

## طراحی شبکه عصبی جلو سوی آشوب گونه

ابوذر طاهرخانی<sup>۱</sup>، شهرام جوادی<sup>۲</sup>، سام معینی<sup>۳</sup>

۱- کارشناسی ارشد مهندسی پزشکی - بیوالکتریک، دانشکده مهندسی پزشکی - دانشگاه صنعتی امیرکبیر -

تهران - ایران

A.taherkhani@aut.ac.ir

۲- عضو هیات علمی دانشگاه آزاد اسلامی واحد تهران مرکز، دانشکده مهندسی برق - تهران - ایران

sh.javadi@iauctb.ac.ir

۳- کارشناسی ارشد مهندسی برق - الکترونیک، دانشکده مهندسی برق - دانشگاه آزاد اسلامی واحد تهران

مرکز - تهران - ایران

sam.moini@gmail.com

**چکیده:** بر اساس مطالعات جدید محققان، سیناپس‌ها یکی از پویاترین اجزا دستگاه عصبی جانداران هستند و حتی پس از مرحله تعلیم نیز قدرت هر سیناپس ثابت باقی نمی‌ماند. در این مقاله، روشی برای آشوبی کردن وزن‌های شبکه عصبی جلو سو ارائه شده است. در این روش وزن‌های یک شبکه عصبی جلو سو پس از تعلیم به عنوان وزن‌های پایه در نظر گرفته شده‌اند. با استفاده از توابع لجستیک (که در محدوده مناسبی به صورت آشوبگونه نوسان می‌کنند) و وزن‌های پایه، شبکه عصبی جلو سوی آشوب‌گونه‌ای طراحی گردید که وزن‌های آن در هر لحظه به صورت آشوب‌گونه تغییر می‌کند. با استفاده از الگوریتم ارائه شده در این مقاله، وزن‌های آشوبی طوری با یکدیگر همزمان می‌شوند که خطای خروجی حداقل می‌گردد. با این روش، تمامی داده‌هایی که توسط شبکه جلو سوی پایه اشتباه تشخیص داده شده بودند، شناسایی و برای آنها خروجی "غیر قابل شناسایی" ایجاد می‌شود.

**واژه‌های کلیدی:** ابر صفحه جداکننده، بازشناسی، سیناپس پویا، شبکه عصبی جلو سو، نظریه آشوب.

### ۱- مقدمه

پردازشی شبکه‌های عصبی مصنوعی موجود شود. پیشرفت‌های جدید در دینامیک‌های غیر خطی، شناخت نظریه آشوب و سیستم‌های پیچیده از یک سو و پیشرفت در تجهیزات آزمایشگاهی از سوی دیگر، باعث شده است که بشر به وجود خاصیت‌های جدید، به ویژه خاصیت آشوب در عملکرد مغز پی ببرد. بنابراین، وارد کردن این خاصیت در مدل‌های شبکه عصبی کلاسیک می‌تواند راهی برای بهبود عملکرد آنها باشد. که این مهم از اهداف این مقاله است.

مدل‌های زیادی برای شبکه‌های عصبی مصنوعی ارائه شده‌اند که در هریک از آنها گوشه‌ای از ویژگی‌های مغز مورد توجه قرار گرفته است. ترکیب این مدل‌ها و ایجاد شبکه‌های عصبی مصنوعی که عملکرد آنها همخوانی بیشتری با عملکرد مغز دارد، می‌تواند باعث بهبود توان

<sup>۱</sup> تاریخ ارسال مقاله : ۱۳۹۰/۷/۲۴

تاریخ پذیرش مقاله : ۱۳۹۱/۶/۱۲

نام نویسنده مسئول : ابوذر طاهرخانی

نشانی نویسنده مسئول: ایران - تهران - دانشگاه

صنعتی امیرکبیر - دانشکده مهندسی پزشکی

مطالعات محققان در اوایل دهه ۹۰ میلادی نشان داد که سیناپس‌ها، بر خلاف آنچه که پیشتر فرض می‌شد، یکی از پویاترین اجزای دستگاه عصبی جانداران هستند [۱، ۲]. حتی پس از مرحله تعلیم، قدرت سیناپس یک کمیت ثابت باقی

و بالعکس می‌دهند. در روش‌های جدید ثبت، رفتار یک کانال به تنهایی مشاهده و مشخص شده است که باز و بسته شدن کانال حالت غیرمنظم دارد. گروهی از محققان معتقد به تصادفی بودن عملکرد آنها هستند و گروهی معتقدند که مدل‌های مبتنی بر نظریه آشوب می‌توانند این خاصیت کانال‌ها را مدل نمایند [۱۵].

پیتو و همکاران به مطالعه تک نورونی از غده دهانی (STG) خرچنگ خاردار کالیفرنایی پرداخته‌اند [۱۶]. در این مطالعه، مدلی برای فعالیت پتانسیل عمل تک نورون ارائه شده است که قادر به مدل کردن رفتار آشوبی نورون طبیعی است. دسته دیگری از محققان به دنبال ایجاد مدل‌هایی از شبکه عصبی آشوب گونه هستند که ضمن همخوانی با مدل‌های شبکه‌های عصبی مصنوعی کلاسیک، توان ایجاد رفتار آشوب گونه را دارا باشند. در این دسته از مدل‌ها، تنها رفتار یک نورون یا دسته کوچکی از نورون‌های مصنوعی بررسی شده است و به تحلیل روابط بین متغیرها و پارامترهای شبکه و تعیین محدوده‌هایی که نورون رفتار آشوب گونه دارد، پرداخته‌اند. در این مدل‌ها نیز از توان پردازشی مدل سخنی به میان نیامده است. در مرجع [۱۷] دینامیک یک شبکه هاپفیلد سه نورونی با استفاده از نمای لیپانوف با روش عددی مطالعه شده است. رفتار این شبکه به ازای مقادیر مختلف پارامترهای آن بررسی و محدوده‌ای که باعث رفتار آشوبی می‌شود، تعیین شده است. در مرجع [۱۸] نیز مدلی از نورون بازگشتی ارائه شده است که قادر به ایجاد رفتار آشوب گونه است. دسته دیگری از مدل‌های آشوب گونه وجود دارند که ضمن دارا بودن خاصیت آشوب گونه دارای توان پردازشی نیز هستند. در مرجع [۱۹] شبکه عصبی آشوب گونه‌ای ارائه شده است که قادر به ذخیره سازی و بازیابی تصاویر چند سطحی است. در مراجع [۲۰، ۲۱، ۲۲] از المان‌های بازگشتی (تابع لجستیک) برای ذخیره و بازیابی رشته‌های دودویی استفاده شده است. در مرجع [۱] شبکه عصبی آشوب گونه‌ای ارائه شده است که قادر به ذخیره سازی و بازیابی تصاویر چند سطحی است. در این مرجع از یک شبکه بازگشتی به عنوان شبکه پایه استفاده شده است. در این شبکه آشوب گونه، در هر مرحله خروجی توسط تابع های لجستیک که در مد آشوب

نمی‌ماند، بلکه به طور پیوسته در حال تغییر است که این تغییر از فعالیت تعدادی فرآیند شیمیایی در نواحی پیش سیناپسی و پس سیناپسی ناشی می‌شود [۳]. از آن هنگام، چندین مدل شبکه عصبی بر مبنای نگرش فوق ارائه شده است که عموماً از آنها با عنوان شبکه‌های عصبی مصنوعی با سیناپس پویا یاد می‌شود. از این مدل‌ها تا کنون در کاربردهای گوناگونی، از جمله استخراج ویژگی‌های تغییر ناپذیر از سیگنال گفتار متأثر از تنوعات، طبقه‌بندی الگوهای فضایی-زمانی تصادفی، تقریب فیلترهای تربیعی و شناسایی گوینده استفاده گردیده است. با وجود این، هنوز بر سر روش فراگیر تعلیم این گونه شبکه‌های عصبی توافقی وجود ندارد [۴، ۵، ۶، ۷، ۸ و ۹]. برای تعلیم شبکه‌های عصبی مصنوعی با سیناپس پویا تعدادی روش بر مبنای تطبیق بلندمدت با الهام از طبیعت، پیشنهاد شده است [۵، ۱۰]، که با وجود سرعت نسبتاً مناسب، تنها قادرند بخشی از پارامترهای سیناپس را تنظیم نمایند. از روش الگوریتم ژنتیک نیز برای تعلیم شبکه عصبی مبتنی بر سیناپس پویا استفاده شده است که اغلب بسیار کند و وقت گیر هستند [۱۰]. روش تعلیم دیگری که پیشنهاد شده، بر مبنای بهینه‌سازی غیرخطی ناحیه اطمینان است [۱۱]. رویکرد دیگر در تعلیم شبکه‌های عصبی مبتنی بر سیناپس پویا استفاده از روش‌های تعلیم مبتنی بر گرادیان است. در مدل ارائه شده در [۱۲] با انتخاب یک تابع خطای هموار از روش‌های تعلیم مبتنی بر گرادیان برای تعلیم شبکه با وزن پویا استفاده شده است.

پیشرفت‌های جدید در دینامیک غیر خطی و نظریه آشوب نشان داده است که امواج EEG تنها نشان دهنده فرایندهای تصادفی نیستند، بلکه دارای خاصیت آشوب گونه مشخص هستند [۱۳، ۱۴]. رفتار آشوب گونه در نورون‌ها به شکل میکروسکوپی نیز مشاهده شده است. برای مثال غشای آکسون اسکونید ۲ در پاسخ به تحریک سینوسی، متناسب با فرکانس و قدرت تحریک، پاسخ پرودییک یا آشوب گونه از خود نشان می‌دهد [۱۵]. منشا فعالیت نورون‌ها تغییر هدایت پروتئین‌های خاص موجود در غشا سلول‌هاست که کانال نامیده می‌شوند. این کانال‌ها به یون‌ها اجازه حرکت از فضای داخل سلولی به فضای بیرون سلولی


نتایج عددی در بخش‌های بعدی ذکر می‌گردد و در قسمت آخر نیز جمع بندی و پیشنهادها ارائه خواهد شد.

## ۲- شبکه عصبی جلو سوی ایستا

فرض کنید که مجموعه داده‌های تعلیم و برچسب‌های خروجی متناظر با آنها در دست باشند. در این صورت، هدف از تعلیم شبکه پیدا کردن وزن‌های شبکه است؛ به طوری که بتوانند، داده‌های ورودی را به بهترین وجهی به خروجی مطلوب (برچسب‌های متناظر) نگاشت کنند. در روش پس‌انتشار خطا، برای تعلیم شبکه یک تابع معیار مشخص فرض می‌شود که معمولاً بهترین انتخاب برای این تابع مجموع مربعات اختلاف میان خروجی مطلوب و خروجی واقعی شبکه است. وزن‌ها در جهت کمینه کردن خطا اصلاح می‌شوند. و در نهایت، شبکه‌ای با وزن‌های ثابت به دست می‌آید. با اعمال هر ورودی آزمون به این شبکه، یک خروجی ثابت داریم.

### ۲-۱- جداسازی خطی پرسپترون

ساده ترین شبکه‌ای که می‌تواند داده‌ها را به دو دسته تقسیم کند، یک نورون باینری است که پرسپترون نامیده می‌شود. این ساختار در شکل ۱ نشان داده شده است. این مدل توسط روزنبلت در سال ۱۹۵۸ معرفی شد. خروجی ساختار پرسپترون به جمع وزنی کامپوننت‌های ورودی ( $x_i$ ) بستگی دارد. وزن‌ها ( $w_i$ ) متعلق به اعداد حقیقی است. این جمع وزن دار پتانسیل نامیده می‌شود [۲۴].



شکل (۱): ساختار یک پرسپترون [۲۴].

فعالیت می‌کنند، اصلاح شده و خروجی اصلاح شده توسط شبکه عصبی بازگشتی پایه ارزیابی می‌گردد و نحوه اصلاحات مراحل بعدی تعیین می‌شود. این مراحل آنقدر تکرار می‌شوند تا به پاسخ مطلوب برسند. شبکه آشوبی طراحی شده در این مرجع از توان پردازشی بالاتری نسبت به شبکه پایه خود برخوردار است. از آنجایی که شبکه‌های جلوسوی چند لایه از شبکه‌های عصبی قدیمی هستند و تحقیقات طولانی بر روی این شبکه‌ها به ایجاد شبکه‌های جلوسوی چند لایه با توانایی پردازشی بالا منجر شده است، بنابراین، اعمال ویژگی آشوب به این شبکه‌ها که برگرفته از ویژگی شبکه‌های عصبی طبیعی است، می‌تواند به تولد شبکه‌های جلوسوی آشوب گونه‌ای منجر شود که از قدرت پردازش بالایی برخوردارند. در این مقاله روشی برای آشوبی کردن شبکه جلوسوی چند لایه ارائه شده است.

شبکه‌های عصبی جلو سو، دسته وسیعی از شبکه‌های عصبی مصنوعی را تشکیل می‌دهند. این شبکه‌ها از توان پردازشی خوبی برخوردارند و در کاربردهای پردازشی فراوانی، به خصوص در باز شناسی الگو استفاده می‌شوند. با اینکه شبکه‌های عصبی جلو سو از قدمت نسبتاً بالایی برخوردارند، ولی به علت توان پردازشی بالا همچنان مورد توجه محققان هستند. برای مثال، در مرجع [۲۳] از این نوع شبکه‌ها برای باز شناسی الگو استفاده شده است. با اینکه شواهد زیادی بر دینامیکی بودن وزن‌های شبکه عصبی طبیعی ارائه شده، ولی این نوع شبکه‌های عصبی جلو سو همچنان به شکل ایستا عمل می‌کنند. در این مقاله روشی برای پویا سازی وزن‌های شبکه عصبی جلو سوی کلاسیک که ایستا هستند، ارائه شده است.

بخش بعدی به بررسی ساختار و نحوه عملکرد شبکه عصبی جلو سوی ایستا، به خصوص هنگام تعلیم پرداخته شده است، سپس تابع لجستیک و توانایی آن در ایجاد آرایش‌های مختلف سری زمانی آشوب گونه ارائه شده است. در ادامه، با استفاده از شبکه عصبی جلو سوی ایستا و توابع لجستیک با توانایی ایجاد سری زمانی آشوب گونه، شبکه عصبی آشوب گونه طراحی شده در این مقاله معرفی می‌گردد. توضیحات در مورد پایگاه داده استفاده شده و


نمایش این خط در شکل (۲) نشان داده شده است. می توان نشان داد که بردار وزن ها بر ابر صفحه جدا کننده عمود است [۲۵]. تغییر بردار وزن ها باعث تغییر موقعیت ابر صفحه جدا کننده در فضای ورودی می گردد. پس با انتخاب مناسب  $W$  می توان از این نورون برای طبقه بندی ورودی ها به دو طبقه استفاده کرد. این نوع طبقه بندی برای داده هایی که به صورت خطی قابل جداسازی هستند یا به عبارت دیگر، بتوان آنها را با یک خط جدا نمود، مناسب هستند.

### ۳-۲- بررسی تعلیم یک نورون

فرض کنید که یک نمونه ورودی ( $X$ ) داده شده و قرار است این ورودی به نورون تعلیم داده شود؛ یعنی می خواهیم وزن های نورون را به دست آوریم. در فضای وزن ها ( $w_i$ ) معادله رویه تصمیم به شکل زیر خواهد بود.

$$X \cdot W = 0 \quad (۳)$$

بردار  $X \in R^{N+1}$  ورودی مورد نظر به همراه یک مؤلفه اضافی  $X_0 = 1$  (سطح آستانه) است. به عبارت دیگر  $X$ ،  $N + 1$  بعدی است که دارای یک مقدار آستانه است.



شکل (۲): نمودار خط جدا کننده  $w_1 \cdot x_1^H + w_2 \cdot x_2^H + w_0 = 0$

$w_0 = 0$  در فضای دو بعدی ورودی  $(x_1, x_2)$  با فرض  $w_1 > 0$ ،  $w_2 > 0$  و  $w_0 < 0$  بردار وزن ها  $W$  بر ابر صفحه (خط) جدا کننده عمود است

با ثابت در نظر گرفتن ورودی  $X$ ، رابطه (۳) نمودار یک ابر صفحه در فضای وزن ها است که بردار ورودی بر آن عمود است. فرض کنید که  $X_1$  ورودی اول و  $X_2$  ورودی دوم و

### ۲-۲- بررسی طبقه بندی کننده پرسپترون از نظر

#### هندسی

در این بخش چگونگی عملکرد یک طبقه بندی کننده پرسپترون توضیح داده می شود و در قسمت های بعدی از این مفاهیم برای تحلیل عملکرد شبکه عصبی جلو سوی آشوب گونه استفاده می شود.

ابر صفحه جدا کننده: برای ورودی  $X$  و وزن  $W$  نقاطی که در معادله زیر صدق می کنند، تشکیل ابر صفحه می دهند.

$$W \cdot X^H = 0$$

این ابر صفحه می تواند فضای ورودی را به دو طبقه تقسیم کند. در فضای ورودی اگر  $W \cdot X > 0$  باشد، آنگاه خروجی نورون (+۱) شده، این ورودی متعلق به طبقه +۱ است و بالعکس، اگر  $W \cdot X < 0$  باشد، این ورودی متعلق به طبقه -۱ است. بنابراین، یک نورون می تواند برای طبقه بندی ورودی ها به دو طبقه استفاده شود.

### چگونگی جداسازی ورودی ها با استفاده از نورون پرسپترون (جدا کننده های خطی)

رابطه مربوط به ابر صفحه جدا کننده را می توان به صورت زیر در نظر گرفت:

$$W \cdot X^H + W_0 = 0 \quad (۱)$$

در رابطه (۱)  $x_0 = 1$  در نظر گرفته شده است. این معادله یک ابر صفحه در فضای  $N$  بعدی  $(X^H \in R^N)$  است. فرض می کنیم که ورودی دو بعدی باشد ( $N = 2$ ). در این صورت برای نقطه  $X^H = [x_1^H, x_2^H]$  داریم:

$$w_1 \cdot x_1^H + w_2 \cdot x_2^H + W_0 = 0 \quad (۲)$$

معادله (۲) یک خط در فضای دو بعدی ورودی  $(x_1, x_2)$  است. با فرض  $w_1 > 0$ ،  $w_2 > 0$  و  $w_0 < 0$  می توان نمودار خط (۲) را در فضای  $x_1$  و  $x_2$  به دست آورد:

$$x_1 = 0 \rightarrow w_2 \cdot x_2 + w_0 = 0 \rightarrow x_2 = -\frac{w_0}{w_2}$$

$$x_2 = 0 \rightarrow w_1 \cdot x_1 + w_0 = 0 \rightarrow x_1 = -\frac{w_0}{w_1}$$

مقادیر را دارا باشند، اگر این نواحی ناحیه اشتراک نداشته باشند بدان معنی است که با این آرایش نوروں نمی‌توان این داده‌ها را به نوروں تعلیم داد.

در این مقاله از شبکه عصبی کلاسیک ارائه شده در مرجع [۲۳] به عنوان شبکه عصبی جلوسوی پایه استفاده شده است. این شبکه عصبی جلوسو دارای وزن‌های ثابت است و بر اساس آنالیز مؤلفه‌های اساسی عمل می‌کند. شبکه‌ای با ساختار ۱۰، ۷۵۰، ۲۰۰، ۲۰۰، ۲۵۶ که داده ورودی (تصویر ارقام دست نوشتار انگلیسی) را به برجسب آنها نسبت می‌دهد، با استفاده از روش ارائه شده در [۲۳] تعلیم داده می‌شود و وزن‌های آن که اعداد ثابتی هستند به دست می‌آیند. قصد داریم با تغییر آشوب گونه وزن‌ها در محدوده مناسب مشابه آنچه در شکل ۳ نشان داده شده است، روشی را ارائه نماییم تا الگوهایی که خیلی نزدیک به مرز تصمیم بوده و ممکن است در برخی شرایط در کلاس دیگری اعلام شوند، تشخیص داده شوند و پس از تشخیص آنها را با عنوان "وضعیت طبقه بندی نامشخص" اعلام نماید. چگونگی تبدیل این شبکه به شبکه عصبی با وزن‌های آشوبی در بخش‌های بعدی ارائه شده است.

### ۳- تابع لجستیک، مولد آرایش‌های مختلف

معمولاً با انتخاب مناسب پارامترهای سیستم غیرخطی می‌توان آنها را به رفتار آشوب گونه مجبور نمود. سیستم آشوب گونه با شروع از یک نقطه از فضای حالت ناحیه مشخصی را جستجو می‌کند، بدون اینکه از نقطه‌ای دو بار عبور کند. محدوده این ناحیه با استفاده از پارامترهای سیستم تعیین می‌شود. از ویژگی‌های دیگر سیستم‌های آشوب گونه وابستگی چگونگی جستجوی آنها در محدوده مشخص به شرایط اولیه است. در این مقاله از این ویژگی‌های سیستم آشوب گونه برای یافتن وزن‌های آشوب گونه مطلوب استفاده شده است.


تابع لجستیک یک تابع غیرخطی و دارای یک پارامتر کنترل است. در این تابع در هر لحظه خروجی لحظه بعد از رابطه زیر به دست می‌آید:

$$x(k+1) = Ax(k)(1-x(k)) \quad (4)$$

که در آن  $x(k)$  حالت سیستم در تکرار  $k$  و  $A$  پارامتر دوشاخه شدگی آن است. دینامیک این تابع به شدت به

$X_3 \cdot W = 0$  ورودی سوم باشد. در این صورت نمایش (ابر) صفحه‌ای است در فضای وزن‌ها که بر بردار ورودی  $X_1$  عمود و از مبدا مختصات می‌گذرد (شکل (۳)). با توجه به شکل (۳) در یک طرف خط  $X_1 \cdot W = 0$  داریم  $X_1 \cdot W < 0$  و در طرف دیگر  $X_1 \cdot W > 0$  است. به همین ترتیب  $X_2 \cdot W = 0$  صفحه‌ی دیگری در فضای وزن‌هاست که از مبدا مختصات می‌گذرد و بر بردار ورودی  $X_2$  عمود است.

فرض کنید که خروجی‌های مطلوب به ورودی‌های  $X_1$ ،  $X_2$  و  $X_3$  عبارتند از: ۱، ۰ و ۱. با توجه به این خروجی‌ها ناحیه مطلوبی که وزن‌ها باید در آن قرار بگیرند، مکانی از صفحه فضای وزن‌هاست که در آن  $X_1 \cdot W > 0$ ،  $X_2 \cdot W < 0$  و  $X_3 \cdot W > 0$  باشد، که این نواحی همراه با صفحه‌های تصمیم مربوط به هر ورودی در شکل ۳ نشان داده شده است. باید  $W$  را در ناحیه‌ای که این سه شرط را برآورده می‌سازد، انتخاب نمود. این ناحیه در شکل (۳) با  $I$  نشان داده شده است.



شکل (۳): مکانی از فضای وزن‌ها که در آن  $X_1 \cdot W > 0$ ،  $X_2 \cdot W < 0$  و  $X_3 \cdot W > 0$  باشد با  $I$  نشان داده شده است.

تعلیم نوروں؛ یعنی این که چگونه از یک  $W_0$  اولیه به  $W_f$  مطلوب برسیم. بنا براین، با توجه به شکل (۳) باید با شروع از یک وزن اولیه به سمت ناحیه اشتراک داده‌های تعلیم در فضای تعلیم حرکت کرد. همان طوری که در شکل (۳) مشاهده می‌شود، این ناحیه یک فضای نامتناهی است بنابراین، بی‌نهایت وزن می‌توان برای نوروں یافت که داده‌های تعلیم را برآورده نماید. به عبارت دیگر، وزن‌های مطلوب دارای مقدار یکتا نیستند و می‌توانند مجموعه‌ای از

شکل (۶) نمودار زمانی پنجاه نمونه از  $x(Tk)$  به ازای دو شرط اولیه مختلف را نشان می‌دهد. در این شکل‌ها  $\alpha = 1$  در نظر گرفته شده است. به ازای  $T = 1$  که سری زمانی پایه است، تمام مقادیر  $x$  به دست آمده از تابع لجستیک (۵) رسم شده است. به ازای  $T = 2$  تنها نمونه‌های زوج سری زمانی پایه، یا  $x$  های به دست آمده از رابطه (۶) رسم شده‌اند.

$$x(k+1) = f(f(x(k))) = f_{T=2}(x(k)) \quad (6)$$


که  $f(x(k))$  از رابطه (۵) محاسبه می‌شود. به ازای  $T = 3$  نمونه‌های مضرب ۳ رسم شده است. همان طور که مشاهده می‌شود، با تغییر  $T$  وضعیت این سیگنال‌ها نسبت به هم تغییر می‌کند (بدون اینکه شرط اولیه را تغییر دهیم). علت این است که پارامتر  $A$  طوری قرار داده شده که تابع لجستیک دارای دینامیک آشوب گونه باشد. این تغییر وضعیت‌ها هیچ گاه تکرار نمی‌شوند، زیرا تابع لجستیک در وضعیت آشوب قرار دارد. همان طور که در قسمت بعد بیان خواهد شد، این خاصیت برای یافتن حالتی از آرایش وزن‌ها که کمترین خطا را داشته باشند، استفاده می‌شود، به این صورت که با ایجاد آرایش‌های مختلف (از طریق تغییر  $T$ )، آرایشی که کمترین خطا را در بازشناسی داده‌ها دارد، پیدا می‌شود. به عبارت دیگر، با استفاده از این روش وزن‌های پویای شبکه را طوری همزمان می‌کنیم که خطای شبکه نهایی کمینه باشد.

#### ۴- شبکه عصبی جلوسوی آشوب گونه

با اینکه روش‌های رایج تعلیم شبکه‌های عصبی جلوسو وزن‌ها را بر اساس محاسبات دقیق ریاضی و معین به دست می‌آورد، اما جوابی که برای وزن‌ها به دست می‌آید یکتا نبوده، به شدت به شرایط اولیه وابسته است؛ به طوری که با انتخاب شرایط اولیه مختلف، وزن‌های مختلفی برای شبکه به دست می‌آید. بنابراین، برای یک مجموعه تعلیم می‌توان شبکه‌های مختلف با ساختار مشابه به دست آورد. به عبارت دیگر، وزن‌ها به جای اینکه یک مقدار ثابت داشته باشند می‌توانند مجموعه‌ای از مقادیر مختلف را بگیرند؛ به طوری که این وزن‌ها نسبت به هم طبق قاعده خاصی تغییر می‌کنند. همان طوری که در قسمت‌های قبل توضیح داده شد در


پارامتر  $A$  وابسته است؛ به طوری که با تغییر  $A$  این تابع از خود انواع رفتارها (از پرودیک تا آشوب گونه) را نشان می‌دهد [26] (شکل (۴)). با قرار دادن  $A = 4$  تابع لجستیک از خود رفتار آشوب گونه نشان می‌دهد. در مرجع [۱] رابطه‌ای برای تابع لجستیک به صورت (۵) تعریف شده است که در آن با اضافه کردن یک پارامتر جدید،  $\alpha$ ، به تابع لجستیک یک تابع جدید تعریف شده است که ناحیه  $\left[-\frac{\alpha}{2}, +\frac{\alpha}{2}\right]$  را به صورت آشوب گونه جستجو می‌کند (با فرض  $A = 4$ ). با تغییر  $\alpha$  می‌توان ناحیه جستجوی تابع را در حول مبدأ تغییر داد. شکل (۵) نمودار این تابع را به ازای دو مقدار مختلف  $\alpha = 1$  و  $\alpha = 0.5$  نشان می‌دهد که به ترتیب دو ناحیه  $[-0.5, +0.5]$  و  $[-0.25, +0.25]$  را به ازای  $A = 4$  به صورت آشوب گونه جستجو می‌کند. در این مقاله از رابطه (۵) برای تغییر محدوده جستجوی شبکه آشوب گونه جهت یافتن محدوده مناسب استفاده می‌شود.

$$x(k+1) = f(x(k)) = \alpha \left[ A \left( \frac{x(k)}{\alpha} + 0.5 \right) (0.5 - \frac{x(k)}{\alpha}) - 0.5 \right] \quad (5)$$



شکل (۴): نمودار دوشاخه شدگی تابع لجستیک به ازای تغییر

پارامتر  $A$



شکل (۵): ناحیه جستجوی تابع (۵) به ازای دو مقدار مختلف  $\alpha = 1$  (۱) باعث جستجو در ناحیه  $[-0.5, +0.5]$  می‌شود.  $\alpha = 0.5$  (۲) باعث جستجو در ناحیه  $[-0.25, +0.25]$  می‌شود [۱].

تغییر آرایش سری زمانی به دست آمده از رابطه (۵) می‌توان از تغییر شرط اولیه یا تغییر  $T$  استفاده نمود. در این مقاله برای تغییر آرایش وزن‌ها همان طوری که در شکل (۶) نشان داده شده است، از تغییر  $T$  استفاده شده است. فعالیت هر تابع از شرط اولیه ثابت بسیار کوچک که متناسب با وزن پایه متناظر ( $x(0) = 0.0001W$ ) است، شروع می‌شود. بنابراین، برای یافتن وزن‌های آشوبی اولاً باید محدوده تغییرات این وزن‌ها را تعیین کرد، که این کار از طریق تعیین مقدار مناسب  $\alpha$  انجام می‌شود. دوم اینکه  $T$  را طوری تعیین کنیم که خطای شبکه کمینه شود.

با مشخص شدن مقادیر  $T$  و  $\alpha$  در رابطه (۵) و با شروع از شرط اولیه ثابت  $x(0) = 0.0001W$  یک دنباله با مقادیر مشخص برای  $x(k)$  که متناظر با هر وزن است، به دست می‌آید که با دیگر وزن‌ها همزمان است. به عبارت دیگر، این دنباله دارای ویژگی کاملاً معین است. در حالی که اگر از یک متغیر تصادفی برای  $x(k)$  استفاده می‌شد در هر بازشناسی با سری جدیدی مواجه بودیم که با سری‌های تصادفی دیگر نمی‌توانست همزمان باشد. بنابراین، با ثابت کردن پارامترهای یک تابع آشوب و با شروع از یک شرط اولیه ثابت، یک سری زمانی داریم که کاملاً معین است.

برای یافتن  $\alpha$  مطلوب نیز از داده‌های تعلیم استفاده می‌شود. برای این منظور، در صد صحت بازشناسی شبکه جلوسوی تعلیم داده شده پایه بر روی دادگان تعلیم به دست می‌آید که معمولاً ۱۰۰٪ است. در رابطه (۵) با شروع  $\alpha$  از یک مقدار مینیمم تعدادی از وزن‌های شبکه را آشوبی می‌کنیم؛ به طوری که درصد صحت بازشناسی شبکه بر روی دادگان تعلیم همچنان ۱۰۰٪ باقی بماند. مقدار  $\alpha$  (دامنه تغییرات آشوب گونه وزن‌ها) آنقدر افزایش داده می‌شود تا درصد صحت باز شناسی شبکه از ۱۰۰٪ کمتر شود. در این صورت، حداکثر مقدار  $\alpha$  که به ازای آن درصد صحت بازشناسی شبکه جلوسو همچنان ۱۰۰٪ است، به عنوان  $\alpha$  مطلوب در نظر گرفته می‌شود.

برای یافتن  $T$  مطلوب با شروع از  $T=1$  و افزایش آن تا ۱۰۰، برای هر  $T$  شبکه جلوسویی داریم که وزن‌های آن به

تعلیم شبکه پرسپترون وزن‌های مطلوب در یک ناحیه از فضای وزن‌ها هستند (ناحیه I در شکل (۳)). که این ناحیه را داده‌های تعلیم و ساختار شبکه تعیین می‌کنند. محدود شدن به یک مجموعه وزن ثابت باعث محدود کردن توانایی شبکه در بازشناسی داده‌ها، به خصوص داده‌های جدید می‌شود. در این مقاله ناحیه وزن‌های مطلوب یک شبکه به طور تقریبی به دست می‌آید و اثر تغییرات وزن‌ها در این ناحیه مطلوب بر روی قدرت بازشناسی یک شبکه جلوسو بررسی می‌گردد. برای این منظور، ابتدا شبکه عصبی جلوسوی معرفی شده در بخش‌های قبلی آشوبی می‌شود. سپس با جستجوی آشوب‌گونه آرایش‌های مختلف وزن‌ها، آن آرایشی که بهترین صحت باز شناسی را دارد، پیدا می‌شود. در این مقاله فقط وزن‌های لایه اول آشوبی می‌شوند.

برای آشوبی کردن وزن‌های یک شبکه جلوسو، مجموعه‌ای از وزن‌های آن را در نظر بگیرد. همان طوری که در شکل (۳) نشان داده شده است، این وزن‌ها یکتا نبوده، می‌توانند متغیر باشند. یک دسته از این وزن‌ها را به عنوان وزن پایه انتخاب می‌کنیم. به منظور طراحی شبکه عصبی پویا (آشوب‌گونه) برای هر وزنی که قرار است آشوبی شود یک تابع لجستیک با رابطه (۵) در نظر می‌گیریم که در محدوده  $\left[-\frac{\alpha}{2}, +\frac{\alpha}{2}\right]$  تغییر می‌کند. سپس خروجی این تابع را در هر لحظه به وزن پایه اضافه می‌کنیم. به این ترتیب وزن‌ها در هر لحظه به صورت آشوب‌گونه تغییر می‌کنند. حال اگر یک الگو به عنوان ورودی به این شبکه اعمال کنیم، برخلاف شبکه ایستا، هر وزن مقادیری مختلف دارد و در نتیجه، تعداد زیادی الگوی خروجی داریم که هر یک حاوی اطلاعات مفیدی در مورد خروجی اصلی هستند. بدیهی است که این خروجی‌ها دارای خطا هستند. نحوه تغییرات وزن‌ها باید طوری انتخاب شود که خطای خروجی حداقل گردد؛ یعنی باید تغییرات وزن‌ها طوری با هم همزمان شوند که خطای خروجی ایجاد شده مینیمم باشد. برای یافتن آرایشی از مقادیر وزن‌ها که خطا را کمینه کند، آرایش‌های مختلفی از وزن‌های آشوب گونه را تولید کرده، خطای شبکه را برای هر آرایش به دست می‌آوریم. برای

گردید. نمودار درصد بازشناسی شبکه آشوب گونه به ازای  $\alpha$  های مختلف در شکل (۷) نشان داده شده است. به ازای  $\alpha=0/2$  درصد صحت بازشناسی شبکه با دقت دو رقم اعشار همچنان ۱۰۰٪ است. این مقدار  $\alpha$  را به عنوان مقدار مطلوب در نظر می گیریم.

برای همزمان کردن وزن ها و یافتن  $T$  مطلوب به منظور رسیدن به خطای کمینه،  $T$  از ۱ تا ۱۰۰ افزایش داده می شود و خطای شبکه آشوب گونه متناظر با هر یک از این  $T$  ها محاسبه می گردد. سپس  $T$  متناظر با خطای مینیمم به عنوان  $T$  مطلوب در نظر گرفته می شود. شکل (۸) نمودار خطای بازشناسی شبکه آشوب گونه را برای  $T$  های مختلف نشان می دهد. خطای بازشناسی شبکه آشوب گونه به ازای  $T=12$  کمینه می شود. مقدار خطای کمینه برابر  $1.9 \times 10^{-7}$  است. از روش متوسط مربعات خطا برای محاسبه خطا استفاده شده است.

پس از به دست آوردن  $\alpha$  و  $T$  مطلوب شبکه آشوب گونه ایجاد شده مورد آزمون قرار گرفت و به ازای هر ورودی صد خروجی اول شبکه آشوب گونه در نظر گرفته شد. با بررسی نتایج به دست آمده، مشخص شد برای داده هایی که به وسیله شبکه ایستا درست تشخیص داده شده اند، اکثر ۱۰۰ خروجی به دست آمده از شبکه آشوب گونه نیز این داده را در همان طبقه ای که شبکه ایستا تشخیص داده است، قرار می دهد، اما داده هایی که توسط شبکه ایستا غلط تشخیص داده شده اند، توسط شبکه آشوب گونه قابل تشخیص نبوده، این شبکه این داده ها را جزو طبقات مختلف، از جمله طبقه اصلی مربوط به داده ورودی قرار می دهد. بنابراین، از این ویژگی می توان برای تشخیص بازشناسی های اشتباه شبکه ایستا استفاده کرد.

خروجی های شبکه عصبی جلوسوی آشوب گونه به یک داده آزمون (عدد ۳ دست نوشتار) که توسط شبکه ایستا درست تشخیص داده شده است، در شکل (۹-۱) نمایش داده شده است. چنانکه مشاهده می شود، تمامی صد خروجی شبکه آشوب گونه این داده را به طبقه ۳ اختصاص می دهند.

صورت آشوب گونه تغییر می کند. این شبکه برای هر تصویر ورودی بی شمار خروجی ایجاد می کند. صد خروجی اول مربوط به هر  $T$  را در نظر می گیریم. به روش مربعات خطا، خطای هر یک از این خروجی ها را نسبت به خروجی اصلی (که عضو داده های تعلیم است) به دست آورده، میانگین گیری می کنیم.  $T$  را تا ۱۰۰ افزایش داده، خطای متناظر با هر  $T$  را محاسبه می کنیم. سپس  $T$  متناظر با خطای کمینه را به عنوان  $T$  مطلوب در نظر می گیریم. به عبارت دیگر، در  $T$  مطلوب وزن ها طوری با هم همزمان می شوند که مقدار خطا کمینه می شود.

## ۵- پایگاه داده ها


برای بررسی کارایی شبکه پیشنهادی، از آن برای بازشناسی ارقام دست نوشتار انگلیسی موجود در پایگاه داده های USPS استفاده شد. این پایگاه داده حاوی ۴۶۴۹ داده تعلیم و ۴۶۴۹ داده تست است. داده های تعلیم بردارهای به دست آمده از تصاویر  $16 \times 16$  ارقام دست نوشتار انگلیسی هستند. تصویر ارقام دارای سطوح خاکستری هستند دامنه تغییرات هر نقطه تصویر در بازه [۰، ۱-] نرمال سازی شده است [27].

## ۶- نتایج شبیه سازی


۴۶۴۹ داده تست پایگاه داده USPS با روش ارائه شده در مرجع [۲۳] به شبکه ای با ساختار ۱۰، ۷۵۰، ۲۰۰، ۲۰۰، ۲۵۶ که داده ورودی (تصویر ارقام دست نوشتار با ۲۵۶ نقطه) را به برجسب آن نسبت می دهد، تعلیم داده شدند ماتریس وزن های لایه اول یک ماتریس با ۲۵۷ ردیف (که یک ردیف مربوط به بایاس است) و ۲۰۰ ستون است.

برای آشوبی کردن وزن های ابتدا محدود شده تغییرات وزن ها ( $\alpha$  مطلوب) تعیین شد. در این مقاله ۳۰ ردیف اول از ماتریس وزن لایه اول آشوبی شده اند. برای به دست آوردن  $\alpha$  مطلوب،  $\alpha$  به تدریج از ۰/۱۲ تا ۰/۲۸ با گام های ۰/۰۰۲ افزایش داده شد و درصد صحت بازشناسی شبکه بر روی داده های تعلیم برای هر یک از این  $\alpha$  ها محاسبه







شکل (۶): نمودار زمانی  $x(Tk)$  مربوط به تابع لجستیک به ازای دو شرط اولیه مختلف و  $T = 1, 2, 3$



شکل (۷) نمودار درصد صحت بازشناسی شبکه عصبی آشوب گونه بر روی داده های تعلیم به ازای  $\alpha$  های مختلف.



شکل (۸): نمودار خطای بازشناسی شبکه آشوب گونه به ازای  $T$  های مختلف. خطای بازشناسی شبکه آشوب گونه به ازای  $T=12$  کمینه می‌شود. مقدار خطای کمینه برابر  $1.9 \times 10^{-7}$  است. از روش متوسط مربعات خطا برای محاسبه خطا استفاده شده است.



شکل (۹): فراوانی خروجی شبکه آشوب گونه (۱) وقتی که شبکه ایستا داده تست را درست تشخیص داده است (۲) وقتی که شبکه ایستا داده تست را اشتباه تشخیص داده است.

۱۴۳ داده‌ای که توسط شبکه ایستا اشتباه تشخیص داده شده بودند، در این دسته بودند. به این ترتیب، شبکه دینامیکی توانست ۱۰۰٪ اشتباهات شبکه جلوسو را تشخیص دهد، اما این شبکه ۴۳ داده دیگر را که توسط شبکه ایستا درست تشخیص داده شده بود، به عنوان ناشناخته معرفی کرد. به این ترتیب ۱۰۰٪ داده‌هایی را که تشخیص داده است درست است و حدود ۴٪ داده‌هایی که قبلاً درست تشخیص داده شده بودند را به عنوان ناشناخته معرفی کرد. با توجه به نوع مسأله و میزان مهم بودن تشخیص درست، می‌توان معیارهای تصمیم‌گیری شبکه آشوب‌گونه را طوری تغییر داد تا به نتیجه مطلوب رسید. جدول (۱) صحت باز شناسی دو شبکه را مقایسه کرده است.


جدول (۱): مقایسه نتایج به دست آمده از آزمون شبکه ایستا ارائه شده در [۲۳] و شبکه آشوب‌گونه بر روی ۴۶۴۹ داده آزمون.

شبکه آشوب‌گونه	شبکه ایستا	خاصیت
۱۰۰	۹۶/۹	درصد صحت تشخیص
۰	۱۴۳	داده‌هایی که اشتباه طبقه بندی شده‌اند
۴۴۶۲	۴۵۰۶	داده‌هایی که به درستی طبقه بندی شده‌اند
۱۸۷	۰	داده‌هایی که شبکه در مورد آنها اظهار نظر نکرده است

شکل (۹-۲) خروجی‌های شبکه جلوسوی آشوب‌گونه را در حالتی که داده تست ورودی ۷ است و شبکه ایستا آن را به اشتباه ۱ تشخیص داده است، نشان می‌دهد. همان طوری که مشاهده می‌شود، خروجی‌های شبکه آشوب‌گونه این ورودی را جزو طبقات ۱، ۳ و ۹ قرار داده‌اند. به عبارت دیگر، شبکه جلو سوی آشوب‌گونه سردر گم است. از این خاصیت استفاده شده و معیاری تعیین شد که قادر است داده‌هایی را که توسط شبکه ایستا اشتباه تشخیص داده شده‌اند، شناسایی و معرفی نماید. معیار اعمال شده به این صورت بود که اگر تعداد طبقاتی که صد خروجی اول شبکه آشوب‌گونه به آنها نسبت داده می‌شوند (برای یک ورودی تست) بیشتر از دو طبقه باشد، شبکه جلوی سوی ایستای پایه این ورودی را اشتباه تشخیص داده است. همچنین، اگر ماکزیمم فراوانی طبقات کمتر از ۸۰ باشد نیز شبکه جلوسوی پایه در تشخیص خود اشتباه کرده است. برای تعیین محدوده تغییرات هر وزن از داده‌های تعلیم استفاده شد. تغییرات را از یک محدوده کوچک شروع و کم کم این محدوده را زیاد نموده، این افزایش تا جایی ادامه می‌یابد که شبکه عصبی جلوسوی پایه (ایستا) در تشخیص داده‌های تعلیم اشتباه کند.

صحت بازشناسی شبکه جلوسوی ایستا بر روی داده‌های تعلیم ۱۰۰٪ و بر روی ۴۶۴۹ داده تست ۹۶/۹٪ شد؛ یعنی این شبکه ۱۴۳ داده تست را اشتباه تشخیص می‌دهد. با دینامیکی کردن این شبکه در محدوده مناسب توانستیم ۱۸۷ داده را از داده‌های تست جدا کنیم که تمامی

آن  $y$  برابر یک خواهد بود. اکنون فرض کنید که بخواهیم سیستمی داشته باشیم که دو گروه الگوهای '0' و 'X' را در فضای دو بعدی، چنانکه در شکل (۱۰) نشان داده شده است، از یکدیگر تفکیک نماید. نورون شکل ۲ می‌تواند از عهده این کار بر آید، به طوری که اگر یکی از الگوهای ورودی '0' به نورون اعمال شود، مقدار خروجی، -۱ و اگر یکی از الگوهای 'X' به نورون اعمال شود، مقدار آن +۱ شود. الگوریتم‌های یادگیری معمول مانند الگوریتم یادگیری پس انتشار خطا با آغاز از یک دسته وزن تصادفی که به منزله یک خط تصادفی در صفحه شکل (۱۰) است، در جهت یافتن خطی که این داده‌ها را با خطای کمتر جداسازی نماید، حرکت می‌کند. هدف اکثر این الگوریتم‌ها تنها یافتن نخستین دسته وزنی است که خطای آن از یک حد آستانه کمتر باشد، اما این خط تنها خط جدا کننده این داده‌ها نیست و لزوماً بهینه‌ترین آنها نیز نیست. همان طوری که در شکل (۱۱) نشان داده شده است برای جدا سازی دو ناحیه '0' و 'X' خط‌های مختلفی وجود دارد (L1, L2 و L3 و...)، اما بهتر آن است که به دنبال خطی باشیم که ضمن اینکه خطا را مینیمم می‌کند، حاشیه اطمینان را نیز افزایش دهد؛ یعنی خطی را انتخاب کنیم که فاصله نمونه‌ها از آن ماکزیمم گردد. فاصله اطمینان نکته‌ای است که در شبکه‌های کلاسیک کمتر به آن توجه می‌شود.



شکل (۱۰): مرز تصمیم‌گیری برای تفکیک الگوهای 0, X

## ۷- بررسی و تحلیل

یکی از ویژگی‌های مهم مغز، خاصیت دینامیکی آن است. در این مقاله سعی شد مدلی از شبکه عصبی آشوب‌گونه ارائه شود که ضمن دارا بودن خاصیت آشوب‌گونه از توان پردازشی بیشتری نسبت به شبکه عصبی پایه برخوردار باشد. برخلاف شبکه‌های کلاسیک که در مورد همه ورودی‌ها یک خروجی قطعی می‌دهند (هرچند که آن خروجی اشتباه باشد)، یک ویژگی قابل توجه مدل ارائه شده، این است که اگر قادر به تشخیص داده‌ای نباشد، اعلام می‌کند. این عملکرد شبکه عصبی آشوب‌گونه به عملکرد مغز بیشتر شبیه است. به عبارت دیگر این شبکه با هوش تر است و می‌داند که جواب برخی از ورودی‌ها را ندارد.

سوالی که اینجا مطرح می‌شود، این است که چرا دینامیکی کردن وزن‌های شبکه عصبی ایستا باعث ایجاد شبکه عصبی آشوب‌گونه با توان پردازشی بیشتر گردید؟ چگونه می‌توان این اتفاق را از نظر قوانین حاکم بر شبکه‌های عصبی مصنوعی توجیه نمود؟ برای پاسخ به این سؤال به بررسی عملکرد وزن‌ها در شبکه عصبی مصنوعی می‌پردازیم.

شبکه عصبی به عنوان یک طبقه بندی کننده، فضای ورودی را به نواحی تصمیم‌گیری تفکیک می‌کند. سرحد هر ناحیه تصمیم‌گیری را، مرز تصمیم‌گیری ۳ می‌نامند. گاهی اوقات تجسم حدود و نواحی تصمیم‌گیری راحت است، ولی همواره ممکن نیست.

نورون پرسپترون شکل (۱) با تابع پله‌ای به عنوان تابع عملکردی نورون و  $N = 2$  را در نظر بگیرید. بنابراین فضای ورودی که در اینجا یک صفحه است، توسط مرز تصمیم‌گیری که یک خط است، به دو بخش تقسیم می‌شود (شکل ۲). با تعمیم مطالب فوق، پی می‌بریم که معادله مرز تصمیم‌گیری وقتی ورودی‌ها، یک فضای  $N$  بعدی را می‌سازند، یک ابر صفحه  $N-1$  بعدی خواهد بود که در یک طرف آن  $y$  (خروجی نورون) برابر صفر و در طرف دیگر


بازشناسی‌ها باشد که بسیار حساس بوده، به صحت بازشناسی ۱۰۰٪ نیاز دارند.

بهبود محدوده تغییر وزن‌ها و استفاده از توابع دیگر (به جای تابع لجستیک) که همخوانی بیشتری با ساختار شبکه، داده‌های تعلیم و ... دارند، می‌تواند نتایج را بهبود دهد. با اعمال پردازش‌های مناسب بر روی خروجی شبکه آشوب گونه (شکل (۹)) می‌توان در مورد داده‌هایی که تشخیص داده نشده‌اند اظهار نظر دقیق‌تری کرد.

یکی از ویژگی‌های مهم شبکه آشوبی ارائه شده، این است که یک روش عمومی بوده، قابل اعمال به بسیاری دیگر از شبکه‌های عصبی معمولی است. از مشکلات این روش این است که برای هر داده ورودی صد داده خروجی حساب می‌شود، که این باعث طولانی شدن پروسه بازشناسی می‌شود. به عبارت دیگر، مقداری وقت صرف فکر کردن می‌کند! که از این نظر نیز می‌توان گفت مانند شبکه‌های عصبی واقعی عمل می‌کند. مشکل دیگر این شبکه آشوب گونه این است که تعدادی از داده‌هایی که توسط شبکه پایه درست تشخیص داده شده‌اند را نیز به عنوان غیرقابل تشخیص معرفی می‌کند، ولی در مقابل این شبکه تمامی خطاهای شبکه پایه را تشخیص می‌دهد. با تنظیم مناسب پارامترها و سطح آستانه‌ها می‌توان به سطح مناسبی از صحت باز شناسی دست یافت.

## مراجع

- [1] A. Taherkhani, S.A. Seyyedsalehi, A.H. Jafari, "Design of a chaotic neural network for training and retrieval of grayscale and binary patterns", *Neurocomputing*, Volume 74, Issue 17, Pages 2824-2833, October 2011.
- [2] P. Stern, "Neuroscience: A Vibrant Connection", *Science*, Vol. 298, p. 769, 2002.
- [3] R. S. Zucker, and W. G. Regehr, "Short-term Synaptic Plasticity", *Annu. Rev. Physiol.*, Vol. 64, pp. 355-405, 2002.
- [4] J. S. Liaw, and T. W. Berger, "Dynamic Synapse: A New Concept of Neural Representation and Computation", *Hippocampus*, Vol. 6, pp. 591-600, 1996.



شکل (۱۱): برای جدا سازی دو ناحیه '0' و 'X' خط‌های مختلفی وجود دارد (L1, L2 و L3 و...). خطی که خطا را مینیمم می‌کند، حاشیه اطمینان را افزایش می‌دهد.

دینامیکی کردن وزن‌ها در یک محدوده مشخص، در واقع به معنی جابه جایی این خط‌های جداکننده طبقات است. این کار باعث می‌شود داده‌هایی که در مرز تصمیم قرار دارند؛ با هر بار جابه‌جایی خط تصمیم به طبقات مختلف نسبت داده شوند. معمولاً اشتباه‌های یک شبکه مربوط به داده‌هایی است که در نزدیکی مرز تصمیم قرار دارند. بنابراین، همان گونه که نشان داده شد، دینامیکی کردن وزن‌های شبکه در یک محدوده مناسب می‌تواند به شناسایی این داده‌ها کمک کند.

## ۸- نتیجه گیری

تحقیقات جدید، وجود رفتارهای آشوب گونه در عملکرد شبکه‌های عصبی طبیعی را اثبات کرده است. در این مقاله با استفاده از تابع لجستیک که دارای توان تنظیم محدوده خروجی است، تعدادی از وزن‌های لایه اول یک شبکه جلوسو را به طور هماهنگ با هم طوری آشوب گونه کردیم که خطای شبکه حاصل مینیمم شود. این کار باعث شد تا داده‌هایی که در نزدیک مرز تصمیم‌گیری هستند و احتمال بازشناسی اشتباه آنها وجود دارد، شناسایی و جدا شوند. به این ترتیب، شبکه آشوبی حاصل توانست داده‌های باقیمانده از داده‌های تست را با ۱۰۰٪ صحت بازشناسی کند. بنابراین، یکی از کاربردهای این شبکه می‌تواند در

- [14] Yao, Y., Freeman, "Model of biological pattern recognition with spatially chaotic dynamics", *Neural Networks*, 3(2), 153, 1990.
- [15] Michael A. Arbib, *The Handbook of Brain Theory and Neural Networks*, second edition, MIT Press, Cambridge, Massachusetts, London, England, 2003.
- [16] R. D. Pinto, P. Varona, A. R. Volkovskii, A. Szűcs, H. D. I. Abarbanel and M. I. Rabinovich, "Synchronous Behavior of Two Coupled Electronic Neurons" *Phys. Rev. E* 62, 2644, 2000.
- [17] Xiao. Yanga, Q. Yuan, "Chaos and transient chaos in simple Hopfield neural networks", *Neurocomputing* 69, 232–241, 2005.
- [18] Sang. Kim, Su-Dong, Won. Park, "An adaptive neuro-controller with odified chaotic neural networks", *IEEE International Joint Conference on Neural Networks. IJCNN '01*, Washington, D.C., Vol. 1, 509 – 514, 2001.
- [19] L. Zhao, J. C.G. Ca'ceres, A. P.G. Damiance, H. Szu, "Chaotic dynamics for multi-value content addressable memory", *Neurocomputing* 69, 1628–1636, 2006.
- [20] E. Del-Moral-Hernandez, "Neural networks with chaotic recursive nodes: techniques for the design of associative memories, contrast with Hopfield architectures, and extensions for time-dependent inputs", *Neural Networks* 16, 675–682, 2003.
- [21] E. Del-Moral-Hernandez, "Non-homogenous neural networks with chaotic recursive nodes: Connectivity and multi-assemblies structures in recursive processing elements architectures", *Neural Networks* 18, 532–540, 2005.
- [22] E. Del-Moral-Hernandez, "Chaotic Searches and Stable Spatio-temporal Patterns as a Naturally Emergent Mixture in Networks of Spiking Neural Oscillators with Rich Dynamics", *IEEE International Joint Conference on Neural Networks, Vancouver, BC, Canada*, 4506 – 4513, 2006.
- [23] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks", *SCIENCE*, Vol. 313, 28 July 2006.
- [24] G. Dreyfus, *Neural Networks Methodology and Applications*, Springer-Verlag Berlin Heidelberg Printed in Germany, 2005.
- [25] Sergios Theodoridis, Konstantinos Koutroumbas, *pattern recognition*, 4th [5] J. Storck, F. Jäkel, and G. Deco, "Temporal Clustering with Spiking Neurons and Dynamic Synapses: Towards Technological Application", *Neural Networks*, Vol. 14, pp. 275-285, 2001.
- [6] J. Storck, F. Jäkel, and G. Deco, "Learning Spatiotemporal Stimuli with Networks of Spiking Neurons and Dynamic Synapses", *Neurocomputing*, Vol. 38-40, pp. 935-943, 2001.
- [7] T. Natschläger, W. Maass, and A. Zador, "Efficient Temporal Processing with Biologically Realistic Dynamic Synapses", *Network: Computation in Neural Systems*, Vol. 12, pp. 75-87, 2001.
- [8] S. George, A. Dibazar, V. Desai, and T. W. Berger, "Speaker Recognition Using Dynamic Synapse Based Neural Networks with Wavelet Preprocessing", *Proc. IEEE International Joint Conference on Neural Networks (IJCNN)*, Vol. 2, pp. 1122-1125, 2001.
- [9] S. George, A. Dibazar, V. Desai, and T. W. Berger, "Using Dynamic Synapse Based Neural Networks with Wavelet Preprocessing for Speech Applications", *Proc. IEEE International Joint Conference on Neural Networks (IJCNN)*, Vol. 1, pp. 666-669, 2003.
- [10] W. Senn, H. Markram, and M. Tsodyks, "An Algorithm for Modifying Neurotransmitter Release Probability Based on Pre- and Postsynaptic Spike Timing", *Neural Computation*, Vol. 13, pp. 35-67, 2000.
- [11] H. H. Narnarvar, and T. W. Berger, "Trust Region Nonlinear Optimization Learning Method for Dynamic Synapse Neural Networks", *Proc. IEEE International Joint Conference on Neural Networks (IJCNN)*, Vol. 4, pp. 2848-2853, 2003.
- [ ] سهراب صائب طاهری، آیدین فرجی و سید علی سیدصالحی، مقایسه روش‌های مبتنی بر گرادیان به منظور تعلیم شبکه عصبی مصنوعی با سیناپس پویا، سیزدهمین کنفرانس مهندسی پزشکی ایران، تهران، ایران، ۱۳۸۵.
- [13] WALTER J. FREEMAN, "Strange Attractors that Govern Mammalian Brain Dynamics Shown by Trajectories of Electroencephalographic (EEG) Potential", *IEEE Transactions on Circuits and Systems*, Vol. 35, No. 7, July, 1988.

edition, Academic Press is an imprint of Elsevier, Printed in the United States of America, 2009.

[26] R. C. Hilborn, Chaos and nonlinear dynamics An introduction for scientists and engineers, Oxford University press, Second edition, 2000.

[27] USPS handwritten digit data : esampled.zip was gathered at the Center of Excellence in Document Analysis and Recognition (CEDAR) at SUNY Buffalo, as part of a project sponsored by the US Postal Service. <http://www.gaussianprocess.org/gpml/data/>

زیر نویس ها

- 
- 1- Dynamic Synapse Neural Networks
  - 2- Squid
  - 3- Decision Boundry