

ترکیب بهینه شبکه عصبی آشوب‌گون با پسخوراند خودی، نمای لیاپانوف و تبرید تدریجی در حل مسئله فروشنده دوره‌گرد

سیدعابد حسینی^۱، محمدرضا اکبرزاده توتونچی^۲

۱- گروه مهندسی فناوری اطلاعات، دانشکده مهندسی، دانشگاه آزاد اسلامی واحد مشهد - مشهد - ایران.

Hosseyni@mshdiau.ac.ir

۲- گروه‌های مهندسی برق و کامپیوتر، قطب علمی رایانش نرم و پردازش هوشمند اطلاعات، دانشکده مهندسی،

دانشگاه فردوسی مشهد - مشهد - ایران.

Akbazar@um.ac.ir

چکیده

این مقاله یک ترکیب هم‌افزای شبکه عصبی آشوب‌گون با پسخوراند خودی، نمای لیاپانوف و تبرید تدریجی را برای حل مسائل بهینه‌سازی ترکیبی نظیر فروشنده دوره‌گرد (TSP) پیشنهاد می‌دهد. برخلاف شبکه‌های عصبی مصنوعی که با دینامیک گرادیان نزولی به سمت نقطه تعادل پایدار همگرا می‌شوند، شبکه‌های عصبی آشوبی دینامیک‌های فضایی - زمانی غنی‌تر و ساختار پیچیده‌تری دارند؛ بنابراین انتظار می‌رود شبکه عصبی آشوبی توان زیادی برای یافتن نقطه بهینه سراسری و یا دست‌کم نزدیک به سراسری داشته باشد. یکی از مهم‌ترین مشکلات شبکه‌های عصبی مصنوعی، گرفتاری آن‌ها در کمینه‌های محلی است. اگرچه شبکه‌های عصبی آشوب‌گون تا حدی این مشکل را حل می‌کنند، ولی به لحاظ سرعت همگرایی در حرکت به سوی نقطه تعادل مشکل دارند؛ بنابراین در این مقاله به کمک نمای لیاپانوف و تبرید تدریجی، حضور شبکه در حالت آشوب‌گون، کنترل و شبکه به سمت نقطه بهینه سراسری هدایت می‌شود. به منظور ارزیابی این شبکه، TSP با تعداد شهرهای مختلف استفاده شده است. نتایج شبیه‌سازی نشان می‌دهد این شبکه می‌تواند جواب بهینه را در TSP با تعداد تکرار کمتر و سرعت بیشتر پیدا کند. **واژه‌های کلیدی:** بهینه‌سازی، تبرید تدریجی، نمای لیاپانوف، شبکه عصبی آشوب‌گون، فروشنده دوره‌گرد.

۱- مقدمه

حوزه‌های جدید در مطالعه پدیده‌ها است و ایده‌ها و راه‌حل‌های خوبی را برای حل بسیاری از مسائل ارائه می‌دهد. از این رو، پژوهشگرها در تلاش هستند تا به کمک دینامیک آشوب‌گون، رفتار عصب‌های واقعی را با عصب‌های مصنوعی مدل کنند. برای نمونه مطالعه‌های فریمن^۲ روی حس بویایی نشان می‌دهد؛ دینامیک‌های سیستم عصبی در حالت پایه آشوب‌گون است و با اعمال تحریک بویایی سیستم به سرعت رفتار خود را اصلاح می‌کند و دینامیک‌ها منظم و نزدیک به متناوب می‌شوند [۱]. با توجه به وجود رفتارهای آشوب‌گون مغز، به نظر می‌رسد اگر به شبکه عصبی قابلیت دینامیک آشوب‌گون

یکی از هدف‌های اصلی سیستم‌های هوشمند، ترکیب هم‌افزای روش‌ها و ابزارها به منظور به دست آوردن قابلیت بیش از استفاده تک‌تک آن‌ها است. آشوب^۱ از جمله

۱ تاریخ ارسال مقاله: ۱۳۹۱/۱۱/۱۵

تاریخ پذیرش مقاله: ۱۳۹۵/۰۱/۲۸

نام نویسنده مسئول: سیدعابد حسینی

نشانی نویسنده مسئول: ایران - مشهد - دانشگاه آزاد اسلامی واحد مشهد - دانشکده مهندسی - گروه مهندسی فناوری اطلاعات

۶۴ ترکیب بهینه شبکه عصبی آشوب‌گون با پسخوراند خودی، نمای لیاپانوف و تیرید تدریجی در حل مسئله فروشنده دوره‌گرد

الکترونیکی [۱۵]، تعیین مسیر بهینه در انتقال داده در شبکه‌های رایان‌های [۱۶]، مکان یابی ربات، پردازش تصویر و تشخیص الگو [۱۷] کاربرد دارد.

هدف TSP انتخاب کوتاه‌ترین مسیر بسته (دور) ممکن بین N شهر متمایز است که باید از هر شهر فقط و فقط یک‌بار عبور کند. تاکنون روش‌های متعددی نظیر تیرید تدریجی (SA) [۱۸]، جستجوی ممنوعه (TS) [۱۹]، ترکیب شبکه‌های عصبی و الگوریتم ژنتیک (GA) [۲۰]، شبکه‌های عصبی آشوب‌گون گذرا [۸]، شبکه‌های عصبی آشوب‌گون [۱۰] و کولونی مورچه‌ها (ACO) [۲۱] برای حل ارائه شده است. هر کدام از این روش‌ها دارای نقاط قوت و وضعی هستند. به‌عنوان نمونه، از روش‌های تکاملی نظیر GA به دلیل حجم محاسبات زیاد، معمولاً در کاربردهای برون خط^{۱۵} استفاده می‌شود. البته این روش‌ها توانایی خوبی در بهینه‌سازی مسائل غیرخطی و پیچیده دارند. پژوهش‌های کریک‌پاتریک^{۱۶} و همکاران، الگوریتم SA (یک روش فرا ابتکاری ساده و اثربخش) را [۲۲] در حل مسائل بهینه‌سازی است. تیرید تدریجی به معنای بالابردن دمای جسم تا رسیدن آن به نقطه ذوب و سپس سرد کردن آن طی شرایط مشخص است که در طول این فرآیند انرژی جسم به حداقل می‌رسد. با اینکه SA و ACO نسبت به الگوریتم‌های تکاملی سریع‌تر هستند، اما معمولاً از صحت کمتری برخوردار هستند.

آکی‌یاما^{۱۷} و همکاران [۲۳] در ماشین‌های گوسی به ترکیب نویزهای تصادفی با توزیع گوسی و اعمال آن‌ها به شبکه‌های عصبی پرداختند، تا بدین طریق فرآیند تیرید تصادفی را انجام دهند. تاکنون پژوهشگران، شبکه‌های عصبی آشوب‌گون متعددی را با مشاهده رفتارهای آشوب‌گون در پدیده‌های زیستی ارائه کرده‌اند. برای نمونه، شبکه‌های عصبی آشوب‌گون بر پایه شبکه‌های خود انجمنی^{۱۸} و دیگر انجمنی^{۱۹} برای مدل‌سازی حافظه طراحی شده است [۲۴، ۲۵]. این شبکه‌ها بر پایه هاپفیلد و قانون یادگیری هب^{۲۰} هستند؛ بنابراین مشکلاتی از جمله ظرفیت ذخیره‌سازی پایین، رشد نامحدود وزن‌ها و ناتوانایی یادگیری الگوهای هم‌بسته را دارند [۲۶]. طاهرخانی و همکاران [۲۷] روشی برای آشوبی کردن وزن‌های شبکه

اضافه شود، بهتر بتواند با مسائل مختلف برخورد کند. تاکنون پژوهش‌های زیادی در راستای ترکیب آشوب با شبکه‌های عصبی سنتی انجام شده است. بیشتر دو رویکرد معمول در طراحی شبکه‌های عصبی آشوب‌گون مطرح است: ۱- طراحی شبکه‌های عصبی آشوب‌گون بر مبنای نظریه انتخاب طبیعی^۲؛ ۲- طراحی شبکه‌های عصبی آشوب‌گون با استفاده از عصب‌های آشوب‌گون. شبکه‌های عصبی آشوب‌گون بر مبنای نظریه انتخاب طبیعی، شامل گره‌های آشوبی برای تولید تنوع‌ها و از شبکه‌های عصبی به‌عنوان هوش حاکم برای کنترل این تنوع‌ها استفاده می‌شود [۲]. در شبکه‌های عصبی آشوب‌گون با عصب‌های آشوب‌گون، از عصب‌هایی استفاده می‌شود که رفتارهایی آشوب‌گون در برخی از نواحی فعالیت خود دارند. با تغییر پارامترهای دوشاخه‌شدگی عصب‌ها رفتار عصب و در نتیجه رفتار شبکه تغییر می‌کند [۳، ۴].

برخلاف رفتارهای ایستا^۳ و یا نیمه پایدار شبکه‌های عصبی سنتی، شبکه‌های عصبی آشوبی دارای دینامیک غنی‌تر و ناپایدارتری به همراه جذب‌کننده‌های متفاوتی هستند. جذب‌کننده‌هایی که نه فقط از نقاط تعادل و یا نقاط متناوب، بلکه حتی از بستر جذب‌های عجیب نیز تشکیل شده‌اند. دینامیک اغلب شبکه‌های عصبی مصنوعی مبتنی بر گرادیان نزولی^۴ است؛ ولی شبکه‌های عصبی آشوبی^۱ (CNN) [۵-۸] و شبکه‌های عصبی بازگشتی آشوبی می‌توانند دینامیک‌های پیچیده‌تری را بروز دهند. از جمله شبکه‌های بازگشتی آشوبی، می‌توان به شبکه عصبی آشوبی با پسخوراند خودی^۵ غیرخطی اشاره کرد [۹، ۱۰]. این شبکه‌ها علاوه بر توان پردازشی بالا، توجیه خوبی از نظر فیزیولوژی مغز دارند. دینامیک این شبکه‌ها با تغییر یک یا چند مقدار تغییر می‌کند و با تنظیم این مقادیر [۱۱-۱۳] شبکه در حالت آشوب و یا غیرآشوب‌گون قرار می‌گیرد.

مسائل بهینه‌سازی ترکیبی نظیر فروشنده دوره‌گرد^۸ (TSP) از دسته مسائل NP سخت^۹ یا NP مکمل^{۱۰} است [۱۴]. مدت زمان لازم برای حل این مسئله با افزایش تعداد پارامترها به‌صورت نمایی افزایش می‌یابد؛ درحالی‌که نیاز به حل سریع و مناسب رو به افزایش است. TSP در بسیاری مسائل نظیر حرکت بهینه مته در سوراخ کاری سطح‌های

۲- توصیف مدل شبکه عصبی آشوب گون

برخلاف شبکه‌های عصبی مصنوعی سنتی که معمولاً با حد آستانه ساده‌ای نظیر سیگموئید، تانژانت هایپربولیک و دینامیک گرادیان نزولی به سمت نقطه تعادل پایدار همگرا می‌شوند، مدل شبکه‌های عصبی آشوبی دینامیک‌های فضایی - زمانی^{۳۲} غنی‌تر و ساختار پیچیده‌تری دارند [۸]. مطالعه‌ها نشان داده‌اند، اغلب شبکه‌های عصبی سنتی همگرایی به سمت یک وضعیت تعادل، را تضمین می‌کنند؛ اما همچنان در کمینه‌های محلی گرفتار هستند. از طرف دیگر، اگرچه دینامیک شبکه عصبی آشوب‌گون دارای ویژگی حرکت آشوبی در فضای حالت با ساختار فرکتالی بوده است و سبب حل نسبی گرفتاری در کمینه محلی می‌شود، اما مشکل همگرایی دینامیک آشوبی هنوز به نحو مطلوبی حل نشده است؛ بنابراین شبکه‌های عصبی آشوبی با پس‌خوراند خودی به منظور به دست آوردن دو ویژگی فوق ارائه شده‌اند [۱۰، ۳۰]. شبکه عصبی آشوبی با پس‌خوراند خودی با روابط (۱) توصیف می‌شود.

$$x_i(t) = \frac{1}{1 + e^{-y_i(t)/\epsilon_1}},$$

$$y_i(t+1) = ky_i(t) + \alpha \left[\sum_{j=1}^n \omega_{ij} x_j(t) + I_i \right] - z_i(t)g(x_i(t) - I_0),$$

$$g(x) = \frac{1}{1 + e^{-y_i(t)/\epsilon_2}},$$

$$z_i(t+1) = (1 - \beta)z_i(t),$$

$$i = 1, \dots, n$$

که در این روابط:

i: شماره عصب

n: تعداد عصب‌ها (0 ≤ n ≤ 1)

x_i(t): خروجی عصب iام در زمان

y_i(t): حالت داخلی عصب iام در زمان

ω_{ij}: وزن‌های اتصالی بین عصب i و j (ω_{ij} = 0, ω_{ij} = ω_{ji})

I₀: بایاس ورودی عصب iام

I₀: پارامتر مثبت

α: پارامتر مقیاس^{۳۳} مثبت برای ورودی‌ها

k: عامل میرایی^{۳۴} غشاء عصب (0 ≤ k ≤ 1)

ε₁: پارامتر شیب (تندی^{۳۵}) تابع فعال‌ساز (ε₁ > 0)

ε₂: پارامتر شیب تابع سیگموئید و یا بسل (ε₂ > 0)

عصبی جلو سو ارائه کردند. در پژوهش آن‌ها وزن‌های آشوبی طوری با یکدیگر هم‌زمان می‌شوند که خطای خروجی به کمترین رسد. چن^{۲۱} و آیهارا^{۲۲} [۸] یک شبکه عصبی آشوب‌گون گذرا^{۲۳} برای مسائل بهینه‌سازی ترکیبی نظیر TSP ارائه دادند. آن‌ها بر پایه تئوری اثبات کردند، شبکه عصبی آشوب‌گون می‌تواند پایداری و همگرایی مجانبی داشته باشد. شو^{۲۴} و یانگ^{۲۵} [۱۰] یک شبکه عصبی آشوب‌گون با پس‌خوراند خودی و معرفی تابع سیگموئید^{۲۶} را برای حل TSP ارائه دادند. روش آن‌ها می‌تواند پاسخ بهینه در ۱۰ شهر را پیدا کند. شو^{۲۷} و یانگ^{۲۸} [۲۸] یک شبکه عصبی آشوب‌گون با پس‌خوراند خودی و معرفی تابع موجک مورلت^{۲۹} را برای TSP ارائه دادند. روش آن‌ها می‌تواند پاسخ بهینه در ۱۰ شهر را پیدا کند. همچنین یی^{۳۰} [۲۹] یک شبکه عصبی آشوب‌گون با پس‌خوراند خودی و معرفی تابع بسل^{۳۱} را برای حل مسائل بهینه‌سازی ترکیبی ارائه داد. او نشان داد که به دلیل غیرخطی بودن تابع بسل، توانایی بیشتری در تقریب توابع دارد.

تاکنون گزارش‌های زیادی تأیید کرده‌اند که دینامیک آشوبی روشی مناسب برای پردازش اطلاعات و بهینه‌سازی است؛ ولی آن‌ها همچنان مشکل همگرایی دارند؛ زیرا معمولاً تصمیم‌گیری در مورد زمان کنترل دینامیک آشوب و هدایت رفتار آشوبی به سمت نقطه تعادل پایدار دشوار است. هدف این پژوهش حل یکی از مسائل بهینه‌سازی کاربردی نظیر TSP، به کمک ترکیب هم‌افزای شبکه عصبی آشوب‌گون با پس‌خوراند خودی، نمای لیاپانوف و تبرید تدریجی است. در این مقاله تلاش شده است به کمک تبرید تدریجی و نمای لیاپانوف حضور شبکه در حالت آشوب‌گون، کنترل و شبکه به سمت نقطه تعادل سراسری هدایت شود.

ساختار این پژوهش بدین شرح است که ابتدا در بخش ۲ به توصیف شبکه عصبی آشوب‌گون به‌عنوان شبکه پایه پرداخته می‌شود. در بخش ۳ نتایج ترکیب شبکه عصبی آشوب‌گون با پس‌خوراند خودی، نمای لیاپانوف و تبرید تدریجی گزارش می‌شود. در نهایت در بخش ۴ بحث و نتیجه‌گیری می‌شود.

بهینه برسد مسئله مهمی است. در این پژوهش از تیرید تدریجی بدین منظور استفاده می‌شود.

دینامیک آشوبی مربوط به تک عصب

به منظور بررسی دینامیک‌های آشوب‌گون یک تک عصب، می‌توان مقدار α در روابط (۱) را برابر صفر قرار داد و مدل را به صورت روابط (۲) بیان کرد.

$$\begin{aligned} x(t) &= \frac{1}{1 + e^{-y(t)/\varepsilon_1}}, \\ y(t+1) &= ky(t) - z(t)g(x(t) - I_0), \\ g(x) &= \frac{1}{1 + e^{-y(t)/\varepsilon_2}}, \\ z(t+1) &= (1 - \beta)z(t). \end{aligned} \quad (2)$$

در این مقاله $z_i(t)$ به صورت یک تابع نمایی و یا تانژانت هایپربولیک میراشونده مطابق شکل‌های (۱) و (۲) در نظر گرفته می‌شود.

از این رو، مطابق شکل (۱) دمای $z_i(t)$ با افزایش زمان مطابق رابطه $z_i(t) = z_i(0)e^{-y(t)/\varepsilon_1}$ به سمت صفر میل می‌کند.

$z_i(t)$: وزن اتصالی پسخوراند خودی ($z_i(t) > 0$)

β : تیرید تدریجی و یا پارامتر میرایی متغیر وابسته به

زمان ($0 \leq \beta \leq 1$) $z_i(t)$

جمله $g(x_i(t) - I_0)$: جمله پسخورد با تابع سیگموئید و یا بسل

اگر $g(x) = x$ باشد، جمله پسخورد خطی است و شبکه

عصبی آشوب‌گون چن - آیهارا سستی می‌شود. تفاوت بین

شبکه‌های عصبی آشوبی با شبکه‌های عصبی آشوبی با

پسخوراند خودی در جمله $z_i(t)x_i(t)$ است، که آن جمله در

شبکه‌های عصبی آشوبی با پسخوراند خودی به

$z_i(t)g(x_i(t) - I_0)$ تغییر می‌یابد.

نشان داده شده است که این شبکه به صورت طبیعی

دارای دینامیک آشوبی بوده است و سرانجام به سمت یک

نقطه تعادل پایدار از طریق انشعاب^{۳۶} های متوالی نظیر دو

برابر شدن دوره تناوب معکوس و از طریق تکامل وابسته به

زمان متغیر $z_i(t)$ همگرا می‌شود. تصمیم‌گیری برای


چگونگی کنترل رفتار آشوبی عصب تا به نقطه تعادل پایدار

و یا نزدیک به کمینه سراسری همگرا شود، کار دشواری


است. به هر حال پارامتر I_0 ثابت در نظر گرفته می‌شود و با

تغییر پارامتر $z_i(t)$ رفتار آشوبی شبکه کنترل می‌شود؛ اما

اینکه پارامتر $z_i(t)$ چگونه کاهش داده شود تا به نقطه تعادل



شکل (۱): نمودار تغییرات زمانی $z(t)$ به صورت نمایی میراشونده با $z(0)=0.1$

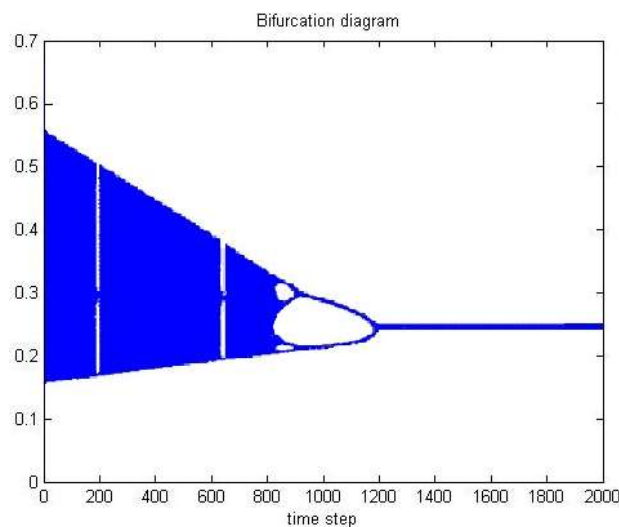


شکل (۲): نمودار تغییرات زمانی $z(t)$ به صورت تانژانت هایپربولیک میراثونده با $z(0)=0.1$

آشوب‌گون از بین رفت، دینامیک‌های گرادیان نزولی، رفتار دینامیکی واحد عصب تکی را کنترل می‌کند. سپس هنگامی که رفتار واحد عصب تکی شبیه به هاپفیلد^{۳۷} است، شبکه تمایل به همگرایی نقطه تعادل پایدار را دارد. شکل (۳) نشان می‌دهد $x(t)$ در حدود ۸۰۰ تکرار اول رفتاری پیش‌بینی نشده دارد و سرانجام پس از حدود ۱۲۰۰ تکرار به سمت یک نقطه تعادل پایدار از طریق یک انشعاب دو برابر شدن متناوب معکوس، همگرا می‌شود.

نمودار دوشاخه‌شدگی حالت تک عصب به ازای پارامترهای $z(0)=0.1, y(1)=0.28, \varepsilon_2=0.03, \varepsilon_1=0.04, I_0=0.55, k=0.7$ در $\beta=0.001$ نشان داده شده است.

شکل (۳) نشان می‌دهد عصب، دارای رفتار دینامیکی آشوب‌گون است. واحد عصبی تکی، ابتدا به صورت جستجوی آشوب‌گون سراسری رفتار می‌کند و با کاهش مقدار $z_i(t)$ ، انشعاب معکوس به تدریج به حالت تعادل پایدار، همگرا می‌شود. پس از اینکه رفتار دینامیکی



شکل (۳): نمودار دوشاخه‌شدگی حالت $x(t)$ یک تک عصب به ازای مقادیر $z(0)=0.1, y(1)=0.28, \varepsilon_2=0.03, \varepsilon_1=0.04, I_0=0.55, k=0.7$ و $\beta=0.001$

۶۸ ترکیب بهینه شبکه عصبی آشوب‌گون با پس‌خوراند خودی، نمای لیاپانوف و تیرید تدریجی در حل مسئله فروشنده دوره‌گرد

$$d_n = d_0 e^{\lambda n} \quad (۴)$$

که در آن d_n فاصله نمونه متوالی در زمان n ام و d_0 فاصله متوالی در زمان اولیه است. با لگاریتم‌گرفتن از رابطه (۴)، رابطه لیاپانوف (۵) حاصل می‌شود.

$$\lambda = \frac{1}{n} \ln \frac{d_n}{d_0} \quad (۵)$$

به منظور مشخص کردن خصوصیات جذب‌کننده در پدیده‌های آشوب‌گون عمدتاً از میانگین λ مطابق رابطه (۶) استفاده می‌شود.

$$\lambda = \frac{1}{N} \sum_{i=1}^N \lambda(x_i) \quad (۶)$$

که در آن $\lambda(x_i)$ بیانگر وابستگی λ به مقدار x_i و به‌عنوان مقدار اولیه در نظر گرفته می‌شود. ماکزیمم مقدار مثبت λ به‌عنوان بزرگ‌ترین نمای لیاپانوف شناخته می‌شود. حال با توجه به روابط یکی از شروط اساسی وجود رفتار آشوب‌گون حساسیت سیستم به شرایط اولیه و مثبت بودن λ است. همچنین در نقاطی که سری زمانی در نقطه شروع و یا $\lambda=0$ باشد رفتار متناوب بوده است و زمانی که مقدار λ منفی می‌شود رفتار به‌کلی متناوب و سیستم غیرحساس به شرایط اولیه خواهد شد. نمای لیاپانوف با استفاده از روابط (۵)، (۶) و (۷) به ازای تعداد تکرارهای به اندازه کافی بزرگ n برای هر مقدار ثابت متغیر $z(t)$ محاسبه می‌شود.

$$y_i(t+1) = ky(t) - z(t) \left(\frac{1}{1 + e^{-y_i(t)/\epsilon_i}} - I_0 \right) \quad (۷)$$

مقادیر مثبت λ نشان‌دهنده این است که دینامیک معادله (۷) برای هر مقدار ثابت $z(t)$ به‌صورت طبیعی دارای ناپایداری آربیتی و رفتار آشوبی است. نمودار سیر زمانی نمای لیاپانوف یک تک‌عصب در شکل (۴) نشان داده شده است.

نمای لیاپانوف^{۳۸}

سونیا کوالسکایا استفاده از نماهای تغییرناپذیر در مطالعه پایداری سیستم‌های دینامیکی را در سال ۱۸۸۹^{۳۹} مطرح کرد. سپس الکساندر میخایلوویچ لیاپانوف این نظریه را در سال ۱۸۹۲^{۴۰} توسعه داد. نمای لیاپانوف میزان واگرایی مسیرهای حالت را اندازه‌گیری می‌کند و از آن می‌توان به‌عنوان معیاری برای وجود و اندازه‌گیری آشوب در یک پدیده بهره جست.

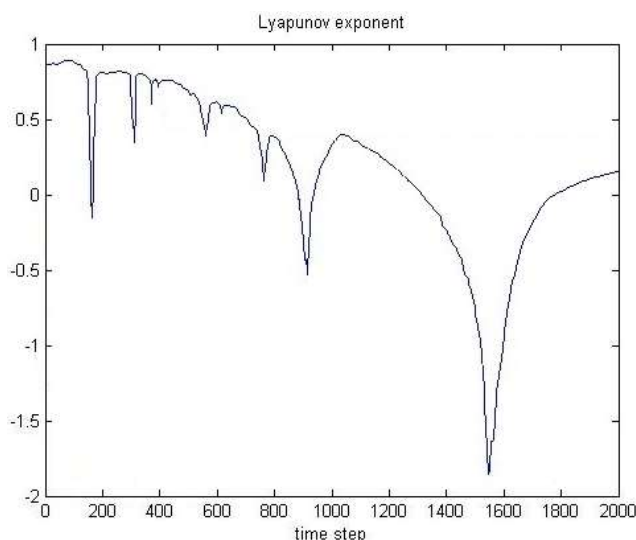
در پدیده‌های آشوب‌گون که پویا و در حرکت‌اند، برخلاف پدیده‌های غیرآشوب‌گون که عمدتاً مصرف‌کننده توان هستند، واگرایی فاصله مسیرهای حالت همواره مثبت است؛ بنابراین در پدیده‌های آشوب‌گون مسیرهای حالت هیچ‌گاه یکدیگر را قطع نمی‌کنند و در واقع هیچ‌گاه به یکدیگر نخواهند رسید. به عبارت دیگر، در این پدیده‌ها چیزی به‌عنوان نقطه یا نقاط کار به چشم نمی‌خورد؛ بلکه چیزی که وجود خواهد داشت، بستر جذبی است که مسیر حالت سیستم در آن بستر بدون تلاقی دوباره با خود پیوسته در حال حرکت است و این همان چیزی است که از آن به تعادل پویا یاد می‌شود.

روش‌های مختلفی نظیر روش‌های مبتنی بر ژاکوبین و مستقیم [۳۲،۳۱] برای محاسبه بزرگ‌ترین نمای لیاپانوف وجود دارد. در این پژوهش از روش مستقیم ولف^{۴۱} استفاده می‌شود [۳۲].

در اینجا از نمای لیاپانوف به‌عنوان یک شاخص برای تعیین ناپایداری آربیتی^{۴۲} رفتار آشوبی استفاده می‌شود. نمای لیاپانوف با این فرض استفاده می‌شود که واگرایی فاصله مسیرهای حالت در فضای بستر جذب دارای رشدی نمایی است. پس با در نظر گرفتن سری زمانی به‌صورت $x(t_0), x(t_1), \dots$ که در آن فرض می‌شود فاصله بین نمونه‌ها یکسان است (یعنی $t_n - t_0 = nt$)، رابطه (۳) حاصل می‌شود.

$$d_0 = |x_j - x_i|, \dots, d_n = |x_{j+n} - x_{i+n}| \quad (۳)$$

با در نظر گرفتن فرض رشد نمایی، واگرایی بین مسیرهای حالت در فضای حالت رابطه (۴) حاصل می‌شود.



شکل (۴): نمودار سیر زمانی نمای لیاپانوف یک تک عصب

محدود N رشد می‌کند. در این مقاله از TSP متقارن برای ارزیابی شبکه به کمک تبرید تدریجی استفاده می‌شود. رابطه (۸) تابع انرژی محاسباتی را توصیف می‌کند [۱۱].

$$E = \frac{W_1}{2} \left\{ \sum_{i=1}^n \left[\sum_{j=1}^n x_{ij} - 1 \right]^2 + \frac{W_2}{2} \sum_{j=1}^n \left[\sum_{i=1}^n x_{ij} - 1 \right]^2 \right\} + \frac{W_3}{2} \sum_{i=1}^n \sum_{j=1}^n \sum_{k=1}^n (x_{k,j+1} + x_{k,j-1}) x_{ij} d_{ik} \quad (8)$$

که $x_{i,n+1}=x_{i1}$ و $x_{i0}=x_{in}$. همچنین W_1 ، W_2 و W_3 پارامترهای تزویج مطابق با محدودیت‌ها و تابع هزینه از طول دور هستند. d_{ij} فاصله بین شهر i تا شهر j است. توسط تنظیم هر وزن ارتباطی w_{ij} مشابه شبکه عصبی هاپفیلد، معادلات توصیفی دینامیکی برای TSP به صورت روابط (۹) است.

$$x_{ij}(t) = \frac{1}{1 + e^{-y_{ij}(t)/\epsilon_1}},$$

$$y_{ij}(t+1) = ky_{ij}(t) - z(t)g(x_{ij}(t) - I_0) + \alpha \left\{ -W_1 \left(\sum_{l \neq j} x_{il}(t) + \sum_{k \neq i} x_{kj}(t) \right) - W_3 \left(\sum_{k \neq i} d_{ik} x_{kj+1}(t) + \sum_{k \neq i} d_{ik} x_{kj-1}(t) \right) + W_1 \right\},$$

$i, j = 1, 2, \dots, n,$

$$z(t+1) = (1 - \beta)z(t).$$

با توجه به اینکه نمای لیاپانوف در حدود ۸۰۰ تکرار اول مطابق شکل (۴) اغلب مثبت است، رفتار در این ناحیه به صورت آشوبی و با پنجره‌های متناوب ممکن شناخته می‌شود. شکل‌های (۳) و (۴) نشان می‌دهند که نوسان‌های آشوب به مرور با میرایی $z(t)$ کاهش می‌یابد و سرانجام از بین می‌روند؛ البته سرعت این تغییرات به ضریب میرایی β بستگی دارد؛ به طوری که هر چقدر β کوچک‌تر باشد، دینامیک آشوبی $x(t)$ مدت زمان بیشتری تداوم می‌یابد. این ویژگی نشان‌دهنده نوعی از دینامیک آشوبی است و هرگاه مقدار $z(t)$ به اندازه کافی کاهش یابد، ساختار دینامیکی شبکه تقریباً بر شبکه عصبی هاپفیلد منطبق می‌شود.


۳- نتایج

در TSP تعداد N شهر مختلف وجود دارد و هدف، انتخاب کوتاه‌ترین دوری است که از یک شهر دلخواه شروع و سپس از تمامی شهرها یکبار و فقط یکبار عبور کند و مجدداً به شهر شروع بازگردد. تعداد کل راه‌حل‌ها و یا تعداد دورهای ممکن برای TSP متقارن $d_{ij} = d_{ji}$ برابر $(N-1)!/2$ و برای TSP نامتقارن $d_{ij} \neq d_{ji}$ برابر $(N-1)!$ است که d_{ij} فاصله شهر i تا شهر j است. در واقع این عدد برابر تعداد دورهای همیلتونی در یک گراف کامل با N رأس است. مشخص است تعداد دورهای ممکن سریع‌تر از هر توان

۷۰ ترکیب بهینه شبکه عصبی آشوب‌گون با پس‌خوراند خودی، نمای لیاپانوف و تیرید تدریجی در حل مسئله فروشنده دوره‌گرد

۱۰ شهر را نشان می‌دهد. کوتاه‌ترین فاصله ۱۰ شهر ۲/۶۷۷۶ است (به‌عنوان بهینه سراسری)؛ بنابراین موارد دیگری نظیر ۲/۷۸، ۲/۸۳ به‌عنوان کمینه محلی محسوب می‌شوند.

که متغیر $z(t)$ به‌صورت مشترک برای همه عصب‌ها در نظر گرفته شده است. در این مقاله به منظور مقایسه نتایج با [۸،۱۰] از یک TSP متقارن با تعداد شهرهای مختلف استفاده شده است [۳۳]. شکل (۵) موقعیت مکانی مسئله با



شکل (۵): موقعیت مکانی ۱۰ شهر در صفحه مختصات در TSP

کمینه سراسری تقریباً ۱۰۰ درصد دست یافته است که نتایج مقاله حاضر به نرخ کمینه سراسری ۱۰۰ درصد رسیده است. در [۸] تعداد تکرارها برای رسیدن به نرخ کمینه سراسری ۱۰۰ درصد ۳۹۸ است؛ بنابراین تعداد تکرارها در این مقاله کاهش یافته است و در نتیجه سرعت همگرایی بیشتر شده است. همچنین از نظر سرعت همگرایی نتایج این پژوهش بهتر از [۳۴،۳۵] است. همچنین نرخ پاسخ‌های نشدنی در [۳۶] صفر است که نتایج این پژوهش را تأیید می‌کند. همچنین نرخ پاسخ‌های نشدنی در [۳۷] به جز یک مورد صفر است. به طریق مشابه با در نظر گرفتن $z(t)$ مطابق شکل (۲)، جدول (۲) حاصل می‌شود.

مجموعه پارامترهای شبکه $W_3=0.7, W_1=W_2=1, I_0=0.65, \varepsilon_1=0.03, \varepsilon_2=0.05, k=0.9, \alpha=0.6$ و $z(0)=0.1$ شبیه‌سازی‌ها با ۵۰۰۰ شرایط اولیه مختلف از y_{ij} که به‌صورت تصادفی در بازه -1 تا 1 تولید شده‌اند و β های بین 0.01 تا 0.02 انجام شده است. با در نظر گرفتن $z(t)$ مطابق شکل (۱) و تعریف پارامترهایی نظیر نرخ کمینه سراسری، نرخ کمینه محلی، نرخ پاسخ‌های نشدنی^{۳۳} و متوسط تکرارها برای همگرایی جدول (۱) حاصل می‌شود.

جدول (۱) نشان می‌دهد به ازای β های مختلف، نرخ پاسخ‌های نشدنی صفر است. به ازای $\beta=0.006$ شبکه به نرخ کمینه سراسری ۱۰۰ درصد و نرخ کمینه محلی صفر درصد رسیده است و متوسط تعداد تکرارها برای همگرایی ۲۱۱ می‌شود. نتایج مرجع [۲۹] به ازای $\beta=0.002$ به نرخ

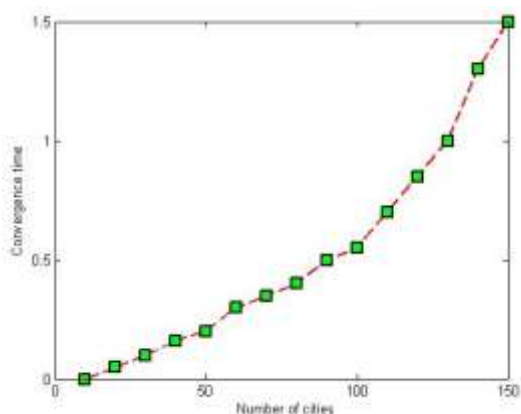
جدول (۱): نمایش مقادیر نرخ کمیته سراسری، نرخ کمیته محلی، نرخ پاسخ‌های نشدنی و متوسط تکرارها برای همگرایی به ازای مقادیر β های مختلف با در نظر گرفتن $Z(t)$ به صورت نمایی میراثونده

β	نرخ کمیته سراسری	نرخ کمیته محلی	نرخ پاسخ‌های نشدنی	متوسط تکرارها برای همگرایی
۰/۰۲	۸۳/۳	۱۶/۷	۰/۰	۱۴۵
۰/۰۱۵	۸۶/۹	۱۳/۱	۰/۰	۱۵۷
۰/۰۱	۹۳/۷	۶/۳	۰/۰	۱۷۲
۰/۰۰۸	۸۹/۹	۱/۱	۰/۰	۱۹۷
۰/۰۰۶	۱۰۰	۰	۰/۰	۲۱۱
۰/۰۰۴	۹۹/۲	۰/۸	۰/۰	۲۳۰
۰/۰۰۳	۹۷/۳	۲/۷	۰/۰	۲۷۷
۰/۰۰۲	۹۴/۶	۵/۴	۰/۰	۳۱۴
۰/۰۰۱	۹۳/۸	۶/۲	۰/۰	۳۶۹

جدول (۲): نمایش مقادیر نرخ کمیته سراسری، نرخ کمیته محلی، نرخ پاسخ‌های نشدنی و متوسط تکرارها برای همگرایی به ازای مقادیر β های مختلف با در نظر گرفتن $Z(t)$ به صورت تانژانت هایپربولیک

β	نرخ کمیته سراسری	نرخ کمیته محلی	نرخ پاسخ‌های نشدنی	متوسط تکرارها برای همگرایی
۰/۰۲	۸۹/۷	۱۳/۳	۰/۰	۱۳۹
۰/۰۱۵	۸۷/۹	۱۲/۱	۰/۰	۱۶۱
۰/۰۱	۸۹/۱	۱۰/۹	۰/۰	۱۸۹
۰/۰۰۸	۹۰/۱	۹/۹	۰/۰	۲۱۵
۰/۰۰۶	۹۵/۲	۴/۸	۰/۰	۲۴۹
۰/۰۰۴	۱۰۰	۰	۰/۰	۲۸۷
۰/۰۰۳	۹۴/۱	۵/۹	۰/۰	۳۵۰
۰/۰۰۲	۹۰/۶	۹/۴	۰/۰	۴۱۷
۰/۰۰۱	۸۶/۳	۱۳/۷	۰/۰	۴۳۰

توزیع وابسته به موقعیت شهرهاست، قبل از متوسط‌گیری نتایج آن‌ها بهنجار می‌شود. متوسط زمان همگرایی برای هر توزیع از شهرها در شکل (۶) به نمایش گذاشته شده است.



شکل (۶): متوسط زمان همگرایی برای هر توزیع از تعداد شهرهای مختلف

جدول (۲) نشان می‌دهد به ازای β های مختلف نرخ پاسخ‌های نشدنی مجدداً صفر است. به ازای $\beta=0.004$ شبکه به نرخ کمیته سراسری ۱۰۰ درصد و نرخ کمیته محلی صفر درصد رسیده است و متوسط تعداد تکرارها برای همگرایی ۲۸۷ می‌شود. همچنین نرخ پاسخ‌های نشدنی در [۳۷] تقریباً صفر است. همچنین جدول‌های (۱) و (۲) نشان می‌دهند، متوسط تعداد تکرارها برای همگرایی به ازای مقادیر مختلف β به ترتیب ۲۳۰ و ۲۷۰ است؛ بنابراین به نظر می‌رسد با در نظر گرفتن $Z(t)$ مطابق شکل (۱) بتوان به تعداد تکرارهای کمتری دست یافت. به منظور بررسی عملکرد شبکه برای حل TSP، پاسخ‌های آن برای ۵ توزیع ۱۰ شهری، ۵ توزیع ۲۰ شهری و در نهایت ۵ توزیع ۱۵۰ شهری محاسبه شده است. از آنجاکه طول مسیرها در هر

گون از بین رفت، دینامیک‌های گرادیان نزولی، رفتار دینامیکی واحد عصب تکلی را کنترل می‌کند؛ هنگامی که رفتار واحد عصب تکلی شبیه به هاپفیلد است، شبکه تمایل به همگرایی به نقطه تعادل پایدار را دارد. همان‌طور که در شکل (۳) مشاهده می‌شود $x(t)$ در حدود ۸۰۰ تکرار اول رفتاری پیش‌بینی نشده دارد و سرانجام پس از حدود ۱۲۰۰ تکرار به سمت یک نقطه تعادل پایدار از طریق یک انشعاب دو برابر شدن متناوب معکوس، همگرا می‌شود. مطابق شکل (۴) با توجه به اینکه نمای لیاپانوف در حدود ۸۰۰ تکرار اول اغلب مثبت است، رفتار در این ناحیه به صورت آشوبی و با پنجره‌های متناوب ممکن شناخته می‌شود.

شکل‌های (۳) و (۴) نشان می‌دهند که نوسان‌های آشوب به مرور با میرایی $z(t)$ کاهش می‌یابند و سرانجام از بین می‌روند؛ البته سرعت این تغییرات به ضریب میرایی β بستگی دارد. به طوری که هر چقدر β کوچک‌تر باشد، دینامیک آشوبی $x(t)$ مدت زمان بیشتری تداوم می‌یابد. این ویژگی، نشان‌دهنده نوعی از دینامیک آشوبی است و هرگاه مقدار $z(t)$ به اندازه کافی کاهش یابد، ساختار دینامیکی شبکه تقریباً بر شبکه عصبی هاپفیلد منطبق می‌شود.

روش جستجوی آشوبی شبکه‌های عصبی آشوب‌گون در یافتن نقطه بهینه سراسری، وابستگی نداشتن به شرط اولیه است؛ بنابراین با هر شرط اولیه‌ای به جواب بهینه می‌رسند؛ البته مشکل اصلی در این شبکه‌ها حساسیت زیاد به تنظیم پارامترهای شبکه است و بنابراین ممکن است با تغییر در پارامترها باز هم در کمینه محلی گرفتار شوند؛ اما احتمال گرفتار شدن آن‌ها نسبت به شبکه‌های سنتی کمتر است.

برای ارزیابی شبکه از TSP متقارن با ۱۰ شهر مختلف استفاده شده است. نتایج نشان می‌دهد با در نظر گرفتن $z(t)$ به صورت نمایی میراشونده و انتخاب $\beta=0.006$ به بیشترین نرخ کمینه سراسری ۱۰۰ درصد و نرخ کمینه محلی صفر درصد رسیده و متوسط تعداد تکرارها برای همگرایی ۲۱۱ است. مرجع [۲۹] به ازای $\beta=0.002$ به نرخ کمینه سراسری تقریباً ۱۰۰ درصد دست یافته است؛ در حالی که مقاله حاضر به نرخ کمینه سراسری ۱۰۰ درصد رسیده است. تعداد تکرارها در [۸] برای رسیدن به نرخ کمینه سراسری ۱۰۰ درصد ۳۹۸ است؛ بنابراین در این مقاله تعداد تکرارها

مرجع [۱۰] نشان می‌دهد زمانی که مقدار β از یک حدی افزایش می‌یابد، فشار وارده بر سیستم در افزایش سرعت بیشتر می‌شود. به طور خلاصه نتایج پژوهش در برخی موارد [۳۵،۳۴،۲۹،۱۰۸] بهبود خوبی را نسبت به پژوهش‌های گذشته نشان می‌دهد. در برخی موارد نتایج پژوهش‌های گذشته [۳۶،۲۹،۲۸] نتایج تحقیق را تأیید می‌کنند.

۴- بحث و نتیجه‌گیری

در این پژوهش از ترکیب هم‌افزای شبکه عصبی آشوب‌گون با پسخوراند خودی، نمای لیاپانوف و تبرید تدریجی به منظور حل بهینه مسائل بهینه‌سازی ترکیبی نظیر TSP با تعداد شهرهای مختلف استفاده می‌شود. شبکه‌های عصبی آشوبی دینامیک فضایی - زمانی غنی‌تر و ساختار پیچیده‌تری دارند؛ بنابراین انتظار می‌رود توان بالایی برای یافتن نقطه بهینه سراسری و یا نزدیک به سراسری داشته باشند. از مهم‌ترین مشکلات شبکه‌های مصنوعی سنتی گرفتاری آن‌ها در کمینه‌های محلی و همگرایی به سمت نقطه تعادل مطلوب است؛ بنابراین در این مقاله سعی شده است با افزودن نمای لیاپانوف و یک پارامتر کنترلی $z(t)$ به شبکه به عنوان تبرید تدریجی، نحوه خروج از دینامیک آشوبی به سمت نقطه تعادل پایدار و رفتار متناوب را کنترل کرد؛ البته اگرچه دینامیک شبکه عصبی آشوب‌گون دارای ویژگی حرکت آشوبی در فضای حالت با ساختار فرکتالی بوده است و سبب حل نسبی گرفتاری در کمینه محلی می‌شود، اما مشکل همگرایی دینامیک آشوبی هنوز به نحو مطلوبی حل نشده است. به منظور به دست آوردن دو مزیت دینامیک‌های همگرایی و آشوبی، شبکه عصبی آشوبی با پسخوراند خودی استفاده شده است.

در این پژوهش پارامتر کنترلی $z(t)$ به صورت نمایی میراشونده و تانژانت هاپیبولیک در نظر گرفته شده است. شکل (۳) نشان می‌دهد عصب دارای رفتار دینامیکی آشوب‌گون است. واحد عصبی تکلی ابتدا به صورت جستجوی آشوب‌گون سراسری رفتار می‌کند و با کاهش مقدار $z_i(t)$ انشعاب معکوس به تدریج به حالت تعادل پایدار همگرا می‌شود. پس از اینکه رفتار دینامیکی آشوب

- NDRAM Network,” IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, pp. 3500-3504, 2008.
- [3] He, G., Shrimali, M. D., Aihara, K., “Threshold Control of Chaotic Neural Network,” Neural Networks, Vol. 21, No. 2-3, pp. 114-121, 2008.
- [4] Kim, S. H., Hong, S. D., Park, W. W., “An Adaptive Neurocontroller with Modified Chaotic Neural Networks,” International IEEE Joint Conference on Neural Networks, Washington, DC, Vol. 1, pp. 509-514, 2001.
- [5] Kwok, T., Smith K. A., “Experimental Analysis of Chaotic Neural Network Models for Combinatorial Optlmization under a Unifying Framework,” Neural Network, Vol. 13, No. 5, pp. 731-744, 2000.
- [6] Bersini, H., Sener, P., “The Connections between the Frustrated Chaos and the Intermittency Chaos in Small Hopfield Networks,” Neural Networks, Vol. 15, No. 10, pp. 1197–1204, 2002.
- [7] Hasegawa, M., Ikeguchi, T., Aihara, K., “Solving Large Scale Traveling Salesman Problems by Chaotic Neurodynamics Problems,” Neural Network, Vol. 15, No. 1, pp. 271-283, 2002.
- [8] Chen, L., Aihara, K., “Chaotic Simulated Annealing by A Neural Network Model with Transient Chaos,” Neural Networks, Vol. 8, No. 6, pp. 915–930, 1995.
- [9] Zhao, L., Sun, M., Cheng, J., Xu, Y., “A Novel Chaotic Neural Network with the Ability to Characterize Local Features and its Application,” IEEE Transactions on Neural Networks, Vol. 20, No. 4, pp. 735-742, 2009.
- [10] Xu, Y., Yang, X., “Chaotic Neural Network with Sigmoid Function Self-Feedback,” 6th International Conference on Natural Computation, pp. 1605-1609, 2010.
- [11] Aihara, K., Takabe, T., Toyoda, M., “Chaotic Neural Networks,” Phys. Lett. A, Vol. 144, No. 6-7, pp. 333–340, 1990.
- [12] Chartier, S., Boukadoum, M., “A Chaotic Bidirectional Associative Memory,” Proceedings of Maghrebian Conference on Software Engineering and Artificial Intelligence, Agadir, Morocco, pp. 498-501, 2006.
- [13] Chartier, S., Renaud, P., Boukadoum, M., “A Nonlinear Dynamic Artificial Neural Network Model of Memory,” New Ideas in Psychology, Vol. 26, No. 2, pp. 252-277, 2007.
- [14] Weise, T., Chiong, R., Lassig, J., Tang, K., Tsutsui, S., Chen, W., Michalewicz, Z., Yao, کاهش یافته است و در نتیجه سرعت همگرایی بیشتر شده است. همچنین از نظر سرعت همگرایی نتایج این پژوهش بهتر از [۳۴،۳۵] است. همچنین نرخ پاسخ‌های نشدنی در [۳۶] نیز صفر است که نتایج این پژوهش را تأیید می‌کند. همچنین نرخ پاسخ‌های نشدنی در [۳۷] به جز یک مورد صفر است.
- همچنین با در نظر گرفتن $z(t)$ به صورت تانژانت هایپربولیک و انتخاب $\beta=0.004$ به بیشترین نرخ کمینه سراسری ۱۰۰ درصد و نرخ کمینه محلی صفر درصد رسیده و متوسط تعداد تکرارها برای همگرایی ۲۸۷ است. همچنین نرخ پاسخ‌های نشدنی در [۳۷] تقریباً صفر است. همچنین جدول‌های ۱ و ۲ نشان می‌دهند متوسط تعداد تکرارها برای همگرایی به ازای مقادیر مختلف β به ترتیب ۲۳۰ و ۲۷۰ است؛ بنابراین به نظر می‌رسد با در نظر گرفتن $z(t)$ به صورت نمایی میراثونده بتوان به تعداد تکرارهای کمتری دست یافت.
- همچنین به منظور بررسی عملکرد شبکه عصبی آشوب‌گون برای حل TSP، پاسخ‌های آن برای ۵ توزیع ۱۰ شهری، ۵ توزیع ۲۰ شهری و در نهایت ۵ توزیع ۱۵۰ شهری در شکل (۶) محاسبه شده است. نتایج شبیه‌سازی نشان می‌دهد، این شبکه می‌تواند جواب بهینه را در مسائل بهینه‌سازی ترکیبی نظیر TSP پیدا کند. همچنین نتایج نشان می‌دهد در برخی موارد بهبود خوبی نسبت به پژوهش‌های گذشته [۳۵،۳۴،۲۹،۱۰،۸] حاصل شده است. در برخی نیز، نتایج پژوهش‌های گذشته را تأیید می‌کند [۳۶،۲۹،۲۸]. در مقایسه با پژوهش‌های گذشته مشاهده می‌شود متوسط زمان همگرایی و تعداد تکرارهای آن برای هر توزیع از شهرهای آزمایش شده بهبود یافته است.

مراجع

- [1] Freeman, W. J., “Strange Attractors that Govern Mammalian Brain Dynamics Shown by Trajectories of Electroencephalographic (EEG) Potential,” IEEE Transaction on Circuits and systems, Vol. 35, No. 7, pp. 781-783, 1988.
- [2] Taherkhani, A., Mohammadi, A., Seyedsalehi, S. A., Davande, H., “Design of a Chaotic Neural Network by using Chaotic Nodes and

- 1106–1111, 1999.
- [25] Uwate, Y., Nishio, Y., Ikeguchi, T., “Associative Memory by Hopfield NN with Chaos Injection,” *IEEE International Joint Conference on Neural Networks*, Vol. 1, 2004.
- [26] Kanter, I., Sompolinsky, H., “Associative Recall of Memory without Errors,” *Physical Review A*, Vol. 35, No. 1, p. 380, 1987.
- [27] Taherkhani, A., Javadi, S., Moeini, S., “Design of a chaotic feed forward neural network,” *IEEE Computational Intelligence in Electrical Engineering*, Vol. 2, No. 4, pp. 21- 34, 2012.
- [28] Xu, Y., Yang, X., “A class of Chaotic Neural Network with Morlet Wavelet Function Self-feedback,” in *Bio-Inspired Computing and Applications*, Springer, 7th International Conference on Intelligent Computing, pp. 32–40, 2012.
- [29] Ye, Y., “Bessel Function Self-Feedback Chaotic Neural Network Model and Applications,” *International Journal of Hybrid Information Technology*, Vol. 7, No. 4, pp. 19–28, 2014.
- [30] Xu, X., Tang, Z., Wang, J., “A Method to Improve the Transiently Chaotic Neural Network,” *Neurocomputing*, Vol. 67, pp. 456-463, 2005.
- [31] Kurths, J., Herzel, H., “An Attractor in Solar Time Series,” *Physica D*, Vol. 25, No. 1-3, pp. 165-172, 1987.
- [32] Wolf, A., Swift, J. B., Swinney, H. L., Vastano, J. A., “Determining Lyapunov Exponents from a Time Series,” *Physica*, Vol. 16, No. 3, pp. 285-317, 1985.
- [33] Wilson, G. V., Pawley, G. S., “On the Stability of the Traveling Salesman Problem Algorithm of Hopfield and Tank,” *Biological Cybernetics*, Vol. 58, No. 1, pp. 63-70, 1988.
- [34] Zhou, C.S., Chen, T. L., Huang, W.Q., “Chaotic Neural Network with Nonlinear Self-feedback and Its Application in Optimization,” Vol. 14, No. 3, pp. 209-222, 1997.
- [35] Zhou, C.S., Chen, T. L., “Chaotic Annealing for Optimization,” *Phys. Rev. E*, Vol. 55, No. 3, pp. 2580-2587, 1997.
- [36] Yang, L.J., Chen, T. L., Huang, W.Q., “Dynamics of Transiently Chaotic Neural Network and Its Application to Optimization,” *Communications in Theoretical Physics*, Vol. 35, No. 1, pp. 22-27, 2001.
- [37] Xu, Y., Zhao, T., “Chaotic Neural Network with Nonlinear Function Self-feedback,” 33rd Chinese Control Conference, pp. 5075 - 5079, 2014.
- X., “Benchmarking Optimization Algorithms: An Open Source Framework for the Traveling Salesman Problem,” Vol. 9, No. 3, pp. 40-52, 2014.
- [15] Fujimura, K., Fujiwaki, S., Kwaw, O. C., Tokutaka, H., “Optimization of Electronic Chip-mounting Machine using SOM-TSP Method with 5 Dimensional Data,” *International Conferences on Info-tech and Info-net*, Vol. 4, pp. 26-31, 2001.
- [16] Mehmet-Ali, M. K., Kamoun, F., “Neural Networks for Shortest Path Computation and Routing in Computer Networks,” *IEEE Transactions on Neural Networks*, Vol. 4, No. 6, pp. 941-954, 1993.
- [17] Saadatmand-Tarzjan, M., Khademi, M., Akbarzadeh-T., M. R., Abrishami-Moghaddam. H., “A Novel Constructive-Optimizer Neural Network for the Traveling Salesman Problem,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, Vol. 37, No. 4, pp. 754 - 770, 2007.
- [18] Tian, F., Wang, L., “Chaotic Simulated Annealing with Augmented Lagrange for Solving Combinatorial Optimization Problems,” 26th Annual Conference of the IEEE Industrial Electronics Society, Vol. 4, pp. 2722 -2725, 2000.
- [19] Osaba, E., Diaz, F., “Comparison of a Memetic Algorithm and a Tabu Search Algorithm for the Traveling Salesman Problem,” *Conference on Computer Science and Information Systems*, pp. 131-136, 2012.
- [20] Nguyen, H. D., Yoshihara, I., Yamamori, K., Yasunaga, M., “Implementation of an Effective Hybrid GA for Large-Scale Traveling Salesman Problems,” *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, Vol.37 , No.1, pp. 92-99, 2007.
- [21] Li, M., “Efficiency Improvement of Ant Colony Optimization in Solving the Moderate LTSP,” *Journal of Systems Engineering and Electronics*, Vol. 26, No. 6, pp. 1300-1308, 2015.
- [22] Kirkpatrick, S., Gelatt, C. D., Vecchi, M. P., “Optimization by Simulated Annealing,” *Science*, Vol. 220, No. 4598, pp. 671–680, 1983.
- [23] Akiyama, Y., Yamashira, A., Kajiura, M., Anzal, Y., Aiso, H., “The Ganssian Machine: a Stochastic Neural Network for Solving Assignment Problems,” *Journal of Neural Network Computation*, Vol. 2, pp. 43-51, 1991.
- [24] Nakagawa, M., “A Novel Chaos Associative Memory,” 6th International Conference on Neural Information Processing, Vol. 3, pp.

-
- ¹ Chaos
 - ² Freeman
 - ³ Natural selection theory
 - ⁴ Static
 - ⁵ Gradient descent dynamics
 - ⁶ Chaotic Neural Network
 - ⁷ Self-feedback
 - ⁸ Travelling Salesman Problem
 - ⁹ NP-hard (NP: Nondeterministic polynomial)
 - ¹⁰ NP-complete
 - ¹¹ Simulated Annealing
 - ¹² Tabu Search
 - ¹³ Genetic Algorithm
 - ¹⁴ Ant Colony Optimization
 - ¹⁵ Offilne
 - ¹⁶ Kirkpatrick
 - ¹⁷ Akiyama
 - ¹⁸ Auto-Association
 - ¹⁹ Hetro-Association
 - ²⁰ Hebbian learning
 - ²¹ Chen
 - ²² Aihara
 - ²³ Transient
 - ²⁴ Xu
 - ²⁵ Yang
 - ²⁶ Sigmoid
 - ²⁷ Xu
 - ²⁸ Yang
 - ²⁹ Morlet wavelet
 - ³⁰ Ye
 - ³¹ Bessel
 - ³² Spatio-temporal dynamics
 - ³³ Scaling
 - ³⁴ Damping
 - ³⁵ Steepness
 - ³⁶ Biforcation
 - ³⁷ Hopfiled
 - ³⁸ Lyapunov exponents
 - ³⁹ Sonia Kovalevskaia
 - ⁴⁰ Aleksandr Mikhailovich Lyapunov
 - ⁴¹ Wolf
 - ⁴² Orbital instability
 - ⁴³ Infeasible

۷۶ ترکیب بهینه شبکه عصبی آشوب‌گون با پس‌خوراند خودی، نمای لیاپانوف و تبرید تدریجی در حل مسئله فروشنده دوره‌گرد