

پیش‌بینی نرخ ترافیک ورودی به مسیریاب با استفاده از شبکه عصبی با قابلیت وزن‌های دینامیک‌دار

مریم شکیبا^۱، محمد تشنه‌لب^۲، سعدان زکایی^۳

۱- مربی، دانشگاه صنعتی جندی شاپور دزفول، shakiba@jsu.ac.ir

۲- دانشیار، دانشگاه صنعتی خواجه نصیرالدین طوسی، teshnehlab@eedt.kntu.ac.ir

۳- دانشیار، دانشگاه صنعتی خواجه نصیرالدین طوسی، szokaei@eedt.kntu.ac.ir

چکیده

با توجه به مشکلات ترافیکی موجود در مسیریاب رابط میان مرکز تحقیقات مخابرات ایران و شرکت دیتا، در این مقاله هدف پیش‌بینی نرخ ترافیک ورودی به این مسیریاب به منظور جلوگیری از ازدحام در این گره می‌باشد. این پیش‌بینی با استفاده از شبکه عصبی با قابلیت وزن‌های دینامیک‌دار انجام شده که دقت بسیار بالایی در پیش‌بینی سری‌های زمانی آشوبناک نسبت به دیگر شبکه‌های عصبی حافظه‌دار از جمله شبکه‌های عصبی گاما، پویا و TDL دارد. در این روش نوین، پیش‌بینی نرخ ترافیک با استفاده از شبکه عصبی با قابلیت وزن‌های دینامیک‌دار انجام شده که در آن، پارامترهای شبکه عصبی مذکور با استفاده از الگوریتم بهینه‌سازی گروه ذرات بهینه شده‌اند. در مرحله بعد پیش‌بینی سری زمانی مورد نظر به کمک شبکه عصبی TDL صورت پذیرفته است. نتایج، حاکی از برتری روش پیشنهادی، به منظور پیش‌بینی دقیق سری زمانی است.

واژه‌های کلیدی

شبکه عصبی با قابلیت وزن‌های دینامیک‌دار، الگوریتم بهینه‌سازی گروه ذرات، شبکه عصبی TDL، پیش‌بینی


سری‌های زمانی

۱- مقدمه

مسیریاب‌ها ناچارند بسته‌ها را در بافر خود صف^۱ کنند اما بعد از مدتی صف پر شده و مسیریاب ناچار می‌شود بسته‌های اضافی را دور بریزد^۲، حال چون بسته به گیرنده نمی‌رسد و فرستنده هم اعلان وصول بسته^۳ را دریافت نمی‌کند، فرستنده بسته را دوباره ارسال خواهد کرد. تنها راه حل قطعی ازدحام، کاهش نرخ ارسال فرستنده ها است. برای حل این مشکلات مکانیزم‌های کنترل ازدحام جدید که متکی به پنجره‌های دینامیک هستند به پروتکل TCP^۴ افزوده شد. در این میان استفاده از شبکه‌های عصبی می‌تواند نقش به‌سزایی در


در کنترل ترافیک شبکه‌های مخابراتی با دو مبحث روبرو هستیم: کنترل جریان و کنترل ازدحام [۱]. در کنترل جریان، هدف آن است که از هماهنگی سرعت دریافت گیرنده و سرعت ارسال فرستنده اطمینان حاصل کنیم، بدین معنی که فرستنده آنقدر سریع بسته‌ها را ارسال نکند که بافر گیرنده سرریز و پر شود. اما در کنترل ازدحام، هدف اطمینان از تحویل داده شدن صحیح بسته‌های داده به گیرنده توسط شبکه است. ازدحام به دلیل اشباع شدن منابع شبکه (لینک‌ها، بافرها و مسیریاب‌ها) رخ می‌دهد. وقتی ازدحام رخ می‌دهد،

انعطاف‌پذیری سیناپسی^۵ است بدین معنی که در سلول‌های عصبی واقعی دو عامل تشدید و تضعیف در احتمال آزادسازی نوروترنسمیترها تأثیر دارند. با توجه به اینکه انتقال اطلاعات توسط آزادسازی نوروترنسمیترها در فضای سیناپسی رخ می‌دهد مشاهده شده است که اگر فاصله بین دو تحریک کمتر از ۲۰ میلی‌ثانیه باشد پاسخ نرون نسبت به آن تحریک تضعیف می‌شود. اعتقاد بر این است که این مسئله به خاطر پاسخ زمانی کانال Ca^{2+} است که مستقیماً در آزادسازی نوروترنسمیتر نقش دارند. با توجه به پاسخ زمانی طولانی کانال Ca^{2+} ، این کانال‌ها به‌کندی خنثی می‌شوند و به همین خاطر اگر تحریک نرون پیش‌سیناپسی در فاصله کمی از تحریک قبلی وارد شود، کانال فرصت کافی برای غیرفعال کردن خود و آماده شدن برای انتقال تحریک جدید را ندارد. به همین دلیل تحریک دوم نمی‌تواند جریان مورد نیاز Ca^{2+} را تولید کند تا باعث شود کیسه‌های حاوی نوروترنسمیتر مواد داخل خود را در فضای سیناپسی آزاد کنند. چنین فرآیندی همانند یک فیلتر پایین‌گذر عمل می‌کند که همان حالت افسردگی نرون است. فرآیند مخالف حالت قبل زمانی اتفاق می‌افتد که فاصله زمانی بین دو تحریک بین ۲۰ تا ۵۰ میلی‌ثانیه باشد. فرآیند کار بدین ترتیب است که باقی ماندن Ca^{2+} و رسوب آن بر روی ترمینال نرون پیش‌سیناپسی آزادسازی بسته‌های نوروترنسمیتری را مشکل می‌سازد. ولی اگر فاصله دو تحریک زیاد باشد به‌علت پاکسازی داخلی یون Ca^{2+} از ترمینال‌های خروجی نرون‌های پیش‌سیناپسی، وضعیت آزادسازی به حالت اولیه خود باز می‌گردد. این حالت، وضعیت نشاط در نرون می‌باشد.



شکل ۳- پاسخ سیناپس در حالت نشاط

بهبود الگوریتم‌های کنترل ازدحام داشته باشد. بنابراین سعی ما در این پروژه پیاده‌سازی شبکه عصبی با قابلیت وزن‌های دینامیک‌دار به‌منظور پیش‌بینی [۲] دقیق سیگنال‌های ترافیکی است. این شبکه عصبی به پیش‌بینی مقدار آتی نرخ ترافیک ورودی به مسیریاب در چند برهه زمانی بعد که افق پیش‌بینی نام دارد، می‌پردازد. داده‌های تحت بررسی نمونه‌های اندازه‌گیری شده در ماه‌های آذر، دی، بهمن و اسفند سال ۱۳۸۵ در مسیریاب واسط مرکز تحقیقات مخابرات ایران و شرکت دیتا می‌باشد. شکل (۱) نمودار این سری زمانی را نشان می‌دهد. نرخ نمونه‌برداری انجام شده هر ۳۵ دقیقه می‌باشد.



شکل ۱- داده‌های سری زمانی مربوط به نمونه‌برداری انجام شده در ماه‌های آذر، دی، بهمن و اسفند و با نرخ نمونه‌برداری ۳۵ دقیقه یکبار


۲- شبکه عصبی با قابلیت وزن‌های دینامیک‌دار

در دو دهه اخیر تحقیقات بر روی شبکه‌های عصبی مصنوعی بیشتر بر روی نقش سیناپس در محاسبات متمرکز شده است و به این نتیجه رسیده‌اند که سیناپس در خود دارای دینامیک می‌باشد [۳]. در شبکه‌های عصبی معمولاً سیناپس‌ها به‌صورت ضرایبی ثابت در نظر گرفته می‌شوند. در شبکه‌های عصبی طبیعی سیناپس‌ها از خود دینامیکی در یک زمان بسیار کوچک در حد چند میلی‌ثانیه و یا در زمان‌های نسبتاً طولانی‌تر در حد یک ثانیه نشان می‌دهند. شبکه عصبی مصنوعی با وزن‌های دینامیک‌دار، با مدل نمودن دینامیک موجود در سیناپس‌های طبیعی، طراحی شده‌اند. در واقع در سیستم عصبی واقعی انتقال سیناپسی ذاتاً فرآیندی اتفاقی است. بدین معنا که اگر یک پالس تحریک به یک نرون پیش‌سیناپسی برسد، آزادسازی مواد از کیسه‌های حاوی نوروترنسمیتر با احتمالی کمتر از یک رخ می‌دهد. مسئله دیگری که در سلول‌های عصبی واقعی رخ می‌دهد و تا کنون کمتر مورد توجه واقع شده،

همچنین پارامتر U_{ij} نشان‌دهنده احتمال اولیه برای آزادسازی نروترنسmitter است. معادلات برای بیان ارتباط بین ورودی j -ام از نرون پیش‌سیناپسی به نرون i -ام پس‌سیناپسی است. از نظر شماتیک ساختار این شبکه با یک لایه میانی در شکل (۴) آمده است. تمایز آن با شبکه‌های تک‌لایه معول کنونی در آن است که وزن سیناپسی w_{ij} بین نود i و j در عبارت p_{ij} هم ضرب می‌شود [۳].

۳- الگوریتم شبکه پیشرو

در این شبکه بردار خروجی لایه ورودی در ماتریس P ضرب می‌شود و با مقدار B که مقدار آفست شبکه می‌باشد جمع شده و بردار ورودی نرون‌های لایه میانی را تشکیل می‌دهند [۳].



شکل ۴- ساختار شبکه عصبی با قابلیت وزن‌های دینامیک‌دار

این محاسبات به صورت ماتریسی در زیر آورده شده است. آنگاه مقدار خروجی از لایه میانی به صورت زیر می‌باشد، که به منزله ورودی لایه بعدی می‌باشد.

$$Net^1 = (W^T * P^1) \cdot X + B^1 \quad (4)$$

$$[Net^1]_{n_1 \times 1} = [W^T]_{n_1 \times n_0} * [P^1]_{n_0 \times n_0} \cdot [X]_{n_0 \times 1} + [B^1]_{n_1 \times 1} \quad (5)$$

$$O_e^1 = \log \text{sig}(Net^1(1 : n_e))$$

$$O_i^1 = \log \text{sig}(Net^1(1 : n_i))$$

$$O^1 = [o_e^1 o_e^2 \dots o_e^{n_e} o_i^1 o_i^2 \dots o_i^{n_i}]$$

در رابطه (۶) وزن‌های مربوط به نرون‌های تحریک‌کننده (E) مثبت و وزن‌های مربوط به نرون‌های ساکن‌کننده (I) منفی در نظر گرفته می‌شود.

آنچه بیان شد در صورتی که به صورت ریاضی بیان شود، می‌تواند در مدل شبکه‌های عصبی کنونی وارد شود. شبکه‌هایی که ساختار آنها از چنین مدلی پیروی می‌کند با نام شبکه‌های سیناپسی دینامیک‌دار [۳] در ادبیات موجود علم شبکه‌های عصبی شناخته می‌شوند. شکل‌های (۲ و ۳) پاسخ سیناپس را در حالت افسردگی و نشاط نشان می‌دهند. مدل‌های مختلفی برای پیاده‌سازی ایده‌های بالا روی شبکه‌های عصبی مصنوعی داده شده است. روابط مدل استفاده شده در معادلات زیر آورده شده‌اند. علت استفاده از این مدل سهولت آموزش آن و واضح بودن فرمول‌های مربوطه بود. منابع مربوط به مدل‌های دیگری که برای این شبکه عصبی مورد استفاده قرار می‌گیرد در مراجع بیان شده است [۴-۶]. همان‌طور که گفته آنچه که باید به مدل کنونی شبکه‌های عصبی افزوده شود، احتمالاتی شدن در مورد وزن‌ها می‌باشد [۳]. این کار با وارد کردن عامل افسردگی^۷ و تسهیل^۸ و بیان آنها به صورت دو معادله دیفرانسیل مرتبه اول با ثابت زمانی‌های متفاوت و استفاده از حاصل ضرب این دو به عنوان احتمال برقراری ارتباط بین دو نرون استفاده کرد. در این معادلات $f_{ij}(t)$ کمیتی است که تمایل طبیعی سیناپس را برای آزاد کردن یون‌های Ca^{2+} نشان می‌دهد. این تمایل از طریق فعالیت پیش‌سیناپسی ($X_{ij}(t)$) افزایش می‌یابد. توابع f و d در واقع توانایی یا عدم توانایی کانال کلسیم در انتقال تحریک از نرون پیش‌سیناپسی به نرون سیناپسی را نشان می‌دهند که حاصل ضرب این در تابع همان احتمال انتقال (p) توسط کانال کلسیم است. در این حالت معادله مربوط به تضعیف با معادله مربوط به تشدید ترکیب می‌شود. در زیر معادلات مربوط به یک سیناپس در حالت گسسته آورده شده است [۳].

$$P_{ij}(t) = f_{ij}(t) \cdot d_{ij}(t) \quad (1)$$

$$\bar{f}_{ij}(t+1) = \bar{f}_{ij}(t) - \frac{\bar{f}_{ij}(t)}{F_{ij}} + U_{ij} \cdot (1 - \bar{f}_{ij}(t)) \cdot x_j(t)$$

$$d_{ij}(t+1) = d_{ij}(t) + \frac{1 - d_{ij}(t)}{D_{ij}} - P_{ij}(t) \cdot x_j(t)$$

$$f_{ij}(t) = \bar{f}_{ij}(t) \cdot (1 - U_{ij}) + U_{ij}$$

شرایط اولیه در این حالت برابر خواهد بود با:

$$d_{ij}(1) = 1 \quad \text{و} \quad \bar{f}_{ij}(1) = 0 \rightarrow f_{ij}(1) = U_{ij} \quad (2)$$

تحت این شرایط باید داشته باشیم:

$$D_{ij} > 1 \quad (3)$$


در رابطه (۱) فاکتور تسهیل را با $F_{ij} > 1$ ثابت زمانی F_{ij} مدل می‌کند و $d_{ij}(t)$ تاثیر ترکیب افسردگی و تسهیل را با یک معادله دیفرانسیل مرتبه اول با ثابت زمانی D_{ij} مدل می‌نماید.

$$w = w_0 + r(1 - w_0) \quad (10)$$

که در آن w_0 مقداری مثبت است و مقدار پیشنهادی برای آن در بازه [۰,۵] قرار دارد. r نیز عددی مثبت است که به صورت اتفاقی در بازه [۰,۱] تولید می‌شود. در ادامه از شبکه عصبی TDL^{۱۲} که در آن قابلیت حافظه دار شدن شبکه در ورودی‌ها اعمال شده است، نیز برای پیش‌بینی این سری زمانی استفاده شده و نتایج حاصل با شبکه عصبی با قابلیت وزن‌های دینامیک‌دار مقایسه شده است. شبکه TDL استفاده شده از یک لایه ورودی، دو لایه میانی و یک لایه خروجی تشکیل یافته است. در لایه ورودی، ورودی‌ها با چهار درجه تأخیر اعمال شده‌اند. در هر لایه میانی پنج نرون و در لایه خروجی یک نرون وجود دارد. در ساختار شبکه عصبی با قابلیت وزن‌های دینامیک‌دار، از یک لایه ورودی، یک لایه میانی و یک لایه خروجی استفاده شده است. ورودی‌ها با دو درجه تأخیر، اعمال می‌شوند و لایه میانی دوازده نرون و لایه خروجی یک نرون دارد. به این ترتیب تعداد پارامترها در این ساختار برابر با ۱۴۴ خواهد بود. همچنین تعداد جمعیت‌های استفاده شده برای هر یک از پارامترهای $W^1, W^2, U^1, D^1, F^1, U^2, D^2, F^2$ برابر با ۲۰ می‌باشد. طبق رابطه (۱۱) از تابع RMSE به عنوان تابع هزینه استفاده شده است. در شکل‌های (۵) و (۶) نتایج شبیه‌سازی‌ها نشان داده شده است.

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (o(n) - d(n))^2} \quad (11)$$

که در آن $d(n)$ خروجی مطلوب و $o(n)$ خروجی شبکه عصبی در لحظه n -ام است. با توجه به شبیه‌سازی‌های انجام شده، مقدار معیار خطای RMSE برای شبکه TDL برابر با ۰,۱۳۹۶۸ و برای شبکه عصبی با قابلیت وزن‌های دینامیک‌دار برابر با ۰,۰۸۲۲ می‌باشد.



شکل ۵- پیش‌بینی با استفاده از بهینه‌سازی پارامترهای شبکه

به وسیله الگوریتم بهینه‌سازی AWPSO

$$Net^2 = \sum_{k \in E} W_k^2 \cdot P_k^2 \cdot O_k^2 + \sum_{k \in I} W_k^2 \cdot P_k^2 \cdot O_k^2 \quad (6)$$

E : Exhibitory, I : Inhibitory

$$Output = Net^2 \quad (7)$$

که در آن، n_0 تعداد نرون‌های ورودی، n_1 تعداد نرون‌های لایه میانی، n_2 تعداد نرون‌های لایه خروجی و T همان اپراتور ترانسپوز^{۱۰} است.

۴- بهینه‌سازی پارامترهای شبکه با استفاده از الگوریتم

بهینه‌سازی AWPSO

با توجه به وجود برخی مشکلات در آموزش پارامترهای شبکه عصبی با قابلیت وزن‌های دینامیک‌دار با استفاده از الگوریتم گرادیان نزولی از جمله فرارگیری پاسخ نهایی در کمینه‌های محلی و بی‌حساسیت نسبت به شرایط اولیه پارامترها، در این مقاله هدف، بهینه‌سازی پارامترهای شبکه عصبی با استفاده از الگوریتم AWPSO و مقایسه کارایی آن با آموزش پارامترها به کمک الگوریتم گرادیان نزولی در شبکه عصبی TDL می‌باشد. الگوریتم AWPSO^{۱۱} [۷] برای افزایش راندمان الگوریتم بهینه‌سازی اجتماع پرندگان در مسائل بهینه‌سازی، پیشنهاد شده که در آن بردار سرعت ذرات با استفاده از فرمول زیر به‌روز شود:

$$V_i(t+1) = wV_i(t) + \quad (8)$$


$$\alpha[r_1(X_i^{PB}(t) - X_i(t)) + r_2(X_i^{GB}(t) - X_i(t))]$$

بخش دوم معادله بالا، جمله‌ای افزایشی است. که در آن افزایش، وابسته به فاصله هر ذره (X_i) از بهترین تجربه شخصی خود (X_i^{PB}) و نیز فاصله‌اش از بهترین تجربه گروهی (X_i^{GB}) می‌باشد فاکتور افزایشی بالا به صورت زیر تعریف می‌شود:

$$\alpha = \alpha_0 + \frac{t}{N_t} \quad t = 1, 2, \dots, N_t \quad (9)$$

که در آن N_t تعداد دفعات تکرار در برنامه و t شماره تکرار است. محدوده پیشنهادی برای ثابت α_0 بازه [۰,۵] می‌باشد. همان‌طور که در معادله بالا مشخص است، با افزایش تعداد دفعات مقدار α افزایش می‌یابد. بنابراین این پارامتر باعث افزایش توانایی جستجوی اساسی در دفعات آخر اجرای برنامه می‌شود. علاوه بر پارامتر α ، در این الگوریتم به جای استفاده از وزن لختی که به صورت خطی کاهش یابد، مقدار آن به صورت اتفاقی و طبق معادله زیر بدست می‌آید. این معادله توسط Zhang اثبات شده است.

- [3] Thomas Natschläger, Wolfgang Maass, Anthony Zador; **Efficient Temporal Processing with Biologically Realistic Dynamic Synapses**, Network: Computer. Neural Syst, pp.75-87, Vol. 12, 2001.
- [4] N. Mehrtaash, D. Jung, H. Klar; **Image Preprocessing with Dynamic Synapses**, Neural Computer & Application, pp.33-41, Vol. 12, No. 1 / September, 2003.
- [5] J. Gao, Ph. Holmes, **On the dynamics of electrically-coupled neurons with inhibitory synapses**, J Comput Neurosci, pp. 5-100, Volume 22, Number 1 / February, 2007.
- [6] Narayanan Kasthuri, Jeff W Lichtman; **Structural Dynamics of Synapses in Living Animals**, Current Opinion in Neurobiology 2004, 14: pp.105-111, PMID: 15018945.
- [7] Mahdi Mahfouf, Min-You Chen, and Derek Arthur Linkens, Adaptive Weighted Particle Swarm Optimization for Multi-objective Optimal Design of Alloy Steels, Department of Automatic Control and Systems Engineering, The University of Sheffield, Technical Report, 2004, ISBN: 978-3-540-23092-2, pp. 762-771, Vol. 3242, 2004.



شکل ۶- پیش‌بینی با استفاده از شبکه TDL

علت برتری مطلق روش پیشنهادی نسبت به روش استفاده از شبکه عصبی TDL در پیش‌بینی سری زمانی، اهمیت حافظه‌دار کردن وزن‌های شبکه دینامیکی در مقایسه با اعمال حافظه در ورودی‌ها، در شبکه TDL است. همچنین استفاده از الگوریتم بهینه‌سازی AWPSO احتمال قرارگیری در کمینه‌های محلی و همچنین حساسیت نسبت به شرایط اولیه پارامترها را به حداقل می‌رساند.

۷- پی‌نوشت‌ها

- 1- Queue
- 2- Discard
- 3- Acknowledgment
- 4- Transport Control Protocol
- 5- Synaptic Plasticity
- 6- Dynamic Synapse
- 7- Depression
- 8- Facilitation
- 9- Off-Set
- 10- Transpose
- 11- Adaptable Weighted PSO
- 12- Tapped Delay Line

۵- نتیجه‌گیری

با توجه به توانایی بالای شبکه عصبی با قابلیت وزن‌های دینامیک‌دار در حافظه‌دار بودن، می‌توان از این شبکه عصبی به منظور پیش‌بینی سری‌های زمانی که دارای دینامیک بالایی هستند، استفاده نمود. همچنین با توجه به نتایج شبیه‌سازی انجام شده، اهمیت حافظه‌دار کردن وزن‌ها در مقایسه با اعمال حافظه در ورودی‌ها برای افزایش دقت پیش‌بینی، نمایان است. در این مقاله از الگوریتم AWPSO برای بهینه‌سازی پارامترهای شبکه عصبی با قابلیت وزن‌های دینامیک‌دار استفاده شد که در آن با وجود پارامتر توانایی جستجوی اساسی در دفعات آخر اجرای برنامه افزایش می‌یابد و نتایج بهتری را در بر خواهد داشت.

۶- مراجع

- [1] Tanenbaum A. S.; **“Computer Networks”**, 3thd ed., Prentice Hall, 813 pages, ISBN-10: 0133499456, ISBN-13: 978-0133499452.
- [2] Box, G.E.P and Jenkins, G. M.; **Time Series Analysis Forecasting and Control**, San Francisco, Holden-Day, 1994.