

بهبود بازشناسی مقاوم الگو در شبکه‌های عصبی بازگشتی جاذب از طریق به کارگیری دینامیک‌های آشوب‌گونه

معصومه آذرپور و سیدعلی سیدصالحی

آزمایشگاه پردازش گفتار، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، تهران، ایران

چکیده

در این مقاله، به منظور ارزیابی تأثیر دینامیک‌های آشوب‌گونه در افزایش کارایی شبکه‌های عصبی بازگشتی در بازشناسی مقاوم الگو، دو مدل برای شبکه‌های عصبی آشوب‌گونه ارائه شده است. در مدل اول که براساس نظریه انتخاب طبیعی طراحی شده است، شبکه عصبی بازگشتی جاذب (ARNN) به عنوان هوش حاکم، تنوعات ایجاد شده توسط گره‌های آشوبی را در جهت رسیدن به جواب بهینه هدایت می‌کند. در مدل دوم، ساختاری از شبکه عصبی آشوب‌گونه طراحی شده است که در لایه پنهان خود نورون‌هایی با تابع فعالیت آشوب‌گونه دارد. رفتار این نورون‌ها توسط پارامتر آنها تنظیم می‌شود. بهبود درصد صحبت عمکرد مدل اول در بازشناسی الگوی نوفاء در سطوح نوفه بالا (بیش از ۶۰٪) به ترتیب ۳۷/۱۶٪، ۲۹/۱۵٪ و ۸/۵٪ نسبت به شبکه جلوسو، شبکه عصبی آشوب‌گونه برمبنای گره اشوبی – NDRAM و شبکه ARNN است. همچنین مدل دوم، درصد صحبت بازشناسی شبکه ARNN و مدل اول را در حالت رفتار جاذب (بیش از ۶۰٪) به ترتیب ۱۳/۹۱٪ و ۴/۵٪ ارتقا داده است. از سوی دیگر، نتایج نشان می‌دهد که این مدل، حتی در حالت رفتار جاذب نقطه‌ای که مشابه رفتار شبکه ARNN است، درصد صحبت بازشناسی را ۱۰/۴۱٪ نسبت به این شبکه بهبود داده است.

واژگان کلیدی: شبکه عصبی بازگشتی جاذب (ARNN)، دینامیک‌های آشوب‌گونه، نورون آشوب‌گونه، جاذب نقطه‌ای، بازشناسی مقاوم الگو.

۱- مقدمه

آشوب‌گونه بوده و با اعمال تحریک بويایي، دستگاه به سرعت رفتار خود را اصلاح کرده و دینامیک‌ها، منظم و نزدیک به دوره‌ای می‌شوند (Freeman, 1988). به عبارت دیگر، قبل از آمدن ورودی، حافظه در قسمت بزرگی از فضای حالت با یک دینامیک پویا و آشوب‌گون در حرکت است. به محض اعمال یک ورودی، این فضا کوچک و کوچکتر می‌شود تا به تطور تقریبی به یک رفتار دوره‌ای که همان جواب مورد نظر است، محدود شود (Skarda & Freeman, 1987). خواص آشوب‌گونه باعث می‌شود که در مغز همیشه یک حالت آماده و پویا وجود داشته باشد به طوری که لازم نیست برای هر ورودی، مغز بیدار شود و سپس به یک نقطه تعادل خاموش برگردد. بر این اساس، مغز مدام بین گروهی از رفتارها در فضای حالت در رفت و آمد است.

امروزه آشوب^۱ از جمله جدیدترین زمینه‌هایی است که دریچه جدیدی را برای مطالعه جهان می‌گشاید و ایده‌های خوبی را در حل بسیاری از مسائل حل نشده ارائه می‌کند. از سوی دیگر، توجیه بسیاری از پدیده‌های طبیعی جز از منظر آشوب امکان‌پذیر نیست. در مطالعات زیستی نیز، وجود رفتار آشوب‌گونه در مغز چه در سطح میکروسکوپیک و تعاملات بین نورون‌ها، و چه در سطح ماکروسکوپیک و تعاملات میان (Korn & Faure, 2003; Sarbadhikari & Chakrabarty, 2001).

به عنوان مثال، مطالعات فریمن^۲ روی حس بويایی نشان می‌دهد که دینامیک‌های دستگاه عصبی در حالت پایه

¹ Chaos

² Freeman

حافظه طراحی شده‌اند (Nakagawa, 1999; Uwate et al., 2004). این شبکه‌ها به دلیل استفاده از شبکه‌های عصبی بر پایه هاپفیلد و پیروی از الگوریتم تعلیم هب⁶، مشکلاتی از جمله ظرفیت ذخیره‌سازی پایین، رشد نامحدود وزن‌ها و عدم توانایی یادگیری الگوهای هم‌بسته دارند (Kanter & Sompolinsky, 1987) . اگرچه برخی از این مشکلات تا حدی با ارائه الگوریتم‌های یادگیری جدید (Chartier & Proulx, 2005) حل شده است، ولی کماکان، این گونه شبکه‌ها ظرفیت ذخیره‌سازی پایینی دارند.

غالب مدل‌هایی که برای شبکه‌های عصبی آشوب‌گونه ارائه شده‌اند (Chartier & Boukadoum, 2006; Chartier & Proulx, 2005; He et al., 2007)، به صورت بازگشتی و دوسویه عمل کرده و جاذب تشکیل می‌دهند. البته برای عملکرد صحیح شبکه در بازنمایی الگوها، می‌بایست جاذب‌های تشکیل شده در فضای حالت محدود شوند که به طور معمول دو دیدگاه محدود کردن جاذب‌ها وجود دارد: ۱- تغییر پارامترهایی از سامانه که منجر به تغییر رفتار می‌شوند (تا赫رخانی، ۱۳۸۶)؛ ۲- استفاده از اتصالات مهاری و بازخورد (Ohta, 2002).

به عنوان کلی غالباً دو رویکرد رایج در طراحی شبکه‌های عصبی آشوب‌گونه به شرح زیر مطرح هستند:

۱) طراحی شبکه‌های عصبی آشوب‌گونه بر مبنای نظریه انتخاب طبیعی⁷؛ این نوع شبکه‌ها شامل گره‌های آشوبی و هوش مصنوعی‌اند که از گره‌های آشوبی جهت تولید تنوعات و از شبکه‌های عصبی به عنوان هوش حاکم برای کنترل این تنوعات استفاده می‌شود (تا赫رخانی، ۱۳۸۶)؛

۲) طراحی شبکه‌های عصبی آشوب‌گونه با استفاده از نورون‌های آشوب‌گونه؛ در این نوع شبکه‌ها از نورون‌هایی استفاده می‌شود که رفتارهای آشوب‌گون در برخی از نواحی فعالیتشان دارند. با تغییر پارامترهای دوشاخه‌شدنگی⁸ این نورون‌ها که غالباً از مطالعات زیستی الهام گرفته شده‌اند، رفتارهای نورون و درنتیجه رفتار شبکه تغییر می‌کند (He et al., 2001 ; Kim et al., 2008 ; Taha et al., 2008) غالباً این نورون‌ها با وجود تفاوت‌های ظاهری خود (تفاوت در توابع فعالیت، پارامترها و ...)، در چندین وجه، مشترکند. به طور

از سویی دیگر، توانایی بالای مغز در پردازش مقاوم داده در برابر تعییرات و تنوعات باعث شده است که نحوه عملکرد آن مورد توجه قرار گیرد. شبکه‌های عصبی مصنوعی از جمله پرکاربردترین ابزارهای پردازشی هستند که با الهام از عملکرد مغز، جهت پردازش داده در بسیاری از زمینه‌ها به کار گرفته شده‌اند. تاکنون مدل‌های بسیاری برای شبکه‌های عصبی مصنوعی ارائه شده‌اند (Carpenter, 1989 ; Kohonen, 1997) در غالب این مدل‌ها، حالت نهایی شبکه عصبی مصنوعی در تشخیص و طبقه‌بندی الگوها، قطعه‌بندی تصویر و ...، توقف در یک نقطه است که شبکه آن را به عنوان جواب در نظر می‌گیرد. این در حالی است که مغز انسان پویایی و تنوع داشته و هیچ‌گاه در یک نقطه متوقف نمی‌شود و دائم در حال حرکت و جنبش است؛ به طوری که توقف در یک نقطه به منزله مرگ است.

با توجه به وجود رفتارهای آشوب‌گونه در سطح مغز، یکی از رویکردهای مطرح شده جهت افزایش توان پردازشی شبکه‌های عصبی کلاسیک، وارد کردن دینامیک‌های آشوب‌گونه^۹ در عملکرد آنهاست. دینامیک آشوب‌گونه می‌تواند ابزار بسیار قوی در ذخیره، بازیابی، بازشناسی و ایجاد اطلاعات در این نوع شبکه‌های عصبی باشد (Andras & Lycett, 2007).

مسیر یک سامانه آشوب‌گونه در فضای حالت می‌تواند در زمان بسیار طولانی در یک ناحیه مشخص (جاذب آشوب‌گونه^{۱۰} خود) سیر کند، بدون اینکه از نقطه‌ای دوبار عبور نماید. از طرف دیگر با انتخاب مناسب پارامترهای سامانه آشوب‌گونه می‌توان اندازه این ناحیه (بستر جذب) را به دلخواه تغییر داد؛ بنابراین با یک سامانه آشوب‌گونه می‌توان یک ناحیه دلخواه را با دقت بالایی مورد جستجو قرار داد. لذا یکی از رویکردهایی که در جهت وارد کردن آشوب در شبکه‌های عصبی کلاسیک مطرح شده است، استفاده از قدرت جستجوگری آشوب و توان پردازشی شبکه‌های عصبی است (Khoa & Nakagawa, 2007 ; Chartier & Boukadoum, 2006).

با توجه به وجود رفتارهای آشوب‌گونه در سامانه‌های بیولوژیکی، تاکنون شبکه‌های عصبی آشوب‌گونه^{۱۱} بسیاری ارائه شده‌اند. غالباً این شبکه‌های عصبی آشوب‌گونه بر پایه شبکه‌های خودانجمنی^{۱۲} و دیگرانجمنی^{۱۳} در جهت مدل‌سازی

¹ Chaotic Dynamics

² Chaotic Attractor

³ Chaotic Neural Network (CNN)

⁴ Autoassociation

⁵ Hetro-Association

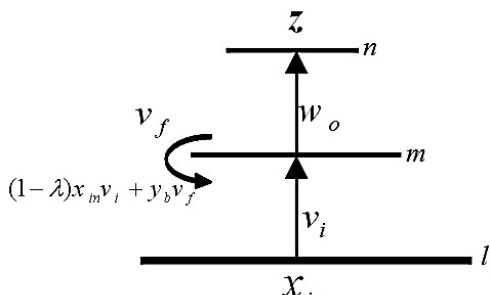
⁶ Hebbian

⁷ Natural Selection Theory

⁸ Bifurcation



جادب (ARNN)^۲ به عنوان شبکه پایه مورد استفاده در این تحقیق، ارائه می‌شود. بخش سوم این مقاله به معرفی دادگان تصویری که در این مقاله مورد بررسی قرار گرفتند، اختصاص دارد. شبکه عصبی آشوب‌گونه بر مبنای شبکه عصبی بازگشتی جاذب و گرهای آشوبی (CARNN)، که بر اساس آشوب‌گونه ایجاد و گرهای آشوبی است، در بخش چهارم ارائه می‌شود. رویکرد اول طراحی شده است در بخش چهارم ارائه می‌شود. بخش پنجم نیز به معرفی ساختاری از شبکه عصبی آشوب‌گونه اختصاص دارد که بر اساس رویکرد دوم مطرح شده در این بررسی و با استفاده از نورون‌های آشوب‌گونه طراحی شده است. در بخش ششم نیز عملکرد شبکه‌های عصبی آشوب‌گونه در بازناسنی مقاوم الگو نسبت به نوافه ارزیابی شده و با عملکرد شبکه ARNN و دیگر شبکه‌های عصبی آشوب‌گونه مقایسه می‌شود در بخش هفتم نیز، مباحث مطرح شده جمع‌بندی و نتیجه‌گیری خواهد شد.



(شکل ۱)- ساختار شبکه عصبی بازگشتی پیشنهاد شده
توسط خانم دهیادگاری

تقریبی همه آنها یک یا چندین پارامتر دارند که تغییرات آنها باعث تغییر دینامیک نورون و شبکه می‌شود؛ و در همه این مدل‌ها به نوعی رابطه بازگشتی وجود دارد. طراحی این گونه مدل‌ها بر پایه ایجاد رفتار آشوب‌گونه است. البته به علت روابط ریاضی بازگشتی پیچیده این نورون‌ها، در برخی از تحقیقات، توابعی را به عنوانتابع فعالیت برای نورون‌ها درنظر می‌گیرند که در حالت تکراری، رفتار آشوب‌گون ایجاد می‌کنند (اطاهرخانی، ۱۳۸۶؛ Aydiner et al., 2004؛ et al., 2003). از جمله این توابع، تابع لاجستیک^۱ را می‌توان نام برد.

از سوی دیگر، نظریه انتخاب طبیعی، از جمله نظریه‌هایی است که تاکنون در توجیه رفتارهای بیولوژیکی موجودات زنده مطرح شده است. طبق نظریه انتخاب طبیعی اگر یک سامانه طبیعی تحت تأثیر یک محیط، که یک فشار گزینشی روی آن اعمال می‌کند، قرارگیرد دستخوش تنوع شده و فقط آن آرایش‌هایی از سامانه باقی می‌ماند (یا رشد می‌کند) که در خور و مناسب محیط باشند یا با محیط سازگار شوند. سامانه در حالت تکامل را می‌توان به "حل کننده مسأله" تشبیه کرد که با تولید تنوعات برای مسائلهای که توسط محیط مطرح شده، راه حل‌های ممکن را ارائه می‌دهد. سامانه طبیعی این تنوعات را بر اساس یک هوش اولیه و ساده برای رسیدن به حل مسأله هدایت می‌کند (Heylighen, 1989).

در این مقاله، دو شبکه عصبی آشوب‌گونه جدید با دو رویکرد متفاوت پیشنهاد می‌شود. طراحی شبکه اول با توجه به تحقیقاتی که تاکنون در راستای تلفیق آشوب با شبکه‌های عصبی کلاسیک صورت پذیرفته و شبکه دوم بر مبنای تئوری انتخاب طبیعی طراحی شده است.

شبکه‌های ارائه شده در این مقاله از چندین منظر نسبت به دیگر شبکه‌های عصبی آشوب‌گونه برتری دارند:

- ۱) عملکرد بهتری در بازناسنی مقاوم الگوی نوافه‌ای دارد.
- ۲) به سبب ساختار شبکه، ظرفیت ذخیره‌سازی بیشتر داشته و متعاقباً توان پردازش بالاتری دارد (۳ مدل دوم، برخلاف بسیاری از شبکه‌های عصبی آشوب‌گونه، ساختار منسجمی و واحدی دارد که قادر به تولید انواع رفتارهای آشوب‌گونه، دوره‌ای و غیره است.

در بخش بعدی این مقاله، شبکه عصبی بازگشتی

۲- شبکه عصبی بازگشتی جاذب

در این بررسی از شبکه عصبی بازگشتی جاذب (ARNN) پیشنهاد شده توسط خانم دهیادگاری، به عنوان شبکه عصبی پایه استفاده شده است (دهیادگاری، ۱۳۸۴). این شبکه بازگشتی به عنوان مدل کارآمد برای ساختار شبکه عصبی بازگشتی ارائه شده است. همچنین این شبکه که پیش‌تر برای بازناسنی گفتار نوافه‌ای به کار گرفته شده است، به عنوان یک شبکه مناسب برای هدف مقاوم‌سازی بازناسنی با استفاده از خاصیت جاذب‌ها معرفی شده است. طراحی این شبکه بازگشتی به گونه‌ای است که شبکه می‌تواند در هنگام تعلیم، نحوه حرکت به سمت جاذب‌ها را نیز فراگیرد. به این ترتیب که برای هر ورودی در هنگام تعلیم، شبکه آن‌قدر دور می‌زند تا به بهترین خطای ممکن دست پیدا کند. با این نحوه

² Attractor Recurrent Neural Network

سال ۱۳۹۲ شماره ۲ پیاپی

^۱ Logistic

الگوها را طبقه‌بندی می‌کند (شکل (۲)).

۲-۲ - تعلیم شبکه ARNN

در تعلیم این شبکه بازگشتی، به نحوی از الگوریتم پس‌انتشار خطا استفاده می‌شود؛ به این صورت که خطای مربوط به خروجی به دست آمده از شبکه و خروجی مطلوب و نیز خطای بین ورودی لایه پنهان و درصدی از ورودی مطلوب در شبکه پس‌انتشار شده و وزن‌ها به‌هنگام می‌شوند. در این شبکه در هنگام تعلیم در شبکه چرخش (تکرار) خواهیم داشت. درواقع، علاوه بر این که برای هر الگو جاذبی در شبکه ساخته می‌شود، چگونگی حرکت به سمت جاذب نیز به شبکه تعلیم داده می‌شود. در این حالت شبکه یاد می‌گیرد که چگونه از روی هر نمونه نوشهای در طی چندبار دور زدن در شبکه، نمونه تمیز را بازسازی کند. ساختار بازشده شبکه برای نشان‌دادن نحوه پس‌انتشار خطاها در شکل (۳) آمده است. در تعلیم این شبکه عصبی بازگشتی دوتابع خطای طبق روابط (۶) و (۷) تعریف می‌شود:

$$E_1 = \sum_{i=1}^n (d_i - z_i)^2 \quad (6)$$

که n تعداد نرون‌ها در لایه خروجی، z_i و d_i به ترتیب خروجی شبکه و خروجی مطلوب در نامین نuron است.

$$E_2 = \sum_{i=1}^m (x_{in}v_i - y_n)^2 \quad (7)$$

در این رابطه m تعداد نرون‌ها در لایه پنهان، x_{in} ورودی شبکه عصبی، v_i وزن‌های لایه اول و y_n طبق رابطه زیر تعریف می‌شود:

$$y_n = (1 - \lambda)x_{in}v_i + \gamma v_f \quad (8)$$

وزن‌های شبکه در جهت رسیدن به ورودی مطلوب و همچنین خروجی مطلوب به‌هنگام می‌شوند. نحوه محاسبه گرادیان خطاهای در روابط (۹) تا (۱۱) آمده است.

$$\delta z_k = (1 - z^2_k) \left[\sum_{i=1}^n (d_i - z_{ik}) \right] \quad (9)$$

$$\delta y_{n_k} = 0.1 \times \left[\sum_{i=1}^m x_{ik}v_i - y_n \right] \quad (10)$$

$$\delta y_k = (1 - y^2_k) \left(\sum_{i=1}^n \delta z_i w_{o_{ik}} - \delta y_{n_k} v_{f_k} \right) \quad (11)$$

تعلیم در واقع شبکه ورودی را از روی همان ورودی در لحظه قبل اصلاح می‌کند و این اصلاح را آنقدر ادامه می‌دهد تا به یک حالت بهینه یا به عبارتی به جاذب آن ورودی برسود. بنابراین هنگامی که ورودی نوشهای به شبکه داده می‌شود، شبکه با چند بار دور زدن، ورودی را که در اثر نوشه از جاذب خود خارج شده است، به سمت آن هدایت می‌کند (دهیادگاری، ۱۳۸۴).

۲-۱-۲ - ساختار شبکه ARNN

ساختار این شبکه عصبی بازگشتی در شکل (۱) نشان داده شده است. خروجی این شبکه عصبی بازگشتی طبق روابط زیر محاسبه می‌شود:

$$z = f(yw_o) \quad (1)$$

که w_o وزن شبکه از لایه پنهان به لایه خروجی و y طبق رابطه زیر محاسبه می‌شود:

$$y(t+1) = f[(1 - \lambda)x_{in}v_i + y_b(t)v_f] \quad (2)$$

که در اینجا λ ضریب اعمال ورودی شبکه، v_f وزن اتصال بازگشتی در لایه پنهان و $y_b(t)$ طبق روابط (۳) و (۴) به دست می‌آید.

$$y_b(t) = f(x_{in}v_i) \quad (3)$$

$$y_b(t+1) = y(t+1) \quad (4)$$

که x_{in} ورودی شبکه و v_i وزن‌های شبکه از ورودی به لایه پنهان است. این جایگزینی روابط (۳) و (۴) آنقدر ادامه می‌یابد تا اینکه y به مقدار ماندگار خود برسد. در این برسی تمام توابع فعالیت نورون‌ها به صورت تائزانت سیگموید طبق رابطه (۵) در نظر گرفته شده‌اند:

$$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}} = \tanh\left(\frac{x}{2}\right) \quad (5)$$

این شبکه را می‌توان به عنوان یک شبکه عصبی با یادگیری چندوظیفه‌ای^۱ دانست. به بیانی دیگر، این شبکه می‌تواند ترکیبی از دو شبکه باشد؛ یک شبکه به صورت نگاشت^۲ خودانجمنی تکراری الگوها را به سمت جاذب‌ها پیش می‌برد و شبکه دیگر از طریق به طبقات خروجی،

¹ Multi task learning
² Mapping



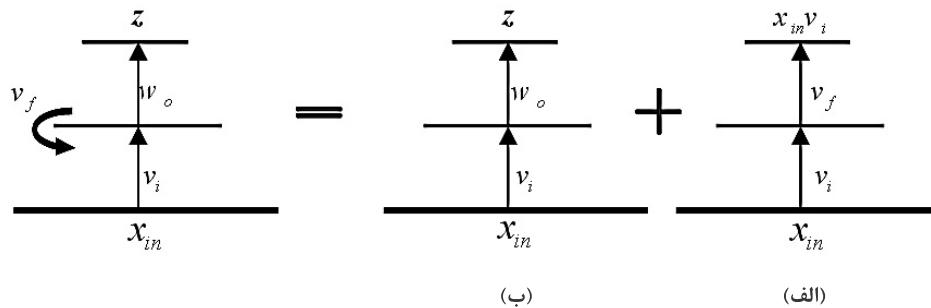
که $\Delta v_{f_j}(t)$ ، $\Delta v_{i_j}(t)$ و $\Delta w_{o_j}(t)$ به ترتیب مقداری است که به مقدار وزن‌های w_{o_j} ، v_{i_j} و v_{f_j} در دوره اجرای t اضافه می‌شود. η ضریب یادگیری و α ضریب ممتنوم است.

که δy_{nk} ، δz_k و δy_{nk} به ترتیب سیگنال خطای مربوط به لایه خروجی، اتصال بازگشتی و لایه پنهان است. و درنهایت وزن‌های شبکه طبق روابط زیر اصلاح می‌شوند.

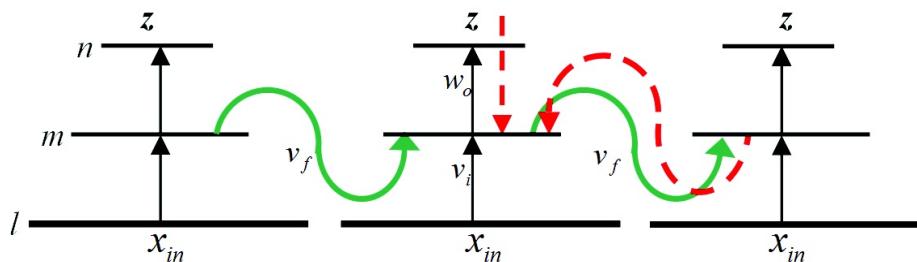
$$\Delta w_{o_j}(t) = \eta \cdot y_i \cdot \delta z_j + \alpha \Delta w_{o_j}(t-1) \quad (12)$$

$$\Delta v_{i_j}(t) = \eta \cdot x_i \cdot \delta y_j + \alpha \Delta v_{i_j}(t-1) \quad (13)$$

$$\Delta v_{f_j}(t) = \eta \cdot y_i \cdot \delta y_{n_j} + \alpha \Delta v_{f_j}(t-1) \quad (14)$$



(شکل ۲)- ساختار بازشده شبکه عصبی با اتصال بازگشتی در لایه پنهان. الف) شبکه خود انجمنی ب) شبکه طبقه‌بندی



(شکل ۳)- مسیر محاسبات برای یک ورودی در طی سه دوره تعلیم متوالی (خطوط منقطع مسیرهای پس انتشار خطرا نشان می‌دهد).

$$y(t+1) = f((1-\lambda)x_{in}v_i + y_b(t)v_f) \quad (16)$$

$$y_b(t+1) = y(t+1) \quad (17)$$

پس از ۱۰ گام، تغییرات خروجی لایه پنهان کاهش یافته و آنگاه خروجی شبکه طبق رابطه زیر محاسبه می‌شود:

$$z = f(y(t_0)w_o) \quad (18)$$

۳-۲- آزمایش شبکه ARNN

در مرحله آزمایش این شبکه، در حین فراخوانی الگوها نیز در شبکه چرخش خواهیم داشت. بدین صورت که با دورزندن در اتصال بازگشتی لایه پنهان، الگوی ورودی به سمت جاذب یکی از الگوهای ذخیره شده هدایت می‌شود و بدین ترتیب تغییرات ناخواسته در الگوی ورودی حذف می‌شود.

خروجی لایه پنهان در گام اول از رابطه (۱۵) محاسبه می‌شود.

$$y_b(0) = f(x_{in}v_i) \quad (15)$$

خروجی لایه پنهان در گام‌های بعدی طبق روابط (۱۶) و (۱۷) محاسبه می‌شود.

کنترل این تنوعات پیشنهاد شده است. شبکه ARNN به دلیل ساختار بازگشتی و روابط غیر خطی حاکم بر آن، به عنوان هوش حاکم استفاده شده که با ماهیت بازگشتی گره‌های آشوبی تولیدکننده تنوعات، همخوانی بسیار مناسبی دارد.

در ادامه نشان داده می‌شود که این شبکه عصبی آشوب‌گونه نسبت به شبکه‌های عصبی آشوب‌گونه مبتنی بر شبکه‌های پلید ظرفیت ذخیره‌سازی بیشتری دارد. در این شبکه، الگوهای تعليمی به عنوان جاذب‌های شبکه شکل گرفته و در مرحله بازشناسی، گره‌های آشوبی لایه پنهان شبکه شروع به جستجو می‌کنند. به عبارت دیگر، روند بازیابی ARNN بدین‌گونه است که خروجی نورون‌های لایه پنهان به عنوان شرط اولیه به گره‌های آشوبی اعمال می‌شود، و بدین ترتیب مقادیر خروجی این گره‌ها به صورت آشوب‌گونه شروع به تغییرات می‌کنند. در هر تکرار گره آشوبی، تابع عدم موافق^۲ هر گره نسبت به کل گره‌ها با استفاده از دانشی که از تعليم دادگان به دست آمده است، محاسبه می‌شود. اگر این میزان عدم موافقت از یک حد آستانه کمتر باشد، تغییرات آشوب‌گونه آن گره متوقف می‌شود. این عمل آن‌قدر ادامه می‌یابد تا مقدار همه یا اکثر گره‌ها ثابت شود، در این صورت خروجی گره‌های آشوبی به نورون‌های لایه پنهان شبکه عصبی داده شده و خروجی شبکه که برچسب‌های تصاویر ورودی است، محاسبه می‌شود. در این بخش پس از معرفی گره‌های آشوبی، به توضیح شبکه عصبی آشوب‌گونه و اصول مطرح شده در این شبکه خواهیم پرداخت.

۱-۴ گره‌های آشوبی

تاكون مدل‌های زیادی برای نورون و گره آشوب‌گونه رائه شده است (Szu et al., 1993; Pasemann, 1997; Del Moral Hernandez, 2005). غالب این مدل‌ها با وجود تفاوت‌های ظاهری خود، در چندین وجه مشترک هستند. به طور تقریبی همه آنها دارای یک یا چندین پارامتر هستند که تغییرات آن باعث تغییرات دینامیک آنها می‌شود. همچنین در همه این مدل‌ها نوعی رابطه بازگشتی وجود دارد. طراحی این گونه مدل‌ها بر پایه ایجاد رفتار آشوب‌گونه است. البته در بسیاری از بررسی‌ها نیز از مدل‌های کلاسیک که رفتار نورون را براساس معادلات تفاضلی و دیفرانسیل بیان می‌کنند، استفاده نشده است؛ بلکه برای هر گره تابعی

² Disagreement function

شکل (۲۱)، برای تعليم به شبکه ARNN و شبکه عصبی آشوب‌گونه پیشنهاد شده، به کار گرفته شده است. دادگان آزمون نیز نوشهای شده الگوهای تمیز است. برای ایجاد نوشه با n درصد، نسبت به دامنه تغییرات نوشه به سیگنال، یک بردار تصادفی در بازه $[-\frac{n}{100}, +\frac{n}{100}]$ به الگوی اصلی اضافه شده است شکل (۴).



شکل (۴)- تصاویر دستنوشتار موجود در پایگاه دادگان USPS



شکل (۵)- اولين الگوي تعليم داده شده به شبکه‌های عصبی و نمونه‌های نوشهای آن به‌ازای درصدی مختلف نوشه

۴- شبکه عصبی آشوب‌گونه مبتنی بر شبکه عصبی بازگشتی جاذب و گره‌های آشوبی (CARNN)^۱

با توجه به تحقیقاتی که تاکنون در راستای تلفیق آشوب با شبکه‌های عصبی کلاسیک صورت پذیرفته و با توجه به تئوری انتخاب طبیعی، در این بخش شبکه عصبی آشوب‌گونه جدیدی پیشنهاد داده می‌شود. این شبکه عصبی آشوب‌گونه بر اساس نظریه انتخاب طبیعی و با استفاده از شبکه ARNN که به نوعی حافظه‌دار است، طراحی شده است. طبق نظریه انتخاب طبیعی اگر یک سامانه بیولوژیکی تحت شرایطی تغییر یابد، تنها ترکیباتی باقی می‌مانند که با این تغییرات سازگارتر باشند. به عبارت دیگر حل یک مسئله را می‌توان به یک سامانه در حال تکامل تشییه کرد که این سامانه طبیعی، تنوعات تولید شده توسط محیط را بر اساس یک هوش اولیه و ساده برای رسیدن به حل مسئله هدایت می‌کند (Heylighen, 1989).

در این بررسی، گره‌های آشوبی با تابع فعالیت شبکه لاجستیک برای ایجاد تنوعات و شبکه ARNN جهت

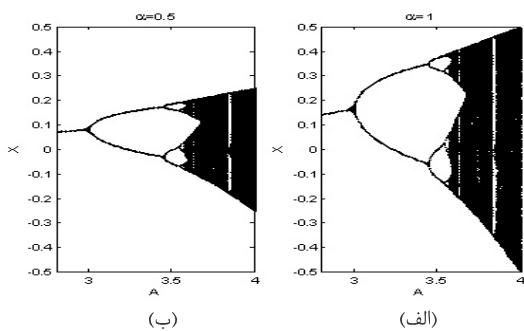
¹ Chaotic Attractor Recurrent Neural Network

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

t و α_i پارامتر تنظیم است. رفتار تابع شبه لاجستیک و محدوده تغییرات این تابع به ترتیب توسط پارامترهای A_i و α_i قابل تنظیم است. با تغییر مقدار A_i ، که می‌تواند دو مقدار داشته باشد: A_p و A_c ، رفتار گره‌های آشوبی از آشوب‌گونه به دوره‌ای (با دوره‌های مختلف) و به عکس قابل تنظیم خواهد بود. اگر $A_c = A_i = A_p$ باشد، دینامیک گره به صورت آشوبی و اگر $A_i = A_p$ باشد، دینامیک آن به صورت دوره‌ای با دوره مورد نظر است.

نمودار دوشاخه‌گی مربوط به رابطه بیست بهمازای دو مقدار α_i در شکل (۷) نشان داده شده است. دامنه تغییرات خروجی تابع شبه لاجستیک (معادله بیست) با تغییر α_i ، تغییر می‌نماید.

از این پارامتر برای تنظیم عملکرد گره‌های آشوبی در شبکه عصبی آشوب‌گونه و تنظیم نواحی جستجوی این گره‌ها استفاده شده است. همان‌طور که در (ظاهرخانی، ۱۳۸۶) نشان داده شده است، این رابطه به واسطه پارامتر α_i اعطاف‌پذیری بالایی برای ایجاد سازگاری بین خروجی‌های شبکه و گره‌های آشوبی، دارد. نکات مهمی که در طراحی این گره‌های آشوبی مطرح می‌شود، این است که این گره‌ها، جستجوی خود را از کجا شروع کنند، تا چه محدوده‌ای را مورد جستجو قرار دهند و در چه زمان این جستجو متوقف شود که در ادامه در مورد آنها بیشتر توضیح خواهیم داد.



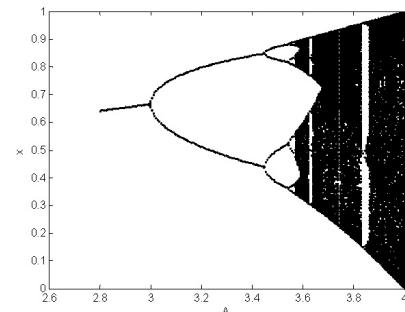
(شکل ۷)- نمودار دوشاخه‌گی مربوط به رابطه α_i (الف) $\alpha_i = 1/5$ (ب) $\alpha_i = 0.5$

درنظر گرفته شده که قادر به تولید رفتار آشوب‌گونه است (ظاهرخانی، ۱۳۸۶؛ Zhao et al., 2006). در این بررسی با توجه به مراجع (ظاهرخانی، ۱۳۸۶؛ Del Zhao et al., 2006; Moral Hernandez, 2005) از مدل معادله لاجستیک برای بازنمایی رفتار آشوب‌گونه استفاده شد.

$$x_{CHi}(t+1) = A_i x_{CHi}(t)(1 - x_{CHi}(t)) \quad (19)$$

که A_i پارامتر دوشاخه‌گی و $x_{CHi}(t)$ مقدار آمین گره در زمان t است.

در توضیح این پارامتر که از این پس به کرات با آن مواجه خواهیم شد، می‌توان گفت: در سامانه‌های دینامیکی، نقاط ثابت می‌توانند خلق یا نابود شده و یا پایداری آنها تغییر کند یعنی از نوع جاذب به دافع و یا بر عکس تبدیل شوند. شروع تغییرات در رفتار نقاط ثابت، دوشاخه‌شدنگی گفته می‌شود. گذار به حالت دوشاخه‌شدنگی با تغییر کمیتی به نام پارامتر دوشاخه‌شدنگی صورت می‌گیرد. در شکل (۶) نمودار دوشاخه‌گی تابع لاجستیک به ازای تغییر پارامتر A رسم شده است.

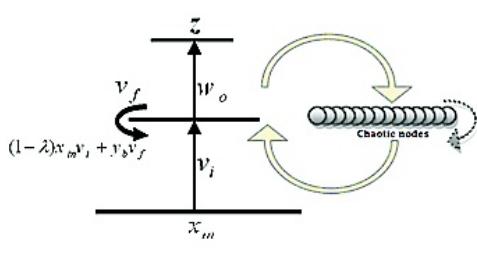


(شکل ۶)- نمودار دوشاخه‌گی تابع لاجستیک به ازای تغییر پارامتر A

از آنجایی که گره‌های آشوبی در تعامل با شبکه عصبی قرار داشته و می‌بایست بهمازای ورودی‌های مختلف شبکه عصبی رفتاری متفاوت داشته باشد، تابع شبه لاجستیک برای کنترل ناحیه و دامنه جستجو، به صورت زیر اصلاح و تعریف شده است:

$$x_{CHi}(t+1) = \alpha_i \left(A_i \left[\left(\frac{1}{\alpha_i} x_{CHi}(t) + 0.5 \right) \left(0.5 - \frac{1}{\alpha_i} x_{CHi}(t) \right) \right] - 0.5 \right) \quad (20)$$

که A_i پارامتر دوشاخه‌گی و $x_{CHi}(t)$ مقدار آمین گره در زمان



(شکل ۸)- ساختار شبکه عصبی آشوب‌گونه CARNN

آشوبی به $y_B(0)$ اضافه شده تا آن را اصلاح نمایند:

$$y_{Bi}(t) = y_{Bi}(0) + x_{Chi}(t) \quad (22)$$

که $y_{Bi}(t)$ خروجی گره α_i لایه پنهان در مرحله α است. در هر تکرار $y_{Bi}(t)$ مورد بررسی قرار می‌گیرد. برای تعیین میزان مطلوب‌بودن (t) y_{Bi} در انتشار اطلاعات به لایه بعدی شبکه عصبی آشوب‌گونه CARNN، رابطه‌ای برای محاسبه میزان عدم موافقت هر گره آشوبی با کل گره‌ها تعریف شده است. برای محاسبه این رابطه به دانشی که از دادگان تعلیم به دست آمده نیاز است.تابع عدم موافقت هر گره آشوبی با کل گره‌ها با رابطه زیر تعیین می‌شود:

$$d_i(t) = |y_{Bi}(t) - ((1-\lambda)x_{in}v_i + y_{Bi}(t))v_f| \quad (23)$$

در صورتی که $d_i < \delta$ باشد گره آشوبی به نقطه مناسبی رسیده و جستجوی خود را متوقف می‌کند؛ در غیر این صورت گره آشوبی مورد نظر در مرحله بعدی نیز به جستجوی خود ادامه می‌دهد. این کار آنقدر ادامه می‌پاید تا مقدار خروجی همه یا اکثر گره‌ها ثابت شود. در این حالت خروجی گره‌ها به عنوان خروجی اصلی ارائه می‌شود. سپس این مقادیر به لایه بعدی منتقل شده و خروجی شبکه محاسبه می‌شود. در این هنگام، d_i عملکرد صحیح شبکه را با جاذبهای لایه پنهان بررسی می‌کند.

نقطه شروع جستجو با توجه به بررسی‌های پیشین (طاهرخانی، ۱۳۸۶)، مقداری نزدیک به صفر و ضریبی از $x_{in}v_i$ در نظر گرفته می‌شود:

$$x_{Chi}(0) = 0.01\alpha_h \quad (24)$$

که $x_{Chi}(0)$ ورودی گره آشوبی و α_h مقدار اولیه برای a_i است که توسط، رابطه (۲۶) محاسبه می‌شود. تعیین مقدار آستانه δ بسیار مهم بوده و تأثیر بهسزایی در عملکرد شبکه عصبی آشوب‌گونه دارد. در این بررسی آزمایش‌های بسیاری برای تعیین این مقدار آستانه انجام شد؛ نتیجه این آزمایش‌ها نشان می‌دهد که انتخاب سطح آستانه متناسب برای هر گره، به جای درنظر گرفتن یک مقدار آستانه مشخص برای همه گره‌ها، عملکرد بهتری در روند جستجوی گره‌های آشوبی دارد.

به عبارت دیگر، هر گره با سطح آستانه مربوط به خود که از روند تعلیم به دست آورده است، به جستجو در فضای

۴-۲- شبکه عصبی آشوب‌گونه CARNN

ساختار شبکه عصبی آشوب‌گونه‌ای که در این بررسی CARNN براساس نظریه انتخاب طبیعی و با استفاده از شبکه ARNN و گره‌های آشوبی طراحی شده است، در شکل (۸) نشان داده شده است. شبکه عصبی آشوب‌گونه ارائه شده شامل شبکه ARNN و گره‌های آشوبی است. شبکه CARNN توسط دادگان تمیز، تعلیم داده می‌شود. در مرحله بازخوانی و تشخیص الگوهای نو فهای، خروجی نورون‌های لایه پنهان به گره‌های آشوبی داده می‌شود. هر یک از این گره‌های آشوبی در فضای الگوی ذخیره شده در لایه پنهان به جستجوی پردازد. همان‌طور که در توضیح شبکه ARNN دیدیم، لایه پنهان و اتصال بازگشتی آن همانند یک شبکه خودانجمنی عمل می‌کند که سعی دارد با تعلیم الگوی نو فهای به الگوی تمیز، عملکرد بازشناصی شبکه عصبی بازگشتی را بهبود بخشد. از این خاصیت شبکه عصبی بازگشتی در کنترل عملکرد جستجوی گره‌های آشوبی استفاده شده است. بدین صورت که گره‌های آشوبی در فضای این لایه به جستجوی الگویی می‌پردازند که کمترین فاصله را با الگوی ذخیره شده داشته باشد. همان‌طور که می‌دانیم، ناحیه این جستجو به طور مستقیم به مقدار نو فه اضافه شده به الگوی ورودی بستگی دارد. به عبارت دیگر، هرچه نو فه ناخواسته اضافه شده به الگو بیشتر باشد، فاصله آن با الگوی تمیز ذخیره شده بیشتر است و لذا گره‌های آشوبی می‌باشند ناخیه وسیع تری را مورد جستجو قرار دهند. مادامی که گره‌های آشوبی در نقطه مناسبی قرار نگرفته‌اند، جستجو ادامه می‌پاید. پس از رسیدن همه یا اکثر این گره‌ها به سطح آستانه معین، جستجو متوقف شده و خروجی گره‌های آشوبی در مسیر شبکه عصبی بازگشتی قرار می‌گیرند.

در ادامه به بیان کامل‌تری از عملکرد شبکه عصبی آشوب‌گونه CARNN پرداخته و روابط ریاضی حاکم بر آن را به تفصیل بیان خواهیم کرد. همان‌طور که پیش تر گفته شد، پس از تعلیم دادگان تعلیم به شبکه بازگشتی، در مرحله آزمون و یا بازخوانی داده‌ها، الگوی ورودی به شبکه داده و خروجی لایه پنهان در اوّلین دور محاسبه می‌شود:

$$y_B(0) = x_{in}v_i \quad (21)$$

در روند بازخوانی اطلاعات، گره‌های آشوبی شروع به اصلاح $y_B(0)$ می‌کنند، بدین صورت که به صورت آشوبی شروع به جستجو کرده و در هر تکرار خروجی گره‌های

فصل نهم

ش. علیرضا حسنه



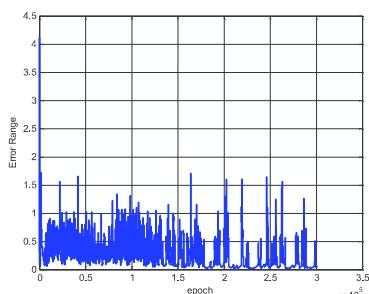
آشوبی، میزان خطا در لایه پنهان است، مطالعاتی در مورد خطا در این لایه انجام شد.
از آنجایی که اتصال بازگشتی در این لایه به مثابه شبکه خودانجمنی عمل می‌نماید، بدیهی است که این حد آستانه به میزان این خطای خود انجمنی بستگی خواهد داشت. ورودی این شبکه، $x_{in}v_i + (1-\lambda)x_{in}v_i + y_b v_f$ (۱۶) و خروجی مطلوب آن $x_{in}v_i$ است. البته این نکته قابل تأمل است که میزان اهمیت خطای پس انتشار شده از لایه پنهان و لایه خروجی در محاسبه خطای شبکه و اصلاح وزن‌ها یکسان نیست؛ ولی با کمی اغماض می‌توان از آن چشم‌پوشی کرد. لذا اختلاف این دو مقدار را می‌توان به عنوان تقریبی از خطای لایه پنهان در نظر گرفت.
با تعلیم شبکه عصبی بازگشتی جاذب، این خطا طبق رابطه (۲۹) در طول تعلیم محاسبه شده است.

$$E_l = x_{in}v_i - y_n \quad (29)$$

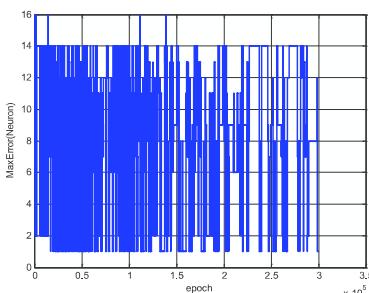
$$y_n = (1-\lambda)x_{in}v_i + y_b v_f \quad (30)$$

$$y_b = f(x_{in}v_i) \quad (31)$$

همان‌طور که انتظار می‌رفت و در شکل (۹) نشان داده شده است، محدوده خطا و بیشترین مقدار خطا در طول تعلیم کاهش می‌یابد. همچنین شکل (۱۰) نورون با بیشترین خطا را در حین تعلیم نشان می‌دهد.



شکل (۹)- محدوده تغییر خطا در لایه پنهان در طول تعلیم



شکل (۱۰)- شماره نورون با بیشترین خطا در لایه پنهان (۱۶ نورون)

حالت می‌پردازد. محدوده تغییرات نورون‌های لایه پنهان در روند تعلیم به خصوص گام‌های نهایی که تعلیم تا حدی کامل شده است، قابل محاسبه است و همین محدوده تغییرات می‌تواند معیار خوبی برای تعیین سطح آستانه هر گره در جستجو باشد. مقدار δ طبق رابطه ۲۵ محاسبه می‌شود.

$$\delta_i = k \cdot e_i(E_{max}) \quad (25)$$

که E_{max} بیشترین مقدار خطای نورون‌های لایه پنهان، e_i خطای هر یک از نورون‌های لایه پنهان در مرحله تعلیم دادگان و k ضریب ثابت است که مقدار آن برابر کمترین مقداری است که عملکرد گره‌های آشوبی در وضعیت مناسب قرار دارد. در بخش‌های آتی در مورد این ضریب ثابت و چگونگی تعیین آن بیشتر توضیح داده خواهد شد.

ناحیه جستجوی هر گره آشوبی نیز بسیار مهم بوده و مناسب با نوفة اضافه شده در الگوی ورودی است، به گونه‌ای که در درصد های بالای نوفة، که گستره تغییرات زیاد است، ناحیه جستجو نیز می‌بایست به نسبت وسیع تر انتخاب شود.
با توجه به بررسی‌های پیشین، شبکه بیشترین بازسازی خود را دوره‌های ابتدایی انجام می‌دهد؛ لذا ناحیه جستجوی آشوب‌گونه طبق رابطه زیر، از اختلاف ورودی لایه پنهان و خروجی آن محاسبه می‌شود.

$$\alpha_i = |x_{in}v_i - ((1-\lambda)x_{in}v_i + f(x_{in}v_i)v_f)| \quad (26)$$

در هر مرحله، خروجی حاصل از این گره‌های آشوبی با خروجی لایه پنهان $y_b(0) = f(x_{in}v_i)(0)$ جمع می‌شود. درنهایت پس از ثابت شدن اکثر گره‌های آشوبی خروجی طبق روابط زیر محاسبه می‌شود:

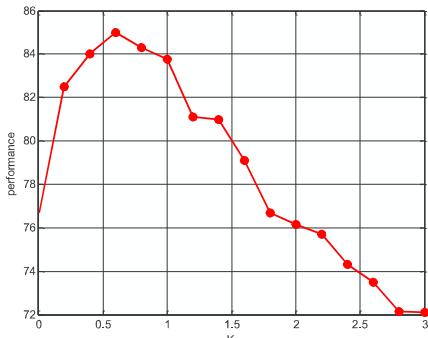
$$y_b(0) = f(y_B(t)) \quad (27)$$

$$y = f((1-\lambda)x_{in}v_i + y_b v_f) \quad (28)$$

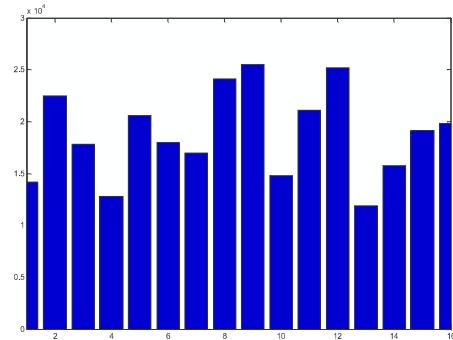
که f ،تابع تائزه‌انت سیگموید در نظر گرفته شده است.

۱-۲-۴- تعیین آستانه خطا در لایه پنهان شبکه CARNN عصبی آشوب‌گونه

همان‌طور که پیش‌تر گفته شد، برای توقف جستجوی گره‌های آشوبی در فضای الگوی ذخیره شده، می‌بایست حد آستانه‌ای برای گره‌ها تعیین شود. با توجه به این موضوع که یکی از بهترین پارامترها جهت کنترل خروجی گره‌های



(شکل ۱۳)- درصد صحت بازشناسی شبکه عصبی آشوب‌گونه بهازای مقادیر مختلف k - برای الگوی ورودی نویهای (۵٪)



(شکل ۱۱)- نمودار میله‌ای تعداد دفعات انتخاب هر نورون لایه پنهان به عنوان نورون با بیشینه خطا

با افزایش تعداد این گره‌های غیر آشوب‌گونه^۱، همان‌گونه که پیشتر ذکر شد، عملکرد شبکه عصبی آشوب‌گونه در بازشناسی الگوی نویهای نیز کاهش می‌یابد. شکل (۱۳)، درصد صحت عملکرد شبکه بهازای مقادیر مختلف k را در بازشناسی الگوی نویهای (نویه نرم‌الملجم شونده ۵٪) نشان می‌دهد. همان‌طور که مشاهده می‌شود، به ازای $k > 0.6$ و افزایش δ و به دنبال آن، افزایش تعداد نورون‌های غیر آشوب‌گونه، درصد صحت عملکرد کاهش می‌یابد. لذا مقدار k در رابطه $25 = \frac{1}{6} \cdot \delta$ در نظر گرفته شد. بدیهی است این مقدار به میزان نویه الگوی ورودی بستگی ندارد.

در نهایت، با توجه به آنچه تا اینجا گفته شد مراحل آزمون شبکه آشوب‌گونه به صورت زیر است:

۱) تعیین حد آستانه خطای هر نورون آشوب‌گونه لایه پنهان (۰.۸) با استفاده از دادگان تعلیم:

$$\delta_i = k \cdot e_i(E_{\max})$$

۲) تعیین محدوده جستجوی هر نورون آشوب‌گونه لایه پنهان (α_i) با استفاده از داده آزمون ورودی:

$$\alpha_i = |x_{in}v_i - ((1-\lambda)x_{in}v_i + f(x_{in}v_i)v_f)|$$

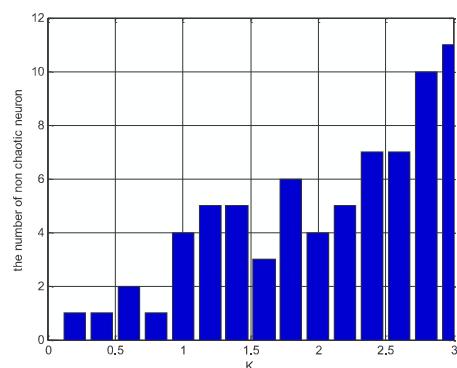
۳) تعیین ورودی لایه پنهان در اولین دور

$$y_B(0) = x_{in}v_i$$

۴) تعیین شرط اولیه برای نورون‌های آشوب‌گونه

$$x_{CHi}(0) = 0.01\alpha_i$$

۵) بررسی عدم موافقت هر نورون آشوب‌گونه



(شکل ۱۲)- تعداد نورون‌های غیر آشوب‌گونه بهازای مقادیر مختلف k - برای الگوی ورودی نویهای (۵٪)

طبق بررسی‌های انجام شده و با اطلاعاتی که خطا در لایه پنهان و محدوده آن به دست آمد، مقدار آستانه خطای در شرط توقف جستجوی نورون‌ها به صورت رابطه (۲۵) تعریف شد که در این رابطه، k مقدار ثابت معین است. هرچه مقدار آستانه خطای هر نورون لایه پنهان وابسته است، بیشتر باشد تعداد نورون‌های آشوب‌گونه بیشتری با چرخش‌های ابتدایی خود به آستانه توقف رسیده و اثر جستجوی آشوب‌گونه کمتر خواهد شد. از این مسأله می‌توان برای تعیین ضریب k استفاده کرد. بدین منظور، با افزایش مقدار k عملکرد شبکه عصبی آشوب‌گونه مورد ارزیابی قرار گرفته شد. همان‌طور که در شکل (۱۲) نمایش داده شده است، با افزایش مقدار k از مقدار مشخصی تعداد گره‌هایی که در حالت غیر آشوبی قرار دارند، افزایش می‌یابد.

¹ Non-chaotic

۱-۵ نورون‌های آشوب‌گونه

Chartier & Boukadoum, 2006; Chartier &)

(Boukadoum, 2006) برای نورون تابع فعالیتی ارائه شده است که این مدل بر پایه معادله کلاسیک Verhulst رابطه (۳۲) تعريف شده است. این مدل به نسبت دیگر مدل‌های مطرح در شبکه‌های عصبی، توجیه بهتری از مشاهده‌های فیزیولوژیکی که در تحقیقات مورد توجه گرفته شده است، ارائه می‌کند.

$$\frac{dz}{dt} = G(1-z)z \quad (32)$$

که G پارامتر کلی^۴ نام دارد. این رابطه دارای دو نقطه ثابت^۵ و $z=1$ است، البته تنها نقطه $z=1$ نقطه ثابت پایدار است و بنابراین رابطه فوق تنها یک جاذب دارد. برای داشتن دو جاذب، می‌بایست سمت راست معادله به نگاشت مکعبی تغییر یابد. پس از ساده‌سازی‌ها و استفاده از معادله تفاضلی به جای مشتق داریم:

$$\frac{dz}{dt} = G(1-z^2)z \quad (33)$$

معادله به دست آمده دارای ۳ نقطه $z=0$ و $z=-1$ است، که هر دو نقطه $z=1$ و $z=-1$ نقطه ثابت پایدار هستند. اگر به جای مشتق معادله تفاضلی معادل آن را قرار دهیم خواهیم داشت:

$$(34)$$

$$z_{[t+1]} = \Delta G(1-z_{[t]}^2)z_{[t]} + z_{[t]}, \Delta G = \delta$$

مقدار δ که رفتار دینامیکی خروجی را به سامانه تحمیل می‌کند، در کارایی و عملکرد شبکه بسیار تعیین‌کننده است؛ اگر مقدار این پارامتر بسیار زیاد باشد، شبکه ممکن است به صورت تناوبی به جاذب‌های پایدار، حدی و یا آشوب‌گونه همگرا شود. شکل (۱۴) فضای مرحله تابع بهازای $0/2 = \delta$ را در حالت تک بعدی نشان می‌دهد. همان‌گونه که انتظار می‌رود، نقاط ثابت پایدار $1 \pm \delta$ هستند در حالی که صفر ناپایدار است.

$$d_i(t) = |y_{Bi}(t) - ((1-\lambda)x_{in}v_i + y_{Bi}(t))v_f|$$

(۶) اصلاح ورودی لایه پنهان (y_{Bi}) با استفاده از نورون‌های آشوب‌گونه برای نورون‌هایی که $d_i < \delta$ است:

$$x_{CHi}(t+1) = \\ \alpha_i \left(A_i \left[\left(\frac{1}{\alpha_i} x_{CHi}(t) + 0.5 \right) \left(0.5 - \frac{1}{\alpha_i} x_{CHi}(t) \right) \right] - 0.5 \right) \\ y_{Bi}(t+1) = y_{Bi}(0) + x_{CHi}(t+1)$$

(۷) تکرار گام‌های ۵ و ۶ تا زمانی (t_0) که اکثر نورون‌ها به پایداری برسند.

(۸) محاسبه خروجی

$$y_b = f(y_B(t_o)) \\ y = f((1-\lambda)x_{in}v_i + y_b v_f)) \\ z = f(yw_o)$$

۵-شبکه‌های آشوب‌گونه با استفاده از نورون‌های آشوب‌گونه (CNN)^۱

در این بخش به معرفی شبکه‌های آشوب‌گونه‌ای می‌پردازیم که علاوه بر داشتن توان پردازشی بالاتر نسبت به دیگر شبکه‌های عصبی آشوب‌گونه، توجیه بهتری از دیدگاه فیزیولوژی معز دارد. درواقع در طراحی این شبکه‌های آشوب‌گونه از رویکرد متفاوتی نسبت به رویکرد مطرح شده در بخش قبل استفاده شده است. طراحی این شبکه‌های آشوب‌گونه با توجه به مبانی مطرح شده در (Chartier & Boukadoum, 2006; Chartier et al., 1990; Aihara et al., 1990) می‌باشد که علاوه بر ساختار بازگشتی در شبکه، شامل نورون‌هایی هستند که دینامیک آنها با تغییر یک یا چندین پارامتر تغییر می‌کند. در این شبکه‌ها مانند آنچه آیهارا^۲ و Chartier & Boukadoum, 2006; Aihara et al., 1990 ارائه کردند، با تنظیم پارامترهای نورون‌ها، شبکه در حالت دوره‌ای و یا آشوب‌گونه قرار می‌گیرد. شبکه در حالت غیر آشوب‌گون تعییم می‌بیند و در حالت آشوب‌گونه به بازخوانی الگوهای ذخیره شده می‌پردازد.

¹ Chaotic Neural Network

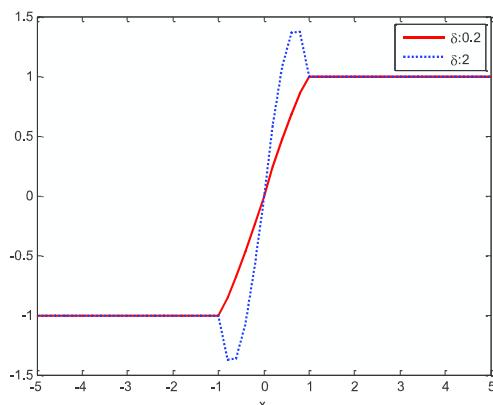
² Kazuyuki Aihara

³ Sylvain Chartier

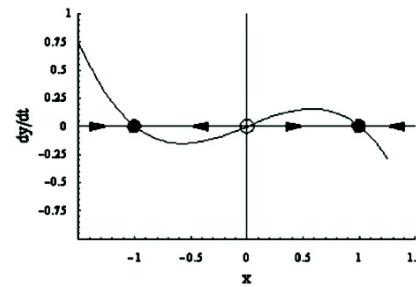
صورت آشوب‌گونه می‌باشد. شکل (۱۶)، منحنی نمای لیاپانوف آن را نمایش می‌دهد که با استفاده معادله ۳۷ محاسبه شده است. ($T=200$, $W=1$, $B=0$, $\delta=0.2$).

$$\lambda \approx \frac{1}{T} \sum_{t=1}^T \log(1 + \delta - 3\delta a_{i[t]}^2) \quad (37)$$

همان‌طور که مشاهده می‌شود، شبکه در مواردی که δ در محدوده $0 \dots 0.5$ است، رفتار یکنواختی را در حرکت به سمت حالات پایدار از خود نشان داده و در $\delta=0.2$ دارای رفتار آشوب‌گونه است. در شکل (۱۷) نیز نمودار دوشاخه‌گی این تابع نشان داده شده است. نکته قابل تأمل در این تابع، W و B است که در بررسی های پیشین (He et al., 2007) به خوبی مورد بررسی قرار نگرفته است. همچنین، چارتیر در (Chartier & Boukadoum, 2006) تنهای به مطالعه رفتار نورون‌ها و شبکه عصبی BAM، در $W=1$ و $B=0$ است که در بینامیک‌های نورون‌ها و پرداخته و در مورد W و تأثیر آن بر دینامیک‌های نورون‌ها و بالطبع شبکه، صحبتی به میان نیاورده است و درنهایت نیز شبکه عصبی آشوب‌گونه BAM، را با توجه به نمودار دوشاخه‌گی نورون‌های آشوب‌گونه ($W=1$), مورد ارزیابی قرار داده است. در ادامه خواهیم دید که دینامیک‌های نورون‌های آشوب‌گونه و به دنبال آن شبکه، چگونه تحت تأثیر وزن‌های شبکه (W) و مقدار ثابت تابع فعالیت (B) تغییر می‌کند. در شکل (۱۸)، نمودار دوشاخه‌گی این تابع را به ازای مقادیر مختلف W نشان داده شده است. ($B=0$).



شکل (۱۵)- تابع فعالیت بهازای مقادیر مختلف δ



(شکل (۱۶)- فضای فاز تابع $dz/dt = (1 + \delta)z - \delta z^3$

(http://www.gaussianprocess.org/gpml/data/usps_resampled.zip)

این تابع آشوب‌گونه توسط چارتیر در شبکه عصبی BAM مورد استفاده و ارزیابی قرار گرفت. این شبکه توانایی ساخت جاذب‌ها را به صورت نقطه ثابت داشت. همچنین به دلیل استفاده از تابع فعالیت آشوب‌گونه و تنها با تغییر پارامتر دوشاخه‌گی، این شبکه می‌توانست انسواع دیگر جاذب‌ها و همچنین مقادیر سطوح خاکستری را تولید کند. سرانجام، در رابطه ۳۴ با قرار دادن $a_{i[t]} = z_{i[t]}$, $\Delta G = \delta$, $a_{i[t+1]} = z_{i[t+1]}$ با ارائه شده برای تابع فعالیت نورون آشوب‌گونه از معادله زیر پیروی می‌کند:

$$\forall i, \dots, N, b_{i[t+1]} = g(a_{i[t]}) \\ = \begin{cases} 1 & a_{i[t]} > 1 \\ -1 & a_{i[t]} < -1 \\ (\delta + 1)a_{i[t]} - \delta a_{i[t]}^3 & \text{else} \end{cases} \quad (35)$$

$$a_{i[t+1]} = Wb_{i[t+1]} + B$$

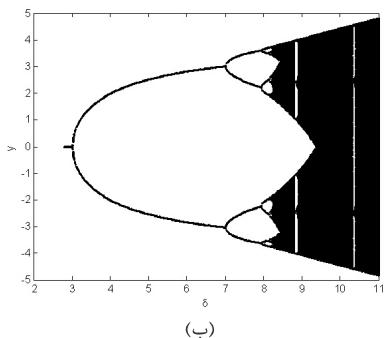
در این رابطه $a_{i[t]}$ ورودی و $b_{i[t+1]}$ خروجی نورون آم در لحظه t است و پارامترهای B و W مقادیر ثابتند. همچنین δ یک پارامتر کلی است که نوع رفتار دینامیکی خروجی را به سامانه تحمیل می‌کند و در کارایی و عملکرد شبکه بسیار تعیین کننده است؛ اگر مقدار این پارامتر بسیار زیاد باشد، شبکه ممکن است به صورت تناوبی به جاذب‌های پایدار، حدی و یا آشوب‌گونه همگرا شود. شکل (۱۵) نمودار این تابع فعالیت را به ازای مقادیر مختلف δ نشان می‌دهد ($W=1$, $B=0$). همان‌طور که مشاهده می‌کنید، به ازای $\delta = 0.2$ این تابع فعالیت بسیار شبیه تابع تائزانت سیگموید رابطه (۳۶) می‌باشد.

$$f(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (36)$$

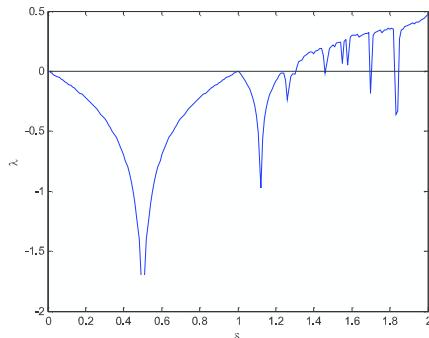
درواقع پارامتر δ تعیین کننده نوع رفتار این تابع است. به گونه‌ای که به ازای مقادیر خاصی از δ دینامیک نورون به

^۱ Bidirectional Associative Memory

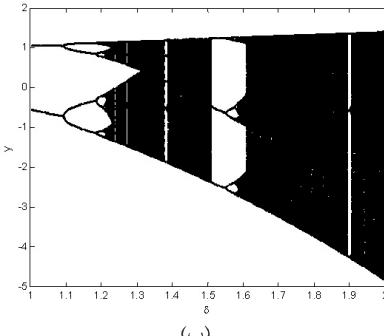
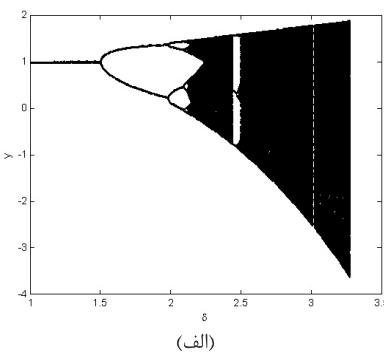




(شکل ۱۸) نمودار دوشاخه‌گی $B=0/5$ (الف) $W=0/25$ (ب)

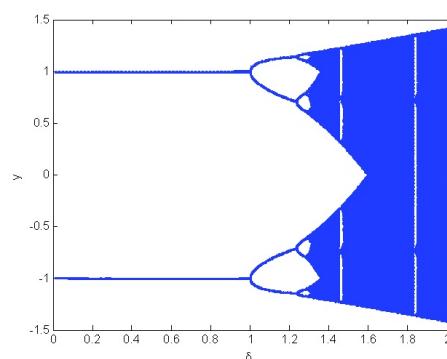


(شکل ۱۶) نمودار نمای لیاپانوف به‌ازای مقادیر مختلف δ



(شکل ۱۹) نمودار دوشاخه‌گی $B=0/5$ (الف) $B=1/5$ (ب)

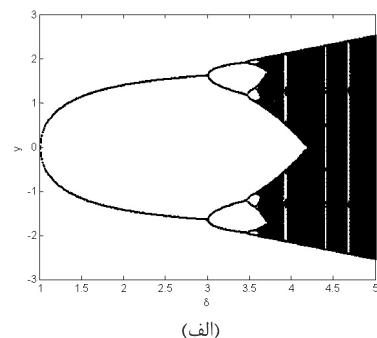
همان‌طور که در شکل (۱۹) مشاهده می‌شود مقدار B نیز تعیین‌کننده رفتار نورون است؛ به‌گونه‌ای که در نواحی یکسان δ ، به‌ازای مقادیر مختلف B ، رفتار نورون متفاوت است شکل (۱۹-الف)، شکل (۱۹-ب) لذا با توجه به آنچه تاکنون گفته شد، برای بررسی رفتار نورون آشوب‌گونه، می‌بایست تمام پارامترهای نورون، معین و تعریف شده باشند و این مسئله‌ای است که در طراحی شبکه عصبی آشوب‌گونه بسیار مهم و تعیین کننده جلوه می‌نماید.



(شکل ۱۷) نمودار دوشاخه‌گی

با مقایسه نواحی رفتار نورون در می‌یابیم که دینامیک‌های نورون به مقدار W نیز وابسته می‌باشد؛ به‌گونه‌ای که به ازای $W=0/25$ و $W=0/5$ ، نواحی دوره‌ای و آشوب‌گونه نورون آشکارا متفاوت است.

به‌عبارت دیگر، وزن‌های تعلیم‌یافته شبکه، دینامیک معینی را برای هر نورون تعیین می‌کند که با توجه به آن و مقدار δ ، می‌توان این دینامیک‌ها را کنترل کرد. از سوی دیگر، مقدار پارامتر B نیز در رفتار نورون آشوب‌گونه مؤثر است که در مطالعات گذشته، به‌دلیل ساختار شبکه‌های BAM، تاکنون مورد بررسی قرار گرفته نشده بود.



(الف)

۲-۵ شبکه عصبی آشوب‌گونه CNN

در این بخش به معرفی شبکه عصبی آشوب‌گونه جدید دیگری خواهیم پرداخت که رویکرد مطرح شده در

که توابع f و g طبق روابط زیر تعریف می‌شوند:

$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad (41)$$

$$g(s) = \begin{cases} 1 & s > 1 \\ -1 & s < -1 \\ (\delta + 1)s - \delta s^3 & \text{else} \end{cases} \quad (42)$$

۵-۱-۲-۵ تعلیم شبکه عصبی آشوب‌گونه CNN

در تعلیم این شبکه نیز به نحوی از الگوریتم پسانشمار خطای استفاده می‌شود؛ به این صورت که خطای مربوط به خروجی به دست آمده از شبکه و خروجی مطلوب، و نیز خطای بین ورودی لایه پنهان و وزن‌ها به هنگام می‌شوند. در این شبکه نیز در هنگام تعلیم، در شبکه چرخش خواهیم داشت. محاسبه گرادیان خطاهای در روند تعلیم شبکه عصبی آشوب‌گونه در روابط ۴۳ تا ۴۶ آمده است.

$$\delta z_k = (1 - z_{k-1}^2) \left[\sum_{i=1}^n (d_i - z_{ik}) \right] \quad (43)$$

$$\delta y_{n,k} = 0.1 \times \left[\sum_{i=1}^m x_k v_i - y_n \right] \quad (44)$$

$$\delta y_k = g'(y) \left(\sum_{i=1}^n \delta z_i w_{oi} - \delta y_{n,i} v_{fik} \right) \quad (45)$$

که $g'(y)$ مشتق تابع فعالیت نورون‌های آشوب‌گونه است که به صورت زیر در نظر گرفته شد:

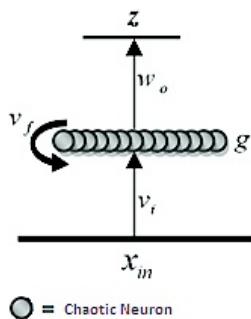
$$\forall i, \dots, N, g'(a_{i[l]}) = \begin{cases} 0 & a_{i[l]} > 1 \\ 0 & a_{i[l]} < -1 \\ -3\delta a_{i[l]}^2 + \delta + 1 & \text{else} \end{cases} \quad (46)$$

در فرآیند تعلیم، طبق نمودار دوشاخه‌گی تابع فعالیت نورون آشوب‌گونه شکل (۱۷)، مقدار پارامتر کلی (δ) به گونه‌ای انتخاب می‌شود که نورون رفتاری غیرآشوب‌گونه داشته باشد. نمودار توابع g و g' را به ازای $\delta = 0.2$ در شکل (۲۱ و ۲۲) مشاهده می‌کنید.

در گام‌های اولیه تعلیم شبکه عصبی آشوب‌گونه، ورودی تابع فعالیت در خارج محدوده $[0, 1]$ قرار دارد، با قرارگیری ورودی در این بازه همان‌طور که در شکل (۲۲) مشاهده می‌شود، مشتق تابع برابر صفر است و با توجه به رابطه ۴۵ خطای، پسانشمار نمی‌شود؛ از این رو به نظر

طراحی آن با رویکردی که در ارائه شبکه عصبی آشوب‌گونه بر مبنای شبکه CARNN (CARNN) مطرح شد؛ به طور کامل متفاوت است. شکل (۲۰).

در این شبکه برخلاف شبکه عصبی آشوب‌گونه CARNN، هوش حاکم و نورون‌های آشوب‌گونه در دو سامانه مجزا قرار نداشته و در تعامل با یکدیگر است. در این شبکه عصبی آشوب‌گونه از نورون‌هایی با تابع فعالیت آشوب‌گونه (رابطه ۳۵) در لایه پنهان شبکه ARNN استفاده شد. همان‌طور که در در بخش ۱-۵ دیدیم، این مدل نورون دارای پارامتری است که با تغییر این پارامتر دینامیک‌های نورون تغییر می‌یابد. از این خاصیت برای تغییر و تنظیم رفتار نورون و شبکه در فرآیند تعلیم و بازشناسی الگوها استفاده شد.



شکل ۲۰- ساختار شبکه عصبی آشوب‌گونه CNN

در فرآیند تعلیم که تنها شکل گیری صحیح جاذب‌های نقطه‌ای اهمیت دارد، مقدار این پارامتر به گونه‌ای تنظیم شد که رفتار نورون به صورت جاذب نقطه‌ای باشد. در فرآیند بازشناسی که لازم است جستجو در فضای الگوی ذخیره شده به صورت وسیع و کارآمد انجام شود، این پارامتر به گونه‌ای انتخاب می‌شود که نورون دارای رفتار آشوب‌گونه باشد. به این صورت که ناحیه معینی را با دقت معینی مورد جستجو قرار داده و حتی نقطه‌ای را بیش از یک بار جستجو نکند.

رونده انتشار اطلاعات از ورودی به خروجی در این شبکه عصبی با معادلات ۳۸ تا ۴۲ بیان می‌شود:

$$z = f(yw_o) \quad (38)$$

$$y = g((1-\lambda)x_{in}v_i + y_b v_f) \quad (39)$$

$$y_b = g(x_{in}v_i) \quad (40)$$

فصل نهم
پروردگاری



۲-۲-۵- آزمون شبکه عصبی آشوب‌گونه CNN

در فرآیند بازخوانی الگوها، به دلیل استفاده از قدرت جستجوگری آشوب در فضای الگوهای ذخیره شده و بازخوانی آنها، پارامترکلی (δ) نورون آشوب‌گونه به گونه‌ای انتخاب می‌شود که نورون در وضعیت آشوب‌گونه قرار گیرد. در این حالت نیز مانند قبل، در شبکه چرخش خواهیم داشت بدین صورت که با دورزدن در لایه پنهان، الگوی ورودی به جاذب مربوط به یکی از الگوهای ذخیره شده هدایت می‌شود و بدین ترتیب تغییرات ناخواسته در الگوی ورودی حذف می‌شود. خروجی لایه پنهان در گام اول از رابطه ۴۷ محاسبه می‌شود.

$$y_b(0) = g(x_{in}v_i) \quad (47)$$

خروجی لایه پنهان در گام‌های بعدی طبق روابط ۴۸ و ۴۹ محاسبه می‌شود.

$$y(t+1) = g((1-\lambda)x_{in}v_i + y_b(t)v_f) \quad (48)$$

$$y_b(t+1) = y(t+1) \quad (49)$$

پس از گام t_0 می‌توان گفت تغییرات خروجی لایه پنهان کاهش می‌یابد و خروجی شبکه طبق رابطه زیر محاسبه می‌شود:

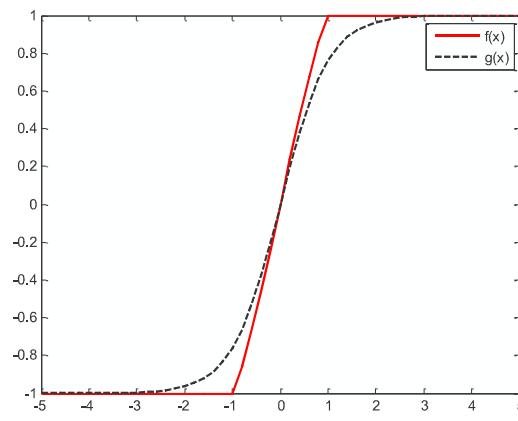
$$z = f(y(t_0)w_o) \quad (50)$$

با توجه به آنچه در بخش ۱-۵ بیان شد در شبکه عصبی آشوب‌گونه پیشنهاد شده مقادیر W و B به گونه‌ای انتخاب شده‌اند که در مورد مقدار آنها نمی‌توان قضاؤت کرد. این مسئله در مورد پارامتر B ، به مراتب شدیدتر است. ($B=(1-\lambda)x_{in}v_i$). چرا که مقدار x_{in} و حتی محدوده آن نیز به دلیل نامشخص بودن مقدار نویفه ناخواسته ورودی، قابل تعیین نیست. لذا، پیش‌بینی رفتار دقیق نورون‌های شبکه عصبی آشوب‌گونه در این بررسی به صورت تئوری امکان‌پذیر نیست؛ از این‌رو در این بررسی، با آزمون و خطا محدوده δ تعیین شده است.

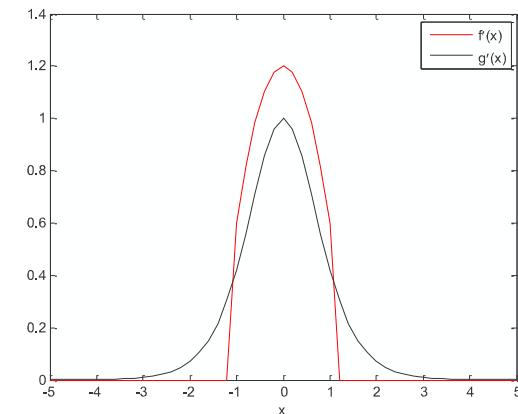
۶- ارزیابی

در این بخش به ارزیابی عملکرد شبکه‌های عصبی آشوب‌گونه پیشنهادشده پرداخته و عملکرد آنها در بازشناسی الگوی نویفه‌ای با عملکرد شبکه ARNN و دیگر شبکه‌های عصبی آشوب‌گونه مقایسه خواهد شد. در ادامه ابتدا به معرفی

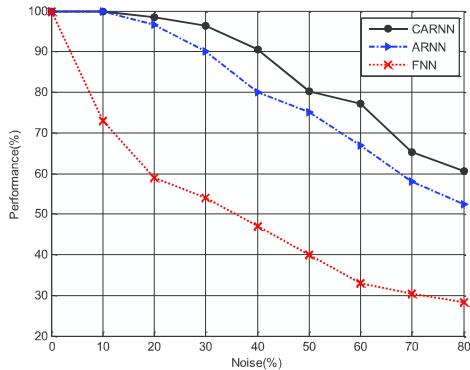
می‌رسد که خطای وجود نداشته و تعلیم به اتمام رسیده است. لذا همان‌طور که در بررسی‌های عملی مشاهده شد، شبکه در تعلیم با مشکل هم‌گرایی مواجه است؛ برای رفع این مشکل و هم‌گرا شدن شبکه، بررسی‌های زیادی انجام گرفت. درنهایت، با توجه به اینکه توابع فعالیت نورون آشوب‌گونه با $\delta = 0/2$ و تابع تائزانت سیگموید - همان‌طور که در شکل (۲۱) نشان داده شده است- به‌طور تقریبی شکل یکسان دارند، در رابطه ۴۵ که رابطه مربوط به اصلاح وزن لایه پنهان شبکه است، از مشتق تابع تائزانت سیگموید، به جای مشتق تابع تکه‌ای مشتق پذیر g استفاده شد. با استفاده از مشتق تابع تائزانت سیگموید، مشکل واگرایی شبکه حل شده و خطای تعلیم شبکه عصبی آشوب‌گونه پس از چندین دوره تعلیم به مقدار قابل قبولی رسید.



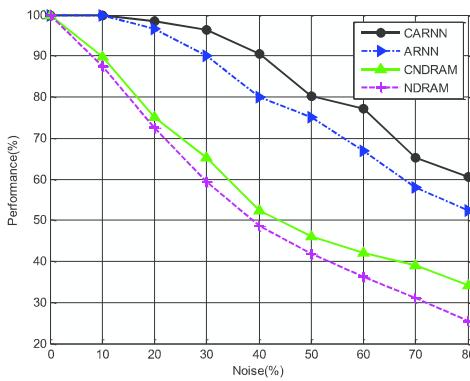
(شکل ۲۱)- مقایسه شکل تابع تائزانت سیگموید و تابع فعالیت نورون آشوب‌گونه $\delta = 0/2$.



(شکل ۲۲)- مقایسه مشتق تابع تائزانت سیگموید (f') و تابع فعالیت نورون آشوب‌گونه (g'): $\delta = 0/2$



(شکل ۲۴)- مقایسه درصد صحبت عملکرد شبکه ARNN، شبکه آشوب‌گونه CARNN و شبکه عصبی جلوسو (FNN) به‌ازای سطوح مختلف نویه در الگوی ورودی



(شکل ۲۵)- مقایسه درصد صحبت عملکرد شبکه ARNN، شبکه آشوب‌گونه CARNN، شبکه عصبی NDRAM و شبکه عصبی آشوب‌گونه CNDRAM به‌ازای سطوح مختلف نویه

همچنین، شبکه CARNN برای تصاویر نویه‌ای با درصد نویه بالاتر از ۲۰٪، عملکرد به مراتب بهتری نسبت به شبکه ARNN دارد. به طوری که برای نویه حدود ۶۰٪ با به کارگیری دینامیک‌های آشوب‌گونه، این صحبت بازناسانی از ۶۷٪ به ۷۷٪ بهبود یافته است.

علاوه بر این همان‌طور که در شکل (۲۴) مشاهده می‌شود، شبکه عصبی آشوب‌گونه CARNN و شبکه ARNN عملکرد به مراتب بهتری از شبکه عصبی جلوسو (FNN)^۱ در بازناسانی مقاوم الگو دارد. که این نشان‌دهنده مثمر ثمریودن اتصالات بازگشتی از یک سو و دینامیک‌های آشوب‌گونه از سوی دیگر است.

طاهرخانی در (طاهرخانی، ۱۳۸۶) بر اساس نظریه انتخاب طبیعی، شبکه عصبی آشوب‌گونه‌ای - از این پس برای سهولت در بیان، این شبکه، CNDRAM^۲ نامیده

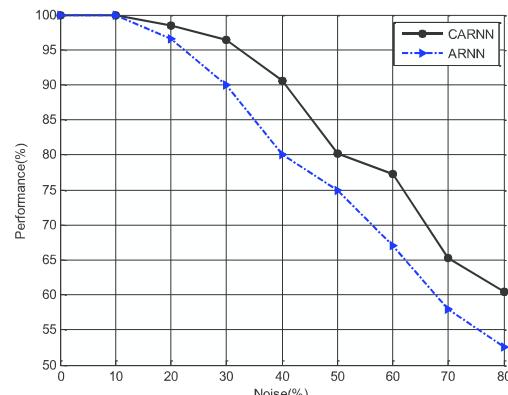
دادگان مورد استفاده پرداخته و سپس به تشریح آزمایش‌ها و روش‌های اجرایی برای ارزیابی کار خواهیم پرداخت.

۱-۶- شبیه‌سازی

شبکه‌های عصبی آشوب‌گونه با ساختار نشان‌داده در شکل‌های ۸ و ۲۰، ۲۵۶ نورون در لایه ورودی، ۱۶ نورون در لایه پنهان و ۱۰ نورون در لایه خروجی) تعلیم داده شده‌اند. در تعلیم شبکه‌ها ۸ برابر $0.0001/0.0001$ در نظر گرفته شد. برای بررسی میزان تأثیر داخل کردن دینامیک‌های آشوب‌گونه در شبکه‌های عصبی بازگشتی، عملکرد شبکه ARNN و شبکه عصبی آشوب‌گونه CARNN در بازخوانی الگوهای نویه‌ای با سطوح مختلف نویه در شکل (۲۳) مورد مقایسه قرار گرفته شده است.

تمامی شبکه‌ها با داده تصویر انتخاب شده از پایگاه داده شکل (۵) تعلیم داده شده است. در مرحله آزمون نیز، این تصاویر با سطوح مختلف نویه برای ارزیابی عملکرد شبکه‌های پیشنهادی استفاده شده است. برای معبرسازی نتایج تمامی آزمایش‌های انجام شده، برای هر مقدار معین درصد نسبت نویه به سیگنال (n)، صدبار نویه تولید کرده و هر بار صحبت بازناسانی را به دست آورده و میانگین این مقادیر به عنوان صحبت بازناسانی مربوط به این n درصد نویه ثبت شده است.

همان‌طور که در شکل (۲۳) مشاهده می‌شود، با افزایش درصد نویفۀ اضافه شده به تصاویر، درصد صحبت عملکرد شبکه، کاهش می‌یابد؛ ولی این نرخ کاهش در شبکه عصبی آشوب‌گونه پیشنهاد داده شده کمتر است.



(شکل ۲۳)- مقایسه درصد صحبت عملکرد شبکه ARNN و شبکه آشوب‌گونه CARNN به‌ازای سطوح مختلف نویه در الگوی ورودی

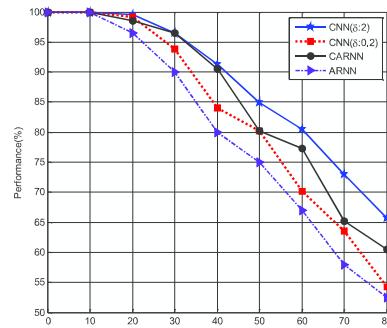


¹ FeedForward Neural Network

² Chaotic Nonlinear Dynamic Recurrent Associative Memory

عصبي آشوب‌گونه به‌ازاي مقادير مختلف نوافه در سه مقدار ۸ نشان داده شده است. همان‌طور که مشاهده می‌شود، با انتخاب مقدار ۸ در محدوده‌های مختلف، عملکرد شبکه عصبی آشوب‌گونه CNN متفاوت است.

با مقایسه درصد صحت بازناسی شبکه عصبی آشوب‌گونه در مقادير مختلف ۸ می‌توان اين‌گونه توجيه کرد که در مقادير بسيار كوچك ۸، شبکه عصبی آشوب‌گونه CNN در حالت غير آشوب‌گونه قرار دارد.

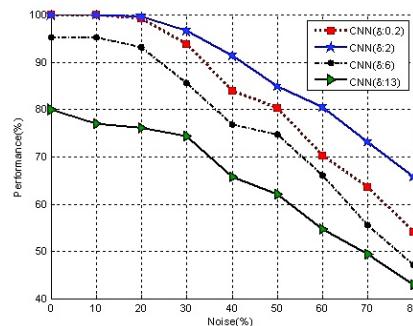


(شکل ۲۷)- مقایسه درصد صحت عملکرد شبکه عصبی آشوب‌گونه CNN (۸)، شبکه CARNN و شبکه ARNN

با افرايش ۸ ديناميک‌های شبکه به سمت آشوب‌گونه ميل می‌کنند، اما به ازاي ۸=۲ شبکه در محدوده آشوب مقيد^۱ قرار دارد که جاذب کوچکی داشته و شبکه را قادر می‌سازد با درجه آزادی بيشتری نسبت به حالت نقطه ثابت، در اين جاذب به جستجو بپردازد که درنتيجه منجر به بازناساني بهتر در فضاي الگوي ذخيري شده می‌شود.

به عبارت ديگر قدرت جستجوگري آشوب، اين امكان را به شبکه عصبی می‌دهد تا با دقت بيشتری در فضای الگوها به جستجو بپردازد. در اين حالت شبکه عصبی آشوب‌گونه CNN می‌کوشد در فضای الگوهای ذخيري شده در لايه پنهان، ورودی‌های تغيير یافته را بازسازی کند و اين موجب افزايش قدرت شبکه در بازناساني الگوهای نوافه‌ای می‌شود. به طوري که برای نوافه حدود ۰.۸۰٪ مقدار درصد صحت بازناساني به طور تقربي ۱۱٪ بهبود یافته است. با افزايش بيشتر ۸ و به‌ازاي ۶=۵، به دليل تغيير رفتار به حالت آشوب غيرمقييد^۲، شبکه در فضای الگوي ذخيري شده سرگردن است؛ لذا همان‌طور که مشاهده می‌کنیم درصد صحت عملکرد شبکه عصبی آشوب‌گونه به ازاي ۶=۵ بسیار کاهش یافته است. به طوري که درصد صحت عملکرد شبکه

می‌شود- طراحی کرد و نشان داد که اضافه کردن گره‌های آشوبی به شبکه NDRAM که مدلی از حافظه می‌باشد، موجب افزایش توان پردازشی نسبت به خود شبکه می‌شود. در شکل (۲۵) عملکرد شبکه عصبی آشوب‌گونه CNDRAM در بازناساني مقاوم الگوهای نوافه‌ای با شبکه عصبی آشوب‌گونه CARNN، مورد مقایسه قرار گرفته شده است. همان‌طور که مشاهده می‌شود، شبکه عصبی آشوب‌گونه CARNN ارائه شده در اين بررسی، عملکرد به مرتب بهتری نسبت به شبکه CNDRAM دارد.



(شکل ۲۸)- درصد صحت عملکرد شبکه عصبی آشوب‌گونه CNN در سطوح مختلف نوافه به‌ازاي مقادير مختلف ۸

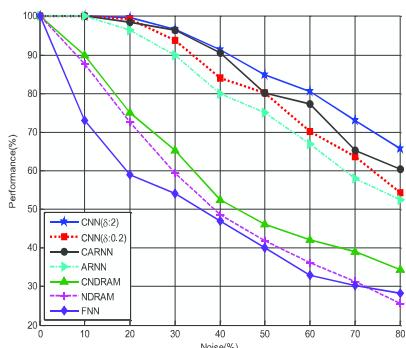
علت اين کاريبي منحصر به فرد را می‌توان در ساختار شبکه، وجود اتصالات بازگشتی، الگوريتم تعليم مناسب و پارامترهای تنظيم‌کننده بهتر ديناميک‌های شبکه عصبی CARNN، آشوب‌گونه پيشنهاد شده، جستجو کرد. همچنان، ظرفيت ذخيره‌سازی بسیار بالاتری نسبت به CNDRAM و شبکه‌های عصبی آشوب‌گونه پيشنهاد داده شده در Nakagawa, 1999; Aihara et al., 1990; Taherkhani et al., 2008) دارد، به طوري که قادر به يادگيري و بازناساني الگوهای به مرتب بيشتری است.

در ادامه به ارزیابی شبکه عصبی آشوب‌گونه CNN که در بخش پنجم معرفی گشت، می‌پردازیم. اين شبکه با ساختار نشان داده شده در شکل (۱۸)، با دادگان معرفی شده در بخش سوم تعليم داده شد. در حين تعليم بهمنظور شکل گيري جاذبها و ذخيره‌سازی‌های الگوهای ورودی، پارامتر کلی درتابع فعالیت نورون‌های آشوب‌گونه لایه پنهان با توجه به نمودار دوشاخه‌گی تابع فعالیت نورون برابر ۰/۰ درنظر گرفته شد تا رفتار نقطه ثابت نورون را تضمین کند. پس از تعليم شبکه عصبی آشوب‌گونه، عملکرد آن در بازناساني مقاوم الگو توسط دادگان نوافه‌ای با درصد های مختلف نوافه ارزیابی شد. شکل (۲۶) درصد بازناساني شبکه

¹ Constrained

² Unconstrained

نورون، نسبت به نقاط ثابت ایجاد شده در شبکه CARNN پایدارتر بوده و لذا عملکرد شبکه در بازشناسی الگوهای نوفاءی بهتر است.



(شکل ۲۹)- مقایسه درصد صحت عملکرد شبکه CNN ($\delta = 2$)، CNN ($\delta = 0.2$)، شبکه CARNN، شبکه ARNN، شبکه FNN، شبکه CNDRAM و شبکه NDRAM

در انتها نیز، عملکرد شبکه‌های عصبی آشوب‌گونه که در این بررسی با توجه به هر دو رویکرد طراحی شده‌اند، با عملکرد دیگر شبکه‌های عصبی آشوب‌گونه مورد مقایسه قرار گرفته است. شکل (۲۹).

۷- جمع‌بندی و نتیجه‌گیری

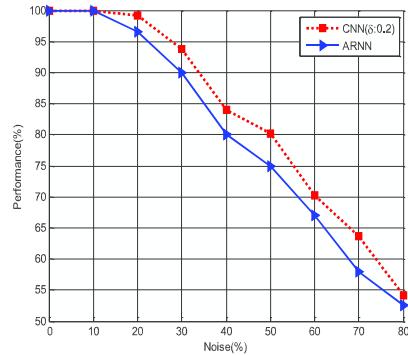
توانایی بالای مغز در پردازش مقاوم داده در برابر تغییرات و تنوعات باعث شده است که نحوه عملکرد آن مورد توجه قرار گرفته و الهام‌بخش طراحی بسیاری از سامانه‌ها شود. وجود رفتارهای آشوب‌گونه در عملکرد سامانه‌های زنده بهویژه مغز انسان، ما را بر آن داشت تا با وارد کردن تصوری آشوب در ساختار شبکه‌های عصبی کلاسیک، توان پردازشی آنها را افزایش دهیم. در این راستا دو نوع شبکه عصبی آشوب‌گونه طراحی شد: ۱- طراحی شبکه عصبی آشوب‌گونه مبنی بر شبکه ARNN و گره‌های آشوبی براساس نظریه انتخاب طبیعی (CARNN) ۲- شبکه عصبی آشوب‌گونه با استفاده از نورون‌های آشوب‌گونه (CNN).

در طراحی شبکه عصبی آشوب‌گونه نوع اول از این نظریه که سامانه طبیعی، تنوعات ممکن برای حل یک مسئله را برای رسیدن به بهترین جواب هدایت می‌کند؛ استفاده شد. بدین صورت که گره‌های آشوبی برای تولید تنوعات ممکن و شبکه ARNN به عنوان هوش حاکم برای هدایت این تنوعات در نظر گرفته شد. گره‌های آشوبی به دلیل داشتن دینامیک‌های آشوب‌گونه، می‌توانند ناحیه معینی را با دقت

در بازشناسی الگوهای تعلیمی یافته نیز از ۱۰۰٪ به ۹۵٪ کاهش می‌یابد.

برای مقایسه بهتر عملکرد شبکه‌های عصبی آشوب‌گونه ای که در این بررسی ارائه شد، درصد صحت عملکرد بازشناسی هریک از این شبکه‌ها در شکل (۲۷) نشان داده شده است. همان‌طور که مشاهده می‌شود شبکه عصبی آشوب‌گونه CNN بهترین عملکرد را در بازشناسی مقاوم الگو دارد. چرا که در این شبکه نورون‌های آشوب‌گونه در تعامل مستقیم با شبکه هستند و مانند بصورت جداگانه از سامانه قرار ندارند.

شبکه عصبی آشوب‌گونه CNN چه در مرحله تعلیم و چه در مرحله آزمون در لایه پنهان خود از نورون‌های آشوب‌گونه استفاده می‌کند و تنها با تنظیم پارامترهای نورون، شبکه رفتارهای مختلفی در دو مرحله دارد. لذا شبکه عصبی آشوب‌گونه CNN انسجام بیشتری داشته و از لحاظ توجیه فیزیولوژیکی نیز نسبت به شبکه CARNN در مرتبه بهتری قرار دارد.



(شکل ۲۸)- مقایسه درصد صحت عملکرد شبکه ARNN و شبکه CNN($\delta = 0.2$)، به‌ازای سطوح مختلف نویف

نکته قابل تأمل دیگر، برتری شبکه عصبی آشوب‌گونه با $\delta = 0.2$ نسبت به شبکه ARNN است شکل (۲۸). با وجود این که هر دوی این شبکه‌ها در حالت نقطه ثابت عمل می‌کنند، شبکه عصبی با توابع فعالیت آشوب‌گونه‌ای که طبق رابطه ۳۵ تعریف شده‌اند، عملکرد به مراتب بهتری نسبت به شبکه ARNN دارد. به‌گونه‌ای که در نویف حدود ۷۰٪ درصد صحت بازشناسی به‌طور تقریبی ۵/۶٪ نسبت به ARNN بهبود یافته است. علت این امر نیز، اختلاف نوع جاذبه‌ای نقطه‌ای است که در هر دو شبکه ایجاد می‌شوند. جاذبه‌ای نقطه‌ای که در شبکه عصبی آشوب‌گونه CNN، شکل گرفته است، به‌دلیل وجود قطب ناپایدار دافع^۱ در تابع فعالیت

¹ Repeller

سال ۱۳۹۲ شماره ۲ پیاپی ۲۰

نیز فعالیت نمی‌کند، بهدلیل داشتن نقاط ثابت پایدارتر، عملکرد به مرتب بهتری نسبت به شبکه ARNN دارد. البته با توجه به این حقیقت که تعیین دقیق پارامترهای شبکه به صورت تئوری میسر نبود، در بررسی‌های آینده می‌بایست روشی برای تنظیم هوشمندانه این پارامترها طراحی شود.

۸- مراجع

دھیادگاری، لوئیزا، "بهبود کیفیت سیگنال گفتار آغشته به نویه و اعجاج توسط شبکه‌های عصبی"، پایان‌نامه کارشناسی ارشد مهندسی بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، ۱۳۸۴

طاهرخانی، ابوذر، "استفاده از نورون‌های بازگشته آشوب‌گونه در بازشناسی مقاوم ارقام دست نوشتار مجزای انگلیسی" پایان‌نامه کارشناسی ارشد مهندسی بیوالکتریک، دانشکده مهندسی پزشکی، دانشگاه صنعتی امیرکبیر، ۱۳۸۶

Adachi, M. and Aihara, K., "Associative Dynamics in A Chaotic Neural Network," *Neural Networks*. 10, pp. 83-98, 1997.

Aihara, K., Takabe, T. and Toyoda, M., "Chaotic Neural Networks", *Phys. Lett. A* 144, 333-340, 1990.

Andras, P., Lycett, S., "An Advantage of Chaotic Neural Dynamics," *IJCNN Conf.*, 1417-1422, 2007.

Aydiner, E., Vural, A. M., Ozcelik, B., Kiymac, K. & Tan, U., "A Simple Chaotic Neuron Model: Stochastic Behavior Of Neural Networks" *International Journal of Neuroscience*, 113(5), 607-619, 2003.

Carpenter, G.A., "Neural Network Models for Pattern Recognition and Associative Memory," *Neural Networks*, 1989.

Carpenter, G.A., Grossberg, S., "Pattern Recognition by Self-Organizing Neural Networks," MIT Press: Cambridge, MA, p. 691, 1991.

Chartier, S. and Boukadoum, M., "A Bidirectional Heteroassociative Memory for Binary and Grey-Level Patterns," *IEEE Transactions on Neural Networks*, vol. 17, pp. 385-396, 2006.

Chartier, S. and Proulx, R., "NDRAM: Nonlinear Dynamic Recurrent Associative Memory for Learning Bipolar and Nonbipolar Correlated Patterns", *IEEE Trans. Neural Networks*, Vol. 16, No. 6, 2005.

سال ۱۳۹۲ شماره ۲ پایابی

خوبی مورد جستجو قرار دهند. همچنین با تنظیم پارامترهای این گره‌ها می‌توان ابعاد این ناحیه را مشخص و محدود کرد. از این‌رو با تعیین هدفمند این نواحی، با توجه به دانشی که از هوش حاکم به دست می‌آید، می‌توان عمل جستجو را نیز هوشمندانه تسریع کرد. استفاده از قدرت جستجوگری آشوب در طراحی این مدل، موجب شد که کارایی این شبکه عصبی آشوب‌گونه CARNN از شبکه عصبی بازگشتی به کار رفته در آن نیز به مراتب بیشتر باشد. همچنین مقایسه عملکرد این شبکه CARNN با دیگر شبکه عصبی آشوب‌گونه‌ای که با این رویکرد طراحی شده است (طاهرخانی، ۱۳۸۶؛ Taherkhani et al., 2008) نیز نشان می‌دهد که این مدل توانایی به مراتب بهتری در بازشناسی مقاوم الگو نسبت به نویه است. علت آن را نیز می‌بایست در شکل‌گیری بهتر و صحیح‌تر جاذب‌ها، ساختار ویژه شبکه ARNN در هدایت خروجی گره‌های آشوبی برای رسیدن به جاذب مورد نظر و تعریف پارامترهای کنترلی بهتر گره‌های آشوبی جستجو کرد.

در شبکه عصبی آشوب‌گونه نوع دوم که در این بررسی ارائه شد، از نورون‌های آشوب‌گونه با تابع فعالیت منحصر به فردی استفاده شد. این تابع فعالیت که بر مبنایتابع Verhulst طراحی شده پارامتری که دینامیک‌های نورون آشوب‌گونه به واسطه تغییر این پارامتر تغییر می‌کند. با تنظیم این پارامتر و قراردادن نورون‌ها در حالت غیرآشوب‌گونه، جاذب‌های نقطه‌ای در شبکه عصبی آشوب‌گونه شکل می‌گیرد و با قرار گیری شبکه در حالت آشوب‌گونه به جستجو در فضای الگوی ذخیره شده می‌پردازد. در اینجا نیز، قدرت جستجوگری آشوب، موجب افزایش عملکرد شبکه عصبی آشوب‌گونه CNN نسبت به شبکه ARNN به کار رفته در آن می‌شود. البته به دلیل محدودیت‌های موجود بر سر طراحی این شبکه عصبی آشوب‌گونه، تعیین دقیق نواحی‌ای که در آن شبکه در حالت آشوب‌گونه، دوره‌ای و ... است به صورت تئوری، امکان‌پذیر نیست. همچنین بررسی‌ها نشان داده است که شبکه عصبی آشوب‌گونه‌ای که با این رویکرد طراحی شده است (CNN): دارای عملکرد بهتری نسبت به شبکه عصبی آشوب‌گونه CRANN که براساس نظریه انتخاب طبیعی و با استفاده از گره‌های تولید‌کننده تنوعات و هوش حاکم جهت هدایت این تنوعات، طراحی شده است.

نکته قابل تأمل دیگر این است که شبکه عصبی آشوب‌گونه CNN، حتی در حالتی که به صورت آشوب‌گونه

- Kanter, I. and Sompolinsky, H., "Associative Recall of Memory without Errors", Phys. Rev. A, vol. 35, pp. 380–392, 1987.
- Khoa, T. Q. D. and Nakagawa, M., "Neural Network Learning Based on Chaos", International Journal of Computer, Information, and Systems Science, and Engineering (IJCISSE) ISSN 1307-2331 Vol.1:2, pp.97-102 May 2007.
- Kim, S.H., Hong, S.D and Park, W.W., "An Adaptive Neuro-Controller with Modified Chaotic Neural Networks," Proceedings. IJCNN Conf., vol.1, 509 – 514, 2001.
- Kohno, T. and Aihara, K., "Mathematical-Model-Based Design of Silicon Burst Neurons", Neurocomputing, 1619–1628, 2008.
- Kohonen, T., "Self-Organizing Maps," Berlin: Springer, 448p, 1997.
- Korn, H., Faure, P., "Is There Chaos in The Brain? II. Experimental Evidence and Related Models," Neurosciences, 326, pp. 787–840, 2003.
- Nakagawa, M., "A Novel Chaos Associative Memory," Proceedings of ICONIP Conference on Neural Information Processing, vol.3, pp. 1106-1111, 1999.
- Ohta, M., "Chaotic Neural Networks with Reinforced Self-Feedbacks and Its Application to N-Queen Problem," Math. Comput. Simul. 59, 2002.
- Pasemann, F., "A Simple Chaotic Neuron", Physica D. 205-211, 1997.
- Sarbadhikari, S. N., Chakrabarty, K., "Chaos in The Brain: A Short Review Alluding To Epilepsy, Depression, Exercise and Lateralization," Medical Engineering & Physics, Vol. 23, Issue 7, pp. 447-457, 2001.
- Savi, M. A., "Chaos and Order in Biomedical Rhythms," J. of the Braz. Soc. of Mech. Sci. & Eng., Vol. XXVII, No. 2, pp. 157-169, 2005.
- Skarda, C. A. and Freeman, W. J., "How Brains Make Chaos in Order to Make Sense of The World" Behavioral and Brain Sciences, vol. 10, pp. 161–195, 1987.
- Szu, H., Yentis, R., Hsu, C.C., Gobovic, D. and Zaghloul, M., "Chaotic Neuron Models and Artificial Neural Networks," Neural Networks, 1993.
- Taherkhani, A., Mohammadi, A., Seyyedsalehi, S.A., Davande, H., "Design of a chaotic neural netw-
- Chartier, S., Boukadoum, M., "A Chaotic Bidirectional Associative Memory," Proceedings of Maghrebian Conference on Software Engineering and Artificial Intelligence, Agadir, Morocco, 498-501, 2006.
- Chartier, S., Renaud, P., Boukadoum, M., "A Nonlinear Dynamic Artificial Neural Network Model of Memory," New Ideas in Psychology, 2007.
- Crook, N., W. Goh, J., Hawarat, M., "Pattern Recall in Networks of Chaotic Neurons", BioSystems, 267–274, 2007.
- Dafilis, M. P., Bourke, P. D., Liley, D. T. J., and Cadusch, P. J., "Visualising Chaos in A Model Of Brain Electrical Activity," Computers & Graphics 26, pp. 971–976, 2002.
- Del Moral Hernandez, E., "Non-Homogenous Neural Networks with Chaotic Recursive Nodes Connectivity and Multi-Assemblies Structures in Recursive Processing Elements Architectures," Neural Networks, 18, 532-540, 2005.
- Freeman, W. J., "Mesoscopic neurodynamics: From neuron to brain," Journal of Physiology-Paris, Vol. 94, Issues 5-6, pp. 303-322, 2000.
- Freeman, W. J., "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.
- Haykin, S., "Neural Networks: A Comprehensive Foundation," Macmillan: N.Y. etc., 1994.
- He, G., Chen, L. and Aihara, K., "Associative Memory with A Controlled Chaotic Neural Network," Neurocomputing, 2007.
- He, G., Shrimali, M. D. and Aihara, K., "Threshold Control of Chaotic Neural Network," Neural Networks, 21, 114–121, 2008.
- Hecht-Nielsen, R., "Neurocomputing," Reading, MA etc.: Addison-Wesley, pp. 433, 1990.
- Heylighen, F., "Self-Organization, Emergence and the Architecture of Complexity," Proceedings of the 1st European Conference on System Science, (AFCET, Paris), pp. 23-32, 1989.
- Hindmarsh, J.L., Rose, R.M., "A Model of Neuronal Bursting Using Three Coupled First Order Differential Equations," Proc. R. Soc. London B 221, 87–102, 1984.

ork by using chaotic nodes and NDRAM network,” Neural Networks, IJCNN (Hong Kong), pp.3500-3504, 2008.

Taherkhani, A., Seyyedsalehi, S.A. and Mohammadi, A., “Design of Chaotic Neural Network for Robust Phoneme Recognition,” ISSPIT 2008, 106-110, Sarajevo.

USPS handwritten digit data:http://www.gaussianprocess.org/gpml/data/usps_resampled.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.

Uwate, Y., Nishio, Y., Ikeguchi, T., "Associative Memory by Hopfield NN with Chaos Injection," Proceedings of IEEE International Joint Conference on Neural (IJCNN'04), vol. 1, pp. 69-74, Jul. 2004.

Zhao, L., Ca'ceres, J.C.G., Damiane Jr, A.P.G., Szu, H., "Chaotic Dynamics for Multi-Value Content Addressable Memory", Neurocomputing, 69, 1628-1636, 2006.

معصومه آذرپور مدرک کارشناسی خود را در رشته مهندسی پزشکی- بیوالکتریک از دانشگاه صنعتی امیرکبیر در سال ۱۳۸۶ و کارشناسی ارشد خود را در همان رشته از دانشگاه صنعتی امیرکبیر در زمینه شبکه‌های عصبی آشوب‌گونه در سال ۱۳۸۸ دریافت کرده است.



نشانی رایانمۀ ایشان عبارت است از:
Masoumeh.Azarpour@rub.de



سید علی سید صالحی مدرک کارشناسی خود را در رشته مهندسی برق از دانشگاه صنعتی شریف در سال ۱۳۶۱، کارشناسی ارشد را در رشته مهندسی برق از دانشگاه صنعتی امیرکبیر در سال ۱۳۶۷ و دکتراخود را در رشته مهندسی برق- بیوالکتریک از دانشگاه تربیت مدرس در سال ۱۳۷۴ دریافت کرده است. ایشان در حال حاضر دانشیار دانشکده مهندسی پزشکی دانشگاه صنعتی امیرکبیر است. زمینه‌های پژوهشی مورد علاقه ایشان پردازش و بازنامه‌گفتار، شبکه‌های عصبی مصنوعی و زیستی، مدل‌سازی عمل کرد مغز و پردازش خطی و غیرخطی سیگنال است.

نشانی رایانمۀ ایشان عبارت است از:
ssalehi@aut.ac.ir