عوامل بیرونی (نظیر داده‌های ورودی شبکه) امکان ایجاد پدیده هم‌آوایی را به دلیل تعامل وزن‌ها با یک‌دیگر فراهم



- synchronization of high-frequency oscillations in human cortex. *Nat Commun* 2020;11:5363.
- [11] Amor F, Baillet S, Navarro V, Adam C, Martinerie J, Le Van Quyen M. Cortical local and long-range synchronization interplay in human absence seizure initiation. *Neuroimage* 2009;45:950–62.
- [12] Bosman CA, Womelsdorf T, Desimone R, Fries P. A microsaccadic rhythm modulates gamma-band synchronization and behavior. *J Neurosci* 2009;29:9471–80.
- [13] Womelsdorf T, Fries P, Mitra PP, Desimone R. Gamma-band synchronization in visual cortex predicts speed of change detection. *Nature* 2006;439:733–6.
- [14] Börgers C, Kopell N. Synchronization in networks of excitatory and inhibitory neurons with sparse, random connectivity. *Neural Comput* 2003;15:509–38.
- [15] Mahmoud GM, Mahmoud EE. Phase and antiphase synchronization of two identical hyperchaotic complex nonlinear systems. *Nonlinear Dyn* 2010;61:141–52.
- [16] Koike T, Tanabe HC, Okazaki S, Nakagawa E, Sasaki AT, Shimada K, et al. Neural substrates of shared attention as social memory: a hyperscanning functional magnetic resonance imaging study. *Neuroimage* 2016;125:401–12.
- [17] Malik SA, Mir AH. Synchronization of hindmarsh rose neurons. *Neural Networks* 2020;123:372–80.
- [18] Wang J, Lu M, Li H. Synchronization of coupled equations of Morris–Lecar model. *Commun Nonlinear Sci Numer Simul* 2008;13:1169–79.
- [19] Vivekanandhan G, Hamarash II, Ali Ali AM, He S, Sun K. Firing patterns of Izhikevich neuron model under electric field and its synchronization patterns. *Eur Phys J Spec Top* 2022;231:4017–23.
- [20] Basheer IA, Hajmeer M. Artificial neural networks: fundamentals, computing, design, and application. *J Microbiol Methods* 2000;43:3–31.
- [21] Dreyfus G. *Neural networks: methodology and applications*. Springer Science & Business Media; 2005.
- [22] Citri A, Malenka RC. Synaptic plasticity: multiple forms, functions, and mechanisms. *Neuropsychopharmacology* 2008;33:18–41.
- [23] Kennedy MB. Synaptic signaling in learning and memory. *Cold Spring Harb Perspect Biol* 2016;8:a016824.
- [24] Abraham WC, Jones OD, Glanzman DL. Is plasticity of synapses the mechanism of long-term memory storage? *NPJ Science of Learning* 4: 9 2019.
- [25] Ma S, Zuo Y. Synaptic modifications in learning and memory—a dendritic spine story. *Semin. Cell Dev. Biol.*, vol. 125, Elsevier; 2022, p. 84–90.
- [26] Quiroga RQ, Kraskov A, Kreuz T, Grassberger P. Performance of different synchronization measures in real data: a case study on electroencephalographic signals. *Phys Rev E* 2002;65:41903.

فاصله‌ی اقلیدسی است در حالی که می‌توان از روش‌های دیگر سنجش فاصله یا از روش‌های سنجش شباهت غیرفاصله‌ای نظیر همبستگی نیز استفاده کرد.

روش ارائه شده در این مقاله که مبتنی بر استفاده از علامت مشتق سیگنال است، تغییرات متضاد را از طریق علامت مشتق نمایان می‌سازد اما این تغییرات متضاد با اعمال خوشه‌بندی سلسله‌مراتبی در یک خوشه قرار نگرفته و به عبارت دیگر هم‌آوا تشخیص داده نمی‌شوند. از این رو برای تشخیص هم‌آوایی‌های متضاد باید روش‌های دیگری مورد استفاده قرار گیرد.

شبکه‌های عصبی مورد استفاده در این پژوهش از نوع شبکه‌ی جلوسو بوده و تحلیل‌ها نیز بر اساس ساختار و روش‌های تعلیم این شبکه‌ها ارائه شده است. در پژوهش‌های آتی می‌توان از شبکه‌هایی با ساختارهای بازگشتی برای بررسی پدیده‌ی هم‌آوایی و نحوه‌ی رخداد آن استفاده کرد.

## ۵- مراجع

- [1] Shafiei M, Jafari S, Parastesh F, Ozer M, Kapitaniak T, Perc M. Time delayed chemical synapses and synchronization in multilayer neuronal networks with ephaptic inter-layer coupling. *Commun Nonlinear Sci Numer Simul* 2020;84:105175.
- [2] Timofeev I, Bazhenov M, Seigneur J, Sejnowski T. Neuronal synchronization and thalamocortical rhythms in sleep, wake and epilepsy. *Jasper's Basic Mech Epilepsies [Internet] 4th Ed* 2012.
- [3] Arenas A, Díaz-Guilera A, Kurths J, Moreno Y, Zhou C. Synchronization in complex networks. *Phys Rep* 2008;469:93–153.
- [4] Kazemi S, Jamali Y. Phase synchronization and measure of criticality in a network of neural mass models. *Sci Rep* 2022;12:1319.
- [5] Etémé AS, Tabi CB, Mohamadou A. Firing and synchronization modes in neural network under magnetic stimulation. *Commun Nonlinear Sci Numer Simul* 2019;72:432–40.
- [6] Rakshit S, Ray A, Bera BK, Ghosh D. Synchronization and firing patterns of coupled Rulkov neuronal map. *Nonlinear Dyn* 2018;94:785–805.
- [7] Sun H, Cao H. Synchronization of two identical and non-identical Rulkov models. *Commun Nonlinear Sci Numer Simul* 2016;40:15–27.
- [8] Fell J, Axmacher N. The role of phase synchronization in memory processes. *Nat Rev Neurosci* 2011;12:105–18.
- [9] Ahn S, Park C, Rubchinsky LL. Neural synchronization in parkinson's disease on different time scales. *Multiscale Model Brain Disord* 2019:57–65.
- [10] Arnulfo G, Wang SH, Myrov V, Toselli B, Hirvonen J, Fato MM, et al. Long-range phase

- [29] Murtagh F, Contreras P. Algorithms for hierarchical clustering: an overview, II. *Wiley Interdiscip Rev Data Min Knowl Discov* 2017;7:e1219.
- [30] Roodschild M, Gotay Sardiñas J, Will A. A new approach for the vanishing gradient problem on sigmoid activation. *Prog Artif Intell* 2020;9:351–60.
- [27] Soriano MC, Van der Sande G, Fischer I, Mirasso CR. Synchronization in simple network motifs with negligible correlation and mutual information measures. *Phys Rev Lett* 2012;108:134101.
- [28] Zhang Q, Lü J, Chen S. Coexistence of anti-phase and complete synchronization in the generalized Lorenz system. *Commun Nonlinear Sci Numer Simul* 2010;15:3067–72.